



# Bilişsel Yorgunluğun EEG İşaretleri ile Sınıflandırılması

## Classification of Cognitive Fatigue with EEG Signals

Ayşe EKİM ve Önder AYDEMİR  
Elektrik-Elektronik Mühendisliği Bölümü  
Karadeniz Teknik Üniversitesi  
Trabzon, Türkiye

ayse-simsek@hotmail.com, onderaydemir@ktu.edu.tr

Mengü DEMİR  
Elektrik-Elektronik Mühendisliği Bölümü  
Karadeniz Teknik Üniversitesi  
Trabzon, Türkiye  
mengudemir@ktu.edu.tr

**Özetçe**— Bilişsel yorgunluk, yüksek zihinsel iş yükü gerektiren veya yorucu bir işin yürütülmesi sırasında uzun süreli zihinsel çabalamanın doğal sonucudur. Bu durum genellikle üretkenlikte azalmaya ve güvenlik risklerinin artmasına yol açar. Bu çalışmada bilişsel yorgunluk, öznel verilere bağlı kalmadan, hızlı ve doğru bir şekilde tespit edilmek istenmiştir. Bunun için CogBeacon veri seti kullanılmıştır. CogBeacon veri setini oluşturan veriler 19 katılımcıdan 76 oturumda, 4 elektrotlu MUSE elektroensefalografi (EEG) cihazı yardımıyla toplanmıştır. Toplanan ham EEG'ler rastgele ayrılarak öznitelik çıkarma işlemi yapılmıştır. Sınıflandırma işleminde Destek Vektör Makinesi (DVM) ve k-En Yakın Komşu (k-EYK) algoritmaları kullanılmıştır. Öznitelik olarak Katz ve Higuchi Fraktal Boyut, standart sapma, medyan, varyans ve kovaryans denenmiştir. DVM ile sınıflandırılma yapıldığında eğitim ortalaması %93.99 ve test ortalaması %83.14 elde edilmiştir. Fractal Boyut özniteliklerinin kullanıldığı denemelerde kullanılan denemelere göre ortalama başarı oranı %4.43 ile %7.40 arasında artmıştır. k-EYK ile sınıflandırma yapıldığında eğitim ortalaması %91.71 ve test ortalaması %83.34 elde edilmiştir. Fractal Boyut özniteliklerinin kullanıldığı denemelerde kullanılan denemelere göre, ortalama başarı oranında %5.10 ile %8.92 arasında artış gözlenmiştir.

**Anahtar Kelimeler** — Bilişsel Yorgunluk; Elektroensefalografi; Katz Fraktal Boyut; Higuchi Fraktal Boyut.

**Abstract**— Cognitive fatigue is the natural result of longtime mental effort during the execution of a high mental workload or a strenuous task. This situation often leads to decreased productivity and increased security risks. In this study, it was aimed to detect cognitive fatigue quickly and accurately, regardless of subjective data. CogBeacon dataset was used for this. Data that make up the CogBeacon dataset were collected from 19 participants in 76 sessions with the help of a 4-electrode MUSE electroencephalography (EEG) device. The collected raw EEGs were randomly separated and feature extraction was performed. Support Vector Machine (SVM) and k-Nearest Neighbor (KNN) algorithms were used in the classification process. Katz and Higuchi Fractal Dimension, standard deviation, median, variance and covariance were tested as features. When the classification was made with SVM, the education average was 93.99% and the test average was 83.14%. The average success rate increased between 4.43% and 7.40%, compared to the trials that were not used in the trials where Fractal Dimension features were used. When the classification was made with KNN, the education average was 91.71% and the test average was 83.34%. The

average success rate increased between 5.10% and 8.92% compared to the trials that were not used in the trials in which Fractal Dimension features were used.

**Keywords** — Cognitive Fatigue; Electroencephalography; Katz Fractal Size; Higuchi Fractal Size.

### I. GİRİŞ

Bilişsel yorgunluk (BY), uygun bilişsel performansı sürdürebilmek için geçici yetersizliktir. BY algısını, beyin retiküler aktivasyon sisteminin algıladığı düşünülmektedir. Herhangi bir bilişsel aktivite sırasında, yorgunluğun başlaması yavaş yavaş belirir ve zamanla daha da hızlanarak devam eder. Bilişsel yorgunluk, sınırlı kaynakların ödenetim kapasitesinin düşmesiyle ortaya çıkan azalmış dikkat olarak da kendini gösterebilir [1]. BY, fiziksel yorgunluktan farklı olsa bile fiziksel yorgunluğa bağlı olarak da ortaya çıkabilen geçici bir durumdur [2].

Fiziksel olarak önemsiz ve geçici bir durum olsa da bilişsel yorgunluk başta araç kullanımı olmak üzere pek çok farklı alanda ölümcül kazalara yol açabilmektedir. Bundan dolayı bilişsel ağırlıklı işlerde çalışanların zihinsel yeterliliklerini analiz etmek için yeni ölçüm tekniklerine ihtiyaç duyulmuştur. Geleneksel bilişsel yorgunluk ölçüm yöntemleri davranışsal indeksleri, tepki süresi, hata oranı veya öznel ölçümler gibi çeşitli metrikleri kullanır. Bu tür ölçüm yöntemleri, nesnel bir bilişsel yorgunluk ölçüm yönteminin gerekli olduğu alanlarda yetersiz kalmaktadır. Yorgunluk seviyelerini objektif olarak değerlendirmenin olası bir yolu, kalp atış hızı değişkenliği, elektrookülografi ve elektroensefalografi (EEG) gibi bilişsel yorgunluk ile önemli ölçüde ilişkili olan fizyolojik değişiklikleri ölçmektir [3]. EEG sinyali üzerindeki spektral analizler, alfa, teta ve beta gücünde kaymaların, bilişsel yorgunluğun tahmini için etkili bir şekilde kullanılabilen sinirsel bir imzası olduğunu ortaya koymuştur [4].

Son zamanlarda bilişsel yorgunluğu tespit etmek için birçok araştırma yapılmıştır. Dehais ve arkadaşları 32 kanallı EEG sistemi ile ölçüm yaparak zihinsel yorgunluk ve zihinsel aşırı yüklemenin elektrofizyolojik etkilerini ölçmek için gerçek uçuş koşulları altında iki deney yapmışlar ve bilişsel yorgunluğun ortaya çıkmasının teta ve alfa bant gücü ile ilişkili olduğunu ortaya koymuşlardır. Sınıflandırma doğruluğu ve zihinsel yorgunluğu ayırt etmede sırasıyla %76.9 ve %89.1'e ulaşmışlardır [5]. Başka bir çalışmada Trejo ve arkadaşları, 16

kişiden 30 kanal üzerinden aldıkları sinyaller üzerinde Bayes analizi uygulanarak 3 durumlu yorgunluk modeli için yakınsak kanıtlar bulmuşlardır [6]. Sun ve arkadaşları bu konuda yaptıkları çalışmada, fonksiyonel-bağlantı tabanlı zihinsel yorgunluk izleme yöntemi geliştirmişlerdir. 26 denekten yüksek çözünürlüklü EEG izleme ile 20 dakikalık zihinsel dikkat testini uygulamışlardır. Uygulamanın ilk ve son 5 dakikalık çeyreklerinde kortikal aktivitelerin kaynak lokalizasyonu ile kortikal yüzeyde fonksiyonel bağlantı paternleri elde edilmiştir. Daha sonra ayrıntılı fonksiyonel bağlantı bilgisini çıkarmak için çok değişkenli desen analizi kullanmışlardır. Mevcut çalışmada kullanılan algoritma, çapraz doğrulama yoluyla yorgunluk sınıflandırması % 81.5'lik genel bir doğruluk göstermiştir [3]. Veri setini kullandığımız Papakostas ise 19 kadın ve erkekten oluşan katılımcıya Wisconsin Kart Sıralama Testi ve bu testin değiştirilmiş halini uygulayarak 76 oturumdan oluşan bilişsel görev uygulamıştır. Görev sırasında kaydettiği EEG sinyallerini kullanarak Destek Vektör Makinası (DVM) Algoritması ile sınıflandırma işlemi yapılmış ve % 67'lik bir doğruluk elde edilmiştir [2].

Bu çalışmada bilişsel yorgunluğun tespiti için EEG İşaretleri kullanılarak farklı öznelikler ve sınıflandırma teknikleri denenmiştir. Elde edilen sonuçlar aynı veri kümesi kullanılarak yapılan diğer çalışmaların sonuçları ile karşılaştırılmıştır.

## II. MALZEME VE YÖNTEMLER

### A. Veri Seti

Bu çalışmada insanların zihinsel faaliyetlerindeki bilişsel yorgunluk izlerini tespit edebilmek amacıyla elde edilmiş olan CogBeacon veri seti kullanılmıştır. Bu veri seti temel olarak deneysel psikoloji alanında önemli yer tutan Wisconsin Kart Sıralama Testi (WCST) ilkelerine dayanmaktadır. Bahsi geçen ilkeler 6'sı kadın 13'ü erkek olmak üzere 19 sağlıklı kişi üzerinde uygulanmış 76 bilişsel görevden oluşmaktadır. Deneklerin hepsi üniversite öğrencisi olup 19 - 33 yaş aralığındadır.

Veri toplama süreci iki aşamada gerçekleşmiştir ve farklı günlerde yapılmıştır. Bir deneyin toplam süresi 25-30 dakika arasındadır. Birinci aşamanın birinci oturumuna orijinal WCST uygulanmış, ikinci oturumda ise değiştirilmiş WCST (V1) tatbik edilmiştir. İkinci aşamanın birinci oturumunda orijinal WCST uygulanırken ikinci oturumunda ise başka bir değiştirilmiş WCST (V2) tatbik edilmiştir.

Her iki aşamaya da aynı katılımcılar katılmıştır. Deney esnasında katılımcıların EEG sinyalleri 2'si prefrontal lob üzerinden, 2'si kulak arkasından olmak üzere 4 farklı noktadan alınmıştır. Toplamda 6946 veri kaydedilmiş ve kaydedilen verilerden 2160 tanesi yorgun, 4786 tanesi yorgun değil olarak ayrılmıştır [2]. Aşağıda deneyin uygulanma süreci adım adım anlatılmıştır.

1. Adım: Orijinal WCST deneklere anlatılmıştır (~5dk).
2. Adım: Orijinal WCST uygulanmıştır (~4 ile 7dk).
3. Adım: Öznel yorgunluğu bildirmek için bir anket yapılmıştır (~2dk).
4. Adım: Araştırmacılar tarafından değiştirilmiş WCST (V1 ve V2) testleri deneklere anlatılmıştır (~3dk).

5. Adım: WCST'nin değiştirilmiş sürümü (V1 ve V2) gerçekleştirilmiştir (~7 ile 9dk).

6. Adım: Deneyin tamamlanmasından sonra öznel yorgunluğu bildirmek için anket yapılmıştır (~2dk).

### B. Öznelik Çıkarımı

Bu çalışmada Şekil 1'de gösterildiği gibi her bir kanal üzerinden alınan EEG sinyalleri üzerinde aşağıda bahsi geçen yöntemler uygulanarak öznelikler elde edilmiştir. Daha sonra sınıflandırma doğruluğu sonuçları elde edilmiştir.



Şekil 1: İş Akış Şeması

1) *Katz Fraktal Boyut*: Fraktal boyut, bir veri veya miktarın karmaşıklığını gösteren, bazı sinyal veya zaman serileri alanına benzer olan istatistiksel bir ölçüdür. Bir fraktal modeldeki detayların farklı ölçeklerde değişebileceği gösterilebilir. Tipik olarak sinyal işlemede, daha yüksek fraktal boyut değeri daha karmaşık sinyale karşılık gelirken, daha düşük fraktal boyut değeri sinyalin daha basit olduğu anlamına gelir.

Katz, Fraktal boyutun (Kfb) hesaplanması için birbirini izleyen iki nokta arasındaki mesafe hesaplandığından, daha az hesaplama karmaşıklığına sahip fraktal boyutu hesaplamak için bir algoritma önermiştir. Bu mesafe, tek boyutlu zaman serileri olarak temsil edilen sinyaldeki düzensizliğin bir ölçüsü olarak düşünülebilir. Zaman serisi  $X(1), X(2), \dots, X(N)$  maksimum mesafesi için başlangıç noktasından  $d$  olarak eşitlik (1) de görüldüğü gibi hesaplanır [7].

$$d = (|X_1 - X_j|), \quad j = 2, 3, \dots, N \quad (1)$$

Serinin toplam uzunluğu:

$$L = \sum_{(x=2)}^N X_i - X_{i-1} \quad (2)$$

Birbirini izleyen iki nokta arasındaki ortalama mesafe:

$$a = \frac{L}{N-1} \quad (3)$$

Katz'ın Fraktal boyut hesabı:

$$Kfb = \frac{\ln \frac{L}{a}}{\ln \frac{L}{a}} \quad (4)$$

2) *Higuchi Fraktal Boyut*: Higuchi, doğrudan zaman serilerinden fraktal boyutu bulmak için Higuchi Fraktal boyut (Hfb) algoritmasını geliştirdi. Orijinal zaman serisi  $X(1), X(2), \dots, X(N), X_m^k$  zaman serisi  $X_m^k(X(m), X(m+k), X(m+2k), \dots), X(m + \text{int}(\frac{N-m}{k}) * k)$   $m = 1, 2, 3, 4, \dots, k$  olarak tanımlanır [7].

Burada  $m$  başlangıç zamanı ve  $k$  zaman aralığıdır. Eğrinin uzunluğu  $L_m(k)$  olarak gösterilir.

$$L_m(k) = \frac{\sum_{i=1}^{\text{int}(\frac{N-m}{k})} |X(m+ik) - X(m+(i-1)k)| * (n-1)}{k * \text{int}(\frac{N-m}{k})} \quad (5)$$

Burada,  $N$  toplam örnek sayısıdır. Eğrinin uzunluğu  $L_m(k)$ ,  $k$  değerlerinin ortalama değeri olarak alınır.

Fraktal boyut, bu tür nesnelere ve miktarları karakterize etmek için çeşitli alanlarda başarıyla kullanılmıştır, ancak EEG uygulamalarında kullanımı daha yeni olmuştur. Daha iyi bir sınıflandırma doğruluğu hızla elde etmek için, en uygun fraktal boyut tahmin yöntemi kullanılır [8].

3) *Standart Sapma*: Varyans değerinin karekökü Standart sapma (S) değerini verir [9]. Verilerin ortalamaya göre yayılmasını gösteren istatistiksel bir ölçüdür. Burada n alınan örneklem büyüklüğü sayısıdır.

$$S = \sqrt{\frac{\sum_{i=1}^n (X_i - \mu)^2}{n}} \quad (6)$$

4) *Medyan*: Verilerin dağılımında uç noktalarının etkisini dikkate almak için medyan (M) hesaplanır. Küçükten büyüğe sıraladıktan sonra tam ortada kalan değerdir. Veriler  $\{X_1, X_2, \dots, X_N\}$  ve N veri sayısı olmak üzere eşitlik (8)'deki gibi hesaplanır [10].

$$M = \begin{cases} \frac{X_{\frac{N}{2}} + X_{\frac{N}{2}+1}}{2} & N \text{ çift ise} \\ \frac{X_{\frac{N+1}{2}}}{2} & N \text{ tek ise} \end{cases} \quad (8)$$

5) *Varyans*: Bir veri setinin nasıl dağıldığının ölçüsü varyans (V)'dir. Düşük varyans, verilerin uyumlu olduğunun bir göstergesidir. Burada n alınan örneklem büyüklüğü sayısıdır.

$$V = \frac{\sum_{i=1}^n (X_i - \mu)^2}{n} \quad (9)$$

6) *Kovaryans*: Kovaryans (K) iki değişkenin birlikte değişimlerini incelemenin bir ölçüsüdür. Kovaryans hesabı eşitlik (10)'daki gibi yapılmaktadır. Eşitlikteki x ve y değişkenleri ifade etmektedir. N örnek sayısıdır.  $x_i, y_i$  i'nci örnek ve  $\bar{x}, \bar{y}$  örneklerin ortalama değerini temsil etmektedir.


$$K = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{N-1} \quad (10)$$

### C. Sınıflandırma

1) *k-En Yakın Komşu Algoritması*: Sınıflandırıcılar arasında en çok bilinen ve uygulaması en kolay olanıdır. k-EYK algoritması, eğitim veri setinde bulunan daha önceden sınıflı belirlenmiş özellik vektörleri ile sınıflandırmasını yapmak istediğimiz özellik vektörünü karşılaştırma ölçütleri kullanarak en yakın olan özelliklere göre bir sınıfa dahil etme işlemidir. Karşılaştırma ölçütü olarak genellikle Öklid mesafesi hesaplanmaktadır. Eşitlik (11)'de bu bağıntı verilmiştir. Kullanıcılar tarafından belirlenen k değeri, k-EYK algoritmasında sınıflandırılmak istenen test verisine en yakın k adet komşuyu ifade etmektedir [11].

$$d_{öklid} = (x, y) = \sqrt{\sum_i (x_i - y_i)^2} \quad (11)$$


Eşitlik (11)'de  $x_i = x_1, x_2, x_3 \dots x_m$  ve  $y_i = y_1, y_2, y_3 \dots y_m$  m nitelik değerlerinin iki kaydı göstermektedir. Örneğin k=1 ise sınıflandırılmak istenen veri için bir komşu değerine bakılır ve en yakın mesafedeki sınıfa atanır. k değeri birden fazla olduğu durumlarda test verisi için k değeri kadar komşu değere bakılır ve en yakın mesafedeki sınıflardan hangisi fazla ise test verisi o sınıfa atanır. [12].



Şekil 2: k-En yakın komşu sınıflandırma örneği

Şekil 2'de verilen örnekte yeşil daire test verisini, kırmızı üçgenler sınıf1'i ve mavi kareler ise sınıf2'yi temsil etmektedir. Eğer k=3 olarak verilirse; en yakın üç komşu değere bakılır. Şekil2'de de görüldüğü üzere çember içinde en yakın üç komşu değerlerden kırmızı üçgen sayısı mavi kare sayısından fazla olduğu için test verisi sınıf1'e atanır. Eğer k=5 olarak verilirse; en yakın beş komşu değere bakılır. Şekil2'de kesikli çizgili içinde en yakın beş komşu değerden mavi kare sayısı kırmızı üçgen sayısından fazla olduğu için test verisi sınıf2'ye atanır.

2) *Destek Vektör Makinesi Algoritması*: Son zamanlarda geliştirilmiş olan makine öğrenmesi algoritmaları arasında en başarılılarından birisidir. DVM algoritması birçok sınıflandırma problemlerinin çözümünde doğruluğu yüksek sonuçlar vermiştir [13]. DVM algoritmasındaki amaç iki sınıfa ait veri grubunu bir düzlem ile ayırmaktır. Her iki gruba da yakın olacak şekilde destek vektörleri adı verilen iki paralel çizgi belirlenir. Sınıflandırıcı, belirlenen destek vektörlerini kullanarak uygun mesafede verileri ayırt edici bir düzlem belirler (Şekil3). DVM algoritmaları ile çoğu veriyi doğrusal olarak ayırmak sorun oluşturur. Bu sorunu ortadan kaldırmak için veri seti doğrusal olmayan dönüşümlerle yüksek boyutlu bir uzaya çekirdek fonksiyonları kullanılarak aktarılır. Böylece veri seti doğrusal bir düzlem ile ayrılabilir hale gelmiş olur [14].



Şekil 3: Destek Vektör Makineleri destek vektörleri ve ayırım düzlemi

### III. SONUÇLAR VE TARTIŞMA

CogBeacon veri setini kullanarak yaptığımız çalışmamızda ham EEG'ler % 50 eğitim, % 50 test verisi olarak rastgele ayrılmıştır. Öznitelik çıkarma işlemi yapılarak DVM ve k-EYK sınıflandırıcıları kullanılarak sınıflandırma işlemi yapılmıştır. Öznitelik çıkarma işlemi gerçekleştirilirken öznitelikler önce tek tek, sonra birkaçı birlikte ve en son hepsi birlikte denlenmiştir. Geliştirilen bu algoritmalar 100 kez tekrarlanmış ve elde edilen başarı oranlarının ortalaması deney olarak kaydedilmiştir. Elde edilen değerler Tablo 1'de değişen özniteliklere göre sınıflandırıcılara ait eğitim ve test ortalamaları ayrıntılı bir şekilde yer almaktadır.

Tablo 1: Sınıflandırıcı Doğrulukları

No	Öznitelikler						Başarı Oranları			
							DVM Başarı Oranları		k-EYK Başarı Oranları	
							Eğitim Ort.	Test Ort.	Eğitim Ort.	Test Ort.
1	+						74.75	66.65	78.90	61.18
2		+					89.56	71.12	81.73	67.20
3			+				86.41	70.02	83.06	68.43
4				+			89.21	70.84	83.96	69.92
5					+		93.28	79.31	89.61	80.35
6						+	90.95	74.25	85.28	72.84
7	+	+					88.18	73.71	84.42	71.15
8	+		+				85.11	71.31	84.32	70.60
9	+			+			87.42	73.00	85.61	72.67
10	+				+		91.42	80.60	89.76	80.34
11	+					+	88.16	76.22	86.06	74.44
12	+	+	+				89.30	75.89	86.62	74.92
13	+	+		+			90.51	76.97	87.45	75.98
14	+	+			+		93.61	81.15	90.46	81.01
15	+	+				+	91.70	79.09	88.77	78.67
16	+	+	+	+			89.83	76.81	87.48	76.13
17	+	+	+		+		93.68	81.45	90.98	81.94
18	+	+	+			+	92.31	80.41	89.67	80.11
19	+	+	+	+	+		93.45	81.48	90.65	81.54
20	+	+	+	+		+	93.17	81.54	90.52	81.45
21					+	+	92.99	81.74	90.02	80.73
22	+	+	+	+	+	+	93.99	83.14	91.71	83.34

Tabloda görüldüğü üzere DVM sınıflandırıcısı başarı oranları eğitim ortalaması % 74.75 ile % 93.99 arasında değişmektedir. Test ortalaması ise % 66.65 ile % 83.14 arasında değiştiği görülmektedir. Kullandığımız öznitelikler tek tek denendiğinde doğrulama ortalamasının düşük elde edildiği, öznitelikler birlikte kullanıldığında bu değer arttığı gözlemlenmiştir. Özellik olarak Fraktal Boyut öznitelikleri kullanıldığında kullanılan deneylere göre eğitim ortalamasında % 4.43 ve test ortalamasında % 7.40 değerinde bir artış görülmektedir. Özniteliklerin tamamı bir arada kullanıldığında eğitim ortalaması %93.99 iken test ortalaması %83.14 olarak en iyi sonuçlar elde edilmiştir.

k-EYK sınıflandırıcısı başarı oranları ise eğitim ortalaması %78.90 ile %91.71 ve test ortalaması % 61.18 ve 83.34 arasında değişmektedir. Aynı işlemler k-EYK sınıflandırıcısı içinde uygulanmış olup öznitelikler tek tek uygulandığında doğrulama ortalaması düşerken birlikte kullanıldığında doğrulama ortalaması yükselmiştir. Fraktal Boyut öznitelikleri kullanıldığında eğitim ortalamasında % 5.10 ve test ortalamasında % 8.92'lik bir artış görülmektedir. Özniteliklerin tamamı bir arada kullanıldığında eğitim ortalaması % 91.71 ve test ortalaması % 83.34 olarak elde edilmiştir.

Çalışmamızda veri setini kullandığımız Papakostas çalışmasında öznitelik olarak ortalama değer, standart sapma, maksimum değer, minimum değer, spektral sentroid ve spektral rollof kullanılmıştır. 10 kat çapraz doğrulama yapılarak verileri belirlenmiş ve Gauss Dairesel Tabanlı İşlev Çekirdeği, Rastgele Ormanlar, Ekstra Ağaçlar, Gradyan Yükselten DVM'leri denemiştir. Ortalama % 67 doğruluk elde etmiştir. Bizim çalışmamızda öznitelik olarak varyans, ortalama değer, covaryans, standart sapma, Katz Fraktal Boyut ve Higuchi Fraktal Boyut özniteliklerini kullanıldı. Verilerimiz rastgele belirlendi ve DVM sınıflandırıcısı kullanıldığında test

ortalaması % 83.14 k-EYK sınıflandırıcısı kullanıldığında test ortalaması % 83.34 elde edildi. Sonuçlardan anlaşıldığı üzere k-EYK sınıflandırıcısı DVM sınıflandırıcısına göre daha iyi sınıflandırma işlemi yaptığı söylenebilir. Kullanılan öznitelikler arasında Fraktal Boyut öznitelikleri her iki sınıflandırıcı için de daha iyi sonuçlar elde etmemizi sağlamıştır. Bu verilere dayanarak bilişsel yorgunluğu tespit etmek için Fraktal Boyut öznitelikleri tercih edilebilir.

#### KAYNAKLAR

- [1] D. Chuckravanen, "Approximate Entropy as a Measure of Cognitive Fatigue: An EEG Pilot Study," *Int. J. Emerg. Trends Sci.*, vol. 10, no. 1, pp. 1036-1042, 2014, [Online]. Available: <http://ijetst.in/ems/index.php/ijetst/article/view/304>.
- [2] M. Papakostas, A. Rajavenkatanarayanan, and F. Makedon, "CogBeacon: A Multi-Modal Dataset and Data-Collection Platform for Modeling Cognitive Fatigue," *Technologies*, vol. 7, no. 2, p. 46, Jun. 2019, doi: 10.3390/technologies7020046.
- [3] Y. Sun, J. Lim, J. Meng, K. Kwok, N. Thakor, and A. Bezerianos, "Discriminative Analysis of Brain Functional Connectivity Patterns for Mental Fatigue Classification," *Ann. Biomed. Eng.*, vol. 42, no. 10, pp. 2084-2094, 2014, doi: 10.1007/s10439-014-1059-8.
- [4] F. Dehais *et al.*, "Monitoring Pilot's Cognitive Fatigue with Engagement Features in Simulated and Actual Flight Conditions Using an Hybrid fNIRS-EEG Passive BCI," *Proc. - 2018 IEEE Int. Conf. Syst. Man, Cybern. SMC 2018*, pp. 544-549, 2019, doi: 10.1109/SMC.2018.00102.
- [5] F. Dehais, B. Somon, T. Mullen, and D. E. Callan, "A Neuroergonomics Approach to Measure Pilot's Cognitive Incapacitation in the Real World with EEG: A Neuroergonomics Approach to Measure Pilot's Cognitive Incapacitation in the Real World with EEG. Introduction Operating aircrafts is a complex activit," no. March, 2020.
- [6] L. J. Trejo *et al.*, "LNAI 4565 - EEG-Based Estimation of Mental Fatigue: Convergent Evidence for a Three-State Model," 2007.
- [7] J. E. Jacob, G. K. Nair, A. Cherian, and T. Iype, "Application of fractal dimension for EEG based diagnosis of encephalopathy," *Analog Integr. Circuits Signal Process.*, vol. 100, no. 2, pp. 429-436, 2019, doi: 10.1007/s10470-019-01388-z.
- [8] H. Siamaknejad, W. S. Liew, and C. K. Loo, "Fractal dimension methods to determine optimum EEG electrode placement for concentration estimation," *Neural Comput. Appl.*, vol. 31, no. 3, pp. 945-953, 2019, doi: 10.1007/s00521-017-3126-1.
- [9] M. Yazici and M. Ulutas, "Classification of EEG signals using time domain features," pp. 2358-2361, 2015, doi: 10.1109/siu.2015.7130354.
- [10] Ö. Türk and M. S. Özerdem, "Epileptik EEG Sinyallerinin Sınıflandırılması için Bir Boyutlu Medyan Yerel İkili Örtüntü Temelli Öznitelik Çıkarımı One Dimensional Median Local Binary Pattern Based Feature Extraction for Classifying Epileptic EEG Signals," *GUJ Sci, Part C*, vol. 5, no. 3, pp. 97-107, 2017.
- [11] B. Yılmaz, E. Arıkan, M. H. Asyalı, E. M. Bölümü, and B. M. Birimi, "Tek Kanallı EKG Kayıtlarından Uyku Evrelemesi Yapılmasında kNN ve Kuadratik Diskriminant Analizi Yöntemlerinin Kullanılması Use of kNN and Quadratic Discriminant Analysis Methods for Sleep Staging from Single Lead ECG Recordings," pp. 0-3, 2010.
- [12] S. Çamalan, G. Şengül, "Yerel İkili Örtüntü Özellikleri ve En Yakın K Komşu ve Diskriminant Analiz Sınıflandırıcılarını Kullanarak Cinsiyet Tahmini Gender Prediction by Using Local Binary Pattern and K Nearest Neighbor and Discriminant Analysis Classifications" Bilişim Sistemleri Mühendisliği Bölümü, Bilgisayar Mühendisliği Bölümü, Atılım Üniversitesi, Ankara, Türkiye
- [13] M. B. Terzi and O. Arıkan, "Akut Miyokard İskemisinin Destek Vektör Makinelerine Dayalı Tespiti Detection of Acute Myocardial Ischemia Based on Support Vector Machines," pp. 8-11.
- [14] R. Uzun, Y. İşler, and M. Toksan, "Sigil Tedavi Yöntemlerinin Başarısının Tahmininde Destek Vektör Makineleri Kullanımı Use of Support Vector Machines to Predict the Success of Wart Treatment Methods," pp. 31-34, 2018.