

Classification of Mental Arithmetic-Based Task Discrimination from Electroencephalography Signals

Merve KOÇYİĞİT^{1*}, Ayşegül GÜVEN¹, Furkan ÇAM¹

¹Erciyes Üniversitesi, Biyomedikal Mühendisliği, Kayseri/TURKEY

Abstract: In this article, mental arithmetic classification of electroencephalography (EEG) signal which is widely used in Brain Computer Interface applications is studied. In order to evaluate the specificity of EEG signals, the EEG signal was split into alpha, beta, delta, theta and gamma subbands using a 6-degree discrete wavelet transform. Then, for each EEG subband, Mean Energy, Standard Deviation, Variance and kurtosis based feature vectors were extracted. The resulting feature vectors were classified by J48 classification algorithm and 98.2% classification accuracy was calculated.

Keywords: Electroencephalography; Brain Computer Interface; Mental Arithmetic Task; J48 Algorithm

Elektroensefalografi Sinyallerinden Zihinsel Aritmetik Tabanlı Görev Ayırımı Sınıflandırması

Özet: Bu makalede, Beyin Bilgisayar Arayüzü uygulamalarında yaygın olarak kullanılan Elektroensefalografi (EEG) sinyalinin zihinsel aritmetik görev ayırımı sınıflandırması üzerine çalışılmıştır. EEG sinyallerinin özelliklerini değerlendirmek üzere, 6. dereceden ayrık dalgacık dönüşümü kullanılarak EEG sinyali alfa, beta, delta, teta ve gama alt bantlarına ayrıştırılmıştır. Daha sonra, her bir EEG alt bandı için Ortalama Enerji, Standart Sapma, Varyans ve Basıklık tabanlı öznelik vektörleri çıkarılmıştır. Ortaya çıkan öznelik vektörleri J48 sınıflandırma algoritması ile sınıflandırılarak %98.2 sınıflandırma doğruluğu hesaplanmıştır.

Anahtar Kelimeler: Elektroensefalografi; Beyin Bilgisayar Arayüzü; Zihinsel Aritmetik Görev; J48 Algoritması

Reference to this paper should be made as follows (bu makaleye aşağıdaki şekilde atıfta bulunulmalı):

M. Koçyiğit, A. Güven, F. Çam, 'Classification of Mental Arithmetic-Based Task Discrimination from Electroencephalography Signals', Elec Lett Sci Eng, vol. 15(3), (2019), 57-65

1.Giriş

Beyin, insanın kabiliyetini ve yetisini ortaya koyan vücudun komuta merkezi olarak adlandırılabilir önemli bir organdır. Bu organ milyarlarca nöron (sinir hücresi) ihtiva etmektedir. Nöronlar ana bileşen olarak dentrit, akson ve hücre gövdesinden oluşmaktadır. Nöronların kas hücresi, salgı bezi veya bir başka nöron hücresi ile mesaj iletilmesine imkan sağlayan arada özel sinaps yapıları bulunmaktadır. Beyindeki sinapstik yapılar vasıtasıyla kimyasal ve elektriksel aktivite oluşmaktadır [1].

Sinir sisteminde, insanın motor kabiliyetini sınırlayan rahatsızlıklar oluşabilmektedir. Bu rahatsızlıklara; Amiyotrofik lateral skleroz, beyin kökü tramvası, kas distrofisi ve multipl skleroz örnek olarak verilebilir. Bu durumda beyinden gelen sinyaller ilgili uzuvlar tarafından yorumlanamamakta ve cevap oluşturulamamaktadır. Beyin Bilgisayar Arayüzü (Brain Computer Interface-BCI) sistemi kişinin bu faaliyetlerini yerine getirebilmesinde kolaylık sağlamak adına gelişen bir teknolojidir. BCI uygulamaları beyinden almış oldukları sinyaller ile beyinle ilgili mekanik yapıyı, bir bilgisayarı veya mekanik bir uzuvun kontrolünü sağlayabilmektedir. BCI sistemleri bu arayüzler sayesinde beyin işaretlerini yorumlayıp harici cihazlarda kullanımı sağlanabilecek kontrol komutu haline getirebilmektedir [2].

Corresponding author; Tel. :+903522076666 Dahilli: 32979,mervekocuyigit38@hotmail.com

ISSN 1305-8614 © 2019 dergipark.org.tr/else All rights reserved.

BCI sistemlerinde, elektriksel sinyalin alınması invaziv ve non-invaziv uygulama olmak üzere iki farklı şekilde gerçekleşmektedir. İnvazif uygulamalarda kafatası açılarak elektrotlar beyin üzerinde yerleştirilir, non-invasiz yöntemde ise elektrotlar iletken bir jel ile kafatasında ilgili bölgeye tutturulur. İnvaziv uygulamaya Elektrokortikogram ve non-invaziv uygulamaya da Elektroensefolografi (EEG), Yakın kızılötesi spektroskopisi, Pozitron emisyon tomografi, Fonksiyonel manyetik rezonans gibi yapılar örnek verilebilir [3,4].

BCI sistemlerinde, non-invaziv uygulamalar invaziv uygulamalara göre daha çok tercih edilmektedir. Bunun sebebi invaziv uygulamaların kafatasının açılması gibi insanı ruhsal ve bedensel olarak etkileyecek operasyon içermesinden dolayıdır. Diğer taraftan BCI uygulamalarında non-invaziv uygulamalar içerisinde en çok tercih edilen çalışma EEG üzerinedir. Çünkü EEG diğerlerine nazaran daha ekonomik, erişimi kolay, taşınabilir ve yüksek zamansal çözünürlüğe sahiptir. Fakat elektrotların yerleştirilmesinde yaşanan sıkıntı ve bunun yanında uzaysal çözünürlüğünün düşük olması EEG için dezavantaj oluşturmaktadır. Buna rağmen BCI sistemlerinde en sık kullanım ve yüksek başarımlar elde etmede öncüdür [4,5].

EEG, beyin aktivitesi sonucu oluşan beyindeki elektriksel potansiyeli kaydetmek bununla birlikte beyindeki sinirsel işlem etkinliklerini, beyindeki bozuklukları ve bilişsel süreci test etmek için yaygın olarak kullanılan bir beyin görüntüleme tekniğidir [6]. EEG analizi, kafa derisine yerleştirilen elektrotlar vasıtasıyla alınan elektriksel potansiyeller ile olmaktadır. Bu yüzden elektrotlar EEG çekimi esnasında kafa yüzeyine ilgili olan bölgeye dikkatlice yerleştirilmelidir. En yaygın olarak kullanılan elektrot yerleştirme uygulamaları; 10-5, 10-10 ve 10-20 dir. Bu çalışmada ise Shin ve arkadaşları tarafından 10-5 EEG elektrot sistemine göre oluşturulan veri üzerinde çalışılmıştır [7].

EEG karmaşık ve incelenmesi zor bir işarettir. Bu sebeple genel olarak delta (0-4 Hz), teta (4-8 Hz), alfa (8-12 Hz), beta (13-25 Hz) ve gama (>25 Hz) olarak beş EEG alt bandına ayrıştırılır [3]. Bu alt bantlar düşük frekans aralığını ihtiva eder ve daha yüksek frekans aralığı genellikle gürültü olarak adlandırılır. Bundan dolayı alt bantlar EEG'nin içerdiği kurucu nöronal faaliyetler hakkında daha doğru bilgi verebilir. Böylelikle tam spektrumlu EEG'de belirgin olmayan bazı değişiklikler EEG'nin alt bantlara ayrıştırılması ve alt bantların her biri için gerekli analizlerin yapılması ile daha geniş doğruluğa götürebilir [8,9].

Literatürde EEG tabanlı sınıflandırma doğruluğunu (SD) artırmak için farklı yöntem adımları uygulanmış birçok BCI çalışması vardır.

Shin ve arkadaşları, kayıt ettikleri ve açık erişime sundukları [7] numaralı referanstaki veri kümesini kullanarak EEG kaydından Zihinsel Aritmetik (ZA) ve Temel Durum (TD) işaretlerini ayırmak için sınıflandırma yapmışlardır. Çalışmalarında kullandıkları EEG sinyaline taban çizgisi sinyal analiz metodu uygulamışlar ve ortak uzamsal örüntü ile uzamsal filtre belirlemişler. Ardından kişiye özgü bant geçiren filtre katayısının tahminini yapabilen bir metot ile birlikte 10x5 kat çapraz doğruama metodunu kullanmışlar. Daha sonra, doğrusal ayırım analizi sınıflandırma algoritması ile % 75.90 SD elde etmişlerdir [13].

EEG işaretinden ZA ayırımı sınıflandırma çalışmalarından biri Yavuz ve Aydemir'in çalışmasıdır. Bu çalışmada, [7] numaralı referanstaki veri kümesini kullanmışlardır. EEG tabanlı bu veri işaretinden öncelikle ZA'yı ayırabilmek için entropi, çarpıklık ve entropi + çarpıklık özniteliklerini çıkarmışlardır. Daha sonra bu öznitelikleri Destek Vektör makinaları (DVM) ile sınıflandırmışlardır. Sonuç olarak EEG işaretindeki ZA ayırımını en iyi belirleyen özniteliğin entropi olduğunu ve ortalama % 85.69 SD elde ettiklerini belirtmişlerdir [10].

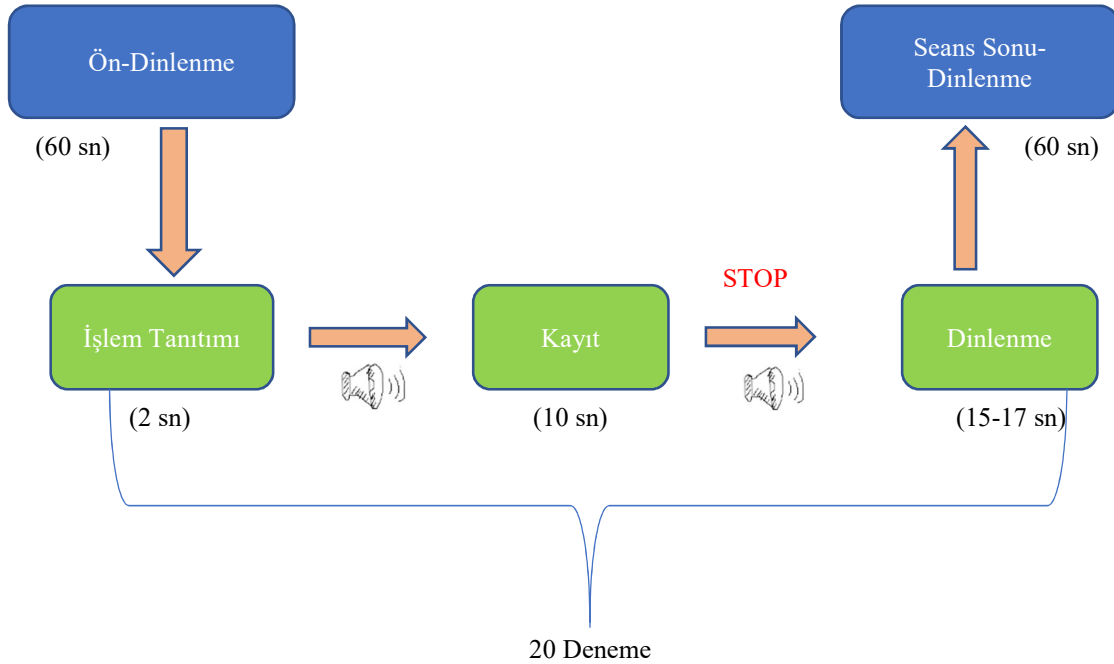
Wang ve Sourina çalışmalarında, EEG sinyalinden ZA görev sınıflandırması için öncelikle istatistiksel özellikler, otoregresif model (AR), Higuchi Fraktal boyut spektrumu (GHFDS) ve Güç spektrumu yoğunluğu (PSD) özelliklerini çıkarmışlardır. Ardından sınıflandırma için DVM sınıflandırma algoritmasını uygulamışlardır. En yüksek SD'yi 14 kanal için dört özelliği de kullanarak %97.87 olarak hesaplamışlardır [11]. Palaniappan çalışmasında, EEG kaydındaki ZA ile TD birbirinden ayırmak için öncelikle eliptik filtreler kullanarak alfa, beta, teta, delta ve gama alt bantlarını çıkarmışlardır. Ardından her banttan spektral güç ve spektral güç farkı özelliğine ulaşmışlardır. Daha sonra bu özelliklere Çok Katlı Perceptron (MLP-BP) sınıflandırma uygulamışlar ve %97.5'e kadar SD'nin mümkün olduğunu belirtmişlerdir [12].

Bu çalışmada temel amaç farklı önışlem, öznitelik ve sınıflandırma metodu kullanımı deneyerek EEG sinyalinden ZA ayrımı sınıflandırılmasındaki SD yüzdesi performansını artırmaya çalışmaktır.

2. Materyal ve Metot

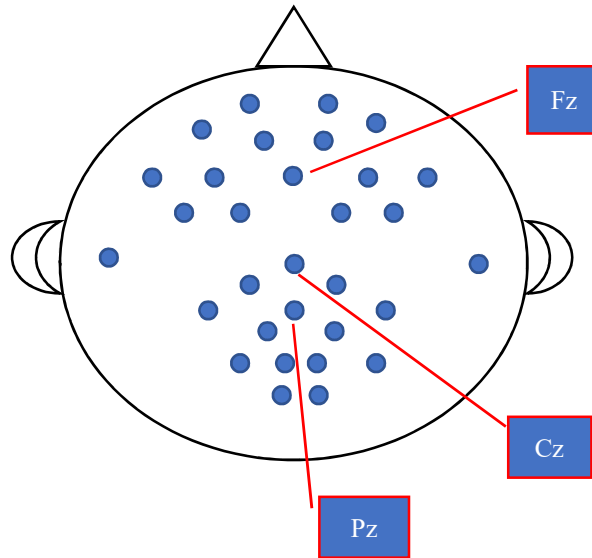
2.1. Veri Seti

Bu çalışmadaki veri seti, 16'sı kız 13'ü erkek toplam 29 sağlıklı ve gönüllü bireye zihinsel aritmetik aktivite 'üç basamaklı sayı eksi bir basamaklı sayı' ve temel görev olacak şekilde EEG sinyali kaydı ile oluşturulmuştur. Shin ve arkadaşları tarafından kaydedilen bu veri seti [7] nolu referansta belirtildiği gibi açık erişime sunulmuştur. Kayıt sırasında uygulanan deney aşaması Şekil 1.'deki kayıt şemasına göre yapılmıştır.



Şekil 1. Deney Kayıt Şeması

Deney 3 seanstan oluşmaktadır. Her bir seans adımı 60 saniyelik (sn) ön bir dinlenme ile başlamakta sonrasında ekranda 2sn'lik görsel işlem tanıtımının ardından kayıt basamağına kısa bir bip sesi ile geçilmektedir. Yirmi deneme tekrarın yapıldığı 10 sn'lik kayıtlar ile zihinsel aritmetik ve temel durum tabanlı işlem basamağı gerçekleştirilmiştir. Bu yirmi denemenin 10 tanesi zihinsel aktivite (üç basamaklı sayı eksi bir basamaklı sayı) geriye kalan 10 tanesi de temel durum (hiç düşünmeden dinlenerek) kısmından oluşmaktadır. Daha sonra 1 sn'lik dur anlamına gelen stop uyarısı ile 15-17 sn'lik dinlenmenin ardından seans sonu 60 sn dinlenme ile bir seans aşaması tamamlanmıştır. 3 seans sonunda 60 deneme (20 deneme x 3 seans) kayıt alınmıştır. Her bir denemenin 2000 örnek içerdiği 200 Hz'lik alt örnekleme frekansına sahip olan EEG verileri 1000 Hz örnekleme frekansı adı altında otuz aktif elektrotlu çok kanallı BrainAmp EEG amplifikatörü tarafından kaydedilmiştir. Otuz adet EEG elektrotu, uluslararası 10-5 sistemine göre (AFp1, AFp2, AFF1h, AFF2h, AFF5h, AFF6h, F3, F4, F7, F8, FCC3h, FCC4h, FCC5h, FCC6h, T7, T8, Cz, CCP3h, CCP4h, CCP5h, CCP6h, Pz, P3, P4, P7, P8, PPO1h, PPO2h, POO1, POO2 ve Fz) Şekil 2'deki gibi yerleştirilmiştir [14].



Şekil 2. EEG Veri Kaydının Alındığı Elektrot Pozisyonu

2.2. Ön İşleme

Bu çalışmada, EEG sinyallerini ön işleme için literatür de yaygın olarak kullanılan Ayrık Dalgacık Dönüşümü (ADD) yöntemi kullanılmıştır.

2.2.1. Ayrık Dalgacık Dönüşümü

ADD, sinyali frekans bileşenlerine ayırarak filtreleyen bir yöntemdir. ADD, düşük ve yüksek frekans bileşenlerini birbirinden ayırmak için yüksek frekans bileşenlerini yüksek geçiren filtreden, düşük frekans bileşenlerini de alçak geçiren filtreden geçirir. Alçak geçiren filtre sonucu oluşan yaklaşım terimi $A(n)$, yüksek geçiren filtre sonucu oluşan detay terimi de $D(n)$ olarak ifade edilir [15].

ADD'nin temel formülü (1)'deki gibidir.

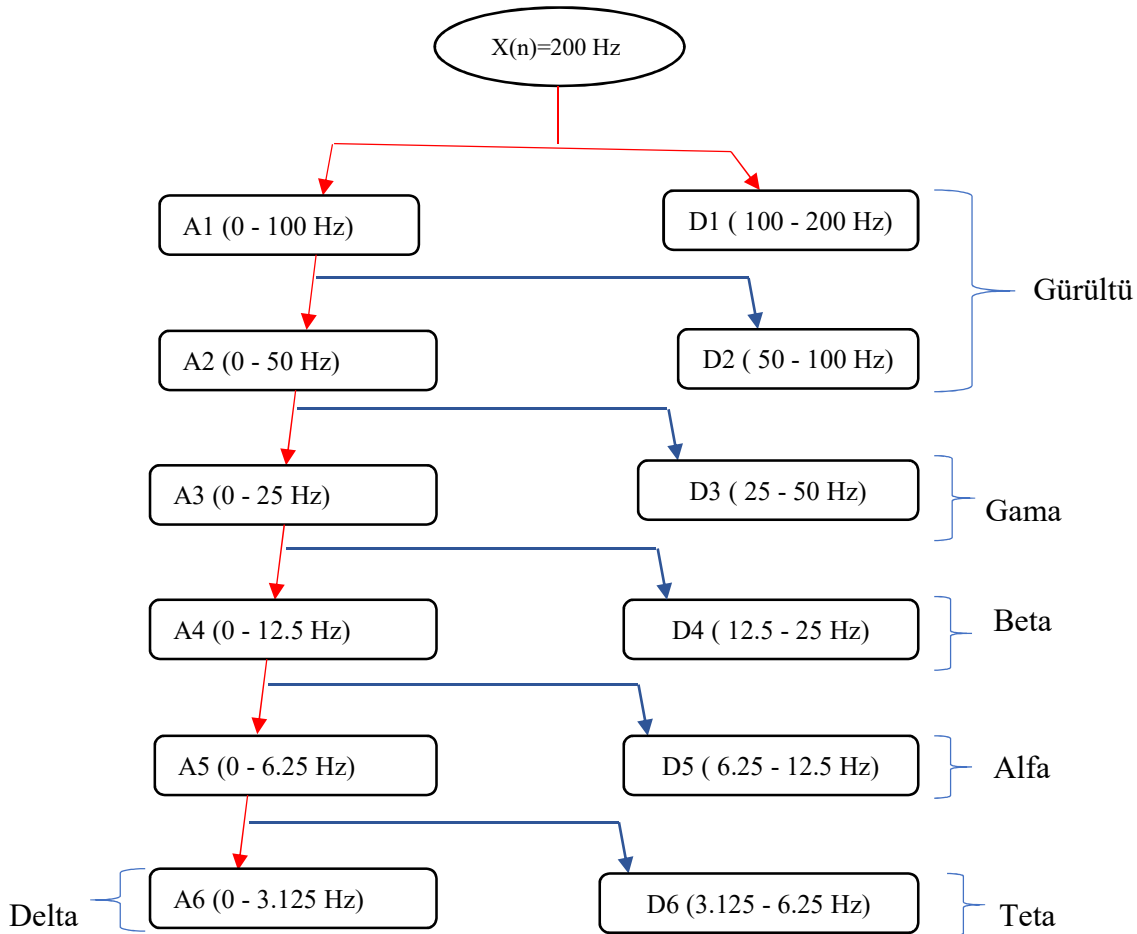
$$w(j, k) = \sum_j \sum_k X(n) 2^{-j/2} \Psi(2^{-j}n - k) \quad (1)$$

ADD'nin temel formülündeki Ψ ana dalgacık ve $x(n)$ işaretin kendisidir.

Bu çalışmada, EEG sinyaline Daubechies-6 dalgacık fonksiyonu uygulanarak, ADD ile sinyal 6.dereceden frekans bandına kadar ayrıştırılmıştır. Şekil 3'te görüldüğü gibi ilk iki detay katsayısı yüksek frekans aralığına sahip olduğundan D1 ve D2 katsayıları kullanılmamıştır. Öznitelik vektörü oluşturulurken D3, D4, D5 ve D6 detay katsayıları ve A6 yaklaşım katsayısı kullanılmıştır.

EEG beyindeki çeşitli işlemlerin üst üste binmesini temsil eden bir sinyaldir. Bu işlemlerin daha açık incelenmesini ve etkili olduğu frekans aralığına ulaşıp EEG üzerine yapılan çalışmalar da işlemleri daha da kolaylaştırmak adına EEG sinyali alt bant bileşenlerine ayrıştırılır [8].

EEG alt bantları: D3 detay katsayısı gama bandı, D4 detay katsayısı beta bandı, D5 detay katsayısı alfa bandı, D6 detay katsayısı teta bandı ve A6 yaklaşım katsayısı da delta bandıdır. Alfa, beta, teta, delta ve gama EEG alt bantları düşük frekans bant aralığına sahiptir. Daha yüksek frekanslar genellikle gürültü olarak adlandırılır burada da D1 ve D2 bandı ise yüksek frekans aralığına sahip olduğu için gürültü olarak değerlendirilerek çalışmaya katılmamıştır.



Şekil 3. 6. Dereceden ADD Frekans Ağacı

2.3. Öznitelik Çıkarma

Çalışmaya göre uygun öznitelik seçimi sınıflandırma performansının yüksek olması açısından önemlidir. Bu çalışmada, EEG işaretinin ADD ile alt frekans bantlarına ayrıştırılmış olan alfa, beta, teta, delta ve gama bantlarından; Basıklık, Ortalama Enerji, Varyans ve Standart Sapma öznitelik vektörleri çıkarılmıştır. Çıkarılan öznitelikler aşağıda kısaca anlatılmıştır.

2.3.1. Standart Sapma

Verilerin aritmetik ortalamaya göre göstermiş olduğu dağılımı ifade etmeye standart sapma denir. Eşitlik (2)'deki standart sapma olarak adlandırılan Std formülünde kullanılmış olan \bar{a} ortalamayı ve k veri sayısını temsil etmektedir.

$$Std = \sqrt{\frac{1}{k-1} \sum_{i=1}^k (a_i - \bar{a})^2} \quad (2)$$

2.3.2. Ortalama Enerji

Sinyalin genlik değerlerinin karesinin ortalaması ortalama enerjidir. Ortalama enerjiye ait OE olarak adlandırılmış denklem eşitlik (3)'te verilmiştir.

$$OE = \frac{1}{k} \sum_{i=1}^k a_i^2 \quad (3)$$

2.3.3. Varyans

Basit istatistiksel bir ifade olan varyans standart sapmanın karesidir. Eşitlik (4)'te varyans işleminin formülü Var olarak verilmiştir.

$$Var = \frac{1}{k-1} \sum_{i=1}^k (a_i - \bar{a})^2 \quad (4)$$

2.3.4. Basıklık

Rastgele sürecin 4. Momenti ile hesaplanan ve olasılık dağılımının ölçüsü olarak bilinen basıklık ifadesinin eşitlik (5)'te bas olarak adlandırılan formülü verilmiştir. Bu formülde k veri sayısı, std standart sapma ve \bar{a} ortalama olarak ifade edilir.

$$bas = \frac{\sum_{i=1}^k (a_i - \bar{a})^4}{(k-1)std^4} \quad (5)$$

2.4. Sınıflandırma Metodu

Bu çalışmada sınıflandırıcının sınıflama sonuçları WEKA(bilgi analizi için Waikato Ortamı) Sürüm 3.8.3 kullanılarak elde edilmiştir. Bu çalışmada elde edilen veriler veri madenciliğinde çok sık kullanılan J48 algoritması ile sınıflandırılmıştır.

2.4.1. J48 Sınıflandırıcı Algoritması

J48, C4.5 algoritması temeline dayanan J. R. Quilan tarafından geliştirilmiş bir karar ağacı algoritmasıdır [16]. Bu algoritma öznitelikler için birkaç örnek yaklaşım ile uygun davranış biçimlerini bulmaya çalışır. Böylelikle erişilmek istenen değışkene ulaşabilmek için kurallar üretir. Karar ağaçları oluşturulurken alt ağaçlar oluşturulur ve bu alt ağaçlar veri kümesi yapısına göre daha fazla alt dallara ayrıştırılabilir. Ayrıca J48 istenmeyen ve anlamlı olmayan dalların karar ağacından silinmesi için budama işlemi de yapılmaktadır. J48'deki budama tekniğinin amacı yanlış sınıflandırma hatasını azaltmak için geliştirilmiştir. J48 sınıflandırıcı algoritması, muhtemel tahmin için eldeki verinin farklı özellik değerine dayanan veri setine bölünmüştür. Karar ağacı, karar düğümü ve yaprak düğümünden oluşmaktadır. Karar düğümü özelliklerinin testini belirler ve yaprak düğümü de sınıf değerlerini tespit eder. Böylelikle J48 sınıflandırıcı algoritması kolay anlaşılır modeller oluşturur ve sınıflandırma performansının artmasında etkinlik sağlamış olur [17-19].

Son yıllarda, BCI ve biyomedikal alanda çalışılmış J48 sınıflandırıcı algoritma uygulamaları yer almaktadır. Bu uygulamalardan biri Eraldemir ve arkadaşlarının çalışmasıdır. Bu çalışmada matematiksel işlemler ve text okuma işlemleri sırasında kaydedilen EEG verisinin sınıflandırılması için J48 ve Random Forest karar ağaçlarının performansı karşılaştırılmış. J48 sınıflandırıcı algoritması ile denek bağımlı matematiksel işlem ve text okuma işlemi ikili sınıfının ayırt edilmesi sınıflandırma doğruluğunu % 90.92 olarak elde etmişler diğer yandan denek bağımsız sınıflandırma doğruluğunu ise % 95.28 olarak elde etmişlerdir [20]. Eraldemir ve Yıldırım, çalışmalarında sayısal ve metinsel işlemin yapılması sırasında oluşturulan EEG verisinden öznitelik çıkarımı yaptıktan sonra BayesNet ve J48 sınıflandırıcı algoritmasını kullanmışlar. En iyi sonucu J48 sınıflandırıcı algoritması ile % 90.6 olarak elde etmişlerdir [21]. Daş ve Türkoğlu, çalışmalarında 4 bakterinin DNA'sındaki farklı uzunluktaki dizimleri almışlar ve bu dizimdeki tekrar eden nükleotid çiftlerinin frekansını bularak bu frekans değerlerine J48, Random Forest ve LMT sınıflandırması algoritması uygulamışlar. Böylelikle çalışmalarında J48 sınıflandırıcı algoritması ile sınıflandırma doğruluğunu %93 olarak bulmuşlardır [22].

3. Sonuçlar ve Tartışma

Bu çalışmada zihinsel aritmetik (üç basamaklı sayı eksi bir basamaklı sayı) ve temel durum (hiç düşünmeden dinlenme hali) tabanlı 29 gönüllü kişiden kaydedilmiş EEG verisi üzerine çalışılmıştır. EEG verisi ayrık dalgacık dönüşümü ile alt frekans bantlarına ayrıştırılmış ve filtreleme işlemi yapılmıştır. Bu ön işlem adımı yapıldıktan sonra Ortalama Enerji, Standart Sapma, Basıklık ve Varyans öznitelikleri çıkarılmıştır. Çıkarılan özniteliklere J48 sınıflandırıcı algoritması, 10 kat çapraz doğrulama ile uygulanmıştır. Sınıflandırma sonucunda %98.2 sınıflandırma doğruluğu hesaplanmıştır. Bu çalışmada, J48 sınıflandırması için oluşan konfüzyon matrisi Tablo 1. de verilmiştir.

Tablo 1. ZA ve TD Konfüzyon Matris

	Zihinsel Aktivite	Temel Durum
a	29	1
b	0	28

[10], [11], [12] ve [13] referanslarında görüldüğü gibi EEG sinyalinin ZA ayırımı için yüksek SD yüzdesine sahip çalışmalar yer almaktadır. Bu çalışmada; farklı önileme, öznitelik ve sınıflandırma algoritması kullanarak SD yüzdesi daha da artırılıp EEG'nin BCI uygulamalarındaki başarımı vurgulanmıştır.

Teşekkür

Bu çalışmada kullanmış olduğumuz veri setini [7] nolu referansta açık erişime sunmuş olmalarından dolayı Shin ve arkadaşlarına teşekkür ediyoruz.

Referanslar

- [1] <https://medium.com/@mubuyuk51/neuroscience-ve-eeeg-analizi-nedir-525ed2204231> (erişim tarihi 20.02.2018)
- [2] Yağanoğlu, M., Bozkurt, F., & Günay, F.B., “EEG Tabanlı Beyin-Bilgisayar Arayüzü Sistemlerinde Öznitelik Çıkarma Yöntemleri”, Süleyman Demirel Üniversitesi Mühendislik Bilimleri ve Tasarım Dergisi 2(3), ÖS:BiyoMekanik2014, 313-318, 2014.
- [3] Olgun, N., “EEG Sinyallerinin Sınıflandırılarak Beyin-Bilgisayar Arayüzü Tabanlı Bir Sistem Otomasyonunun Gerçekleştirilmesi”, Yüksek Lisans Tezi, Fırat Üniversitesi, Elazığ, 2014.
- [4] Kaya, M., Cömert, M., & Mıshchenko, Y., “Beyin Bilgisayar Arayüzü için DVM Makine Öğrenme Yöntemi Kullanılarak EEG Verilerinden Sağ ve Sol El Hareket Düşüncelerinin Tespiti”, Türk Bilim Araştırma Vakfı (TÜBAV), vol.10, no.3, pp. 1-20, 2017.
- [5] Argunşah, A.Ö., “Beyinden Bilgisayara Bir Yol: BEYİN BİGİSAYAR ARAYÜZÜ”.
- [6] Amin, H.U., Malik, A.S., Ahmad, R.F., Badrutin, N., Kamel, N., Hussain, M. & Chooi, W., “Feature Extraction and Classification for EEG Signals Using Wavelet Transform and Machine Learning Techniques”, *Australasian Physical & Engineering Sciences in Medicine*, 38(1), 139-149, 2015.
- [7] <http://doc.ml.tu-berlin.de/hBCI/> (erişim tarihi 01.01.2017)
- [8] Adeli, H., Ghosh-Dastidar, S., & Dadmehr, N., “A Wavelet-Chaos Methodology for Analysis of EEGs and EEG Subbands to Detect Seizure and Epilepsy”, *IEEE Transactions on Biomedical Engineering*, 54(2), 205-211, 2007.
- [9] Zhang, L., He, W., He, C., & Wang, P., “Improving Mental Task Classification by Adding High Frequency Band Information”, *Journal of Medical Systems*, 34(1), 1-60, 2008.
- [10] Yavuz, E., & Aydemir, Ö., “Zihinsel Aritmetik Tabanlı EEG Sinyallerinden Öznitelik Çıkarımı”, 2017 Medical Technologies National Congress (TIPTEKNO), DOI:10.1109/TIPTEKNO.2017.8238078, 2017.
- [11] Wang, Q., & Sourina, O., “Real-Time Mental Arithmetic Task Recognition From EEG Signals”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 21(2), 225-232, 2013. DOI:10.1109/TNSRE.2012.2236576
- [12] Palaniappan, R., “Brain Computer Interface Design Using Band Powers Extracted During Mental Tasks”, *Conference Proceedings. 2nd International IEEE EMBS Conference on Neural Engineering*, 2005. DOI:10.1109/CNE.2005.1419622
- [13] Shin, J., Lüthmann, A., Blankertz, B., Kim, D.W., Jeong, J., Hwang, H.J., & Müller, K.R., “Open Access Dataset for EEG+NIRS Single-Trial Classification”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(10), 1735-1745, 2016. DOI:10.1109/TNSRE.2016.2628057
- [14] Jurcak, V., Tsuzuki, D., & Dan, I., “10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems”, *NeuroImage*, 34(4), 1600-1611, 2007.
- [15] Eraldemir, S.G., Yıldırım, E., & Kutlu, Y., “EEG İşaretlerinden Matematiksel İşlemlerin k-NN Algoritması ile Sınıflandırılması”, *Elektrik-Elektronik-Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu (ELECO 2014)*, 2014.

- [16] Singaravelan, S., Murugan, D., & Mayakrishnan, R., “Analysis of Classification Algorithms J48 and Smo on Different Datasets”, *World Engineering & Applied Sciences Journal*, 6(2), 119-123, 2015. DOI:10.5829/idosi.weasj.2015.6.2.22162
- [17] Aljawarneh, S., Yassein, M.B., & Aljundi, M., “An enhanced J48 classification algorithm for the anomaly intrusion detection systems”, *Cluster Computing*, 1-17, 2017.
- [18] Çavuşoğlu, Ü., & Kaçar, S., “Anormal Trafik Tespiti için Veri Madenciliği Algoritmalarının Performans Analizi”, *Academic Platform Journal of Engineering and Science*, 7(2), 205-216, 2019.
- [19] Alan, M.A., & Yeşilyurt, C., “Farklı Veri Setleri Üzerinde SMO ve J48 Algoritmalarının Sınıflandırma Sonuçlarının Karşılaştırılması”, *İşletme Bilimi Dergisi (JOBS)*, 6(3), 199-213, 2018. DOI:10.22139/jobs.487388
- [20] Eraldemir, S.G., Yıldırım, E., & Arslan, M.T., “Hilbert Hung Dönüşümü Uygulanan EEG İşaretlerinde J48 ve Rastgele Orman Sınıflandırıcılarının Karşılaştırılması”, *International Advanced Researches & Engineering Congress-2017*.
- [21] Eraldemir, S.G., & Yıldırım, E., “Comparison of wavelets for classification of cognitive EEG signals”, 2015 23rd Signal Processing and Communications Applications Conference (SIU), 2015. DOI:10.1109/SIU.2015.7130099
- [22] Daş, B., & Türkoğlu, İ., “DNA Dizilimlerinin Sınıflandırılmasında Karar Ağacı Algoritmalarının Karşılaştırılması”, *Elektrik-Elektronik-Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu (ELECO 2014)*, 2014.