

Eğricik Dönüşümü Ayırıştırması Kullanılarak İki Sınıflı Motor Görüntüsü EEG Sinyallerinin Sınıflandırılması

Nebi GEDİK^{*1}

¹ Sağlık Bilimleri Üniversitesi, Hamidiye Sağlık Bilimleri Enstitüsü, İstanbul, Türkiye

^{*1} e-mail: nebi.gedik@sbu.edu.tr, <https://orcid.org/0000-0002-1560-1058>

The arrival date: 03.10.2022 ; Date of Acceptance: 09.05.2023

Öz

Beyin bilgisayar arayüzü çalışmaları, temel olarak beyin sinyallerini toplamayı, analiz etmeyi ve kullanılmak üzere komutlara çevirmeyi amaçlamaktadır. Beyin sinyallerinin kontrol komutlarına çevrilmesinde elektroensefalogram (EEG) bir olanak sağlamaktadır. Deneğe özgü ve durağan olmayan yapısı nedeniyle EEG sinyallerinin sınıflandırılması zorlu görevlerdendir ve farklı yaklaşımlarla çalışmalar yapılmaktadır. Bu çalışmaların bir bölümü motor hareket hayali içeren beyin aktivitelerinin analizini kapsamaktadır. Bu makale, eğricik dönüşüm ayırıştırmasını kullanan iki sınıflı bir motor görüntüsü sınıflandırma algoritması sunmaktadır. Önerilen algoritma, BBA yarışması IV veri kümesi IIa kullanılarak gerçekleştirilmiştir. 22 kanaldan oluşturulan veri kümesinden, seçilen üç kanala (C3, Cz ve C4) ait EEG sinyalleri uygulamada kullanılmaktadır ve kanal sinyallerine 9-30 Hz frekans aralığı için eğricik dönüşümü uygulanmaktadır. Elde edilen dönüşüm katsayıları üzerinden standart sapma, ortalama değer ve log-varyans değerleri hesaplanarak özellik vektörleri oluşturulmaktadır. Doğrudan özellik vektörleri üzerinden ve özellik seçimi yapılarak karşılaştırmalı sınıflandırma işlemleri gerçekleştirilmektedir. Özellik seçimi için t-test yöntemi kullanılmakta, sınıflandırma işlemi k-NN sınıflandırıcısı kullanılarak gerçekleştirilmiştir.

Anahtar kelimeler

BBA, EEG, motor görüntüsü, eğricik dönüşümü, k-NN.

Classification of Two-Class Motor Imagery EEG Signals Using Curvelet Transform Decomposition

Abstract

Studies on brain computer interfaces primarily attempt to gather, analyze, and transfer brain signals into usable commands. The electroencephalogram (EEG) gives researchers the chance to convert brain signals into control instructions. Due to its subject-specific and non-stationary character, classification of EEG signals is a difficult issue, and research are being undertaken using methodological approaches. Analysis of the brain's activities, including motor imagery, is part of some research that have been done. This article presents a two-class motor imagery classification algorithm using curvelet transform decomposition. The proposed algorithm is carried out using the BCI competition IV dataset IIa. EEG signals of the three selected channels (C3, Cz and C4) from the data set composed of 18 channels are used in practice. Curvelet transform is applied to the selected channel signals for the 9-30 Hz frequency range. The feature vectors are created by calculating the standard deviation, mean and log-variance values over the obtained transform coefficients. Comparative classification processes are carried out over feature vectors with and without feature selection. The t-test method is used for feature selection, and the classification process is carried out using the k-NN classifier.

Keywords

BCI, EEG, motor imagery, curvelet transform, k-NN.

1. Giriş

Beyin Bilgisayar Arayüzü (BBA, BCI brain-computer interface), insan beyni ile doğal bir iletişim ve kontrol olanağı sağlayarak beyin aktivitesini ölçer ve ardından beyin ve bilgisayar arasında doğrudan bir etkileşim kurmak için ölçülen aktiviteleri anlaşılır hale getirmeye çalışır (Guger vd. 2014, Vallabhaneni vd. 2005). EEG tabanlı veriler, cerrahi işlem gerektirmeyen yapısı, düşük maliyeti ve göreceli basitliği nedeniyle BBA çalışmalarında alternatiflerinden daha yaygın olarak kullanılmaktadır (Constantin vd. 2007, Curran vd. 2003). Yapılan BBA çalışmalarının bir bölümü motor görüntü bilgilerini içeren EEG tabanlı veriler üzerine odaklanmaktadır. Bu çalışmalar, farklı motor görüntülerin nasıl ayırt edileceğine odaklanmış ve başarılı sonuçlara ulaşmak için çeşitli algoritmalar önerilmiştir (Wang vd. 2004, Ramoser vd. 2000, Garrett vd. 2003).

Zhang vd. (2017), motor görüntüleri içeren EEG sinyallerini sınıflandırmak için seyrek Bayesian frekans bantları öğrenme yöntemini kullanmaktadır. Özellik verileri, ortak uzamsal örüntüler (CSP: Common spatial pattern) algoritması kullanılarak ham EEG verilerine birden fazla örtüşen alt bantlı bir filtre bankası uygulanarak elde edilen sinyal kümesinden üretilmektedir. Seyrek Bayesian öğrenme, en etkili özellikleri özellik kümesinden ayırt etmek için kullanılmaktadır. Wang vd. (2016), ayırt edici kararlı durum görsel uyarılmış potansiyel (SSVEP: steady-state visual evoked potentials) özellikleri elde etmek için çok değişkenli doğrusal regresyon (MLR: Multivariate linear regression) yöntemi içeren zaman-uzaysal özellik çıkarımı kullanan bir yaklaşım sunmaktadır. MLR, boyutu küçültülmüş EEG eğitim verilerine ve en uygun ayırt edici alt alanları bulmak için oluşturulan bir etiket matrisine uygulanmaktadır. Zhang vd. (2018), motor görüntü EEG sinyallerini sınıflandırmak için çok çekirdekli aşırı öğrenme makinesine (MK-ELM: Multi-kernel extreme learning machine) dayalı bir yöntem kullanılmaktadır. İki farklı çekirdek fonksiyonunun (Gauss ve polinom) ELM performansı üzerindeki etkileri araştırılmıştır. MK-ELM yöntemi, EEG motor örüntü verilerini daha yüksek sınıflandırma

doğruluğu ile sınıflandırmak için bu çekirdeklerin çok çekirdekli bir öğrenme stratejisi ile birleştirilmesiyle oluşturulmaktadır.

Yang vd. (2017), çok sınıflı EEG sinyallerinin sınıflandırma doğruluğunu iyileştirmeyi ve motor görüntü verilerine dayalı olarak BBA sisteminde ihtiyaç duyulan EEG kanallarının sayısını azaltmayı amaçlamaktadır. Deneğe özgü özellikleri çıkarmak için en uygun zaman-frekans alanlarını arayan bir yöntem sunulmak amaçlanmaktadır. Baali vd. (2015), doğrusal tahmine dayalı tekil değer ayrışımı (LP-SVD: linear prediction singular value decomposition) adı verilen özellik çıkarımı için sinyale bağlı bir ortogonal dönüşüm kullanılmaktadır. Dönüşüm, eşlemeyi LP katsayı filtresi darbe yanıt matrisinin sol tekil vektörleri olarak tanımlayarak elde edilen özellikleri bir lojistik ağaç tabanlı model sınıflandırıcıya sunmaktadır. Chaudhary vd. (2019), motor görüntü EEG sinyallerini sınıflandırmak için derin evrişimli sinir ağlarına (DCNN: Deep convolutional neural networks) dayalı bir yöntem sunmaktadır. Önerilen yöntem ilk olarak zaman frekansı (T-F) yaklaşımlarını uygulayarak EEG sinyallerini görüntülere dönüştürmekte ardından elde edilen görüntülere DCNN uygulanmaktadır. Burada T-F yaklaşımları, kısa süreli Fourier dönüşümü (STFT: Short-time-Fouriertransform) ve sürekli dalgacık dönüşümüdür (CWT: Continuous-wavelet-transform). Gedik (2022) çalışmasında BBA yarışması III veri seti IIIa'ya ait EEG sınıflandırması için ham EEG sinyalleri 4 frekans bandına bölünmekte ve her frekans aralığına eğricik dönüşümü uygulanmaktadır. Dönüşüm katsayıları kullanılarak özellik verisi oluşturulmakta ve sınıflandırıcı olarak SVM ve k-NN kullanılmaktadır. Diğer bir çalışmasında, Gedik (2022), önceki çalışmasındaki özellik verisi oluşturulma aşamasında değişiklik yapmakta ve dalga-atom dönüşümü kullanılmaktadır. Yine Gedik (2022) başka bir çalışmasında, BBA yarışması III veri seti IIIa'ya ait EEG sinyalleri 2 frekans bandına ayırmakta ve her frekans aralığına dalga-atom dönüşümü uygulanmaktadır. Elde edilen dönüşüm katsayılarından ortalama, standart sapma, entropi, medyan, maksimum değer, basıklık, çarpıklık ve

log-varyans değerleri hesaplanarak sınıflandırma başarıları incelenmektedir.

Bu çalışmada, çok ölçekli analiz yöntemi olan eğricik dönüşümü kullanılarak BBA yarışması IV veri seti IIa'ya ait motor görüntü EEG sinyallerinin sınıflandırılması gerçekleştirilmektedir. Eğricik dönüşümü, C3, C4 ve Cz kanallarına EEG sinyallerinin 9-30 Hz frekans aralığına uygulanmakta ve dönüşüme ait katsayılar elde edilmektedir. Bu katsayılardan, ortalama, standart sapma ve log-varyans değerleri hesaplanarak özellik vektörleri üretilmekte ve farklı kombinasyonlarda sınıflandırıcıya sunulmaktadır başarı oranları analiz edilmektedir. Sınıflandırma işlemi k-NN algoritması kullanılarak gerçekleştirilmektedir. Uygulama i7-8700 CPU @ 3.20 GHz 8 GB ram özellikli bilgisayar ile MATLAB ortamında gerçekleştirilmiştir.


2. Materyal ve Metot

Motor görüntü EEG verileri, BBA yarışması IV veri kümesi IIa'dan elde edilmiştir. Veri seti dört sınıf motor görüntü sinyali (sol el, sağ el, ayak ve dil) içermektedir. Bu çalışmada, sağ ve sol el görüntü EEG sinyallerinin sınıflandırılmasına odaklanılmıştır. Bu doğrultuda, ilk işlem olarak sağ ve sol motor görüntü bilgisini içeren sinyaller veri setinden ayrıştırılmaktadır. Ardından, ayrıştırılan sinyallerden de literatürde sıklıkla tercih edilen C3, C4 ve Cz kanallarına ait sinyaller (Yang vd. 2017) çıkarılarak EEG veri seti oluşturulmuştur. Oluşturulan veri setine Butterworth filtresi 9-30 Hz frekans aralığı için uygulanmakta ve ardından eğricik dönüşümü uygulanarak dönüşüm katsayıları elde edilmektedir. Katsayılar üzerinden üç farklı özellik kümesi oluşturulmakta ve farklı kombinasyonlarla sınıflandırıcıya sunulmaktadır başarıları değerlendirilmektedir. Özellik vektörleri ve sınıflandırma kombinasyonları: 1-) Filtrelenmiş EEG sinyallerine uygulanan eğricik dönüşüm katsayılarından ortalama, standart sapma ve log-varyans değerleri hesaplanarak üç özellik vektörü (F1, F2, F3 sırasıyla) oluşturulması ve ayrı ayrı sınıflandırılması, 2-) F1, F2 ve F3 özellik verileri birleştirilerek sınıflandırmanın gerçekleştirilmesi, 3-) birleştirilen özellik vektör kümesine t-test ile özellik

seçimi uygulandıktan sonra sınıflandırma yapılması. Yönteme ait akış şeması Şekil 1'de gösterilmektedir.

2.1 Veri kümesi

BBA yarışmaları, veri analiz tekniklerinin doğrulanmasını sağlamak ve BBA teknolojisini gelişimini teşvik etmek için düzenlenmektedir. Her yarışmada çeşitli veri setleri internet üzerinden herkesin kullanımına sunulmakta ve her bir veri seti BBA teknolojisinde deneyimli ve lider laboratuvarlarda hazırlanmış beyin sinyallerinin bir kayıdır. Bu kayıtlar iki bölüme ayrılır: etiketli veri bölümü ("eğitim seti") ve etiketlenmemiş veri bölümü ("test seti"). Önerilen yöntem, BBA yarışması IV'te dört sınıf motor görüntü verisini içeren veri kümesi IIa kullanılarak gerçekleştirilmiştir (IntKyn 1). Veri kümesi dokuz deneye ait sağ el, sol el, ayak ve dil bilgilerini içermektedir. Kayıtlar, 22 kanal üzerinden her bir denek için 6 çalışma ve her çalışmada 48 deneme yapılarak toplanarak 288 deneme (her bir motor görüntü için 72) sonucunda oluşturulmuştur (IntKyn 2). Çalışmada, sağ ve sol el görüntü EEG sinyallerinin sınıflandırılmasına odaklanıldığı için eğitim ve test veri seti 144'er EEG sinyal verisinden oluşmaktadır.



Şekil 1. Uygulamaya ait akış şeması.

2.2 Eğricik dönüşümü

Eğricik dönüşümü Candès ve Donoho tarafından 2000'da (Candès ve Donoho 2000) ilk versiyon olarak ve 2006'da (Candès vd. 2006) ikinci versiyon olarak tanıtılmıştır. İlk versiyon olan Sürekli Eğricik Dönüşümü, bir görüntünün radon dönüşümünün sırtcık analizini içeren kompleks dizi adımlarını içermektedir. Oldukça yavaş olması nedeniyle algoritma güncellenmiş ve hızlı ayrık eğricik dönüşümü olarak tanımlanarak ikinci versiyon oluşturulmuştur. Eğricik dönüşümü, konum, ölçek ve yön parametreleriyle indekslenen çerçeve elemanlarına sahip çok ölçekli bir dönüşümdür ve aynı zamanda çok yüksek derecede yönlülük ve anizotropi göstermektedir. Verilen bir f fonksiyonu için, eğricik dönüşümü bir iç çarpım olarak Eşitlik 1'deki gibi tanımlanmaktadır.

$$C(j, l, k) = \langle f, \phi(j, l, k) \rangle = \int f(x) \phi_{j,l,k} dx \quad (1)$$

burada, $\phi(j, l, k)$ eğricik temel fonksiyonunu temsil ederken j, l, k sırasıyla ölçeği, yönü ve konum parametrelerini temsil etmektedir. Ayrık eğricik dönüşümü ise Eşitlik 2'de tanımlanmaktadır.

$$C^D(j, l, k) = \sum_{0 \leq x_1, y_1 < n} f[x_1, y_1] \phi_{j,l,k}^D[x_1, y_1] \quad (2)$$

burada, $\phi_{j,l,k}^D[x_1, y_1]$ ayrık eğricik dalga formunu temsil etmektedir.

3. Bulgular

C3, C4 ve Cz kanallarına ait EEG sinyalleri 9-30 Hz frekans aralığı için filtreledikten sonra eğricik dönüşümü uygulanmakta ve eğricik katsayıları üzerinden beş farklı özellik verisi oluşturulmuştur. İlk üç özellik verisi (F1, F2, F3) eğricik katsayılarından sırasıyla ortalama, standart sapma ve log-varyans hesaplamaları gerçekleştirilerek oluşturulmuştur. Dördüncü özellik kümesi elde edilen üç özellik kümesinin birleştirilmesiyle (F1+F2+F3) oluşturulmuştur. Son olarak birleştirilen özellik kümesine t-test yöntemiyle özellik seçimi uygulanmış ve yeni bir özellik kümesi oluşturulmuştur. Özellik kümeleri ayrı ayrı sınıflandırıcıya sunulmuş ve sınıflandırma sonuçları karşılaştırmalı olarak değerlendirilmiştir. Çizelge

1'de ilk dört özellik kümesine ait sınıflandırma doğruluğu değerleri sunulmaktadır.

Çizelge 1. Oluşturulan ilk dört özellik kümesi için sınıflandırma sonuçları.

Özellik verisi	k-NN	k	
F1	Denek 1	55.55556	23
	Denek 2	62.5	41
	Denek 3	56.94444	3
	Denek 4	50	5
	Denek 5	54.16667	7
	Denek 6	51.38889	35
	Denek 7	54.86111	21
	Denek 8	53.47222	3
	Denek 9	59.72222	7
F2	Denek 1	60.41667	37
	Denek 2	56.94444	5
	Denek 3	81.94444	21
	Denek 4	58.33333	17
	Denek 5	56.25	39
	Denek 6	59.72222	7
	Denek 7	54.86111	29
	Denek 8	57.63889	7
	Denek 9	82.63889	41
F3	Denek 1	60.41667	7
	Denek 2	54.16667	39
	Denek 3	61.80556	41
	Denek 4	58.33333	15
	Denek 5	56.94444	23
	Denek 6	57.63889	25
	Denek 7	56.25	11
	Denek 8	52.08333	3
	Denek 9	62.5	37
F1+F2+F3	Denek 1	59.02778	17
	Denek 2	55.55556	3
	Denek 3	77.08333	25
	Denek 4	63.19444	13
	Denek 5	54.86111	5
	Denek 6	56.94444	15
	Denek 7	56.94444	23
	Denek 8	59.72222	7
	Denek 9	81.94444	39

Elde edilen en başarılı sınıflandırma sonuçları F1 özellik verisi için 62.5 %, F2 özellik verisi için 82.64 % ve F3 özellik verisi için 62.5 % dir. Bu değerler sırasıyla denek 2 ve denek 9'a ait EEG verisinden elde edilmiştir. Bütün denekler göz önünde


bulundurularak özellik kümesi başarısına bakıldığında F1 özellik verisi için ortalama sınıflandırma sonucu 55.4 %, F2 için 63.2 % ve F3 için 57.8 % olarak elde edilmiştir. Birleştirilen özellik verisi için (F1+F2+F3) en başarılı sınıflandırma sonucu denek 9'a ait EEG verisi ile 81.94 % olarak elde edilmiş, birleştirilen özellik verisi için bütün deneklere ait ortalama sınıflandırma değeri ise 62.81 % olmuştur. Sınıflandırma değerleri göz önünde bulundurulduğunda en başarılı sonuçlar F2 özellik verisi ile elde edilmektedir.

t-test yöntemiyle gerçekleştirilen özellik seçimine ait sınıflandırma sonuçları Çizelge 2'de gösterilmektedir. Birleştirilen özellik verisi t-test yöntemi ile sıralanmış ve bu sıralanmış veri 5 gruba ayrılarak her bir grubun sınıflandırma başarısına bakılmıştır. Gruplar oluşturulurken en yüksek sıralama değeri ve en düşük sıralama değerinin farkı beşe bölünerek grup adım aralığı elde edilmiştir. Her adımda (eşik) sıralanmış özellik verisinin boyutu küçülmekte ve sıralama değeri eşikten büyük olan özellik verisi sınıflandırmada kullanılmaktadır. Yapılan sınıflandırma işlemlerinde özellik seçiminin genel olarak sınıflandırma doğruluğunu iyileştirdiği gözlenmiştir. Elde edilen en başarılı sınıflandırma sonucu 84.72 % olarak denek 2 ye ait EEG verisinden elde edilmiştir. t-test özellik seçimi üzerinden elde edilen sınıflandırma sonuçlarının değişimi Çizelge 2'de gösterilmektedir. Denekler üzerinden özellik kümeleri değerlendirildiğinde en başarılı sonuçlar, denek 1 için F2 ve F3 özellik kümesiyle 60.42 % olarak, denek 2 için F1 özellik kümesiyle 62.5 % olarak, denek 3 için F2 özellik kümesiyle 81.94 % olarak, denek 4 için F1+F2+F3 özellik kümesiyle 63.19 % olarak, denek 5 için F3 özellik kümesiyle 56.94 % olarak, denek 6 için F2 özellik kümesiyle 59.72 % olarak, denek 7 için F1+F2+F3 özellik kümesiyle 56.94 % olarak, denek 8 için F1+F2+F3 özellik kümesiyle 59.72 % olarak ve denek 9 için F2 özellik kümesiyle 82.63 % olarak elde edilmiştir.

Çizelge 2. t-test yöntemiyle yapılan özellik seçimi üzerinden gerçekleştirilen sınıflandırmaya ait sonuçlar.

Özellik verisi	k-NN	k
Denek1	59.02778	17
	59.02778	17
	59.02778	17
	59.02778	17
	57.63889	35
Denek2	55.55556	3
	55.55556	3
	54.16667	3
	54.16667	3
	53.47222	3
Denek3	77.08333	25
	80.55556	9
	84.72222	5
	77.08333	7
	59.02778	9
Denek4	63.19444	13
	57.63889	27
	56.94444	15
	56.25	15
	57.63889	27
Denek5	54.86111	5
	55.55556	9
	57.63889	7
	57.63889	7
	57.63889	7
Denek6	56.94444	15
	62.5	31
	61.11111	3
	61.11111	3
	59.02778	23
Denek7	56.94444	23
	58.33333	23
	57.63889	11
	57.63889	11
	51.38889	5
Denek8	59.72222	7
	63.19444	9
	58.33333	15
	62.5	25
	63.19444	23
Denek9	81.94444	39
	81.94444	39
	81.94444	39
	82.63889	37
	81.94444	37

(F1+F2+F3)+t-test



Şekil 2. Her bir denek için t-test özellik seçimi üzerinden elde edilen sınıflandırma sonuçları ve değişimi.

4. Sonuç

Bu çalışmada, sağ ve sol el hareket hayali bilgilerini içeren motor görüntü EEG sinyallerini sınıflandırmak için alternatif bir çalışma sunulmakta ve eğricik dönüşümün başarısı araştırılmaktadır. Belirli üç kanaldan elde edilen EEG verisi ön işlemden sonra eğricik dönüşümü uygulanarak üç özellik vektörü elde edilmiştir. Elde edilen özellik vektörleri üç farklı sınıflandırma işlemine tabi tutularak başarı oranları değerlendirilmiştir. Özellik vektörleri ayrı ayrı değerlendirildiğinde, eğricik katsayıları üzerinden standart sapma hesaplamasıyla oluşturulan özellik verisi en başarılı sonucu (82.63 %) denek 9'a ait EEG verisi üzerinden vermektedir. Özellik vektörleri birleştirilerek yapılan sınıflandırma işlemlerinde, t-test yöntemiyle yapılan özellik seçimi işleminin sınıflandırma başarısını genel olarak iyileştirdiği (84.72 %) gözlemlenmiştir.

5. Kaynaklar

- Baali, H., Khorshidtalab, A., Mesbah, M., & Salami, M. J. (2015). A transform-based feature extraction approach for motor imagery tasks classification. *IEEE journal of translational engineering in health and medicine*. **3**, 1-8.
- Candes, E.J., and Donoho, D.L., 2000. Curvelets: A surprisingly effective nonadaptive representation for objects with edges. *Curves and Surfaces*. 105-120.
- Candès E., Demanet L., Donoho D., and Ying L., 2006. Fast Discrete Curvelet Transforms. *Multiscale Modeling and Simulation*, **5(3)**, 861-899.
- Chaudhary, S., Taran, S., Bajaj, V., & Sengur, A. (2019). Convolutional neural network based approach

towards motor imagery tasks EEG signals classification. *IEEE Sensors Journal*. **19(12)**, 4494-4500.

Constantin A., and Danyluk A., 2007. A Brain-Computer Interface for the Classification of Motor Imagery. Bachelor thesis, Williams College, USA.

Curran E.A., and Stokes M.J., 2003. Learning to control brain activity: A review of the production and control of EEG components for driving brain-computer interface (BCI) systems. *Brain and cognition*. **51(3)**, 326-336.

Garrett D., Peterson D.A., Anderson C.W., and Thaut M.H., 2003. Comparison of linear, nonlinear, and feature selection methods for EEG signal classification. *IEEE Transactions on neural systems and rehabilitation engineering*. **11(2)**, 141-144.

Gedik N., 2022. Two Class Motor Imagery Classification via Wave Atom Sub-Bants. *World Academy of Science, Engineering and Technology International Journal of Health and Medical Engineering*. **16(1)**, 1-4.

Gedik N. (2022). Curvelet Transform Based Two Class Motor Imagery Classification. *World Academy of Science, Engineering and Technology International Journal of Health and Medical Engineering*. **16(1)**, 5-8.

Gedik N. (2022). Wave Atom Transform Based Two Class Motor Imagery Classification. *World Academy of Science, Engineering and Technology International Journal of Computer and Systems Engineering*. **16(1)**, 1-4.

Guger C., Allison B.Z., and Edlinger G., 2014. Brain-Computer Interface Research: A State-of-the-Art Summary 2, Springer, New York, NY, USA, 2014.

Ramoser H., Muller-Gerking J., and Pfurtscheller G., 2000. Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE transactions on rehabilitation engineering*. **8(4)**, 441-446.

Vallabhaneni A., Wang T., and He B., 2005. Brain-computer interface. *In Neural engineering*, 85-121.

Wang Y., Zhang Z., Li Y., Gao X., Gao S., and Yang F., 2004. BCI competition 2003-data set IV: an algorithm based on CSSD and FDA for classifying single-trial EEG. *IEEE Transactions on Biomedical Engineering*. **51(6)**, 1081-1086.

Wang H., Zhang Y., Waytowich N.R., Krusienski D.J., Zhou G., Jin J., ... and Cichocki A., 2016. Discriminative feature extraction via multivariate

linear regression for SSVEP-based BCI. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. **24(5)**, 532-541.

Yang Y., Chevallier S., Wiart J., and Bloch I., 2017. Subject-specific time-frequency selection for multi-class motor imagery-based BCIs using few Laplacian EEG channels. *Biomedical Signal Processing and Control*. **38**, 302-311.

Zhang Y., Wang Y., Jin J., and Wang X., 2017. Sparse Bayesian learning for obtaining sparsity of EEG frequency bands-based feature vectors in motor

imagery classification. *International journal of neural systems*. **27(2)**, 1650032.

Zhang Y., Wang Y., Zhou G., Jin J., Wang B., Wang X., and Cichocki A., 2018. Multi-kernel extreme learning machine for EEG classification in brain-computer interfaces. *Expert Systems with Applications*. **96**, 302-310.

İnternet kaynakları

1- <https://www.bbc.de/competition/iv/> (25/09/2022)

2- https://www.bbc.de/competition/iv/desc_2a.pdf (25/09/2022)