



AUTOMATIC EEG EMOTION RECOGNITION METHOD BASED ON MULTI-LEVEL WAVELET TRANSFORM AND LOCAL BINARY PATTERNS

Merve Akay^{*1} , Türker Tuncer¹ 

¹Firat University, Faculty of Technology Department of Digital Forensics Engineering, Elazığ, Turkey

Abstract

Original scientific paper

Electroencephalogram (EEG) signals have been considered to diagnose several brain and neurologic disorders. Moreover, the brain generated characteristic EEG signals according to the situation. Therefore, EEG signals have been used to detect emotional state and several EEG-based automated emotion detection models have been presented in the literature. In this work, a new automated EEG emotion detection model presented using multilevel discrete wavelet transform, local binary pattern, neighborhood component analysis, and k nearest neighbor classifier. The phases of the presented EEG classification model are; (i) the used EEG signals are divided into five equal non-overlapping segments, (ii) frequency coefficients are generated using multilevel discrete wavelet transform, (iii) local binary pattern generates features from raw EEG segment and frequency coefficients, (iv) feature selection using neighborhood component analysis, (v) classification and (vi) hard majority voting. We used the GAMEEMO dataset to test our proposal. This EEG emotion corpus contains 14 channels and channel-wise results were calculated. Our proposal reached perfect classification rate (100.0%) on the GAMEEMO dataset. Moreover, the average accuracy value obtained from all channels was obtained as 99.36%. These results clearly denoted the high classification ability of our model on the EEG signals for emotion classification.

Keywords: Majority voting, multilevel wavelet transform, EEG emotion recognition, local binary pattern,

ÇOK SEVİYELİ DALGACIK DÖNÜŞÜMÜ VE YEREL İKİLİ ÖRÜNTÜLER TABANLI OTOMATİK EEG DUYGU TANIMA YÖNTEMİ

Özet

Orijinal bilimsel makale

Elektroensefalogram (EEG) sinyallerinin çeşitli beyin ve nörolojik bozuklukları teşhis ettiği düşünülmektedir. Ayrıca beyin duruma göre karakteristik EEG sinyalleri üretir. Bu nedenle, duygusal durumu tespit etmek için EEG sinyalleri kullanılmış ve literatürde birçok EEG tabanlı otomatik duygu algılama modeli sunulmuştur. Bu çalışmada, çok düzeyli ayrık dalgacık dönüşümü, yerel ikili desen, komşuluk bileşen analizi ve k en yakın komşu sınıflandırıcı kullanılarak yeni bir otomatik EEG duygu algılama modeli sunulmuştur. Sunulan EEG sınıflandırma modelinin aşamaları; (i) kullanılan EEG sinyalleri beş eşit örtüşmeyen bölüme bölünmüştür, (ii) frekans katsayıları çok düzeyli ayrık dalgacık dönüşümü kullanılarak üretilmiştir, (iii) yerel ikili desen ham EEG bölümü ve frekans katsayılarından özellikler üretir, (iv) komşuluk bileşen analizi kullanarak özellik seçimi, (v) sınıflandırma ve (vi) katı çoğunluk oylaması. Yöntemimizi test etmek için GAMEEMO veri kümesini kullandık. Bu EEG duygu veri seti 14 kanal içerir ve kanal bazında sonuçlar hesaplanmıştır. Önerimiz, GAMEEMO veri kümesinde mükemmel sınıflandırma oranına (% 100.0) ulaştı. Ayrıca, tüm kanallardan elde edilen ortalama doğruluk değeri 99.36% olarak elde edilmiştir. Bu sonuçlar, modelimizin duygu sınıflandırması için EEG sinyalleri üzerindeki yüksek sınıflandırma yeteneğini açıkça gösterdi.

Anahtar Kelimeler: Çoğunluk oylaması, çok seviyeli dalgacık dönüşümü, EEG duygu tanımı, yerel ikili örüntü

1 Giriş

Duygu, dış uyaranlara tepki olarak tanımlanabilen ve insan bilincini temsil eden [1], bireyin düşüncelerinden oluşur. Duygular, insanların düşünürken, iletişim kurarken, öğrenirken ve karar verirken dış uyaranlara verdikleri tepkiler olarak ifade edildiğinden, insanların günlük

yaşamındaki davranışlarını belirlemede temel bir rol oynar. [2]

İnsan duygularının daha iyi tanınması, etkili iletişime yol açacaktır. Duygu tanıma, hastanelerde, akıllı evlerde ve akıllı şehirlerde IOT(nesnelerin interneti) ve akıllı ortamların tanıtılmasıyla son zamanlarda ilgi görmüştür [3] ve teknolojinin artması bu sistemlerin mobil

* Corresponding author.

E-mail address: 182144105@firat.edu.tr (M. Akay)

Received 29 March 2021; Received in revised form 25 May 2021; Accepted 29 June 2021

2587-1943 | © 2021 IJIEA. All rights reserved.

Doi: <https://doi.org/10.46460/ijiea.904838>

sistemlerde[4-6] sağlık hizmetleri [7, 8] eğitim[9, 10] gibi farklı alanlarda kullanılmasını sağlamıştır.

Son zamanlarda EEG, beyin bilgisayar arayüzü sistemlerinde önemli bir rol oynadı. Chen vd. [4] beynin aktivite sensörleri sayesinde elde edilen kayıtların analizi sonucu epilepsi nöbetlerinin tespit edilmesi ile ilgili çalışma yaptı.

EEG, epilepsi tanısının konulmasında, kesin epilepsi tanısı almış hastaların sınıflaması, uygun tedavi seçimi ve prognoz belirlenmesinde ve hastalığın seyrinin takibinde kullanılan en değerli inceleme yöntemidir. Sadece mental durum bozukluğu ile karakterize nonkonvülfiz status epileptikus (NKSE) tablosunun tanısı için tanı koydurucu tek inceleme yöntemi iken yavaş virüs hastalıkları, herpes simpleks ensefaliti ve hepatik ensefalopati gibi bazı özel tabloların tanısı ve takibinde de çok önemli ipuçları sağlar.

Ayrıca uyku ve bozuklukları ile beyin ölümünün değerlendirilmesinde de EEG kullanılır[5].

Geçmiş ve günümüzde yapılan çalışmalar incelendiğinde EEG sinyalleri kontrol edilemediği için daha doğru sonuç vermesi amacıyla bu sinyaller üzerinden duygu tanıma seçilmiştir. Son zamanlarda duygu tanıma işleminin sağlıklı olabilmesi için başvurulan yöntem beyin sinyallerine dayalı duygu tahmini araştırmaları hız kazanmıştır. Ses ve yüz verileri kullanılarak duygu tanımayla ilgili yapılan çalışmalar vardır ancak ses, yüzlerin kontrol edilebilir olması sebebiyle doğru sonuçların elde edilemeyeceği aşikârdır. Bu sebepten dolayı duygusal ve bilişsel durumu anlayıp, anlamlı sinyale dönüştüren yöntemin duygu tanıma amaçlı kullanılması doğruluk düzeyini artıracaktır. EEG tabanlı duygu tanıma çalışmalarının birkaçı Tablo 1’de özetlenmiştir.

Tablo 1. Literatür taraması

Makale	Yöntem	Veriseti	Doğruluk değeri(%)
Li vd.[6]	Destek Vektör Makineleri	DEAP SEED	59.06 83.33
Shawky vd. [7]	3 Katmanlı Evrişimsel Sinir Ağı	DEAP	87.44, 88.49
Pandey vd. [8]	Varyasyonel Mod Ayırıştırma Derin Sinir Ağı	DEAP	62.50, 61.25
Lan vd. [9]	Diferansiyel Entropi Etki Alanı Uyarılma Tekniği	DEAP SEED	48.93 54.73
Qing vd. [10]	Karar Ağacı K-En Yakın Komşu Rastgele Orman	DEAP SEED	62.63 74.85
Yin vd. [11]	Yerel Olarak Sağlam Özellik Seçimi	DEAP	65, 68
Gao vd. [12]	Destek Vektör Makineleri Alaka Vektör Makineleri	DEAP	89.17, 91.18
Alakus vd. [1]	Ayrık Dalgacık Dönüşümü Vektör makineleri desteklemek K-En Yakın Komşu Çok Katmanlı Algılayıcı Sinir Ağı	GAMEEMO	72.73
Hassouneh vd. [3]	Evrişimsel Sinir Ağı Uzun Kısa Süreli Bellek	Veri toplama	99.81
Wei vd. [13]	Tekrarlayan Sinir Ağı Basit Tekrarlayan Birimler Çift Ağaçlı Karmaşık Dalgacık Dönüşümü	SEED	80.02
Naser vd. [14]	Güç Spektral Yoğunluğu Çift Ağaçlı Karmaşık Dalgacık Paket Dönüşümü K-Katlı Çapraz Doğrulama Destek Vektör Makineleri	DEAP	22.50, 14.87, 19.44
Er vd. [2]	Hızlı Fourier Dönüşümü Veri Arttırma Süreci (Rastgele Döndürme, Kesme, Renk, Kaydırma, Gauss Filtresi, Tuz Biber Gürültüsü) Evrişimsel Sinir Ağı	Kendi verisetleri	73.28
Tuncer vd. [15]	Fraktal Fırat Deseni, Ayarlanabilir Q-Faktörü Dalgacık Dönüşümü, Doğrusal Ayrımcı K-En Yakın Komşu Destek Vektör Makineleri	GAMEEMO	99.82
Ghosh vd. [16]	3 Katmanlı Evrişimsel Sinir Ağı	Veri toplama	95
Cheng vd.[17]	GCFORREST	DEAP DREAMER	97.69, 97.53 89.03, 90.41, 89.89

2 Kullanılan EEG Veriseti

Bu çalışmada, 14 kanallı EMOTIV EPOC + adı verilen giyilebilir ve taşınabilir bir EEG cihazı ile 4 farklı

bilgisayar oyunu oynayan, 28 farklı kişiden toplanan GAMEEMO [1] veri seti kullanılmıştır. Kullanılan veri seti Tablo 2'deki gibidir.


Tablo 2. Verisetinin özellikleri

Özellik	Değer
Sinyal türü	EEG
Cihaz Kanalı	14 kanal EMOTIV EPOC+
EEG elektrotları	16 farklı kafa derisi bölgesi
Sinyallerin bant genişliği	0.16Hz-43Hz.
Her EEG sinyalinin uzunluğu	38252
Oyun türü	4 farklı bilgisayar oyunu: • Komik • Sıkıcı • Korku • Sakin
Kişi sayısı	28

3 Önerilen Yöntem

Bu yöntemin temel amacı basit ve efektif yöntemleri bir arada kullanarak yüksek doğruluğa sahip bir EEG duygu tanıma yöntemi önermektir. Bu nedenle literatürde sıklıkla kullanılan elle özellik çıkarma yöntemlerinden birisi olan bir boyutlu yerel ikili örüntüler (BBYİÖ) [18, 19] kullanılmıştır. Ancak, BBYİÖ sadece alçak seviyeli özellikler çıkarmaktadır. Bu problemi çözmek için ayrı dalgacık dönüşümü (ADD) [20, 21] kullanılarak frekans katsayıları elde edilmiştir ve elde edilen frekans katsayıları kullanılarak çok seviyeli bir özellik çıkarma modeli oluşturulmuştur. BBYİÖ hem frekans alanında hem de uzaysal alanda özellikler çıkarılır. Çıkarılan özelliklerden en belirgin olanları seçmek için komşuluk bileşen analizi (KBA) [22, 23] kullanılır. Önerilen yöntem 4 seviyeli ADD kullanarak 4 adet alçak geçiren filtre katsayısı oluşturmuştur. BBYİÖ her bir sinyalden 256 özellik çıkarmaktadır. Bu nedenle, toplamda 256 x 5=1280 uzunluğundaki özellik vektörü elde edilir ve KBA en belirgin 256 özelliği seçer. Seçilen 256 özellik k en K-En Yakın Komşu [24, 25] sınıflandırıcısı kullanılarak sınıflandırma sonuçları elde edilir.

Önerilen yöntemin blok diyagramı Şekil 1'deki gibi verilmiştir.



Şekil 1 Önerilen yöntemin blok diyagramı

Yöntemi daha basit bir şekilde açıklamak için adımlar tanımlanmıştır ve tanımlanan adımlar verilmiştir.

Adım 0: GAMEEMO veri setini yükle.

Adım 1: Her bir kanala ait her bir EEG sinyalini oku.

Adım 2: Okunan EEG sinyallerini 5 eşit parçaya böl ve gözlem sayısını 112' den 560'a çıkar.

Adım 3: Her bir gözleme 4 seviyede ADD uygula. Bu aşamada ana dalgacık filtresi olarak symlet 4 kullanılmıştır.

$$[L^1, H^1] = ADD(s) \quad (1)$$

$$[L^k, H^k] = ADD(L^{k-1}), k \in \{2,3,4\} \quad (2)$$

Eşitlik 1 ve 2 kullanılan çok seviyeli ayrı dalgacık dönüşümünü ifade etmektedir. Eşitliklerde (Eşitlik 1 ve 2), s EEG sinyalini, L^k, H^k sırasıyla k . alçak geçiren ve yüksek geçiren frekans katsayılarını, $ADD(.)$ bir boyutlu ayrı dalgacık dönüşümü fonksiyonunu ifade etmektedir.

Adım 4: BBYİÖ kullanılarak EEG sinyalinden (gözlem) ve her bir gözlemden 256 özellik çıkar. BBYİÖ literatürde sıklıkla kullanılan özellik çıkarma yöntemlerinden birisidir. Bu yöntemin en önemli özellikleri şu şekilde sıralanmaktadır. Uygulanması basit bit yöntemdir, sinyal boyutundan bağımsız özellik çıkarır ve çıkardığı özelliklerin sınıflandırma kapasitesi yüksektir. BBYİÖ yönteminin sözde kodu Algoritma 1' de verilmiştir.

BBYİÖ ve ADD tabanlı çok seviyeli özellik çıkarma yöntemi Eşitlik 3-4' te açıklanmıştır.

$$f^1 = BBYIO(s) \quad (3)$$

$$f^{t+1} = BBYIO(L^t), t \in \{1,2,3,4\} \quad (4)$$

Burada, f^t t . özellik vektörü olarak tanımlanmaktadır.

Algoritma 1. BBYİÖ özellik çıkarıcısının sözde kodu

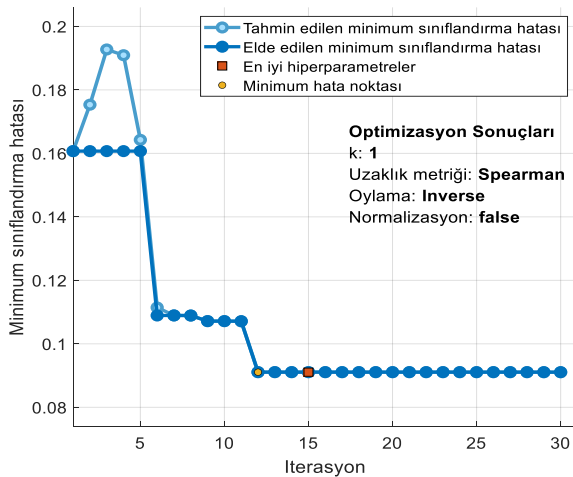
Prosedür: <i>BBYIO</i> (<i>s</i>)
Girdi: Tek boyutlu <i>u</i> uzunluğundaki sinyal (<i>s</i>)
Çıktı: Özellik vektörü
01: for <i>i</i> =1 to <i>u</i> - 8 do
02: <i>b</i> = <i>s</i> (<i>i</i> : <i>i</i> + 8); // Sinyali 9 elemanlı örtüşen bloklara ayır
03: <i>m</i> = <i>b</i> (5); // Örtüşen bloğun ortanca değerini merkez değer (<i>m</i>) olarak ata.
04: <i>sayac</i> = 1;
05: for <i>j</i> =1 to 9 do
06: if <i>j</i> !=5 then
07: <i>bit</i> (<i>sayac</i>) = <i>b</i> (<i>j</i>) >= <i>m</i> ; // Karşılaştırma fonksiyonu kullanarak bitleri çıkar
08: <i>sayac</i> = <i>sayac</i> + 1;
09: end if
10: end for j
11: <i>map</i> (<i>i</i>) = $\sum_{j=1}^8 bit(j) * 2^{j-1}$; // Özellik sinyalini üret
12: end for i
13: Özellik sinyalinin histogramını çıkar ve özellik vektörünü elde et.

Adım 5: Çıkarılan özellikleri birleştir (*ft*) ve 1280 özellik elde et.

$$ft((k-1) * 256 + j) = f^k(j), j \in \{1, 2, \dots, 256\}, k \in \{1, 2, \dots, 5\} \quad (5)$$

Adım 6: En uygun 256 özelliği çıkarılan 1280 özellik arasından seç.

Adım 7: K-En Yakın Komşu sınıflandırıcısı kullanarak çıkarılan 560 x 1280 boyutundaki özellik vektörünü 10-kat çapraz doğrulama yönteminin kullanarak sınıflandırın ve 560 elemanlı tahmin edilen etiket vektörünü oluşturun. En optimum K-En Yakın Komşu parametrelerini seçmek için MATLAB Classification Learner aracından bulunan optimize edilebilir K-En Yakın Komşu sınıflandırıcısı kullanıldı. Bu sınıflandırıcının seçtiği optimum parametreler Şekil 2'de gösterilmiştir.



Şekil 2 Kullanılan K-En Yakın Komşu sınıflandırıcısının optimum parametrelerinin hesaplanması

Adım 8: Çoğunluk oylama yöntemini kullanarak her bir EEG sinyalinin tahmin edilen değerini hesapla. Bu aşamada çoğunluklu oylama yöntemi olarak mod fonksiyonu kullanılmıştır. Elde edilen tahmin vektörlerine mod fonksiyonu uygulanarak genel değerler elde edilmiştir.

Adım 9: Her bir kanal için Adım 1-8' i tekrarla.

4 Deneysel Sonuçlar

Önerilen yöntem ve GAMEEMO veri seti kullanılarak hesaplanmıştır. GAMEEMO veri seti 14 kanallı bir veri setidir. Bu sebepten dolayı her bir kanala ait sonuçlar hesaplanmıştır. Hesaplanan performans metrikleri doğruluk (*OA*), hassasiyet (*Pr*), hatırlama (*Rec*) ve F1-skor (*F1*). Bu performans metriklerinin matematiksel tanımı Eşitlik 6-10' da verilmiştir. Ayrıca, bu performans metriklerini hesaplamak için doğru pozitif (*dp*), doğru negatif (*dn*), yanlış pozitif (*yp*) ve yanlış negatif (*yn*) değerleri kullanılmaktadır.

$$OA = \frac{dp + dn}{dp + dn + yp + yn} \quad (6)$$

$$Pr = \frac{dp}{dp + yp} \quad (7)$$

$$Rec = \frac{dp}{dp + yn} \quad (8)$$

$$F1 = 2 \frac{Pr * Rec}{Pr + Rec} \quad (9)$$

GAMEEMO veri seti 14 adet kanaldan oluşmaktadır. Önerilen yöntem tüm kanallara tek tek uygulanmış ve kanal tabanlı sonuçlar elde edilmiştir. Elde edilen sonuçlar Tablo 3' te gösterilmiştir.

Tablo 3' de gösterildiği gibi, 14 kanalın 7 âdetinde 100% sınıflandırma doğruluğu elde edilmiştir. En kötü sonuç veren kanal 96.43% doğruluk oranıyla F7 kanalıdır. Bunun yanı sıra önerilen yöntem duyguları en doğru şekilde parietal loba takılan kanallar (P7 ve P8) kullanarak tespit etmektedir. Çünkü her iki kanalda da 100% doğruluk oranına erişilmiştir.

Önerilen yöntemin performansını daha iyi yorumlayabilmek için Tablo 4' te karşılaştırma tablosu verilmiştir.

Tablo 4'de sonuçlar analiz edildiğinde GAMEEMO yöntemi bu yöntemler arasındaki en iyi yöntemdir. Sadece T7 kanalında Tuncer vd.'nin [22] yöntemi önerilen yöntemden 0.72% daha yüksek sonuç elde etmiştir. Geriye kalan 13 kanalda önerilen yöntem en iyi sonuçları elde etmiştir. Bunun yanı sıra GAMEEMO' yu sınıflandırmak için derin öğrenme yöntemi de kullanılmıştır. Alakus ve Turkoglu [1] GAMEEMO'ya derin öğrenme uygulamışlardır ve 76.93% sınıflandırma başarımları elde etmişlerdir. Önerilen yöntem derin öğrenme tabanlı yöntemden 23.07% daha yüksek performansa ulaşmıştır.

Tablo 3. Önerilen yöntemin kanal bazlı sonuçları (%)

No	Kanal Adı	OA	Pr	Rec	F1
1	AF3	99.11	99.14	99.11	99.12
2	AF4	100	100	100	100
3	F3	100	100	100	100
4	F4	99.11	99.14	99.11	99.12
5	F7	96.43	96.51	96.43	96.47
6	F8	100	100	100	100
7	FC5	99.11	99.14	99.11	99.12
8	FC6	100	100	100	100
9	O1	99.11	99.14	99.11	99.12
10	O2	100	100	100	100
11	P7	100	100	100	100
12	P8	100	100	100	100
13	T7	98.21	98.21	98.21	98.21
14	T8	100	100	100	100
Ortalama		99.36	99.38	99.36	99.37

Tablo 4. Karşılaştırmalı sonuçlar

Kanal	Alakus vd.'nin yöntemi [1]	Tuncer vd.'nin yöntemi [15]	Önerilen yöntem
AF3	80	97.86	99.11
AF4	75	98.39	100
F3	75	98.21	100
F4	82	98.04	99.11
F7	71	98.39	96.43
F8	71	98.75	100
FC5	75	98.04	99.11
FC6	74	98.39	100
O1	71	98.57	99.11
O2	65	97.68	100
P7	70	98.04	100
P8	72	98.75	100
T7	65	98.93	98.21
T8	79	98.39	100

5 Deneysel Sonuçlar

Bu makalede yeni bir EEG duygu sınıflandırma yöntemi önerilmiştir. Önerilen yöntem basit ve efektif bir yöntemdir. GAMEEMO EEG duygu veri seti kullanılarak 14 kanalın ortalama 99.36%, 7 kanalında 100% doğruluk oranı elde edilmiştir.

Elde edilen sonuçlar önerilen yöntemin gerçek zamanlı uygulamalarda kolaylıkla kullanılabileceğini açık bir şekilde göstermektedir. Ayrıca önerilen yöntem düşük maliyetli bir yöntemdir. Önerilen yöntemin sağladığı avantajlar şu şekilde sıralanmaktadır. Önerilen yöntem yüksek başarıma sahiptir, basittir, kolayca kodlanabilir ve gömülü akıllı sistemler bu yöntem kullanılarak geliştirilebilir. Bu çalışmanın sahip olduğu tek sınırlılık ise yalnızca GAMEEMO veri setinin kullanılmasıdır.

Gelecekteki çalışmalarda bu sınırlılığı gidermek ve evrensel doğruluğu göstermek için birden çok EEG duygu veri seti kullanılacaktır. Bunun yanı sıra sorgularda, psikiyatri kliniklerinde ve psikoloji bölümlerinde bireylerin duygularını tanımlayabilmek için akıllı beyin şapkalarının geliştirilmesi de planlanmaktadır.

Yazarların Katkıları

Conceptualization: Merve Akay, Turker TUNCER; Methodology: Merve Akay; Software: Merve Akay, Turker TUNCER; Validation: Merve Akay; Formal analysis: Merve Akay; Investigation: Merve Akay; Resources: Merve Akay; Data Curation: Merve Akay;

Writing - Original Draft: Merve Akay, Turker TUNCER; Writing - Review & Editing: Merve Akay, Turker TUNCER; Visualization: Turker TUNCER; Supervision: Turker TUNCER; Project Administration: Turker TUNCER

Teşekkür

We thank Talha Burak Alakus and Ibrahim Türkoğlu for sharing the GAMEEMO dataset.

Bilgilendirme

Gerçekleştirilen bu çalışmada Etik Kurul Onay belgesine gerek yoktur.

Kaynaklar

- [1] Alakus, T. B., Gonen, M., & Turkoglu, I. (2020). Database for an emotion recognition system based on EEG signals and various computer games – GAMEEMO. *Biomedical Signal Processing and Control*, 60, 101951.
- [2] Er, M. B., Çiğ, H., & Aydılek, İ. B. (2021). A new approach to recognition of human emotions using brain signals and music stimuli. *Applied Acoustics*, 175, 107840.
- [3] Hassouneh, A., Mutawa, A. M., & Murugappan, M. (2020). Development of a Real-Time Emotion Recognition System Using Facial Expressions and EEG based on machine learning and deep neural network methods. *Informatics in Medicine Unlocked*, 20, 100372.

- [4] Chen, S., Zhang, X., Chen, L., & Yang, Z. (2019). Automatic Diagnosis of Epileptic Seizure in Electroencephalography Signals Using Nonlinear Dynamics Features. *IEEE Access*, 7, 61046-61056.
- [5] Baykan, B., Altındağ, E., & Elmalı A.D. ELEKTROENSEFALOGRAFİ. Retrieved March 6, 2021, from <http://www.itfnoroloji.org/semi2/eeg.htm>
- [6] Li, X., Song, D., Zhang, P., Zhang, Y., Hou, Y., & Hu, B. (2018). Exploring EEG Features in Cross-Subject Emotion Recognition [Original Research]. *Frontiers in Neuroscience*, 12(162).
- [7] Shawky, E., El-Khoribi, R., Shoman, M., & Wahby Shalaby, M. (2018). EEG-Based Emotion Recognition using 3D Convolutional Neural Networks. *International Journal of Advanced Computer Science and Applications*, 9, 329.
- [8] Pandey, P., & Seeja, K. R. (2019). Subject independent emotion recognition from EEG using VMD and deep learning. *Journal of King Saud University - Computer and Information Sciences*.
- [9] Lan, Z., Sourina, O., Wang, L., Scherer, R., & Müller-Putz, G. R. (2019). Domain Adaptation Techniques for EEG-Based Emotion Recognition: A Comparative Study on Two Public Datasets. *IEEE Transactions on Cognitive and Developmental Systems*, 11(1), 85-94.
- [10] Qing, C., Qiao, R., Xu, X., & Cheng, Y. (2019). Interpretable Emotion Recognition Using EEG Signals. *IEEE Access*, PP, 1-1.
- [11] Yin, Z., Zhang, W., & Zheng, Z. (2020, July). Locally Robust Feature Selection of EEG Signals for the Inter-subject Emotion Recognition. In *2020 39th Chinese Control Conference (CCC)* (pp. 6250-6255). IEEE.
- [12] Gao, Q., Wang, C.-h., Wang, Z., Song, X.-l., Dong, E.-z., & Song, Y. (2020). EEG based emotion recognition using fusion feature extraction method. *Multimedia Tools and Applications*, 79.
- [13] Wei, C., Chen, L.-l., Song, Z.-z., Lou, X.-g., & Li, D.-d. (2020). EEG-based emotion recognition using simple recurrent units network and ensemble learning. *Biomedical Signal Processing and Control*, 58, 101756.
- [14] Naser, D. S., & Saha, G. (2021). Influence of music liking on EEG based emotion recognition. *Biomedical Signal Processing and Control*, 64, 102251.
- [15] Tuncer, T., Dogan, S., & Subasi, A. (2021). A new fractal pattern feature generation function based emotion recognition method using EEG. *Chaos, Solitons & Fractals*, 144, 110671.
- [16] Ghosh, L., Saha, S., & Konar, A. (2020). Decoding Emotional Changes of Android-Gamers Using A Fused Type-2 Fuzzy Deep Neural Network. *Computers in Human Behavior*, 116, 106640.
- [17] Cheng, J., Chen, M., Li, C., Liu, Y., Song, R., Liu, A., & Chen, X. (2021). Emotion Recognition From Multi-Channel EEG via Deep Forest. *IEEE Journal of Biomedical and Health Informatics*, 25(2), 453-464.
- [18] Chatlani, N., & Soraghan, J. (2010). Local binary patterns for 1-D signal processing. *2010 18th European Signal Processing Conference*, 95-99.
- [19] Kaya, Y., Uyar, M., Tekin, R., & Yıldırım, S. (2014). 1D-local binary pattern based feature extraction for classification of epileptic EEG signals. *Applied Mathematics and Computation*, 243, 209-219.
- [20] Murugappan, M., Ramachandran, N., & Sazali, Y. (2010). Classification of human emotion from EEG using discrete wavelet transform. *Journal of Biomedical Science and Engineering*, 03, 390-396.
- [21] Zubair, M., & Yoon, C. (2018). EEG based classification of human emotions using discrete wavelet transform. In *IT Convergence and Security 2017* (pp. 21-28). Springer, Singapore.
- [22] Goldberger, J., Roweis, S., Hinton, G. E., & Salakhutdinov, R. (2004). Neighbourhood components analysis. *Advances in neural information processing systems*, 17, 513-520.
- [23] Raghu, S., & Sriraam, N. (2018). Classification of focal and non-focal EEG signals using neighborhood component analysis and machine learning algorithms. *Expert Systems with Applications*, 113, 18-32.