

Destek Vektör Makineleri Algoritması Kullanılarak Epileptik Atakların Belirlenmesi

Detection of Epileptic Seizures with Support Vector Machine Algorithm

Furkan Hasan Sakaci, Emine Cetiner, Suayb Cagri Yener

Department of Electrical and Electronics Engineering,

Sakarya University

Sakarya, Turkey

{furkan.sakaci, emine.cetiner} @ogr.sakarya.edu.tr, syener@sakarya.edu.tr

Özetçe— EEG (Elektroansefalografi) yöntemi ile elde edilen kompleks ve periyodik olmayan işaretler çok sayıda hastalığın tespitinde kullanılmaktadır. Bunlardan biri olan epilepsi, dünya çapında çok sayıda insanı etkileyen, nöbet anlarında hastaya çeşitli şekillerde fiziksel olarak zarar verme riski taşıyan nörolojik bir rahatsızlıktır. EEG sinyallerinin anlık izlenmesi, araç/makine kullanımı gibi anlarda kriz tespiti bildirimini yapılmasını sağlayarak hasta açısından hayatı önem taşımaktadır. Bu çalışmada epileptik atakların tespitine yönelik destek vektör makineleri algoritması temelli bir yaklaşım sunulmuştur. Çalışmada 23 hastanın kriz dışı ve kriz anlarına karşılık gelen EEG veri setleri kullanılmıştır. EEG işaretlerinin işlenmesinde sırasıyla dalgacık dönüşümü, fourier dönüşümü, özellik çıkarımı ve seçilen algoritma karşılık olarak sınıflandırma yapılmıştır. Ortaya konan yöntemle ataklar %97 oranında doğrulukla tespit edilmiştir.

Anahtar Kelimeler — makine öğrenmesi; destek vektör makinesi; EEG; epileptik krizler; dalgacık dönüşümü; Hızlı Fourier Dönüşümü

Abstract— The complex and non-periodic signs obtained by EEG (electroencephalography) are used in the detection of a large number of diseases. Epilepsy, which is one of them, is a neurological disorder that affects a large number of people around the world and has a risk of causing injury of the patient in various ways. Instant monitoring of EEG signals is vital for the patient by providing notification of crisis detection in moments of vehicle / machine use. In this paper, a support vector machine based algorithm is used for the detection of epileptic attacks. In the study, EEG data sets corresponding to 23 non-crisis and crisis moments have been used. During the process of the EEG signals, wavelet transform, fourier transform, feature extraction and classification have been applied, respectively. Based on the implementation steps used and classification method selected the epileptic attacks have been determined with 97% accuracy.

Keywords — machine learning; support vector machine; EEG; epileptic crises; wavelet transform; Fast Fourier Transform

I. GİRİŞ

EEG (Elektroensefalografi) sinyalleri kullanılarak beyin aktiviteleri gözlenmekte ve elde edilen veriler çeşitli hastalıkların tespisinde kullanılmaktadır [1]–[4]. Günümüzde

gelişen nöro-görüntüleme yöntemlerine rağmen EEG sinyalleri epilepsi, bipolar bozukluk, alzaymır ve şizofreni gibi önemli hastalıkların tespisine yönelik süreçlerde önemini ve öncelliğini korumaktadır. Bu hastalıkların tespisi uzmanlık gerektirmekte, beyin dalgalarının incelenerek tespis aşamasında ise işaretler kişiden kişiye farklılık göstermesinden dolayı da yanlış tespis konulmakta ya da tespis için geç kalınabilmektedir. Bu alanda ihtiyaç duyulan ve çalışma yapılan önemli konulardan biri de epilepsi krizlerinin hızlı ve doğru biçimde saptanmasıdır [1], [2], [5], [6].

Epilepsi, sinir hücrelerinde sebepsiz ve anormal elektriksel deşarj durumu oluşması ile kısa bir süre sonra hastanın bilincini kaybetmesidir [1], [7]–[10]. Epilepsi hastaları bu durumu nöbetler şeklinde yaşamakta ve bu nedenle günlük hayatı nöbet sırasında boğulma, trafik kazası geçirmeye gibi yaşamı sonlandıabilecek düzeyde tehlikelerle karşı karşıya kalmaktadırlar [11]. Epilepsi hastalarının nöbet geçirmeden hemen önce uyarılması hayatı önem taşımaktadır. Nöbet geçirmeden önce krizin saptanabilmesi için EEG sinyalinin işlenmesi ve elde edilen işaretin kriz olup olmadığıının sınıflandırması gereklidir. Son yıllarda özellikle makine öğrenmesi kullanılarak bu konuda yapılmış birçok çalışma vardır [12]–[15].

Makine öğrenmesi matematiksel ve istatistiksel yöntemler kullanılarak mevcut verilerden çıkarımlar yapan, bu çıkarımlarla bilinmeyece dair tahminlerde bulunan bir yöntemdir [2], [15], [16]. Epilepsi hastalarının kriz anlarının saptanmasında doğrusal ve doğrusal olmayan SVM (Destek Vektör Makinesi - Support Vector Machine) algoritmaları ile makine eğitmek yüksek oranda başarıyı sağlamaktadır [4]. Bu algoritmaları kullanan çalışmalarından biri Jerald Yoo tarafından yapılan epilepsi hastalarının anlık krizlerinin bir çip ile tespit edilmesidir [7]. Bu çalışmada EEG sinyallerinin her insanda farklılık göstermesinden dolayı filtreleme sonrası spektral dönüşüm metotları kullanılarak frekans uzayına geçilmiş ve eğitim yapılmıştır. Kaleem ve Fiscon ise yaptıkları çalışmalarda filtreleme yerine dalgacık dönüşümü kullanarak epileptik atakların analizini ve sınıflandırmasını yapmıştır [5], [17].

EEG sinyallerinin işlenmesi spektral dönüşümlerinin yanı sıra dalgacık dönüşümü ile de mümkündür. Dalgacık dönüşümü

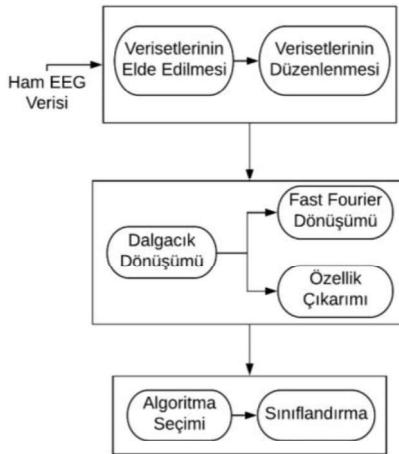
genellikle sabit olmayan sinyalleri önceden belirlenmiş dalgacık ailesine ve ayırma seviyesine göre art arda frekans bantlarına parçalayarak ön işleme için kullanılır [9], [18], [19]. Fourier dönüşümünden farklı olarak, yüksek frekanslar için dar ve düşük frekanslar için geniş pencere boyutlarına sahiptir[20]. Bu şekilde, tüm frekans aralıklarında en uygun zaman-frekans çözümünü elde edilebilir. Bu yöntemi kullanarak literatürde birçok çalışma vardır [6], [8], [9]. Dalgacık dönüşümü epilepsinin yanı sıra farklı biyomedikal hastalıkların tespitinde de kullanılır [18], [19], [21].

Bu çalışmada epileptik atakların tespitine yönelik destek vektör makineleri algoritması temelli bir yaklaşım sunulmuştur. Bu giriş bölümünün ardından, çalışmanın ikinci bölümünde kullanılan veri setleri ve gerçekleştirilecek süreç adımları sunulmuştur. Epilepsi hastalarının araba kullanabilmesi için gömülü sistem üzerinde kriz anlarının tespiti yapılmıştır. Üçüncü ve dördüncü bölümde sırasıyla özellik çıkarımı ve sınıflandırma işlemleri gerçekleştirilmiştir. Çalışma sonuçları bölümyle sonlandırılmıştır.

II. VERİ SETİ VE YÖNTEM

A. İşleme ve Sınıflandırmaya Yönelik Süreç Adımları

EEG ölçümleri genel olarak 23 prob kullanılarak gerçekleştiriliyor ancak epileptik nöbetlerin belirlenmesinde hepsi kullanılmamaktadır. Bu çalışma kapsamında epileptik krizlerin günlük hayatı tespiti için kaskın boyutunun büyük olması hastayı rahatsız edecekinden dolayı sadece 3 prob göz önünde bulundurulmuştur. Bu veri setleriyle epileptik krizlerin tespiti için gerekli adımlar Şekil 1'de verilmiştir.



Şekil 1. Veri toplama, işleme ve sınıflandırmaya yönelik işlem aşamaları

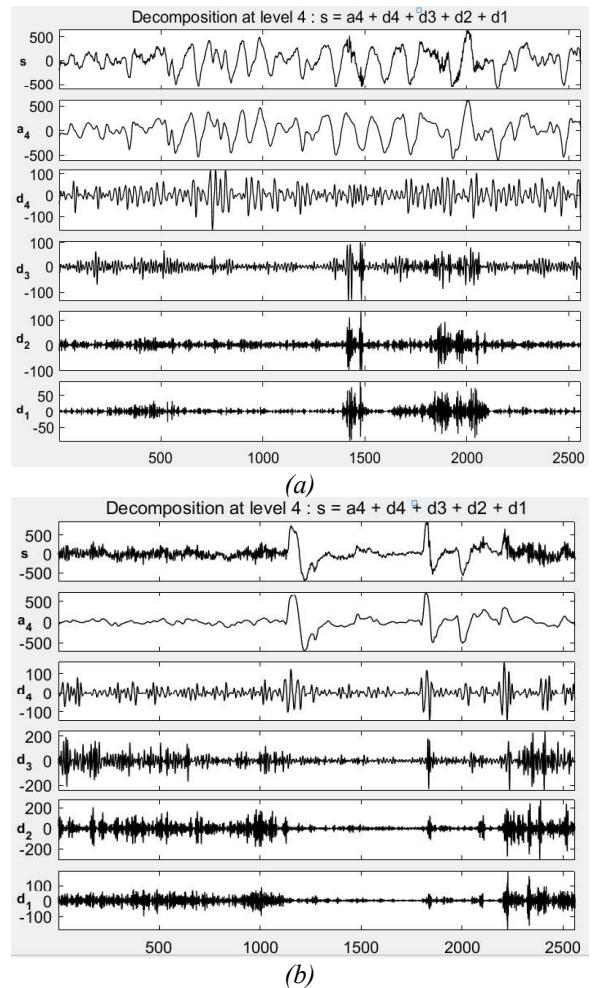
B. Veri Toplama ve Düzenleme

Makineyi düzgün yönetmek için kullanılacak veri setleri son derece önemlidir. Giriş değerleri ve çıkışta istenen değerler doğru şekilde verilmelidir. Bu araştırma da veri setleri olarak 20 yaş altı 23 epilepsi hastası da epileptik nöbetlerin tespiti için MIT tarafından hazırlanan chb mit veri kümeleri kullanılmıştır [22]. Chb mit veri kümeleri toplam 916 saatten oluşmaktadır ve 173 tane epileptik nöbet içermektedir. Burada bulunan veriler 1 saatlik dosyalara ayrılmış halde olup her hasta için nöbetlerin hangi dosyanın kaçinci saniyesinde olduğu belirlidir. Yapılan

çalışmada 10 hasta ele alınmış olup bu hastaların verilerini sınıflandırmak için nöbet ve nöbet geçirilmeyen anlar MATLAB programı kullanılarak 10'ar saniyelik parçalara ayrılmıştır. Bu amaçla 10 saniyelik parçalama işlemleri için örneklem frekansı olan 256Hz'in 10 katı uzunlukta vektörler oluşturulup daha sonra bir matriste birleştirilmiştir. Yapılan işlemlerin ardından oluşan matriste 300'er adet nöbet geçirilen an ile nöbet geçirilmeyen an oluşmuştur.

III. ÖN İŞLEME VE ÖZELLİK ÇIKARIMI

İşaretler sınıflandırılırken birbirlerinden ayırt edilebilmesi ve özelliklerinin çıkarılabilmesi için bazı ön işlemelerden geçmesi gereklidir. EEG sinyallerinde bu ön işlemeler işaretin zaman domeninde durağan olmaması nedeniyle Fourier dönüşümü, filtreleme, spektral yoğunluk çıkarılması ve dalgacık dönüşümü gibi metodlarla yapılmaktadır.

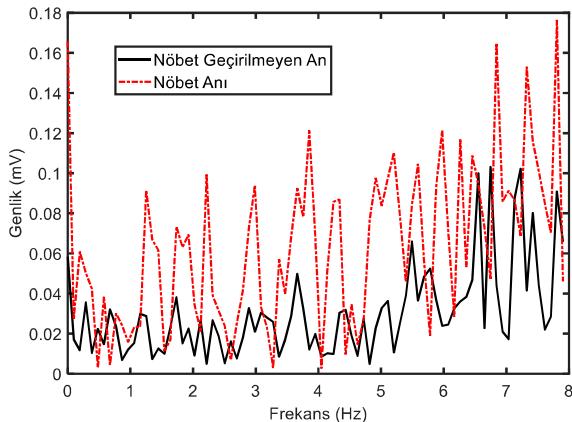


Şekil 2. Veri toplama, işleme ve sınıflandırmaya yönelik işlem aşamaları a) Nöbet geçirilen anın dalgacık analizi b) Nöbet geçirilmeyen anın dalgacık analizi

Bu çalışmada düzenlenmiş veri setleri üzerinde öncelikle MATLAB'in Wavelet Analyzer aracı kullanılarak incelenme yapılmıştır. Yapılan analizler sonucunda Daubechies-4 ailesinin 4. seviye dalgacık dönüşümünde en iyi sonuçların elde edildiği görülmüştür. Örnek olarak nöbet geçirilen (a) ve geçirilmeyen (b)

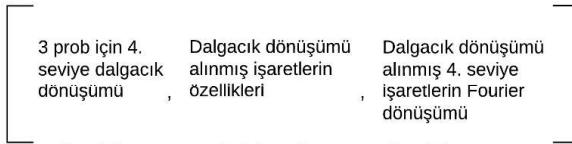
iki anın 4. seviyeye kadar olan dalgacık dönüşümlerinin görüntüleri Şekil 2 ile verilmiştir.

Elde edilen 4. seviye dalgacık dönüşümünün eğitim için yeterince bilgi içermemesinden dolayı 4. Seviye dalgacığın Fourier dönüşümü alınarak frekans uzayına geçirilmiştir. Bu dönüşüm alındıktan sonra elde edilen görüntüler Şekil 3 ile verilmiştir.



Şekil 3. Nöbet dışı ana ve nöbet anına karşılık frekans spektrumu

Ayrıca dalgacık dönüşümü ile oluşturulmuş tüm seviye dalgaların varyansı, standart sapması, ortalaması, maksimum noktası, etkin değeri ve minimum noktası alınıp özellik olarak kullanılmıştır. Sonuç olarak sınıflandırması yapılacak olan vektörün yapısı Şekil 4 ile verilmiştir.



Şekil 4. Sınıflandırması yapılacak olan vektörün yapısı

IV. SINIFLANDIRMA

Epileptik krizlerin otomatik olarak saptanabilmesi için ön işleme ile oluşturulan veriler kullanılarak makinenin eğitilmesi gereklidir. Bu eğitim için MATLAB'in Classification Learner aracı kullanılmıştır. Yapılan sınıflandırma sonucunda farklı yapılar için farklı algoritmalar kullanılarak yapılmış analizler Tablo I'de verilmiştir.

TABLO I. FARKLI ALGORİTMALAR KULLANILARAK ELDE EDİLEN BAŞARIM SEVIYELERİ

Vektör Tipi	Lineer SVM	Kuadratik SVM	Kübik SVM	M. Gaussian SVM	F. Gaussian SVM
4. seviye dalgacık dönüşümü	%56.7	%60.7	%59.1	%57.8	%73.2
Dalgacık dönüşümü ve bu dönüşümden çıkan özellikler	%70.1	%73.8	%78	%76.2	%77.3
Dalgacık dönüşümü, bu dönüşümden çıkan özellikler ve dalgacık dönüşümünün FFT'si	%88.6	%97	%95.2	%84.5	%83.1

Yapılan analizlerde yalnızca SVM algoritmaları göz önünde bulundurulmuştur. Analizlerinden sonucunda ise çalışma kapsamında doğruluğu en yüksek olan kuadratik SVM algoritması kullanılmıştır. Kuadratik SVM algoritması ile oluşturulan modelin karışıklık (confusion) matrisi Tablo II'de verilmiştir. Burada 0 krizin olmadığı 1 ise krizin olduğu durumları ifade etmekte ve kriz anları %98 oranında saptanırken kriz geçirilmeyen anlar %96 oranında doğru saptandığı görülmektedir.

TABLO II. KARŞITLIK MATRİSİ

		Tahmin Edilen Sınıf	
		0	1
Doğru Sınıf	0	288	12
	1	6	294

Seçilen algoritmanın testi için ise eğitim sırasında kullanılmamış 200 nöbet anı ile 200 nöbet geçirilmeyen an sistemin girişi olarak verilmiştir. Burada kullanılan nöbet anlarının %98'i tespit edilirken nöbet geçirilmeyen anların %94'ü tespit edilmiştir. Literatürde yapılmış farklı yöntem ve metodlar kullanılarak elde edilmiş bazı sonuçlar Tablo III'te verilmiştir.

TABLO III. LITERATÜRDEKİ BENZER ÇALIŞMALARIN ÖZELLİKLERİ VE BAŞARIM ORANLARI

Yazar	Kullanılan Metot	Veri Seti	Başarı (%)
Shoeb ve Guttag [15]	SVM	MIT-CHB	96
Faust, Acharya, Adeli ve Adeli [9]	Yapay Sinir Ağları	MIT-CHB	96
Kaleem, Guergachi ve Krishnan [5]	SVM/ k-NN	MIT-CHB	99.4/ 98.6
Güler ve Ülbeyli [4]	SVM	Andrzejak veri seti A-B-C-D-E	99.28
Jerald Yoo [7]	LSVM/ NLSVM	MIT-CHB	84.4/95.7
Abdulhamit Subasi [14]	ME/MLPN N	Andrzejak veri seti A-B-C-D-E	94.5/ 93.2
Yapılan Çalışma	SVM	MIT-CHB	97

V. SONUÇLAR

Bu çalışmada EEG işaretlerinden yararlanarak epilepsi hastalarında epileptik atakların oluşumunu tespit etmeye yönelik destek vektör makineleri algoritması temelli bir yaklaşım sunulmuştur. Çalışmada epilepsi hastalarının kriz ve kriz dışı anlarından elde edilen gerçek EEG sinyalleri kullanılmıştır. Ortaya konan yaklaşımıla ataklar %97 oranında doğrulukla tespit edilmiştir. Ortaya konan yöntem, epilepsi hastalarının EEG verilerinin anlık takibi ile araç kullanımı, yüzme gibi kriz geçirmeleri durumunda, kriz anı bildirimini yaparak kendileri ve çevredekkilerin korunması açısından önemli katkı sunabilecektir. Yazalar gelecek çalışma olarak hasta üzerinde pratik biçimde bulunarak, gerekli tespiti anlık gerçekleştirip önlemlerin alınmasını sağlayabilecek gömülü sistem temelli bir gerçekleme üzerinde çalışmaktadır.

KAYNAKLAR

- [1] K. R. V *et al.*, "Machine learning detects EEG microstate alterations in patients living with temporal lobe epilepsy," *Seizure*, vol. 61, pp. 8–13, 2018.
- [2] Y. Zhang *et al.*, "Multi-kernel extreme learning machine for EEG classification in brain-computer interfaces," *Expert Syst. Appl.*, vol. 96, pp. 302–310, 2018.
- [3] S. Ç. Yener, A. Uygur, and H. H. Kuntman, "Ultra low-voltage ultra low-power memristor based band-pass filter design and its application to EEG signal processing," *Analog Integr. Circuits Signal Process.*, vol. 89, no. 3, pp. 719–726, Dec. 2016.
- [4] I. Guler and E. D. Ubeyli, "Multiclass Support Vector Machines for EEG-Signals Classification," *IEEE Trans. Inf. Technol. Biomed.*, vol. 11, no. 2, pp. 117–126, Mar. 2007.
- [5] M. Kaleem, A. Guergachi, and S. Krishnan, "Patient-specific seizure detection in long-term EEG using wavelet decomposition," *Biomed. Signal Process. Control*, vol. 46, pp. 157–165, Sep. 2018.
- [6] M. Sharma, P. V. Achuth, D. Deb, S. D. Puthankattil, and U. R. Acharya, "An automated diagnosis of depression using three-channel bandwidth-duration localized wavelet filter bank with EEG signals," *Cogn. Syst. Res.*, vol. 52, pp. 508–520, Dec. 2018.
- [7] J. Yoo, "On-chip epilepsy detection: Where machine learning meets patient-specific healthcare," in *2017 International SoC Design Conference (ISOCC)*, 2017, pp. 146–147.
- [8] K. D. Tzimourta, L. G. Astrakas, M. G. Tsipouras, N. Giannakeas, A. T. Tzallas, and S. Konitsiotis, "Wavelet Based Classification of Epileptic Seizures in EEG Signals," in *2017 IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS)*, 2017, pp. 35–39.
- [9] O. Faust, U. R. Acharya, H. Adeli, and A. Adeli, "Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis," *Seizure*, vol. 26, pp. 56–64, Mar. 2015.
- [10] S. Ammar and M. Senouci, "Seizure detection with single-channel EEG using Extreme Learning Machine," in *2016 17th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA)*, 2016, pp. 776–779.
- [11] A. Krumholz, R. S. Fisher, R. P. Lesser, and W. A. Hauser, "Driving and Epilepsy," *JAMA*, vol. 265, no. 5, p. 622, Feb. 1991.
- [12] M. Mohammadi *et al.*, "Data mining EEG signals in depression for their diagnostic value," *BMC Med. Inform. Decis. Mak.*, vol. 15, no. 1, p. 108, Dec. 2015.
- [13] M. Gunay and T. Ensari, "EEG signal analysis of patients with epilepsy disorder using machine learning techniques," in *2018 Electric Electronics, Computer Science, Biomedical Engineering's Meeting (EBBT)*, 2018, pp. 1–4.
- [14] A. Subasi, "EEG signal classification using wavelet feature extraction and a mixture of expert model," *Expert Syst. Appl.*, vol. 32, no. 4, pp. 1084–1093, May 2007.
- [15] A. Shoeb and J. Guttag, "Application of Machine Learning To Epileptic Seizure Detection."
- [16] M. Kang and N. J. Jameson, "Machine Learning: Fundamentals," in *Prognostics and Health Management of Electronics*, Chichester, UK: John Wiley and Sons Ltd, 2018, pp. 85–109.
- [17] G. Fiscon *et al.*, "Combining EEG signal processing with supervised methods for Alzheimer's patients classification," *BMC Med. Inform. Decis. Mak.*, vol. 18, no. 1, p. 35, Dec. 2018.
- [18] R. Singh, R. Mehta, and N. Rajpal, "Efficient wavelet families for ECG classification using neural classifiers," *Procedia Comput. Sci.*, vol. 132, pp. 11–21, Jan. 2018.
- [19] A. Kumar, R. Komaragiri, and M. Kumar, "Design of wavelet transform based electrocardiogram monitoring system," *ISA Trans.*, vol. 80, pp. 381–398, Sep. 2018.
- [20] M. Coşkun, A. Dostanbullu, B. Üniversitesi, M.-M. Fakültesi, and M. Bölümü, "EEG Düşürelerinin FFT ve Dalgaçık Dönüşümü ile Analizi."
- [21] S. Abhishek, S. Veni, and K. A. Narayanankutty, "Biorthogonal wavelet filters for compressed sensing ECG reconstruction," *Biomed. Signal Process. Control*, vol. 47, pp. 183–195, Jan. 2019.
- [22] "PhysioNet." [Online]. Available: <https://physionet.org/>. [Accessed: 28-Mar-2019].