



Özgün Araştırma / Original Article

Görsel Uyarılara İlişkin Manyetoensefalografi Sinyallerinin Genelleştirilmiş Regresyon Sinir Ağı ile Sınıflandırılması

Onursal Çetin¹, Feyzullah Temurtaş²

*1 Bandırma Onyediy Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektronik ve Haberleşme Müh. Böl., 10200, Bandırma, Balıkesir, Türkiye
ORCID: 0000-0001-5220-3959*

*2 Bandırma Onyediy Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektronik ve Haberleşme Müh. Böl., 10200, Bandırma, Balıkesir, Türkiye
ORCID: 0000-0002-3158-4032*

Geliş: 13.07.2018; Revizyon: 10.09.2018; Kabul Tarihi: 26.11.2019

Öz

Amaç: Bu çalışmanın amacı, beyin aktivitesini çözmek için Manyetoensefalografi (MEG) sinyallerini yapay sinir ağı ile sınıflandırmaktır.

Yöntemler: MEG sinyallerini sınıflandırmak için Genelleştirilmiş Regresyon Sinir Ağı (GRSA) kullanılmıştır. Riemannian yaklaşımı ile sinyallerin öznitelikleri çıkarılmış ve 10 katlı çapraz doğrulama tekniği ile GRSA'nın doğruluğu hesaplanmıştır.

Bulgular: Çalışmada 9 kız, 7 erkek bireye ait 306 kanaldan kaydedilen MEG verileri kullanılmıştır. Her bireye yaklaşık 588 uyarın gösterilmiştir ve böylece tüm veri seti 9414 uyarıdan oluşmaktadır. Ortalama spesifite, ortalama duyarlılık ve ortalama sınıflandırma doğruluğu sırasıyla %75,43, %82,57 ve %79 olarak elde edilmiştir. Bu çalışma ve aynı MEG veri setini kullanan diğer çalışmalar tarafından elde edilen sınıflandırma doğrulukları karşılaştırmalı olarak sunulmuştur.

Sonuç: GRSA'nın MEG sinyallerinin sınıflandırılmasında kullanılan mevcut yöntemlere başarılı bir alternatif oluşturduğu düşünülmektedir.

Anahtar kelimeler: Manyetoensefalografi Genelleştirilmiş regresyon sinir ağı, Sınıflandırma, Riemannian yaklaşımı.

DOI: 10.5798/dicletip

Yazışma Adresi / Correspondence: Onursal Çetin, Bandırma Onyediy Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü, 10200, Bandırma, Balıkesir, Türkiye e-mail: ocerin@bandirma.edu.tr

Classification of Magnetoencephalography Signals Regarding Visual Stimuli by Generalized Regression Neural Network

Abstract

Objective: The aim of this study is to classify the magnetoencephalography (MEG) signals with artificial neural network to solve brain activity.

Methods: The Generalized Regression Neural Network (GRNN) was used to classify MEG signals. The features of the signals were extracted by the Riemannian approach and the accuracy of the GRNN was calculated by the 10-fold cross validation technique.

Results: In the study, MEG data recorded from 306 channels belonging to 7 male subjects and 9 female subjects were used. Approximately 588 stimuli were shown to each individual, so the entire data set is composed of 9414 stimuli. Mean specificity, mean sensitivity and mean classification accuracy were obtained 75.43%, 82.57% and 79%, respectively. The classification accuracies obtained by this study and other studies for same MEG dataset were presented comparatively.

Conclusion: GRNN is thought to be a successful alternative to existing methods for classifying MEG signals.

Keywords: Magnetoencephalography, Generalized regression neural network, Classification, Riemannian approach.

GİRİŞ

Beyin-bilgisayar arayüzü (BBA) zihinsel aktivite ile insan-makine haberleşmesini olanaklı hale getiren sistemdir. Sinir hücrelerinin elektrokimyasal etkileşimi sonucu ortaya çıkan beyin sinyallerinin kaydedilmesi, bu sistemler için en temel seviyedir¹. BBA sistemleri, çeşitli tekniklerle alınan beyin sinyallerinin işlenmesi ile gerçekleştirilmektedir. Manyetoensefalografi (MEG), BBA sistemleri gerçekleştirmek için zihinsel aktivitenin tespitinde kullanılan yöntemlerden biridir. MEG, nöronal aktivite tarafından üretilen küçük manyetik alanların çoklu ölçümlerini her milisaniyede gerçekleştiren ve invazif olmayan fonksiyonel görüntüleme tekniğidir².

İnsan beyni milisaniyeler mertebesinde görsel algılama hızına sahiptir ve bu mükemmel görsel sistematüğün nasıl çalıştığını anlamak nörobilim araştırmaları açısından önemlidir³. Bireye bir uyarın gösterildiğinde, uyarın ve beyinde oluşan sinyal arasındaki ilişki, makine öğrenmesi algoritmaları geliştirmek için kullanılır. MEG sinyalleri kullanılarak, eş zamanlı beyin aktivitesinden bireye sunulan

uyarının tahmin edilmesinde, Yapay Sinir Ağları (YSA) kullanılarak geliştirilen sınıflandırıcılar kullanılabilirler⁴.

YSA, insan beyninin sistematüğünden esinlenen ve sınıflandırma çalışmalarında sıklıkla kullanılan bilgisayar sistemleridir⁵. Sınıflandırma işlemi gerçekleştirilirken sınıflandırıcıyı eğitmek ve sınıflandırıcı doğruluğunu test etmek gerekmektedir. MEG sinyallerinin karmaşıklığı, çevresel değişkenler ve beynin yapısından kaynaklanan fonksiyonel farklılıklar sınıflandırma işlemi zorlaştırmaktadır⁴. MEG görüntüleme tekniğinin kolay ulaşılabilen yapısı sebebiyle bu tekniğin kullanıldığı çalışmalar sınırlı sayıdadır^{4,6-12}. Sınıflandırıcının performansını artırmak için hem iyi bir sınıflandırma algoritmasına hem de başarılı bir öznitelik çıkarım yöntemine ihtiyaç duyulmaktadır⁴. Literatürde çok kanallı ve karmaşık yapıdaki beyin sinyallerinin özniteliklerinin çıkarılmasında çeşitli yöntemler kullanılmıştır^{13,15}. Öznitelik çıkarım yöntemleri arasında Riemannian yaklaşımı rekabetçi özelliğiyle öne çıkmaktadır^{15,16}.

Bu çalışma kapsamında, Specht tarafından önerilen Genelleştirilmiş Regresyon Sinir Ağı (GRSA) kullanılarak MATLAB (Lisans no: 40692431) programı vasıtasıyla MEG sinyalleri sınıflandırılmıştır. Bu amaçla, Henson ve arkadaşları tarafından sunulan MEG veri setinden faydalanılmıştır¹⁷. Öncelikle karmaşık ve çok kanallı MEG sinyali filtrelenmiş ve gürültüden arındırılmıştır. Daha sonra Riemannian yaklaşımı^{15,16} kullanılarak öznitelik çıkarım işlemi gerçekleştirilmiş, çok kanallı MEG sinyallerinin boyutu azaltılmıştır. 10 katlı çapraz doğrulama tekniği GRSA ağının doğruluğunu hesaplamak için kullanılmıştır¹⁸. Elde edilen sonuçlar, aynı MEG veri setini kullanan önceki yöntemler ile karşılaştırılmıştır.


YÖNTEMLER

Manyetoensefalografi Veri Seti

“Dec2Meg2014”¹⁹ yarışması kapsamında yeniden düzenlenen MEG veri seti Henson ve arkadaşları tarafından sunulmuştur¹⁷. Bu yarışmada amaç, bireye sunulan görsel uyarının sınıfının beyin aktivitesinden tahmin edilmesidir. 9’u kız, 7’si erkek toplam 16 bireye sıradan kişilerin yüzleri, ünlü kişilerin yüzleri ve bu resimlerin anlamsız halleri olmak üzere 3 farklı uyarın gösterilmiş ve 306 kanaldan MEG sinyalleri kaydedilmiştir.

Bu çalışmada, MEG veri seti Olivetti ve arkadaşlarının düzenledikleri şekliyle kullanılmıştır. Yapılan düzenlemeyle resimler normal yüz ve anlamsız yüz olmak üzere iki sınıfa ayrılmıştır². Veri seti hakkında daha detaylı bilgi [19] numaralı referanstan edinilebilir. Normal yüz ve anlamsız yüz örnek resimleri Şekil 1’de gösterilmiştir¹⁹.

Normal yüz ya da anlamsız yüzlerden oluşan yaklaşık 588 resim, 16 bireye rastgele ve seri şekilde 1 saniye boyunca gösterilmiş ve bireyler her bir resimden sonra 0,5 saniye dinlendirilmiştir. 16 bireye toplamda 9414 resim gösterilmiştir.



Şekil 1. Normal yüz ve anlamsız yüz örnekleri

Özniteliklerin Belirlenmesi

MEG verileri GRSA’ya sunulmadan önce sinyallerin örnekleme frekansı 250 Hz’e düşürülmüş ve bant geçiren filtre yardımıyla gürültüden arındırılmıştır². Filtreleme işlemi için 10. Dereceden Butterworth 1-20 Hz bant geçiren filtre kullanılmıştır. MEG sinyalleri çok kanallı olup hangi kanalların kritik bilgi içerdiğinin belirlenmesi önemlidir³. Bu nedenle öznitelik çıkarma işleminin önemi büyüktür. Konumsal filtreleme yardımıyla 306 olan kanal sayısı 8’e düşürülmüştür. Daha sonra bu kanallardan alınan sinyallerden elde edilen kovaryans matrislerinin arasındaki Riemannian mesafesi^{20,21} hesaplanarak öznitelikler elde edilmiştir²².

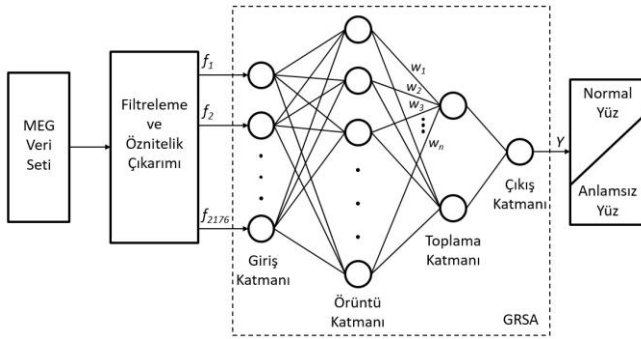
Genelleştirilmiş Regresyon Sinir Ağı ile MEG Sinyallerinin Sınıflandırılması

Genelleştirilmiş regresyon sinir ağı, hedef değişkenler sürekli olduğunda doğrusal olmayan regresyonlar gerçekleştirir. Bu regresyon analizi, veri davranışını taklit eden fonksiyonel formun tahmin edilmesini gerektirir. Çok boyutlu bir problemde, lineer olmayan regresyon analizi ile bu fonksiyonu seçmek zordur. Donald Specht tarafından 1991 yılında önerilen GRSA algoritması, varsayılan bir işlevsel forma ihtiyaç duymadığından bu dezavantajı başarılı bir şekilde aşmaktadır²³. Geriye yayılım metodundan farklı olarak iteratif bir eğitim süreci gerektirmeyen GRSA, radyal tabanlı çalışan ileri beslemeli bir YSA

modelidir²⁴. 'F' giriş vektörü için GRSA çıkışı 'Y' şu şekilde hesaplanır;

$$Y(F) = \frac{\sum_{i=1}^n W_i \exp \left[-\frac{D_i^2}{2\sigma^2} \right]}{\sum_{i=1}^n \exp \left[-\frac{D_i^2}{2\sigma^2} \right]} \quad (1)$$

Bu denklemde, n gözlenen örnek sayısını; $D_i^2 = (F - F_i)^T (F - F_i)$ mesafe fonksiyonunu; F_i örnek değerlerini ve W_i ağırlık değerlerini; σ ise yayılım parametresini ifade etmektedir. MEG sinyalinin sınıflandırılması için kullanılan GRSA yapısı Şekil 2'de verilmiştir.



Şekil 2. Sınıflandırmada kullanılan GRSA yapısının şematik gösterimi

GRSA, her biri bir sonraki katmanla bağlantılı olmak üzere giriş katmanı, örüntü katmanı, toplama katmanı ve çıkış katmanı olmak üzere dört katmandan oluşmaktadır. Bu dört katmandan her biri farklı sayılarda nörona sahiptir. Giriş katmanındaki nöronların sayısı bağımsız değişkenlerin sayısına eşittir. Eğitim veri setindeki her örnek veri için örüntü katmanında bir adet nöron ilişkilendirilmesi sebebiyle işlem sayısı artmaktadır. Eğitim esnasında, giriş vektörünün her bir giriş nöronu için Öklid mesafesi hesaplanır. Her bir giriş nöronundan gelen mesafeler, doğrusal olmayan üstel bir aktivasyon fonksiyonuna bir düzeltme parametresi ile beslenir. Ortaya çıkan değerler toplama katmanına aktarılır. Toplama katmanı, pay ve payda adı verilen iki nöron içerir. Payda nöronu, örüntü katmanının

çıkıtlarının toplamını hesaplar. Pay nöronu ise örüntü katmanı çıktıları ile her eğitim verisinin beklenen değerlerini içeren bir vektör arasındaki nokta çarpımı hesaplar. Çıkış katmanında pay nöronundan gelen değer, payda nöronundan gelen değere bölünerek tahmini değer bulunur^{23,24}.

Sınıflandırma Doğruluğu

Sistem performansını belirlemek için performans değerlendirme ölçütlerinden faydalanılmaktadır. Bu çalışmada Denklem 2, Denklem 3 ve Denklem 4 ile verilen sınıflandırma doğruluğunun yanı sıra Denklem 5 ile verilen spesifite ve Denklem 6 ile verilen duyarlılık değerlendirme ölçütleri de kullanılmıştır^{25,26}.

$$\text{Doğruluk } (N) = \frac{\sum_{i=1}^{|N|} \text{Tahmin}(n_i)}{|N|}, n_i \in N \quad (2)$$

$$\text{Tahmin}(n) = \begin{cases} 1, & \text{Eğer } \text{Tahmin}(n) = nc \\ 0, & \text{aksi halde} \end{cases} \quad (3)$$

$$\begin{aligned} \text{Sınıflandırma Doğruluğu (Alg)} \\ = \frac{\sum_{i=1}^{|k|} \text{Doğruluk } (N_i)}{|k|} \end{aligned} \quad (4)$$

Burada; N , sınıflandırılan (test) veri setini, nc , n değerinin sınıfını, $\text{Tahmin}(n)$, n 'nin sınıflandırma sonucunu ve k değeri de k -katlı çapraz doğrulama parametresini ifade etmektedir. Spesifite ve duyarlılık şu şekilde hesaplanmaktadır;

$$\text{Spesifite} = \frac{TN}{TN + FP} \quad (5)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (6)$$

Burada;

- Yanlış pozitif (FP): Anlamsız yüzlerin, normal yüz olarak sınıflandırma karar sayısı.
- Yanlış negatif (FN): Normal yüzlerin, anlamsız yüz olarak sınıflandırma karar sayısı.
- Gerçek pozitif (TP): Normal yüzlerin, normal yüz olarak sınıflandırma karar sayısı.

- Gerçek negatif (TN): Anlamsız yüzlerin, anlamsız yüz olarak sınıflandırma karar sayısı.

K-katlı Çapraz Doğrulama

Sistem doğruluğunun sınanması için veri kümesi, eğitim kümesi ve test kümesi olmak üzere iki parçaya ayrılmaktadır. Çalışma içerisinde GRSA ağının doğruluğu hesaplanırken K-katlı çapraz doğrulama tekniği kullanılmıştır. 'k' parametresi, veri setinin eşit büyüklükte kaç alt kümeye bölüneceğini belirtmektedir. Veri seti sınıflara ayrılır ve sonrasında sınıflandırma algoritması k-kez eğitilir ve test edilir. Her defasında k adet kümeden bir tanesi test işlemi için ayrılmakta ve geriye kalan k-1 küme sınıflandırıcının eğitimi için kullanılmaktadır. Böylece, k adım sonunda elde edilen k-farklı test sonucunun ortalaması alınarak genel sınıflandırma doğruluğu elde edilmektedir²⁷. Bu çalışmada GRSA ağının doğruluğunu hesaplamak amacıyla 10-katlı çapraz doğrulama tekniği kullanılmıştır¹⁸.

SONUÇLAR

Bu çalışmada, 16 bireye ait 306 kanaldan kaydedilen MEG verileri kullanılmıştır. Her bir bireye yaklaşık 588 uyarın olmak üzere toplam 9414 uyarın gösterilmiştir. Gürültü içeren MEG sinyalleri filtrelenip gürültüden arındırılmış ve öznelikleri elde edilmiştir. 2176 özneliğe sahip 9414 uyarın rastgele GRSA ağına sunulmuştur. Çalışmanın amacı, GRSA kullanılarak MEG sinyalinin "normal yüz" ya da "anlamsız yüz" sınıflarından hangisine ait olduğunun belirlenmesidir.

10-katlı çapraz doğrulama tekniği ile sınıflandırıcının doğruluğu sınanmıştır. Bu amaçla veri seti 10 eşit parçaya (kat) bölünmüştür. GRSA toplamda 10 kere eğitilip test edilmiş, her defasında parçalardan biri test işlemine ayrılıp geriye kalan 9 parça ağı eğitimi için kullanılmıştır. 10 parça için elde edilen doğrulukların ortalaması alınarak sınıflandırma doğruluğu elde edilmiştir. Her bir

parça için düzeltme parametreleri ve hesaplanan duyarlılık, spesifite ve doğruluk ile bu parametrelere ait ortalama başarımlar Tablo 1'de yer almaktadır.

Tablo 1: 10-katlı çapraz doğrulama için başarımlar oranları

	Yayımlı Parametresi (σ)	Spesifite (%)	Duyarlılık (%)	Doğruluk (%)
Kat 1	1.6367	75,71	82,98	79,35
Kat 2	1.3924	74,71	82,24	78,48
Kat 3	1.3185	75,24	82,36	78,80
Kat 4	1.4961	75,11	82,56	78,84
Kat 5	1.6155	75,54	82,36	78,95
Kat 6	0.5356	75,51	82,33	78,92
Kat 7	1.7698	75,35	82,53	78,94
Kat 8	1.5768	75,66	82,66	79,16
Kat 9	1.4128	75,73	82,75	79,24
Kat 10	1.6418	75,74	82,91	79,33
ORTALAMA		75,43	82,57	79,00

Tablo 1 incelendiğinde, katlar arası veri dağılımının birbirini dışlayan bir yapıda rastgele olarak gerçekleştiği ve sonuç olarak katlar arası doğruluğun birbirine yakın olduğu gözlenmektedir. Aynı zamanda duyarlılığın yüksek olması normal yüzün anlamsız yüze göre daha iyi ayırt edildiği anlamına gelmektedir. Ortalama spesifite, ortalama duyarlılık ve ortalama sınıflandırma doğruluğu sırasıyla %75,43, %82,57 ve %79 olarak elde edilmiştir.

Aynı MEG verisini kullanan yöntemler ve bu çalışma tarafından elde edilen sınıflandırma doğrulukları karşılaştırmalı olarak Tablo 2'de gösterilmiştir.

Tablo 2'den de görüldüğü gibi Abdullah Çalışkan ve arkadaşları kullandıkları algoritmalar ile %68,36 ile %80,85 arasında değişen sınıflandırma doğrulukları elde etmişlerdir³. En iyi performansı Derin Sinir Ağı (Deep Neural Network-DNN) gösterirken en

düşük performansı Karar Ağacı (Decision Trees-DT) yapısı göstermiştir. Çetin ve Temurtas yaptıkları çalışmada öğrenmeli vektör kuantalama (Learning Vector Quantization-LVQ) kullanmışlar ve %69,39 sınıflandırma doğruluğu elde etmişlerdir⁴. Bu çalışma ise en iyi sonucu göstermese de GRSA'nın performans açısından %79 ile Destek Vektör Makinesi (Support Vector Machine SVM) yapısından daha iyi olduğu ve DNN yapısına yakın sonuç verdiği görülmektedir.

Tablo 2: MEG verisi için kullanan yöntemler ve erişilen sınıflandırma doğrulukları

Çalışmalar	Uygulanan Yöntemler	Sınıflandırma Doğrulukları (%)
[3]	DNN	80.85
	SVM	78.01
	KNN	72.84
	NB	71.92
	DT	68.36
[4]	LVQ	69.39
Bu çalışma	GRSA	79.00

TARTIŞMA

MEG sinyalleri çok kanallı ve gürültü içeren yapıda olup bu sinyallerden anlamlı bilgi edinilmesi bazı işlemler gerektirmektedir. Bu çalışma kapsamında, MEG sinyallerinin sınıflandırılmasında daha önce başarıyı incelenmemiş bir yöntem olan GRSA kullanılmıştır. Bu amaçla GRSA algoritması MATLAB programı üzerinde çalıştırılmıştır. 10-katlı çapraz doğrulama tekniği ile sınıflandırıcının doğruluğu sınanmış, performans değerlendirme ölçütleri olan spesifite ve duyarlılık da hesaplanmıştır. GRSA, literatürde sınıflandırma işlemi için sıklıkla kullanılan SVM ve K En Yakın Komşu (K-Nearest Neighbours-KNN) yöntemleri ile kıyaslandığında daha başarılı ve kullanımı gün geçtikçe artan fakat gerçekleştirilmesi yazılım kütüphanelerinin yaygın olmaması nedeniyle

uzmanlık gerektiren DNN yapısına yakın sonuç vermiştir. Buradan yola çıkarak, GRSA'nın MEG sinyallerinin sınıflandırılmasında kullanılan mevcut yöntemler için başarılı bir alternatif oluşturduğu düşünülmektedir.

Çıkar Çatışması Beyanı: Yazarlar çıkar çatışması olmadığını bildirmişlerdir.

Finansal Destek: Bu çalışma her hangi bir fon tarafından desteklenmemiştir.

Declaration of Conflicting Interests: The authors declare that they have no conflict of interest.

Financial Disclosure: No financial support was received.

KAYNAKLAR

1. Bascil MS, Tesneli AY, Temurtas F. A study on analog and digital EEG signal filtering for brain computer interfaces (BCI). *Electronic Letters on Science&Engineering* 2014; 10: 1-10.
2. Olivetti E, Kia SM, Avesani P. MEG decoding across subjects. *International Workshop on Pattern Recognition in Neuroimaging* 2014; doi: 10.1109/PRNI.2014.6858538.
3. Caliskan A, Yuksel ME, Badem H, Basturk A. A deep neural network classifier for decoding human brain activity based on Magnetoencephalography. *Elektronika ir Elektrotechnika* 2017; 23: 63-7.
4. Cetin O, Temurtas F. Öğrenmeli vektör kuantalama ile beyin bilgisayar arayüzü üzerine bir çalışma. *Sakarya University Journal of Computer and Information Sciences* 2018; 1: 17.
5. Gulbag A, Temurtas F. A study on quantitative classification of binary gas mixture using neural networks and adaptive neuro-fuzzy inference systems. *Sensors and Actuators B* 2006; 115: 252-62.
6. Abadi MK, Subramanian R, Kia SM, Avesani P, Patras I, Sebe N. DECAF: MEG-based multimodal database for decoding affective physiological responses. *IEEE Trans. Affective Computing* 2015; 6: 209-22.
7. Chan AM, Halgren E, Marinkovic K, Cash SS. Decoding word and category-specific spatiotemporal representations from MEG and EEG. *NeuroImage* 2011; 54: 3028-39.
8. Daliri MR. A hybrid method for the decoding of spatial attention using the MEG brain signals. *Biomedical Signal Processing and Control* 2014; 10: 308-12.

9. Kia SM, Pedregosa F, Blumenthal A, Passerini A. Group-level spatio-temporal pattern recovery in MEG decoding using multi-task joint feature learning. *Journal of Neuroscience Methods* 2017; 285: 97-108.
10. Huttunen H, Kauppi JP, Tohka J. Regularized logistic regression for mind reading with parallel validation. *ICANN 2011 International Conference on Artificial Neural Networks, Pattern Analysis, Statistical Modelling and Computational Learning* 2011; 20-24.
11. Kia SM, Vega Pons S, Weisz N, Passerini A. Interpretability of multivariate brain maps in linear brain decoding: Definition, and heuristic quantification in multivariate analysis of MEG time-locked effects. *Frontiers in Neuroscience* 2017; 10: 619; doi: 10.3389/fnins.2016.00619
12. Redcay E, Carlson TA. Rapid neural discrimination of communicative gestures. *Social Cognitive and Affective Neuroscience* 2015; 10: 545-51.
13. Ursulean R, Lazar AM. Detrended cross-correlation analysis of biometric signals used in a new authentication method. *Elektronika ir Elektrotechnika* 2009; 89: 55-8.
14. Raudonis V, Narvydas G, Simutis R. A classification of flash evoked potentials based on artificial neural network. *Elektronika ir Elektrotechnika* 2008; 81: 31-6.
15. Barachant A, Bonnet S, Congedo M, Jutten C. Multiclass brain-computer interface classification by Riemannian geometry. *IEEE Trans. Biomedical Engineering* 2012; 59: 920-28.
16. Yger F, Berar M, Lotte F. Riemannian approaches in brain computer interfaces: a review. *IEEE Trans. Neural Systems and Rehabilitation Engineering* 2017; 25: 1753-62.
17. Henson RN, Wakeman DG, Litvak V, Friston KJ. A parametric empirical Bayesian framework for the EEG/MEG inverse problem: generative models for multi-subject and multi-modal integration. *Frontiers in Human Neuroscience* 2011; 5: 76.
18. Cetin O, Temurtas F, Gulgonul S. An application of multilayer neural network on hepatitis disease diagnosis using approximations of sigmoid activation function. *Dicle Medical Journal* 2015; 42: 150-7.
19. Ulaşabileceği adres: <https://www.kaggle.com/c/decoding-the-human-brain>
20. Moakher M. A differential geometric approach to the geometric mean of symmetric positive-definite matrices. *SIAM Journal on Matrix Analysis and Applications* 2005; 26: 735-47.
21. Ulaşabileceği adres: <https://github.com/alexandrebarachant/covariancetoolbox>
22. Pennec X, Fillard P, Ayache N. A Riemannian framework for tensor computing. *International Journal of Computer Vision* 2006; 66: 41-66.
23. Specht DF. A general regression neural network. *IEEE Transactions on Neural Networks* 1991; 2: 568-76.
24. Specht DF, Shapiro PD. Generalization accuracy of probabilistic neural networks compared with backpropagation networks. *IJCNN-91-Seattle International Joint Conference on Neural Networks* 1991; 887-92; doi: 10.1109/IJCNN.1991.155296.
25. Bascil MS, Cetin O, Er O, Temurtas F. Olasılıksal sinir ağının (PNN) parkinson hastalığının teşhisinde kullanılması. *Electronic Letters on Science & Engineering* 2012; 8: 1-10.
26. Gorur K, Bozkurt MR, Bascil MS, Temurtas F. Glossokinetic potential based tongue-machine interface for 1-D extraction. *Australas Phys Eng Sci Med* 2018; 41: 379-91.
27. Bascil MS, Oztekin H. A study on hepatitis disease diagnosis using probabilistic neural network. *Journal of Medical Systems* 2012; 36: 1603-6.