

Bir Boyutlu Evrişimsel Sinir Ağı Yardımıyla Faz Kilitleme Değeri ve Diferansiyel Entropi Özellikleri Kullanılarak EEG Sinyallerinde Duygu Tanınması

Hakan UYANIK^{1*}, Salih Taha Alperen ÖZÇELİK², Abdulkadir ŞENGÜR³

¹ Elektrik Elektronik Mühendisliği, Mühendislik Fakültesi, Munzur Üniversitesi, Tunceli, Türkiye

² Elektrik Elektronik Mühendisliği, Mühendislik ve Mimarlık Fakültesi, Bingöl Üniversitesi, Bingöl, Türkiye

³ Elektrik Elektronik Mühendisliği Teknolojileri, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

*¹ hakanuyanik@munzur.edu.tr, ² sozcelik@bingol.edu.tr, ³ ksengur@firat.edu.tr

(Geliş/Received: 25/01/2023;

Kabul/Accepted: 28/07/2023)

Öz: Duygu analizi günümüz bilim dünyasında üzerinde en çok araştırma yapılan alanların başında gelmektedir. Özellikle insan-bilgisayar etkileşimi gibi günlük hayatımıza her geçen gün daha çok dahil olan alanların yanı sıra nörobilim ve psikoloji gibi bilim dallarının da yakından incelediği bir konudur. Duygu analizi için konuşma sinyalleri, mimikler, vücut dili, yüz ifadeleri gibi yöntemler kullanılsa da bu yöntemler manipülasyona açık oldukları için biyolojik sinyaller kadar güvenilir sonuçlar vermezler. Bu çalışmada sanal gerçeklik (SG) teknolojisi yardımıyla hazırlanmış, biyoelektriksel bir sinyal olan elektroensefalografi (EEG) sinyalleri ile duygu tanıma için yeni bir yöntem önerilmiştir. Bu yöntemde EEG sinyallerinin alt bantlarının diferansiyel entropi (DE) ve faz kilitleme değeri (FKD) özellikleri, tasarlanan bir boyutlu evrişimsel sinir ağı (1B-ESA) yardımı ile pozitif ve negatif duyguların tanınması için kullanılmıştır. Her iki özellik yardımıyla elde edilen özellik matrisleri on defa teste tâbi tutularak ortalama başarı değerleri elde edilmiştir. Bu testler sonucunda DE ve FKD özellikleri ile en yüksek ortalama başarı puanları, tüm alt bant özellik matrislerinin birleştirilmesi ile sırasıyla %74,061±1,41 ve %63,7590±1,72 olarak elde edilmiştir. Ayrıca çalışmada elde edilen yüksek frekanstaki sinyal bileşenlerine ait testlerin başarı oranlarının düşük frekans bantlarına göre daha yüksek elde edilmesi daha önce bu alanda yapılan benzer çalışmaların sonuçlarını destekler nitelikte olmuştur.

Anahtar kelimeler: Duygu tanıma, elektroensefalografi, diferansiyel entropi, faz kilitleme değeri, bir boyutlu evrişimsel sinir ağı.

Emotion Recognition in EEG Signals Using Phase Lock Value and Differential Entropy Features with the Help of One-Dimensional Convolutional Neural Network

Abstract: Emotion recognition is one of the most researched fields in today's scientific world. It is a subject that is closely examined by disciplines such as neuroscience and psychology, and it is more and more involved in our daily lives, especially in human-computer interaction area. Although methods such as speech signals, facial expressions, body language, and facial expressions are used for emotion analysis, these methods do not give as reliable results as biological signals because they are open to manipulation. In this study, a new method for emotion recognition with electroencephalography (EEG) signals, which is a bioelectrical signal prepared with the help of virtual reality (VR) technology, is proposed. In this method, differential entropy (DE) and phase-locking value (PLV) properties of sub-bands of EEG signals were used to recognize positive and negative emotions with the help of a designed one-dimensional convolutional neural network (1D-CNN). The feature matrices obtained with the help of both features were tested ten times and average accuracy values were obtained. As a result of these tests, the highest average accuracy scores with DE and FKD features were obtained as 74.061±1.41% and 63.7590±1.72%, respectively, by combining all sub-band feature matrices. In addition, the higher accuracy rates of the tests of the high-frequency signal components obtained in the study compared to the low-frequency bands, supported the results of similar studies carried out in this area before.

Key words: Emotion recognition, electroencephalography, differential entropy, phase locking value, one dimensional convolutional neural network.

1. Giriş

Düşünce ve duygu kavramları içsel dünyamızı oluşturan soyut yapılardır. Bu iki kavram birbirleri ile bağlantılıdır ve kişisel deneyimler oldukları için dışarıdan doğrudan gözlemlenemezler. Öte yandan bu iki kavram çevre ile etkileşim halindedir [1-3]. Bilişsel nörobilimci Ralph Adolphs'e göre duygular, bir avcıdan kaçmak veya

* Sorumlu yazar: hakanuyanik@munzur.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-6870-7569, ² 0000-0002-7929-7542, ³ 0000-0003-1614-2639

avına saldırmak gibi belirli karmaşık davranışların nedensel açıklamalarını sağlayan beynin işlevsel durumlarıdır [4-6].

İnsan duygularının tespiti için çeşitli yöntemler geliştirilmiştir. Duygular konuşma sinyallerinden [7-9], vücut dilinden [10], EEG sinyallerinden [11-14], mimiklerden [15,16], yüz ifadelerinden [17,18], fonksiyonel manyetik rezonans görüntüleme (fMRI) verilerinden [19,20], yakın kızılötesi spektroskopi (NIRS) verilerden [21,22] ve daha birçok farklı yöntem ile tespit edilebilir. Duygu tanıma için EEG sinyallerinin kullanımı bu yöntemler arasında en çok tercih edilen, en güvenilir ve en pratik yöntemlerden birisidir. Güvenilir olmasının ardında yatan sebep, bu sinyallerin doğrudan duyguların meydana geldiği otonom sinir sisteminin merkezi olan beyinden elde edilmesinden dolayıdır. Dolayısıyla bu sinyaller manipülasyona kapalıdır. Örneğin yüz ifadeleri veya vücut dili verileri kişilerce olduğundan farklı gösterilebilirken, EEG ve diğer biyolojik sinyallerde bu durum aynı değildir.

EEG sinyalleri ile duygu tanıma için kullanılan veri setleri çeşitli uyarılar yardımıyla oluşturulurlar. Bu uyarılar kimi zaman bir ses kaynağıyken, kimi zaman görsel bir uyarı olabilir. Birçok veri setinde ise her iki uyarı tipi bir arada kullanılmıştır. Günümüzde en popüler iki EEG sinyal veri seti DEAP [23] ve SEED [24] veri setleridir. Bu iki veri seti ses ve görüntü uyarıları yardımıyla oluşturulmuştur. Kullanılan görüntü uyarıları ise iki boyutludur.

İsmael ve ark. [25] nolu çalışmalarında DEAP veri setinde EEG tabanlı duygu sınıflandırması için iki aşamalı bir yöntem önermişlerdir. Yazarlar çalışmalarında gürültü eliminasyonu için düşük geçişli filtreleme yöntemi kullanmış ve ritim çıkarımı için bant geçiren filtreleme adımlarını EEG sinyallerine uygulamışlardır. Her ritim için en iyi performans gösteren EEG kanallarını dalgacık bazlı entropi özelliklerini ve fraktal boyut tabanlı özellikleri kullanarak k-En Yakın Komşuluk (k-EYK) sınıflandırıcısı yardımıyla belirlemişlerdir. Daha sonra, her EEG ritmi için nihai tahmini elde etmek için çoğunluk oylamasında en iyi beş EEG kanalını dikkate almışlardır. Önerilen çalışmada yüksek değerlik (HV) ve düşük değerlik (LV) sınıflandırmasında %86,3 başarı puanına karşılık, yüksek uyarılma (HA) ve düşük uyarılma (LA) sınıflandırmasında ise %85,0 başarı puanı elde etmişlerdir.

Örneğin, Arı ve ark. [26] nolu çalışmalarında, EEG sinyalleri ile duygu tanıma için yeni bir veri artırma yaklaşımı (Extreme Learning Machine Wavelet Auto Encoder) önermişlerdir. GAMEEMO [27] veri setini kullanan yazarlar başlangıçta EEG sinyallerini sürekli dalgacık dönüşümü (CWT) kullanarak zaman-frekans görüntülerine dönüştürmüşlerdir. Daha sonra elde ettikleri bu görüntüleri önerdikleri veri artırma yöntemini kullanarak çoğaltmışlardır. Son olarak, sınıflandırma için ResNet-18'e bir takım ince ayar uygulayarak % 99.6 başarı puanı elde etmişlerdir.

Joshi ve ark. ise [28] nolu çalışmada SEED ve DEAP veri setlerini bir arada kullanmışlardır. Yazarlar özellik çıkarımı için giriş EEG sinyallerinin doğrusal ve Gaussian olmayan karakteristiklerini elde etmek için Diferansiyel Entropinin Doğrusal Formülasyonunu (LF-DfE) kullanmışlardır. Daha sonra elde ettikleri özelliklerin sınıflandırılması için Çift Yönlü Uzun Kısa Süreli Bellek (BiLSTM) yaklaşımının kullanıldığı EEG tabanlı bir duygu tanıma yöntemi önermişlerdir. Çalışmada sırasıyla %80,64 ve %76,75 doğruluk puanları elde etmişlerdir.

Gelişen teknoloji ile araştırmacılar bugün üç boyutlu uyarılar yardımıyla veri setleri oluşturmayı başarmışlardır. Araştırmacılar bu veri setlerinin oluşturulması aşamasında sanal gerçeklik teknolojilerinden yararlanmışlardır. Sanal gerçeklik alanında insan bilgisayar etkileşimi için oldukça önemli bir yöntemdir. Çünkü teknolojinin hedeflediği konulardan birisi de insan zihni ile kontrol sistemlerinin geliştirilmesidir.

Morales ve ark. [29] EEG sinyalleri toplanırken daha gerçekçi uyarılarla bu işlemi yapmak için üç boyutlu uyarılardan yararlanmışlardır. 4 sanal oda kullanılarak 60 katılımcıdan hem EEG hem de EKG sinyallerinin kaydedildiği bir veri seti oluşturmuşlardır. Dört odadan ikisi olumlu duyguları, geri kalan iki oda ise olumsuz duyguların uyarıldığı düzeneklerle ayarlanmıştır. Giriş sinyallerinden özellikleri çıkarmak için güç spektral yoğunluğu (PSD), faz bağlantısı ve kalp atış hızı değişkenliği özelliklerinin kullanan yazarlar, sınıflandırma amacıyla bir destek vektör makinesi (SVM/DVM) sınıflandırıcısı kullanmışlardır. Gerçekleştirilen deneysel çalışmalar, önerilen şema ile değerlik sınıfı için %71,21 doğruluk puanı ve uyarılma sınıfı için %75 doğruluk puanı oluşturmuştur.

Suhami ve ark. [30] nolu çalışmalarında benzer olarak sanal gerçeklik gözlüklerini kullanarak EEG sinyallerini kaydetmişlerdir. Çalışmalarında mutluluk, korku, sakinlik ve sıkılma türünde duyguları araştırmışlardır. Özellik çıkarımı için doğrusal interpolasyon ve spline interpolasyonu yöntemlerini kullanmış ve sınıflandırma adımında bir DVM sınıflandırıcısı tercih etmişlerdir. Deneysel çalışmalar, dört duygunun sınıflandırılması aşamasında %85,01'lik bir doğruluk puanına ulaşmıştır.

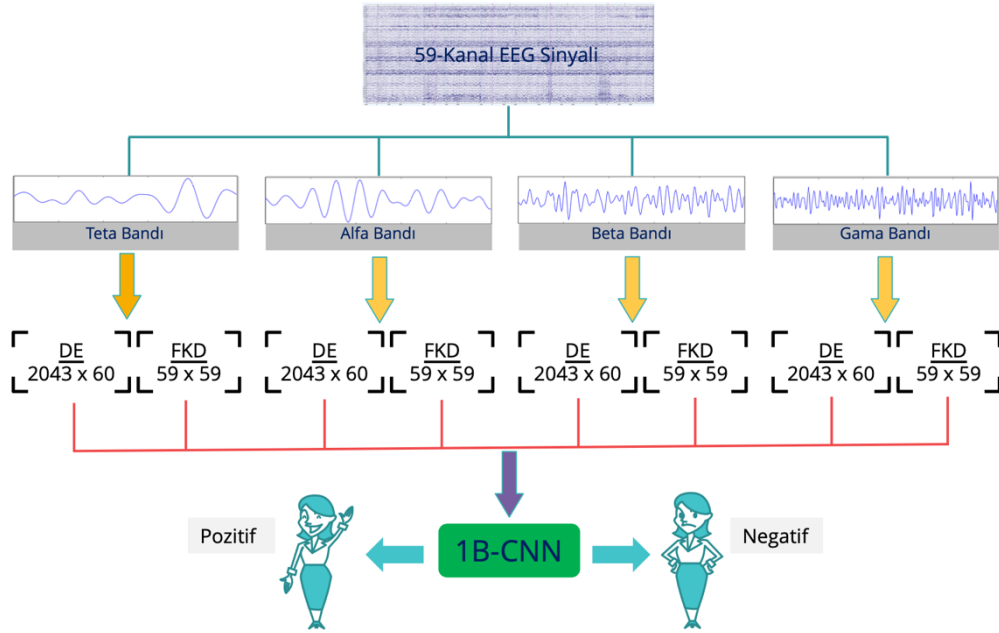
EEG duygu tanıma alanında sıklıkla tercih edilen yöntemlerden birisi de DE metodudur. [31-34] nolu çalışmalar bu özellik yardımıyla gerçekleştirilmiş bazı başarılı çalışmalardır. Örneğin Zheng ve ark. [35] duygu tanıma için 6 farklı özellik çıkarma yöntemi (PSD, DE, Diferansiyel Asimetri (DASM), Rasyonel Asimetri, Asimetri (RASM), Diferansiyel Nedensellik) kullanarak EEG sinyalleri ile duygu tanıma deneyleri gerçekleştirmişlerdir. Yazarlar, DEAP ve SEED veri setlerinde sırasıyla k-EYK, Lojistik Regresyon (LR), DVM

ve GELM (Generalized Extreme Learning Machine) olmak üzere dört farklı sınıflandırma yöntemiyle kullanmışlardır. Tüm deneyler sonucunda DE özellikleri diğer beş farklı özelliğe göre daha yüksek doğruluk puanı ve daha düşük standart sapma değeri üretmiştir. En iyi ortalama başarı puanları, DEAP ve SEED veri setlerinde DE özelliklerine sahip ayırıcı GELM ile sırasıyla % 69,67 ve % 91,07 olarak elde etmişlerdir.

Bu çalışmada sanal gerçeklik tabanlı oluşturulan bir EEG veri seti [36] ile duygu tahmini yapan bir yöntem önerilmiştir. Önerilen yöntemde giriş EEG sinyalleri başlangıçta gürültü giderme ve taban çizgisi ayarlaması için MATLAB programında EEGLAB [37] araç kutusu yardımıyla birtakım ön işlemlere tâbi tutulmuştur. Bu işlemlerin ardından sinyallerin alt bantlara ayrılması için dalgacık dönüşümü uygulanmıştır. Bu ayrışma sonrasında elde edilen teta, alfa, beta ve gama bantları daha sonra özellik çıkarma işlemleri için kaydedilmiştir. Bu alt bantlar için DE ve FKD olmak üzere iki tür özellik çıkarım işlemi gerçekleştirilmiştir. Elde edilen özellik matrisleri rastgele şekilde %70'i eğitim verisi ve kalan %30'luk kısmı ise test seti olacak şekilde ayarlanarak tasarlanan 1B-ESA'na girdi olarak verilmiş ve iki tür duygunun (pozitif-negatif) tahmini yapılmıştır. Bu işlemler tüm veri seti için her bir özellik çıkarım yöntemi için on defa tekrarlanmış ve elde edilen sonuçların ortalama değeri ve standart sapması hesaplanmıştır. Bu çalışmanın literatüre kazandırdığı en belirgin özgün katkı, bu veri setinde ilk defa bir derin öğrenme metodunun kullanılmasıdır.

2. Materyal ve Yöntem

Bu çalışmada önerilen yönteme ait şema Şekil 1'de verilmiştir.



Şekil 1. Çalışmada önerilen yöntemin şeması [38].

Şekil 1'de görüldüğü üzere başlangıçta 59 kanallı EEG sinyalleri alt ritim bantlarına ayrılarak işlemlere devam edilmekte. Burada kullanılan dört alt bant sırasıyla teta, alfa, beta ve gama bantlarıdır. Bu dört banttan teta bandı, 4 ile 8 Hz arasında salınım yapan alt banttır. Bu bantın aktivitesi meditasyon ve uyusukluk anlarında yüksektir. Temel ritim olarak adlandırılan alfa bandı ise 8 ile 13 Hz arasında salınım gösterir. Bu banttaki aktivite uyanıkken ve gözler açıkken yüksektir. Görsel dikkatin ve zihinsel çabanın arttığı anlarda bu bantın aktivitesi düşer. Başın üst kısımlarında ölçülen aktivitesi diğer bölgelere göre daha yüksektir. Beta bandı 13 ile 30 Hz arasında bir salınım gösterir. Aktif düşünme ve konsantrasyon anlarında aktivitesi yüksektir. Gama bandı ise 30 Hz ve üzeri salınımları kapsar. İstemli hareketler ve bilgi işleme anlarında aktivitesi yüksektir [39]. Bu alt bantlara ayırma işleminde dalgacık dönüşümü kullanılmıştır. Dalgacık dönüşümünde 'db8' filtresi kullanılmış ve sinyaller 5 seviyeli bir dönüşüme tâbi tutulmuştur. Burada kullanılmayan alt bant delta bandıdır. Bu bant en düşük frekans değerinde salınım yapan banttır (0.5-4 Hz). Baş, omuz, göz, dil ve çene hareketlerinden kaynaklı sinyaller bu bantın salınımına yakın salınımlar oluşturan hareketlerdir ve bu sinyaller istenmeyen sinyaller olarak adlandırılan

artefaktları olarak adlandırılırlar ve EEG sinyallerine dahil olurlar. Bu artefaktların EEG sinyalleri içerisinde tamamen elimine edilmesi oldukça zordur. Bu sebeple bu bandın değerlendirilmesinden feragat edilmiştir. Bu durum birçok çalışmada benzer şekilde gerçekleştirilmektedir.

Ritimlere ayırma işleminden sonra bu alt bantlara ait iki tür özellik matrisi oluşturulur. Bunlar DE ve FKD özellikleridir. Daha sonra bu özellik matrisleri tasarlanan 1B-ESA'na girdi olarak aktarılır ve duygunun sınıfı tahmin edilir. Bu işlemlerin detaylı açıklamaları ilgili alt başlıklarda yapılmıştır.

2.1. Diferansiyel entropi

DE kavramı Shannon'nın [40] nolu kaynaktaki çalışmasında sürekli dağılımlar için oluşturmuş olduğu entropi hesaplama yönteminin eşdeğeridir [41]. Bu yöntem ile sürekli ve rastgele bir değişkenin düzensizliği veya bu belirsizlikteki değişiklik ölçülebilir. Bu özellik EEG sinyalleri gibi oldukça karmaşık ve rastgele oluşan sinyaller için oldukça kullanışlıdır.

X sürekli zamanlı ve rastgele bir değişken ve X 'in olasılık yoğunluk fonksiyonu $p_X(x)$ olmak üzere X 'in DE'si Denklem 1'de ki gibi hesaplanır.

$$h_X = - \int_S p_X(x) \log(p_X(x)) dx \quad (1)$$

Burada $S = \{x | p_X(x) > 0\}$ X 'in destek kümesi olarak adlandırılır. Rastgele değişkenin Gauss dağılımı $N(\mu, \sigma^2)$ 'ye uyduğu için olasılık fonksiyonu formülasyonu Denklem 2'de ki forma dönüşür.

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2 + \mu^2}{2\sigma^2}} \cosh\left(\frac{\mu x}{\sigma^2}\right) \quad (2)$$

Bu ifade Denklem 1'de ki eşitlikte yerine konulursa Denklem 3'te ki DE eşitliği elde edilir.

$$h_X = \int_{-\infty}^{+\infty} p(x) \ln(p(x)) dx = \frac{1}{2} \log_2(2\pi e \sigma^2) + L\left(\frac{\mu}{\sigma}\right) \quad (3)$$

Bu eşitlikte $L(\cdot)$ 0'dan 1'e ($\ln 2$ 'ye) giden μ/σ fonksiyonudur. e Euler sabiti ve σ 'da x 'in standart sapmasıdır. Bu eşitlikten yola çıkarak her bir EEG sinyalinin DE'si hesaplanarak özellik matrislerine kaydedilmiştir ve deneysel adımlar bu matrislerle gerçekleştirilmiştir.

2.2. Faz kitleme değeri

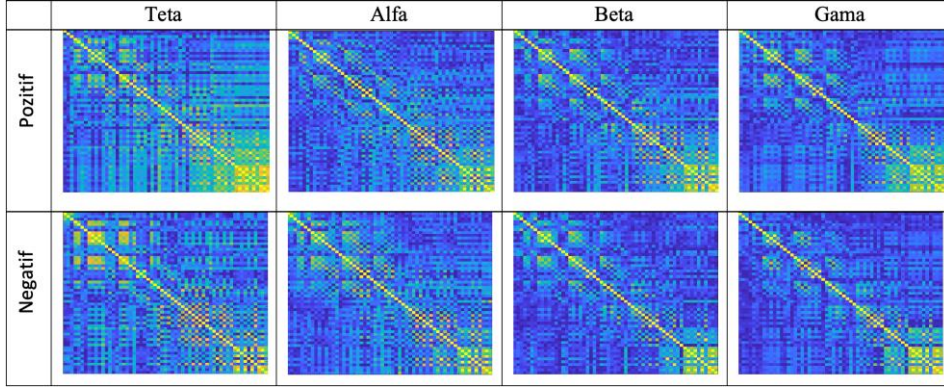
EEG gibi sinyaller için en çok kullanılan bağlantı hipotezlerinden biri faz senkronizasyonudur. Faz senkronizasyonuna göre, beynin iki farklı bölgesi farklı salınım aktivitesi gösterir ve farklı bölgeler arasında bir bağlantı varsa, salınım özellikleri arasında bir ilişki oluşur. Bu ilişki matematiksel olarak değerlendirilebilirse, faz eşleşmesinin bir tahminçisi elde edilir. Literatürde bulunan faz senkronizasyon ölçümlerinde en sık kullanılan temel ölçümlerden biri FKD'dir [42]. Bu ölçüm yönteminde, sinyaller arasında bağlı alanların anlık fazlarının birlikte gelişen sinyaller ürettiği hipotezi ile sinyallerin anlık faz farkı değerlendirilir. Bağlı sinyallerin fazlarının kilitli olduğu kabul edilir ve bu sinyaller arasındaki faz farkları sabit kabul edilir.

FKD'ni hesaplamak için kullanılan en yaygın yöntem, Hilbert veya Wavelet dönüşümleri kullanılarak elde edilen sinyallerin anlık fazının hesaplanmasıdır. Bu işlem için kullanılan FKD formülasyonu Denklem 4'te ki gibidir [43].

$$FKD_{i,j}(t) = \frac{1}{N} \left| \sum_{n=1}^N e^{-i(Q_i(t,n) - Q_j(t,n))} \right| \quad (4)$$

burada N , deneme sayısıdır ve $Q_i(t, n)$ ise t zamanındaki n denemesinde bulunan i sinyalinin anlık fazıdır.

EEG sinyallerine ait FKD kanallar arasındaki faz bağılıklarını gösterir ve bu çalışmada kullanılan EEG sinyal veri setindeki sinyallerde 59 kanallı olduğu için her bir sinyal parçasına ait 59×59 boyutunda özellik matrisleri elde edilecektir. Bu sinyaller arasında iki farklı duygu durumunda oluşan FKD matrisleri için dört alt bantta oluşan FKD matrislerine ait örnek bir gösterim Şekil 2'de ki gibidir.



Şekil 2. Veri setinden rastgele seçilen iki farklı duygu durumuna ait EEG sinyallerinin dört alt bandı için oluşan FKD görselleri

2.3. 1B-ESA

Geleneksel ESA çoğunlukla 2 boyutlu görüntü sınıflandırma uygulamaları için geliştirilmiştir [44]. 1B-ESA, bazı uygulamalarda daha avantajlı olan tek boyutlu özelliklere veya sinyal vektörlerine uygulanmasının daha etkili olmasıyla bilinen bir ESA uygulamasıdır. 1B-ESA ve 2B-ESA arasında bazı yapısal farklılıklar olsa da bunlar aynı çalışma prensiplerine dayanmaktadır [45].

Evrişim katmanı, giriş verileri ile skaler çarpım işlemi gerçekleştiren K adet filtreden oluşur. Her filtre, K 'nın özellik haritalarını tahmin eder ve bu filtreler belirli bir adım boyutuyla girişin uzunluğu boyunca kayarak hareket eder. 1B-ESA'da, evrişim katmanı, N boyutundaki giriş sinyali X vektörünün L boyutundaki bir filtre vektörü ω ile evrişimi ile gerçekleştirilir. Bu işlem Denklem 5 ile formüle edilebilir. Bu işlem herhangi bir sıfır dolgu olmadan $N-L+1$ uzunluğunda bir bir-boyutlu çıkış katmanı c ile sonuçlanır.

$$c(j) = f\left(\sum_{i=0}^{L-1} \omega(i) \cdot x(j-i) + b\right), j = 0, 1, \dots, N-1 \quad (5)$$

Bu denklemde, b ön gerilim vektörüdür ve $f(\cdot)$ doğrusal olmayan bir fonksiyondur. Her evrişim katmanını, bir çekirdek penceresi fonksiyonu u 'da ki maksimum değerin, boyutu $m \times 1$ ve adımları s olan bir c giriş vektörü üzerinden alınan ve d olarak tanımlanan bir çıkış vektörü ile sonuçlanan bir maksimum havuzlama katmanı izler;

$$d = \max(u(m \times 1, s)c) \quad (6)$$

Tam bağlantılı katman (TBK), önceki katmandan gelen özellik haritası çıktısını giriş olarak alır ve tüm nöron düğümlerini birbirine bağlar. Bir aktivasyon fonksiyonu (örneğin Softmax, Sigmoid, vb.), ağ eğitimi sırasında çapraz entropi kaybı l 'yi hesaplamak için kullanılan tahmini çıktıyı Denklem 7'de ki gibi belirler:

$$l = \sum_{k=1}^c t(k) \log(p(k)) \quad (7)$$

Burada C , sınıfların sayısıdır. $t(k)$ ise tahmin edilen etiket ile doğru etiket arasındaki karşılaştırmanın sonucudur.


2.4. Veri seti

Çalışmada kullanılan veri seti [36] daha önce belirtildiği gibi üç boyutlu uyarılar yardımıyla oluşturulmuştur. Bunun için Shangay Film Akademisi tarafından üç boyutlu olarak hazırlanmış her biri 4 saniye uzunluğundaki üç farklı sınıftan 60 adet farklı video bir sanal gerçeklik gözlüğü yardımıyla deneklere izletilmiştir.

Bu esnada deneklerden 64 kanallı uluslararası 10-20 sistemine göre yerleştirilmiş bir EEG kayıt cihazı ile 100Hz örnekleme hızında EEG sinyalleri toplanmıştır. Veri setinde toplam 13 erkek ve 6 kadın denek ile 19 kişi yer almıştır. Veri seti oluşturulurken kullanılan 60 video ilk aşamada iki guruba ayrılmıştır. Bu grupların birinde 20 adet pozitif ve 10 adet nötr etiketli video yer alırken diğer grupta ise 20 adet negatif ve 10 adet nötr etiketli video yer almaktadır. Deneklere bu video grupları rastgele şekilde iki defa izletilerek sinyaller kaydedilmiştir. Böylece her bir denek için toplamda 120 adet EEG kaydı oluşmuştur. Tüm kayıt işlemleri bittikten sonra toplanan EEG sinyallerinden bozuk olan parçalar silinmiş ve veri seti son halini almıştır. Bu işlemlerden sonra tüm veri setinde toplamda 2043 adet EEG sinyali yer almıştır. Bu sinyallere ait filtreleme, bağımsız bileşen analizi (BBA) ve taban çizgisi etiketleme işlemleri yapıldıktan sonra bir MATLAB altprogramı olan EEGLAB ile kullanıma uygun dosya formatlarında (.set, .bdf) kaydedilmiştir.

3. Deneysel Çalışmalar ve Sonuçlar

Çalışmada yapılan tüm deneyler MATLAB programında gerçekleştirilmiştir. MATLAB içerisinde EEGLAB araç kutusu yardımıyla önerilen yöntem uygun şekilde EEG sinyalleri okunmuş, gerekli etiketleme işlemleri yapılmış ve taban çizgisinden itibaren tüm sinyaller yeniden kaydedilmiştir. Daha sonra Şekil 1’de önerilen yöntem uygun şekilde işlemler gerçekleştirilmiştir. Veri setindeki tüm EEG sinyallerine ait dört alt bantın DE ve FKD verileri hesaplanarak özellik matrisleri oluşturulmuştur. Bu dört banttan elde edilen özellik matrisleri yan yana konularak (kombine) beşinci özellik matrisi oluşturulmuştur. Daha sonra bu özellik matrisleri 1B-ESA için %70 eğitim ve %30 test verisi olacak şekilde rastgele bir şekilde ayrılmıştır. Bu işlem tüm özellik matrisleri için 10 defa tekrarlanarak tüm deneyler gerçekleştirilmiştir. Böylece veri seti içerisinde oluşabilecek kümelenmiş veriler nedeniyle elde edilecek anormal sonuçların önüne geçilmesi amaçlanmıştır. Çalışmada kullanılan 1B-ESA mimarisi Şekil 3’te verilmiştir.



Şekil 3. Tasarlanan 1B-ESA'na ait katmanlar

EEG sinyalleri bir boyutlu, çok kanallı ve oldukça kompleks yapıya sahiptir. Bu sinyallerin görüntüye dönüştürülmesi çok kanallı yapısından dolayı oldukça zordur ve çoğu zaman anlamlı ve başarılı sonuçlar elde edilememektedir. Bu sebeple bu sinyallerin geleneksel 2 ve 3 boyutlu evrişimsel sinir ağlarıyla incelenmesi çok tercih edilmez. Ayrıca, geleneksel 2 ve 3 boyutlu evrişimsel sinir ağları sahip oldukları yüksek parametre sayıları sebebiyle hesapsal karmaşıklıkları, eğitim ve uygulama işlemleri açısından bu yöntemlere göre çok daha kompakt yapıdaki bir boyutlu evrişimsel sinir ağlarından çok daha fazladır. Şekilden görüleceği üzere tasarlanan model 3 adet konvolüsyon katmanı ve bunları takip eden 3 adet 'ReLU' tipi aktivasyon fonksiyonu katmanlarından oluşmaktadır. Böylece olası bir ezberleme durumunun önüne geçilmesi amaçlanmıştır. Modelin sınıflandırma katmanından önce maksimum havuzlama, TBK (tam bağlantılı katman) ve 'softmax' tipi bir aktivasyon katmanı yer almaktadır. İlk konvolüsyon katmanı 26 adet 1×6 boyutunda bir boyutlu konvolüsyon filtreleri içermektedir. İkinci ve üçüncü konvolüsyon katmanlarında filtre boyutları aynı büyüklükte fakat sayıca iki katı büyüklüktedir. İki adet 'dropout' katmanı aşırı öğrenme durumunun azaltılması için 0.005 katsayı değeri ile ilk iki normalizasyon katmanlarından sonra kullanılmıştır. Eğitim aşamasında 'Adam' optimizasyon modeli ağa uygulanarak eğitimlerin optimizasyon işlemi gerçekleştirilmiştir. 'minibatch' parametresi 32 olarak ayarlanmıştır. Başlangıç öğrenme katsayısı 0.001 olarak ayarlanmış ve herhangi bir adaptasyon bu katsayıya uygulanmamıştır.

Tasarlanan bu model üzerinde gerçekleştirilecek değişiklikler ile daha kompleks bir ağ modeline dönüştürülebilir. Örneğin model çok girişli tasarlanarak aynı anda birden fazla aynı etikete sahip özellik vektörü

ağa girdi olarak aktararak eğitim işlemleri gerçekleştirilebilir. Tasarlanan ESA modelinde giriş katmanı bir boyutlu olduğu için elde edilen özellik matrislerinin bu mimarinin girişine uygun olması gerekmektedir. Toplamda 19 kişiden toplanan 2043 adet EEG sinyallerine ait DE özellik matrisleri 4 alt bant ve temel sinyaller için yukarıda da belirtildiği üzere 2043×60 boyutunda oluşmaktadır. Bu matriste satırlar deneylere karşılık gelirken sütunlardan ilk 59'u sinyale ait kanallara karşılık gelmekte ve son sütun ise sınıf etiketine karşılık gelmektedir. Bu matris evrimsel sinir ağına giriş olarak verilirken bu hususlar göz önünde bulundurulmuştur ve satır satır bu işlemler tüm verilerin rastgele karıştırılarak 10 defa aynı deneysel adımların izlenmesi ile gerçekleştirilmiştir. FKD özellik matrisleri ise 59×59 boyutlarında oluşmaktaydı ve bu matris sinyale ait kanalların birbirleriyle olan faz ilişkilerini göstermekteydi. Bu özellik matrisleri de DE özellik matrislerine benzer olarak 4 alt bant ve temel sinyal için 19 kişiden elde edilen 2043 adet EEG sinyallerinden elde edilmiştir. Bu matrisler tasarlanan sinir ağına her görüntü için aynı olacak şekilde satır vektörü haline getirilerek girdi yapılmıştır. Dolayısıyla her bir deneye ait giriş vektör uzunluğu 3481 (59×59) olmuştur.

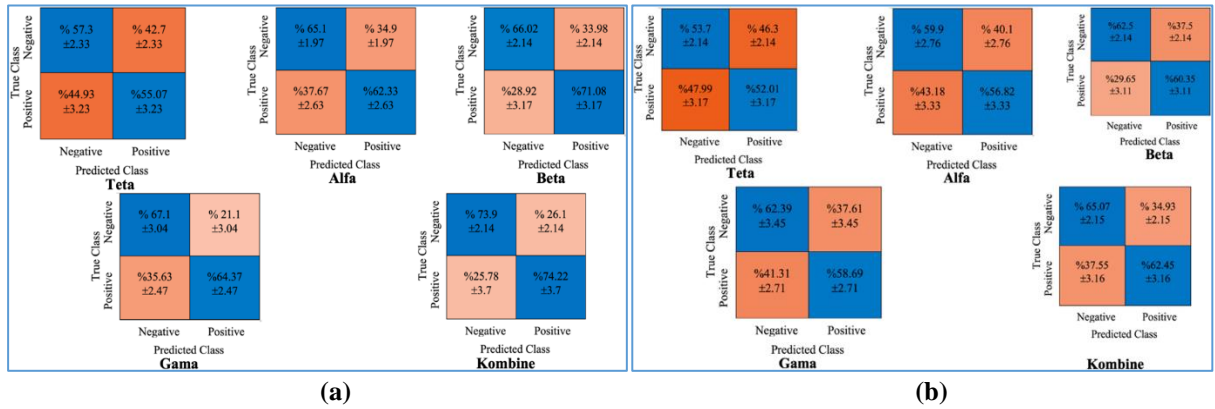
Şekil 4, Tablo 1 ve Tablo 2'de DE ve FKD özellikleri ile 1B-ESA sınıflandırıcı kullanılarak elde edilen ortalama doğruluk puanları ile sınıflandırma işlemlerine ait performans metrikleri ve bu puanlara ait standart sapma değerleri gösterilmiştir. İlk etapta Tablo 1 yakından incelendiğinde DE özellikleri ile gerçekleştirilen sınıflandırma işlemlerinin ortalama doğruluk puanlarının tüm durumlarda FKD özellikleri ile gerçekleştirilen sınıflandırma işlemlerinden daha yüksek olduğu görülmektedir. Tablo 2'de beta bantı sınıflandırma performans ölçütlerinde tüm durumlar arasında en yüksek değerleri oluşturmuştur. Ayrıca Tablo 1'de her iki özellik için tüm bantların bir arada değerlendirildiği kombine özellik matrislerinde elde edilen sonuçlar tüm alt bantlardan daha iyi sonuçlar vermiştir. Şekil 4'te ki veriler bu sonuçları destekler niteliktedir.

Tablo 1. Özellik matrislerine ait ortalama sınıflandırma sonuçları ve standart sapmaları

Özellik	Teta	Alfa	Beta	Gama	Kombine
DE	56.5±1.5842	63.3710±1.8644	68.55±1.7823	65.736 ±2.3494	74.0610 ±1.4065
FKD	52.854±1.1189	58.36±1.7787	61.4250±1.9536	60.5290 ±1.4261	63.7590 ±1.7429

Tablo 2. Özellik matrislerine ait ortalama sınıflandırma performans sonuçları

DE	Teta	Alfa	Beta	Gama	Kombine
Kesinlik (%)	56.21±1.8224	63.73±1.7654	68.60±2.7902	70.31±1.2232	74.06 ±1.5778
Hassasiyet (%)	56.32±2.6478	63.69±1.7096	68.55±1.5726	70.22±2.6897	74.16 ±1.4548
F1 Skor (%)	56.19±1.5732	63.72±1.8641	68.57±1.6732	70.27±1.3451	74.12 ±1.4689
FKD	Teta	Alfa	Beta	Gama	Kombine
Kesinlik (%)	52.86±1.4890	58.27±1.4641	64.75±1.9053	60.58±1.3987	63.77 ±1.4421
Hassasiyet (%)	52.77±1.5752	58.32±2.1689	64.78±1.8841	60.54±2.4220	63.76 ±2.3588
F1 Skor (%)	52.81±2.4742	58.31±1.4438	64.76±1.7832	60.49±1.5055	63.76 ±1.4365



Şekil 4. (a) DE ve (b) FKD özelliği ile gerçekleştirilen sınıflandırma işlemleri sonucu elde edilen ortalama karışıklık matrisleri

Elde edilen sonuçlardan görüleceği üzere görece yüksek frekans bandındaki beta ve gama bantlarında elde edilen sonuçlar daha düşük frekans bantlarındaki teta ve alfa bantlarına göre daha yüksek sonuçlar üretmiştir. Özellikle beta bandı her iki özellik testleri için tekil değerlendirmelerde en yüksek sonucu vermiştir.

4. Tartışma

Bu çalışmada EEG sinyalleri ile duygu tanıma için yeni bir yöntem önerilmiştir. Önerilen yöntemde giriş EEG sinyalleri ilk etapta birtakım ön işlemlerden geçerek dalgacık dönüşümü yardımıyla alt ritim bantlarına ayrılmaktadır. Daha sonra bu alt bantlara ait DE ve FGD özellikleri hesaplanarak tasarlanan 1B-ESA için girdi olarak kullanılıp iki duygu durumunun (pozitif-negatif) tespiti yapılmıştır. Çalışmada kullanılan veri seti diğer EEG veri setlerinden farklı olarak üç boyutlu uyarınlar yardımıyla oluşturulmuş bir veri setidir. Gerçekleştirilen deneysel çalışmalar neticesinde dört adet alt bant ve bu bantların kombine edilmesiyle oluşturulan toplam özellik matrisleri yardımıyla on farklı test işleminin sonucu kaydedilmiş ve bu sonuçlara ait ortalama doğruluk puanları ve bu değerlere ait standart sapma değerleri elde edilmiştir.

Tablo 3. Önerilen yönteme ait sonuçların aynı veri seti ile gerçekleştirilen çalışmalarla kıyaslanması

Çalışma	Yıl	Veri Seti	Kullanılan Özellik	Sınıflandırıcı	Doğrulama Metodu	Doğruluk Puanı (%)
Yu ve ark. [36]	2022	VREED	GG (Göreceli Güç)	DVM	Çapraz doğrulama (70%-30%) 10 test ortalaması	73,77
Yu ve ark. [36]	2022	VREED	OFKD (Ortalama Faz Kilitleme Değeri)	DVM	Çapraz doğrulama (70%-30%) 10 test ortalaması	67,91
Uyanık ve ark. [11]	2022	VREED	DE	DVM	Çapraz doğrulama (70%-30%) 10 test ortalaması	76,22
Önerilen	2022	VREED	DE	1B-CNN	Çapraz doğrulama (70%-30%) 10 test ortalaması	74,06
Önerilen	2022	VREED	FGD	1B-CNN	Çapraz doğrulama (70%-30%) 10 test ortalaması	63,75

Tablo 3'te önerilen yöntemin başarısı veri seti ile gerçekleştirilen ilk çalışma olan [36] ve sonrasında 2022 yılında yaptığımız, bu veri seti ile yapılmış ikinci çalışma olan [11] ile karşılaştırılmıştır. [11] nolu çalışmamızda destek vektör makinesi tipi sınıflandırıcı ile elde edilen sonucun daha yüksek olduğu görülmektedir. Bu çalışmada önerilen yöntem Yu ve ark.'nın önerdiği göreceli güç (GG) özellikleri ile elde edilen sonuçlardan daha yüksek elde edilmiştir. [36] yeni veri kümesinde olumsuz ve olumlu duyguların sınıflandırılmasının etkinliği için bir temel sağlamıştır. Yazarlar elde edilen özelliklerin sınıflandırılmasında özellik çıkarımı için göreceli güç ve ortalama PLV yaklaşımlarını kullanmış ve DVM sınıflandırıcısı ile deneylerini gerçekleştirmişlerdir. Yazarlar, teta, alfa, beta ve gama bantlarının göreceli güç özelliklerinin birleştirilmesiyle %73,77'lik en iyi ortalama doğruluğu ürettiklerini bildirmişlerdir.

5. Sonuçlar

Bu çalışmada sanal gerçeklik tabanlı hazırlanmış bir EEG sinyali veri seti üzerinden farklı iki duygu tipinin tanınması için yeni bir yöntem önerilmiştir. Elde edilen sonuçlardan görüleceği üzere DE özelliklerinin EEG duygu tanıma için kullanılan veri setinde FGD özelliklerine göre çok daha yüksek oranda başarı elde ettiği görülecektir. Ayrıca, EEG sinyallerine ait alt bantlardan yüksek frekans değerlerinde salınım yapan beta ve gama bantlarının daha düşük salınım yapan teta ve alfa alt bantlarına göre daha yüksek başarı değerleri oluşturduğu gözlemlenmiştir. Bu durum bu alanda yapılan birçok çalışmaya paralellik göstermiştir [46-50]. Tüm bantlara ait özelliklerin birleştirilmesi senaryosunun ise en iyi başarı oranlarını elde ettiği ayrıca gözlemlenmiştir.

Bu çalışmada elde ettiğimiz sonuçların bir önceki çalışmada elde ettiğimiz sonuçların geride kalması, önceki çalışmamızın tartışma kısmında belirtmiş olduğumuz DE özelliklerinin ESA türü sınıflandırıcılar ile kullanılmasının iyi sonuçlar vermeyeceği durumunu ispatlar nitelikte olmuştur. Çalışmada elde edilen DE ile 1B-ESA sınıflandırıcıya ait sonucun, kullanılan veri seti ile gerçekleştirilen ilk çalışma olan [36] nolu çalışmadaki göreceli güç (GG) özelliğinin DVM ile sınıflandırılması yönteminden, aynı metodoloji adımları takip edilerek gerçekleştirilerek daha yüksek başarı puanı oluşturduğu görülmektedir. Bu durum DE özelliklerinin EEG sinyalleri

ile kullanımı için oldukça uygun bir yöntem olduğunu bir kez daha göstermiştir. Yukarıda da belirtildiği üzere DE özellikleri sinyaller içerisindeki düzensizlik özelliklerini net bir şekilde açığa çıkaran bir yöntemdir. Sinyaller içerisindeki doğrusal olmayan özellikleri çıkarmak için oldukça kullanışlıdır ve bu durum EEG sinyalleri için oldukça net sonuçlar verir.

Çalışmada elde edilen özellik verileri yardımıyla oluşturulacak 3 boyutlu bir özellik tensörünün 3 boyutlu bir ESA ile test edilmesi ve sonuçların burada elde edilen sonuçlar ile karşılaştırılması ileriye dönük bir çalışma planımızdır.

Kaynaklar

- [1] Chalmers D. The hard problem of consciousness. *The Blackwell companion to consciousness*, 2007, pp. 225–235.
- [2] Klinger E. Thought flow: Properties and mechanisms underlying shifts in content. *Singer*, 1999, pp. 29–50.
- [3] Robinson MD, Watkins E, Harmon-Jones E (Eds.). *Handbook of cognition and emotion*. The Guilford Press, pp. 3-16. (2013).
- [4] Adolphs R, Anderson DJ. *The Neuroscience of Emotion: A New Synthesis*. Princeton University Press, 2018.
- [5] Davidson RJ, Fox AS, Lapate RC, Shackman AJ. *Nature of Emotion: Fundamental Questions*. Oxford University Press, 2018.
- [6] Adolphs R, Mlodinow L, Barrett LF. What is an emotion?. *Current biology*, 2019, CB, 29(20), R1060–R1064.
- [7] Yadav SP, Zaidi S, Mishra A, Yadav V. Survey on machine learning in speech emotion recognition and vision systems using a recurrent neural network (RNN). *Archives of Computational Methods in Engineering*, 2022, 29(3), 1753-1770.
- [8] Aggarwal A, Srivastava A, Agarwal A, Chahal N, Singh D, Alnuaim A, Lee HN. Two-way feature extraction for speech emotion recognition using deep learning. *Sensors*, 2022, 22(6), 2378.
- [9] Hansen L, Zhang YP, Wolf D, Sechidis K, Ladegaard N, Fusaroli R. A generalizable speech emotion recognition model reveals depression and remission. *Acta Psychiatrica Scandinavica*, 2022, 145(2), 186-199.
- [10] Wu J, Zhang Y, Sun S, Li Q, Zhao X. Generalized zero-shot emotion recognition from body gestures. *Applied Intelligence*, 2022, 52(8), 8616-8634.
- [11] Uyanik H., Ozcelik STA, Duranay ZB, Sengur A, Acharya UR. Use of Differential Entropy for Automated Emotion Recognition in a Virtual Reality Environment with EEG Signals. *Diagnostics*, 2022, 12(10), 2508.
- [12] Chowdary MK, Anitha J, Hemanth DJ. Emotion Recognition from EEG Signals Using Recurrent Neural Networks. *Electronics*, 2022, 11(15), 2387.
- [13] Zuo X, Zhang C, Hämäläinen T, Gao H, Fu Y, Cong F. Cross-Subject Emotion Recognition Using Fused Entropy Features of EEG. *Entropy*, 2022, 24(9), 1281.
- [14] Şengür D, Siuly S. Efficient approach for EEG-based emotion recognition. *Electronics Letters*, 2020 December, vol. 56, no. 25, pp. 1361-1364.
- [15] Kyranides MN, Petridou M, Gokani HA, Hill S, Fanti KA. Reading and reacting to faces, the effect of facial mimicry in improving facial emotion recognition in individuals with antisocial behavior and psychopathic traits. *Current Psychology*, 1-14, 2022.
- [16] Massaccesi C, Korb S, Willeit M, Quednow BB, Silani G. Effects of the mu-opioid receptor agonist morphine on facial mimicry and emotion recognition. *Psychoneuroendocrinology*, 2022, 105801.
- [17] Khattak A, Asghar MZ, Ali M, Batool U. An efficient deep learning technique for facial emotion recognition. *Multimedia Tools and Applications*, 2022, 81(2), 1649-1683.
- [18] Xiao H, Li W, Zeng G, Wu Y, Xue J, Zhang J, Guo, G. On-Road Driver Emotion Recognition Using Facial Expression. *Applied Sciences*, 2022, 12(2), 807.
- [19] Menting-Henry S, Hidalgo-Lopez E, Aichhorn M, Kronbichler M, Kerschbaum H, Pletzer B. Oral contraceptives modulate the relationship between resting brain activity, amygdala connectivity and emotion recognition—a resting state fMRI study. *Frontiers in Behavioral Neuroscience*, 2022, 16.
- [20] Fauvé P, Tyvaert L, Husson C, Hologne E, Gao X, Maillard L, Hingray C. Functional MRI-based study of emotional experience in patients with psychogenic non-epileptic seizures: Protocol for an observational case-control study—EMOCRISES study. *Plos one*, 2022, 17(1), e0262216.
- [21] Gao L, Cai Y, Wang H, Wang G, Zhang Q, Yan X. Probing prefrontal cortex hemodynamic alterations during facial emotion recognition for major depression disorder through functional near-infrared spectroscopy. *Journal of Neural Engineering*, 2019, 16(2), 026026.
- [22] Nishi R, Fukumoto T, Asakawa A. Possible effect of natural light on emotion recognition and the prefrontal cortex: A scoping review of near-infrared (NIR) spectroscopy. *Advances in Clinical and Experimental Medicine: Official Organ Wroclaw Medical University*. 2023 April, PMID: 37093092.
- [23] Koelstra S ve diğerleri. DEAP: A Database for Emotion Analysis using Physiological Signals, *IEEE Transactions on Affective Computing*. 2012, vol. 3, no. 1, pp. 18-31.
- [24] Zheng WL, Lu BL. Investigating Critical Frequency Bands and Channels for EEG-based Emotion Recognition with Deep Neural Networks, *IEEE Transactions on Autonomous Mental Development (IEEE TAMD)*. 2015, 7(3): 162-175.
- [25] Ismael AM, Alçin ÖF, Abdalla KH, Şengür A. Two-stepped majority voting for efficient EEG-based emotion classification. *Brain Informatics*, 2020, 7(1), 1-12.

- [26] Ari B, Siddique K, Alçin ÖF, Aslan M, Şengür A, Mehmood RM. Wavelet ELM-AE Based Data Augmentation and Deep Learning for Efficient Emotion Recognition Using EEG Recordings. *IEEE Access*, 2022, vol. 10, pp. 72171-72181.
- [27] Alakus TB, Gonen M, Turkoglu I. Database for an emotion recognition system based on EEG signals and various computer games–GAMEEMO. *Biomedical Signal Processing and Control*, 2020, 60, 101951.
- [28] Joshi VM, Ghongade RB. EEG based emotion detection using fourth order spectral moment and deep learning. *Biomedical Signal Processing and Control*, 2021, 68, 102755.
- [29] Marín-Morales J, Higuera-Trujillo JL, Greco A. ve diğerleri. Affective computing in virtual reality: emotion recognition from brain and heartbeat dynamics using wearable sensors. *Scientific Reports*, 8(1), 2018,13657.
- [30] Suhaimi NS, Mountstephens J, Teo J. A Dataset for Emotion Recognition Using Virtual Reality and EEG (DER-VREEG): Emotional State Classification Using Low-Cost Wearable VR-EEG Headsets. *Big Data and Cognitive Computing*, 2022; 6(1):16.
- [31] Chen DW, Miao R, Yang WQ, Liang Y, Chen H, Huang L, Han N. A feature extraction method based on differential entropy and linear discriminant analysis for emotion recognition. *Sensors*, 2019, 19(7), 1631.
- [32] Li D, Xie L, Chai B, Wang Z. A feature-based on potential and differential entropy information for electroencephalogram emotion recognition. *Electronics Letters*, 2022, 58(4), 174-177.
- [33] Joshi VM, Ghongade RB. Optimal number of electrode selection for EEG based emotion recognition using linear formulation of differential entropy. *Biomedical and Pharmacology Journal*, 2020, 13(2), 645-653.
- [34] Li Y, Wong CM, Zheng Y, Wan F, Mak PU, Pun SH, Vai MI. EEG-based emotion recognition under convolutional neural network with differential entropy feature maps. In *2019 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications*, 2019 June (CIVEMSA), pp. 1-5.
- [35] Zheng WL, Zhu JY, Lu BL. Identifying Stable Patterns over Time for Emotion Recognition from EEG. *IEEE Transactions on Affective Computing*. 2017, 1–1.
- [36] Yu M. ve diğerleri. EEG-based emotion recognition in an immersive virtual reality environment: From local activity to brain network features. *Biomedical Signal Processing and Control*, 72 (2022): 103349.
- [37] Delorme A, Makeig S. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of Neuroscience Methods*, 2004, 134(1):9–21.
- [38] İnternet kaynağı, By Hugo Gambo - Own work, CC BY-SA 3.0, <https://commons.wikimedia.org/w/index.php?curid=473246>. Erişim Tarihi: 02.01.2023.
- [39] Sorkhabi MM. "Emotion Detection from EEG signals with Continuous Wavelet Analyzing." *American Journal of Computing Research Repository* 2.4 (2014): 66-70.
- [40] Shannon CE. A mathematical theory of communication. *The Bell System Technical Journal*, 27:379–423, 623–656, 1948.
- [41] Michalowicz JV, Nichols JM, Bucholtz F. *Handbook of Differential Entropy* (1st ed.). Chapman and Hall/CRC, 2013.
- [42] Lachaux JP ve diğerleri. Measuring phase synchrony in brain signals. *Human brain mapping*, 1999, pp.194–208.
- [43] Bruña R, Maestú F, Pereda E. Phase locking value revisited: teaching new tricks to an old dog. *Journal of neural engineering*, 2018, 15(5), 056011.
- [44] O'Shea K, Ryan N. An introduction to convolutional neural networks. *arXiv preprint*, 2015, arXiv:1511.08458.
- [45] Kiranyaz S, Avci O, Abdeljaber O, Ince T, Gabbouj M, Inman DJ. 1D convolutional neural networks and applications: A survey. *Mechanical systems and signal processing*, 151, 2021, p. 107398.
- [46] Yang K, Tong L, Shu J, Zhuang N, Yan B, Zeng Y. High gamma band EEG closely related to emotion: evidence from functional network. *Frontiers in human neuroscience*, 2020, 14, 89.
- [47] Yang Y, Gao Q, Song Y, Song X, Mao Z, Liu J. Investigating of Deaf Emotion Cognition Pattern By EEG and Facial Expression Combination. *IEEE Journal of Biomedical and Health Informatics*, Feb. 2022, vol. 26, no. 2, pp. 589-599.
- [48] Wang XW, Nie D, Lu BL. Emotional state classification from EEG data using machine learning approach, *Neurocomputing*, Volume 129, 2014, Pages 94-106.
- [49] Zheng WL, Zhu JY, Peng Y, Lu BL. EEG-based emotion classification using deep belief networks. *2014 IEEE International Conference on Multimedia and Expo (ICME)*, 2014, pp. 1-6.
- [50] Zhang J, Chen M, Hu S, Cao Y, Kozma R. PNN for EEG-based Emotion Recognition. *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 2016, pp. 2319-2323.