



Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Durağan Durum Görsel Uyarı Potansiyellerinden Fourier Dönüşümü ile Üç Farklı Frekansın Kestirimi

Ebru SAYILGAN ^a, Yılmaz Kemal YÜCE ^b, Yalçın İŞLER ^{c*}

^a *Biyomedikal Teknolojiler Anabilim Dalı, Fen Bilimleri Enstitüsü, İzmir Katip Çelebi Üniversitesi, İzmir, TÜRKİYE*

^b *Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Alanya Alaaddin Keykubat Üniversitesi, Alanya-Antalya, TÜRKİYE*

^c *Biyomedikal Mühendisliği Bölümü, Mühendislik-Mimarlık Fakültesi, İzmir Katip Çelebi Üniversitesi, İzmir, TÜRKİYE*

* Sorumlu yazarın e-posta adresi: islerya@yahoo.com

DOI : 10.29130/dubited.716386

ÖZET

Durağan durum görsel uyarılmış potansiyeller (DDGUP), diğer beyin bilgisayar ara yüzü (BBA) tekniklerine oranla oldukça yüksek sinyal-gürültü oranları ve bilgi aktarım hızına sahip oldukları için EEG çalışmalarında sıkça kullanılır. Ayrıca durağan durum paradigmaları, dinamik neokorteks süreçlerinde tercih edilen frekansları karakterize etmek için de kullanılır. Kısa eğitim süresine sahip olan DDGUP'lar, pratik uygulamalarda önemli bir rol oynar. Sinyalleri komuta dönüştürmekte kullanılan, sinyal işleme algoritmaları, BBA sistemlerinin performansını arttırmak için kilit öneme sahiptir. Buna ek olarak, DDGUP sinyallerinin birbirinden farklı yöntemlerle sınıflandırılmasını araştıran çok az çalışma vardır. Bu çalışmada, internetten açık erişim ile alınan veri seti (AVI SSVEP Dataset) üzerinde analizler yapılmıştır. Veri setindeki EEG kayıtları, katılımcılar, rengi siyahtan beyaza hızla değişen yedi farklı frekansta yanıp sönen bir kutuya baktıkları durumda kaydedilmiştir. Oksipital bölgeden kaydedilen DDGUP sinyalleri ilk olarak Hızlı Fourier Dönüşümü uygulanarak, sinyal alt bantlarına (delta, teta, alfa, beta ve gama) ayrılmıştır. Alt bantların her biri için enerji ve varyans öznitelik vektörleri çıkarılmıştır. Öznitelikler altı temel sınıflandırıcı (LDA, k-NN, SVM, Naive Bayes, Topluluk Öğrenmesi, Karar Ağacı) ile sınıflandırılmıştır. Sınıflandırma performansları birbirleri ile karşılaştırılmıştır. Sınıflandırma 5-kat çapraz doğrulama modeli ve hata matrisinden doğruluk değerleri çıkarılarak analiz edilmiştir. Katılımcılar ayrı ayrı göz önüne alındığında %100'e varan sınıflandırma başarımı SVM ve k-NN sınıflandırıcılarında elde edilirken, ortalamalara göre en yüksek başarımlar Topluluk Öğrenmesi sınıflandırıcısında %79,73 olarak elde edilmiştir.

Anahtar Kelimeler: *Beyin-bilgisayar ara yüzü, Elektroensefalogram, Durağan-durum görsel-uyaran potansiyelleri, Örüntü tanıma, Sınıflandırma*

Estimation of Three Distinct Frequencies Using Fourier Transform of Steady-State Visual-Evoked Potentials

ABSTRACT

Steady-state visual evoked potentials (SSVEP) are frequently used in EEG studies as they have relatively high signal-to-noise ratios and information transfer rates compared to other brain computer interface (BCI) techniques. Also, steady state paradigms are used to characterize the frequencies preferred in dynamic neocortex

processes. SSVEPs, which have a short training time, play an important role in practical applications. Signal processing algorithms used to convert signals into command are key to improving the performance of BCI systems. In addition, there are very few studies investigating the classification of SSVEP signals by different methods. In this study, analyzes were made on the data set (AVI SSVEP Dataset) received with open access from the internet. EEG recordings in the dataset were recorded when participants looked at a flashing box at seven different frequencies that changed color from black to white. SSVEP signals recorded from the occipital region were first applied to the Fast Fourier Transform to separate the signal subbands (delta, theta, alpha, beta and gamma). Energy and variance feature vectors are extracted for each subband. Features are classified with six basic classifiers (LDA, k-NN, SVM, Naive Bayes, Ensemble Learner, Decision Tree). Classification performances are compared with each other. Classification was analyzed by extracting accuracy values from 5-fold cross-validation model and confusion matrix. When the participants are considered separately, 100% classification success is achieved in SVM and k-NN classifiers, while the highest performance in the averages is obtained in the Ensemble Learning classifier with the accuracy of 79.73%.

Keywords: Brain-computer interface, Electroencephelogram, Steady-state visually-evoked potentials, Pattern recognition, Classification

I. GİRİŞ

Beyin Bilgisayar Ara yüzleri (BBA), kişilerin sadece beyin aktivitesini yorumlayarak ve anlamlandırarak, insanlara çevresi ile çeşitli elektronik cihazları ve/veya protezleri, ortezleri kontrol ederek iletişim kurma imkânını sağlayan bir sistem veya sistemler bütünüdür [1, 2]. Beyindeki bazı nörofizyolojik etkileşimlerin algılanmasına dayanan BBA sistemlerinin temel yapı taşlarını, biyolojik sinyal ölçümleri, sinyallere yönelik yazılımlar ve donanımlar, çeşitli sinyal işleme yöntemleri ve makine öğrenme algoritmaları oluşturmaktadır.

EEG tabanlı BBA'larda yaygın olarak kullanılan sinyaller yavaş kortikal potansiyeller (SCP), mu ve beta ritimleri (μ ve β), olayla ilişkili potansiyeller (ERP), olayla ilgili senkronizasyon ve desenkronizasyon, son olarakta görsel uyarılmış potansiyellerdir (VEP) [1-5]. VEP'ler beyin görsel uyarana verdiği cevaplardır. Durağan durum görsel uyarılmış potansiyeller (DDGUP), 6 Hz'den daha yüksek bir frekansta modüle edilmiş bir görsel uyarana yanıtıdır [4, 5]. DDGUP tabanlı BBA sisteminde, bireylere bilgisayar ekranı veya harici ışık kaynağı tarafından farklı frekanslarda yanıp sönen görsel uyarılar gösterilir. DDGUP, kafa derisi üzerinden beyin görsel korteksinde kaydedilir ve oksipital bölgede maksimum genlikle elde edilir [6]. DDGUP tabanlı BBA'lar, diğer sistemlerin aksine bağımlı bir BBA olarak kabul edilir. Çünkü DDGUP üretimi, kranial sinirlerin ve ekstraoküler kasların çıkış yollarının ve göz hareketlerinin kontrolüne bağlıdır [4]. Bu nedenle, bu yöntem, ekstraoküler kas kontrolünün çıkış kanalından yoksun olabilecek ciddi nöromusküler engelleri olan insanlara uygulanamaz. Bununla birlikte, çoğu insan için DDGUP tabanlı BBA sistemleri, diğer sistemlerden daha uygun olmakla birlikte, yüksek bilgi aktarım hızı, basit sistem yapısı, kısa süren veya gerekli olmayan kullanıcı eğitimi gibi avantajlara sahiptir [7].

Genel olarak, DDGUP tabanlı bir BBA'nın yapısı kabaca dört aşamaya ayrılabilir: veri toplama, sinyal ön-işleme, öznitelik çıkarma ve sınıflandırmadır [6]. İlk aşama olarak DDGUP verileri kaydedilirken, ikinci aşamada, ön-işlem olarak zamansal ve uzamsal filtrelemeler uygulanır. Üçüncü aşamada, seçilen paradigmanın öznitelikleri arasından en uygun öznitelikler çıkarılmaya ve seçilmeye çalışılır. Son olarak ise sınıflandırıcı aşamasında, giriş sinyaline dayalı bir kontrol komutu üretilir. Bu aşamaların her birinde kullanılacak birçok yöntem mevcuttur.

Bu çalışma kapsamında uyarın frekanslarını karakterize etmek ve komuta dönüştürmek için, çentik filtre uygulanmış sinyale Hızlı Fourier Dönüşümü (FFT) uygulanmıştır. FFT'si alınan sinyaller, EEG alt bantlarına ayrılarak her bir bant aralığındaki uyarın frekansının tespiti yapılmıştır. Öznitelik çıkarma aşamasında ise EEG alt bantlarının her birinin enerji ve varyans değerlerinden oluşan öznitelik vektörleri çıkarılmıştır. Son olarak sınıflandırma aşamasında, literatürde yaygın kullanılan ve daha önce bu kombinasyonla birbirleri ile karşılaştırılmamış, altı farklı sınıflandırıcı kullanılarak sinyallerin sınıflandırılması gerçekleştirilmiştir.

II. MATERYAL VE YÖNTEM

A. VERİ SETİ

Bu çalışma için Adnan Vilic tarafından tasarlanarak kaydedilen DDGUP sinyallerini içeren veri seti (AVI SSVEP Dataset) kullanılmıştır [8]. Veri setinde, DDGUP sinyallerinin birbirinden farklı yedi frekanstaki (6 - 6,5 - 7 - 7,5 - 8,2 - 9,3 - 10Hz) yanıtlarını tetiklemek için yanıp sönen kutu halindeki hedefe bakan sağlıklı bireylerin EEG ölçümlerini içeren veriler mevcuttur. Veri kümesi tamamen ücretsizdir ve açık erişimlidir. Tüm veriler üç elektrot (Oz, Fpz, Pz) kullanılarak kaydedilmiştir. Elektrot yerleşim düzeni için standart uluslararası 10-20 sistemi kullanarak, referans elektrot Fz'de sinyal elektrotu Oz'de ve Fpz'de ise toprak elektrotu olacak şekilde konumlandırılmıştır.

Katılımcılar 120Hz yenileme hızına sahip bir LCD bilgisayar ekranından, 60 cm uzağa oturmuşlardır ve ekran çözünürlüğü 1680x1050 pikseldir. Katılımcılara sunulan rengi siyahtan beyaza hızla değişen tek bir yanıp sönen hedef ise 2,89 cm²'lik bir alana sahip olacak şekilde düzenlenmiştir. Görsel uyarının katılımcılara gösterilmesi için Microsoft Silverlight'ta bir uygulama geliştirilmiş ve bu uygulama Windows 8 tabanlı bir bilgisayarda çalıştırılmıştır. Elde edilen verilere şebeke frekansında (50Hz) bir analog çentik filtre uygulanmıştır [8].

Veri seti dört farklı katılımcı ile yapılan dört oturumdan oluşmaktadır. Bir oturumdaki her deneme 30 saniye sürmekte ve katılımcılar denemeler arasında kısa bir mola vermektedir. Her bir frekans için denemeler en az 3 kez tekrarlanmıştır. Tablo I'de deneye katılan sağlıklı bireylerin bazı fizyolojik bilgilerini (cinsiyetini ve yaşını) belirten bir liste sunulmuştur.

Tablo 1. DDGUP deneyine katılanların fizyolojik bilgileri

Tek Hedef Uyarımındaki Katılımcıların Listesi				
Katılımcı	1	2	3	4
Cinsiyet	Erkek	Erkek	Erkek	Kadın
Yaş	32	27	27	31

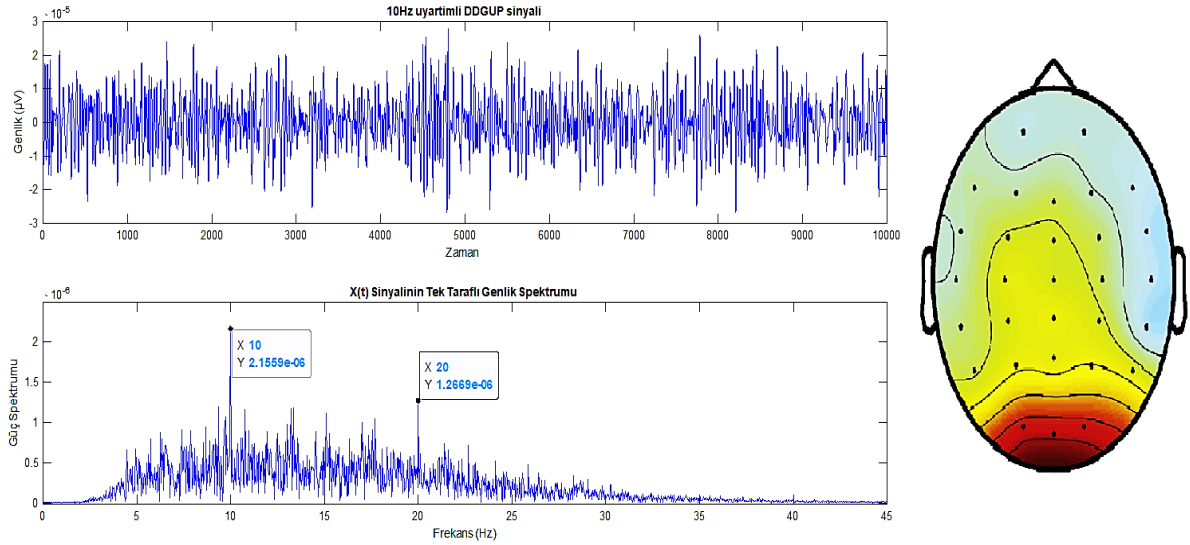
B. ÖZNETELİK ÇIKARMA

Öznitelik çıkarma aşamasında, ilk olarak veri setinde mevcut olan yedi frekans içinden, sınıflandırma performansını artıracakları düşünülen, aralarındaki farkın yüksek olduğu 3 frekans (6Hz – 8,2Hz – 10Hz) seçilmiştir. Bunun nedeni kaynak [9], [10] ve [11]'de yapılan çalışma sonuçlarıdır. Uyarın frekanslarını sinyalden daha net tespit edebilmek için spektrum analizi yapılmıştır. Bu analiz genellikle uyarılmış DDGUP yanıtlarındaki frekans bilgisini elde etmek için kullanılır. Temel fikir her zaman aynıdır: sabit bir frekansta (uyarın frekansı) yanıp sönen veya hareketli bir görsel uyarın, beyinde aynı frekansta bir tepki veya eşit harmoniklerini ortaya çıkarmaktadır [12]. Aynı zamanda frekanslara karşılık gelen frekans aralığındaki bant gücünü ve varyansını hesaplamak için EEG sinyallerinin güç spektrumu MATLAB yazılımı kullanılarak FFT ile belirlenmiştir. Şekil 1'de Oz elektrodundan kaydedilen, 10 Hz frekansında, uyarılmış DDGUP sinyalinin ham hali, FFT uygulanarak güç spektrumu çıkarılmış hali (DDGUP sinyalinde önemli olan 1. ve 2. harmoniği

belirtilmiştir) ve topografisi sunulmuştur. Bu amaçla FFT'si alınan sinyal EEG alt bantlarına (delta, teta, alfa, beta, gama) ayrılmış ve her bir bandın enerji ve varyansı hesaplanarak öznitelik vektörleri oluşturulmuştur.

C. SINIFLANDIRMA

Sinyal işleme sürecinin son adımı olan sınıflandırma aşamasında, DDGUP sinyalinden çıkarılan öznitelik vektörleri altı temel sınıflandırıcı ve sınıflandırıcıların birbirinden farklı alt parametreleri sebebiyle toplamda yirmi üç farklı yöntem ile denenmiştir. Bu sınıflandırıcılar Matlab yazılımı içinde Classifier Learner uygulaması ile yapılmıştır. Kullanılan sınıflandırıcı algoritmaları şunlardır: Karar Ağacı (*Decision Tree*), Doğrusal Ayrıcı Analizi (*LDA*), Naive Bayes, Destek Vektör Makineleri (*SVM*), k- En Yakın Komşuluk (*k-NN*), Topluluk Sınıflandırıcıları (*Ensemble Learner*).



Şekil 1. 10Hz uyarın frekansında görülen DDGUP sinyalinin şekli, güç spektrumu ve topografisi

D. SINIFLANDIRMA PERFORMANSLARININ DEĞERLENDİRİLMESİ

Bu çalışmada sınıflandırma aşamasında 5-katlamalı çapraz doğrulama modeli oluşturularak sınıflandırma yapılmıştır. Algoritmaların performanslarını değerlendirmek için hata matrisi çıkarılarak doğruluk değerleri hesaplanmıştır.

Örüntü tanıma ve/veya makine öğrenmesi çalışmalarında çıkarılan özniteliklerden oluşan veri seti, eğitim ve test kümeleri olmak üzere ikiye ayrılır. Eğitim ve test kümesi olarak veri setini ayırmada en sık kullanılan yöntemlerden birisi k-katlamalı çapraz doğrulama yöntemidir. Bu yöntemde veri seti rasgele k parçaya bölünür. Her seferinde k-1 parça algoritmanın eğitimi için kullanılırken, kalan 1 parça algoritmanın testi için kullanılır. Bu işlem tüm parçalar test edilinceye kadar tekrarlanır. Her seferinde test hataları kayıt edilerek son parçadan sonra hataların ortalaması hesaplanır. Kullanılan sınıflandırıcı algoritmalarının performansı bu şekilde değerlendirilir [13], [14], [15], [16]. Bu çalışmadaki sınıflandırma adımında, veri seti 5 eşit parçaya bölünerek model oluşturulmuştur.

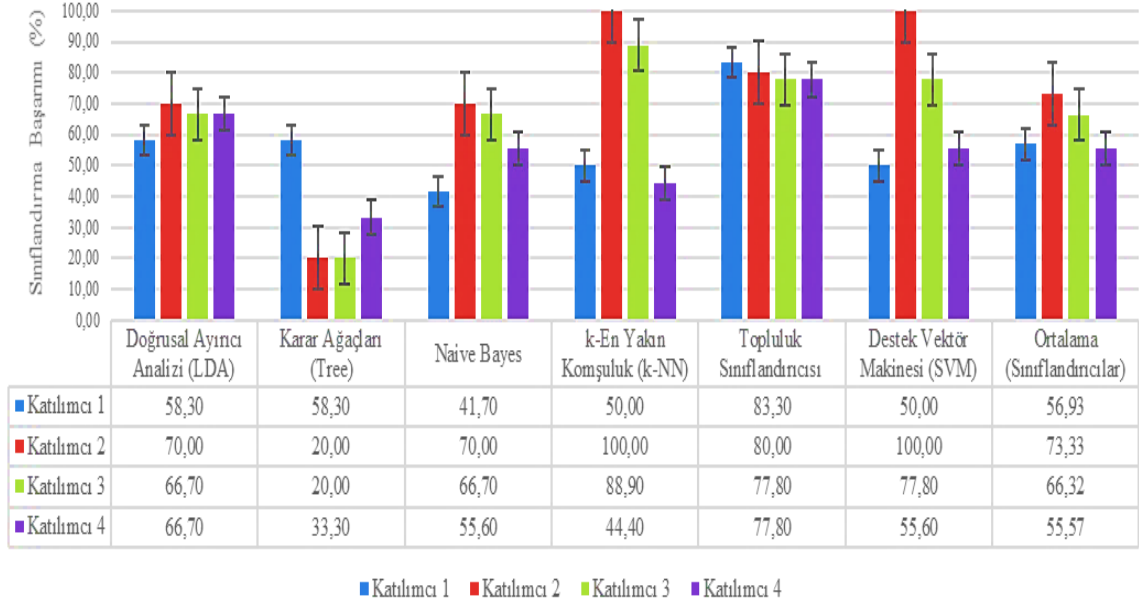
Sınıflandırıcı başarımını değerlendirmek için öncelikle hata matrisi hesaplanmaktadır. Sınıflandırma algoritmasının test kümesine verdiği cevapların veri setindeki gerçek değerlerle karşılaştırılması ile hata matrisi oluşturulur. Dört farklı durumdan oluşan hata matrisi aşağıdaki terimlerle özetlenebilir [16], [17]. TP (incelenen uyartım frekansını doğru tahmin etme durumu), TN (tahmin edilen uyartım frekansının incelenen uyartım frekansından farklı olduğunu doğru tahmin durumu), FP (farklı bir uyartım frekansını yanlışlıkla incelenen frekans olduğuna karar verme durumu), FN (incelenen

uyartım frekansını yanlışlıkla farklı bir frekans olduğuna karar verme durumu)'dir. Bu değerlere bağlı olarak sınıflandırıcı performansını gösteren doğruluk değeri hesaplanır [16], [17], [18], [19]:

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


III. SONUÇLAR VE TARTIŞMA

Bu çalışma için oluşturulan bütün algoritmaların analizleri MATLAB ve EEGLAB programları kullanılarak incelenmiştir. Her bir sınıflandırma algoritmasının performansı hata matrisinden çıkarılan doğruluk ölçütü kullanılarak değerlendirilmiştir. Yedi farklı frekans arasından seçilen üç frekansın sınıflandırma problemi için, öncelikle EEG sinyal analizi çalışmalarında gösterdiği yüksek performanslı sonuçları kanıtlanmış FFT uygulanmıştır. Güç spektrumu alınan sinyal EEG alt bantlarına bölünerek frekansların etkinliği tespit edilmiş ve her bir alt bandın enerji ve varyans değerleri hesaplanarak öznitelik vektörleri oluşturulmuştur. Oluşturulan öznitelikler altı temel sınıflandırıcı algoritması ile sınıflandırılmıştır. Sonuçlar doğruluk değerleri ile Şekil 2 ve Şekil 3'te sunulmuştur.



Şekil 2. Her bir katılımcının sınıflandırma performansları

Şekil 2'de dört katılımcının her birinin ayrı ayrı sınıflandırma sonuçları sunulmuştur. Elde edilen sonuçlara göre 1. Katılımcı için en yüksek sınıflandırma performansı %83,30 ile Topluluk Öğrenmesi sınıflandırıcısında, 2. Katılımcı için en yüksek %100 sınıflandırma performansı ile k-NN ve SVM sınıflandırıcılarında, 3. Katılımcı için %88,90 ile k-NN sınıflandırıcısında ve 4. Katılımcı'da ise %77,80 sınıflandırma performansları görülmüştür.



Şekil 3. Sınıflandırıcıların ortalama başarımları

Şekil 3’te ise altı farklı sınıflandırıcının başarımı dört katılımcının ortalaması alınarak hesaplanmış ve en yüksek performans %79,73 doğruluk değeri ile Topluluk Öğrenmesi sınıflandırıcısında bulunmuştur. Topluluk Öğrenmesi sınıflandırıcısını takip eden en yüksek ikinci sınıflandırıcı %70,85 ile SVM olurken, çok küçük farkla yani %70,83 ile k-NN üçüncü en iyi performansa sahip sınıflandırıcı olmuştur. LDA ve Naive Bayes sınıflandırıcıları nispeten daha düşük sonuçlar verirken, Karar Ağacı sınıflandırıcısının DDGUP frekans analizi için uygun olmadığı görülmektedir.

Sonuç olarak, katılımcı bazında %100’e ve ortalamalar incelendiğinde ise %79,73’e varan sınıflandırma performansları elde edilerek kullanılan yöntemlerin başarılı olduğu ve gerçek zamanlı bir DDGUP tabanlı BBA tasarımında kullanılabileceği görülmüştür. Aynı zamanda sınıflandırıcı başarımları kendi aralarında karşılaştırıldığında Topluluk Öğrenmesi yönteminin DDGUP sinyallerini sınıflandırmada kullanılan diğer sınıflandırıcılara göre daha yüksek başarımlar verdiği görülmektedir.

Gelecek çalışmalarda, zaman alanı, frekans alanı ve zaman-frekans alanında başarılı olan öznelilikler çıkarılarak ve sinyal işleme adımlarına öznelilik seçimi eklenerek sonuçlar irdelenecektir. Aynı zamanda, sınıflandırma yöntemleri çoğaltılarak sınıflandırma sonuçlarının incelenmesine devam edilecektir.

IV. KAYNAKLAR

- [1] J. R. Wolpaw, N. Birbaumer, D. C. McFarland, G. Pfurtscheller, T. M. Vaughan, “Brain–Computer Interfaces for Communication and Control,” *Clin. Neurophysiol.*, c. 113, s. 6, ss. 767-791, 2002.
- [2] D. J. McFarland, J. R. Wolpaw, “Brain-Computer Interfaces for Communication and Control,” *Commun. ACM.*, c. 54, s. 5, ss. 60-66, 2011.
- [3] J. J. Vidal, “Real-Time Detection of Brain Events in EEG,” *Proc. IEEE*, c. 65, ss. 633–641, 1977.
- [4] Y. J. Wang, R. P. Wang, X. R. Gao ve ark., “A Practical VEP-Based Brain-Computer Interface,” *IEEE Trans. Neural. Syst. Rehabil. Eng.*, c. 14, ss. 234-239, 2006.
- [5] G. Schalk, D. J. McFarland, T. Hinterberger, N. Birbaumer, J. R. Wolpaw, “BCI2000: A General-Purpose Brain-Computer Interface (BCI) System,” *IEEE Trans. Biomed. Eng.*, c. 51, s. 6, ss. 1034-1043, 2004.
- [6] Y. Wang, X. Gao, B. Hong, C. Jia, S. Gao, “Brain-Computer Interfaces Based on Visual Evoked Potentials,” *IEEE Eng. Med. Biol.*, c. 27, s. 5, ss. 64-71, 2008.

- [7] X. Chen, Y. Wang, M. Nakanishi, X. Gao, T. Jung, S. Gao, "High-Speed Spelling with A Noninvasive Brain-Computer Interface," *PNAS*, c. 112, s. 44, ss. E6058-67, 2015.
- [8] AVI Steady-State Visual Evoked Potential (SSVEP) Signals Dataset, A. Vilic, 2013. [Çevrimiçi]. Erişim Adresi: <https://www.setzner.com/avi-ssvep-dataset/>
- [9] E. Sayilgan, Y. K. Yuçe, Y. Isler, "Prediction of Evoking Frequency From Steady-State Visual Evoked Frequency," *Natural and Engineering Sciences*, c. 4, s. 3, ss. 91-99, 2019.
- [10] E. Sayilgan, Y. K. Yuçe, Y. Isler, "Uyartım Frekansının Kestiriminde İstatistiksel Anlamlılığa Dayalı Olarak Seçilen Durağan Durum Görsel Uyarılmış Potansiyellere Ait Dalgacık Özniteliklerinin Değerlendirilmesi," *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, Hakemlik sürecinde, 2020.
- [11] E. Sayilgan, Y. K. Yuçe, Y. Isler, "Determining Gaze Information from Steady-State Visually-Evoked Potentials," *Karaelmas Science and Engineering Journal*, Kabul edildi, 2020.
- [12] F. B. Vialatte, M. Maurice, J. Dauwels, A. Cichocki, "Steady State Visually Evoked Potentials: Focus on Essential Paradigms and Future Perspectives," *Progress in Neurobiology*, c. 90, s. 4, ss. 418-438, 2010.
- [13] Y. Jung, J. Hu, "A k-Fold Averaging Cross-Validation Procedure," *J. Nonparametr. Stat.*, c. 27, ss. 1-13, 2015.
- [14] A. Narin, Y. İşler, M. Özer, "Konjestif Kalp Yetmezliği Teşhisinde Kullanılan Çapraz Doğrulama Yöntemlerinin Sınıflandırıcı Performanslarının Belirlenmesine Olan Etkilerinin Karşılaştırılması," *DEÜ Mühendislik Fakültesi Mühendislik Bilimleri Dergisi*, c. 16, s. 48, ss. 1-8, 2014.
- [15] A. Narin, Y. Isler, M. Ozer, "Comparison of the Effects of Cross-Validation Methods on Determining Performances of Classifiers Used in Diagnosing Congestive Heart Failure," *Meas. Sci. Rev.*, c. 15, s. 4, ss. 196-201, 2015.
- [16] G. Altan, Y. Kutlu, "Generative Autoencoder Kernels on Deep Learning for Brain Activity Analysis," *Natural and Engineering Sciences*, c. 3, s. 3, ss. 311-322, 2018.
- [17] R. O. Duda, P. E. Hart, D. G. Stork, *Pattern Classification*, 2nd edition, Wiley Interscience, 2001.
- [18] E. Alpaydin, *Introduction to Machine Learning*, MIT Press, 2004.
- [19] G. Altan, Y. Kutlu, N. Allahverdi, "Deep Belief Networks Based Brain Activity Classification Using EEG from Slow Cortical Potentials in Stroke," *International Journal of Applied Mathematics, Electronics and Computers*, c. 4, ss. 205-210, 2016.