

# Evrişimsel Sinir Ağları ile EEG Tabanlı Duygu Tanıma

## EEG Based Emotion Recognition with Convolutional Neural Networks

Caner ÖZCAN

Bilgisayar Mühendisliği, Karabük  
Üniversitesi, Karabük, Türkiye  
canerozcan@karabuk.edu.tr

Hüseyin ÇİZMECİ

Bilgisayar Teknolojileri, Hitit  
Üniversitesi, Çorum, Türkiye  
huseyincizmeci@hitit.edu.tr

**Özetçe**—Duygu tanımda çok kanallı elektroensefalografi (EEG) sinyallerinin kullanımı giderek daha yaygın hale gelmektedir. Ancak yapılan çalışmalarda, EEG sinyallerinin karmaşıklığından dolayı aynı kişiden kaydedilen sinyallerde bile bozulmalar olabildiği görülmüştür. Bu yüzden insan beyninden elde edilen EEG sinyallerinin doğru ve tutarlı bir şekilde analiz edilmesi ve işlenmesi gerekir. Önerdiğimiz, Welch güç spektral yoğunluğu tahminine ve bir evrişimsel sinir ağına dayanan yöntem ile, SEED EEG veri seti üzerinde yüksek oranda sınıflandırma doğruluğu elde edilmiştir.

**Anahtar Kelimeler** — evrişimsel sinir ağı; duygu analizi; elektroensefalografi; özellik çıkarma.

**Abstract**—The use of multichannel electroencephalography (EEG) signals has become increasingly common in emotion recognition. However, studies have shown that due to the complexity of EEG signals, even the signals recorded from the same person may be disturbed. Therefore, EEG signals from the human brain need to be accurately and consistently analyzed and processed. With the method based on the Welch power spectral density estimation and a convolutional neural network, a high degree of classification accuracy was obtained on the SEED EEG dataset.

**Keywords** — convolutional neural network; emotion analysis; Electroencephalography; feature extraction.

### I. GİRİŞ

Duygu, bir objenin ya da olayın bilinçli veya bilinçsiz algılanmasıyla harekete geçen psikolojik ve fizyolojik bir süreçtir. Genellikle ruh hali, kişilik, yatkınlık ve motivasyonla ilişkilendirilir. Duygu araştırması ise, bilgisayar bilimi, psikoloji ve sinirbilimi ile ilgili çalışmaları kapsayan disiplinler arası bir alandır. Günümüz bilgisayar ve yazılım sistemlerinin çoğu bu bilgiyi yorumlamada yetersizdir. Duygu analizi ile ilgili yapılan çalışmaların amacı, insan-bilgisayar etkileşimi sırasında meydana gelen duygusal ipuçlarını tespit edip sentezleyerek bu yetersizliği gidermektir. Derin öğrenmenin ortaya çıkması sinyal ve bilgi işlemede büyük bir etki meydana getirmiştir [1]. Derin otomatik kodlayıcılar, evrişimsel sinir ağları ve derin

inanç ağları gibi birçok derin mimari model öne sürülmüştür [2-5].

Çeşitli duygu tanıma yöntemleri arasında EEG sinyallerini temel alan yaklaşımlar, yüz ifadesi ve jest gibi diğer dış görünüm ipuçlarına kıyasla yüksek doğruluk ve güvenilir bir değerlendirme sunduğu için daha fazla tercih edilmektedir [6]. EEG, beyin dalgalarının elektriksel yöntemlerle ölçülmesi ve izlenmesi olarak ifade edilebilir. Elektrotlar kafa derisi boyunca yerleştirilerek beyindeki nöronların iyonik akımdan kaynaklanan voltaj değişimlerini ölçer [7]. Ancak EEG sinyalleri düşük sinyal-gürültü oranına (SNR) sahip olduğu için genellikle gürültü ile karıştırılmaktadır [8]. Ayrıca EEG sinyalleri, görüntü veya konuşma sinyallerinden farklı olarak oldukça karmaşık yapıdadır [9]. Bu durum EEG sinyallerinin analizini oldukça güçleştirmektedir.

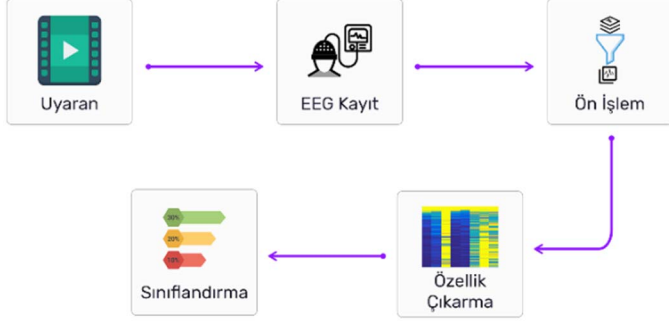
Son zamanlarda araştırmacılar, EEG tabanlı duygu tanımda kritik frekans bantlarını ve kanallarını bulmaya yoğunlaştılar [8]. Elde edilen sonuçlar gama bandının (30-100 Hz.), duygu sınıflandırma için diğerlerine kıyasla daha uygun olduğunu göstermektedir [10]. Ayrıca yapılan çalışmalar F3 ve F4'ün, duygu analizi için uygun elektrot konumları olduğunu işaret etmektedir [11]. Buna rağmen, uygun kanalların ve frekans bantlarının nasıl belirleneceği henüz tam olarak araştırılmamıştır.

Beyin-bilgisayar ara yüzleri sadece sınıflandırıcı kullanmaz. Öncelikle, EEG sinyallerinin tutarlı bir şekilde temsil edilebilmesi için bir ön işleme ve ardından özellik çıkarma / seçme işlemine tabi tutulur [12].

Bu çalışmada, mevcut yöntemlere alternatif olarak, SEED veri setinden elde edilen EEG sinyalleri, Welch güç spektral yoğunluğu tahminine dayanan yöntem ile özellikleri çıkarılıp görsel hale getirilerek, eğitim ve test verileri elde edildi. Ardından oluşturulan evrişimsel sinir ağı tabanlı derin öğrenme modeli bu verilerle eğitildi ve işlem sonunda yüksek oranda sınıflandırma doğruluğu elde edildi.

## II. EEG TABANLI DUYGU ANALİZİ

EEG tabanlı duygu analizi Şekil 1’de görüldüğü üzere beş ana aşamadan oluşur. Öncelikle kullanıcılar ilgili duygunun tetiklenmesini sağlayacak uyarılara maruz kalırlar. Daha sonra beyin aktiviteleri eşzamanlı olarak EEG sinyalleri şeklinde kaydedilir. Ardından, gürültü ve istenmeyen yapıtları (artefakt) gidermek için ham veriler ön işleme tabi tutulur ve işlenen bu verilerin özellikleri çıkartılır. En sonunda çıkartılan özelliklere göre bir sınıflandırıcı modeli eğitilir. Eğer istenirse kullanıcının o anki duygu durumu tespit edildikten sonra bir geri bildirim uygulanabilir.



Şekil 1. EEG tabanlı duygu analizi tasarımı.

## III. YÖNTEM

Yapılan çalışmada, EEG sinyalleri ön işlem sürecinden geçirildikten sonra duygu analizinde kullanılabilecek en uygun kanallar seçildi. Her bir kanal için 2000 adet örnek sayısı alındı. Daha sonra elde edilen bu verilerin özellikleri çıkarılarak görsel hale getirildi. Oluşturulan görseller, 28 x 28 piksel boyutuna ve tek kanal renk moduna düşürüldü. Bu sayede sınıflandırma modelinde kullanılabilecek eğitim ve test verileri oluşturuldu.

### A. Ön İşleme


Sinyallerin boyutunu küçültmek ya da istenmeyen yapıtlardan ve gürültülerden temizlemek için ön işlem süreci uygulanır. Genellikle en sık kullanılan ön işlemler, örneklem hızının düşürülmesi (downsampling) ve belirlenen aralıkta band geçiren filtre (bandpass filter) kullanımıdır.

Örneklem hızının düşürülmesi, bir sinyalin örnekleme oranının azaltılması işlemidir. Genellikle verinin oranını veya boyutunu azaltmak için kullanılır. Band geçiren filtre ise, sadece belirtilen aralıktaki frekansları geçiren, bu aralığın dışındaki frekansları reddeden bir filtre türüdür.

Bu çalışmada kullanılan EEG verileri 200 Hz. örnekleme hızına düşürülmüştür. Gürültüyü filtrelemek için EEG verileri 0,3 ile 50 Hz. arasında bant geçiren filtre ile işlenmiştir [8]. Ayrıca deneylerde elde edilen Elektrookülografi (EOG) verisi, kaydedilen EEG verilerinden göz kırpması artefaktlarını tanımlamak için kullanılmıştır [8].

### B. Uygun Kanalların Seçilmesi

Ön işlemin ardından elde edilen EEG verilerindeki 62 kanaldan AF3, AF4, F3, F4, F7, F8, T7 ve T8 olmak üzere sekiz elektrotlu bir havuz elde edildi [13]. Ayrıca her bir kanal için 2000 adet örnek sayısı alındı. Şekil 2’de 8 kanal ve her kanal için 2000 örnek ile elde edilen ham (sadece ön işlemden geçmiş) EEG verisinin görselleştirilmiş hali bulunmaktadır.



Şekil 2. (2000 x 8) Ham EEG verisinin görselleştirilmiş hali.

### C. Özellik Çıkarma

EEG verisinin sadece ön işlemten geçtikten sonra görüntü formatına dönüştürülmesi bile, elde edilen resmin oldukça karmaşık olmasına neden olacaktır. Bu durum, sınıflandırma işlemi için kullanılacak modelin doğruluğunu olumsuz yönde etkileyecektir. EEG sinyallerinin düzgün bir şekilde temsil edilebilmesi için birçok özellik çıkarma yöntemi vardır. Bunlardan biri, Welch güç spektral yoğunluğu tahminidir.

Güç spektral yoğunluğu (PSD), frekans spektrumuna göre sinyal gücünü verir. PSD’ nin iyileştirilmiş hali ise Welch tarafından önerilen yöntemdir. Bu yöntem, öncelikle zaman serisi verilerini bölümlere ayırır. Daha sonra her bir bölümün değiştirilmiş bir periodogramını hesaplar ve ardından elde edilen PSD tahminlerinin ortalamasını alır.

$$\hat{S}_{xx}^i(f) = \frac{Y_s}{K.M} \left| \sum_{n=1}^{M-1} x_i(n)w(n)e^{-j2\pi fn} \right|^2 \quad (1)$$

Denklem (1)’de  $i$ , iyileştirilmiş periyodogramı,  $f = f_s$  normalize edilmiş frekans değişkenini,  $Y_s$  ölçekleme faktörünü ve  $w(n)$  pencereleme fonksiyonunu ifade eder.

$K$ , normalize sabiti olup;

$$K = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n) \quad (2)$$


Şeklinde ifade edilir (2).

Welch metodu ile güç spektral yoğunluğu tahmini ise;

$$\hat{P}_w(f) = \frac{1}{L} \sum_{i=0}^{L-1} \hat{S}_{xx}^i(f) \quad (3)$$

Şeklinde ifade edilir (3). Burada  $L$ , işaretin uzunluğudur.


Yapılan çalışmada, girdi matrisinde bulunan sekiz kanalın her biri (1 x 2000) alınarak Welch güç spektral yoğunluğu tahmini ile özellikleri çıkarılmıştır. Şekil 3’te, 8 kanal EEG verisinin, Welch güç spektral yoğunluğu tahmini ile özellik çıkarma işlemi görülmektedir.



Şekil 3. 8 Kanal EEG verisinin Welch güç spektral yoğunluğu tahmini ile özellik çıkartma işlemi.

#### D. Yapay Sinir Ağı Modeli İçin Eğitim ve Test Verilerinin Oluşturulması


Özellik çıkartma işleminden sonra her bir resim 28 x 28 piksel boyutuna ve tek kanal (gri-seviyesi) moda düşürüldü. Resimlerin temsil ettiği duygular (negatif, pozitif ve nötr) sırası ile 0, 1 ve 2 değerleri ile birlikte kaydedildi. Şekil 4'te elde edilen resimlerden bir tanesi bulunmaktadır.



Şekil 4. İşlem sonunda girdi olarak elde edilen 28 x 28 piksel ve tek kanal resimlerden bir tanesi.

#### E. Sınıflandırma

Bir sınıflandırma modeli tasarlanırken en önemli kriterler, kodlanan beyin sinyalinin tipi ve kontrol edilen uygulamanın türüdür. Bilindiği üzere evrimsel sinir ağları (CNN), başarılı sonuçlar vermesi nedeniyle bilgisayarlı görü uygulamalarında sıklıkla kullanılmaktadır [14, 15].



Şekil 5. Evrimsel sinir ağı katman yapısı.

Şekil 5'te görüldüğü üzere CNN'ler genellikle, evrşim (CONV), ortaklama (POOL) ve tam bağlantı (FULLY CONNECTED) katmanlarından oluşur.


Çalışmada kullanılan CNN modelinde sırasıyla, 32 ve 64 filtre sayısına ve [3, 3] filtre boyutuna sahip iki adet evrşim katmanı bulunmaktadır. Bu katmanları, [3, 3] boyutundaki kümelerden en büyük değerleri alarak yeni bir matris oluşturan ortaklama (MaxPooling) katmanı takip etmektedir. Modeldeki aşırı öğrenmeyi (overfitting) önlemek için 0.5 oranında

seyreltme (dropout) katmanı kullanılmıştır. Son olarak sırasıyla, 250 ve 3 nörondan oluşan iki adet yapay sinir ağı katmanı (dense) ile model oluşturulmuştur.

#### IV. DENEYSEL ÇALIŞMALAR

Çalışmada kullanılan SEED EEG veri setinde, uyaran olarak materyal havuzundan her biri yaklaşık 4 dakika süreli 15 film klipi seçilmiştir. Her film klipi, duygusal anlamları (pozitif, negatif ve nötr duygular) en üst düzeye çıkarmak için düzenlenmiştir [8, 16].

Deneylere, 7 erkek ve 8 kadın olmak üzere isimleri gizlenmiş toplam 15 kişi katılmıştır. Her deney için toplam 15 deneme vardır ve 3 kez tekrar edilmiştir. Her klipten önce 5 saniye ipucu ve her klipten sonra 45 saniye geri bildirim (değerlendirme) yapılmıştır. Geri bildirimde katılımcılara her klip izlendikten sonra ilgili anketi doldurarak duygusal tepkilerini bildirmeleri söylenmiştir [8, 16]. Şekil 6'da deney protokolünden bir kesit yer almaktadır.



Şekil 6. Deney protokolü.


Deneyler sabah veya öğleden sonraları sessiz bir ortamda, uluslararası 10-20 sistemine göre 62 kanallı elektrot başlığından 1000 Hz. örnekleme hızında bir ESI NeuroScan sistemi kullanılarak kaydedilmiştir [8, 16].

Yapılan çalışmada, elde edilen eğitim ve test verileri ayrı ayrı CNN ile tasarlanan modelde kullanılmıştır. Her uygulama için 10 adet adım sayısı (epoch) belirlenmiştir.

##### 1) Sınıflandırma Modelinin Performans Ölçütleri :

Sınıflandırma modellerinin performansını ölçmede kullanılan yöntemlerden biri karmaşıklık matrisidir. Modelin, pozitif ve negatif örnekleri barındıran test verilerinin, ne oranda sınıflandırıldığını gösterir.

Doğruluk değeri, ağıın sınıflandırmayı ne oranda doğru yaptığını gösterir. Hata değeri ise, Tasarlanan modelin hata oranını belirtir. Şekil 7'de Welch güç spektral yoğunluğu tahmini kullanılarak elde edilen veriler ile eğitimi ve testi yapılan ağıın doğruluk ve hata grafiği gösterilmektedir.



Şekil 7. Modelin doğruluk ve hata grafiği.

Keskinlik (precision), tüm pozitif sınıflardan, ne kadarının doğru tahmin edildiğinin oranıdır.

$$Keskinlik = \frac{Doğru Pozitif}{Doğru Pozitif + Yanlış Pozitif} \quad (4)$$

Duyarlılık (recall) değeri ise, tüm sınıflardan, ne kadarının doğru tahmin edildiğinin oranıdır.

$$Duyarlılık = \frac{Doğru Pozitif}{Doğru Pozitif + Yanlış Negatif} \quad (5)$$

F1-Skoru, keskinlik (4) ve duyarlılık (5) değerlerini aynı anda ölçmeyi sağlar.

$$F1 = 2 \times \frac{Duyarlılık \times Keskinlik}{Duyarlılık + Keskinlik} \quad (6)$$

Tablo 1'de Welch güç spektral yoğunluğu tahmini kullanılarak elde edilen veri seti ile testi yapılan ağın sınıflandırma raporu bulunmaktadır.

TABLO I. AĞIN SINIFLANDIRMA RAPORU.

	Keskinlik	Duyarlılık	F1 Skoru	Örnek
Negatif	0.96	0.86	0.91	612
Pozitif	0.88	0.95	0.91	623
Nötr	0.89	0.90	0.89	615
Doğruluk			0.91	1850
Makro Ort.	0.91	0.91	0.91	1850
Ağırlıklı Ort.	0.91	0.91	0.91	1850

Oluşturulan CNN tabanlı sınıflandırma modelinde kullanılmak için EEG sinyallerinden 3 ayrı veri seti elde edildi. Birinci veri setinde, hiçbir özellik çıkarma işlemine tabi tutulmadan, sadece ön işlemden geçmiş ve uygun kanalları seçilmiş ham EEG verisi kullanıldı. İkinci veri setinde, bu işlemlerin yanında 5. Ayrıştırma seviyesinde ayrık dalgacık dönüşümü kullanılarak (ADD) özellikleri çıkarılan EEG verisi kullanıldı. Son veri setinde ise, Welch güç spektral yoğunluğu tahmini kullanılarak (PSD) özellikleri çıkarılan EEG verisi kullanıldı. Tablo 2'de bütün bu işlemlerin karşılaştırmalı doğruluk ve hata oranları bulunmaktadır.

TABLO II. OLUŞTURULAN CNN TABANLI MODEL İLE ELDE EDİLEN DOĞRULUK VE HATA DEĞERLERİ.

	Eğitim Doğruluk	Eğitim Hata	Test Doğruluk	Test Hata
Ham EEG	0.5772	0.8902	0.5378	0.9571
ADD	0.6058	0.8236	0.5892	0.8587
PSD <sup>a</sup>	0.9050	0.2538	0.9016	0.2573

<sup>a</sup> Welch güç spektral yoğunluğu tahmini kullanılmıştır.

SEED EEG veri seti ile yapılan başka bir çalışmada [8], 15 denekten elde edilen 62 kanal EEG veri seti ile 4, 6, 9 ve 12 kanallı profiller oluşturularak diferansiyel entropi yöntemiyle özellikleri çıkarıldı. Elde edilen veriler ile derin inanç ağı temelli model eğitilerek %86.65 doğruluk oranına ulaşıldı. Önerdiğimiz yöntem sayesinde doğruluk oranı %90.50'ye ulaştırılarak önemli bir başarı oranı sağlanmıştır.

## V. SONUÇLAR

Yapılan çalışma sonucunda, Welch güç spektral yoğunluğu tahmini kullanılarak elde edilen veriler ile eğitimi ve testi

yapılan CNN tabanlı yöntemin, diğer yöntemlere göre daha yüksek doğruluk oranında sonuç verdiği tespit edilmiştir. Gelecekte farklı özellik çıkarma yöntemleri ve farklı yapıda sınıflandırma modelleri kullanılarak daha sağlam ve tutarlı sonuçlar elde edilebilir.

## KAYNAKLAR

1. Hinton, G.E. and R.R. Salakhutdinov, *Reducing the dimensionality of data with neural networks*. Science, 2006. **313**(5786): p. 504-507.
2. Krizhevsky, A., I. Sutskever, and G.E. Hinton, *ImageNet Classification with Deep Convolutional Neural Networks*. Communications of the Acm, 2017. **60**(6): p. 84-90.
3. Rifai, S., et al. *Contractive auto-encoders: Explicit invariance during feature extraction*. in *Proceedings of the 28th International Conference on International Conference on Machine Learning*. 2011. Omnipress.
4. Hinton, G.E., S. Osindero, and Y.W. Teh, *A fast learning algorithm for deep belief nets*. Neural Computation, 2006. **18**(7): p. 1527-1554.
5. LeCun, Y. and Y. Bengio, *Convolutional networks for images, speech, and time series*. The handbook of brain theory and neural networks, 1995. **3361**(10): p. 1995.
6. Ahern, G.L. and G.E. Schwartz, *Differential Lateralization for Positive and Negative Emotion in the Human-Brain - Eeg Spectral-Analysis*. Neuropsychologia, 1985. **23**(6): p. 745-755.
7. Niedermeyer, E., *Niedermeyer's electroencephalography: basic principles, clinical applications, and related fields*. 2011: Lippincott Williams & Wilkins.
8. Zheng, W.L. and B.L. Lu, *Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition with Deep Neural Networks*. Ieee Transactions on Autonomous Mental Development, 2015. **7**(3): p. 162-175.
9. Palus, M., *Nonlinearity in normal human EEG: Cycles, temporal asymmetry, nonstationarity and randomness, not chaos*. Biological Cybernetics, 1996. **75**(5): p. 389-396.
10. Li, M. and B.L. Lu, *Emotion Classification Based on Gamma-band EEG*. 2009 Annual International Conference of the Ieee Engineering in Medicine and Biology Society, Vols 1-20, 2009: p. 1323-1326.
11. Bos, D.O., *EEG-based emotion recognition*. The Influence of Visual and Auditory Stimuli, 2006. **56**(3): p. 1-17.
12. Lotte, F., et al., *A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update*. Journal of Neural Engineering, 2018. **15**(3).
13. Valenzi, S., et al., *Individual classification of emotions using EEG*. Journal of Biomedical Science and Engineering, 2014. **7**(08): p. 604.
14. Wang, J., et al. *Classification of EEG signal using convolutional neural networks*. in *2019 14th IEEE Conference on Industrial Electronics and Applications (ICIEA)*. 2019. IEEE.
15. Li, S. and H. Feng, *EEG Signal Classification Method Based on Feature Priority Analysis and CNN*. in *2019 International Conference on Communications, Information System and Computer Engineering (CISCE)*. 2019. IEEE.
16. Duan, R.N., J.Y. Zhu, and B.L. Lu, *Differential Entropy Feature for EEG-Based Emotion Classification*. 2013 6th International Ieee/Embs Conference on Neural Engineering (Ner), 2013: p. 81-84.