

Motor İmgeleme EEG Sinyallerinde Sınıflandırma Performansını Artırmaya Yönelik Adaptif Segmentasyon Yaklaşımı

Tuğçe BALLI* 

Alınma: 13.05.2025; düzeltme: 17.09.2025; kabul: 24.09.2025

Öz: Elektroansefalogram (EEG) tabanlı beyin-bilgisayar arayüzlerinin (BBA) performansı, sistem tasarımında kullanılan sinyal işleme yöntemlerine doğrudan bağlıdır. EEG sinyal işleme süreci; ön işleme, öz nitelik çıkarma, seçme ve sınıflandırma adımlarını içerir. EEG verilerinden öz nitelik çıkarımı genellikle sabit uzunlukta pencerelere ayrıldıktan sonra yapılmaktadır. Bu çalışmada öz niteliklerin veri temsiliyetini artırmak için değişim noktası tespiti (change point detection, CPD) dayalı adaptif bir segmentasyon yaklaşımı önerilmiştir. Bu amaçla budanmış kesin doğrusal zaman (pruned exact linear time, PELT) algoritması kullanılmıştır. Bu yöntem, değişim noktalarını uygun bir maliyet fonksiyonu ile duyarlılık parametresinin belirlenmesi yoluyla tespit etmektedir. Önerilen yöntemin, sabit segmentasyona kıyasla etkinliği, BCI Competition IV 2a veri seti kullanılarak değerlendirilmiştir. Bu veri seti, 9 katılımcının sol el, sağ el, ayak ve dil imgeleme görevlerini gerçekleştirirken kaydedilmiş EEG verilerini içermektedir. Sonuçlar, CPD tabanlı yöntemin hem ikili hem de dört sınıflı sınıflandırmada test verisi üzerindeki sınıflandırma başarımını artırdığını göstermiştir. İkili sınıflandırma senaryosunda, önerilen yöntemin performans artışı %5,81 ile %8,72 arasında değişmiştir. En yüksek sınıflandırma performansı, sol el ve dil görevleri arasında gözlemlenmiştir; katılımcı bazında performans artışları %4,16 ve %12,73 aralığında değişmiştir. Dört sınıflı sınıflandırma görevinde ise ortalama %7,5 oranında bir başarı artışı sağlanmış olup, katılımcı bazlı performans artışları %3,93 ile %11,11 aralığında değişmiştir.

Anahtar Kelimeler: EEG, Motor İmgeleme, Değişim Noktası Tespiti, Sabit Segmentasyon, Sınıflandırma

Adaptive Segmentation Approach for an Improved Classification of MI-EEG Signals

Abstract: Electroencephalogram (EEG)-based brain-computer interfaces (BCI) rely on effective design of signal processing pipelines to achieve high classification performance. The fundamental EEG signal processing steps include preprocessing, feature extraction, selection, and classification. In the feature extraction step, EEG signals are typically segmented using a fixed window length. This study proposes an adaptive segmentation scheme using change point detection (CPD) to achieve optimal segmentation for enhanced feature representation. Pruned exact linear time (PELT) algorithm was used to detect change points by minimizing a cost function with a sensitivity parameter for avoiding over segmentation. The proposed and fixed-point segmentation approaches were evaluated using BCI Competition IV dataset 2a, which contains EEG recordings from 9 subjects performing motor imagery tasks involving left-hand, right-hand, foot and tongue movements. Results demonstrated that the CPD-based method improved classification performance on test data for both binary and four-class classification tasks. In binary classification, performance improvement ranged from 5.81% to 8.72%, depending on class pair. The highest classification performance was observed in left hand and tongue movements, with participant-specific improvements ranging from 4.16% to 12.73%. In four-class task, an average improvement of 7.5% was observed, with participant-specific improvements ranging from 3.93% to 11.11%.

Keywords: EEG, Motor Imagery, Change Point Detection, Fixed Point Segmentation, Classification

* Kadir Has Üniversitesi; İktisadi, İdari ve Sosyal Bilimler Fakültesi; Yönetim Bilişim Sistemleri Bölümü; 34083, Cibali, İstanbul

Sorumlu Yazar: Tuğçe Ballı (tugce.balli@khas.edu.tr)

1. GİRİŞ

Karmaşık ve doğrusal olmayan fiziksel ve biyolojik sistemlerin durumları, zamanla, iç dinamikler veya dış etkenler nedeniyle değişiklik gösterebilir. Bu değişimler, fiziksel sistemlerde olası bir arıza veya bozulmaya, biyolojik sistemlerde ise olası bir hastalık veya anomali olduğuna işaret edebilir. Sistemlerin bir durumdan diğerine geçişlerinin tespiti olası anomalilerin erken teşhisi açısından kritik bir öneme sahiptir. Bu tür sistemlerin durumları ve davranışları sensörler aracılığıyla izlenmekte ve zaman serisi verileri olarak kaydedilmektedir.

Değişim noktası tespit (change point detection, CPD) algoritmaları dinamik sistemlerdeki davranışsal değişimleri tespit etmeye olanak tanıyan ve dolayısıyla zaman serilerini daha etkin bir şekilde analiz edilmesine katkı sağlayan yöntemlerdir (Truong ve diğ., 2020). Bu yöntemler zaman serisinde ortalama, varyans gibi istatistiksel özelliklerdeki değişikliklerin zaman indislerini tespit etmeyi amaçlar. CPD algoritmaları; endüstriyel sistemlerin izlenmesi (Manca and Fay, 2022), finansal trend analizi (Kim ve diğ., 2022) ve iklim değişimlerinin izlenmesi (Chaer ve diğ., 2022) gibi çeşitli alanlarda kullanılmaktadır. Disiplinler arası kullanım alanları CPD yöntemlerini, karmaşık sistemleri anlama ve yönetmede potansiyel önemli bir araç haline getirmiştir.

Geniş ve disiplinler arası uygulama alanlarına rağmen CPD algoritmalarının Beyin-Bilgisayar Arayüzü (BBA) sistemlerinin tasarımında elektroensefalogram (EEG) sinyallerinin analizine yönelik kullanımı, literatürde çok araştırılmamış bir konudur. Ancak bu alandaki potansiyel kullanım alanlarını ortaya koyan bazı öncü çalışmalar bulunmaktadır.

Kirch ve diğ. (2015) çalışmalarında çok değişkenli zaman serilerindeki değişim noktalarını tespit etmek için istatistiksel yöntemler geliştirmişlerdir. Bu yöntemi motor görev EEG verilerine uygulayarak, yöntemin karmaşık beyin süreçlerinde meydana gelen değişim noktalarının tespitinde kullanılabileceğini göstermiştir. CPD yöntemlerinin kullanıldığı, Gao ve diğ. (2018) tarafından yapılan bir başka çalışmada EEG sinyallerinin gerçek zamanlı izlenmesinde değişim tespiti için denetimsiz ve ölçeklenebilir bir yöntem önerilmiştir. Sonuçlar, önerilen yöntemin epilepsi hastalarının izlenmesinde ve nöbetlerin gerçek zamanlı olarak tespit edilmesinde etkili bir şekilde kullanılabileceğini göstermiştir. Schröder ve Ombao (2019) tarafından yapılan benzer bir çalışmada frekansa özgü değişim noktası tespit algoritması geliştirmiştir. Çalışmada önerilen yöntemin epileptik nöbet öncesi EEG sinyallerindeki değişimleri saptayabildiği, nöbetin bir beyin bölgesinden diğerine yayılımını izleyebildiği ve nöbetin başladığı beyin bölgesi ile zamanını doğru bir şekilde tespit edebildiği gösterilmiştir. CPD yöntemlerinin EEG verilerine etkin bir şekilde uygulanabildiğini gösteren bu çalışmalar, söz konusu yöntemlerin BBA sistemi tasarımı için EEG sinyallerinin analizinde de uygulanabilir olduğuna işaret etmektedir.

BBA sistemlerinin doğruluk performansları EEG sinyallerinin analizi için kullanılan yöntemlerin etkinliği ile doğru orantılıdır. EEG sinyallerinin işlenmesindeki temel adımlar ön işleme, öznitelik çıkarma, seçme ve sınıflandırmadır. Öznitelik çıkarma, EEG sinyallerinden anlamlı bilgileri çıkararak düşük boyutlu bir öznitelik kümesi elde etmeyi amaçlar. Bu süreçte, sinyallerin doğru bir şekilde analiz edilmesi ve özniteliklerin etkin bir şekilde çıkarılabilmesi için uygun segment uzunluğunun belirlenmesi önemli bir adımdır. EEG sinyallerinin durağanlık analizi üzerine yapılan araştırmalar, sinyallerinin istatistiksel özelliklerinin zamanla değiştiğini, yani durağan (stationary) olmadığını göstermektedir. Bu nedenle, sinyaller genellikle durağan kabul edilebilecek kısa segmentlere bölünerek analiz edilir. Böylece her bir segmentin lokal olarak durağanlık özelliğini sağladığı varsayımıyla, zaman içinde değişen istatistiksel özelliklerin daha doğru bir şekilde temsil edilmesi amaçlanır (Gongora ve diğ., 2022). Öte yandan, EEG gibi dinamik ve karmaşık sinyallerde sabit segmentasyona alternatif olarak adaptif segmentasyon yapılması, çıkarılan özniteliklerin istatistiksel tutarlılığını etkin bir şekilde koruyarak sınıflandırma aşamasında yüksek doğruluklu sonuçlar elde edilmesini sağlayabilir.

Bu doğrultuda, mevcut çalışma kapsamında EEG verilerindeki istatistiksel değişim noktalarını tespit eden adaptif bir segmentasyon yöntemi uygulanmış ve bu yöntemin motor

imgeleme EEG verilerinin sınıflandırma performansı üzerindeki etkisi analiz edilmiştir. EEG verilerinin durağan olmayan (non-stationary) doğası göz önüne alındığında, sabit segmentasyonun sınıflandırma performansı üzerindeki sınırlamaları ortaya konmuş ve adaptif segmentasyonun doğruluk oranlarını artırdığı deneysel olarak gösterilmiştir.

Bu çalışmanın literatüre sağladığı özgün katkılar şunlardır:

- 1- Motor imgeleme EEG verilerinin işlenmesi için istatistiksel değişim noktası tespitine dayalı adaptif bir segmentasyon yönteminin kullanılması önerilmiştir.
- 2- Çalışmada kullanılan değişim noktası tespit algoritmasının duyarlılık parametresinin motor imgeleme EEG verilerinde katılımcı bazlı olarak optimize edilmesinin sınıflandırma performansını artırmada önemli bir rol oynadığı gösterilmiştir.
- 3- Önerilen adaptif segmentasyon yönteminin, literatürde yaygın olarak tercih edilen sabit segmentasyona kıyasla hem dört sınıflı hem de iki sınıflı sınıflandırma performanslarını önemli ölçüde artırdığı deneysel olarak gösterilmiştir.

Makalenin geriye kalan bölümleri şu şekilde düzenlenmiştir: İkinci bölümde literatür özeti sunulmuş ve mevcut yaklaşımlar tartışılmıştır. Üçüncü bölümde, kullanılan veri seti, verilerin işlenmesinde takip edilen temel adımlar ve PELT algoritması ile segmentasyon süreci anlatılmıştır. Dördüncü bölümde bulgular aktarılmış ve son olarak beşinci bölümde sonuca yer verilmiştir.

2. LİTERATÜR ÖZETİ

EEG tabanlı sınıflandırma çalışmaları genellikle EEG verilerinin temizlenmesi, segmente edilmesi, öznetelik çıkarma, öznetelik seçme ve sınıflandırma adımlarından oluşur (Amer ve Belhaouari, 2023). EEG verilerinin segmentasyonu için en yaygın yaklaşım verilerin durağanlık (stationarity) özelliklerini sağlayacak şekilde sabit segmentasyon yapmaktır. Bu aşamada segment uzunluğunun doğru seçimi hem zamansal çözünürlük hem de sinyalin durağanlığı açısından önemli bir rol oynamaktadır.

Literatürde farklı segment uzunluklarının tercih edildiği çalışmalar bulunmakta birlikte, EEG tabanlı motor imgeleme sınıflandırma çalışmalarında 1 saniyelik segment uzunlukları yaygın olarak kullanılmaktadır (Hamner ve diğ., 2011; D'Croz-Baron ve diğ., 2012; Vuckovic ve diğ., 2015; Jo ve diğ., 2022; Jin ve diğ., 2025). Bu segment uzunluğunun bu çalışmada da kullanılan CSP ve filtre bankası CSP (FBCSP) özneteliklerinin çıkarılması için de yaygın olarak kullanıldığı ve kısa süreli sabit pencerelerin ayırt ediciliği yüksek öznetelikler elde etmeye olanak tanıdığı literatürde yapılan çalışmalarda gösterilmiştir (Cantillo-Negrete ve diğ., 2018; Chu ve diğ., 2020; Blanco-Diaz ve diğ., 2024; González-Cely ve diğ., 2025).

Ancak, her ne kadar bu yaklaşım yaygın ve etkili olsa da sabit segment uzunluklarının bazı sınırlılıkları da bulunmaktadır: elde edilen segmentler kaçınılmaz olarak gerçek durağan EEG segmentlerinin sınırlarını içerir. Dolayısıyla geçiş bölgelerini içeren, tam anlamıyla durağan olmayan bir veri seti ortaya çıkar. Bu bağlamda, literatürde segment uzunluğu seçiminin sınıflandırma performansına etkisini inceleyen çalışmalar da bulunmaktadır.

Candra ve diğ. (2015), EEG sinyallerinden duygu kestirimi için en uygun segment uzunluğunu belirlemeyi amaçladıkları çalışmalarında, 1 ile 60 saniye arasındaki farklı segment uzunluklarını incelemiştir. Elde edilen bulgular, 3 ile 12 saniyelik segmentlerin değerlik (valence) ve uyarılma (arousal) tespiti için en yüksek doğruluk performansını sağladığını göstermiştir. Rosiani ve diğ. (2021), benzer bir çalışmada EEG tabanlı biyometrik sistemlerde segment uzunluğunun sınıflandırma performansına etkisini incelemiştir. Çalışmada 60; 30; 15; 10; 7,5; 6 ve 5 saniyelik segmentler kullanılarak farklı frekans bantlarından güç spektral yoğunluğu (PSD) özellikleri çıkarılmıştır. Sonuçlar, segment uzunluğu ile sınıflandırma performansı arasında doğrusal bir ilişki bulunmadığını ve en yüksek doğruluk performansının 5 saniyelik segmentlerle elde edildiğini göstermektedir. Maarouf ve diğ. (2024) tarafından yürütülen bir başka çalışmada ise pasif beyin-bilgisayar arayüzlerinde (BBA) zihinsel iş yükü tespitine yönelik farklı EEG

segment uzunlukları incelenmiştir. Bu çalışmada, 0,3 ila 150 saniye arasındaki segment uzunlukları değerlendirilmiş ve Kneedle algoritması kullanılarak yapılan analiz sonucunda, 2,43 saniyenin bilgi içeriği ile hesaplama verimliliği açısından en uygun segment uzunluğu olduğu belirlenmiştir.

Bu çalışmalar, farklı segment uzunluklarının sınıflandırma performansını doğrudan etkilediğini göstermektedir. Ancak sabit segmentasyon yöntemleri basit ve hızlı bir yaklaşım olsa da elde edilen segmentlerin her zaman durağanlık özelliğinin olmaması önemli bir sınırlılıktır. Literatürdeki çalışmalar da segment sınırlarının durağan aralıklar arasındaki geçişleri tespit edecek şekilde dinamik olarak uyarlanması gerektiğini ortaya koymuştur (Kaplan ve diğ., 2001).

Bu bağlamda literatürde farklı adaptif segmentasyon yöntemleri geliştirilmiş ve EEG verilerine uygulanmıştır. Azami ve diğ. (2014) zaman serilerinin otomatik segmentasyonu için zamanla değişen otoregresif (TVAR) modeline dayalı bir yöntem önermiştir. Yöntemin segmentasyon performansı hem sentetik veriler hem de EEG verileri üzerinde test edilmiş ve segmentasyonun sinyalin frekans ve genlik özelliklerine duyarlı olduğu gösterilmiştir. Ancak çalışmada segmentasyon sonrası bir analiz yapılmamıştır. Sarma ve Barma (2021) tarafından yapılan bir başka çalışmada EEG verilerinden duygu kestirimi yapmak amacıyla duygusal durumu yansıtan veri segmentlerini belirlemek ve sadece bu segmentleri kestirim için kullanmak amacıyla rastgele matris teorisi yöntemi uygulanmıştır. Bu yöntemle elde edilen EEG segmentlerinden güç spektral yoğunluğu ve sürekli dalgacık dönüşümü öznitelikleri çıkarılarak k-en yakın komşuluk, destek vektör makinaları ve rassal ormanlar gibi sınıflandırıcılarla duygu kestirimi yapılmıştır. Önerilen yöntemle, iki farklı veri setinde yüksek sınıflandırma performansı elde edilmiştir. Gongore ve diğ. (2022) EEG verilerinin durağanlık özelliklerini değerlendirerek dördüncü dereceden istatistiklere dayalı yeni bir segment uzunluğu seçim yöntemi önermiştir. Farklı pencere uzunlukları için basıklık (kurtosis) değerleri hesaplanarak, durağanlık açısından benzer özellikler gösteren segmentler belirlenmiştir. En fazla sayıda elektrodun benzer durağanlık özellikleri gösterdiği segment uzunluğu ise en uygun değer olarak seçilmiştir. Önerilen yöntem, dinlenme durumunda kaydedilen EEG verileri üzerinde test edilmiş ve hem zamansal hem de uzamsal olarak segment uzunluğunun 4 saniye olarak seçilmesinin durağanlık özelliklerini sağladığı gösterilmiştir.

EEG verilerinin adaptif segmentasyonu için kullanılan bir diğer yöntem grubu ise değişim noktası tespit algoritmalarıdır. Bu yöntemler EEG literatüründe özellikle epileptik EEG segmentlerinin tespit edilmesinde (Malladi ve diğ., 2013; Hamavar ve Asl, 2025) ve epilepsi başlangıcının EEG üzerinden tespit edecek alarm sistemlerinin tasarlanmasında (Schröder ve Ombao, 2019) kullanılmıştır. Bunun yanında Kekovic ve Sekulic (2019) tarafından yapılan çalışmada hareketli ortalama ve dalgacık dönüşümüne dayalı bir değişim noktası tespit algoritması ile motor imgeleme EEG verilerinin yapısal değişikliklerini tespit ederek segmente edilebileceği gösterilmiştir. Kirch ve diğ. (2015) tarafından yapılan bir başka çalışmada verilerde değişim noktalarını tespit etmek adına geliştirdikleri yöntemi EEG verilerine uygulayarak bilişsel motor görevler esnasında görev başlangıcının tespit edilebileceği gösterilmiştir. Bu çalışmalar EEG verilerinin değişim noktası tespit algoritmaları ile segmente edilebileceğini göstermektedir. Ancak, bu yöntemin motor imgeleme EEG verilerinin adaptif bir şekilde segmentasyonu ve sınıflandırılması amacıyla kullanıldığı bir çalışmaya rastlanmamıştır.

Bu çalışmada motor imgeleme EEG verileri hem sabit segmentasyon hem de istatistiksel özelliklerindeki değişimleri temel alan değişim noktası tespit algoritması ile adaptif bir şekilde segmente edilmiştir. Her iki yaklaşım ile ortak uzamsal örüntü öznitelikleri çıkarılmış ve bu öznitelikler rassal ormanlar yöntemi ile sınıflandırılmıştır. Elde edilen sonuçlar her iki yöntemin sınıflandırma performansı açısından karşılaştırılmıştır.


3. METODOLOJİ

3.1 Veri Seti

Bu çalışmada “BCI Competition IV” verilerinden 2a kullanılmıştır (Brunner ve diğ., 2008). EEG verileri katılımcılar sol el, sağ el, her iki ayak ve dil hareketlerini içeren motor imgeleme görevlerini gerçekleştirirken toplanmıştır. Veri seti toplam 9 katılımcıdan oluşmaktadır.

EEG verileri 22 elektrot kullanılarak, 250 Hz örnekleme frekansı ve 0,5 - 100Hz bant geçiren filtre ile kaydedilmiştir. Ek olarak elektrik hattı gürültüsünü gidermek için 50Hz’lük bir çentik filtresi uygulanmıştır.

Bir motor imgeleme görevinin gerçekleştirilmesi için bip sesinden sonra öncelikle ekranda 2 saniye boyunca bir sabitleme çarpısı (fixation cross) görüntülenmiş, ardından dört imgeleme görevinden birine karşılık gelen bir ipucu ekranda 1,25 saniye boyunca kalmıştır. Daha sonra ekranda sabitleme çarpısı tekrar görüntülenmiş ve katılımcılar 6. saniyede sabitleme çağrısı ekrandan kalkıp siyah ekran görünene kadar verilen görevi gerçekleştirmişlerdir. Kayıt paradigmasının zamanlama şeması Şekil 1’de sunulmuştur.



Şekil 1:

EEG kayıt paradigmasının zamanlama şeması (Brunner ve diğ., 2008)

Bu veri setinde eğitim ve test verileri iki farklı günde kaydedilen oturumlardan elde edilmiştir. Her oturumda kısa aralarla ayrılmış altı kayıt gerçekleştirilmiştir. Bir kayıta dört motor imgeleme görevi rastgele şekilde 12’şer kez tekrarlanmıştır. Dolayısıyla her bir oturumda toplam 288 motor imgeleme denemesi (trial) bulunmaktadır (6 kayıt x 4 motor imgeleme görevi x 12 tekrar). Bu çalışmada birinci oturumdan elde edilen veriler (288 deneme) eğitim verisi, ikinci oturumdan elde edilen veriler (288 deneme) ise test verisi olarak kullanılmıştır.

3.2 EEG Verilerinin İşlenmesi

EEG verileri Python (versiyon 3.12.7) ortamında işlenmiş ve sınıflandırılmıştır. Bu çalışmada her bir motor imgeleme görevinin analizi için 3. ve 6. saniyeler arasındaki 3 saniyelik EEG verileri kullanılmıştır. 22 elektrottan kaydedilen ve 750 örneğe karşılık gelen 3 saniyelik EEG verilerine ortak uzamsal örüntü (common spatial patterns, CSP) yöntemi ile boyut indirgeme yapılmıştır. Daha sonra, veriler hem sabit segmentasyon hem de değişim noktası tespiti yaklaşımlarıyla segmentlere ayrılmıştır. Öznitelik çıkarmak için her bir segmentin logaritmik varyans değerleri hesaplanmış ve sınıflandırma yapılmıştır.

3.3 PELT Algoritması ile Segmentasyon

Zaman serilerindeki değişim noktaları verilerdeki istatistiksel özelliklerin değişimine bağlı olarak belirlenmektedir. Bir zaman serisindeki değişim noktaları aralarındaki zamansal ilişki $t_1 < t_2 < t_3 < \dots < t_p$ olacak şekilde $T = \{t_1, t_2, t_3, \dots, t_p\}$ kümesi ile tanımlanabilir.

Değişim noktası tespiti, bu indislerin bir maliyet fonksiyonunu minimize edilecek şekilde belirlenmesi olarak ifade edilir:

$$\min_T V(T) + P(T) \quad (1)$$

V(T) verilerden elde edilen y segmentinin belirli bir modele uygunluğunu ölçen bir maliyet fonksiyonudur. P(T) ise aşırı öğrenmeyi önleyen bir ceza fonksiyonudur.

Değişim noktası tespit algoritmaları üç temel bileşenden oluşmaktadır: maliyet fonksiyonu, arama yöntemi ve değişim noktası sayısını kontrol eden kısıt fonksiyonu. Bu çerçevede değişim noktası tespit problemine yönelik basit bir yaklaşım, tüm olası değişim noktası kombinasyonlarını hesaplayıp değerlendirmektir. Ancak, hesaplama maliyetinin veri boyutuna bağlı olarak üstel şekilde artması nedeniyle, bu yöntemin pratikte uygulanabilirliği sınırlıdır. PELT algoritması bu maliyet fonksiyonunu etkin bir şekilde minimize etmek üzere önerilmiş bir yaklaşımdır. PELT algoritması dinamik programlama ve budama stratejisi kullanarak birden fazla değişim noktasının tespitini verimli ve yüksek doğruluklu şekilde yapmaktadır. Budama stratejisi tüm olası segmentasyonları değerlendirmek yerine, optimal çözüme ulaşmayan segmentasyonları eleyerek hesaplama maliyetini düşürmektedir. Bunun yanında PELT algoritması değişim noktası sayısı ile ilgili önceden varsayımda bulunmayan bir yöntemdir (Killick ve diğ., 2012).

Bu çalışmada maliyet fonksiyonu olarak devamlı doğrusal değişim (CostCLinear) fonksiyonu kullanılmıştır (Truong ve diğ., 2020). Bu fonksiyon zaman serilerinde doğrusal parçalı fonksiyon ile interpolasyon yaparken oluşan hatayı (2) ile verildiği şekilde maliyet fonksiyonu olarak tanımlar;

$$C(y_{a..b}) = \sum_{t=a}^{b-1} \left\| y_t - y_{a-1} - \frac{t-a+1}{b-a} (y_{b-1} - y_{a-1}) \right\|^2 \quad (2)$$

Burada $y = \{y_1, y_2, y_3, \dots, y_n\}$ değişim noktası tespiti uyguladığımız n uzunluğundaki zaman serisini, [a..b] ise bu zaman serisindeki segmentin başlangıç ve bitiş indislerini ifade eder.

PELT algoritmasında ceza fonksiyonu $P(T) = \text{penaltı} * |T|$ olarak verilmektedir. Burada |T| değişim noktası sayısını vermekte olup, P(T) toplam tespit edilecek değişim noktasını sınırlamaktadır. Buradaki penaltı parametresi ise n zaman serisindeki örnek sayısı olacak şekilde (3) ile parametrik olarak tanımlanabilir (Esri, t.y.).

$$\text{Penaltı} = (0,25n)^{(1-\text{duyarlılık})} 2 \ln(n) \quad (3)$$

Penaltı değerinin belirlenmesinde, duyarlılık (sensitivity) parametresi 0,1'den 0,9'a kadar, 0,1'lik artışlarla değiştirilerek testler gerçekleştirilmiştir. PELT algoritması Python'un ruptures kütüphanesi (Truong ve diğ., 2020) kullanılarak uygulanmıştır.


3.4 Öznitelik Çıkarma

EEG verilerinin boyut indirgemesi ve özniteliklerinin çıkarılması için filtre bankası ortak uzamsal örüntü (filter bank common spatial patterns) yöntemi kullanılmıştır (Ang ve diğ., 2008).

Bu yöntem ile öncelikle 22 elektrottan kaydedilmiş EEG verileri delta (0,5-3,5 Hz), teta (4-7 Hz), alfa (8-13 Hz), beta (13-25 Hz) ve gama (25-48 Hz) frekans bantlarında filtrelenmiş ve sonrasında CSP ile uzamsal olarak filtrelenerek 4 boyuta indirgenmiştir. CSP aynı sınıfa ait EEG verilerindeki varyansı maksimize ederken farklı sınıflardaki EEG verilerinin varyans farkını minimize edecek uzamsal filtreler tasarlayan bir yöntemdir (Koles ve diğ., 1990). Bu yolla farklı sınıflara ait EEG verilerinin ayırt ediciliğini artıracak öznitelikler ortaya çıkar. Bu çalışmada CSP öznitelikleri mne kütüphanesindeki (versiyon 1.9.0) CSP fonksiyonu kullanılarak çıkarılmıştır. EEG verilerine CSP uygulandıktan sonra her frekans bandından 4x750 boyutunda bir veri elde edilmiştir. Burada uygulanan genel işlem akışını gösteren diyagram Şekil 2'de verilmiştir.


Her biri 4x750 örnekten oluşan motor görevlere ait verilerin işlenmesi için iki yol izlenmiştir; (1) klasik bir yaklaşım olarak EEG verileri 1 saniyelik segmentlere bölünerek öznitelikler çıkarılmıştır; (2) değişim noktası tespit algoritması kullanılarak, 3 saniyelik mental görev

verilerindeki değişim noktaları tespit edilmiş ve EEG verileri bu değişim noktalarına göre segmente edilerek öznitelikler çıkarılmıştır. Öznitelikler segmentlerin log varyansları hesaplanarak elde edilmiş ve 3 saniyelik veriden elde edilen log varyanslarının ortalaması hesaplanmıştır. Her iki yaklaşımda da elde edilen öznitelikler 3 saniyelik verileri temsil etmektedir. Şekil 3, bu aşamada uygulanan segmentasyon yöntemlerinin genel işlem akışını göstermektedir.



Şekil 2:

22 EEG elektrodundan elde edilen verilerin filtrelenip ardından CSP uygulanmasına ilişkin genel akış. Burada n elektrotlardan elde edilen verilerin örneklem sayısını ifade etmektedir ($n=750$).



Şekil 3:

Uygulanan segmentasyon yöntemlerinin genel işlem akışı.

3.5 Sınıflandırma

Bu çalışmada, lojistik regresyon, destek vektör makineleri, karar ağaçları, rassal ormanlar ve k-en yakın komşuluk gibi geleneksel makine öğrenmesi yöntemleri kullanılmıştır. Bu sınıflandırma algoritmaları literatürde EEG tabanlı motor imgeleme çalışmalarında sıklıkla uygulanan ve farklı sınıflandırma yaklaşımlarını temsil eden yöntemler arasından seçilmiştir.

Lojistik regresyon ve doğrusal destek vektör makineleri doğrusal sınıflandırma yöntemlerini temsil ederken; çekirdek (kernel) fonksiyonları kullanılan destek vektör makineleri, rassal ormanlar ve karar ağaçları parçalı doğrusal ve doğrusal olmayan ilişkileri modelleme kapasiteleri nedeniyle çalışmaya dahil edilmiştir; k en yakın komşuluk ise sezgisel bir sınıflandırma yaklaşımı sunmaktadır (Subasi ve Mian Qaisar, 2021; Dagdevir ve Tokmakci, 2023; Joy ve diğ., 2020; Hou ve diğ., 2022; Firoz ve diğ., 2024).

Bu çalışmada kullanılan veri setine ait hem eğitim setinde hem de test setinde 288 motor imgeleme kaydı bulunmaktadır. Sınıflandırma modellerinin performansını değerlendirmek için eğitim verileri üzerinde 10 katlı çapraz doğrulama uygulanmış ve elde edilen sonuçlar eğitim seti performansı olarak değerlendirilmiştir. Ardından sınıflandırma modeli tüm eğitim verileriyle eğitildikten sonra modelin daha önce görülmemiş veriler üzerindeki performansını ölçmek için test verileri kullanılmış ve elde edilen sonuçlar test verileri üzerindeki sınıflandırma performansı olarak raporlanmıştır. Yapılan testler sonucunda rassal ormanlar ve lojistik regresyon yöntemleri birbirine yakın olarak en yüksek performansları göstermiştir. Bu nedenle, bulgular bölümünde yalnızca rassal ormanlar yönteminin sonuçları sunulmuştur.

4. BULGULAR

Bu çalışmada, dört farklı motor imgeleme görevine ilişkin iki sınıflı ve dört sınıflı sınıflandırma performansları, sabit segmentasyon ve değişim noktası tespiti olmak üzere iki farklı segmentasyon yöntemi ile karşılaştırılmıştır. Bu bölümde raporlanan tüm sonuçlar test verilerinden elde edilmiş doğruluk performanslarıdır.


Bu kapsamda, Tablo 1’de, her bir sınıf çifti için doğruluk (accuracy), duyarlılık (sensitivity) ve özgüllük (specificity) metrikleri verilmiştir. Sabit segmentasyon yaklaşımıyla elde edilen doğruluk oranları %68,31 ile %79,16 arasında değişmektedir. Bu yöntemde duyarlılık oranları %65,68 ile %85,08, özgüllük oranları ise %61,05 ile %81,06 arasında olduğu gözlemlenmiştir. Özellikle dil hareketi (Sınıf 4) ile sol el (Sınıf 1) ve sağ el (Sınıf 2) hareketlerinin sınıflandırılmasında diğer ikili sınıflandırma senaryolarına kıyasla daha yüksek doğruluk performansları elde edilmiştir.

Diğer yandan, değişim noktası tespiti yöntemiyle yapılan segmentasyon ile, genel olarak sabit segmentasyona göre daha yüksek ve tutarlı sınıflandırma performansı elde edilmiştir. Bu yöntemde doğruluk oranları %76,08 ile %85,95 arasında değişmektedir. En yüksek başarı, sol el (Sınıf 1) ile dil hareketi (Sınıf 4) arasındaki sınıflandırmada elde edilmiştir (Doğruluk: %85,95; Duyarlılık: %87,03; Özgüllük: %84,87). Ayrıca, sağ el (Sınıf 2) ile dil hareketi (Sınıf 4) arasındaki sınıflandırmada da benzer şekilde yüksek doğruluk (%85,10), duyarlılık (%81,17) ve özgüllük (%89,04) oranları elde edilmiştir.

Tablo 1. İkili Sınıflandırmada Sabit Segmentasyon ve Değişim Noktası Tespit Algoritmalarının Dokuz Katılımcının Test Verileri Üzerindeki Ortalama Doğruluk, Duyarlılık ve Özgüllük Performansları

Sınıflar	Sabit Seg. Doğruluk (%)	Sabit Seg. Duyarlılık (%)	Sabit Seg. Özgüllük (%)	CPD Doğruluk (%)	CPD Duyarlılık (%)	CPD Özgüllük (%)
1 ve 2	68,31	72,68	63,94	76,08	80,40	71,75
1 ve 3	73,07	85,08	61,05	81,79	92,12	71,45
1 ve 4	79,16	80,40	77,93	85,95	87,03	84,87
2 ve 3	75,97	81,06	70,88	81,79	85,95	77,62
2 ve 4	77,75	74,43	81,06	85,10	81,17	89,04
3 ve 4	70,13	65,68	74,58	77,70	76,54	78,85

* Sınıf 1: Sol el hareketi, Sınıf 2: Sağ el hareketi, Sınıf 3: Ayak hareketi ve Sınıf 4: Dil hareketi.



Şekil 4.


İkili Sınıflandırmada sabit segmentasyon ve değişim noktası tespit yöntemlerine ait doğruluk performanslarının katılımcılara göre karşılaştırılması.

İkili sınıflandırma için sabit segmentasyon ve değişim noktası tespit algoritmalarının her bir katılımcı için test verilerinden elde edilen doğruluk performansları aynı zamanda Şekil 4'te gösterilmiştir. Sonuçlar, değişim noktası tespiti tabanlı segmentasyonun, tüm sınıf çiftlerinde tutarlı ve üstün sınıflandırma performansı sunduğunu göstermektedir.

Şekil 5'te, sol el hareketi ve dil hareketi imgeleme görevlerinin sınıflandırılmasında sabit segmentasyonun doğruluk performansı ile değişim noktası tespit algoritmasının, farklı duyarlılık parametreleri ile elde ettiği doğruluk performansları her bir katılımcı için karşılaştırmalı olarak sunulmuştur. Genel olarak değerlendirildiğinde, değişim noktası tespit algoritmasının performansının duyarlılık değerine bağlı olarak değişiklik gösterdiği görülmektedir. Doğruluk açısından en iyi sonuç veren duyarlılık değeri katılımcıya göre farklılık gösterse de değişim


noktası tespit algoritması performansının çoğu durumda sabit segmentasyona kıyasla daha yüksek olduğu görülmüştür.

Değişim noktası tespit algoritmasının performansını ölçmek için ikili sınıflandırma yaklaşımına ek olarak dört sınıflı sınıflandırma performansları da test edilmiştir. Buna karşılık test verileri üzerinde sabit segmentasyon ile ortalama %53,57, değişim noktası tespit algoritması ile ortalama %61,07 doğruluk performansı elde edilmiştir. Katılımcı bazında doğruluk performansları Şekil 6'da gösterilmiştir. Sonuçlar değişim noktası tespitinin her bir katılımcı için performansı yükselttiğini göstermiştir. Şekil 7'de her bir katılımcı için dört sınıflı doğruluk performanslarının 0,1-0,9 arasında değişen duyarlılık parametresine göre değişimi gösterilmiştir. Elde edilen sonuçların iki sınıflı doğruluk performansları ile tutarlı olduğu ve değişim noktası tespit algoritmasının genel olarak sınıflandırma doğruluğunu artırdığı görülmüştür.




Şekil 5.

Sol el hareketi ve dil hareketi sınıflandırmasında sabit segmentasyon ve değişim noktası tespit yöntemlerine ait doğruluk performanslarının 0,1-0,9 arasında değişen duyarlılık parametresine göre karşılaştırılması.



Şekil 6.

Dört motor imgeleme görevinin sınıflandırılmasında, sabit segmentasyon ve değişim noktası tespit yöntemlerine ait doğruluk performanslarının katılımcılara göre karşılaştırılması.



Şekil 7.

Dört motor imgeleme görevinin sınıflandırılmasında, sabit segmentasyon ve değişim noktası tespit yöntemlerine ait doğruluk performanslarının 0,1-0,9 arasında değişen duyarlılık parametresine göre karşılaştırılması.

5. TARTIŞMA

Bu çalışmada, BCI Competition IV 2a veri setindeki motor imgeleme verilerinin sınıflandırması için sabit segmentasyon ve değişim noktası tespiti (CPD) tabanlı adaptif segmentasyon yaklaşımları karşılaştırılmıştır. Bu çerçevede hem doğrudan dört sınıflı sınıflandırma hem de ikili sınıf kombinasyonlarının performansları değerlendirilmiştir.

İkili sınıflandırmada sabit segmentasyon ile doğruluk oranları %68,31 - %79,16 arasında, değişim noktası tespiti ile ise %76,08 - %85,95 arasında değişmektedir. Dört sınıflı durumda ise doğruluk oranları sabit segmentasyon ile %36,69 - %72,57 arasında, değişim noktası tespiti ile %40,62 - 80,56% arasında değişmiştir. Elde edilen sonuçlar katılımcılar arasında belirgin performans farklılıkları olduğunu göstermektedir. Bu durum mental görev tabanlı EEG verilerinde sıklıkla görülmekte ve literatürde “BCI yetersizliği” (BCI illiteracy) olarak adlandırılmaktadır. BCI yetersizliği katılımcıların beyin elektriksel aktiviteleri aracılığıyla BCI sistemlerini kontrol etmelerindeki sınırlılık olarak tanımlanır (Dreyer ve diğ., 2023). Literatürde yapılan çalışmalara göre BCI yetersizliği katılımcıların %20-25’ini etkilemektedir. Bu durum katılımcıların mental görevleri etkin bir şekilde gerçekleştirememeleri, nöral aktivitelerinde ya da beyinlerindeki yapısal farklılıkları sonucunda ortaya çıkabilmektedir. Bunun sonucunda BCI yetersizliği olan katılımcılardan elde edilen beyin elektriksel aktivitelerinin işlenmesiyle ayırt edici örüntüler elde edilememekte ve sonuç olarak performanslarında farklılıklara sebep olmaktadır (Dreyer ve diğ. 2023; Allison ve Neuper, 2010; Vidaurre ve diğ. 2010)

Literatürdeki benzer çalışmaların önemli bir kısmı, çok sınıflı motor imgeleme problemlerini bire karşı diğerleri (one versus rest) veya ikili sınıflandırma modelleri şeklinde ele almakta ve bu ikili modellerin çıktılarında, çoğunluk oylama (majority voting) yöntemiyle çok sınıflı bir karar mekanizması oluşturmaktadırlar (Ang ve diğ., 2012; Abbas ve Khan, 2018; Zhang ve Eskandarian, 2020; Fang ve diğ., 2022; Chin ve diğ., 2011). Bu yaklaşımlara göre yalnızca 2 sınıflı ayıracak modeller oluşturulduğu için bazı durumlarda daha yüksek doğruluk performansları raporlanabilmektedir, ancak bu çalışmada doğrudan 4 sınıflı ayıracak modeller oluşturulmuştur ve sonuç olarak önerilen yöntemler daha karmaşık bir sınıflandırma senaryosunda değerlendirilmiştir.

BCI Competition IV 2a veri seti üzerinde FBCSP/CSP tabanlı öznitelik çıkarma yöntemleriyle yapılan çalışmalarda, dört sınıflı sınıflandırma performanslarının Kappa katsayıları genellikle 0,36 ile 0,59 arasında değiştiği görülmüştür. Çalışmamızda elde edilen ortalama Kappa katsayısı (0,48) bu aralıkla karşılaştırılabilir düzeydedir. Öte yandan, mevcut çalışmaların çoğu yeni önileme, öznitelik çıkarma, öznitelik seçme veya sınıflandırma yaklaşımları önerdiğinden, doğrudan karşılaştırma sınırlı ölçüde mümkün olmaktadır.

Tablo 2 de aynı veri setini ve benzer yöntemler kullanan çalışmalarla bizim çalışmamızın öznitelik çıkarma, öznitelik seçme/boyut indirgeme, sınıflandırma, pencere uzunluğu, sınıf sayısı ve en iyi doğruluk/Kappa performansları verilmiştir. Ancak bu yöntemler ve bizim çalışmamız arasında önemli metodolojik farklılıklar bulunmaktadır. Örneğin Joy ve diğ. (2020) çalışmasında test verisini ayrıca kullanmamış, birinci ve ikinci oturumdan elde edilen tüm verileri 10 katlı çapraz doğrulama ile değerlendirmiştir. Fang ve diğ. (2022) ise farklı pencere uzunluklarını (ör. 3,5 s; 2 s; 1,5 s) aynı modelde birlikte kullanmıştır. Bununla birlikte mevcut literatürdeki birçok FBCSP uygulaması 9 frekans bandı kullanmakta ve frekans çözünürlüğünü artırmaktadır (Chin ve diğ., 2011; Ang ve diğ., 2012; Joy ve diğ., 2020). Ayrıca karşılıklı bilgi ve mRMR gibi öznitelik seçme yöntemleri ile optimal frekans bantlarının seçildiği çalışmalar da bulunmaktadır (Chin ve diğ., 2011; Ang ve diğ., 2012). Bu optimizasyon adımları, sınıflandırma performansını artırma potansiyeline sahiptir. Ancak bu çalışmada temel amaç, sabit segmentasyon ile CPD tabanlı adaptif segmentasyon yaklaşımlarını karşılaştırmak olduğundan, delta, teta, alfa, beta ve gama olmak üzere beş temel EEG frekans bandı kullanılmış ve ek öznitelik seçimi yapılmamıştır. Böylece, CPD yönteminin etkisi bağımsız olarak değerlendirilmiş ve kullanılan bantların veriyi yeterince temsil etmesi hedeflenmiştir.

Önerdiğimiz CPD tabanlı segmentasyon yöntemi, özellikle ikili sınıflandırma senaryolarında etkin bir performans sergilemiştir. İkili sınıflandırma sonuçlarında Kappa katsayıları 0,52 ile 0,71, doğruluk oranları ise %76,08 ile %85,95 aralığında elde edilmiştir. Bu bulgular, yöntemin sınıf çiftleri arasındaki ayrımı etkin bir şekilde yapabildiğini göstermektedir. Her ne kadar ikili ve dört sınıflı senaryolar doğrudan karşılaştırılamasa da ikili sınıflandırmada elde edilen bu yüksek performans, yöntemin çok sınıflı yapılara uyarlanması halinde de potansiyel olarak etkin sonuçlar elde edilebileceğini işaret etmektedir.

Tablo 2: BCI Competition IV 2a veri setinde FBCSP/CSP tabanlı öznelilik çıkarma yöntemleri kullanan literatür çalışmaları ile önerilen yöntemin karşılaştırılması.

Çalışma	Öznelilik Çıkarma	Öznelilik Seçme / Boyut İndirgeme	Sınıflandırma Algoritması	Pencere Uzunluğu	Sınıf Sayısı	En iyi Doğruluk Performansı (Kappa / Doğruluk)
Chin ve diğ., 2011	FBCSP / FBCSP + FBPLV 9 bant geçiren filtre uygulandı (4-8Hz, 8-12Hz, ..., 36-40Hz)	MI	Naïve Bayes Parzen Window	2s	4 sınıf	FBCSP: 0,58 FBCSP + FBPLV: 0,59 (Kappa)
Ang ve diğ., 2012	FBCSP 9 bant geçiren filtre uygulandı (4-8Hz, 8-12Hz, ..., 36-40Hz)	MI Tabanlı En İyi Bireysel Öznelilik / mRMR	Naïve Bayes Parzen Window	2 s	4 sınıf (6 ikili sınıflandırıcı ile çoğunluk oylaması)	0,572 (Kappa)
Abbas ve Khan, 2018	FBCSP 2 bant geçiren filtre uygulandı (8-13Hz, 14-30Hz) sonrasında zaman tabanlı öznelilikler ve bant gücü çıkarıldı	-	LDA, SVM	2,5 s	4 sınıf (Bire karşı diğerleri)	0,59 (Kappa)
Zhang ve Eskandaria, 2020	Optimal frekans bandı seçimi + CSP	-	LDA, SVM, NB	3 s	4 sınıf	LDA: 0,52 SVM: 0,51 NB: 0,36 (Kappa)
Joy ve diğ., 2020	FBCSP 9 bant geçiren filtre	-	LR, RF, NB	Belirtilmedi	4 sınıf	LR: 74,03% RF: 53,85% NB: 64,68% (Doğruluk)

	uygulandı (4-8Hz, 8-12Hz, 36-40Hz)					*Bütün veriye 10 katlı çapraz doğrulama uygulandı, ayrıca test seti kullanılmadı
Fang ve diğ., 2022	FBCSP FBRTS	-	SVM	3,5s'lik veriler ile 3,5s'lik bu verilerin 2s ve 1,5s'lik segmentleri birlikte kullanılmıştır	4 sınıf (Bire karşı diğerleri)	FBCSP: 69,1% FBRTS: 77,7% (Doğruluk)
Bu Çalışma	Delta, teta, alfa, beta ve gama bantlarında bant geçiren filtre + CSP	-	RF	Değişim noktası tespiti ile pencere uzunluğu belirleme	2 sınıf	1 ve 2: 0,52 / 76,08% 1 ve 3: 0,63 / 81,79% 1 ve 4: 0,71 / 85,95% 2 ve 3: 0,63 / 81,79% 2 ve 4: 0,70 / 85,10% 3 ve 4: 0,55 / 77,70% (Kappa / Doğruluk)
Bu Çalışma	Delta, teta, alfa, beta ve gama bantlarında bant geçiren filtre + CSP	-	RF	Değişim noktası tespiti ile pencere uzunluğu belirleme	4 sınıf	0,48 / 61,07% (Kappa / Doğruluk)

* Bu çalışmanın Kappa katsayısı sınıf dağılımları eşit olduğu için doğruluk değerleri kullanılarak hesaplanmıştır.

* FBPLV (Filter Bank Phase Locking Value – Filtre Bankası Faz Kilitleme Değeri); MI (Mutual Information – Karşılıklı Bilgi); mRMR (minimum Redundancy Maximum Relevance - Minimum Fazlalık ve Maksimum İlgililik); FBRTS (Filter Banks and Riemannian Tangent Space – Filtre Bankası ve Riemann Tanjant Uzayı); LDA (Linear Discriminant Analysis – Doğrusal Ayırtaç Analizi); SVM (Support Vector Machines – Destek Vektör Makinaları); NB (Naïve Bayes – Naif Bayes); RF (Random Forests – Rassal Ormanlar)

6. SONUÇ

Bu çalışmada motor imgeleme görevlerinin sınıflandırılması için sabit segmentasyon ve değişim noktası tespiti ile segmentasyon olmak üzere iki farklı yaklaşım karşılaştırılmıştır. Elde edilen sonuçlar değişim noktası tespiti yönteminin sınıflandırma performansını hem iki sınıflı hem de dört sınıflı sınıflandırmada artırdığını ortaya koymaktadır. İki sınıflı sınıflandırmada sınıf çiftine göre performans artışı %5,81 ile %8,72 aralığında değişmiştir. En iyi sınıflandırma performansının elde edildiği sol el ve dil hareketi imgeleme görevleri arasındaki sınıflandırmada katılımcı bazında performans artışı 4,16% ve 12,73% arasında değişim göstermiştir. Benzer şekilde dört sınıflı sınıflandırma da performansın ortalama %7,5 oranında arttığı görülmüştür. Katılımcı bazında sınıflandırma performans artışları ise 3,93% ile 11,11% arasında değişiklik göstermiştir.

Değişim noktası tespit algoritması ile yapılan segmentasyonda önemli bir faktör duyarlılık parametresinin doğru bir şekilde seçilmesidir. Bu çerçevede elde edilen bulgular, katılımcılara ait doğruluk performanslarının duyarlılık parametresine göre değişiklik gösterdiğini ve her bir

katılımcı için optimize edilmesi gerektiğini göstermiştir. Bununla birlikte, duyarlılık parametresinden bağımsız olarak, değişim noktası tespiti performansının çoğu durumda sabit segmentasyona kıyasla daha yüksek olduğu görülmüştür. Bu sonuçlar sabit segmentasyonun zaman eksenindeki istatistiksel değişimlerini göz ardı etmesi nedeniyle EEG verilerinden öznitelik çıkarma sürecinde bilgi kaybına yol açabileceğini göstermektedir. Değişim noktası tespiti, bu istatistiksel değişimleri hesaba katarak verinin yapısal özelliklerini daha iyi yansıtan özniteliklerin elde edilmesini sağlamış ve böylece sınıflandırma performansının artırmıştır.

İleriki çalışmalarda değişim noktası tespit algoritmalarının farklı mental görev tabanlı EEG verileri üzerinde test edilerek yöntemin genellenebilirliğinin değerlendirilmesi planlanmaktadır. Ayrıca, EEG verilerine uyarlanabilecek farklı maliyet fonksiyonlarının ve duyarlılık parametresi optimizasyon yöntemlerinin araştırılması hedeflenmektedir. Son olarak, bu yöntemlerin farklı öznitelik çıkarma yöntemleri, klasik makine öğrenmesi ve derin öğrenme tabanlı modeller (ör. CNN, LSTM, transformer) ile birlikte kullanılarak yöntemin potansiyel performansının daha kapsamlı bir şekilde değerlendirilmesi planlanmaktadır.

ÇIKAR ÇATIŞMASI

Yazar, bilinen herhangi bir çıkar çatışması veya herhangi bir kurum/kuruluş ya da kişi ile ortak çıkar bulunmadığını onaylamaktadırlar.

YAZAR KATKISI

Tuğçe Ballı önerilen yöntemlerin verilere uygulanması, sonuçların analiz edilmesi, yorumlanması ve makalenin yazım sürecinin tüm aşamalardan sorumludur.

TEŞEKKÜR

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 124E057 numaralı proje kapsamında desteklenmiştir.

KAYNAKLAR

1. Abbas, W., & Khan, N. A. (2018, July). FBCSP-based multi-class motor imagery classification using BP and TDP features. In 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 215-218). IEEE. doi: 10.1109/EMBC.2018.8512238
2. Al-Saegh, A., Dawwd, S. A., & Abdul-Jabbar, J. M. (2021). Deep learning for motor imagery EEG-based classification: A review. Biomedical Signal Processing and Control, 63, 102172. doi: 10.1016/j.bspc.2020.102172
3. Allison, B. Z., & Neuper, C. (2010). Could anyone use a BCI?. In Brain-computer interfaces: Applying our minds to human-computer interaction (pp. 35-54). London: Springer London. doi: 10.1007/978-1-84996-272-8_3
4. Altaheri, H., Muhammad, G., Alsulaiman, M., Amin, S. U., Altuwaijri, G. A., Abdul, W., Bencherif, M.A. & Faisal, M. (2023). Deep learning techniques for classification of

- electroencephalogram (EEG) motor imagery (MI) signals: A review. *Neural Computing and Applications*, 35(20), 14681-14722. doi: 10.1007/s00521-021-06352-5
5. Amer, N. S., & Belhaouari, S. B. (2023). Eeg signal processing for medical diagnosis, healthcare, and monitoring: A comprehensive review. *IEEE Access*, 11, 143116-143142. doi: 10.1109/ACCESS.2023.3341419
6. Ang, K. K., Chin, Z. Y., Wang, C., Guan, C., & Zhang, H. (2012). Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b. *Frontiers in neuroscience*, 6, 39. doi: 10.3389/fnins.2012.00039
7. Azami, H., Anisheh, S. M., & Hassanpour, H. (2013, December). An Adaptive Automatic EEG Signal Segmentation Method Based on Generalized Likelihood Ratio. In *International Symposium on Artificial Intelligence and Signal Processing* (pp. 172-180). Cham: Springer International Publishing. doi: 10.1007/978-3-319-10849-0_18
8. Bentlemsan, M., Zemouri, E. T., Bouchaffra, D., Yahya-Zoubir, B., & Ferroudji, K. (2014, January). Random forest and filter bank common spatial patterns for EEG-based motor imagery classification. In *2014 5th International conference on intelligent systems, modelling and simulation* (pp. 235-238). IEEE. doi: 10.1109/ISMS.2014.46
9. Blanco-Diaz, C. F., da Silva Serafini, E. R., Bastos-Filho, T., de Azevedo Dantas, A. F. O., do Espirito Santo, C. C., & Delisle-Rodriguez, D. (2024). A gait imagery-based brain-computer interface with visual feedback for spinal cord injury rehabilitation on lokomat. *IEEE Transactions on Biomedical Engineering*. doi: 10.1109/TBME.2024.3440036
10. Brunner, C., Leeb, R., Müller-Putz, G., Schlögl, A., & Pfurtscheller, G. (2008). BCI Competition 2008–Graz data set A. Institute for knowledge discovery (laboratory of brain-computer interfaces), Graz University of Technology, 16(1-6), 1. doi: 10.21227/katb-zv89
11. Candra, H., Yuwono, M., Chai, R., Handojoseno, A., Elamvazuthi, I., Nguyen, H. T., & Su, S. (2015, August). Investigation of window size in classification of EEG-emotion signal with wavelet entropy and support vector machine. In *2015 37th Annual international conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 7250-7253). IEEE. doi: 10.1109/EMBC.2015.7320065
12. Cantillo-Negrete, J., Carino-Escobar, R. I., Carrillo-Mora, P., Elias-Vinas, D., & Gutierrez-Martinez, J. (2018). Motor Imagery-Based Brain-Computer Interface Coupled to a Robotic Hand Orthosis Aimed for Neurorehabilitation of Stroke Patients. *Journal of healthcare engineering*, 2018(1), 1624637. doi: 10.1155/2018/1624637
13. Chaer, M. S. I., Nugroho, A. P., Putra, G. M. D., Ngadisih, N., Sutiarso, L., & Okayasu, T. (2022, March). Early warning system using change point analysis to detect microclimate anomalies. In *2nd International Conference on Smart and Innovative Agriculture (ICoSIA 2021)* (pp. 144-149). Atlantis Press. doi: 10.2991/absr.k.220305.021
14. Chin, Z. Y., Ang, K. K., Guan, C., Wang, C., & Zhang, H. (2011, July). Filter Bank Feature Combination (FBFC) approach for brain-computer interface. In *The 2011 International Joint Conference on Neural Networks* (pp. 1352-1357). IEEE. doi: 10.1109/IJCNN.2011.6033381

15. Chou, T. P., Wang, W. R., & Chang, T. S. (2015, July). Low complexity real time BCI for stroke rehabilitation. In 2015 IEEE International Conference on Digital Signal Processing (DSP) (pp. 809-812). IEEE. doi: 10.1109/ICDSP.2015.7251988
16. Chu, Y., Zhao, X., Zou, Y., Xu, W., Song, G., Han, J., & Zhao, Y. (2020). Decoding multiclass motor imagery EEG from the same upper limb by combining Riemannian geometry features and partial least squares regression. *Journal of neural engineering*, 17(4), 046029. doi: 10.1088/1741-2552/aba7cd
17. Craik, A., He, Y., & Contreras-Vidal, J. L. (2019). Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of neural engineering*, 16(3), 031001. doi: 10.1088/1741-2552/ab0ab5
18. D'Croz-Baron, D., Ramirez, J. M., Baker, M., Alarcon-Aquino, V., & Carrera, O. (2012, February). A BCI motor imagery experiment based on parametric feature extraction and fisher criterion. In CONIELECOMP 2012, 22nd International Conference on Electrical Communications and Computers (pp. 257-261). IEEE. doi: 10.1109/CONIELECOMP.2012.6189920
19. Dagdevir, E., & Tokmakci, M. (2023). Determination of effective signal processing stages for brain computer interface on BCI competition IV data set 2b: a review study. *IETE Journal of Research*, 69(6), 3144-3155. doi: 10.1080/03772063.2021.1914204
20. Dreyer, P., Roc, A., Pillette, L., Rimbert, S., & Lotte, F. (2023). A large EEG database with users' profile information for motor imagery brain-computer interface research. *Scientific Data*, 10(1), 580. doi: 10.1038/s41597-023-02445-z
21. Esri. (t.y.). How change point detection works. ArcGIS Pro documentation. <https://pro.arcgis.com/en/pro-app/latest/tool-reference/space-time-pattern-mining/how-change-point-detection-works.htm>
22. Fang, H., Jin, J., Daly, I., & Wang, X. (2022). Feature extraction method based on filter banks and Riemannian tangent space in motor-imagery BCI. *IEEE journal of biomedical and health informatics*, 26(6), 2504-2514. doi: 10.1109/JBHI.2022.3146274
23. Ferdi, A. Y., & Ghazli, A. (2025). Mind-Controlled Web Browser Navigation Based on Brain Computer Interfaces. *Algerian Journal of Signals and Systems*, 10(1), 24-28. doi: 10.51485/ajss.v10i1.260
24. Firoz, K. F., Seong, Y., & Yi, S. (2024). A preliminary study of neural signals of motor imagery task of arm movements through electroencephalography data classification with machine learning. In Proceedings of the 2024 IEEE 4th International Conference on Human-Machine Systems (ICHMS) (pp. 1–6). IEEE. doi: 10.1109/ICHMS59971.2024.10555801
25. Gao Z, Lu G, Yan P, Lyu C, Li X, Shang W, Xie Z, Zhang W. (2018). Automatic change detection for real-time monitoring of EEG signals. *Frontiers in physiology*, 9, 325. doi: 10.3389/fphys.2018.00325
26. Góngora, L., Paglialonga, A., Mastropietro, A., Rizzo, G., & Barbieri, R. (2022). A novel approach for segment-length selection based on stationarity to perform effective connectivity analysis applied to resting-state eeg signals. *Sensors*, 22(13), 4747. doi: 10.3390/s22134747

27. González-Cely, A. X., Soekadar, S. R., Delisle-Rodriguez, D., & Bastos-Filho, T. (2025, May). Lower-Limb Motor Imagery-Based Brain-Computer Interface to Control Treadmill Velocities. In 2025 International Conference On Rehabilitation Robotics (ICORR) (pp. 76-81). IEEE. doi: 10.1109/ICORR66766.2025.11063181
28. Hamavar, R., & Asl, B. M. (2025). Feature selection based on game theory optimization to achieve desired performance metrics in seizure onset detection. *Biomedical Signal Processing and Control*, 100, 107008. doi: 10.1016/j.bspc.2024.107008
29. Hamner, B., Leeb, R., Tavella, M., & Millán, J. D. R. (2011, August). Phase-based features for motor imagery brain-computer interfaces. In 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society (pp. 2578-2581). IEEE. doi: 10.1109/IEMBS.2011.6090712
30. Hou, Y., Chen, T., Lun, X., & Wang, F. (2022). A novel method for classification of multi-class motor imagery tasks based on feature fusion. *Neuroscience Research*, 176, 40-48. doi: 10.1016/j.neures.2021.09.002
31. Isa, N. M., Amir, A., Ilyas, M. Z., & Razalli, M. S. (2019). Motor imagery classification in Brain computer interface (BCI) based on EEG signal by using machine learning technique. *Bulletin of Electrical Engineering and Informatics*, 8(1), 269-275. doi: 10.11591/eei.v8i1.1402
32. Jin, L., Song, Y., Zhao, H., Cao, J., Cheung, V. C., & Liao, W. H. (2025). Frequency-Aware Spatial-Temporal Attention Explainable Network for EEG Decoding. *IEEE Journal of Biomedical and Health Informatics*. doi: 10.1109/JBHI.2025.3576088
33. Jo, S., Jung, J. H., Yang, M. J., Lee, Y., Jang, S. J., Feng, J., Heo, S., Kim, J., Shin, J., Jeon, J. & Park, H. S. (2022, July). EEG-EMG hybrid real-time classification of hand grasp and release movements intention in chronic stroke patients. In 2022 International Conference on Rehabilitation Robotics (ICORR) (pp. 1-6). IEEE. doi: 10.1109/ICORR55369.2022.9896592
34. Joy, M. M. H., Hasan, M., Miah, A. S. M., Ahmed, A., Tohfa, S. A., Bhuiyan, M. F. I., Zannat, A. & Rashid, M. M. (2020, March). Multiclass mi-task classification using logistic regression and filter bank common spatial patterns. In *International Conference on Computing Science, Communication and Security* (pp. 160-170). Singapore: Springer Singapore. doi: 10.1007/978-981-15-6648-6_13
35. Kaplan, A., Röschke, J., Darkhovsky, B., & Fell, J. (2001). Macrostructural EEG characterization based on nonparametric change point segmentation: application to sleep analysis. *Journal of neuroscience methods*, 106(1), 81-90. doi: 10.1016/S0165-0270(01)00331-4
36. Keković, G., & Sekulić, S. (2019). Detection of change points in time series with moving average filters and wavelet transform: Application to EEG signals. *Neurophysiology*, 51, 2-8. doi: 10.1007/s11062-019-09783-y
37. Killick, R., Fearnhead, P., & Eckley, I. A. (2012). Optimal detection of changepoints with a linear computational cost. *Journal of the American Statistical Association*, 107(500), 1590-1598. doi: 10.1080/01621459.2012.737745

38. Kim, K., Park, J. H., Lee, M., & Song, J. W. (2022). Unsupervised change point detection and trend prediction for financial time-series using a new cusum-based approach. *IEEE Access*, 10, 34690-34705. doi: 10.1109/ACCESS.2022.3162399
39. Kirch, C., Muhsal, B., & Ombao, H. (2015). Detection of changes in multivariate time series with application to EEG data. *Journal of the American Statistical Association*, 110(511), 1197-1216. doi: 10.1080/01621459.2014.957545
40. Koles, Z. J., Lazar, M. S., & Zhou, S. Z. (1990). Spatial patterns underlying population differences in the background EEG. *Brain topography*, 2(4), 275-284. doi: 10.1007/BF01129656
41. Maarouf, K., Alzahab, N. A., & Saad, G. (2024, October). The Effect of EEG Segment's Length on Mental Workload Detection. In 2024 IEEE International Conference on Metrology for eXtended Reality, Artificial Intelligence and Neural Engineering (MetroXRINE) (pp. 271-276). IEEE. doi: 10.1109/MetroXRINE62247.2024.10795942
42. Malladi, R., Kalamangalam, G. P., & Aazhang, B. (2013, November). Online Bayesian change point detection algorithms for segmentation of epileptic activity. In 2013 Asilomar conference on signals, systems and computers (pp. 1833-1837). IEEE. doi: 10.1109/ACSSC.2013.6810619
43. Manca, G., & Fay, A. (2022, March). Off-line detection of abrupt and transitional change points in industrial process signals. In 2022 4th International Conference on Applied Automation and Industrial Diagnostics (ICAAID) (Vol. 1, pp. 1-6). IEEE. doi: 10.1109/ICAAID51067.2022.9799507
44. Rosiani, U. D., Saputra, P. Y., & Hendrawan, M. A. (2021, October). The Impact of Segment Length on EEG Based Biometric System. In 2021 IEEE 7th Information Technology International Seminar (ITIS) (pp. 1-5). IEEE. doi: 10.1109/ITIS53497.2021.9791686
45. Sarma, P., & Barma, S. (2021). Emotion recognition by distinguishing appropriate EEG segments based on random matrix theory. *Biomedical Signal Processing and Control*, 70, 102991. doi: 10.1016/j.bspc.2021.102991
46. Schröder, A. L., & Ombao, H. (2019). FreSpeD: Frequency-specific change-point detection in epileptic seizure multi-channel EEG data. *Journal of the American Statistical Association*, 114(525), 115-128. doi: 10.1080/01621459.2018.1476238
47. Shahlaei, F., Bagh, N., Shaligram, A. D., Reddy, M. R., & Zambare, M. S. (2018, June). Classification of motor imagery tasks using inter trial variance in the brain computer interface. In 2018 IEEE International Symposium on Medical Measurements and Applications (MeMeA) (pp. 1-6). IEEE. doi: 10.1109/MeMeA.2018.8438648
48. Steyrl, D., Scherer, R., Faller, J., & Müller-Putz, G. R. (2016). Random forests in non-invasive sensorimotor rhythm brain-computer interfaces: a practical and convenient non-linear classifier. *Biomedical Engineering/Biomedizinische Technik*, 61(1), 77-86. doi: 10.1515/bmt-2014-0117

49. Subasi, A., & Mian Qaisar, S. (2021). The Ensemble Machine Learning-Based Classification of Motor Imagery Tasks in Brain-Computer Interface. *Journal of Healthcare Engineering*, 2021(1), 1970769. doi: 10.1155/2021/1970769
50. Truong, C., Oudre, L., & Vayatis, N. (2020). Selective review of offline change point detection methods. *Signal Processing*, 167, 107299. doi: 10.1016/j.sigpro.2019.107299
51. Vidaurre, C., Sannelli, C., Müller, K. R., & Blankertz, B. (2010, June). Machine-learning based co-adaptive calibration: a perspective to fight BCI illiteracy. In *International Conference on Hybrid Artificial Intelligence Systems* (pp. 413-420). Berlin, Heidelberg: Springer Berlin Heidelberg. doi: 10.1007/978-3-642-13769-3_50
52. Vuckovic, A., Wallace, L., & Allan, D. B. (2015). Hybrid brain-computer interface and functional electrical stimulation for sensorimotor training in participants with tetraplegia: a proof-of-concept study. *Journal of neurologic physical therapy*, 39(1), 3-14. doi: 10.1097/NPT.0000000000000063
53. Xu, F., Uszkoreit, H., Du, Y., Fan, W., Zhao, D., & Zhu, J. (2019, September). Explainable AI: A brief survey on history, research areas, approaches and challenges. In *CCF international conference on natural language processing and Chinese computing* (pp. 563-574). Cham: Springer International Publishing. doi: 10.1007/978-3-030-32236-6_51
54. Yang, J., Ma, Z., & Shen, T. (2021). Multi-time and multi-band CSP motor imagery EEG feature classification algorithm. *Applied Sciences*, 11(21), 10294. doi: 10.3390/app112110294
55. Zhang, C., & Eskandarian, A. (2020, July). A computationally efficient multiclass time-frequency common spatial pattern analysis on EEG motor imagery. In *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* (pp. 514-518). IEEE. doi: 10.1109/EMBC44109.2020.9176705
56. Zhang, R., Xiao, X., Liu, Z., Jiang, W., Li, J., Cao, Y., Ren, J., Jiang, D. & Cui, L. (2018). A new motor imagery EEG classification method FB-TRCSP+ RF based on CSP and random forest. *IEEE Access*, 6, 44944-44950. doi: 10.1109/ACCESS.2018.2860633