



POLİTEKNİK DERGİSİ

*JOURNAL of POLYTECHNIC*

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



**Destek vektör makineleri ile eeg sinyallerinden epileptik nöbet sınıflandırması**

*Epileptic seizure classification from eeg signals with support vector machines*

*Yazar(lar) (Author(s)): Erdem TUNCER<sup>1</sup>, Emine Doğru BOLAT<sup>2</sup>*

*ORCID<sup>1</sup>: 0000-0003-1234-7055*

*ORCID<sup>2</sup>: 0000-0002-8290-6812*

**Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article):** Tuncer E., Bolat E. D., “Destek vektör makineleri ile EEG sinyallerinden epileptik nöbet sınıflandırması”, *Politeknik Dergisi*, 25(1): 239-249, (2022).

**Erişim linki (To link to this article):** <http://dergipark.org.tr/politeknik/archive>

**DOI:** 10.2339/politeknik. 672077

# Destek Vektör Makineleri ile EEG Sinyallerinden Epileptik Nöbet Sınıflandırması


## Epileptic Seizure Classification from EEG Signals with Support Vector Machines

### Önemli noktalar (Highlights)

- ❖ Destek vektör makineleri/Support vector machine
- ❖ Çekirdek fonksiyonu seçimi/Kernel function selection
- ❖ PUK/PUK
- ❖ Elektroensflogram/ Electroencephalogram
- ❖ Epilepsi/Epilepsy

### Grafik Özet (Graphical Abstract)

Parametre optimizasyonu yapılarak EEG verileri sınıflandırılmıştır. / EEG data were classified by parameter optimization.



Şekil. Önerilen sistem algoritması /Figure. Algorithm of the Proposed System

### Amaç (Aim)

Epileptik nöbet sınıflandırmasında Destek Vektör Makineleri kullanılmıştır. / Support Vector Machine was used for epileptic seizure classification.

### Tasarım ve Yöntem (Design & Methodology)

EEG sinyalleri, ayrık dalgacık yöntemi ile farklı frekans bandlarında incelenmiştir. Sınıflandırıcı algoritması olarak SVM kullanılmıştır. / EEG signals have been studied in different frequency bands by the discrete wavelet method. SVM is used as the classifier algorithm.

### Özgünlük (Originality)

PUK çekirdek fonksiyonuna özgü parametre optimizasyonunun sonuçlara olan ilişkisi ortaya konulmuştur. / The relationship of parameter optimization specific to PUK kernel function with results is revealed.

### Bulgular (Findings)

SVM çekirdek fonksiyonlarının optimizasyonu ile sınıflandırma problemlerinde daha az işlem yüküyle yüksek başarı elde edilmiştir. / With the optimization of SVM kernel functions, high success has been achieved in classification problems with less processing load.

### Sonuç (Conclusion)

Önerilen model ile öznitelik hesap yükü azaltılmış, boyut azaltım algoritmaları kullanım ihtiyacı ortadan kaldırılmıştır. / With the proposed model, feature calculation load has been reduced and the need to use feature reduction algorithms has been eliminated.

### Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The authors of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

# Destek Vektör Makineleri ile EEG Sinyallerinden Epileptik Nöbet Sınıflandırması

*Araştırma Makalesi / Research Article*

**Erdem TUNCER<sup>1\*</sup>, Emine Doğru BOLAT<sup>2</sup>**

<sup>1</sup>Bahçeçik Mesleki ve Teknik Anadolu Lisesi, Elektrik Elektronik Bölümü, Kocaeli, Türkiye

<sup>2</sup>Teknoloji Fakültesi, Biyomedikal Müh. Bölümü, Kocaeli Üniversitesi, Türkiye

(Geliş/Received : 10.01.2020 ; Kabul/Accepted : 03.12.2020 ; Erken Görünüm/Early View : 02.01.2021)

## ÖZ

Epileptik aktivitelerin saptanması Elektroensflogram (EEG) verilerinin ayrıntılı analizini gerektirir. El ile epileptik aktiviteleri skorlaması hem zor hem de tutarsızdır. Makine öğrenme teknikleri ise el ile skorlamaya göre daha hızlı ve tutarlıdır. Bu nedenle, EEG verilerini sınıflandırmak için etkili bir makine öğrenmesi tekniğine ihtiyaç vardır. Doğrusal olmayan verileri modelleme başarısından dolayı gözetimli öğrenme algoritmalarından Destek Vektör Makineleri(SVM) tercih edilmiştir. Bu başarı ancak uygun çekirdek fonksiyonu seçildiğinde gerçekleşmektedir. Sıklıkla kullanılan çekirdek fonksiyonları linear, polinom ve radyal tabanlı(RBF)'dir. Verilerin doğası önceden bilinmediğinden çekirdek fonksiyonları arasından uygun seçim yapmak zordur. Bu nedenle modeli oluştururken birden fazla çekirdek fonksiyonu kullanılarak aralarından en iyi performansı veren seçilmelidir. Bu çalışmada Bonn üniversitesinden alınan EEG verileri ile 9 farklı sınıflandırma problemi ele alınmıştır. EEG sinyalleri farklı 5 frekans bandında incelenmiş, her frekans bandının standart sapma değerlerinden öznelik vektörü oluşturulmuştur. Linear, polinom, radyal tabanlı ve Pearson VII(PUK) çekirdek fonksiyonlarının genelleme yetenekleri karşılaştırılmıştır. PUK çekirdek fonksiyonları parametre değerlerinin başarı oranları üzerindeki etkisi de ayrıca incelenmiştir. Çalışmada önerilen model ile öznelik hesap yükü azaltılmış, boyut azaltım algoritmaları kullanım ihtiyacı ortadan kaldırılmış, daha az işlem yükü oluşturmuştur. PUK çekirdek fonksiyonunun diğer fonksiyonlara göre daha iyi genelleme performansına sahip olduğu sonucuna varılmıştır. İki sınıflı problemlerde %100 başarı oranına ulaşılmıştır.

**Anahtar Kelimeler:** Destek vektör makineleri, puk, çekirdek fonksiyonu seçimi, elektroensflogram, epilepsi.

# Epileptic Seizure Classification from EEG Signals with Support Vector Machines

## ABSTRACT

Detection of epileptic activities requires detailed analysis of the electroencephalogram (EEG) data. Scoring manual epileptic activities is both difficult and inconsistent. Machine learning techniques are faster and more consistent than manual scoring. Therefore, there is a need for an effective machine learning technique to classify EEG data. Because of the success of modeling nonlinear data, Support Vector Machines (SVM), which is a supervised learning algorithm, is preferred. This success is achieved only when the appropriate kernel function is selected. Commonly used kernel functions are linear, polynomial and radial based (RBF). Since the nature of the data is not known in advance, it is difficult to make appropriate selection from the kernel functions. For this reason, when creating the model, it should be selected using multiple kernel functions to give the best performance among them. In this study, EEG data from Bonn University and 9 different classification problems are discussed. EEG signals were analyzed in 5 different frequency bands and feature vectors were generated from the standard deviation values of each frequency band. The generalization capabilities of linear, polynomial, radial based and Pearson VII(PUK) kernel functions are compared. The effect of PUK kernel functions parameter values on success rates is also investigated. With the model proposed in the study, processing load was reduced, dimensionality reduction algorithms were eliminated, and less processing load was created. It was concluded that PUK kernel function has better generalization performance than other functions. 100% success rate was achieved in two-class problems.

**Keywords:** Support vector machines, puk, kernel function selection, electroencephalogram, epilepsy.

## 1. GİRİŞ (INTRODUCTION)


Epilepsi, Dünya nüfusunun yaklaşık %1'ini etkileyen bir nörolojik bozukluk olup, beyindeki sinir hücresi kümelerinin anormal şekilde işlev görmesi sonucunda, nöbetlere neden olmasındır.

Şekil 1'de EEG verilerinin tipik örnekleri gösterilmektedir. Li M. ve diğerleri çalışmalarında; Bonn

üniversitesi verileri kullanarak, Çift Yoğunluklu-Ayrık Dalgacık Dönüşümü (DD-DWT) ile EEG verilerini 5 alt frekans bandına ayırtmışlardır. Her alt bant için zaman tanım bölgesinde hurs exponent ve fuzzy entropi öznelikleri hesaplanmış, bu öznelikler varyans ve kovaryans analizi(ANOVA)'ne tabii tutularak, özneliklerden etkin olanlar tespit edilmiş ve öznelik sayısı azaltılmıştır. Veriler üzerinden 5 farklı sınıflandırma problemi oluşturmuşlardır.

\*Erdem TUNCER (Corresponding Author)

e-posta : erdemtuncerr@gmail.com



**Şekil 1.** Set A'dan Set E'ye seçilen tipik örnekler (Typical samples selected from Sets A to E)

Genetik algoritma tabanlı destek vektör makineleri (GA-SVM) ile 10-katlı çapraz doğrulama kullanılarak, %97,20-%100 oranları arasında sınıflandırma doğruluğu elde etmişlerdir [2]. Wang G. ve diğerleri çalışmalarında; Bonn Üniversitesi verilerini; karar ağacı C4.5, Rastgele orman algoritması(RF), Destek vektör makinesi tabanlı karar ağacı algoritması(SVM+C4.5) ve SVM tabanlı RF algoritması(SVM+RF) şeklinde 4 farklı sınıflandırıcı ve 3 farklı sınıflandırma problemi ile test etmişlerdir. EEG sinyallerini kısa süreli fourier dönüşümü (STFT) ile farklı pencerelere ayırmışlar ve her pencere için 5 frekans bandının (Delta, Teta, Alfa, Beta, Gama) enerji değerlerini hesaplamışlardır. SVM ile yapılan sınıflandırmada farklı çekirdek yapılarını(Gaussian, tanh) ve parametre(C=0.2, 2e1, 2e3) sonuçlarını incelemişlerdir. 10-katlı çapraz doğrulama yöntemi kullanılarak yapılan eğitimler sonucunda, 2 sınıflı problemde SVM+RF ve SVM+C4.5 ile %99,67, %99,33, 3 sınıflı problemde RF algoritması ile %82,60, 5 sınıflı problemlerde SVM+RF ve RF algoritması ile %97,20 ve %96 başarı oranına ulaşmışlardır[3]. Li M. ve diğerleri çalışmalarında; Bonn Üniversitesi EEG verileri (Set A, Set D, Set E) kullanılarak oluşturulan sınıflandırma problemleri için zarf analizi temelli dalgacık(EA) ve yapay sinir ağı topluluğu(NNE) yöntemini önermişlerdir. Ayrık Dalgacık Dönüşümü(DWT) ile EEG sinyalleri alt frekans bantlarına ayrıştırılmış, her alt frekans bantları için Hilbert Dönüşümü(HT) kullanılarak zarf analizi yapılmıştır. Elde edilen her alt frekans bantları için zarf spektrumunun ortalaması, enerjisi, standart sapması, maksimum değerini hesaplamışlardır. Ham EEG sinyalinin ortalama, enerji, maksimum genlik değerleri

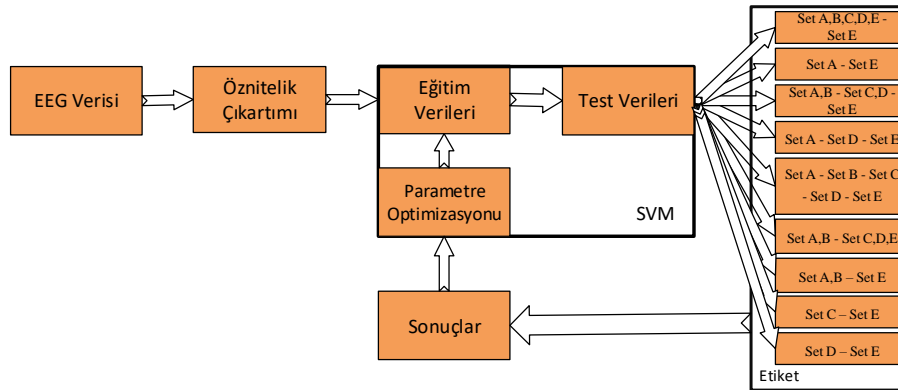
de hesaplanarak öznitelik vektörü elde edilmiştir. Elde edilen öznitelik vektörü ile NNE kullanılarak sınıflandırma gerçekleştirilmiş %98,78 başarı oranına ulaşmışlardır[4]. Yalçın N. ve diğerleri çalışmalarında; Gradient algoritmaları, türev ve diferansiyel denklem hesaplarını kullanmayan eğitim algoritması olan parçacık sürü optimizasyonu (PSO) ile yapay sinir ağını eğiterek epilepsi nöbetini sınıflandırmışlardır. Bonn üniversitesi EEG verileri ile aynı zamanda parçacık sürü optimizasyonlu sinir ağı(PSO) versiyonlarının (PSO1, PSO2, ...) nöbet tespitindeki başarılarını da kıyaslamışlardır. Kullanılan Set Z ve Set S verileri, 1600 epok olarak bölünmüş, her epok için minimum, maksimum, ortalama ve standart sapma değerlerini öznitelik olarak hesaplatmışlardır. Epilepsi nöbet tespitinde yapay sinir ağını (ANN) eğitmek için PSO3 versiyonunun daha uygun olduğu sonucuna ve %99,67 başarı oranına ulaşmışlardır[5]. Yuan Q. ve diğerleri çalışmalarında; Freiburg Üniversite hastanesi epilepsi merkezinde 21 hastadan alınan veriler ile çalışarak, otomatik nöbet tespiti yapılması amacıyla sınıflandırma yapmışlardır. Verileri 4'er saniyelik pencereler halinde, 3 frekans bandında (4–8 Hz, 8–13 Hz ve 13–30 Hz) incelemiş, her frekans bandı için 2 öznitelik hesaplatılarak, öznitelik vektörü elde etmişlerdir. Tek gizli katmana sahip İleri beslemeli yapay sinir ağı(SLFN) kullanılarak yapılan sınıflandırma sonucunda 21 hasta ortalaması % 94,90 başarı oranına ulaşmışlardır[6]. Fergus P. ve diğerleri çalışmalarında; Physionet CHB-MIT veri tabanındaki 23 hasta verisini 171 nöbet ve 171 nöbetsiz kaydı, 60 saniyelik pencereler halinde kullanmışlardır. 0,5–30 Hz frekans aralıklarında 5 alt frekans bandında EEG sinyallerini incelemişlerdir. Her frekans bandı için tepe frekansı, medyan frekansı, varyans, ortalama karekök, örnek entropisi, çarpıklık ve basıklık özniteliklerini çıkartmışlardır. Öznitelik seçim algoritmaları ile 23 kanaldan alınan EEG verisi, 5 frekans bandına ayrıştırılarak, toplamda 115 sütun elde etmişlerdir. 805 (7 öznitelik \* 115 sütun=805) öznitelik arasından boyut azaltımı yapmış, verileri en iyi ayırt edebilen 20 öznitelik seçmişlerdir. Ek olarak beyin farklı 5 bölgesindeki EEG sinyalleri arasından 25 öznitelik elde etmişlerdir. Verilerin %80'ini eğitim kalan kısmını ise test için kullanmışlar, farklı sınıflandırıcıların performanslarını da karşılaştırmışlardır. K-en yakın komşu (kNN) sınıflandırıcısı ile, 20 öznitelik ile oluşturulan modelde %91 başarı oranı, 25 öznitelikle oluşturulan modelde ise %93 başarı oranına ulaşmışlardır[7]. Katerina D. ve diğerleri çalışmalarında; Bonn Üniversitesi EEG veri tabanından alınan veriler ile 5 seviyeli DWT kullanarak daubechies4 (Db4) dalgacığı ile sınıflandırma yapmışlardır. Her alt frekans bandı için; enerji, entropi, ortalama, standart sapma ve varyans değerlerini hesaplayarak öznitelik vektörü elde etmişlerdir. 10-katlı çapraz doğrulama RBF çekirdek fonksiyonu ile SVM sınıflandırıcısı kullanmışlar, 5 farklı sınıflandırma problemleri üzerinde %87-99 arasında değişen başarı oranları elde etmişlerdir[8]. Qin Y.M. ve diğerleri çalışmalarında;

DWT Db1 dalgacığı kullanarak Bonn üniversitesi EEG veri tabanından temin ettiği EEG verilerini 2 sınıflı problem (nöbet var-yok) olarak, 5 alt frekans bandında incelemişlerdir. Ham EEG sinyali ve alt frekans bantları üzerinden istatistiki 9 öznitelik çıkartmış, SVM kullanarak sınıflandırma yapmışlardır. Verileri 0,6 ve 0,1 saniye uzunluğunda pencerelere bölerek incelemişler, %98,1 ve %93,3 başarı oranına ulaşmışlardır[9]. Sharmila A. ve diğerleri çalışmalarında; Bonn üniversitesi EEG verilerinden Set A ve Set B'yi (Sağlıklı insan verisi, Epilepsi kriz anı) kullanmışlardır. Verileri 2,95 saniyelik pencerelere bölmüşler ve DWT Db4 dalgacığı kullanarak alt frekans bantlarını incelemişlerdir. Her alt frekans bandı için standart sapma, ortalama güç gibi değerleri hesaplatmışlardır. Temel bileşen analizi (PCA) ve doğrusal ayırmacılık analizi (LDA) ile boyut indirgemesi yapmışlardır. Veri setinin %50'si eğitim, kalan kısmını ise test verisi olacak şekilde kullanmışlardır. Naive Bayes ve kNN Sınıflandırıcılarının sonuçlarını da karşılaştırılarak epilepsi nöbet tahmini gerçekleştirmişlerdir. LDA kullanılarak kNN sınıflandırıcısı ile %100 başarı oranına ulaşmışlardır[10]. Cilasun M.H. ve diğerleri çalışmalarında; epilepsi nöbet tespiti için evrişimsel sinir ağı kullanmışlardır. Bonn üniversitesi veri tabanından alınan EEG verileri 5 sınıf olacak şekilde incelenmiş, verilerin %50'si eğitim, kalan kısmını ise test için kullanmışlardır. %100 sınıflandırma başarısı elde etmişlerdir[11]. Dash D. çalışmasında; Bonn üniversitesinden alınan EEG (Set S ve Set Z) verilerini kullanarak, Fourier analizi ve DWT ile ayrı ayrı çalışmıştır. Her 23,6 saniyelik EEG sinyalleri, DWT Db4 dalgacığı kullanarak 5 alt frekans bandında incelemiş ve her frekans bandı için ortalama, medyan, mod, minimum, maksimum ve standart sapma özniteliklerini çıkartmıştır. DWT'nin daha etkin olduğu sunucuna varmış, ANN ile yapılan sınıflandırmada %97 başarı oranına ulaşmıştır[12]. Yavuz E. ve diğerleri çalışmalarında; Bonn üniversitesi EEG verilerini kullanmışlardır. 11 farklı sınıflandırma problemi için, daha çok konuşma tanımada kullanılan cepstral analiz tekniği ile mel frekans cepstral katsayıları(MFCC) hesaplatmışlardır. 13, 25, 30 ve 40 cepstral katsayılarını ayrı ayrı hesaplatmışlar ve sınıflandırma başarı oranlarını karşılaştırmışlardır. 30 cepstral katsayısı ile diğerlerine göre daha başarılı sonuçlar elde etmişlerdir. Elde edilen bu katsayılar ile 2, 5, 10-katlı çapraz doğrulamayı ayrı ayrı kullanarak genelleştirilmiş regresyon yapay sinir ağı (GRNN) ile sınıflandırma yapmışlardır. 10- katlı çapraz doğrulama ile %98-%99,9 aralığında başarı oranları elde etmişlerdir[13]. Subaşı A. çalışmasında; Bonn üniversitesi veri tabanındaki EEG verilerinden(Set Z ve Set S) epileptik nöbet EEG'si ile sağlıklı insan EEG'sini sınıflandırmıştır. Db4, Symlet10 (sym10), coiflet 4 (coif4) ve db2 dalgacıklarını kullanarak model performansını karşılaştırmış, db4 dalgacığı ile daha başarılı sonuçlar elde etmiştir. 5 seviyeli DWT ile elde edilen alt frekans bantları katsayılarının her biri için 4 farklı istatistiksel öznitelik (Dalgacık katsayılarının

mutlak değer ortalaması, ortalama gücü, standart sapması ve komşu alt bantların mutlak değer ortalaması oranı) çıkartmıştır. Çok katmanlı algılayıcı sinir ağları (MLPNN) ve uzmanların karışımı (ME) modeli kullanılarak iki farklı yaklaşımın başarı oranlarını karşılaştırmış ve ME temelli sınıflandırıcı ile %94,5 başarı oranına ulaşmıştır[14]. Güler İ. ve diğerleri çalışmalarında; Bonn üniversitesi EEG verilerini kullanarak 4 seviyeli DWT Db2 dalgacığı ile verilerin alt frekans bantlarını analiz etmişlerdir. Her epok için elde edilen her alt bant dalgacık katsayılarının; maksimum, minimum, standart sapma ve ortalama değerlerini hesaplayarak öznitelik vektörü elde etmişlerdir. 5 sınıf için 5 adet gradyan inişi geri yayımlı yapay sinir ağı ile Bulanık Çıkarım Sistemi(ANFIS)'ni eğitmişlerdir. Sınıflandırma doğruluğunu arttırmak amacıyla 5 sınıfın çıktılarının girdi olarak kullanıldığı 6. ANFIS sınıflandırıcısı ile %98,69 başarı oranına ulaşmışlardır[15]. Tzallas A.T. ve diğerleri çalışmalarında; Bonn üniversitesi verileri arasından 3 farklı sınıflandırma problemi(Set Z-Set S, Set Z-Set F-Set S ve Set Z-Set F-Set S-Set O-Set N) oluşturmuşlardır. Oluşturulan her 23,6 sn'lik pencereyi, 5 farklı frekans bandında (0-2,5 Hz, 2,5-5,5 Hz, 5,5-10,5 Hz, 10,5-21,5 Hz, 21,5-43,5 Hz ) ve zaman tanım bölgesinde 3 eşit boyutlu pencerelere bölmüşlerdir. 23,6 sn'lik pencereler için Zaman-frekans analizleri ile 16 boyutlu öznitelik vektörü elde etmişlerdir. Naive Bayes, kNN-5, karar ağacı, lojistik regresyon ve yapay sinir ağları ile yapılan sınıflandırma sonuçlarında, ANN ile %89- 100 arası başarı oranları elde etmişlerdir[16]. Stanimirova I. ve diğerleri çalışmalarında; balın coğrafi kökenini doğrulamak amacıyla Analitik veriler toplamışlar, yapı sınıflandırmasına göre örüntü tanıma tekniklerini uygulamışlardır. LDA, sınıf analojisinin hafif bağımsız modellemesi(SIMCA), diskriminant kısmi en küçük kareler (DPLS) ve SVM (PUK çekirdek fonksiyonunu kullanan) ile yapılan sınıflandırma sonuçlarını irdelemişlerdir. PUK parametre değerlerinin ( $\sigma, w$ ) de optimizasyonu ile SVM'nin daha başarılı olduğu sonucuna ulaşmışlardır[17]. Üstün B. ve diğerleri çalışmalarında; SVM'lerin eşit veya daha iyi bir genelleme performansına yol açan çekirdek işlevlerinden PUK çekirdeğinin diğer çekirdek fonksiyonları ile karşılaştırıldığında eşit veya daha güçlü bir haritalama gücüne sahip olduğu sonucuna ulaşmışlardır. PUK çekirdek fonksiyonunun doğrusal, polinom ve RBF çekirdek fonksiyonlarına genel bir alternatif olarak hizmet edebilir olduğu sonucuna ulaşmışlardır[18]. Zhang G. ve diğerleri çalışmalarında; 2121 haloofilik ve 2400 nonhalofilik proteinleri ayırt etmek için makine öğrenmesi tekniklerini kullanmışlardır. SVM ve diğer makine öğrenmesi tekniklerini kıyaslamışlardır. SVM kullanılarak diğer makine öğrenmesi tekniklerine göre daha yüksek başarı oranlarını elde etmişlerdir. SVM çekirdek fonksiyonlarını da (linear, RBF, polinom ve PUK) kıyaslayarak, en başarılı modelin PUK çekirdek fonksiyonlu SVM olduğu sonucuna ulaşmışlardır[19]. Amin H.U. ve diğerleri çalışmalarında; Bonn üniversitesi

EEG verileri arasından nöbetsiz EEG verileri ve ictal verileri ayırmak için Db4 dalgacıklı 4 seviyeli ayrık dalgacık dönüşümü kullanılmışlardır. EEG sinyaline göre değişen DWT katsayılarının maksimum sıkıştırılabilir sınırını aritmetik kodlama ile belirlemişler ve sıkıştırmışlardır. Sıkıştırılan bu katsayıları normalize ederek öznitelikleri elde etmişler, Radyal taban fonksiyonlu SVM, 3 gizli katmanlı MLP, NaiveBayes, kNN-5 sınıflandırıcıları kullanılarak 10-katlı çapraz doğrulama ile sınıflandırma performanslarını analiz etmişlerdir. Sınıflandırılan 5 varyasyonda da (A-E, AB-E, C-E, CD-E, ABCD-E) %100 başarı oranına ulaşmışlardır[20]. Zhang T. ve diğerleri çalışmalarında; epilepsi nöbet tespiti için Genelleştirilmiş Stockwell Dönüşümü (GST), tekil değer ayrışımı (SVD) ile öznitelik çıkartımını ve rastgele orman algoritmasını önermişlerdir. EEG sinyali GST matrisinden elde edilen N boyutlu global-öznitelik vektörü ve 4 tane 60 boyutlu lokalöznitelik vektörleri birleştirilerek, 240+N boyutlu hibrit öznitelik vektörü elde etmişlerdir. Bonn üniversitesi EEG verileri ile farklı varyasyonlarda (CD - E, ABCD - E, A-D-E, AB-CD-E) 10-katlı çapraz doğrulama yöntemiyle %99,12, %99,63, %99,03 ve %98,62 oranlarında sınıflandırma başarıları elde etmişlerdir[21]. Gupta V. ve diğerleri çalışmalarında;

fonksiyon parametreleri default olarak kullanıldığında, sınıflandırma başarısının yüksek olduğunu ortaya koymuştur. Default ayarları kullanılarak, SVM çekirdek fonksiyonu optimizasyonuna gerek kalmayacağını belirtmiştir. Bu durumdan dolayı da işlem yükünün azaltıldığı aynı zamanda modelin klinik denemeler için uygun olabileceğini belirtmiştir. EEG verileri arasındaki çeşitli varyasyonlarda (C-E, D-E, CD-E) yapılan sınıflandırmada %98,98, %99,91, %98,21 başarı oranı elde edilmiştir[23]. Ullah I. çalışmasında; Epilepsi verilerindeki sınırlılıktan dolayı tek boyutlu evrişimsel sinir ağı modelini önermiştir. Modelde ön işleme, öznitelik çıkartımı ya da manuel parametre ayarlaması olmamasının önemi vurgulanmıştır. Bonn üniversitesi EEG verileri ile 10-katlı çapraz doğrulama kullanılarak çeşitli varyasyonlar (AB- CD-E, AB-CD, AB-E, A-E, B-E, CD-E, C-E, D-E, BCD-E, BC-E, BD-E, AC-E, ABCD-E, AB- CDE, ABC-E, ACD-E.) kullanılarak modelin sınıflandırma performansı analiz edilmiş, %99,1-%99,97 arasında başarı oranları elde edilmiştir[24]. Hussein R. çalışmasında; Bonn üniversitesi EEG verilerinden, A-B-C-D-E, A-C-E, ABCD-E, A-E, veri setleri kullanılarak epilepsi nöbetlerinin otomatik tespit edilmesi için derin öğrenme yaklaşımı önermiştir. Temel yöntemlerle



Şekil 2. Önerilen sistemin algoritması (Algorithm of the proposed system)

özniteliklerin çıkartımı için Fouriere kıyasla daha iyi frekans çözünürlüğüne sahip Fourier-Bessel serisi (FBSE) metodu ve Renyi permütasyon entropinin bir uzantısı olan ağırlıklı çok ölçekli renyi permütasyon entropisi (WMRPE) metodunu önermişlerdir. Elde edilen öznitelikleri RF, en küçük kareler destek vektör makinesi (LS-SVM), regresyon analizleri kullanarak 10-katlı çapraz doğrulama ile farklı varyasyonlarda (A-E, B-E, C-E, D-E, CD-E, ABCD-E, A-C-E) sınıflandırmışlardır. %99,5, %99,5, %99,5, %97,5, %99, %98,6, %97,33 oranlarında sınıflandırma başarıları elde etmişlerdir[22]. Mahapatra A.G. çalışmasında; Bonn üniversitesi EEG veritabanında derinlik elektrodu ile alınan verileri (F, N ve S verileri) kullanmıştır. Epileptik aktivitelerin ayrıştırılması için etkin(RMS) frekans, baskın frekans, anlık frekans karelerinin ortalamasının karekökü ve parametrelerin birbirine oranları öznitelik olarak kullanılmıştır. Bu özniteliklerin girdi olarak verildiği SVM'nin radyal tabanlı ve polinomial çekirdek

karşılaştırıldığında, bu yaklaşım ile %100 başarı oranına ulaşılmıştır[25]. Raghu S. ve diğerleri çalışmalarında; Bonn Üniversitesi ve Ramaiah Tıp Fakültesi ve Hastanesi (RMCH)'nden elde edilen EEG verileri kullanılmıştır. Epilepsi nöbetlerinin tanımlamak için EEG matrisi tanımlamışlardır. Elde edilen öznitelikler SVM, kNN, MLP ile 10-katlı çapraz doğrulama kullanılarak sınıflandırılmıştır. Bonn üniversitesi verileri arasında yapılan 11 sınıflandırma problemlerinde (A-E, B-E, C-E, D-E, AB-E, AC-E, CD-E, ACD-E, ABCD-E, A-C-E, AB-CD-E) A-E veri setinde %99,45, RMCH verileri arasında yapılan sınıflandırmada %97,56 başarı oranına ulaşılmıştır.[26]. Li Y. çalışmasında; çok ölçekli radyal temelli fonksiyon ağırları (MRBF) ve Fisher vektörü (FV) kodlamasına dayanan otomatik nöbet algılama yöntemi önermiştir. Bonn üniversitesi EEG verileri ve Hauz Khas Nöroloji ve Uyku Merkezi gönüllü 10 epilepsi hastasından alınan EEG verileri kullanılmıştır. 10-katlı çapraz doğrulama yöntemiyle

**Çizelge 1.** Bonn EEG veri tabanındaki 5 gönüllü verisinin ayrıntılı açıklaması (Detailed description of 5 volunteer data in the Bonn EEG database) [29].

	Set A(Z)	Set B(O)	Set C(N)	Set D(F)	Set E(S)
<b>Gönüllü Sayısı</b>	5		5		
<b>Veri Özelliği</b>	Sağlıklı	Sağlıklı	Epilepsi Hastası	Epilepsi Hastası	Epilepsi Hastası
<b>Veri Tanımı</b>	Gözü Açık	Gözü Kapalı	Nöbet Anı Öncesi	Nöbet Anı Öncesi	Nöbet Anı
<b>Elektrot Tipi</b>	Saçlı Deri Elektrotu	Saçlı Deri Elektrotu	Derinlik Elektrotu	Derinlik Elektrotu	Derinlik Elektrotu
<b>Elektrot Yerleşimi</b>	10-20 uluslar arası elektrot konumlandırma sistemi	10-20 uluslar arası elektrot konumlandırma sistemi	Epileptik Olmayan Bölgeden	Epileptik Bölgeden	Epileptik Bölgeden
<b>Bölüt Sayısı</b>	100	100	100	100	100
<b>Bölüt Uzunlukları</b>	4097	4097	4097	4097	4097
<b>Örnekleme Frekansı (Hz)</b>	173.61	173.61	173.61	173.61	173.61
<b>Band Geçiren Filte Frekansı(Hz)</b>	0.53-40	0.53-40	0.53-40	0.53-40	0.53-40

SVM kullanılarak yapılan sınıflandırma sonucunda %99,30-%100 aralığında başarı oranına ulaşılmıştır. Çalışmanın sınırlı veri uzunluğu nedeniyle optimum sınıflandırma sonuçlarına ulaşamaması ve bilgisayardaki işlem yükünün çok fazla olması bu çalışmanın sınırlılıkları olarak belirtilmiştir[27]. Ghayab H.R.A., çalışmasında; ayarlanabilir Q faktörü dalgacık dönüşümü (TQWT) ve EEG verilerini analiz etmek için istatistiksel bir yaklaşıma dayanan yeni bir yöntem önermiştir. TQWT yöntemini kullanarak EEG sinyalleri farklı alt bantlara ayrıştırılmış, her bir alt bant için istatistiksel öznelik çıkartılmıştır. Elde edilen öznelikler torbalama-karar ağaçları (BT), kNN ve SVM sınıflandırıcılarına uygulanarak başarı sonuçları irdelenmiştir. 7 farklı varyasyonda (A-E, B-E, C-E, D-E, AB-E, AB-CD-E, A-B-C-D-E) sınıflandırma performansı test edilmiş kNN (k=1) sınıflandırıcı ile %100 başarı oranına ulaşılmıştır[28].

## 2. MATERYAL VE METOD (MATERIAL and METHOD)

Bu çalışmada gerçekleştirilen işlem basamakları Şekil 2'de gösterilmiştir. Bonn üniversitesi veri tabanından pencereler halinde temin edilen EEG verileri ayrı dalgacık dönüşümü kullanılarak 5 frekans bandında incelenmiştir. Her bir frekans bandı için standart sapma değerleri hesaplanarak 5x1 boyutlu öznelik vektörü elde edilmiştir. Sınıflandırıcı model eğitilerek, test verilerindeki başarı oranları kaydedilmiş, çekirdek fonksiyonları için bu işlemler tekrar edilmiştir. Alınan EEG verileri arasında 9 sınıf kombinasyonu oluşturulmuş ve RBF, Polinomial, Linear ve PUK

çekirdek fonksiyonlarından, modele uygun olan çekirdek fonksiyonu tespit edilmiş, bu çekirdek fonksiyonun parametre optimizasyonu da yapılarak başarı oranı üzerindeki etkisi incelenmiştir.

### 2.1. Veri Seçimi (Data Selection)


EEG verileri Bonn Üniversitesi veri tabanından temin edilmiştir. Tek kanaldan alınan EEG verileri A'dan E'ye 5 set halinde 23,6 sn'lik 100 bölütle oluşmaktadır. Set A sağlıklı gönüllü kişiler arasında gözü açık, Set B sağlıklı gönüllü kişiler arasında gözü kapalı saçlı deriden 10-20 uluslararası elektrot konumlandırma sistemi kullanılarak kaydedilmiştir. Set C, D, E ise derinlik elektrotları kullanılarak epilepsi hastası kişilerden alınmıştır. Set C, kriz öncesinde epileptik olmayan bölgeden alınan, Set D kriz öncesinde epileptik olan bölgeden alınan, Set E ise kriz esnasında epileptik bölgeden kaydedilen EEG verileridir. EEG sinyalleri 173,61 Hz örnekleme frekansında kaydedilmiş, 12-bit analog dijital dönüştürücü kullanılmıştır. 0,53- 40 Hz bant geçiren filtreden geçirildikten sonra her veri seti 100'er epok olacak şekilde kaydedilmiştir [29]. EEG verilerine ait detaylı bilgiler Çizelge 1'de verilmiştir.

### 2.2. Öznelik Çıkartımı (Feature Extraction)

#### 2.2.1. Ayrı dalgacık dönüşümü (Discrete wavelet transform)

Bir dalgacık, ortalama değeri sıfır olan ve zamanla sınırlı bir dalga şeklindedir. Dalgacıklar, zamanda uzatılarak veya kısaltılarak ölçeklendirilebilirler ve temel şekillerini değiştirmeden herhangi bir ölçekte farklı zaman konumlarına hareket ettirilebilirler. Aynı temel dalgacık

şekline sahip bütün ölçeklendirilmiş dalgacıklar bir aile oluştururlar[30,31]. Db4 ortogonalite özelliğiyle ve etkili filtre uygulamaları ile epileptik EEG sinyallerinin ayrışmasında uygun bir dalgacık çeşididir[20]. Bu çalışmada, Daubechies dalgacık ailesinden Db4 dalgacığı kullanılmıştır. Dalgacığın ana formu Şekil 3'te gösterilmiştir.



Şekil 3. Db4 Dalgacığı (Db4 Wavelet) [31]

Çizelge 2. Ayrık dalgacık dönüşümü uygulamasının alt band ayrışımı (Subband decomposition of discrete wavelet transform implementation)

Ayrıştırılmış Sinyal	Frekans Aralığı (Hz)
D1	43.4-86.3
D2	21.7-43.4
D3	10.8-21.7
D4	5.4-10.8
D5	0.21-5.42
A5	0-0.21

Mallat'ın 1989 yılındaki çalışmasında önerdiği algoritma yardımıyla orijinal sinyal, yaklaşım(A) ve ayrıntı(D) olarak adlandırılan iki filtreden geçirilerek iki ayrı seviyeye ayrılır. Ardından her yaklaşım seviyesi filtreden geçirilir. Bu sayede sinyal alt çözünürlük seviyesinde bileşenlerine ayrılmış olur.

Yaklaşım seviyesi sinyalin alçak frekanslı bileşenlerini, detay seviyesi ise yüksek frekanslı bileşenlerini temsil eder. Yüksek geçiren filtre çıkışı ayrıntılı, alçak geçiren filtre çıkışı Yaklaşım katsayılarını verir. Bileşenlere ayırma işlemi ardışık tekrar ederek, sinyal istenilen çözünürlük seviyesine ulaşana kadar tekrar eder. Bu yöntemle sinyali bileşenlere ayırmak ve analiz etmek mümkün olmaktadır[31-32]. Eş.1'de Ayrık dalgacık dönüşümü için kullanılan dalgacık fonksiyonu verilmiştir.

$$\varphi_{m,n}\left(\frac{t-\tau}{s}\right) = S_0^{-m/2} \varphi\left(\frac{t-n\tau_0 s_0^m}{s_0^m}\right) \quad (1)$$

Eşitlik 1'deki  $m$  ve  $n$ , dalgacığın ölçek(dikey) ve zaman(yatay) ekseninde tamsayı olarak ötelenme parametreleridir.  $s_0$ , ise ötelenme adımındır. Değeri 1'den büyüktür.  $\tau_0$  ise yatay eksenindeki ötelenme aralığıdır. Yukarıdaki denkleme yatay eksenindeki ötelenme adımının  $s_0^m$  değerine bağlı olarak  $n\tau_0 s_0^m$  şeklinde yazılabilir. İkinci katları kullanılarak oluşturulan dalgacık fonksiyonu Eş.2'deki gibi tanımlanabilir.

$$\varphi_{m,n}(t) = 2^{-\frac{m}{2}} \varphi(2^{-m}t - n) \quad (2)$$

Bir  $i$  ayrık zaman adımına sahip  $x_t$  zaman serisi için, ayrık dalgacık dönüşümü Eş.3'deki şekilde ifade edilebilir.

$$w_{m,n} = 2^{-m/2} \sum_{i=0}^{N-1} X_i \varphi(2^{-m}i - n) \quad (3)$$

Burada  $w_{m,n}$ ,  $s = 2^m$  ölçek ve  $\tau = 2^m n$  zaman değerlerine sahip dalgacık dönüşümü katsayılarıdır.

Alçak ve yüksek frekans bileşenleri Çizelge 2'de, ardışık tekrarlama işlemi ise Şekil 4'de gösterilmiştir. Çalışmada kullanılan frekans bandı 0-43,4 Hz.'dir


### 2.3. Sınıflandırma (Classification)

#### 2.3.1. Destek vektör makineleri (Support vector machines)

Destek Vektör Makineleri bir makine öğrenmesi tekniğidir. Yaygın olarak biyomedikal uygulamalarda ikili sınıflandırma problemleri için kullanılmaktadır. SVM'de amaç, iki sınıf arasındaki uzaklığın maksimum olduğu durumun bulunmasıdır. Bu verileri iki sınıfa ayıracak çok fazla sayıda ayırıcı düzlem bulunmaktadır. Optimum ayırıcı düzlem, her iki sınıfın en uç verileri arasındaki mesafenin (iki sınıfın destek vektörleri arasındaki mesafe) maksimum olduğu durumu sağlayan ayırıcı düzlemdir[33]. SVM'yi oluşturan başlıca bileşenler,

- ❖ İstatiksel öğrenme
- ❖ Optimizasyon algoritması
- ❖ Çekirdek fonksiyonlarıdır.


SVM'nin günümüzde sıklıkla kullanılıyor olmasının temel nedenlerinden bir tanesi uygun çekirdek fonksiyonu seçimi ile karmaşık düzgün olmayan verileri modelleme başarısıdır. Bu durum da yüksek boyutlu bir özellik uzayında doğrusal olmayan ilişkilerin, doğrusal



Şekil 4. Sinyalin beş seviyeli bileşenlerine ayrıştırılması (Decomposition of the signal into five level components)



bir çizgi olarak ifade edilmesi anlamına gelmektedir[33,34].



Şekil 5. Destek Vektör Makinesi (Support Vector Machine)

Şekil 5’de gösterildiği üzere örnek uzaydaki veriler farklı ve çok sayıda doğru ile ayrılabilir. Çok boyutlu uzayda bu doğruların yerini hiper düzlemler almaktadır. İki hiper düzlemin ortasını oluşturan kesikli çizgilerle gösterilen düzlem ise iki sınıftaki verileri birbirinden ayıran doğrusal hiper düzlemdir. Bu düzleme en uygun ayırma hiper düzlemi denir. Hiper düzlem,

$$w \cdot x + \beta = 0 \quad (4)$$

Şekline yazılabilir.  $W$  ağırlık vektörü,  $\beta$  ise bias’dır. Maximum margin matematiksel olarak;

$$Max\ Margin = \frac{2}{\|w\|} \quad (5)$$

$\|W\|$   $w$ 'nin oklid normu olmak üzere ifade edilir.

En uygun ayırma hiper düzlemi ise

$$f(x) = \beta_0 + \beta^T X \quad (6)$$

Şeklinde yazılabilir. Burada ifade edilen  $\beta$  Ağırlık vektörü,  $\beta_0$  bias dır.

Doğrusal olmayan veriler düz bir hiper düzlem ile birbirinden ayrılamazlar. Bu durum için çekirdek fonksiyonlar kullanılır ve en uygun ayırma düzlemine bu çekirdek fonksiyonları ile ulaşılır. Bu fonksiyonların karar kuralı Eş.7’de verilmiştir [33,34].

$$f(x) = \text{sign}(\sum_i \alpha_i y_i \phi(x) \phi(x_i) + b) \quad (7)$$

Destek vektör makineleri kullanılarak yapılacak bir sınıflandırma işlemi için kullanılması planlanan çekirdek fonksiyonu ve bu fonksiyona ait optimum parametrelerin belirlenmesi gerekir. Parametrelerin uygun değerlerinin seçimi SVM sınıflandırıcısının performansını direkt etkilemektedir[35].

### 2.3.1.1. Doğrusal çekirdek fonksiyonu (Linear kernel function)

Doğrusal çekirdek, en basit çekirdek fonksiyonudur.  $\langle x, y \rangle$  iç çarpımı ve bir  $c$  sabiti ile belirtilir. İlgili çekirdek fonksiyonu

$$k(x, y) = x^T y + c \quad (8)$$

şeklinde ifade edilir[35-37].

### 2.3.1.2. Polinomial çekirdek fonksiyonu (Polynomial kernel function)

Polinomial çekirdek fonksiyonu durağan olmayan bir çekirdektir. Polinomial çekirdeği, tüm eğitim verilerinin normalleştirildiği problemler için çok uygundur. İlgili çekirdek fonksiyonu[35-37],

$$k(x, y) = (\alpha x^T y + c)^d \quad (9)$$

şeklinde verilebilir. Ayarlanabilir parametrelerden,  $\alpha$  eğimi,  $c$  sabit terimi ve  $d$  polinom derecesini ifade etmektedir

### 2.3.2.3. RBF çekirdek fonksiyonu (RBF kernel function)

Literatürde sıklıkla kullanılan RBF çekirdek fonksiyonu Eş. 10 ile ifade edilir.

$$k(x, y) = \exp(-\gamma \|x - y\|^2) \quad (10)$$

Ayarlanabilir parametre çekirdek boyutu( $\gamma$ ), çekirdeğin performansında önemli bir rol oynar ve eldeki probleme göre seçilmelidir. Aşırı tahmin söz konusu olduğunda, üstel ifade yaklaşık olarak doğrusallaşır ve yapısını kaybetmeye başlar. Eğer gerçek değerden daha düşük tahmin gerçekleşiyorsa, karar sınırı eğitim verisindeki sınır değerlere karşı son derece duyarlı olacaktır[35-37].

### 2.3.2.4. Pearson VII çekirdek fonksiyonu (Pearson VII kernel function)

PUK fonksiyonu, Gaussian’dan, Lorentzian şekline ve ara şekillere kolayca değişme esnekliğine sahiptir. Bu esneklik, yaygın olarak kullanılan doğrusal, polinom ve RBF çekirdek fonksiyonlarına kıyasla PUK için daha

yüksek bir genelleme ile sonuçlanır. Çekirdek fonksiyonu,

$$f(x) = \frac{H}{\left[ 1 + \left( \frac{z(x-x_0) \sqrt{\frac{1}{w}}}{\sigma} \right)^2 \right]^w} \quad (11)$$

şeklinde yazılabilir.  $w$  ve  $\sigma$  parametreleri, Pearson VII fonksiyonunun genişliğini,  $H$  ise tepe değerleri arasındaki maksimum tepe seviyesini ifade eder. SVM kullanmak için, hem çekirdek parametreleri hem de SVM normalizasyon sabiti  $C$ 'nin kullanıcı tarafından tanımlanması gerekir[35-37].


## 3. BULGULAR (FINDINGS)

Bu çalışmanın odak noktası SVM’de çekirdek fonksiyonlarının optimizasyonudur. Bu optimizasyon sınıflandırma problemlerinde sıklıkla kullanılan SVM’de az işlem yüküyle yüksek sınıflandırma başarısını getirmiştir. Literatürde, çalışmaların büyük çoğunluğu normal ve epileptik aktivite arasındaki sınıflamaya odaklanmaktadır. Bu çalışmada, 9 sınıflandırma problemi ayrı ayrı incelenmiştir. İlk sınıflandırma problemi ile tüm veri seti kullanılmış ve EEG kayıtları Set A, B, C, D, E ve Set E olmak üzere iki sınıfa ayrılmıştır. İkinci sınıflandırma problemi Set A ve Set E olmak üzere oluşturulmuştur. Üçüncü sınıflandırma problemi Set A, B, Set C, D, Set E olmak üzere 3 sınıf

olmak üzere oluşturulmuştur. Dördüncü sınıflandırma problemi Set A, Set D, Set E olmak üzere oluşturulmuştur. Beşinci sınıflandırma problemi Set A, Set B, Set C, Set D, Set E olmak üzere oluşturulmuştur.

Altıncı sınıflandırma problemi, sağlıklı insanlardan

şekilde oluşturulmuştur. 5 seviyeli ayrık dalgacık yöntemi kullanılmış ve Daubechies dalgacık ailesinden Daubechies-4 dalgacı tercih edilmiştir. Sınıflandırıcı algoritması olarak SVM kullanılmış, çekirdek fonksiyonları ve çekirdek fonksiyonlarının parametreleri



Şekil 6. Farklı sınıflandırma problemleri için çekirdek fonksiyonlarının başarı oranları (Success rates of kernel functions for different classification problems)

Çizelge 3. Çekirdek yapısına göre SVM Performansı (SVM performance by kernel structure)

Çekirdek Yapısı	Sınıf	Başarı Oranı(%)	Çekirdek Yapısı	Sınıf	Başarı Oranı(%)
Omega	0.2	100	Omega	0.2	96,6
Sigma	0.2		Sigma	0.2	
Omega	1	100	Omega	1	90
Sigma	1		Sigma	1	
Omega	0.2	100	Omega	0.2	88
Sigma	0.2		Sigma	0.2	
Omega	1	100	Omega	1	75
Sigma	1		Sigma	1	
Omega	0.2	95	Omega	0.2	100
Sigma	0.2		Sigma	0.2	
Omega	1	90	Omega	1	93
Sigma	1		Sigma	1	
Omega	0.2	100	Omega	0.2	100
Sigma	0.2		Sigma	0.2	
Omega	1	100	Omega	1	100
Sigma	1		Sigma	1	
Omega	0.2	100	Omega	1	97,5

alınan EEG verileri Set A, Set B ile epilepsi hastası olan (nöbet anı olsun olmasın) insanlardan alınan (Set C, Set D, Set E) verilerden oluşturulmuştur. Diğer sınıflandırma problemleri ise Set A, B – E, Set C-E ve Set D-E olacak

(omega, sigma) optimize edilerek daha yüksek doğruluk oranlarına ulaşılması hedeflenmiştir.

Farklı çekirdek fonksiyonları arasındaki başarı oranları her sınıf problemine göre ayrı ayrı olmak üzere Şekil

**Çizelge 4.** Nöbet tespit yöntemlerinin performans karşılaştırması (Performance comparison of seizure detection methods)

Yayın yılı Yazar	Veriseti	ZONF-S	Z-S	ZO-NF-S	Z-F-S	Z-F-S-O-N	ZO-NFS	ZO-S	N-S	F-S
2007 Subası A.[14]			95%							
2009 Tzallas A.T. ve ark. [16]			100%		100%	89%				
2005 Güler İ. ve ark. [15]						98%				
2014 Dash D. [12]			97%							
2015 Yalçın N. ve ark. [5]			99,67%							
2016 Li M. ve ark. [2]		99,4%		99,36%	99,6%				100%	100%
2016 Cilasun M.H. ve ark. [11]						100%				
2017 Yavuz E. ve ark. [13]		99%	99,5%	98,6%	98%			99,6%	99%	97,2%
2017 KaterinA D. ve ark. [8]		99%	99%	98%	98%	87%				
2017 Qin Y.M. ve ark. [9]		98%								
2017 Sharmila A. ve ark. [10]			100%							
2017 Li M. ve ark. [4]					98,78%					
2017 Wang G.[3]				82,60%		97,20%		99,67%		
2018 Tao Zhang[21]		100%								
2019 VipinGupta[22]		98,6%	99,5%						99,5%	97,5%
2018 Arindam Gajendra Mahapatra [23]									99,91%	98,98%
2018 Ihsan Ullah [24]		99,7%	100%	99,1%			99,5%	99,8%	99,1%	99,4%
2019 Hussesin R. ve ark.[25]		100%	100%			100%				
2019 Ragh S. ve ark. [26]		97,20%	99,45%	96,5%				97,10%	97,60%	97,60%
2019 Li Y. ve ark. [27]		99,53%	100%						100%	99,30%
2019 Ghayab H.R.A. ve ark. [28]			100%	100%		100%		100%	100%	100%
2019 K.D.Thara ve ark.[38]		97,21%								
2020 HafeezUllah Amin [20]		100%	100%					100%	100%	
<b>This Work</b>		<b>100%</b>	<b>100%</b>	95%	97%	88%	<b>100%</b>	<b>100%</b>	<b>100%</b>	<b>100%</b>

6'da gösterilmiştir. Farklı sınıflara ait EEG verilerinin sınıflandırmasında lineer çekirdek fonksiyonu başarılı sonuçlar vermesine rağmen, PUK çekirdek fonksiyonu bütün sınıflandırma problemlerinde verileri daha iyi genelleyerek daha başarılı sonuçlar elde edilmiştir. RBF ve Polinomial çekirdek fonksiyonları veri setlerini genellemede PUK ve lineer çekirdek fonksiyonları kadar başarılı olamamıştır. PUK çekirdek fonksiyonunu diğer çekirdek fonksiyonlarından daha başarılı kılan, eğri uydurma için fonksiyonun değişme esnekliği ve 2 parametre ( $\omega$ ,  $\sigma$ ) optimizasyonunun sağlanmasıdır. Çizelge 3'de SVM sınıflandırıcısı PUK çekirdek fonksiyonuna özgü parametre değişimleri ile sınıflar arasındaki başarı ilişkisi ortaya konulmuştur. Bununla birlikte PUK çekirdek fonksiyonunun  $\omega$  ve  $\sigma$  parametrelerinden en başarılı iki değere ( $\omega=\sigma=1.0$ ,  $\omega=\sigma=0.2$ ) ve bu değerlerin

farklı veri setleri üzerindeki sınıflandırma başarı oranlarına yer verilmiştir.

Çizelge 4'de ise daha önceden yapılmış çalışmalar ile bu çalışmada sunulan modelin doğruluk oranları kıyaslanmıştır. İki sınıflı problemlerde, başarı oranı %100'dür. 3 sınıflı problemde başarı oranları %95, %96,6'dır. 5 sınıflı problemde ise başarı oranı %88 olarak tespit edilmiştir. EEG verileri arasında yapılan sınıflandırma problemlerine göre literatürde taranan çalışmaların bir çoğundan daha yüksek başarı oranına ulaşıldığı ortaya konulmuştur.

#### 4. SONUÇLAR (RESULTS)

Yapılan çalışmada, kalıcı bir beyin bozukluğu olan epilepsi hastalığı nöbetlerinin ve epilepsi hastası olan insan ile normal insanın, EEG sinyalleri üzerinden ayırt

edilmesi amaçlanmıştır. Tek öznelik hesaplanmasıyla işlem yükü hafifletilmiş, model daha az karmaşık duruma getirilmiştir. Bu duruma ek olarak tek öznelik kullanılmasıyla boyut indirgeme algoritmalarının da kullanılmasına gerek kalmamıştır. İki sınıflı problemlerde PUK çekirdek fonksiyonunu kullanan SVM sınıflandırıcı algoritmasının başarı oranı %100'dür. Literatürdeki çalışmalarda, 2'den çok öznelik kullanılarak daha düşük doğruluk oranlarına ulaşılmış, fazla öznelik hesaplanması hem zaman hem de karmaşık işlem basamaklarına neden olmuştur. Aynı zamanda, yapılan çalışmaların çoğu tek bir sınıflandırma problemi için test edilmiştir. Çok sayıda öznelik hesaplanması, boyut azaltım algoritmaları ile öznelik vektörlerinin küçültülmesi ve daha zor modellenen sınıflandırıcı algoritmaları kullanılarak 3 ve daha fazla sınıflı problemlerde, işlem yükü ve karmaşıklığı olmaksızın bu çalışmadaki başarı oranlarından daha yüksek oranlara ulaşılmıştır. Bu çalışmada yapılan, epilepsi nöbet tespiti, epilepsi hastası EEG verisi (Nöbet geçirin geçirmesin) ile sağlıklı insan EEG verisi ve diğer ikili sınıflandırmalarda, tek öznelik ile %100 doğruluk oranına ulaşılmıştır. PUK çekirdek fonksiyonunun diğer oluşturulan 9 sınıflandırma probleminde de diğer çekirdek fonksiyonlarına nazaran genelleme yeteneğinin daha başarılı olduğu sonucuna ulaşılmıştır. Bununla birlikte parametre optimizasyonunun da yapılarak çekirdek yapısının, problemlerin doğasına daha uygun olacak şekilde belirlenmesi gerekliliği bu çalışmada ortaya konulmuştur.

#### ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

#### YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

**Erdem TUNCER:** Deneyleri yapmış ve sonuçlarını analiz etmiştir. / Performed the experiments and analyse the results.

**Emine Doğru BOLAT:** Deneyleri yapmış ve sonuçlarını analiz etmiştir. / Performed the experiments and analyse the results.

#### ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur. / There is no conflict of interest in this study.

#### KAYNAKLAR (REFERENCES)

- [1] Chu H., Chung C.K., Jeong W., Cho K.H., "Predicting epileptic seizures from scalp EEG based on attractor state analysis", *Computer Methods and Programs in Biomedicine*, 143: 75-87, (2017).
- [2] Li M., Chen W., Zhang T., "Automatic epilepsy detection using wavelet-based nonlinear analysis and optimized SVM", *Biocybernetics and Biomedical Engineering*, 36: 708-718, (2016).
- [3] Wang G., Deng Z., Choi K.Z., "Detection of epilepsy with electroencephalogram using rule-based Classifiers", *Neurocomputing*, 228: 283-290, (2017).
- [4] Li M., Chen W., Zhang T., "Classification of epilepsy EEG signals using DWT based envelope analysis and neural network ensemble", *Biomedical Signal Processing and Control*, 31: 357-365, (2017).
- [5] Yalçın N., Tezel G., Karakuzu C., "Epilepsy diagnosis using artificial neural network learned by PSO", *Turkish Journal of Electrical Engineering & Computer Sciences*, 23: 421-432, (2015).
- [6] Yuan Q., Zhou W., Liu Y., Wang J., "Epileptic seizure detection with linear and nonlinear features", *Epilepsy & Behavior*, 24: 415-421, (2012).
- [7] Fergus P., Hussain A., Hignett D., Al-Jumeily D., Abdel-Aziz K., Hamdan H., "A machine learning system for automated whole-brain seizure detection", *Applied Computing and Informatics*, 12: 70-89, (2016).
- [8] Tzimirta K.D., Astrakas L.G., Tsipouras M.G., Giannakeas N., Tzallas A.T., "Wavelet based classification of epileptic seizures in EEG signals", *IEEE 30th International Symposium on Computer-Based Medical Systems*, 35-39, (2017).
- [9] Qin Y-M., Han C-X., Che Y-Q., Li H-Y., "Efficient Epileptic Seizure Detection Based on Electroencephalography Signal", *Proceedings of the 36th Chinese Control Conference*, 5324-5327, (2017).
- [10] Sharmila A., Mahalakshmi P., "Wavelet-based feature extraction for classification of epileptic seizure EEG signal", *Journal of Medical Engineering & Technology*, 41(8): 670-680, (2017).
- [11] Cilasun M.H., Yalçın H., "A deep learning approach to eeg based epilepsy seizure determination", *Signal Processing And Communication Application Conference*, (2016).
- [12] Dash D., "Advanced Signal Processing Techniques to Study Normal and Epileptic EEG", *Computational Engineering Finance and Science*, (2014).
- [13] Yavuz E., Kasapbaşı M.C., Eyüpoğlu C., Yazıcı R., "An epileptic seizure detection system based on cepstral analysis and generalized regression neural network", *Biocybernetics and Biomedical Engineering*, (2017).
- [14] Subaşı A., "EEG signal classification using wavelet feature extraction and a mixture of expert model", *Expert Systems with Applications*, 32: 1084-1093, (2007).
- [15] Güler İ., Übeyli E.D., "Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients", *Journal of Neuroscience Methods*, 148: 113-121, (2005).
- [16] Tzallas T.A., Tsipouras M.G., Fotiadis D.I., "Epileptic Seizure Detection in EEGs Using Time-Frequency Analysis", *IEEE Transactions on Information Technology in Biomedicine*, 13(5): 703-710, (2009).
- [17] Stanimirova I., Ustun B., Cajka T., Ridelova K., Hajslova J., Buydens L.M.C., Walczak B., "Tracing the geographical origin of honeys based on volatile compounds profiles assessment using pattern recognition techniques", *Food Chemistry*, 171-176, (2010).

- [18] Üstün B., Melssen W.J., “Buydens L.M.C., Facilitating the application of Support Vector Regression by using a universal Pearson VII function based kernel”, *Chemometrics and Intelligent Laboratory Systems*, 29-40, (2006).
- [19] Zhang G., Huihua G., “Support vector machine with a Pearson VII function kernel for discriminating halophilic and non-halophilic proteins”, *Computational Biology and Chemistry*, 16-22, (2013).
- [20] Amin H.U., Yusoff M.Z., Ahmad R.F., “A novel approach based on wavelet analysis and arithmetic coding for automated detection and diagnosis of epileptic seizure in EEG signals using machine learning techniques”, *Biomedical Signal Processing and Control*, 56: 1-10, (2020).
- [21] Zhang T., Chen W., Li M., “Generalized Stockwell transform and SVD-based epileptic seizure detection in EEG using random forest”, *Biocybernetics and Biomedical Engineering*, 38: 519-534, (2018).
- [22] Gupta V., Pachori R.B., “Epileptic seizure identification using entropy of FBSE based EEG rhythms”, *Biomedical Signal Processing and Control*, 53: 1-11, (2019).
- [23] Mahapatra A.G., Horio K., “Classification of ictal and interictal EEG using RMS frequency, dominant frequency, root mean instantaneous frequency square and their parameters ratio”, *Biomedical Signal Processing and Control*, 44: 168–180, (2018).
- [24] Ullah I., Hussain M., Qazi E.H., Aboalsamh H., “An automated system for epilepsy detection using EEG brain signals based on deep learning approach”, *Expert Systems With Applications*, 107: 61–71, (2018).
- [25] Hussein R., Palangi H., Ward R.K., Wang Z.J., “Optimized deep neural network architecture for robust detection of epileptic seizures using EEG signals”, *Clinical Neurophysiology*, 130: 25–37, (2019).
- [26] Raghu S., Sriraam N., Hegde A.S., Kubben P.L., “A novel approach for classification of epileptic seizures using matrix determinant”, *Expert Systems With Applications*, 127: 323–341, (2019).
- [27] Li Y., Cui W.G., Huang H., Guo Y., Li K., Tan T., “Epileptic seizure detection in EEG signals using sparse multiscale radial basis function networks and the Fisher vector approach”, *Knowledge-Based Systems*, 164: 96–106, (2019).
- [28] Ghayab H.R.A., Lia Y., Siuly S., Abdullad S., “A feature extraction technique based on tunable Q- factor wavelet transform for brain signal classification”, *Journal of Neuroscience Methods*, 312: 43–52, (2019).
- [29] Andrzejak R.G., Lehnertz K., Normann F., Rieke C., David P., Elger C.E., “Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state”, *Physical Review E*, 64: 1-8, (2001).
- [30] Tuncer E., Bolat E.D., “EEG Signal based sleep stage classification using discrete wavelet transform, International Conference on Chemistry”, *Biomedical and Environment Engineering*, 57-61, (2014).
- [31] Faust O., Acharya U.R., Adeli H., Adeli A., “Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis”, *Seizure*, 26: 56–64, (2015).
- [32] Martinez-del-Rincon J., Santofimia M.J., Toro X.D., Barba J., Romero F., Navas P., Lopez J.C., “Non-linear classifiers applied to EEG analysis for epilepsy seizure detection”, *Expert Systems with Applications*, 86: 99-112, (2017).
- [33] Subaşı A., Gürsoy M.I., “EEG Signal classification using PCA, ICA, LDA and support vector machines”, *Expert Systems with Applications*, 37: 8659-8666, (2010).
- [34] Abakar K.A., Yu C., “Performance of SVM based on PUK kernel in comparison to SVM based on RBF kernel in prediction of yarn tenacity”, *Indian Journal of Fibre & Textile Research*, 39: 55-59, (2014).
- [35] Kavzoğlu T., Çölkesen İ., “Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi”, *Harita Dergisi*, 144: 73-82, (2010).
- [36] Shanthini D., Shanthi M., Bhuvaneshwari M.C., “Comparative Study of SVM Kernel Functions Based on Polynomial Coefficients and V-Transform Coefficients”, *International Journal of Engineering and Computer Science*, 6: 20765-20769, (2017).
- [37] Zhang G., Ge H., “Support vector machine with a Pearson VII function kernel for discriminating halophilic and non-halophilic proteins”, *Computational Biology and Chemistry*, 46: 16-22, (2013).
- [38] Thara D.K., PremaSudha B.G., Xiong F., “Auto-detection of epileptic seizure events using deep neural network with different feature scaling techniques”, *Pattern Recognition Letters*, 128: 544-550, (2019).