

## Araştırma Makalesi / Research Article

## EEG İşaretlerinin Hilbert Huang Dönüşümü ve Sınıflandırılması

Gazi AKGÜN\*<sup>1</sup>, Ömer AKGÜN<sup>2</sup><sup>1</sup>Marmara Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, İstanbul<sup>2</sup>Marmara Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul\*Sorumlu yazar <sup>1</sup>e-posta: gazi.akgun@marmara.edu.tr ORCID ID: <https://orcid.org/0000-0002-8154-5883><sup>2</sup>e-posta: oakgun@marmara.edu.tr ORCID ID: <https://orcid.org/0000-0003-3486-2197>

Geliş Tarihi: 20.07.2022

Kabul Tarihi: 11.11.2022

**Anahtar kelimeler**

EEG; Epilepsi; Hilbert Huang; Ampirik Mod Ayrışımı; Yapay Sinir Ağları; Destek Vektör Makineleri; Sınıflandırma

**Öz**

Bu çalışmada Elektroensefalogram (EEG) sinyallerinin analizi ve bu analiz üzerinden sınıflandırılması amaçlanmıştır. Bu amaçla EEG işaretleri Hilbert Huang metodu ile alt frekans bantlarındaki bileşenlerine ayrılmış, anlık frekans ve marjinal izge vektörleri elde edilmiştir. Bu vektörler ve bileşenler kullanılarak istatistiksel öznitelikleri çıkarılmıştır. Bu öznitelikler göz açık – göz kapalı, sağlıklı-epileptik ve epileptik nöbet alt sınıflarında incelenmiş, destek vektör makinesi (DVM), yapay sinir ağları (YSA) ve doğrusal ayırım analizi (DAA) algoritmaları ile sınıflandırılmış ve sonuçlar karşılaştırmalı olarak tartışılmıştır.

## Hilbert Huang Transformation and Classification of EEG Signals

**Keywords**

EEG; Epilepsy; Hilbert Huang; Empirical Mode Decomposition; Artificial Neural Networks; Support Vector Machines; Classification

**Abstract**

The goal of this study is to classify the Electroencephalogram (EEG) signals through signal analysis. To achieve this, Hilbert Huang's method is used to decompose EEG signals into components in lower frequency bands, yielding instantaneous frequency and marginal spectral vectors. These vectors and components are then used to extract statistical features. These features are classified in the eye-open, eye-closed, healthy-epileptic, and epileptic seizure subclasses with the support vector machine (SVM), artificial neural networks (ANN), and linear discrimination analysis (LDA) algorithms, and the results are discussed in comparison.

© Afyon Kocatepe Üniversitesi

**1. Giriş**

Epilepsi her yaşta insanı etkileyebilen nörolojik bir hastalıktır. Dünya üzerinde 50 milyonun üzerinde epilepsi hastası bulunmaktadır (Beghi, 2018). Epilepsi benzeri hastalıkların teşhis edilmesi veya epileptik nöbetin önceden kestirilebilmesi için Elektroensefalogram (EEG) sinyallerinden yararlanır. EEG sinyalleri beyin faaliyetleri sonucu kaydedilen elektrik potansiyelleridir (Sharma, 2015; Andrzejak, 2001).

Özellikle epileptik nöbeti tespit etmek veya epilepsi hastalığını teşhis etmek için uzmanlar tarafından EEG sinyalleri üzerinde incelemeler yapılması

gerekir. EEG sinyallerinin çok kanallı ve uzun olması bu incelemenin zor ve zaman alıcı olmasına neden olmaktadır (Nigam, 2004). EEG sinyalleri üzerinden epilepsi teşhis ve nöbet tahmini için algoritmalar üzerinde araştırmalar yapılmaktadır.

Literatürde birçok çalışmada EEG sinyalleri zaman genlik, frekans genlik ve frekans zaman boyutlarında incelenmiş ve bu analizler sonucunda öznitelikleri hesaplanarak sınıflandırma algoritmalarında kullanılmıştır. Öznitelik hesaplamaları için Hızlı Fourier dönüşümü, dalgacık dönüşümü, çoklu sinyal dalgacık dönüşümü, özbağlanım vektörleri gibi teknikler sıklıkla kullanılmıştır (Polat, 2007; Jahankhani, 2006; Özdemir, 2012).

Lyapunov kuvvetleri, korelasyon boyutları, oransal boyutlar, ortalama entropi (ApEn) gibi farklı doğrusal olmayan parametreler epilepsi teşhisi için kullanılmıştır (Andrzejak, 2001; Güler, 2005).

EEG sinyallerinin sınıflandırılması için Yapay sinir ağları, Destek vektör makineleri, Doğrusal ayırım analizi, K en yakın komşu gibi algoritmalar kullanılmıştır (Subasi, 2010; Acharya, 2011). Subasi ve ark. destek vektör makinesi (DVM) ile yaptıkları sınıflandırma başarı doğruluğunu %98,75 olarak raporlamışlardır (Subasi, 2010). Orhan ve ark. K ortalama metodu ile yaptıkları epilepsi tahmin çalışmalarında %96,67 doğruluk oranı ile sınıflandırma yapmışlardır (Orhan, Hekim, & Ozer, 2011). Lie ve ark genetik algoritma ve DVM ile yaptıkları sınıflandırma çalışmasının başarısını %97 olarak bildirmiştir (Li P. K., 2016). Riaz ve ark. Ampirik mod ayrışımı ile hesapladıkları öznelikleri DVM ile sınıflandırmış ve %96,2 başarıya ulaşmışlardır (Riaz, 2015).

EEG sinyalleri farklı beyin faaliyetleri sonucu farklı frekans bantlarında gözlemlenebilmektedir. 1-4 Hz EEG sinyalleri delta, 4-8 Hz alfa, 8-13 Hz teta ve 13-30 Hz EEG sinyalleri beta olarak isimlendirilirler. Ve bu sinyaller beyin faaliyetleri ile ilişkili olarak yorumlanabilmektedir (Adeli, 2007).

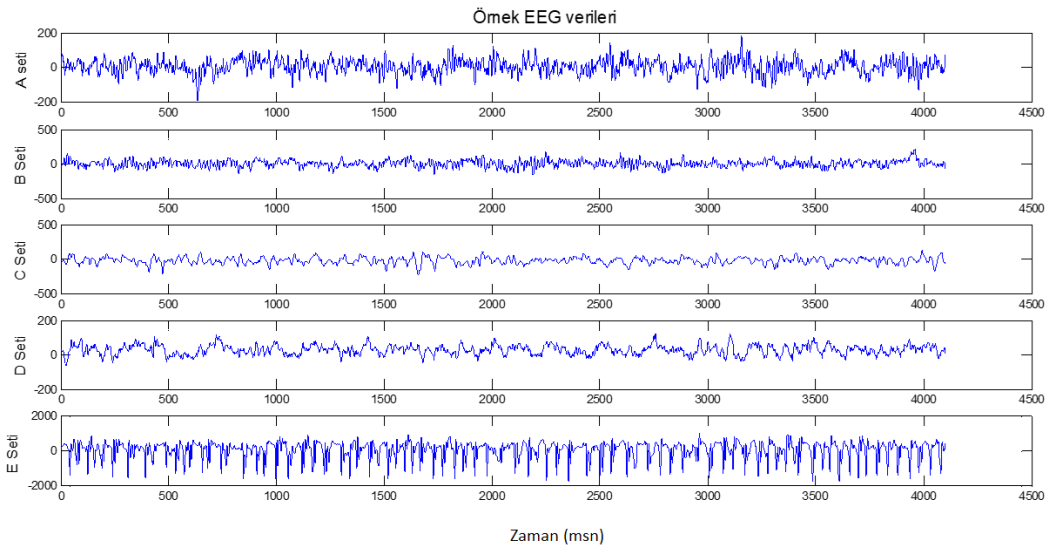
EEG sinyalleri durağan olmayan, karmaşık ve rastgele özellik gösteren bir yapıya sahiptir. Klasik analiz yöntemleri sinyalin doğrusal ve durağan

bileşenlerden oluştuğunu varsayarlar (Özdemir, 2012). Klasik yöntemlere göre yeni bir analiz tekniği olan Hilbert Huang dönüşümünde ise herhangi bir temel dalga kullanılmadan ampirik kip ayrışımı yöntemi ile işaret "içsel mod fonksiyonlarına (IMF) ayrıldıktan sonra hilbert dönüşümü uygulanarak anlık frekans, anlık genlik ve marjinal izge vektörleri elde edilir (Yan R. &, 2006).

Bu çalışmada diğer çalışmalardan farklı olarak Hilbert Huang dönüşümü ile EEG sinyallerinden elde edilen içsel mod fonksiyonları, ve marjinal izge vektörleri kullanılarak EEG sinyalinin frekans ve faz öznelikleri hesaplanmış ve üç farklı sınıflandırma algoritması ile sınıflandırılma başarıları karşılaştırılmıştır.

## 2. Materyal ve Metot

Bu çalışmada Andrzejak ve arkadaşlarının "Beyin elektriksel aktivitesinin zaman serilerinde doğrusal olmayan deterministik ve sonlu boyutlu yapıların endikasyonları" başlıklı çalışmalarında kaydedilmiş ve araştırmacıların kullanımına sunulmuş EEG verileri kullanılmıştır. Veri seti her biri 100 ayrı tek kanal EEG işaretinden oluşan 5 farklı setten oluşur. Bu veriler 128 kanallı olarak kaydedilmiş ve detaylı incelenerek kas aktivitesi göz hareketi gibi etkenlerden oluşan bozuculardan temizlenmiştir (Andrzejak, 2001).



Şekil 1. Örnek EEG verileri

Set A ve B verileri 5 farklı sağlıklı gönüllüden yüzeysel EEG sensörleri kullanılarak kaydedilmiştir.

Ölçüm sırasında standart elektrot yerleşimi kullanılmıştır.

A seti için gönüllüler uyanık ve gözleri açık, B seti için ise uyanık ve gözleri kapalıdır. C, D ve E setleri tanı konulan epilepsi hastalarından alınmıştır. C ve D setleri nöbet dışında kaydedilmiştir. E veri seti nöbet sırasında kaydedildiği için genliği diğer setlere göre belirgin bir şekilde yüksektir. Tüm EEG işaretleri saniyede 173.61 örnekleme ve 12 bit çözünürlüğünde kaydedilmiştir ve 23.6 saniye uzunluğundadır. Tüm veriler 0.53–40 Hz (12 dB/octave) bant geçiren filtreden geçirilmiştir (Andrzejak, 2001).

## 2.1 Hilbert Huang Dönüşümü

İşaret, uyarlamalı ve doğrusal olmayan işaret ayrıştırma yöntemlerinden olan ampirik mod ayrışımı (AMA) yöntemi ile yüksek frekans bileşenlerinden düşük frekans bileşenlerine doğru sıralanan farklı frekanslardaki İçsel Mod Fonksiyonlarına (IMF) ayrıştırılmaktadır. AMA yöntemi ile işaretin elde edilen IMF'lerine Hilbert Dönüşümü uygulanarak her bir IMF bileşeninin anlık faz ve anlık frekans bilgisi elde edilir.


### 2.1.1 Ampirik Mod Ayrışımı (AMA)

Ampirik mod ayrışımı metodu ile herhangi bir işaret sonlu sayıda İçsel Mod Fonksiyonlarına (IMF) ayrılabilir. IMF'ler işareti oluşturan salınımlardır. Bu salınımlar Fourier dönüşümünde kullanılan basit harmoniklere benzerlik gösterirler. IMF'ler harmonik bileşenlerde kullanılan sabit genlik ve frekans yerine zamana göre değişiklik gösteren genlik ve frekansa sahip olabilirler. Bir  $x(t)$  zaman seri işaretinin IMF bileşenlerini bulmak için aşağıdaki işlemler sırasıyla uygulanır;

$x(t)$  işaretinin yerel maksimum ve yerel minimum noktalarının genlik pozisyonları belirlenerek kübik ara değerlendirme kullanılarak üst zarf  $max(t)$  ve alt zarf  $min(t)$  elde edilir.

Denklem 1 de görüldüğü gibi üst zarf ve alt zarf işaretlerinin ortalaması alınarak ortalama zarf işareti  $m(t)$  elde edilir.

$$m(t) = \frac{max(t) + min(t)}{2} \quad (1)$$



Şekil 2. Yerel minimum ve maksimum değerlerin bulunması

Orijinal işareten ortalama zarf işareti çıkarılarak orijinal yeni işaret elde edilir (Denklem 2).

$$i_1 = x(t) - ort_1(t) \quad (2)$$

Ortalama zarf işareti bulma işlemi yeni  $i_1$  işarete uygulanır.

$$i_{11} = i_1 - ort_{11} \quad (3)$$

$$i_{1(k-1)} - ort_{1k} = i_{1k}$$

Elde edilen işaretin IMF işareti olup olmadığı test edilir. Bunun için iki yöntem vardır.

- Denklem 4'te verilmiş olan  $SD_k$  eşik değerinde işaretin hesaplanan eşik değerinin küçük olması;

$$SD_k = \frac{\sum_{t=0}^T |i_{k-1}(t) - i_{(k)}(t)|^2}{\sum_{t=0}^T i_{k-1}^2(t)} \quad (4)$$

- Zarf ortalama işaretinin  $m(t)$  sifıra yakınsaması

Bu şartlardan birisi sağlandığında işaretin 1. IMF'si elde edilmiş olur. Aksi takdirde IMF elde edilinceye kadar birinci işleme tekrar dönülür ve iterasyon devam eder. Birinci IMF, işaretin en yüksek frekanslı bileşenidir.

$$i_{1k} = c_1 = IMF_1 \quad (5)$$

$x(t)$  orjinal işareten  $IMF_1$  çıkarılır ve artan işaret olarak adlandırılan yeni bir işaret elde edilir. Bir sonraki  $IMF$  birinci aşamadan başlanarak bulunmaktadır ve birinci aşama için giriş sinyali bir önceki  $IMF$ 'den elde edilen kalan sinyal ( $a_1$ ) olmaktadır.

$$x(t) - c_1 = a_1 \quad (6)$$

İşaret artan monoton bir fonksiyon olduğunda kaydırma işlemi sona erer.

Böylece  $IMF$  bileşenleri ve artan işareti  $r_n$  elde edilir.

$$a_{n-1} - c_n = r_n \quad (7)$$

Orijinal işaret denklemdaki gibi  $IMF$  bileşenleri ve artan işaret toplanarak yeniden elde edilebilmektedir (Denklem 8).

$$x(t) = \sum_{j=1}^n c_j + a_n \quad (8)$$

Genliğin frekans zaman dağılımına Hilbert izgesi  $H(\omega, t)$  denir. Hilbert izgesi kullanılarak marjinal izgesi ( $h(\omega)$ ) de hesaplanabilir.

$$h(\omega) = \int_0^T H(\omega, t) dt \quad (9)$$

### 2.1.2 Hilbert Dönüşümü (HD)

Gerçel değeri  $x(t)$  olan işaretin Hilbert Dönüşümü uygulanmış karmaşık eşleniği  $y(t)$  dir.

$$y(t) = H[x(t)] = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (10)$$

HD yardımıyla analitik  $x(t)$  fonksiyonu yeniden yazılırsa;

$$z(t) = x(t) + jy(t) = a(t)e^{j\theta(t)} \quad (11)$$

Bu ifadeden yola çıkarak anlık genlik ve faz fonksiyonları bulunabilir.

$$a(t) = \sqrt{x^2(t) + y^2(t)} \quad (12)$$

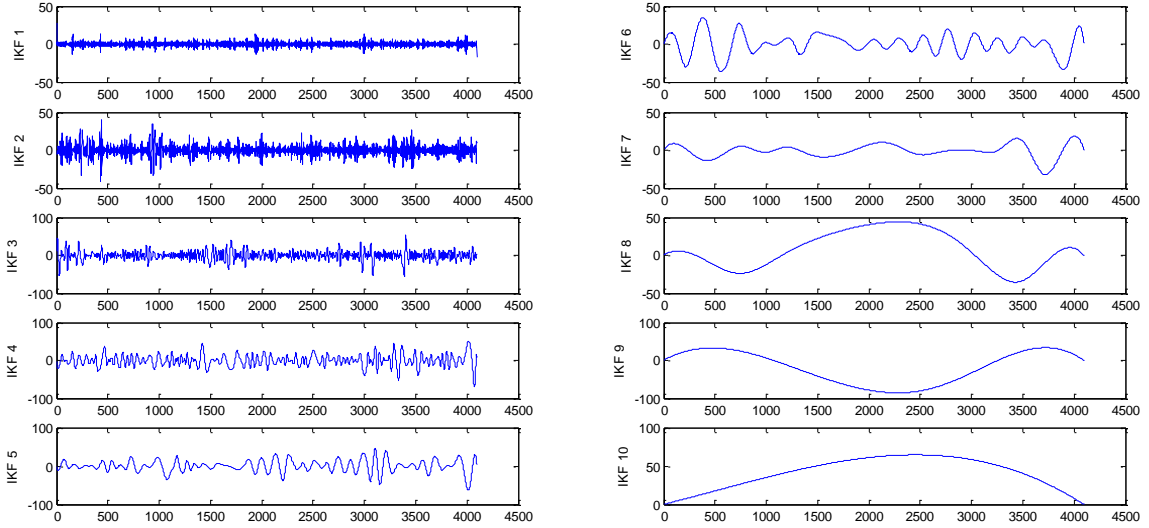
$$\theta(t) = \arctan\left(\frac{y(t)}{x(t)}\right)$$

Denklem 13'ten yola çıkarak anlık frekans bilgisi elde edilir.

$$\omega(t) = \frac{d\theta(t)}{dt} \quad f(t) = \frac{1}{2\pi} \frac{d\theta(t)}{dt} \quad (13)$$

$x(t)$  işarete AMA uygulandıktan sonra elde edilen her  $IMF$ 'nin Hilbert dönüşümü alınırsa  $x(t)$  işaretinin analitik ifadesi elde edilebilir (Özdemir, 2012; Yan J. &, 2014; Ding, 2007; Huang, 2008; Altan, 2014).

$$x(t) = \Re \left\{ \sum_{i=1}^n a_i(t) e^{j\omega_i(t)t} \right\} \quad (14)$$



Şekil 3. Ampirik Mod Ayrışımı ile elde edilen IMF'ler

## 2.2 Özniteliklerin Hesaplanması

Hilbert Huang dönüşümü yapılmış olan sinyalin *IMF*'leri ve Hilbert Marjinal Spektrum kullanılarak çıkarılan öznitelikler sınıflandırma için kullanılmıştır.

### 2.2.1 Enerji Değişim Oranı

Ampirik mod ayrışımı zaman serilerini düşük frekans değerlerinden yüksek frekans değerlerine doğru farklı bileşenlerine ayırmaktadır. Bu da sinyalin farklı frekans bileşenlerinin arasındaki ilişkiyi incelemeyi mümkün kılmaktadır. Bu çalışmada AMA'sı alınan EEG sinyallerinin ilk beş *IMF* si alınarak aralarındaki enerji değişim oranı incelenmiştir.

Bunun için ilk 5 *IMF* den 1 ve 2 numara düşük frekans 4 ve 5 numara yüksek frekans olarak kabul edilmiştir. Yüksek ve düşük frekanslar arasındaki enerji değişimi denklem 15 teki gibi hesaplanmıştır.

$$E_y = \sum_{t=1}^N i_1^2(t) + \sum_{t=1}^N i_2^2(t) \quad (15)$$

$$E_d = \sum_{t=1}^N i_4^2(t) + \sum_{t=1}^N i_5^2(t)$$

$$R_E = \frac{E_y - E_d}{E_d}$$

Burada  $i_1, i_2, i_4$  ve  $i_5$  birinci, ikinci dördüncü ve beşinci *IMF* lerin anlık genlik değerleri,  $N$  ise sinyal uzunluğudur. Hesaplanan  $R_E$  değeri sınıflandırmada kullanılacak bir öznitelik değeri olarak kaydedilmiştir.

### 2.2.2 Ortalama Frekans

Anlık frekans değerleri kullanılarak hesaplanan marjinal spektrum katsayıları kullanılarak sinyalin ortalama frekans değeri denklem 16 daki gibi bulunmuştur.

$$M_f = \frac{\sum (F_k M_k)}{\sum M_k} \quad (16)$$

Burada  $F_k$  frekans matrisi  $M_k$  ise marjinal spektrum matrisidir.

### 2.2.3 Ortalama Faz Açısı

Marjinal spektrum eksen vektörlerinden elde edilen ortalama frekans değeri sanal ve gerçekte kısmi olan karmaşık bir değerdir. Bu değerın faz açısı denklem 17'deki gibi bulunabilir.

$$M_f = \sqrt{a^2 + b^2} \quad (17)$$

$$\theta = \arctan\left(\frac{a}{b}\right)$$

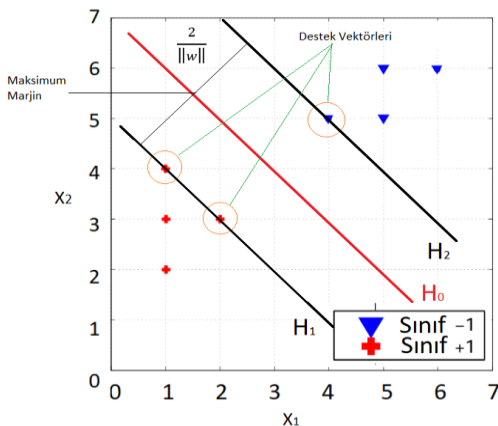
Her bir sinyal için Enerji değişim oranı, Ortalama Frekans ve Ortalama faz açısı değerleri birleştirilerek öznitelik matrisi oluşturulmuştur.

### 2.3 Sınıflandırma

Öznitelikleri hesaplanan sinyallerin göz açık – kapalı, epilepsi hastası veya sağlıklı ve nöbet var yok sınıflarında değerlendirilerek sınıflandırma yapılmıştır.

#### 2.3.1 Destek Vektör Makineleri (DVM)

Destek vektör Makineleri bir optimum sınıflandırma modelidir. Doğrusal olarak birbirinden ayrılabilen iki veri kümesi arasındaki en iyi ayrımın bir fonksiyonu olarak tanımlanan hiper düzlemi hesaplar. Hiper düzlem fonksiyonu, kümelerin karar düzlemine en yakın noktaları olan destek vektörleri ile hesaplanır. Doğrusal olmayan sınıflandırma problemleri ise belirli çekirdek fonksiyonları ile işlemde geçirilerek lineer olarak ayrılabilen öznitelik uzaylarına taşınır ve DVM ile sınıflandırma uygulanabilir.



Şekil 4. İki sınıflı bir veri setini ayıran hiper düzlemler

Negatif örnekler ve pozitif örnekler olarak tanımlanmış olan iki sınıfı birbirinden ayıran ayırım düzleminin dışında kalan örnekler aşağıdaki gibi ifade edilebilir.

$$y_i(W^T X + b) - 1 \geq 0 \quad (18)$$

Burada  $y_i$  pozitif örnekler için +1 negatif örnekler için -1,  $W = \{w_1, w_2, \dots, w_n\}$  ağırlık vektörü,  $X = \{x_1, x_2\}$  veri seti ve  $b$  ise bias'tır.

Bu durumda iki sınıfı birbirinden ayıran en iyi düzlem olan  $H_0$  düzlemi Denklem 19'daki gibi ifade edilir.

$$H_0 = W^T X + b = 0 \quad (19)$$

Burada amaç  $H_1$  ve  $H_2$  düzlemleri arasındaki uzaklığı maksimuma çıkarmaktır. Destek vektörleri arasındaki dik uzaklığın  $\left(\frac{2}{\|w\|}\right)$  maksimum noktasını bulmak için Lagrange çarpımı gradyanı kullanılarak Denklem 20'de verilmiş olan öğrenme modellerine ulaşılabilir (Subasi, 2010; Qi, 2013; Garg, 2015; Silva, 2015).

$$W = \sum_i \alpha_i y_i \tilde{x}_i \quad y_i = \sum_i \sum_j \alpha_i \tilde{x}_i \cdot \tilde{x}_j \quad (20)$$

Burada  $\tilde{x}$  destek vektörleri,  $\alpha_i$  kısıt koşul katsayıları,  $W$  ağırlık vektörü ve  $y_i$  sınıf gösterge değerleridir.

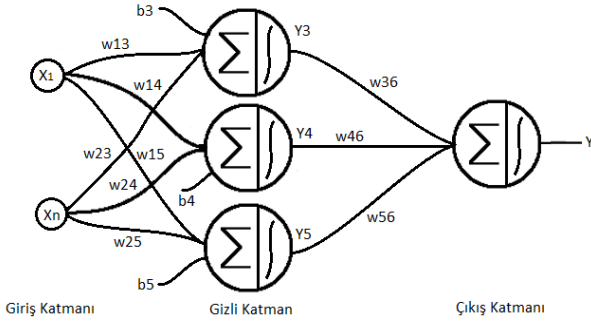
#### 2.3.2 Yapay Sinir Ağları (YSA)

Doğal sinir hücrelerinin matematiksel bir modeli olarak tasarlanan yapay sinir yapıları bir fonksiyon yaklaşım modelidir. Şekil 5'da görüldüğü gibi her bir yapay sinir hücresinin girişine uygulanan sinyaller doğal sinir hücresinin çekirdeğinin bir modeli olan toplam fonksiyonunda toplanır. Bu fonksiyonun sonucu bir aktivasyon fonksiyonundan geçerek sinir hücresinin çıkışı belirler. Bir yapay sinir hücresinin çıkışı denklem 21'de verildiği gibidir.

$$y_i = \sigma\left(\sum_{i=1}^{i=n} w_i x_i + b_i\right) \quad (21)$$

Burada  $w$  ağırlık değerleri  $x$  girişler  $b$  bias ve  $y_i$  yapay sinir hücresinin çıkışı ve  $\sigma$  aktivasyon fonksiyonudur. Ağırlık değerleri tüm örnek değerlerin etiket değerlerine karşılık durumu iteratif

olarak hesaplanarak güncellenir. Bu güncelleme sırasında kullanılan öğrenme kuralı aktivasyon fonksiyonuna bağlıdır.



Şekil 5. Yapay sinir ağı modeli

Birden fazla yapay sinir hücre modeli kaskad bağlanarak çok katmanlı yapay sinir ağları oluşturulur. Çok katmanlı YSA modelinde giriş katmanı, gizli katman ve çıkış katmanı bulunmaktadır. Çıkışta hesaplanan hata değeri geriye doğru yayılarak tüm ağırlık değerlerini güncellemek için kullanılır.

$$\Delta w_i = \eta \frac{\partial J}{\partial w} + \alpha \Delta w_i \quad (20)$$

Burada  $\Delta w_i$  ağırlık değerinin değişimi,  $\eta$  öğrenme oranı,  $J$  kayıp fonksiyonu,  $\alpha$  momentum sabitidir (Nigam, 2004; Lenzi, 2016; Srinivasan, 2007; Hung, 2015).

### 2.3.3 Doğrusal Ayrım Analizi

Çoğunlukla öznitelik boyut azaltma amacıyla kullanılan doğrusal ayrım analizi (DAA) sınıflar arası varyansı maksimize etmeyi amaçlar.

Bu işlem için öncelikle mevcut parametreler ile veri setinde etiketli farklı sınıflar arasındaki ayrılabilirliğinin (özniteliklerin ortalama değerleri arasındaki uzaklığın,  $S_B$ ) hesaplanması gerekir (Tharwat, 2017).

$$(m_i - m)^2 = W^T(\mu_i - \mu)(\mu_i - \mu)^T W = W^T S_{B_i} W \quad (21)$$

Burada  $m_i$   $i$  sınıfı ortalama değeri projeksiyonu ( $W^T \mu_i$ ),  $m$  tüm sınıf verilerinin ortalama değer projeksiyonu ( $W^T \mu$ ),  $W$  DAA transformasyon

matrisi,  $\mu_i$  ( $1 \times M$ ) boyutunda  $i$ . sınıf ortalama değeri ve  $\mu$  ( $1 \times M$ ) boyutunda tüm sınıfların ortalama değeridir. Burada  $M$  hesaplanan öznitelik sayısıdır.

Sınıf içi varyans ( $S_{W_i}$ ) her bir değer için sınıf ortalama değeri ile uzaklığı olarak tanımlanır.

$$\begin{aligned} & \sum_{x_i \in \omega_j, j=1, \dots, c} (W^T x_i - m_j)^2 \\ &= \sum_{x_i \in \omega_j, j=1, \dots, c} W^T (x_{ij} - \mu_j)(x_{ij} - \mu_j)^T W \quad (22) \\ &= \sum_{x_i \in \omega_j, j=1, \dots, c} W^T S_{W_j} W \end{aligned}$$

Burada  $x_{ij}$   $j$ . sınıfın  $i$ . örneği,  $S_{W_j}$   $j$ . sınıf içi varyansdır. Hesaplanan sınıflar arası varyans ( $S_B$ ) ve sınıf için varyans ( $S_W$ ), transformasyon matrisi ( $W$ ) ile Fisher kriteri olarak bilinen metod (Denklem 23) ile maksimum sınıflar arası varyans ve minimum sınıf içi varyans hesaplanır.

$$\arg \max_W \frac{W^T S_B W}{W^T S_W W} \quad (23)$$

$$S_W W = \lambda S_B W$$

Doğrusal ayrım analizinin gruptan herhangi etiketlenmemiş bir verinin ait olduğu grubu en az hata ile saptayabilmektedir (Yan S. W., 2015; Choe, 2010; Li C. H., 2015).

### 3. Deneysel Bulgular

Hesaplanan öznitelikler ile ilgili sayısal bilgiler Çizelge 1 'de verilmiştir. Buna göre Ortalama Frekans değerinin epilepsi hastalığının olmadığı A ve B setleri ile hastalığın teşhis edildiği C ve D setlerinde açık bir şekilde farklı aralıklarda olduğu görülmektedir. Bu da Ortalama frekans değerinin epilepsi tanısı için ayırıcı bir öznitelik olduğunu göstermektedir. Benzer şekilde E setinin Enerji değişim oranının diğer setler ile kesişmeyen bir aralıkta olması bu özneliğin epilepsi nöbeti için ayırıcı özellikte olduğunu göstermektedir.



**Çizelge 1.** Hesaplanan Özniteliklerin maksimum minimum değerleri

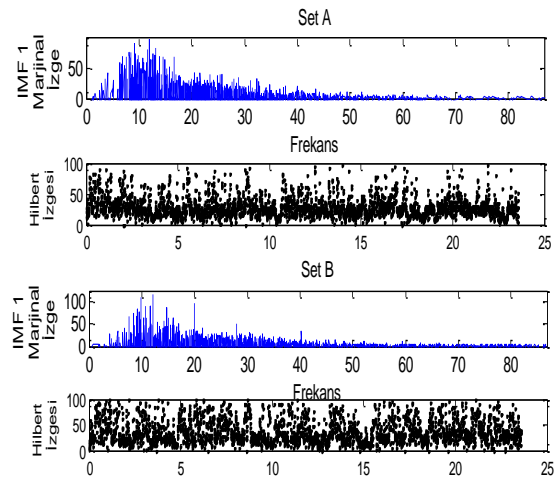
	Enerji Değişim Oranı			Ortalama Frekans			Ortalama Faz Açısı		
	Ortalama	Maksimum	Minimum	Ortalama	Maksimum	Minimum	Ortalama	Maksimum	Minimum
Set A	-0,06	1,38	-0,65	97,80	980,71	6,97	-0,51	2,64	-0,93
Set B	2,48	12,08	-0,38	95,29	700,49	9,06	2,59	2,87	-0,81
Set C	-0,81	0,06	-0,93	38,76	6,84 e3	7,75	2,40	2,65	-0,91
Set D	-0,77	0,98	-0,94	48,69	2,39e3	8,51	2,46	2,77	-0,80
Set E	1,34	22,35	-0,80	343,96	2,63e3	29,64	2,68	2,86	-0,54

Göz açık kaydedilen A seti ile Göz kapalı kaydedilen B setlerinden bir örnek incelendiğinde (Şekil 6) Set B için seyrek te olsa yüksek frekanslı bileşenlerin daha yoğun olduğu set A 'ya göre düşük frekanslı bileşenlerin seyrek görüldüğü söylenebilmektedir. Tüm veri setinden hesaplanan öznitelikler göz açık ve göz kapalı sınıfı ile incelendiğinde (Şekil 7) y ekseninde çizilen özniteliklerin ayırıcılığı gözlemlenebilmektedir. Bu da bahsedilen iki sınıf arasında başarılı bir sınıflandırma yapılabileceğini göstermektedir.


Şekil 8 ve Şekil 9'da görüldüğü gibi sağlıklı hasta ve epilepsi tanısı konulan hastaların EEG verileri HHD dönüşümleri yapılarak incelenmiştir. Buna göre sağlıklı verilerin yüksek frekanslı bileşenlerini içeren *IMF 1* ile epilepsi hasta verileri karşılaştırıldığında, epilepsi hastalarının EEG verilerinin 1. IMF'lerinin genliklerinin çok daha yüksek olduğu görülmektedir.

Şekil 10 ve Şekil 11'de görüldüğü gibi set C ve D ile set E incelendiğinde açık bir şekilde frekans yoğunluklarının epilepsi nöbetinde kaydedilmiş olan E setinde 200 kat daha yüksek olduğu görülmektedir. Aynı şekilde özniteliklerin ayırıcılığı da yüksektir.

Sinyaller alt sınıflarda yapılan analizler sonucu elde edilen öznitelikler ile sınıflandırılmıştır. Sınıflandırma sonuçları Çizelge 1' de verilmiştir. Buna göre en başarılı sonuç sağlıklı epilepsi alt sınıfı arasında yapılan sınıflandırmalarda görülmüştür.




**Şekil 6** Göz Açık Kapalı Analizi

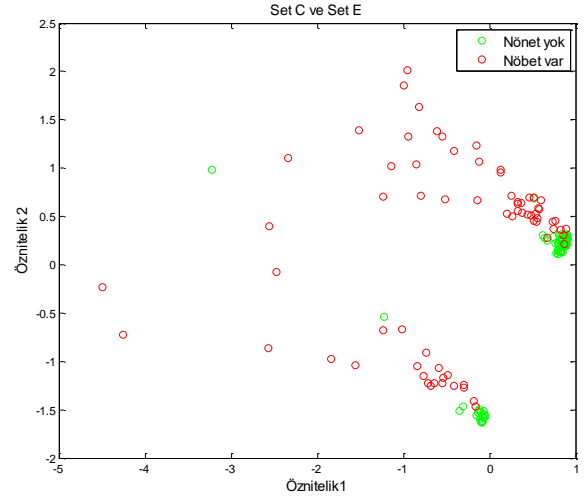


**Şekil 7** Göz Açık Kapalı Analizi





Şekil 8 Göz Açık Kapalı Analizi




Şekil 11 .Göz Açık Kapalı Analizi


Regresyon değerlerine bakıldığında Destek vektör makinesi algoritmasının bu çalışmada diğer iki algoritmaya göre daha başarılı sonuçlar ürettiği görülmektedir.

#### 4. Tartışma ve Sonuç

EEG sinyallerinin hilbert huang dönüşümü ile analizi ve içsel mod fonksiyonlarından elde edilen öznitelikler ile sınıflandırılması gerçekleştirilmiştir. Buna göre epilepsi ve sağlıklı bireylerden alınan EEG sinyalleri frekans bandında incelendiğinde giriş bölümünde verilmiş olan çalışmaların ortalama başarısının üzerinde (%98 - %100) bir doğruluk ile sınıflandırılabilirdi sonucuna ulaşılmıştır. Ayrıca epilepsi nöbeti EEG sinyalleri ile kolayca tespit edilebilmektedir. Hesaplanan öznitelikler kullanılarak makine öğrenme algoritmalarından Destek vektör makineleri, Yapay sinir ağları ve Doğrusal Ayrım analizi yöntemleri yardımıyla sınıflandırma gerçekleştirilmiştir. Bu sonuçlara göre epilepsi teşhisi için %100 'e yakın başarı ile DVM ve DAA metotları öne çıkmaktadır.



Şekil 9 Göz Açık Kapalı Analizi



Şekil 10 .Göz Açık Kapalı Analizi

Çizelge 1. Sınıflandırma Sonuçları

	DVM		DAA		YSA	
	<i>hata</i>	$\rho$	<i>hata</i>	$\rho$	<i>hata</i>	$\rho$
D1*	0,28	0,71	0,31	0,68	0,22	0,80
D2*	0	1,0	0	1,0	$4,5 \cdot 10^{-4}$	0,98
D3*	0,13	0,86	0,23	0,76	0,21	0,70

\*D1: Göz Açık kapalı D2: Sağlıklı Epilepsi, D3: Nöbet var yok. Hata değerleri hataların karelerinin ortalaması ile hesaplanmıştır.  $\rho$  Doğruluk oranıdır.

### Kaynakça

- Acharya, U. R., Sree, S. V., Chattopadhyay, S., Yu, W., & Ang, P. C. A., 2011. Application of recurrence quantification analysis for the automated identification of epileptic EEG signals. *International journal of neural systems*, **21(03)**, 199-211.
- Adeli, H., Ghosh-Dastidar, S., & Dadmehr, N., 2007. A wavelet-chaos methodology for analysis of EEGs and EEG subbands to detect seizure and epilepsy. *IEEE Transactions on Biomedical Engineering*, **54(2)**, 205-211.
- Altan, G., YAYIK, A., Kutlu, Y., YILDIRIM, S., & YILDIRIM, E., 2014. Konjestif Kalp Yetmezliğinin Hilbert-Huang Dönüşümü ile Analizi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, **16(48)**, 94-103.
- 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.
- Beghi, E., & Giussani, G., 2018. Aging and the epidemiology of epilepsy. *Neuroepidemiology*, **51(3-4)**, 216-223.
- Choe, S. H., Chung, Y. G., & Kim, S. P., 2010. Statistical spectral feature extraction for classification of epileptic EEG signals. In 2010 International Conference on Machine Learning and Cybernetics (Vol. 6, pp. 3180-3185). IEEE.
- Ding, H., Huang, Z., Song, Z., & Yan, Y., 2007. Hilbert-Huang transform based signal analysis for the characterization of gas-liquid two-phase flow. *Flow measurement and instrumentation*, **18(1)**, 37-46.
- Garg, M., Sinha, B., & Chandra, S., 2015. Identification of relations from IndoWordNet for indian languages using support vector machine. In 2015 International Conference on Computing and Network Communications (CoCoNet) IEEE., (s. pp. 547-552).
- Güler, I., & Übeyli, E. D., 2005. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients. *Journal of neuroscience methods*, **148(2)**, 113-121.
- Huang, M., Wu, P., Liu, Y., Bi, L., & Chen, H., 2008. Application and contrast in brain-computer interface between Hilbert-Huang transform and wavelet transform. *The 9th International Conference for Young Computer Scientists*, (s. pp. 1706-1).
- Hung, Y. W., Chiu, Y. H., Jou, Y. C., Chen, W. H., & Cheng, K. S., 2015. Bed posture classification based on artificial neural network using fuzzy c-means and latent semantic analysis. *Journal of the Chinese Institute of Engineers*, **38(4)**, 415-425.
- Jahankhani, P., Kodogiannis, V., & Revett, K., 2006. EEG signal classification using wavelet feature extraction and neural networks. *IEEE John Vincent Atanasoff 2006 International Symposium on Modern Computing (JVA'06)*, (s. pp. 120-124).
- Lenzi, G. G., Evangelista, R. F., Duarte, E. R., Colpini, L. M. S., Fornari, A. C., Menechini Neto, R., ... & Santos, O. A. A., 2016. Photocatalytic degradation of textile reactive dye using artificial neural network modeling approach. *Desalination and Water Treatment*, **57(30)**, 14132-14144.
- Li, C. H., Ho, H. H., Kuo, B. C., Taur, J. S., Chu, H. S., & Wang, M. S., 2015. A semi-supervised feature extraction based on supervised and fuzzy-based linear discriminant analysis for hyperspectral image classification. *Appl. Math*, **9(1L)**, 81-87.
- Li, P., Karmakar, C., Yan, C., Palaniswami, M., & Liu, C., 2016. Classification of 5-S epileptic EEG

- recordings using distribution entropy and sample entropy. *Frontiers in physiology*, s. **7**,136.
- Nigam, V. P., & Graupe, D., 2004. A neural-network-based detection of epilepsy. . *Neurological research*, **26(1)**, 55-60.
- Orhan, U., Hekim, M., & Ozer, M., 2011. EEG signals classification using the K-means clustering and a multilayer perceptron neuralnetwork model. *Expert Syst. Appl.*, **38**, 13475–13481.
- Özdemir, N., & Yıldırım, E., 2012. Epileptic seizureprediction based on Hilbert Huang Transform and Artificial Neural Networks. *20th Signal Processing and Communications Applications Conference (SIU) IEEE.*, (s. pp. 1-4).
- 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.
- Qi, Z., Tian, Y., & Shi, Y., 2013. Structural twin support vector machine for classification. *Knowledge-Based Systems*, **43**, 74-81.
- Riaz, F. H., Riaz, F., Hassan, A., Rehman, S., Niazi, I. K., & Dremstrup, K. , 2015. EMD-based temporal and spectral features for the classification of EEG signals using supervised learning. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, s. **24(1)**, 28.
- Sharma, R., & Pachori, R. B., 2015. Classification of epileptic seizures in EEG signals based on phase space representation of intrinsic mode functions. *Expert Systems with Applications*, , **42(3)**, 1106-1117.
- Silva, L., Vaz, J. R., Castro, M. A., Serranho, P., Cabri, J., & Pezarat-Correia, P., 2015. Recurrence quantification analysis and support vector machines for golf handicap and low back pain EMG classification. . *Journal of Electromyography and Kinesiology*. **25(4)**, 637-647.
- Srinivasan, V., Eswaran, C., & Sriraam, N., 2007. Approximate entropy-based epileptic EEG detection using artificial neural networks. *IEEE Transactions on information Technology in Biomedicine*, , **11(3)**, 288-295.
- 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.
- Tharwat, A., Gaber, T., Ibrahim, A., & Hassanien, A. E., 2017. Linear discriminant analysis: A detailed tutorial. . *AI communications*, **30(2)**, 169-190.
- Yan, J., & Lu, L., 2014. Improved Hilbert–Huang transform based weak signal detection methodology and its application on incipient fault diagnosis and ECG signal analysis. . *Signal Processing*, **98**, 74-87.
- Yan, R., & Gao, R. X., 2006. Hilbert–Huang transform-based vibration signal analysis for machine health monitoring. *IEEE Transactions on Instrumentation and measurement*, , **55(6)**, 2320-2329.
- Yan, S., Wang, H., Liu, C., & Zhao, H., 2015. Electrocardiogram classification based on wavelet variance and Fisher linear discriminant analysis. . *In The 27th Chinese Control and Decision Conference (2015 CCDC)* . *IEEE.*, (s. pp. 5404-5408).