

EEG Sinyallerinde Wavelet Dönüşümü ve CNN ile Duygu TanımaAbdulfatah KALAJE ¹, Hasan DEMİR ^{2*}¹ Tekirdağ Namık Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Tekirdağ² Tekirdağ Namık Kemal Üniversitesi Çorlu Mühendislik Fakültesi Elektronik ve Haberleşme Mühendisliği Bölümü, Tekirdağ*Sorumlu yazar (Corresponding author): hdemir@nku.edu.tr**Geliş Tarihi (Received):** 07.01.2025**Kabul Tarihi (Accepted):** 25.02.2025**Özet**

Bu çalışmada farklı Wavelet Dönüşümü yöntemleri kullanılmıştır. Wavelet Dönüşümü katsayıları kullanılarak edilen öznitelikler ile yapay sinir ağları ve konvolüsyonel sinir ağları kullanılarak EEG sinyallerinde duygu tanıma yapılmıştır. Dört kişiden alınan üç farklı duyguya ait EEG sinyallerine ait dataseti kullanılmıştır. Stresli, nötr ve rahat duyguları sınıflama amacıyla kullanılmıştır. Sürekli wavelet dönüşümü (CWT), 1D ve 2D için ayrık wavelet dönüşümü (DWT) ve senkronize sıkıştırılmış wavelet dönüşümü (SSWT) ile elde edilen sonuçlar karşılaştırılarak EEG sinyallerinde duygu tanıma işlemi için uygun wavelet dönüşümü belirlenmeye çalışılmıştır. Senkronize sıkıştırılmış wavelet dönüşümünün (SSWT) en yüksek doğruluk, kesinlik, duyarlılık, özgüllük ve F1-skoru ile duygu sınıflandırması için en etkili algoritma olduğu görülmüştür.

Anahtar Kelimeler: Elektroensefalografi, makine öğrenmesi, duygu tanıma, konvolüsyonel sinir ağı**Emotion Recognition in EEG Signals with Wavelet Transform and CNN****Abstract**

In this study, different Wavelet Transform methods were used. Emotion recognition was performed on EEG signals using artificial neural networks and convolutional neural networks with the features obtained by using Wavelet Transform coefficients. A dataset of EEG signals belonging to three different emotions taken from four people was used. It was used to classify stressful, neutral and relaxed emotions. By comparing the results obtained with Continuous Wavelet Transform (CWT), Discrete Wavelet Transform (DWT) for 1D and 2D and Synchrosqueezed Wavelet Transform (SSWT), an appropriate wavelet transform was tried to be determined for emotion recognition on EEG signals. It was found that Synchrosqueezed Wavelet Transform (SSWT) was the most effective algorithm for emotion classification with the highest accuracy, precision, sensitivity, specificity and F1-score.

Keywords: Electroencephalography, machine learning, emotion recognition, convolutional neural network

1. Giriş


Duygular, günlük yaşantımızda karar verme süreçlerini, davranışları ve sosyal etkileşimleri etkileyerek önemli bir rol oynamaktadır. Ancak, duyguları ölçmek için kullanılan geleneksel yöntemler, kendi kendini raporlama ve davranışsal gözlem, genellikle verimli değildir ve bazı sınırlamalara ve önyargılara sahiptir. Bu nedenle, duyguların daha objektif ve güvenilir bir şekilde tanınması amacıyla fizyolojik sinyallerden yararlanılmaktadır. Fizyolojik sinyaller duyguların daha objektif ve doğrudan ölçülmesine olanak tanır. Bu amaçla elektroensefalogram (EEG) gibi beyin aktiviteleri incelenmektedir. EEG sinyalleri, beynin elektriksel aktivitelerini ölçerek duygusal durumların nörolojik temellerini ortaya koyar. Bu sinyaller, delta, teta, alfa, beta ve gama olmak üzere beş farklı frekans bandına ayrılmaktadır. Her bir frekans bandı, farklı duygusal ve bilişsel durumlarla ilişkilendirilir. Ayrıca, EEG, depresyon, anksiyete, şizofreni, uykusuzluk ve travma sonrası stres bozukluğu (PTSD) gibi duygusal bozuklukların teşhis ve tedavisinde önemli bir rol oynamaktadır. Mehmet Akif Özdemir ve Murside Degirmenci, Elif Izci ve Aydın Akan tarafından yapılan çalışmada (Özdemir ve ark., 2021), EEG sinyalleri kullanarak duygusal durumları (arousal ve valence modeli) tahmin etmek için bir yöntem geliştirmiş. FFT, PSD, CNN ve LSTM teknikleriyle elde edilen sonuçlar, valence için %94.07 (eğitim) ve %90.62 (doğrulama), arousal için ise %92.02 (eğitim) ve %86.13 (doğrulama) doğruluk oranlarına ulaşmıştır. Sumya Akter, Rumman Ahmed Prodhan, Tanmoy Sarkar Pias, David Eisenberg ve Jorge Fresneda Fernandez tarafından yapılan çalışmada (Aker ve ark., 2022), DEAP EEG veri seti kullanılarak 1D Evrişimli Sinir Ağı (CNN) modeliyle duygusal durum tahmini (valence ve arousal) için yüksek doğruluk oranları elde edilmiştir. EEG sinyalleri, FFT ile frekans düzlemine dönüştürülmeden önce 0.5-40 Hz bant geçiren filtre ile temizlenmiştir. İki farklı CNN modeli

(hafif ve ağır) kullanılarak, 14 EEG kanalı üzerinde yapılan analizde, hafif modelden %99.22 ve ağır modeli %99.89 doğruluk oranına ulaşmıştır. Aravind ve ark. (2017) tarafından yapılan çalışmada (Vijayan ve ark., 2015), EEG sinyallerinin analizi için wavelet dönüşümü kullanılmıştır. Özellikle, Daubechies ana waveleti, ortogonalite ve düzleştirme özellikleri nedeniyle tercih edilmiştir. Araştırmacılar, Shannon entropisini temel özellik olarak kullanarak bir duygu tanıma stratejisi geliştirmiş ve bu stratejiyi Çok Ölçekli Destek Vektör Makinesi (SVM) ile birleştirmiştir. Bu yöntem, heyecan, mutluluk, üzüntü ve nefret gibi dört temel duygunun sınıflandırılmasında %94.097 doğruluk oranına ulaşmıştır. Saranya K, Sudharson D, Gokila N M, Lakshmipriya S R ve Suriyavathi K A K tarafından yapılan çalışmada (Saranya ve ark., 2023), EEG sinyallerindeki anlamlı aktiviteyi ayırmak için ayrık wavelet dönüşümü (DWT) ve artefakt temizleme teknikleri kullanılmıştır. EEG sinyali 5 frekans bandına ayrıştırılarak, duygu tanıma için ANN, SVM, RNN, KNN, RF ve DNN gibi altı farklı makine öğrenimi algoritması test edilmiştir. En yüksek doğruluk %73.8 ile ANN tarafından elde edilirken, diğer algoritmalar %63.33 (SVM), %71 (RNN), %58.54 (KNN), %60.23 (RF) ve %70.83 (DNN) doğruluk oranlarına ulaşmıştır. Bu sonuçlar, ANN'nin duygu tanıma görevinde diğer yöntemlere kıyasla daha etkili olduğunu göstermektedir.

2. Materyal ve Yöntem

2.1. Dataset

Bu çalışmada Ishan Agrawal tarafından yayımlanan EEG veri setini kullanılmıştır (Anonymous, 2024). Bu veri seti dört kişiden ölçülmüş olup, normal, stresli ve rahatlı üç duygu setini içerir. Sinyaller, TP9, TP10, AF7 ve AF8 olarak kafa derisine dört elektrot yerleştirilerek elde edilmiştir. Bu veri setindeki sinyaller için bir saniyede 256 ölçüm yapılmıştır. Şekil 1 birinci kişinin stres modunda EEG sinyali gösterilmiştir.



Şekil 1. EEG sinyali

2.2. Filtreleme

EEG sinyallerinin doğru şekilde işlenmesi, göz hareketleri, kas artefaktları, kardiyak etkiler ve cilt yüzeyi koşulları gibi gürültü kaynakları nedeniyle zorlu bir süreçtir. Bu gürültüler, sinyal kalitesini düşürerek analiz sürecini etkisiz hale getirebilir. Bu çalışmada bant geçiren filtresi 30 Hz ile 63 Hz aralığında ve 256 Hz örnekleme frekansı için uygulanmıştır. Bant geçiren filtreler, farklı beyin durumları ve bilişsel süreçlerle ilişkilendirilen belirli frekans bantlarını izole etmek ve analiz etmek için özellikle kullanışlıdır. Delta, theta, alfa, beta ve gama frekansları bantlarından oluşur. Bant geçiren filtrelerin uygulanmasıyla, EEG sinyallerinden

frekans özgül bilgileri çıkarılabilir ve hedeflenen frekans aralıklarında nöral osilasyonların dinamikleri incelenebilir (Bajaj, 2020).

2.3. Sürekli wavelet dönüşümü

Sürekli wavelet dönüşümü (CWT), sinyallerin zaman-frekans özelliklerini analiz etmek için kullanılan etkili bir yöntemdir. Durağan olmayan sinyallerin analizinde, hem zaman hem de frekans düzleminde lokalizasyon sağlar. CWT, farklı ölçeklerde ve ötelemelerle sinyalin detaylı bir şekilde incelenmesi sağlar. Matematiksel olarak (2.1) ve (2.2) denkleminde gösterir ve Şekil 1 EEG sinyali CWT sonucu Şekil 2'de gösterilmektedir (Lee ve Choi, 2019).

$$\psi(a, b)(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (2.1)$$


$$Wx(a, b) = \{x(t), \psi(a, b)(t)\} = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \cdot \psi\left(\frac{t-b}{a}\right) dt \quad (2.2)$$

2.4. Ayrık wavelet dönüşümü


Ayrık wavelet dönüşümü ayrık sinyaller için kullanılır. Alçak, yüksek geçiren filtreleri ve alt örnekleme kullanarak sinyal detay ve

yaklaşımına ayrılmaktadır. Şekil 1 EEG sinyali 1D DWT ve 2D DWT Şekil 3 ve Şekil 4'te sonuçları gösterilmektedir ve matematiksel ifadesi denklem 2.3 de verilmektedir (Mallat, 1989).


$$DWT(m, n) = \{x(t), \psi(m, n)\} = \sum_{n=-\infty}^{\infty} \frac{1}{\sqrt{2^m}} \cdot x(t) \cdot \psi(2^{-m} \cdot t - n) \quad (2.3)$$



Şekil 2. EEG sinyalin CWT



Şekil 3. EEG sinyalin dördüncü seviye 1D DWT



Şekil 4. EEG sinyalin 2D DWT

2.5. Senkronize sıkıştırılmış wavelet dönüşümü


Senkronize sıkıştırılmış wavelet dönüşümü (SSWT), geleneksel wavelet dönüşümünün

sınırlamalarını aşarak, frekans bileşenlerini zamanda daha kesin bir şekilde yerleştirmek için yeniden tahsis tekniklerini ve anlık frekans $\omega_x(a,b)$ kullanır. Bu özellik, durağan olmayan sinyallerin EEG gibi analizinde büyük bir

avantaj sağlar. SSWT, sinyalin zaman-frekans düzlemindeki bileşenlerini daha yoğun ve keskin bir şekilde temsil eder. Matematiksel olarak, SSWT (2.1)(2.2)(2.4) ve (2.5)

$$\omega x(a, b) = -j \cdot (Wx(a, b))^{-1} \frac{\partial Wx(a, b)}{\partial b} \quad (2.4)$$

$$T(w, b) = \int_b Wx(a, b) \cdot \frac{1}{a} \delta(\omega x(a, b) - \omega) da \quad (2.5)$$



Şekil 5. EEG sinyalin SSWT


CWT'yi Şekil 2 ile SSWT'yi Şekil 5 ile karşılaştırılınca, SSWT'nin özellikleri nedeniyle, SSWT sinyalinin CWT'den daha net olduğu görülmektedir.

2.6. Yapay sinir ağları

Yapay sinir ağları (ANN), insan beyninin sinir ağlarının yapısı ve işleyişinden esinlenen hesaplamalı modellerdir. Şekil 6'de göre giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur. Her nöron, girişleri alır, ağırlıklar ve önyargılar uygular ve bilgiyi bir aktivasyon fonksiyonu aracılığıyla

denklemlerde tanımlanır ve Şekil 1 EEG sinyali SSWT sonucu Şekil 5'de gösterilmektedir (Daubechies ve ark., 2011).

işleyerek bir çıkış üretir. ANN, eğitim sırasında bu ağırlıkları ve önyargıları, genellikle geri yayılım (backpropagation) gibi algoritmalar kullanarak ayarlayarak öğrenir. Bu süreç, tahmin edilen ve gerçek çıktılar arasındaki hatayı en aza indirerek ANN'ların kalıpları tanımasını, tahminler yapmasını ve karmaşık problemleri çözmesini sağlar. Ancak, eğitim için büyük miktarda veriye ve önemli hesaplama kaynaklarına ihtiyaç duyulması gibi zorlukları da vardır (Fieres ve ark., 2006).




Şekil 6. Yapay sinir ağı mimarisi

2.7. Konvolüsyonel sinir ağı

Konvolüsyonel sinir ağı (CNN), yapılandırılmış grid verilerini kullanarak otomatik olarak öğrenen ve özellikleri çıkaran derin öğrenme modelidir. CNN'ler, veriler üzerinde kayan filtreler uygulayarak giriş verilerinden özellikleri algılamak ve öğrenmek için evrişimli katmanları kullanır. Bu tür sinir ağları, görüntü işleme, sinyal işleme, duygu algılama ve yüz tanıma gibi çeşitli uygulamalarda kullanılabilir. Mimari olarak

Şekil 7 gösterilmiş gibi, konvolüsyonli katmanlar, havuzlama katmanları ve çıkışı üreten tam bağlı katmandan oluşur. CNN'nin çalışma prensibi birçok adım içerir, ilk adımda, giriş değerleri bir matris biçiminde gösterilir. Daha sonra giriş matrisi I ve çekirdek matrisi K çarpılır çıkış matrisi elde edilir. Denklem 3.6'de giriş matrisinin boyutu N olarak, çekirdek matrisinin boyutu F ve çıkış matrisi onun boyutu olarak tanımlanmıştır (Albawi ve ark., 2017; Ghosh ve ark.2020).

$$O = (N - F) + 1 \quad (2.6)$$



Şekil 7. Konvolüsyonel sinir ağı mimarisi

3. Bulgular ve Tartışma

Bilgisayar benzetim hesaplamaları için python ve pywavelet (Lee ve ark., 2019), ssqueezepy (Anonim, 2020), keras (Anonim, 2015), matplotlib (Hunter, 2007), scipy (Virtanen ve ark., 2020), panda (McKinney, 2010), scikit-learn (Pedregosa ve ark., 2011) kullanılmıştır. EEG sinyallerinden öznitelikler


çıkarıldıktan sonra, duygu tanıma için bir CNN modeli tasarlanmıştır. Model, 128 (örneklene veri boyutu) * EEG kanal sayısı giriş vektörüyle başlar ve iki gizli katmandan oluşur: ilk katman 128 nöron, ikinci katman 64 nöron içerir. Her katmanda (3x3) filtre boyutu, ReLU aktivasyon fonksiyonu ve 2x2 maksimum havuzlama kullanılmıştır. Model,

32 nöronlu tam bağlantılı katman ve softmax aktivasyonlu 3 nöronlu çıkış katmanı ile sonlanır. Veri seti, %80 eğitim ve %20 test olarak ayrılmıştır. Model performansı, karışıklık matrisi ve duyarlılık, özgülük, kesinlik, F1 skoru gibi metriklerle değerlendirilmiştir. Farklı sinyal dönüşümleri


(CWT, DWT 1D, DWT 2D, SSWT) kullanılarak elde edilen sınıflandırma sonuçları Tablo 1'de, karışıklık matrisleri ise Şekil 8-11'te sunulmuştur. Bu metrikler, modelin duygu tanıma performansını kapsamlı bir şekilde analiz etmeyi sağlar.

Tablo 1. Sınıflandırma sonuçları


| | Doğruluk | Duyarlılık | Kesinlik | Özgüllük | F1 skoru |
|--------|----------|------------|----------|----------|----------|
| CWT | 98.4 | 97.69 | 98.82 | 97.51 | 97.53 |
| DWT 1D | 96.93 | 95.38 | 97.69 | 95.36 | 95.37 |
| DWT 2D | 97.06 | 95.87 | 97.77 | 95.62 | 95.71 |
| SSWT | 98.93 | 98.38 | 99.21 | 98.35 | 98.35 |




Şekil 8. CWT ve CNN karışıklık matrisi



Şekil 9. DWT 1D ve CNN karışıklık matrisi



Şekil 10. DWT 2D ve CNN karışıklık matrisi



Şekil 11. SSWT ve CNN karışıklık matrisi

Yukarıdaki şekil ve tabloya göre, Tablo 1, rahatlı, stresli ve normal sınıflarını (duygularını) içeren 4 sinyal dönüşümünün performansını göstermektedir. Bu tablo,

karışıklık matrisiyle bağlayan metrikleri ve model doğruluğunu içermektedir. CNN, 2D özellikleri tanıma yeteneği sayesinde duygu tanıma görevinde verimli sonuç elde

edilmektedir. Şekil 8-11, her bir sinyal dönüşümü için karışıklık matrislerini göstermektedir.

4. Sonuçlar

Duygu tanıma, EEG sinyallerinden wavelet dönüşümü kullanılarak özelliklerin çıkarılması ve bir CNN modeli ile sınıflandırma yapılmasıyla gerçekleştirildi. Bu çalışmada CWT, 1D DWT, 2D DWT ve SSWT. Sonuç olarak, SSWT'nin en yüksek doğruluk, kesinlik, duyarlılık, özgüllük ve F1-skoru ile duygu sınıflandırması için en etkili algoritma olduğu görülmektedir.

Yazarların Katkı Beyanı

Yazarlar makaleye eşit katkıda bulduklarını, makalenin yayına hazır son halini gördüklerini/okuduklarını ve onayladıklarını beyan ederler.

Çıkar Çatışması Beyanı

Tüm yazarlar, bu çalışma için herhangi bir çıkar çatışması olmadığını beyan etmektedir.

Açıklama

Bu çalışma ilk yazarın yüksek lisans tezinden üretilmiştir

Kaynaklar

Akter, S., Prodhon, R.A., Pias, T.S., Eisenberg, D., Fresneda Fernandez, J., 2022. M1M2: deep-learning-based real-time emotion recognition from neural activity. *Sensors*, 22(21): 8467.

Albawi, S., Mohammed, T.A., Al-Zawi S., 2017. Understanding of a convolutional neural network. *International Conference on Engineering and Technology*, 21 August, pp. 1-6.

Anonim, 2015. Keras. (<https://keras.io>), (Accessed: 04.01.2025).

Anonim, 2020. ssqueezepy, (<https://github.com/OverLordGoldDragon/ssqueezepy/>), (Accessed: 04.01.2025).

Anonim, 2024. EEG Signal for stress detection, (<https://www.kaggle.com/datasets/ishan8055/eeg-signal-for-stress-detection>), (Accessed: 04.01.2025).

Bajaj, N., 2020. Wavelets for EEG analysis. *Wavelet Theory*, 1-16.

Daubechies, I., Lu, J., Wu, H.T., 2011. Synchrosqueezed wavelet transforms: An empirical mode decomposition-like tool. *Applied and Computational Harmonic Analysis*, 30(2): 243-261.

Fieres, J., Schemmel, J., Meier, K., 2006. Training convolutional networks of threshold neurons suited for low-power hardware implementation. *IEEE International Joint Conference on Neural Network*, Proceedings Book, pp. 21-28.

Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., De, D., 2020. Fundamental concepts of convolutional neural network. *Recent Trends and Advances in Artificial Intelligence and Internet of Things*, 519-567.

Hunter, J.D., 2007. Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(03): 90-95.

Lee, H.K., Choi, Y.S., 2019. Application of continuous wavelet transform and convolutional neural network in decoding motor imagery brain-computer interface. *Entropy*, 21(12): 1199.

Lee, G., Gommers, R., Waselewski, F., Wohlfahrt, K., O'Leary, A., 2019. PyWavelets: A Python package for wavelet analysis. *Journal of Open Source Software*, 4(36): 1237.

Mallat, S.G., 1989. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7): 674-693.

McKinney, W., 2010. Data structures for statistical computing in Python. *SciPy*, 445(1): 51-56.

- Ozdemir, M.A., Degirmenci, M., Izci, E., Akan, A., 2021. EEG-based emotion recognition with deep convolutional neural networks. *Biomedical Engineering/Biomedizinische Technik*, 66(1): 43-57.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Duchesnay, É., 2011. Scikit-learn: Machine learning in Python. *The Journal of Machine Learning Research*, 12: 2825-2830.
- Saranya, K., Sudharson, D., Gokila, N.M., LakshmiPriya, S.R., Suriyavathi, K.A.K., 2023. Emotion Recognition using EEG Signal Classification of seed Dataset. *2nd International Conference on Advancements in Electrical, Electronics, Communication, Computing and Automation (ICAECA)*, Proceedings Book, pp. 1-6.
- Vijayan, A.E., Sen, D., Sudheer, A.P., 2015. EEG-based emotion recognition using statistical measures and auto-regressive modeling. *IEEE International Conference on Computational Intelligence & Communication Technology*, pp. 587-591.
- Virtanen, P., Gommers, R., Oliphant, T.E., Haberland, M., Reddy, T., Cournapeau, D., Van Mulbregt, P., 2020. SciPy 1.0: fundamental algorithms for scientific computing in Python. *Nature Methods*, 17(3): 261-272.

Atf Şekli: Kalaje, A., Demir, H., 2025. EEG Sinyallerinde Wavelet Dönüşümü ve CNN ile Duygu Tanıma. *MAS Uygulamalı Bilimler Dergisi*, 10(1): 81-89.
DOI: <http://dx.doi.org/10.5281/zenodo.15088482>.

To Cite: Kalaje, A., Demir, H., 2025. Emotion Recognition in EEG Signals with Wavelet Transform and CNN. *MAS Journal of Applied Sciences*, 10(1): 81-89.
DOI: <http://dx.doi.org/10.5281/zenodo.15088482>.
