

Öğrenmeli Vektör Kuantalama ile Beyin Bilgisayar Arayüzü Üzerine Bir Çalışma

Onursal ÇETİN, Feyzullah TEMURTAŞ

Onursal ÇETİN; Corresponding Author; ocerin@bandirma.edu.tr

Bandırma Onyediy Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü, 10200, Balıkesir/Türkiye

Feyzullah TEMURTAŞ; ftemurtas@bandirma.edu.tr

Bandırma Onyediy Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü, 10200, Balıkesir/Türkiye

Received 23 May 2018; Accepted 06 June 2018; Published online 03 August 2018

Özet

Beyin-bilgisayar arayüzü (BCI) insan beyni ve bilgisayar arasında iletişim ve kontrol sağlayabilir. Beyin sinyallerinin saptanması, bu sistemler için en temel düzeydir. Manyetoensefalografi (MEG) beyin aktivitesini çözmek için invazif olmayan bir görüntüleme tekniğidir. MEG sinyalleri karmaşıktır ve çevresel olaylardan ve beyin fonksiyonel farklılıklarından kolayca etkilenir. BCI sistemleri için bu karmaşık sinyallerden bilgi almak zordur. Bu nedenle, bilgiyi anlamlı kılmak için ileri sinyal işleme teknikleri gereklidir. Bu çalışmada, manyetoensefalografi sinyallerini öğrenmeli vektör kuantalama (LVQ) ile sınıflandırarak LVQ algoritmasının başarısı ortaya konulmuştur. Sınıflandırma doğruluğu 10 kat çapraz doğrulama ile elde edilmiştir. Önerilen sınıflandırıcının performansı, MEG'e odaklanan ve aynı veri setini kullanan önceki yöntemler ile karşılaştırılmıştır.

Anahtar Kelimeler: Beyin-bilgisayar arayüzü; manyetoensefalografi; öğrenmeli vektör kuantalama; sınıflandırma

A Study on Brain Computer Interface using Learning Vector Quantization

Abstract

Brain-computer interface (BCI) can provide communication and control between the human brain and a computer. Detection of brain signals is the most basic level for these systems. Magnetoencephalography (MEG) is a non-invasive neuroimaging technique for decoding brain activity. MEG signals are complicated and can be easily affected by environmental events and functional differences of the brain. It is difficult to get information from these complex signals for BCI systems. Therefore, advanced signal processing techniques are required to make the information meaningful. In this study, the success of learning vector quantization (LVQ) algorithm has been put forward by classifying magnetoencephalography signals through LVQ. Classification accuracy is obtained via 10-fold cross validation. The performance of proposed classifier is compared with the results of the previous methods reported focusing on MEG and using same dataset.

Keywords: Brain-computer interface; magnetoencephalography; learning vector quantization; classification

1. Giriş

Beyin-bilgisayar arayüzü zihinsel aktivite ile gerçekleştirilen makine haberleşmesidir. Dolayısıyla bu sistemler için en temel seviye, beyin sinyallerinin kaydedilmesidir (Bascil ve ark. 2014). Zihinsel aktivitenin tespitinde kullanılan yöntemlerden birisi de MEG gibi invazif olmayan ve nöronal aktivite tarafından üretilen küçük manyetik alanların çoklu ölçümlerini her milisaniyede gerçekleştiren fonksiyonel görüntüleme tekniğidir (Olivetti ve ark. 2014).

İnsan beyni mükemmel bir görsel sistematiğe sahiptir ve bu yapının nasıl çalıştığını anlamak nörobilim araştırmaları açısından oldukça önemlidir. Beyin, milisaniyeler mertebesinde görsel algılama hızına sahiptir (Hamalainen ve ark. 1993; Cecotti 2016; Abadi ve ark. 2015; Olivetti ve ark. 2014; Bradberry ve ark. 2009). Bireye bir uyaran gösterildiğinde, uyaran ve beyinde oluşan sinyal arasındaki ilişki, beyin aktivitesi hakkında bilgi sağlayabilir. MEG sinyalleri kullanılarak, eş zamanlı beyin aktivitesinden bireye sunulan uyarının tahmin edilmesine “beyin okuma” adı verilmektedir (Kamitani ve Tong 2005; Kay ve ark. 2008; Wang ve ark. 2009).

İdealde, bir sınıflandırıcıyı eğitmek ve sınıflandırıcı doğruluğunu ağa önceden sunulmayan veriler ile test etmek anlamlı bir işlemdir (Olivetti ve ark. 2014). Fakat MEG sinyalleri söz konusu olduğunda, çevresel değişkenlerin ve beynin fonksiyonel farklılıklarının yanı sıra MEG sinyallerinin karmaşıklığı süreci zorlaştırmaktadır. Bu sebeple, kullanılacak sınıflandırıcının performansı sadece iyi bir sınıflandırma algoritmasına değil, aynı zamanda iyi bir öznitelik çıkarım yöntemine de bağlıdır (Caliskan ve ark. 2017). Çok kanallı beyin sinyalleri için çeşitli öznitelik çıkarım yöntemleri (Caliskan ve ark. 2017; Raudonis ve ark. 2008; Ursulean ve Lazar 2009; Barachant ve ark. 2012) kullanılmış olsa da Riemannian yaklaşımı da rekabetçi özelliğiyle öne çıkmaktadır (Barachant ve ark. 2012; Yger ve ark. 2016). MEG sinyalleri kullanılarak gerçekleştirilen beyin okuma çalışmaları sınırlı sayıda olup makine öğrenme algoritmaları sayesinde büyük ve karmaşık MEG verilerinden beyin okuma teknikleri geliştirilmiştir (Chan ve ark. 2011; Daliri 2014; Abadi ve ark. 2015; Kia ve ark. 2017; Redcay ve Carlson 2015; Huttunen ve ark. 2011; Kia ve ark. 2017).

Yapay sinir ağları (YSA), insan beyninden esinlenen ve sınıflandırma çalışmalarında sıklıkla kullanılan analog bilgisayar sistemleridir (Gulbag ve Temurtas 2006). Sinyal modellerinin sınıflandırılması, en yaygın YSA uygulamalarından biridir (Kohonen 1990). Öğrenmeli Vektör Kuantalama (LVQ-Learning Vector Quantization) da bilinmeyen verilerin benzerliğine dayalı sınıflandırma yapan bir ağ yapısıdır (Temurtas 2009).

Bu çalışmada, LVQ ile beyin bilgisayar arayüzü (BCI) için MEG sinyalleri sınıflandırılmıştır. Bu amaçla, Henson ve arkadaşları tarafından sunulan MEG veri setinden faydalanılmıştır (Henson ve ark. 2011). Öncelikle karmaşık ve çok kanallı MEG sinyali gürültüden arındırılmıştır. Daha sonra öznitelik çıkarım işlemi gerçekleştirilmiş, Riemannian yaklaşımı (Barachant ve ark. 2012; Yger ve ark. 2016) kullanılarak MEG sinyallerinin boyutu azaltılmıştır. 10 katlı çapraz doğrulama LVQ ağının doğruluğunu hesaplamak için kullanılmıştır (Cetin ve ark. 2015). Elde edilen sonuçlar, aynı MEG veri setini kullanan önceki yöntemler ile kıyaslanmıştır.

2. Veri Seti

Henson ve arkadaşları tarafından sunulan Manyetoensefalografi (MEG) veri seti (Henson ve ark. 2011), “Dec2Meg2014” yarışması kapsamında yeniden düzenlenmiştir. 9’u kız, 7’si erkek toplam 16 bireye sıradan kişilerin yüzleri, ünlü kişilerin yüzleri ve bu resimlerin anlamsız halleri olmak üzere 3 farklı uyaran gösterilmiş ve 306 kanaldan MEG sinyalleri kaydedilmiştir. Bu çalışmada, MEG veri seti Olivetti ve arkadaşlarının normal yüz ve anlamsız yüz olmak üzere yeniden düzenledikleri şekliyle kullanılmıştır (Olivetti ve ark. 2014; DecMeg2014-Decoding the Human Brain 2018).

Her bir bireye rastgele ve seri şekilde, yüz ya da anlamsız yüzden oluşan yaklaşık 588 resim 1 saniye boyunca gösterilmiş ve bireyler her bir resimden sonra 0,5 saniye dinlendirilmiştir. 16 bireye toplamda 9414 resim gösterilmiştir (DecMeg2014-Decoding the Human Brain 2018).

3. Metot

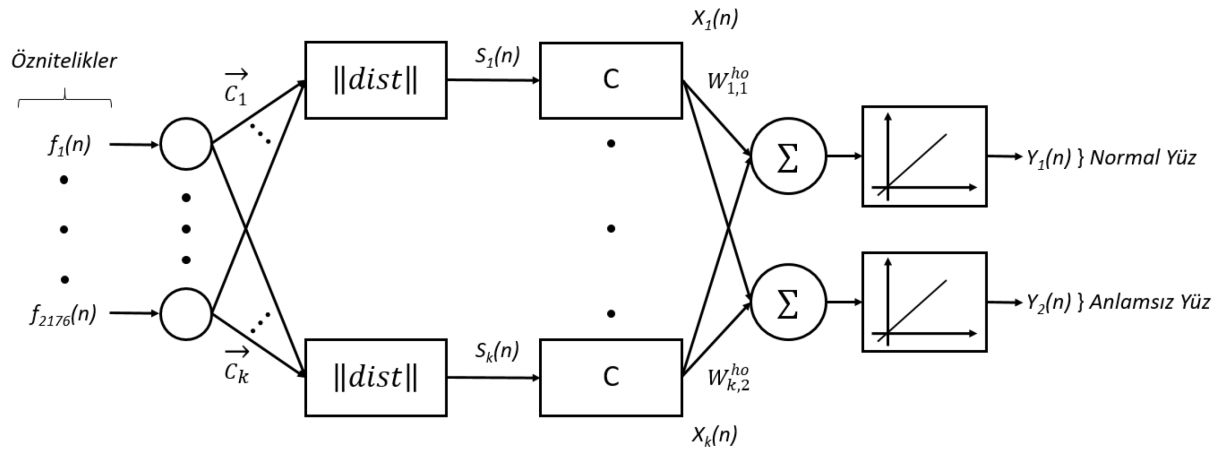
3.1. Öğrenmeli Vektör Kuantalama (LVQ) ile MEG Sinyallerinin Sınıflandırılması

LVQ ağına veriler sunulmadan önce gürültü içeren MEG sinyallerinin örnekleme frekansı 250 Hz’e düşürülmüş ve bant geçiren filtre yardımıyla gürültüden arındırılmıştır (Olivetti ve ark. 2014). Filtreleme işlemi için 10. Dereceden Butterworth 1-20 Hz bant geçiren filtre kullanılmıştır.

Sınıflandırma işleminin sağlıklı bir şekilde gerçekleştirilmesinde öznitelik çıkarma işleminin önemi büyüktür. Birçok kanaldan alınan MEG sinyalleri için hangi kanalların kritik bilgi içerdiğinin belirlenmesi önemlidir (Caliskan 2017). Öznitelikler çıkarılırken öncelikle 306 olan kanal sayısı konumsal filtreleme ile 8'e düşürülmüştür. Daha sonra bu kanallardan alınan sinyallerden ele edilen kovaryans matrislerinin arasındaki Riemannian mesafesi (Moakher 2005; Barachant 2018) hesaplanarak öznitelikler elde edilmiştir (Pennec ve ark. 2006).

Sınıflandırma problemleri için Kohonen tarafından ortaya atılan LVQ, Kendiliğinden Organize Olan Harita (SOM - Self Organizing Maps) ağlarının bir çeşididir (Kohonen 1990). Temel felsefesi, vektörel girişleri "referans vektör" adı verilen ve elde hazır bulunan vektör seti ile ifade etmek olan LVQ modeli geliştirilirken "kazanan her şeyi alır" (WTA - Winner Takes All) ilkesinden yola çıkılmıştır.

LVQ ağı, giriş katmanı, Kohonen katmanı ve çıkış katmanı olmak üzere üç katmandan oluşur (Er ve ark. 2010). Giriş katmanının görevi verileri ağa sunmaktır. Kohonen katmanı referans vektörlerin bulunduğu katmandır ve gelen verileri komşuluk durumuna göre yarıştırmır. En yakın nöronun sınıf bilgisi ise çıkış katmanında bulunmaktadır. LVQ ağ yapısı Şekil 1'de gösterilmektedir.



Şekil 1. LVQ ağ yapısı

LVQ, destekleyici öğrenme türünden ağ yapısı olup sisteme sadece girişler verilir. Her bir giriş ile tüm referans vektörler arasındaki uzaklık, Denklem 1 ile verilen "öklid bağıntısı" kullanılarak hesaplanır;

$$d = \sqrt{\sum_j (R_{ij} - x_j)^2} \quad (1)$$

Burada; d , giriş vektörü x ile referans vektörü R arasındaki mesafedir. j , girdi vektörünün j . değeridir.

Öğrenme aşamasında referans vektörlerin ağırlıkları güncellenerek giriş vektörüne en yakın referans vektörü belirlenmeye çalışılır. Kazanan her şeyi alır ilkesine göre çalışan LVQ ağının çıkışında yalnız bir kazanan vardır ve çıkışlarından sadece biri "1" değerini alırken diğer çıkışlar "0" olur (Kohonen ve ark. 1988; Alkım ve ark. 2012). Eğer sınıflandırma başarılı ise kazanan vektör doğru sınıftadır ve referans vektör giriş vektörüne Denklem 2'ye göre yakınlaştırılır. Böylece aynı girişin ağa sunulması durumunda kazanma ihtimali artırılmış olur. Sınıflandırma işlemi başarısız ise kazanan vektör yanlış sınıftadır ve referans vektör giriş vektöründen Denklem 3'e göre uzaklaştırılır. Bu sayede aynı giriş ağa sunulduğunda kazanma ihtimali azaltılmış olur (Kohonen ve ark. 1988; Alkım ve ark. 2012).

$$R_{yi} = R_{ei} + \lambda(R_{ei} - x_i) \quad (2)$$

$$R_{yj} = R_{ej} - \lambda(R_{ej} - x_j) \quad (3)$$

Burada x_i i. giriş vektörünü, λ öğrenme katsayısını ve R_{yi} ile R_{ei} ise sırasıyla i. referans vektörünün yeni ve eski değerini ifade etmektedir.

Öğrenme katsayısı, LVQ ağının öğrenmesini etkileyen önemli bir katsayıdır. Öğrenme katsayısı çok küçük seçilirse öğrenme için gereken iterasyon sayısının artması söz konusudur. Öğrenme katsayısının çok büyük seçilmesi durumunda ise genel en iyi sonucun atlanması ve yerel en iyi sonucun seçilmesi söz konusudur. İyi bir şekilde seçilmesi gereken bu parametre genellikle deneme yanılma yoluyla belirlenmektedir.

Ağ performansını etkileyen bir diğer faktör de gizli katman nöron sayısıdır. Bu çalışmada Intel(R) Core(TM) i5-6500 3.20 GHz işlemci ve 12 GB RAM kombinasyonuna sahip bilgisayar kullanılmıştır. LVQ ağının yoğun işlem gerektiren öğrenme yapısından dolayı gizli katman nöron sayısı 110 ile sınırlandırılmıştır.

3.2. Performans Değerlendirmesi

3.2.1. Sınıflandırma Doğruluğu

Performans değerlendirme ölçütleri, sistem performansını değerlendirmek için önemli parametrelerdir. Bu çalışmada, Denklem 4, Denklem 5 ve Denklem 6 ile verilen sınıflandırma doğruluğu ile birlikte spesifite ve duyarlılık değerlendirme ölçütleri de kullanılmıştır (Bascil ve ark. 2012; Gorur ve ark. 2018).

$$\text{Doğruluk } (N) = \frac{\sum_{i=1}^{|N|} \text{Tahmin}(n_i)}{|N|}, n_i \in N \quad (4)$$

$$\text{Tahmin}(n) = \begin{cases} 1, & \text{Eğer Tahmin}(n) = nc \\ 0, & \text{aksi halde} \end{cases} \quad (5)$$

$$\text{Sınıflandırma Doğruluğu } (Alg) = \frac{\sum_{i=1}^{|k|} \text{Doğruluk } (N_i)}{|k|} \quad (6)$$

Burada; N , sınıflandırılan (test) veri setini, nc , n değerinin sınıfını, $\text{Tahmin}(n)$, n 'nin sınıflandırma sonucunu ve k değeri de k -kat çapraz doğrulama parametresini temsil etmektedir. Spesifite Denklem 7'de ve duyarlılık Denklem 8'de gösterildiği gibi hesaplanmaktadır;

$$\text{Spesifite} = \frac{TN}{TN+FP} \quad (7)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (8)$$

Burada;

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

3.2.2. K-katlı Çapraz Doğrulama

Uygulanan yöntemin başarısının sınanması için veri kümesi eğitim ve test kümeleri olarak ayrılmaktadır. Çalışma içerisinde LVQ ağının doğruluğu hesaplanırken K-katlı çapraz doğrulama (K-fold cross validation) tekniği kullanılmıştır. Öncelikle veri setinin, eşit büyüklükte kaç alt kümeye bölüneceğini belirten k parametresinin belirlenmesi gerekmektedir. Veri seti sınıflara ayrıldıktan sonra sınıflandırma algoritması k -kez eğitilir ve test edilir. Her defasında kümelere biri test işlemi için ayrılmakta ve geriye kalan $k-1$ küme sınıflandırıcının eğitimi için kullanılmaktadır. Böylece, k adım sonunda k -farklı test sonucu elde edilir (Delen ve ark. 2005; Bascil ve Oztekin 2012). Bu sonuçların ortalaması alınarak genel sınıflandırma sonucu elde edilmektedir. Bu çalışmada LVQ ağının doğruluğunu hesaplamak amacıyla 10-katlı çapraz doğrulama tekniği kullanılmıştır.

4.Sonuçlar

Bu çalışmada, MEG tabanlı beyin bilgisayar arayüzü için 16 bireye ait veriler kullanılmıştır. 2176 özneliğe sahip 9414 uyaran eğitim amacıyla rastgele ağa sunulmuştur. Sınıflandırma işlemi LVQ ağı kullanılarak gerçekleştirilen uygulamada amaç, MEG sinyalinin “normal yüz” ya da “anlamsız yüz” sınıflarından hangisine ait olduğunun belirlenmesidir.

Sınıflandırıcı doğruluğunun sınanmasında 10-kat çapraz doğrulama tekniği kullanılmıştır. Öncelikle veri seti 10 eşit parçaya (kat) bölünmüş, her defasında parçalardan biri test işlemine ayrılıp geriye kalan 9 parça ağın eğitimi için kullanılmıştır. Böylece LVQ ağı toplamda 10 kere eğitilip test edilmiştir. Sınıflandırma doğruluğu, bu 10 parçanın doğruluklarının ortalaması alınarak hesaplanmıştır. Her bir parça için hesaplanan duyarlılık, spesifite ve doğruluk ile bu parametrelere ait ortalama başarımlar Tablo 1’de yer almaktadır.

Tablo 1 10-kat çapraz doğrulama için başarımlar oranları

	Spesifite (%)	Duyarlılık (%)	Doğruluk (%)
Kat 1	66.88	73.74	70.31
Kat 2	72.77	72.19	72.48
Kat 3	73.25	64.26	68.76
Kat 4	63.91	73.32	68.62
Kat 5	64.76	74.26	69.51
Kat 6	65.13	73.65	69.39
Kat 7	67.81	67.93	67.87
Kat 8	71.06	65.96	68.51
Kat 9	70.89	67.33	69.11
Kat 10	70.84	67.92	69.38
ORTALAMA	68.73	70.05	69.39

Tablo 1’den yola çıkılarak, katlar arası veri dağılımının birbirini dışlayan yapıda rastgele gerçekleştiği ve böylece katlar arası doğruluğun birbirine yakın olduğu gözlenmektedir. Ortalama spesifite, ortalama duyarlılık ve ortalama sınıflandırma doğruluğu sırasıyla %68.73, %70.05 ve %69.39 olarak elde edilmiştir.

Aynı MEG verisini kullanan yöntemler ve bu çalışma tarafından elde edilen sınıflandırma doğrulukları Tablo 2’de yer almaktadır.

Tablo 2 MEG verisi için kullanan yöntemler ve erişilen sınıflandırma doğrulukları

Çalışmalar	Uygulanan Yöntemler	Sınıflandırma Doğrulukları (%)
Abdullah Çalışkan ve ark. (2017)	DNN	80.85
	SVM	78.01
	KNN	72.84
	NB	71.92
	DT	68.36
Bu çalışma	LVQ	69.39

Tablo 2’den de görüldüğü gibi Abdullah Çalışkan ve arkadaşları kullandıkları algoritmalarda %68.36 ile %80.85 arasında değişen sınıflandırma doğrulukları elde etmişlerdir (Çalışkan ve ark. 2017). En iyi performansı Derin Sinir Ağı (DNN) gösterirken en düşük performansı Karar Ağacı (DT) yapısı göstermiştir. Bu çalışma ise en iyi sonucu göstermese de LVQ ağının performans açısından %69.39 ile karar ağacı yapısından daha iyi olduğu ve Naive Bayes (NB) yapısına yakın sonuç verdiği görülmektedir.

Sonuç olarak, LVQ ağının yoğun işlem gerektiren yapısı sebebiyle gizli katman nöron sayısı 110 ile sınırlandırılmıştır. Gizli katman nöron sayısının artması durumunda LVQ ağının iyileştirme potansiyeli bulunmaktadır. MEG kayıtlarından nöronal aktivitenin çözülmesinde, teknolojinin imkân tanıdığı ölçüde daha gelişmiş donanım kullanılması durumunda performansın daha da iyileştirilebileceği düşünülmektedir.

Referanslar

- Abadi M. K., Subramanian R., Kia S. M., Avesani P., Patras I., Sebe N. (2015). “DECAF: MEG-based multimodal database for decoding affective physiological responses”, *IEEE Trans. Affective Computing*, 6(3), 209–222.
- Alkım E., Gürbüz E., Kılıç E. (2012). “A fast and adaptive automated disease diagnosis method with an innovative neural network model”, *Neural Networks*, 33, 88–96.
- Barachant A. “Covariance toolbox”. <https://github.com/alexandrebarachant/covariancetoolbox> [Accessed: 05.05.2018]
- Barachant A., Bonnet S., Congedo M., Jutten C. (2012). “Multiclass brain–computer interface classification by Riemannian geometry”, *IEEE Trans. Biomedical Engineering*, 59(4), 920–928.
- Bascil M. S., Cetin O., Er O., Temurtas F. (2012). “Olasılıksal Sinir Ağının(PNN) Parkinson Hastalığının Teşhisinde Kullanılması” *Electronic Letters on Science&Engineering*, 8(1), 1–10.
- Bascil M. S., Oztekin H. (2012). “A Study on Hepatitis Disease Diagnosis Using Probabilistic Neural Network”, *Journal of Medical Systems*, 36(3), 1603–1606.
- Bascil M. S., Tesneli A. Y., Temurtas F. (2014). “A study on Analog and Digital EEG Signal Filtering for Brain Computer Interfaces (BCI)”, *Electronic Letters on Science&Engineering*, 10(1), 1–10.
- Bradberry T. J., Rong F., Contreras-Vidal J. L. (2009). “Decoding center-out hand velocity from MEG signals during visuomotor adaptation”, *Neuroimage*, 47(4), 1691–1700.
- Caliskan A. (2017). “Derin sinir ağının sınıflandırma başarımının artırılması için yeni bir eğitim stratejisi geliştirilmesi ve biyomedikal veri setleri üzerinde test edilmesi”, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Biyomedikal Mühendisliği Anabilim Dalı, Doktora Tezi.*
- Caliskan A., Yuksel M. E., Badem H., Basturk A. (2017). “A Deep Neural Network Classifier for Decoding Human Brain Activity Based on Magnetoencephalography” *Elektronika ir Elektrotehnika*, 23(2), 63–67
- Cecotti H. (2016). “Single-trial detection with magnetoencephalography during a dual-rapid serial visual presentation task”, *IEEE Trans. Biomedical Engineering*, 63(1), 220–227.
- Cetin O., Temurtas F., Gulgonul S. (2015). “An application of multilayer neural network on hepatitis disease diagnosis using approximations of sigmoid activation function” *Dicle Medical Journal*, 42(2), 150–157.
- Chan A. M., Halgren E., Marinkovic K., Cash S. S. (2011). “Decoding word and category-specific spatiotemporal representations from MED and EEG”, *NeuroImage*, 54(4), 3028–3039.
- Daliri M. R. (2014). “A hybrid method for the decoding of spatial attention using the MEG brain signals”, *Biomedical Signal Processing and Control*, 10, 308–312.
- “DecMeg2014-Decoding the Human Brain”. <https://www.kaggle.com/c/decoding-the-human-brain> [Accessed: 05.05.2018]
- Delen D., Walker G., Kadam A. (2005). “Predicting breast cancer survivability: A comparison of three data mining methods”, *Artificial Intelligence in Medicine*, 34(2), 113–127.
- Er O., Yumusak N., Temurtas F. (2010). “Chest diseases diagnosis using artificial neural networks” *Expert Systems with Applications*, 37(12), 7648–7655.
- Gorur K., Bozkurt M. R., Bascil M. S., Temurtas F. (2018). “Glossokinetic potential based tongue-machine interface for 1-D extraction”, *Australas Phys Eng Sci Med*. doi: 10.1007/s13246-018-0635-x.
- Gulbag A., Temurtas F. (2006). “A study on quantitative classification of binary gas mixture using neural networks and adaptive neuro-fuzzy inference systems”, *Sensors and Actuators B*, 115(1), 252–262.
- Hamalainen M., Hari R., Ilmoniemi R. J., Knuutila J., Lounasmaa O. V. (1993). “Magnetoencephalography theory, instrumentation, and applications to noninvasive studies of the

- working human brain”, *Reviews of Modern Physics*, 65(2), 413–497.
- Henson R. N., Wakeman D. G., Litvak V., Friston K. J. (2011). “A parametric empirical Bayesian framework for the EEG/MEG inverse problem: generative models for multi-subject and multi-modal integration”, *Frontiers in Human Neuroscience*, 5, p. 76.
- Huttunen H., Kauppi J. P., Tohka J. (2011). “Regularized logistic regression for mind reading with parallel validation”, 20–24, Aalto-Yliopisto.
- Kamitani Y., Tong F. (2005). “Decoding the visual and subjective contents of the human brain”, *Nature Neuroscience*, 8(5), 679–685.
- Kay K. N., Naselaris T., Prenger R. J., Gallant J. L. (2008). “Identifying natural images from human brain activity”, *Nature*, 452(7185), 352–355.
- Kia S. M., Pedregosa F., Blumenthal A., Passerini A. (2017). “Group-level spatio-temporal pattern recovery in MEG decoding using multi-task joint feature learning”, *Journal of Neuroscience Methods*, 285, 97–108.
- Kia S. M., Vega Pons S., Weisz N., Passerini A. (2017). “Interpretability of Multivariate Brain Maps in Linear Brain Decoding: Definition, and Heuristic Quantification in Multivariate Analysis of MEG Time-Locked Effects” *Frontiers in Neuroscience*, 10, 619, doi: 10.3389/fnins.2016.00619
- Kohonen T. (1990). “Improved versions of learning vector quantization”, In *Proceedings of the IEEE international joint conference on neural networks*, pp. 545–550, New York.
- Kohonen, T. (1990). “The self-organising map”, In *Proceedings of the IEEE*, 78(9), 1464–1480.
- Kohonen T., Bama G., Chrisley R. (1988). “Statistical pattern recognition with neural networks benchmarking studies”, in *Proceeding of the International Joint Conference on Neural Networks*, 1, SanDiago, California, 61–68.
- Moakher M. (2005). “A differential geometric approach to the geometric mean of symmetric positive-definite matrices”, *SIAM Journal on Matrix Analysis and Applications*, 26(3), 735–747.
- Olivetti E., Kia S. M., Avesani P. (2014). “MEG decoding across subjects”, in *Proc. Int. Workshop on Pattern Recognition in Neuroimaging*, Tubingen, doi: 10.1109/PRNI.2014.6858538
- Pennec X., Fillard P., Ayache N. (2006). “A Riemannian framework for tensor computing”, *International Journal of Computer Vision*, 66(1), 41–66.
- Raudonis V., Narvydas G., Simutis R. (2008). “A classification of flash evoked potentials based on artificial neural network”, *Elektronika ir Elektrotechnika*, 81(1), 31–36.
- Redcay E., Carlson T. A. (2015). “Rapid neural discrimination of communicative gestures”, *Social Cognitive and Affective Neuroscience*, 10(4), 545–551.
- Temurtas F. (2009). “A comparative study on thyroid disease diagnosis using neural networks”, *Expert Systems with Applications*, 36(1), 944–949.
- Ursulean R., Lazar A. M. (2009). “Detrended cross-correlation analysis of biometric signals used in a new authentication method”, *Elektronika ir Elektrotechnika*, 89(1), 55–58.
- Wang J., Pohlmeier E., Hanna B., Jiang Y. G., Sajda P., Chang S. F. (2009). “Brain state decoding for rapid image retrieval”, in *Proc. 17th ACM Int. Conf. Multimedia*, 945–954.
- Yger F., Berar M., Lotte F. (2017). “Riemannian approaches in brain computer interfaces: a review”, *IEEE Trans. Neural Systems and Rehabilitation Engineering*, 25(10), 1753–1762.