

Epileptik EEG İşaretlerinin Sınıflandırılması İçin Yeni Bir Öznitelik Çıkarım Yöntemi

Yılmaz KAYA¹, Ramazan TEKİN*²

¹Siirt Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 56100, Siirt

²Batman Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 72060, Batman

(Alınış / Received: 17.04.2018, Kabul / Accepted: 31.08.2018, Online Yayınlanma / Published Online: 20.09.2018)

Anahtar Kelimeler

Elektroensefalografi,
Epilepsi,
Motif öznitelikler,
Öznitelik çıkarımı

Özet: Epilepsi en sık karşılaşılan nörolojik hastalıklardan biri olup beyinde bir grup nöronun anormal aktivitesi sonucu oluşmaktadır. Epilepsi genellikle elektroensefalografi (EEG) sinyalleri kullanılarak teşhis edilmektedir. Bu sebeple, EEG işaretlerinden etkin özniteliklerin çıkarılması doğru sınıflandırma için önemli bir basamaktır. Bu çalışmada epileptik EEG işaretlerinden kararlı öznitelikler çıkaracak motif algoritması isimli yeni bir yaklaşım önerilmiştir. Bu yaklaşım, EEG işaretlerinde belirli büyüklükteki bir pencere içine giren değerlerin birbirleri ile olan büyüklük/küçüklük ilişkisine bağlıdır. Pencere içindeki değerlerin birbirlerine göre oluşturdukları görünüm bir motif olarak ele alınmaktadır. İşaret üzerindeki bu motiflerin frekansları öznitelik vektörü olarak kullanılmıştır. Motif sayısı sinyal üzerinde tanımlanan pencere boyutuna bağlıdır. Motif öznitelikleri elde edildikten sonra sınıflama aşamasında RF, YSA, SVM gibi farklı sınıflandırma algoritmaları kullanılmıştır. Önerilen yöntemin başarısını test etmek için farklı durumlarda (nöbet öncesi, nöbet sonrası, gözler açık ve gözler kapalı vb.) kayıt altına alınmış EEG işaretlerinin birleşimlerinden elde edilen setler kullanılmış ve yüksek sınıflandırma başarıları elde edilmiştir.

A Novel Feature Extraction Method for Classification of Epileptic EEG Signals

Keywords

Electroencephalography,
Epilepsy,
Motif attributes,
Feature extraction

Abstract: Epilepsy is one of the most common neurological diseases and results in abnormal activity of a group of neurons in the brain. Epilepsy is usually diagnosed by using electroencephalography (EEG) signals. For this reason, extracting effective attributes from EEG signals is an important step for correct classification. In this study, a new approach named motif algorithm, which extracts stable features from epileptic EEG signals, has been proposed. The proposed approach is dependent on relational between values in a certain window. The appearance of the values in the window according to each other is treated as a motif. The frequencies of these motifs on the signal are used as the features vector. The number of motifs depends on the window size defined on the signal. Different classification algorithms such as RF, ANN, SVM were used in the classification stage after the motif attributes were obtained. In order to test the success of the proposed method, sets obtained from combinations of recorded EEG signals in different situations (pre-seizure, post-seizure, open eyes and closed eyes, etc.) were used and high classification achievements were achieved.

1. Giriş

Epilepsi, beyinde bir grup nöronun anormal patolojik salınım aktivitesi sonucu bilinç kaybı, dengesiz vücut hareketleri, anormal duygusallık veya kas kasılması şeklinde kendini gösteren beynin önemli hastalıklarından biridir [1-3]. Bu hastalığın teşhisinde en yaygın yöntemlerden biri elektroensefalografi (EEG) işaretlerinin analizidir. EEG sinyalleri kafa dersinde belirli noktalara

yerleştirilen elektrotlarla elde edilmektedir. EEG işaretleri sivri uçlu keskin dalgalar gibi epileptik bölgenin belirlenmesi için gerekli önemli bilgiler içermektedir [1]. Bu işaretlerin uzmanlar tarafından manüel değerlendirildiği klasik analiz yöntemlerinin doğruluğunun kesin olmaması ve zaman alması nedeniyle [4-8] son yıllarda bilgisayar destekli yapay zeka ve istatistiksel yöntemler EEG işaretlerinin epilepsi analizinde yaygın bir şekilde kullanıldığı görülmektedir [9-11].


EEG işaretlerin sınıflandırılabilmesi için öncelikle işaretlerin özniteliklerinin elde edilmesi gerekmektedir. Bu öznitelikler ile EEG işaretlerinin karakteristikleri çıkarılarak birbirinden ayırt edilir. Elde edilen öznitelikler farklı sınıflar arasında ayrışmayı en iyi sağlayacak öznitelikler olmalıdır. Bu sebeple örüntü tanımada öznitelik çıkarımı önemli bir basamaktır. Çünkü sınıflandırma başarısı iyi seçilmiş özniteliklere bağlıdır [11–15]. Bu çalışmada epileptik EEG işaretlerinden öznitelik çıkarımı için motif desenler isimli yeni istatistiksel bir yöntem önerilmiştir.

Motif desenler yöntemi, EEG işaretlerinin bir pencere içindeki değerlerinin birbirlerine göre oluşturdukları büyüklük/küçüklük durumlara göre motif olarak isimlendirilen formlarının frekanslarına bağlıdır. Örneğin pencere boyutu (PB) 4 seçildiğinde pencere içinde 4 adet değer (P1,P2,P3,P4) olacaktır. Bu değerlerin büyüklük sıralamalarına bağlı olarak farklı motifler elde edilecektir. Buna göre pencerenin büyüklük değerlerine bağlı olarak PB! farklı motif söz konusudur. Örneğin PB=4 olması durumunda $4!=24$, PB=5 olması durumunda $5!=120$ farklı motif bulunmaktadır. PB değerine bağlı olarak farklı ölçeklerde motifler elde edilebilmesi motif desenler yöntemin en önemli avantajları arasındadır. Diğer bir avantajı kolay uygulanabilir ve hızlı olmasıdır. Bu yöntemle göre elde edilen EEG işaretlerindeki motif frekanslar öznitelik vektörü olarak kullanılmaktadır. Daha sonra bu motif öznitelikleri kullanılarak farklı sınıflandırma yöntemleri ile EEG işaretleri sınıflandırılmıştır. Önerilen metodu test etmek için Bonn Üniversitesi Etiyoloji Bölümü'nden elde edilen epileptik EEG işaretleri kullanılmıştır. Elde edilen sonuçlara göre önerilen Motif desenler yönteminin epileptik EEG işaretlerinin sınıflandırılması için kararlı öznitelikler sağladığı görülmüştür.

2. Materyal ve Metot

Bu çalışmada Bonn Üniversitesi Epileptoloji bölümünce oluşturulmuş EEG sinyalleri kullanılmıştır [16, 17]. Bu veri kümesi her biri 23,6 saniye süreli ve 173,61 Hz örnekleme frekansına (12 bit çözünürlüklü) sahip 100 adet tek kanal EEG parçasını içeren 5 farklı kümeden (A-E) oluşmaktadır. Bu veri

kümelerinin özellikleri Tablo 1'de ve her bir kümeye ait bir örnek işaret te Şekil 1'de gösterilmiştir [1].



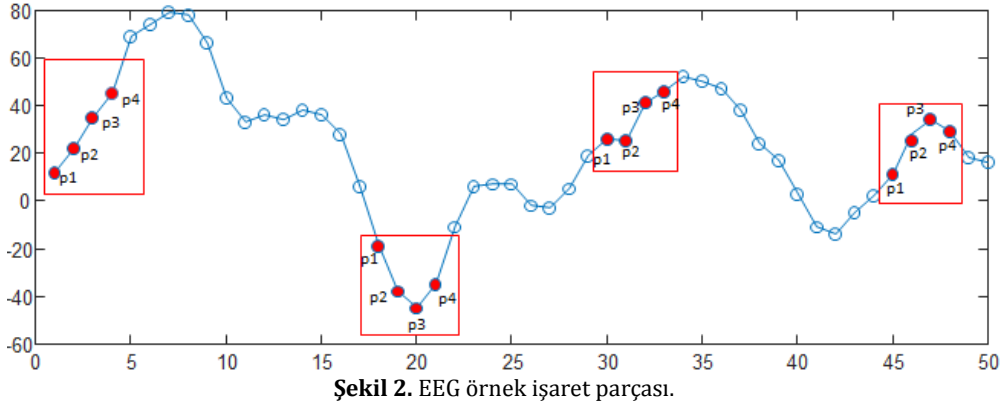
Şekil 1. A, B, C, D ve E kümelerine ait örnek EEG işaretleri.

2.1. Motif örüntüler

Bu çalışmada epileptik EEG işaretlerden etkin özelliklerin elde edilmesi için yeni bir yöntem önerilmiştir. Önerilen yöntem ile EEG işaretleri üzerindeki motif denilen yapılar elde edilerek farklı EEG işaretlerinin sınıflandırılmasında kullanılmıştır. Motif örüntüler, belirli bir uzunluktaki pencere ile pencerelenen EEG değerlerinin birbirlerine bağlı oluşturdukları büyüklük/küçüklük ilişkilerine bağımlı yapılardır. Motifler sinyal üzerindeki alınan komşu sayısına, diğer bir deyişle pencere boyutuna (PB) bağlıdır. PB=5 alındığında $5!=120$, PB=7 alındığında ise $7!=5040$ farklı motif söz konusudur. Motif örüntülerin elde edilme yöntemi Şekil 2'de bir işaret örneği üzerinde anlatılmıştır. Aşağıdaki işaret için pencere uzunluğu PB=4 olarak alınmıştır. Bu durumda her pencere içinde 4 adet işaret değeri (P1, P2, P3 ve P4) bulunur. Bu değerlerin birbirlerine göre büyüklükleri bir motif olarak değerlendirilmekte ve toplam PB! yani $4!=24$ farklı motif söz konusudur. Motifler örüntüler, pencerenin işaretler üzerinde nokta nokta ilerletilmesi ile elde edilmektedir.

Tablo 1. EEG veri kümesinin özellikleri.


Veri Kümesi	Gönüllü Türü	Ölçüm özelliği
A	Sağlıklı	5 sağlıklı gönüllüden gözler açıkken kaydedilmiş yüzey EEG kayıtları.
B	Sağlıklı	5 sağlıklı gönüllüden gözler kapalıyken kaydedilmiş yüzey EEG kayıtları.
C	Hasta	5 epilepsi hastasından nöbet öncesinde, hipokampal oluşumlu karşı yarım küreden intrakraniyal olarak kaydedilmiştir.
D	Hasta	5 epilepsi hastasından nöbet öncesinde, epileptojenik bölgeden intrakraniyal olarak kaydedilmiştir.
E	Hasta	5 epilepsi hastasından nöbet sırasında intrakraniyal olarak kaydedilmiştir.



Şekil 2. EEG örnek işaret parçası.

Şekil 2'de örnek 4 pencerenin durumu görülmektedir. Birinci penceredeki değerlerin oluşturduğu motif ($P4 > P3 > P2 > P1$), ikinci penceredeki motif ($P1 > P4 > P2 > P3$), üçüncü penceredeki motif ($P4 > P3 > P1 > P2$) ve son pencere ise ($P3 > P4 > P2 > P1$) şeklindedir. Bu motifler Şekil 3'te verilmiştir.

Daha öncede ifade edildiği gibi motif sayıları ve formları PB değerine bağlıdır. Yukarıda $PB = 4$ olarak alındığından 24 adet motif örüntü bulunmaktadır. İşaret üzerindeki her motif örüntü frekansı bir öznitelik olarak kabul edilmektedir. Pencere uzunluğunun $PB = 4$ olması durumunda olası tüm motifler Şekil 4'te verilmiştir.




Şekil 3. Örnek işaret üzerindeki motifler.

Şekil 4. $PB = 4$ olması durumunda oluşan motifler.

2.2. EEG sinyal sınıflandırma aşamaları

Bu çalışmada literatürde önerilen özellik çıkarma yöntemlerinden tümüyle farklı yeni bir yaklaşım önerilmiştir. Önerilen bu yöntemde, EEG işaretinde pencereleştirilmiş PB adet nokta grubunun birbirleri arasındaki büyüklük/küçüklük ilişkisi sonucu elde edilen örüntüleri kullanan istatistiksel bir

yaklaşımdır. Önerilen yaklaşımla EEG işaretlerinin sınıflandırılmasına ait blok diyagram Şekil 5'te verilmiştir.



Şekil 5. Önerilen yöntemle EEG işaretlerinin sınıflandırılmasına ait blok diyagram.

Blok 1: Önerilen yöntemde ham epileptik EEG sinyalleri girdi olarak kullanılmaktadır.

Blok 2: Motif örüntülerin elde edildiği bloktur. EEG işareti üzerindeki her motif sayısı bulunur. Bu motifler sınıflandırma metotlarına verilen öznitelikler olarak kabul edilir.

Blok 3: Bu aşamada elde edilmiş olan motif örüntüler kullanılarak karar destek vektörleri (SVM), rastgele ağaçlar (RF) ve fonksiyonel ağaçlar (FT) gibi karar ağaçları, yapay sinir ağları (YSA), k en yakın komşu (KNN), A1DE (Aggregating One-Dependence Estimators) ve A2DE (Aggregating Two-Dependence Estimators) gibi farklı makine öğrenmesi yöntemleri ile sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma aracı olarak ücretsiz ve açık kaynak kodlu bir veri madenciliği aracı olan Weka programı kullanılmıştır. Sınıflandırma işlemleri 10 kat çapraz geçerlilik yaklaşımına göre gerçekleştirilmiştir.

2.3. Başarı ölçütleri

Önerilen yöntemin performansını göstermek üzere doğruluk, hata oranı, kesinlik ve duyarlılık kullanılmıştır. Bu başarı ölçütleri aşağıdaki gibi hesaplanmaktadır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$\text{Hata Oranı} = \frac{FP + FN}{TP + TN + FP + FN} \quad (2)$$

$$\text{Kesinlik} = \frac{TN}{(TN + FP)} \quad (3)$$

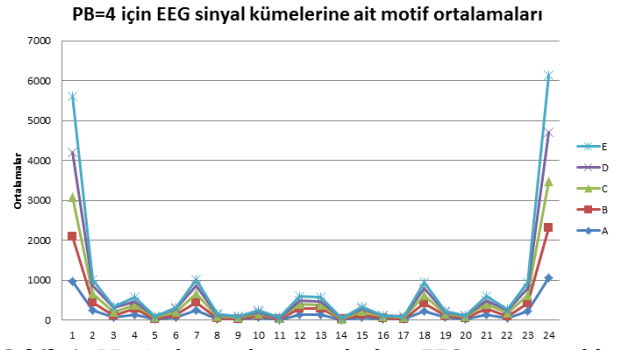
$$\text{Duyarlılık} = \text{TP}/(\text{TP} + \text{FN}) \quad (4)$$

Bu denklemlerde T, F, P ve N sırasıyla doğruyu, yanlış, pozitif ve negatif ifade etmektedir. Örneğin, TP doğru sınıflandırılan pozitif örnek sayısını; FN ise yanlış sınıflandırılan negatif örnek sayısını göstermektedir. Doğruluk, başarının tespiti için kullanılan en popüler ve basit yöntemdir ve bu oran doğru sınıflandırılmış (TP+TN) örnek sayısının, toplam örnek sayısına (TP+TN+FP+FN) oranı olarak tanımlanmaktadır [18]. Hata oranı ise yanlış sınıflandırılmış örnek sayısının, toplam örnek sayısına oranı olarak ifade edilmektedir [19]. Kesinlik, negatif olarak tahmin edilen doğru örnek sayısının (TN), negatif olarak tahmin edilmiş tüm örnek sayısına oranı (TN+FP), duyarlılık ise doğru sınıflandırılmış pozitif örnek sayısının (TP) toplam pozitif örnek sayısına oranı (TP+FN) göstermektedir [20].

3. Bulgular

Bu çalışmada epileptik EEG işaretlerin sınıflandırılması için yeni bir öznitelik çıkarım yaklaşımı önerilmiştir. Önerilen Motif örüntüler yöntemi, işaretin pencerelenmiş değerlerinin komşuları ile karşılaştırması sonucu elde edilen istatistiksel bilgilere dayandığından bu işarettaki en küçük değişime karşı yüksek hassasiyete sahip olup ayrıca hesaplama kolaylığı bulunmaktadır. Çalışmada 5 (A,B,C,D,E) farklı EEG veri kümesi kullanıldı. PB=4 (24 farklı motif) olması durumunda her EEG kümesinden elde edilen motiflere ait frekanslar ve standart sapma (SS) değerleri Tablo 2'de verilmiştir. 5 EEG veri kümesi için en çok elde edilen motifler M1 ve M24 motiflerdir. Elde edilen motif frekans dağılımları Şekil 6'da görülebilir. Motif frekans

ortalama değerlerinin EEG veri kümelerine göre farklı olduğu görülmektedir.



Şekil 6. PB=4 olması durumunda her EEG seti için elde edilen motif ortalamalarının dağılımları.

Şekil 6'de görüldüğü gibi EEG işaretlerin frekans ortalama dağılımlarından bu işaretlerin birbirinden ayrışacağı görülebilir. EEG işaretleri pencere uzunluğu PB=4 için elde edilen 24 adet motifin öznitelik frekans dağılımları kullanılarak farklı sınıflandırma metotları ile sınıflandırılmıştır. Elde edilen başarı oranları Tablo 3'te verilmiştir.

Tablo 3'e bakıldığında A-E EEG setleri için %100 başarı oranı elde edilmiştir. A2DE, RF, FT metotları ile A-E işaretleri için en yüksek başarı oranı elde edilmiştir. A-D seti için en yüksek başarı oranı %98 olarak KNN, FT ve YSA ile elde edilmiştir. C-E setine bakıldığında ise en yüksek başarı oranı %98 olarak FT ile gözlenmiştir. Son olarak D-E seti için en yüksek başarı %95,5 olarak A2DE ve SVM sınıflandırma metodu ile elde edilmiştir. Genel olarak EEG işaretlerin sınıflandırılmasında FT metodu başarılı olduğu gözlenmiştir.

Tablo 2. EEG veri kümeleri için Motif örüntülere ait ortalamalar ve SS değerleri.

Motifler	Veri Kümesi A		Veri Kümesi B		Veri Kümesi C		Veri Kümesi D		Veri Kümesi E	
	Ort.	SS	Ort.	SS	Ort.	SS	Ort.	SS	Ort.	SS
M1	964,03	105,34	1124,18	153,69	990,99	160,16	1118,75	183,53	1406,89	310,64
M2	239,18	20,19	209,75	35,54	212,12	22,82	201,48	25,54	156,37	28,24
M3	65,47	23,67	36,55	21,53	107,18	31,74	97,61	27,81	23,15	18,71
M4	141,22	22,73	135,8	18,36	99,04	17,74	91,85	14,06	106,98	22,26
M5	20,67	10,63	12,02	8,93	29,19	11,80	26,03	10,48	5,56	5,21
M6	75,14	11,44	57,53	16,29	77,34	13,09	69,98	13,94	35,52	12,11
M7	239,43	19,59	207,51	34,90	214,66	21,83	200,87	26,71	158,89	27,58
M8	30,67	14,39	15,71	11,86	49,48	20,84	43,56	16,67	7,35	8,29
M9	20,58	10,36	11,44	8,38	29,92	11,41	25,16	10,32	6,74	6,37
M10	60,88	12,38	46,66	19,08	49,96	12,11	44,91	11,75	31,31	12,41
M11	12,13	7,58	6,16	4,88	21,48	10,20	16,92	7,68	3,09	4,11
M12	144,6	21,81	138,73	21,03	105,66	16,95	99,47	16,62	109	21,54
M13	142	21,69	138,53	20,43	97	16,04	93,22	16,32	105,53	18,44
M14	10,15	6,16	5,46	4,98	16,98	7,56	13,48	6,92	2,32	3,32
M15	76,97	12,54	56,48	17,27	78,05	13,77	71,22	14,47	39,15	14,06
M16	25,73	10,51	14,66	10,42	39,72	14,67	32,62	10,77	7,32	8,26
M17	21,07	14,63	11,53	10,36	29,4	15,64	22,89	10,40	5,1	6,33
M18	227,26	21,63	199,69	37,51	194,28	28,89	175,15	27,33	147,08	25,55
M19	59,81	14,98	46,08	16,54	49,45	13,99	44,09	10,81	29,98	10,44
M20	25,91	10,87	13,88	9,49	40,74	15,6	34,5	11,98	7,21	7,051
M21	142,97	19,78	138,94	21,22	105,77	16,34	96,67	16,36	107,02	20,67
M22	53,32	24,02	31,85	20,39	86,44	31,68	70,86	23,43	16,55	15,61
M23	227,23	21,08	200,6	36,66	193,51	30,21	176,85	28,14	145,52	24,83
M24	1067,58	110,74	1234,26	201,66	1175,64	151,60	1225,86	142,2379	1430,37	323,75

Tablo 3. PB=4 için gözlenen başarı oranları.

Veri Kümeleri	A1DE	A2DE	KNN	RF	FT	YSA	SVM
A-E	99	100	98,5	100	100	98,5	98,5
A-D	95	95	98	96,5	98	98	94,5
C-E	96	96	97	97,5	98	97,5	96,5
D-E	95	95,5	93	95	95	95	95,5

Daha öncede ifade edildiği gibi motif desenler yöntemi ile elde edilecek öznitelik vektörünün büyüklüğü pencere uzunluğu PB'ya bağlıdır. PB parametresi önerilen yöntemde esneklik katmaktadır. EEG işaretlerini birbirinden ayırtıracak farklı örüntülerin yakalanması açısından PB önemli bir parametre olmaktadır. PB'nin farklı değerleri için elde edilen motif örüntüler kullanılarak FT sınıflandırma metodu için başarı oranları Tablo 4'te gösterilmiştir.

Tablo 4. Pencere boyutunun başarı oranına etkisi.

PB	#öznitelik	A-E	A-D	C-E	D-E
3	6	99,5	85	98,5	96
4	24	100	98	98	95,5
5	120	99,5	99	98,5	97,5
6	720	100	100	99,5	97,5
7	5040	100	100	98,5	97,5

Tablo 4'e bakıldığında PB'nin başarı oranı üzerinde etkisinin olduğu görülmektedir. EEG işaretlerini ayırtıracak etkili özniteliklerin elde edilmesi için farklı PB'lerin kullanılması gerekmektedir. Ancak pencere boyunda küçük bir artış bile elde edilecek öznitelik sayısını büyük bir oranda artırmaktadır. Dolayısıyla pencere uzunluğu PB'nin artması işlem maliyetini de artırmaktadır. Tablo 4'te görüldüğü gibi PB=6 seçildiğinde öznitelik sayısı 720'e çıkmış ve A-E işaretleri için %100, A-D için %100, C-E işaretleri için %99,5 ve D-E seti için %97,5 başarı oranı gözlenmiştir.

Epileptik nöbetlerin tespiti uzun yıllardır üzerinde çalışılan bir konudur. Yapılan çalışmaların önemli bir kısmı epileptik işaretlerden öznitelik çıkarımı ve bu özniteliklerin kullanılarak sınıflandırma ile ilgili oldukları görülmektedir. Bu yüzden yapılan çalışmalar öznitelik çıkarımı ve sınıflandırma yöntemleri şeklinde iki grupta değerlendirilmektedir. Bonn Üniversitesi tarafından paylaşılan epileptik EEG işaretleri üzerinde yapılan diğer çalışmalar Tablo 5'te verilmiştir.

Tablo 5'e bakıldığında önerilen motif desenler yöntemi ile yüksek başarı oranları elde edildiği görülmektedir. Literatürde verilen çalışmalara göre önerilen yöntemi başarısının kabul edilebilir olduğu görülmektedir. Motif yönteminin farklı işaretlerin sınıflandırılmasında da kullanılabilceği düşünülmektedir.

4. Tartışma ve Sonuç

Sınıflandırma algoritmaları tıbbi tanı sistemlerinde medikal verilerin daha kısa sürede incelenmesine olanak vermektedir.

Tablo 5. Kullanılan EEG işaretleri üzerinde yapılan çalışmalar ve başarı oranları.

Model	Veri Kümesi	Başarı (%)
DWT ve karışımli modeller[18]	A-E	94,5
WT + Lyapunov exponents ve SVM[13]	A-B-C-D-E	99,28
Time-frequency analiz ve YSA[21]	A-E	100
	A-D-E	99,28
Wavelet entropy öznitelikler ve Recurrent Elman ağı[22]	A-E	99,75
Hızlı Fourier dönüşüm ve karar ağaçları[2]	A-E	98,72
WT ve doğrusal sınıflandırıcılar [23]	A-E	99,5
Multiwavelet transform+approximate entropy feature ve MLPNN [15]	A-E	99,85
Doğrusal olmayan önışlem filtreler ve YSA[24]	ABCD-E	98,27
Time-frequency domain öznitelikleri ve YSA[25]	A-E	97,2
	A-E	99,6
	A-E	100
DWT+k-ortalamlar ve MLPNN[26]	A-D-E	96,67
Dalgacık paket entropisi ve hiyerarşik EEG sınıflandırması [27]	A-E	99,44
GP-öznitelikler ve KNN sınıflandırıcı [28]	A-E	99,2
	A-E	93,55
	B-E	82,88
Permutation entropy ve SVM [29]	C-E	88
	D-E	79,94
Çapraz korelasyon ve SVM [12]	A-E	95,96
Burg AR ve LS-SVM [8]	A-E	99,56
DWT+Özellik Seçimi ve SVM [30]	A-E	100
DTCWF ve KNN[31]	A-E	100
DTCWT ve GRNNs [32]	A-E	100
Kesikli harmonik arama ve PNNs [33]	A-E	100
EMD-GP[34]	A-E	99,11
	ACD-E	99,41
	A-E	99,6
DWT+MLP [14]	ACD-E	97,75
	A-E	100
	B-E	100
	C-E	99,6
Bulanık yaklaşım entropi ve SVM [35]	D-E	95,85
	ACD-E	98,15
	BCD-E	98,22
	ABCD-E	97,38
GA ve SVM [36]	A-E	100
	A-E	98,5
Ağırlıklandırılmış permütasyon entropi (WPE) ve SVM[37]	B-E	85,0
	C-E	93,5
	D-E	96,5
Contourlet dönüşüm ve SVM [38]	A-E	100
Tunable-Q faktor WD ve BA[39]	A-E	100
Sequential method ve RBF-SVM[40]	A-E	100
DWPT+CSA-tabanlı özellik seçimi+WNNs[41]	A-E	100
	ACD-E	98,43
	A-E	100
	B-E	98,0
	C-E	99,0
	D-E	98,5
Korelasyon tabanlı özellik seçimi ve RF[42]	ACD-E	98,5
	BCD-E	97,5
	CD-E	98,67
	ABCD-E	97,4
	A-E	100
	B-E	98,25
DWT+KNN[43]	C-E	97,25
	D-E	95,62
	AB-E	98,83
	ABCD-E	97,1
	A-E	100
	B-E	99,25
	C-E	99,62
DWT+NB[43]	D-E	95,12
	AB-E	99,16
	ABCD-E	95,85
1D-LBPall + FT	A-E	99,50
1D-LBPall + BayesNet	A-D	99,50
1D-LBPu2 + BayesNet	D-E	95,50
1D-LBPu2 + BayesNet	E-CD	97
1D-LBPall + BayesNet	AB-CDE	93
1D-LBPall + BayesNet[1]	A-D-E	95,67
	A-E	100
	B-E	96
1D-LBP+FS+GRA[10]	C-E	100
	D-E	99
	A-D	100
Motif Desenler (PB=6)+FT	A-E	100
Motif Desenler (PB=6)+FT	A-D	100
Motif Desenler (PB=6)+FT	C-E	99,5
Motif Desenler (PB=6)+FT (Bu çalışma)	D-E	97,5

Bu çalışmada Epileptik EEG işaretlerinin analizi için yeni bir öznitelik çıkarım yöntemi önerilmiştir. Motif desenler yöntemi, pencerelemiş işaretlerdeki her bir değer için komşuları ile büyüklük/küçüklük karşılaştırılması esasına dayanan istatistiksel bir yaklaşımdır. Bu yaklaşım ile farklı pencere uzunluklarına (PB) göre farklı boyutlarda öznitelik vektörleri oluşturulmaktadır. Bu öznitelikler kullanarak farklı makine öğrenmesi yöntemleri ile sınıflandırma işlemleri gerçekleştirilmiştir. Kullanılan A-E, A-D, C-E ve D-E gibi farklı EEG işaret kombinasyonları için sırası ile %100, %100, %99,5 ve %97,5 doğruluk oranları elde edilmiştir. Bu sonuçlardan da görüleceği üzere önerilen yöntem EEG işaretlerinin sınıflandırılmasında yerel değişimlere karşı hassasiyeti nedeniyle başarılıdır. Bu sebeple önerilen yöntemin tıbbi karar destek sistemlerinde uzmanlara karar vermede yardımcı olacağı düşünülmektedir. Ayrıca motif desenler yönteminin diğer işaretlerin sınıflandırılmasında da başarılı olacağı düşünülmektedir.

Kaynakça

- [1] Kaya, Y., Uyar, M., Tekin, R., Yıldırım, S. 2014. 1D-local binary pattern based feature extraction for classification of epileptic EEG signals. *Applied Mathematics and Computation*, 243(2014), 209-219.
- [2] Polat, K., Güneş, S. 2007. Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform. *Applied Mathematics and Computation*, 187(2), 1017-1026.
- [3] Yuan, Q., Zhou, W., Li, S., Cai, D. 2011. Epileptic EEG classification based on extreme learning machine and nonlinear features. *Epilepsy research*, 96(1-2), 29-38.
- [4] Übeyli, E. D. 2008. Analysis of EEG signals by combining eigenvector methods and multiclass support vector machines. *Computers in Biology and Medicine*, 38(1), 14-22.
- [5] Übeyli, E. D. 2008. Implementing eigenvector methods/probabilistic neural networks for analysis of EEG signals. *Neural networks*, 21(9), 1410-1417.
- [6] Übeyli, E. D. 2008. Wavelet/mixture of experts network structure for EEG signals classification. *Expert systems with applications*, 34(3), 1954-1962.
- [7] Übeyli, E. D. 2009. Probabilistic neural networks combined with wavelet coefficients for analysis of electroencephalogram signals. *Expert systems*, 26(2), 147-159.
- [8] Übeyli, E. D. 2010. Least squares support vector machine employing model-based methods coefficients for analysis of EEG signals. *Expert Systems with Applications*, 37(1), 233-239.
- [9] Altunay, S., Telatar, Z., Eroglu, O. 2010. Epileptic EEG detection using the linear prediction error energy. *Expert Systems with Applications*, 37(8), 5661-5665.
- [10] Kaya, Y. 2015. Hidden pattern discovery on epileptic EEG with 1-D local binary patterns and epileptic seizures detection by grey relational analysis. *Australasian physical & engineering sciences in medicine*, 38(3), 435-446.
- [11] Li, Y., Wen, P. P. 2011. Clustering technique-based least square support vector machine for EEG signal classification. *Computer methods and programs in biomedicine*, 104(3), 358-372.
- [12] Chandaka, S., Chatterjee, A., Munshi, S. 2009. Cross-correlation aided support vector machine classifier for classification of EEG signals. *Expert Systems with Applications*, 36(2), 1329-1336.
- [13] Guler, I., Ubeyli, E. D. 2007. Multiclass support vector machines for EEG-signals classification. *IEEE Transactions on Information Technology in Biomedicine*, 11(2), 117-126.
- [14] Guo, L., Rivero, D., Dorado, J., Rabunal, J. R., Pazos, A. 2010. Automatic epileptic seizure detection in EEGs based on line length feature and artificial neural networks. *Journal of neuroscience methods*, 191(1), 101-109.
- [15] Guo, L., Rivero, D., Pazos, A. 2010. Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks. *Journal of neuroscience methods*, 193(1), 156-163.
- [16] Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., Elger, C. E. 2001. 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(6), 061907.
- [17] Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., Elger, C. E. 2001. EEG Verisi. <http://www.meb.unibonn.de/epileptologie/science/physik/eegdata.html> (Erişim Tarihi: 25.07.2018).
- [18] Subasi, A. 2007. EEG signal classification using wavelet feature extraction and a mixture of expert model. *Expert Systems with Applications*, 32(4), 1084-1093.
- [19] Menéndez, L. Á., de Cos Juez, F. J., Lasheras, F. S., Riesgo, J. A. Á. 2010. Artificial neural networks applied to cancer detection in a breast screening programme. *Mathematical and Computer Modelling*, 52(7-8), 983-991.
- [20] Witten, I. H., Frank, E. 2005. *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann.
- [21] Tzallas, A. T., Tsipouras, M. G., Fotiadis, D. I. 2009. Epileptic seizure detection in EEGs using

- time-frequency analysis. *IEEE transactions on information technology in biomedicine*, 13(5), 703-710.
- [22] Kumar, S. P., Sriraam, N., Benakop, P. G., Jinaga, B. C. 2010. Entropies based detection of epileptic seizures with artificial neural network classifiers. *Expert Systems with Applications*, 37(4), 3284-3291.
- [23] Fathima, T., Bedeuzzaman, M., Farooq, O., Khan, Y. U. 2011. Wavelet based features for epileptic seizure detection. *MES Journal of Technology and Management*, 2(1), 108-112.
- [24] Nigam, V. P., Graupe, D. 2004. A neural-network-based detection of epilepsy. *Neurological Research*, 26(1), 55-60.
- [25] Srinivasan, V., Eswaran, C., Sriraam, N. 2005. Artificial neural network based epileptic detection using time-domain and frequency-domain features. *Journal of Medical Systems*, 29(6), 647-660.
- [26] Orhan, U., Hekim, M., Ozer, M. 2011. EEG signals classification using the K-means clustering and a multilayer perceptron neural network model. *Expert Systems with Applications*, 38(10), 13475-13481.
- [27] Wang, D., Miao, D., Xie, C. 2011. Best basis-based wavelet packet entropy feature extraction and hierarchical EEG classification for epileptic detection. *Expert Systems with Applications*, 38(11), 14314-14320.
- [28] Guo, L., Rivero, D., Dorado, J., Munteanu, C. R., Pazos, A. 2011. Automatic feature extraction using genetic programming: An application to epileptic EEG classification. *Expert Systems with Applications*, 38(8), 10425-10436.
- [29] Nicolaou, N., Georgiou, J. 2012. Detection of epileptic electroencephalogram based on permutation entropy and support vector machines. *Expert Systems with Applications*, 39(1), 202-209.
- [30] Subasi, A., Gursoy, M. I. 2010. EEG signal classification using PCA, ICA, LDA and support vector machines. *Expert systems with applications*, 37(12), 8659-8666.
- [31] Chen, G. 2014. Automatic EEG seizure detection using dual-tree complex wavelet-Fourier features. *Expert Systems with Applications*, 41(5), 2391-2394.
- [32] Swami, P., Gandhi, T. K., Panigrahi, B. K., Tripathi, M., Anand, S. 2016. A novel robust diagnostic model to detect seizures in electroencephalography. *Expert Systems with Applications*, 56, 116-130.
- [33] Gandhi, T. K., Chakraborty, P., Roy, G. G., Panigrahi, B. K. 2012. Discrete harmony search based expert model for epileptic seizure detection in electroencephalography. *Expert Systems with Applications*, 39(4), 4055-4062.
- [34] Bhardwaj, A., Tiwari, A., Krishna, R., Varma, V. 2016. A novel genetic programming approach for epileptic seizure detection. *Computer methods and programs in biomedicine*, 124(2016), 2-18.
- [35] Kumar, Y., Dewal, M. L., Anand, R. S. 2014. Epileptic seizure detection using DWT based fuzzy approximate entropy and support vector machine. *Neurocomputing*, 133(2014), 271-279.
- [36] Dhiman, R., Saini, J. S. 2014. Genetic algorithms tuned expert model for detection of epileptic seizures from EEG signatures. *Applied Soft Computing*, 19(2014), 8-17.
- [37] Tawfik, N. S., Youssef, S. M., Kholief, M. 2016. A hybrid automated detection of epileptic seizures in EEG records. *Computers & Electrical Engineering*, 53(2014), 177-190.
- [38] Amorim, P., Moraes, T., Fazanaro, D., Silva, J., Pedrini, H. 2017. Electroencephalogram signal classification based on shearlet and contourlet transforms. *Expert Systems with Applications*, 67(2017), 140-147.
- [39] Hassan, A. R., Siuly, S., Zhang, Y. 2016. Epileptic seizure detection in EEG signals using tunable-Q factor wavelet transform and bootstrap aggregating. *Computer methods and programs in biomedicine*, 137, 247-259.
- [40] Li, D., Xie, Q., Jin, Q., Hirasawa, K. 2016. A sequential method using multiplicative extreme learning machine for epileptic seizure detection. *Neurocomputing*, 214(2016), 692-707.
- [41] Ong, P., Zainuddin, Z., Lai, K. H. 2017. A novel selection of optimal statistical features in the DWPT domain for discrimination of ictal and seizure-free electroencephalography signals. *Pattern Analysis and Applications*, 21(2), 515-527.
- [42] Mursalin, M., Zhang, Y., Chen, Y., Chawla, N. V. 2017. Automated epileptic seizure detection using improved correlation-based feature selection with random forest classifier. *Neurocomputing*, 241(2017), 204-214.
- [43] Sharmila, A., Geethanjali, P. 2016. DWT based epileptic seizure detection from EEG signals using Naïve Bayes/k-NN classifiers. *Ieee Access*, 4(2016), 7716-7727.