



T.C.

MUSTAFA KEMAL ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**EEG İŞARETLERİNDEN HILBERT-HUANG TRANSFORM (HHT)
YÖNTEMİ İLE NÖBET ALGILAMA VE TAHMİNİ**

NİLÜFER ÖZDEMİR

YÜKSEK LİSANS TEZİ

İskenderun/HATAY

NİSAN 2012



T.C.

MUSTAFA KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**EEG İŞARETLERİNDEN HILBERT-HUANG TRANSFORM (HHT)
YÖNTEMİ İLE NÖBET ALGILAMA VE TAHMİNİ**

NİLÜFER ÖZDEMİR

YÜKSEK LİSANS TEZİ

İskenderun/HATAY

NİSAN 2012

T.C.
MUSTAFA KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**EEG İŞARETLERİNDEN HILBERT- HUANG TRANSFORM (HHT)
YÖNTEMİ İLE NÖBET ALGILAMA VE TAHMİNİ**

NİLÜFER ÖZDEMİR
YÜKSEK LİSANS TEZİ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Y.Doç.Dr. Esen YILDIRIM danışmanlığında, hazırlanan bu tez 04 / 04 / 2012 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul/œed edilmiştir.

İmza:.....	İmza:.....	İmza:.....
Yrd.Doç.Dr. Esen YILDIRIM	Yrd.Doç.Dr.Vedat ÖZKANER	Yrd.Doç.Dr.Yakup KUTLU
Başkan	Üye	Üye

Bu tez Enstitümüz Elektrik Elektronik Mühendisliği Anabilim Dalında hazırlanmıştır.

Kod No:

.....
Enstitü Müdürü
İmza ve Mühür

Bu çalışma TÜBİTAK tarafından desteklenmiştir.
Proje no: 109E223

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

İÇİNDEKİLER

ÖZET.....	1
ABSTRACT.....	2
SİMGELER VE KISALTMALAR DİZİNİ	3
ÇİZELGELER DİZİNİ	5
ŞEKİLLER DİZİNİ.....	6
1. GİRİŞ	7
1.1. İnsan Beyni	9
1.2. Epilepsi ve Elektroensefalografi (EEG).....	11
2. ÖNCEKİ ÇALIŞMALAR.....	14
2.1. Nöbet Algılama	14
2.2. Nöbet Tahmini.....	15
2.3. Ampirik Kip Ayrışımı Kullanılarak Yapılan Çalışmalar	18
2.4. Hilbert-Huang Transform Yöntemi Kullanılarak Yapılan Çalışmalar.....	19
3. MATERYAL	22
3.1. Freiburg Veritabanı	22
3.2. Freiburg Veriseti Kullanılarak Yapılan Çalışmalar.....	25
4. YÖNTEM.....	28
4.1 Hilbert-Huang Transformu.....	28
4.2. Veri İşleme Metotlarının Gözden Geçirilmesi	29
4.2.1. Spektrogram.....	29
4.2.2. Dalgacık Analizi	29
4.2.3. Diğer Çeşitli Yöntemler.....	30
4.3 Anlık Frekans	31
4.4. İçsel Mod Fonksiyonları.....	32
4.5. Ampirik Kip Ayrışımı Metodu: Eleme Süreci	33
4.6. Hilbert Dönüşümü	38
4.7. Yapay Sinir Ağları.....	42
4.7.1 Yapay Sinir Ağlarının Özellikleri.....	42
4.7.2. Yapay Sinir Modelleri	45
4.7.3. Aktivasyon Fonksiyonları.....	46

4.7.4. Yapay Sinir Ağlarının Sınıflandırılması.....	46
4.7.4.1. İleri Beslemeli Ağlar.....	47
4.7.4.2. Geri Beslemeli Ağlar	49
4.8. Bayes Ağları	49
4.9. Korelasyon Tabanlı Öznitelik Seçme.....	50
5. ARAŞTIRMA BULGULARI VE TARTIŞMA	52
5.1. Verilerin Önışlemde Geçirilmesi.....	52
5.2. Nöbet Algılama Çalışmaları ve Sonuçları.....	56
5.3. Nöbet Tahmini Çalışmaları ve Sonuçları	60
5.3.1. Nöbet Tahmini İçin HHT Yöntemiyle Özniteliklerin Elde Edilmesi.....	61
5.3.2. Öznitelik Seçimi	62
5.4 Sınıflandırma	65
5.5. Sınıflandırma Sonrası İşleme (Post-Processing)	67
6. SONUÇ VE ÖNERİLER	69
KAYNAKLAR	80
TEŞEKKÜR.....	89
ÖZGEÇMİŞ	90

ÖZET

Dünya çapında çok sayıda insanı etkileyen epilepsi, bilinen en yaygın nörolojik bozukluktur. Epilepsi, hastayı sadece nöbet anlarında, ve bazı durumlarda bu nöbeti izleyen birkaç saat süreyle, rahatsız eden, bunun dışında normal yaşamına devam etmesini engellemeyen bir hastalıktır. Bu nedenle epilepsi tanısı konmuş bir hasta için nöbet geçirme zamanının önceden tespit edilebilmesi çok önemlidir. Erken nöbet teşhisinde, EEG işaretlerinden çıkarılan özelliklerin ve farklı parametrelerin önemli bilgiler taşıdığı kabul edilmektedir.

Bu tez çalışmasında, nöbet algılama ve nöbet tahmini olmak üzere iki farklı çalışma yapılmıştır. Nöbet algılama çalışmasında, nöbet tespiti için Ampirik Kip Ayrışım tabanlı bir yöntem önerilmiştir. Önerilen yöntem, 123 dakikalık nöbet verisi ve 200 dakikalık nöbet dışı veri üzerinde 3 farklı sınıflandırıcı kullanılarak test edilmiştir. Tüm sınıflandırıcılar için %80 üzerinde duyarlılık ve %95 üzerinde belirlilik elde edilmiştir.

Nöbet tahmini çalışmasında, Hilbert-Huang Transform tabanlı bir epileptik nöbet tahmini yöntemi önerilmektedir. Bu yöntemde EEG işaretleri İçsel Mod Fonksiyonlarına ayrılmakta ve ilk 6 İMF, nöbet öncesi ve nöbetler arası verileri sınıflandırmada kullanılacak özniteliklerin çıkarılmasında kullanılmaktadır. Nöbet öncesi / nöbetler arası ikili sınıflandırma işlemi Yapay Sinir Ağları ve Bayes Ağları yöntemiyle gerçekleştirilmiştir. Sınıflandırma öncesinde Korelasyon Tabanlı Öznitelik Seçimi yöntemiyle öznitelik seçimi yapılmıştır. Önerilen yöntemle Freiburg iEEG veri setindeki 87 adet nöbet öncesi 58 saatlik veri ile 504 saatlik nöbetler arası veri test edilmiştir. %50 örtüşen 30 saniyelik EEG verileri kullanılarak, %95,4 duyarlılık (87 nöbetin 83'ü) ve 0.55 YP/saat elde edilmiştir. Bu sonuçlar epileptik nöbet tahmininde Hilbert-Huang Transform yönteminin ümit verici olduğunu göstermektedir.

2012, 91 sayfa

Anahtar Kelimeler: Epileptik Nöbet Tahmini, Huang Hilbert Transform (HHT), Ampirik Kip Ayrışımı (AKA), Yapay Sinir Ağları (YSA), BAYESNet, Korlesyon Tabanlı Öznitelik Seçimi (KTÖS)

ABSTRACT

Epilepsy is a neurological disorder that affect a serious number of people all around the world. Detection of epileptic seizures using EEG signals occupies an important part in the diagnosis of epilepsy. Epilepsy is a pathology that effects the patient only during a seizure, and the following short duration for some cases, and otherwise allows the patient to maintain his/her normal life. Therefore, for a patient diagnosed with epilepsy, it is important to predict a seizure before it happens. Features and parameters extracted from EEG signals from the epileptic patient are expected to have important information for seizure detection.

In this work two different kinds of study was made; seizure detection and prediction. In the study of seizure detection, we present a method for seizure detection based on Empirical Mode Decomposition. This method was tested on 123 minutes of ictal data and 200 minutes of inter-ictal data using different classifiers. For all classifiers, over 80% sensitivity and over 95% specificity were obtained.

In the study of seizure prediction, seizure prediction method based on Hilbert-Huang Transform was advised. In this method EEG signals are decomposed into Intrinsic Mode Functions and first six IMFs are used to obtain features for classification of preictal and interictal recordings employing Artificial Neural Networks and Bayesian Network. Correlation Feature Selection method is used for feature selection before classification. Proposed method was tested on Freiburg iEEG database. A total of 58 hours of preictal data, prior to 87 seizures, and 504 hours of interictal data were examined. Algorithm resulted in 95.4% sensitivity (83 of 87 seizures) and 0.55 FPs/h using 30 seconds EEG segment with 50% overlap. The results show that epileptic seizure prediction in EEG records via Hilbert-Huang Transform is very promising.

2012, 91 pages

Key Words: Epileptic Seizure Prediction, Hilbert Huang Transform (HHT), Empirical Mode Decomposition (EMD), Artificial Neural Network (ANN), Bayesian Network, Correlation Feature Selection (CFS)

SİMGELER VE KISALTMALAR DİZİNİ

a	Adilasyon faktörü.
W_0	Ağırlık vektörü
W	Ağırlıklar matrisi
θ	Aktivasyon faktörü
$w_i(t)$	Analitik işaretin anlık frekansı
$\theta_i(t)$	Analitik işaretin fazı
$G_i(t)$	Analitik işaretin genliği
d_i	Ara katman sinir hücresi
E	Enerji
μ_E	Enerji bandı ortalaması
E_i	Enerji değeri
E_{st}	Enerji değerlerinin standart skorları
$\theta(t)$	Faz fonksiyonu
w	Frekans
$g(t)$	Gerçek değerli zaman serisi
X_j	Giriş vektörü bileşenleri
W_{ij}	Her ara katman sinir hücresine, giriş vektör bileşenlerinden gelen ağırlık vektörü
$\hat{g}(t)$	Hilbert dönüşümü alınmış zaman serisi
$H(w, t)$	Hilbert genlik spektrumu
y	Sinir hücresinin çıkış vektörü
x	Sinir hücresinin giriş vektörü
r_N	Kalan işaret
b	Orijin çevirisi
$m(t)$	Ortalama
f_k	Ortonormal temel
$\psi^*(.)$	Temel dalgacık fonksiyonu
σ_E	Enerji bandı standart sapması
$E_g^+(t)$	Yerel en büyükler
$E_g^-(t)$	Yerel en küçükler
t	Zaman

ART	Adaptive Resonance Theory
AKA	Ampirik Kip Ayrışımı
MVAR	Çok değişkenli özbağımlı model
DN	Doğru negatif
DP	Doğru pozitif
EEG	Elektroenseflogram
EMG	Elektromiyografi
ERG	Elektroretinogram
max	En büyük değer
min	En küçük değer
HHT	Hilbert Huang Transformu
İMF	İçsel Mod Fonksiyonları
SOM	Self Organizing Map
SNEO	Smoothed Nonlinear Energy Operator
YN	Yanlış negatif
YP	Yanlış pozitif
YSA	Yapay Sinir Ağları
RNN	Yinelenen Sinir Ağları

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1. AKA ve HHT Kullanılarak Yapılan Çalışmalar.....	21
Çizelge 3.1. EEG Veri ve Hasta Karakteristikleri.....	23
Çizelge 3.2. Değişik Yöntemler Kullanılarak Yapılan Nöbet Tahmin Çalışmaları.....	27
Çizelge 4.1. Sinir sistemi ile YSA'nın benzerlikleri.....	43
Çizelge 5.1. Nöbet algılama için duyarlılık ve belirlilik sonuçları	60
Çizelge 5.2. Öznitelikler Çizelgesi.....	62
Çizelge 5.3. Öznitelik Seçiminden Sonra Sınıflandırma İçin Gerekli Olduğu Tespit Edilen Öznitelikler	64
Çizelge 5.4. Hastalara göre nöbet ve nöbetler arası dosya sayıları.....	67
Çizelge 6.1. Sınıflandırma sonuçları (BAYESNet_60 sn).....	70
Çizelge 6.2. Sınıflandırma sonuçları (YSA_60 sn).....	71
Çizelge 6.3. Sınıflandırma sonuçları (YSA_KTÖS_60 sn)	72
Çizelge 6.4. Sınıflandırma sonuçları (BAYESNet_30 sn).....	73
Çizelge 6.5. Sınıflandırma sonuçları (YSA_30 sn).....	74
Çizelge 6.6. Sınıflandırma sonuçları (YSA_KTÖS_30 sn)	75
Çizelge 6.7. Hastalara göre en başarılı sınıflandırmalar	77
Çizelge 6.8. En başarılı sınıflandırma sonuçları (BAYESNet_30 sn)	78

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. Beyin lobları	10
Şekil 1.2. Beyin dalgaları	12
Şekil 3.1. 1, 2, 3, 4, 5, 6,9. Hastaların elektrotlarından bazılarının yerleştirme şekilleri	26
Şekil 4.1 Aynı sayıda sıfır kesişimler ve uç değerler ve sıfıra göre üst ve alt zarfların simetrisi ile tipik bir İMF	33
Şekil 4.2. Eleme sürecinin gösterimi	35
Şekil 4.2. (devam) Eleme sürecinin gösterimi	36
Şekil 4.3. Tekrarlanan eleme sürecinin etkilerinin gösterimi	37
Şekil 4.4. 1. Hasta için örnek EEG veriler	39
Şekil 4.5 1. Hasta için örnek EEG verileri	40
Şekil 4.6. İlk 5 İMF'nin Hilbert Spektrumları	41
Şekil 4.6. (devamı) İlk 5 İMF'nin Hilbert Spektrumları.....	42
Şekil 4.7. Sinir hücresi	44
Şekil 4.8. Temel Statik Yapay Sinir Hücresi	46
Şekil.4.9. İleri beslemeli 3 katmanlı YSA.....	47
Şekil 5.1. Hastanın 1,2 ve 3. elektrotlarında kaydedilen 1. nöbet anı ve bu andan önceki 3 dakikalık EEG verileri.....	53
Şekil 5.2. 1. Hastanın 4, 5 ve 6. elektrotlarında kaydedilen 1. nöbet anı ve bu andan önceki 3 dakikalık EEG verileri.....	54
Şekil 5.3. Şekil 5.1.'de verilmiş olan EEG verilerinin 45-55 sn arasındaki penceresine ait ham EEG verileri ve bu pencereden elde edilmiş olan İMF'ler.....	55
Şekil 5.4. Nöbet anı EEG sinyali ve bu sinyalden elde edilmiş olan İMF'ler.	58
Şekil 5.5. Nöbet dışı EEG sinyali ve bu sinyalden elde edilmiş olan İMF'ler.	59
Şekil 5.6. Bir hastaya ait <i>nöbet öncesi</i> ve <i>nöbetler arası</i> dosyaları gösterimi	66
Şekil 5.7. Dosyaların gruplandırılması	66
Şekil 5.8. Örnek yanlış alarm gösterimleri	68

1. GİRİŞ

Dünya nüfusunun yaklaşık %1-3'ünü, Türkiye nüfusunun da yaklaşık %1'ini etkileyen epilepsi, bilinen en yaygın nörolojik bozukluktur. Epilepsi, hastayı sadece nöbet anlarında rahatsız eden, bunun dışında normal yaşamına devam etmesini engellemeyen bir hastalıktır. Epileptik nöbet, beyin içerisinde bir grup sinir hücresinin normal olmayan yoğun boşalımı sonucunda ortaya çıkan durumdur. Epileptik nöbet tespiti, epilepsi teşhisinin önemli bir parçasıdır. EEG işaretleri beyin hareketlerinin klinik olarak gözlemlenmesinde en çok yararlanılan yöntemdir. EEG işaretlerini kullanarak epileptik nöbetlerin saptanması, epilepsi tanısı konulmasında önemli bir rol oynamaktadır. Epilepsi tanısında nöbet algılama önemli bir bileşendir. Bu tanı genellikle uzun EEG kayıtlarının uzman hekimler tarafından görsel olarak taranması ile konulur. Bu çok zaman alıcı ve hata oranı yüksek bir yöntemdir. Bu nedenle, EEG sinyallerinin otomatik algoritmalar kullanılarak bilgisayarla analiz edilmesi, bu hastalığın tanısı için çok önemlidir.

Epileptik nöbetlerin, ne zaman ortaya çıkacağı kestirilemeyen ve aniden ortaya çıkarak yıkıcı bir etki gösteren doğası, epilepsi hastalığının kişiyi etkisiz hale getiren en etkileyici yönüdür. Bu nedenle, nöbetin ortaya çıkmasından bir süre önce hastayı uyurabilen bir metot geliştirilmesi bu hastalıkla mücadele eden bireylerin hayatlarını kontrol altında tutabilmeleri ve bazı durumlarda hayati bir tehlike riskini önleyebilmeleri açısından önemlidir. EEG kayıtlarının yüksek zaman çözünürlüğüne sahip olması ve beynin fizyolojik ve patafizyolojik fonksiyonlarını inceleme olanağı vermesi nedeniyle, epileptoloji biliminde EEG kayıtları klinik uygulamalar için vazgeçilmez olarak görülmektedir. Bu nedenle 1970'lerden itibaren araştırmacılar nöbet tahmini üzerinde çalışmaya başlamış ve EEG verileri içerisinde gerçekleşmek üzere olan bir nöbet için ayırt edici olabilecek karakteristik özelliklerin var olup olmadığını araştırmışlardır (Lehnertz vd., 2007). Bu konuda pek çok araştırma yapılmış ancak henüz yaygın olarak kullanılacak standart bir yöntem geliştirilememiştir (Mormann vd., 2007).

EEG işaretleri, dinamik, stokastik, doğrusal olmayan, durağan olmayan, aynı zamanda önemli derecede karmaşık davranış sergileyen kendiliğinden oluşan elektriksel beyin faaliyetleridir. Fourier Dönüşümü ve Dalgacık Dönüşümü gibi geleneksel veri analiz yöntemleri kullanıldığında, zaman serisi verilerinin durağan ve/veya doğrusal

oldukları varsayımı yapılmaktadır. Bu analizlerin EEG verilerine uygulanması durumunda, verilerdeki doğrusal olmayan karakteristikler göz ardı edilmekte, işaretin yalnızca doğrusal dinamikleri incelenebilmektedir. Bu nedenle, EEG işaretlerinin zaman içerisinde nasıl değiştiğini analiz edebilmek amacıyla, tüm veriyi kapsayacak şekilde durağan olmayan genel modellere ihtiyaç duyulmaktadır. Çok çözünürlüklü Dalgacık analizinin 80'lerin sonunda tanıtılması ile birlikte EEG işaretlerinin zaman-frekans analizleri yapılmaya başlanmıştır (Thakor, 1993; Senhadji, 1995; Duman, 2005; Übeyli, 2009). Dalgacık tekniği, Fourier spektral analizini temel almaktadır. Dalgacık analizinde, Fourier analizinde olduğu gibi sabit temel fonksiyonlar kullanmak yerine, durağan olmayan işaretler için zaman-frekans çözünürlüğünü sağlayabilmek amacıyla frekansa bağlı ayarlanabilir pencere fonksiyonları kullanılmaktadır. Ancak Fourier temelli spektral analiz yöntemleri, işaretin dalga bileşenlerinin lineer süperpozisyonundan oluştuğu varsayımına dayanmaktadır. Bu nedenle Dalgacık analizi ile bir işarettaki doğrusal olmama durumu da harmonik bileşenler oluşturması açısından yorumlanır ve bu durum düşük frekanslardaki spektral enerjinin yüksek frekans bileşenlerine akmasına neden olur (Hwang, 2003).

Yüksek derecede doğrusal olmayan ve durağan olmayan karakteristiği bir arada barındıran EEG işaretlerinin tam olarak analiz edilebilmesi için, bu iki özelliği aynı anda incelemeye imkân veren bir metod kullanılmalıdır. 90'lı yılların sonlarına doğru Norden E. Huang tarafından önerilmiş olan, Ampirik Kip Ayrışımı (AKA) ve bu ayrışım sonucunda elde edilen İçsel Mod Fonksiyonlarına uygulanan Hilbert Spektral Analizi metodlarının birleşimi ile elde edilen Hilbert-Huang Transformu (HHT) yöntemi, hem doğrusal hem de durağan olmayan işaretlerin analizine imkân veren, uyarlanabilir bir yöntemdir (Huang, 1998). Fourier tabanlı zaman-frekans analiz yöntemlerindeki gibi önceden belirlenmiş varsayımlara ve temel fonksiyonlara ihtiyaç duymayan AKA metodu yoluyla, işaret, yerel karakteristiklerine göre, her biri tek elemanlı, diğer bir deyişle en küçük zaman biriminde tek frekans içeriğine sahip, sınırlı sayıda fonksiyona ayrılır. Bu fonksiyonlar İçsel Mod Fonksiyonları (İMF) olarak adlandırılırlar. HHT yönteminin sonraki aşaması, AKA yöntemi yoluyla elde edilen İMF'lere Hilbert Dönüşümü uygulanarak zamana karşı anlık frekans değerlerine ulaşılmasıdır.

HHT yöntemi geleneksel yöntemlere nazaran çok yeni olmasına karşın, doğrusal ve/veya durağan olmayan özellikler gösteren işaretlere uygulanabiliyor olması nedeniyle, kısa sürede farklı bilim dallarında uygulama alanı bulmuştur. Yöntem, tanıtılmasından kısa süre sonra konuşma işleme (Huang, 2006), okyanus bilim (Datig, 2004), çevre bilim (Frankze, 2009), ekonomi (Yu, 2008), inşaat bilimleri (Lee, 2003) ve biyomedikal işaret işleme gibi çok farklı bilim dallarında uygulama alanı bulmuştur. EKG verilerinin gürültüden arındırılması (Lu vd., 2009), yüzey elektromiyografi (EMG) işaretlerinden öznitelik çıkarılması (Lei vd., 2009), EMG işaretlerinin filtrelenmesi (Andrade vd., 2006) ve şizofrenik EEG işaretlerindeki faz uyumu (Ziqiang vd., 2007) biyomedikal işaret işleme dalında AKA kullanılarak yapılmış olan çalışmalardan bazılarıdır. Son zamanlarda EEG işaretlerinden epilepsi tespitinde de AKA yöntemi kullanılmıştır (Pachori, 2008; Orosco, 2009). Yapılan bazı çalışmalarda sadece AKA yöntemi, bazı çalışmalarda ise AKA ve Hilbert Dönüşümü beraber (HHT) kullanılmıştır.

Bu çalışmada, Freiburg Üniversite Hastanesi Epilepsi Merkezinde ameliyat öncesi epileptik gözlem altında bulunan hastalardan invaziv olarak alınan verilerden oluşan Freiburg Veritabanındaki iEEG kayıtları, HHT yöntemi ile incelenmiş ve çıkarılan özniteliklere çeşitli sınıflandırma yöntemleri (En Yakın Komşuluk, Karar Ağaçları, Deste Vektör Makinaları, Yapay Sinir Ağları ve Bayes Ağları) uygulanarak nöbet algılama ve tahmin çalışmaları yapılmıştır.

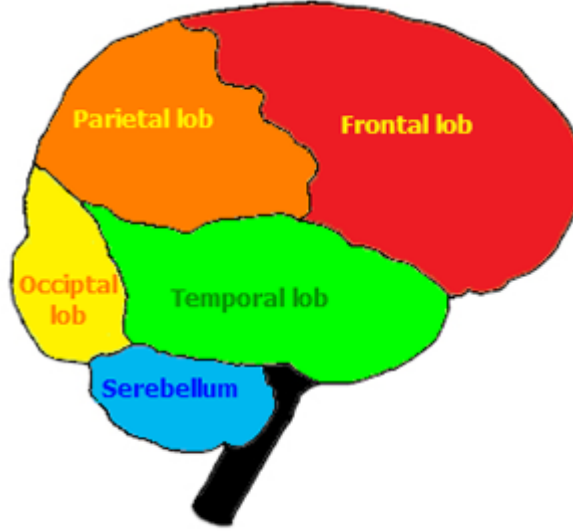
1.1. İnsan Beyni

İnsan beyni dünyamızda yaşayan canlılar arasında en karmaşık yapıya sahip organlardan birisidir. Günümüzde ulaşılan tüm teknolojik ilerlemeye rağmen hala insan beyninin nasıl çalıştığına ilişkin çok az bilgiye sahibiz. Vücudun denge ve karar merkezi olan, bu denli karmaşık görevler üstlenen insan beyni ortalama olarak 1400 gram ağırlığında yağ ve protein dokudan oluşmuş, gri renkli, yüzeyi girintili çıkıntılı bir organdır.

Merkezi sinir sistemimizin bir parçası olan beyin, omurilikle birlikte vücudun karar verme ve iletişim faaliyetlerini yürüten en önemli organdır. Günlük hayatımızda nefes almadan konuşmaya, hareket etmeden, hafızaya kadar bütün faaliyetlerimiz beynin denetimindedir. Çevresel Sinir Sistemi (ÇSS) üzerinden önce omuriliğe oradan

beyine ulaşan sinyaller beyin kabuğu kortekste işlenerek bunlara ilişkin cevaplar gene sinir sistemi vasıtasıyla ilgili kas ve sinir gruplarına iletilir.

Beyin yapısal olarak kendi içinde farklı bölümlere ayrılır, bu bölümlerden en önemlisi her türlü algısal faaliyetin gerçekleştirildiği beyin kabuğudur (serebral korteks). Serebral kortekste kendi içerisinde lob adı verilen 5 bölüme ayrılır.



Şekil 1.1. Beyin lobları

- 1- **Frontal (ön) Lob:** Bilinçli düşünmeyi sağlayan lobdur. Zarar görmesi durumunda ruh hali, hissiyat değişikliği olabilir.
- 2- **Parietal (yan) Lob:** Çeşitli duyu organlarından gelen bilgileri birleştirmede önemli rol oynar. Ayrıca nesnelere kullanılması ve bazı mekansal görüş işlemlerinde parietal lobun bazı bölümleri rol alır.
- 3- **Osipital (arka baş) Lob:** Görme duyusuyla ilgili bilgilerin işlendiği lobdur. Hafif zarar görmesi halüsinasyonlara sebep olur.
- 4- **Temporal (şakak) Lob:** Ses ve kokunun algılanması, aynı zamanda da yüzler, mekanlar gibi karmaşık uyarıların işlenmesi bu lob tarafından sağlanır.
- 5- **Serebellum (beyincik) Lob:** Duyu organlarından gelen bilgilerle hareketi ilişkilendirir. Bu lob özellikle dengenin sağlanmasında önemli rol oynar. Yukarıda listelenen her bir lob, beynin her iki yarımküresinde de bulunur.

1.2. Epilepsi ve Elektroensefalografi (EEG)

Halk dilinde “sara” hastalığı olarak bilinen epilepsi, beyinde meydana gelen önemli rahatsızlıklardan biri olarak günümüzde ciddiyetini korumaktadır. Patolojik beyin hareketlerinin incelenmesinde EEG işaretleri önemli bilgiler taşımakta (Nunez ve Srinivasan, 2006) ve beyin fonksiyonel rahatsızlıklarının özellikle epilepsi hastalığının teşhisinde EEG cihazı Nöroloji Kliniklerinde rutin olarak kullanılmaktadır. Ancak epileptik deşarjların meydana gelmesi esnasında kaydedilen EEG işaretlerinin içerdiği dalga şekilleri diğer bazı beyin rahatsızlıklarındaki dalga şekilleriyle benzerlik gösterdiğinden epilepsi hastalığının çıplak gözle teşhisi zordur ve aynı zamanda zaman alıcı bir işlemdir (Mohammad vd., 2002).


İnsan beyninin elektriksel aktivitesinin görüntülenmesi anlamına gelen elektroensefalogram ilk olarak 1920’li yılların başında Hans Berger tarafından kafaya yerleştirilen elektrotlar ve bunlara bağlı bir galvanometre yardımıyla incelenmiş ve bu dalgalar Elektroensefalografi adı verilen geçerli bir tanı yöntemi olarak tıbbı girmiştir. Günümüzde EEG, klinik alanda epilepsi, şizofreni, Parkinson gibi hastalıkların teşhisinde yaygın olarak kullanılmaktadır. Bunun dışında psikiyatri, pedagoji, pediatri gibi alanlarda kullanımı da gün geçtikçe yaygınlaşmaktadır.

EEG işaretleri beyni oluşturan milyarlarca sinir hücresinin birbiriyle elektriksel etkileşimi sonucu oluşan işaretlerdir. Beyindeki her bir sinir hücresi yüzlerce veya binlerce farklı sinir hücresiyle bağlantılıdır. Bu bağlantılardan bazıları uyarıcı bazıları söndürücü şekilde görev yapar. Beynin elektriksel aktivitesi ölçülürken tek bir sinir hücresinin faaliyetlerini gözlemlemek mümkün değildir. EEG işaretleri ancak birçok sinir hücresinin etkileşiminin bileşkesi olarak incelenebilir. Bu yönüyle EEG işaretleri genel anlamda öngörülemeyen işaretler olarak kabul edilir.

EEG işaretleri genlik ve frekans içerikleri ile tanımlanır. EEG frekans içerikleri, belli aralıklar arasında benzer özellikler taşıdıklarından, frekans bantları altında gruplanmıştır. Her bir frekans bandı, belirli bir sıraya göre değil tarihsel gelişimine paralel olarak rastgele şekilde, Yunan harfleri ile isimlendirilmiştir: Delta (δ), teta (θ), alfa (α), beta (β) ve gamma (γ).

EEG işaretlerinde kişinin psikolojik durumuna veya uyanıklık durumuna bağlı olan değişimler genellikle farklı frekans bantlarının aktif olmasına neden olurlar. Genlik

değerleri yaklaşık olarak aynı seviyede kalmakla beraber EEG işaretlerinin baskın frekans içeriklerinin beynin zihinsel aktivitesi arttıkça yükseldiği söylenebilir.



Şekil 1.2. Beyin dalgaları

Delta Dalgaları: 4 Hz'in altındaki EEG dalgaları (genellikle 0.5-4 Hz) delta bölgesi olarak adlandırılır.

Teta Dalgaları: 4 ile 8 Hz arasında değişen dalgalarıdır.

Alfa Dalgaları: İnsan beyninde en baskın olan beyin dalgalarıdır. 8-13 Hz aralığında uyanık ve sakin insanlarda görülen beyin dalgası türüdür.

Beta Dalgaları: Beyindeki 12-36 Hz arasındaki bütün aktiviteler beta dalgaları olarak adlandırılır. Beta dalgalarının genliği çok seyrek olarak $30 \mu V$ 'in üzerine çıkar.

Düşük Beta: 12-15 frekans aralığındadır. Hareketsiz iken dikkatli olmak bu dalga'nın ortaya çıktığı en iyi durumdur.

Orta Beta: 15-18 frekans aralığındadır. Mental aktivite durumunda görülür.

Yüksek Beta:18-36 sıklığındadır. Aşırı konsantrasyon, uyarı halinde olma ve ajitasyon durumlarında ortaya çıkar.

Gama: 36 Hz ve üstü. Popüler bir teoriye göre gamma dalgaları bilinçli algı birliğinin oluşturulmasında (bağlanma problemi) aktif rol oynamaktadır. (Buzsaki, 2006; Pollack, 1999; Singer and Gray, 1995).

2. ÖNCEKİ ÇALIŞMALAR

1970'lerden itibaren arařtırmacılar nöbet tahmini üzerinde çalışmaya başlamış ve EEG verileri içerisinde gerçekleşmek üzere olan bir nöbet için ayırt edici olabilecek karakteristik özelliklerin var olup olmadığını arařtırmışlardır (Lehnertz vd., 2007). Bu konuda pek çok arařtırma yapılmış ancak henüz yaygın olarak kullanılabilir standart bir yöntem geliřtirilememiştir (Mormann vd., 2007).

2.1. Nöbet Algılama

EEG işaretleri beynin durumu hakkında önemli bilgiler taşıyan işaretlerdir ve bu işaretler beynin farklı durumlarda bulunması halinde (örneğin nöbet anı ya da nöbet dışı anda) deęişiklik gösterecektir. Ancak bu ince deęişiklikler insan gözlemciler tarafından doğrudan gözlenemeyebilir. Bunun başlıca nedeni olarak, biyo-işaretlerin kişilere göre çok farklılık göstermesi ve semptomların zaman ekseninde rasgele olarak ortaya çıkması gösterilebilir. Bu nedenle bu deęişimlerin otomatik sistemler tarafından yapılabilir olması; yorgunluk, dikkatsizlik ya da tecrübe eksikliği gibi nedenlerle yanlış karar verme ihtimali olan, zaman ve emek açısından yüksek maliyetlere neden olabilecek insan gözlemci ihtiyacını en aza indirecektir.

Gürsoy ve Subaşı 2008'de, Andrzejak ve dięerleri (Andrzejakvd., 2001) tarafından tanımlanan EEG veritabanını kullanarak, EEG işaretlerinden epilepsi teşhisinde destek vektör makinelerini kullanarak epileptik ve epileptik deęil şeklinde sınıflandırma yapmışlardır (Gürsoy ve Subaşı, 2008). Bu çalışmada, kontrol ve epileptik deneklerin kayıtları kullanılarak epilepsi teşhisi yapılmıştır. %100 başarı elde edildięi rapor edilmiştir. Epileptik nöbet belirleme çalışmasında Güler, Übeyli ve Güler (Güler vd., 2005) aynı veritabanı üzerinde Yinelenen Sinir Ağlarını (RNN) kullanarak %96.13 duyarlılık ve %97.38 belirlilik elde etmişlerdir.

2008'de 57 hastadan kayıt edilen 91 nöbet üzerinde çalışan Meier ve dięerleri (Meier vd., 2008) %85 ile %100 arasındaki duyarlılık oranlarıyla nöbet algılama yapabildiklerini rapor etmişlerdir. 2009'da Freiburg veritabanınındaki 9 hastanın 39 nöbeti ile nöbet algılama yapılan bir çalışmada (Orosco vd., 2009), epileptik nöbetleri normal verilerden ayırt etmek için AKA yöntemi ile ilk 3 İMF'nin enerji hesaplaması yapılmıştır. 15 saniyelik pencerelerin kullanıldığı bu çalışmada 39 nöbetin 22'si

(%56.41) tespit edilebilmiştir. Analiz edileilen 58 nöbet değil penceresinin 14 tanesi nöbet anı olarak sonuçlanarak %75.86'lık bir belirlilik oranı açıklanmıştır.

Bir başka epileptik nöbet teşhisi çalışmasında, Freiburg veritabanındaki veriler AKA yöntemiyle analiz edilmiştir (Tafreshi vd., 2008). Bu çalışmada ilk 4 İMF kullanılarak %90.69 duyarlılık elde edilmiş, AKA yoluyla elde edilen öznitelikler ile dalgacık dönüşümü öznitelikleri de eklenerek başarı %95.42'ye çıkarılmıştır.

2.2. Nöbet Tahmini

Epileptik hastalarla ilgilenen klinisyenlerin iddialarına göre; hastalar, tam olarak oluşma anını kestiremeseler de, nöbetlerinin başlamasından bir süre önce nöbet geçirme ihtimalinin yüksek olduğu zaman aralıklarını belirleyebilmektedirler. Rajna ve diğerleri, klinik prodrom adı verilen belli belirsiz algılamalar ile hastaların bu zaman aralıklarını karakterize edilebildiğini, inceledikleri 562 hastanın %50'sinden fazlasında görmüşlerdir (Rajna vd., 1997). Küçük hasta grupları üzerinde yapılan bazı fizyolojik çalışmalarda da, nöbet öncesi dönemin varlığını destekleyen bulgulara rastlanmıştır. Weinand ve diğerlerinin çalışmasında, epileptik temporal lob bölgesindeki kan akışının nöbetin başlamasından 10 dakika öncesinde önemli derecede arttığı ve nöbet başlangıcından 2 dakika öncesinde de iki temporal loba yayıldığı rapor edilmiştir (Weinand vd., 1997). Başka çalışmalarla da benzer sonuçlar elde edilerek nöbet öncesi dönemde nöbetin gelmekte olduğunun sinyalinin alınabildiği onaylanmıştır (Baumgartner, 1998; Adelson, 1999). Bunların yanı sıra epileptik nöbetlerin bir grup sinir hücrelerinin normal olmayan yoğun boşalımı sonucunda ortaya çıkan bir durum olduğu ve bu olayın EEG analizi ile kolaylıkla incelenebileceği düşünülmektedir. Bu varsayımlara dayanarak nöbet tahmini yapabilmek için EEG verileri kullanılarak pek çok çalışma gerçekleştirilmiştir (Mormann vd., 2007). Nöbet tahmini; nöbet öncesi durumu, nöbetin gerçekleşmesinden yeteri kadar uzun bir süre öncesinde belirleyebilmeyi amaçlamaktadır. Bu amaçla kullanılan nöbet tahmin algoritmaları genel olarak iki temel adım içermektedir: (1) EEG verilerinden özniteliklerin seçimi, (2) bu özniteliklerin ve doğal olarak hastanın durumunun, 'Nöbet Öncesi' ya da 'Nöbetler arası' şeklinde sınıflandırılması (Lehnertz, 2005; Mirowski, 2008). Bazı çalışmalarda sınıflandırma basit eşikleme yöntemi kullanılarak yapılmış, bazıları ise daha gelişmiş olan

sınıflandırma yöntemleri (örneğin Destek Vektör Makineleri, Yapay Sinir Ağları, k-Means Sınıflandırma, Genetik Algoritmalar vs.) kullanılarak gerçekleştirilmiştir.

Rogowski, Gath ve Bental, 1981'deki çalışmalarında 12 epileptik hasta üzerinde 8 kanallı EEG çekimleri yapmış ve nöbet öncesi EEG kayıtlarını lineer bir model olan özbağlanımlı model kullanarak incelemişlerdir (Rogowski vd., 1981). Özbağlanım katsayılarını nöbet tahmincisinin kutuplarının hesaplanmasında kullanmış ve tahmin edici olarak kullandıkları parametrelerin, nöbetin gerçekleşmesinden birkaç saniye öncesinde (0.6 – 6sn), nöbet tahminine yardımcı olacak şekilde bir yol izlediklerini ve böylece nöbet tahminine yardımcı olabileceğini göstermişlerdir. Yaptıkları çalışmada, 12 hastanın 10'unda ve inceledikleri 28 kayıtlı nöbetin 25'inde tahmin edicinin kutuplarının nöbet oluşumuna bağlı olarak spesifik bir yol izlediğini rapor etmişlerdir.

Bir başka çalışmada, 5 denek üzerinde inceleme yapan Siegel, Grady ve Mirsky, nöbet öncesi periyotta 20 saniyelik epoklarda 0-50 Hz arası 2'şer Hz'lik bant genişlikleri kullanarak güç spektrumunu hesaplamışlar ve bu değerleri nöbet dışı anlarda elde edilen değerler ile karşılaştırarak sınıflandırma yapmışlardır (Siegel vd., 1982). Bu çalışmada %64 - %83 oranında doğru sınıflandırma yaptıklarını ve her hastanın nöbet öncesi EEG kayıtlarının kendine özgü bir değişiklik gösterdiğini ve ortak bir belirtinin tespit edilemediğini rapor etmişlerdir.

Gotman 1983'te, epileptik hastalardan kafatası dışından ve içinden alınan EEG kayıtlarının uyumluluk ve faz spektrumlarını incelemiş, epileptik fokus bölgesinden alınan EEG zaman serilerinin istikrarlı bir şekilde diğer kayıt alınan bölgelerden önde gittiğini tespit etmiştir (Gotman, 1983). 1987'de yaptığı çalışmada, 8 epileptik hastadan aldığı intrakranyal (kafa içine yerleştirilen elektrotlarla alınan) EEG verilerinde, simetrik kontralateral kayıtlar arasındaki etkileşim derecesini yine uyumluluk yöntemi ile incelemiş ve beyin yarım küreleri arasındaki uyumluluğun en yüksek değere erken nöbet anında ulaştığını ve bu değer nöbet süresince düşük seyrettiğini göstermiştir (Gotman, 1987). Ayrıca, incelenen çoğu durumda, nöbet süresince, fokus noktasının bulunduğu tarafın zaman serilerinin önde gittiği belirtilmiştir.

1992'de fareler ve intrakranyal veriler üzerinde yapılan çalışmada çok değişkenli özbağlanımlı (MVAR) model kullanılarak amigdala ve hippokampus arasında nöbet sırasında artan ve 0.9'dan daha yüksek değere ulaşan senkronizasyon tespit edilmiş ve nöbet tahmininde, çok kanallı süreçlerin tek kanal süreçlerinden daha iyi sonuç

verebileceği iddia edilmiştir (Gath vd., 1992). Bu çalışmadan yola çıkarak, parametrik MVAR modeli, epileptik yüzey EEG verilerine uygulanmış ve 5 hastadan alınan pek çok nöbet kaydı incelenerek nöbet tahmin süresi 1-6 saniye olarak rapor edilmiştir (Salant vd.,1998).

80'lerin ortalarında beyin aktivitelerinde kaotik dinamiklerin varlığına dair kanıtlar gösterilmeye başlanmış (Babloyantz vd., 1985) ve beyin dinamiklerindeki değişikliklerin analizi için doğrusal olmayan zaman serileri analizi kullanılan çalışmalar başlamıştır. Iasemidis, Olson, Savit ve Sackellares; orijinal verilerden elde edilen faz uzayında şartlı olasılık analizi kullanarak, nöbetlerin ortaya çıkma durumlarının önceki nöbetlerin ortaya çıkması ile bağlantılı olduğunu göstermişler (Iasemidis vd., 1994). 1998'de Martinerie ve çalışma arkadaşları, 11 epileptik hasta üzerinde yaptıkları çalışmada nöbet öncesi dönemde bağıntı yoğunluğu ölçüsünde azalma olduğunu belirtmiş ve bu bilgiyi kullanarak inceledikleri 19 nöbetin 17'sini 2-6 dakika öncesinden tahmin edebildiklerini rapor etmişlerdir (Martinerie vd., 1998). Yine aynı grup daha sonra geliştirdikleri dinamik benzerlik indeksi ölçüsünü kullanarak pek çok çalışma gerçekleştirmişlerdir (Le Van Quyen vd., 1999; Le Van Quyen vd.,2000; Le Van Quyen vd., 2001). Daha sonraki yıllarda faz senkronizasyonunun nöbet anı verileri nöbet öncesi verilerden ayırmak için kullanılabilir bir ölçü olduğu belirtilmiştir (Mormann vd., 2003 a,b; Le Van Quyen vd., 2005).

Burada bahsedilen metotların çoğu eşikleme yöntemi kullanılarak sınıflandırma yapmaktadır. Sınıflandırma algoritmaları EEG işaretlerinin işlenmesinde sıkça kullanılmaktadır. Petrosian ve diğerleri sınıflandırma için Yinelenen Sinir Ağlarını kullanarak nöbetlerden yaklaşık 60 sn öncesinde sinyallerdeki değişimin fark edilebildiğini belirtmişlerdir (Petrosian vd., 2000). Olasılıksal Sinir Ağları kullanarak nöbetöncesi ve nöbetlerarası sınıflandırması yapan D'Alessandro ve diğerleri 3.455 dakikalık tahmin süresi, %62.5 duyarlılık ve %90.47 belirlilik belirtmişlerdir (D'Alessandro vd., 2003).

1990'lardan itibaren yapılan bu çalışmalarda çok umut verici sonuçlar elde edilmiş olmasına rağmen, 2000'lerin ortalarına doğru bu optimistik sonuçlar tekrar elde edilmeye çalışılmış (Winterhalder vd., 2003; Maiwald vd., 2004) ancak başarılı olunamamıştır. Bu nedenle daha önce ortaya konulmuş olan yöntemlerin geçerliliği ve güvenilirliği konusunda şüpheler doğmaya başlamıştır (Mormann vd., 2007). Bunun

yanı sıra; yapılmış olan çalışmaların, farklı hasta ve nöbet sayısına ve epilepsi tipine sahip gruplar üzerinde yapılmış olması, nöbet tahmin ölçütlerinin tam olarak tanımlanmış olmaması, bazı çalışmalarda sadece nöbet öncesi dönemin incelenerek, elde edilen algoritmanın nöbetlerarası kontrol döneminde uygulanmadan sadece duyarlılık oranının incelenmesi ve yanlış tahmin oranına bakılmaması nedeniyle nöbet tahmin algoritmalarının objektif olarak karşılaştırılmadığı iddiaları ortaya atılmıştır (Jerger vd., 2001; Maiwald vd., 2004). Jerger, Netoff, Francis ve diğerleri, tedavi edilemez epilepsi nedeniyle ameliyat öncesi gözlemlenilen 4 çocuk hastadan aldıkları intrakraniyal kayıtlarda 12 nöbet kaydını incelemiş ve bu veriler üzerinde 7 farklı lineer ve nonlineer yöntemi denemiştirler (Jerger vd., 2001). Maiwald, Winterhalder, Aschenbrenner-Scheibe ve diğerleri yaptıkları çalışmada üç farklı yöntemi 21 hastadan topladıkları yüksek kaliteli uzun süreli EEG kayıtları üzerinde denemiştirler (Maiwald, 2004).

2.3. Ampirik Kip Ayrışımı Kullanılarak Yapılan Çalışmalar

Liang vd. (2005)'de yaptıkları çalışmada, makak maymunlarının görsel uzaysal dikkat deneyi esnasında, V4 görsel kortikal bölgesindeki nöronal faaliyetleri incelemek için AKA yöntemi kullanmış ve Kısa zamanlı Fourier analizi ile karşılaştırma yapmışlardır. Bu çalışmada, maymunların renk değişimine odaklandıkları süre içerisinde, her iki yöntemin de hem zaman hem de uzayda gamma bandında enerji yoğunlaşmasını tespit edebildikleri, bununla beraber AKA yönteminin Fourier Dönüşümüne göre daha iyi uzaysal ve zamansal çözünürlük sağlayabildiği gösterilmiş ve AKA yönteminin anlık frekans analizi ile birleştiğinde nöral verilerin analizi için önemli bir teknik olduğu ortaya konulmuştur. Sweeney vd. (2007)'de kavrama işleminin temelini oluşturduğu düşünülen geçici nöronal gruplaşmaya neden olan belli frekanslar arasındaki faz senkronizasyonu AKA metodu yoluyla istatistiksel bir çerçevede incelenmiş ve AKA yönteminin, senkronizasyonun zamanda ve frekansta lokalizasyonu konusunda, var olan yöntemlere göre daha iyi sonuç verdiği gösterilmiştir.

Weng vd. (2006)'da AKA yöntemini kullanarak EKG (elektrokardiyogram) işaretlerinde gürültü temizliği yapmıştır. Yapılan çalışmada ilk 3 İMF toplanmış ve son kısım işaretten çıkarılmıştır. Sonuç olarak AKA yoluyla, EKG sinyal kalitesi korunmak suretiyle yüksek frekanslardaki gürültünün temizlenebildiği rapor edilmiştir. Bir başka

çalışmada yine AKA yöntemiyle elde edilen İMF'lerin sonuncusu atılarak Elektroretinogram (ERG) sinyallerinde başarıyla gürültü temizliği yapılmıştır (Latifoğlu vd., 2010)

Diez vd. (2009)'da yaptıkları çalışmada Beyin Bilgisayar Arayüzü (BCI) için zihinsel görevler sınıflandırmasında AKA yöntemi ile EEG sinyallerinden çıkardıkları öznelikleri kullanarak sınıflandırma yapmışlar ve %91 (+/- 5) başarı elde etmişlerdir. Bu çalışmada ilk 5 İMF'ye bakılmış ve ilk 3 İMF kullanılarak yapılan sınıflandırmada en iyi sonuç alınmıştır.

AKA yöntemi son yıllarda epileptik nöbet teşhisinde yoğunlukla kullanılmaya başlanmıştır. Pachori (2008)'de AKA yöntemi ile elde edilen İMF'lerin ortalama frekansına Fourier-Bessel açılımı kullanılarak elde edilmiş nöbet anı EEG sinyalleri ile nöbet dışı anlardaki EEG sinyalleri arasında istatistiksel olarak anlamlı fark olduğu gösterilmiştir. Bu yöntemde ilk 4 İMF kullanılmıştır. Bir başka epileptik nöbet teşhisi çalışmasında, epileptik nöbet verileri ve nöbetler arası veriler AKA yöntemiyle analiz edilmiş (Tafreshi vd., 2008), normal ve epileptik nöbet sinyallerinin özelliklerini elde etmek için AKA yöntemi kullanılmış ve yapılan çalışmada ilk 3, 4, 5 ve 6 İMF toplanarak sınıflandırma yapılmış ve ilk 4 İMF kullanılarak yapılan sınıflandırma da en yüksek başarı sağlanmıştır. Orosco vd. (2009)'da yaptıkları çalışmada epileptik nöbetlerin normal verilerden ayırt etmek için AKA yöntemi kullanılmış ve ilk 3 İMF'nin enerji hesaplaması yapılmıştır.

2.4. Hilbert-Huang Transform Yöntemi Kullanılarak Yapılan Çalışmalar

Hu vd. (2005)'de Normal ve Hipoksi (oksijen yetmezliği durumu) EEG işaretlerini sınıflandırmak için HHT yöntemini kullanmışlar ve hipoksi derecesine göre değişmek koşuluyla bu iki durumun birbirinden ayırt edilebildiğini göstermişlerdir. Bu çalışmada şiddetli hipoksi durumundaki 2 hasta için %97.5, hafif hipoksi durumundaki 1 hasta için %77.5 doğru sınıflandırma oranına ulaşıldığı rapor edilmiştir. Cui vd. (2005)'de interiktal alanda epileptik nöbetlerin karakteristik işaretlerini tespit etmek için, AKA, Hilbert Dönüşüm ve SNEO (Smoothed Nonlinear Energy Operator) yöntemlerini birleştiren yeni bir algılama algoritması kullanmışlardır. Bu yöntemde ilk 2-7 İMF'ler kullanılmış ve nöbet dikenleri %96.25 duyarlılıkla tespit edilmiştir.

Li (2006)'da beyin hastalıklarının mekanizmasını anlamak ve sinirsel bilgi işlemek amacıyla nöronal salınım frekans analizi yapmıştır. Nöronal salınımların anlık frekans zaman dağılımı ve Hilbert spektrum ile incelemiştir. Bu amaçla, yaptığı çalışmada epileptik sığınların hipokampus içindeki nöronal salınım analizlerini HHT yöntemi kullanarak yapmıştır. Sharabaty vd. EEG verilerinde Alfa ve Teta dalgalarının otomatik olarak ayırmak için HHT yöntemine dayalı bir algoritma sunmuşlardır (Sharabaty vd., 2006)

Eftekhar vd. (2008)'de yaptıkları çalışmada EKG ve invaziv EEG verilerinin HHT yöntemi ile frekans ve genlik değişmesi, epileptik nöbet ve kardiyak aritmi tespiti açısından incelenmiştir.

Bir başka çalışmada, EEG sinyalleri HHT yöntemi kullanılarak otomatik bir uyku aşaması sınıflandırma yöntemi önerilmektedir (Li vd., 2009). EEG enerji-frekans dağılımı her uyku aşaması özellikleri parametre olarak kullanılmıştır.

Wei vd. (2009)'da yapılan çalışmada beyin bilgisayar ara yüzünün farklı zihinsel görevleri uzaysal-zaman-frekans olarak sınıflandırmak için HHT yöntemi kullanılmıştır. Dört konuda sınıflandırma testi yapılmış ve ortalama %85.9 (%77-%95 arası) doğruluk oranı elde edilmiştir. Önceki yöntemlerle karşılaştırıldığında görsel hareketleri tanımlayan makul bir performans tespit edilmiştir. 2010 yılında yapılan bir çalışmada, sağlıklı çocuklardan alınan EEG verileri üzerinde uyku iğneciklerini karakterize etmek için HHT yöntemi kullanılmış ve mevcut yöntemlere göre gelişmiş sonuçlar elde edildiği rapor edilmiştir (Causa vd., 2010). Yapılan çalışmalarla ilgili olarak (Çizelge 2.1)'de özetleme yapılmıştır.

Bu tez çalışmasında; biyomedikal işaret işleme alanında, epileptik nöbet algılama da dahil olmak üzere, bir çok çalışmada kullanılarak başarılı sonuçlar vermiş olan HHT yöntemi invaziv EEG işaretlerinden nöbet tahmininde kullanılmak üzere öznitelik çıkarımında kullanılmıştır. Sınıflandırma yöntemi olarak BAYESNet ve YSA kullanılarak nöbet öncesi dönem bulunmaya çalışılmıştır.

Çizelge 2.1. AKA ve HHT Kullanılarak Yapılan Çalışmalar. AKA: Ampirik Kip Ayırımı; HHT: Hilbert Huang Transform; İMF: İçsel Mod Fonksiyonları

Çalışma Grubu	Kullanılan Yöntem	Kullanılan İMF'ler
Flandrin vd. (2004)	AKA	Belirtilmemiş
Rillinge vd. 2003	AKA	Belirtilmemiş
Deering ve Kaiser, 2005	AKA	Belirtilmemiş
Liang vd. (2004)	AKA	Belirtilmemiş
Sweeney vd. (2007)	AKA	Belirtilmemiş
Junsheng vd. (2006)	AKA	Belirtilmemiş
Weng vd. (2006)'da	AKA	İlk 3 İMF
Pachori (2008)	AKA	İlk 4 İMF
Tafreshi vd.(2008)	AKA	İlk 3,4,5,6. İMF (en başarılı ilk 4 İMF)
Diez vd. (2009)	AKA	İlk 5 İMF (en başarılı ilk 3 İMF)
Orosco vd.(2009)	AKA	İlk 3 İMF
Latifoğlu vd.(2010)	AKA	Son İMF atılarak, bütün İMF'ler kullanılmış
Hu vd. (2005)	HHT	Belirtilmemiş
Cui vd. (2005)	HHT	İlk 2-7 İMF
Li (2006)	HHT	Belirtilmemiş
Sharabaty vd. (2006)	HHT	Belirtilmemiş
Eftekhar vd. (2008)	HHT	Belirtilmemiş
Li vd.(2009)	HHT	Belirtilmemiş
Wei vd. (2009)	HHT	Belirtilmemiş
Causa vd. (2010)	HHT	Belirtilmemiş

3. MATERİYAL

3.1. Freiburg Veritabanı

Freiburg Veritabanındaki EEG kayıtları, Freiburg Üniversite Hastanesi Epilepsi Merkezinde ameliyat öncesi epileptik gözlem altında bulunan hastalardan invaziv olarak alınan verilerden oluşmaktadır (Maiwald vd., 2004). Bu kayıtlar nerede kullanılacağına belirtilmesi, Freiburg Epilepsi merkezinin yazılı izni olmadan paylaşılması ve bu veriler kullanılarak elde edilecek sonuçların izin alınmadan yayımlanmaması şartıyla araştırmacıların kullanımına açılmıştır.

EEG veritabanı, tıbbi açıdan zorlu olarak nitelendirilen 21 hastadan invaziv yöntemlerle elde edilmiştir. Veriler ameliyat öncesindeki epilepsi izleme kayıtlarıdır. Hastalardaki epileptik yoğunlaşma noktaları 2 farklı bölgede belirlenmiştir. Epileptik odak, 11 hastada neokortikal beyin bölgesinde, 8 hastada hipokamp bölgesinde bulunmaktadır. Diğer 2 hastada belirtilen her iki bölgede de epileptik odak saptanmıştır. Yüksek bir sinyal gürültü oranı elde etmek, bozulma etkilerini azaltmak ve direkt olarak bu yoğunlaşma bölgelerinden bilgi alabilmek amacıyla elektrotlarda bazı düzenlemelere gidilmiştir. Ölçümler için 6 adet elektrot kullanılmış olup, bu elektrotların 1-3 nolu elektrotlar fokal olarak adlandırılan nöbet başlangıç bölgesine, 4-6 nolu elektrotlar ise extrafokal olarak adlandırılan nöbetle ilişkilendirilebilecek en son noktalara yerleştirilmiştir. Elektrot tipi olarak ızgara, şerit veya derin elektrot tipleri kullanılmıştır. EEG verileri, 128 kanallı Neurofile NT dijital video EEG sistemi ile, 256 Hz örnekleme frekansı ve 16 bitlik analog-dijital çevirici kullanılarak kaydedilmiştir. Almanya'daki elektrik hattı gürültüsü 50 Hz olarak belirtilmiş ancak orijinal verilere herhangi bir filtre uygulanmamıştır.

Her hasta için "iktal" (nöbet) ve "interiktal" (nöbetlerarası) verisetleri kaydedilmiştir. Iktal veriler nöbet anını ve nöbet öncesinde kaydedilen en az 50 dakikalık nöbet öncesi (pre-iktal) veriyi kapsamaktadır. Interiktal veriler ise yaklaşık 24 saatlik, nöbet aktivitesi içermeyen verilerden oluşmaktadır. 13 hasta için en az 24 saatlik kesintisiz kayıt mevcuttur. Diğer hastalar için, sürekli olmayan kayıtlar en az 24 saatlik veri oluşacak şekilde birleştirilmiştir.

Kullanılan ızgara, şerit ve derin elektrotlardan altı tanesi, lisanslı bir epileptolog tarafından görsel inceleme yoluyla seçilmiştir. Bu 6 elektrotlardan üç tanesi epileptik

nöbetin başlangıç bölgesinden, diğer bir deyişle erken iktal aktivitenin görüldüğü bölgelerden; kalan üç tanesi ise nöbet aktivitesinin gözlemlenmediği ya da nöbet ile en son ilişkilendirilebilecek bölgelerden seçilmiştir.

Hastalarda kullanılan elektrot tipleri (Çizelge 3.1.) ve bazı hastalar için elektrotların yerleştirme şekilleri (Şekil 3.1.) aşağıda belirtilmiştir.

Çizelge 3.1. EEG Veri ve Hasta Karakteristikleri Nöbet Tipleri: BP, Basit Parsiyel Nöbet; KP, Kompleks Parsiyel Nöbet; ve JTK Jeneralize Tonik-Klonik nöbet; ElektrotTipleri: 1, ızgara elektrot; ş, şerit elektrot; d, derin elektrot

Hasta	Cinsiyet	Yaş	Nöbet Tipi	Nöbet Başlangıç Bölgesi	Elektrot Tipi	Nöbet Sayısı	Interiktal Kayıt Süresi (Saat)
1	K	15	BP,KP	Frontal	1,ş	4	24
2	E	38	BP,KP,JTK	Temporal	d	3	24
3	E	14	BP,KP	Frontal	1,ş	5	24
4	K	26	BP,KP,JTK	Temporal	d,1,ş	5	24
5	K	16	BP,KP,JTK	Frontal	1,ş	5	24
6	K	31	KP,JTK	Temporal-Occipital	d,1,ş	3	24
7	K	42	BP,KP,JTK	Temporal	d	3	25
8	K	32	BP,KP	Frontal	1,ş	2	24
9	E	44	KP,JTK	Temporal-Occipital	1,ş	5	24
10	E	47	BP,KP,JTK	Temporal	d	5	24
11	K	10	BP,KP,JTK	Parietal	1,ş	4	24
12	K	42	BP,KP,JTK	Temporal	d, 1,ş	4	25
13	K	22	BP,KP,JTK	Temporal-Occipital	d,ş	2	24
14	K	41	KP,JTK	Frontal-temporal	d,ş	4	24
15	E	31	BP,KP,JTK	Temporal	d,ş	4	24
16	K	50	BP,KP,JTK	Temporal	d,ş	5	24
17	E	28	BP,KP,JTK	Temporal	ş	5	24
18	K	25	BP,KP	Frontal	ş	5	25
19	K	28	BP,KP,JTK	Frontal	ş	4	24
20	E	33	BP,KP,JTK	Temporoparietal	d,ş	5	26
21	E	13	BP,KP	Temporal	ş	5	24

Aşağıda, veritabanındaki 21 hastada görülen nöbet tipleri ile ilgili açıklamalar yer almaktadır.

Basit Parsiyel Nöbetler;

Bu nöbetlerde hasta nöbet geçirirken tek bir bulgusu vardır, vücudun belirli bir bölgesini tutar. Örneğin bir ayakta ya da kolda kasılmalar nitelikli epilepsi türüne basit parsiyel motor nöbetler denir.

Kompleks Parsiyel Nöbetler;

Yukarıda sözü edilen nöbetlere bilinç bozukluğu eşlik ettiğinde kompleks parsiyel nöbetler terimi kullanılır

Jeneralize Tonik Klonik Epileptik Nöbetler;

Elektrik boşalması, beyin korteksinin salt bir bölümüne ait ise kısmi; tüm beyni aynı anda etkiliyor ise jeneralize nöbet olarak tanımlanır. Epilepsi nöbeti denince insanların aklına en çok gelen, ancak istatistik olarak en sık rastlanana olmayan, jeneralize tonik-klonik nöbetlerdir. Bu nöbetler iki aşamada gelişir: Birinci aşamada (tonik) kişi bilincini kaybeder ve yere düşer, vücut kaskatı bir hal alır. İkinci aşamada (klonik), uzuvlar titremeye ve gerilmeye başlar. Nöbet sona erdikten bir süre sonra bilinç yavaşça tekrar kazanılır.

Freiburg veritabanındaki veriler her bir hasta için şu şekilde düzenlenmiştir:

Bir adet bilgi dosyası;

Hastanın geçirdiği nöbetlerin bulunduğu dosyaların isimleri (bu dosyalar iktal veriler klasöründe bulunmaktadır) ve hastanın geçirdiği her bir nöbetin o dosya içerisinde başlangıç ve bitiş örnek sayıları verilmektedir. Kayıt sırasında belirlenen artefaktların örnek sayıları, herhangi bir sebeple kayıtlarda bir kesilme olmuşsa elektrot bağlantısının kesildiği (EBD) ve yeniden bağlantının sağlandığı (EBR) örnek sayıları bu dosyada belirtilmektedir. Ayrıca o hasta için seçilen elektrotların hangi elektrotlar oldukları sırasıyla gösterilmektedir.

Preiktal ve iktal verilerin bulunduğu klasör;

Hastanın geçirdiği nöbetler ve her bir nöbetin öncesindeki yaklaşık 50 dakikalık veriler bu klasörde yer almaktadır. Dosyalar, her biri yaklaşık 1 saatlik veri saklayacak şekilde bölünmüştür. Bazı nöbet kayıtları 2 farklı dosya yayılmış şekilde olabilmektedir.


İnteriktal verilerin bulunduğu klasör;

Hastaya ait nöbetler arası verilerin bulunduğu bu klasörde her biri yaklaşık 1 saatlik veri bulunduran dosyalar bulunmaktadır.

İndirilen, iktal ve İnteriktal veriler ASCII formatındadır. Bu çalışmada işaretler, MATLAB programı kullanılarak analiz edilmiştir. Bu nedenle, öncelikle ASCII formatında olan veriler .mat formatına dönüştürülerek saklanmış ve MATLAB ortamında kullanımını kolaylaştırılmıştır. Bu dönüşümün yanı sıra veriler 4 sınıfa ayrılmıştır. Bu sınıflar; **nöbet öncesi**, **nöbet anı**, **nöbet sonrası** ve **nöbet dışı** anlardır. Hastalar için sağlanan bilgi dosyaları kullanılarak iktal veri dosyalarından “nöbet anı”, “nöbet dışı an”, “nöbet öncesi” ve “nöbet sonrası” anlar çıkarılarak ayrı ayrı kaydedilmiştir. Hasta için belirtilen artefaktlar ve elektrot bağlantısının kesik olduğu durumlardaki örnekler veri dosyalarından çıkarılmıştır.

3.2. Freiburg Veriseti Kullanılarak Yapılan Çalışmalar

Bu veritabanı kullanılarak yapılan ilk çalışma Freiburg Veri Analiz ve Modelleme Merkezi tarafından 2003 yılında gerçekleştirilmiştir (Aschenbrenner-Scheibe vd., 2003). Bu çalışmada elde edilen yanlış pozitif oranı (FPR) saatte 0.1'den küçük (<0.1 FPR/saat) ve duyarlılık ise %8.3 – %38.3 olarak açıklanmıştır. Aynı grubun yaptığı bir diğer çalışmada üç farklı yöntem karşılaştırılmıştır (Maiwald, 2004). Karşılaştırılan yöntemlerden, günde 1 - 3.6 yanlış tahmin oranı (0.042 – 0.15 FPR/saat) ve %21 - %42 duyarlılık oranı ile dinamik benzerlik indeksinin en iyi sonucu verdiği bildirilmiştir. Aynı yanlış tahmin oranları için, biriktirilmiş enerji kullanılarak %17.9 - %30.5 duyarlılık oranı ve efektif korelasyon boyutu kullanılarak %12.8 - %29.3 duyarlılık oranı elde edilmiştir. Elde edilen bu sonuçların, daha önce aynı yöntemler kullanılarak başka veri setleri üzerinde yapılan çalışmalarda elde edilen sonuçlardan tamamen farklı olması daha önce belirtildiği üzere yöntemlerin geçerliliği ve güvenilirliğinin sorgulanmasına neden olmaktadır. Sonuçların daha iyi karşılaştırılabilmesi açısından bu yöntemler kullanılarak yapılmış olan çalışmalar Çizelge 3.2.'de verilmektedir.



Şekil 3.1. 1, 2, 3, 4, 5, 6,9. Hastaların elektrotlarından bazılarının yerleştirme şekilleri (Freiburg veritabanından örneklenmiştir)

Çizelge 3.2. Değişik Yöntemler Kullanılarak Yapılan Nöbet Tahmin Çalışmaları. DBİ: Dinamik Benzerlik İndeksi, BE: Biriktirilmiş Enerji, EK: Efektif Korelasyon yöntemleri kullanılarak yapılan çalışmalar. iEEG: Intrakranyal EEG, sEEG: Surface EEG

Çalışma Grubu	Hasta Sayısı	İncelenen Nöbet Sayısı	EEG Veri Tipi	İnteriktal Kontrol Verileri (Saat)	Ort. Tahmin Süresi (dk)	Duy. (%)	Yanlış Tahmin Sayısı (FPR/h)	Yöntem
[Le Van Quyen vd 1999]	13	23	iEEG	0	5.75	83	-	DBİ
[Le Van Quyen vd 2000]	9	17	iEEG	0	4.45	94	-	DBİ
[Le Van Quyen vd 2001]	23	26	sEEG	0	7	96.1	-	DBİ
[Navarro vd 2002]	11	41	iEEG sEEG	12-60	7.54	83	0.3	DBİ
[Winterhalder vd 2003]	21	88	iEEG	509	-	42	0.15	DBİ
[Navarro vd 2005]	13	129	iEEG	0	12	64	-	DBİ
[Litt vd 2001]	5	30	iEEG	50	18.5	90	0.12	BE
[Maiwald 2004]	21	88	iEEG	509	-	30.5	0.15	BE
[Gigola vd 2004]	4	13	iEEG	10.5	-	92	0	BE
[Esteller vd 2005]	4	42	iEEG	168	85.38	71.6	0.11	BE
[Lehnertz and Elger 1998]	16	16	iEEG	16.9	12	94	0	EK
[Lehnertz vd 2001]	59	95	iEEG	115	19	47	0	EK
[Aschenbrenner-Scheibe vd 2003]	21	88	iEEG	509	-	42	0.15	EK

4. YÖNTEM

4.1 Hilbert-Huang Transformu

EEG işaretleri, dinamik, stokastik, doğrusal olmayan, durağan olmayan, aynı zamanda karmaşık davranış sergileyen, kendiliğinden oluşan elektriksel beyin aktiviteleridir. Geleneksel veri analiz yöntemleri kullanıldığında, zaman serileri verilerinin doğrusal ya da durağan oldukları varsayımı yapılmaktadır. Örneğin, Fourier Transformu, hem doğrusal hem de durağan olduğu varsayılan işaretlere uygulanırken, Dalgacık Dönüşümü durağan olmayan doğrusal işaretlere uygulanabilmektedir. Bu analizlerin EEG verilerine uygulanması durumunda, verilerdeki doğrusal olmayan karakteristikler gözardı edilmekte, işaretin yalnızca doğrusal dinamikleri incelenebilmektedir. Diğer işaret işleme tekniklerine göre çok yeni olan Hilbert-Huang Transformu (HHT), 1996 yılında Norden E. Huang tarafından önerilmiş (Huang vd., 1996), hem doğrusal hem de durağan olmayan işaretlerin analizine imkan veren bir işaret işleme yöntemidir. Bu yöntem sayesinde EEG işaretleri tam olarak analiz edilebilmekte ve bu işaretlerin içerdiği tüm özellikler incelenebilmektedir.

HHT, yakın zamanda Huang ve çalışma arkadaşları tarafından tanıtılan Ampirik Kip Ayrışımı (AKA) ve Hilbert Spektral Analizi metotların birleşimi ile elde edilen tekniğe verilen isimdir. Bu teknik özellikle doğrusal olmayan ve durağan olmayan işlem ve işaretleri analiz etmek için geliştirilmiştir. İşaretin analiz edilebilmesi için anlık frekans değerlerinin zamana göre değişimi elde edilmelidir. Herhangi bir işaretin anlık frekans değerleri Hilbert Transformu ile işaretin bir anda sadece bir frekans içeriğine sahip olduğu varsayımı kullanılarak bulunabilir. EEG işaretleri herhangi bir anda birden fazla frekans içeriğine sahip olabilen geniş bantlı işaretler oldukları için HHT direk olarak EEG işaretlerine uygulanamamaktadır. Huang bu problemi çözebilmek için işareti, İçsel Mod Fonksiyonu (İMF) adını alan, herbiri anlık olarak tek frekans içeriğine sahip fonksiyonların toplamı şeklinde ifade etmeyi önermiştir. AKA metodu yardımıyla işaret iteratif bir işlem kullanılarak İMF'lere ayrılır.

4.2. Veri İşleme Metotlarının Gözden Geçirilmesi

Metotların çoğu hala Fourier analizine dayandığı için sadece lineer sistemlerle sınırlıdır. Mevcut metotların herhangi birisinin benimsenmesi uygulamanın yapıldığı alanın özelliğine göre belirlenir.

4.2.1. Spektrogram

Spektrogram sadece sınırlı zamanlı pencere-genişlik Fourier spektral analizinden ibaret olan en temel metottur (Haykin, 1991). Pencere zaman eksenini boyunca sırayla kaydırılarak, bir zaman-frekans dağılımı elde edilir. Geleneksel Fourier spektral analizine dayandığı için veri kısmi durağan kabul edilmelidir. Bu kabul durağan olmayan veride her zaman doğrulanamaz. Veri kısmi durağan olsa bile, benimsenen pencerenin her zaman durağan zaman skalaları ile çakışacağı garanti edilemez. Ayrıca, metodu uygulamada pratik zorluklarda vardır. Bir olayı zaman içinde lokalize etmek için pencere genişliği dar olmalıdır, öte yandan, frekans çözümü daha uzun zaman serileri gerektirmektedir. Bu çatışan gereksinimler metodu sınırlı kullanıma düşürür. Ancak, hızlı Fourier dönüşümüyle uygulanması son derece kolaydır; bu yüzden geniş bir kullanım bulmaktadır. Bu metot genellikle konuşma modeli analizinin niteliksel gösterimi için kullanılmaktadır (Oppenheim ve Schaffer, 1989).

4.2.2. Dalgacık Analizi

Dalgacık yaklaşımı esas olarak aşağıda genel tanımı olan bir ayarlanabilir pencere Fourier spektral analizidir.

$$W(a; b; X, \psi) = |a|^{-1/2} \int_{-\infty}^{\infty} X(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (4.1)$$

Burada $\psi^*(.)$ belirli genel koşulları sağlayan temel dalgacık fonksiyonu, a , dilasyon faktörü, b , orijin çevirisidir. Her ne kadar, zaman frekans dönüşümü sonuçta açıkça görülmesi de $1/a$ değişkeni frekans skalasını ve b bir olayın geçici lokasyonunu verir. (4.1)

Dönüşümde $at + b$ temel formu nedeniyle bu yöntem yakın dalgacık analizi olarak da bilinir. Özel uygulamalar için, temel dalgacık fonksiyonu $\psi^*(.)$ özel ihtiyaçlara göre modifiye edilebilir. Ancak yaygın uygulamalarda, Morlet Dalgacık 5,5

dalgalı Gaussian zarflı sinüs ve cosinüs dalga grupları olarak tanımlanır (Chan, 1995). Sürekli veya ayırık olsun, dalgacık analizi bir lineer analizdir. Dalgacık analizinin özelliği, bütün skalalar için eşdüze bir çözüm sağlamasıdır.

Dalgacık analizi kısa zamanda popüler hale gelmiştir. Gerçekte, kademeli frekans değişikliği verinin analizinde çok yararlıdır. Sonuç analitik bir forma sahip olduğundan, uygulamalı matematikçilerin çok ilgisini çekmektedir. Sınır saptama ve görüntü sıkıştırma alanlarında çok uygulama bulmaktadır. Zaman serilerinde ve iki boyutlu görüntülerde (Farge, 1992; Long vd., 1993) ve iki boyutlu görüntülerde de zaman-frekans dağılımında sınırlı uygulamalar yapılmaktadır. (Spedding vd., 1993)

Yerel oluşan bir değişikliği tanımlamak için, yüksek frekans aralığındaki sonuca bakılmalıdır, çünkü frekans ne kadar yüksekse ana dalgacık o kadar lokalizedir. Bir lokal olay, yalnızca düşük frekans aralığında olursa, onun yüksek frekanstaki etkilerine de bakmak zorunludur (Huang vd., 1996). Dalgacık analizinin bir başka zorluğu onun uyarlanamaz doğasıdır. Bir defa ana dalgacık seçildiğinde, bu dalgacık tüm veriyi analiz etmek için kullanılmalıdır. En yaygın kullanılan Morlet dalgacığı Fourier temelli olduğu için, o da Fourier spektral analizinin bir çok dezavatajlarından sıkıntı çeker, lineer olaylara ancak fiziksel anlamlı yorum getirebilir; dalgalar arası frekans modülasyonunu, ana dalgacığın uzunluğu 5,5 olduğu için çözemez.

4.2.3. Diğer Çeşitli Yöntemler

Aşağıda kısaca açıklanan metotlar da veri işleme metotları arasında yer almaktadır.

Wigner-Ville dağılımı, Heisenberg dalgacığı da denilmektedir. Tanım olarak, merkezi kovaryans fonksiyonunun Fourier dönüşümüdür. Bu dönüşüm Claasen&Mecklenbräuer (1980 a,b,c) ve Cohen (1995) tarafından çok miktarda uygulanmıştır. Bu yöntemin bir açılımı, Wigner-Ville dağılımını, bir komplike veri setini sınırlı sayıda basit bileşenlere düşüren dalga paketlerini tanımlamada kullanan Yen (1994) tarafından yapılmıştır. Bu açılım çok güçlüdür ve birçok problem çeşidine uygulanabilir. Ancak komplike verilere uygulamaları çok zordur.

Evrimsel spektrum ilk olarak Priestley (1965) tarafından önerilmiştir. Temel fikir, klasik Fourier spektral analizi daha genellenmiş bir esasa geliştirmektir. Evrimsel

spektral analiz yöntemi deprem çalışmalarında yaygın olarak kullanılmaktadır (Liu 1970, 1971, 1973; Lin ve Cai 1995).

Bunlar dışında, eğilimin en küçük kare tahmini, hareketli ortalama ile düzeltme ve kararlı veri üretmek için farklılaştırma gibi değişik bazı metotlar da vardır. Yararlı olsa da böyle metotlar, genel kullanım için çok elverişli değildir.

Bu çalışmada, veri analizinde iki aşama gerektiren genel bir metot sunulmuştur. İlk aşama, verinin birkaç içsel mod fonksiyon bileşenine ayrıştığı Ampirik Kip Ayrışım metoduyla, ön bir işlemde geçmesidir. Böylece, veri, veriden elde edilen bir temelde genişletilecektir. İkinci aşama ise Hilbert Dönüşümünün çözülmüş İMF'lere uygulanması ve Hilbert spektrumu denilen enerji-frekans-zaman dağılımını oluşturmasıdır. Diğer deyişle, Fourier spektral analizince tanımlanan global frekans ve enerjiden çok anlık frekans ve enerjinin bulunması istenir. Bu nedenle öncelikle anlık frekansın tanımına açıklık getirmek gerekir.

4.3 Anlık Frekans

Anlık enerji fikri veya sinyalin anlık zarfı fikri iyi algılanmıştır; öte yandan anlık frekans fikri çok tartışıla gelmiştir. Mevcut fikirler anlık frekans yok saymaktan (Shekel, 1953), yalnızca tek bileşenli özel sinyal olarak kabul etmeye (Cohen, 1995) kadar uzanmaktadır.

Anlık frekans fikrini kabul etmenin iki temel zorluğu vardır. Birincisi, Fourier spektral analizinin derin sağlamlaştırılmış etkisinden kaynaklanır. Geleneksel Fourier analizinde frekans, tüm veri uzunluğunu sabit genlikle geçen sinüs ve kosinüs fonksiyonu için tanımlıdır. Bu tanımın bir uzantısı olarak, anlık frekanslar da ya bir sinüs veya bir kosinüs fonksiyonu ile ilişkilendirilmelidir. Bu mantığa göre, bir tüm dalgadan daha kısası çalışmamalıdır. Ancak böyle bir tanım, frekansın bazı anlarda değer değiştirmesi gerektiği durağan olmayan veriler için anlamsız kalır. İkinci zorluk ise gerçek işaretler için anlık frekans tanımlamadaki sıkıntıdan kaynaklanır. Bu sorun, Hilbert Dönüşümüyle verilerin analitik yapılması ile çözülebilir. Gerçek değerli bir $g(t)$ zaman serisi için, Hilbert Dönüşümü, (4.2)'deki şekilde elde edilebilir.

$$\hat{g}(t) = H\{g(t)\} = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{g(\tau)}{t - \tau} d\tau \quad (4.2)$$

Bu denklemde P , karmaşık entegralin Cauchy esas değerini göstermektedir. (4.2)'de verilen Hilbert Dönüşümü gerçek veri $g(t)$ için analitik çiftin sanal kısmını, $\hat{g}(t)$, elde etmemizi ve sonuç olarak özgün analitik bir sinyale, $\tilde{g}(t)$, ulaşmamızı sağlar:

$$\tilde{g}(t) = g(t) + \hat{g}(t) = G(t)e^{j\theta(t)} \quad (4.3)$$

Elde edilen sinyal için anlık frekans, eğer sinyal tek bileşenli ise, analitik çiftin faz fonksiyonunun, $\theta(t)$, zamana göre türevi alınarak kolaylıkla elde edilir:

$$w(t) = \frac{d\theta(t)}{dt} \quad (4.4)$$

Hilbert Dönüşümü yoluyla elde edilen anlık frekans kavramı ancak tek bileşenli işaretler için anlamlıdır. Tek bileşenli sinyal en küçük zaman biriminde tek frekans içeriğine sahip bir sinyal olarak tanımlanabilir. Tek bileşenli sinyaller için Hilbert Dönüşümü yöntemiyle analitik sinyal elde edilerek zamana karşı anlık frekans değerleri bulunur. İşaretin çok bileşenli olması durumunda analizin yapılabilmesi için, işaret her biri tek bileşenli fonksiyonların toplamı şeklinde ifade edilebilir. Bu fonksiyonlar İçsel Mod Fonksiyonları (İMF) olarak adlandırılır (Huang, 1998).

4.4. İçsel Mod Fonksiyonları

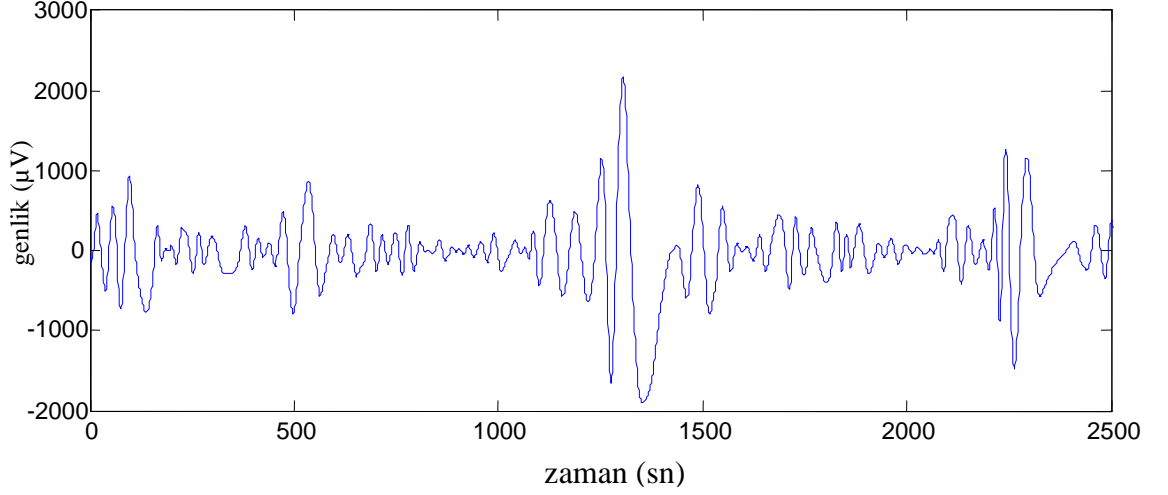
İçsel Mod Fonksiyonu anlık olarak tek frekans içeriğine sahip bir fonksiyondur ve basit bir salınım modunu simgeler. Bu açıdan Fourier Dönüşümünde kullanılan basit harmonik fonksiyonlar ile benzeşmektedir. Bir İçsel Mod Fonksiyonu aşağıdaki iki koşulu sağlayan bir fonksiyondur:

1. Veri setinin tümünde, uç değerlerin sayısı ve sıfır geçişlerinin sayısı ya eşit olmalı veya en fazla bir farklı olmalıdır.
2. Herhangi bir noktada, yerel maksimumlarca tanımlanan ve yerel minimumlarca tanımlanan zarfların ortalama değeri sıfırdır.

Yerel simetriyi sağlamak için gerçek yerel ortalama yerine yerel maksimum ve yerel minimumlar tarafından tanımlanan zarfların yerel ortalaması kullanılır.

Bu fonksiyonlara İçsel Mod Fonksiyonları (İMF) adı verilmesinin nedeni, her bir fonksiyonun veri içerisine gömülü olan bir salınım modunu temsil etmesidir. Yukarıda

verilen 2 koşulla tanımlanan İMF'ler sadece bir salınım modunu içerir ve birbiri üzerine binmiş karmaşık dalgalara izin verilmez. Tipik bir İMF Şekil 4.1.'de gösterilmiştir.



Şekil 4.1 Aynı sayıda sıfır kesişimler ve uç değerler ve sıfıra göre üst ve alt zarfların simetrisi ile tipik bir İMF. (9. Hastanın interiktal verilerinden 10 saniyelik bir pencereden elde edilen 3. İMF görüntülenmektedir)

Komplike bir işaret için, herhangi bir zaman anında muhtemelen birden fazla anlık frekans bilgisi söz konusu olacaktır. Diğer bir deyişle incelenecek olan işaret çok bileşenli olacaktır ve bu işareti her biri tek bileşenli olan İMF'lere ayırmak gerekecektir. Bu işlemi gerçekleştirmek için gereken Ampirik Kip Ayrışımı metodu aşağıda sunulmuştur.

4.5. Ampirik Kip Ayrışımı Metodu: Eleme Süreci

HHT için temel ve atılması gereken ilk adım Ampirik Kip Ayrışımı (AKA) metodudur. Bu metot sayesinde herhangi bir karmaşık veri seti sonlu sayıda (genellikle küçük bir rakam) İçsel Mod Fonksiyonlarına (İMF) ayrıştırılabilir. Veri setinin İMF'lerine ayrıştırılma işlemi uyarlanabilir bir yöntem olduğu için çok verimlidir ve verilerin zaman düzlemindeki yerel karakteristiklerine dayandığı için doğrusal olmayan ve durağan olmayan işlemlere uygulanabilir. İşaret İMF'lerine ayrıştırıldıktan sonra her bir İMF'ye Hilbert Dönüşümü uygulanarak, Hilbert Spektrumu adı verilen enerji-frekans-zaman dağılımını oluşturmak mümkündür.

İMF'ler, karmaşık işareti oluşturan salınımlar olmaları sebebiyle, Fourier Dönüşümünde kullanılan basit harmonik fonksiyonlar ile benzerlik gösterir. Ancak İMF'ler çok daha genel bir yapıya sahiptir. Örneğin basit harmonik komponentlerde kullanılan sabit genlik ve frekans yerine bir İMF zamana göre değişim gösteren genlik ve frekansa sahip olabilir.


Bu tanımlar ışığında herhangi bir işaret aşağıdaki adımlar izlenerek İMF'lerine ayrıştırılabilir:

1. Asıl işaret başka bir değişkene atılır, $g_1(t)=x(t)$
2. İşaretin, $g_i(t)$, tüm yerel uç değerleri belirlenir. Yerel en büyükler (maxima) yukarı zarfı, $E_g^+(t)$, oluşturacak şekilde kübik oluk doğrusu (cubic spline line) ile birleştirilir. Benzer şekilde birleştirilen yerel en küçükler (minima) de aşağı zarfı, $E_g^-(t)$, oluşturur (Şekil 4.2.(a,b,c,d,e)).
3. Oluşturulan yukarı ve aşağı zarfların aritmetik ortalaması alınarak $g_i(t)$ 'den çıkarılır (Şekil 4.2.(f)).


$$m(t) = \frac{(E_g^+(t) + E_g^-(t))}{2} \quad (4.5)$$

$$g_i(t) = g_i(t) - m(t) \quad (4.6)$$


4. Elde edilen işaretin, İMF olma şartlarını sağlayıp sağlamadığı kontrol edilir. Şartların sağlanması durumunda $g_i(t)$ *iinci* İMF olarak kaydedilir ve 5. aşamaya geçilir, değilse 2. aşamaya dönülür (Şekil 4.2).
5. *i'inci* İMF elde edildikten sonra kalan işaret, $r_i(t)=x(t)- g_i(t)$, incelenir. Eğer kalan işaret sabit bir sayı, monotonik bir fonksiyon ya da tek bir en büyük ve en küçüğü olan bir fonksiyon ise, kısacası bu kalan işareten başka bir İMF elde edilemeyecekse, işlem bitirilir. İMF elde etme işlemi bitmediyse, yeni İMF bulunabilmesi için kalan işaret kullanılır, $g_{i+1}(t)=r_i(t)$, ve 2. adıma geri dönülür.



Şekil 4.2. Eleme sürecinin gösterimi: **(a)** orijinal veri; **(b)** kırmızı noktalar yerel maksimumlar; **(c)** kırmızı çizgi yerel maksimumların oluşturduğu zarfın üst çizgisi



Şekil 4.2. (devam) Eleme sürecinin gösterimi: **(d)** mavi noktalar yerel minimumlar; **(e)** mavi çizgi yerel minimumların oluşturduğu zarfın alt çizgisi, yeşil çizgi oluşan zarfın ortalama değerleri; **(f)** veri ve ortalama arasındaki fark. Bu bir İMF değildir, çünkü hala binen dalgalar gösteren negatif yerel maksimum ve pozitif minimumlar vardır



Şekil 4.3. Tekrarlanan eleme sürecinin etkilerinin gösterimi: **(a ve b)** Şekil 4.2.(f)'deki sonucun bir kere daha elemesinden sonra, sonuç hala asimetriktir ve hala bir İMF değildir; **(c ve d)** altı elemekten sonra, d'de görülen fonksiyon elde edilmiş ve asimetri kaybolduğu için 1.İMF olarak kaydedilmiştir

Sonuç olarak N adet İMF elde edildiği varsayılırsa, N- İMF ve bir kalan şeklinde ayrıştırılmış olan işaret aşağıdaki şekilde ifade edilebilir:

$$x(t) = \sum_{i=1}^N g_i(t) + r_N \quad (4.7)$$

4.6. Hilbert Dönüşümü

HHT'nin ikinci aşamasında, AKA yöntemi yoluyla elde edilen İMF'lere Hilbert Dönüşümü uygulanır ve sonuç olarak gerçek işaretten analitik işaret elde edilir. $g(t)$ işaretinin Hilbert Dönüşümü, $g(t)$ işaretinin $1/\pi t$ ile konvolüsyonu olarak tanımlanabilir ve genellikle $\hat{g}_i(t)$ ile gösterilir. $\hat{g}_i(t)$ işaretinin elde edilişi (4.8)'de, bu sanal kısmın kullanılması ile elde edilen analitik işaret ise (4.9)'da gösterilmiştir. Elde edilen analitik işaretin genliği, $G_i(t)$, fazı, $\theta_i(t)$, ve anlık frekansı, $w_i(t)$, aşağıdaki gibi hesaplanır.

$$G_i(t) = \sqrt{g_i(t)^2 + \hat{g}_i(t)^2} \quad (4.8)$$

$$\theta_i(t) = \tan^{-1} \left(\frac{\hat{g}_i(t)}{g_i(t)} \right) \quad (4.9)$$

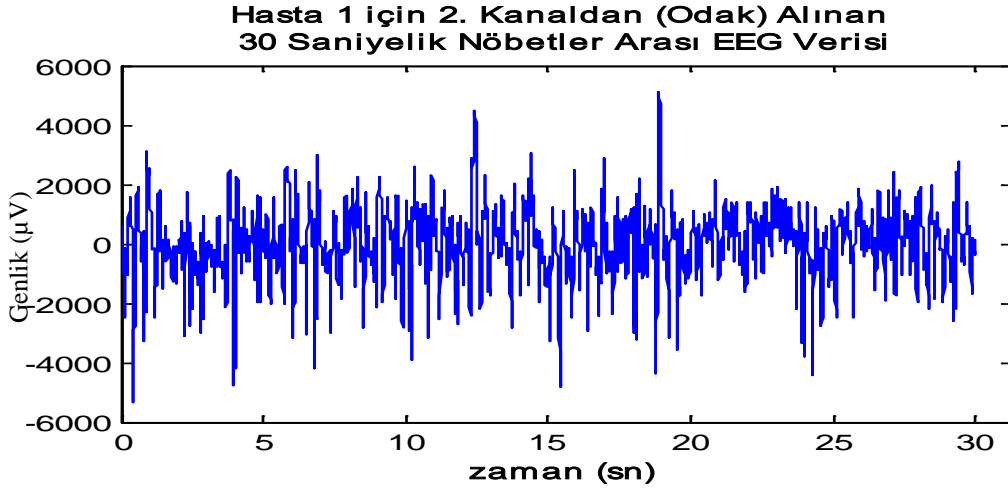
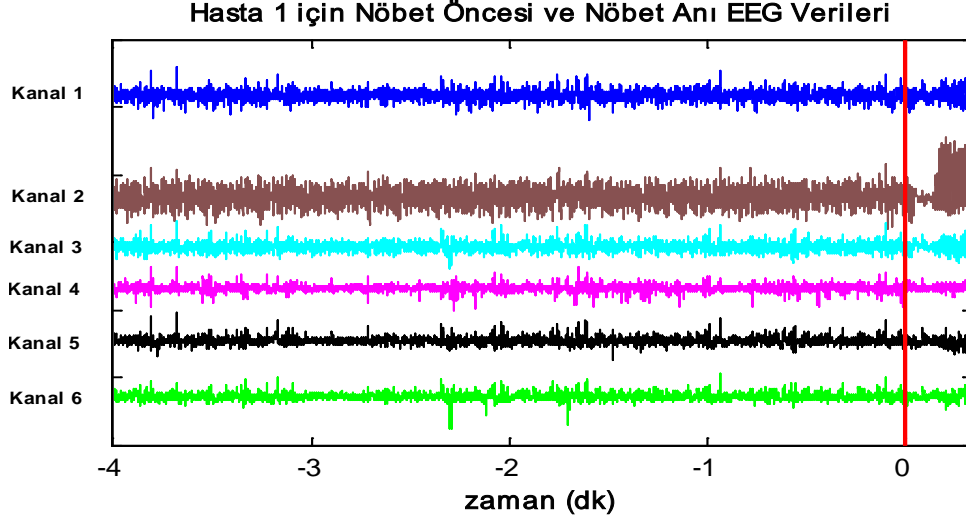
$$w_i(t) = \frac{d\theta_i(t)}{2\pi dt} \quad (4.10)$$

Bu durumda orijinal sinyelimizi, gürültü $r_N(t)$ atıldıktan sonra, aşağıdaki şekilde ifade edebiliriz:

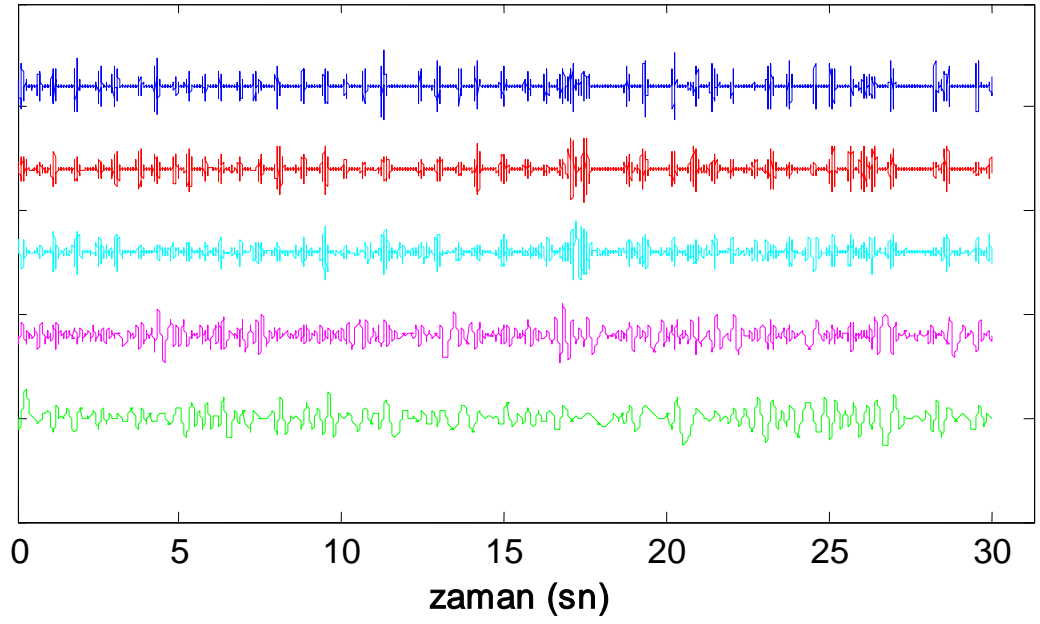
$$x(t) = \sum_{i=1}^N G_i(t) e^{j \int w_i(t) dt} \quad (4.11)$$

(4.11)'de gösterilen eşitlik, aynı zamanda genlik ve anlık frekansı üç boyutlu planda zamanın fonksiyonu olarak göstermemizi sağlar. Bu durumda İMF'ler için zamana bağlı genlik, $G(t)$, ve anlık frekans, $w(t)$, değerleri bulunabilmekte ve zaman-frekans düzleminde genlik değeri 3. boyut olarak eklenebilmektedir. Bu şekilde ifade edilebilen, genliğin zaman-frekans dağılımı *Hilbert Genlik Spektrumu* ya da kısaca

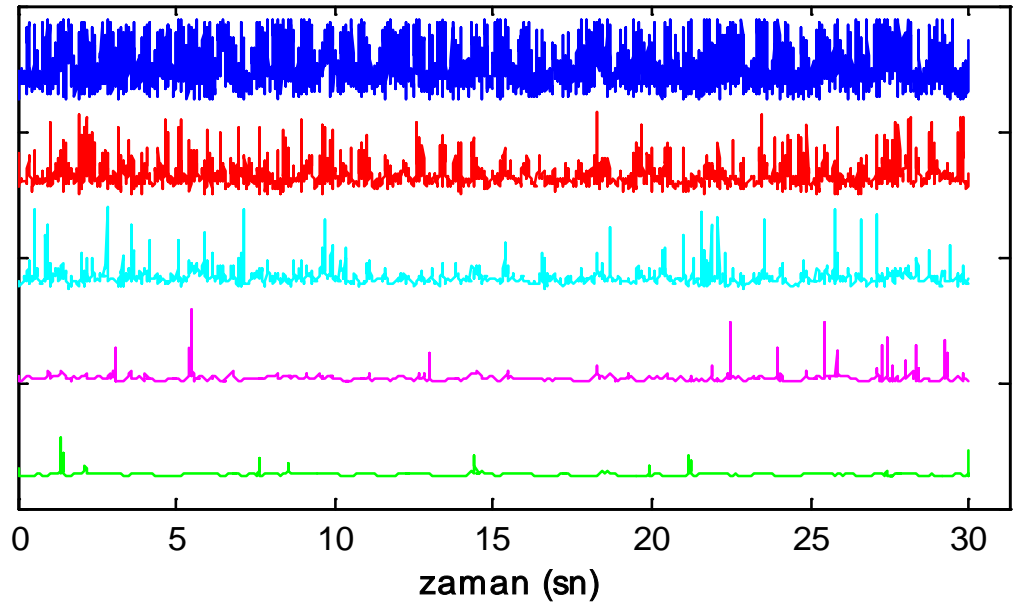
Hilbert Spektrum olarak adlandırılır. Hilbert Spektrum, $H(\omega, t)$, her t anı için hesaplanan anlık frekansta, $w(t)$, genliğin çizilmesiyle hem zamana hem de frekansa bağlı olarak görüntülenebilir. 11. hastanın 4 dakikalık nöbet öncesi ham EEG verileri, 2. kanaldan alınmış 30 saniyelik veri penceresi; bu pencereye ait ilk 5 İMF ve bunların anlık frekans değerleri ve İMF'lere ait Hilbert spektrumları sırasıyla Şekil 4.4, 4.5, 4.6'da örnek olarak gösterilmiştir.



Şekil 4.4. 1. Hasta için örnek EEG verileri a) Tüm kanallar için 4 dakikalık ham EEG verileri, (b) 2. Kanaldan alınmış 30 saniyelik ham EEG verileri.

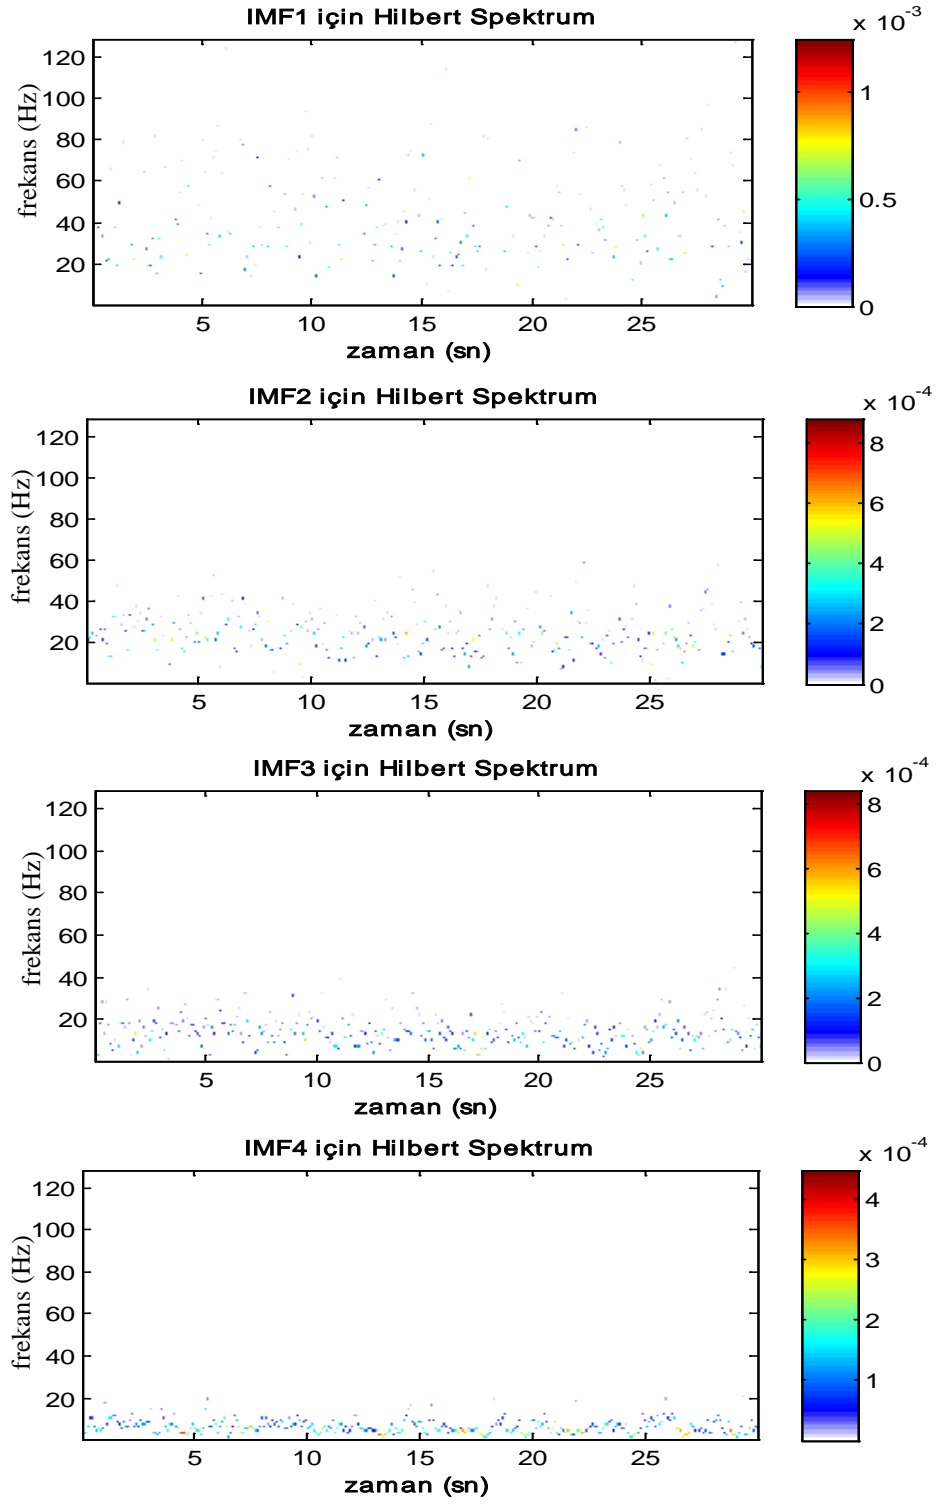
İlk 5 İMF

(a)

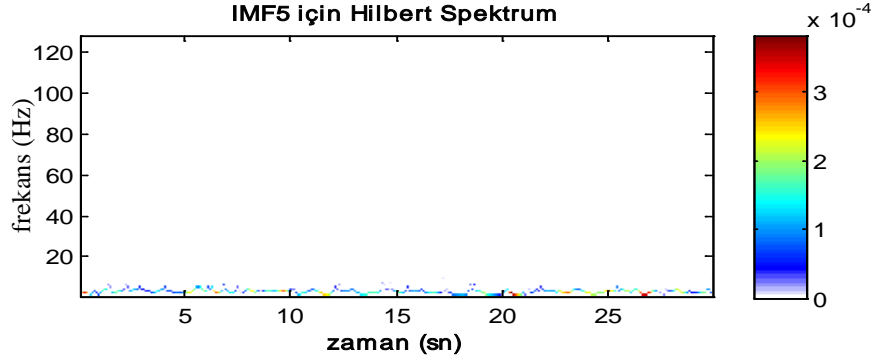
Anlık Frekans Değerleri

(b)

Şekil 4.5 1. Hasta için örnek EEG verileri (a) 30 saniyelik EEG verilerinden elde edilmiş olan ilk 5 İMF (Yukarıdan aşağıya doğru sıralanmış olarak), (b) ilk 5 İMF'nin anlık frekans değerleri.



Şekil 4.6. İlk 5 İMF'nin Hilbert Spektrumları



Şekil 4.6. (devamı) İlk 5 İMF'nin Hilbert Spektrumları

4.7. Yapay Sinir Ağları

Beynin üstün özellikleri, bilim adamlarını beynin çalışma prensipleri üzerine çalışmaya teşvik etmiş ve beynin nörofiziksel yapısından esinlenilerek matematiksel modeli çıkarılmaya çalışılmıştır. Beynin bütün davranışlarını modelleyebilmek için çeşitli yapay sinir hücresi ve ağ modelleri geliştirilmiştir.

Genel anlamda Yapay sinir Ağları (YSA), beynin bir işlevi yerine getirme yöntemini modellemek için tasarlanan bir sistem olarak tanımlanabilir. YSA, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmasından oluşur ve genellikle katmanlar şeklinde düzenlenir. Literatürde 100'den fazla YSA modeli vardır.

YSA'ların en önemli özelliği öğrenme kapasitesidir. YSA algoritmaları, daha önce karşılaşılmamış durumlara, eğitim setinde bulunan verilerden esinlenerek çözüm bulmaya çalışır.

4.7.1 Yapay Sinir Ağlarının Özellikleri

Biyolojik sinir yapılarının çalışma biçimlerinden esinlenerek ortaya çıkarılan YSA modelleri, biyolojik olmayan yapı taşlarının birbirlerine bağlanmalarından oluşmaktadırlar ve biyolojik sinir sisteminin bazı üstün özelliklerine sahiptir. Bu üstünlükler şu şekilde özetlenebilir; Doğrusal olmama, paralellik, yerel bilgi işleme, hata toleransı, öğrenebilirlik, genelleme, uyarlanabilirlik, donanım ve hız, analiz ve tasarım kolaylığı (Saraç, 2004).

Sinir hücreleri, özellikle beyin olmak üzere sinir sisteminin temel birimidir ve başlıca üç kısımdan oluşur. Bunlar:


- Gövde (soma),
- Gövdeye giren sinyal alıcı lifler (dendrit),
- Gövdeden çıkan sinyal iletici lifler (axon).

YSA'ların, insan beyninin çalışma prensibi örneklenecek geliştirilmeye çalışılmıştır ve aralarında yapısal olarak bazı benzerlikler vardır. Bu benzerlikler Çizelge 4.1'de verilmiştir.

Çizelge 4.1. Sinir sistemi ile YSA'nın benzerlikleri

SİNİR SİSTEMİ	YSA SİSTEMİ
Sinir hücresi	İşlem elemanı
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Aksonlar	Eleman çıkışı
Sinapslar	Ağırlıklar

Şekil 4.7.'de bir sinir hücresinin yapısı verilmiştir. Bir sinir hücresinden yüzlerce, bazen de binlerce dendrit çıkabilir. Bunların uzunluğu genellikle bir milimetreden daha kısadır. Bazıları ise birkaç milimetre uzunluğa ulaşabilir. Dendritler çevre sinir hücrelerinden gelen sinyalleri alıp, gövdeye ulaştırırlar. Her sinir hücresi, dendritler vasıtasıyla diğer birçok sinir hücresinden gelen işaretleri alan ve birleştiren basit bir mikroişlemcidir.



Şekil 4.7. Sinir hücresi

Beyin, milyarlarca sinir hücresinden oluşmaktadır. Her eleman kendi aralarında oldukça çok sayıda sinir hücresine bağlanmıştır. Her bir sinir hücresinin aksonu ayrıştırılmıştır ve sinaps olarak adlandırılan bağlantı noktaları ile diğer sinir hücrelerinin dendritlerine bağlanmıştır. Bu bağlantı noktalarının uçlarındaki iletim kimyasaldır ve işaretin miktarı, akson tarafından serbest bırakılan kimyasalların büyüklüğüne bağlı olarak transfer edilir ve dendritler vasıtasıyla alınır.

Sinapsa gelen ve dendritler tarafından alınan bilgiler genellikle elektriksel darbelerdir ancak, sinapsdaki kimyasal ileticilerden etkilenir. Belirli bir sürede bir sinir hücresine gelen girişlerin değeri, belirli bir eşik değerine ulaştığında sinir hücresi bir tepki üretir.

İnsan beyninin 10 milyar sinir hücresinden ve 60 trilyon sinaps bağlantısından oluştuğu düşünülürse son derece karmaşık ve etkin bir yapı olduğu anlaşılır. Diğer taraftan bir sinir hücresinin tepki hızı, günümüz bilgisayarlarına göre oldukça yavaş olmakla birlikte duyuşsal bilgileri son derecede hızlı değerlendirebilmektedir. Bu nedenle insan beyni; öğrenme, birleştirme, uyarılma ve genelleştirme yeteneği nedeniyle son derece karmaşık, doğrusal olmayan ve paralel dağılmış bir bilgi işleme sistemi olarak tanımlanabilir.


4.7.2. Yapay Sinir Modelleri

YSA'nın çalışmasına esas teşkil eden en küçük bilgi işleme birimidir. Geliştirilen sinir hücresi modellerinde bazı farklılıklar olmakla birlikte genel özellikleri ile bir yapay sinir hücresi modeli, Şekil 4.8.'de görüldüğü gibi girişler, ağırlıklar, birleştirme fonksiyonu, aktivasyon fonksiyonu ve çıkışlar olmak üzere 5 kısımdan meydana gelir. Girişler, diğer sinir hücrelerinden ya da dış ortamlardan sinir hücrelerine giren bilgilerdir. Bilgiler, bağlantılar üzerindeki ağırlıklar üzerinden sinir hücresine girer ve ağırlıklar, ilgili girişin sinir hücresi üzerindeki etkisini belirler. Birleştirme fonksiyonu, bir sinir hücresine gelen net girişi hesaplayan bir fonksiyondur ve genellikle net girdi, girişlerin ilgili ağırlıkla çarpımlarının toplamıdır. Birleştirme fonksiyonu, ağ yapısına göre maksimum/ minimum bulma ya da çarpım fonksiyonu olabilir. Aktivasyon fonksiyonu ise birleştirme fonksiyonundan elde edilen net girişi bir işlemde geçirerek sinir hücresi çıkışını belirleyen ve genellikle doğrusal olmayan bir fonksiyondur. Sinir hücresi modellerinde, giriş vektörü (x_0), katsayısı ise ağırlık vektörü (W_0) içerisine alınabilir. Sinir hücreleri gerçekleştirdikleri işleve göre dinamik veya statik davranış gösterebilirler.

Şekil 4.8.'de ağırlıkların sabit olduğu ve sinir hücresinde geri besleme ya da gecikme kullanılmadığı dikkate alınır, bu sinir hücresi statik bir işlevi gerçekleştireceğinden statik sinir hücresi modeli olarak adlandırılabilir. Statik sinir hücresinin matematiksel modeli (4.12)'deki gibi yazılabilir.

$$v = \sum_{i=0}^x W_i X_i \quad \text{ya da} \quad v = \sum_{i=0}^x W_i X_i + b \quad (4.12)$$

Burada; W sinir hücresinin ağırlıklar matrisini, x giriş vektörünü, v net girişini, y çıkışını ve θ aktivasyon fonksiyonunu göstermektedir. (4.8)'de, x giriş vektörünün bileşenlerinin geri beslemesiz girişler olması durumunda sinir hücresinin doğrusal olmayan statik bir işlevi gerçekleştirebileceği görülmektedir (Türker, 2004).



Şekil 4.8. Temel Statik Yapay Sinir Hücresi (Türker, 2004)

4.7.3. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonu, birleştirme fonksiyonundan elde edilen net girişi bir işlemde geçirerek sinir hücresi çıkışını belirleyen ve genellikle doğrusal olmayan bir fonksiyondur. Sinir hücresi modellerinde, sinir hücresinin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir. Aktivasyon fonksiyonları sabit parametrelili ya da uyarlanabilir parametrelili seçilebilir. En uygun aktivasyon fonksiyonu tasarımcının denemeleri sonucunda belli olur. Geçiş fonksiyonları içinde en çok kullanılanı sigmoid ve tanjant hiperbolik fonksiyonlardır.

Aktivasyon fonksiyonları bir YSA' da sinir hücresinin çıkış genliğini, istenilen değerler arasında sınırlar. Bu değerler genellikle $[0,1]$ veya $[-1,1]$ arasındadır. YSA' da kullanılacak aktivasyon fonksiyonlarının türevi alınabilir olması ve süreklilik arz etmesi gereklidir. Lineer veya doğrusal olmayan transfer fonksiyonlarının kullanılması YSA' ların karmaşık ve çok farklı problemlere uygulanmasını sağlamıştır. (Saraç, 2004).

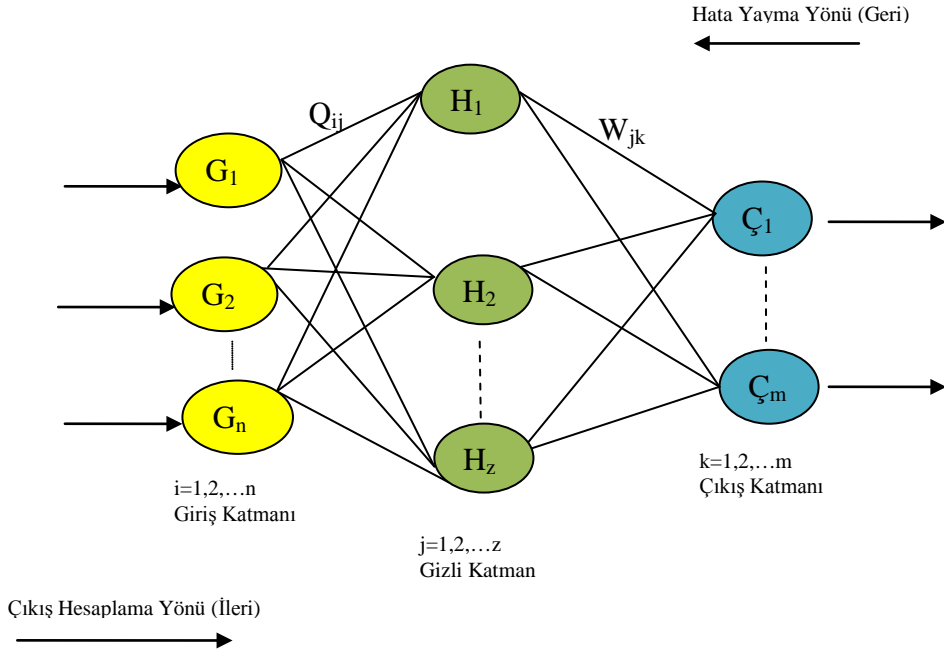
4.7.4. Yapay Sinir Ağlarının Sınıflandırılması

Her bir sinir hücresi arasındaki bağlantıların yapısı YSA'nın ağ yapısını belirler. Öğrenme algoritması yoluyla bağlantıların değişimi belirlenerek istenilen hedefe ulaşılmaya çalışılır. Ağın ağırlıkları, kullanılan öğrenme algoritmasına göre, hatayı en aza indirecek şekilde, değiştirilir. YSA' lar yapılarına ve öğrenme algoritmalarına göre

sınıflandırılırlar. YSA'lar, yapılarına göre, ileri beslemeli ve geri beslemeli ağlar olmak üzere iki şekilde sınıflandırılırlar (Sağıroğlu vd. 2003).

4.7.4.1. İleri Beslemeli Ağlar

İleri beslemeli YSA'da, sinir hücreleri katmanlar şeklinde düzenlenir ve bir katmandaki sinir hücrelerinin çıkışları bir sonraki katmana giriş olarak verilir. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan orta katmandaki sinir hücrelerine iletir. Ağ çıkışı, bilgilerin orta ve çıkış katmanlarında işlenmesiyle belirlenir. Basitliği ve kullanım kolaylığı açısından ağ eğitimi için en sık kullanılan algoritmalarından olan geriye yayılım öğrenme algoritması giriş, orta (gizli) ve çıkış katmanlarından oluşmaktadır. Şekil 4.9'da 3 katmanlı ileri beslemeli ağ yapısı verilmektedir. $\{G_1, G_2, \dots, G_n\}$ giriş sinir hücrelerini, $\{H_1, H_2, \dots, H_z\}$ gizli sinir hücrelerini, $\{Ç_1, Ç_2, \dots, Ç_m\}$ çıkış sinir hücrelerini, Q_{ij} , i giriş sinir hücresinden, j gizli sinir hücresinden olan bağlantının ağırlığını ve W_{jk} , j gizli sinir hücresinden k , çıkış sinir hücresinden olan bağlantının ağırlığını göstermektedir.



Şekil.4.9. İleri beslemeli 3 katmanlı YSA

1970'li yıllarda geliştirilen ileri beslemeli geri yayılım yapısı karmaşık verilerin sınıflandırılmasında kullanılır. Bu yapı ilk olarak Werbos (1994) tarafından

geliştirilmiştir. Ortaya çıkışından sonra, hem etkili hem de çok kullanışlı olmasından dolayı büyük ilgi görmüştür ve hala en çok kullanılan ağ türü olarak bilinmektedir (Yurtoğlu, 2005). Genel itibariyle bir geri yayılım ağında, bir giriş katmanı, bir çıkış katmanı ve en az bir gizli katman vardır. Gizli katmanların sayısı için bir sınırlama bulunmamaktadır. Geri yayılım ağlarında katman sayısı ve her katmanda bulunan düğüm sayısının dikkatle seçilmesi gerekir. Bu sayıların ne olacağı hakkında kesin bir hüküm yoktur, ancak takip edilmesi gereken genel kurallar bulunmaktadır. Bu kurallar şu şekilde ifade edilebilir:

1. Giriş verisi ile çıkış arasındaki ilişki karmaşıklaştığında gizli katmanlardaki işleme elemanlarının sayısı artmaktadır.
2. Sınıflandırma yapılan konu birçok aşamaya ayrılabilir, katman sayısının artırılması gerekebilir.
3. Ağda kullanılan eğitim verisinin miktarı, gizli katmanlarda işleme sayısı için üst limiti oluşturur.

Geri yayımlı yapay sinir ağları ileri besleme ve geri yayılım temel aşamalarından oluşur. İleri Besleme aşamasında sinir ağı verilerle beslenerek ağdan çıkış alınır. Bu aşamanın sonunda elde edilen çıkışlar hata fonksiyonuna girilir ve hatalar geriye yayılarak ağırlıklar güncellenir. Ağdaki sinir hücrelerinin, giriş sinir hücreleri hariç, birden fazla girişi ve sadece bir çıkışı vardır. Bir sinir hücresi çıkış üretirken kendisine iletilen tüm giriş sinyallerini toplar ve bu toplamı aktivasyon fonksiyonundan geçirir. Giriş katmanındaki sinir hücrelerinin dendritleri yoktur. Bu sinir hücreleri girişlerini dışarıdan alır ve çıkış üretmek için aktivasyon fonksiyonu kullanmazlar. Çıkış değerleri direkt olarak giriş değerleridir. Son katmanda bulunan sinir hücrelerinin çıkış değerleri ağın çıkışıdır.

Ağdan alınan çıkışların, beklenen değerlere ne kadar uzak olduklarının bir fonksiyon yardımıyla ölçülmesi gerekir. Geri yayılım algoritmasında, en küçük kareler ortalaması (least mean square, LMS), hata fonksiyonu olarak kullanılır. Hata fonksiyonunu ve dolayısıyla toplam hatayı minimuma yaklaştırmak için gradyan iniş metodu kullanılır. Bu metotta çok değişkenli fonksiyonun gradyeni alınarak, bu fonksiyon üzerindeki bir noktada en hızlı artış gösterdiği yön bulunur ve bu vektörün yönünün tersine ilerlenerek minimum noktaya yaklaşılr.

4.7.4.2. Geri Beslemeli Ağlar

Geri beslemeli sinir ağı, çıkış ve ara katlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Bu tür ağlarda, bir sinir hücresinin çıkışı kendisine ya da diğer sinir hücrelerine giriş olarak verilir. Geri besleme, genellikle, geciktirme elemanı üzerinden yapılır. Geriye doğru hesaplamada, ağın ürettiği çıkış değeri, ağın beklenen çıkış değerleri ile kıyaslanır. Bunların arasındaki fark, hata olarak kabul edilir. Amaç bu hatanın düşürülmesidir. Bu ağlara örnek olarak Hopfield, SOM (Self Organizing Map), Elman ve Jordan ağları verilebilir.

4.8. Bayes Ağları

Bayes ağları İngiliz matematikçi Thomas Bayes'in 18. yüzyılda ortaya atmış olduğu Bayes kuramına dayanır (Bayes, 1763). Bayes kuramına dayalı olarak düğümler arasındaki kollar, Bayes ağlarını oluştururlar (Pearl, 1988). Bu sayede oluşturulan Bayes ağları üzerinden belirlenmiş kanıt ve hedef düğümleri arasındaki ilişkiler üzerinden tahmin yapılabilir (Neapolitan, 2003). Bayes ağları yardımıyla tahmin yapma ve ardışık olarak hedef düğümlerdeki değişkenleri güncelleme sayesinde makine öğrenmesine dayalı olarak teşhis ve tahmin problemlerine çözümler üretilebilir (Korb ve Nicholson, 2003).

Bayes ağlarının uygulama alanı geniştir. Bilimsel çalışmalar, biyoloji, finansal uygulamalar, büyük ölçekli sanayi donanımları, nedensel öğrenme uygulamaları, bilgisayar oyunları, bilgisayar donanımları ve yazılımları, veri madenciliği, tıbbi uygulamalar, doğal dil işleme, planlama, psikoloji, güvenilirlik çözümlemesi, konuşma tanıma, taşıt denetimi ve arıza teşhisi, hava tahmini gibi birçok farklı alanda Bayes ağlarına başvurulmaktadır (Neapolitan, 2003).

Bayes ağlarının temelini oluşturan Bayes teoremi aşağıda kısaca hatırlatılmaktadır.

Bayes Teoremi; A sınıf üyeliği bilinmeyen veri örneği olsun. B ise bu veri örneği X'in C sınıfına ait olduğunu öngören bir hipotez olsun. Bu sınıflandırma problemi için, $P(B/A)$ olasılığını hesaplamak istiyoruz. Bu olasılık hipotez B'nin C sınıfına ait olarak farz edilerek verilen veriyi tutmasıdır.

$P(B/A)$, B'nin A üzerindeki koşullandırmasına ait sonrasal olasılıktır. Karşıtlıkta, $P(B)$, B' ye ait öncesel olasılıktır. Sonrasal olasılık, $P(B/A)$, A'dan bağımsız olan öncesel olasılıktan, $P(B)$, daha fazla bilgi üzerine kuruludur. $P(A)$, $P(B)$, ve $P(A/B)$ verilen veriden aşağıdaki şekilde hesaplanabilir. Bayes teoremi sonraki olasılığı, $P(B/A)$, $P(B)$, $P(A)$ ve $P(A/B)$ 'yi kullanarak hesap eden bir yol sağlayan kullanışlı bir teoremdir.

$$\text{Bayes Teoremi } P(B/A) = \frac{P(A/B) P(B)}{P(A)} \quad (4.13)$$

Bayesian sınıflandırıcılar kolay uygulanabilir olasılığa dayanan sınıflandırıcılardır. Bayes ağları, karar verme durumundaki belirsizlikleri ve istatistiksel çıkarımları modellemede kullanılan ve son yıllardaki popülaritesiyle oldukça göze çarpan bir yöntemdir. Birçok algoritma Bayes ağları kullanarak ilgilendikleri alanda üzerinde çalıştıkları değişkenlerin bir sonraki değerlerini başarılı bir şekilde hesaplayabilir. Bu olasılıksal model, yönlü döngüsüz çizge yapısına dayanır. Verilerin aşağıdan yukarı veya yukarıdan aşağıya birleştirilebilmesi, çift yönlü çıkarım yapılabilmesi ve bu yapıya eklenen olasılık dağılımları sayesinde Bayes ağları, belirsizlik sırasında tahmin yapmak için tercih edilen önemli bir yöntem olmuştur.

4.9. Korelasyon Tabanlı Öznitelik Seçme

Yapılan çalışmalar, sınıflandırma performansının artırılmasında, öznitelik alt kümesi seçiminin çok önemli olduğunu göstermiştir. Çok fazla veri, sınıflandırma algoritmalarında performansı kötü etkilerken aynı zamanda yavaşlamasına neden olabilmektedir. Bazı verilerin de öğrenme işlemiyle ilişkileri olmayabilir. Korelasyon Tabanlı Öznitelik Seçme (KTÖS), korelasyon katsayısına dayanan bir öznitelik alt küme seçme metodudur. KTÖS öznitelik vektörlerinin korelasyon katsayılarına bakarak öznitelik alt kümelerini derecelendirir. Bu yöntemin temelinde, öznitelik alt kümelerinin değerini hesaplama vardır. Bu hesaplamada, tek başına sınıf etiketini tahmin eden özniteliklerin sayısına bakılırken, korelasyon derecesi de göz önüne alınır (Hall, 1998).

Bir değişkenin değeri değişirken, bir diğer değişkenin de değeri değişiyorsa, bu ikisi arasında bir ilişki olduğu söylenebilir. Korelasyon iki değişken arasındaki bu ilişkiyi ölçmek için kullanılır. İki değişkenin değerleri tüm durumlar için birlikte artıyor

ya da azalıyorsa aralarında pozitif korelasyon, biri artarken diğeri azalıyorsa aralarında negatif korelasyon olduğu söylenebilir. Korelasyon katsayısı (r), bağımsız değişkenler arasındaki ilişkinin yönünü ve büyüklüğünü belirten katsayıdır. Bu katsayı, (-1) ile (+1) arasında bir değer alır. (+1) kusursuz pozitif korelasyon, (-1) kusursuz negatif korelasyon anlamındadır. Pozitif değerler direk yönlü doğrusal ilişkiyi; negatif değerler ise ters yönlü bir doğrusal ilişkiyi belirtir. Korelasyon katsayısı 0 ise söz konusu değişkenler arasında doğrusal bir ilişki yoktur.

$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{n(\sum x^2) - (\sum x)^2} \sqrt{n(\sum y^2) - (\sum y)^2}} \quad (4.14)$$

5. ARAŞTIRMA BULGULARI VE TARTIŞMA

Epilepsi hastaları üzerinde yapılan klinik ve araştırmaya yönelik çalışmalar iki konu üzerinde yoğunlaşmaktadır: *nöbet algılama* ve *nöbet tahmini*. Nöbet algılama, genel olarak, bir epilepsi hastasından kaydedilen biyolojik sinyallerin analiz edilerek bir nöbetin ortaya çıktığı anda otomatik olarak belirlenebilmesi olarak tanımlanmaktadır. Nöbet tahmininde ise, bir nöbetin meydana geleceğini elektro grafiksel nöbet başlangıç noktasından yeterince uzun bir süre önce belirleyebilmek amaçlanmaktadır. Nöbet tahmini çalışmalarında çok farklı algoritmalar kullanılmıştır. Bu algoritmalarda verilerin zamana bağlı bilgileri ya da çeşitli dönüşüm yöntemleri yoluyla bulunan frekans bilgilerinden elde edilen öznitelikler kullanılmıştır. Bazı çalışmalarda istatistiksel olarak belirlenen eşik değerleri ile direk değerlendirme yapılmış, bazı çalışmalarda ise sınıflandırıcılar kullanılmıştır. Ancak, ister eşikleme, ister sınıflandırma yoluyla olsun, nöbet tahmini performansındaki en büyük etken özniteliklerdir.


Bu tez çalışmasında HHT kullanılarak elde edilen öznitelikler yardımıyla nöbet algılama ve nöbet tahmini yapılmıştır.

5.1. Verilerin Önışlemeden Geçirilmesi


Materyal bölümünde ayrıntılı olarak açıklanan Freiburg veritabanındaki veriler, tüm hastalar için, durumlarına göre (*nöbet anı*, *nöbet öncesi* ve *nöbetler arası*) ayrıldıktan sonra, şebekeden kaynaklı gürültüyü ortadan kaldırmak için 50 Hz bant durduran filtreden geçirilmiştir. Gürültüden temizlenmiş olan veriler kayan pencere yöntemi ile analiz edilmek üzere farklı uzunluklarda bölütlere ayrılmışlardır. Pencere uzunluğu olarak 10, 30 ve 60 saniye kullanılmış tüm pencere uzunlukları için %50 örtüşme kullanılmıştır. Böylelikle, yapılan çalışmalarda kullanılan pencere uzunluğuna göre, her 5, 15 veya 30 saniyede analizler gerçekleştirilmiştir. Bölütlerine ayrılmış olan işaretler AKA yöntemi uygulanarak, her biri tek frekans bileşenli (monocomponent) olan İMF'lerine ($g_i(t), i = 1, 2, \dots, N$) ayrılmış, tüm pencereler için elde edilen ilk 6 İMF çalışmalarda öznitelik çıkarımında kullanılmak üzere kaydedilmiştir.

$$x(t) = \sum_{i=1}^N g_i(t) + r_N \quad (5.1)$$


Şekil 5.1’de ve Şekil 5.2’de örnek EEG verileri verilmektedir. Şekil 5.1’de 1. hastanın epileptik nöbet başlangıç bölgelerinden kayıt yapan 3 elektrottan (fokal elektrotlar) alınan 1. nöbetini ve ondan önceki 3 dakikalık EEG verileri, Şekil 5.2’de ise aynı nöbete ait verilerin, nöbet faaliyetinin gözlemlenmediği elektrotlardan (extrafokal elektrotlar) alınan veriler gösterilmektedir.



Şekil 5.1. Hastanın 1,2 ve 3. elektrotlarında kaydedilen 1. nöbet anı ve bu andan önceki 3 dakikalık EEG verileri. 0. dakika nöbet başlangıç anını göstermektedir



Şekil 5.2. 1. Hastanın 4, 5 ve 6. elektrotlarında kaydedilen 1. nöbet anı ve bu andan önceki 3 dakikalık EEG verileri. 0. dakika nöbet başlangıç anını göstermektedir.



Şekil 5.3. Şekil 5.1.'de verilmiş olan EEG verilerinin 45-55 sn arasındaki penceresine ait ham EEG verileri ve bu pencereden elde edilmiş olan İMF'ler.

5.2. Nöbet Algılama Çalışmaları ve Sonuçları

Bu çalışmada HHT analizi ile elde edilmiş öznitelikler kullanılmıştır. Veriler önce İMF'lerine ayrılmış ve bu İMF'lerin en büyük, en küçük, ortalama ve standart sapma değerleri ile enerjileri kullanılmıştır. Çalışmada sırasıyla aşağıdaki adımlar izlenmiştir:

1. EEG verilerinin gürültüden temizlenmesi; Veriler, durumlarına göre (nöbet anı, nöbet öncesi ve nöbetler arası) ayrılarak 50 Hz bant durduran filtreden geçirilmiştir. Yüksek geçiren filtre (120 Hz) ile DC bileşenler ve çok yavaş bozulmalar, alçak geçiren filtre (0,5 Hz) ile yüksek frekanslı bozulmalar filtrelenmiştir.
2. Gürültüden temizlenmiş verilerin bölütlere ayrılması; Bu analiz yönteminde, EEG verileri, önceden belirlenen uzunluktaki pencerelere bölünmekte, bu pencerelerden ölçüm/öznitelik çıkarımı yapılarak bir sonraki pencereye geçilmektedir. Nöbet algılama çalışmasında 10 saniyelik pencereler ve 5 saniyelik kaydırmalar (%50 örtüşme) kullanılmıştır.
3. EEG bölütlerinden AKA yöntemi yardımıyla özniteliklerin elde edilmesi; Hastaların epileptik nöbetin başlangıç bölgesi olarak belirlenen 3 odak elektrottan elde edilen veriler kullanılmıştır. Kullanılan her elektrottan elde edilen veriler AKA yöntemi uygulanarak İMF'lerine ayrılmıştır. İlk 4 İMF'nin zaman boyunca en küçük, en büyük, ortalama, standart sapma ve enerji değerleri hesaplanarak her zaman dilimi için öznitelik vektörleri elde edilmiştir.
4. Sınıflandırma; Nöbet algılama çalışmalarında veriler *Nöbet/Nöbet Değil* şeklinde 3 farklı sınıflandırmaya kullanılarak sınıflandırılmaktadır. Sınıflandırma için hastalardan alınan nöbet ve nöbetler arası veriler eğitim ve test aşamaları için kullanılmıştır. Test aşamasında eğitim için kullanılmayan veriler kullanılmıştır. Sistem test verileri ile sınanarak performansı açıklanmıştır. Bu sonuçlardaki değişkenliği azaltmak amacıyla 10-kat çapraz doğrulama kullanılmıştır. Bu işlemde veriler rastgele olarak 10 eşit parçaya bölünür ve her defasında bir parça test için geriye kalan 9 parça da eğitim için kullanılır. Böylece, eğitim-test işlemi 10 kere tekrarlanır. Sonuç olarak bireysel elde edilen 10 sonucun ortalaması alınır. Böylelikle her veri seti bir defa test için kullanılmış olur.

Sınıflandırma aşamasında K En Yakın Komşuluk (kNN), Destek Vektör Makinaları (DVM) ve Karar Ağaçları (KA) yöntemleri kullanılmıştır.

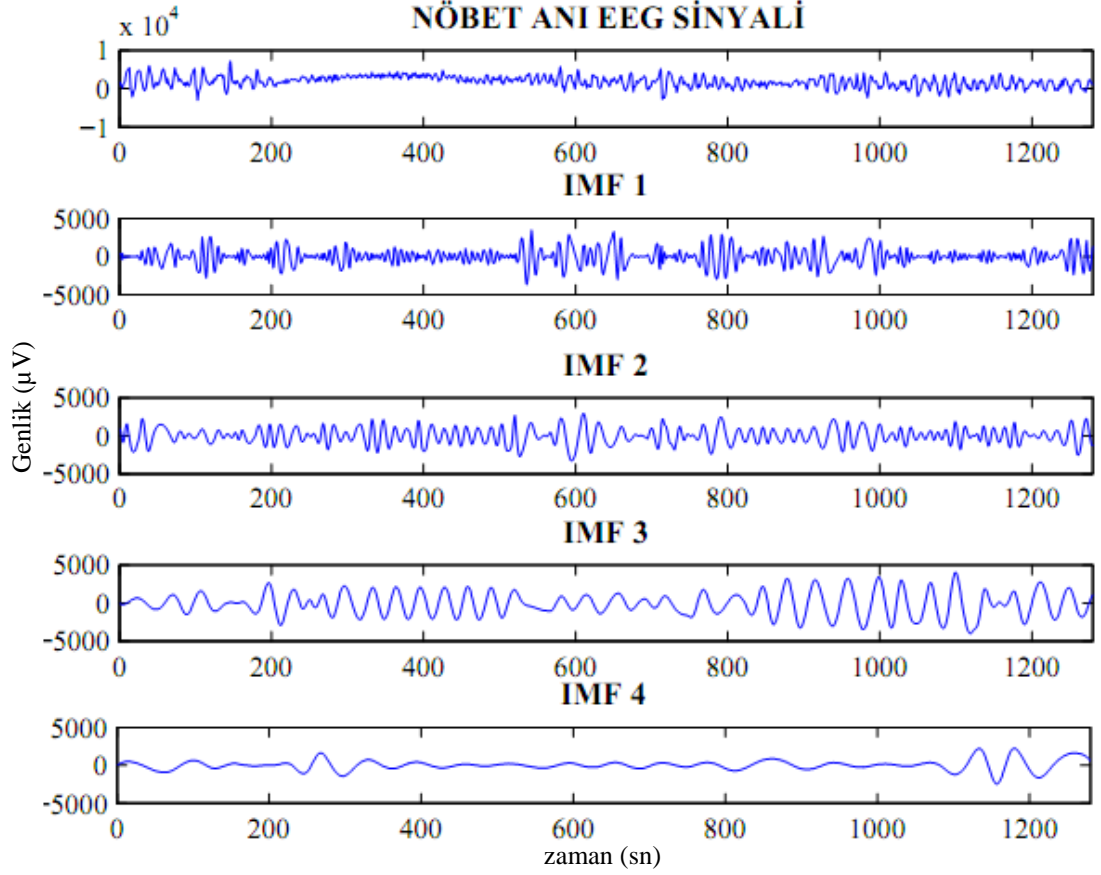
K En Yakın Komşuluk; Bu yöntem, örüntü tanıma ve makine öğrenmesi algoritmaları içinde en basit olanıdır. kNN algoritması, sınıflandırılmak istenen herhangi bir özellik vektörünün eğitici veri setinde var olan ve daha önceden bir sınıfın elemanı olduğu bilinen diğer özellik vektörleriyle belirlenen bir kritere göre karşılaştırılarak, en yakın olanların daha çok bulunduğu sınıfa ait olarak etiketlendirilmesi prensibine dayanmaktadır. Karşılaştırma kriteri olarak genelde Öklid uzaklığı kullanılmaktadır (Duda vd., 2001).

Destek Vektör Makinaları; DVM, son yıllarda yaygın olarak kullanılan bir sınıflandırma algoritmasıdır. Temelde doğrusal olarak ayrıştırılabilir iki sınıfın karar yüzeyinin destek vektörler olarak tanımlanan ve sınıf sınırlarını belirleyen örnekler arasında en yüksek mesafe oluşturulması ilkesine dayanan bir algoritmadır. Mesafeyi en yükseğe çıkarma işlemi, karesel sınırlamalı optimizasyon problemi şeklinde yazılır ve ikili biçime dönüştürülür. Doğrusal problemler için geliştirilen bu yaklaşım doğrusal olmayan ayrıştırma problemleri için kernel problemleri kullanılarak genelleştirilebilir (Cristianini ve Shawe-Taylor, 2000).

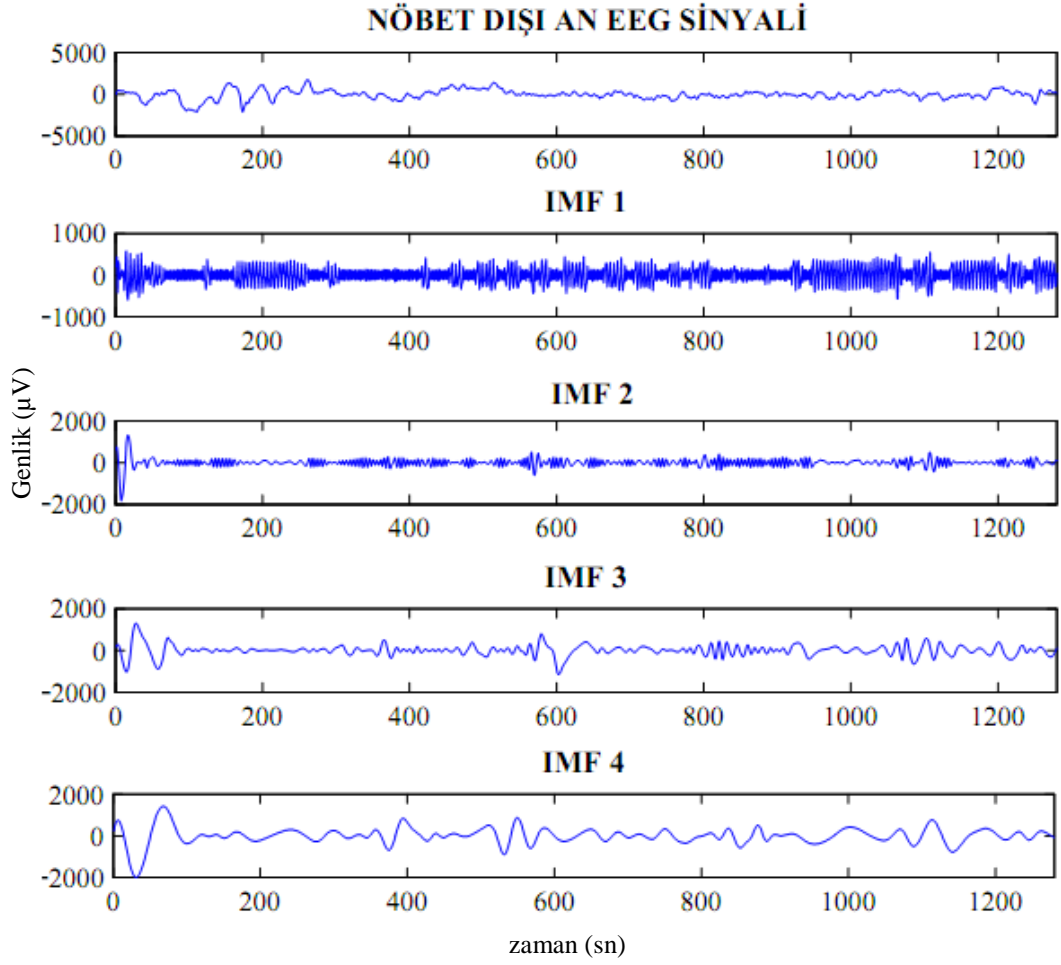
Karar Ağaçları; KA, son yıllarda literatürde yaygın kullanımı olan bir sınıflandırma ve örüntü tanımlama algoritmasıdır. Bir ağaç yapısı; verileri içeren bir kök düğümü, iç düğümler (dallar) ve uç düğümler (yapraklar) oluşur. Eğitim verilerine ait öznitelik bilgilerinden yararlanılarak bir karar ağacı yapısı oluşturulmasında temel prensip verilere ilişkin bir dizi sorular sorulması ve elde edilen cevaplar doğrultusunda hareket edilerek en kısa sürede sonuca gidilmesi olarak ifade edilebilir. Bu şekilde karar ağacı sorulara aldığı cevapları toplayarak karar kuralları oluşturur. Ağacın ilk düğümü olan kök düğümünde verilerin sınıflandırılması ve ağaç yapısının oluşturulması için sorular sorulmaya başlanır ve dalları olmayan düğümler ya da yapraklar bulunana kadar bu işlem devam eder. Karar ağaçlarının oluşturulmasındaki en önemli adım ağaçtaki dallanmanın hangi kritere göre yapılacağı ya da hangi öznitelik değerlerine göre ağaç yapısının oluşturulacağıdır. Bu çalışmada C4.5 algoritması kullanılarak sınıflandırma yapılmıştır (Quinlan, 1993).

Nöbet algılama çalışmasında, sınıflandırma aşamasının sağlıklı olabilmesi açısından, Freiburg Veritabanındaki 21 hastadan, nöbet süreleri ve sayıları eğitim ve test

aşamaları için yeterli sayıda pencere elde edilebilecek kadar uzun olan 12 hasta seçilmiştir. Öznitelik hesaplamalarında, 3 odak elektrotta kaydedilmiş olan işaretlerden elde edilen ilk 4 IMF kullanılmıştır. Enerji hesaplamasında zaman serisindeki gerçek değerler göz önünde bulundurulmuştur. Şekil 5.4 ve 5.5'te nöbet anı ve nöbet dışı anlara ait EEG veri penceresi ve bunlardan elde edilen İMF'ler gösterilmiştir.



Şekil 5.4. Nöbet anı EEG sinyali ve bu sinyalden elde edilmiş olan İMF'ler



Şekil 5.5. Nöbet dışı EEG sinyali ve bu sinyalden elde edilmiş olan İMF'ler

Nöbet algılama çalışması, 12 hastanın 49 nöbeti için yapılmıştır. 49 nöbete karşılık gelen 123 dakikalık (1475 EEG bölütü) veriler ile sistemin duyarlılığı ölçülmüştür. Sistemin belirliliğinin ölçülebilmesi için yaklaşık olarak toplam 200 dakika (2400 EEG bölütü) nöbet dışı an verisi kullanılmıştır. Duyarlılık, $DP/(DP+YN)$; belirlilik ise $DN/(DN+YP)$ şeklinde hesaplanmaktadır. Doğru pozitif (DP); nöbet anına ait bir pencerenin sınıflandırıcı tarafından nöbet olarak, yanlış negatif (YN); nöbet anındaki bir pencerenin nöbet değil olarak, yanlış pozitif (YP); nöbet dışı anına ait bir pencerenin nöbet olarak ve doğru negatif (DN); nöbet dışı anına ait bir pencerenin nöbet değil olarak sınıflandırılması durumunda ortaya çıkmaktadır. Tüm hastalar için elde edilen duyarlılık ve belirlilik oranları Çizelge 5.1'de verilmektedir.

Çizelge 5.1. Nöbet algılama için duyarlılık ve belirlilik sonuçları

Hasta No	Duyarlılık			Belirlilik		
	knn	dvm	ka	knn	dvm	ka
3	0,88	0,65	0,89	1,00	0,99	0,96
4	0,99	0,99	0,99	1,00	1,00	1,00
7	0,80	0,76	0,85	0,97	0,97	0,96
8	0,65	0,24	0,55	0,92	0,99	0,93
9	0,98	0,93	0,96	1,00	0,97	0,96
10	0,92	0,82	0,93	0,86	0,87	0,86
11	0,98	0,92	0,95	1,00	1,00	0,98
13	1,00	0,95	0,95	0,99	0,98	0,98
14	0,92	0,89	0,93	0,98	0,99	0,92
15	0,87	0,62	0,92	0,99	0,98	0,97
16	0,84	0,63	0,96	0,99	0,99	0,96
17	0,92	0,94	0,97	0,99	1,00	1,00
Ortalama	0,91	0,80	0,90	0,97	0,98	0,95

Çizelge 5.1.'deki sonuçlar tüm hastalar için genel olarak değerlendirildiğinde; kNN sınıflandırıcısının %90,51 duyarlılığa ve %97,25 belirliliğe, destek vektör makineleri sınıflandırıcısının %79,93 duyarlılığa ve %97,63 belirliliğe ve karar ağaçları sınıflandırıcısının %90,48 duyarlılığa ve %95,38 belirliliğe sahip olduğu görülmektedir (Özdemir vd., 2011).

5.3. Nöbet Tahmini Çalışmaları ve Sonuçları

Yapılan çalışmada, Freiburg veritabanındaki gürültüden temizlenerek, %50 örtüşen 30 ve 60 saniyelik pencerele ayrılan EEG verileri analiz edilmiştir. Bu pencerelerden çıkarılan İMF'lerden HHT yardımıyla çeşitli öznitelikler elde edilmiştir. Öznitelik seti olarak ilk 3, 4, 5 ve 6 İMF kullanılarak ayrı çalışmalar yapılmış ve her bir çalışma için YSA ve BAYESNet sınıflandırıcıları kullanılarak *nöbet öncesi/nöbetler arası* ikili sınıflandırma işlemi gerçekleştirilmiştir. YSA ile yapılan çalışmalar Korelasyon Tabanlı Öznitelik Seçimi (KTÖS) yöntemi ile öznitelik seçimi yapılarak

tekrarlanmış ve sonuçlar karşılaştırılmıştır. Karşılaştırma sonucunda KTÖS yöntemi ile öznitelik sayısının azaltılması işleminin YSA'daki başarıyı düşürdüğü görülmüştür. Bu nedenle KTÖS ile çok uyumlu çalıştığı bilinen BAYESNet sonuçları sadece öznitelik seçimi sonrasında verilmiştir.

5.3.1. Nöbet Tahmini İçin HHT Yöntemiyle Özniteliklerin Elde Edilmesi

EEG bölütlerinden elde edilen ilk 3,4,5 ve 6 İMF öznitelik çıkarımı için kullanılmıştır. Bu İMF'lerin zaman boyunca en küçük genlik değeri, en büyük genlik değeri ortalama genlik değeri, genliğinin standart sapması, toplam enerjisi, her İMF fonksiyonunun delta (0.5-4 Hz), teta (4-8 Hz), alfa (8-13 Hz), beta (13-30 Hz), gama ve üstü (30-50 Hz, 50-70 Hz, 70-90 Hz ve 90-128 Hz) frekans bantlarındaki enerjileri ve bu enerjilerin toplam enerjiye oranları ve tüm enerji değerlerinin standart skorları öznitelik olarak kullanılmıştır. Standart skorlar (5.2.)'deki şekilde hesaplanmıştır.

$$E_{st} = \frac{E - \mu_E}{\sigma_E} \quad (5.2)$$

Her kanaldan ($k=1,2,\dots,6$) alınan EEG verilerinin İMF'leri ($i=1,2,\dots,6$) çıkarılmış, çıkarılan her İMF'den öznitelikler (38'er adet) elde edilmiştir. Sonuç olarak, Çizelge 5.2'de de görüldüğü üzere; $6 \times 6 \times 38 = 1368$ adet öznitelik sınıflandırma çalışmaları için kaydedilmiştir. İlk 3 İMF'nin kullanıldığı çalışmada toplam 684, İlk 4 İMF'nin kullanıldığı çalışmada toplam 912, İlk 5 İMF'nin kullanıldığı çalışmada toplam 1140 öznitelik, ilk 6 İMF'nin kullanıldığı çalışmada ise tüm öznitelik seti kullanılmıştır.

Çizelge 5.2. Öznitelikler Çizelgesi

KANAL 1 KANAL 2 KANAL 3 KANAL 4 KANAL 5 KANAL 6	İlk 3 İMF	<ul style="list-style-type: none"> • Minimum Genlik • Maksimum Genlik • Ortalama Genlik • Genlik Standart Sapması • Toplam Enerji
	İlk 4 İMF	<ul style="list-style-type: none"> • Delta (0.5-4 Hz) Bandı Toplam Enerjisi • Teta (4-8 Hz) Bandı Toplam Enerjisi • Alfa (8-13 Hz) Bandı Toplam Enerjisi • Beta (13-30 Hz) Bandı Toplam Enerjisi
	İlk 5 İMF	<ul style="list-style-type: none"> • Gama 1 (30-50 Hz) Bandı Toplam Enerjisi • Gama 2 (50-70 Hz) Bandı Toplam Enerjisi • Gama 3 (70-90 Hz) Bandı Toplam Enerjisi • Gama 4 (90-128 Hz) Bandı Toplam Enerjisi
		<ul style="list-style-type: none"> • Delta (0.5-4 Hz) Bandı Toplam Enerjisi / Toplam Enerji • Teta (4-8 Hz) Bandı Toplam Enerjisi / Toplam Enerji • Alfa (8-13 Hz) Bandı Toplam Enerjisi / Toplam Enerji • Beta (13-30 Hz) Bandı Toplam Enerjisi / Toplam Enerji • Gama 1 (30-50 Hz) Bandı Toplam Enerjisi / Toplam Enerji • Gama 2 (50-70 Hz) Bandı Toplam Enerjisi / Toplam Enerji • Gama 3 (70-90 Hz) Bandı Toplam Enerjisi / Toplam Enerji • Gama 4 (90-128 Hz) Bandı Toplam Enerjisi / Toplam Enerji • Tüm enerji değerlerinin standart skorları
	İlk 6 İMF	

5.3.2. Öznitelik Seçimi

Bu çalışmada öznitelik seçimi için Korelasyon Tabanlı Öznitelik Seçimi yöntemi kullanılmıştır. Öznitelik seçme yöntemleri, orijinal veri kümesinden elde edilen öznitelik kümesi içerisinde belli sayıda öznitelik içeren bir alt küme seçerler. Öznitelik seçiminin en önemli avantajı, öznitelik elde etmek için harcanan zaman ve hesaplama maliyetinin azalmasıdır. Bunun yanı sıra sınıflandırma aşamasında hem eğitim, hem de test zamanları da kısalmıştır. Öznitelik seçimindeki amaç ilgisiz ve gereksiz özniteliklerin elenmesi ve sınıflandırma işleminde sonuca gerçek katkıyı sağlayan özniteliklerin seçilmesidir.

Öznelik seçiminde, verilerin dengesiz dağılımı göz önünde bulundurularak, ölçüt fonksiyonu olarak doğru sınıflandırılmış pencere sayısı değil, yüksek doğru pozitif sayısı ve düşük yanlış pozitif sayısı gözetilmiştir. Nöbet tahmin çalışmamızda kullandığımız veri setinde nöbet sayısı 2 ile 5 arasında değişmektedir. Yapılan çalışmalarda *nöbet öncesi* verilerden 40'ar dakikalık bölümler kullanıldığı için eğitim ve test aşamalarında 80 dakika ile 200 dakika arası *nöbet öncesi* verilere karşılık, yaklaşık 24 saatlik *nöbetler arası* veriler mevcuttur. *Nöbetler arası* verilere yüksek oranda meyil gösteren sınıf gruplarını değerlendirmek için, sadece doğru sınıflandırılmış pencere sayısının toplam pencere sayısına bölüdüğü doğruluk ölçütü yerine, doğru pozitif ve yanlış pozitif sayılarının değerlendirilmesi daha uygun görülmüştür. Doğru pozitif, bir nöbetin başlangıç noktasından önce en az bir pencerenin *nöbet öncesi* olarak; yanlış pozitif *nöbetler arası* bir pencerenin *nöbet öncesi* olarak sınıflandırılması durumunda ortaya çıkmaktadır. Süreklilik gösteren yanlış pozitifler tek olarak değerlendirilmektedir.

Öznelik seçimi sonrasında sınıflandırma için gerekli olduğu tespit edilen öznelikler Çizelge 5.3.'de verilmiştir.


Öznitelik seçiminden sonra sınıflandırma için gerekli olduğu tespit edilen öznitelikler Çizelge 5.3’de verilmiş olup, tüm hastalar için en çok kullanılan (✓) ve en az kullanılan öznitelikler rahatlıkla görülmektedir. Çizelge, kanallar açısından incelendiğinde, kanal katkılarının hastalara göre değişiklik gösterdiği ve genel olarak İMF’lerin çoğunun kullanıldığı, özellikle ilk 3 ve ilk 4 İMF'nin katkılarının daha çok olduğu görülmektedir. Öznitelikler, tamamlayıcı istatistikler ve enerjilere bakıldığında ise bant enerjilerinin öznitelik seçiminde etkin rol oynadığı görülmektedir.

5.4 Sınıflandırma

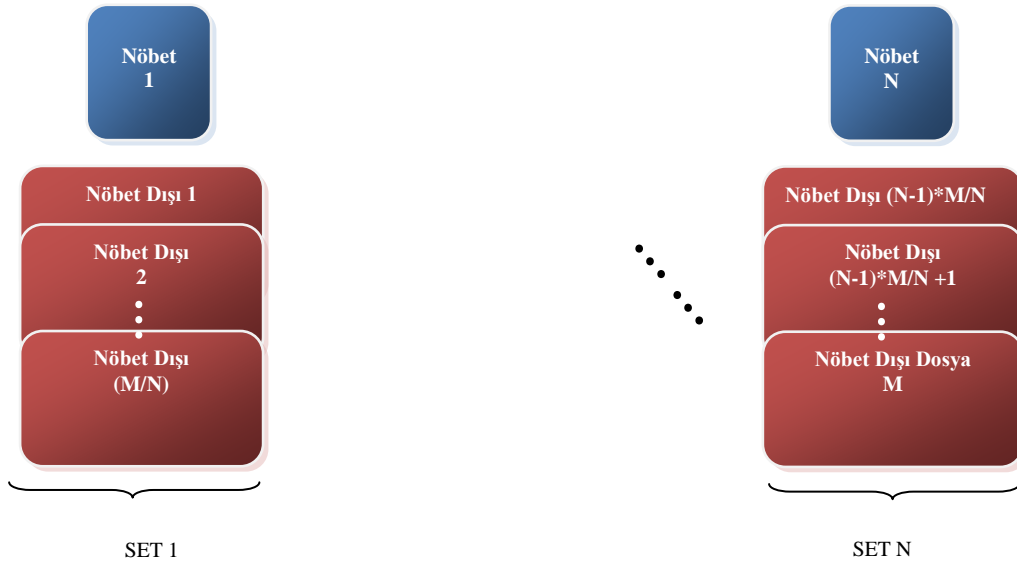
Sınıflandırma için, Yapay Sinir Ağları (YSA) ve BAYESNet yöntemleri kullanılmıştır. Son aşama olarak, sınıflandırma sonuçları, sahte algılamalara karşı sınıflandırma sonrası işleminden (post-processing) geçirilmiştir. Sınıflandırma sonuçları değerlendirilirken, toplam veri setinde önceden tahmin edilebilen nöbet sayısı ve saatte beklenen yanlış alarm sayıları göz önünde bulundurulmuştur.

Sınıflandırma sonuçları değerlendirilirken, çapraz doğrulama işlemi değil, verilerin eğitim ve test olarak ayrılması ile elde edilen gruplar kullanılmıştır. Bir hasta için *nöbet öncesi* ve *nöbetler arası* dosya gösterimleri Şekil 5.6.’da, dosyaların eğitim ve test için ayrılmış şekilleri ise Şekil 5.7.’de gösterilmektedir.

Her nöbetin öncesindeki veriler ve tüm *nöbetler arası* veriler birer defa test için ve en az birer defa (nöbet sayısına bağlı olarak bu sayı değişmektedir) eğitim için kullanılmıştır. *Nöbet öncesi* verilerden, nöbet anından önceki 40 dakikalık bölümler kullanılmıştır. Her hastaya ait *nöbet* ve *nöbetler arası* dosya sayısı Çizelge 5.4.’te verilmiştir.



Şekil 5.6. Bir hastaya ait *nöbet öncesi* ve *nöbetler arası* dosyaları gösterimi



Şekil 5.7. Dosyaların gruplandırılması

Çizelge 5.4. Hastalara göre nöbet ve nöbetler arası dosya sayıları

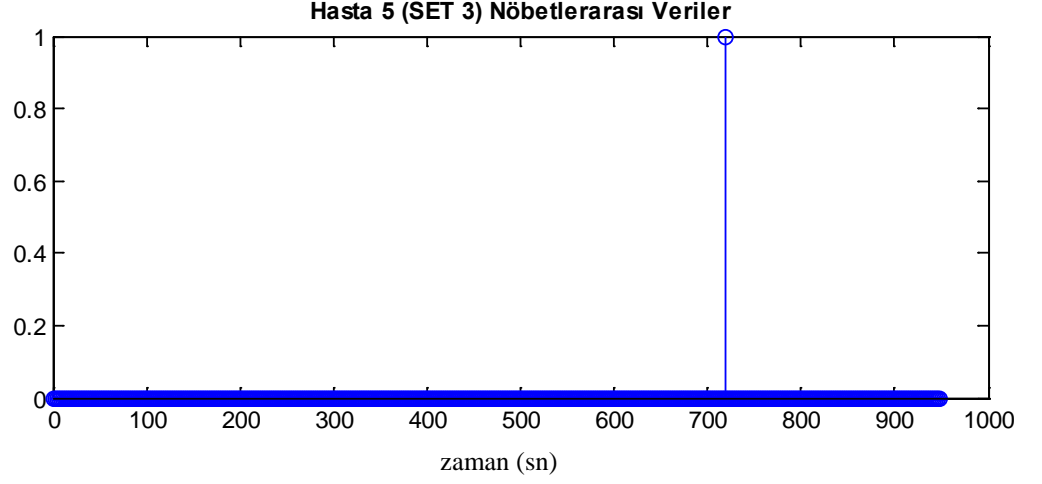
Hasta No	Nöbet Sayısı	Nöbetler arası Dosya Sayısı (Her Kanal İçin)
1	4	24
2	3	24
3	5	24
4	5	24
5	5	24
6	3	24
7	3	25
8	2	25
9	5	26
10	5	25
11	4	25
12	4	26
13	2	24
14	4	25
15	4	25
16	5	24
17	5	25
18	5	26
19	4	25
20	5	26
21	5	25

5.5. Sınıflandırma Sonrası İşleme (Post-Processing)

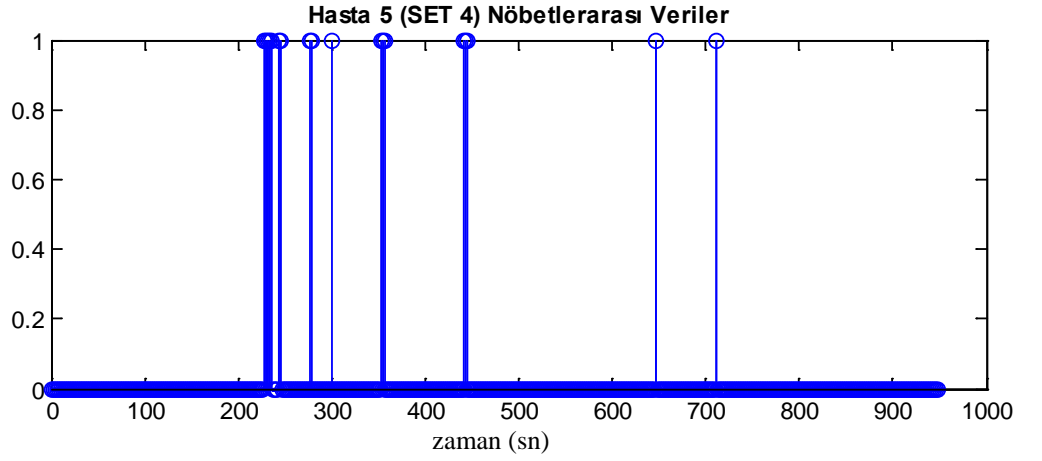
Sınıflandırma sonuçlarına bakıldığı zaman bazı yanlış pozitiflerin sadece kısa süreler için (1,2 pencere) geçerli olduğu, öncesi ve sonrasında uzun süreler boyunca *nöbet değil* sınıflandırmasının doğru şekilde yapıldığı gözlenmektedir. Kısa süreli değişimlerin herhangi bir gürültüden kaynaklanabileceği göz önünde bulundurularak, sınıflandırma sonrasında sonuçlar basit bir süreçten geçirilmiştir. Bu süreçle, izole olan yanlış pozitiflerin kaldırılması amaçlanmaktadır. Ancak aynı zamanda kısa süreli devam eden doğru pozitiflerin de bu işlem ile ortadan kalkacağı unutulmamalıdır. Diğer bir deyişle, bu işlem ile ancak süreklilik gösteren sonuçlar değerlendirmeye alınacaktır.

Bu süreçte, bir sonucun *Nöbet öncesi* olarak değerlendirilmesi için, önceki 2 dakika içerisinde çoğunlukla *Nöbet öncesi* olarak sınıflandırılmış olması gerekmektedir. 30 (60) saniyelik pencereler kullanılarak yapılan çalışmalarda; bir pencere, kendisi dahil olmak üzere son 7 (3) pencerenin en az 4'ü (2'si) *Nöbet öncesi* olarak sınıflandırılmışsa *Nöbet öncesi*, diğer durumlarda *Nöbetler arası* olarak değerlendirilmektedir.

Çizelgelerde yanlış pozitif sayıları (YP) ve buna bağlı olarak verilen saatteki yanlış pozitif sayıları (YP/saat) süreklilik gösteren yanlış alarmlar bir adet olarak düşünülecek şekilde verilmiştir. Yanlış alarm değerlendirmeleri için örnek gösterimler Şekil 5.8.'de verilmiştir.



(a)



(b)

Şekil 5.8. Örnek yanlış alarm gösterimleri. (a) YP sayısı=1, (b) YP sayısı=8

6. SONUÇ VE ÖNERİLER

Epilepsi teşhisinde, EEG işaretleri kullanılarak epileptik nöbet tahmini yapılması işlemi önemli bir yer tutmaktadır. Epilepsi, hastayı sadece nöbet anlarında ve bazı durumlarda bu nöbeti izleyen birkaç saat süreyle, rahatsız eden, bunun dışında normal yaşamına devam etmesini engellemeyen bir hastalıktır. Bu nedenle epilepsi tanısı konmuş bir hasta için nöbet geçirme zamanının önceden tespit edilebilmesi çok önemlidir. Erken nöbet teşhisinde, EEG işaretlerinden çıkarılan özelliklerin ve farklı parametrelerin önemli bilgiler taşıdığı kabul edilmektedir. EEG işaretlerini kullanarak epileptik nöbetlerin saptanması, epilepsi tanısı konulmasında önemli bir rol oynamaktadır. EEG sinyallerinin otomatik algoritmalar kullanılarak bilgisayarla analiz edilmesi, bu hastalığın tanısı için çok önemlidir.

Epileptik nöbet tahmin çalışmalarında nihai hedef, bir nöbetin yakın gelecekte ortaya çıkıp çıkmayacağını tespit edilmesidir. Bu durumda, önemli olan bir nöbet öncesinde geçen belli süre boyunca (bu çalışmada eğitim ve test için 40 dakikalık süre kullanılmıştır) tüm pencerelerin nöbet öncesi olarak bulunması değil, en azından bir nöbetin geldiğine dair işaretlerin alınması ve bu işaretin yeterince erken bulunmasıdır.

Yapılan çalışmada, 30 ve 60 saniyelik pencerelerden elde edilen ilk 3, 4, 5 ve 6 İMF'ler kullanılarak YSA ve BAYESNet ile sınıflandırma yapılmıştır. BAYESNet sonuçları sadece Korelasyon Tabanlı Öznitelik Seçimi ile değerlendirilmiş, ancak YSA sonuçları tüm öznitelikler kullanılarak ve öznitelik seçimi sonrası olarak verilmiştir. Yapılan çalışma ile elde edilen sonuçlar Çizelge 6.1.-6.6.'da verilmiştir.

Çizelge 6.1. Sınıflandırma sonuçları (BAYESNet_60 sn)

		BAYESNET (60 SN)															
		İLK 3 İMF				İLK 4 İMF				İLK 5 İMF				İLK 6 İMF			
		Hasta No	G.Nöb.Sa.	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP
1	4	4	1	38,50	0,04	4	1	38,50	0,04	4	1	38,50	0,04	4	1	38,50	0,04
2	3	3	2	34,33	0,08	3	1	37,33	0,04	3	1	34,00	0,04	3	1	37,33	0,04
3	5	5	1	31,80	0,04	5	1	31,80	0,04	5	1	31,80	0,04	4	1	31,80	0,04
4	5	5	1	36,40	0,04	5	1	36,40	0,04	5	1	36,40	0,04	5	1	36,40	0,04
5	5	4	32	28,50	1,20	5	33	30,00	1,24	4	31	29,70	1,17	4	33	30,20	1,24
6	3	2	13	35,17	0,51	2	14	35,00	0,55	3	13	36,17	0,51	3	12	37,67	0,47
7	3	3	0	37,83	0,00	3	0	38,00	0,00	3	0	38,00	0,00	3	0	38,00	0,00
8	2	2	4	35,25	0,16	2	3	35,25	0,12	2	5	24,00	0,20	2	5	24,00	0,20
9	5	5	0	38,50	0,00	5	0	38,50	0,00	5	0	38,50	0,00	5	0	38,50	0,00
10	5	5	4	37,90	0,15	4	3	33,30	0,11	4	3	30,90	0,11	4	3	30,90	0,11
11	4	3	0	28,63	0,00	3	0	28,63	0,00	3	0	28,63	0,00	3	0	28,63	0,00
12	4	4	1	38,50	0,04	4	1	38,50	0,04	4	1	38,50	0,04	4	1	38,50	0,04
13	2	1	0	18,75	0,00	1	0	18,75	0,00	1	0	18,75	0,00	1	0	18,75	0,00
14	4	3	27	34,38	1,05	4	26	33,13	1,01	3	27	33,13	1,05	3	27	33,13	1,05
15	4	4	11	38,50	0,42	4	7	38,50	0,27	4	7	38,50	0,27	4	7	38,50	0,27
16	5	5	8	37,70	0,30	5	9	37,70	0,33	5	13	33,70	0,48	5	12	37,70	0,45
17	5	5	46	37,70	1,71	5	43	38,20	1,60	5	43	38,10	1,60	5	42	38,20	1,56
18	5	5	8	38,50	0,29	5	8	38,50	0,29	5	8	38,50	0,29	5	8	38,50	0,29
19	4	2	39	28,88	1,47	3	37	28,88	1,39	3	74	28,88	2,78	3	64	28,88	2,40
20	5	5	34	31,80	1,23	5	41	33,30	1,48	5	41	33,30	1,48	5	46	28,60	1,66
21	5	4	6	35,70	0,22	4	6	35,70	0,22	4	6	35,70	0,22	4	6	35,70	0,22
Σ	87	79	238	-	-	81	235	-	-	80	276	-	-	79	270	-	-
Ortalama	-	-	-	34,85	0,43	-	-	34,83	0,42	-	-	34,11	0,50	-	-	34,27	0,49

Çizelge 6.2. Sınıflandırma sonuçları (YSA_60 sn)

		YSA (60 SN)																
		İLK 3 İMF				İLK 4 İMF				İLK 5 İMF				İLK 6 İMF				
		Hasta No	G.Nöb.Sa.	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm
YSA	1	4	4	3	38,50	0,11	4	2	38,50	0,08	4	2	38,50	0,08	4	5	38,50	0,19
	2	3	2	0	25,83	0,00	2	1	25,67	0,04	2	0	22,33	0,00	2	0	24,83	0,00
	3	5	5	0	38,20	0,00	5	1	38,50	0,04	5	0	37,90	0,00	5	1	38,50	0,04
	4	5	5	1	36,40	0,04	5	1	36,30	0,04	5	0	33,90	0,00	5	0	34,70	0,00
	5	5	5	54	28,60	2,03	3	66	26,30	2,48	3	72	28,70	2,71	4	56	26,90	2,11
	6	3	3	1	38,00	0,04	3	10	38,50	0,40	3	8	38,17	0,32	3	8	37,17	0,32
	7	3	3	28	38,00	1,07	3	2	37,67	0,08	3	1	38,50	0,04	3	0	38,50	0,00
	8	2	1	12	5,00	0,48	2	8	24,00	0,32	1	6	17,25	0,24	2	12	27,25	0,48
	9	5	5	0	38,50	0,00	5	0	38,50	0,00	5	0	38,50	0,00	5	1	38,50	0,04
	10	5	4	4	30,9	0,15	4	2	37,90	0,07	5	1	37,90	0,04	4	1	30,90	0,04
	11	4	3	5	26,38	0,20	3	3	30,13	0,12	3	7	27,25	0,28	3	2	26,50	0,08
	12	4	4	8	38,50	0,30	4	12	38,50	0,44	4	8	38,50	0,30	4	4	38,38	0,15
	13	2	1	0	19,50	0,00	0	0	3,75	0,00	0	1	0,50	0,04	0	0	0,50	0,00
	14	4	3	39	28,63	1,52	3	43	28,63	1,68	3	22	28,75	0,86	3	46	29,00	1,79
	15	4	4	14	38,38	0,54	4	4	38,25	0,15	4	22	38,50	0,84	4	11	38,13	0,42
	16	5	5	25	33,50	0,93	4	35	30,90	1,30	5	15	37,80	0,56	4	23	33,50	0,86
	17	5	5	20	35,70	0,74	5	25	35,70	0,93	5	34	36,20	1,26	5	38	38,50	1,41
	18	5	5	3	38,10	0,11	5	7	38,10	0,25	5	6	38,50	0,22	4	10	31,30	0,36
	19	4	3	50	28,63	1,88	3	62	28,38	2,33	3	44	28,88	1,65	3	20	24,00	0,75
	20	5	4	29	28,10	1,05	4	32	33,10	1,15	3	25	27,70	0,90	4	20	24,80	0,72
	21	5	5	5	36,40	0,19	5	3	36,50	0,11	5	7	36,50	0,26	4	6	37,70	0,22
Σ	87	79	301	-	-	76	319	-	-	76	281	-	-	75	264	-	-	
Ortalama	-	-	-	33,02	0,54	-	-	33,67	0,58	-	-	33,36	0,51	-	-	32,32	0,48	

Çizelge 6.3. Sınıflandırma sonuçları (YSA_KTÖS_60 sn)

		KORELASYON TABANLI ÖZNİTELİK SECİMİ VE YSA (60 SN)																
		İLK 3 İMF				İLK 4 İMF				İLK 5 İMF				İLK 6 İMF				
		Hasta No	G.Nöb.Sa.	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm
YSA_KTÖS	1	4	4	3	38,50	0,11	4	2	38,50	0,08	4	1	38,50	0,04	4	3	38,50	0,11
	2	3	2	2	22,00	0,08	2	0	17,83	0,00	2	2	21,00	0,08	2	5	37,17	0,20
	3	5	5	1	38,40	0,04	5	1	38,20	0,04	5	5	38,50	0,19	5	4	38,50	0,15
	4	5	5	0	36,40	0,00	5	0	35,70	0,00	5	0	36,40	0,00	5	0	36,40	0,00
	5	5	3	48	15,70	1,80	3	34	22,90	1,28	2	51	21,70	1,92	2	50	21,10	1,88
	6	3	3	10	38,33	0,40	3	2	38,50	0,08	3	7	38,50	0,28	3	9	37,50	0,36
	7	3	3	0	38,50	0,00	3	2	38,50	0,08	3	0	38,50	0,00	3	0	38,50	0,00
	8	2	2	19	24,00	0,75	2	5	17,75	0,20	1	8	36,25	0,32	2	13	15,00	0,52
	9	5	5	2	38,50	0,07	5	0	38,50	0,00	5	0	38,50	0,00	5	0	38,50	0,00
	10	5	4	3	33,80	0,11	4	4	30,90	0,15	4	3	35,40	0,11	4	2	35,40	0,07
	11	4	3	9	31,88	0,36	4	8	34,88	0,32	3	9	28,13	0,36	4	4	34,25	0,16
	12	4	4	2	34,00	0,07	4	8	34,00	0,30	4	6	34,00	0,22	4	6	33,88	0,22
	13	2	0	0	0,50	0,00	0	2	0,50	0,08	1	0	17,00	0,00	1	0	19,50	0,00
	14	4	3	40	29,00	1,56	3	33	28,63	1,29	3	40	28,63	1,56	3	33	28,75	1,29
	15	4	4	5	37,63	0,19	4	7	37,88	0,27	4	2	38,25	0,08	4	12	37,63	0,46
	16	5	5	22	33,40	0,82	4	16	30,90	0,60	4	17	30,90	0,63	4	16	30,90	0,60
	17	5	5	9	37,90	0,33	5	22	38,20	0,82	5	14	38,10	0,52	5	19	38,20	0,71
	18	5	5	2	38,50	0,07	5	4	38,50	0,14	5	4	32,70	0,14	5	4	38,50	0,14
	19	4	3	51	26,88	1,92	3	39	27,88	1,47	2	28	18,75	1,05	3	27	28,13	1,01
	20	5	4	22	36,50	0,79	4	23	30,00	0,83	3	17	23,60	0,61	4	22	28,60	0,79
	21	5	4	1	37,00	0,04	5	5	38,20	0,19	5	3	36,40	0,11	4	3	33,70	0,11
Σ	87	76	251	-	-	77	217	-	-	73	217	-	-	76	232	-	-	
Ortalama	-	-	-	32,96	0,45	-	-	32,62	0,39	-	-	32,26	0,39	-	-	33,47	0,42	

Çizelge 6.4. Sınıflandırma sonuçları (BAYESNet_30 sn)

BAYESNET (30 SN)																	
Hasta No	İLK 3 İMF					İLK 4 İMF				İLK 5 İMF				İLK 6 İMF			
	G.Nöb.Sa.	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm	FP/h
1	4	4	0	38,25	0,00	4	0	38,25	0,00	4	0	38,25	0,00	4	0	38,25	0,00
2	3	3	0	36,67	0,00	3	0	36,58	0,00	3	0	34,25	0,00	3	1	33,75	0,04
3	5	5	1	34,65	0,04	5	1	34,65	0,04	5	1	34,65	0,04	5	0	34,65	0,00
4	5	5	0	36,00	0,00	5	0	36,00	0,00	5	0	36,00	0,00	5	0	36,00	0,00
5	5	4	19	25,65	0,71	4	20	24,50	0,75	4	29	24,45	1,09	5	33	28,00	1,24
6	3	3	28	34,42	1,10	3	21	38,08	0,83	3	27	35,58	1,06	3	25	35,58	0,99
7	3	3	1	37,75	0,04	3	1	38,25	0,04	3	0	38,17	0,00	3	0	37,92	0,00
8	2	2	11	25,75	0,44	2	10	25,88	0,40	2	11	25,88	0,44	2	11	25,88	0,44
9	5	5	2	38,25	0,07	5	2	38,25	0,07	5	1	38,25	0,04	5	1	38,25	0,04
10	5	5	10	37,75	0,37	5	9	33,20	0,33	5	7	37,75	0,26	5	8	37,75	0,29
11	4	3	1	28,63	0,04	3	3	28,63	0,12	3	3	28,63	0,12	3	3	28,63	0,12
12	4	4	0	38,25	0,00	4	0	38,25	0,00	4	0	38,25	0,00	4	0	38,25	0,00
13	2	1	0	18,75	0,00	1	0	18,63	0,00	1	0	18,63	0,00	1	0	18,63	0,00
14	4	4	29	34,25	1,13	4	30	34,44	1,17	4	30	34,38	1,17	4	30	34,44	1,17
15	4	4	16	38,25	0,61	4	19	38,06	0,73	4	18	38,06	0,69	4	18	38,06	0,69
16	5	5	7	32,45	0,26	5	9	37,35	0,33	5	7	32,55	0,26	5	6	32,55	0,22
17	5	5	50	35,60	1,85	5	54	38,00	2,00	5	53	38,00	1,96	5	55	38,00	2,04
18	5	5	10	38,25	0,36	5	9	38,25	0,32	5	9	38,25	0,32	5	9	38,25	0,32
19	4	3	37	28,38	1,39	3	49	28,69	1,84	3	47	28,69	1,76	3	45	28,69	1,69
20	5	5	53	30,40	1,91	5	56	30,35	2,01	5	55	30,35	1,98	5	56	30,30	2,01
21	5	5	3	36,40	0,11	5	5	31,50	0,19	5	5	31,50	0,19	4	4	30,65	0,15
Σ	87	83	278	-	-	83	298	-	-	83	303	-	-	83	305	-	-
Ortalama	-	-	-	34,10	0,50	-	-	34,06	0,54	-	-	33,87	0,55	-	-	34,00	0,55

Çizelge 6.5. Sınıflandırma sonuçları (YSA_30 sn)

		YSA (30 SN)																
		İLK 3 İMF					İLK 4 İMF				İLK 5 İMF				İLK 6 İMF			
		Hasta No	G.Nöb.Sa.	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm
YSA	1	4	4	1	38,25	0,04	4	4	38,00	0,15	4	10	38,25	0,38	4	1	38,25	0,04
	2	3	2	1	24,83	0,04	2	0	17,92	0,00	2	2	15,25	0,08	2	0	25,50	0,00
	3	5	5	9	35,30	0,34	5	4	38,15	0,15	5	6	38,20	0,22	5	2	37,45	0,07
	4	5	5	1	29,10	0,04	5	1	28,70	0,04	5	0	35,90	0,00	5	1	36,00	0,04
	5	5	4	93	19,00	3,49	4	111	20,25	4,16	4	90	24,30	3,38	3	64	20,75	2,40
	6	3	3	11	37,67	0,43	3	9	38,25	0,35	3	3	36,17	0,12	3	17	37,92	0,67
	7	3	3	0	38,25	0,00	3	0	38,25	0,00	3	0	38,25	0,00	3	2	38,25	0,08
	8	2	0	2	0,25	0,08	1	5	0,38	0,20	1	5	4,38	0,20	1	8	5,00	0,32
	9	5	5	0	38,25	0,00	5	4	38,25	0,15	5	1	38,25	0,04	5	0	38,25	0,00
	10	5	5	3	35,55	0,11	4	7	30,60	0,26	5	3	37,8	0,11	4	8	30,65	0,29
	11	4	3	14	28,75	0,55	3	4	27,25	0,16	4	14	38,13	0,55	3	3	27,94	0,12
	12	4	4	8	38,25	0,30	4	16	38,25	0,59	4	2	38,25	0,07	4	4	38,25	0,15
	13	2	0	0	0,25	0,00	0	0	0,25	0,00	0	1	0,25	0,04	0	0	0,25	0,00
	14	4	3	50	28,44	1,94	3	43	28,38	1,67	4	64	33,5	2,49	3	38	28,38	1,48
	15	4	4	16	38,25	0,61	4	20	38,25	0,76	4	42	38,25	1,61	4	14	38,25	0,54
	16	5	5	27	33,20	1,00	4	18	30,65	0,67	5	37	38,25	1,37	5	15	37,40	0,56
	17	5	5	20	35,8	0,74	5	24	37,95	0,89	5	14	35,55	0,52	5	22	35,75	0,81
	18	5	5	10	38,25	0,36	5	11	38,25	0,40	5	9	38,25	0,32	5	11	38,25	0,40
	19	4	3	100	28,56	3,75	3	62	27,5	2,33	3	101	27,06	3,79	3	30	25,75	1,13
	20	5	4	61	25,85	2,19	5	44	32,85	1,58	5	29	35,25	1,04	3	42	20,10	1,51
	21	5	5	9	35,90	0,33	4	2	30,40	0,07	5	9	36,15	0,33	5	4	35,95	0,15
Σ	87	77	436	-	-	76	389	-	-	81	442	-	-	75	286	-	-	
Ortalama	-	-	-	31,45	0,78	-	-	31,09	0,70	-	-	33,58	0,80	-	-	31,67	0,51	

Çizelge 6.6. Sınıflandırma sonuçları (YSA_KTÖS_30 sn)

YSA_KTÖS		KORELASYON TABANLI ÖZNİTELİK SEÇİMİ VE YSA (30 SN)																
		İLK 3 İMF					İLK 4 İMF				İLK 5 İMF				İLK 6 İMF			
		Hasta No	G.Nöb.Sa.	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm	FP/h	B.Nöb.Sa.	FP	İlk Alarm
1	4	4	0	38,25	0,00	4	0	38,25	0,00	4	3	38,25	0,11	4	1	38,25	0,04	
2	3	1	0	6,25	0,00	1	1	5,17	0,04	1	1	5,25	0,04	1	0	5,92	0,00	
3	5	5	5	38,00	0,19	5	2	38,25	0,07	5	0	37,65	0,00	5	1	38,25	0,04	
4	5	5	0	36,00	0,00	5	0	36,00	0,00	5	0	36,00	0,00	5	0	36,00	0,00	
5	5	2	51	15,45	1,91	2	32	15,45	1,20	3	43	17,80	1,61	2	32	11,95	1,20	
6	3	2	5	35,17	0,20	3	2	38,00	0,08	3	8	37,67	0,32	3	6	38,17	0,24	
7	3	3	0	38,25	0,00	3	0	38,25	0,00	3	0	38,25	0,00	3	0	38,25	0,00	
8	2	2	3	23,63	0,12	2	5	23,63	0,20	1	6	4,88	0,24	2	5	23,50	0,20	
9	5	5	0	38,25	0,00	5	0	38,25	0,00	5	2	38,25	0,07	5	0	38,25	0,00	
10	5	5	2	37,55	0,07	5	2	38,25	0,07	5	3	37,55	0,11	5	1	35,45	0,04	
11	4	3	4	27,38	0,16	3	3	27,94	0,12	3	9	28,25	0,35	3	4	27,31	0,16	
12	4	4	3	38,25	0,11	4	5	38,25	0,18	4	1	38,25	0,04	4	5	38,25	0,18	
13	2	0	0	0,25	0,00	0	0	0,25	0,00	0	0	0,25	0,00	1	0	19,25	0,00	
14	4	3	31	28,69	1,21	3	29	32,75	1,13	3	30	28,38	1,17	3	35	28,56	1,36	
15	4	4	9	37,56	0,34	4	10	35,13	0,38	4	6	35,63	0,23	4	15	38,25	0,57	
16	5	4	7	30,65	0,26	4	15	30,65	0,56	5	7	33,20	0,26	4	16	30,65	0,59	
17	5	5	13	37,65	0,48	5	12	37,75	0,44	5	20	37,75	0,74	5	23	37,90	0,85	
18	5	5	1	38,10	0,04	5	3	38,25	0,11	5	1	38,25	0,04	5	3	37,60	0,11	
19	4	1	34	9,63	1,28	3	41	25,81	1,54	3	64	26,31	2,40	3	48	28,06	1,80	
20	5	5	29	35,00	1,04	4	28	30,30	1,01	5	24	31,35	0,86	4	29	24,80	1,04	
21	5	5	3	36,35	0,11	5	1	36,25	0,04	5	0	36,35	0,00	5	1	36,05	0,04	
Σ	87	73	200	-	-	75	191	-	-	77	228	-	-	76	225	-	-	
Ortalama	-	-	-	31,27	0,36	-	-	31,97	0,34	-	-	31,66	0,41	-	-	31,74	0,40	

Çizelge 6.1.'de, 60 saniyelik pencereler için, Korelasyon Tabanlı Öznitelik Seçimi sonrasında BAYESNet ile alınan sonuçlar verilmiştir. Bu sınıflandırmanın en başarılı sonuçları ilk 4 İMF'nin kullanıldığı pencerelerde elde edilmiştir. Bulunan nöbet sayısı bakımından %93,1 duyarlılık (87 nöbetin 81'i) elde edilmiş ve yanlış pozitif oranı 0,42 olarak bulunmuştur. İlk alarm süresi ise 18,75-38,5 dakika aralığında hesaplanmıştır.

Çizelge 6.2.'de, 60 saniyelik pencereler için, öznitelik seçimi yapılmadan YSA ile alınan sonuçlar verilmiştir. Bu sınıflandırmanın en başarılı sonuçları ilk 3 İMF'nin kullanıldığı pencerelerde elde edilmiştir. Bulunan nöbet sayısı bakımından %90,8 duyarlılık (87 nöbetin 79'u) elde edilmiş ve yanlış pozitif oranı yaklaşık olarak 0,54 bulunmuştur. İlk alarm süresi ise 5-38,5 dakika aralığında hesaplanmıştır.

Çizelge 6.3.'de, 60 saniyelik pencereler için, Korelasyon Tabanlı Öznitelik Seçimi sonrasında YSA ile alınan sonuçlar verilmiştir. Bu sınıflandırmanın en başarılı sonuçları ilk 4 İMF'nin kullanıldığı pencerelerde elde edilmiştir. Bulunan nöbet sayısı bakımından %88,5 duyarlılık (87 nöbetin 77'si) elde edilmiş ve yanlış pozitif oranı yaklaşık olarak 0,39 bulunmuştur. İlk alarm süresi ise yaklaşık 0,50-38,5 dakika aralığında hesaplanmıştır.

Çizelge 6.4.'de, 30 saniyelik pencereler için, Korelasyon Tabanlı Öznitelik Seçimi sonrasında BAYESNet ile alınan sonuçlar verilmiştir. Bu sınıflandırmada bütün İMF'ler için benzer sonuçlar alınmıştır. Bulunan nöbet sayısı bakımından %95,4 duyarlılık (87 nöbetin 83'ü) elde edilmiş ve yanlış pozitif oranı yaklaşık olarak 0,55 bulunmuştur. İlk alarm süresi ise yaklaşık 19-38 dakika aralığında hesaplanmıştır.

Çizelge 6.5.'de, 30 saniyelik pencereler için, öznitelik seçimi yapılmadan YSA ile alınan sonuçlar verilmiştir. Bu sınıflandırmanın en başarılı sonuçları ilk 5 İMF'nin kullanıldığı pencerelerde elde edilmiştir. Bulunan nöbet sayısı bakımından %93,1 duyarlılık (87 nöbetin 81'i) elde edilmiş ve yanlış pozitif oranı 0,80 bulunmuştur. İlk alarm süresi ise yaklaşık 4-38 dakika aralığında hesaplanmıştır. Ancak bu sınıflandırmada 13. hastanın hiçbir nöbeti bulunamamıştır.

Çizelge 6.6.'da, 30 saniyelik pencereler için, Korelasyon Tabanlı Öznitelik Seçimi sonrasında YSA ile alınan sonuçlar verilmiştir. Bu sınıflandırmanın en başarılı sonuçları ilk 5 İMF'nin kullanıldığı pencerelerde elde edilmiştir. Bulunan nöbet sayısı

bakımından %88,5 duyarlılık (87 nöbetin 77'si) elde edilmiş ve yanlış pozitif oranı yaklaşık olarak 0,41 bulunmuştur. İlk alarm süresi ise yaklaşık 5-38 dakika aralığında hesaplanmıştır. Ancak bu sınıflandırmada 13. hastanın hiçbir nöbeti bulunamamıştır.

Hastalara göre en başarılı sınıflandırma yöntemi ve bu sonuçların elde edildiği İMF'ler Çizelge 6.7. ile aşağıya çıkarılmıştır.

Çizelge 6.7. Hastalara göre en başarılı sınıflandırmalar

Hasta No	Nöbet Sayısı	Bulunan Nöbet Sayısı	Yanlış Pozitif	İlk Alarm (dakika)	YP/saat	Sınıflandırma Yöntemi	En Başarılı İMF'ler
1	4	4	0	38,25	0,00	BAYESNet_30 sn	İlk 3,4,5,6 İMF
2	3	3	0	36,67	0,00	BAYESNet_30 sn	İlk 3 İMF
3	5	5	0	34,65	0,00	BAYESNet_30 sn	İlk 6 İMF
4	5	5	0	36,00	0,00	BAYESNet_30 sn	İlk 3,4,5,6 İMF
5	5	5	33	28,00	1,24	BAYESNet_30 sn	İlk 6 İMF
6	3	3	21	38,08	0,83	BAYESNet_30 sn	İlk 4 İMF
7	3	3	0	38,25	0,00	BAYESNet_30 sn	İlk 5 İMF
8	2	2	11	25,88	0,44	BAYESNet_30 sn	İlk 4,5,6 İMF
9	5	5	1	38,25	0,04	BAYESNet_30 sn	İlk 5 ve 6 İMF
10	5	5	7	37,75	0,26	BAYESNet_30 sn	İlk 5 İMF
11	4	3	1	28,63	0,04	BAYESNet_30 sn	İlk 3 İMF
12	4	4	0	38,25	0,00	BAYESNet_30 sn	İlk 3,4,5,6 İMF
13	2	1	0	18,75	0,00	BAYESNet_30 sn	İlk 3 İMF
14	4	4	18	38,06	0,69	BAYESNet_30 sn	İlk 5,6 İMF
15	4	4	16	38,25	0,61	BAYESNet_30 sn	İlk 3 İMF
16	5	5	9	37,35	0,33	BAYESNet_30 sn	İlk 4 İMF
17	5	5	53	38,00	1,96	BAYESNet_30 sn	İlk 5 İMF
18	5	5	9	38,25	0,32	BAYESNet_30 sn	İlk 4,5,6 İMF
19	4	3	45	28,69	1,69	BAYESNet_30 sn	İlk 6 İMF
20	5	5	53	30,40	1,91	BAYESNet_30 sn	İlk 3 İMF
21	5	5	3	36,40	0,11	BAYESNet_30 sn	İlk 3 İMF

Çizelge incelendiğinde tüm hastalar için en başarılı sınıflandırmanın 30 saniyelik pencerelerde BAYESNet yöntemi ile elde edildiği görülmektedir. Ancak hastalar arasında öznelilikler çıkarılırken kullanılan İMF sayıları arasında farklılıklar olduğu sonucu çıkarılmıştır. Hastaların %50'den fazlasında ilk 6 İMF'nin kullanıldığı pencerelerden daha fazla başarı elde edilmiştir. Bu sonuçlar Çizelge 6.8.'de verilmiştir.

Çizelge 6.8. En başarılı sınıflandırma sonuçları (BAYESNet_30 sn)

Hasta No	Nöbet Sayısı	Bulunan Nöbet Sayısı	Yanlış Pozitif	İlk Alarm (dakika)	YP/saat
1	4	4	0	38,25	0,00
2	3	3	1	33,75	0,04
3	5	5	0	34,65	0,00
4	5	5	0	36,00	0,00
5	5	5	33	28,00	1,24
6	3	3	25	35,58	0,99
7	3	3	0	37,92	0,00
8	2	2	11	25,88	0,44
9	5	5	1	38,25	0,04
10	5	5	8	37,75	0,29
11	4	3	3	28,63	0,12
12	4	4	0	38,25	0,00
13	2	1	0	18,63	0,00
14	4	4	30	34,44	1,17
15	4	4	18	38,06	0,69
16	5	5	6	32,55	0,22
17	5	5	55	38,00	2,04
18	5	5	9	38,25	0,32
19	4	3	45	28,69	1,69
20	5	5	56	30,30	2,01
21	5	4	4	30,65	0,15
Toplam	87	83	305	-	-
Ortalama		-	-	34,00	0,55

Bu çalışmada Freiburg veri tabanındaki tüm hastalar analiz edilmiş olup toplamda kayıtlı bulunan 87 nöbetin 83 tanesi nöbet başlangıcından 40 dakika önceki zaman diliminde tahmin edilebilmiştir. Çizelge 6.8.'de ilk alarm zaman sütunu, hastalar için bir nöbetin ortalama olarak ne kadar süre önce tespit edilebildiğini göstermektedir. Bu sonuçlara göre, 21 hastanın 8'i için nöbetler yaklaşık 38 dakika öncesinde, 8'i için 30,30-36 dakika öncesinde, 4'ü için 25,88-28,69 dakika öncesinde tahmin edilebilmekte, 13. hasta için nöbetler nöbet başlangıcından 18,63 dakika öncesinde tahmin edilebilmektedir.

Sonuçlar genel olarak değerlendirildiğinde, önerilen sistem saatte 0,55 yanlış pozitif ile sonuçlanabilme ihtimaline karşılık %95,4 duyarlılığa sahiptir. 18 hastanın tüm nöbetleri tahmin edilebilmiş, diğer 3 hasta için ise nöbetlerin en az %50'si öngörülebilmiştir. Bir pencerenin hangi sınıfa ait olduğunun tespit edilebilmesi için

harcanan toplam süre yaklaşık 4 saniye olup, bu sürenin 15 saniye olan kaydırma miktarından çok daha küçük olması sebebiyle, sistemin gerçek zamanlı bir epileptik nöbet tahmini için uygun olduğu görülmektedir.

2000’li yılların başında Freiburg veritabanı üzerinde yapılan çalışmaların çoğunda %50’nin altında duyarlılık elde edilmiştir (Aschenbrenner-Scheibe vd., 2003; Winterhalder vd., 2003; Maiwald vd., 2004). D’Alessandro ve diğerleri %62.5 duyarlılık elde ettiklerini belirtmiş ve nöbet tahmin süresi olarak 3.455 dakikalık tahmin süresini not etmişlerdir (D’Alessandro vd., 2003). 2011 yılında veritabanındaki 21 hastadan 18’inin incelendiği bir çalışmada (Park vd., 2011), incelenen 80 nöbetin 78 tanesinin tahmin edilebildiği belirtilmiş ancak tahminlerin nöbet başlangıcından ne kadar önce yapılabildiği bilgisi verilmemiştir. Literatürdeki bu sonuçlara bakıldığında, yapılan çalışmada nöbetlerin, oluşumundan yeterince uzun bir süre öncesinde yüksek bir duyarlılık oranı ile tahmin edilebildiği görülmektedir.

Sistem invaziv EEG verileri ile eğitilmiş ve test edilmiştir. Ancak, eğitim ve test için kullanılacak EEG kayıtlarının olması durumunda, öznitelik elde etme yöntemi ASCII verilerden belli aşamalardan sonra elde edilebildiği için, kullanılabilir bir sistemdir. Sistem, bu tez kapsamında, bu tür EEG verileri ile test edilmemiş ve böyle bir eğitim test sonucunda nasıl bir duyarlılık ve belirlilik elde edilebileceği üzerine bir çalışma yapılmamıştır. Ancak böyle bir analizin gelecek çalışmalarda yapılabileceği düşünülmektedir.

Bu çalışma, otomatik nöbet tahmin sistemi için önemli bir adım atılmıştır. Bu sistemin sınıflandırma aşamasında, literatürde hali hazırda kullanılan özniteliklerin yanında HHT yöntemi yardımıyla yeni tanımlanan öznitelikler kullanılması, bunlar arasından nöbet tahmini için en etkili özniteliklerin bulunması hedeflenmiştir. Bu çalışmanın sonucunda elde edilen bu öznitelikler hem daha sonra yapılacak olan bilimsel çalışmalarda hem de klinik uygulamalarda kullanılacaktır.

KAYNAKLAR

- Adelson P.D., Nemoto E., Scheuer M., Painter M., Morgan J., Yonas H., 1999. Noninvasive continuous monitoring of cerebral oxygenation periictally using nearinfrared spectroscopy: a preliminary report. **Epilepsia**, 40: 1484–9.
- Andrade A.O, Nasuto S., Kyberd P., Sweeney-Reed C.M., and Van Kanijn F.R., 2006. EMG signal filtering based on empirical mode decomposition. **Biomedical Signal Processing and Control**, vol. 1, no. 1, pp. 44 – 55.
- 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, p. 061907.
- Aschenbrenner-Scheibe R., Maiwald T., Winterhalder M., Voss H.U., Timmer J., Schulze-Bonhage A., 2003. How well can epileptic seizures be predicted? An evaluation of a nonlinear method. **Brain**, 126: 2616–26.
- Babloyantz A.,Salazar J.M. and Nicolis C., 1985. **Evidence of chaotic dynamics of brain activity during the sleep cycle**. 111:3.152-156.
- Baumgartner C., Serles W., Leutmezer F., Pataraiia E., Aull S., Czeck T., Pietrzyk U., Relic A., Podreka I., 1998. Preictal SPECT in temporal lobe epilepsy: regional cerebral blood flow is increased prior to electroencephalography-seizure onset. **Jnuclmed.**; 39: 978–82.
- Bayes, T., 1763. **An Essay towards Solving a Problem in the Doctrine of Chances**, **Philosophical Transactions**. (1683 – 1775), 53(1763): 370 – 418.
- Buzsaki G., 2006. Cycle 9, The Gamma Buzz. **Rhythms of the brain**, Oxford, <http://www.amazon.com/dp/0195301064>.
- Causa L., Held C.M., Causa J., Estevez P.A., Perez C.A., Chamorro R., Garrido M., Algarin C., Peirano P., 2010. Automated Sleep-Spindle Detection in Healthy Children Polysomnograms. **Biomedical Engineering**, IEEE Transactions on, Vol.57,pp.2135-2146.
- Chan, Y. T., 1995. **Wavelet Basics**. Boston: Kluwer.
- Chin-Feng L., Shan-Wen Y., Yu-Yi C., Tsung-Ii P., Jung-Hua W. and Shun-Hsyung C., 2008. A HHT-based Time Frequency Analysis Scheme in Clinical Alcoholic EEG Signals. **Wseas Transactions On Biology And Biomedicine**, Issue 10, Volume 5.
- Claasen, T. A. C. M. & Mecklenbrauker, W. F. G., 1980a. The Wigner distribution|a tool for time-frequency signal analysis. **I. Continuous time signals**. Philips JI Research. 35, 217-250.

- Claasen, T. A. C. M. & Mecklenbrauker, W. F. G., 1980b. The Wigner distribution|a tool for time-frequency signal analysis. II. **Discrete time signals**, Philips JI Research, 35, 276-300.
- Claasen, T. A. C. M. & Mecklenbrauker, W. F. G., 1980c. The Wigner distribution|a tool for time-frequency signal analysis. III. **Relations with other time-frequency signal transformations**, Philips JI Research. 35, 372-389.
- Cohen L., 1995. **Time-frequency analysis**. Englewood Cliffs, NJ: Prentice-Hall.
- Cristianini N. and Shawe-Taylor J., 2000. **An introduction to support vector machines**. Cambridge: Cambridge University Press.
- Cui S., Li X., Ouyang G., Guan X., 2005. Detection of epileptic spikes with empirical mode decomposition and nonlinear energy operator. **International symposium on Neural Networks**, Chongqing, China, May 2005, Lecture Notes in Computer Science, Springer, Vol. 3498, pp. 445–450.
- D'Alessandro M., Esteller R., Vachtsevanos G., Hinson A., Echauz J., Litt B., 2003. Epileptic seizure prediction using hybrid feature selection over multiple EEG electrode contacts: a report of four patients. **IEEE Trans Biomed Eng.**, 50(5):603–15.
- Datig, M. and Schlurmann, T., 2004. Performance and limitations of the Hilbert-Huang transformation (HHT) with an application to irregular water waves. **Ocean Engineering**. v31 i14. 1783-1834.
- Deering R. and Kaiser J. F., 2005. The Use of a Masking Signal to Improve Empirical Mode Decomposition. **Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing**, 4:485–488.
- Diez P.F, Mut V., Laciari E., Torres A. and Avila E., 2009. Application of the empirical mode decomposition to the extraction of features from EEG signals for mental task classification. **Conf Proc IEEE Eng Med Bio Soc.I**, pp.2579-S2.
- Duda R.O., Hart P.E. and Stork D.G., 2001. **Pattern Classification (2nd Ed.)**. Wiley-Interscience.
- Duman F., Erođul O., Telatar Z., Yetkin S., 2005. Automatic Sleep Spindle Detection and Localization Algorithm. **EUSIPCO 2005, 13th. European Signal Processing Conference**, On Conference CD-ROM, Antalya.
- Eftekhari, A, Vohra, F, Toumazou, C, Drakakis, E.M, Parker, K., 2008. Hilbert-Huang Transform: Preliminary studies in Epilepsy and Cardiac Arrhythmias. **IEEE BIOCAS (Biomedical Circuits and Systems Conference)**, 373-37.
- Esteller R, Echauz J, D'Alessandro M, Worrell G, Cranston S, Vachtsevanos G, et al., 2005. Continuous energy variation during the seizure cycle: towards an on-line accumulated energy. **Clin Neurophysiol.**, 116: 517–26.

- Farge M., 1992. Wavelet transforms and their applications to turbulence. **Ann. Rev. Fluid Mech.** 24, 395 - 457.
- Ferber G., 1987. Treatment of some non-stationarities in the EEG. **Neuropsychobiology**, 17, pp.100–104.
- Flandrin P., Rilling G., and Goncalves P., 2004. Empirical mode decomposition as a filter bank. **IEEE Signal Process. Lett.**, vol. 11, no. 2, pp. 112–114.
- Franzke C., 2009. Multi-scale analysis of teleconnection indices: climate noise and nonlinear trend analysis. **Nonlinear Processes in Geophysics**, 16 (1). 65-76.
- Freiburg Veritabanı EEG Database at the Epilepsy Center of the University Hospital of Freiburg, Germany. [https://epilepsy.uni-freiburg.de/freiburg-seizure-prediction-project/eeg-database/\(http://www.fdmold.uni-freiburg.de/epilepsydata/download/\)](https://epilepsy.uni-freiburg.de/freiburg-seizure-prediction-project/eeg-database/(http://www.fdmold.uni-freiburg.de/epilepsydata/download/)) Mart 2010.
- Gath I., Feuerstein C., Pham D.T. And Rondoun G., 1992. On The Tracking Of Rapid Dynamic Changes İn Seizure EEG. **IEEE Trans. Biomed. Eng.**, 39: 952-958.
- Gigola S., Ortiz F., D’Attellis C.E., Silva W., Kochen S., 2004. Prediction of epileptic seizures using accumulated energy in a multiresolution framework. **J Neurosci Methods**, 138: 107–111.
- Gotman J., 1983. Measurement of small time differences between EEG channels: method and application to epileptic seizure propagation. **Electroencephal. Clin. Neurophysiol.**, 56: 501-514
- Gotman J., 1987. Interhemispheric interactions in seizures of focal onset: data from human intracranial recordings. **Electroencephal, Clin. Neurophysiol.** 67:120-133.
- Güler N.F., Übeyli E.D., Güler İ., 2005. Recurrent neural networks employing Lyapunov exponents for EEG signals classification. **Expert Systems with Applications.**, 29(3):506-514
- Gürsoy M.I, Subası A., 2008. DVM ile EEG isaretlerinin sınıflandırılmasında TBA, BBA ve DAA'nın performansının karşılaştırılması. **16. IEEE SIU (Signal Processing, Communication and Applications) Konferansı**, 20-22 Nisan 2008;1-4.
- Hall, M.A., 1998. **Correlation-based feature selection machine learning**. PhD thesis, Department of Computer Science, University of Waikato, New Zealand.
- Haykin S., 1991. **Advances in Spectrum Analysis and Array Processing**. vol.1, Prentice-Hall.
- Huang H. ve Jiaqiang P., 2006. Speech pitch determination based on Hilbert–Huang transform. **Signal Process.** 86 (4), pp. 792–803.

- 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. **Young Computer Scientists, ICYCS 2008**, The 9th International Conference for , vol., no., pp.1706-1710, 18-21.
- Huang, N. E., Long, S. R. & Shen, Z. 1996. The mechanism for frequency downshift in nonlinear wave evolution. **Adv. Appl. Mech.** 32, 59-111.
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, S. H., Zheng, Q., Tung, C. C., and Liu, H. H., 1998. The empirical mode decomposition method and the Hilbert spectrum or non-stationary time series analysis. **Proc. Roy. Soc. London**, A454, 903-995.
- Hwang P.A., Huang N.E and. Wang D.W., 2003. A note on analyzing nonlinear and nonstationary ocean wave data. **Appl. Ocean Res.** 25 (4), pp. 187-193.
- Iasemidis L.D., Olson L.D., Savit R.S., Sackellares J.C., 1994. Time dependencies in the occurrences of epileptic seizures: a nonlinear approach. **Epilepsy Res.**, 17(1):81-94.
- Jerger K.K., Netoff T.I., Francis J.T., Sauer T., Pecora L., Weinstein S.L., 2001. Early seizure detection. **J. Clin. Neurophysiol.**; 18: 259-68.
- Junsheng C., Dejie Y. and Yu Y., 2006. Research on intrinsic mode function (IMF) criterion in EMD method. **Mechanical Systems and Signal Processing** 20 , pp. 817-824.
- Kawabata, N., 1973. A non-stationary analysis of the electroencephalogram. **IEEE Trans Biomed Eng** 20, pp. 444-452.
- Korb, K.B. and Nicholson, A.E., 2003. **Bayesian Artificial**. Intelligence, Chapman & Hall/CRC, Florida, 392p.
- Le Van Quyen M., Martinerie J., Baulac M., Varela F., 1999. Anticipating epileptic seizure in real time by a nonlinear analysis of similarity between EEG recordings. **Neuroreport.**; 10: 2149-55.
- Le Van Quyen M., Adam C., Martinerie J., Baulac M., Clemenceau S., Varela F., 2000. Spatio-temporal characterization of non-linear changes in intracranial activities prior to human temporal lobe seizures. **Eur J Neurosci.**;12: 2124-34.
- Le Van Quyen M., Martinerie J., Navarro V., Boon P., D'Havé M., Adam C., Renault B., Varela F., Baulac M., 2001. Anticipation of epileptic seizures from standard EEG recordings. **Lancet.**, 357: 183-188.
- Le Van Quyen M., Soss J., Navarro V., Robertson R., Chavez M., Baulac M., et al.,2005. Preictal state identification by synchronization changes in long-term intracranial EEG recordings. **Clin Neurophysiol** , 116: 55968.

- Lee Z.K., Wu T.H., Loh C.H., 2003. System identification on the seismic behavior of an isolated bridge. **Earthquake Engineering and Structural Dynamics**.
- Lehnertz K, Le Van Quyen M, Litt B., 2007. **Seizure Prediction**. In: Engel J, Pedley T (eds.) *Epilepsy: A Comprehensive Textbook*, 2nd Ed. Volume 1. Chapter 85.
- Lehnertz K., Andrzejak R.G., Arnhold J., Kreuz T., Mormann F., Rieke C., 2001. Nonlinear EEG analysis in epilepsy: its possible use for interictal focus localization, seizure anticipation, and prevention. **J Clin Neurophysiol.**, 18: 209–22.
- Lehnertz K., Litt B. 2005. The first international collaborative workshop on seizure prediction: summary and data description. **Clinical Neurophysiology.**, 116:493-505.
- Lei M., Meng G. And Jiashui C., 2009. Analysis of surface EMG signal based on empirical mode decomposition. **Rehabilitation Robotics, 2009. ICORR 2009.** IEEE International Conference on, vol., no., pp.230-233, 23-26 June 2009.
- Li X.L., 2006. Temporal structure of neuronal population oscillations with empirical model decomposition. **Phys Lett A** 356 (3) (2006), pp. 237–241.
- Li Y., Yingle F., Gu L., Qinye T., 2009. Sleep stage classification based on EEG Hilbert-Huang transform. **Industrial Electronics and Applications, 2009. ICIEA 2009. 4th IEEE Conference on** , vol., no., pp.3676-3681, 25-27 May 2009.
- Liang H., Bressler S.L., Desimone R., and Fries P., 2005. Empirical mode decomposition of local field potentials from macaque V4 in visual spatial attention. **Biol. Cybern.**, vol. 92, pp. 380–392.
- Lin Y. K. & Cai, G. Q. 1995. **Probabilistic structural dynamics: advanced theory and applications**. New York: McGraw-Hill.
- Litt B., Esteller R., Echaz J., D'Alessandro M., Shor R., Henry T., et al. 2001. Epileptic seizures may begin hours in advance of clinical onset: a report of five patients. **Neuron**. 2001; 30: 51–64.
- Liu S. C., 1971. Time varying spectra and linear transformation. **Bell System Tech. JI** 50, 2365-2374.
- Liu S. C., 1970. Evolutionary power spectral density of strong earthquake. **Bull. Seism. Soc. Am.** 60, 891-900.
- Liu S. C., 1973. An approach to time-varying spectral analysis. **J. EM. Div. ASCE** 98, 245-253.
- Long S. R., Lai R. J., Huang N. E. & Spedding, G. R. 1993. Blocking and trapping of waves in an inhomogeneous flow. **Dyn. Atmos. Oceans** 20, 79 - 106.

- Lu Y., Yan J., and Yam Y., 2009. Model-based ECG Denoising Using Empirical Mode Decomposition. **IEEE International Conference on Bioinformatics and Biomedicin.**
- Maiwald T., Winterhalder M., Aschenbrenner-Scheibe R., Voss H.U., Schulze-Bonhage A., Timmer J. 2004. Comparison of three nonlinear seizure prediction methods by means of the seizure prediction characteristic. **Physica D** . 2004;194: 357–68.
- Martinerie J., Adam C., Le Van Quyen M., Baulac M., Clemenceau S., Renault B., Varela F.J., 1998. Epileptic seizures can be anticipated by non-linear analysis. **Nature Medicine**. 1998; 4: 1173–6.
- Meier R., Dittrich H., Schulze-Bonhage A., Aertsen A., 2008. Detecting epileptic seizures in long-term human EEG: a new approach to automatic online and real-time detection and classification of polymorphic seizure patterns. **J Clin Neurophysiol**, 25, pp. 119–131.
- Meng H.; Guang L.; Qiuping D. Jiaojie L., 2005. Classification of Normal and Hypoxia EEG Based on Hilbert Huang Transform. **Neural Networks and Brain, 2005. ICNN&B '05. International Conference on** , vol.2, no., pp.851-854, 13-15 Oct. 2005.
- Mirowski P., Lecun Y., Madhavan D., Kuzniecky R., 2008. Comparing SVM and Convolutional Networks for Epileptic Seizure Prediction from Intracranial EEG. **IEEE Workshop on MLSP (Machine Learning for Signal Processing)**. 16-19 Oct. 2008:244-249.
- Mohammad, N., Achmad, J., Mohamad, A.M., 2002. Automatic Detection of Epileptic Spikes Based on Wavelet Neural Network. **IEEE APCCAS Asia-Pacific Conference on Circuits and Systems**, 2002, 2, 483–486.
- Mormann F., Andrzejak R.G., Elger C.E., Lehnertz K. 2007. Seizure prediction: the long and winding road. **Brain**;130:314–33.
- Mormann F., Andrzejak R.G., Kreuz T., Rieke C., David P., Elger C.E., Lehnertz K., 2003. Automated detection of a pre-seizure state based on a decrease in synchronization in intracranial EEG recordings from epilepsy patients. **Phys Rev E**. 2003; 67:021912.
- Mormann F., Kreuz T., Andrzejak R.G., David P., Lehnertz K., Elger C.E., 2003. Epileptic seizures are preceded by a decrease in synchronization. **Epilepsy Res.** 2003 Mar;53(3):173-85.
- Navarro V., Martinerie J., Le Van Quyen M., Baulac M., Dubeau F., Gotman J. 2005. Seizure anticipation: do mathematical measures correlate with video-EEG evaluation? . **Epilepsia**, 2005; 46: 385–96.
- Navarro V., Martinerie J., Le vanquyen M., Clemenceau S., Adam C., Baulac M., Varela F., 2002. Seizure anticipation in human neocortical partial epilepsy. **Brain**; 125: 640–55.

- Neapolitan, R.E., 2003. **Learning Bayesian Networks**. Prentice – Hall, 674p.
- Nunez P. L. and Srinivasan R., 2006. Electric Fields of the Brain. **The Neurophysics of EEG**, Oxford University Press, New York, NY, USA, 2nd edition.
- Oppenheim A.V. & Schafer, R.W. 1989. **Digital signal processing**. Englewood Clis, NJ: Prentice-Hall.
- Orosco L.,Laciar E., Correa A.G., Torres A., Graffigna J.P., 2009. An epileptic seizures detection algorithm based on the empirical mode decomposition of EEG. **Conf Proc IEEE Eng Med Biol Soc.**;2651-4.
- Özdemir N., Duman F., Yıldırım E., 2011. Ampirik Kip Ayırışımı Yoluyula Epileptik Nöbet Teşhisi. **IEEE 19. Sinyal İşleme ve İletişim Uygulamaları Kurultayı – SIU 2011**, 20-22 Nisan 2011, Antalya.
- Pachori R.B., 2008. Discrimination between ictal and seizure-free EEG signals using empirical mode decomposition. **Research Letters in Signal Processing**, vol. 2008, no. 14, pp. 1–5, January 2008.
- Park Y., Luo L., ParhiK.K., Netoff T.,2011. Seizure prediction with spectral power of EEG using cost-sensitive support vector machines. **Epilepsia**, 2011 Jun 21.
- Pearl, J., 1988. **Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference**. Morgan Kaufmann, USA, 552p.
- Petrosian A., Prokhorov D., Homan R., Dasheiff R., Wunsh II D., 2000. Recurrent neural network based prediction of epileptic seizures in intra- and extracranial EEG. **Neurocomputing**, 30:201–18.
- Pollack R., 1999. **The Missing Moment**.
- Priestley, M. B.,1965. Evolutionary spectra and non-stationary processes. **J. R. Statist. Soc.** B27, 204-237.
- Quinlan J.R., 1993. **C4.5: Programs for Machine Learning**. Morgan Kaufman, San Mateo, CA.
- Rajna P., Clemens B., Csibri E., Dobos E., Geregely A., Gottschal M., Gyorgy I., Horvath A., Orvath F., Mező L., Velkey I., Veres J., Wagner E., 1997 . Hungarian multicentre epidemiologic study of the warning and initial symptoms (prodrome, aura) of epileptic seizures. **Seizure** 6, 361–368.
- Rilling G., Flandrin P., and Goncalves P., 2003. On empirical mode decomposition and its algorithms. **IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing, NSIP-03**.
- Rogowski Z., Gath I., Bental E.,1981. On the prediction of epileptic seizures. **Biol Cybern.**; 42: 9–15.

- Rutkowski T.M., Zdunek R., Cichocki A., 2006. Multichannel EEG brain activity patterns analysis in time frequency domain with nonnegative matrix factorization support. **Third International Conference on Brain-Inspired Information Technology**, Hibikino, Kitakyushu, Japan, p. 102.
- Sađırođlu Ő., BeŐdok E., Erler M.,2003. **Mühendislikte Yapay Zeka Uygulamaları-I Yapay Sinir Ağları**. Ufuk Kitap Kırtasiye-Yayıncılık Tic. Ltd. Őti., 417s. Kayseri.
- Salant Y., Gath I., Henriksen O., 1998. Prediction of epileptic seizures from two channel EEG. **Med Biol Eng Comput .;** 36: 549–56.
- Saraç T., 2004. **Yapay Sinir Ağları**. Gazi Üniversitesi Endüstri Mühendisliđi Anabilim Dalı, Seminer Projesi,71s, Ankara.
- Senhadji L., Dillenseger J.L., Wendling F., Rocha C.and Kinie A., 1995. Wavelet analysis of EEG for three-dimensional mapping of epileptic events. **Ann. Biomed. Eng.** 32, pp. 738–748.
- Sharabaty H., Jammes B, and Esteve D., 2008. EEG analysis using hht: One step toward automatic drowsiness scoring. **Advanced Information Networking and Applications - Workshops, 2008. AINAW 2008**. 22nd International Conference on, pages 826–831.
- Sharabaty H., Martin J., Jammes B., Esteve D. 2006. Alpha and Theta Wave Localisation Using Hilbert-Huang Transform: Empirical Study of the Accuracy. **Proc. of IEEE Conference**, pp. 1159-1164.
- Shekel J., 1953. **Instantaneous' frequency**. Proc. IRE 41, 548.
- Siegel A., Grady C. ve Mirsky A., 1982. Prediction Of Spike-Wave Bursts In Absence Epilepsy By Eeg PowerSpectrum signals. **Epilepsia;** 23:47-60.
- Singer W. and Gray C.M., 1995. Visual feature integration and the temporal correlation hypothesis. **Annu. Rev. Neurosci.** 18, pp. 555-586.
- Spedding G.R., Browand F K., Huang N. E. & Long S. R., 1993. A 2D complex wavelet analysis of an unsteady wind-generated surface wave field. **Dyn. Atmos. Oceans** 20, 55-77.
- Sweeney-Reed C. M. and Nasuto S. J., 2007. A novel approach to the detection of synchronization in eeg based on empirical mode decomposition. **Journal of Computational Neuroscience**, vol. 23, no. 1, pp. 79–111, August 2007.
- Tafreshi A.K., Nasrabadi A.M., and Omidvarnia A.H., 2008. Epileptic seizure detection using empirical mode decomposition. **Signal Proc. and Inf. Tech.,ISSPIT. IEEE International Symposium** on, dec. 2008, pp. 238–242.
- Thakor N.V., Yi-Chun S. and Hanley D.F., 1993. Multiresolution wavelet analysis of evoked potentials. **IEEE Trans Biomed Eng** 11, pp. 1085–1093.

- Türker N., 2004. **RF/Mikrodalga Düzlemsel İletim Hatlarının Yapay Sinir Ağı ile Analiz ve Sentezi**. Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 92s, İstanbul.
- Übeyli E.D., İlbay G., Şahin D., Ateş N., 2009. Analysis of spike-wave discharges in rats using discrete wavelet transform. **Computers in Biology and Medicine**.
- Wei P., Qihua L., Guanglin L., 2009. Classifying motor imagery EEG by Empirical Mode Decomposition based on spatial-time-frequency joint analysis approach. **BioMedical Information Engineering, FBIE 2009, International Conference on Future**, pp. 489 – 492,13-14 Dec 2009.
- Weinand M., Carter L., El-Saadany W., Sioutos P., Labiner D., Oommen K., 1997. Cerebral blood flow and temporal lobe epileptogenicity. **J.Neurosurg.**;86:226–232.
- Weng B., Blanco-Velasco M. and Barner K.E., 2006. ECG denoising based on the empirical mode decomposition. **Proc. IEEE EMBS'06** pp 1-4.
- Werbos, P.J., 1994. **Beyond Regression: New Tools For Prediction And Analysis In The Behavioral Sciences**. Ph. D. Thesis, Harvard University, Cambridge, MA, 1974. Also Published As The Roots Of Backpropagation, New York: John Wiley & Sons.
- Winterhalder M., Maiwald T., Voss H.U., Aschenbrenner-Scheibe R., Timmer J., Schulze-Bonhage A., 2003. The seizure prediction characteristic: a general framework to assess and compare seizure prediction methods. **Epilepsy Behav.**; 4: 318–25.
- Yen N. C., 1994. Wave packet decomposition. **J. Acoust. Soc. Am.** 95, 889-896.
- Yu L, Wang S Y & Lai K K, 2008. Forecasting Crude Oil Price with an EMD-Based Neural Network Ensemble Learning Paradigm. **Energy Economics**, 30, 2623-2635.
- Yurtoğlu H. 2005. **Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği**. DPT Uzmanlık Tezleri, Ankara.
- Ziqiang Z. and Puthusserypady S., 2007. Analysis of schizophrenic EEG synchrony using empirical mode decomposition. **Digital Signal Processing**, 2007 15th International Conference on, July 2007, pp. 131 –134.

TEŐEKKÜR

Yüksek Lisans tez konumun belirlenmesinde ve çalışmalarımın her aşamasında yardımlarını esirgemeyen danışmanım Sayın Y.Doç.Dr. Esen YILDIRIM'a (Mustafa Kemal Üniversitesi Mühendislik Fakültesi), Y.Doç.Dr. Serdar YILDIRIM'a (Mustafa Kemal Üniversitesi Mühendislik Fakültesi), tez sürecinde bana destek olan eşim ve herkese teşekkürlerimi sunarım.

ÖZGEÇMİŞ

Adı Soyadı : Nilüfer ÖZDEMİR
Doğum yeri : İskenderun
Doğum tarihi : 15.07.1975
Medeni durumu : Evli
Adres : Meydan mah. 507 Sokak no: 10 İskenderun / HATAY
e-mail : nozdemir@mku.edu.tr

Eğitim Durumu :

Yüksek Lisans

Nisan 2012 Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü
 Elektrik-Elektronik Mühendisliği Anabilim Dalı

Lisans

09 04 2008 Mustafa Kemal Üniversitesi Mühendislik Mimarlık Fak.
 Elektrik-Elektronik Mühendisliği

Önlisans

Haziran 1995 Mustafa Kemal Üniversitesi İskenderun Meslek Yüksekokulu
 Endüstriyel Elektronik Programı

Orta Öğretim

İlk, orta ve lise eğitimi İskenderun

İş Deneyimi:

1996 - Mustafa Kemal Üniversitesi İskenderun Meslek Yüksekokulunda
 İdari Personel

1995-1996 İskenderun İnönü İlköğretim Okulunda Ücretli Öğretmenlik

Yayımları:

Özdemir N., Duman F., Yıldırım E., 2011. Ampirik Kip Ayrışımı Yoluyla Epileptik Nöbet Teşhisi. **IEEE 19. Sinyal İşleme ve İletişim Uygulamaları Kurultayı – SIU 2011**, 20-22 Nisan 2011, Antalya.

Duman F., Özdemir N., Yıldırım E., 2012. Patient Specific Seizure Prediction Algorithm Using Hilbert-Huang Transform. **IEEE-EMBS International Conference on Biomedical and Health Informatics, BHI 2012**, Hong Kong, Shenzhen, 5-7 Jan 2012.

Özdemir N., Yıldırım E., 2012. Hilbert Huang Transform ve Yapay Sinir Ağları İle Epileptik Nöbet Tahmini. **IEEE 20. Sinyal İşleme ve İletişim Uygulamaları Kurultayı – SIU 2012**, 18-20 Nisan 2012, Fethiye.