

Epilepsi Nöbet Tespiti için Zaman-Frekans Görüntüleme: Transformer Model ile Özellik Füzyonu

Time-Frequency Imaging for Epileptic Seizure Detection: Feature Fusion with Transformer Model

¹Mesut TOĞAÇAR 

¹Fırat Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri, Elazığ, Türkiye

mtogacar@firat.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 14 February 2025

Accepted : 15 April 2025

Keywords:

Epileptic Seizure,
Time-Frequency Imaging,
Transformer Model,
Feature Processing

ABSTRACT

Epilepsy is a common neurological disorder that carries serious risks, such as seizures and irreversible brain damage. Accurate and rapid diagnosis of this condition is of great importance. Traditional EEG signal analysis is manual, time-consuming, and prone to human error. The use of artificial intelligence approaches provides a means for more accurate and faster detection. In this study, EEG signals were converted into 2D images using time-frequency transformation methods. Three image datasets were obtained through time-frequency transformations. Each image dataset was then trained using a transformer model, and feature sets were generated by the model. Different feature sets were combined using the feature fusion method, and these combined sets were classified using machine learning method (support vector machines). With the approach proposed in this study, an overall accuracy of 91.20% was achieved.

© 2025 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 14 Şubat 2025

Kabul : 15 Nisan 2025

Anahtar Kelimeler:

Epileptik Nöbet,
Zaman-Frekans Görüntüleme,
Transformatör Modeli,
Özellik İşleme

ÖZET

Epilepsi, nöbetler ve bu durumun yol açtığı geri dönüşümsüz beyin hasarı gibi ciddi riskler taşıyan yaygın bir nörolojik hastalıktır. Bu hastalığın doğru ve hızlı bir şekilde teşhis edilmesi büyük önem taşır. Geleneksel EEG sinyal analizi, manuel ve zaman alıcı olup insan hatalarına açıktır. Bu sorunu çözmek için yapay zekâ yaklaşımlarının kullanımı, daha hassas ve hızlı tespit imkânı sunmaktadır. Bu çalışmada, EEG sinyalleri zaman-frekans dönüşüm yöntemleri kullanarak 2B görüntülere dönüştürülmüştür. Zaman-frekans dönüşüm yöntemleri ile üç adet görüntü kümesi elde edilmiştir. Ardından her bir görüntü kümesi transformer model ile eğitilmiştir ve model tarafından özellik setleri oluşturulmuştur. Özellik füzyonu yöntemiyle farklı özellik setleri birleştirilmiş ve bu birleşik setler, makine öğrenmesi yöntemiyle (destek vektör makineleri) sınıflandırılmıştır. Bu çalışmada önerilen yaklaşım sayesinde %91.20 genel doğruluk oranı elde edilmiştir.

© 2025 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Epilepsi, istemsiz hareketler, bilinç kaybı veya kasılmalar gibi nöbetlerle kendini gösteren bir beyin hastalığıdır [1]. Dünya nüfusunun yaklaşık %1'ini etkileyen bu hastalık, nöbet geçiren bireyler için hayatı tehdit edebilecek zorluklar doğurabilir. Epilepsi hastalarının yaklaşık %66'sı ilaç tedavisine olumlu yanıt verirken, aynı zamanda fiziksel müdahalelere de ihtiyaç duyabilmektedir [2]. Epilepsi hastaları, nöbetlerin ne zaman ve nerede gerçekleşeceğini bilmedikleri için sürekli bir tehlike altındadırlar, bu da yaşam kalitelerini olumsuz etkiler. Bu çalışmada, sağlıklı ve epileptik nöbet sinyalleri arasındaki farklar araştırılmış ve elektroensefalografi (EEG)'nin epilepsi tanısındaki rolü vurgulanmıştır. 1970'lerin başında, epilepsi teşhisine yardımcı olmak amacıyla insan EEG'sinin otomatik analizi yapılmaya başlanmıştır. EEG sinyallerindeki güç değişiklikleri, nöbetli ve nöbetsiz durumlar arasındaki farkları ayırt etmek için kullanılabilir. Epileptik EEG, belirli frekans aralıklarında daha yüksek bir güç gösterir ve nöbetli dönemde bu güç, nöbetsiz döneme göre sürekli olarak artış gösterir [3].

EEG sinyallerin sınırlı kanal sayısı, elde edilen bilgiyi kısıtlamaktadır. Bu sebeple, tek kanal kullanarak epilepsi tespiti yapmak isteyen modellerin yüksek doğruluk ve dayanıklılık sağlamak amacıyla geliştirilmesi gerekiyor. Geleneksel yöntemler, EEG sinyallerinden özellikler çıkarıp, bu özellikler üzerinden sınıflandırma yaparak tespit sağlıyordu. Bu özellikler, sinyalin zaman, frekans veya her ikisiyle ilgili olabilir. Ancak, hangi özelliklerin kullanılacağı tespit başarısını etkileyen önemli bir faktördür. Son yıllarda ise, derin öğrenme yaklaşımlarının ilerlemesiyle, geleneksel yöntemlerden farklı olarak, özelliklerin otomatik öğrenilmesi ve daha karmaşık tespit işlemlerinin başarıyla yapılması mümkün hale geldi [4]. Literatürde son zamanlarda epilepsi nöbeti tespiti için birçok çalışma gerçekleştirilmiştir. Bunlardan bazıları incelenirse; Varlı vd. [5], epilepsi hastalığının teşhisinde EEG sinyallerini kullanarak, derin öğrenme tabanlı bir model geliştirmiştir. Çalışmada, EEG verilerinin zaman serisi ve zaman-frekans bileşenlerinden elde edilen görüntüler ile epilepsi nöbetlerini yüksek doğrulukla tespit etmek amacıyla bir kombine derin öğrenme yapısı oluşturulmuştur. Sonuç olarak, kullanılan model, evrimsel sinir ağı (CNN) girdilerinde kısa zamanlı fourier dönüşümü (STFT) ve sürekli dalgacık dönüşümü (CWT) yöntemleriyle yapılan ikili sınıflandırmalarda sırasıyla %99.47 ve %99.27 doğruluk oranları elde etmiştir. S. Mallick ve V. Baths, epileptik nöbet tespiti için yeni bir yöntem önermiştir. Bu yöntem, 1B konvolüsyonel katmanlar, çift yönlü uzun kısa süreli bellek (Bi-LSTM), geçitli tekrarlayan birim (GRU) ve ortalama havuzlama katmanının birleşiminden oluşan bir yapı kullanarak EEG sinyallerinden özellik çıkarımı yapmışlardır. Önerdikleri yaklaşımda üç sınıflı veriler için %97.2 bandında genel doğruluk başarıları elde ettiler [6]. S. Srinivasan vd. [7], yetişkinlik öncesi hastalarda nöbet tespiti için yeni bir yaklaşım önermişlerdir. Bu yaklaşım, hem çok kanallı EEG sinyalleri üzerinde çalışan üç boyutlu derin konvolüsyonel auto-encoder kullanarak, epilepsi nöbetlerini sınıflandırmak için otomatik özellik öğrenme yeteneklerinden faydalanmaktadır. Önerdikleri model, Bi-LSTM tabanlı bir sınıflayıcıyla entegre edilerek, epileptik ve interiktal durumları yüksek doğrulukla sınıflandırmayı başarmıştır. Test sonuçlarında yaklaşık %99 genel doğruluk başarıları elde etmişlerdir. G. Yogarajan vd. [8], EEG tabanlı gelişmiş bir otomatik nöbet tespit sistemi geliştirmiştir. Bu sistem, sabit dalgacık dönüşümü kullanılarak elde edilen sinyal seviyelerinden çıkarılan dokuz farklı istatistiksel ve Hjorth parametresi ile EEG sinyallerinin özelliklerini öğrenen derin sinir ağı (DNN) modelini kullanmaktadır. Ardından, çıkarılan özellikler, modelin daha hızlı eğitimini ve yüksek performansını sağlamak amacıyla ikili yusufçuk algoritması (BDFA) ile azaltılmaktadır. Sonuçlar, modelin normal, nöbet arası ve nöbet sinyallerini %100 doğrulukla sınıflandırabileceğini göstermiştir. A. Yadav vd. [9], kırsal bölgelerdeki epilepsi hastaları için erken tanı koymanın önemini vurgulayarak, EEG sinyalleri üzerinden nöbet tespiti yapmak amacıyla derin öğrenme tabanlı bir sistem önermektedir. Onların çalışması, üç tür EEG sinyallerini sınıflandırmak için Bayesian optimizasyon tekniğiyle double-LSTM modelini kullanmaktadır. Sonuçlar, modelin üç sinyal türünü %95 doğrulukla sınıflandırabileceğini göstermiştir. Wang vd. [10] tıbbi zaman serisi verilerini sınıflandırmak amacıyla geliştirilmiş bir transformer tabanlı model olan Medformer'ı sunmaktadır. Onların bu araştırmasında, Medformer'ın EKG ve EEG gibi biyopotansiyel sinyallerde elde ettiği yüksek doğruluk oranları detaylı bir şekilde ele alınmıştır. Onlar, modelin farklı seviyelerdeki granülasyona sahip tıbbi verileri analiz etme yeteneğinin, geleneksel yöntemlerle kıyaslandığında nasıl daha etkili sonuçlar verdiğini vurgulamaktadır. Diğer taraftan, Forigua vd. [11] MR görüntüleme süper çözünürlüğü için tasarlanmış üç boyutlu bir transformer modelini tanıtmaktadır. Onlar çalışmasında, önerilen modelin 3D konvolüsyonel sinir ağlarına kıyasla daha yüksek çözünürlükte görüntüler oluşturma kapasitesi üzerinde durulmakta ve tıbbi görüntüleme alanında bu yeniliğin potansiyel etkileri tartışılmaktadır. Onlar, modelin MR görüntülerindeki detayları daha hassas bir şekilde yeniden yapılandırarak tıbbi teşhislerde kayda değer iyileşmeler sağlayabileceğini belirtmektedir.


Bu çalışmanın özgün katkısı, geleneksel EEG sinyal analiz yöntemlerine kıyasla, zaman-frekans dönüşüm tekniklerini kullanarak EEG sinyallerini 2B görüntülere dönüştürmek ve yapay zekâ tabanlı özellik füzyonu ile desteklenen sınıflandırma süreci ile daha hassas ve hızlı bir teşhis imkânı sunmasıdır. Bu yaklaşım, manuel ve zaman alıcı analizlerin yerine, daha etkili bir çözüm önerisi getirerek epilepsi gibi nörolojik hastalıkların erken teşhisinde önemli bir ilerleme sağlamaktadır.

Bu makalenin diğer bölümleri şu şekilde yapılandırılmıştır: 2. bölümde veri kümesi hakkında ayrıntılı bilgi sunulmaktadır. 3. bölümde ise görüntü işleme yöntemleri, yapay zekâ yaklaşımları ve önerilen model detaylandırılmaktadır. 4. bölümde, deneysel analizler ve yapılan yorumlar yer almaktadır. Sonraki bölümlerde ise tartışma ve sonuç kısmı ele alınmaktadır.

2. VERİ KÜMESİ

Veri kümesi, her biri EEG sinyallerinden oluşan beş farklı setten (Z, O, N, F ve S) meydana gelir ve bu veriler, kafa derisinin yüzeyinden tek bir kanal aracılığıyla kaydedilmiştir. Set Z ve O, sırasıyla gözleri açık ve kapalı olan sağlıklı bireylerden elde edilen EEG kayıtlarını içerirken, N, F ve S setleri ise epilepsi tanısı konmuş hastaların ameliyat öncesi EEG verilerinden alınmıştır. Epileptik set grupları: Set S (nöbet aktivitesi), Set F (nöbetsiz), Set N (nöbetsiz); sağlıklı set grupları: Set O (gözler kapalı), Set Z (gözler açık).

Set N, beynin karşı yarım küresindeki hipokampus bölgesinden elde edilirken, Set F epileptojenik alanlardan alınmış ve her iki set de nöbetsiz aralıkları kapsayan veriler içerir. Set S ise yalnızca nöbet aktivitesini barındırır. Bu veri kümesi, epilepsi tespiti ve beyin fonksiyonlarının zaman-frekans analizine yönelik derin öğrenme ve makine öğrenmesi yöntemleri için oldukça değerli bir kaynak sağlar. Sinyal türlerinin çeşitliliği, farklı beyin bölgelerinin ve durumlarının gözlemlenmesine olanak tanır, bu da model eğitimi ve analiz sürecinde daha geniş bir perspektif sunar. Veri kümesi, açık erişimli olarak Kaggle web sitesinde erişime sunulmuştur [12]. Her bir set 1500 sinyal verisinden oluşmaktadır. Veri kümesinin toplamda 7500 sinyal verisinden oluşmaktadır. Veri kümesinin setleri ile ilgili çoklu çözünürlük analizi (MRA) örnek görüntüleri Şekil 1’de gösterilmiştir.



Şekil 1. Veri kümesinin MRA tabanlı örnek görüntüleri.

3. METODOJİ

3.1. Karmaşık Morlet Dönüşümü

Karmaşık morlet dönüşümü (CMT), sinyallerin zaman ve frekans bileşenlerini incelemek için geliştirilmiş bir analiz yöntemidir. Bu dönüşüm, dalgacık tabanlı tekniklerden biri olup, belirli bir sinüs dalgasının gauss penceresi ile çarpılmasıyla elde edilen özel bir dalga formunu temel alır [13]. Özellikle beyin dalgalarının incelenmesi gibi biyomedikal uygulamalarda sıkça kullanılır ve EEG sinyallerinin detaylı frekans çözümlemesini yapmaya imkân tanır. CMT yönteminin matematiksel formülü Denklem 1’de gösterilmiştir. Denklem 1 incelendiğinde; A değişkeni genliği, $\exp(-\frac{t^2}{2\sigma^2})$ işlemi zaman ekseninde dar bir pencereleme etkisi sağlayan gauss fonksiyonunu temsil eder. $\cos(2\pi f_0 t)$ işlemi sinyalin frekans bileşenlerini temsil eden sinüs fonksiyonudur. f_0 frekansı temsil eder ve σ gauss fonksiyonunun genişliğini belirleyen değişkendir.

$$\Psi(t) = A \cdot \exp(-\frac{t^2}{2\sigma^2}) \cdot \cos(2\pi f_0 t) \quad (1)$$

CMT yönteminin sunmuş olduğu avantajlar şunlardır;

- CMT, sinyalleri hem zamansal hem de spektral bileşenleri açısından eşzamanlı değerlendirme imkânı sunar. Bu yetenek, sinyallerdeki ani değişimlerin veya uzun vadeli frekans eğilimlerinin detaylı bir şekilde incelenmesini sağlar.
- Hem düşük hem de yüksek frekans aralıklarını kapsayarak farklı ölçeklerde veri elde edilmesine olanak tanır. Bu özellik, nörolojik bozukluklar gibi değişken yapıya sahip sinyallerin incelenmesinde oldukça etkilidir.
- Gauss fonksiyonunun sağladığı esneklik ile sinyalin belirli anlarda gösterdiği özel davranışlar daha iyi tespit edilebilir. Böylece belirli olayların zamana yayılmış etkileri hassas bir şekilde incelenebilir.

3.2. Sürekli Dalgacık Dönüşümü

Sürekli Dalgacık Dönüşümü (CWT), sinyallerin farklı frekans bileşenlerini ortaya çıkarmak için özel matematiksel fonksiyonlar kullanır. Bu fonksiyonlar, sinyalin hem zaman hem de frekans içeriğini anlamaya yardımcı olur. CWT, belirli bir dalgacık fonksiyonu ile sinyali ölçekleyip kaydırarak detaylı bir analiz gerçekleştirir [14]. CWT matematiksel olarak Denklem 2’deki formüle göre hesaplanır. Bu denklemde; analizleri gerçekleştirilen sinyal $x(t)$, dalga fonksiyonu ψ , sıkıştırma parametresi $'a'$, kaydırma parametresi $'b'$ ile temsil edilir.

$$\text{CWT}(a, b) = \int_{-\infty}^{\infty} x(t) \cdot \psi \left(\frac{t-b}{a} \right) dt \quad (2)$$

Bu yöntem, fourier dönüşümüne göre daha gelişmiş bir zaman-frekans çözünürlüğü sunar. Frekans bileşenlerini analiz etmek için farklı uzunluklarda pencereler kullanarak, düşük frekanslarda geniş, yüksek frekanslarda ise dar alanlarda çözünürlük sağlar. Bu sayede, sinyalin dinamik yapısını çok daha ayrıntılı bir şekilde çözümlemek mümkün olur. Özellikle EEG gibi zaman içinde değişim gösteren sinyallerde, sinyalin zamansal evrimini ve

frekans bileşenlerini paralel bir şekilde izleyerek daha derinlemesine bir analiz yapmayı mümkün kılar. Bu çalışmada kullanılan veri kümesine erişim sağlandığında, CWT yöntemi ile elde edilen görüntüler de hazır formatta sunulmuştur.

3.3. Stockwell Dönüşümü


Stockwell dönüşümü (ST), Stockwell ve ekibi tarafından geliştirilmiş bir yöntem olup, kısa süreli fourier dönüşümü ve dalgacık dönüşümünün güçlü yönlerini birleştirir. Bu dönüşüm, özellikle jeofizik, optik, biyomedikal görüntüleme, okyanus bilimi, biyoenformatik ve sinyal işleme gibi farklı alanlarda büyük ilgi uyandırmıştır. ST, fourier spektrumuyla doğrudan bağlantılı olmasına rağmen, frekanslara bağlı çözünürlük sunarak eşsiz bir özellik gösterir. Ayrıca, klasik ST, faz düzeltmesi yapılmış bir dalgacık dönüşümü olarak düşünülebilir, bu da ona zaman-frekans analizlerinde sinyalin yerel özelliklerine dair daha doğru ve ayrıntılı bilgiler sağlar [15]. ST işlemini gerçekleştirmek için Denklem 3'teki matematiksel formül kullanılır. Denklem 3'te zaman (t), frekans (f), analiz edilen sinyal $x(t')$ ile temsil edilir. Oluşan sinyalin pencere fonksiyonu $g(t - t')$ 'dir; sinyalin frekans bileşenleri $e^{-j2\pi ft'}$ 'dir. Burada 'j' değişkeni $\sqrt{-1}$ 'dir.

$$S(t, f) = \int_{-\infty}^{\infty} x(t') \cdot g(t - t') \cdot e^{-j2\pi ft'} dt' \quad (3)$$

ST, zaman ve frekans çözünürlüklerini birbirinden bağımsız olarak optimize etme kapasitesine sahip bir tekniktir. Yüksek frekanslar için zaman çözünürlüğü daha hassas hale gelirken, düşük frekanslarda ise frekans çözünürlüğü artırılır. Bu özellik, özellikle karmaşık sinyalleri analiz ederken daha net sonuçlar elde edilmesini sağlar. Ayrıca, ST, dalgacık dönüşümünde olduğu gibi, sinyalin yerel özelliklerini yüksek doğrulukla ortaya çıkarabilir. Fourier dönüşümünün aksine, faz bilgisini de koruyarak daha doğru ve anlamlı analizler yapılmasına olanak tanır. Geleneksel dalgacık dönüşümünde her çözünürlük için sabit bir pencere fonksiyonu kullanılırken, ST'nin esnek pencere fonksiyonu sayesinde çözünürlük dinamik bir şekilde ayarlanabilir ve sinyalin zaman-frekans özellikleri daha etkili bir şekilde temsil edilebilir. Bu esneklik, sinyallerin daha karmaşık yapılarının ve hızlı değişen özelliklerinin daha iyi analiz edilmesine yardımcı olur [16].

3.4. DeiT3 Model

Transformatör modellerinin çalışma prensibi incelendiğinde, genellikle altı temel aşamadan geçerek veri işlediği görülmektedir. Ancak, her modelin kendine özgü mimari yapısına bağlı olarak, bu aşamalara ek olarak farklı katmanlar, bloklar veya özel mekanizmalar bulunabilir. Sürecin nasıl ilerlediğini daha iyi anlayabilmek için bu aşamalar Şekil 2'de görselleştirilmiştir. İlk olarak, giriş verileri alınarak görüntü belirli parçalara ayrılır ve işlenmeye hazır hale getirilir. Daha sonra, bu parçalar özel bir yerleştirme katmanı aracılığıyla işlenerek her biri vektör biçiminde temsil edilir. Sonraki aşamada, bu parçaların dizilimi belirlenir ve konum bilgileri eklenerek verinin mekânsal yapısı korunur. Ardından, transformatör kodlayıcı blokları devreye girerek veriyi katmanlar halinde işler. Bu sürecin önemli bir noktası da çok başlı öz dikkat mekanizmasıdır. Bu mekanizma, görüntü parçaları arasındaki ilişkileri analiz ederek modelin daha anlamlı bağlantılar kurmasını sağlar. Son aşamada, sinir ağları kullanılarak eğitim gerçekleştirilir. Modelin derin katmanları, işlenen bilgileri bir araya getirerek çıkarılan özellikleri çıkış katmanına iletir ve nihai sonuçlar elde edilir.



Şekil 2. Transformatör (dönüştürücü) modellerin genel iş hattı.


Veri açısından verimli görüntü dönüştürücüler (DeiT), görüntü işleme alanında öne çıkan, son derece verimli bir dönüşüm modelidir. Geleneksel görüntü dönüştürücü (vision transformer) mimarilerine kıyasla, daha az veriyle eğitildiğinde bile yüksek başarı gösterebilir. Bunun arkasındaki temel neden, DeiT'in eğitim sürecinde kullanılan çeşitli optimizasyon teknikleridir. Model, öğrenme sürecini geliştirmek ve verimliliği artırmak için yükseltme, bilgi seçme gibi yöntemlerden faydalanır. Bu sayede, büyük veri kümelerine ihtiyaç duymadan etkileyici sonuçlar elde edebilir ve özellikle sınırlı veriyle çalışan uygulamalar için avantaj sağlar [17]. DeiT3, DeiT ailesinin üçüncü nesil versiyonu olarak geliştirilmiş ve 224×224 piksel boyutunda giriş görüntülerini işleyebilen bir modeldir. Görüntüyü 16×16 piksellik parçalara ayırarak, hem yerel detayları hem de geniş ölçekli görsel ilişkileri yakalama yeteneğine sahiptir. Önceki sürümlere kıyasla, daha kompakt bir yapıya sahiptir ve daha az dönüştürücü kodlayıcı bloğu içerir. Bu tasarım, modelin parametre sayısını azaltırken performansını korumasına olanak tanır. Hafif bir model olması sayesinde, daha az bellek tüketir ve işlemleri daha hızlı gerçekleştirebilir. Özellikle donanım kısıtlamaları olan sistemlerde, verimli bir şekilde çalışmasıyla dikkat çeker [18].

DeiT3 modelinin diğer transformer modellere göre tercih edilme nedeni, görsel verilerle işlenmiş EEG sinyalleri üzerinde yüksek doğruluk ve verimlilik sağlamasıdır. Bu model, görsel veriye dayalı özellik çıkarımı konusunda

üstün bir performans sergileyerek, EEG sinyallerinin sınıflandırılmasında etkili bir çözüm sunmaktadır. Ayrıca, diğer birçok transformer modele kıyasla daha az parametreye sahip olması, modelin daha hızlı eğitim süreleri ve düşük hesaplama maliyetleri sunmasına olanak tanımaktadır.

3.5. Destek Karar Vektörleri

Destek vektör makineleri (SVM), gözetimli öğrenme yöntemlerinden biri olup, hem sınıflandırma hem de regresyon problemlerinde yaygın olarak kullanılır. Temel amacı, veriyi en iyi şekilde ayırtan optimal bir hiper düzlem belirlemektir. SVM, maksimum marj ilkesini temel alarak farklı sınıfları en uzak mesafeyle ayıran sınırı oluşturur ve özellikle çok sınıflı sınıflandırma problemlerinde etkili bir yaklaşım sunar. Bu algoritma, iki sınıf arasındaki en uygun ayırma çizgisini veya düzlemini hesaplayarak, sınıfların mümkün olan en geniş mesafeyle birbirinden ayrılmasını sağlar. Ayırma işlemi, "destek vektörleri" adı verilen belirleyici veri noktaları üzerinden gerçekleştirilir. Bu noktalar, modelin dayanıklılığını artırarak yeni veriler karşısında daha güçlü tahminler yapmasına yardımcı olur. Bu durum Şekil 3'te gösterilmiştir. SVM'nin en önemli avantajlarından biri, yalnızca doğrusal veri kümeleriyle değil, aynı zamanda doğrusal olmayan yapılarla da çalışabilmesidir. Bu esneklik, çekirdek fonksiyonları sayesinde sağlanır ve algoritmanın geniş bir uygulama alanına sahip olmasını mümkün kılar [19].




Şekil 3. SVM'de hiper düzlem, kenar boşluğu ve destek vektörlerinin gösterimi.

3.6. Önerilen Model

Önerilen yaklaşım, epileptik bireylerin verilerini (N, F, S) ve sağlıklı bireylerin verilerini (O, Z) dikkate alarak epileptik nöbet tespitini gerçekleştiren yapay zeka tabanlı hibrit bir model sunmaktadır. Bu yaklaşım; ön işleme, model eğitimi, son işleme ve sınıflandırma süreçlerinden oluşmaktadır. Ön işleme aşamasında EEG sinyalleri, CMT, CWT ve ST yöntemleri kullanılarak 2B görüntülere dönüştürülmektedir. Bu dönüşüm sonucunda elde edilen üç farklı görüntü kümesi, bir sonraki aşamada 2B-DeiT3 modeli ile eğitilmektedir. DeiT3 modelinin son katmanı, 768 özellik içeren bir özellik seti üretebilmektedir. DeiT3 modelinin son katmanından çıkarılan özellikler, EEG sinyallerini temsil eden 768 boyutlu vektörler olarak elde edilmiştir. Model eğitildikten sonra, her bir görüntü kümesi (CMT, CWT, ST) için toplamda üç farklı özellik seti (A, B, C) elde edilir. Özellik füzyonu işlemi, bu üç özellik setinin kendi aralarındaki kombinasyonlarıyla gerçekleştirilir. Her bir özellik seti (A, B, C), modelin farklı özellikleri yakalama kapasitesine dayalı olarak oluşturulmuştur. Bu setler daha sonra birleştirilerek yeni, daha verimli bir özellik kümesi elde edilir. Örneğin, A ve B setleri birleştirildiğinde (A&B), A ve C setleri birleştirildiğinde (A&C) veya tüm setler birleştirildiğinde (A&B&C), her bir birleşim modeli, daha kapsamlı ve çeşitlendirilmiş bilgi sağlar. Python dilinde, NumPy kütüphanesi kullanılarak bu özellik setleri birleştirilir ve her birleştirilmiş küme, sınıflandırma amacıyla destek vektör makineleri (SVM) gibi makine öğrenmesi yöntemleriyle işlenir. Bu süreç, her bir veri kümesinin sağladığı farklı bilgi bileşenlerinin bir araya getirilmesiyle modelin sınıflandırma başarısını artırmakta önemli bir rol oynamaktadır. Sınıflandırma sürecindeki performans sonuçları özellik füzyonunun sunmuş olduğu katkıyı gözleme imkânı tanır. Önerilen yaklaşımın genel tasarımı Şekil 4'te verilmiştir.

4. DENEYSEL ANALİZLER

Deneysel analizler kapsamında, özellik füzyonu ve sınıflandırma aşamalarında (SVM yöntemi), MATLAB 2024 yazılımı kullanılmıştır. Ön işleme süreçleri (CMT, CWT, ST yöntemleri) ve model eğitimi (DeiT3 modeli) ise Python programlama dili ile gerçekleştirilmiştir. Python kodları, Jupyter Notebook arayüzü üzerinden çalıştırılmıştır. Kullanılan bilgisayarın teknik özellikleri şu şekildedir: 3,40 GHz hızında Intel Core i7 işlemci, 32 GB RAM ve 10 GB belleğe sahip bir grafik kartı. Analiz sonuçlarının değerlendirilmesi için karmaşıklık matrisi (confusion matrix) kullanılmış olup, bu matrisin metrikleri ve formülleri aşağıda sunulmuştur. Denklemler incelendiğinde; pozitif (P), negatif (N), doğru (T) ve yanlış (F) olmak üzere temel sınıflandırma bileşenleri yer almaktadır. Bu metriklerin kısaltmaları şu şekildedir: doğruluk (Doğ), f-puanı (F-skr), kesinlik (Kes) ve duyarlılık (Duy) [20]–[22]. Ölçüm analizlerinde yaygın olarak kullanılan Doğ metriği, dengeli veri kümeleri ile yüksek performans göstermektedir. $F - skr$ metriği ise veri kümesinde sınıf dağılımı dengesiz olduğunda daha etkili sonuçlar sunmaktadır [23], [24].



Şekil 4. Önerilen yaklaşımın iş hattı.

Bu çalışmada kullanılan veri kümesi dengeli bir yapıya sahiptir. Önerilen yaklaşımda tercih edilen parametreler Tablo 1’de verilmiştir. Bu parametreler dışında yöntemler için tercih edilen parametreler varsayılan değerlerdir.

$$Duy = \frac{TP}{TP+FN} \quad (4)$$

$$Kes = \frac{TP}{TP+FP} \quad (5)$$

$$F\text{-skr} = \frac{2 \times [Kes \times Duy]}{Kes + Duy} \quad (6)$$


$$Doğ = \frac{TP}{TP+TN} \quad (7)$$

Tablo 1. Önerilen yaklaşım için tercih edilmiş parametreler ve değerleri.


Model /Yöntem	Parametre	Tercih / Değer
DeiT3	Sınıflandırıcı	Linear
	Devir sayısı (epoch)	20
	Öğrenme oranı	1e-4
	Kayıp fonksiyonu	Cross Entropy
	Mini-toplu	32
	Optimizasyon	RMSprop
	Eğitim & Test oranı	%80 – %20
SVM	Ön ayar	Cubic
	Çekirdek ölçeği	Auto
	Kutu kısıtlama düzeyi	1
	Çoklu sınıf yöntemi	One-vs-One

Deneyisel analizler üç aşamadan oluşmaktadır. İlk aşamada (ön işleme süreci), orijinal veri kümesi kullanılarak veriler 2B görüntülere dönüştürülmüştür. Bu adım, 2B bir transformatör model ile eğitim yapılabilmesi için gerekli alt yapıyı sağlamaktadır. Bu amaçla, orijinal veri kümesindeki EEG sinyallerinin zaman-frekans ölçütleri dikkate alınmıştır. CMT, CWT ve ST yöntemleri kullanılarak üç farklı türde görüntü kümesi elde edilmiştir. Elde edilen görüntü kümelerinin örnekleri, Şekil 5’te sunulmuştur.


İkinci aşamada, önerilen yaklaşımın ön işleme sürecinde oluşturulan üç görüntü kümesinin bir model aracılığıyla performansının değerlendirilmesidir. Bu aşamada, literatürde [25], [26] gibi sıkça bahsedilen ve benzer modellere kıyasla mimarisinde daha az parametre barındıran yeni nesil bir model olan DeiT3 tercih edilmiştir. Model üç görüntü kümesi için ayrı ayrı eğitildi. Modelin eğitim sürecinde veri kümesinin %80’i eğitim verisi, %20’si test verisi olarak ayrıldı. Devir sayısı olarak 20 tercih edildi ve model için seçilmiş diğer parametreler Tablo 1’de gösterilmiştir. Üç görüntü kümesinin model tarafından elde edilen eğitim-test başarı grafikleri Şekil 6’da gösterilmiştir. Model eğitimlerinden elde edilen karmaşıklık matrisleri Şekil 7’de gösterilmiştir. Analizlerin metrik sonuçlarının genel başarıları Tablo 2’de verilmiştir. CMT tabanlı görüntü kümesinden %75,33 genel doğruluk başarısı, CWT tabanlı görüntü kümesinden %76,93 genel doğruluk başarısı ve ST tabanlı görüntü kümesinden %76,13 genel doğruluk başarısı elde edilmiştir. Bu adımda yapılan analizler, 2B görüntü kümelerinin DeiT3 modeli tarafından başarıyla algılandığını göstermektedir.



Şekil 5. EEG sinyallerinin CMT, CWT ve ST yöntemleri kullanılarak 2B görüntü kümelerine dönüştürülmesinden elde edilen örnek görüntüler.



Şekil 6. DeiT3 modelinin eğitim-test başarı grafikleri; a) CMT kümesi, b) CWT kümesi, c) ST kümesi.




Şekil 7. DeiT3 modelinin eğitiminden elde edilen karmaşıklık matrisi; a) CMT kümesi, b) CWT kümesi, c) ST kümesi.

Tablo 2. DeiT3 modelinin analizlerinden elde edilen metrik sonuçları (genel başarı-%).

Veri kümesi	Duy	Kes	F-skr	Doğ.
CMT	75.33	75.39	75.26	75.33
CWT	76.93	77.97	76.79	76.93
ST	76.13	76.36	75.92	76.13

Üçüncü aşama, özellik füzyonu yaklaşımıyla DeiT3 modelinin her bir görüntü kümesinden çıkarılan özellik setlerinin birbirleriyle kombinasyonunun yapılmasıdır. Bu aşamanın amacı, model tarafından elde edilen performansı artırmak ve özellik füzyonunun katkısını gözlemlemektir. Bunun için, DeiT3 modelinin son katmanından [görüntü sayısı $\times$ 768] boyutunda özellik seti çıkarılmıştır. Her bir görüntü kümesi (CMT, CWT, ST) için bu işlem ayrı ayrı gerçekleştirilmiştir. Her bir kombinasyon işlemi sonucu; (CMT & CWT) setinden [görüntü sayısı $\times$ 1536], (CMT & ST) setinden [görüntü sayısı $\times$ 1536], (CWT & ST) setinden [görüntü sayısı $\times$ 1536] ve (CMT & CWT & ST) setinden [görüntü sayısı $\times$ 2304] boyutlarında dört adet özellik seti elde edilmiştir.

Özellik setlerinin performans sonuçlarını analiz edebilmek için SVM yöntemi kullanılmıştır. Eğitim ve test verisi model eğitiminde kabul edilen oranlarda (eğitim verisi %80, test verisi %20) ayırt edilmiştir. Sınıflandırma sonucunda elde edilen karmaşıklık matrisi sonuçları Şekil 8’de gösterilmiştir. Karmaşıklık matrisleri ise Tablo 3’te verilmiştir.

**Şekil 8.** Özellik setlerinin kombinasyonu sürecinden elde edilmiş karmaşıklık matrisleri; a) CMT & CWT, b) CMT & ST, c) CWT & ST, d) CMT & CWT & ST.**Tablo 3.** Önerilen yaklaşım ile elde edilmiş karmaşıklık matrisinin metrik sonuçları (%).

Set Birleşimi	Sınıf	Duy	Kes	F-skr	Genel Doğ.
CMT & CWT	F	72	77.70	74.74	84.33
	N	75.67	73.23	74.43	
	O	86.33	91.52	88.85	
	S	97	99.66	98.31	
	Z	90.67	80.71	85.40	
CMT & ST	F	70	78.65	74.07	84.47
	N	77.67	70.61	73.97	
	O	89.33	89.93	89.63	
	S	98.33	99.33	98.83	
	Z	87	84.74	85.86	
CWT & ST	F	72.67	80.15	76.22	84.61
	N	77.08	72.73	74.84	
	O	86.67	90.28	88.44	
	S	98	100	98.99	
	Z	88.67	81.10	84.71	
CMT & CWT & ST	F	86.33	90.56	88.40	91.20
	N	87.33	86.47	86.90	
	O	89.67	93.40	91.50	
	S	99.33	99.91	99.67	
	Z	93.33	96.11	86.42	

Tablo 3 incelendiğinde, özellikli füzyonu yaklaşımından setlerin birbiriyle birleşimi analiz sonuçlarının başarısını artırdığı gözlemlenmiştir. Üçlü kombinasyon (CMT & CWT & ST) diğer ikili kombinasyon setlerine göre daha iyi performans sergilemiştir. (CMT & CWT & ST) setiyle %91.20 genel doğruluk başarısı elde edilmiştir. İkili kombinasyonlardaki genel doğruluk başarıları; (CMT & CWT) setinden %84.33, (CMT & ST) setinden %84.47, (CWT & ST) setinden %84.61 başarı elde edilmiştir. Özellik füzyonu yaklaşımı, DeiT3 modelinden elde edilen başarıları göre daha iyi sonuçlar vermiştir. Önerilen yaklaşım genel hatları ile her bir adımı performansa katkı sunmuştur.

5. TARTIŞMA VE SONUÇ

Bu araştırmada, epilepsi nöbetlerinin tespitinde zaman-frekans dönüşüm teknikleri ve özellikli füzyonu stratejisinin etkinliği değerlendirilmiştir. Araştırma sonuçları, EEG sinyallerinin CMT, CWT ve ST yöntemleriyle 2B görüntülere dönüştürülüp ardından DeiT3 modeliyle eğitildiğinde, elde edilen özelliklerin epilepsi nöbetlerini tespit etme doğruluğunu artırdığını ortaya koymaktadır. Özellikle, farklı görüntü kümesi kombinasyonları ile yapılan özellikli füzyonu, modelin performansını önemli derecede geliştirmiştir. Özellik füzyonu yaklaşımının, çeşitli özellik kümelerinin birleştirilmesiyle daha güçlü ve anlamlı temsilciler oluşturduğuna dikkat çekilmiştir. Üçlü kombinasyon (CMT & CWT & ST) seti, diğer ikili kombinasyonlarla kıyaslandığında daha yüksek bir doğruluk oranı sunarak %91.20 doğruluk başarısı elde edilmesini sağlamıştır. Bu bulgu, özellikli füzyonunun modelin doğruluğunu artırmada belirleyici bir rol oynadığını göstermektedir. EEG sinyallerinin zaman-frekans dönüşümünden elde edilen veriler ve transformer modelinin güçlü özellik çıkarım yetenekleri, mevcut yöntemlere kıyasla önemli bir avantaj sunmaktadır.

Çalışmanın bulguları, EEG sinyallerinin farklı frekans bileşenlerinden elde edilen görüntü kümelerinin birleşiminin daha güvenilir ve doğru sonuçlar sağladığını göstermektedir. Her ne kadar CMT, CWT ve ST yöntemleri tek başlarına başarılı doğruluklar sunmuş olsa da, bu yöntemlerin birleşimi ve özellikli füzyonu, daha yüksek performans göstermiştir. Bu durum, EEG sinyallerinin çeşitli özelliklerinin birleşiminin, nöbet tespiti gibi karmaşık bir görevin başarısında daha etkili olduğunu desteklemektedir. Ayrıca, modelin doğruluğunun artırılmasında önemli bir diğer etken, DeiT3 modelinin güçlü ve esnek yapısıdır. Düşük parametre sayısı ile elde edilen yüksek doğruluk, modelin verimli bir şekilde eğitildiğini ve gereksiz hesaplama yüklerinden kaçınıldığını göstermektedir. Önerilen yaklaşım, zaman-frekans analiz yöntemlerini ve derin öğrenme algoritmalarını kullanarak epilepsi gibi nörolojik hastalıkların tespitinde daha hassas ve hızlı bir şekilde çalışabileceğini göstermektedir.

Makalemizde yer alan literatür ile karşılaştırıldığında bu çalışma da benzer doğruluk başarısı vermiştir. Mevcut literatürle yapılan karşılaştırmalar, kullanılan yöntemlerin çeşitliliği ve doğruluk başarılarının yüksekliğini gözler önüne sermektedir. Ancak, önerilen modelin sınıflandırma başarısının bu kadar yüksek olabilmesi için, EEG sinyallerinin işlenmesi, modelin parametrelerinin seçimi ve özellikli füzyonu gibi kritik faktörlerin etkisi büyüktür. Literatür taramasındaki yöntemlerin çoğu, derin öğrenme tekniklerini başarıyla uygulamasalar da, literatürde istatistiksel karşılaştırmaların ve daha kapsamlı analizlerin eksikliği dikkat çekmektedir. Gelecekte yapılacak çalışmalarda, farklı yöntemlerin daha ayrıntılı karşılaştırılması ve istatistiksel analizlerin derinlemesine ele alınması, epilepsi nöbet tespiti alanındaki modellerin genel performansını daha güvenilir bir şekilde değerlendirebilmek için önemli bir adım olacaktır.

Gelecek araştırmalarda, farklı EEG sinyali işleme yöntemleri ve çeşitli transformer modelleri kullanılarak daha geniş kapsamlı bir inceleme yapılabilir. Özellik füzyonu adımıyla sonra, özellik seçimi yaklaşımları da önerilen yönteme dâhil edilerek performansın artırılması sağlanabilir. Ayrıca, istatistiksel tabanlı tekniklerle analizler yapılarak elde edilen sonuçlar daha anlamlı bir şekilde yorumlanabilir.

Yazar Katkıları

Mesut Toğaçar: Fikrin ortaya çıkmasını sağlamış, deneysel analizleri gerçekleştirmiş ve makaleyi yazmıştır.

Çıkar Çatışması

Makale yazarı, herhangi bir çıkar çatışması olmadığını beyan eder.

KAYNAKÇA

- | | |
|---|---|
| <p>[1] C. Günbey and G. Turanlı, "Epilepsi ve Pediatrik Epilepsi Sendromları," <i>Turkish J. Pediatr. Dis.</i>, pp. 1–9, Jan. 2022.</p> <p>[2] S. U. Khan, S. U. Jan, and I. Koo, "Robust Epileptic Seizure Detection Using Long Short-Term Memory and Feature Fusion of Compressed Time-Frequency EEG Images," <i>Sensors</i>, vol. 23, no. 23, p. 9572, Dec. 2023.</p> <p>[3] R. Tutuk and R. Zengin, "Epileptic seizure detection combining power spectral density and high-frequency oscillations," <i>Int. J. Appl. Math. Electron. Comput.</i>, vol. 11, no. 2, pp. 117–127, Jun. 2023.</p> | <p>[4] Y. Pan, X. Zhou, F. Dong, J. Wu, Y. Xu, and S. Zheng, "Epileptic Seizure Detection with Hybrid Time-Frequency EEG Input: A Deep Learning Approach," <i>Comput. Math. Methods Med.</i>, vol. 2022, pp. 1–14, Feb. 2022.</p> <p>[5] M. Varlı and H. Yılmaz, "Kombine Derin Öğrenme Tabanlı Epileptik Nöbet Teşhisi," <i>Eur. J. Sci. Technol.</i>, Oct. 2021.</p> <p>[6] S. Mallick and V. Baths, "Novel deep learning framework for detection of epileptic seizures using EEG signals,"</p> |
|---|---|

- Front. Comput. Neurosci., vol. 18, Mar. 2024, doi: 10.3389/fncom.2024.1340251.
- [7] S. Srinivasan, S. Dayalane, S. kumar Mathivanan, H. Rajadurai, P. Jayagopal, and G. T. Dalu, "Detection and classification of adult epilepsy using hybrid deep learning approach," *Sci. Rep.*, vol. 13, no. 1, p. 17574, Oct. 2023.
- [8] G. Yogarajan et al., "EEG-based epileptic seizure detection using binary dragonfly algorithm and deep neural network," *Sci. Rep.*, vol. 13, no. 1, p. 17710, Oct. 2023.
- [9] A. Yadav, S. Rathee, Shalu, D. Sheoran, and P. Kumar, "Advanced Epileptic Seizure Detection Using Deep Learning and Bayesian Optimization," *SN Comput. Sci.*, vol. 5, no. 7, p. 854, Sep. 2024.
- [10] Y. Wang, N. Huang, T. Li, Y. Yan, and X. Zhang, "Medformer: A Multi-Granularity Patching Transformer for Medical Time-Series Classification," May 2024, [Online]. Available: <http://arxiv.org/abs/2405.19363>
- [11] C. Forigua, M. Escobar, and P. Arbelaez, "SuperFormer: Volumetric Transformer Architectures for MRI Super-Resolution," Jun. 2024.
- [12] A. Reigns, "Epileptic Seizure EEG Dataset with CWT Images," *Kaggle Web*, 2024. <https://www.kaggle.com/datasets/alexreigns14/finaldata>
- [13] K. Khairudin, L. Hakim, F. H. Nasution, and R. Kurniawan, "The Application of Complex Morlet Wavelet for Estimating Damping Ratio and Detecting Inter-Area Oscillation Mode on a Real Power System," in *2021 International Conference on Converging Technology in Electrical and Information Engineering (ICCTEIE)*, Oct. 2021, pp. 1–4.
- [14] B. Bilgehan and C. Kavalcioglu, "Sürekli glikoz izleme (CGM) sinyalleri ile tip 1 diyabet tedavisi için sürekli dalgacık dönüşüm (CWT) tabanlı filtreleme yöntemi," *Gazi Üniversitesi Mühendislik Mimar. Fakültesi Derg.*, vol. 35, no. 2, pp. 581–594, Dec. 2019.
- [15] D. Wei and Y. Zhang, "Fractional Stockwell transform: Theory and applications," *Digit. Signal Process.*, vol. 115, p. 103090, Aug. 2021.
- [16] S. Maksimović and S. Gajić, "Stockwell Transform and its Modifications in Signal Processing Courses: Comparison and Features," in *2023 22nd International Symposium Infoteh-Jahorina (Infoteh)*, Mar. 2023, pp. 1–6.
- [17] İ. Paçal and İ. Kunduracıoğlu, "Data-Efficient Vision Transformer Models for Robust Classification of Sugarcane," *J. Soft Comput. Decis. Anal.*, vol. 2, no. 1, pp. 258–271, Jun. 2024.
- [18] M. Agar, S. Aydin, M. Cakmak, M. Koc, and M. Togacar, "Detection of Thymoma Disease Using mRMR Feature Selection and Transformer Models," *Diagnostics*, vol. 14, no. 19, p. 2169, Sep. 2024.
- [19] Y. Alaca, E. Basaran, and Y. Celik, "Enhancing Anomaly Detection in Large-Scale Log Data Using Machine Learning: A Comparative Study of SVM and KNN Algorithms with HDFS Dataset," *ADBA Comput. Sci.*, Jul. 2024.
- [20] A. Şener, G. Doğan, and B. Ergen, "A novel convolutional neural network model with hybrid attentional atrous convolution module for detecting the areas affected by the flood," *Earth Sci. Informatics*, vol. 17, no. 1, pp. 193–209, Feb. 2024.
- [21] M. Yildirim, E. Cengil, Y. Eroglu, and A. Cinar, "Detection and classification of glioma, meningioma, pituitary tumor, and normal in brain magnetic resonance imaging using deep learning-based hybrid model," *Iran J. Comput. Sci.*, vol. 6, no. 4, pp. 455–464, Dec. 2023.
- [22] A. Çalışkan, "Detecting human activity types from 3D posture data using deep learning models," *Biomed. Signal Process. Control*, vol. 81, p. 104479, Mar. 2023.
- [23] A. T. Karadeniz, E. Başaran, and Y. Çelik, "Classification of walnut dataset by selecting CNN features with whale optimization algorithm," *Multimed. Tools Appl.*, vol. 83, no. 31, pp. 77061–77076, Feb. 2024.
- [24] M. Hasnain, M. F. Pasha, I. Ghani, M. Imran, M. Y. Alzahrani, and R. Budiarto, "Evaluating Trust Prediction and Confusion Matrix Measures for Web Services Ranking," *IEEE Access*, vol. 8, pp. 90847–90861, 2020.
- [25] I. Pacal, "Improved Vision Transformer with Lion Optimizer for Lung Diseases Detection," *Uluslararası Muhendis. Arastirma ve Gelistirme Derg.*, May 2024.
- [26] S. Zhu et al., "Application and visualization study of an intelligence-assisted classification model for common eye diseases using B-mode ultrasound images," *Front. Neurosci.*, vol. 18, May 2024.