



Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi

<https://dergipark.org.tr/tr/pub/yyufbed>



Araştırma Makalesi

Kişiden Bağımsız Çevrimiçi P300-Tabanlı Beyin-Bilgisayar Arayüzü Sınıflandırma Modeli Oluşturulması

Onur Erdem KORKMAZ*¹, Önder AYDEMİR², Emin Argun ORAL³, İbrahim Yücel ÖZBEK³

¹Atatürk Üniversitesi, İspir Hamza Polat M.Y.O, Elektrik ve Enerji Bölümü, 25900, Erzurum, Türkiye

²Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği, 61080, Trabzon, Türkiye

³Atatürk Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği, 25240, Erzurum, Türkiye
Onur Erdem KORKMAZ, ORCID No: 0000-0001-6336-6147, Önder AYDEMİR, ORCID No: 0000-0002-1177-8518, Emin Argun ORAL, ORCID No: 0000-0002-8120-9679, İbrahim Yücel ÖZBEK, ORCID No: 0000-0002-5734-7430

*Sorumlu yazar e-posta: onurerdem.korkmaz@atauni.edu.tr

Makale Bilgileri

Geliş: 23.02.2022
Kabul: 18.03.2022
Online Nisan 2022
DOI:10.53433/yyufbed.1077648

Anahtar Kelimeler

Beyin-bilgisayar arayüzü,
Çevrimiçi,
Kişiden bağımsız model,
Olay ilişkili potansiyeller,
EEG

Öz: Beyin-bilgisayar arayüzleri, elektroensefalografi sinyallerini bilgisayar komutlarına çevirerek insan beyni ile bilgisayar veya harici cihazlar arasında iletişim kurmaya yarayan sistemlerdir. Bu sistemlerin en büyük sınırlamalarından biri, kişiye özgü modelin geliştirilmesinin uzun sürmesi, böylelikle de hasta bireylerin tak-çalıştır konforundan yararlanamamasıdır. Yapılan bu çalışma ile geliştirilen yeni paradigma kullanılarak çevrimdışı oturumda 10 katılımcıdan toplanılan verilerle kişiden bağımsız çalışan sınıflandırma modeli geliştirildi. Öncelikle olay ilişkili potansiyel ve olay ilişkili olmayan potansiyel tespitinin gerçekleştirildiği bu ikili sınıflandırma probleminde 50 kez tekrarlanan sınıflandırma işlemi sonucunda 99.40 ± 0.21 test doğruluğu elde edilmiş ve kişiden bağımsız model olarak kaydedilmiştir. Geliştirilen bu model farklı 30 katılımcının kendilerinin belirlediği kelimelerin yazdırılması şeklinde test edilmiştir. Önerilen kişiden bağımsız bu modelin çevrimiçi karakter tespit etme başarısı ise 95.41 olarak hesaplanmıştır.

Creating an Online Subject Independent P300-Based Brain-Computer Interface Classification Model

Article Info

Received: 23.02.2022
Accepted: 18.03.2022
Online April 2022
DOI:10.53433/yyufbed.1077648

Keywords

Brain-computer interface,
Online,
Subject-independent model,
Event related potentials,
EEG

Abstract: Brain-computer interfaces convert electroencephalography signals into computer commands to communicate between the human brain and computer or external devices. However, one of the most significant limitations of these systems is that it takes a long time to develop a subject-independent model, so patients cannot benefit from the plug-and-play comfort. With this study, we created our data set with the data we collected from 10 people in the offline session using new paradigm we developed. A brain-computer interface classification model that works subject-independent was created with this data set. First of all, in the binary classification problem in which event-related potential and non-event-related potential detection were performed, $99.40\% \pm 0.21$ test accuracy was obtained due to the classification process being repeated 50 times, and this model was saved. This developed model was tested by printing the words that 30 different participants determined themselves. This model's online character detection success, subject independent, was 95.41% .

1. Giriş

Beyin-bilgisayar arayüzleri (BBA), elektroensefalografi (EEG) sinyalini bilgisayar komutlarına çevirerek insan beyni ile bilgisayar veya harici cihazlar arasında iletişim kurmaya yarayan sistemlerdir (Ergün & Aydemir, 2020; Wolpaw ve ark., 2000; Xu ve ark., 2018; Zhang ve ark., 2019; Ahmad & Ahuja, 2022). Yani EEG sinyalleri tıpkı bir fare veya klavye gibi kullanılarak bir bilgisayar kontrol edilebilir. Genel olarak EEG sinyallerindeki motor görüntüleri (Devlaminck ve ark., 2011; Kevric & Subasi, 2017; Park ve ark., 2012), olayla ilgili P300 potansiyellerini (Kleih & Kübler, 2013; Sellers ve ark., 2006; Xu ve ark., 2013) veya kararlı durum görsel olarak uyarılmış potansiyelleri (Jalilpour ve ark., 2020; Muller & Pfurtscheller, 2007; Wu ve ark., 2008) içeren özellikleri kullanır. EEG tabanlı BBA sistemlerinde olaya bağlı P300 potansiyelleri (ing. Event Related Potentials, ERPs), kısa sürede ortaya çıkmaları, göz hareketi artefaktları ile bozulmamaları ve bu sistemlerin ön eğitim aşaması gerektirmemeleri nedeniyle sıklıkla tercih edilmektedir. Bu nedenle, sınıflandırma doğruluğu (SD) ve bilgi aktarım hızı (BAH) açısından yüksek performanslı BBA sistemleri oluşturulabilmektedir.

Literatürde P300 heceleyici için kişiye özel ve kişiden bağımsız (ing. subject independent) olmak üzere iki farklı eğitim yaklaşımı vardır (Loizidou ve ark., 2022). Bazı çalışmalarda bu yaklaşımlar kişiye özel eğitim ve genel eğitim olarak da adlandırılmaktadır (Mussabayeva ve ark., 2021). Wu ve arkadaşlarının yaptıkları çalışmada 11 katılımcı ile iki farklı paradigmada çevrimdışı (ing. offline) veri alınmıştır. Birinci oturumda hedef karakter yeşil daire içine yerleştirilmiş, ikinci paradigmada ise bu yeşil dairenin alt veya üst kısmına kırmızı nokta yerleştirilerek veriler kaydedilmiştir. Sonuç olarak ikinci paradigmanın katılımcıların dikkatini artırdığı, daha yüksek sınıflandırma doğruluğu-ITR elde edildiği ve bu farkın istatistiksel olarak farklı olduğu gösterilmiştir (Wu ve ark., 2020). Diğer çalışmada ise kişinin kendi siması ve tanıdık simalarla P300 heceleme paradigması oluşturulmuş ve her iki paradigmanın sonuçları karşılaştırılmıştır. Çalışmaya toplam 20 denek katılmış, bunlardan bir grup çevrimdışı deneye katılmış ve diğer grup çevrimiçi deneye katılmıştır. Sonuçlar incelendiğinde kişinin kendi simasının kullanıldığı paradigmada özellikle parietal ve fronta-sentral bölgelerde ERP genlikleri daha yüksek olduğu görülmüştür (Lu ve ark., 2020). Diyafram kullanımının ERP yanıtına etkisinin incelendiği bir diğer çalışmada ise Kirasirova ve arkadaşları azaltılmış görme alanının ERP yanıtını daha belirgin hale getirdiğini göstermişlerdir (Kirasirova ve ark., 2020). 4x4 karakter dizisine sahip paradigma ile toplam 10 kişiyle deneyler gerçekleştirilmiştir. Sonuçlar incelendiğinde görme alanının diyafram ile sınırlandırılmasının ERP yanıtını daha da belirginleştirdiği ispatlanmıştır. P300 heceleme paradigmalarında görsel modülasyonların değerlendirildiği çalışmada ise (Zhang ve ark., 2021) toplam 10 kişiyle çevrimiçi ve çevrimdışı deneyler gerçekleştirilmiş, sonuçlar incelendiğinde beyaz çerçeve içerisindeki kırmızı yüz paradigmasının çevrimiçi oturumda mavi çerçeve içerisindeki kırmızı yüz paradigması ve kırmızı çerçeve içerisindeki kırmızı yüz paradigmasından daha yüksek ortalama doğruluk sağladığını göstermişlerdir.

Günümüz BBA uygulamaları genelde kişiye bağlı model kullanılarak gerçekleştirilmektedir. Kişiye bağlı modelin geliştirilmesi de hem uzun sürmekte hem de zahmetli olmaktadır. Bu nedenle bu sistemler günlük hayatta tak-çalıştır konforundan uzaktır. Bu dezavantajları ortadan kaldırmak için bu çalışma ile literatüre iki önemli katkı sunulmaktadır.

- BBA çalışmalarında kişiye özgü geliştirilen modellerin sadece o kişi tarafından kullanılabilmesi bu alanın en önemli kısıtlarındandır. Geliştirilen yeni üç boyutlu sütun (3B-S) flaşlanma tabanlı P300 heceleme paradigması kullanılarak, 10 kişiden çevrimdışı oturumda (ÇDO) EEG verisi alınmıştır. Elde edilen bu verilerle kişiden bağımsız P300 sınıflandırma modeli geliştirilmiştir. Kişiden bağımsız çalışan ve herhangi bir ön eğitim aşaması gerektirmeyen heceleme modeli bu açıdan özgündür.
- Ayrıca literatürde yapılan bir çok BBA çalışması (Wu ve ark., 2020) çevrimdışı gerçekleştirilmektedir. Bu çalışmada çevrimiçi (ing. online) kelime tespiti yapılmıştır. Geliştirilen kişiden bağımsız model kullanılarak farklı 30 kişiyle çevrimiçi oturumda (ÇİO) serbest kelimeler yazdırılarak modelin çevrimiçi performansı belirlenmiştir. Kişiden bağımsız çalışan modelle çevrimiçi kelime tespitinin yapılması yönüyle de çalışmamız literatüre önemli katkı sunmaktadır.

2. Materyal ve Yöntem

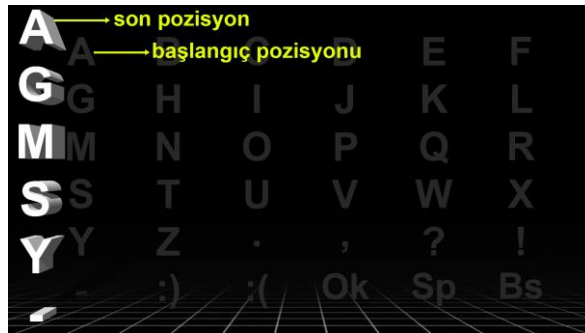
2.1. Katılımcılar

Veri toplama süreci Atatürk Üniversitesi Sağlık Bilimleri Enstitüsünün B.30.2.ATA.0.01.00/35 sayılı ve 15.02.2018 tarihli Etik Kurulu tarafından onaylanmış ve tüm katılımcılar EEG kaydı başlamadan önce kurul tarafından doğrulanan onay formunu imzalamışlardır. Çalışmanın ÇDO'na beş erkek (yaş ortalaması 28 ± 4.84) ve beş kadın (yaş ortalaması 27 ± 4.15) olmak üzere toplam on gönüllü katıldı. Modelin test edildiği ÇİO'na ise 21 erkek (yaş ortalaması 30.14 ± 6.85) ve 9 kadın (yaş ortalaması 26.33 ± 4.87) olmak üzere toplam 30 katılımcı katıldı. Tüm katılımcılar sağ elini kullanmakta ve herhangi bir görme ya da nörolojik bozuklukları bulunmamaktadır. Katılımcılardan yedisi daha önce benzer bir deneye katılmışken, diğerlerinin daha önce BBA deneyimi bulunmamaktadır.

2.2. Paradigma


Bu paradigmanın klasik yaklaşımdan en büyük farkı, literatürde verilen iki ayrı paradigmanın birleşiminden oluşmasıdır. Ramirez-Quintana ve arkadaşları (Ramirez ve ark., 2021) tarafından önerilen yalnızca sütun tabanlı flaşlanma ile Qu ve arkadaşları (Qu ve ark., 2018) tarafından önerilen tek bir karakterin üç boyutlu (3B) flaşlanması yöntemlerinin birleştirilmesiyle oluşturulan bu yeni paradigma hem yalnızca sütun yaklaşımını hem de 3B flaşlanmayı (yanıp sönmeyi) içerdiğinden, 3B-S paradigma olarak adlandırılmıştır. Bu yaklaşımın klasik yaklaşımdan bazı önemli farklılıkları bulunmaktadır. İlk olarak, karakter matrisinin sütunları birbiri ardına flaşlandıktan sonra, bu satırlar transpoze edilerek [satur^T] sütun olarak da flaşlandırılır. Bu fikir, batı ülkelerinin metinleri yatay olarak okuma alışkanlığı nedeniyle, sütunları kullanan P300 paradigmalarında ERP dalgasının genliğinin satır temelli paradigmadan daha büyük olduğu gerçeğine dayanmaktadır (Brysbart, 2019; Ramirez ve ark., 2021). Öte yandan, Qu ve arkadaşlarının 3B tek karakter flaşlanmasının BBA performansını artırdığı fikrinin yanında, Orlandi ve arkadaşları (Orlandi & Proverbio, 2019), 3B görsellerin beynin ERP yanıtını artırdığını söylemektedirler. Bu fikirlerden yola çıkarak, çalışmamızda ERP yanıtını artıracak daha verimli ve daha hızlı bir BBA paradigması tasarlanmıştır. Önerilen paradigma, 3D animasyonlar tarafından desteklenen ve yalnızca sütun flaşlanmasının yapıldığı hibrit bir yaklaşımdır.

Önerilen 3B-S görsel paradigma örneği Şekil 1'de gösterilmektedir. Adobe Photoshop CC 2017'de (Adobe Photoshop®, 2017) hazırlanan bu şekil, 3B görselleştirmenin etkisini göstermektedir. Burada orijinal iki boyutlu (2B) karakter seti arka planda soluk bir renkle görüntülenirken, 3B efektli belirli bir sütun, ön planda parlak bir renkle gösterilir. Her karakterin 3B perspektif görünümle yeniden konumlandırıldığı bu şekilden açıkça görülmektedir. Örneğin, "A" karakterinin başlangıç ve son konumları farklı olup, bu şekilde her ikisi işaretlenmişlerdir.



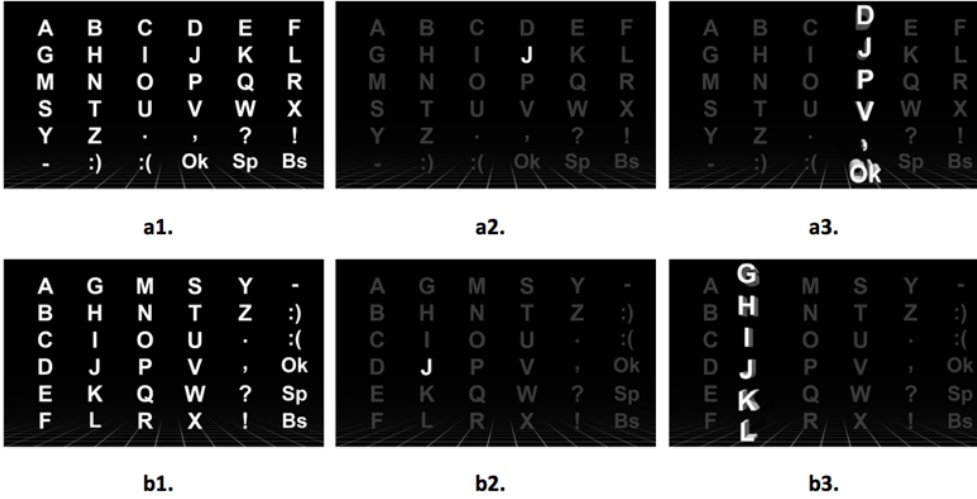
Şekil 1. Üç boyutlu görsel paradigma.

3B animasyon efekti üç adımda gerçekleştirilir. İlk adımda, 75 milisaniye (ms) (ara uyarın aralığı, AUA) süreyle arka plan karakter seti görüntülenir. Ardından, yanıp sönen sütun, ön planda 100ms boyunca görüntülenir. Son olarak, arka plan karakter seti 75ms süreyle tekrar görüntülenir. Bu 3 adımlı animasyon Şekil 2'de gösterilmektedir. Bu çalışmada kullanılan bu paradigmanın bir örneğine <https://youtu.be/mJbak5xPB7w> bağlantısından ulaşılabilir.



Şekil 2. Üç boyutlu animasyon efekti.

3B-S paradigmasının bir diğer dikkat çekici özelliği transpoze edilmiş satırların sütun olarak da gösterilmesidir. Bunun bir örneği Şekil 3'te gösterilmiştir. Başlangıçta, paradigmada yer alan altı sütunun tümü, 15 kez rastgele 3B olarak flaşlandırılır ve toplam 90 adet sütun flaşlanması (6x15) gerçekleştirilir. Burada, Şekil 3.a1 orijinal karakter setini, Şekil 3.a2 hedef karakteri (örneğin "J") ve Şekil 3.a3 ise sütun flaşlanmalarına örnek bir ekran görüntüsünü göstermektedir. Sütun flaşlanmalarının tamamlanmasından sonra satırların transpozu alınarak Şekil 3.b1 ile gösterilen yeni karakter seti elde edilir. Daha sonra Şekil 3.b2'de görüldüğü gibi hedef karakterin yeni konumu gösterildikten sonra satırların transpozları sütunlar şeklinde flaşlandırılarak yine toplam 90 flaşlanma işlemi gerçekleştirilir. Flaşlanma adımına bir örnek Şekil 3.b3'de görülmektedir.




Şekil 3. Üç boyutlu animasyon efekti.

2.3. Deneysel prosedürü

Tüm deneysel çalışma oturumları loş ışıklı ve sesiz bir odada gerçekleştirildi. Katılımcılar 27 inç ekrandan 1 metre uzaklıkta bulunan rahat bir koltukta otururken veri kaydı yapıldı. Çalışmada, 3B-S tabanlı görsel P300 yazım paradigması kullanılarak 1920 x 1080 çözünürlüklü bir LED ekranda hedef uyarılar gösterildi. Önce 10 kişilik birinci grup ile sınıflandırma modelinin geliştirildiği ÇDO aşaması gerçekleştirildi. Sonrasında ise daha önce modelin geliştirildiği oturuma katılmamış farklı 30 kişi ile modelin çevrimiçi test edildiği ÇİO aşaması yürütüldü.

ÇDO'da, katılımcıya hedef karakter gösterilerek 6 sütunun tamamı rastgele flaşlandırılır ve bu süreç sütun dizisi flaşlandırılması olarak tanımlanır. Öte yandan, bir hedef karakter için toplam 15 sütun dizisi flaşlandırılması ise bir koşul olarak tanımlanır. Bir hedef karakter için gerçekleştirilen 15 koşul sütun flaşlanması sonucunda toplam 90 flaşlanma (6x15) gerçekleştirilmektedir. Daha sonra satırların transpozu $[\text{satır}]^T$ alınarak hedef karakterin yeni konumu gösterilip, $[\text{satır}]^T$ lar için de aynı prosedür tekrarlanır. Dolayısıyla bir hedef karakter için 90 sütun ve 90 $[\text{satır}]^T$ flaşlanması olmak üzere toplam 180 flaşlanma gerçekleştirilmektedir. ÇDO esnasında her bir katılımcıya toplam 60 karakter hedef olarak gösterilip, EEG kayıtları alınmaktadır. Şekil 4 ile bu çalışmada yer alan sütun flaşlandırılmaları ve koşul örneği gösterilmiştir.


ÇDO'da deneyler sırasında deneklere, göz kırpmaya dahil gereksiz hareketlerden kaçınmaları, hedef karaktere dikkat etmeleri ve hedef karakterin flaşlanma sayısını sessizce saymaları talimatı verilmiştir. Katılımcıların dinlenmesi için her 15 hedef karakterden sonra 3 dakikalık aralar verilmiştir.



Şekil 4. Deney prosedürü.

ÇİO'da ise katılımcıya hedef karakter gösterilmeyip bunun yerine bir kelime belirleyip, bunu önerilen BBA sistemini kullanarak yazdırmaları istenmiştir. Yine bu oturumda da 6 adet sütunun tamamı rastgele 15 kez, daha sonra 6 adet [satur]^T ların tamamı 15 kez flaşlandırılarak toplam 180 flaşlanma ile hedef karakter tanıma işlemi gerçekleştirilmiştir. ÇDO'da elde edilen veriler kullanılarak oluşturulan ve kişiden bağımsız çalışan sınıflandırma modeli kullanılarak ÇİO'da karakter tespiti yapılmıştır.

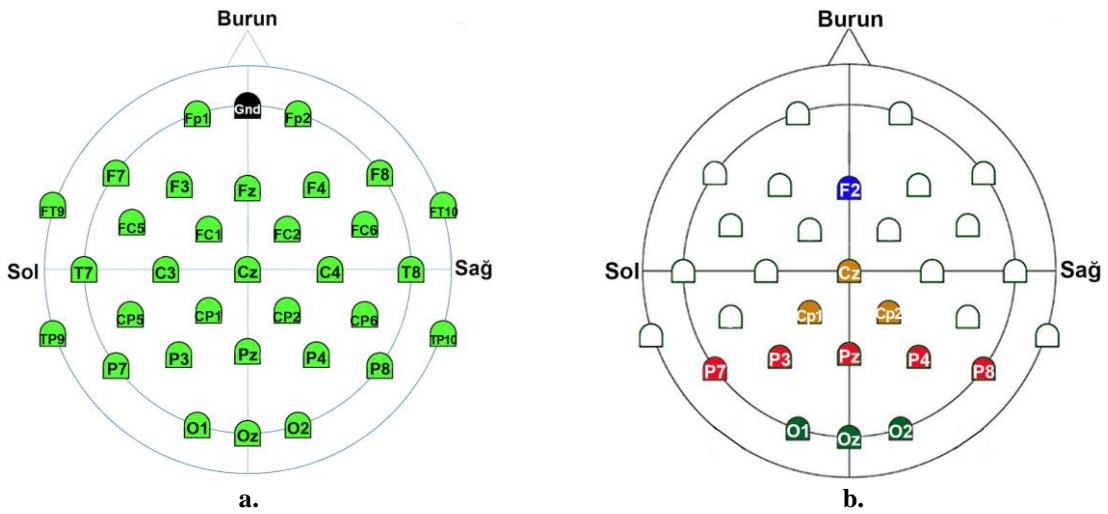
Çalışmada kullanılan düzenek Şekil 5 ile gösterilmiştir. ÇDO'da aşamasında kullanılan veri toplama düzeneği Şekil 5.a ile ÇİO aşamasında kullanılan düzenek ise Şekil 5.b ile gösterilmiştir. ÇDO veri toplama düzeneği; biri görsel uyaran sunumunun yapıldığı diğeri ise veri kaydının yapıldığı iki ayrı bilgisayar ve görsel uyaran sunumunun yapıldığı esnada beyin tepkilerinin ölçüldüğü EEG cihazından oluşmaktadır. Burada uyaran sunumu bir MATLAB (Matlab®, 2018) yazılımı kullanılarak gerçekleştirilmektedir. Uyaran sunumunun yapıldığı bilgisayardan gelen ve hangi sütun ya da [satur]^T un flaşlandığına dair indis bilgisi ile elektrotlardan gelen beynin elektriksel aktivitesi, EEG cihazı tarafından birleştirilerek kayıt bilgisayarına gönderilmektedir. Böylece, EEG verileri ve görsel uyaran indeksi zaman kilitli olarak kaydedilmektedir. ÇİO'da bu sisteme ek olarak; EEG ve indis bilgileri uyaran sunumunun yapıldığı bilgisayarda arka planda çalışan ve karar verici olarak görev yapan ikinci bir MATLAB yazılımına yerel ağ üzerinden gönderilmektedir. Gelen bu bilgilerden hedef karakter belirlenerek, uyaran sunumunun yapıldığı sunum yürüten MATLAB yazılımına aktarılmaktadır. Uyaran sunumu yapıldıktan sonra verilerin arka planda çalışan karar verici MATLAB'a gönderilmesi ve hedef karakterin tespit edilmesi süreci yaklaşık 3-4 saniye (s) sürmektedir. Böylelikle ÇİO'da uyaran sunumu yapıldıktan 3-4s sonra hedef karakter tespit edilerek çevrimiçi olarak ekrana yazdırılmaktadır.



Şekil 5. Veri toplama prosedürü a. çevrimdışı b. çevrimiçi.

2.4. Veri kaydı

EEG verileri 32 kanaldan actiCHamp (Brain Products GmbH, Gilching, Almanya) cihazıyla uluslararası 10-20 yerleşim sistemine göre alınmıştır. 250Hz örnekleme frekansına sahip kayıtlar 'Fz' referans elektrotu ve alın bölgesine yerleştirilen toprak elektrotu kullanılarak kaydedilmişlerdir. Yürütülen deneyler boyunca, tüm elektrotların empedanslarının 5kΩ değerinin altında olabilmesi için jel uygulanarak kullanılmışlardır. Veri alınırken kullanılan tüm elektrotların dizilimi Şekil 6.a'da görülmektedir. Şekil 6.b'de ise analizde kullanılan sentral, pariyetal ve oksipital EEG kanal grupları sırasıyla turuncu, kırmızı ve yeşil renkle kodlanarak gösterilmişlerdir.

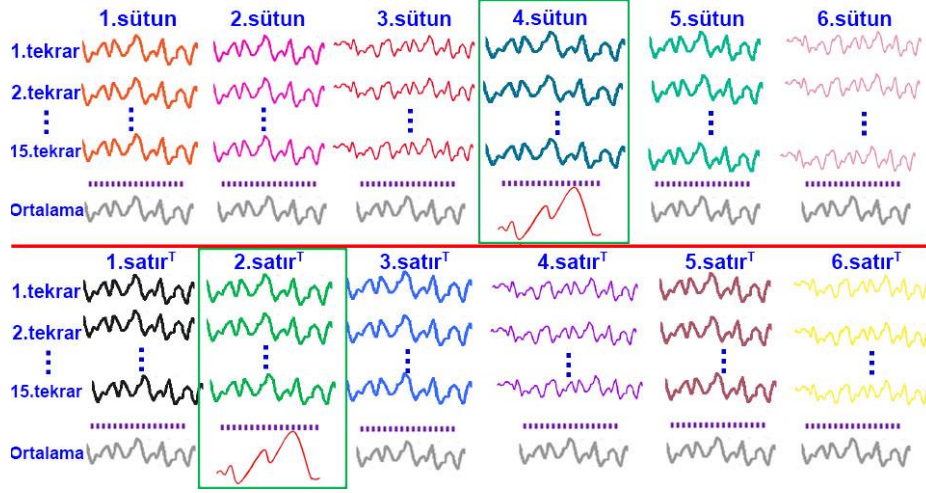


Şekil 6. a. Veri alımında kullanılan elektrotlar b. Analizde kullanılan elektrotlar.

2.5. Veri işleme ve analizi

Elde edilen EEG sinyallerine ön işleme, parçalama, taban hattının temizlenmesi ve ortalama alma olmak üzere dört aşamalı veri işleme adımları uygulanmaktadır. Çalışmada 31 kanaldan elde edilen EEG verilerinde yer alan P300 dalgaları düşük frekans bileşenlerine sahip olduğundan (Rakotomamonjy & Guigue, 2008), gürültü giderme için uygulanan ön işleme adımında 0.1-10Hz bant geçiren filtreleme işlemi uygulanır. Parçalama adımında, sütun ya da [satur]^T flaşlandıktan önceki 200ms'lik ve sonraki 1 000ms'lik EEG verisi tüm kanallar ve sütun-[satur]^T indisleri için ayrı ayrı elde edilir. Şekil 7'de bir kanal için tüm sütun ve [satur]^T larına ait 15 flaşlanma sonrası 1.2s'lik (1 000ms + 200ms) EEG parçalarının temsili görüntüleri yer almaktadır. Taban hattının temizlenmesi aşamasında ise 1.2s'lik her bir EEG parçasının hedef uyarı gelmeden önceki 200ms uzunluğundaki verisi kullanılarak taban çizgisi belirlenir ve uyarıdan sonraki 1 000ms veri bu taban hattına göre düzenlenir. Ortalama alma aşamasında ise her bir kanal için tüm sütun-[satur]^T larına ait parçaların ortalaması alınarak olay ilişkili

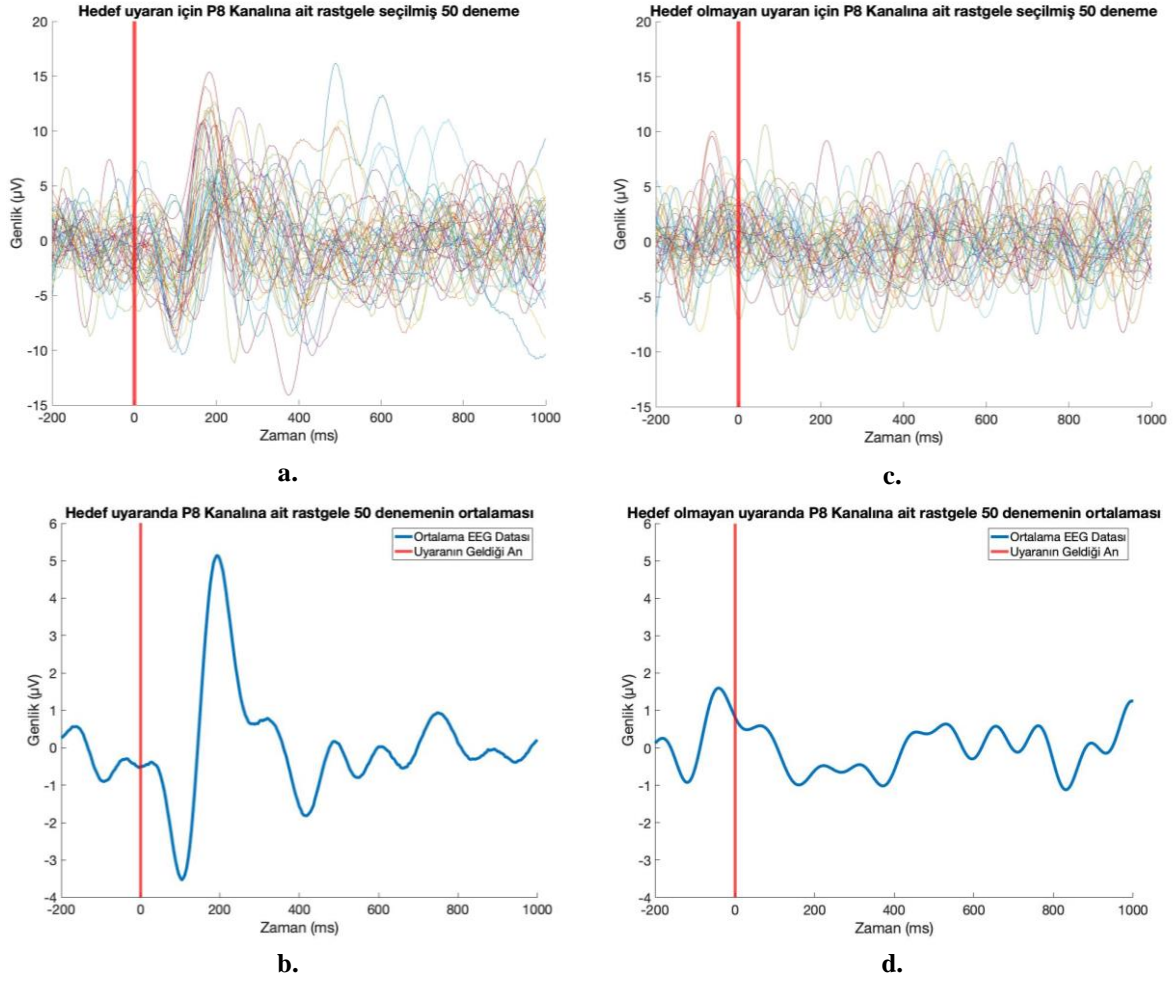
potansiyeller (OİP) elde edilir. Bunlar Şekil 7’de her bir sütunun altında temsili olarak gösterilmişlerdir. Şekilde hedef karakterin mesela ‘J’ (4.sütun ve 2.satır^T) olduğu durumda; EEG parçalarının ortalaması alındığında 4.sütun ve 2.[satır]^T da OİP elde edilirken, diğer tüm sütun veya [satır]^T ortalamalarında benzer OİP oluşmadığı gösterilmektedir.



Şekil 7. Bir kanal için sütun ve [satır]^T'leri flaşlanmalarından sonra elde edilen EEG parçaları.


2.6. Sınıflandırma

ÇDO’da katılımcılara toplam 60 harf hedef karakter olarak gösterilmiştir. Bu hedef karakter için altı sütun arasından bir tanesi ve altı [satır]^T arasından bir tanesi hedef karaktere ait EEG parçası içeriyorken, kalan 10 sütun-[satır]^T a ait EEG parçaları hedef karakteri içermemektedir. Dolayısıyla bir kanalda bir hedef karakter için 2 hedef uyaran (P300 içeren) sinyali ve 10 adet hedef uyaran içermeyen (P300-olmayan) sinyal mevcuttur. Bir katılımcıya 60 hedef karakter gösterildiğinden; bir kişi için bir kanalda toplam 120 adet P300 ve 600 adet P300-olmayan sinyal mevcuttur. ÇDO’da toplam 10 katılımcıyla deneyler gerçekleştirildiğinden; bir kanal için 1 200 adet P300 ve 6 000 adet P300-Olmayan EEG datası mevcut olup, önerilen çalışma P300-içeren/P300-içermeyen ikili sınıflandırma problemi olarak ele alınmıştır. Şekil 8’de örnek olarak; P8 kanalı için 1 200 adet P300 içeren sinyallerden rastgele seçilmiş 50 örnek (Şekil 8.a) ve bu örneklerle ait ortalama (Şekil 8.b) ve benzer şekilde 6 000 adet P300-Olmayan sinyali içerisinde yine rastgele seçilmiş 50 örnek (Şekil 8.c) ve bu örneklerin ortalaması (Şekil 8.d) görülmektedir. Bu sonuçlarda uyarının geldiği an 0.sn’de kırmızı düz bir çizgi ile gösterilmiştir. Şekil 8’de yer alan grafiklerin görsel olarak ayırt edilebilmesi için sadece 50 örnek ortalaması kullanılarak elde edilen ortalama EEG sinyallerinin karşılaştırılmalarından; tamamen ayırt edilebilir ölçüde farklılık oluştuğu gözlenmektedir. Ayrıca elde edilen bu ortalama EEG işaretlerinde uyarandan önceki 200ms’lik taban hattı ve uyarandan sonraki 1 000ms’lik EEG parçaları görülmektedir.

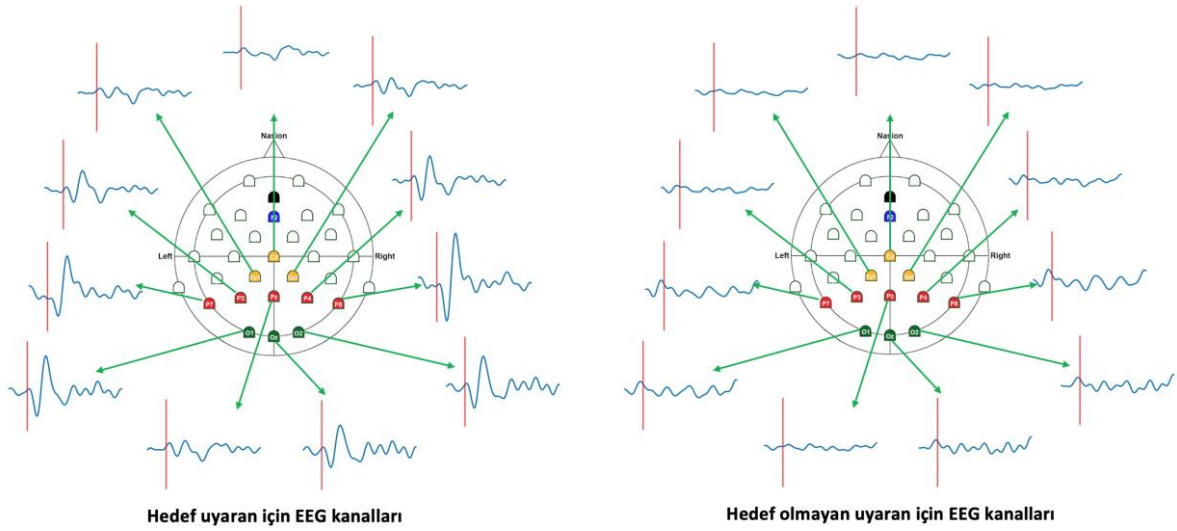


Şekil 8. P8 kanalına ait hedef ve hedef olmayan uyarılara ait elli örneklik (a.ve c.) ve bu elli örneğe ait ortalama (b. ve d.) EEG sinyalleri.

Benzer şekilde P8 kanalı için tüm 1 200 adet hedef uyarı içeren ve 6 000 adet hedef uyarı içermeyen (toplam 7 200 adet) tüm denemelerin ortalamaları alınarak (ing. grand average) elde edilen grafikler ise Şekil 9'da görülmektedir. Grafiklerde yatay eksen ms cinsinden zamanı, dikey eksen ise -4 ile 6 arasında mikrovolt (μV) cinsinden genliği göstermektedir. Görüldüğü üzere tüm denemelerin ortalamaları da benzer sonuçlar üretmektedir. Hedef ve hedef olmayan uyarılara ait tüm denemelerin ayrı kanallar bazında ortalamaları alınarak elde edilen grafikler ise Şekil 10'da görülmektedir. Bu şekilde gösterilen tüm grafiklerdeki eksen bilgisi Şekil 9'dakilerle aynı olup, şekilsel açıdan farklılığın değerlendirilmesi, görselin karışmaması ve farkın daha rahat görülebilmesi için eksen bilgileri ayrıca gösterilmemiştir. Çalışmada kullanılan 11 kanalda (Cz, Cp1, Cp2, Pz, P3, P4, P7,P8, Oz, O1 ve O2) da benzer şekilde hedef uyarı içeren ve içermeyen EEG datalarının birbirinden ayrıt edilebildiği bu şekilde görülmektedir.



Şekil 9. Hedef ve hedef olmayan uyaranlara ait tüm denemelerin P8 kanalı bazında ortalamaları.



Şekil 10. Hedef ve hedef olmayan uyaranlara ait tüm denemelerin analizde kullanılan kanallar bazında ortalamaları.

Analizde kullanılan her bir kanala ait uyaran öncesi 200ms'lik (50 zaman noktası) ve uyaran sonrası 1000ms'lik (250 zaman noktası) EEG parçaları yan yana eklenerek toplam 300 zaman noktasından oluşan veri grupları da benzer şekilde toplam 11 kanal için art arda getirilerek; sınıflandırılma çalışmalarında kullanılan ve 3 300 (11x300) zaman noktasından oluşan veri vektörleri oluşturulmuştur. Bu vektörler kullanılarak sınıflandırma modeli oluşturulurken; 7 200 adet vektör her defasında rastgele biçimde %60 eğitim, %20 doğrulama ve %20 test olmak üzere üç parçaya ayrılarak, toplamda 50 kez sınıflandırma işlemi tekrarlanarak bu işlem gerçekleştirilmiştir. Önerilen çalışmada bu amaçla tek çıkış nöronlu iki katmanlı yapay sinir ağı (YSA) modeli kullanılmıştır. Dolayısıyla bir adet gizli katmana sahip ve 50 nöronlu olarak tasarlanmış bu YSA modeli aşağıdaki gibi ifade edilir.

$$\hat{y} = \tilde{g}\left(\sum_{j=1}^M w_{1j}^{(2)} * g\left(\sum_{i=1}^d w_{ji}^{(1)} * x_i + w_{j0}^{(1)}\right)\right) + w_{11}^{(2)} \quad (1)$$

Burada (x_i) , i 'inci girişi, $(w_{ji}^{(k)})$ k 'ıncı katmandaki i 'inci nöronu j 'inci nörona bağlayan katman ağırlığını, (g) tan-sigmoid fonksiyonunu ve (\tilde{g}) lineer fonksiyonu ifade etmektedir. Ayrıca, (d) giriş vektörünün boyutunu ($d=300$) ifade etmektedir. Tüm veri seti için toplam hata ise;

$$J(w) = -\frac{1}{N} \sum_{n=1}^N [y_n \log \hat{y}_n + (1 - y_n) \log (1 - \hat{y}_n)] \quad (2)$$

Burada (N) veri setindeki toplam örnek sayısını, (\hat{y}_l) sinir ağı modeli tarafından hesaplanan tahmini değerdir ve (y_l) ise örneğin etiketini ifade etmektedir.

Geliştirilen bu model kullanılarak ÇİO'da farklı 30 kişi ile eş zamanlı karakter belirleme işlemi gerçekleştirilmiştir. ÇDO'da kullanılan aynı kanallar kullanılarak gerçekleştirilen analizde; 6 sütun ve 6 [satır]^T arasından bir P300 sinyali tespit edilerek, katılımcının odaklandığı karakter çevrimiçi olarak tespit edilmiştir. İşleme ait örnek video dosyasına <https://youtu.be/qs2w9rhwcaM> linkinden ulaşılabilir.

3. Bulgular

Yürütülen çalışmalarda, ÇDO olarak yürütülen kişiden bağımsız sınıflandırma modeli oluşturulurken kullanılan 10 kişi (model geliştirilen katılımcılar) K1-K10 ile gösterilmiştir. Bu veri; hedef uyaran içeren (sınıf1) veri (1 200x3300 boyutlu veri ve 1 200x1 boyutlu etiket) ile hedef uyaran içermeyen (sınıf2) veri (6 000x3300 boyutlu veri ve 6 000x1 boyutlu etiket) olmak üzere düzenlenmiş olup, her defasında daha önce de ifade edildiği gibi rastgele olarak %60 eğitim, %20 doğrulama ve %20 test olmak üzere üç parçaya ayrılarak toplam 50 kez sınıflandırma işlemi gerçekleştirilmiştir. Elde edilen 50 koşuma ait test sınıflandırma doğruluğu 99.40 ± 0.21 olarak elde edilmiştir. Bu model kaydedilmiş ve ÇİO'da kişiden bağımsız hedef karakter belirleme modeli olarak çalışmanın devam eden adımlarında kullanılmıştır.

Önerilen çalışmanın ikinci aşamasında yürütülen ÇİO'da, bu şekilde geliştirilen modelin performansı farklı 30 katılımcı ile test edilmiştir. İlgili çalışma sonuçları Çizelge 1 ile gösterilmiş olup, burada modelin test edildiği farklı katılımcılar K11-K40 ile gösterilmiştir. Bu şekilde yürütülen çalışmalarda; her bir katılımcıya serbest kelime belirleyip, bunu BBA ile düşünsel olarak yazdırma imkânı sunulmuştur. Deney sonunda katılımcının yazdırmak istediği ve buna karşılık önerilen modelin tespit ettiği kelimeler karşılaştırılarak model performansı Çizelge 1'de gösterildiği biçimde belirlenmiştir. Bu sonuçlara göre; 30 katılımcının belirledikleri kelimeler 3 ile 6 harf arasında değişen uzunlukta olup, bu kelimelerden (katılımcılardan) 6 tanesi yazdırmak istediği kelimeyi bir harf hata ile geri kalan 24 tanesi ise doğru olarak yazdırmıştır. Bir arada ele alındığında; tüm katılımcılar için toplam 131 karakterlik yazdırma işleminden 125 karakter doğru olarak, 6 karakter ise yanlış olarak tespit edilmiş olup, kişiden bağımsız modelin çevrimiçi karakter tespit etme başarısı ise %95.41 olarak tespit edilmiştir.

Çizelge 1. Çevrimiçi oturuma ait sonuçlar.

	Toplam Karakter Sayısı	Doğru Tespit Edilen Karakter Sayısı	Yazdırılmak İstenen Kelime	Modelin Tespit Ettiği Kelime
K11	5	5	KUBRA	KUBRA
K12	4	4	ELMA	ELMA
K13	3	3	MUZ	MUZ
K14	5	4	CANIM	CANIG
K15	5	5	KITAP	KITAP
K16	4	4	GOLF	GOLF
K17	5	5	BEDIR	BEDIR
K18	5	5	HAKEM	HAKEM
K19	4	4	EMRE	EMRE
K20	4	4	ANNE	ANNE
K21	5	5	SEHPA	SEHPA
K22	4	3	KALE	GALE
K23	3	3	KAL	KAL
K24	4	4	PRIZ	PRIZ
K25	3	3	TOP	TOP
K26	4	4	TEZ	TEZ
K27	4	4	SENAM	SENAM
K28	5	5	SILGI	SILGI
K29	4	4	SAAT	SAAT
K30	4	3	MASA	YASA
K31	4	4	ASAL	ASAL
K32	5	5	AYLIN	AYLIN
K33	6	5	SEBILE	AEBILE
K34	4	3	SPOR	VPOR
K35	5	4	SEVGI	AEVGI
K36	4	4	ARDA	ARDA
K37	4	4	METE	METE
K38	5	5	OKLID	OKLID
K39	5	5	ASLAN	ASLAN
K40	5	5	KALEM	KALEM
TOPLAM	131	125		
Ortalama SD		%95.41		

4. Sonuç

Günümüzde makine öğrenme algoritmalarının uygulama alanlarından biri de BBA sistemleridir. Çeşitli sebeplerle konuşamayan, hareket edemeyen dolayısıyla çevresindeki kişilere ihtiyaçlarını aktaramayacak seviyede olan hasta bireylerin BBA sistemleriyle çevresindeki kişilerle iletişim kurabilmeleri sağlanmaktadır. BBA sistemlerindeki en büyük sınırlama, geliştirilen modelin kişiye bağlı olması ve çevrimiçi gerçekleştirme zorluğudur. Geliştirilen BBA sistemini yeni bir kişide kullanmak gerektiğinde, bu kişiden veri toplanması ve elde edilen bu verilerle kişiye özgü modelin eğitilmesi gerekir. Bu işlem uzun sürmekte bu sebeple kişiye özgü modelle çalışan sistemler tak-çalıştır konforundan uzak olmaktadır. Sistemi çevrimiçi çalıştırmada yaşanan zorluklar ise BBA uygulamalarının diğer bir sınırlamalarındandır. Bu çalışmada bu iki problemin çözümüne katkı sağlayacak gerçek zamanlı çalışan ve kişiden bağımsız BBA modeli önerilmiştir. Önerilen yöntemin performansını ölçmek için 10 kişiden veri toplanıp kişiden bağımsız çalışan bir model oluşturulmuş ve farklı 30 kişi ile çevrimiçi test edilmiştir. Elde edilen sonuçlara göre, geliştirilen modelin hedef uyararı

ve hedef olmayan uyaranlara ait sinyalleri ayırma performansı 99.40 ± 0.21 , ve bu modelle yapılan çevrimiçi kelime tespiti uygulamasının performansı ise 95.41 olarak bulunmuştur. Kişiden bağımsız ve çevrimiçi kelime tespitinin yapılması bakımından yaptığımız bu çalışma literatüre önemli katkı sunmaktadır.

Teşekkür

Bu çalışma Atatürk Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından FOA-2018-6524 proje numarası ile desteklenmiştir.

Kaynakça

- Adobe. (2017). Adobe Inc. Adobe Photoshop for Windows.
- Ahmad, M. M., & Ahuja, K. (2022). Role of 5G Communication Along with Blockchain Security in Brain-Computer Interfacing: A Review. *Futuristic Design and Intelligent Computational Techniques in Neuroscience and Neuroengineering*. doi: 10.4018/978-1-7998-7433-1.ch004
- Brysbaert, M. (2019). How many words do we read per minute? A review and meta-analysis of reading rate. *Journal of Memory and Language*, 109, 104047. doi: 10.1016/j.jml.2019.104047
- Devlaminc, D., Wyns, B., Grosse-Wentrup, M., Otte, G., & Santens, P. (2011). Multisubject learning for common spatial patterns in motor-imagery BCI. *Computational intelligence and neuroscience*, 2011. doi: 10.1155/2011/217987
- Ergün, E., & Aydemir, Ö. (2020). A hybrid BCI using singular value decomposition values of the fast walsh hadamard transform coefficients. *IEEE Transactions on Cognitive and Developmental Systems*. doi: 10.1109/TCDS.2020.3028785
- Jalilpour, S., Sardouie, S. H., & Mijani, A. (2020). A novel hybrid BCI speller based on RSVP and SSVEP paradigm. *Computer methods and programs in biomedicine*, 187, 105326. doi: 10.1016/j.cmpb.2020.105326
- Kevric, J., & Subasi, A. (2017). Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system. *Biomedical Signal Processing and Control*, 31, 398-406. doi: 10.1016/j.bspc.2016.09.007
- Kirasirova, L., Bulanov, V., Ossadtchi, A., Kolsanov, A., Pyatin, V., & Lebedev, M. (2020). A P300 brain-computer interface with a reduced visual field. *Frontiers in neuroscience*, 14, 1246. doi: 10.3389/fnins.2020.604629
- Kleih, S. C., & Kübler, A. (2013). Empathy, motivation, and P300 BCI performance. *Frontiers in human neuroscience*, 7, 642. doi: 10.3389/fnhum.2013.00642
- Loizidou, P., Rios, E., Martini, A., Keluo-Udeke, O., Soetedjo, J., Belay, J., & Speier, W. (2022). Extending brain-computer interface access with a multilingual language model in the P300 speller. *Brain-Computer Interfaces*, 9(1), doi: 10.1080/2326263X.2021.1993426
- Lu, Z., Li, Q., Gao, N., & Yang, J. (2020). The self-face paradigm improves the performance of the P300-speller system. *Frontiers in computational neuroscience*, 13, 93. doi: 10.3389/fncom.2019.00093
- Matlab. (2018). MathWorks for Windows.
- Muller-Putz, G. R., & Pfurtscheller, G. (2007). Control of an electrical prosthesis with an SSVEP-based BCI. *IEEE Transactions on Biomedical Engineering*, 55(1), 361-364. doi: 10.1109/TBME.2007.897815
- Mussabayeva, A., Jamwal, P. K., & Akhtar, M. T. (2021). *Ensemble learning approach for subject-independent P300 speller*. Paper presented at the 2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). doi: 10.1109/EMBC46164.2021.9629679
- Orlandi, A., & Proverbio, A. M. (2019). Left-hemispheric asymmetry for object-based attention: an ERP study. *Brain sciences*, 9(11), 315. doi: 10.3390/brainsci9110315
- Park, C., Looney, D., ur Rehman, N., Ahrabian, A., & Mandic, D. P. (2012). Classification of motor imagery BCI using multivariate empirical mode decomposition. *IEEE transactions on neural systems and rehabilitation engineering*, 21(1), 10-22. doi: 10.1109/TNSRE.2012.2229296

- Qu, J., Wang, F., Xia, Z., Yu, T., Xiao, J., Yu, Z., Li, Y. (2018). A novel three-dimensional P300 speller based on stereo visual stimuli. *IEEE Transactions on Human-Machine Systems*, 48(4), 392-399. doi: 10.1109/THMS.2018.2799525
- Rakotomamonjy, A., & Guigue, V. (2008). BCI competition III: dataset II-ensemble of SVMs for BCI P300 speller. *IEEE Transactions on Biomedical Engineering*, 55(3), 1147-1154. doi: 10.1109/TBME.2008.915728
- Ramirez-Quintana, J. A., Madrid-Herrera, L., Chacon-Murguia, M. I., & Corral-Martinez, L. F. (2021). Brain-computer interface system based on P300 processing with convolutional neural network, novel speller, and low number of electrodes. *Cognitive Computation*, 13(1), 108-124. doi: 10.1007/s12559-020-09744-2
- Sellers, E. W., Krusienski, D. J., McFarland, D. J., Vaughan, T. M., & Wolpaw, J. R. (2006). A P300 event-related potential brain-computer interface (BCI): the effects of matrix size and inter stimulus interval on performance. *Biological psychology*, 73(3), 242-252. doi: 10.1016/j.biopsycho.2006.04.007
- Wolpaw, J. R., Birbaumer, N., Heetderks, W. J., McFarland, D. J., Peckham, P. H., Schalk, G., Vaughan, T. M. (2000). Brain-computer interface technology: a review of the first international meeting. *IEEE transactions on rehabilitation engineering*, 8(2), 164-173.
- Wu, Y., Zhou, W., Lu, Z., & Li, Q. (2020). A spelling paradigm with an added red dot improved the P300 speller system performance. *Frontiers in neuroinformatics*, 14, 57. doi: 10.3389/fninf.2020.589169
- Wu, Z., Lai, Y., Xia, Y., Wu, D., & Yao, D. (2008). Stimulator selection in SSVEP-based BCI. *Medical engineering & physics*, 30(8), 1079-1088. doi: 10.1016/j.medengphy.2008.01.004
- Xu, M., Qi, H., Wan, B., Yin, T., Liu, Z., & Ming, D. (2013). A hybrid BCI speller paradigm combining P300 potential and the SSVEP blocking feature. *Journal of neural engineering*, 10(2). doi: 10.1088/1741-2560/10/2/026001
- Xu, M., Xiao, X., Wang, Y., Qi, H., Jung, T.-P., & Ming, D. (2018). A brain-computer interface based on miniature-event-related potentials induced by very small lateral visual stimuli. *IEEE Transactions on Biomedical Engineering*, 65(5), 1166-1175. doi: 10.1109/TBME.2018.2799661
- Zhang, X., Jin, J., Li, S., Wang, X., & Cichocki, A. (2021). Evaluation of color modulation in visual P300-speller using new stimulus patterns. *Cognitive Neurodynamics*, 1-14. doi: 10.1007/s11571-021-09669-y
- Zhang, Y., Zhang, X., Sun, H., Fan, Z., & Zhong, X. (2019). Portable brain-computer interface based on novel convolutional neural network. *Computers in biology and medicine*, 107, 248-256. doi: 10.1016/j.combiomed.2019.02.023