



POLİTEKNİK DERGİSİ

JOURNAL of POLYTECHNIC

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



EEG sinyalleri kullanılarak zihinsel iş yükü seviyelerinin sınıflandırılması

Classification of mental workload levels by using EEG signals

Yazar(lar) (Author(s)): Eda AKMAN AYDIN

ORCID: 0000-0002-9887-3808

Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article): Aydın E.A., “EEG sinyalleri kullanılarak zihinsel iş yükü seviyelerinin sınıflandırılması”, *Politeknik Dergisi*, 24(2): 681-689, (2021).

Erişim linki (To link to this article): <http://dergipark.org.tr/politeknik/archive>

DOI: 10.2339/politeknik.794655

EEG Sinyalleri Kullanılarak Zihinsel İş Yükü Seviyelerinin Sınıflandırılması


Classification of Mental Workload Levels by Using EEG Signals

Önemli noktalar (Highlights)

- ❖ Fraktal boyut algoritmaları zihinsel iş yükü seviyelerinin sınıflandırılmasında kullanılabilir./Fractal dimension algorithms can be used for classifying mental workload levels.
- ❖ Higuchi fraktal boyut (HFB) algoritması destek vektör makineleri ile birlikte zihinsel iş yükü seviyelerinin sınıflandırılmasında en yüksek sınıflandırma doğruluğu sağlamıştır./Higuchi fractal dimension (HFB) algorithm combined with support vector machines provided the highest classification accuracy in classifying mental workload levels.

Grafik Özet (Graphical Abstract)

Bu çalışmada zihinsel iş yükü seviyeleri EEG sinyalleri kullanılarak sınıflandırılmıştır./ In this study, mental workload levels were classified by using EEG signals.



Şekil. Zihinsel İş Yükü Sınıflandırma Prosedürü /Figure. Mental Workload Classification Procedure

Amaç (Aim)

Bu çalışma EEG sinyalleri kullanılarak zihinsel iş yükü seviyelerinin düşük, orta ve yüksek seviyelere sınıflandırılmasını amaçlamaktadır./This study aims to classify mental workload levels into low, medium and high levels by using EEG signals.

Tasarım ve Yöntem (Design & Methodology)

Öznitelik çıkarma yöntemi olarak Katz (KFB) ve Higuchi fraktal boyut (HFB) algoritmaları; sınıflandırma yöntemi olarak ise, hata düzelten çıkış kodlaması (HDÇK) yöntemi, destek vektör makineleri (DVM), k-en yakın komşuluk (k-EYK) ve kuadratik ayırtaç analizi (KAA) sınıflandırıcılar ile birlikte kullanılmıştır. / Katz (KFB) and Higuchi fractal dimension (HFB) algorithms were used as feature extraction methods; error correcting output coding (ECOC) method was used together with support vector machines (SVM), k-nearest neighborhood (k-NN) and quadratic discriminant analysis (QDA) classifiers.

Özgünlük (Originality)

Fraktal boyut algoritmalarının zihin iş yükü seviyelerinin sınıflandırılmasında kullanılabileceği çeşitli sınıflandırma yöntemleri ile karşılaştırmalı olarak incelenmiş; en yüksek başarımın HFB ve DVM-HDÇK yöntemlerinin bir arada kullanımı ile elde edildiği gösterilmiştir./Fractal dimension methods and various classification methods comparatively examined on classification of the mental workload levels; and it is revealed that the highest performance was achieved by the combination of HFD and SVM-ECOC methods.

Bulgular (Findings)

KFB ve HFB tabanlı öznitelikler ile DVM, k-EYK ve KAA sınıflandırıcıları için sınıflandırma doğruluğu sırasıyla %78.74, %75.98, %67.59 ve %95.39, %92.80, %73.76 olarak belirlenmiştir./Classification accuracy of SVM, k-NN and QDA classifiers were determined as 78.74%, 75.98%, 67.59% and 95.39%, 92.80%, 73.76%, for KFD and HFD-based features with respectively.

Sonuç (Conclusion)

HFB ve DVM-HDÇK yöntemlerinin bir arada kullanımının zihinsel iş yükünün sınıflandırılmasında başarılı bir yöntem olabileceği görülmektedir. / It is seen that the combination of HFD and SVM-ECOC methods can be a successful method in classifying the mental workload.

Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

EEG Sinyalleri Kullanılarak Zihinsel İş Yükü Seviyelerinin Sınıflandırılması

Araştırma Makalesi / Research Article

Eda AKMAN AYDIN*

Elektrik-Elektronik Mühendisliği, Teknoloji Fakültesi, Gazi Üniversitesi, Türkiye

(Geliş/Received : 29.04.2020 ; Kabul/Accepted : 29.09.2020)

ÖZ

Zihinsel iş yükü, bir görevi gerçekleştirmek için gerekli olan bilişsel kapasite miktarıdır. Elektroensefalogram (EEG), zihinsel iş yükünün objektif olarak değerlendirilebilmesi için kullanılan bir görüntüleme tekniğidir. Bu çalışmada, eşzamanlı görevlerin yerine getirilmesi sırasında kaydedilmiş EEG sinyallerinden zihinsel iş yükü seviyelerinin sınıflandırılması için, Katz fraktal boyut (KFB) ve Higuchi fraktal boyut (HFB) algoritmalarına dayalı öznelik çıkarma yöntemleri ile hata düzelten çıkış kodlaması (HDÇK) yönteminin kullanılması önerilmiştir. Çok sınıflı sınıflandırma problemleri için önerilen bir sınıflandırıcı birleşim tekniği olan HDÇK, zihinsel iş yükünün düşük, orta ve yüksek seviye olarak sınıflandırılması için kullanılmıştır. HDÇK, destek vektör makineleri (DVM), k en yakın komşuluk ve kuadratik ayırtaç analizi yöntemleri kullanılarak bire-karşı-diğerleri yaklaşımı ile oluşturulmuştur. Önerilen yöntemin performansı, 48 katılımcıdan kaydedilen EEG sinyallerini içeren Eşzamanlı Görev EEG İş Yükü veri kümesi üzerinde değerlendirilmiştir. KFB ve HFB algoritmaları kullanılarak sınıflandırma doğrulukları sırasıyla %78.44 ve %95.39 ve Cohen's Kappa değeri 0.52 ve 0.89 olarak belirlenmiştir. Sonuçlar, HFB ve DVM-HDÇK yöntemlerinin bir arada kullanımının zihinsel iş yükünün çok sınıflı sınıflandırılmasında başarılı bir yöntem olabileceğini göstermektedir.

Anahtar Kelimeler: Elektroensefalogram (EEG), zihinsel iş yükü, Katz fraktal boyut, Higuchi fraktal boyut, hata düzelten çıkış kodlaması (HDÇK).

Classification of Mental Workload Levels by Using EEG Signals

ABSTRACT

Mental workload is amount of the required cognitive capacity during performing tasks. Electroencephalogram (EEG) is an objective monitoring technique used to evaluate mental workload. In this study, feature extraction methods based on Katz's fractal dimension (KFD) and Higuchi's fractal dimension (HFD); and error correcting output coding (ECOC) are proposed to classify mental workload levels through EEG signals, which were recorded during performing of the simultaneous tasks. ECOC, which is a classifier combination technique proposed for multiclass classification problems, is employed to classify mental workload as low, moderate and high level. ECOC was created based on one vs. all approach, by using support vector machines (SVM), k nearest neighbourhood and quadratic discriminant analysis. The performance of the proposed method is evaluated on Simultaneous Task EEG Workload (STEW) dataset collected from 48 subjects. By using KFD and HFD with respectively, the classification accuracy was determined as %78.44 and %95.39; and Cohen's Kappa value was determined as 0.52 ve 0.89. The results indicate that combination of HFD and SVM-ECOC is a successful method in the multiclass classification of mental workload.

Keywords : Electroencephalography (EEG); mental workload (MWL); Katz's fractal dimension; Higuchi's fractal dimension; error coding output codes (ECOC).

1. GİRİŞ (INTRODUCTION)

Zihinsel iş yükü, bilişsel ya da motor bir görevi gerçekleştirmek için gerekli olan bilişsel kapasite miktarı olarak tanımlanmaktadır [1]. Zihinsel iş yükünün değerlendirilmesi, simüle ya da gerçek otomobil kullanıcılarının, pilotların, makinistlerin, hava trafik yönetim merkezlerinde ve şehir trafik yönetim merkezlerinde çalışanların, ameliyat sırasında cerrahların zihinsel iş yüklerinin değerlendirilmesinde kullanıldığı gibi, son yıllarda beyin bilgisayar arayüzü kullanıcılarının da performans değerlendirmelerinde kullanılmaktadır [2,3].

Zihinsel iş yükü seviyesinin değerlendirilmesi için kullanılan geleneksel teknik, anketler yoluyla, bireylerden yazılı veya sözlü geri bildirim alınmasıdır. Ancak, bu yöntemin subjektif olması ve bireylerin kendilerini ifade edebilme becerilerine bağlı olması gibi kısıtlamaları vardır [4]. Fizyolojik büyüklüklerin ölçülmesi ve değerlendirilmesine dayalı yöntemler ise zihinsel iş yükü değerlendirmesinin objektif olarak yapılabileceği yöntemlerdir. Bu yöntemler genellikle, kişilerin kendilerine verilen bir görevi gerçekleştirmeleri sırasında kaydedilen fizyolojik verilerin değerlendirilmesi şeklinde uygulanır. Elektrokardiyak aktivite [5], solunum ölçümleri [6], elektrodermal aktivite [7], kan basıncı [8], göz hareketleri [9] ve beyin aktivitesi ölçümleri [10] iş yükü değerlendirmesinde

*Sorumlu Yazar (Corresponding Author)
e-posta : edaakman@gazi.edu.tr

kullanılan fizyolojik ölçümlerdir. Lohani ve arkadaşları, fizyolojik işaretler ve zihinsel iş yükü arasındaki ilişkiyi özetlemiştir [11]. Buna göre, zihinsel iş yükündeki artış durumunda kalp atış hızı, sistolik kan basıncı, elektrodermal aktivite, gözbebeği çapı ve elektroensefalogram işaretinin teta aktivitesinde artış; elektroensefalogram işaretinin alfa aktivitesinde baskılanma ve kalp atış hızı değişkenliğinde azalma beklenilmektedir.

Elektroensefalogram (EEG), yakın kızılötesi spektroskopisi (NIRS), fonksiyonel manyetik rezonans görüntüleme (fMRI) ve manyetoensefalogram (MEG) beyin aktivitesinin incelenmesinde kullanılan görüntüleme teknikleridir. EEG, sinir hücreleri arasındaki iyon akışından kaynaklanan gerilim değişimlerinin algılanması ve izlenmesi amacıyla kullanılan, girişimsel olmayan, yüksek zaman çözünürlüğüne sahip, taşınabilir ve düşük maliyetli bir görüntüleme tekniğidir [12]. Beyindeki bilişsel aktiviteler sonucu oluşan değişimleri algılama hassasiyetinin yüksek olması nedeniyle, EEG sinyalleri zihinsel iş yükü değerlendirmelerinde sıklıkla kullanılan bir yöntemdir [13-14].

Zihinsel iş yükü seviyelerinin çok seviyeli sınıflandırılması üzerine çeşitli çalışmalar yürütülmüştür [15-19]. Wang ve arkadaşları [15], dört spesifik EEG alt bandı için hesapladıkları, entropi, sinyal gücü, morfolojik ve istatistiksel öznitelikleri içeren 658 öznitelikten oluşan öznitelik vektörünü kullanarak, mRMR tabanlı öznitelik seçimi ve destek vektör makineleri tabanlı sınıflandırma sonucu %84 sınıflandırma doğruluğuna erişmişlerdir. Qu ve arkadaşları [16], EEG sinyallerine bağımsız bileşenler analizi uygulamış; bağımsız bileşenlerine ait güç spektral yoğunluklarını destek vektör makineleri ile sınıflandırmıştır. Bu çalışmada, zihinsel iş yükü seviyesi düşük, orta ve yüksek olmak üzere üç seviyeye sınıflandırılmasında %79.8 başarıya erişmişlerdir. Chin ve arkadaşları [17], EEG sinyal bant güçleri ve doğrusal ayırtaç analizi yöntemleri ile, mental aritmetik görevleri sırasındaki zihinsel iş yükünü kolay, orta ve zor olmak üzere %66 doğrulukla sınıflandırmıştır. Lim ve arkadaşları [18], 48 katılımcının kendilerine verilen çoklu görevleri gerçekleştirmeleri sırasında kaydedilen EEG sinyallerini içeren bir zihinsel iş yükü aktivitesi veri kümesi oluşturmuşlardır. Hızlı Fourier Dönüşümü ile alt bantlarına ayrıştırılmış EEG sinyallerinin her alt bant için güç spektral yoğunluklarını öznitelik olarak kullanarak, düşük, orta ve yüksek zihinsel iş yükünü %69 doğrulukla belirlemişlerdir. Chakladar ve arkadaşları [19], zihinsel iş yükünün değerlendirilmesi için, güç spektral yoğunlukları, Hurstexponent, istatistiksel öznitelikler (ortalama, standart sapma, skewness, kurtosis), yaklaşık entropi ve otoregresif katsayıları öznitelik olarak kullanmış; gri kurt optimizasyon algoritması ile öznitelik seçimi yapmış; seçilen öznitelikleri uzun kısa-vadeli bellek ve çift yönlü uzun kısa süreli bellek yöntemlerine dayalı hibrit bir derin sinir ağı ile sınıflandırmışlar; 82.57% sınıflandırma doğruluğu elde etmişlerdir. Zihinsel iş yükü seviyelerinin, yüksek doğrulukla

objektif olarak değerlendirilmesi, özellikle yüksek dikkat gereken durumlar için önem teşkil eder. Bu nedenle, çok seviyeli sınıflandırma doğruluğunun iyileştirilmesi gerekmektedir.

Bu çalışmada, bireylerin zihinsel iş yükü seviyelerinin düşük, orta ve yüksek seviye olmak üzere üç sınıfa sınıflandırılması için, öznitelik çıkarma yöntemi olarak Katz fraktal boyut (KFB) ve Higuchi fraktal boyut (HFB) algoritmaları; sınıflandırma yöntemi olarak ise, bire karşı-diğerleri yaklaşımına dayalı hata düzelten çıkış kodlaması (HDÇK) yöntemi önerilmiştir. Önerilen yöntemin performansını karşılaştırmak amacıyla HDÇK, destek vektör makineleri (DVM), k-en yakın komşuluk (k-EYK) ve kuadratik ayırtaç analizi (KAA) sınıflandırıcıları birlikte kullanılmış, sonuçlar karşılaştırmalı olarak verilmiştir. Önerilen yöntem, Lim ve diğerleri [18] tarafından sağlanan, Eşzamanlı Görev EEG İş Yükü veri kümesi üzerinde test edilmiştir. Önerilen yöntemin performansı, sınıflandırma karmaşıklık matrisi, istatistiksel ölçütler ve Kappa katsayısı kullanılarak değerlendirilmiştir.

Çalışmanın devamı aşağıdaki gibi organize edilmiştir: İkinci bölümde, çalışmada kullanılan veri kümesi ve sinyal analizinde kullanılan teknikler açıklanmıştır. Üçüncü bölümde, çalışmanın sonuçları sunulmuştur. Son bölümde ise, çalışmanın genel bir özeti verilmiş ve çalışmanın sınırlı kalan yönlerine değinilmiştir.

2. MATERYAL VE METOD (MATERIAL and METHOD)

A. Veri Kümesi (Dataset)

Bu çalışmada, Lim ve arkadaşları tarafından kaydedilen, eşzamanlı görev EEG veri kümesi (STEW) kullanılmıştır [18]. Veri kümesi, 48 sağlıklı erkek katılımcıdan kaydedilen verileri içermektedir. Veriler, AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 ve AF4 pozisyonlarında bulunan 14 elektrot üzerinden, 128 Hz örnekleme frekansı ile, Emotiv EPOC EEG sistemi kullanılarak kaydedilmiştir.

Katılımcılara, deneyler sırasında, Vienna Test Sisteminin Simultane Kapasite test modülü uygulanmıştır. Bu test, bireylerin çoklu görev ve stres toleransını değerlendirmek için kullanılan psikolojik bir testtir. Test, katılımcıların kendilerine işitsel olarak yöneltilen soruları yanıtlarken, aynı zamanda, iki ayrı panel üzerindeki özdeş nesnelere eşleştirmeleri şeklinde görevler içermektedir. Testin süresi 18 dakikadır. SIMKAP testinin ekran görüntüsü Şekil 1'de verilmiştir.

Deneyler iki oturumda gerçekleştirilmiştir. İlk oturumda, deneyin 3 dakikalık kısmında, katılımcılara herhangi bir görev verilmeksizin, gözleri açık bir şekilde dinlenme pozisyonunda kalmaları istenmiştir. İkinci oturumda, katılımcıların EEG sinyalleri kaydedilirken, kendilerinden SIMKAP testini uygulamaları istenmiştir. Bu oturumda kaydedilen EEG sinyallerinin sadece son 3 dakikalık kısmı, zihinsel iş yükü durumunun değerlendirilmesi amacıyla kullanılmıştır. EEG verisinin

ilk ve son 15 saniyelik kısımları da görev etkinliği geçişlerinin etkisini azaltmak için veri dışında tutulmuştur. Son olarak kalan 2.5 dakikalık EEG verisi, iş yükünün seviyesinin değerlendirilmesi amacıyla kullanılmıştır. Deneylerin sonunda, katılımcılardan dinlenme durumu ile karşılaştırdıklarında, testi uygularken kendi algıladıkları zihinsel iş yükü seviyelerini değerlendirecekleri bir anket uygulanmıştır. Anketin derecelendirme ölçeği 1 ile 9 arasındadır. Derecelendirme ölçeğinde 1-3 arası düşük iş yükü, 4-6 arası orta iş yükü ve 7-9 arası yüksek iş yükü olarak gruplandırılmıştır [18].

B. Fraktal Boyutlar (Fractal Dimensions)

Fraktal boyut (FB), bir öz-benzerlik ölçütüdür. FB algoritmaları, bir örüntünün zaman serilerinde tekrar edilme sayısını belirlemeye çalışır ve bu yolla sinyallerdeki içeriğin öz-benzerlik içeriğini ölçer, karmaşıklığını yansıtır [20]. Bu çalışmada öznelik çıkarma amacıyla Katz ve Higuchi fraktal boyut algoritmaları kullanılmaktadır.

B.1. Katz fraktal boyut (Katz's fractal dimension)

KFB, ardışık noktalar arasındaki mesafeyi kullanan, düşük hesaplama maliyetli bir FB algoritmasıdır. Tek boyutlu bir zaman serisi sinyalindeki düzensizliğin ölçütü olan KFB, doğrudan sinyal dalga şeklinden elde edilebilir. Zaman serisi, X_1, X_2, \dots, X_N olan bir sinyal için KFB Denklem 1 ile hesaplanabilir. Denklem 1’de, L, sinyalin toplam uzunluğu ve d, dizinin ilk noktası ile dizinin en uzak mesafeyi sağlayan noktası arasındaki

mesafe olarak tahmin edilen çaptır. L ve d, sırasıyla Denklem 2 ve 3 ile hesaplanmaktadır [20,21].

$$KFB = \frac{\log_{10}(L)}{\log_{10}(d)} \tag{1}$$

$$d = \text{maksimum}(|x_1 - x_j|) \quad j = 2,3, \dots, N \tag{2}$$

$$L = \sum_{i=2}^N x_i - x_{i-1} \tag{3}$$

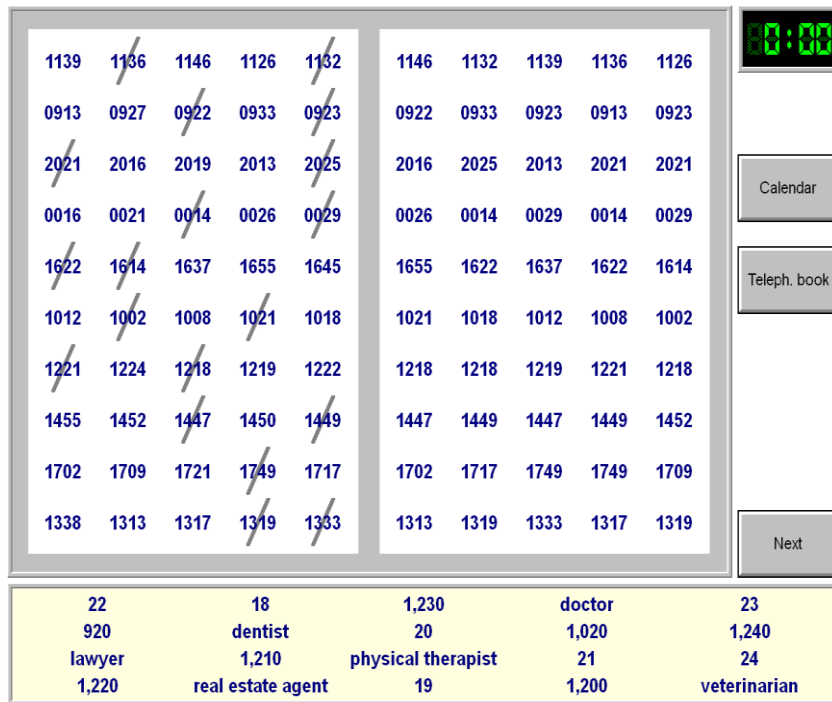
Sinyalin ardışık noktaları arasındaki ortalama mesafe α , Denklem 4 ile hesaplanmaktadır. Bu durumda elde edilen KFB Denklem 5 kullanılarak hesaplanmaktadır [20,21].

$$\alpha = \frac{L}{N - 1} \tag{4}$$

$$KFB = \frac{\log_{10}(n)}{\log_{10}(n) + \log_{10}(\frac{d}{L})} \tag{5}$$

B.2. Higuchi fractal boyut (Higuchi's fractal dimension)

HFB, fraktal boyutların doğrudan zaman serileri üzerinden belirlenmesini sağlayan bir algoritmadır. $X(1), X(2), \dots, X(N)$ şeklinde verilen N elemanlı bir zaman serisi sinyali, Denklem 6 ile tanımlanan yeni bir zaman serisi (x_k^m) olarak tanımlanabilir. Denklem 6’da m ve k tamsayıları sırasıyla, başlangıç zamanını ve zaman aralığını göstermektedir. Böylece k zaman aralığı için k adet yeni zaman serisi altkümesi elde edilir. Çalışmada $k_{max} = 6$ seçilmiştir. Oluşturulan her x_k^m zaman serisi için eğri uzunluğu, Denklem 7 ile



Şekil 1. SIMKAP çoklu görev testinin ekran görüntüsü (Screenshot of the SIMKAP multitask test) [18].

hesaplanmaktadır. Eşitliklerde, N, x veri dizisinin toplam uzunluğu; $\frac{N-1}{\lfloor \frac{N-m}{k} \rfloor k}$ ise zaman serisi altkümesinin eğri uzunluğu için normalizasyon faktörünü göstermektedir. Ortalama uzunluk, aynı k gecikmesine sahip tüm zaman serileri için hesaplanır. Bu prosedür 1 ve k_{max} aralığındaki tüm k değerleri için tekrarlanır ve toplam ortalama uzunluk L(k) elde edilir. k değeri için toplam ortalama uzunluk L(k), Denklem 8'de verilmiştir. Fraktal boyut eğri uzunluğu D ile gösterilecek olursa, ortalama eğri uzunluğu ve fraktal boyut arasında $L(k) \propto k^{-D}$ şeklinde bir ilişki olduğu söylenebilir. D değeri, logaritmik ölçekli L(m) ve k ilişkisini gösteren grafik üzerinde, en küçük kareler yöntemine dayanan lineer uydurma ile hesaplanabilen doğrunun eğimi kullanılarak elde edilebilir [22-23].

$$x_k^m = \left\{ x(m), x(m+k), x(m+2k), \dots, x\left(m + \left\lfloor \frac{N-m}{k} \right\rfloor k\right) \right\}$$

$$m = 1, 2, 3, \dots, k \quad (6)$$

$$L_m(k) = \left\{ \left(\sum_{i=1}^{\lfloor \frac{N-m}{k} \rfloor} |x(m+ik) - x(m+(i-1)k)| \right) \frac{N-1}{\lfloor \frac{N-m}{k} \rfloor k} \right\} / k$$

$$L(k) = \sum_{m=1}^k L_m(k) \quad (8)$$

C. Hata Düzeltme Çıkış Kodlaması (Error-Coding Output Codes)

HDÇK, sayısal iletişim teorisinden türetilmiş ve çok sınıflı sınıflandırma problemlerinin çözümünde kullanılan bir sınıflandırma yaklaşımıdır. HDÇK, DVM ile birlikte EEG sinyallerinin sınıflandırılmasında çeşitli çalışmalarda kullanılmıştır [24]. HDÇK, sınıf sayısının n olduğu bir problem için, her biri farklı sınıf kombinasyonlarını ayırt eden, $2^{n-1}-1$ adet DVM eğitilmesi şeklinde uygulanmaktadır.

HDÇK yaklaşımında kullanılan çeşitli kodlama teknikleri bulunmaktadır. Bire-karşı-diğerleri (one-vs-all) kodlaması bu tekniklerden biridir. Üç sınıflı bir sınıflandırma problemi için bire-karşı-diğerleri kodlama matrisi Çizelge 1'de görülmektedir. Çizelgede matrisin satırları her bir sınıf için kod sözcüklerini ($C_i, i = 1, 2, 3$); sütunlar ise, her bir sınıflandırıcıyı ($f_i, i = 1, 2, 3$) ve sınıfların nasıl ayırt edildiğini (ayrıştırıldığını) temsil etmektedir [25].

D. Sınıflandırma (Classification)

Önerilen fraktal boyut algoritmaları ve HDÇK tekniğinin performansı, destek vektör makineleri, k en yakın komşuluk ve kuadratik ayırtaç analizi yöntemleri ile birlikte kullanılarak değerlendirilmiştir.

Destek vektör makineleri, iki sınıflı sınıflandırma problemleri için Vapnik [26] tarafından önerilen danışmanlı bir makine öğrenmesi yöntemidir. Veri kümesinin doğrusal olarak ayrılabilir olduğu durumlarda,

Çizelge 1. HDÇK bire-karşı-diğerleri yaklaşımı (ECOC one vs.all approach)

| | $f1$ | $f2$ | $f3$ |
|------|------|------|------|
| $C1$ | 1 | -1 | -1 |
| $C2$ | -1 | 1 | -1 |
| $C3$ | -1 | -1 | 1 |

ayırtedici hiperdüzlem, $w^T x + b = 0$ ile tanımlanabilir. Burada, w ağırlık vektörü, b ise giriş vektörü için sapmadır. Sınıfları ayırt edecek optimal hiperdüzlem, iki sınıfın destek vektörleri arasındaki maksimum marjınlı doğrusal karar fonksiyonu olarak tanımlanır. Maksimum marjınlı karar yüzeyi $\|w\|$ minimize edilerek elde edilir. Verilerin doğrusal olarak ayrılmadığı durumlarda, ikili olarak etiketlenmiş giriş vektörleri doğrusal olmayan haritalama ile daha yüksek boyutu bir öznelik uzayına taşınır ve bu uzayda, lineer bir karar yüzeyi oluşturulur.

DVM verilerin doğrusal olmayan özellik haritalama işlemi için çekirdek fonksiyonları kullanılmaktadır. Bu çalışmada Gauss radyal tabanlı çekirdek fonksiyonu (RÇF) kullanılmıştır. Verilerin doğrusal olarak ayrılmadığı DVM'ler için ayrıca düzenleme parametresi (C) kullanılmaktadır. Bu çalışmada, RÇF'nin genişliğini gösteren sigma ve C değerlerinin belirlenmesi için ızgara arama tekniği kullanılmıştır.

k-en yakın komşuluk (k-EYK) algoritması, örnek tabanlı bir sınıflandırıcıdır. k-EYK, bir mesafe metriği kullanarak bir sorgu örneğinin en yakın k adet komşusunu bulur ve örneğin ait olabileceği sınıfı çoğunluk oyu ile belirlemektedir. Bu sınıflandırıcı için mesafe ölçütü ve en yakın komşuluk parametresi algoritmanın performansı ile ilgili önemli parametrelerdir [27].

Kuadratik ayırtaç analizi (KAA), doğrusal ayırtaç analizinin genelleştirilmiş bir versiyonudur. KDA, verilerin normal dağıldığını varsayarken, doğrusal ayırtaç analizinin aksine, sınıfların kovaryans matrislerinin eşit olduğu varsayımını dikkate almaz. KAA sınıflar arası varyans oranını maksimize, sınıflı varyans oranını ise eder. Ancak, KAA sınıflar arasında ikinci dereceden karar sınırlarına izin verir, böylece sınıflandırıcının daha etkili çalışmasını sağlar ve sınıflandırma doğruluğunu artırır [27-28]. Sınıflandırıcının genelleştirme kapasitesinin iyileştirilmesi için tüm sınıflandırma işlemlerinde 10 kat çapraz geçişleme uygulanmıştır.

E. Performans Ölçütleri (Performance Measures)

Çalışmanın sonuçları doğruluk, hassasiyet, Cohen's Kappa (κ), kriterlerine dayanarak değerlendirilmiştir. Doğruluk, doğru tahmin edilen örneklerin oranını, hassasiyet ise, belirli bir sınıftaki örneklerin doğru olarak sınıflandırılma oranını verir. DP, YN, YP ve DN'in sırasıyla Doğru Pozitif, Yanlış Negatif, Yanlış Pozitif ve Doğru Negatif olduğu varsayıldığında; doğruluk ve hassasiyet sırasıyla Eşitlik 9 ve 10 ile hesaplanmaktadır [29].

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (9)$$

$$\text{Hassasiyet} = \frac{DP}{DP+YN} \quad (10)$$


Cohen's Kappa katsayısı (κ) ise, değerleyici güvenilirliğini test etmek için kullanılan bir istatistiksel ölçüttür ve Denklem 11 ile hesaplanır. Denklemde p_o ve p_e sırasıyla iki değerlendirici için gözlemlenen uyumların toplam oranı ve bu uyumun şansa bağlı ortaya çıkma olasılığıdır [30]. Kappa katsayısı bir güvenilirlik ölçütüdür. Cohen's Kappa değeri, elde edilen sonuçların veri kümesindeki gerçek sonuçlar ile uyuma derecesi hakkında bilgi vermektedir. Kappa'nın olası değerleri -1 ile 1 aralığındadır; ancak genellikle 0 ile 1 arasında değer alır. Kappa katsayısı değerinin 1 olması, değerlendiriciler arasında uyumun mükemmel olduğunu; 0 olması ise, değerlendiriciler arasındaki uyumun tesadüfen beklenenden daha iyi olmadığını göstermektedir [31].

$$\kappa = \frac{p_o - p_e}{1 - p_e} \quad (11)$$


3. DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)

Bu çalışmada, EEG sinyalleri kullanılarak, zihinsel iş yükü seviyelerinin düşük, orta ve yüksek olmak üzere üç sınıfa sınıflandırılması amacıyla fraktal boyut algoritmaları ve HDÇK yöntemi önerilmiştir. Fraktal boyut algoritmaları olarak KFB ve HFB kullanılmıştır. Önerilen yöntemin performansını karşılaştırmak amacıyla HDÇK yöntemi, DVM, KAA ve k-EYK sınıflandırıcıları birlikte kullanılmıştır. Önerilen yöntem, Eşzamanlı Görev EEG İş Yükü veri kümesi üzerinde test edilmiştir. Veri kümesindeki düşük, orta ve yüksek zihinsel iş yükü seviyeleri için 150 saniyelik tüm veri kaydını içeren örnek EEG sinyalleri Şekil 2'de görülmektedir.

Çalışmada, ön işleme aşamasında, EEG sinyallerine kesim frekansı 1Hz olan bir yüksek geçiren filtre ve bir 50 Hz band durdurucu filtre uygulanmıştır. Filtrelenen EEG sinyalleri örnek boyutu 512 olan ve 128 örneklilik kaymalarla uygulanan bir kayan pencere ile bölümlere ayrılmıştır. Her bir bölüm için, 14 kanaldan KFB hesaplaması yapılarak öznitelik vektörü elde edilmiştir. Düşük, orta ve yüksek zihinsel iş yükü seviyeleri için, F7 elektrodu üzerinden, KFB ve HFB'ye dayalı özniteliklerin dağılımları sırasıyla Şekil 3 ve Şekil 4'te görülmektedir.



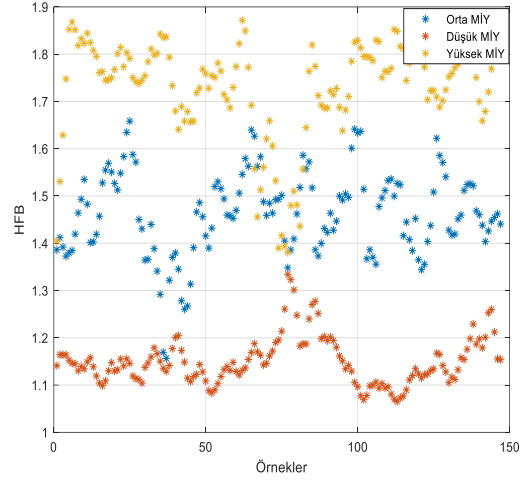
Şekil 2. Düşük, orta ve yüksek zihinsel iş yükü seviyeleri için EEG sinyalleri (EEG signals for low, medium and high mental workload levels)



Şekil 3. F7 kanalı üzerinde kaydedilen düşük, orta ve yüksek zihinsel iş yükü seviyeleri için Katz fraktal boyut dağılımları (Katz's fractal size distributions for low, medium and high mental workload levels recorded on the F7 channel)

Sınıflandırma aşamasında, HDÇK bire-karşı-diğerleri yaklaşımı kullanılarak oluşturulmuştur. DVM, KAA ve k-EYK sınıflandırıcıları birlikte kullanılmıştır. Doğrusal olmayan DVM'nin oluşturulmasında Radyal Tabanlı Fonksiyon, Gauss çekirdek fonksiyonu (RÇF) ile birlikte kullanılmıştır. Sınıflandırıcının en yüksek performans ile

kullanılması için optimum sigma ve C parametrelerinin belirlenmesi gereklidir. Optimum

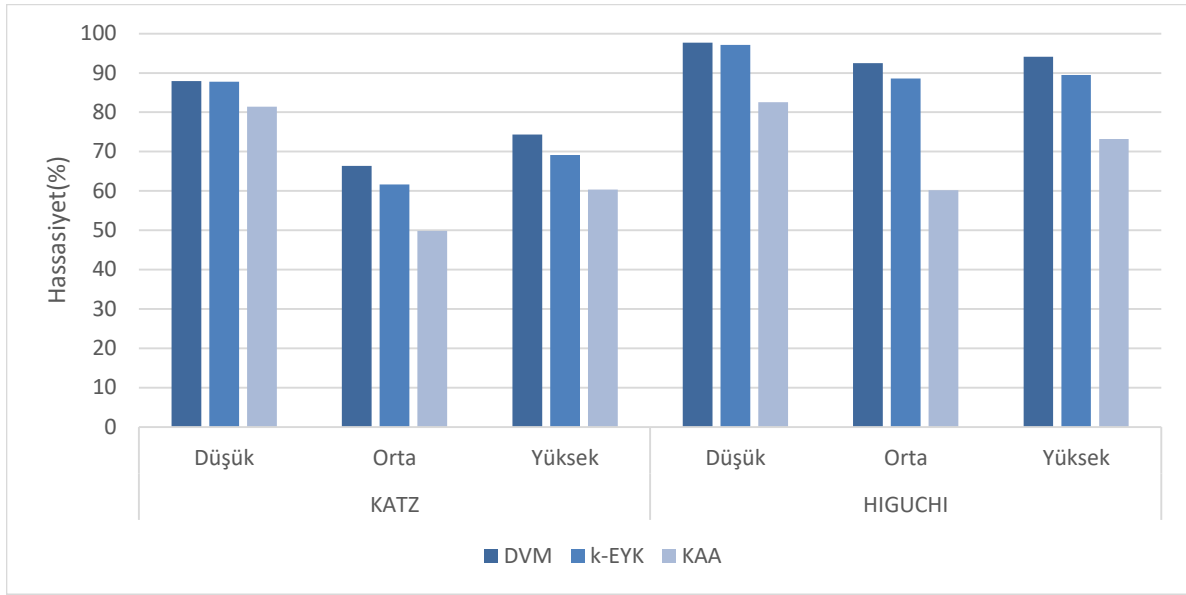


Şekil 4. F7 kanalı üzerinde kaydedilen düşük, orta ve yüksek zihinsel iş yükü seviyeleri için Higuchi fraktal boyut dağılımları (Higuchi's fractal size distributions for low, medium and high mental workload levels recorded on the F7 channel)

parametrelerin belirlenmesi için 10 kat çapraz geçirme uygulanarak ızgara arama yöntemi kullanılmış; optimum sigma ve C parametreleri sırasıyla 2^{-2} ve 2^2 olarak belirlenmiş ve sınıflandırıcıların eğitilmesinde kullanılmıştır.

Çizelge 2. KFB ve HFB için sınıflandırıcı performansları (Classifier performances for KFD and HFD)

| Sınıflandırıcı | Zihinsel İş Yükü Seviyesi | KFB | | HFB | |
|----------------|---------------------------|------------|--------------------------------|------------|--------------------------------|
| | | Hassasiyet | Toplam Sınıflandırma Doğruluğu | Hassasiyet | Toplam Sınıflandırma Doğruluğu |
| DVM | Düşük | % 87.95 | %78.74 | %97.68 | %95.39 |
| | Orta | % 66.40 | | %92.51 | |
| | Yüksek | % 74.36 | | %94.15 | |
| k-EYK | Düşük | % 87.78 | % 75.98 | %97.10 | %92.80 |
| | Orta | % 61.61 | | %88.56 | |
| | Yüksek | % 69.17 | | %89.46 | |
| KDA | Düşük | % 81.42 | % 67.59 | %82.58 | %73.76 |
| | Orta | % 49.88 | | %60.16 | |
| | Yüksek | % 60.35 | | %73.17 | |



Şekil 5. KFB ve HFB algoritmaları için DVM, k-EYK ve KAA sınıflandırıcılarının düşük, orta ve yüksek zihinsel iş yükü sınıf hassasiyet oranları (Low, moderate and high mental workload class sensitivity ratios of SVM, k-NN and QDA classifiers for KFD and HFD)

k-EYK sınıflandırıcısı için kritik parametreler, mesafe ölçütü ve en yakın komşu sayısıdır. Bu çalışmada, mesafe ölçütü olarak Öklid mesafesi; en yakın komşu sayısı ise deneysel olarak belirlenen 7 değeri olarak kullanılmıştır. Sınıflandırıcıların nihai performans değerlendirmesinin yapılması sırasında verilere 10-kat çapraz geçiş uygulanmıştır. Çizelge 2’de Katz ve Higuchi FB kullanılması durumunda, DVM, k-EYK ve KAA sınıflandırıcılar için 10 kat-çapraz doğrulama ile elde edilen ortalama doğruluk ve hassasiyet oranları görülmektedir.

Çizelge 2 incelendiğinde, KFB tabanlı öznelikler ile DVM, k-EYK ve KDA sınıflandırıcıları için toplam sınıflandırma doğruluğu sırasıyla %78.74, %75.98 ve %67.59 olarak belirlenmiştir. Buna göre en yüksek sınıflandırma doğruluğu DVM ile elde edilmiştir. HFB tabanlı öznelikler için elde edilen doğruluk oranları incelendiğinde, DVM k-EYK ve KDA sınıflandırıcıları için sınıflandırma doğruluklarının sırasıyla %95.39, %92.80 ve %73.76 olduğu görülmektedir. Buna göre, her iki fraktal boyut algoritması için de en yüksek sınıflandırma doğruluğu, DVM kullanılarak hazırlanan HDÇK ile elde edilmiştir. En yüksek sınıflandırma doğruluğunu sağlayan DVM sınıflandırıcısı için KFB ve HFB tabanlı öznelikler kullanılması durumunda Cohen’s Kappa değeri sırasıyla 0.52 ve 0.89 olarak hesaplanmıştır. Bu durum, sınıflandırma sonuçlarının veri kümesinden sunulan sınıf etiketleri ile uyuşmasının yüksek olduğunu göstermektedir.

Katz ve Higuchi fraktal boyut algoritmaları ile kullanılan sınıflandırıcılar için, düşük, orta ve yüksek sınıfların hassasiyet oranları Şekil 5’teki grafikte görülmektedir. Şekil 5 incelendiğinde, tüm öznelik-sınıflandırıcı kombinasyonları için en yüksek hassasiyet oranlarının

düşük zihinsel iş yükü seviyesinin ayırt edilmesinde elde edildiği görülmektedir. Orta zihinsel iş yükü seviyesi ise, hem kullanılan FB algoritmaları ve hem de kullanılan sınıflandırıcılar açısından, hassasiyet oranı en düşük seviyedir. Öte yandan, sınıf hassasiyet oranları açısından bakıldığında da HFB algoritmasının, KFB algoritmasına göre daha başarılı bir yöntem olduğu söylenebilir.

Çizelge 3 ve 4’te sırasıyla KFB ve HFB kullanıldığı durumlarda, 10-kat çapraz geçiş işlemi tek bir sınıflandırma aşaması için karmaşıklık matrisi

Çizelge 3. KFB ve DVM’ye dayalı HDÇK için karmaşıklık matrisi (Confusion matrix for KFD and SVM-ECOC)

| Gerçek Sonuçlar | Sınıflandırıcı Çıktıları | | |
|-----------------|--------------------------|-----------------|--------------|
| | Düşük | Orta | Yüksek |
| Düşük | 518 (%88.09) | 43 | 27 |
| Orta | 55 | 218 (%70.77) | 35 |
| Yüksek | 55 | 37 | 276 (%75) |

Çizelge 4. HFB ve DVM’ye dayalı HDÇK için karmaşıklık matrisi(Confusion matrix for HFD and SVM-ECOC)

| Gerçek Sonuçlar | Sınıflandırıcı Çıktıları | | |
|-----------------|--------------------------|-----------------|-----------------|
| | Düşük | Orta | Yüksek |
| Düşük | 578 (%98.29) | 6 | 4 |
| Orta | 12 | 292 (%94.49) | 5 |
| Yüksek | 9 | 8 | 350 (%95.36) |

verilmiştir. Sonuçlar en yüksek sınıflandırma doğruluğunun elde edildiği DVM sınıflandırıcı ile kurulan HDÇK yöntemi üzerinden verilmiştir. Buna göre KFB için, düşük, orta ve yüksek zihinsel yorgunluk seviyeleri sırasıyla, %88.09, %70.77 ve %75 doğrulukla belirlenmiştir. HFB için ise, düşük, orta ve yüksek zihinsel yorgunluk seviyelerinin sınıflandırma doğruluğu sırasıyla, %98.29, %94.49 ve %95.36 olarak elde edilmiştir. Her iki FB algoritması için de en düşük sınıflandırma doğruluğu orta zihinsel yorgunluk seviyesinin belirlenmesinde elde edilmiştir.

düşük, orta ve yüksek zihinsel iş yükü olmak üzere üç sınıfa sınıflandırılmıştır. Çalışmada, öznelik çıkarma yöntemi olarak KFB ve HFB, sınıflandırma işlemi için ise, HDÇK yaklaşımı kullanılmıştır. Önerilen yöntemin performansının karşılaştırılabilmesi için HDÇK kodlamasında DVM, k-EYK ve KAA sınıflandırıcı olarak kullanılmıştır. Zihinsel iş yükünün üç sınıfa ayrılmasında, KFB ve DVM tabanlı HDÇK yöntemi ile %78.74; HFB ve DVM tabanlı HDÇK yöntemi ile %95.29 sınıflandırma doğruluğu elde edildiği görülmektedir. Çalışma sonuçları FB'nin zihinsel iş

Çizelge 5. Aynı veri kümesini kullanan çalışmaların karşılaştırılması (Comparison of studies that use the same data set)

| Çalışma | Yöntem | Doğruluk | Cohen's Kappa |
|-------------------------------|---|----------|---------------|
| Lim ve arkadaşları [18] | HFD- Güç spektral yoğunlukları tabanlı öznelikler, komşuluk komponent analizi ile öznelik seçimi, destek vektör regresyon modeli ile sınıflandırma | %69 | 0.46 |
| Chakladar ve arkadaşları [19] | Güç spektral yoğunlukları, Hurstexponent, istatistiksel öznelikler ve yaklaşık entropi tabanlı öznelikler,GKO tabanlı öznelik seçimi ve hibrit derin sinir ağları ile sınıflandırma | %82.57 | - |
| Bu çalışma | KFB ve DVM dayalı HDÇK | %78.74 | 0.52 |
| | HFB ve DVM dayalı HDÇK | %95.39 | 0.89 |

Çizelge 5'te bu çalışmaya ait sonuçlar, aynı veri kümesini kullanan çalışmalar ile kullandıkları yöntemler ve elde ettikleri doğruluk oranları üzerinden karşılaştırılmıştır. Veri kümesini sağlayan Lim ve arkadaşları [18], Hızlı Fourier Dönüşümü (HFD) ile EEG sinyallerini delta, teta, alfa ve beta bandlarına ayırarak her band için güç spektral yoğunluklarını öznelik olarak kullanmış; komşuluk komponent analizi ile öznelik seçimi yaparak destek vektör regresyon modeli ile verileri sınıflandırmışlardır. Bu çalışmada zihinsel iş yükünün düşük, orta ve yüksek seviyelere sınıflandırma doğruluğu %69 olarak bulunmuştur. Chakladar ve arkadaşları [19], EEG sinyallerinden çıkarttıkları güç spektral yoğunlukları, Hurstexponent, istatistiksel öznelikler ve yaklaşık entropi tabanlı öznelikleri arasından GKO ile en ayırt edici öznelikleri belirlemiş ve hibrit derin sinir ağları ile sınıflandırarak %82.57 sınıflandırma doğruluğuna erişmişlerdir. Bu çalışmada, KFB ve HFB tabanlı öznelikler DVM dayalı HDÇK kullanılarak sınıflandırıldığında, sırasıyla %78.74 ve %95.39 doğruluk oranlarına erişildiği görülmektedir. Çalışmanın sonuçları aynı veri kümesini kullanan çalışmalar ile karşılaştırıldığında, HFB ve DVM ile kurulan HDÇK yönteminin sınıflandırma doğruluğunu arttırdığı söylenebilir.

6. SONUÇ (CONCLUSION)

Zihinsel iş yükü, bir görevin tamamlanması sırasında gerekli olan bilişsel kapasiteyi tanımlar. Zihinsel iş yükünün objektif olarak değerlendirilmesi, özellikle yüksek dikkat gereken durumlar için önem arz eder. Bu çalışmada, zihinsel iş yükü EEG sinyalleri kullanılarak,

yükünün sınıflandırılması için ayırt edici öznelikler olarak kullanılabileceğini; ancak HFB'nin daha yüksek başarımla elde edildiğini göstermiştir. HDÇK yaklaşımında, kullanılan sınıflandırıcılar arasında en yüksek sınıflandırma doğruluğuna DVM kullanılarak erişilmiştir. Bu çalışmada kullanılan tüm yöntemlerde, diğer iki seviyeye göre, en yüksek sınıflandırma hatasının, orta zihinsel iş yükünün sınıflandırmasında (KFB için %66.40, HFB için ise %92.51) olduğu görülmüştür. Bu açıdan sınıflandırma doğruluğunun iyileştirilmesi gerekmektedir.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Eda AKMAN AYDIN: Deneyleri yapmış, deney sonuçlarını analiz etmiş ve makalenin yazım işlemini gerçekleştirmiştir. / Performed the experiments, analyzed the results and wrote the manuscript.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur. / There is no conflict of interest in this study.

KAYNAKLAR (REFERENCES)

- [1] Stasi L.L.D., Antolí A., Cañas J.J., “Evaluating mental workload while interacting with computer-generated artificial environments”, *Entertainment Computing*, 4: 63–69, (2013).
- [2] Charles R.L., Nixon J., “Measuring mental workload using physiological measures: A systematic review”, *Applied Ergonomics*, 74: 221–232, (2019).
- [3] Acı Ç.İ., et.al., “Distinguishing mental attention states of humans via an EEG-based passive BCI using machine learning methods”, *Expert Systems with Applications*, 134: 153–166, (2019).
- [4] Marinescu A., et.al. “Exploring the Relationship between Mental Workload, Variation in Performance and Physiological Parameters”, *IFAC-PapersOnLine*, 49(19): 591–596, (2016).
- [5] Heine T., Lenis G., Reichensperger P., Beran T., Doessel O., Deml B., “Electrocardiographic features for the measurement of drivers' mental workload”, *Applied Ergonomics*, 61:31-43, (2017).
- [6] Jaiswal D., Chowdhury A., Banerjee T., Chatterjee D., “Effect of Mental Workload on Breathing Pattern and Heart Rate for a Working Memory Task: A Pilot Study”, *41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Germany, 2202-2206, 2019.
- [7] Ruscio D., Bos A.J., Ciceri M.R., “Distraction or cognitive overload? Using modulations of the autonomic nervous system to discriminate the possible negative effects of advanced assistance system”, *Accident Analysis and Prevention*, 103: 105–111, (2017).
- [8] Stuiver A., Brookhuis K.A., Waard D., Mulder B., “Short-term cardiovascular measures for driver support: Increasing sensitivity for detecting changes in mental workload”, *International Journal of Psychophysiology*, 92: 35–41, (2014).
- [9] Marquart G., Cabral C., “Winter J., Review of eye-related measures of drivers' mental workload”, *Procedia Manufacturing*, 3: 2854 – 2861, (2015).
- [10] Wang S., Gwizdka J., Chaovalitwongse W.A., “Using Wireless EEG Signals to Assess Memory Workload in the n-Back Task”, *IEEE Transactions on Human-Machine Systems*, 46(3): 424-435, (2016).
- [11] Lohani M., Payne B.R., Strayer D.L., “A Review of Psychophysiological Measures to Assess Cognitive States in Real-World Driving”, *Frontiers in Human Neuroscience*, 13:57, (2019).
- [12] Alonso L.F.N., Gil J.G., “Brain Computer Interfaces, a Review”, *Sensors*, 12:1211-1279, (2012).
- [13] Duru A.D., “Determination of Increased Mental Workload Condition From EEG by the Use of Classification Techniques”, *International Journal of Advances in Engineering and Pure Sciences*, 1: 47-52, (2019).
- [14] Gianluca Di Flumeri G.D., et.al., “EEG-Based Mental Workload Neurometric to Evaluate the Impact of Different Traffic and Road Conditions in Real Driving Settings”, *Frontiers in Human Neuroscience*, 12:509, (2018).
- [15] Wang S., Gwizdka J., Chaovalitwongse W. A., “Using Wireless EEG Signals to Assess Memory Workload in the n-Back Task”, *IEEE Transactions on Human-Machine Systems*, 46(3): 424-435, (2016).
- [16] Qu H., Shan Y., Liu Y., Pang L., Fan Z., Zhang J., Wanyan X., “Mental Workload Classification Method Based on EEG Independent Component Features”, *Applied Science*, 10: 3036, (2020).
- [17] Chin Z.Y., et.al. “EEG-based discrimination of different cognitive workload levels from mental arithmetic”, *40th Annual International Conference of the IEEE (EMBC)*, Honolulu, 1984-1987, (2018).
- [18] Lim W. L., Sourina O., Wang L. P., “STEW: Simultaneous Task EEG Workload Data Set”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26 (11): 2106-2114, (2018).
- [19] Chakladar D.D., Dey S., Roy P.P., Dogra D.P., “EEG-based mental workload estimation using deep BLSTM-LSTMnetwork and evolutionary algorithm”, *Biomedical Signal Processing and Control*, 60 101989, (2020).
- [20] Jacob J.E., Nair G.K., Cherian A., Iype T., “Application of fractal dimension for EEG based diagnosis of encephalopathy”, *Analog Integrated Circuits and Signal Processing*, 100:429–436, (2019).
- [21] Esteller R., Vachtsevanos G., Echauz J., Litt B., “A Comparison of Waveform Fractal Dimension Algorithms”, *IEEE Transactions on Circuits and Systems—I: Fundamental Theory and Applications*, 48(2):177-183, (2001).
- [22] Higuchi T., “Approach to an Irregular Time Series on the Basis of the Fractal Theory”, *Physica D*, 31: 277-283, (1988).
- [23] Khosrowabadi R., Quek C., Ang K.K., Tung S.W., Heijnen M., “A Brain-Computer Interface for classifying EEG correlates of chronic mental stress”, *International Joint Conference on Neural Networks*, USA, 575-562, (2011).
- [24] Guler İ., Ubeyli E.D., “Multiclass Support Vector Machines for EEG-Signals Classification”, *IEEE Transactions on Information Technology in Biomedicine*, 11(2):117-126, (2007).
- [25] Joutsijoki H., et.al., “Error-Correcting Output Codes in Classification of Human Induced Pluripotent Stem Cell Colony Images”, *BioMed Research International*, 2016: 3025057, (2016).
- [26] Cortes, C., Vapnik, V., “Support-vector networks”, *Machine Learning*, 20: 273-297, (1995).
- [27] Bhattacharyya S, Khasnobish A., Chatterjee S., Konar A., Tibarewala D.N., “Performance Analysis of LDA, QDA and KNN Algorithms in Left-Right Limb Movement Classification from EEG Data”, *International Conference on Systems in Medicine and Biology*, India, 126- 131, (2010).
- [28] Naseer N., Qureshi N.K., Noori F.M., Hong K.S., “Analysis of Different Classification Techniques for Two-Class Functional Near-Infrared Spectroscopy-Based Brain-Computer Interface”, *Computational Intelligence and Neuroscience* 2016: 5480760, (2016).
- [29] Aydin E.A., Bay O.F., Guler I., “P300-Based Asynchronous Brain Computer Interface for Environmental Control System”, *IEEE Journal of Biomedical and Health Informatics*, 22(3): 653-663, (2018).
- [30] Kılıç S., “Kappa Testi”, *Journal of Mood Disorders*, 5(3):142-144, (2015).
- [31] Sim J., Wright C.C., “The Kappa Statistic in Reliability Studies: Use, Interpretation, and Sample Size Requirements”, *Physical Therapy*, 85(3): 257–268, (2005).