

Classification of Focal and Non-Focal EEG Signals

Bayram KARAMAN^{1*}, Ayşegül GÜVEN¹

¹Erciyes Üniversitesi, Biyomedikal Mühendisliği, Kayseri/TURKEY

Abstract: Epilepsy is a neurophysiological disease that occurs as a result of sudden and uncontrolled discharges in neurons in the brain. Many people around the world suffer from epilepsy. Automatic classification of focal (F) and non-focal (NF) regions over Electroencephalogram (EEG) signals has an important place in the diagnosis of epilepsy disease. In the proposed study, Discrete Wavelet Transform was used for wavelet coefficients of F and NF EEG signals. Four properties were derived from these coefficients as Shannon Entropy, Log Energy Entropy, Arithmetic Mean and Median. These features are classified with Logistic Regression (LR) and Support Vector Machines (SVM) algorithms in WEKA (wikato environment for information analysis) program. As a result of these classifications, LR and SVM classification accuracy was obtained as 81% and 83%, respectively.

Keywords: Epilepsy, Electroencephalogram, Logistic Regression, Support Vector Machines

Fokal ve Fokal Olmayan EEG Sinyallerinin Sınıflandırılması

Özet: Epilepsi beyinde bulunan nöronlarda ani ve kontrolsüz boşalmalar sonucu oluşan nörofizyolojik bir hastalıktır. Dünya üzerinde birçok insan epilepsi hastalığından mustarıptır. Fokal (F) ve Fokal olmayan (NF) bölgelerin Elektroensefalogram (EEG) sinyalleri üzerinden otomatik olarak sınıflandırılması epilepsi hastalığının teşhisinde önemli bir yere sahiptir. Önerilen çalışmada F ve NF EEG sinyallerinin dalgacık katsayıları için Ayrık Dalgacık Dönüşümü kullanılmıştır. Bu katsayılardan Shannon Entropi, Log Enerji Entropi, Aritmetik Ortalama ve Medyan olarak dört özellik çıkarılmıştır. Bu özellikler WEKA (bilgi analizi için wikato ortamı) programında yer alan Lojistik Regresyon (LR) ve Destek Vektör Makineleri (SVM) algoritmaları ile sınıflandırılmıştır. Yapılan bu sınıflandırmalar sonucunda LR ve SVM sırasıyla %81 ve %83 sınıflandırma doğruluğu elde edilmiştir.

Anahtar Kelimeler: Epilepsi, Elektroensefalogram, Lojistik Regresyon, Destek Vektör Makineleri

Reference to this paper should be made as follows:

B. Karaman, A. Güven, 'Classification of Focal and Non-Focal EEG Signals', Elec Lett Sci Eng , vol. 17(1) , (2021), 20-29.

1. Giriş

Epilepsi, insan beyninde meydana gelen anormal değişimlerden dolayı ortaya çıkan ve hastanın yaşam kalitesini etkileyen nörolojik bir hastalıktır [1]. Bu hastalık çocuklarda, gençlerde ve yaşlılarda görülebilir ve hastalığa sahip olan bireylerin olmayanlara göre erken ölme ihtimali daha yüksektir [2].

Epilepsinin teşhisi; Pozitron Emisyon Tomografisi (PET) [3], Tek Foton Emisyon Bilgisayarlı Tomografi (SPECT) [4], Manyetik Rezonans Görüntüleme (MRI) [5] ve Elektroensefalogram (EEG) gibi yöntemler kullanılarak yapılmaktadır. Bunlar arasında en yaygın kullanılan yöntem EEG sinyalleri kullanılarak epilepsi teşhisi ve klinik olarak analizidir. EEG özelliklerinin kantitatif analizi ve düşük maliyeti sebebiyle tercih edilmektedir [6].

EEG, beynin elektriksel aktivitesinin sonucunda oluşan sinyallerdir [7]. Epilepsi nöbetleri sırasında meydana gelen beyindeki değişimlerin yerlerini tespit etmek için Fokal (F) ve Fokal

* Corresponding author; baryamkaraman103@gmail.com

olmayan (NF) EEG sinyalleri kullanılır. F EEG sinyali, ilk nöbet değişiminin olduğu ve kaydedildiği beyin bölgesine ait sinyaldir. NF EEG sinyali ise, nöbetin başlangıcında yer almayan beyin bölgesinden kaydedilir [8]. Kafa derisine yerleştirilen elektrotlar yardımıyla EEG sinyalleri kaydedilerek epilepsi hastalığının tedavisinde kullanılabilir. EEG kayıtları keskin dalgalar veya sivri uçlarda epileptik olan bölgenin belirlenebilmesi için önemli bilgiler yer almaktadır [9]. EEG kayıtları kullanım kolaylığı, noninvaziv ve düşük maliyetinden dolayı tercih edilmektedir [10].

F ve NF EEG sinyallerinin arasındaki farkı göz ile ayırt etmek zor, zaman alıcı olmasının yanı sıra doktora göre değişebilir. Literatürde bu sinyallerin sınıflandırması ile ilgili çeşitli çalışmalar bulunmaktadır [11-14]. Bu çalışmalara bakıldığında; Bhattacharyya ve ark. tarafından Ampirik Dalgacık Dönüşümü kullanılmıştır. F ve NF EEG sinyallerinin farklı ritimlere ayrıştırılması yapılmıştır. Bu ritimlerden faz alanında iki boyutlu projeksiyonlar elde edilmiştir. Çalışmada F ve NF EEG sinyallerini sınıflandırmak için En Küçük Kareler Destek Vektör Makinesi yöntemi kullanılmıştır. Yapılan çalışmada veri setinde yer alan 50 ve 750 F-NF EEG sinyalleri kullanılmıştır. F ve NF EEG sinyallerinin sınıflandırması sonucunda 50 ve 750 veri seti için sırasıyla %90 ve %82.53 doğruluk sağlanmıştır [11].

Bir başka çalışma da Ayrık Fourier Dönüşümü tekniği kullanılarak F ve NF EEG sinyallerinin delta, teta, alfa, beta ve gama ritimleri elde edilmiştir. En Küçük Kareler Destek Vektör Makinesi bu sinyalleri sınıflandırmada kullanılmıştır. Sınıflandırma için F ve NF EEG sinyalleri için hem ellışer ve hem de iki yüz ellışer veri kullanılmış, sınıflandırma sonucunda sırasıyla %89.7 ve % 89.52 doğruluk elde edilmiştir [12].

Prasanna ve ark. tarafından yapılan çalışmada ise Yerel İkili Örüntü (LBP) kullanılarak öznelik çıkarımı yapılmıştır. Bu öznelikler Yapay Sinir Ağları (YSA) algoritması ile sınıflandırılmıştır. Yapılan çalışmada Bern-Barcelona veri tabanından alınan 3750 çift F ve NF EEG sinyali kullanılmıştır. Bu sinyallerin YSA ile sınıflandırması sonucunda doğruluk oranı %93.21 olarak hesaplanmıştır [13].

Yapılan diğer bir çalışmada ise F ve NF EEG sinyallerine Ampirik Mod Ayrıştırma ve Ayrık Dalgacık Dönüşümü yöntemi uygulanmıştır. Bu yöntemlerden üç farklı entropi için özellik çıkarımı için yapılmıştır. F ve NF EEG sinyallerini sınıflandırmak için K-En Yakın Komşu (KNN) yöntemi kullanılmıştır. Doğruluk oranı %89.4 olarak elde edilmiştir. [14].


Yapılan bu çalışmanın temel amacı uzmanlar tarafından ayırt edilmesi zor olan F ve NF EEG sinyallerini daha basit olarak analiz edilmesi ve daha doğru bir şekilde ayırt edilmesini sağlamak için farklı önışleme, özellik çıkarımı ve sınıflandırma yöntemlerini uygulamaktır. Bu yöntemlerin uygulanmasıyla çalışmada etkili ve yüksek sınıflandırma doğruluğu amaçlanmıştır. Ayrıca bu çalışma literatürde yer alan diğer ön işleme, özellik çıkarma ve sınıflandırıcı yöntemleriyle karşılaştırılmıştır.

2. Materyal ve yöntem

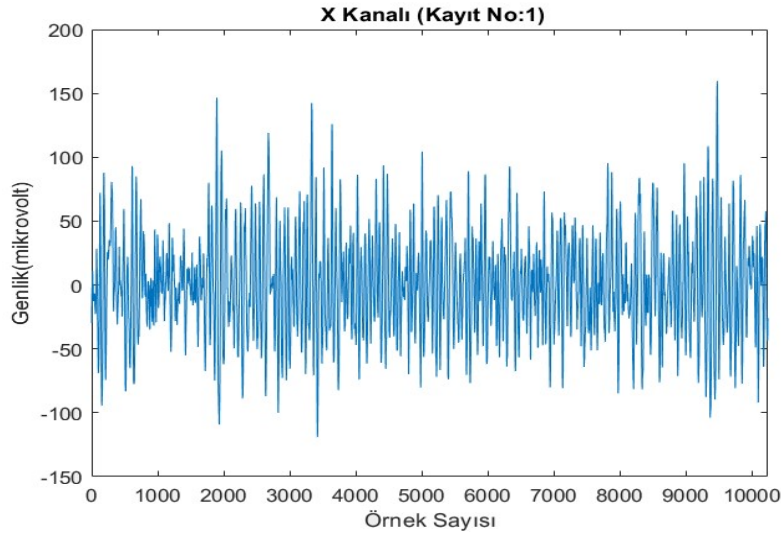
2.1 Veri seti

Bu çalışmada kullanılan veri seti Bern Üniversitesi Nöroloji Bölümünde 5 epilepsi hastasından kaydı alınmıştır [8]. Bu veri setinde örnekleme oranı 512 Hz olarak belirlenip ve toplamda 3750 F ve 3750 NF EEG sinyali bulunmaktadır. Her sinyal 20 saniye boyunca alınmış 10240 örnek boyutundan oluşmaktadır. Veri kümesi X ve Y olarak iki kanallı EEG sinyallerden

oluşmaktadır [8]. Yapılan çalışmada veri setinden seçilen 50 F ve 50 NF EEG sinyalleri kullanılmıştır. Şekil 1 ve Şekil 2. de sırasıyla F ve NF EEG sinyal örneği gösterilmiştir.



Şekil 1. F EEG sinyali örneği



Şekil 2. NF EEG sinyali örneği

2.2 Ön işleme

Bu çalışmada, Ayırık Dalgacık Dönüşümü kullanılarak EEG işaretlerine ön işleme uygulanmıştır.

2.2.1 Ayırık Dalgacık Dönüşümü (ADD)

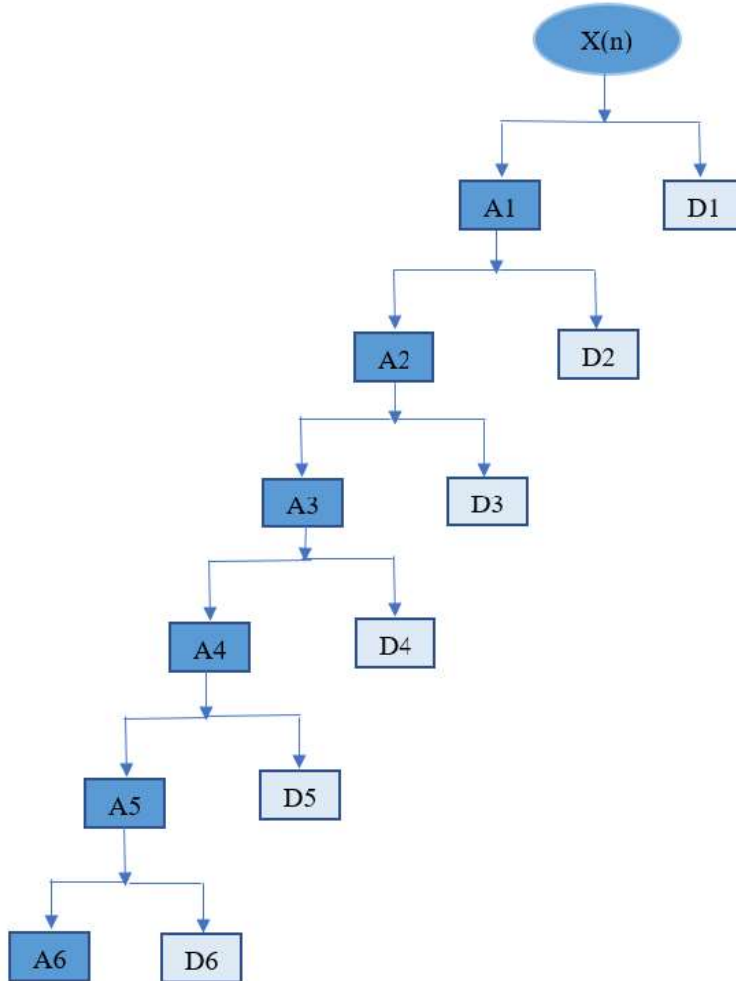
EEG sinyalleri durağan olmayan sinyallerdir. Bu sinyallerden zaman ve frekans açısından en iyi çözünürlüğü elde etmek için ADD yöntemi kullanılmaktadır. ADD yönteminde yüksek frekanslı bileşenler için küçük boyutlu ve düşük frekanslı bileşenlerde ise büyük boyutlu pencere kullanılır [15] .

ADD' nin en genel formülü Denklem (1)' de gösterilmiştir.

$$w(j, k) = \sum_j \sum_k x(n) 2^{-\frac{j}{2}} \Psi(2^{-j}n - k) \quad (1)$$

Bu denklemde $x(n)$ sinyalin kendisi ve Ψ ise ana dalgacıktır. Bu çalışmada F ve NF EEG sinyallerine Daubechies-6 filtresi uygulanmış ve Şekil 3'te görüldüğü gibi 6.dereceden dalgacık ağacı kullanılmıştır.

Çalışmada kullanılan EEG sinyallerinin örnekleme frekansı 512 Hz olması nedeniyle, ayrıştırılan D1 (256-512 Hz) ve D2 (128-256 Hz) detay katsayılarının frekansı yüksek olduğu için gürültü olarak kabul edilmiş ve çalışmaya dahil edilmemiştir. D3 (64-128 Hz) detay katsayısı ise yüksek frekans aralığına sahip olduğu için çalışmada kullanılmamıştır. Özellikleri oluşturmak için düşük frekans aralığına sahip olan D4 (32-64 Hz), D5 (16-32 Hz), D6 (8-16 Hz) detay katsayıları ve A6 (0-8 Hz) yaklaşım katsayısı kullanılmıştır.



Şekil 3. 6.dereceden Dalgacık Ağacı

2.3 Özellik Çıkarma

Özellik çıkarma işlemleri, yapay zeka yöntemlerinin başarımı için önemli bir adımdır. EEG sinyali gibi karmaşık verilerden veriyi tanımlayan özelliklerin çıkarılması verinin tamamının kullanıldığı çalışmalara göre yüksek başarımlı göstermektedir ve oluşturulan sistemin daha basit olmasını sağlamaktadır. Bu sebeple F ve NF EEG sinyallerini tanımlayan özellikler epilepsi sınıflandırmasında kullanılan önemli kriterlerden birisidir. Yapılan çalışmada her bir F ve NF EEG sinyallerinin özellik çıkarması için Shannon entropisi (SE), Log Enerji entropisi (LogEn), Aritmetik Ortalama ve Medyan olmak üzere toplam dört adet yöntem kullanılmıştır.

2.3.1. Shannon Entropisi (SE)

Shannon entropisi, EEG sinyallerinin analizinde sıklıkla kullanılan entropi çeşitlerinden birisidir. Bu entropi yönteminde işaretlerin belirsizlikleri ve artı kalan bilgiler entropi ile ölçülür. Denklem 2' deki formülle ifade edilir [16].

$$E(s) = - \sum_i^n s_i^2 \log_2(s_i^2) \quad (2)$$

Bu denklemde, s işaret, s_i işaretin i . katsayısını ve E sinyalin entropi değerini ifade etmektedir.

2.3.2. Log Enerji Entropisi (LogEn)

Shannon entropisi gibi Log Enerji entropisi de sinyallerin analizinde kullanılmaktadır ve Denklem 3' deki formülle ifade edilmektedir [16].

$$H_{LogEn}(x) = - \sum_{i=0}^{n-1} (\log_2(p_i(x)))^2 \quad (3)$$

Bu denklemde x ifadesi sinyali, p_i işaretin i . katsayı değerini ifade etmektedir.

2.3.3. Aritmetik Ortalama (AO)

Bir veri grubundaki tüm elemanlarının toplamının o veri grubundaki eleman sayısına bölünmesi sonucu ortaya çıkan değere aritmetik ortalama denir. Eşitlik 4'te gösterildiği gibi hesaplanmaktadır.

$$\text{Aritmetik ortalama} = \frac{\sum_{j=1}^n y_j}{n} \quad (4)$$

Bu eşitlikte n veri sayısını ve y_j ise veri değerlerini göstermektedir.

2.3.4. Medyan (M)

Medyan (Ortanca Değer), küçükten büyüğe sıralanmış bir veri grubunda tam ortada yer alan değer olarak adlandırılan merkeze yığılma ölçüsüdür.

2.4. Sınıflandırma yöntemi

F ve NF EEG sinyallerinin tespit edilmesinde sınıflandırma önemli bir rol oynamaktadır. Bu sınıflandırmanın sonuçları WEKA (bilgi analizi için wickato ortamı) sürümü 3.8.4 kullanılmasıyla elde edilmiştir. Yapılan çalışmada WEKA programındaki Lojistik Regresyon

ve Destek Vektör Makinesi (SVM) algoritmaları kullanılmıştır. Ayrıca 10 kat çapraz doğrulama ile sınıflandırma işlemleri gerçekleştirilmiştir.

2.4.1 Lojistik Regresyon (LR)

Lojistik Regresyon, bağımlı değişken ile bir veya daha fazla bağımsız değişken arasında sebep sonuç ilişkisini belirlemede kullanılan güçlü bir istatistiksel yöntemdir. Bu yöntemin amacı bağımlı değişken ile bağımsız değişkeni tanımlayarak en uygun fonksiyonu belirlemektir.

Lojistik Regresyon sınıflandırma yaparken bir lojistik fonksiyon kullanır. Lojistik fonksiyon 0 ile 1 arasında değer alabilen sürekli bir fonksiyondur. Bu sürekli fonksiyona ait olan denklem Eşitlik 5.'te gösterilmiştir [17].

$$y(x) = \frac{1}{1+e^{a_0+a_1x_1+a_2x_2+\dots+a_kx_k}} \quad (5)$$

Bu denklemde x giriş verisini a ise parametre vektörünü belirtmektedir.

Bu çalışmada F ve NF EEG sinyallerini sınıflandırmak için kullanılan Lojistik Regresyon yöntemi, matematiksel olarak kullanımı daha kolay fonksiyonlar oluşturabildiği için, parametrelerinin karmaşık yapıya sahip olmadığı için, diğer sınıflandırıcı algoritmalarına göre daha kullanışlı olduğu için tercih edilmiştir.

2.4.2 Destek Vektör Makineleri (DVM)

Vapnik tarafından geliştirilen Destek Vektör Makineleri, verileri sınıflandırmak ve doğrusal olmayan fonksiyonları çözmek için yaygın olarak kullanılan istatistiksel bir algoritmadır. Destek Vektör Makineleri temelde iki sınıfın ayrıştırılmasında kullanılan en uygun düzlemin (hiperdüzlem) bulunmasını sağlar. Hiperdüzlem ile birbirinden ayrılan iki sınıf gruplandırılır. Bu iki sınıf arasında yer alan en uzak düzlem en iyi sınırı oluşturmaktadır. Bu oluşan sınırlar sınıfların en uygun biçimde sınıflandırılmasını sağlamaktadır [18-19]. Destek Vektör Makineleri son yıllarda genellikle yüz tanıma, ses tanıma, yazı tanıma gibi alanlarda kullanılmıştır [20].

DVM yöntemi F ve NF EEG işaretlerinin sınıflandırmasında çeşitli çalışmalarda sıklıkla uygulanmıştır. Bu çalışmalardan birinde Duo Chen ve ark. Bern-Barcelona veri setinde bulunan 3750 çift F ve NF EEG sinyali kullanmışlardır. Bu sinyalleri DVM sınıflandırıcı algoritması ile sınıflandırmışlardır ve %83.0 doğruluk elde etmişlerdir [21]. Başka bir çalışmada ise Tatsunori Itakura ve ark. Bern-Barcelona veri setinde yer alan F ve NF EEG sinyallerini farklı sayılarda veri kümesi olarak kullanmışlardır. Yapılan çalışmada sırasıyla 50, 750 ve 3750 çift F ve NF EEG sinyallerini DVM sınıflandırıcısıyla sınıflandırmışlardır. Bu çalışmanın sonucunda kullanılan sinyaller için sırasıyla doğruluk oranları %81, %83.73 ve %86.89 hesaplamışlardır [22]. Fasil ve ark. tarafından yapılan çalışmada ise 3750 çift F ve NF EEG sinyalleri kullanmışlardır. DVM algoritması ile sınıflandırma işlemini gerçekleştirmişlerdir ve %88.14 doğruluk elde etmişlerdir [23].

3. Sonuçlar ve Tartışma

Bu çalışmada, Bern-Barcelona veri setinden alınan 50 çift F ve NF EEG sinyallerine ayrık dalgacık yöntemi uygulanarak alt frekans basamaklarına ayrıştırılmıştır. Yapılan ön işlemeden sonra yeni verilerden Shannon Entropi, Log Enerji Entropi, Aritmetik Ortalama ve Medyan özellikleri çıkarılmıştır. Tablo 1 de üç F ve üç NF EEG sinyali için çıkarılan özellikler verilmiştir. Çıkarılan özellikler Lojistik Regresyon ve Destek Vektör Makineleri algoritmalarında sınıflandırması yapılmış ve 10 kat çapraz doğrulama uygulanmıştır. Bu sınıflandırma sonucunda LR ve SVM de sırasıyla %83 ve %81 doğruluk elde edilmiştir.

Tablo 1. Çıkarılan özellik değerleri

		SE	LogEn	AO	M
F1	D4	-2.3550	2.4666	-0.0027	6.9317
	D5	-9.5268	3.7911	0.0161	12.5704
	D6	-2.2024	4.4937	0.0031	18.0200
	A6	-5.8172	5.3552	0.2912	27.6690
F2	D4	-2.1549	2.3723	0.000073	6.6780
	D5	-6,3015	3.4411	-0.0076	10.5458
	D6	-1.3924	3.9859	-0.0039	14.6739
	A6	-1.5970	6.2219	0.0583	43.1258
F3	D4	-2.6568	1.8532	0.0011	6.9078
	D5	-1.1454	2.7375	0.0103	12.7317
	D6	-3.7659	4.7231	-0.0573	22.4691
	A6	-2.4277	6.7142	-0.0505	52.3966
NF1	D4	-2.4442	2.5586	0.0022	7.0750
	D5	-3.5229	4.9836	-0.0148	22.2518
	D6	-3.5375	4.6812	0.0305	21.9790
	A6	-6.7488	3.2792	-0.0118	10.7035
NF2	D4	-4.6617	3.0204	0.0028	9.1833
	D5	-1.2743	3.6858	0.0263	13.8906
	D6	-2.7276	4.0091	-0.0540	18.9421
	A6	-1.1566	5.4817	0.1647	36.7978
NF3	D4	-1.4007	2.1096	0.000078	5.6490
	D5	-3.3522	2.9495	-0.0036	8.1405
	D6	-7.4012	3.2807	0.0334	11.1497
	A6	-2.1620	4.4894	0.0162	17.8229

F ve NF EEG sinyallerinin sınıflandırılması için yapılan çalışmalarda ön işleme için Ampirik Dalgacık Dönüşümü, Ayrık Fourier Dönüşümü gibi yöntemler kullanılmıştır. Bu yöntemlerden ritim, entropi vb. özellik çıkarma işlemleri uygulanan çalışmalar yapılmıştır [11-14]. Önerilen bu çalışmada ise F ve NF EEG sinyallerine farklı ön işleme, özellik çıkarma yöntemleri ve sınıflandırıcılar kullanılarak literatürde yer alan doğruluk oranlarına yakın sonuçlar elde edilmiştir. Tablo 2 de [11], [12], [13] referanslar ve bu çalışmada yapılan ön işleme, özellik çıkarma ve sınıflandırma algoritmaları karşılaştırılmıştır. Bundan sonraki çalışmalarda farklı ön işleme uygulaması ve özellik çıkarımları yapılacak olup, Yapay Sinir Ağları yöntemi kullanılması planlanmaktadır.

Tablo 2. Bu çalışmada elde edilen sonuçlar ile literatürde bulunan çalışmaların karşılaştırılması

Referans No	Ön İşleme	Özellik	Sınıflandırıcı	Veri Seti Boyutu	Doğruluk
[11]	Ampirik Dalgacık Dönüşümü	Ritimler	En Küçük Kareler Destek Vektör Makinesi	100	%90.00
				1500	%82.53
[12]	Ayrık Fourier Dönüşümü	Ritimler	En Küçük Kareler Destek Vektör Makinesi	100	%89.70
				500	%89.52
[13]	-----	Yerel İkili Örüntü	Yapay Sinir Ağları	7500	%93.21
Bu Çalışmada Önerilen Yöntem	Ayrık Dalgacık Dönüşümü	SE LogEn AO M	Lojistik Regresyon	100	%81.00
			Destek Vektör Makinesi	100	%83.00

4. Referanslar

- [1] Fisher, RS., Van Emde Boas, W., Blume, W., et al., “Epileptic seizures and epilepsy: definitions proposed by the International League Against Epilepsy (ILAE) and the International Bureau for Epilepsy (IBE).”, *Epilepsia*, 46(4)., 470-2., 2005.
- [2] <http://www.who.int/news-room/fact-sheets/detail/epilepsy>. World Health Organization, World Health Organization, 10.10.2020.
- [3] Savic, I., Thorell, JO., & Roland, P., “[11C] flumazenil positron emission tomography visualizes frontal epileptogenic regions.”, *Epilepsia*, 36(12), 1225-1232, 1995.
- [4] Newton, M.R., Berkovic, S.F., Austin, M.C., Row, C.C., McKay, W. J., & Bladin, P.F., “SPECT in the localisation of extratemporal and temporal seizure foci”, *Journal of Neurology, Neurosurgery & Psychiatry*, 59(1), 26-30, 1995.
- [5] Seeck, M., Lazeyras, F. C., Michel, M., Blanke, O., Gericke, C. A., Ives, J., & Landis, T., “Non-invasive epileptic focus localization using EEG-triggered

- functional MRI and electromagnetic tomography”, *Electroencephalography and clinical Neurophysiology*, 106(6), 508-512, 1998.
- [6] Acharya, U.R., Hagiwara, Y., Despande, S.N., Suren, S., Koh, J.E.W., Oh, S.L., Arunkumar, N., Ciaccio, E.J., Lim, C.M., "Characterization of focal EEG signals: A review", *Future Generation Computur Systems*, 91, 290-299, 2019.
- [7] Sharma, R., Kumar, M., Pachori, R.B., Acharya, U.R., "Decision support system for focal EEG signals using tunable-Q wavelet transform", *Journal of Computational Science*, 20, 52-60, May 2017.
- [8] Andrzejak, R.G., Schindler, K., Rummel, C., "Nonrandomness nonlinear dependence and nonstationarity of electroencephalographic recordings from epilepsy patients", *Physical Review E*, 86, 046206, 2012.
- [9] Kaya, Y., Uyar, M., Tekin, R., Yıldırım, S., "1D-local binary pattern based feature extraction for classification of epileptic EEG signals”, *Applied Mathematics and Computation*, 243, 209-219, 2014.
- [10] Arunkumar, N., Ram Kumar, K., Venkataraman, V., "Entropy features for focal EEG and nonfocal EEG", *J. Comput. Sci*, 27, 440-444, 2018.
- [11] Bhattacharyya, A., Sharma, M., and Bilas, R., "A novel approach for automated detection of focal EEG signals using empirical wavelet transform”, *Neural Comput. Appl.*, 29(8), 47–57, 2018.
- [12] Singh, P., Pachori, R.B., "Classification of focal and nonfocal EEG signals using features derived from Fourier-based rhythms", *Journal of Mechanics in Medicine and Biology*, 17(07), 2017.
- [13] Prasanna, J., Sairamya, N.J., George, S.T., Vinutha, C.R., and Subathra, M.S.P., "Classification of Non-focal and Focal EEG signals using Local Binary Pattern”, *International Conference on Computer Communication and Informatics (ICCCI)*, 1-4, IEEE, 2019.
- [14] Das, A.B., Bhuiyan, M.I.H., "Discrimination and classification of focal and non-focal EEG signals using entropy-based features in the EMD-DWT domain”, *Biomedical Signal Processing Control*, 11-21, 2016.
- [15] Daubechies, I., "The wavelet transform, timefrequency localization and signal analysis”, *IEEE Transactions on Information Theory*, 36(5), 961- 1005, 1990.
- [16] Serap, A., Hamdi, M.S., Sadık, K., "Log energy entropy-based EEG classification with multilayer neural network in seizure”, *Annals of Biomedical Engineering*, 37(12); 2009.
- [17] Behshad, H., Moradi, M.H., and Rostami, R., "Classifying depression patients and normal subjects using machine learning techniques and nonlinear features from EEG signal” *Computer methods and programs in biomedicine*, 109.3, 339-345., 2013.
- [18] Sezer, O.G., Erçil, A., Keskinöz, M., "Destek Vektör Makinesi Kullanarak Bağmsız Bileşen Tabanlı 3B Nesne Tanıma”, 2005.
- [19] Siyah, B. "Destek Vektör Makineleri ve Çok Katmanlı Algılayıcılar ile Göğüs Kanseri Teşhisi”.
- [20] Vapnik, V., "Statistical Learning Theory”, Wiley, New York, 1998.
- [21] Chen, D., Wan, S., and Bao, F.S., "Epileptic Focus Localization Using Discrete Wavelet Transform Based on Interictal Intracranial EEG", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 4320, 1-12, 2016.
- [22] Itakura, T., Tanaka, T., A., Dataset, "Epileptic Focus Localization Based on Bivariate Empirical Mode Decomposition and Entropy”, *AsiaPacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC)*, 1426-1429, December 2017.

- [23] Fasil, O.K., Rajesh, R., & Thasleema, T.M., “Influence of differential features in focal and non-focal EEG signal classification”, IEEE Region 10 Humanitarian Technology Conference, 646-649, 2017.