

Araştırma Makalesi

Epileptik Nöbet Tespitinde Derin Öğrenme Yaklaşımlarının ve Dalgacık Dönüşümlerinin Rolü

Ali Demir ^{1,*} , Mesut Toğaçar ² 

Gönderim: 22.07.2025

Kabul: 08.09.2025

¹Teknoloji ve Bilgi Yönetimi, Sosyal Bilimler Enstitüsü, Fırat Üniversitesi, Elazığ, Türkiye; alidemir2302@gmail.com

²Yönetim Bilişim Sistemleri Bölümü, İktisadi ve İdari Bilimler Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye; mtogacar@firat.edu.tr

* Sorumlu yazar

Özet: Epilepsi, tekrarlayan nöbetlerle ortaya çıkan ve kalıcı nörolojik hasarlara neden olabilen ve insan hayatı için ciddi bir sinir sistemi bozukluğudur. Epileptik nöbetlerin erken tanısı, teşhis ve tedavi sürecinin etkinliğini doğrudan etkiler. Günümüzde teknolojik gelişmeler, hastalık tanısı ve tedavi süreçlerini hızlandırarak daha doğru ve etkili sonuçlar elde edilmesini sağlamaktadır. Bu çalışmada yapay zeka tabanlı hibrit bir model önerilmiştir. Önerilen yaklaşımda, EEG sinyalleri zaman-frekans dönüşüm teknikleri kullanılarak CMT, CWT ve FCWT tabanlı 2B görüntü verilerine dönüştürülmüştür. Ardından üç veriseti, derin öğrenme modelleri (ResNet ve ViT) ile eğitilip öznitelik vektörleri elde etmiştir. Bu öznitelik setleri, özellik füzyon stratejileriyle birleştirilmiş ve sınıflandırma aşamasında subspace discriminant yöntemi ile değerlendirilmiştir. Deneysel bulgular, özellikle üçlü özellik füzyonlarının birleştirilmesinden elde edilen sınıflandırma sonucunu başarılı olduğunu kanıtlamıştır. İki modelden özellik füzyonu ile elde edilen setler de birleştirilerek yeniden subspace discriminant yöntemi ile sınıflandırılmıştır. Sınıflandırma sonucu %90.65 genel doğruluk başarıları elde edilmiştir. Sonuçlar, önerilen modelin epilepsi tespitinde yüksek doğruluk ve güvenilirlik sunduğunu ve klinik uygulamalarda etkili bir destek aracı olabileceğini göstermektedir.

Anahtar Kelimeler: epilepsi tespiti; derin öğrenme; transformer modeli; özellik birleştirme; alt uzay ayrıştırıcı.

Research Article

The Role of Deep Learning Approaches and Wavelet Transformations in Epileptic Seizure Detection

Abstract: Epilepsy is a serious nervous system disorder characterized by recurrent seizures that can cause permanent neurological damage and pose a serious threat to human life. Early diagnosis of epileptic seizures directly affects the effectiveness of the diagnosis and treatment process. Today, technological advances are accelerating disease diagnosis and treatment processes, enabling more accurate and effective results. In this study, an artificial intelligence-based hybrid model is proposed. In the proposed approach, EEG signals are converted into 2D image data using time-frequency transformation techniques such as CMT, CWT, and FCWT. Subsequently, the three datasets are trained with deep learning models (ResNet and ViT) to obtain feature vectors. These feature sets were combined using feature fusion strategies and evaluated using the subspace discriminant method during the classification phase. Experimental findings

demonstrated the successful classification results obtained from the combination of triple feature fusions. The sets obtained from feature fusion of the two models were also combined and reclassified using the subspace discriminant method. The classification result achieved overall accuracy of 90.65%. The results demonstrate that the proposed model offers high accuracy and reliability in epilepsy detection and could serve as an effective support tool in clinical applications.

Keywords: epilepsy detection; deep learning; transformer model; feature fusion; subspace discriminant.

1. Giriş

Epilepsi, beyinde ani ve kontrolsüz elektriksel deşarjların meydana gelmesiyle karakterize edilen nörolojik bir bozukluktur. Bu durum, çoğunlukla kısa süreli nöbetlerle kendini gösterir ve istemsiz kasılmalar, kontrol dışı motor hareketler, dil ve dudak ısırma, şiddetli kas spazmları ile ani düşmeler gibi klinik semptomlara yol açabilir. Epileptik nöbetler, birey üzerinde fiziksel ve psikolojik açıdan ciddi komplikasyonlara neden olabilmekte ve yaşam kalitesini önemli ölçüde etkileyebilmektedir [1]. Her yıl yaklaşık 2,4 milyon kişiye yeni teşhis konulduğu Dünya Sağlık Örgütü (DSÖ) tarafından tahmin edilmektedir [2]. Epileptik nöbetlerin erken tespiti ve öngörülmesi, hastaların yaşam kalitesini artırmak ve nöbete bağlı gelişebilecek ciddi komplikasyon riskini azaltmak açısından hayati bir öneme sahiptir [3]. Bu bağlamdan yola çıkarak hastalığın tespitleri arasında EEG sinyalleri, düşük maliyetli olmaları ve kolay erişilebilirlikleri nedeniyle epilepsi tanı ve izleme süreçlerinde yaygın olarak kullanılmaktadır. Epileptik nöbetlerin hızlı ve doğru bir şekilde tespit edilmesinde önemli rol oynayan EEG tabanlı analizler, aynı zamanda uygun tedavi yaklaşımlarının belirlenmesine de katkı sağlamakta ve EEG sinyalleri, nöbetli ve nöbetsiz durumlar arasındaki güç değişimlerini ayırt edebilme potansiyeli nedeniyle, epileptik aktivitelerin belirlenmesinde önemli bir araç olarak kullanılmaktadır [4]. Epileptik EEG sinyalleri, önceden tanımlanmış frekans bantları içerisinde karakteristik olarak daha yüksek güç değerleri sergiler. Bu sinyaller, nöbetli dönemlerde nöbetsiz dönemlere kıyasla sürekli artan bir güç profili göstermekte ve bu durum, epileptik nöbetlerin tespitinde ayırt edici bir özellik sunmaktadır [5].

Literatürde gerçekleştirilen kapsamlı çalışmalar, EEG sinyallerinden elde edilen veriler aracılığıyla epilepsinin tanınması ve nöbet durumlarının belirlenmesine yönelik çok sayıda öznelilik çıkarma yöntemi ve sınıflandırma algoritmasının önerildiğini ortaya koymaktadır [6]. Epileptik EEG sinyallerinin analizi kapsamında, özellikle öznelilik çıkarımı süreçlerinde; bilgi kuramına dayalı çeşitli entropi ölçütleri [7] farklı spektral çözünürlüklere sahip dalgacık dönüşümleri [8] zaman-frekans düzlemini adaptif biçimde parçalayan ampirik mod ayrıştırma yöntemleri sistemin doğrusal olmayan dinamiklerini incelemeye yönelik kaotik ve fraktal tabanlı analiz teknikleri [5], [8] ile çok düzeyli bilgi temsili bir araya getiren hibrit yaklaşımlar [7] literatürde sıklıkla başvuru yöntemleri arasında yer almaktadır. Epileptik nöbetlerin otomatik tespiti ve sınıflandırılması amacıyla geliştirilen çalışmalarda; Subspace Discriminant, yapay sinir ağları (ANN), k-en yakın komşu algoritması (kNN), adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS) ve Naive Bayes sınıflayıcısı gibi çeşitli denetimli öğrenme tabanlı sınıflandırma ve kümeleme algoritmaları sıklıkla tercih edilmektedir [3]. Bu yöntemler, EEG sinyallerinden elde edilen çok boyutlu öznelilik kümeleri üzerinde yüksek doğrulukla karar verme yetenekleri sayesinde epileptik aktivitenin ayrık olarak modellenmesine katkı sağlamaktadır. Manuel öznelilik çıkarma yöntemleri, genellikle zaman alıcı olup yüksek hesaplama karmaşıklığına yol açmaktadır. Bu bağlamda, söz konusu karmaşık süreçlerin gerçek zamanlı uygulamalarda entegrasyonu, işlem süresi ve hesaplama yükü açısından önemli zorluklar teşkil etmektedir [6]. Günümüzde derin öğrenme teknikleri, ileri düzey yapay zeka teknolojileriyle entegre olarak, birçok araştırmanın ana odak noktası haline gelmiştir. Geleneksel makine öğrenmesi algoritmaları ile yapılan karşılaştırmalar, büyük veri setleri üzerinde derin öğrenme yöntemlerinin daha yüksek doğruluk ve daha etkin öğrenme kapasiteleri sunduğunu ortaya koymaktadır. Bu bulgu, derin öğrenme yöntemlerinin diğer sınıflandırma algoritmalarına karşı belirgin bir üstünlük sağladığını göstermektedir [7]. Son yıllarda, derin evrişimli sinir ağları (D-CNN), sınıflandırma problemlerinde özellikle transfer öğrenme yaklaşımları ile birlikte etkili bir şekilde kullanılmaktadır [9]. Göker ve ark. [10], çocuklarda gelişimsel bozuklukların tespiti amacıyla EEG sinyallerinden yararlanarak, rastgele orman (RF), kNN ve uzun-kısa süreli bellek (LSTM) gibi çeşitli makine öğrenmesi ve derin öğrenme algoritmalarıyla performans analizi gerçekleştirmiştir. Çalışma sonucunda, Welch yöntemi ile

LSTM mimarisinin entegrasyonu en yüksek sınıflandırma başarımını sağlamıştır. Öter [11], epileptik nöbetleri tespit etmek amacıyla EEG sinyalleri üzerinde parametrik yöntemler kullanarak frekans temelli özellikler çıkarmıştır. Bu özellikler, makine öğrenmesine dayalı üç farklı sınıflandırma yöntemi Gradient Boosting, Rastgele Orman ve Yapay Sinir Ağları ile ayrı ayrı eğitilmiş ve sınıflandırma performansları karşılaştırmalı olarak değerlendirilmiştir. Bu kapsamda Gradient Boosting (GB), RF ve YSA sınıflandırıcıları eğitilmiş ve performansları karşılaştırılmıştır. Elde edilen verilere incelendiğinde, YSA sınıflandırıcısının yaklaşık %97 doğruluk sağladığı görülmüştür.

Aslam ve ark. [11] gerçekleştirdikleri çalışmada EEG sinyalleri üzerinden bireyselleştirilmiş nöbet tahmini yapmayı hedeflemiştir. Bu kapsamda, CNN özellik sürecinde, LSTM ağı da sınıflandırma katmanında değerlendirmiştir. Ön işleme safhasında, sinyal verilerinden kaynaklı parazitler giderilmiş ve yüksek geçiren filtre uygulamasıyla sinyalin önemli bileşenleri ön plana çıkarılmıştır. Deneylerde kullanılan CHB-MIT EEG veri setindeki kayıtlar, 30 saniyelik segmentlere bölünmüş; nöbet öncesi örnek çeşitliliğini artırmak amacıyla bu segmentler %50 oranında bindirilerek kesitlenmiştir. Zaman-frekans düzlemine geçiş sağlamak için Short-Time Fourier Transform (STFT) yöntemi uygulanmış ve bu işlem sonucunda spektrogram görüntüleri elde edilmiştir. Üretilen bu görseller CNN mimarisine giriş verisi olarak sunulmuş ve çıkarılan özellikler, LSTM ağına aktarılmıştır. LSTM modeli aracılığıyla nöbet öncesi ve nöbet dışı dönemlerin ayrımı gerçekleştirilmiştir. Önerilen yöntem ile elde edilen en yüksek doğruluk ve duyarlılık değerleri sırasıyla %94 ve %93,8 olarak kaydedilmiştir.

Jemal ve ark. [12] EEG sinyallerinin incelenmesine yönelik olarak Filter Bank Common Spatial Pattern (FBCSP) tabanlı bir metodoloji geliştirmiştir. Bu yaklaşımla, sinyalden anlamlı öznitelikler çıkarabilmek ve bu öznitelikleri görselleştirebilmek amacıyla, bant geçiren ve uzamsal filtreleme süreçlerini simüle eden çok katmanlı bir CNN mimarisi tasarlanmıştır. Geliştirilen yöntem, epileptik nöbet öncesi evre ile normal beyin aktivitelerini birbirinden ayırabilen ve erken nöbet tahminine olanak tanıyan ikili sınıflama yapısına sahip bir yapay sinir ağı olarak yapılandırılmıştır. Çalışmada geliştirilen model, hem bireysel hasta temelli hem de hasta bağımsız genellemeye dayalı tahmin senaryolarında test edilmiştir. CHB-MIT EEG veri seti üzerinde yürütülen deneysel analizler sonucunda, bireysel hasta bazlı testlerde önerilen CNN mimarisi ile ortalama F1 skoru %91,9 ve duyarlılık oranı %96,1 olarak kaydedilmiştir. Buna karşın, farklı bireyler arası genelleme yapılan senaryolarda aynı metrikler sırasıyla %65,84 ve %67,17 düzeylerinde kalmıştır. Elde edilen bulgular, geliştirilen yöntemin bireye özel tahminlerde yüksek başarı sağladığını, ancak hasta bağımsız genellemelerde performansın belirgin şekilde düştüğünü göstermektedir. Truong ve ark. [13], epileptik nöbetlerin tahmini amacıyla DCGAN mimarisine dayalı bir yarı denetimli öğrenme yöntemi sunmuştur. Bu yaklaşımlarında, EEG sinyallerinden STFT yoluyla elde edilen zaman-frekans bilgileri, gerçek veri örneği olarak değerlendirilmiş ve bu bilgiler temel alınarak benzer yapıda yapay iki boyutlu öznitelikler oluşturulmuştur. Modelde, bu sentetik ve gerçek veriler arasındaki farkı ayırt edebilecek şekilde eğitilen bir ayırıştırıcı bileşen kullanılmıştır. Modelin eğitim süreci kararlı hâle ulaştığında, bu ayırıştırıcı ağ, denetimli öğrenme aşamasında özellik çıkarım modülü olarak yeniden değerlendirilmiştir.


Bu çalışmada, sağlıklı bireyler ve epilepsi tanısı konmuş hastalardan elde edilen EEG sinyallerinin yer aldığı hazır bir veri seti kullanılmıştır. Söz konusu sinyaller, ön işleme aşamasında çeşitli dalgacık dönüşüm teknikleri uygulanarak zaman-frekans alanında temsil edilen görüntü biçimine dönüştürülmüştür. Literatür incelendiğinde analizler için genellikle bir boyutlu görüntüler kullanılırken, bu çalışmadan iki boyutlu görüntüler elde edilmiş ve analiz edilmiştir. Elde edilen görüntü kümeleri, özellik çıkarımı amacıyla Transformer tabanlı derin öğrenme modeli ile analiz edilmiştir. Bir sonraki adımda, farklı öznitelik kümeleri bir araya getirilmiş ve bu süreçte özellik birleştirme yöntemi kullanılarak daha bütüncül ve bilgi yoğunluğu yüksek bir öznitelik kümesi elde edilmiştir. Son aşamada, oluşturulan bu birleşik özellik kümesi üzerinden makine öğrenmesi algoritmaları ile sınıflandırma gerçekleştirilmiş ve böylece epilepsi tespitinin doğruluğunu artırmak hedeflenmiştir.

Bu makalenin geri kalan bölümleri şu şekilde yapılandırılmıştır: İkinci bölümde, çalışmada kullanılan EEG veri kümesine ilişkin ayrıntılı bilgiler ve görseller sunulmaktadır. Üçüncü bölümde, uygulanan görüntü işleme yöntemleri ve denklemleri, yapay zekâ tabanlı yaklaşımlar ve önerilen modelin mimari detayları açıklanmaktadır. Dördüncü bölüm, deneysel çalışmaların bulgularını, analizlerini ve performans değerlendirmelerini içermektedir. Son bölümde, araştırmadan elde edilen veriler yorumlanarak genel sonuçlar ortaya konulmuş; çalışmanın bulgularına dayanarak gelecekteki araştırmalar için çeşitli yönlendirmelerde bulunulmuştur.

2. Materyal ve Metot

Bu çalışmada kullanılan EEG veri kümesi, her biri farklı deneysel koşullarda kaydedilmiş sinyalleri içeren beş alt gruptan (Z, O, N, F ve S) oluşmaktadır. Veri kümesi açık kaynaklı olup, herkes tarafından erişime sunulmuştur. Tüm veriler, kafa derisi yüzeyine yerleştirilen elektrot aracılığıyla tek kanallı olarak elde edilmiştir. Z ve O setleri, sırasıyla gözleri açık ve gözleri kapalı durumdaki sağlıklı bireylerden kaydedilen EEG sinyallerini içermektedir. Epileptik bireylerden elde edilen N, F ve S setleri ise cerrahi müdahale öncesinde kaydedilmiş olup, farklı epileptik durumları temsil etmektedir. Bu çerçevede, S grubu verileri epileptik nöbet sürecinde kaydedilen sinyalleri temsil ederken; N ve F gruplarına ait veriler, nöbet öncesi ya da sonrası gibi nöbet dışı zaman aralıklarında toplanmıştır. Dolayısıyla, Z ve O veri setleri kontrol grubuna ait görüntüleri oluştururken; N, F ve S setleri epileptik grup kapsamında değerlendirilmiştir [15].

Set N, beynin epilepsiye neden olmayan tarafındaki hipokampal bölgeden, nöbetin yaşanmadığı zaman diliminde kaydedilen EEG sinyallerini içermektedir. Öte yandan, Set F verileri, doğrudan epileptik odak olarak tanımlanan bölgelerden toplanmış olup, yine nöbet dışı döneme ait elektriksel beyin aktivitelerini temsil etmektedir. Buna karşılık, Set S yalnızca epileptik nöbet anında kaydedilen sinyalleri kapsamaktadır. Bu bağlamda, veri kümesi epilepsi tespiti ve beyin aktivitesinin zaman-frekans düzleminde incelenmesine yönelik olarak geliştirilen makine öğrenmesi ve derin öğrenme tabanlı yöntemler için yüksek derecede değerli bir kaynak sunmaktadır. EEG sinyallerinin farklı beyin bölgeleri ve fizyopatolojik durumlar temelinde çeşitlilik göstermesi, hem sınıflandırma algoritmalarının eğitimi hem de nörofizyolojik süreçlerin çok boyutlu analizi açısından geniş bir olanak sağlamaktadır. İlgili veri kümesi, açık erişim kapsamında Kaggle platformu üzerinden araştırmacıların kullanımına sunulmuştur [15]. Her bir alt set, 1500 adet EEG sinyali içermekte olup; toplam veri kümesi, 7500 sinyallik kapsamlı bir örneklem büyüklüğüne sahiptir. Setlere ilişkin çoklu çözünürlük analizi (Multi-Resolution Analysis, MRA) sonuçlarına dair örnek görselleştirmeler Şekil 1’de sunulmuştur.



Şekil 1. Veri kümesinin MRA tabanlı örnek görüntüleri.

3. Yöntem ve Yaklaşımlar

3.1. Karmaşık Morlet Dönüşümü

Bir sinyalin zamana bağlı frekans bileşenlerini ortaya çıkarma için Karmaşık Morlet Dönüşümü (CMT) adı verilen bir analiz metodu kullanılır. Bu metot, özünde bir dalgacık tekniği olup, analiz için Gauss penceresi uygulanmış bir sinüs dalgasını temel alır [14]. Bu çalışmada, CMT aracılığıyla elde edilen çok boyutlu zaman-frekans temsilleri, bir transformer tabanlı derin öğrenme mimarisi ile işlenmiş ve epileptik EEG sinyallerinin yüksek doğrulukla sınıflandırılması gerçekleştirilmiştir. Denklem (3.1)’de CMT tekniğinin matematiksel tanımı gösterilmiş ve denklem incelendiğinde; j , sanal birimdir. ($j = \sqrt{-1}$), f_0 dalgacığın merkez frekansıdır, t zaman değişkeni olarak ifade edilmektedir.

$$\Psi(t) = \frac{1}{\sqrt[4]{\pi}} e^{j2\pi f_0 t} e^{\left\{-\frac{t^2}{2}\right\}} \quad (3.1)$$

Epileptik olayların, özellikle ani nöbet başlangıçlarının, doğru bir şekilde tespit edilebilmesi; yüksek frekans çözünürlüğüne ve faz bilgisinin hassas biçimde analizine ihtiyaç duymaktadır. Bu bağlamda,

CMT, geleneksel dalgacık ve fourier tabanlı yöntemlere kıyasla zaman-frekans düzleminde daha ayrıntılı bilgi sağlayarak üstün performans sergilemektedir [15].

3.2. Sürekli Dalgacık Dönüşümü

Sürekli Dalgacık Dönüşümü (CWT), bir sinyalin belirli bir ana dalgacık ile olan benzerliğini zamana ve frekansa bağlı olarak incelemeye olanak tanıyan güçlü bir analiz tekniğidir. Bu yöntem, temel dalgacığın belirli oranlarda ölçeklendirilip zaman ekseninde ötelenmesi yoluyla sinyal ile sürekli iç çarpım alınmasına dayanır. Bu işlem sonucunda elde edilen dalgacık katsayıları, sinyalin farklı zaman ve frekans bileşenlerini temsil eder [16]. CWT'nin fourier dönüşümü ile karşılaştırıldığında en belirgin avantajı, yalnızca frekans bileşenlerini değil, bu bileşenlerin zaman içerisindeki dağılımını da ortaya koyabilmesidir. Fourier Dönüşümü, sinyalin genel frekans içeriğini sağlarken zamansal bilgiyi göz ardı eder. Oysa CWT, zaman-frekans düzleminde yüksek çözünürlükte yerleştirme sağlayarak özellikle durağan olmayan sinyallerin analizinde daha ayrıntılı bilgi sunar. Bu dönüşümde kullanılan ana dalgacık fonksiyonu Denklem (3.2)'de tanımlanmıştır.

$$W_{x(a,b)} = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t) \cdot \left| \pi^{-1/4} e^{-\frac{(t-b)^2}{2a}} \cdot e^{-j\omega_0 \left(\frac{t-b}{a}\right)} \right| dt \quad (3.2)$$

Bu formülde elde edilen $W_{x(a,b)}$ katsayıları, EEG sinyalinin hangi zamanda hangi frekans bileşenlerini gösterir. Ölçek a küçüldükçe daha yüksek frekanslar, büyüdükçe düşük frekanslar analiz edilir. EEG'de beyin dalgaları farklı frekans aralıklarındadır ve CWT bu dalgaları zamana göre ayırt etmede kullanılır. Kullanılacak dalgacık türü, analiz edilen sinyalin özelliklerine ve uygulama hedefine bağlı olarak seçilir. Literatürde yaygın olarak kullanılan dalgacıklar arasında Mexican Hat, Morlet, Gaussian türevi ve Shannon fonksiyonları yer almaktadır. Bu çalışmada, erişim sağlanan açık kaynak veri setlerinde CWT yöntemi kullanılarak elde edilen görüntüler hazır olarak verilmiştir [17].

3.3. Hızlı Sürekli Dalgacık Dönüşümü

Hızlı Sürekli Dalgacık Dönüşümü (FCWT) algoritması CWT'den alınan verimi yükseltmek için geliştirilmiştir. CWT tekniğinden farklı olarak FCWT ölçekten bağımsız ve ölçeğe bağlı olmak üzere iki bölüme ayırır. Ölçekten bağımsız aşamada, frekans düzlemine aktarırken sinyal ve ana dalgacık hızlı fourier dönüşümü (FFT) yöntemi ile aktarılır. Bu aşama, yalnızca bir defa mahsus gerçekleşir ve dalgacık dönüşüm sürecinde ölçek parametresinde etkilenmez [18]. Bu dönüşümde kullanılan ana dalgacık fonksiyonu Denklem (3.3)'te tanımlanmıştır.


$$W_{x(a,b)} = F^{-1} [F[x(t)] \cdot F[\psi_a^*(t)]] \quad (3.3)$$

FCWT yöntemi, F fourier dönüşümü, F^{-1} ters fourier dönüşümü, $\psi_a^*(t)$ ölçeklenmiş dalgacığın kompleks eşleniği ifade etmektedir. Her bir ölçek için hesaplamaların tekrarlanmasına rağmen, Klasik CWT ile kıyaslayınca ölçekten bağımsız bölüm bir kez çalıştığında önemli ölçüde düşük hesaplama maliyeti sunar. Bunların yanı sıra dönüşüm aşamasında sinyalin başlangıç ve bitiş noktalarında ortaya çıkabilecek sınır etkilerini azaltmak amacıyla yanlı olmayan sıfır uzatma tekniği uygulanmıştır. Bu yapı sayesinde FCWT, EEG gibi yüksek örnekleme oranına sahip sinyallerin yüksek zaman-frekans çözünürlüğü sağlayarak verimli şekilde analiz edilmesine olanak tanır.

3.4. ResNet-18 Model

Derin öğrenme modellerinden biri olan ResNet 2015 yılında ILSVRC yarışmasını kazanarak ortaya çıkmıştır. Model derin sinir ağlarında ortaya çıkabilen gradyan sönümlenmesi problemini hafifletmek ve modelin öğrenme sürecini iyileştirmek amacıyla, evrimsel bloklara ait giriş bilgisi, bir veya daha fazla katmandan sonra elde edilen çıkış aktivasyonlarına yönlendirilerek ağ içerisine artık bağlantılar entegre edilmektedir. Bu bağlantılar ile ağında etkili ve daha hızlı öğrenmesine yardımcı olan bu yaklaşıma artık öğrenme denir [9]. ResNet veriyi birkaç ana aşama üzerinden işler. Bu aşamalar, modelin derinliğine (Ör: ResNet-18, ResNet-34, ResNet-50 vb.) göre değişse de temel işleyiş mantığı aynıdır. En

önemli özelliklerinden biri olan bilgi kaybını önleme yeteneklerinden biri ağ derinleşmesine rağmen atlamalı bağlantılar sayesinde iyi öğrenme yeteneğine sahip olmasıdır [16]. ResNet-18 aşamaları Şekil 2’de görselleştirilmiştir. İlk aşamada giriş verileri alınır ve ilk evrişim ve havuzlama katmanları ile boyutlar küçültülür daha artık bloklar ile detaylı özellik çıkarımı yapılır. Ardından tam bağlantılı katmanında FC sinir ağlarında tüm nöronların birbirine bağlandığı bir katmandır ve genellikle sınıflandırma işleminin sonunda yer alır. Son aşama sınıflandırma işleminin gerçekleştirileceği softmax katmanından oluşur. FC çıkışına softmax uygulanarak her sınıfa ait olasılık tahmin edilir ve en yüksek olasılığa sahip sınıf, modelin çıktısıdır.




Şekil 2. ResNet-18 Dönüştürücü modelin genel işlem aşamaları.

Giriş verisi olarak genellikle 224×224 piksel boyutundaki görüntüleri kullanır. Artık bloklar, standart sinir ağlarına kıyasla çok daha verimli derin öğrenme sağlar ve eğitim sürecini kolaylaştırmak için geliştirilmiştir. Bu bloklar sayesinde model, gereksiz katmanların etkisini azaltarak daha doğru tahminler yapılmasına olanak tanır. Evrişimli sinir ağlarında derinliği arttıkça, modelin hesaplama sürecinde işlem hızı düşmektedir. Ayrıca derin ağların birleşimi sonucunda oluşan çok katmandan dolayı bazen modelin doğruluk oranında azalmaya yol açabilir. Artık blokları bu sorunu çözmek için etkili bir çözüm olarak kullanmak mümkündür. Derin ağlarda performansı olumsuz etkileyen ve gereksiz katmanları atlanmasına olanak sağlayan artık bloklar sayesinde modelin daha hızlı ve doğru sonuçlar üretmesini sağlar [19].

3.5. ViT Base Patch-8

Derin öğrenme yöntemleri arasında en çok kullanılan görüntü analiz modelleri arasında Vision Transformer (ViT) yer almaktadır. Modelin çıkış amacı ilk başlarda doğal dil işleme olsa da transformer tabanlı mimarilere öncü çalışmalarından biri olmuştur [20]. Bu çalışmada, veri setinin daha iyi analiz edilmesi amacıyla ViT-B/8 modeli kullanılmıştır. ViT, dikkat mekanizmasına dayalı olarak geliştirilmiş yenilikçi bir derin öğrenme mimarisidir. Bu yaklaşım, CNN sınırlı yerel algılama kapasitesinin ötesine geçerek daha kapsamlı bağlamsal öğrenme imkânı sağlar. Geleneksel evrişimsel yapılar genellikle yerel detaylara odaklanırken, ViT tüm görüntü alanı boyunca kapsamlı bağlantıları modelleyebilme yeteneğine sahip modeldir. Özellikle büyük ölçekli verilerle eğitildiğinde, ViT görüntüleri parçalara ayırarak bu parçaları sıralı bir veri dizisi olarak işler. Şekil 3’te bu modelin yapısına dair temel bir görünüm sunulmaktadır.




Şekil 3. ViT-Base Patch-8 gösterimi.

Modelin veri işleme süreci şu aşamalardan oluşmaktadır. İlk olarak, giriş görüntüsü 224×224 piksel boyutunda giriş görüntülerini 8×8 piksellik sabit boyutlu parçalara ayrılır. Her bir parça, vektör haline getirilmek üzere düzeltilir. Daha sonra, doğrusal bir dönüşüm uygulanarak bu vektörler gömülür. Transformer mimarisine özgü olarak, yama dizisinin başına bir token eklenir. Ayrıca, her vektöre karşılık gelen öğrenilebilir pozisyon kodlamaları, modelin mekânsal farkındalığını artırmak amacıyla giriş dizisine dâhil edilir. Bu sayede model, görüntüdeki her bir yamanın hem içerik bilgisini hem de konumsal bilgisini aynı anda işleyebilir hale gelir [21]. ViT-B/8 modeli, 12 katmanlı transformer encoder blokları üzerinden işlenmiştir. Her bir katmanda bulunan çok başlı dikkat mekanizması, her bir yamanın diğer tüm yamalarla olan ilişkisini öğrenerek küresel dikkat üretmiştir. Bu sayede, görüntüdeki farklı bölgeler arasındaki anlamsal ilişkiler modellenmiştir. Modelin çıktısı olarak, token tarafından temsil edilen özet bilgi, tam bağlantılı bir sınıflandırma katmanına aktarılmıştır. Bu katmanda tahmin fonksiyonu uygulanarak, her görüntünün ait olduğu sınıf tahmini gerçekleştirilmiştir.

3.6. Önerilen Model

Önerilen model, epileptik bireylerden (N, F, S) ve sağlıklı bireylerden (O, Z) alınan EEG sinyallerini içeren açık erişimli bir veri kümesi kullanılarak geliştirilmiş yapay zekâ temelli hibrit bir yaklaşımdır. Modelin amacı, epileptik ve sağlıklı durumları yüksek doğrulukla ayırt edebilecek etkili bir sınıflandırma mekanizması sunmaktır. Model dört temel aşamadan oluşmaktadır: ön işleme, model eğitimi, son işlem ve sınıflandırma. Ön işleme aşamasında EEG sinyalleri, CMT, CWT ve FCWT teknikleri kullanılarak iki boyutlu görüntülere dönüştürülür. Bu süreç sonucunda elde edilen üç farklı görüntü seti, sırasıyla ResNet-18 ve ViT modellerine giriş verisi olarak sunulur ve bu modeller üzerinde eğitim gerçekleştirilir. Modellerin son katmanları, her biri EEG sinyalini temsil eden özellik vektörleri üretmektedir. Model eğitiminin tamamlanmasının ardından, her görüntü kümesi için ayrı ayrı üç farklı özellik seti çıkarılır. ResNet-18 modeli için 'A', 'B', 'C'; ViT modeli için ise 'V', 'Y', 'Z' adlarında özellik setleri elde edilir. Özellik füzyonu aşamasında, her model kendi içinde çıkartılan bu özellik setleri birleştirilir. Örneğin, ResNet-18 için 'A&B', 'A&C', 'B&C' ve 'A&B&C' gibi birleşik setler oluşturulurken, ViT modeli için 'V&Y', 'V&Z', 'Y&Z' ve 'V&Y&Z' setleri oluşturulur. Bu birleşimler, modelin farklı sinyal bileşenlerini yakalama kapasitesini artırmaya yöneliktir. Özellik setlerinin birleştirilmesiyle oluşturulan yeni setler, önceki tekil setlere göre daha kapsamlı ve zengin bilgi içerir. Örneğin, CMT ve CWT setlerinin birleşimi (A&B), CMT ve FCWT setlerinin birleşimi (B&C) ya da tüm setlerin birleşimi (A&B&C), farklı veri setlerinin entegre edilmesiyle modelin performansını iyileştirmiştir. Aynı birleşim işlemleri, ViT modeli için de uygulanmıştır. En iyi performansı gösteren birleşik özellik setlerinin kullanılması, model başarısını önemli ölçüde artırmıştır. Bu birleşik özellik setleri, Subspace Discriminant yöntemi ile sınıflandırılmıştır. Özelliklerin bu şekilde birleştirilmesi, modelin sınıflandırma doğruluğunu ve genel başarısını artırmıştır. Elde edilen sınıflandırma sonuçları, uygulanan özellik füzyon yönteminin model performansını yükselttiğini göstermektedir. Önerilen modelin mimarisi ve iş hattı Şekil 4'te sunulmuştur.



Şekil 4. Önerilen yaklaşımın iş hattı.

4. Deneyisel Analizler

Modellerin eğitimi, ön işlem adımları ve son işlem adımlarında MATLAB 2024 ve Jupyter Notebook yazılımları kullanıldı. Python kodları Jupyter Notebook ortamında çalıştırılmıştır. Deneyisel analizlerde kullanılan donanım bilgileri şunlardır; 3,40 GHz hızında Intel Core i7 işlemci, 32 GB RAM ve 10 GB grafik belleğine sahip ekran kartı. Makine öğrenmesi ve istatistiksel sınıflandırma alanlarında, model doğruluğunu değerlendirmenin temel yöntemlerinden biri karışıklık matrisi (confusion matrix) kullanımıdır. Karışıklık matrisi, her bir satırı gerçek sınıfları, her bir sütunu ise model tarafından öngörülen sınıfları temsil edecek şekilde yapılandırılmıştır. Bu matris, sınıflandırma algoritmalarının hangi tür hataları yaptığını ve bu hataların dağılımını sistematik olarak ortaya koyar [22]. Bu yapıdaki sınıflardan biri pozitif (P), diğeri negatif (N) olarak etiketlenir ve çok sınıflı sınıflandırma problemlerinde, karışıklık matrisi $N \times N$ boyutundadır; burada N, sınıf sayısını ifade eder. Bu tür durumlarda doğru pozitif (TP), yanlış pozitif (FP), doğru negatif (TN) ve yanlış negatif (FN) kavramları doğrudan uygulanamayacağı için her sınıf ayrı ayrı ele alınır ve söz konusu sınıf pozitif kabul edilirken diğerleri negatif olarak değerlendirilir. Karmaşıklık matrisi için kullanılan metriklerin hesaplamaları Denklem (4.1-4.4)'de belirtilmiştir [23], [24]. Bu çalışmada kullanılan veri kümesinde sınıflar eşit sayıda örnek içerecek şekilde dengelenmiştir. Yönteme ait kullanılan hiperparametreler Tablo 1'de detaylı biçimde verilmiştir. Belirtilen parametreler haricindeki tüm diğer model ayarları, ilgili algoritmaların varsayılan konfigürasyonlarıyla sürdürülmüştür.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (4.1)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (4.2)$$

$$\text{F-skor} = \frac{2 \times [\text{Kesinlik} \times \text{Duyarlılık}]}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4.3)$$


$$\text{Doğruluk} = \frac{TP+TN}{FP+FN+TP+TN} \quad (4.4)$$

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

Model /Yöntem	Parametre	Tercih / Değer
ResNet-18	Sınıflandırıcı	Softmax
	Devir sayısı (epoch)	6
	Öğrenme oranı	10^{-4}
	Kayıp fonksiyonu	Cross Entropy Loss
	Mini-toplu	64


	Optimizasyon	SGD
	Eğitim & Test oranı	%75 – %25
ViT-B/8	Patch Boyutu	8×8
	Sınıflandırıcı	Linear
	Öğrenme oranı	10 ⁻⁴
	Kayıp fonksiyonu	Cross Entropy Loss
	Mini-toplu	64
	Optimizasyon	SGD
	Eğitim & Test oranı	%75 – %25

Deneyisel analiz süreci üç temel adımdan meydana gelmektedir. İlk etapta, orijinal veri setinden elde edilen ham EEG sinyalleri, iki boyutlu görüntülere dönüştürülmüştür. Bu dönüştürme işlemi, zaman-frekans çözümlemeleri temel alınarak gerçekleştirilmiştir ve böylece 2B yapıya sahip derin öğrenme modeli eğitime uygun bir veri yapısı oluşturulmuştur. Zaman ve frekans bileşenlerinin analiz edilmesi için farklı metodolojiler uygulanmıştır. Bu kapsamda, özellikle CMT, CWT ve FCWT teknikleri kullanılarak, sinyallerden üç ayrı türde görüntü seti üretimi sağlanmıştır. Elde edilen bu çoklu görüntü kümeleri, modelin çeşitli zaman-frekans özelliklerini yakalayabilmesini mümkün kılmaktadır. Bu görüntü kümelerine ait örnekler, okuyucunun daha iyi kavrayabilmesi için Şekil 5'te görsel olarak sunulmuştur.



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

Bu aşamanın devamında, oluşturulan üç farklı görüntü kümesi kullanılarak derin öğrenme modelleri ile ne kadar başarılı olduğu değerlendirilmiştir. Her bir görüntü türü, seçilen derin öğrenme modeli ile ayrı ayrı eğitilmiş ve sınıflandırma performansı karşılaştırılmıştır. Amaç, her dönüşümün başarıya katkısını görmek ve yöntemin genel doğruluğunu ortaya koymaktır. Elde edilen sonuçlar, modelin performans ölçütleri dikkate alınarak analiz edilmiştir. Bu aşamada, literatürde yaygın olarak kullanılan ve mimarisindeki derinlik-optimizasyonu sayesinde öne çıkan ResNet-18 ve ViT-B/8 modelleri tercih edilmiştir. ResNet-18 düşük parametre sayısına sahip olmasına karşın güçlü temsil kabiliyeti sunması, bu modellerin çalışmada değerlendirilmesini mümkün kılmıştır. ResNet-18, zaman-frekans tabanlı üç farklı görüntü veri kümesi (CMT, CWT ve FCWT) üzerinde ayrı ayrı eğitilerek test edilmiştir. Her görüntü türü için elde edilen eğitim ve test başarı grafikleri, Şekil 6'da sunulmuştur. Ayrıca, ResNet modelinin çıktıların sınıflandırma performansı, Şekil 7'de karmaşıklık matrisleri ile gösterilmiştir. Sınıflandırma sonuçlarının metrik değerlendirmeleri ise Tablo 2'de özetlenmiştir. Bu bulgular, ResNet-18 modelinin farklı dönüşüm teknikleriyle oluşturulan iki boyutlu EEG görüntüleri üzerinde başarılı bir şekilde sınıflandırma yapabildiğini göstermektedir.



Şekil 6. ResNet-18 modelinin eğitim-test başarı grafikleri; a) CMT kümesi, b) CWT kümesi, c) FCWT kümesi.

Tahmin						Tahmin						Tahmin					
F	240	114	2	14	5	F	319	51		3	2	F	282	77		7	9
N	38	320		2	15	N	68	283		1	23	N	32	319			24
O	1	3	342	1	28	O	2	1	327		45	O	1		332		42
S	7	2	6	358	2	S	9		1	365		S		2	1	370	2
Z	6	10	44	1	314	Z	3	15	25	2	330	Z	3	6	21		345
	F	N	O	S	Z		F	N	O	S	Z		F	N	O	S	Z


Şekil 7. ResNet-18 modelinin eğitiminden elde edilen karmaşıklık matrisi; a) CMT kümesi, b) CWT kümesi, c) FCWT kümesi.

Tablo 2. ResNet-18 modelinin analizlerinden elde edilen metrik sonuçları.

Veri Kümesi	Sınıf	Duyarlılık	Keskinlik	F-skor	Doğruluk
CMT	F	64.00	82.19	71.96	83.95
	N	85.33	71.27	77.67	
	O	91.20	86.80	88.95	
	S	95.47	95.21	95.34	
	Z	83.73	86.26	84.98	
CWT	F	85.07	79.55	82.22	86.61
	N	75.47	80.86	78.07	
	O	87.20	92.63	89.84	
	S	97.33	98.38	97.86	
	Z	88.00	82.50	85.19	
FCWT	F	75.20	88.68	81.39	87.89
	N	85.07	78.96	81.90	
	O	88.53	93.79	91.08	
	S	98.67	98.14	98.40	
	Z	92.00	81.75	86.57	

ResNet-18 modelinden elde edilen çeşitli görüntü kümelerine ait özellik vektörleri, özellik birleştirme yöntemiyle kombine edilmiştir. Bu işlem, modelin sınıflandırma başarısını artırmak ve birleşik özelliklerin performansa etkisini değerlendirmek amacıyla gerçekleştirilmiştir. Modelin son katmanından çıkarılan her bir özellik seti, [örnek sayısı $\times$ 1000] boyutunda olup, CMT, CWT ve FCWT görüntü verileri için ayrı ayrı alınmıştır. Farklı kombinasyonlar sonucunda dört adet birleşik özellik matrisi oluşturulmuştur: (A & B), (A & C) ve (B & C) ikili kombinasyonları [örnek sayısı $\times$ 2000] boyutunda, üçlü kombinasyon ise [örnek sayısı $\times$ 3000] boyutunda özellikler içermektedir. Bu birleşik özelliklerin sınıflandırma performansı, Subspace Discriminant yöntemi kullanılarak ölçülmüştür. Elde edilen ResNet modelinin sınıflandırma sonuçlarının karmaşıklık matrisleri Şekil 8'de gösterilmiştir, performans değerleri Tablo 3'te ayrıntılı olarak sunulmuştur. Tablo 3 incelendiğinde, özellik füzyonu yaklaşımından

setlerin birbirleriyle birleşimi analiz sonuçlarının başarısını artırdığı gözlemlenmiştir. Üçlü kombinasyon diğer ikili kombinasyon setlerine göre daha iyi performans sergilemiştir. Üçlü kombinasyon setiyle %83.91 genel doğruluk başarısı elde edilmiştir.




Şekil 8. ResNet-18 modelin özellik setlerinin kombinasyonu sürecinden elde edilmiş karmaşıklık matrisleri; a) CMT & CWT, b) CMT & FCWT, c) CWT & FCWT, d) CMT & CWT & FCWT.


Tablo 3. ResNet-18 modelin önerilen yaklaşım ile elde edilmiş karmaşıklık matrisinin metrik sonuçları.

Set Birleşimi	Sınıf	Duy	Kes	F-skr	Genel Doğ.
CMT & CWT	F	63.80	67.97	65.82	79.91
	N	69.87	65.99	67.88	
	O	81.93	90.84	86.15	
	S	95.73	99.03	97.36	
	Z	88.20	77.78	82.66	
CMT & FCWT	F	64.73	71.50	67.95	81.07
	N	72.47	66.93	69.59	
	O	83.93	89.93	86.83	
	S	96.73	99.52	98.11	
	Z	87.47	79.04	83.04	
CWT & FCWT	F	66.33	72.00	69.05	81.47
	N	72.07	68.68	70.33	
	O	83.27	89.99	86.50	
	S	97.07	99.25	98.15	
	Z	88.60	78.69	83.35	
CMT & CWT & FCWT	F	68.87	74.21	71.44	83.91
	N	75.73	71.22	73.41	
	O	86.80	92.80	89.70	
	S	97.80	99.53	98.66	
	Z	90.33	82.82	86.42	

ViT Base Patch-8 modeli, sahip olduğu dikkat temelli yapısı ve çok katmanlı mimarisi sayesinde EEG görüntülerinden anlamlı öznitelikler çıkarmada yüksek bir temsil kapasitesi sergilemiştir. Bu mimari, özellikle zaman-frekans düzlemindeki çok boyutlu yapıları bağlamsal olarak öğrenme yeteneği ile dikkat çekmiş ve bu nedenle çalışmada değerlendirilmiştir. ResNet-18 modelinde olduğu gibi, ViT modeli de CMT, CWT ve FCWT dönüşümleriyle elde edilen üç farklı EEG görüntü veri kümesi üzerinde ayrı ayrı eğitilmiş ve test edilmiştir. Her bir dönüşüm tekniğiyle oluşturulan EEG görüntüleri, ViT modelinin 8×8 boyutundaki yama yapısına uygun şekilde işlenmiş ve her örnek için 768 boyutlu öznitelik vektörleri çıkarılmıştır. Şekil 9’de, her dönüşüm türüne ilişkin eğitim ve test başarı oranları grafiksel olarak sunulurken; modelin sınıflandırma performansına ait karmaşıklık matrisleri ise Şekil 10’da verilmiştir. Metriklerin değerlendirme sonuçları ise Tablo 4’te detaylı biçimde yer almaktadır. Elde edilen sonuçlar, ViT modelinin EEG görüntüleri üzerinde başarılı sınıflandırmalar gerçekleştirdiğini ve güçlü bir temsil yetisi sunduğunu göstermektedir.



Şekil 9. ViT-B/8 modelinin eğitim-test başarı grafikleri; a) CMT kümesi, b) CWT kümesi, c) FCWT kümesi.




Şekil 10. ViT-B/8 modelinin eğitiminden elde edilen karmaşıklık matrisi; a) CMT kümesi, b) CWT kümesi, c) FCWT kümesi.

Tablo 4. ViT-B/8 modelinin analizlerinden elde edilen metrik sonuçları.

Veri Kümesi	Sınıf	Duyarlılık	Keskinlik	F-skor	Doğruluk
CMT	F	65.60	56.81	60.89	73.97
	N	48.27	63.51	54.85	
	O	79.73	86.42	82.94	
	S	91.73	92.72	92.23	

CWT	Z	84.53	72.05	77.79	74.67
	F	53.60	62.23	57.59	
	N	64.80	60.90	62.79	
	O	74.67	89.17	81.28	
	S	94.40	94.65	94.53	
FCWT	Z	85.87	69.25	76.67	75.47
	F	76.80	57.95	66.06	
	N	39.47	69.81	50.43	
	O	81.33	84.96	83.11	
	S	95.73	96.77	96.25	
	Z	84.00	72.25	77.68	

ResNet-18 modelinde uygulanan stratejiye benzer biçimde, ViT modelinden elde edilen öznetelikler de dönüşüm türlerine göre ayrı ayrı çıkarılmış ve daha zengin temsil gücüne ulaşmak amacıyla birleştirilmiştir. Modelin encoder katmanlarından elde edilen her bir öznetelik seti [örnek sayısı $\times$ 768] boyutunda olup; ikili öznetelik füzyonları [örnek sayısı $\times$ 1536], üçlü birleşim ise [örnek sayısı $\times$ 2304] boyutundadır. Bu öznetelik kombinasyonları, Subspace Discriminant sınıflayıcı ile test edilerek performans değerlendirmesi yapılmıştır. Tablo 5'te sunulan sonuçlar, özellikle üçlü öznetelik füzyonu uygulandığında sınıflandırma doğruluğunun anlamlı düzeyde arttığını göstermektedir. Üçlü kombinasyon seti (CMT, CWT ve FCWT) ile en başarılı sonuç elde edilmiş olup, bu setle %84,31 genel doğruluk başarıları sağlanmıştır. Elde edilen ViT modelinin sınıflandırma sonuçlarının karmaşıklık matrisleri Şekil 11'de görsel olarak paylaşılırken, karmaşıklık matrisinin metrik sonuçları Tablo 5'te ayrıntılı olarak sunulmuştur.



Şekil 11. ViT-B/8 modelin özellik setlerinin kombinasyonu sürecinden elde edilmiş karmaşıklık matrisleri; a) CMT & CWT, b) CMT & FCWT, c) CWT & FCWT, d) CMT & CWT & FCWT.

Tablo 5. ViT-B/8 modelin önerilen yaklaşım ile elde edilmiş karmaşıklık matrisinin metrik sonuçları.

Set Birleşimi	Sınıf	Duy	Kes	F-skr	Genel Doğ.
CMT & CWT	F	66.20	73.61	69.71	81.64
	N	75.20	68.65	71.78	
	O	83.67	90.81	87.09	
	S	95.80	98.97	97.36	

CMT & FCWT	Z	87.33	78.26	82.55	83.64
	F	68.33	78.07	72.88	
	N	79.73	71.70	75.51	
	O	85.07	90.56	87.73	
	S	97.20	99.12	98.15	
CWT & FCWT	Z	87.87	80.41	83.98	82.51
	F	66.33	76.83	71.20	
	N	78.87	69.83	74.08	
	O	84.07	89.37	86.64	
	S	96.93	99.32	98.11	
CMT & CWT & FCWT	Z	86.33	79.16	82.59	84.31
	F	69.67	78.34	73.75	
	N	80.20	72.30	76.04	
	O	85.80	91.54	88.58	
	S	97.53	99.46	98.49	
	Z	88.33	81.54	84.80	

Sonuç olarak, bu çalışmada hem ResNet-18 hem de ViT Base Patch-8 modelleri kullanılarak EEG sinyallerinin zaman-frekans düzleminde dönüştürülmüş görsellerinden çıkarılan öznelilikler analiz edilmiştir. Her iki derin öğrenme mimarisi, farklı dönüşüm tekniklerine karşılık gelen öznelilikleri başarıyla temsil etmiş ve bu öznelilikler, ikili ve üçlü kombinasyonlarla birleştirilerek daha zengin özellik kümeleri oluşturulmuştur. Birleştirilen öznelilik setleri, Subspace Discriminant sınıflayıcı yardımıyla değerlendirildiğinde, sınıflandırma doğruluğunun önemli ölçüde yükseldiği görülmüştür.

Son aşamada, ResNet-18 ve ViT-B/8 modelleri aracılığıyla en iyi performans sergileyen üçlü kombinasyon setleri yeniden birleştirilerek yeni bir özellik seti elde edilmiştir. Ardından Subspace Discriminant yöntemi ile yeniden sınıflandırılarak genel doğruluk performansının artırılması sağlanmıştır. Bu aşama sonucunda, %90.65 genel doğruluk oranına ulaşılmıştır. Son aşamanın karmaşıklık matrisi Şekil 12’de gösterilmiştir ve bu karmaşıklık matrisinden elde edilen metriksel sonuçlar Tablo 6’da verilmiştir.

Tahmin

F	1177	319		1	3
N	181	1300			19
O	2		1399		99
S	12	1	3	1484	
Z	7	8	46		1439
	F	N	O	S	Z

Gerçek

Şekil 12. ResNet-18 ve ViT-B/8 modellerin en iyi özellik setlerinin kombinasyonu sürecinden elde edilmiş karmaşıklık matrisi.

Tablo 6. ResNet-18 ve ViT-B/8 modellerin önerilen yaklaşım ile elde edilmiş karmaşıklık matrisinin metrik sonuçları.

Set Birleşimi	Sınıf	Duy	Kes	F-skr	Genel Doğ.
(A&B&C) & (V&Y&Z)	F	78.47	85.35	81.76	90.65
	N	86.67	79.85	83.12	
	O	93.27	96.62	94.91	
	S	98.93	99.93	99.43	
	Z	95.93	92.24	94.05	

Bu sonuçlar, çoklu derin öğrenme mimarilerine dayalı öznelik füzyonunun epileptik EEG sinyallerinin otomatik olarak tanımlanmasında yüksek doğruluk oranları elde edilmesine önemli katkı sağladığını göstermektedir. Derin öğrenme mimarilerinin sunduğu güçlü öznelik çıkarımı, zaman-frekans dönüşüm tekniklerinin sağladığı çeşitlilikle birleştğinde, epileptik EEG verilerinin etkili ve güvenilir bir biçimde sınıflandırılmasına olanak sağlamaktadır. Elde edilen bulgular, Özellik füzyonlarının birleştirilmesi yaklaşımı, ResNet-18 ve ViT modellerinin ayrı ayrı elde edilen başarılarına göre daha iyi sonuçlar vermiştir. Önerilen yaklaşım genel hatları ile her bir adımı performansa katkı sunmuştur ve epilepsi nöbetlerinin otomatik tespitine yönelik olarak sağlam ve yüksek doğruluk sağlayan bir sistem sunduğunu ortaya koymuştur.

5. Tartışma ve Sonuç

Bu çalışmada, epileptik nöbetlerin doğru ve güvenilir biçimde tespit edilmesi amacıyla EEG sinyalleri zaman-frekans dönüşüm yöntemleriyle iki boyutlu görsellere dönüştürülmüş ve bu görüntüler üzerinden derin öğrenme tabanlı öznelik çıkarımı gerçekleştirilmiştir. CMT, CWT ve FCWT yöntemleriyle oluşturulan zaman-frekans görüntüleri hem ResNet-18 hem ViT-B/8 mimarileri kullanılarak analiz edilmiştir. Yapılan deneysel çalışmalar, her iki modelin de EEG görsellerinden yüksek ayırt ediciliğe sahip öznelikler çıkarabildiğini ve tekil olarak uygulandıklarında sınıflandırmada tatmin edici başarılar sergilediğini ortaya koymuştur. Özellikle, her iki modelden türetilen özneliklerin birleştirilmesiyle elde edilen füzyon yaklaşımı, sınıflandırma performansını anlamlı biçimde artırmıştır. Ayrıca, en başarılı özellik kümelerinin birleştirilerek oluşturulan karma füzyon yapısı, Subspace Discriminant sınıflandırıcı ile değerlendirildiğinde %90.65'in üzerinde genel doğruluk oranına ulaşmıştır.

Bu sonuçlar, ResNet-18 ve ViT-B/8 modellerinin EEG tabanlı epileptik nöbet tespiti probleminde etkili olduğunu göstermektedir. Literatürde de bu modellerin başarısı desteklenmektedir. Örneğin, Yoshihara ve ark. [25], tek kanallı frontal EEG sinyalleri üzerinden ResNet-18 tabanlı öznelik çıkarımı gerçekleştirerek yüksek duyarlılık ve özgüllük değerleri elde etmişlerdir. Benzer şekilde, Hussein ve ark. [26], çok kanallı EEG verilerini kullanarak ViT tabanlı bir model geliştirmiş ve epileptik nöbet tespitinde güçlü performans elde etmişlerdir. Bu bulgular, çalışmamızda hem ResNet-18 hem de ViT-B/8 modellerinden türetilen özneliklerin hem tek başına hem de füzyonla birlikte kullanılmasının literatürle örtüşüğünü ve önerilen hibrit yaklaşımın etkinliğini güçlendirdiğini göstermektedir.

ResNet-18'in sade ve hesaplama açısından verimli yapısı, ViT-B/8 modelinin ise dikkat temelli bağlamsal öğrenme yetenekleri sayesinde elde edilen öznelikler birbirini tamamlayıcı nitelikte olmuş ve birleşik kullanım, sınıflandırma başarımını üst düzeye taşımıştır. Ayrıca, EEG sinyallerinin karmaşık ve çok boyutlu doğasının, yalnızca tek bir analiz yöntemiyle tam olarak temsil edilmesinin sınırlı kalabileceği; bu nedenle çoklu dönüşüm tekniklerinin ve modellerin birlikte değerlendirilmesinin daha zengin temsiller sunduğu görülmüştür. Bu bağlamda, özellik füzyonu stratejilerinin model başarımına etkisi açık biçimde ortaya konmuştur.

İleriye dönük çalışmalar kapsamında, modelin genellenebilirliğini artırmak amacıyla daha büyük ve çeşitli EEG veri kümeleri üzerinde test edilmesi, farklı klinik ve demografik hasta grupları ile kapsamlı analizlerin yapılması önerilmektedir. Ayrıca, aşırı öğrenme riskini azaltmak ve hesaplama yükünü optimize etmek adına boyut indirgeme ve özellik seçimi gibi yöntemlerin entegre edilmesi, sistemin etkinliğini daha da geliştirecektir.

Bununla birlikte, elde edilen sonuçların klinik uygulamalara entegrasyonu açısından değerlendirildiğinde, geliştirilen modelin epileptik nöbetlerin erken ve doğru biçimde tespitine yönelik karar destek sistemlerinde kullanıma potansiyeli taşıdığı görülmektedir. Özellikle gerçek zamanlı EEG izleme senaryolarında, modelin hesaplama verimliliği ve yüksek doğruluk oranı, klinisyenlerin nöbet tanılama süreçlerini hızlandırabilir ve tedavi planlarının daha etkin biçimde uygulanmasına katkı sağlayabilir. Bununla birlikte, sistemin klinik pratikte yaygın olarak kullanılabilmesi için farklı hasta gruplarında, uzun süreli ve çok kanallı EEG kayıtları üzerinde kapsamlı testlere ihtiyaç duyulmaktadır. Ayrıca, gerçek zamanlı uygulamalarda karşılaşılabilecek yüksek hesaplama yükü, veri aktarım gecikmeleri ve hasta kaynaklı biyolojik varyasyonlar gibi sınırlılıkların da dikkate alınması gerekmektedir.

Sonuç olarak, bu çalışma epileptik nöbetlerin tespitinde derin öğrenme mimarilerinin ve zaman-frekans dönüşümlerinin bütünleştirilmesinin, yüksek doğruluk oranı sağlayan güvenilir ve ölçeklenebilir bir sınıflandırma yaklaşımı sunduğunu ortaya koymuştur. Elde edilen bulgular, yapılacak olan çalışmalarda EEG tabanlı klinik karar destek sistemlerinin geliştirilmesinde bu tür hibrit ve çok modelli yaklaşımların önemli katkılar sağlayabileceğini göstermektedir.

Teşekkür

Yazar(lar), *International Journal of Pure and Applied Sciences* dergisinin hakemlerine ve dergi kurullarına teşekkür eder.

Not

Bu çalışma Fırat Üniversitesi Sosyal Bilimler Enstitüsü “Epileptik Nöbet Belirtilerinin Tespiti: EEG Sinyallerinin Dalgacık Dönüşümleri ve Transformer Modelinin Rolü” yüksek lisans tezinden türetilmiştir.

Yazar Katkıları

A.D. ve M.T.: Fikrin ortaya çıkmasını sağlamış, deneysel analizleri gerçekleştirmiş ve makaleyi yazmıştır.

Veri Kullanılabilirliği Bildirimi

Makalede özetlenen tüm veriler Kaggle Web Veri Havuzunda açık erişime sunulmuş veri setidir. Veri kümesi bağlantı linki: <https://www.kaggle.com/datasets/alexreigns14/finaldata>

Çıkar Çatışması

Yazar(lar) bu çalışmada çıkar çatışması olmadığını beyan etmektedir. Çalışma, tüm yazarların katkılarıyla yazılmıştır.

Araştırma ve Yayın Etiği Beyanı

Yazar(lar), çalışmanın tüm süreçlerinde *International Journal of Pure and Applied Sciences* dergisinin bilimsel, etik ve atıf kurallarına uyduklarını beyan etmişlerdir.

Kaynaklar

- [1] M. Monemian ve H. Rabbani, “Red-lesion extraction in retinal fundus images by directional intensity changes’ analysis”, *Sci Rep*, c. 11, Ara. 2021, doi: 10.1038/s41598-021-97649-x.
- [2] K. K. Kamila, S. Maliawan, I. W. Nirvana, ve D. P. W. Wardhana, “Gambaran karakteristik pasien epilepsi di RSUP Prof. Dr. IGNG Ngoerah periode Januari–Desember 2023”, *Intisari Sains Medis*, c. 16, sy 1, ss. 273-279, 2025.
- [3] A. S. Pulungan, C. A. Batubara, ve A. Fitri, “Hubungan Antara Kadar Vitamin D Dengan Frekuensi Bangkitan Pada Pasien Epilepsi di Rumah Sakit Adam Malik”, *Jurnal sosial dan sains*, c. 5, sy 4, ss. 714-722, 2025.
- [4] Y. Geniş ve E. A. Aydın, “EEG sinyallerini kullanarak 2D konvolüsyonel sinir ağları ile epilepsi hastalığının çok sınıflı tespiti”, *Politeknik Dergisi*, s. 1, 2025.
- [5] M. Toğaçar, “Epilepsi Nöbet Tespiti için Zaman-Frekans Görüntüleme: Transformer Model ile Özellik Füzyonu”, *Mühendislik Bilimleri ve Araştırmaları Dergisi*, c. 7, sy 1, ss. 93-102.
- [6] S. Kiranyaz vd., “Real-time pcg anomaly detection by adaptive 1d convolutional neural networks”, *arXiv preprint arXiv:1902.07238*, 2019.
- [7] M. İ. Gürsoy, “Emg Sinyalleri İle Derin Öğrenme Yöntemlerini Kullanarak El/Parmak Hareketi Tanıma”, *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, c. 28, sy 1, ss. 179-188, 2025.
- [8] M. Talo, U. B. Baloglu, Ö. Yıldırım, ve U. R. Acharya, “Application of deep transfer learning for automated brain abnormality classification using MR images”, *Cogn Syst Res*, c. 54, ss. 176-188, 2019.
- [9] İ. Kılıç ve N. Yalçın, “Transfer Öğrenme Teknikleri Kullanarak Nohut Çeşidi Sınıflandırma”, *Karaelmas Fen ve Mühendislik Dergisi*, c. 14, sy 1, ss. 48-58, 2024.

- [10] Z. Göker, E. Güney, G. Dinç, ve Ö. Üneri, “Bir Eğitim ve Araştırma Hastanesinde Yatarak Tedavi Gören Çocuk ve Ergenler İçin İstenen Psikiyatri Konsültasyonlarının Değerlendirilmesi.”, *Journal of Pediatric Disease/Türkiye Çocuk Hastalıkları Dergisi*, c. 8, sy 1, 2014.
- [11] M. H. Aslam vd., “Classification of EEG signals for prediction of epileptic seizures”, *Applied Sciences*, c. 12, sy 14, s. 7251, 2022.
- [12] I. Jemal, N. Mezghani, L. Abou-Abbas, ve A. Mitiche, “An interpretable deep learning classifier for epileptic seizure prediction using EEG data”, *IEEE Access*, c. 10, ss. 60141-60150, 2022.
- [13] N. D. Truong, L. Zhou, ve O. Kavehei, “Semi-supervised seizure prediction with generative adversarial networks”, içinde *2019 41st annual international conference of the IEEE engineering in medicine and biology society (EMBC)*, IEEE, 2019, ss. 2369-2372.
- [14] D. Łuczak, “Mechanical vibrations analysis in direct drive using CWT with complex Morlet wavelet”, *Power Electronics and Drives*, c. 8, 2023.
- [15] D. K. Bülbül ve B. Güçlü, “Correction of Tactile Stimulator Artifacts from Epidural Field Potentials Recorded in Rat S1 Cortex”, içinde *2021 29th Signal Processing and Communications Applications Conference (SIU)*, IEEE, 2021, ss. 1-4.
- [16] F. Demirdöğen, Ç. Danacı, S. A. Tuncer, M. Akkuş, ve S. Yıldız, “Deep Convolutional Neural Network Model for the Differential Diagnosis of Schizophrenia Using EEG Signals”, *Hitit Medical Journal*, c. 6, sy 3, ss. 257-265, 2024.
- [17] Y. Aydın, B. Erkmen ve C. Gürpınar, "Lityum-İyon Bataryaların CWT Tabanlı Derin Öğrenme Yöntemleri ile Kalan Sağlıklı Ömür (RUL) Kestirimi," *ELECO 2022 Elektrik-Elektronik ve Biyomedikal Mühendisliği Konferansı*, Bursa, Türkiye, 24-26 Kasım 2022.
- [18] H. Zhou, Z. Li, L. Pan, J. Tian, ve L. Zhu, “Online chatter detection via lightweight deep learning framework with efficient signal pre-processing”, *Mech Syst Signal Process*, c. 223, s. 111882, 2025.
- [19] F. F. Ateş, A. Çalışkan, ve M. Toğaçar, “Meme kanserinin tespiti için yapay zeka tabanlı hibrit bir model önerisi”, *Fırat Üniversitesi Fen Bilimleri Dergisi*, c. 34, sy 2, ss. 189-199, 2022.
- [20] Y. Huo, K. Jin, J. Cai, H. Xiong, ve J. Pang, “Vision transformer (Vit)-based applications in image classification”, içinde *2023 IEEE 9th Intl Conference on Big Data Security on Cloud (BigDataSecurity)*, *IEEE Intl Conference on High Performance and Smart Computing (HPSC)* and *IEEE Intl Conference on Intelligent Data and Security (IDS)*, IEEE, 2023, ss. 135-140.
- [21] Y. Huang vd., “Segment anything model for medical images?”, *Med Image Anal*, c. 92, s. 103061, 2024.
- [22] I. Markoulidakis, G. Kopsiaftis, I. Rallis, ve I. Georgoulas, “Multi-Class Confusion Matrix Reduction method and its application on Net Promoter Score classification problem”, içinde *Proceedings of the 14th Pervasive Technologies Related to Assistive Environments Conference*, New York, NY, USA: ACM, Haz. 2021, ss. 412-419. doi: 10.1145/3453892.3461323.
- [23] Y. Wang, Y. Jia, Y. Tian, ve J. Xiao, “Deep reinforcement learning with the confusion-matrix-based dynamic reward function for customer credit scoring”, *Expert Syst Appl*, c. 200, s. 117013, Ağu. 2022, doi: 10.1016/j.eswa.2022.117013.
- [24] Y. E. Gür, M. Toğaçar, ve B. Solak, “Integration of CNN Models and Machine Learning Methods in Credit Score Classification: 2D Image Transformation and Feature Extraction”, *Comput Econ*, c. 65, sy 5, ss. 2991-3035, May. 2025, doi: 10.1007/s10614-025-10893-5.

- [25] T. Yoshiba, H. Kawamoto, ve Y. Sankai, "Basic study of epileptic seizure detection using a single-channel frontal EEG and a pre-trained ResNet", içinde *2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, IEEE, Kas. 2021, ss. 3082-3088. doi: 10.1109/EMBC46164.2021.9630982.
- [26] R. Hussein, S. Lee ve R. Ward, "Multi-channel vision transformer for epileptic seizure prediction," *Biomedicines*, vol. 10, no. 7, p. 1551, 2022. doi: 10.3390/biomedicines10071551