



Classification of finger movements using statistically significant time-domain EEG features

Mürşide Değirmenci¹, Yılmaz Kemal Yüce², Yalçın İşler^{3*}

¹Department of Biomedical Technologies, Institute of Science, İzmir Katip Çelebi University, 35620, İzmir, Türkiye

²Department of Computer Engineering, Faculty of Engineering, Alanya Alaaddin Keykubat University, 07425, Antalya, Türkiye

³Department of Biomedical Engineering, Faculty of Engineering and Architecture, İzmir Katip Çelebi University, 35620, İzmir, Türkiye

Highlights:

- Using statistically significant features improves classification performance.
- Subject-dependent classification performances ranged from 33.3% to 57.5% for ix movements.
- Classifier performances of subject-dependent cases are higher than those in subject-independent cases.

Keywords:

- Finger movement classification
- Electroencephalogram signals
- Machine learning
- Statistically significance

Article Info:

Research Article

Received: 24.01.2023

Accepted: 24.08.2023

DOI:

10.17341/gazimmfd.1241334

Acknowledgement:

This study was supported by İzmir Katip Çelebi University Scientific Research Projects (BAP) Coordination Unit with the project number 2023-TDR-FEBE-0002 within the scope of Mürşide Değirmenci's doctoral thesis studies.

Correspondence:

Author: Yalçın İşler
e-mail: islerya@yahoo.com
phone: +90 507 701 6050

Graphical/Tabular Abstract

The steps of the study are summarized as a flowchart given in Figure A. In this study, after time-domain features were extracted from EEG signals, statistically significant time-domain features were applied to the classification algorithms to determine which finger movement were imagined by the subject.




Figure A. The graphical representation of this study

Purpose:

The accurate decoding of individual finger movements is pivotal for advanced prosthetic control. In this study, it is aimed to show the effectiveness statistically significant time-domain features based on ANOVA in the classification of EEG signals of finger movements.

Theory and Methods:

We tried to differentiate the finger movements EEG signals from the dataset which is an open-available and large motor imaginary EEG dataset. The time domain features were calculated from 21 channels of EEG signals of 8 healthy subjects. The effectiveness of two different feature selection methods which are statistically significance-based feature selection (ANOVA) and Principal Component Analysis (PCA) were investigated to discriminate five finger movements and no motor imagery task condition (NoMT). The feature vectors which including all time domain features, ANOVA-selected time domain features, PCA-selected time domain features, and both ANOVA- and PCA-selected time-domain features were applied to 8 different classifiers. The proposed approaches were investigated for both subject-dependent and subject-independent conditions.

Results:

The highest classification testing accuracy of 35.8% obtained using ANOVA-selected time-domain features with SVM classifier in subject-independent analysis; whereas, in subject-dependent analysis for 8 subjects, the highest classification testing accuracies achieved between 33.3%-57.5% using ANOVA-selected time-domain features for SVM classifier respectively.

Conclusion:

The results show that the ANOVA-based feature selection method improves the classification performances. The performances of the subject-dependent classifications are higher than the performance of the subject-independent classifications. Therefore, the subject-dependent results of the proposed model have a big potential, which may pave the way for the design of advanced personalized hand prostheses.



İstatistiksel anlamlı zaman alanı EEG özniteliklerinden el parmak hareketlerinin sınıflandırılması

Mürşide Değirmenci¹, Yılmaz Kemal Yüce², Yalçın İşler^{3*}

¹İzmir Katip Çelebi Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Teknolojiler Anabilim Dalı, 35620, Çiğli, İzmir, Türkiye

²Alanya Alaaddin Keykubat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 07425, Alanya, Antalya, Türkiye

³İzmir Katip Çelebi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Biyomedikal Mühendisliği Bölümü, 35620, Çiğli, İzmir, Türkiye

Ö N E Ç İ K A N L A R

- İstatistiksel anlamlı özniteliklerin kullanılması sınıflandırma başarımlarını iyileştirmektedir
- Deneğe bağımlı sınıflandırma başarımları altı hareket için %33,3-%57,5 aralığındadır
- Deneğe bağımlı sınıflandırıcı başarımları denekten bağımsız olanlardan daha yüksek olmaktadır

Makale Bilgileri

Araştırma Makalesi

Geliş: 24.01.2023

Kabul: 24.08.2023

DOI:

10.17341/gazimmfd.1241334

Anahtar Kelimeler:

Parmak hareketi
sınıflandırması,
elektroensefalogram
sinyalleri,
makine öğrenmesi,
istatistiksel anlamlılık

ÖZ

Motor Hayali (MH) görev sınıflandırmasında, parmak hareketlerinin ayırımı zorlaştıran gürültülü sinyal özellikleri nedeniyle parmak hareketi sınıflandırması daha az sıklıkla analiz edilmektedir. Bu çalışma, parmak hareketinin ve hayali görev (NoMT) koşulunun olmadığı durumun sınıflandırılması için istatistiksel olarak anlamlı zaman alanı özniteliklerini araştıran bir yöntem önermektedir. Her zaman MH görevinin yerine getirildiğini varsayan ve NoMT koşulunu göz ardı eden mevcut MH görev sınıflandırma çalışmalarından farklı olarak bu çalışmada daha gerçekçi bir protez tasarımı için NoMT koşulu da değerlendirilmiştir. 8 sağlıklı deneğin 19 EEG kanalından 24 farklı zaman alanı özniteliği çıkarılmaktadır. Önemli zaman alanı özniteliklerini belirlemek için istatistiksel anlamlılığa (ANOVA) dayalı öznitelik seçme yöntemi kullanılmaktadır. Farklı parametrelere sahip sekiz farklı tipik sınıflandırıcı, 5-kat çapraz doğrulama kullanılarak 6 grubu sınıflandırmak için hesaplanmıştır. Denek bağımsız ve denek bağımlı analizlerde ANOVA kullanılarak seçilmiş zaman alanı özellikleri ve Destek Vektör Makinesi (SVM) algoritması kullanılarak en yüksek test doğruluk değeri sırasıyla %35,9 ve %33,3-%57,5 olarak hesaplanmıştır. Çalışma sonucunda, denek-bağımlı sınıflandırmaların performansları denek-bağımsız sınıflandırmaların performansından daha yüksektir. Deneğe bağlı bu en yüksek sonuçlar, gelecek zamanda kişiselleştirilmiş el protezlerinin tasarımı çalışmalarında EEG tabanlı BBA sistemlerinin tasarımı için ümit vericidir.

Classification of finger movements using statistically significant time-domain EEG features

H I G H L I G H T S

- Using statistically significant features improves classification performance
- Subject-dependent classification performances ranged from 33.3% to 57.5% for six movements
- Classifier performances of subject-dependent cases are higher than those in subject-independent cases

Article Info

Research Article

Received: 24.01.2023

Accepted: 24.08.2023

DOI:

10.17341/gazimmfd.1241334

Keywords:

Finger movement
classification,
electroencefalogram
signals, machine learning,
statistically significance

ABSTRACT

In Motor Imagery (MI) task classification, finger movement classification is less frequently analyzed due to their noisy signal characteristic that makes the difficult discrimination of finger movements. This study proposes a method investigating statistically significant time-domain features for classification of finger movement and no imaginary task condition (NoMT). Unlike existing MI task classification studies, which always assume that the MI task is fulfilled and ignore the NoMT condition, this study also evaluated the NoMT condition for a more realistic prosthesis design. The 24 different time-domain features are extracted from 19 EEG channels of 8 subjects. The statistically significance (ANOVA) based feature selection method is used to define significant time-domain features. Eight distinct typical classifiers with different parameters were computed to classify 6 groups using 5-fold cross-validation. In subject-independent and subject-dependent analysis, the highest test accuracy value was calculated as %35,9 and %33.3-%57.5 using ANOVA-selected time-domain features and Support Vector Machine (SVM) algorithm, respectively. As a result of study, the performances of the subject-dependent classifications are higher than the performance of the subject-independent classifications. These highest subject-dependent results are encouraging for the design of the accurate EEG-based BCI systems in future studies on the design of personalized hand prostheses.

1. Giriş (Introduction)

Beyin-Bilgisayar Arayüzleri (BBA), zihinlerimiz ve harici cihazlar arasında doğrudan iletişim yolları sağlar. Günümüzde, engelli bireyler için tasarlanan yardımcı cihaz teknolojilerinde beyin elektrofizyolojik aktivitelerinin doğrudan harici cihazları kontrol etmek için kullanılması önemli çalışmalar arasındadır. Ayrıca, BBA tabanlı el protezleri, el engeli bulunan kişilerin sınırlı hareket kabiliyetinin neden olduğu zorluklarla başa çıkmasına yardımcı olabilir [1]. Maalesef ki, bu kişiler günlük aktivitelerde, sosyalleşmede ve çalışmalarında zorluklar yaşamaktadır. Bu sebeplerden dolayı, son zamanlarda motor hayali elektroensefalografi (EEG) sinyalleri BBA'da yaygın olarak kullanılmaktadır. Motor hayali, vücut uzuv hareketlerinin hayal edilmesi durumunda motor kortekste gerçekleşen elektrofizyolojik bir aktivitedir. Condori ve arkadaşları, el protezlerinin açılıp kapanmasını kontrol etmek için el motor hayali görev sinyallerini kullanmışlardır [2]. Elstob ve Secco, ayrıca başparmak ekstansiyonu ve fleksiyon hareketini ekleyerek motor hayali tabanlı el protez hareketini iyileştirmişlerdir [3]. Ancak, bu protez ellerin tasarımlarında bireysel parmak hareketlerinde hala kısıtlamalar vardır. Bu nedenle, kişilerin yaşamlarında karmaşık görevleri gerçekleştirebilmelerine uygun protez ellerin tasarımı için ek bireysel parmak hareketlerinin doğru çözülmesi gerekmektedir [4].

Motor hayali BBA sistem uygulamaları belirli temel adımlardan oluşmaktadır. Bu aşamalar: sinyallerin elde edilmesi, ön işleme (filtreleme, sinyallerin bölütlenmesi vb.), öznitelik çıkarma, öznitelik seçimi, sınıflandırma ve kontrol arayüzü. Bu aşamalar arasında her aşamanın kendi önemi olmakla birlikte, öznitelik çıkarımı, öznitelik seçimi ve sınıflandırma aşamaları BBA sisteminde EEG sinyallerinin doğru çözülmesi görevinin yürütülmesinde önemli rol oynamaktadır. Bu yüzden, çalışmalarda sistemlerin bu adımlarında etkili yöntemler kullanılarak tasarlanmalıdır.

Kaya ve arkadaşları, 2018 yılında EEG tabanlı BBA çalışmaları için büyük boyutlu EEG motor hayali veri setini literatüre kazandırdılar [5]. Online erişime açık olan en büyük motor hayali veri setlerinden biri olan bu veri setinde 10 farklı motor hayali görev mevcuttur. Bu görevlerden 5'i el hareketlerinin hayalidir, diğerleri ise bir elin 5 parmağının hareketlerinin hayalidir. Fazla sayıda EEG sinyallerinin parmak hareketi motor hayali görevleri için kaydedilmesiyle, literatürde EEG sinyallerinden parmak hareketlerinin sınıflandırılmasına yönelik çeşitli makine öğrenmesi tabanlı yaklaşımları yer almaya başlamıştır. Kaya ve arkadaşları önermiş oldukları veri setiyle aynı zamanda Destek Vektör Makinesi (SVM) tabanlı sınıflandırma çalışması gerçekleştirmişlerdir [5]. 19 kanallı EEG sinyallerinin öznitelik gösterimleri için Güç Spektral Yoğunluğu (PSD), EEG bantlarının gücü, Fourier Dönüşümü (FT) genlikleri ve EEG zaman serileri kullanılmıştır. Önermiş oldukları çalışmayla, bir elin beş parmak hareketinin sınıflandırılmasında tüm deneklerin kullanıldığı durumda %43,0 ortalama doğruluk başarımı elde edilmiştir. Aynı zamanda deneğe bağımlı sınıflandırma çalışması da yürütülmüştür ve 8 kişinin başarımları %20,0-%60,0 aralığında yer almıştır. Başka bir çalışmada [6], 4 kişinin EEG sinyalleri kullanılarak deneğe bağımlı 5 parmak hareketi sınıflandırılmaya çalışılmıştır. Bu doğrultuda, Ortak Uzamsal Model (CSP) tabanlı öznitelik çıkarma işlemi kullanılmıştır ve bu öznitelikler Rasgele Orman (RF) algoritması ile sınıflandırılmıştır. Sonuçlara göre, her denekte %100 eğitim doğruluk başarısı elde edilmiştir ve test doğruluk başarımları %51,0-%56,0 aralığında değişmiştir. Azizah ve arkadaşları [7], CSP yönteminin farklı bir türevini (CSP- OVR) kullanarak kanal seçimi yapmışlardır ve 19 kanaldan 4 tanesini seçerek spektrogram özniteliklerini çıkarmışlardır. SVM ile gerçekleştirdikleri sınıflandırmalarda denek-bağımlı %21,2-%66,6 aralığında değişmiştir. Bir diğer çalışmada, Kato ve arkadaşları [8], 19 kanallı

EEG sinyallerinde, Çok-sınıflı CSP (Multi-class CSP), kompleks Fourier genlikleri (Complex Fourier amplitudes) öznitelikleriyle çalışmışlardır. Denek-bağımlı analizlerinde, SVM algoritmasıyla yaptıkları sınıflandırmaların eğitim başarımları %23,9-%58,3 aralığında rapor edilmiştir.

Son zamanlarda makine öğrenmesi yöntemlerinden derin öğrenme yaklaşımları medikal görüntülerden hastalık tespiti [9], biyolojik sinyallerden duyu durumu analizi [10] ve Elektrokardiyografi (EKG) aritmi tespiti [11] gibi çok farklı çalışmalarda araştırmacılar tarafından ilgi odağı olmuştur. Bunun temel nedeni, derin öğrenme yapılarının gizli katmanlarında öznitelik çıkarma ve sınıflandırma aşamalarının birlikte gerçekleştirilebiliyor olmasıdır. Literatürde, parmak hareketleri motor hayali görevlerinin sınıflandırılması için de derin öğrenme yaklaşımlarına yer verilmiştir. Yapılan bir çalışmada Mwato-Velu ve arkadaşları [12], Görgül Kip Ayrışımı (EMD) tabanlı bir öznitelik çıkarma işlemini, 19 EEG kanalından 4 etkili EEG kanalını seçerek gerçekleştirmişlerdir. Derin öğrenme (BiLSTM) tabanlı deneğe bağımlı sınıflandırmalar gerçekleştirmişlerdir. Gerçekleştirilen sınıflandırmalarda 8 denekte eğitim başarımları %73,47-%98,69 aralığında, test başarımları ise %66,0-%76,13 aralığında hesaplanmıştır. Mwato-Velu ve arkadaşlarının gerçekleştirmiş olduğu bir başka çalışmada [13], EEG zaman serilerini derin öğrenme (EEGNet) yapısıyla sınıflandırmayı amaçlamışlardır. 8 deneğin mevcut olduğu veri setinden 4 deneğin verileri kullanılmıştır ve aynı zamanda 19 EEG kanalından 4'ü seçilmiştir. 4 kişi ile gerçekleştirilen deneğe bağımlı analizlerde eğitim başarımları, %80,1-%91,7 aralığında rapor edilmiştir. Bir diğer çalışmada [14], CSP algoritması kullanılarak öznitelikler çıkarılmıştır ve otonom derin öğrenme (ADL) yaklaşımıyla sınıflandırmaya çalışılmıştır. Yine 4 deneğin 19 kanallı EEG sinyalleri kullanılmıştır ve yapılan denek-bağımlı değerlendirmelerde eğitim başarımları %74,73-%77,61 aralığında, test başarımları ise %74,61-%77,75 aralığında değişim göstermiştir. Son olarak, Zahra ve arkadaşları [15], Evrişimli Sinir Ağları (CNN) tabanlı bir yaklaşımla 5 parmak hareketinin motor hayali görevlerini sınıflandırmaya çalışmışlardır. Öznitelik çıkarma aşamasında, EEG zaman serilerinin pencereleme (sliding window) ve gürültü ekleme (noise addition) yöntemleriyle kombine edildiği bir yaklaşım kullanılmışlardır. Bu doğrultuda, 8 deneğin 19 kanallı EEG sinyalleri kullanılmıştır. Sınıflandırma aşamasında deneğe bağımsız bir eğitim süreci gerçekleştirilerek, eğitim başarımları %57,5 olarak hesaplanmıştır.

Yukarıdaki bir elin parmak hareketlerinin motor hayali görevlerini sınıflandırılmasını amaçlayan çalışmalar incelendiğinde, tüm kanalların kullanıldığı ve kişiye bağımsız sınıflandırma çalışmalarında başarımların düşük değerlerde kaldığı gözlemlenmiştir. Kanal seçimi ve kişiye bağımlı sınıflandırmalar ile başarımların daha yüksek oranlara çıktığı görülmektedir. Parmak hareketlerinin sınıflandırılmasında başarımların düşük seviyelerde kalmasının sebebi bir eldeki parmaklarının hareketlerinin aslında motor korteksin aynı bölgesinden kontrol edilmesi olabilir [5]. Kaya ve arkadaşları diğer vücut uzuv hareketlerinin motor hayali görevlerinin ve parmak hareketlerinin motor hayali görevlerinin olayla ilgili potansiyel (ERP) eğrilerini incelemişlerdir. Yaptıkları analizler ile parmak hareketlerinin motor hayali görevlerinde eğrilerin açıkça ayırtılamadığını rapor etmişlerdir [5]. Sonuç olarak, parmak hareketlerinin motor hayali görevlerinin sınıflandırılmasında etkili öznitelik çıkarma yöntemleri, öznitelik seçme metodları ve sınıflandırma algoritmalarının kullanılarak sınıflandırma başarımlarının artırılmasına ihtiyaç vardır.

Bu çalışmada, parmak hareketlerinin motor hayali görevlerinin sınıflandırılması için, 19 kanallı EEG sinyallerinden elde edilen 24 farklı zaman alanı özniteliklerinin iki farklı öznitelik seçme

yöntemiyle 4 farklı durumu üzerinde analizler gerçekleştirilmesi planlanmaktadır. Öznitelik seçme aşamasında, istatistiksel anlamlılığa dayalı öznitelik seçme yöntemi ve Temel Bileşen Analizi (TBA) yönteminin kullanılması hedeflenmiştir. Sınıflandırma aşamasında 7 farklı temel sınıflandırıcının farklı parametrelerine göre tasarlanmış olan 27 farklı algoritma ile eğitim ve test süreçlerinin gerçekleştirilmesi hedeflenmiştir. Var olan motor hayali görev sınıflandırma çalışmaları hep motor hayali görevin gerçekleştirildiğini düşünüp hiçbir motor hayali görevin gerçekleştirilmediği durumu (NoMT) yok saymaktadır ve sınıflandırma aşamasına NoMT durumu dahil etmemektedirler. Bu çalışmada diğer çalışmaların aksine, beş parmak hareketinin motor hayali görevlerine NoMT durum da dahil edilerek 6 sınıflı bir çalışma gerçekleştirilmiştir. Çalışmada hem deneğe-bağımlı hem de deneğe-bağımsız sınıflandırmaların gerçekleştirilmesi ve sınıflandırma performansların karşılaştırılması planlanmaktadır.

2. Materyal ve Yöntem (Material and Method)

Bu çalışmada parmak hareketlerinin motor hayali görev EEG sinyalleri ve motor hayali görev gerçekleştirilmediği (NoMT) durumun EEG sinyallerinin önışlemlerden geçirilmesi, özniteliklerin çıkarılması, farklı yöntemlerle öznitelik seçimi ve son olarak çeşitli makine öğrenmesi algoritmalarıyla 6 farklı sınıfın ayrılması üzerine çalışılmıştır. Önerilen yöntem hem denek-bağımlı hem denek-bağımsız olarak incelenmiştir. Şekil 1'de ise önerilen çalışmanın şeması kullanılan algoritmalar ile gösterilmeye çalışılmıştır.

2.1. Veri Seti (Data Set)

Bu çalışmada, Kaya ve arkadaşları tarafından sunulan motor hayali EEG veri seti kullanılmıştır. 8 sağlıklı denekten 19 kanallı EEG sinyalleri kaydedilmiştir [5]. 19 EEG elektrotu, 2 referans elektrotu ve toprak elektrotu uluslararası 10/20 EEG elektrot dizilimine göre yerleştirilmiştir. Kaya ve diğerleri, EEG-1200 JE-912A sistemini kullanarak EEG sinyallerini kaydetmişlerdir ve 10 farklı vücut uzvunun hareketlerine dayalı bireysel bir motor hayali deneyi gerçekleştirmişlerdir. Deney süreci 4 farklı paradigma şeklinde planlanmıştır. Paradigma 1, klasik (CLA) paradimasıdır, sağ el ve sol elin hareketlerinin motor hayali görevlerini ve herhangi bir görevin olmadığı pasif durumu içermektedir. Paradigma 2 (HaLT), 3 durumlu CLA paradimasının sağ ve sol ayağın hareketinin ve dil hareketinin motor hayali görevleriyle genişletilmiş halidir. Paradigma 3 (5F), bir elin beş parmak hareketinin motor hayali görevlerini içermektedir. Denekler 5 farklı parmak için verilen görevler sırasında ilgili parmağın aşağıya ve yukarıya olacak şekilde büküldüğünü hayal etmişlerdir. Parmak hareketleri şu şekilde kodlanmıştır: başparmak (Thumb, sınıf 1), işaret parmağı (Index finger, sınıf 2), orta parmak (Middle finger, sınıf3), yüzük parmağı (Ring finger, sınıf 4) ve serçe parmak (Pinkie finger, sınıf 5). Paradigma 4 (NoMT), deneklere herhangi görsel bir uyarının gönderilmediği, pasif bir şekilde bilgisayar ekranını izledikleri durumdur. Biz bu çalışmada 5F ve NoMT paradigmalarını kullanarak 6 sınıflı bir sınıflandırma yapmayı amaçladık. Kayıtlar alınırken, her motor hayali görev 1 s boyunca aksiyon sinyali ilgili motor hayali görevi uygulayabilmesi için ekranda kalmıştır. Verilen sürenin sonunda görev gösterimi ekrandan kalkıp yerine 1.5-2.5 s boyunca bir sonraki göreve kadar ara verilmiştir. Bu veri setinde 200 Hz ve 1000 Hz olacak şekilde iki farklı örnekleme frekansı belirlenmiştir. Bu çalışmada 1000 Hz örnekleme frekansı ile kaydedilen EEG sinyalleriyle çalışılmıştır. 1000 Hz'lik EEG kayıtlarına 53-100 Hz bant geçiren filtre uygulanmıştır. Ek olarak, elektrik şebekesi arayüzünü azaltmak için 50 Hz çentik filtre uygulanmıştır. Öznitelik çıkarma ve diğer adımları uygulamadan önce, bu çalışmanın önışleme aşamasında 5F ve NoMT paradigmalarının 1000 Hz'lik EEG sinyalleri 1000 örnekleme olacak şekilde bölütlenmiştir. Sınıflar arasında dengeli bir dağılım olması için, her bir sınıf için 100 deney ile çalışılmıştır. Sonuç olarak bir denek için 600 deney mevcuttur.


2.2. Öznitelik Çıkarma (Feature Extraction)

Öznitelik çıkarma aşamasında, motor hayali EEG sinyallerinin öznitelikler ile doğru bir şekilde temsil edilmesi BBA sistemlerin motor hayali görevleri birbirinden ayırmasında başarıyı etkileyen en önemli faktörlerden biridir. Bu çalışmada motor hayali görevlerin gerçekleştirildiği 1000 örnekleme içeren ilgili EEG bölütleri ayrıştırıldıktan sonra, zaman alanı öznitelikleri ile çalışılmıştır. EEG sinyallerinin genliğine (örneğin ortalama genlik değişim değeri, karekök ortalama, çeyrekler arası, aralık vb.) ve istatistiksel (örneğin ortalama, varyans, çarpıklık ve basıklık vb.) değişimlerine dayalı farklı öznitelikler hesaplanmıştır [16, 17]. Bu çalışma için önerilen zaman alanı öznitelikleri Şekil 1'de detaylı bir şekilde belirtilmiştir. Böylece, 19 EEG kanalının her biri için 24 farklı öznitelik çıkarılarak, toplamda 504 öznitelik 600 örnekten oluşan veri setleri 8 denek için ayrı ayrı oluşturulmuştur. Oluşturulan 8 farklı veri seti denek-bağımlı sınıflandırmalar için kullanılacaktır. İkinci bir sınıflandırma olan denek-bağımsız analizler için de tüm deneklerin verilerinin mevcut olduğu 7800 örnekleme 504 öznitelik içeren veri seti elde edilmiştir.

2.3. Öznitelik Seçimi (Feature Selection)

Öznitelik seçimi, öznitelik boyutunun azaltılması olarak bilinen güçlü öğrenme modellerinin oluşturabilmesi için ilgili özniteliklerden oluşan alt öznitelik kümelerini belirlemeyi amaçlayan BBA sistem tasarımıda önemli bir aşamadır. Tüm özniteliklerinin bir arada kullanılması sınıflandırıcı karmaşıklığını artırmaktadır ve bazı durumlarda düşük sınıflandırma başarımlarına sebep olmaktadır [16, 18-21]. Öznitelik seçimi, öznitelik kümesinden ilgisi olmayan ve gereksiz öznitelikleri kaldırarak, boyutluluğun lanetinin etkisini hafifleterek modelin öğrenme sürecinin ve anlaşılabilirliğinin iyileştirilmesini hedefler [17]. Böylece, sınıflandırma modelinin performansının iyileştirilmesine yardımcı olur. Bu çalışmada, motor hayali görevler arasında en iyi ayrımı sağlayan zaman alanı özniteliklerinin kombinasyonunun belirlenebilmesi için, literatürde de kullanılan istatistiksel anlamlılığa dayalı öznitelik seçimi [16, 19, 20] ve TBA [22, 23] yöntemlerinin etkisi araştırılmıştır. İlk olarak zaman alanı özniteliklerin seçilmesinde istatistiksel anlamlılığa dayalı öznitelik seçiminin etkisi araştırılmıştır. Sınıflandırılmak istenen grup sayısına göre çalışılacak olan istatistiksel anlamlılık testi belirlenmektedir [16]. Bu çalışmada, 6 farklı motor hayali görevin sınıflandırılması üzerinde çalışıldığı için tek yönlü varyans analizi (ANOVA testi) kullanılmıştır. 504 farklı zaman alanı özniteliklerinin motor hayali görevlerinin ayrılması üzerindeki istatistiksel olarak anlamlılığı ayrı ayrı incelenmiştir. İstatistiksel anlamlılığı analiz etmek için her öznitelik için p değeri ANOVA testiyle belirlenmiştir. Daha sonrasında p değeri %5 olan istatistiksel anlamlılığı sağlayan öznitelikler belirlenip, istatistiksel anlamlı zaman alanı özniteliklerinden oluşan veri setleri belirlenmiştir. Seçilen özniteliklerden oluşan öznitelik kümeleri sınıflandırıcılara giriş verisi uygulanmıştır ve istatistiksel anlamlılığın dayalı öznitelik seçiminin sınıflandırıcı performansı üzerindeki etkisi değerlendirilmiştir.

Bu çalışmada, önermiş olduğumuz istatistiksel anlamlılığa dayalı öznitelik seçiminin etkinliğini daha iyi analiz edebilmek için, literatürde de sıklıkla kullanılmakta olan TBA tabanlı öznitelik seçimine dayalı analizler de gerçekleştirilmiştir. TBA'nın temel amacı, çok sayıda mevcut bilgiyi içeren bir veri kümesinin boyutunu azaltmaktır. TBA sınıflandırma aşamasında önerilen modelin karmaşıklığını azaltır ve hesaplama verimliliğini artırır. TBA, verilerin boyutunu azaltan denetimsiz bir öğrenme tekniğidir ve makine öğrenmesi yaklaşımlarında kullanılmaktadır [24]. Bu, temel bileşen (PC) olarak adlandırılan yeni bir değişken grubuna dönüştürülerek uygulanabilir. Öncelikle, öznitelikler standartlaştırarak kovaryans matrisleri hesaplanmaktadır ve bu kovaryans matrislerinin özdeğerleri ve özvektörleri hesaplanarak özniteliklerin boyutu azaltılmaktadır [25]. Toplam değişimin yeni değişkenlerde hangi oranda göz ardı edileceği önceden belirlenmektedir [23], bu çalışmada da bu oran %5



Şekil 1. Çalışmanın akış şeması (The flowchart of the work.)

olarak belirlenmiştir. Bu da değişimdeki artış %5'in altına düşüncüye kadar temel bileşen araştırılmasına devam edileceği anlamına gelmektedir. Böylece, özellikler seçilerek özellik vektörünün boyutu azaltılmaktadır. Bu çalışmada, TBA ile tüm özellikler üzerinden özellik seçimi gerçekleştirildiği gibi ANOVA ile belirlenen özelliklere de TBA ile özellik seçimi uygulanmaktadır. ANOVA ve TBA birlikte uygulandığı durumun etkinliği de araştırılmak istenmiştir.

2.4. Sınıflandırma (Classification)

Bu çalışmada, zaman alanı özellikleri kullanılarak 5 parmak hareketinin motor hayali görevleri ve NoMT durum sınıflandırılmaya çalışılmıştır. Çalışmada hem denek-bağımlı ve denek-bağımsız durumlar için hem de 4 farklı yaklaşım için sınıflandırma süreçleri ayrı ayrı gerçekleştirilmiştir. Özellik vektörleri 7 temel sınıflandırıcı ile sınıflandırılmıştır [21]. Bunlar: Karar Ağaçları (Decision Trees),

Naive Bayes (Naive Bayes), Destek Vektör Makineleri (SVM), k en Yakın Komşu (k-Nearest Neighbours), Ayırma Analizi (Discriminant Analysis), Topluluk Öğrenmesi (Ensemble Learning), ve Sinir Ağları sınıflandırıcıları (NN) [17, 19, 26-29]. Bu çalışmada bu 7 temel sınıflandırıcı altında geliştirilmiş olan toplamda 27 farklı makine öğrenmesi algoritmasıyla çalışılmıştır [17, 26].

2.4.1. Karar Ağaçları (Decision Trees)

Karar Ağacı (DT), verileri birkaç farklı alt gruba ayırabilen ve regresyon işlemi dışında sınıflandırma için de kullanılabilen makine öğrenmesi algoritmasıdır. Dalları ve düğümleri içeren bu algoritmanın karakteristik ağaç benzeri yapısı, algoritmanın adını verir [32]. Eğitim süreci, bir takım karar kurallarının öğrenilmesine dayalı olarak gerçekleştirilir. Karar verildiğinde yaprak düğüm, karar kesin olmadığında diğer dal olan karar düğümü oluşturulur [30, 31]. DT tabanlı sınıflandırma sürecinde, bu çalışma için DT altında geliştirilmiş olan İnce (Fine), Orta (Medium) ve Kaba (Coarse) algoritmaları kullanılmaktadır.

2.4.2. Naive Bayes (Naive Bayes)

Naive Bayes marjinal ve koşullu olasılıklar arasındaki ilişkiyi ilişkilendiren olasılığa dayalı Bayes teoremini kullanan bir sınıflandırma algoritmasıdır [21]. Algoritmanın çalışma prensibinde tüm öznitelikler bağımsız kabul edilir ve bu da 'Naive' adının kullanılmasının sebebidir. Yani tüm öznitelikler sınıflandırma üzerinde aynı etki değerine sahiptir, bu da eğitim sürecinde özniteliklerin her birinin eşit ağırlığa sahip olduğu anlamına gelir [30]. Gerçekçi olmayan yaklaşımıyla oluşturulan basit hesaplama mekanizması nedeniyle makine öğrenimi yaklaşımlarında sıklıkla tercih edilen bir algoritmadır [16, 17, 31]. Naive Bayes sınıflandırıcısının altında geliştirilmiş olan Çekirdek (Kernel) algoritması bu çalışma için kullanılmaktadır.

2.4.3. Destek Vektör Makineleri (Support Vector Machines)

SVM, girdi verilerinin geometrik özelliklerini kullanan, olasılıksal olmayan bir yaklaşım olan, iyi bilinen bir denetimli öğrenme algoritmasıdır. Daha çok hem sınıflandırma hem de regresyon çalışmalarında kullanılmaktadır. N boyutlu uzay, koordinat sistemlerinin elemanları kullanılarak oluşturulur. Bu elemanlar, n özniteliklerini içeren verilerden oluşur. Girdi verilerini farklı sınıflara ayırmak için 'hiper düzlem' olarak adlandırılan karar sınırları oluşturulur. Süreçteki farklı sınıfları birbirinden ayırt etmek için birçok hiper düzlem tanımlanabilir de daha doğru sınıflandırma sağlamak için farklı sınıfları en iyi ayıran optimum hiper düzlem belirlenmelidir. Farklı sınıf kategorilerine ait 'destek vektörleri' arasındaki mesafe 'marjın' olarak tanımlanır. Bu algoritmada maksimum marjın sağlanması kritik bir noktadır. Hiper düzlemin farklı bölümlerine yerleştirilen veriler, farklı bir sınıfın bileşeni olarak gösterilmektedir [21, 32, 33]. Çalışmada, SVM altında geliştirilmiş olan Doğrusal (Linear), Kuadratik (Quadratik), Kübik (Cubic), İnce Gauss (Fine Gaussian), Orta Gauss (Medium Gaussian), Kaba Gauss (Coarse Gaussian) algoritmalarıyla sınıflandırmalar gerçekleştirilmiştir.

2.4.4. k en Yakın Komşu (k-Nearest Neighbour)

k en Yakın Komşu (k-NN), sınıflandırma ve regresyon süreçlerinde çoğunlukla tercih edilen başarılı bir makine öğrenmesi algoritmasıdır. Öğrenme işlemi, bu algoritmada verilere dayalı olarak gerçekleştirilir. İlk adım olarak, tahmin edilecek örnek ile eğitim setindeki tüm girdi verileri arasındaki mesafe hesaplanır. Daha sonra, k-en yakın komşular arasından minimum mesafeyi sağlayanlar belirlenir [18, 30]. Sonuç olarak, yeni örneğin sınıfı, bu k-En Yakın Komşular arasında en yaygın sınıf olarak belirlenir. Mesafelerin hesaplanması 'Öklid', 'Manhattan',

'Minkowski' ve 'Hamming' gibi farklı mesafe ölçüm yöntemleri kullanılarak yapılabilmektedir [21]. Bu çalışmada, k-NN sınıflandırıcının İnce (Fine), Orta (Medium), Kaba (Coarse), Kübik (Cubic), Kosinüs (Cosine), Ağırlıklı (Weighted) algoritmaları sınıflandırma sürecinde kullanılmıştır. 'Öklid' mesafe ölçme yöntemi en çok tercih edilen uzaklık hesaplama yöntemlerinden biridir [18, 19, 31]. Bu çalışmada, İnce, Orta, Kaba ve Ağırlıklı k-NN algoritmalarında da mesafe ölçümü için Öklid seçilmiştir. Ayrıca, çalışmada Kübik ve Kosinüs k-NN algoritmalarında sırasıyla 'Kübik' ve 'Kosinüs' mesafe ölçüm yöntemleri kullanılmıştır. Eğitim işlemi için k değeri İnce algoritmasında 1, Orta, Kübik, Kosinüs ve Ağırlıklı algoritmalarında 10 ve Kaba algoritmasında 100 olarak tanımlanır.

2.4.5. Ayırma Analizi (Discriminant Analysis)

Ayırma analizi sınıflandırıcısı örüntü tanıma yöntemlerinden biridir ve asıl amacı verideki bağımsız değişkenleri doğru bir şekilde homojen gruplara ayırmaktır [34, 35]. Bu çalışmada, ayırma analizinden hem Doğrusal hem de Kuadratik algoritmalar kullanılarak sınıflandırma yapılmıştır. Bu sınıflandırıcılardan Doğrusal Ayırma Analizi (Linear Discriminant Analysis), grup elemanlarını belirler ve her bir elemanın farklı gruplara ait olma olasılığını hesaplar. Daha sonra eleman en yüksek olasılık puanına sahip gruba atanır. LDA tahmin edicilerin normal dağıldığını varsayar (Gauss dağılımı). Ayrıca, farklı sınıfların sınıfa özgü öğelere ve eşit varyansa/kovaryansa sahip olduğunu varsayan doğrusal bir ayırım fonksiyonu oluşturur.

2.4.6. Topluluk Öğrenmesi (Ensemble Learning)

Toplulukla Öğrenmesi sınıflandırıcısı, varyansı (torbalama), yanlışlığı (artırma) azaltmak ve/veya tahminleri (istifleme) iyileştirmek için birden çok makine öğrenimi tekniğini tek bir tahmin modelinde (sınıflandırıcı) birleştiren meta algoritmalarlardır. Topluluk Öğrenmesi algoritmaları genellikle tek bir sınıflandırıcının olası gücünü, örtüşen veri dağılımları ve verilerdeki aykırı değerler nedeniyle kesin ve belirli sınıflandırma doğruluğuna ulaşamayacağını varsayar. Dolayısıyla bu algoritmalar, her sınıflandırma problemi için en iyi çalışan tek bir model (sınıflandırıcı) olmadığını varsayar [36]. Bu nedenle Topluluk Öğrenmesi yöntemleri, sınıflandırma işlemleri için önemli algoritmalarlardır. Önerilen çalışmada, Topluluk Öğrenmesi sınıflandırıcıları altında geliştirilen Yükseltmiş Ağaçlar (Boosted Trees), Torbalama Ağaçlar (Bagged Trees), Altuzay Ayırma (Subspace Discriminant), Altuzay k en Yakın Komşu (Subspace k-NN) ve RUS-Yükseltilmiş Ağaçlar (RUSBoosted Trees) algoritmaları test edilmiştir. Öğrenme sayısı (number of learners) Topluluk Öğrenmesi altında geliştirilmiş olan tüm algoritmaları için 30 olarak belirlenmiştir. Ayrıca öğrenme oranı (learning rate) Yükseltilmiş Ağaçlar ve RUS-Yükseltilmiş Ağaçlar için 0,1 olarak belirlenmiştir.

2.4.7. Sinir Ağları Sınıflandırıcıları (Neural Networks Classifiers)

Sinir ağı (NN) sınıflandırma modelleri tipik olarak iyi tahmin doğruluğuna sahiptirler ve çok sınıflı sınıflandırma için de ikili sınıflandırmalar için de kullanılabilirler. Diğer sınıflandırıcı türlerine göre eğitim aşaması, yapılarındaki katman sayıları ve daha birçok parametre sebebiyle daha uzundur [10, 11]. NN modelleri, temel olarak giriş katmanı (input layer), tam bağlantılı katmanları (fully connected layers) ve çıkış katmanı (output layer) olacak şekilde 3 karakteristik yapıdan oluşmaktadır. Farklı modellerinde aradaki tam bağlantılı katmanların sayıları değişmektedir. Sinir ağına ilk tam bağlantılı katmanı, ağ girişinden (tahmin edici veriler) bir bağlantıya sahiptir ve sonraki her katman, önceki katmandan bir bağlantıya sahiptir. Tam bağlantılı her katman, girişi bir ağırlık (weight) matrisi ile çarpar ve ardından bir sapma vektörü (bias) ekler. Tam bağlantılı her katmanı bir aktivasyon fonksiyonu takip eder. Nihai son tam bağlantılı katman ve sonraki softmax aktivasyon fonksiyonu, ağına

çıktısını (output), yani sınıflandırma puanlarını (sonraki olasılıklar) ve tahmin edilen etiketleri (prediction labels) üretir [9, 27, 28]. Model karmaşıklığı, sinir ağındaki tamamen bağlı katmanların boyutu ve sayısı ile artar [10, 11]. Bu çalışmada, NN sınıflandırıcıları altında geliştirilen Dar (Narrow), Orta (Medium), Geniş (Wide), İki Katmanlı (Bilayered) ve Üç Katmanlı (Trilayered) algoritmalar ile sınıflandırmalar yapılmıştır. Öğrenme oranı, moment oranı (moment rate) ve tam bağlantılı katmanlarındaki aktivasyon fonksiyonu tüm algoritmaların test süreci için sırasıyla 0,0001, 0,9 ve ReLU olarak belirlenmiştir. Maksimum iterasyon sayısı 1000 ile kısıtlanmıştır. Dar NN, Orta NN ve Geniş NN algoritmalarında 1 tam bağlantılı katmanı vardır ve katman boyutu sırasıyla 10, 25 ve 100 olarak belirlenmiştir. İki katmanlı NN ve Üç Katmanlı NN algoritmalarında sırasıyla 2 ve 3 tam bağlantılı katmanı vardır ve tüm katmanların boyutu 10 olarak ayarlanmıştır.

2.5. Performans Ölçümü (Performance Measurement)

Sınıflandırma aşamasında eğitim ve test verilerini belirlemek için k-kat çapraz doğrulama yönteminden faydalanılmıştır. Şekil 2, önerilen k-kat çapraz doğrulama yöntemine dayalı performans değerlendirilmesini ifade etmektedir. Öncelikle, ilgili veri seti rasgele olacak şekilde ikiye ayrılmıştır. Öznitelik veri setinin %80'i eğitim verisi olarak ayrılmıştır ve bu kısım sınıflandırıcının model parametrelerini belirlemesi için kullanılmıştır, geriye kalan %20'si ise test verisi olarak ayrılmıştır ve eğitim aşamasından sonra sınıflandırıcı performansını test etmek için kullanılmıştır. Belirlenen eğitim verisinde eğitim aşaması 5-kat çapraz doğrulama yöntemine dayalı gerçekleştirilmiştir. Bu yöntemle eğitim seti 5 eşit parçaya ayrılmıştır ve bunlardan 4'ü eğitim 1'i doğrulama için kullanılmıştır. Böylece sınıflandırıcı 5 defa eğitilmiştir ve her defasında doğrulama verisi farklı alınmıştır. Sınıflandırıcının eğitim performansı 5 tekrarlı eğitimin ortalama doğrulama performans değerine dayalı hesaplanmaktadır.


Sınıflandırıcı performanslarının ölçülmesinde Doğruluk (Accuracy) tabanlı performans değerlendirme ölçümlerinden faydalanılmıştır. Doğruluk değerleri eğitim ve test sonunda elde edile karmaşıklık matrisi üzerinden hesaplanmaktadır [21]. Karmaşıklık matrisi, doğru pozitiflerin (TP), gerçek negatiflerin (TN), yanlış pozitiflerin (FP), yanlış negatiflerin (FN) sayısını ifade etmek için kullanılmıştır ve aynı zamanda eğitim ve test verisinin boyutunu etmek ifade etmek için de kullanılmaktadır [21]. Karmaşıklık matrislerinin elde edilmesinden sonra Eş. 1'i kullanarak sınıflandırıcıların doğruluk performansları hesaplanmıştır [18, 21].

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Burada, FP aslında farklı bir sınıfta bulunup sınıflandırıcı tarafından yanlışlıkla gerçek sınıfa atanan örnek sayısını, FN ise aslında gerçek sınıfta bulunup sınıflandırıcı tarafından yanlışlıkla farklı sınıfa atanan örnek sayısı ifade eder. TP gerçek sınıfta bulunup sınıflandırıcı tarafından doğru bir şekilde aynı sınıfa atanan örnek sayısını, TN ise farklı sınıfta bulunup sınıflandırıcı tarafından doğru tahmin edilen örnek sayısını ifade etmektedir [11, 18, 37].

3. Deneysel Sonuçlar ve Tartışma (Experimental Results and Discussion)

Bu çalışmada, farklı parmak hareketlerinin motor hayali görevlerinin sınıflandırılması için motor hayali EEG sinyallerinden zaman alanı özniteliklerinin çıkarılması ve farklı öznitelik seçme yöntemlerinin bu öznitelikler ile etkinliğinin araştırılmasına yönelik bir çalışma tasarlanmıştır. Önerilen çalışmanın uygulanması için, EEG sinyallerin bölütlenmesi, özniteliklerin çıkarılması, öznitelik seçimi ve sınıflandırma aşamaları MATLAB uygulaması ile gerçekleştirilmiştir.



Şekil 2. 5-kat çapraz doğrulama yöntemine dayalı performans değerlendirilmesi (Performance evaluation based on 5-fold cross validation method.)

EEG sinyalleri, Kaya ve arkadaşlarının önermiş olduğu büyük motor hayali EEG veri setinden elde edilmiştir. Bu veri setinden, bir elin 5 farklı parmak hareketinin motor hayali görevleri (5F) ve deneklere herhangi görsel bir uyarının gönderilmediği, pasif bir şekilde bilgisayar ekranını izledikleri durum (NoMT) için kaydedilen 8 deneğin 19 kanallı EEG sinyalleri ile çalışılmıştır. Öncelikle tüm EEG sinyalleri 1000 örneklem içerecek şekilde bölütlenmiştir ve sınıflar arasında dengeli bir veri dağılımı sağlayabilmek için her sınıfta 100 EEG sinyali ile çalışılmıştır. Sonra bölütlenmiş olan bu EEG sinyallerinin 19 kanalından 24 farklı zaman alanı özneteliği çıkarılmıştır. Öznetelik seçme aşamasında, ANOVA ve TBA yöntemleri önerilmiştir. Tablo 1’de tüm özneteliklerin bulunduğu durum için veri boyutu, eğitim ve test verilerinin boyutu, ANOVA tabanlı öznetelik seçimiyle belirlenen anlamlı öznetelik sayısı ve TBA ile belirlenen temel bileşen sayısı hem denek-bağımlı hem de denek-bağımsız durumlar için ayrı ayrı verilmiştir. Bu çalışmada ANOVA ile anlamlı olarak belirlenen özneteliklerin TBA ile tekrardan öznetelik seçimiyle temel bileşenlerin belirlenip bu öznetelik grubunun da etkisi araştırılmıştır. Bu durum için de belirlenen öznetelik sayıları yine Tablo 1’de belirtilmiştir. Sonuç olarak denek-bağımlı ve denek-bağımsız analizler için 4 farklı paradigma ile çalışılmıştır. “Paradigma 1” tüm zaman alanı özneteliklerin kullanıldığı sınıflandırmaları, “Paradigma 2” TBA ile belirlenen temel zaman alanı öznetelikleri bileşenlerinin kullanıldığı sınıflandırmaları, “Paradigma 3” ANOVA ile belirlenen istatistiksel anlamlı zaman alanı özneteliklerinin kullanıldığı sınıflandırmaları ve “Paradigma 4” ise ANOVA ile belirlenen özneteliklerden TBA ile belirlenen temel zaman alanı bileşenlerinin kullanıldığı sınıflandırmaları ifade etmektedir. Bu dört farklı paradigma için sınıflandırmalar ayrı ayrı hem denek-bağımlı hem de denek-bağımsız durumlar için ayrı ayrı gerçekleştirilmiştir. Sınıflandırma aşamasında 7 farklı temel sınıflandırıcının altında farklı parametrelere göre geliştirilen 27 farklı makine öğrenmesi algoritması ile çalışılmıştır. Eğitim ve test veri gruplarının oluşturulmasında rasgele bölme (random split) yönteminden faydalanılmıştır, öznetelik vektörlerinin %80’i eğitim, %20’si ise modelin test aşamasında kullanılmıştır, vektörlerin boyutları Tablo 1’de belirtilmiştir. Ayrıca, eğitim aşamasında 5-kat çapraz doğrulama yöntemi kullanılmıştır ve eğitim başarısı 5 tekrarlı doğrulama verilerinin ortalama değeri ile hesaplanmaktadır. Önermiş olduğumuz tüm paradigmaların farklı

makine öğrenme algoritmaları ile gerçekleştirilen sınıflandırma performansları her paradigma için ayrı ayrı tablolar (Tablo 2-5) halinde verilmiştir. Denek-bağımlı ve denek-bağımsız analizler için tüm zaman alanı öznetelikleri kullanılarak tüm sınıflandırıcılarda gerçekleştirilen test performansları Tablo 2’de verilmiştir. Denek-bağımlı ve denek-bağımsız analizler için TBA ile belirlenen zaman alanı öznetelikleri kullanılarak tüm sınıflandırıcılarda gerçekleştirilen test performansları Tablo 3’te verilmiştir. Denek-bağımlı ve denek-bağımsız analizler için ANOVA ile belirlenen zaman alanı öznetelikleri kullanılarak tüm sınıflandırıcılarda gerçekleştirilen test performansları Tablo 4’te verilmiştir. Denek-bağımlı ve denek-bağımsız analizler için ANOVA ile belirlenen özneteliklerden TBA ile belirlenen temel zaman alanı bileşenleri kullanılarak tüm sınıflandırıcılarda gerçekleştirilen test performansları Tablo 5’te verilmiştir. Tablolarda kalın yazı puntoları ile belirtilen doğruluk başarımları değerleri, denek-bağımlı ve denek-bağımsız analizlerde tüm sınıflandırıcılar arasından hangisiyle en yüksek doğruluk değeri elde edildiğini ifade etmektedir.

Bu çalışmada, denek-bağımlı ve denek-bağımsız durumda yüksek test başarımları DVM algoritmaları ve Paradigma 3 ile elde edilmiştir. ANOVA tabanlı seçilmiş öznetelikler ve Kuadratik DVM algoritması kullanılarak denek-bağımsız sınıflandırmanın test karmaşıklık matrisi ve hem doğrulama hem de test verisinin doğruluk performansları Tablo 6’da verilmiştir. Doğrulama ve test verilerinin doğruluk başarımları değerleri sırasıyla %37,7 ve %35,9 olarak hesaplanmıştır. Denek-bağımlı analizler değerlendirildiğinde en yüksek test başarımlarının Denek 3’te Doğrusal DVM ile yapılan sınıflandırma ile elde edildiği gözlemlenmiştir. Bu doğrultuda, ANOVA tabanlı seçilmiş öznetelikler ve Doğrusal Destek Vektör Makinesi algoritması kullanılarak Denek C için deneye-bağımlı sınıflandırmanın test karmaşıklık matrisi ve hem doğrulama hem de test verisinin doğruluk performansları Tablo 7’de verilmiştir. Doğrulama ve test verilerinin doğruluk başarımları değerleri sırasıyla %53,0 ve %57,0 olarak hesaplanmıştır.

Bu çalışmada önerilen farklı paradigmaların etkinliği deneysel sonuçlar incelenerek araştırılmıştır. İlk olarak denek-bağımsız durumda, eğitim aşamasında en yüksek doğrulama doğruluk değeri

Tablo 1. Sadece zaman alanı öznetelikleri kullanıldığı durumdaki veri setlerinin boyutu ve önerilen öznetelik seçimi yöntemleriyle seçilen öznetelik sayıları

(Size of datasets when only time-domain features are used and number of features selected by the proposed feature selection methods)

Öznetelik vektörleri	Veri setinin boyutu	Eğitim verisinin boyutu	Test verisinin boyutu	ANOVA ile seçilen öznetelik sayısı	TBA ile seçilen öznetelik sayısı	ANOVA+TBA ile seçilen öznetelik sayısı
1 (Subject A)	600x504	480x504	120x504	(286/504)	(3/504)	(2/286)
2 (Subject B)	600x504	480x504	120x504	(298/504)	(1/504)	(1/298)
3 (Subject C)	600x504	480x504	120x504	(410/504)	(1/504)	(1/410)
4 (Subject E)	600x504	480x504	120x504	(423/504)	(1/504)	(1/423)
5 (Subject F)	600x504	480x504	120x504	(253/504)	(3/504)	(3/253)
6 (Subject G)	600x504	480x504	120x504	(305/504)	(3/504)	(2/305)
7 (Subject H)	600x504	480x504	120x504	(321/504)	(3/504)	(2/321)
8 (Subject I)	600x504	480x504	120x504	(213/504)	(5/504)	(1/213)
All subjects	7800x504	6240x504	1560x504	(346/504)	(5/504)	(4/346)

Tablo 2. Tüm zaman alanı öznetelikleri kullanılarak bu çalışmada test edilen tüm sınıflandırıcı performansları
(All classifier performances which were tested in this study using all time-domain features)

Model	S1 (A)	S2 (B)	S3 (C)	S4 (E)	S5 (F)	S6 (G)	S7 (H)	S8 (I)	Denek-bağımsız
Karar Ağaçları	24,2	37,5	38,3	40,0	28,3	35,8	29,2	32,5	28,6
Doğrusal Ayırma Analizi	15,0	26,7	34,2	32,5	20,0	29,2	25,0	26,7	32,1
Naive Bayes	30,0	40,0	33,3	41,0	26,7	33,3	30,8	38,3	27,9
Destek Vektör Makineleri	28,3	50,0	56,0	48,3	40,0	45,8	28,3	40,8	36,2
k en Yakın Komşu	35,8	44,2	45,0	42,0	34,2	45,0	27,5	38,3	33,5
Topluluk Öğrenmesi	30,0	44,2	48,3	50,0	38,4	46,7	30,0	37,5	32,6
Sinir Ağları	29,2	45,0	51,5	47,5	35,8	45,8	31,7	38,3	34,9

Tablo 3. Bu çalışmada, Temel Bileşen Analizi yöntemi kullanılarak test edilen tüm sınıflandırıcı performansları
(All classifier performances which were tested in this study using the Principal Component Analysis method.)

Model	S1 (A)	S2 (B)	S3 (C)	S4 (E)	S5 (F)	S6 (G)	S7 (H)	S8 (I)	Denek-bağımsız
Karar Ağaçları	27,5	20,0	27,5	32,5	22,5	20,0	26,7	19,2	23,0
Doğrusal Ayırma Analizi	25,8	18,3	27,0	32,5	20,8	26,7	18,3	18,3	20,9
Naive Bayes	23,3	18,3	28,3	36,7	21,7	22,5	25,8	16,7	21,9
Destek Vektör Makineleri	26,7	17,5	26,0	34,2	25,0	24,2	24,2	23,3	19,9
k en Yakın Komşu	27,5	17,5	31,0	35,0	27,5	22,5	25,0	20,0	24,0
Topluluk Öğrenmesi	30,0	20,0	27,0	34,2	25,0	26,7	30,0	19,2	23,0
Sinir Ağları	24,2	19,2	31,0	36,7	25,0	25,0	23,3	18,3	23,5

Tablo 4. Bu çalışmada ANOVA testi kullanılarak test edilen tüm sınıflandırıcı performansları
(All classifier performances which were tested in this study using the ANOVA test.)

Model	S1 (A)	S2 (B)	S3 (C)	S4 (E)	S5 (F)	S6 (G)	S7 (H)	S8 (I)	Denek-bağımsız
Karar Ağaçları	35,0	38,3	36,0	45,0	24,2	39,2	30,8	31,7	28,5
Doğrusal Ayırma Analizi	34,2	41,7	43,3	46,7	36,7	37,5	20,8	31,7	29,9
Naive Bayes	25,0	42,5	45,0	48,3	30,0	39,2	30,8	37,5	28,5
Destek Vektör Makineleri	35,0	49,2	57,5	54,2	39,2	55,0	33,3	41,7	35,9
k en Yakın Komşu	29,2	45,0	47,0	50,0	35,0	48,3	30,8	39,2	32,7
Topluluk Öğrenmesi	33,3	43,3	53,3	55,8	43,3	50,0	34,2	40,8	33,6
Sinir Ağları	35,8	46,7	57,0	50,8	40,8	48,3	34,2	40,0	34,7

Tablo 5. Bu çalışmada hem ANOVA testi hem de Temel Bileşen Analizi yöntemi kullanılarak test edilen tüm sınıflandırıcı performansları
(All classifier performances which were tested in this study using both the ANOVA test and Principal Component Analysis method.)

Model	S1 (A)	S2 (B)	S3 (C)	S4 (E)	S5 (F)	S6 (G)	S7 (H)	S8 (I)	Denek-bağımsız
Karar Ağaçları	25,8	15,8	27,0	43,3	25,8	25,0	25,0	21,7	22,6
Doğrusal Ayırma Analizi	27,5	18,3	28,3	31,7	25,8	28,3	19,2	20,8	19,7
Naive Bayes	27,5	18,3	27,0	34,2	22,5	25,0	17,5	20,8	21,8
Destek Vektör Makineleri	25,8	19,2	33,3	33,3	27,5	30,0	22,5	20,0	20,0
k en Yakın Komşu	34,2	16,7	29,2	40,8	28,3	32,5	25,8	25,8	22,8
Topluluk Öğrenmesi	28,3	18,3	31,0	40,0	25,0	28,3	21,7	25,8	23,5
Sinir Ağları	30,0	17,5	31,0	35,8	31,7	27,5	24,2	20,8	24,0

Tablo 6. ANOVA tabanlı seçilmiş öznitelikler ve Kuadratik Destek Vektör Makinesi algoritması kullanılarak denek-bağımsız sınıflandırmanın test karmaşıklık matrisi ve doğruluk performansları
(The test confusion matrix and accuracy performances of the subject-independent classification using ANOVA-based selected features and Quadratic Support Vector Machine algorithm)

Test Karmaşıklık Matrisi (Denek-bağımsız)		Tahmin edilen sınıf						Validation accuracy	Test accuracy
		NoMT	Thumb	Index finger	Middle finger	Ring finger	Pinkie finger		
Gerçek sınıf	NoMT	192	15	11	14	9	19	37,7	35,9
	Thumb	13	74	67	47	31	28		
	Index finger	10	61	72	52	27	38		
	Middle finger	13	40	45	62	66	34		
	Ring finger	9	32	27	58	78	56		
	Pinkie finger	14	23	28	53	60	82		

Tablo 7. ANOVA tabanlı seçilmiş öznitelikler ve Doğrusal Destek Vektör Makinesi algoritması kullanılarak Denek C için deneye-bağımlı sınıflandırmanın test karmaşıklık matrisi ve doğruluk performansları
(The test confusion matrix and accuracy performances of the subject-dependent classification for Subject C using ANOVA-based selected features and Linear Support Vector Machine algorithm)

Test Karmaşıklık Matrisi (Subject C)		Tahmin edilen sınıf						Validation accuracy	Test accuracy
		NoMT	Thumb	Index finger	Middle finger	Ring finger	Pinkie finger		
Gerçek sınıf	NoMT	17	2	0	1	0	0	53,0	57,5
	Thumb	0	12	4	2	1	1		
	Index finger	0	7	8	3	1	1		
	Middle finger	0	3	4	8	3	2		
	Ring finger	0	2	0	3	12	3		
	Pinkie finger	0	1	3	2	2	12		

%38,2 olarak 4 paradigma arasından Paradigma 1 yaklaşımla, test aşamasında ise en yüksek test doğruluk değeri %36,2 olarak yine 4 paradigma arasından Paradigma 1 yaklaşımla elde edilmiştir. Aynı zamanda 4 farklı paradigmanın 7 farklı makine öğrenmesi algoritması ile performansları analiz edildiğinde, test sonuçlarına göre en yüksek

test başarımları 5 farklı sınıflandırıcıda Paradigma 1’de, ve 2 farklı sınıflandırıcıda ise Paradigma 3’te elde edilmiştir. Sonuç olarak, denek-bağımsız sonuçlarına göre hem eğitim hem de test aşamasında 4 paradigma arasından en yüksek doğruluk başarımları değerleri Paradigma 1 ile sağlanmıştır. Tüm zaman alanı özniteliklerinin

birlikte kullanıldığı yaklaşımın bu çalışmada denek-bağımsız analizlerde iyi sonuçlar verdiğini söyleyebiliriz.

Denek-bağımlı analizlerde de paradigmaların performansları ayrı ayrı analiz edilmiştir. Denek 1 (Subject A) için yapılan sınıflandırmalarda, Tablo 2-5 verilerine göre eğitim aşamasında en yüksek doğrulama doğruluk değeri %31,0 olarak 4 paradigma arasından Paradigma 2 yaklaşımıyla, test aşamasında ise en yüksek test doğruluk değeri %35,8 olarak 4 paradigma arasından Paradigma 1 ve Paradigma 3 yaklaşımıyla elde edilmiştir. Aynı zamanda 4 farklı paradigmanın 7 farklı makine öğrenmesi algoritması ile performansları analiz edildiğinde, test sonuçlarına göre ise en yüksek test başarımları 5 farklı sınıflandırıcıda Paradigma 1'de ve 2 sınıflandırıcıda Paradigma 3'te elde edilmiştir. Denek 2 (Subject B) için yapılan sınıflandırmalarda, Tablo 2-5 verilerine göre eğitim aşamasında en yüksek doğrulama doğruluk değeri %46,9 olarak 4 paradigma arasından Paradigma 3 yaklaşımıyla, test aşamasında ise en yüksek test doğruluk değeri %50,0 olarak 4 paradigma arasından Paradigma 1 yaklaşımıyla elde edilmiştir. Aynı zamanda 4 farklı paradigmanın 7 farklı makine öğrenmesi algoritması ile performansları analiz edildiğinde, test sonuçlarına göre en yüksek test başarımları 5 farklı sınıflandırıcıda Paradigma 1'de ve 2 sınıflandırıcıda Paradigma 3'te elde edilmiştir. Denek 3 (Subject C) için yapılan sınıflandırmalarda, Tablo 2-5 verilerine göre eğitim aşamasında en yüksek doğrulama doğruluk değeri %54,8 olarak 4 paradigma arasından Paradigma 1 yaklaşımıyla, test aşamasında ise en yüksek test doğruluk değeri %57,5 olarak 4 paradigma arasından Paradigma 3 yaklaşımıyla elde edilmiştir. Aynı zamanda 4 farklı paradigmanın 7 farklı makine öğrenmesi algoritması ile performansları analiz edildiğinde, test sonuçlarına göre en yüksek test başarımları 6 farklı sınıflandırıcıda Paradigma 1'de, 1 farklı sınıflandırıcıda Paradigma 3'te elde edilmiştir. Denek 4 (Subject E) için yapılan sınıflandırmalarda, Tablo 2-5 verilerine göre eğitim aşamasında en yüksek doğrulama doğruluk değeri %54,4 olarak 4 paradigma arasından Paradigma 1 yaklaşımıyla, test aşamasında ise en yüksek test doğruluk değeri %55,8 olarak 4 paradigma arasından Paradigma 3 yaklaşımıyla elde edilmiştir. Aynı zamanda 4 farklı paradigmanın 7 farklı makine öğrenmesi algoritması ile performansları analiz edildiğinde, test sonuçlarına göre en yüksek test başarımları 7 farklı sınıflandırıcıda Paradigma 1'de elde edilmiştir. Denek 5 (Subject F) için yapılan sınıflandırmalarda, Tablo 2-5 verilerine göre eğitim aşamasında en yüksek doğrulama doğruluk değeri %39,8 olarak, test aşamasında ise en yüksek test doğruluk değeri %43,3 olarak her iki durum için de 4 paradigma arasından Paradigma 3 yaklaşımıyla elde edilmiştir. Aynı zamanda 4 farklı paradigmanın 2 farklı makine öğrenmesi algoritması ile performansları analiz edildiğinde, test sonuçlarına göre en yüksek test başarımları 5 farklı sınıflandırıcıda Paradigma 1'de ve 2 sınıflandırıcıda Paradigma 3'te elde edilmiştir. Denek 6 (Subject G) için yapılan sınıflandırmalarda, Tablo 2-5 verilerine göre eğitim aşamasında en yüksek doğrulama doğruluk değeri %46,0 olarak, test aşamasında ise en yüksek test doğruluk değeri %55,0 olarak her iki durum için de 4 paradigma arasından Paradigma 3 yaklaşımıyla elde edilmiştir. Aynı zamanda 4 farklı paradigmanın 7 farklı makine öğrenmesi algoritması ile performansları analiz edildiğinde, test sonuçlarına göre en yüksek test başarımları 7 farklı sınıflandırıcıda Paradigma 1'de elde edilmiştir. Denek 7 (Subject H) için yapılan sınıflandırmalarda, Tablo 2-5 verilerine göre eğitim aşamasında en yüksek doğrulama doğruluk değeri %32,5 olarak, test aşamasında ise en yüksek test doğruluk değeri %34,2 olarak her iki durum için de 4 paradigma arasından Paradigma 3 yaklaşımıyla elde edilmiştir. Aynı zamanda 4 farklı paradigmanın 7 farklı makine öğrenmesi algoritması ile performansları analiz edildiğinde, test sonuçlarına göre ise en yüksek test başarımları 2 farklı sınıflandırıcıda Paradigma 1'de, 1 farklı sınıflandırıcıda ve 4 farklı sınıflandırıcıda Paradigma 3'te elde edilmiştir. Denek 8 (Subject I) için yapılan sınıflandırmalarda, Tablo 2-5 verilerine göre eğitim aşamasında en yüksek doğrulama doğruluk

değeri %39,2 olarak, test aşamasında ise en yüksek test doğruluk değeri %41,7 olarak her iki durum için de 4 paradigma arasından Paradigma 3 yaklaşımıyla elde edilmiştir. Aynı zamanda 4 farklı paradigmanın 7 farklı makine öğrenmesi algoritması ile performansları analiz edildiğinde, test sonuçlarına göre en yüksek test başarımları 5 farklı sınıflandırıcıda Paradigma 1'de ve 2 sınıflandırıcıda Paradigma 3'te elde edilmiştir.

Tüm denek-bağımlı sınıflandırmalar denekler için ayrı ayrı incelendiğinde, eğitim sonuçlarına göre 4 paradigma arasından en yüksek doğruluk başarımları 2 denekte (C ve E) Paradigma 1 ile, 1 denekte (A) Paradigma 2 ile, 5 denekte (B, F, G, H ve I) ise Paradigma 3 ile sağlanmıştır. Test sonuçlarına göre en yüksek doğruluk başarımları 1 denekte (B) Paradigma 1 ile, 1 denekte hem Paradigma 1 hem de Paradigma 3 ile, 6 denekte (C, E, F, G, H ve I) ise Paradigma 3 ile sağlanmıştır. Sonuç olarak önerilen yaklaşımlardan en yüksek başarımların daha çok istatistiksel anlamlı zaman alanı özneteliklerinin kullanıldığı yaklaşımlar ile gerçekleşmiştir. Bu da önerilen ANOVA tabanlı öznetelik seçiminin etkili bir yöntem olduğunu ve performansta iyileştirmeler sağladığını göstermektedir.

Denek-bağımlı sınıflandırmaların sonuçları denek-bağımsız sınıflandırma sonuçları ile karşılaştırılmıştır. Sonuçlara göre denek-bağımlı analizlerde eğitim ve test aşamalarında sırasıyla en yüksek doğrulama doğruluk değeri ve test doğruluk değeri %53,0 ve %57,5 olarak her iki durum için de Denek 3 (Subject C) için istatistiksel anlamlı zaman alanı öznetelikleri kullanılarak yapılan sınıflandırmalarda elde edilmiştir. Denek-bağımsız analizlerde ise eğitim ve test aşamalarında sırasıyla en yüksek doğrulama doğruluk değeri ve test doğruluk değeri %37,7 ve %35,9 olarak hesaplanmıştır. Ayrıca 8 denekte ayrı ayrı gerçekleştirilen istatistiksel anlamlı özneteliklerin kullanıldığı durum için sınıflandırma sonuçları incelendiğinde Denek 1 ve 7 (Subject A ve H) haricinde diğer tüm deneklerde, denek-bağımsız analizden daha yüksek test doğruluk değerleri elde edilmiştir. Denek-bağımlı sınıflandırmalarda yüksek başarımlar elde edilmesi parmak hareketlerinin daha doğru bir şekilde birbirinden ayrıştırılabildiğini ve bu durumun kişiye özel el protezlerinin tasarımı için umut verici olduğunu göstermektedir. Kişiye özel el protezleri için yüksek doğrulukta EEG tabanlı BBA sistemlerinin tasarımlarının önünü açmaktadır.

Çalışmadaki sonuçların literatürdeki diğer çalışmalar ile de karşılaştırılması gerekmektedir. Tablo 8 ile literatürdeki aynı veri setini kullanarak parmak hareketlerinin motor hayali görevlerini sınıflandırmaya çalışan tüm çalışmalar karşılaştırılmıştır. Yapılan denek-bağımlı bir çalışmada [7], hem kanal seçimi gerçekleştirilip 4 EEG kanalı ile çalışılmış hem de daha kompleks öznetelik çıkarma yöntemi önerilmiştir. Sonuçlara göre eğitim başarımları %21,2-%66,6 aralığında değişmiştir. Etkili kanallarla çalışılmasına rağmen başarımlar yüksek seviyede değildir, önerilen çalışmanın işlem yükü fazladır. Yapılan bir diğer denek-bağımlı [6], 4 denegin verileri ile çalışılmıştır, kanal seçimi yapılmamıştır. CSP tabanlı öznetelik çıkarma yöntemi ve RF sınıflandırıcısının kullanılmasıyla test doğruluk başarımları %51,0-%56,0 aralığında değişmiştir. İş yükünü artıran kompleks yapıda öznetelik yöntemi önerilmesine rağmen test başarımları önermiş olduğumuz çalışmanın test başarımlarından düşüktür. Yapılan bir diğer denek-bağımlı çalışmada [12], kanal seçimi gerçekleştirilip 4 EEG kanalı ile çalışılmış hem de derin öğrenme (BiLSTM) kullanılmıştır. Etkili kanallar ile çalışılmış olmasına ve derin öğrenmenin eğitim aşamasının uzun sürmesinin meydana getirdiği iş yüküne rağmen test başarımları %66,0-%76,13 olarak hesaplanmıştır. Mwata-Velu ve arkadaşları [13] ise EEGNet tabanlı 4 denegin verilerinin kullanıldığı denek-bağımlı bir çalışma gerçekleştirmişlerdir, önerdikleri çalışmayla, %80,1-%91,7 aralığında değişen eğitim başarımları elde edilmiştir ama test başarımları

Tablo 8. Aynı veri setini kullanarak parmak hareketleri motor hayali görevlerini sınıflandıran diğer çalışmalar ile önerilen çalışmanın başarımlarının karşılaştırılması
(Comparison of the performance results of the proposed study with other studies that classify finger movements motor imaginary tasks using the same data set)

Çalışma	Yıl	Denek durumu	Sınıf sayısı	Kanal sayısı	Öznitelik çıkarma	Öznitelik seçme	Sınıflandırıcı algoritma	Eğitim Başarımı (%)	Test Başarımı (%)
[7]	2022	Denek-bağımlı 8	5 (T, I, M, R, P)	4 (OVR-CSP: F7, F8, Fp2, Fp1)	Spektrogram Öznitelikleri	-	SVM	21,2-66,6	-
[6]	2019	Denek-bağımlı 4 (A, B, C, D)	5 (T, I, M, R, P)	19	CSP	-	RF	100	51,0-56,0
[12]	2021	Denek-bağımlı 8	5 (T, I, M, R, P)	4 (C3, Cz, P3, Pz)	EMD	-	BiLSTM	73,47-98,69	66,0-76,13
[13]	2022	Denek-bağımlı 4 (A, B, C, F)	5 (T, I, M, R, P)	4	EEG ham verileri	-	EEGNet	80,1-91,7	-
[14]	2020	Denek-bağımlı 4 (A, B, C, F)	5 (T, I, M, R, P)	19	CSP	-	ADL	74,73-77,61	74,61-77,75
[8]	2020	Denek-bağımlı 8	5 (T, I, M, R, P)	19	Çok-sınıflı CSP, Kompleks Fourier genlikleri	-	SVM	23,9-58,3	-
[15]	2022	Denek-bağımsız 8	5 (T, I, M, R, P)	19	Hibrit yaklaşım: EEG zaman serileri, pencereleme, gürültü ekleme	-	CNN	57,5	-
[5]	2018	Denek-bağımlı 8	5 (T, I, M, R, P)	19	PSD, EEG band gücü, FT büyüklükleri	-	SVM	20,0-60,0	-
[5]	2018	Denek-bağımsız 8	5 (T, I, M, R, P)	19	PSD, EEG band gücü, FT büyüklükleri	-	SVM	43,0	-
Bu çalışma	2022	Denek-bağımsız 8	6 (T, I, M, R, P, NoMT)	19	Zaman Alanı Öznitelikleri	- ANOVA	SVM SVM	38,2 37,7	36,2 35,9
Bu çalışma	2022	Denek-bağımlı 8	6 (T, I, M, R, P, NoMT)	19	Zaman Alanı Öznitelikleri	- ANOVA	SVM SVM	28,1-54,8 27,7-53,0	28,3-56,0 33,3-57,5

verilmemiştir. Yüksek başarımlı olmasına rağmen derin öğrenme kullanılmasından dolayı iş yükünün fazla olduğu bir yöntemdir. Yapılan bir diğer derin öğrenme (Autonomous deep learning) tabanlı denek-bağımlı çalışmada [14] ise 4 denek için verileri kullanılmıştır. CSP tabanlı kompleks yapıda öznitelik çıkarma ve derin öğrenmenin eğitim süresinin getirmiş olduğu iş yüklerine rağmen test başarımları %74,61-%77,75 aralığında değişmiştir. Başarımları bizim çalışmamızdan fazladır ama iş yükü de önermiş olduğumuz çalışmadan fazladır. Yapılan bir diğer denek-bağımlı çalışmada [8], multi-class CSP tabanlı öznitelik çıkarma yöntemi kullanılmıştır ve SVM ile sınıflandırma süreci gerçekleştirilmiştir. Daha kompleks yapıda öznitelik çıkarma yöntemleri kullanılmasına rağmen eğitim başarımları %23,9-%58,3 aralığında değişmiştir, test başarımları verilmemiştir. Yapılan bir denek-bağımsız çalışmada [15], CNN tabanlı sınıflandırmaya yapılmıştır ve eğitim başarımları %57,5 olarak

hesaplanmıştır. Derin öğrenmenin iş yüküne göre düşük bir başarımdır. Son olarak, Kaya ve arkadaşları [5] ise SVM sınıflandırmasına dayalı hem denek-bağımlı hem de denek-bağımsız durum için parmak hareketlerini sınıflandırmaya çalışmışlardır. Denek-bağımlı sınıflandırmalarda eğitim başarımları %20,0-%60,0 aralığında değişmiştir, denek-bağımsız sınıflandırmada ise %43,0 eğitim başarımları rapor edilmiştir. Tüm çalışmalar incelendiğinde, denek-bağımlı sınıflandırmalarda başarımların daha yüksek oranlarda sağlandığı gözlemlenmiştir. Bizim önermiş olduğumuz çalışma da bu çalışmalar ile tutarlı sonuçlar göstermiştir. Denek-bağımsız

analizlerde, tüm zaman alanı özniteliklerini kullanarak %38,2 eğitim başarımları ve %36,2 test başarımları, istatistiksel anlamlı zaman alanı özniteliklerini kullanarak ise 37,7% eğitim başarımları ve %35,9 test başarımları hesaplandı. Denek-bağımlı analizlerde ise 8 denek için SVM altında geliştirilen algoritmalar ile yapılan sınıflandırmalar yüksek başarımlar elde etmiştir. Tüm zaman alanı özniteliklerinin kullanıldığı durumda, eğitim başarımları %28,1-%54,8 aralığında, test başarımları ise %28,3-%56,0 aralığında hesaplanmıştır. İstatistiksel anlamlı zaman alanı özniteliklerinin kullanıldığı durumda ise eğitim başarımları %27,7-%53,0 aralığında, test başarımları ise %33,3-%57,5 aralığında hesaplanmıştır. Önermiş olduğumuz zaman alanı öznitelikleri ve ANOVA tabanlı öznitelik seçimi yönteminin işlem karmaşıklığı yönünden avantajlıdır ve sınıflandırıcı performanslarındaki iyileşmeler düşünüldüğünde istatistiksel anlamlı zaman alanı özniteliklerinden diğer EEG sinyalleri tabanlı çalışmalarda da faydalanılabilir.

4. Sonuçlar (Conclusions)

19 EEG kanalından hesaplanmıştır ve toplamda 504 zaman alanı özniteliği elde edilmiştir. Ayrıca, farklı öznitelik seçme yöntemleriyle 4 farklı yaklaşım önerilmiştir ve bu yaklaşımlar ayrı ayrı sınıflandırma sürecine verilmiştir. Çalışmada aslında ANOVA tabanlı öznitelik seçimi önerilmektedir, performans üzerindeki etkinliğinin araştırılması için sıklıkla kullanılmakta olan TBA yöntemi de kullanılmıştır. Yaklaşımlardan Paradigma 1'de tüm zaman alanı özniteliklerinin, Paradigma 2'de TBA ile belirlenen temel zaman alanı

bileşenlerinin, Paradigma 3'te ANOVA ile belirlenen istatistiksel anlamlı zaman alanı öznelitliklerinin ve Paradigma 4'te ANOVA ile belirlenmiş olan istatistiksel anlamlı zaman alanı öznelitliklerinden TBA ile belirlenen temel zaman alanı bileşenlerinin etkinliği araştırılmıştır. Tüm bu yaklaşımlar için 7 temel sınıflandırıcının farklı parametrelerine göre geliştirilen 27 farklı makine öğrenmesi algoritması ile sınıflandırma süreçleri gerçekleştirilmiştir. Çalışmada hem denek-bağımlı hem de denek-bağımsız durum üzerinde önerilen yöntemler ile çalışılmıştır. Çalışmada 4 farklı paradigmanın 27 farklı sınıflandırıcı ile etkinliği detaylı bir şekilde karşılaştırılmıştır. 4 farklı paradigmanın performansları hem denek-bağımsız hem de denek-bağımlı durumlar için analiz edilmiştir.

Çalışmadaki en önemli noktalar ve yenilikçi yönler şu şekilde ifade edilebilir:

- Parmak hareketlerinin motor hayali görevlerini sınıflandırabilmek için istatistiksel anlamlı 24 farklı zaman alanı öznelitliğinin kullanılmasına dayalı bir yaklaşım önermekteyiz.
- Önermiş olduğumuz yaklaşımın etkinliğini daha iyi analiz edebilmek için, literatürde de sıklıkla öznelitlik seçme aşamasında uygulanmakta olan TBA yöntemini de kullanarak çalışma 4 farklı paradigma şeklinde kurgulanmıştır. Bunlar: (1) tüm zaman alanı öznelitliklerinin kullanılması, (2) TBA ile belirlenen temel zaman alanı bileşenlerinin kullanılması, (3) ANOVA ile belirlenen istatistiksel anlamlı zaman alanı öznelitliklerinin kullanılması ve (4) ANOVA ile belirlenen istatistiksel anlamlı zaman alanı öznelitliklerinden TBA ile belirlenen temel zaman alanı bileşenlerinin kullanılması.
- Önermiş olduğumuz 4 yaklaşım için, 7 temel sınıflandırıcı altında geliştirilen 27 farklı makine öğrenmesi algoritması ile sınıflandırma süreci gerçekleştirilerek etkili karşılaştırmalar yapılmıştır.
- Literatürdeki motor hayali görev sınıflandırma çalışmalarında, her zaman motor hayali görevin gerçekleştirildiği düşünülüp hiçbir motor hayali görevin gerçekleştirilmediği durum yok sayılmaktadır ve sınıflandırma aşamasına NoMT durumu dahil edilmemektedir. Bu çalışmaların aksine, önermiş olduğumuz çalışmada gerçeğe daha yakın el protez tasarımlarının mümkün olabilmesi için NoMT durumu da sınıflandırma sürecine alınarak 6 sınıflı bir sınıflandırma çalışması gerçekleştirilmiştir.
- Ayrıca, çalışmada denek-bağımlı ve denek-bağımsız durumlar için ayrı ayrı önermiş olduğumuz yaklaşımlar ve sınıflandırma algoritmalarıyla çalışılmıştır.
- Sonuçlara göre, istatistiksel anlamlı zaman alanı öznelitliklerinin kullanılmasıyla sınıflandırma performanslarında iyileşmeler gerçekleşmektedir.
- İstatistiksel anlamlı zaman alanı öznelitliklerinin DVM sınıflandırıcısı altında geliştirilmiş olan farklı makine öğrenmesi algoritmalarıyla hem denek-bağımlı hem de denek-bağımsız durum için gerçekleştirilen sınıflandırmalarında en yüksek başarımlar elde edilmiştir.
- Önermiş olduğumuz zaman alanı öznelitliklerinin çıkarılması, öznelitlik seçimi yöntemleri ve sınıflandırıcı algoritmaları işlem karmaşıklığı yönünden avantajlıdır. Bu da tasarlanacak olan el protezlerinde etkili bir BBA sistemi oluşturulabilmesi için önemlidir, parmak hareketlerinin mümkün olan en az işlem karmaşıklığı ve doğru bir şekilde birbirinden ayırt edilebilir olması gerekmektedir.
- Son olarak, denek-bağımlı analizlerde 8 denekten iki denek haricinde denek-bağımsız durumdan daha yüksek eğitim ve test başarımları elde edilmiştir. Çalışmanın denek-bağımlı sınıflandırmadaki teşvik edici sonuçları kişiye özel el protezleri için yüksek doğrulukta EEG tabanlı BBA sistemlerinin tasarımının önünü açmaktadır.

Teşekkür (Acknowledgement)

Bu çalışma, İzmir Katip Çelebi Üniversitesi Bilimsel Araştırma Projeleri (BAP) Koordinasyon birimi tarafından Mürşide Değirmenci'nin doktora tez çalışmaları kapsamında 2023-TDR-FEBE-0002 proje numarası ile desteklenmiştir. Ayrıca, Mürşide Değirmenci doktora eğitim süreci için Yüksek Öğrenim Kurumu (YÖK) tarafından YÖK 100/2000 Öncelikli Alan doktora bursu ve Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 2211A genel doktora bursu kapsamında desteklenmektedir.

Etik Beyanı (Ethical Declaration)

Bu çalışmada etik kurul izni gerektiren bir durum söz konusu olmayıp kullanılan EEG verileri Internet üzerinden açık ve ücretsiz olarak erişime sunulan Kaya ve arkadaşlarının [5] önermiş olduğu motor hayali EEG veri setinden elde edilmiştir.

Kaynaklar (References)

1. Hidayatullah A.N., Pranowo P., Membuka Ruang Asa dan Kesejahteraan Bagi Penyandang Disabilitas, Jurnal Penelitian Kesejahteraan Sosial, 17 (2), 195-206, 2018.
2. Condori K.A., Urquiza E.C., Diaz D.A., Embedded Brain Machine Interface based on motor imagery paradigm to control prosthetic hand, In 2016 IEEE ANDESCON, IEEE, 1-4, 2016.
3. Elstob D., Secco E.L., A low cost EEG based BCI prosthetic using motor imagery, arXiv preprint arXiv:1603.02869, 6 (1), 2016.
4. Azizah R.N., Zakaria H., Hermanto B.R., Channels Selection for Pattern Recognition of Five Fingers Motor Imagery Electroencephalography Signals, In Journal of Physics: Conference Series, IOP Publishing, 2312 (1), 012019, 2022.
5. Kaya M., Binli M.K., Ozbay E., Yanar H., Mishchenko Y., A large electroencephalographic motor imagery dataset for electroencephalographic brain computer interfaces, Scientific Data, 5 (1), 1-16 2018.
6. Anam K., Nuh M., Al-Jumaily A., Comparison of EEG pattern recognition of motor imagery for finger movement classification, 6th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI), IEEE, 24-27, 2019.
7. Azizah R.N., Zakaria H., Hermanto B.R., Channels Selection for Pattern Recognition of Five Fingers Motor Imagery Electroencephalography Signals, In Journal of Physics: Conference Series, IOP Publishing 2312 (1), 012019, 2022.
8. Kato M., Kanoga S., Hoshino T., Fukami T., Motor imagery classification of finger motions using multiclass CSP, 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), IEEE, 2991-2994, 2020.
9. Narin A., Isler Y., Detection of new coronavirus disease from chest x-ray images using pre-trained convolutional neural networks, Journal of the Faculty of Engineering and Architecture of Gazi University, 36 (4), 2095-2107, 2021.
10. Ozdemir M.A., Degirmenci M., Izci E., Akan A., EEG-based emotion recognition with deep convolutional neural networks, Biomedical Engineering/Biomedizinische Technik, 66 (1), 43-57, 2021.
11. Degirmenci M., Ozdemir M.A., Izci E., Akan A., Arrhythmic heartbeat classification using 2d convolutional neural networks, Irbm, 43 (5), 422-433, 2021.
12. Mwata-Velu T.Y., Avina-Cervantes J.G., Cruz-Duarte J.M., Rostro-Gonzalez H., Ruiz-Pinales J., Imaginary Finger Movements Decoding Using Empirical Mode Decomposition and a Stacked BiLSTM Architecture, Mathematics, 9 (24), 3297, 2021.
13. Mwata-Velu T.Y., Avina-Cervantes J.G., Ruiz-Pinales J., Garcia-Calva T.A., González-Barbosa E.A., Hurtado-Ramos J.B., González-Barbosa J.J., Improving Motor Imagery EEG Classification Based on Channel Selection Using a Deep Learning Architecture, Mathematics, 10 (13), 2302, 2022.
14. Anam K., Bukhori S., Hanggara F.S., Pratama M., Subject-independent Classification on Brain-Computer Interface using Autonomous Deep Learning for finger movement recognition, 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), IEEE, 447-450, 2020.

15. Zahra H.N., Zakaria H., Hermanto B.R., Exploration of Pattern Recognition Methods for Motor Imagery EEG Signal with Convolutional Neural Network Approach. In Journal of Physics: Conference Series, IOP Publishing, 2312 (1), 012064, 2022.
16. Degirmenci M., Yuce Y.K., Isler Y., Motor imaginary task classification using statistically significant time-domain EEG features. In 2022 30th Signal Processing and Communications Applications Conference (SIU), IEEE May 16-18, Safranbolu, Turkey, 2022.
17. Sayilgan E., Yuce Y.K., Isler Y., Evaluating Steady-State Visually Evoked Potentials-Based Brain-Computer Interface System Using Wavelet Features and Various Machine Learning Methods, In Brain-Computer Interface, IntechOpen, 2021.
18. Isler Y., A detailed analysis of the effects of various combinations of heart rate variability indices in congestive heart failure, Ph.D. thesis, Dokuz Eylul University, Institute of Science, Izmir, 2009.
19. Narin A., Isler Y., Ozer M., Investigating the performance improvement of HRV Indices in CHF using feature selection methods based on backward elimination and statistical significance, Computers in Biology and Medicine, 45, 72-79, 2014.
20. Degirmenci M., Yuce Y.K., Isler Y., Motor imaginary task classification using statistically significant time domain and frequency domain eeg features, Journal of Intelligent Systems with Applications, 5 (1), 49-54, 2022.
21. Duda R.O., Hart P.E., Stork D.G., Pattern Classification, 2nd Edition, John Wiley and Sons, New York, 2001.
22. Selek M.B., Yesilkaya B., Egeli S.S., Isler Y., The effect of principal component analysis in the diagnosis of congestive heart failure via heart rate variability analysis, Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine, 235 (12), 1479-1488, 2021.
23. Narin A., Isler Y., Effect of principal component analysis on diagnosing congestive heart failure patients using heart rate records. In 2012 20th Signal Processing and Communications Applications Conference (SIU), IEEE, 1-4, 2012.
24. Lu H., Plataniotis K.N., Venetsanopoulos A. N., Multilinear principal component analysis of tensor objects for recognition, In 18th International Conference on Pattern Recognition (ICPR'06), IEEE, 2, 776-779, 2006.
25. Hongye X., Zhuoya H., Gait recognition based on gait energy image and linear discriminant analysis. In 2015 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC), IEEE, 1-4, 2015.
26. Degirmenci M., Yuce Y.K., Isler Y., Classification of multi-class motor imaginary tasks using poincare measurements extracted from eeg signals, Journal of Intelligent Systems with Applications, 5 (2), 74-78, 2022.
27. Pan S., Iplikci S., Warwick K., Aziz T.Z., Parkinson's Disease tremor classification-A comparison between Support Vector Machines and neural networks. Expert Systems with Applications, 39 (12), 10764-10771, 2012.
28. Richard M.D., Lippmann R.P. Neural network classifiers estimate Bayesian a posteriori probabilities, Neural computation, 3 (4), 461-483, 1991.
29. Degirmenci M., Ozdemir M.A., Sadighzadeh R., Akan, A. Emotion recognition from EEG signals by using empirical mode decomposition. In 2018 Medical Technologies National Congress (TIPTEKNO), IEEE, 1-4, 2018.
30. Tzallas A.T., Tsipouras M.G., Fotiadis D.I., Epileptic seizure detection in EEGs using time-frequency analysis, IEEE Transactions on Information Technology in Biomedicine, 13 (5), 703-710, 2009.
31. Cura O.K., Akan A., Analysis of epileptic EEG signals by using dynamic mode decomposition and spectrum. Biocybernetics and Biomedical Engineering, 41 (1), 28-44, 2021.
32. Lotte F., Baugrain L., Cichocki A., Clerc M., Congedo M., Rakotomamonjy A., Yger F., A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update, Journal of Neural Engineering, 15 (3), 031005, 2018.
33. Vapnik V., The nature of statistical learning theory, Springer Science & Business Media, 1999.
34. Chakrabarti S., Roy S., Soundalgekar M.V., Fast and accurate text classification via multiple linear discriminant projections, The VLDB journal, 12 (2), 170-185, 2003.
35. Liu C., Wechsler H., Enhanced fisher linear discriminant models for face recognition, In Proceedings. Fourteenth International Conference on Pattern Recognition (Cat. No. 98EX170), IEEE, 2, 1368-1372, 1998.
36. Sayilgan E., Yuce Y.K., Isler Y., Evaluation of wavelet features selected via statistical evidence from steady-state visually-evoked potentials to predict the stimulating frequency, Journal of the Faculty of Engineering and Architecture of Gazi University, 36 (2), 593-605, 2021.
37. Isler Y., Narin A., Ozer O., Perc M., Multi-stage classification of congestive heart failure based on shortterm heart rate variability, Chaos, Solitons & Fractals, 118, 145-151, 2019.

