



Research Article

Machine Learning-Based Automatic Emotion Classification Using EEG Signals

Hakan Köksal¹ , Mehmet Baygın² 

¹ Department of Advanced Technologies, Ardahan University, 75002 Ardahan, Türkiye

² Department of Computer Engineering, Erzurum Technical University, 25000 Erzurum, Türkiye

* Correspondence: hknpyr@hotmail.com

Received: 8 May 2023; Accepted: 7 June 2023; Published: 30 June 2023

Abstract: Today, a wide variety of studies are carried out on the automatic interpretation of brain signals. At the beginning of these studies are emotion recognition and classification. Emotions play an active role in individuals' relations with the outside world, their actions and decisions. Therefore, emotion recognition is critical in human-computer interaction. It is a fact that various activities develop in the brain in the emotional changes of individuals. At this point, electroencephalogram (EEG) signals provide important clues. In this study, an approach using local binary patterns and statistical moment methods is proposed for automatic emotion recognition and classification. In this model, tunable Q wavelet transform method is used for signal separation and feature extraction is performed from both the raw signal and the subbands of this signal. ReliefF, a well-known method in the literature, was used in the feature selection phase of the model, and the most significant features were selected with this method. In the classification phase of the model, support vector machines, a classical classifier, were used. In this study, which exemplifies a basic level machine learning model, the DREAMER dataset is tested to validate the proposed model, and the k-fold cross-validation strategy is applied as a validation technique. In this study, in which arousal, valence and dominance states were examined, binary classification was performed.

Keywords: EEG, machine learning, emotion recognition, classification

Araştırma Makalesi

EEG Sinyalleri Kullanılarak Makine Öğrenmesi Tabanlı Otomatik Duygu Sınıflandırma

Öz: Günümüzde beyin sinyallerinin otomatik yorumlanması konusunda çok çeşitli çalışmalar yürütülmektedir. Bu çalışmaların başında ise duygu tanıma ve sınıflandırma gelmektedir. Duygular, bireylerin dış dünyayla olan ilişkilerinde, eylemlerinde ve kararlarında etkin rol oynamaktadır. Bu nedenle duygu tanıma insan-bilgisayar etkileşiminde kritik öneme sahiptir. Bireylerin duygusal değişimlerinde beyinde çeşitli aktivitelerin geliştiği bir gerçektir. Bu noktada, elektroansefalogram (EEG) sinyalleri önemli ipuçları sağlamaktadır. Bu çalışmada, otomatik duygu tanıma ve sınıflandırma için yerel ikili örüntüler ve istatistiksel moment yöntemlerini kullanan bir yaklaşım önerilmiştir. Bu modelde, sinyal ayrıştırma için ayarlanabilir Q dalgacık dönüşümü yöntemi kullanılmış olup hem ham sinyalden hem de bu sinyalin alt bantlarından özellik çıkarımı gerçekleştirilmiştir. Modelin özellik seçim aşamasında literatürde iyi bilinen bir yöntem olan ReliefF kullanılmış olup, en anlamlı özellikler bu yöntem ile seçilmiştir. Modelin sınıflandırma fazında ise klasik bir sınıflandırıcı olan destek vektör makineleri kullanılmıştır. Temel düzeyde bir makine öğrenmesi modelini örnekleyen bu çalışmada, önerilen modeli doğrulamak DREAMER veri seti test edilmiş olup doğrulama tekniği olarak k-katlamalı çapraz doğrulama stratejisi uygulanmıştır. Uyarılma, değerlik ve baskınlık durumlarının incelendiği bu çalışmada, ikili sınıflandırma işlemi gerçekleştirilmiştir.

Anahtar Kelimeler: EEG, makine öğrenmesi, duygu tanıma, sınıflandırma

Citation: H. Köksal and M. Baygın, "Machine Learning-Based Automatic Emotion Classification Using EEG Signals", *Journal of Studies in Advanced Technologies*, vol. 1, no. 1, pp. 26-40, Jun 2023, doi: 10.5281/zenodo.8074861

1. Giriş

Duygu insanoğlunun varoluşundan beri hislerini yansıtan ve bireylerin içsel/tepkisel durumlarını ifade eden ruh halleridir [1]. İnsanların karar verme mekanizmasında duygular oldukça büyük bir etkiye sahiptir [2]. Duygular sosyalleşerek ifade edilmekte ve kültürden kültüre farklılık göstermektedir [3]. İnsani bir durum olan duyguları analiz edebilmek için literatürde çeşitli yöntemler bulunmaktadır. Bu yöntemler arasında genellikle ses, konuşma, vücut hareketleri ve yüz ifadeleri bulunmaktadır. Bu durumlara ek olarak elektromiyogram (EMG), elektroansefalografi (EEG) ve elektrookülogram (EOG) gibi fizyolojik sinyaller de kullanılarak duygu analizi yapılabilmektedir [4]. Bu tür sinyaller duyguların güvenilir ve doğru bir şekilde analiz edilmesini sağlamaktadır. Duygu tanıma için kullanılan fizyolojik sinyaller arasında literatürde en sık kullanılan yaklaşım EEG'dir. EEG sinyallerinden duygu tanıma işlemi, bir bireyin insan-makine etkileşiminde önemli bir faktör olarak kabul edilen içsel durumunun doğrudan değerlendirilmesi olarak düşünülmektedir [5].

Tıp alanında çalışan profesyoneller ve psikiyatristler, hastalarının duygularını anlamaları ve doğru bir şekilde teşhis etmeleri için çalışmaktadır. Bu, duygusal tanımlamaların yapılabilmesi için önemli bir dönüm noktasıdır ve hastalarla ilgili sorunların çözümünde büyük bir rol oynamaktadır. Günümüzde, duyguların otomatik olarak tespiti için fizyolojik ve tıbbi görüntü sinyalleri kullanılmaktadır. Manyetik rezonans görüntüleme (MRI) gibi yöntemler duygu sınıflandırmada tercih edilen metotlardan biridir. Ancak, MRI kullanarak duygu sınıflandırma teknikleri zaman ve maliyet açısından oldukça pahalıdır [6]. Duyguların otomatik olarak tespit edilebilmesi için EEG sinyalleri kullanılmaktadır, çünkü duyguların tanımlanması zaman alan bir süreçtir. Bu nedenle, güvenilir, doğru ve sağlam sonuçlar elde etmek amacıyla bir otomatik duygu tanımlama sistemi geliştirilmesi gerekmektedir. Bu çalışmada, DREAMER veri tabanı ve makine öğrenme modeli, doğru bir sınıflandırma sistemi elde etmek için tercih edilmiştir. Genellikle görüntü işleme uygulamalarında kullanılan yerel ikili örüntü yöntemi bu çalışmada bir boyutlu sinyalden özellik çıkarma için kullanılmıştır. Ayrıca istatistiksel moment yaklaşımı kullanılarak da özellik çıkarma işlemi gerçekleştirilmiştir. Önerilen modelin performansını arttırabilmek için ayarlanabilir dalgacık dönüşümü yöntemi kullanılmıştır. Bu yöntem ile sinyal alt bantlarına ayrıştırılmış ve her alt banttan özellik çıkarımı gerçekleştirilmiştir. Modelin özellik seçim aşamasında ReliefF yöntemi tercih edilmiş olup, sınıflandırma fazında ise destek vektör makineleri kullanılmıştır. Bu sınıflandırma yaklaşımında k-katlamalı çapraz doğrulama tekniği uygulanmış olup k değeri 10 olarak belirlenmiştir.

1.1. Literatür Taraması

Otomatik duygu tanıma ve sınıflandırma literatürde sıklıkla çalışılan konuların başında gelmektedir. Bu kapsamda, EEG tabanlı otomatik duygu tanıma ve sınıflandırma için literatürde gerçekleştirilen bazı çalışmalar Tablo 1'de karşılaştırmalı olarak sunulmuştur.

Tablo1. EEG sinyalleri kullanılarak duygu sınıflandırma üzerine gerçekleştirilen bazı çalışmalar

Yazar(lar)	Yıl	Yöntem	Veri Seti	Kanal Sayısı	Sonuç(lar)
Xiao et al.[7]	2022	Dört boyutlu attention tabanlı sinir ağı, Evrişimli sinir ağı	SEED	62	Doğ.=%96.10
Li et al. [8]	2022	Çok ölçekli residual ağ, ikili sınıflandırma	SEED	62	Doğ.=%87.05
Zhong et al. [9]	2022	Hibrit evrişimli tekrarlayan sinir ağı	SEED	62	Doğ.=%95.33
Aguiñaga et al. [10]	2022	Çok sınıflı genetik programlama, evrişimli sinir ağı	BED	14	Doğ.=%92.10
Zhang et al. [11]	2022	Özel tasarım evrişimli sinir ağı	DREAMER	14	Doğ.=%84.16 Değerlik
Yuvara et al. [12]	2023	Regresyon ağacı	DREAMER	14	Doğ.=%85.28 Doğ.=%92.02
Liu et al. [2]	2023	Ön eğitilmiş evrişimli kapsül ağı	DEAP	32	Doğ.=%95.04 Değerlik
Wei et al. [13]	2023	Dönüşüm tabanlı evrişimli sinir ağı	DEAP	32	Doğ.=%93.89 Uyarılma
					Doğ.=%98.81 Değerlik
					Doğ.=%98.76

Tablo 1'den görüleceği üzere literatürde çok çeşitli açık erişimli veri setleri bulunmaktadır. Bu veri setleri ise genellikle evrişimli sinir ağı yöntemleri ile test edilmiştir. Derin ağ modelleri olarak isimlendirilen evrişimli sinir ağı yaklaşımları oldukça kompleks yaklaşımlardır. Bu yöntemlerin elde ettikleri başarı oranları yüksek olmasına rağmen hesapsal karmaşıklıkları oldukça yüksektir. Bu nedenle literatürdeki bu yöntemlere alternatif olarak hafif sıklet yöntemlerin önerilmesi gerekmektedir.

1.2. Motivasyon

Günümüzde beyin sinyallerinin otomatik olarak yorumlanması üzerine çeşitli çalışmalar gerçekleştirilmektedir. Bu çalışmaların çoğunluğu beyinle ilişkili nörolojik hastalıkların tespiti ve tanısı üzerinedir. Fakat gelişen teknolojiye paralel olarak beyin sinyallerini toplayabilen cihazlarda da çeşitli gelişmeler yaşanmıştır. Özellikle mobil EEG sinyal toplama cihazlarının yaygınlaşması ile EEG sinyalleri hastalık tanısından ziyade daha farklı alanlarda da kullanılabilir hale gelmiştir. Bu noktada duygu tanıma ve sınıflandırma literatürde EEG sinyalleri kullanılarak gerçekleştirilen çalışmaların başında gelmiştir.

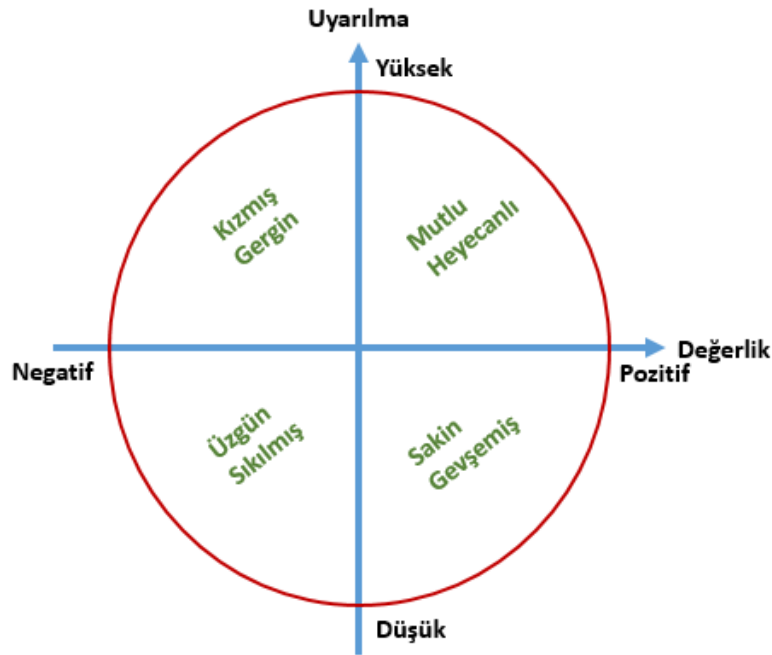
İnsan-bilgisayar etkileşiminde kritik bir öneme sahip olan duygu tanıma literatürde oldukça önemli bir problemdir. Bu amaçla EEG sinyalleri, duygusal değişimler sırasında beyindeki çeşitli aktiviteleri gösterebilmektedir. Gerçekleştirilen bu çalışmada, otomatik duygu tanıma ve sınıflandırma için bir makine öğrenmesi yaklaşımı önerilmiştir. Önerilen yöntemde sinyal ayırıştırma, bir boyutlu özellik çıkarma, özellik seçme ve sınıflandırma fazları uygulanmıştır. Temel düzeyde bir makine öğrenmesi yöntemi içeren bu yaklaşımı test etmek için literatürde açık erişimli olarak sunulan DREAMER veri seti kullanılmış, yine bu veri seti içerisinde yer alan uyarılma, değerlik ve baskınlık sinyalleri kanal bazlı test edilmiştir. Literatürdeki çalışmalar genellikle evrişimli sinir ağı tabanlıdır. Bu nedenle, ilgili çalışmaların hesapsal karmaşıklıkları oldukça yüksektir. Bu çalışmada ise literatürün aksine hesapsal karmaşıklığı düşük yöntemler tercih edilmiştir. Hafif sıklet olarak adlandırılan bu yaklaşım ile duygu tanıma ve sınıflandırma konusundaki araştırmalara katkı sağlanması amaçlanmıştır.

1.3. Organizasyon

Bu çalışmanın, ilk bölümünde literatürdeki EEG tabanlı duygu sınıflandırma modelleri incelenmiştir. Çalışmanın ikinci bölümünde duygu sınıflandırma için kullanılan bazı parametreler incelenmiştir. Üçüncü bölümde çalışmada kullanılan veri seti incelenmiş olup, dördüncü bölümde önerilen yöntemin detayları paylaşılmıştır. Çalışmanın beşinci bölümünde deneysel sonuçlar ve tartışma verilmiştir. Makalenin altıncı ve son bölümünde ise sonuçlar ile gelecek çalışmalar sunulmuştur.

2. EEG Tabanlı Duygu Tanıma

Son yıllarda, EEG sinyalleri temelli duygu tanıma konusu sıkça incelenen bir konudur. Psikologlar, duyguları ayrık ve kategorik yaklaşımlar olarak ikiye ayırmaktadır [14]. Ayrık model, öfke, şaşkınlık, mutluluk, korku, tiksinti ve üzüntü gibi altı farklı duygusal durumdan oluşmaktadır [15]. Kategorik model ise, duyguların uyarılma, değerlik ve baskınlık düzlemlerindeki boyutlarına göre ifade edilmektedir [16]. Bu durumun görsel ifadesi Şekil 1'de gösterilmiştir.



Şekil 1. Değerlik-uyarılma duygu modeli


Şekil 1'den görüleceği üzere duygu tanıma iki eksen üzerinde ifade edilebilmektedir. Bunlar sırasıyla uyarılma ve değerliktir. Ayrıca bu eksenler yüksek/düşük ve pozitif/negatif olmak üzere iki grupta incelenmektedir. Kategorik model olarak ifade edilen bu yaklaşım ile kişilerden alınan sinyaller gruplandırılabilir ve bireyin duygu durumu tespit edilebilmektedir. Bu model sadece EEG sinyalleri için değil, başka veri türleri içinde kullanılabilir. Temel olarak katılımcıların duygu durumlarını tetikleyerek toplanan verilerin yine bir anket kullanılarak etiketlenmesi prensibine dayanmaktadır. Öz değerlendirme mankeni (Self-Assessment Manikin-SAM) olarak adlandırılan bu yöntem ile katılımcıların mevcut duygu durumlarını ölçülebilmektedir [17].

3. Materyal

Bu çalışmada, literatürde açık erişimli olarak sunulan DREAMER [18] veri seti kullanılmıştır. Veri seti, Emotiv EPOC cihazı kullanılarak 14 erkek ve 9 kadından toplanan EKG ve EEG sinyallerini içermektedir. Katılımcılara 18 video izletilerek EEG sinyalleri kaydedilmiş ve duygusal durumlarını tespit edebilmek için değerlik, uyarılma ve baskın duygu durumları derecelendirilmiştir. Bu derecelendirmeler, 1-5 arasında değerlendirilmiş ve 3. seviye dışındaki diğer seviyeler düşük veya yüksek olarak sınıflandırılmıştır. EEG sinyalleri 128 Hz örnekleme hızında, 14 kanal üzerinden toplanmıştır. DREAMER veri setinin özellikleri Tablo 2'de sunulmuştur. Ek olarak, DREAMER veri seti için bir katılımcıya ait örnek EEG sinyali (uyarılma eksenini için) Şekil 2'de verilmiştir.

Tablo 2. DREAMER veri tabanının teknik özellikleri [18]

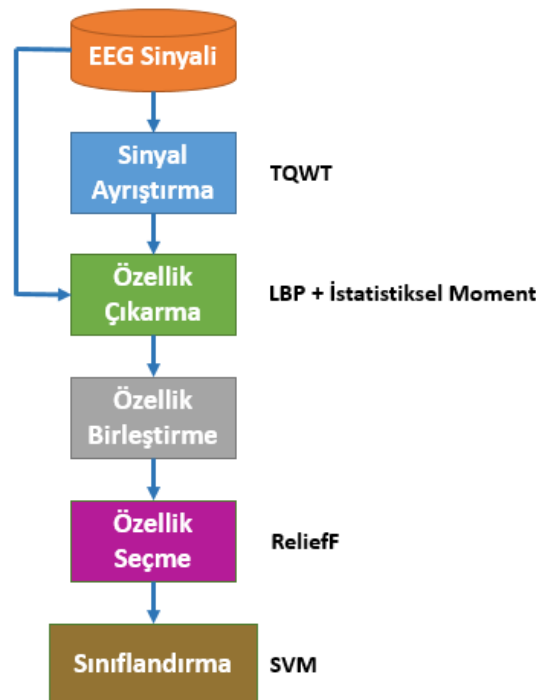
Özellikler	Değer
Sinyal Türü	EEG
Cihaz	Emotiv EPOC
Kanal Sayısı	14
Katılımcı Sayısı	23 (9 Kadın ve 14 Erkek)
Yaş Ortalaması	26.7
Kanallar	AF3, F3, F7, FC5, T7, T8, P7, O1, O2, P8, FC6, AF4, F4 ve F8
Uyaran Sayısı	18
Frekans	128 Hz
Sınıflar	Uyarılma, Değerlik ve Baskınlık



Şekil 2. Örnek bir katılımcı için uyarılma eksenine ait EEG sinyali

4. Önerilen Yöntem

Bu çalışmada, otomatik duygu sınıflandırma için hafif sıklet bir makine öğrenmesi yaklaşımı geliştirilmiştir. Geliştirilen model temel olarak sinyal ayrıştırma, özellik çıkarma, özellik seçme ve sınıflandırma fazlarından meydana gelmektedir. Bu noktada sinyal ayrıştırma için ayarlanabilir dalgacık dönüşümü (TQWT) kullanılmıştır. Bu yöntem ile ham sinyal alt bantlarına ayrıştırılmaktadır. Modelin ikinci aşamasında özellik çıkarımı işlemi gerçekleştirilmektedir. Bu fazda yerel ikili örüntüler ve istatistiksel moment yaklaşımları kullanılmaktadır. Uygulamanın üçüncü aşamasında en anlamlı özellikler ReliefF yöntemi ile seçilmekte ve seçilen özellikler destek vektör makinesi kullanılarak sınıflandırılmaktadır. Bu araştırmada geliştirilen modeli özetleyen bir blok diyagram Şekil 3'te verilmektedir.



Şekil 3. Çalışmada önerilen duygu sınıflandırma modeli

Şekil 3'ten görülebileceği üzere çalışma kapsamında önerilen model giriş olarak DREAMER EEG veri setini giriş olarak almaktadır. Daha sonrasında ham EEG sinyali özellik çıkarma modülüne giriş olarak verilmektedir. Ek olarak, TQWT yöntemi kullanılarak sinyal alt bantlarına ayrıştırılmakta ve bu alt bantlarda yine özellik çıkarım modülüne giriş olarak verilmektedir. Buradaki temel amaç hem ham sinyalden hem de alt bantlardan özellik çıkarmaktır. Bu sayede özellik vektörünün boyutunun genişletilmesi amaçlanmaktadır. Uyarılma, değerlik ve baskınlık sinyalleri için elde edilen özellik vektörleri literatürde iyi bilinen bir yöntem olan ReliefF algoritmasına giriş olarak verilmektedir. Bu aşamada sınıflandırma işlemi için en anlamlı özellikler seçilmekte ve bu sayede özellik vektörünün boyutu indirgenmektedir. Bu işlem, sınıflandırma algoritmasının performansını da arttırmaktadır. Bu sayede algoritmanın daha hızlı ve yüksek doğruluklu işlem yapabilmesi sağlanmaktadır. Modelin son fazında ise sığ bir sınıflandırıcı olan destek vektör makineleri kullanılmıştır. Bu aşamada, seçilen en anlamlı özellikler etiket değerlerine göre sınıflandırılmaktadır. Sınıflandırma fazında 10-katlamalı çapraz doğrulama stratejisi uygulanmıştır. Bu sayede genel ve yüksek güvenilirliğe sahip sınıflandırma sonuçları elde edilmiştir. Test işlemleri uyarılma, değerlik ve baskınlık sinyallerinin her biri için gerçekleştirilmiş ve bu eksenler için sonuçlar hesaplanmıştır. Bu çalışmada geliştirilen modelin detayları alt bölümler halinde verilmiştir.

4.1. TQWT Tabanlı Sinyal Ayrıştırma


Geliştirilen modelin ilk aşaması sinyal ayrıştırma işlemidir. Sinyal ayrıştırma işleminde ham EEG sinyali yüksek ve düşük frekanslı bileşenlerine ayrılmaktadır. Bu çalışmada düşük frekanslı bileşenler kullanılmıştır. Çünkü düşük frekanslı bileşenler genellikle sinyalin daha düzgün ve yavaş değişen kısımlarını içermektedir. Yüksek frekanslı bileşenler ise yine aynı sinyalin daha hızlı ve ani değişen bölümlerini kapsamaktadır. Bu nedenle geliştirilen model de ham EEG sinyalinin düşük frekanslı bileşenleri kullanılmıştır. Modelin sinyal ayrıştırma adımı TQWT [19] yöntemi tercih edilmiştir. TQWT yöntemi sinyali farklı frekans bileşenlerine ayırmaktadır. Bu yöntem sabit olmayan sinyallerin analizinde etkili bir performans göstermektedir. Klasik zaman-frekans analiz yöntemlerine göre ayarlanabilir frekans ayırma özelliğine sahiptir. Dalgacık dönüşümünün gelişmiş bir versiyonu olan bu yaklaşımda dalgacık seviyeleri ayarlanabilmektedir ve bu nedenle tercih edilmiştir. Özellikle biyomedikal sinyal işleme alanında sıklıkla kullanılan bu yöntem klasik dalgacık dönüşümü yöntemlerine göre daha etkili ve esnek bir yapı sunmaktadır.

4.2. Özellik Çıkarma

Geliştirilen modelde iki yöntem kullanılarak özellik çıkarımı yapılmıştır. Bunlar sırasıyla yerel ikili örüntüler (LBP) ve istatistiksel moment yaklaşımlarıdır. Bu yöntemlere ait detaylar alt bölümlerde verildiği gibidir.

4.2.1. Yerel İkili Örüntüler


Yerel ikili örüntü temel olarak bir görüntü işleme tekniğidir ve merkez pikselin komşuları ile karşılaştırılması prensibine dayanmaktadır. Bu yaklaşımda görüntü belirli parçalara bölünmekte ve merkez pikselin etrafındaki diğer piksel değerleri merkez ile karşılaştırılmaktadır. Karşılaştırma işlemi sonucunda 0 ve 1'lerden meydana gelen ikilik tabanda bir değer elde edilmektedir. Son olarak ikilik tabandaki değer onluk sisteme dönüştürülmekte ve yeni merkez piksel değeri belirlenmektedir. Bu işlemi özetleyen bir diyagram Şekil 4'te verilmiştir.



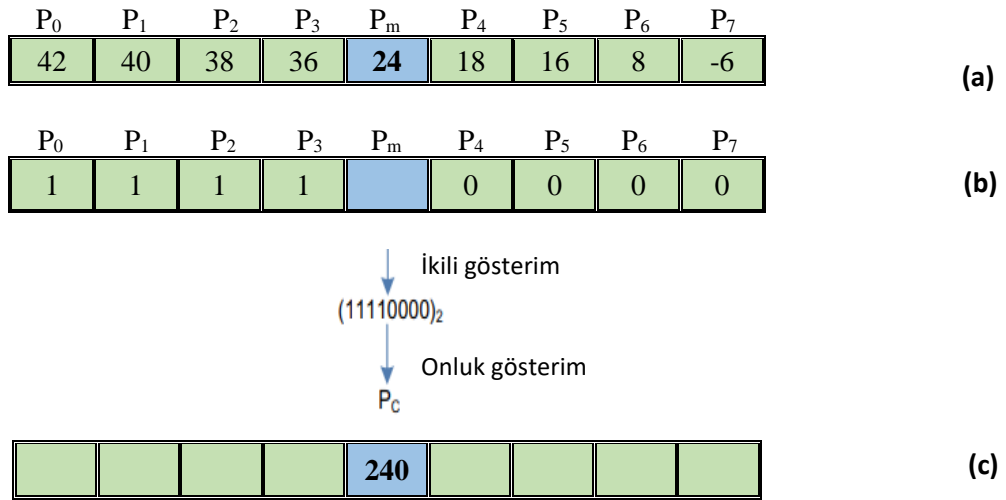
Şekil 4. Görüntü işleme için yerel ikili örüntü yaklaşımı

Şekil 4'te verilen yaklaşım incelendiğinde görüntünün temel olarak 3x3 boyutlarında parçalara bölündüğü ve merkez pikselin her bir komşu piksel ile karşılaştırıldığı görülmektedir. Benzer işlem EEG

sinyali içinde geçerlidir. EEG sinyallerinde ise sinyal segmenti 9 uzunluğunda örtüşen bloklara bölünmektedir. Daha sonra bu blok 3x3 matris boyutlarına dönüştürülmekte ve Şekil 4'te verilen adımlar benzer şekilde bu değerlere uygulanmaktadır. Elde edilen LBP değeri bir harita matrisinde tutulmakta ve son olarak bu harita matrisinin histogramı çıkarılmaktadır. Bu özellik çıkarım aşamasında elde edilen özellik sayısı 256 (2^8) adettir. Bu işlemin adımlarını özetleyen bir blok diyagram Şekil 5 ve 6'da verilmiştir.



Şekil 5. Örnek bir EEG sinyaline LBP işleminin uygulanması



Şekil 6. (a) Örnek sinyalin değerleri, (b) Karşılaştırma işlemi ve 8 bitlik ikilik gösterime sahip komşu örnekler ve (c) Ondalık değer

4.2.2. İstatistiksel Moment

Bu çalışmada kullanılan bir diğer özellik çıkarım işlemi istatistiksel momenttir. Bu işlemde sinyale ait lineer ve lineer olmayan özellikler çıkarılmaktadır. Bu işlemde 40 adet özellik elde edilmektedir. Özellik çıkarma işlemi ham sinyale ve alt bantlara uygulanmaktadır. Bu aşamada sinyalin maksimum, minimum, medyan, varyans, standart sapma, ortalama, entropi, kurtosis gibi değerleri hesaplanmaktadır. Bu değerleri hesaplamak için istatistiksel momentin matematiksel denklemleri aşağıda ifade edilmiştir [20].

$$f_1 = \min(x) \quad (1)$$

$$f_2 = \max(x) \quad (2)$$

$$f_3 = \frac{\sum x}{n}, \quad x = \text{sinyal} \quad (3)$$

$$f_4 = \frac{\sum(x - f_1)^2}{n - 1} \quad (4)$$

$$f_5 = \left\{ \frac{(n + 1)}{2} \right\} \quad (5)$$

$$f_6 = \sqrt{\frac{\sum(x - f_1)^2}{n - 1}} \quad (6)$$

$$f_7 = - \sum_i x_i^2 \log(x_i^2) \quad (8)$$

$$f_8 = |x_i| \leq p + \sum_i \min(x_i^2, p^2), \quad p = \text{threshold} \quad (7)$$

$$f_9 = \sum_i \log(x_i^2) \quad (9)$$

$$f_{10} = \frac{E(y - f_{10})^4}{(f_{11})^4} \quad (10)$$

$$f_{11} = \frac{E(x - f_1)^4}{(f_2)^4} \quad (11)$$

$$f_{12} = \frac{E(y - f_{10})^3}{(f_{11})^3} \quad (12)$$

$$f_{13} = \frac{E(x - f_1)^3}{(f_2)^3} \quad (13)$$

Yukarıda belirtilen denklemlerde, x sinyali ifade ederken, y ise sinyalin mutlak değerini ifade etmektedir. f_1, f_2, f_3, f_4, f_5 ve f_6 sırasıyla sinyalin minimumunu, maksimumunu, ortalamasını, varyansını, ortancasını ve standart sapmasını. f_7, f_8 ve f_9 sırasıyla Shannon, sure ve log enerji entropilerini hesaplamaktadır. f_{10} ve f_{11} kurtosis sürecini, f_{12} ve f_{13} skewness değerlerini temsil etmektedir.

4.3. Özellik Birleştirme

Geliştirilen modelin bu aşamasında yerel ikili örüntü ve istatistiksel moment adımlarından elde edilen özellikler birleştirilmekte ve yeni bir özellik vektörü elde edilmektedir. Temel olarak LBP yönteminden 256 özellik elde edilmektedir. Ek olarak, istatistiksel moment işleminden ise 40 özellik sağlanmaktadır. Bu sayede her bir EEG sinyalinden 296 adet özellik çıkarılmaktadır. Bu noktada, bölüm başında da belirtildiği üzere hem ham sinyalden hem de alt bantlardan özellik çıkarım işlemi gerçekleştirilmektedir. Geliştirilen modelde kullanılan sinyal ayrıştırma işlemi ile 14 alt bant elde edilmektedir. Bu işlemlerin neticesinde her bir EEG sinyalinden 4440 (1x296+14x296) boyutunda özellik vektörü sağlanmaktadır.

4.4. Özellik Seçme

Modelin bu fazında özellik vektörünün indirgenmesi sağlanmıştır. Bu aşamada sınıflandırma sonucu üzerinde anlamsız etkiye sahip olan özellikler elimine edilmiştir. Başka bir deyişle, en anlamlı özellikler seçilmiştir. Bu işlemde literatürde iyi bilinen bir yöntem olan ReliefF yaklaşımı tercih edilmiştir. ReliefF algoritması özellik vektöründeki her bir özellik için bir ağırlık değeri hesaplamaktadır. Bu değerler negatif veya pozitif olabilmektedir. Negatif değerler anlamsız özellikleri temsil ederken, pozitif ağırlığa sahip özellikler ise anlamlı olarak nitelendirilebilecek özelliklerdir. Algoritmanın bu aşamasında en yüksek ağırlığa sahip ilk 1000 özellik seçilmiş ve sınıflandırma fazına bu indirgenmiş özellik vektörü giriş olarak verilmiştir.

4.5. Sınıflandırma

Geliştirilen uygulamanın son aşaması sınıflandırmadır. Bu aşamada klasik ve sık bir sınıflandırıcı olan destek vektör makineleri kullanılmıştır. Ayrıca doğrulama tekniği olarak k-katlamalı çapraz doğrulama işlemi uygulanmış olup, bu noktada k değeri 10 olarak seçilmiştir.


5. Deneysel Sonuçlar ve Tartışma

Gerçekleştirilen bu çalışmada, otomatik duygu tanıma ve sınıflandırma için temel düzeyde bir makine öğrenmesi yaklaşımı geliştirilmiştir. Sinyal ayrıştırma, özellik çıkarma, özellik seçme ve sınıflandırma aşamalarından meydana gelen bu yaklaşımda literatürde açık erişimli sunulan bir veri seti kullanılmıştır. Bu veri seti uyarılma, değerlik ve baskınlık değerlerine sahip olup, EEG sinyallerinden oluşmaktadır. Geliştirilen modelde bu üç durum için sınıflandırma işlemi gerçekleştirilmiş olup, sonuçlar kanal bazlı hesaplanmıştır. Geliştirilen modelin performansını gözlemleyebilmek için doğruluk, kesinlik, duyarlılık, geometrik ortalama ve F1-skor parametre değerleri hesaplanmıştır. İkili sınıflandırma prensibine dayanan bu yaklaşımda uyarılma eksenini için kanal bazlı hesaplanan sonuçlar Tablo 3'te verilmiştir.

Tablo 3. Uyarılma eksenini için hesaplanan kanal bazlı sonuçlar

Kanal No	Kanal Adı	Doğruluk	Kesinlik	Duyarlılık	Geometrik Ort.	F1-Skor
1	AF3	66.44	64.21	61.94	58.68	62.08
2	F7	65.42	62.95	60.62	56.81	60.62
3	F3	65.42	62.93	60.95	57.67	61.04
4	FC5	62.71	59.42	57.60	53.02	57.30
5	T7	63.73	60.83	59.24	55.84	59.23
6	P7	67.80	66.03	63.04	59.46	63.23
7	O1	68.47	67.48	62.94	58.04	62.94
8	O2	68.14	66.93	62.67	57.86	62.66
9	P8	64.75	62.16	59.09	53.60	58.68
10	T8	66.44	64.43	61.12	56.47	61.02
11	FC6	66.44	64.27	61.61	57.83	61.68
12	F4	68.14	66.51	63.32	59.66	63.51
13	F8	64.41	61.64	59.47	55.35	59.36
14	AF4	66.78	64.74	61.89	58.02	61.96

Geliştirilen modelin uyarılma verilerine uygulanması ile elde edilen performans metrik değerleri Tablo 3'te verilmiştir. Bu sonuçlara göre en yüksek sınıflandırma başarısı 7 numaralı kanal olan O1 için elde edilmiştir. Bu kanala ait hata matrisi ise Şekil 7'de verilmektedir.



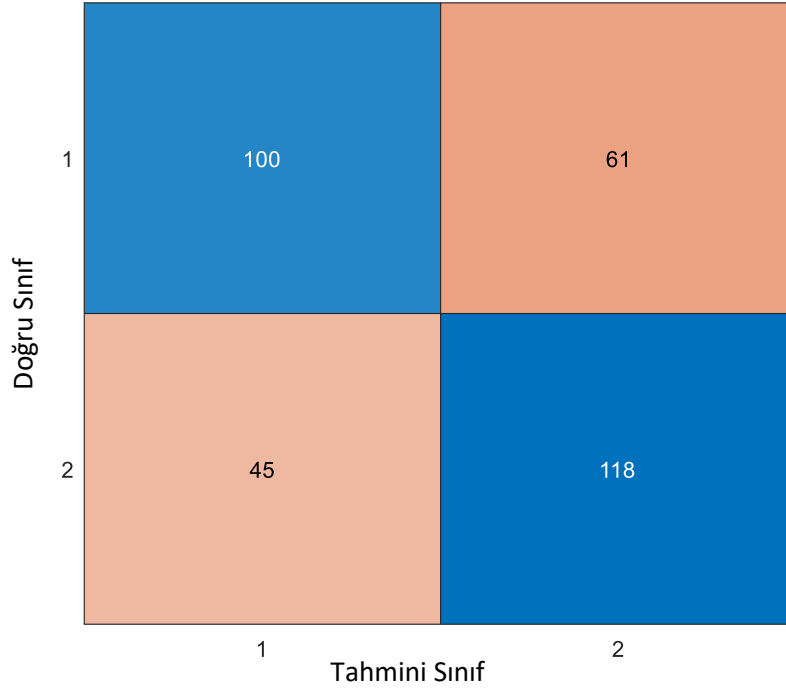
Şekil 7. Uyarılma için O1 kanalı ait hata matrisi

Bölüm başında belirtildiği üzere üç durum için de kanal bazlı sonuçlar hesaplanmıştır. Bu kapsamda değerlik eksenini için hesaplanan performans metrik değerleri Tablo 4’te verildiği gibidir.

Tablo 4. Değerlik eksenini için hesaplanan kanal bazlı sonuçlar

Kanal No	Kanal Adı	Doğruluk	Kesinlik	Duyarlılık	Geometrik Ort.	F1-Skor
1	AF3	63.89	63.89	63.88	63.87	63.88
2	F7	62.04	62.04	62.03	62	62.02
3	F3	67.28	67.44	67.25	67.06	67.18
4	FC5	64.81	64.83	64.80	64.77	64.79
5	T7	62.96	62.97	62.97	62.96	62.96
6	P7	63.58	63.64	63.56	63.43	63.51
7	O1	64.81	64.81	64.81	64.80	64.81
8	O2	54.01	54.01	54	53.94	53.98
9	P8	62.35	62.35	62.35	62.35	62.35
10	T8	57.41	57.42	57.41	57.41	57.41
11	FC6	62.04	62.04	62.04	62.04	62.04
12	F4	63.89	63.89	63.88	63.87	63.88
13	F8	63.27	63.27	63.27	63.27	63.27
14	AF4	55.25	55.24	55.23	55.18	55.21

Tablo 4’te verildiği üzere değerlik durumu için en yüksek sınıflandırma sonucu %67.28 olarak hesaplanmıştır. Ek olarak, en yüksek başarı F3 kanalı üzerinde elde edilmiştir. Bu bağlamda, F3 kanalı için elde edilen hata matrisi ise Şekil 8’de verilmiştir.




Şekil 8. Uyarılma için F3 kanalı ait hata matrisi

Geliştirilen modelin son aşamasında ise test edilen diğer durum baskınlıktır. Bu durum için hesaplanan performans metrik değerleri kanal bazlı olarak Tablo 5’te verilmiştir.

Tablo 5. Baskınlık eksenini için hesaplanan kanal bazlı sonuçlar

Kanal No	Kanal Adı	Doğruluk	Keskinlik	Duyarlılık	Geometrik Ort.	F1-Skor
1	AF3	70.07	64.85	59.74	52.11	59.91
2	F7	75.17	73.59	65.70	60.01	66.89
3	F3	67.01	59.45	56.10	46.86	55.60
4	FC5	74.15	72.56	63.85	56.83	64.72
5	T7	68.37	62.03	58.48	51.37	58.56
6	P7	72.79	71.71	60.92	50.85	60.93
7	O1	68.71	62.51	58.46	50.77	58.46
8	O2	67.01	59.06	55.27	44.22	54.31
9	P8	75.51	74.69	65.68	59.51	66.89
10	T8	69.39	63.72	58.13	48.65	57.81
11	FC6	74.83	74.22	64.35	57.13	65.31
12	F4	68.03	61.36	57.68	49.71	57.56
13	F8	73.81	70.85	64.70	59.35	65.69
14	AF4	74.83	73.15	65.18	59.19	66.29

Baskınlık durumu için hesaplanan en yüksek sınıflandırma sonucu %75.51 ile P8 kanalına aittir. Bu kanal için hesaplanan karmaşık matrisi ise Şekil 9’da verilmektedir.



Şekil 9. Değerlik için P8 kanalı ait hata matrisi

Gerçekleştirilen bu çalışmada, temel seviyede bir makine öğrenmesi yaklaşımı geliştirilmiştir. Bu kapsamda, kullanılan yöntemlerde temel düzeyde seçilmiştir. Bu nedenle hesaplanan sınıflandırma doğrulukları düşüktür.

5.2. Karşılaştırmalı Sonuçlar

Literatürde açık erişimli veri setleri kullanılarak gerçekleştirilen çok çeşitli çalışmalar bulunmaktadır. Bu çalışmada DREAMER veri setini kullanan bir makine öğrenmesi modeli geliştirilmiştir. Geliştirilen modelin aynı veri setini kullanan diğer çalışmalar ile karşılaştırması Tablo 6'da verilmiştir.

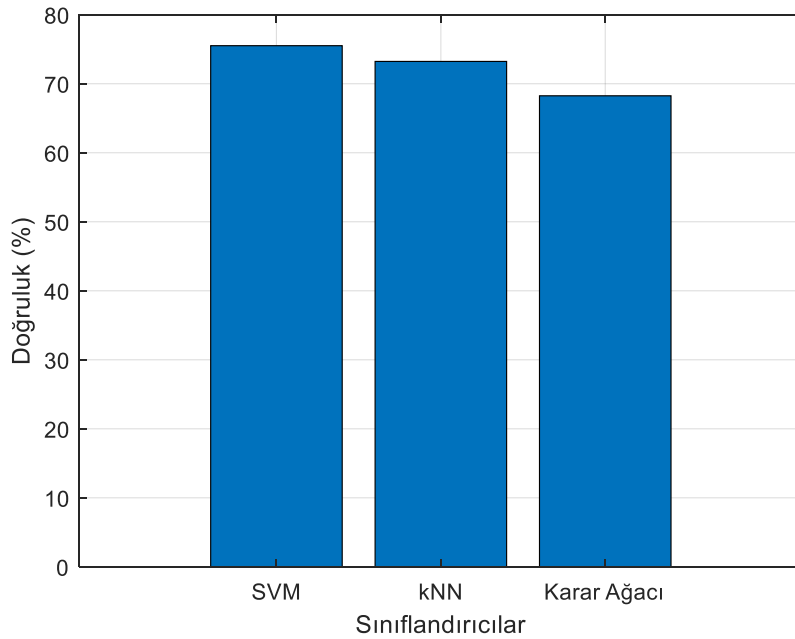
Tablo 6. DREAMER veri setini kullanan diğer çalışmalar ile karşılaştırmalı sonuçlar

Yazar(lar)	Yıl	Yöntem	Doğrulama Stratejisi	Sonuçlar		
				Uyarılma	Değerlik	Baskınlık
Cheng et al. [21]	2020	Derin sinir ağlar	10-katlamalı çapraz doğrulama	90.41	89.03	89.89
Liu et al. [22]	2020	Kapsül ağlar	10-katlamalı çapraz doğrulama	95.26	94.59	95.13
Bhattacharyya et al. [23]	2021	FBSE-EWT	10-katlamalı çapraz doğrulama	85.4	86.2	84.5
Wang et al. [24]	2021	Domain adaptasyon simetrik matris	---	76.57	67.99	81.77
Dogan et al. [25]	2021	Prime örüntü	LOSO çapraz doğrulama	100	100	100
Tuncer et al. [26]	2021	LEDPatNet19	10-katlamalı çapraz doğrulama	94.58	94.44	92.86
Li et al. [27]	2022	MTCA CapsNet	10-katlamalı çapraz doğrulama	94.96	95.54	95.52
Tuncer et al. [28]	2022	Tetromino örüntü	10-katlamalı çapraz doğrulama	100	100	100
He et al. [29]	2022	Zamansal evrişimli ağlar	LOSO çapraz doğrulama	63.69	66.56	
Quan et al. [30]	2023	Çoklu temsil varyasyonel otomatik kodlayıcı	15-katlamalı çapraz doğrulama	79.59	75.08	---

Tablo 6 (Devamı)

Yazar(lar)	Yıl	Yöntem	Doğrulama Stratejisi	Sonuçlar		
				Uyarılma	Değerlik	Baskınlık
Liu et al. [8]	2023	Özellik toplama ağı	10-katlamalı çapraz doğrulama	94.91	94.53	95.35
Wei et al.[13]	2023	Dönüşüm tabanlı evrişimli sinir ağı	10-katlamalı çapraz doğrulama	98.59	98.61	98.67
Bizim Metod		TQWT, LBP, istatistiksel moment, ReliefF ve SVM	10-katlamalı çapraz doğrulama	68.47	67.28	75.51

Tablo 6'dan görülebileceği üzere bu çalışmada önerilen yöntem literatürde gerçekleştirilen diğer çalışmalara göre düşük sınıflandırma başarısına sahiptir. Nitekim, DREAMER veri seti üzerinde bazı çalışmalar [25],[28] her üç durum için %100 sınıflandırma başarısına ulaşmıştır. Bizim yöntemimiz literatürdeki temel yöntemlerden oluşmaktadır. Bu nedenle, önerilen model düşük sınıflandırma performansı göstermiştir. Fakat, daha kompleks özellik çıkarma yöntemleri kullanılarak sınıflandırma performansının arttırılacağı ön görülmektedir. Gerçekleştirilen çalışmada farklı sınıflandırıcıların performansı da değerlendirilmiştir. Bu aşamada SVM, kNN ve karar ağaçları kullanılarak önerilen yöntemin performansı karşılaştırılmıştır. Karşılaştırma işlemi baskınlık eksenini için test işlemleri gerçekleştirilmiş olup, bu işleme ait test sonuçları Şekil 10'da verilmiştir.



Şekil 10. Sınıflandırma algoritmalarının baskınlık eksenindeki performansları

Şekil 10'dan görülebileceği üzere önerilen yöntem en yüksek sınıflandırma başarısına SVM algoritması ile ulaşmıştır. SVM ve kNN algoritmaları birbirine yakın performans göstermesine rağmen karar ağacı yöntemi %70'in altında kalarak en düşük sınıflandırma performansını göstermiştir.

6. Sonuçlar

Bu çalışmada, literatürde önemli bir sorun olan otomatik doğru duygu tanınmanın EEG sinyalleri kullanılarak gerçekleştirilmesine odaklanılmıştır. Önerilen yöntem, yerel ikili örüntü (YİÖ) ve istatistiksel moment tabanlı özellik çıkarma, ReliefF ile özellik seçme ve destek vektör makinesi (DVM) tabanlı sınıflandırma tekniğini kullanmaktadır. Önerilen yöntem, mevcut literatürde açık erişimli olan DREAMER veri seti üzerinde test edilmiştir ve sırasıyla uyarılma, değerlik ve baskınlık durumları için %68.47, %67.28 ve %75.51 oranında sınıflandırma doğruluğu elde edilmiştir.

Gerçekleştirilen bu çalışmada önerilen yöntem düşük sınıflandırma performansı göstermiştir. Diğer bölümlerde de belirtildiği üzere bu durum önerilen modelin basit yapısından kaynaklanmaktadır. Gelecekte

daha kompleks özellik çıkarma yöntemlerinin geliştirilmesi ve literatürdeki diğer çalışmalarda olduğu gibi yüksek sınıflandırma başarısına ulaşılması hedeflenmektedir. Ek olarak, önerilecek yeni yöntemlerin düşük hesapsal karmaşıklığa sahip olması amaçlanmaktadır.

Kaynakça

- [1] B. Parkinson, “Emotions are social”, *Br. J. Psychol.*, c. 87, sayı 4, ss. 663–683, 1996, doi: 10.1111/j.2044-8295.1996.tb02615.x.
- [2] S. Liu, Z. Wang, Y. An, J. Zhao, Y. Zhao, ve Y. D. Zhang, “EEG emotion recognition based on the attention mechanism and pre-trained convolution capsule network”, *Knowledge-Based Syst.*, c. 265, s. 110372, 2023, doi: 10.1016/j.knosys.2023.110372.
- [3] J. Prinz, “Which emotions are basic?”, *Emot. Evol. Ration.*, ss. 1–19, 2012, doi: 10.1093/acprof:oso/9780198528975.003.0004.
- [4] D. Maheshwari, S. K. Ghosh, R. K. Tripathy, M. Sharma, ve U. R. Acharya, “Automated accurate emotion recognition system using rhythm-specific deep convolutional neural network technique with multi-channel EEG signals”, *Comput. Biol. Med.*, c. 134, sayı May, s. 104428, 2021, doi: 10.1016/j.combiomed.2021.104428.
- [5] R. Jenke, A. Peer, ve M. Buss, “Feature Extraction and Selection for Emotion Recognition from Electrodermal Activity”, *IEEE Trans. Affect. Comput.*, c. 12, sayı 4, ss. 857–869, 2021, doi: 10.1109/TAFFC.2019.2901673.
- [6] A. Dogan vd., “Automated accurate emotion classification using Clefia pattern-based features with EEG signals”, *Int. J. Healthc. Manag.*, ss. 1–14, 2022, doi: 10.1080/20479700.2022.2141694.
- [7] G. Xiao, M. Shi, M. Ye, B. Xu, Z. Chen, ve Q. Ren, “4D attention-based neural network for EEG emotion recognition”, *Cogn. Neurodyn.*, ss. 1–14, 2022, doi: 10.1007/s11571-021-09751-5.
- [8] J. Li vd., “Cross-subject EEG emotion recognition combined with connectivity features and meta-transfer learning”, *Comput. Biol. Med.*, c. 145, sayı April, s. 105519, 2022, doi: 10.1016/j.combiomed.2022.105519.
- [9] M. yu Zhong, Q. yu Yang, Y. Liu, B. yu Zhen, F. da Zhao, ve B. bei Xie, “EEG emotion recognition based on TQWT-features and hybrid convolutional recurrent neural network”, *Biomed. Signal Process. Control*, c. 79, sayı P2, s. 104211, 2023, doi: 10.1016/j.bspc.2022.104211.
- [10] A. R. Aguiñaga, L. M. Delgado, V. R. López-López, ve A. C. Téllez, “EEG-Based Emotion Recognition Using Deep Learning and M3GP”, *Appl. Sci.*, c. 12, sayı 5, s. 2527, 2022, doi: doi.org/10.3390/.
- [11] Z. Zhang, S. hua Zhong, ve Y. Liu, “GANSER: A Self-supervised Data Augmentation Framework for EEG-based Emotion Recognition”, *IEEE Trans. Affect. Comput.*, c. XX, sayı XX, ss. 1–17, 2022, doi: 10.1109/TAFFC.2022.3170369.
- [12] R. Yuvara, P. Thagavel, J. Thomas, ve J. Fogarty, “Comprehensive Analysis of Feature Extraction Methods for Emotion Recognition from Multichannel EEG Recordings”, *Sensors*, ss. 1–19, 2023, doi: 10.3390/s23020915.
- [13] Y. Wei, Y. Liu, C. Li, J. Cheng, R. Song, ve X. Chen, “TC-Net: A Transformer Capsule Network for EEG-based emotion recognition”, *Comput. Biol. Med.*, c. 152, sayı June 2022, s. 106463, 2023, doi: 10.1016/j.combiomed.2022.106463.
- [14] K. R. Scherer, “What are emotions? and how can they be measured?”, *Soc. Sci. Inf.*, c. 44, sayı 4, ss. 695–729, 2005, doi: 10.1177/0539018405058216.
- [15] L. F. Barrett, M. Gendron, ve Y. M. Huang, “Do discrete emotions exist?”, *Philos. Psychol.*, c. 22, sayı 4, ss. 427–437, 2009, doi: 10.1080/09515080903153634.
- [16] E. Harmon-Jones, C. Harmon-Jones, ve E. Summerell, “On the importance of both dimensional and discrete models of emotion”, *Behav. Sci. (Basel)*, c. 7, sayı 4, 2017, doi: 10.3390/bs7040066.
- [17] M. M. Bradley ve P. J. Lang, “Measuring emotion: The self-assessment manikin and the semantic differential”, *J. Behav. Ther. Exp. Psychiatry*, c. 25, sayı 1, ss. 49–59, Mar. 1994, doi: 10.1016/0005-7916(94)90063-9.
- [18] S. Katsigiannis ve N. Ramzan, “DREAMER: A Database for Emotion Recognition Through EEG and ECG Signals from Wireless Low-cost Off-the-Shelf Devices”, *IEEE J. Biomed. Heal. Informatics*, c. 22, sayı 1, ss. 98–107, 2018, doi: 10.1109/JBHI.2017.2688239.

- [19] I. W. Selesnick, "Wavelet transform with tunable Q-factor", *IEEE Trans. Signal Process.*, c. 59, sayı 8, ss. 3560–3575, 2011, doi: 10.1109/TSP.2011.2143711.
- [20] M. Baygin, "An accurate automated schizophrenia detection using TQWT and statistical moment based feature extraction", *Biomed. Signal Process. Control*, c. 68, sayı January, s. 102777, 2021, doi: 10.1016/j.bspc.2021.102777.
- [21] J. Cheng vd., "Emotion Recognition From Multi-Channel", *IEEE J. Biomed. Heal. Informatics*, c. 25, sayı 2, ss. 453–464, 2021.
- [22] Y. Liu vd., "Multi-channel EEG-based emotion recognition via a multi-level features guided capsule network", *Comput. Biol. Med.*, c. 123, sayı July, s. 103927, 2020, doi: 10.1016/j.combiomed.2020.103927.
- [23] A. Bhattacharyya, R. K. Tripathy, ve L. Garg, "A Novel Multivariate-Multiscale Approach for Computing EEG Spectral and Temporal Complexity for Human Emotion Recognition", c. 21, sayı 3, ss. 3579–3591, 2021, doi: 10.1109/JSEN.2020.3027181.
- [24] Y. Wang, S. Qiu, X. Ma, ve H. He, "A prototype-based SPD matrix network for domain adaptation EEG emotion recognition", *Pattern Recognit.*, c. 110, s. 107626, 2021, doi: 10.1016/j.patcog.2020.107626.
- [25] A. Dogan vd., "PrimePatNet87: Prime pattern and tunable q-factor wavelet transform techniques for automated accurate EEG emotion recognition", *Comput. Biol. Med.*, c. 138, sayı September, s. 104867, 2021, doi: 10.1016/j.combiomed.2021.104867.
- [26] T. Tuncer, S. Dogan, ve A. Subasi, "LEDPatNet19: Automated emotion recognition model based on nonlinear LED pattern feature extraction function using EEG signals", *Cogn. Neurodyn.*, c. 16, sayı 4, ss. 779–790, 2022, doi: 10.1007/s11571-021-09748-0.
- [27] C. Li vd., "Emotion recognition from EEG based on multi-task learning with capsule network and attention mechanism", *Comput. Biol. Med.*, c. 143, sayı January, s. 105303, 2022, doi: 10.1016/j.combiomed.2022.105303.
- [28] T. Tuncer, S. Dogan, M. Baygin, ve U. Rajendra Acharya, "Tetromino pattern based accurate EEG emotion classification model", *Artif. Intell. Med.*, c. 123, sayı March 2021, s. 102210, 2022, doi: 10.1016/j.artmed.2021.102210.
- [29] Z. He, Y. Zhong, ve J. Pan, "Joint Temporal Convolutional Networks and Adversarial Discriminative Domain Adaptation for Eeg-Based Cross-Subject Emotion Recognition", *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, c. 2022-May, ss. 3214–3218, 2022, doi: 10.1109/ICASSP43922.2022.9746600.
- [30] J. Quan, Y. Li, L. Wang, R. He, S. Yang, ve L. Guo, "EEG-based cross-subject emotion recognition using multi-source domain transfer learning", *Biomed. Signal Process. Control*, c. 84, sayı September 2022, s. 104741, 2023, doi: 10.1016/j.bspc.2023.104741.