ÇOK KANALLI iEEG SİNYALLERİNİN EVRİŞİMSEL SİNİR AĞLARIYLA ANALİZİ

MUHİTTİN BAYRAM

ARALIK 2021

DİYARBAKIR

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ÇOK KANALLI iEEG SİNYALLERİNİN EVRİŞİMSEL SİNİR AĞLARIYLA ANALİZİ

MUHİTTİN BAYRAM

DİCLE ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM-ÖĞRETİM VE SINAV YÖNETMELİĞİNİN BİR PARÇASI OLARAK
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALINDA
DOKTORA TEZİ
OLARAK HAZIRLANMIŞTIR

ARALIK 2021

DİYARBAKIR

ÇOK KANALLI iEEG SİNYALLERİNİN EVRİŞİMSEL SİNİR AĞLARIYLA ANALİZİ

Muhittin BAYRAM tarafından Dicle Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin bir parçası olarak hazırlanan bu çalışma, aşağıda bilgileri yazılı jüri üyeleri tarafından değerlendirilerek **Elektrik Elektronik Mühendisliği Ana Bilim Dalı**'nda **Doktora Tezi** olarak kabul edilmiştir.

Prof. Dr. Neslihan DALKILIÇ _____
Müdür, **Fen Bilimleri Enstitüsü**

Dr. Öğretim Üyesi Muhammet Ali ARSERİM _____
Danışman, **Elektrik Elektronik Mühendisliği Bölümü, Dicle Üniversitesi**

Sınav Jürisi:

Prof. Dr. Ayşegül UÇAR(*) _____
Mekatronik Mühendisliği Bölümü, Fırat Üniversitesi

Dr. Öğretim Üyesi Muhammet Ali ARSERİM(**) _____
Elektrik Elektronik Mühendisliği Bölümü, Dicle Üniversitesi

Doç. Dr. Hasan GÜLER _____
Elektrik Elektronik Mühendisliği Bölümü, Fırat Üniversitesi

Doç. Dr. Muhammed Bahaddin KURT _____
Elektrik Elektronik Mühendisliği Bölümü, Dicle Üniversitesi

Dr. Öğr. Üyesi Abdulnasır YILDIZ _____
Elektrik Elektronik Mühendisliği Bölümü, Dicle Üniversitesi

ONAY

Savunma Tarihi: 17 / 12 / 2021

(*) Sınav Jürisi kısmının birinci satırına Jüri Başkanının bilgilerini yazınız.
(**) Sınav Jürisi kısmının ikinci satırına Tez Danışmanının bilgilerini yazınız.

Aileme…

Dicle Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırlanan bu tez çalışmasında yer alan tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu beyan ederim. Ayrıca, bahse konu bu kural ve ilkelerin gerektirdiği üzere, bu çalışmada özgün olmayan tüm bilimsel içerikleri kurallara uygun biçimde alıntılayıp kaynak gösterdiğimi beyan ederim. Beyanımla çelişen herhangi bir delil bulunduğu takdirde tüm sorumluluğu üstleneceğimi kabul ederim.

Ad, Soyad: Muhittin BAYRAM

İmza: …….

TEŞEKKÜR

Öncelikle danışmanım Dr. Muhammet Ali ARSERİM'e gösterdiği destek ve sabırdan dolayı teşekkür ederim. TİK ve Jüri üyelerime bu tezin daha nitelikli bir hale gelmesi için yaptıkları eleştiri ve önerileri için teşekkür ederim.
Tezin her aşamasındaki yardımları için Dr. Hüseyin ACAR'a teşekkür ederim. Sinyal ve görüntü işleme aşamalarında sundukları destek için Dr. Ömer TÜRK, Dr. Cafer BUDAK, Dr. Ömer Faruk SÖYLEMEZ ve Vasfiye MENÇİK'e teşekkür ederim.

Son olarak, benden yardımlarını esirgemeyen, anlayan ve katlanan eşim, çocuklarım ve torunlarıma da en içten teşekkürler…

İÇİNDEKİLER

TEŞEKKÜR v
İÇİNDEKİLER vi
ŞEKİLLER LİSTESİ viii
TABLOLAR LİSTESİ x
SİMGELER VE KISALTMALAR LİSTESİ xi
ÖZET xiii
ABSTRACT xiv
1. GİRİŞ 1
1.1 Problem Tanımı 1
1.2 Çalışmanın Amacı ve Kapsamı 3
1.3 Tez Düzeni 3
2. ÖNCEKİ ÇALIŞMALAR 5
3. MATERYAL VE METOT 7
3.1 Sinir Sistemi 7
3.1.1 Sinir Hücreleri 8
3.1.2 Hücre Membranı 9
3.1.3 Aksiyon Potansiyeli 9
3.1.4 Beyin Korteksi 10
3.2 Elektroansefalogram (EEG) 11
3.2.1 EEG Verisinin Altbantları 11
3.2.2 iEEG Veritabanı 12
3.2.3 iEEG Verisinin Altbantlara Ayrıştırılması 16
3.2.4 iEEG Verisinin önişlenmesi 17
3.3 Epilepsi 17
3.3.1 Epilepside EEG'nin Kullanılması 18
3.4 Kaos Teorisi 19

3.4.1 Nonlineer Dinamik Sistemler 19
3.4.2 Kaos Kavramı ve Özellikleri 20
3.4.3 Kaotik Sistemler 20
3.5 Kaotik Sistem Analizi 23
3.5.1 Faz Uzayı 23
3.5.1.1 Zaman gecikmesinin belirlenmesi 27
3.5.1.2 Gömülü boyutun belirlenmesi 27
3.6 Entropi 32
3.7 Dalgacık Dönüşümü 33
3.7.1 Sürekli Dalgacık Dönüşümü 33
3.7.2 Ayrık Dalgacık Dönüşümü 34
3.8 Skalogram 34
3.9 Evrişimsel Sinir Ağları 36
3.9.1 Giriş Katmanı 37
3.9.2 Evrişim Katmanı 37
3.9.3 Aktivasyon Katmanı 38
3.9.4 Havuzlama Katmanı 39
3.9.5 Tam-Bağlantılı Katman 40
3.9.6 Sınıflama Katmanı 40
3.9.7 Aktivasyon Kesici 41
3.10 Performans Değerlendirmesi 42
4. BULGULAR VE TARTIŞMA 44
5. SONUÇLAR VE ÖNERİLER 56
KAYNAKLAR 58
ÖZGEÇMİŞ 64

ŞEKİLLER LİSTESİ

Şekil 1.1 Tez içeriğinin şematik gösterimi 3
Şekil 3.1 Materyal ve Metot bölünün şematik gösterimi 7
Şekil 3.2 Sinir hücresinin şematik gösterimi 8
Şekil 3.3 Aksiyon potansiyelinin şematik gösterimi 10
Şekil 3.4 Preiktal iEEG işaretinin zaman grafiği.....14
Şekil 3.5 İktal iEEG işaretinin zaman grafiği.....15
Şekil 3.6 Postiktal iEEG işaretinin zaman grafiği 15
Şekil 3.7 iEEG sinyalinin altbantlarına ayrıştırılma şeması.....16
Şekil 3.8 iEEG işaretinin ESA'ya uygulanmadan önceki önişleme aşamaları 17
Şekil 3.9 Temsili EEG işaretinin pencereleme sürecini gösteren grafik 21
Şekil 3.10 Epileptik EEG işaretinin pencereleme sürecini gösteren grafik 22
Şekil 3.11 Lorenz kaotik sisteminin zaman ve faz uzay grafikleri.....24
Şekil 3.12 Faz uzayında yörünge gösterimi 29
Şekil 3.13 Preiktal iEEG işareti faz uzay grafiği.....30
Şekil 3.14 İktal iEEG işareti faz uzay grafiği.....31
Şekil 3.15 Postiktal iEEG işareti faz uzay grafiği 32
Şekil 3.16 iEEG sinyalinin a) preiktal, b) iktal, c) postiktal skalogram görüntüleri ..35
Şekil 3.17 ESA modelinin temel katmanları 37
Şekil 3.18 Evrişim işlem aşamaları.....38
Şekil 3.19 Doğrultulmuş lineer birim grafiği 38
Şekil 3.20 Havuzlama işlem aşamaları 39
Şekil 3.21 Tam-bağlantılı katmanda tek girişli veri elde edilmesi 40
Şekil 3.22 Klasik ağ grafiği.....41
Şekil 3.23 Aktivasyon kesici uygulanmış ağ grafiği 42
Şekil 4.1 Bulgular ve Tartışma bölümünün şematik gösterimi 44
Şekil 4.2 Preiktal, iktal ve postiktal safhalarını içeren epileptik iEEG sinyali 45
Şekil 4.3 Preiktal safhasını içeren iEEG bölütü ve faz uzay grafiği.....47
Şekil 4.4 İktal safhasını içeren iEEG bölütü ve faz uzay grafiği.....48
Şekil 4.5 Postiktal safhasını içeren iEEG bölütü ve faz uzay grafiği 48
Şekil 4.6 iEEG bölütü ve faz uzay grafikleri.....49
Şekil 4.7 Delta alt bandının skalogram grafikleri. 50

Şekil 4.8 Resnet50 ESA modeli 50
Şekil 4.9 ESA modelinden elde edilen karışıklık matrisi 51
Şekil 4.10 ESA modelinin doğruluk ve kayıp grafikleri.....52
Şekil 4.11 Grupların çoklu karşılaştırması.....53
Şekil 4.12 Gruba göre verilerin kutu çizimleri.....54

TABLOLAR LİSTESİ

Tablo 3.1 Epileptik hasta tablosu.....13
Tablo 3.2 ESA'nın eğitim ve testi için kullanılan skalogram çizelgesi.....36
Tablo 3.3 ESA'nın eğitiminin doğrulaması için kullanılan skalogram çizelgesi.....36
Tablo 3.4 Üç boyutlu karışıklık matrisi 43
Tablo 4.1 Epileptik iEEG'nin beş altbandının Shannon entropi değerleri.....46
Tablo 4.2 Epileptik EEG sinyallerine ESA yöntemi uygulanan güncel çalışmalar ...55

SİMGELER VE KISALTMALAR LİSTESİ

Simge	Açıklama
A^-	Organik İyonlar
cA	Yaklaşık Katsayıları
Ca^{++}	Kalsiyum
cD	Ayrıntı Katsayıları
Cl^-	Klorür
K^+	Potasyum
Hz.	Hertz
ms	Milisaniye
mV	Mili volt
µm	Mikrometre
µV	Mikro volt
Na^+	Sodyum
s	Saniye

Kısaltma	Açıklama
ADD	Ayrık Dalgacık Dönüşümü
ANOVA	Tek Yönlü Varyans Analizi
CNN	Convolutional Neural Networks
DD	Dalgacık Dönüşümü
EEG	Elektroansefalogram
EKG	Elektrokardiyogram
ESA	Evrişimsel Sinir Ağları
FLE	Frontal Lob Epilepsi
FPGA	Alanda Programlanabilir Kapı Dizileri
GN	Gerçek Negatif
GP	Gerçek Pozitif
KZFD	Kısa Zamanlı Fourier Dönüşümü
LSTM	Uzun Kısa Zamanlı Hafıza
NKD	Negatif Sonucun Kestirim Değeri
PKD	Pozitif Sonucun Kestirim Değeri

PLE	Pariyetal Lob Epilepsi
ReLU	Doğrultulmuş Lineer Birim
SDD	Sürekli Dalgacık Dönüşümü
TLE	Temporal Lob Epilepsi
YN	Yanlış Negatif
YP	Yanlış Pozitif
YSA	Yapay Sinir Ağları

ÖZET

ÇOK KANALLI iEEG SİNYALLERİNİN EVRİŞİMSEL SİNİR AĞLARIYLA ANALİZİ

BAYRAM, Muhittin
Doktora, Elektrik Elektronik Mühendisliği Bölümü
Danışman: Dr. Öğr. Üyesi Muhammet Ali ARSERİM
Aralık 2021, 72 sayfa

EEG, beyin aktivitesi hakkında bilgi içerdiğinden ve beyin aynı zamanda kişinin merkezi karar organı olduğundan, analizi özellikle önemlidir. Nöral aktivitenin çoğu beyinde gerçekleşir. Beyindeki faaliyetleri ne kadar anlarsak bilinç, hafıza, zekâ gibi kavramlar da o kadar iyi anlaşılır ve yorumlanır. Bu bağlamda beynin önemi her geçen gün artmaktadır. Elektroansefalogram (EEG), beyindeki nöronların aktivasyonu sonucu oluşan kafatasından gelen sinyallerin ölçülmesini ifade eder. iEEG bir tür EEG'dir, ancak iEEG doğrudan beynin yüzeyinden yapılan ölçümü ifade eder. Bu çok kanallı bir ölçüm olduğundan, beynin yüzeyine ulaşan bilgilerin daha da kesin algılanmasına yol açar. Ancak, bu durumda daha fazla parametre üretildiğinden veri kalabalığı anlamına gelir. Bu çalışmada, epileptik intrakraniyal EEG (iEEG) sinyallerinin nöbet öncesi (preiktal), nöbet anı (iktal) ve nöbet sonrası (postiktal), beyin dinamiklerinin teşhis ve erken tanı sistemlerinin gelişimine katkıda bulunabilmek ve iEEG sinyallerinin patolojik durumlarının tespitine dayanak oluşturacak sonuçlara ulaşmak amacıyla, düşük frekanslı skalogramlara, Evrişimsel Sinir Ağları (ESA) metodu uygulanmıştır. Bu çalışma kapsamında epileptik deneklerden elde edilen iEEG verisi öncelikle dalgacık dönüşümüyle altbantlarına ayrıştırılmış daha sonra bu beş altbanda (delta, teta, alfa, beta ve gama) Shannon entropi uygulanmıştır. Elde edilen sonuçlardan delta altbant entropi değerlerinin diğer altbant entropi değerlerinden daha düşük olduğu görülmüştür. Entropi değerinin düşük olması verinin daha az düzensiz ve kaotik olduğu anlamına gelir. Verinin daha az düzensiz ve kaotik olması, daha iyi öngörülebilirlik anlamını taşır. Bu bağlamda, düşük frekanslı delta altbandının nöbet öncesi, nöbet anı ve nöbet sonrasının skalogram görüntüleri elde edilmiş ve ESA yöntemiyle eğitilmiş ve yapılan testte % 93,33 doğruluk oranı elde edilmiştir.

Anahtar Kelimeler: Entropi, Epilepsi, Evrişimsel sinir ağları, iEEG, Skalogram

ABSTRACT

ANALYSIS OF MULTI-CHANNEL iEEG SIGNALS WITH CONVOLUTIONAL NEURAL NETWORKS

BAYRAM, Muhittin
PhD of Science in Department of Electrical and Electronics Engineering
Supervisor: Dr. Muhammet Ali ARSERİM
December 2021, 72 pages

Since EEG contains information about brain activity, and the brain is also the central decision organ of a person, its analysis is of particular importance. Most of the neural activity takes place in the brain. As much as we understand the activities in the brain, concepts such as consciousness, memory, and intelligence are better understood and interpreted. Within this context, the importance of the brain is increasing every day. Electroencephalogram (EEG) refers to the measurement of signals from the skull formed due to the activation of neurons in the brain. iEEG is a type of EEG, but iEEG refers to measurement directly from the surface of the brain. Since this is a multi-channel measurement, it leads to an even more precise perception of information reaching the brain's surface. However, this means a data crowd, as more parameters are generated. In this study, in order to contribute to the development of the diagnosis and early diagnosis systems of epileptic intracranial EEG (iEEG) signals before seizure (preictal), during seizure (ictal) and after seizure (postictal), brain dynamics and to reach results that will form the basis for the detection of pathological conditions of IEEG signals. Convolutional Neural Networks (CNN) method was applied to low frequency scalograms. Within the scope of this study, IEEG data obtained from epileptic subjects was first decomposed into subbands by wavelet transform, and then Shannon entropy was applied to these five subbands (delta, theta, alpha, beta and gamma). From the results obtained, it was seen that the delta subband entropy value was lower than the other subband entropy values. A lower entropy value means that the data is less disordered and chaotic. Less disorganized and chaotic data means better predictability. In this context, scalogram images of the low-frequency delta subband before, during and after seizure were obtained and trained with the CNN method, and an accuracy rate of 93.33% was obtained in the test.

Keywords: Convolutional neural networks, Entropy, Epilepsy, iEEG, Scalogram

1. GİRİŞ

İnsan vücudundaki organlar çalışırken biyoelektrik işaretler üretirler. Bu işaretlerin algılanması kadar işlenmesi ve analizi de önemlidir. İnsan vücudundan alınan parametreler üzerinde çalıştıkça organların çalışma mekaniği hakkında daha çok bilgiye ulaşılmaktadır. Bu parametreler analiz edildikçe organların normal işleyişi yanında anormal işleyişi de gözlemlenebilmektedir. Bu da teşhis ve tedavi için yeni tekniklerin geliştirilmesine olanak sağlamaktadır.

Beyin, insanın merkezi karar ve yönetim organıdır. Sinirsel aktivitelerin çoğu bu organda gerçekleşir. Beyindeki aktiviteler anlaşıldıkça, bilinç, hafıza ve zekâ gibi kavramlar daha iyi anlamlandırılmakta ve yorumlanabilmektedir. Bu bağlamda, beynin önemi her geçen gün daha da artmaktadır. Elektroansefalogram (EEG) beyindeki nöronların aktifleşmesi sonucu oluşan işaretlerin kafatasından ölçümünü ifade etmektedir. iEEG ise doğrudan beyin yüzeyinden ölçümü ifade eder. Bu ölçümün çok kanallı olması beyin yüzeyine ulaşan bilgilerin daha da hassas algılanmasına yol açar. Fakat bu, daha çok parametre oluştuğu için veri kalabalığı anlamına gelir.

Çevremizde muazzam boyutlu ve çok sayıda parametre içeren bilgilerin olması bu bilgilerin yorumlanması ve değerlendirilmesini zorlaştırır. Bunun için sürekli gelişen matematiksel modeller kullanılır. Güncel ve sürekli gelişen modellerden biri ve en yaygını yapay sinir ağlarıdır. Makine öğrenmesi denince akla ilk gelen yapay sinir ağları (YSA), derin öğrenme denince ise ilk akla gelen Evrişimsel Sinir Ağları (ESA) modelidir. Konvansiyonel sınıflandırma yönteminde öznitelikler belirlendikten sonra YSA ile sınıflama safhasına geçilir. ESA'da ise özniteliklerin belirlenmesi ve sınıflama safhaları aynı modelde gerçekleştirilir. YSA modeli tek kanallı veriler, ESA modeli ise çok kanallı sinyaller için daha çok tercih edilir. ESA'nın (ve derin öğrenmenin) en büyük avantajı, gerekli ve uygun özellikleri kendi başlarına otomatik olarak öğrenebilmeleridir.

1.1 Problem Tanımı

EEG, beyin faaliyetleriyle ilgili bilgiler içerdiğinden ve beyin de insanın merkezi karar organı olduğundan analizi ayrı bir önem taşır. EEG, sağlıklı bireylerin beyin aktivitelerinin incelenmesi yanında patolojik durum ve anomalilerin tespiti için de vazgeçilmez bir yöntem olmayı sürdürmektedir. Kanal sayısı arttıkça ince kesit

üzerinden daha hassas ölçümler elde edilebilmektedir. Bununla beraber veri ve parametre sayısı arttığından işlem ve analiz güçlüğü yaşanmaktadır.

Bu çalışmada, derin öğrenme yöntemlerinden biri olan ESA kullanılarak, çok kanallı iEEG verilerinin analizinde daha başarılı sonuçlar elde edilmesi düşünülmektedir. Derin öğrenme yöntemleri kullanıldığında, hem öznitelik ve hem de sınıflandırma safhaları aynı modelde yer aldığından, model dışında öznitelik vektörü oluşturulmasına ihtiyaç kalmamaktadır. Bu, bizi daha az matematiksel modelle ve/veya parametreyle sonuca götürebilmektedir. Bu çalışmayla, beyin faaliyetlerindeki durum ve patolojilerin, derin öğrenme ağlarından olan ESA ile daha etkin ve hızlı bir şekilde analiz edileceği düşünülmektedir.

Biyolojik organların dinamiğinden elde edilen elektriksel işaretler veya sinyaller tıpta tanı ve tedavi için birçok alanda veri olarak kullanılmaktadır. EEG, EKG ve diğer biyolojik işaretler, ilgili organın durumu hakkında direkt veya dolaylı bilgiler içermektedir. Biyolojik işaretler birçok açıdan (zaman, frekans, zaman-frekans, evre, gibi) sinyal işleme yöntemleriyle (sinyal, örüntü ve görüntü işleme ve istatistiksel yöntemler gibi) işlenerek her geçen gün yeni parametreler (veriler) elde edilmektedir. Bu veriler ışığında tıp alanında yeni stratejiler geliştirilebilmektedir.

Beyin ve vücuttaki tüm organlar arasındaki senkronize enteraktif yapıdan dolayı beyinde oluşan bir olumsuzluk beyinle beraber vücudu ve benzer şekilde vücutta oluşan bir rahatsızlık da vücutla beraber beyini etkilemektedir. EEG sinyalleri beyin dinamikleri ile ilgili bilgiler taşımakta ve bu bilgileri mümkün olan anlaşılır bir doğrulukta ortaya çıkaracak yöntemlerin geliştirilmesi büyük önem arz etmektedir. Beyin sinyalleri doğrusal olmadıklarından, doğrusal olmayan bir metot geliştirme amacı ve/veya hedefi büyük önem arz etmektedir.

Epilepsi nöbetlerinde, beyin dinamiklerinin grafiğini oluşturan EEG sinyallerinde anormallikler oluşmaktadır. Bu sinyallerin dinamiği birçok etkene bağlı olduğundan bu sinyallerden gerekli bilgileri çıkarmak kolay olmamaktadır. Bundan dolayı sinyallerin hem zaman ve hem de frekans bantlarını inceleyip örüntü tespitine gitmek gerekmektedir.

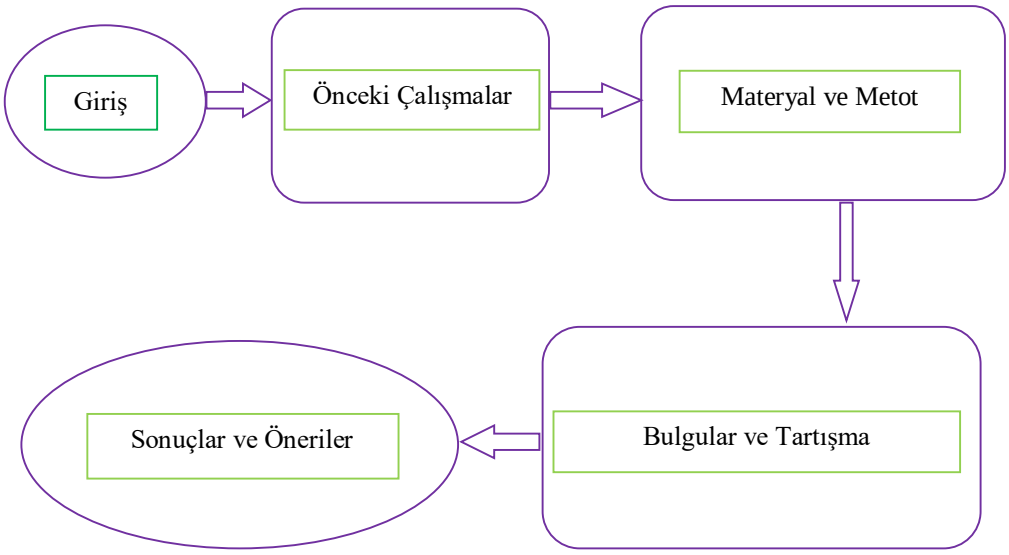
1.2 Çalışmanın Amacı ve Kapsamı

Bu çalışmada, derin öğrenme yöntemlerinden biri olan ESA kullanılarak, çok kanallı iEEG verilerinin analizinde daha başarılı sonuçlar elde edilmesi düşünülmektedir. Derin öğrenme yöntemleri kullanıldığında hem öznitelik ve hem de sınıflandırma safhaları aynı modelde yer aldığından model dışında öznitelik vektörü oluşturulmasına ihtiyaç kalmamaktadır. Bu, bizi daha az matematiksel modelle ve/veya parametreyle sonuca götürebilmektedir. Bu çalışmayla, beyin faaliyetlerindeki durum ve patolojilerin, derin öğrenme ağlarından olan ESA ile daha etkin ve hızlı bir şekilde analiz edileceği düşünülmektedir.

1.3 Tez Düzeni

Bu Tez çalışmasında, beyin dinamiklerinin teşhis ve erken tanı sistemlerinin gelişimine katkıda bulunabilmek ve EEG sinyallerinin patolojik durumlarının tespitine dayanak oluşturacak sonuçlara ulaşmak amacıyla, epileptik EEG sinyalleri ve bunlara ait altbantların entropi değerleri alınarak delta entropi değerlerinin düşük olduğu görülmüştür. Bu bağlamda, delta altbantların skalogram görüntüleri elde edilmiş ve Evrişimsel sinir ağları yöntemiyle sınıflama yoluna gidilmiştir. Entropi; sistemin (sinyalin) düzensizliğini gösteren bir ölçüt olarak bilinmektedir. Entropi, kaosu niceliksel belirleyen önemli bir parametredir.

Şekil 1.1'de Tez içeriğinin şematik gösterimi yer almaktadır.



Şekil 1.1 Tez içeriğinin şematik gösterimi

Bu çalışmanın ikinci bölümünde, EEG sinyallerini Evrişimsel sinir ağları yöntemini kullanarak analiz eden Literatür çalışmasına, tarihi akış içerisinde yer verilmiştir.

Üçüncü bölümde EEG, epilepsi, kaos, evrişimsel sinir ağları ve skalogram konuları incelenmiştir. Materyal incelenirken, çalışmada EEG ve epilepsi kullanıldığından, bunların tanımlamalarına, oluşum mekanizmalarına ve karakteristik özelliklerine kısaca değinilmiştir. Yöntem bağlamında ise Kaotik sistem analizi, Shannon entropisi, Evrişimsel sinir ağları, dalgacık dönüşümü ve skalogram konuları incelenmiştir.

Dördüncü bölüm, "Bulgular ve Tartışma" hakkında bilgi içermektedir. Bu amaç doğrultusunda öncelikle iEEG sinyalleri, altbantlarına ayrıştırılmış ve entropi değerleri hesaplanmıştır. Yapılan analizlerde delta altbant entropi değerlerinin diğer altbant entropi değerlerine göre düşük çıktığı tespit edilmiş ve Delta altbant sinyalleri, preiktal, iktal ve postiktal safhalarına ayrılarak skalogram görüntüleri elde edilmiştir. Elde edilen skalogram görüntüleri, Evrişimsel sinir ağları yöntemiyle eğitilmiştir.

Son olarak beşinci bölümde ise "Sonuçlar ve Öneriler" bölümü yer almaktadır. Bu bölümde "Bulgular ve Tartışma" kısmında elde edilen çıktılar (veriler) karşılaştırılarak Literatür bağlamında yorumlanmış ve gelecekte yapılabilecek çalışmalar hakkında öneriler sıralanmıştır.

2. ÖNCEKİ ÇALIŞMALAR

Derin öğrenme metotlarından olan Evrişimsel Sinir Ağları yönteminde özellik çıkarımı ve sınıflandırma safhaları aynı modelde yer almaktadır. Geleneksel yaklaşımda ise veriye öncelikle öznitelik çıkarma yöntemleri uygulanır ve daha sonra yapay sinir ağları (YSA) ile sınıflandırma safhasına geçilir. Aşağıda ESA ve sağlıklı ve/veya hastalıklı EEG sinyalleriyle yapılan çalışmalar verilmiştir.

Hajinoroozi ve ark. [1], EEG içerikli ESA modelini kullanarak sürüş performansıyla ilgili bilişsel durum tahminine yönelmişlerdir [1]. Shirrmeister ve ark. [2], EEG işaretlerine ESA modeli uygulamışlardır. Bu çalışmanın yenilikçi görselleştirme ve EEG tabanlı beyin haritalaması için yeni pencereler açma konusunda başarılı olduğu söylenebilir [2]. Acharya ve ark. [3], çalışmalarında EEG işaretlerini kullanarak nöbetin otomatik tespiti ve tanısı için derin ESA modelini kullanmışlardır. EEG sinyalleri epilepsi teşhisi için yaygın kullanıldıklarından ve ESA yöntemi de güncel modern matematiksel yöntemler arasında sayıldığından ve tercih edildiğinden böyle bir çalışma yapmışlardır. Bu çalışmada % 88,67 doğruluk oranı yakalanmıştır [3]. Li ve ark. [4], "Hibrit Derin Sinir Ağları ile Elektroensefalografik Çok Boyutlu Özelliklerle İnsan Duygularının Tanımlanması" başlıklı çalışmalarında EEG ile insan duygusu tanımaya çalışmışlardır. EEG ile elde edilen görüntüler ESA ile sınıflandırılmış ve analiz edilmiştir [4].

Lawhern ve ark. [5], "EEG Tabanlı Beyin-Bilgisayar Ara Yüzleri için Kompakt ESA" isimli çalışmalarında, EEG işaretlerini ESA modeli ile sınıflandırmışlardır. ESA modeli, sinyalleri ham olarak alıp otomatik olarak hem özellik haritasını çıkarmakta ve hem de sınıflandırma safhasını içermektedir [5]. Cloostermans ve ark. [6], ESA modeliyle EEG verilerinden faydalanarak fokal epileptik deşarjları bulmuşlardır [6]. Zhou ve ark. [7], interiktal, preiktal ve iktal durumları ESA metodu ile frekans ve iEEG sinyalleriyle en yüksek % 96,7, EEG sinyalleriyle de en yüksek % 97,5 doğruluk oranını yakalamışlardır [7].

Hussein ve ark. [8], epileptik ataklara öncelikle LSTM, uzun kısa zamanlı hafıza ağı uygulamış ve buradan elde edilen değerleri kullanarak derin öğrenme ile % 100 doğruluk oranına ulaştıklarını iddia etmişlerdir [8]. Hu ve ark. [9], 18 kanallı epileptik EEG verilerine preiktal safhasını alt bantlara ayırarak ESA ile özellik çıkarmışlar ve

SVM ile de sınıflama yoluna gitmişlerdir. Bu çalışmada % 86,25 doğruluk oranını yakalamışlardır [9]. Gao ve ark. [10], Bonn Üniversitesinden alınan epileptik EEG verilerine yaklaşık entropi ve ESA uygulayarak % 99,26 doğruluk oranına ulaşmışlardır. Sadece yaklaşık entropi ile % 92 doğruluk oranı yakalanmıştır [10]. Wei ve ark. [11], epileptik EEG sinyallerine ESA, azalan ve artan dizilerin birleşmesi ve veri artışı yöntemlerini uygulayarak % 90,57 oranında atak tespiti yapmışlardır [11]. Türk ve Özerdem [12], Bonn üniversitesinden alınan epileptik EEG verilerini alt bantlarına ayırarak ESA uygulamışlar ve ikili karşılaştırmada % 99,5, üçlü karşılaştırmada % 99, dörtlü karşılaştırmada % 91,5 ve beşli karşılaştırmada ise % 93,6 doğruluk oranına ulaşmışlardır [12]. Emami ve ark. [13], uzun kayıtlı epileptik EEG zaman sinyallerini kısa kayıtlı EEG sinyallerine çevirerek ve görüntülerini elde ederek ESA ile saniye bazında % 74, dakika bazında ise % 100 epileptik nöbetleri tespit ettiklerini iddia etmişlerdir [13].

Abiyev ve ark. [14], Bonn Üniversitesi nöroloji kliniğinde EEG verilerine ESA uygulamışlar ve % 98,67 doğruluk oranını yakalamışlardır [14]. Raghu ve ark. [15], 19 kanallı epileptik EEG sinyallerinin spektrogram görüntülerini alarak ESA yöntemi uygulamışlardır. İki farklı metot uygulayarak birinde % 82,85 diğerinde ise % 88,30 doğruluk oranını yakalamışlarıdır [15]. Gao ve ark. [16], epileptik EEG verilerini interiktal, nöbetin 30 dakika öncesi, nöbetin 10 dakika öncesi ve nöbet durumlarını ESA modeli uygulayarak % 90'ın üzerinde bir doğruluk oranını aştıklarını ifade etmişlerdir [16].

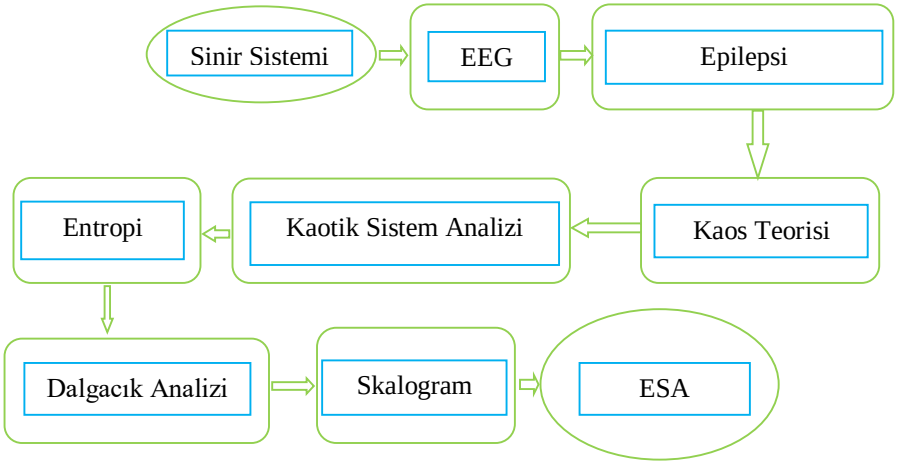
Prathaban ve Balasubramanian [17], preiktal, interiktal ve iktal EEG sinyal verisine üç boyutlu optimize edilmiş ESA modeli uygulayarak % 98 doğruluk oranına ulaştıklarını belirtmişlerdir [17]. Yıldız ve ark. [18], normal, interiktal ve iktal EEG verisinin spektrogram + skalogram görüntülerini ESA yöntemiyle eğitmiş ve % 100 doğruluk oranını yakaladıklarını belirtmişlerdir [18].

Epilepsi tespiti ile ilgili son çalışmalar [19-27] gözden geçirildiğinde, ESA'nın epileptik hastalardan alınan kafa derisi veya kafa içi EEG verilerine yoğun olarak uygulandığı görülmektedir. Bu çalışmada, derin öğrenme yöntemleri arasında yer alan ESA yöntemi kullanılarak çok kanallı iEEG verilerinin analizinde daha başarılı sonuçlar elde edilmesi amaçlanmıştır.

3. MATERYAL VE METOT

Bu bölümde yer alan "EEG ve Epilepsi" konusuna materyal kapsamında, "Kaos, kaotik sistem analizi, entropi, Evrişimsel sinir ağları, dalgacık analizi ve skalogram" konularına ise metot kapsamında değinilmiştir. Materyal incelenirken, çalışmada "EEG" ve "Epilepsi" kavramları kullanıldığından, bunların tanımlamalarına, oluşum mekanizmalarına ve karakteristik özelliklerine kısaca değinilmiştir. Metot oluşturulurken de "Kaos, entropi, Evrişimsel sinir ağları, dalgacık analizi ve skalogram" konuları incelenmiştir.

Materyal ve metot bölümünün içeriği Şekil 3.1'de şematik olarak adım adım gösterilmiştir.



Şekil 3.1 Materyal ve metot bölümünün şematik gösterimi

EEG sinyalleri kafatasından alındığından ve beyin dinamikleri hakkında bilgi içerdiklerinden konuya daha iyi anlam verebilmek için öncelikle sinir sistemi hakkında bilgiler verilmiş ve daha sonra da EEG sinyallerinin tanımı, oluşum mekanizmaları ve karakteristikleri konularına değinilmiştir. Konunun bütünlüğünün sağlanması açısından öncelikle sinir sistemi ele alınmış ve işlenmiştir.

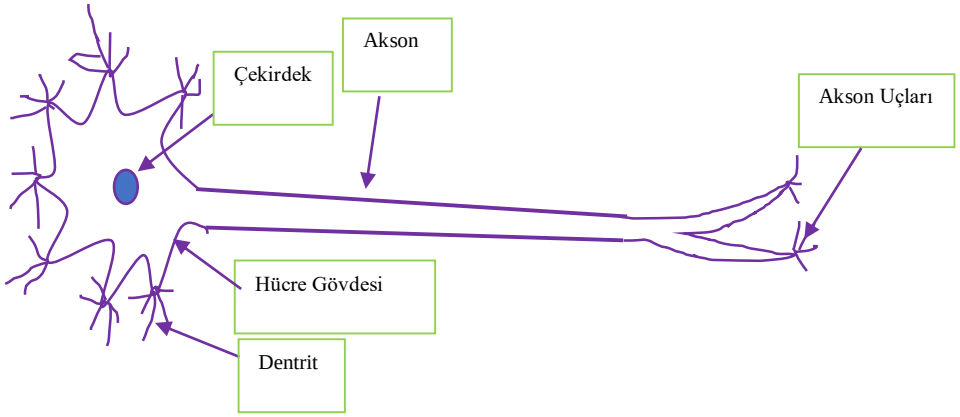
3.1 Sinir Sistemi

Sinir sistemi vücutta haberleşmeyi sağlayan bir mekanizmadır. Merkezi sinir sistemini oluşturan beyine ve dinamiklerine anlam verebilmek için bu mekanizmanın iyi irdelenmesi gerekmektedir.

İnsanlar algılama, öğrenme, düşünme gibi birçok eylemi sinir sistemi yolu ile gerçekleştirirler. Sinir sisteminin temel görevi sinirsel bilgiyi işlemek ve iletmektir. Sinir alt sistemleri, sinir sisteminin temel görevini yerine getiren sinir hücreleri (nöron) ve bunlara destek sağlayan glial hücrelerden oluşmaktadır. Nöronlar, elektriksel ve kimyasal sinyaller aracılığı ile sinirsel bilgiyi iletme özelliğine sahiptir [28]. Sinir sistemi kısaca, insanın merkezi karar sürecinin yürütülmesini sağlamaktadır.

3.1.1 Sinir hücreleri

Sinir hücreleri genel olarak, soma, dentrit ve aksondan oluşmaktadır. Sinir hücresinin şematik gösterimi Şekil 3.2'de gösterilmiştir.



Şekil 3.2 Sinir hücresinin şematik gösterimi

Sinir sisteminin temel yapı taşı olan sinir hücreleri, fizyolojik ve fonksiyonel olarak çok farklı özelliklere sahiptir. Bazı nöronlar birkaç mikrometre kadar kısa olmakla beraber bazı nöronlar bir veya iki metre kadar uzundur [28]. "Nörotransmitter" denilen haberci moleküller, hücreler arasındaki boşluğu geçerek, bir milisaniyeden daha kısa bir zamanda hedef nörondaki iyon kanal iletkenliklerini değiştirirler [29]. Bu olay kimyasal haberleşmenin ana mekanizması niteliğindedir.

Hücre gövdesinin dentrit ve akson denilen iki uzantısı mevcuttur. Aksonun hücre gövdesine yakın olan bölgesine "akson tepeciği" denir ve bu bölgede aksiyon potansiyeli oluşur. Ağaç dalları gibi uzantılara sahip dendritler diğer nöronlarla haberleşmeyi sağlamaktadır. Aksiyon potansiyeli adı verilen elektriksel bir işaret akson yardımı ile çok uzak mesafelere iletilmektedir. Akson uzantısının boyu bir metreye kadar artabilmekte ve çapı ise 0,2-20 µm arasında değişmektedir [30]. Nöron üzerindeki haberleşme elektriksel haberleşmeye örnektir.

3.1.2 Hücre membranı

Hücreyi dış etkenlerden koruyan ve sitoplazmanın dağılmamasını sağlayan, hücre zarı yani hücre membranıdır. Hücre içi ve hücre dışı ortam, seçici-geçirgen hücre zarı ile ayrılmaktadır. Hücre zarı bir çift fosfolipid tabakasından ve bu tabakanın arasına yerleşmiş çeşitli protein moleküllerinden oluşmaktadır. Su molekülleri ve suda eriyen maddelerin geçişini bu çift katlı fosfolipid tabakası büyük ölçüde sınırlamaktadır. Hücre zarından madde ya da iyon taşınması protein molekülleri aracılığı ile olmaktadır. Proteinler çift katlı lipit tabakanın düzenliliğini bozarak çeşitli molekül ve iyonların membrandan geçişine izin vermektedir. Bu tür protein moleküllerine kanal proteinleri adı verilir. Kanal proteinleri molekül ve iyonların tiplerine göre seçici-geçirgendir [31]. Elektriksel olaylar hücre membranında gerçekleşmektedir.

3.1.3 Aksiyon potansiyelleri

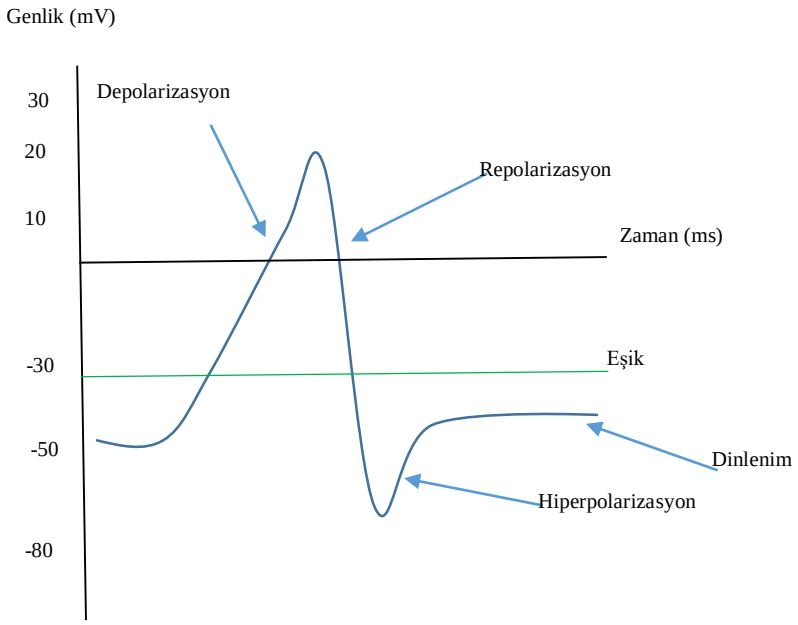
Aksiyon potansiyeli oluşumunda temel mekanizma mürekkep balığı aksonunda Na^+ ve K^+ voltaj-kapılı iyon kanalları ile açıklanmaktadır. Aksiyon potansiyeli oluşumu ile ilgili ilk çalışmalar Hodgkin ve Huxley tarafından mürekkep balığı dev aksonunda gerçekleştirilmiştir [32]. Bu çalışmalar, aksiyon potansiyeli oluştuğu an membranın iyonlara karşı geçirgenliğinin değiştiğini gösterir.

Sinir ve kas hücreleri gibi uyarılabilir hücreler çok küçük genlikli elektriksel uyarılar ile uyarılamaz. Küçük genlikli ve kısa süreli uyartımlar membran potansiyelinde geçici küçük değişimlere neden olmaktadır. Aksiyon potansiyeli oluşturmayan bu potansiyeller eşik-altı potansiyeller olarak adlandırılır. Uyartının şiddeti arttıkça eşik-altı potansiyeller de artar. Uyartının büyüklüğü belli bir eşik değere ulaşınca eşik-altı gerilim belli bir kritik değeri aşarak aksiyon potansiyelini oluşturur. Sinir hücreleri için karakteristik olan bu potansiyele eşik potansiyeli ya da eşik adı verilir. Darbe biçiminde bir uyartı için bu eşik potansiyeli en düşüktür. Bu özellik sinir hücrelerinin ya hep ya hiç davranışına sahip olduğunu ifade eder. Ya hep ya hiç yasası tüm uyarılabilir hücreler için geçerlidir [32, 33].

Aksiyon potansiyeli Şekil 3.3'te görüldüğü gibi dört temel evreden oluşmaktadır: Depolarizasyon evresi, repolarizasyon evresi, hiperpolarizasyon evresi ve son olarak dinlenim evresidir. Depolarizasyon evresinde membranın sodyuma karşı iletkenliği ya da geçirgenliği ani bir şekilde artarak çok büyük miktarda Na^+ iyonu membran

içerisine akmaktadır. Bu durumda, membran iç yüzeyi pozitif hale gelmekte ve membran potansiyeli eşik potansiyel düzeyini aşarak aksiyon potansiyeli oluşmaktadır. Bu evrede Na^+ kanallarının aktivasyonu depolarizasyon sürecini belirlemektedir. Repolarizasyon evresinde Na^+ kanalları kapanırken K^+ kanalları açılmaya başlar. K^+ iyonlarının dışarı akışı membran potansiyelini dinlenim potansiyeline geri döndürür. Bu evrede membranda bulunan gerilim-kapılı K^+ kanal aktivasyonu ve Na^+ kanal inaktivasyonu repolarizasyon sürecini belirlemektedir. Hiperpolarizasyon evresinde ise membran gerilimi dinlenim geriliminden daha düşük gerilim seviyelerine düşmekte ve daha sonra dinlenim gerilimine geri dönmektedir. Dinlenim evresinde membran polarize durumdadır [28, 32].

Aksiyon potansiyelinin şematik gösterimi Şekil 3.3'te gösterilmiştir.



Şekil 3.3 Aksiyon potansiyelinin şematik gösterimi

3.1.4 Beyin korteksi

Beyin korteksinde, insana ait düşünme, karar verme, planlama, hafıza gibi yüksek beyin faaliyetleri yürütülmekle beraber, insanın fonksiyonel açıdan diğer memelilerden üstün kılınmasına yol açmaktadır. Ayrıca beyin korteksi, duyu bilgisini alıp analiz eden, hareketlerin yapılmasını planlayıp yöneten ve homeostatik dengenin korunması için gerekli olayları düzenleyen en önemli merkezdir [34]. Kısacası insanın merkezi karar organıdır.

Beyin korteksi, genellikle beyni en dış kısmından saran birkaç milimetre kalınlığında, üç–altı hücre tabakası içeren özelleşmiş bir yapıdır [35]. İnsan beynini diğer omurgalıların beyninden ayıran en önemli fark korteksin aşırı ölçüde geniş ve girintili-çıkıntılı olmasıdır. Beyin korteksinin farklı bölgelerinin farklı görevleri yüklenmiş olması iç organizasyondan çok korteks dışı bağlantıların bir sonucu olduğu düşünülmektedir. İhtiva ettiği hücre çeşitleri ve yerel nöron devreleri benzer olduğu halde, görevleri farklı olan bölgelerin bulunması ancak bu sonuçla açıklanabilir [36].

3.2 Elektroansefalogram

1875 yılında Caton tarafından tavşan beyninde yapılan çalışmalar ile beynin spontan ve sürekli bir aktivite gösterdiği keşfedildi. İnsan beyninde elektriksel alanla ilgili ilk kayıtlar 1924 yılında Hans Berger tarafından gerçekleştirildi. O, bu kaydı EEG olarak adlandırdı ve bazı hastalıklarda EEG'nin değiştiğini ileri sürdü [37]. Bu çalışma, beynin sinyal ile değerlendirilmesinin başlangıcı kabul edilir.

Beyin korteksi görevlerini, ihtiva ettiği çok sayıda hücre sayesinde yerine getirmektedir. EEG, beyin araştırmaları ve hastalıklarında kullanılan en yaygın yöntemler arasında yer alır.

EEG dalgalarının frekansı son derece önemlidir ve önemli bilgiler ihtiva eder. Bu sinyallerde beyin fonksiyonları hakkında bilgiler yer almaktadır [38].

EEG sinyallerinin frekansları, beynin çeşitli noktalarından alınan EEG sinyallerinin birbiriyle olan faz farkları, insan beyni hakkında önemli bilgiler sağlar. Kafa yüzeyi üzerinden alınan EEG verilerinin yüksekliği tepeden tepeye (peek to peek) 1-100 μV arasında değişir ve frekans bandı ise yaklaşık olarak 0,5-100 Hz. arasındadır [39, 40].

EEG sinyallerinden anlamlı bilgiler elde edebilmek için oldukça uzun süreli ölçüm ve kayıt yapılması gerekir. Çünkü EEG sinyallerinin, beyin aktivitesine göre frekans, faz ve genlik bilgileri çok değişiklik gösterir.

3.2.1 EEG verisinin altbantları

EEG sinyalleri üzerinde çalışırken, alt frekans bantlarını oluşturan bileşen sinyalleri hakkında da bilgi sahibi olmak gerekir. Bu frekans bileşenleri (ritim, altbant) aşağıda açıklanmıştır.

Delta: Düşük frekanslı yüksek genlikli dalga formuna sahiptir. Delta; 0,5-4 Hz frekans ve 20-200 μV genlik aralığında osilasyon yapar.
Teta: Frekansı 4-8 Hz ve genlik aralığı ise 20-100 μV olan yavaş dalgalardır.
Alfa: Alfa, saniyede 8-12 Hz frekans ve 20-60 μV genlik aralığında osilasyona sahip dalgadır.
Beta: Beta, 12-30 Hz frekans ve yaklaşık olarak 2-20 μV genlik aralığına sahip düzensiz osilasyon yapan bir işarettir.
Gama: Düşük genlikli ve yüksek frekanslı dalgalar olup genellikle 30-60 Hz frekans bandında osilasyon yaparlar.

3.2.2 iEEG veritabanı

ESA modelinin giriş verileri, 16 hastadan alınan ve 512 Hz örnekleme frekansına sahip epileptik iEEG verilerinden oluşmaktadır. Bu verilerin ilk kısmı 180 saniye preiktal, orta kısmı 13 saniye ile 126 saniye arasında değişen sürelerde iktal ve son kısmı da 180 saniye postiktal safhadan oluşmaktadır. Tüm epileptik iEEG verileri preiktal, iktal ve postiktal bölütlerine ayrıştırılıp her birinin altbantları alınıp skalogram görüntüleri elde edilmiştir. Segment ve delta altbant entropi değerleri birbirine yakın olduğundan dolayı her bir segmentin delta altbandının bölüt skalogram görüntüleri elde edilerek, ESA modelinin giriş parametreleri olarak kullanılmıştır. Elde edilen işaretlerin % 80'i eğitim, % 20'si ise test verisi olarak kullanılmıştır.

Bu çalışmada, Inselspital Bern Üniversitesi Nöroloji Bölümü Uyku-Uyandırma–Epilepsi merkezinde 16 hastanın epileptik iEEG verisi [41] kullanılmıştır. 16 bit analogdan dijitale dönüşümden sonra, veriler analizden önce dördüncü dereceden bir Butterworth filtresi kullanılarak 0,5 ila 150 Hz arasında dijital olarak bant geçiren filtreden geçirilmiş ve 512 Hz hızında diske yazılmıştır. Her kayıt, 3 dakikalık preiktal segmentlerden (yani, nöbet başlangıcından hemen önce), iktal segmentten (13 saniye ile 126 saniye arasında) ve üç dakikalık postiktal süreden (yani, nöbet bitiminden hemen sonra) oluşur.

Hasta kodları, kanal sayısı, hasta yaşı ve her bir hastaya ait iktal süreleri Tablo 3.1'de gösterilmiştir.

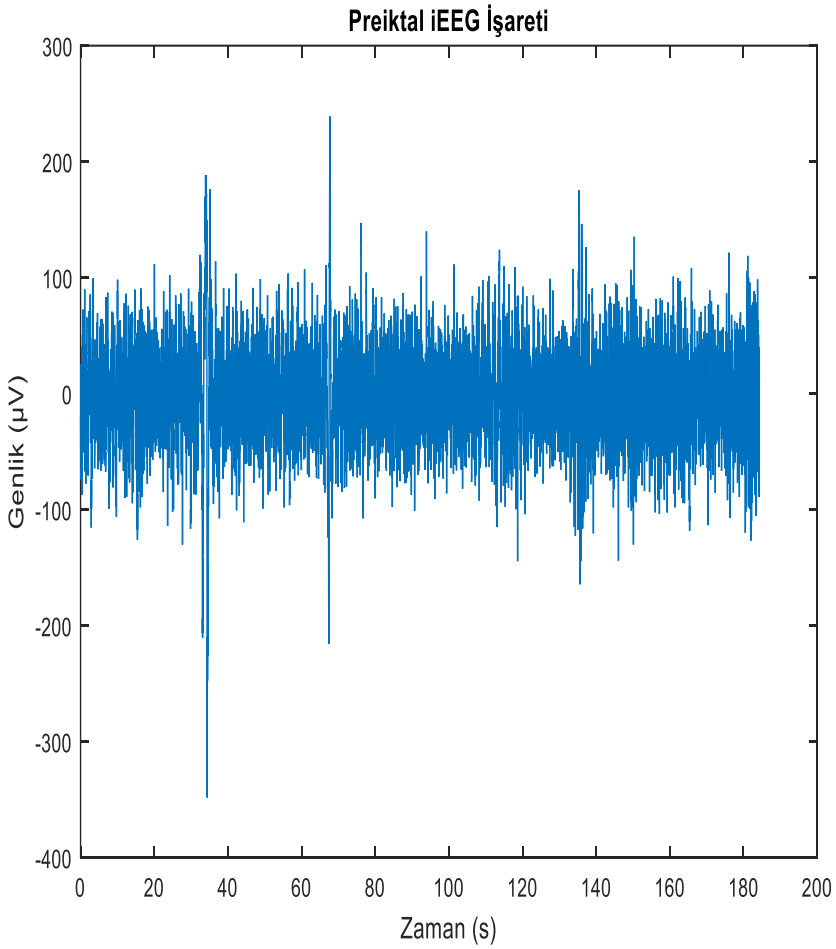
Tablo 3.1 Epileptik Hasta Tablosu

Hasta	Kanal Sayısı	Yaş	Hemisfer	Sendrom	Nöbet Süresi (s)
Hasta 1	100	46	Sağ	TLE	13
Hasta 2	64	48	Sol	TLE	89
Hasta 3	62	32	Sol	PLE	127
Hasta 4	42	19	Sol	TLE	96
Hasta 5	59	31	Sol	TLE	81
Hasta 6	36	31	Sağ	FLE	14
Hasta 7	74	36	Sol	PLE	154
Hasta 8	61	23	Sol	TLE	126
Hasta 9	92	49	Sağ	FLE	19
Hasta 10	47	24	Sol	TLE	125
Hasta 11	59	38	Sol	TLE	52
Hasta 12	54	20	Sağ	TLE	154
Hasta 13	98	25	Sağ	TLE	125
Hasta 14	49	59	Sol	TLE	23
Hasta 15	56	27	Sol	TLE	104
Hasta 16	64	26	Sağ	TLE	89
Ortalama	**64**	**33**			**87**

Tablo 3.1'de Frontal lob epilepsisi; FLE, Temporal lob epilepsisi; TLE ve Pariyetal lob epilepsisi ise PLE olarak kodlanmıştır.

Çalışmada kullanılan epileptik iEEG verileri üç ana kısma ayrılmıştır. Şekil 3.4'te preiktal iEEG işareti, Şekil 3.5'te iktal iEEG işareti ve Şekil 3.6'da postiktal iEEG işareti gösterilmiştir. Preiktal ve postiktal iEEG işaretleri "-100 μV" ile "+100 μV" düzeyinde osilasyon yaparken iktal iEEG işareti "-300 μV" ile "+300 μV" düzeyinde osilasyon yapmaktadır. İktal sürecinde genliğin artması ani elektriksel deşarjdan kaynaklıdır.

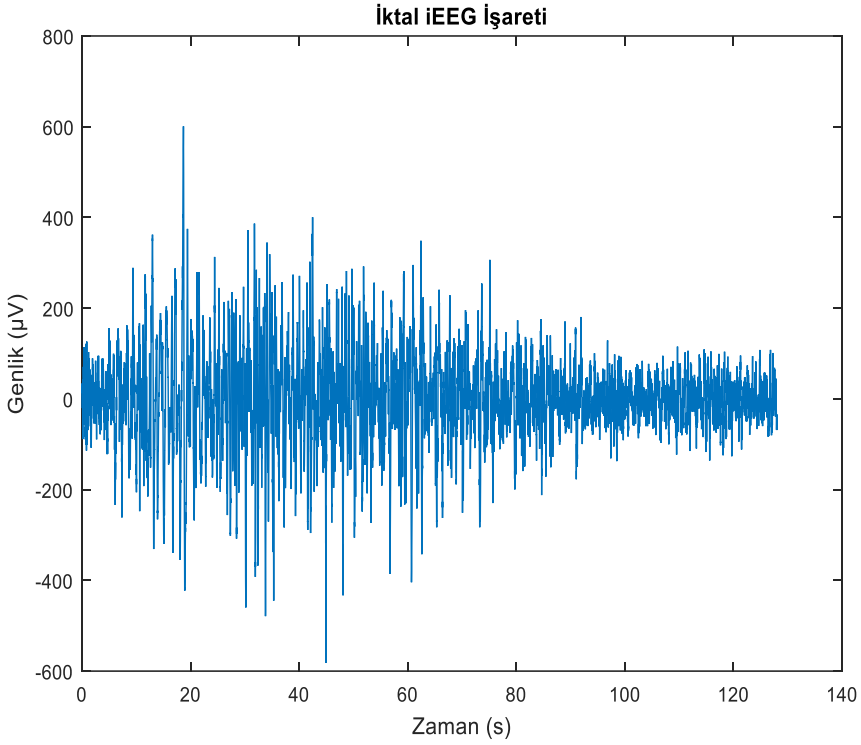
Şekil 3.4'te epileptik iEEG işaretinin preiktal safhasının üç dakikalık (180 s) kısmı gösterilmiştir.



Şekil 3.4 Preiktal iEEG işaretinin zaman grafiği

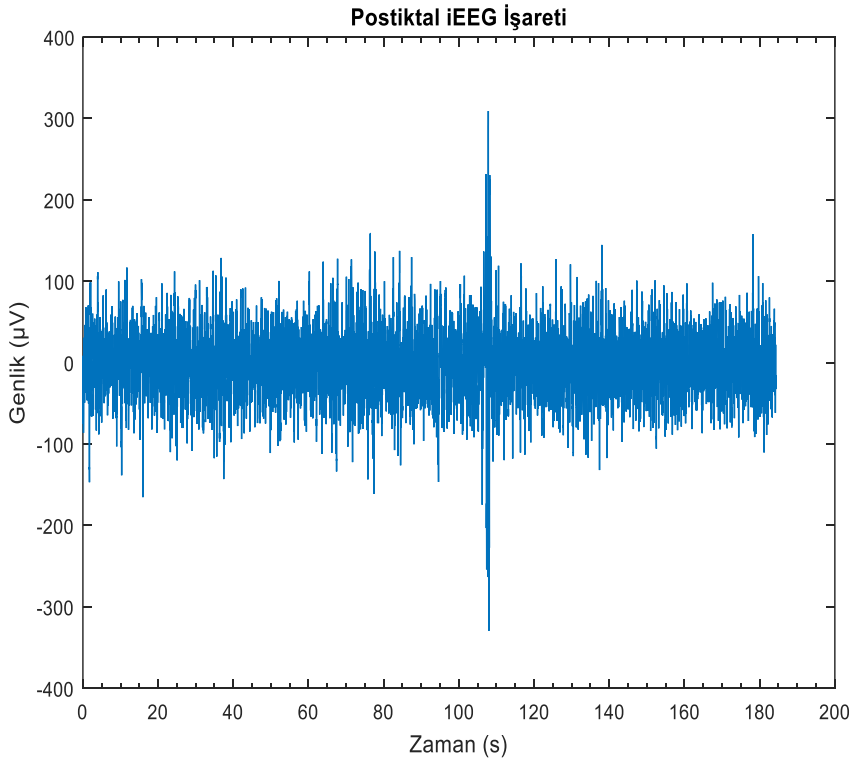
Şekil 3.4'te gösterilen preiktal iEEG işareti ile Şekil 3.6'da gösterilen postiktal iEEG işareti birbirine yakın değerlerde osilasyon yaparken Şekil 3.5'te gösterilen iktal iEEG işareti nöbetten dolayı yüksek genliklerde osilasyon yapmaktadır.

Şekil 3.5'te epileptik iEEG işaretinin 125 saniyelik iktal safhası gösterilmiştir. Bu safhada hasta nöbet geçirdiği için sinyal genliği yüksek değerlerde seyretmektedir.



Şekil 3.5 İktal iEEG işaretinin zaman grafiği

Şekil 3.6'da epileptik iEEG verisinin postiktal safhası gösterilmiştir.



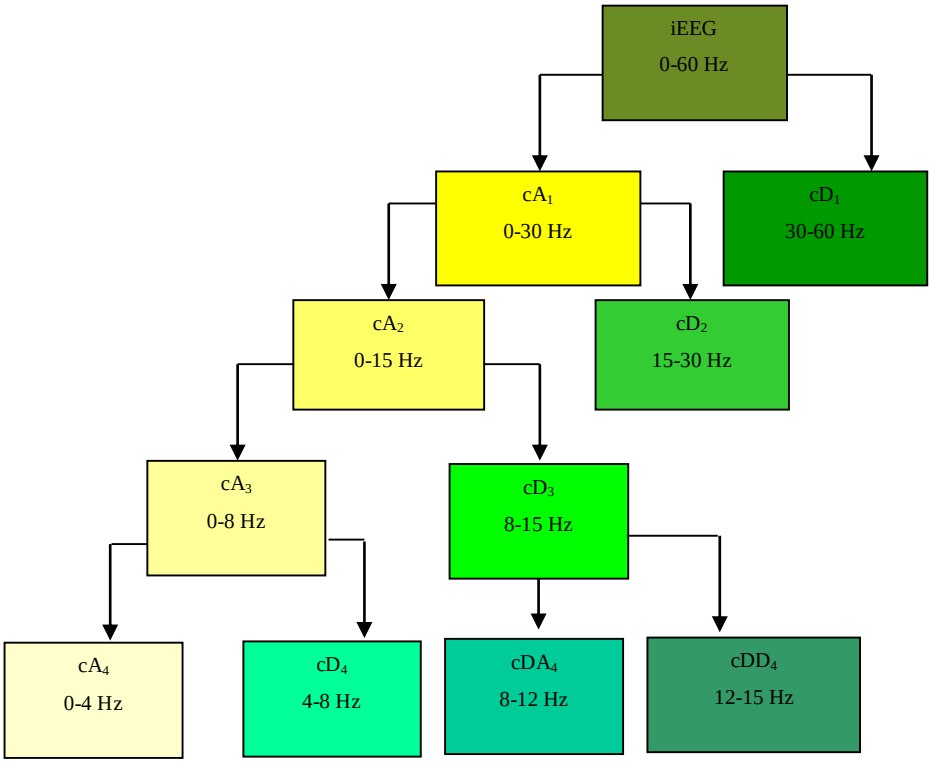
Şekil 3.6 Postiktal iEEG işaretinin zaman grafiği

3.2.3 iEEG verisinin altbantlara ayrıştırılması

iEEG verisi, ayrık dalgacık analizi ile altbantlarına ayrıştırılır. Ayrık dalgacık analizi, durağan olmayan sinyallerin özellik çıkarılmasında büyük bir öneme sahiptir. Bu analiz ile sinyalin zaman-frekans bilgisi açığa çıkarılır. Şekil 3.7'de gösterildiği gibi, sinyal bir alçak bir de yüksek geçiren filtreden tekrar tekrar geçirilir. Alçak geçiren filtreden süzülen alt bantlar "yaklaşık katsayıları" oluştururken, yüksek geçiren filtreden süzülen alt bantlar "ayrıntı katsayılarını" oluşturmaktadır [42].

Şekil 3.7'deki şema, iEEG alt bantlarına yönelik özel tasarlanmıştır. iEEG sinyallerinin "yaklaşık katsayıları" (cA) ve "ayrıntı katsayılar" ise (cD) şeklinde ifade edilir. Burada iEEG sinyali (0-60 Hz) bant geçiren filtreden geçirildikten sonra beş alt banda ayrıştırılır. Bunlar sırasıyla, delta=cA4=(0-4 Hz), teta=cD4=(4-8 Hz), alfa=cDA4=(8-12 Hz), beta=cD2+ cDD4=(12-30 Hz) ve gama=cD1=(30-60 Hz) olarak alınmıştır. Ayrık dalgacık analizi, Literatürde[34] beyin sinyallerinin analizinde sık kullanılan bir metot olduğundan çalışmamızda bu yöntemin de yer alması tercih edilmiştir.

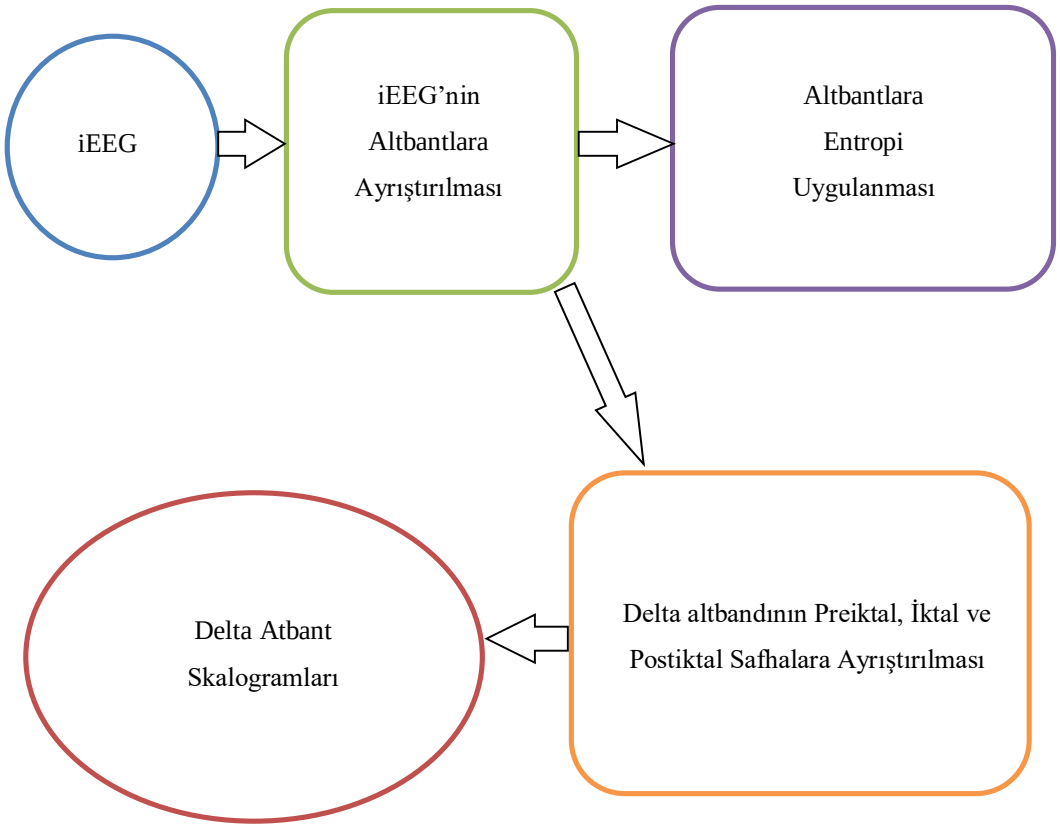
Şekil 3.7'de iEEG verisinin altbantlarına ayrıştırma şeması gösterilmiştir.



Şekil 3.7 iEEG sinyallerinin altbantlarına ayrıştırma şeması

3.2.4 iEEG verisinin ön işlenmesi

Şekil 3.8'de iEEG işaretinin ESA modeli girişine verilmeden önce geçtiği evreler gösterilmiştir.



Şekil 3.8 iEEG işaretinin ESA'ya uygulanmadan önceki önişleme aşamaları

Öncelikle epileptik iEEG verileri, altbantlarına ayrıştırılmıştır. Sonra altbantların entropi değerleri bulunmuştur. En düşük entropi değerlerinin delta altbantlarına ait olduğu görülmüştür (Tablo 4.1). Daha sonra delta altbantları, preiktal, iktal ve postiktal bölütlerine ayrıştırılmıştır. Son olarak, MATLAB ortamında delta altbantlarının 224x224 boyutundaki skalogram grafikleri oluşturulmuştur.

3.3 Epilepsi

Epilepsi; halk arasında "sara" olarak bilinen beyin odaklı bir hastalıktır. Toplum genelinde; bu hastalıkla ilgili olarak pek çok gerçek bilinmemektedir. Nöbet; epilepsinin dış dünyada fark edilmesinin sadece bir şeklidir. Bunun yanı sıra, nöbet şekilleri de çok farklı olabilmektedir. Epilepsi nöbeti, değişik nedenlere bağlı olarak santral sinir sistemindeki bazı nöronların artmış uyarılabilirliğinden kaynaklanan

beynin yerel ya da genel karakterde ani paroksismal bir reaksiyonudur [44]. Epilepsi, tekrarlayıcı nöbetlerle karakterize kronik bir bozukluktur. Bununla birlikte antipsikotikler ya da antidepresanlar gibi ilaçların etkilerinden dolayı nöbet geçiren hastalar ya da organik beyin sendromlarının değişik şekillerinden kaynaklanan serebral fonksiyonlarda ortaya çıkan geçici değişikliklerden dolayı nöbet geçiren hastalar epileptik hasta olarak kabul edilmemektedirler [45]. Epileptik nöbetler, değişik şekillerde olabilmektedir.

Epilepsi, nöbet halinde kendini gösteren bir hastalık olmakla beraber, bir yıl içinde birden fazla epileptik nöbet geçirildikten sonra epilepside bahsedilmesi mümkün olmaktadır [46].

Büyük bir nöron topluluğu birlikte (senkron, eşzamanlı) ve anormal biçimde deşarj yapınca epileptik nöbetler görülmektedir. Senkron deşarj kalıplaşmış, istek dışı ve aniden beliren geçici nöbet davranışlarına neden olmakta ve bu değişiklikler epileptik hastanın hayatını derinden etkilemektedir. Anormal hücre deşarjı; travma, oksijenin yetmemesi, tümörler, enfeksiyon ve metabolik bozukluklar gibi nedenlerle oluşabilmektedir. Ancak, epileptik hastaların yaklaşık yarısında herhangi bir sebep bulmak mümkün olmamaktadır [47].

3.3.1 Epilepside EEG'nin kullanımı

Epilepsiyle ilgili çalışmalarda EEG teşhis için en çok başvurulan metottur. Temel araştırmalara göre, kısa süreli olan aksiyon potansiyellerinin EEG'ye direkt katkısı çok azdır [48].

Epileptik deşarjlar EEG'nin aşırı senkronizasyonunu ifade eder. EEG epileptik nöbetin imzası sayılır. EEG'nin bilgi aktarma özelliğini kısıtlayan iki önemli nokta zamansal ve alansal faktörlerden kaynaklanmaktadır. Videomonitorizasyon sistemleri, telemetrik kayıtlar ve uyku EEG tetkikleri ile zamansal, gerek kafatası üzerine elektrot yerleştirme sistemlerindeki değişim ve gelişmeler gerekse kafa içi elektrot uygulamaları ile alansal kısıtlamalar da büyük ölçüde giderilmeye çalışılmaktadır. Bu da daha iyi analiz etmeyi tetiklemektedir. Epilepside EEG bulgularını değerlendirirken epilepsilerde görülen biyoelektrik patolojilerin sadece epilepsilere özgü olmadığı, beyni etkileyen çeşitli patolojilerin seyri sırasında da ortaya çıkabileceği, ayrıca

normal kişilerde düşük oranda da olsa (yaklaşık % 2) benzer bulgulara rastlanabileceği de göz önünde bulundurulmalıdır [49].

Materyal olarak ele alınan "EEG ve Epilepsi" konuları irdelendikten sonra Yöntem kapsamında kullanılan kaotik sistem analizine geçmeden Kaos teorisi hakkında bilgilerin verilmesi uygun olacaktır. Aşağıda Kaos teorisi hakkında bilgiler verildikten sonra "Kaotik sistem analizi" konusu anlatılmıştır.

3.4 Kaos Teorisi

Kaotik sistem analizine geçmeden nonlineer (doğrusal olmayan) sistemler hakkında bilgiler verilmiş ve böylece konunun pekişmesi sağlanmaya çalışılmıştır.

3.4.1 Nonlineer dinamik sistemler

Kaos kavramına geçmeden, doğrusal olmayan (nonlineer) dinamik sistemler hakkında bilgi verilmesi uygun görülmüştür. Çünkü Kaos, nonlineer sistemler içerisinde cereyan eden bir olgudur.

Sistem kavramını, "karşılıklı etkileşim içinde olan şeyler ve bunların arasındaki ilişkilerin anlaşılması" olarak tanımlayabiliriz [50].

Dinamik sistem, sisteme ait değişkenlerin zaman içindeki davranış karakteristikleri olarak tanımlanır. Bir dinamik sistemin durumunu tespit etmek için sisteme ait çok sayıda, bazen sonsuz sayıda değişkene gerek duyulmaktadır. Bu değişkenler arasındaki ilişki, zaman içindeki bu ilişkinin evrimi, bir denklem takımıyla yani diferansiyel denklem sistemiyle ifade edilir [51-53].

Dinamik bir sistem;

1. Sistemin nasıl geliştiğini belirten kural,
2. Bir başlangıç koşulu veya sistemin başladığı durum, olarak iki bileşenden ibarettir [54].

Bir diferansiyel denklem, denklemi sağlayan bir fonksiyon bulunarak çözülebilir. Aynı zamanda, belirli bir başlangıç koşulu ile sistemin yörüngesi belirlenebilir [55].

Doğrusal olmayan sistemler genellikle çözüme elverişli değildir. Bu sistemlerdeki karmaşık ilişkiler, doğrusalsızlığın hesaplanmasını zorlaştırmakla kalmaz aynı zamanda da doğrusal sistemlerde hiçbir zaman bulunmayan bir davranış biçimini oluştururlar [56].

Doğrusal olmayan sistem teorilerindeki ilerleme, son zamanlardaki işlem gücü yüksek bilgisayarların yaygınlığı ve teknolojinin gelişmesiyle bilim insanları doğrusal olmayan sistemlerde meydana gelen karmaşık davranışları benzetim yardımıyla kolaylıkla inceleme ve analiz imkânı bulmuşlardır. Kaosun disiplinler arası bir konu olması, sistemde Kaosun varlığını gösteren yöntemleri ön plana çıkarmıştır [57].

3.4.2 Kaos kavramı ve özellikleri

Kaos kelimesinin, Türkçe' ye Fransızca'dan geçen iki anlamı vardır [58].

1. Evrenin uyumsuz ve karışık durumu,
2. Kargaşa ve karışıklıktır.

Kaos bilimsel anlamda ise, düzensiz ve karmaşık görünümlü, ilk koşullara hassas bağlı; belirlenimci, doğrusal olmayan, zamanla değişen sistemlerde ortaya çıkan bir olgu olarak tanımlanabilir [58, 59].

"Kaos" ayrıca, "düzensizliğin içindeki düzen" şeklinde tanımlanan doğrusal olmayan bir bilim dalıdır. Kaotik işaret ve Kaosun başlıca özellikleri; zaman boyutunda rastgelelik ve başlangıç koşullarına hassas bağlılıktır [60].

3.4.3 Kaotik sistemler

Kaotik sistemlerin matematiksel modelleri doğrusal olmayan terim içermesinden dolayı doğrusal olmayan bir yapıya sahiptir. Kaotik sistemlerin matematiksel modellerinin belirlenimci olmasına rağmen uzun vadedeki davranışının kestirilemez olması, kaotik sistemleri doğrusal olmayan sistemler altında incelenen modellerden farklı kılan en önemli özelliktir [61].

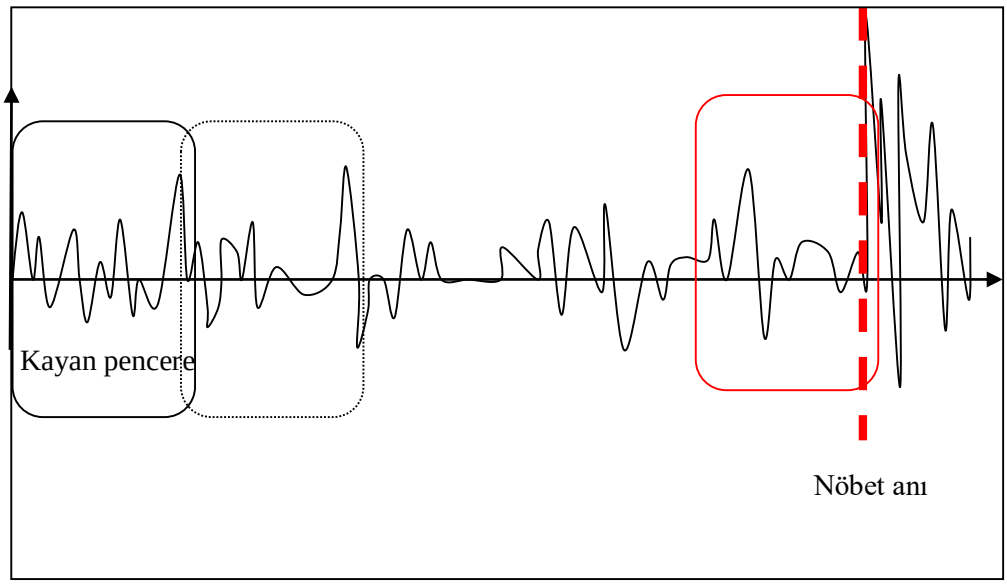
Kaotik sistemler deterministik denklemlerle ifade edilmesine rağmen sistemin geçmişteki davranışını tekrar etmeyerek düzensiz bir yapıya sahip olması ve sistemin

başlangıç şartlarına hassas bağımlı olması kaotik sistemlerin sahip olduğu iki temel özelliktir [62].

Kaotik sistemler iki şekilde ifade edilebilirler [63].

1. Doğrusal olmayan dinamik yapıları nedeniyle, sürekli sistemler için diferansiyel denklemlerle ya da ayrık sistemler için fark denklemleriyle (deterministik),
2. Denklemlerinin bilinmediği durumlarda ise deneysel veriyle (stokastik).

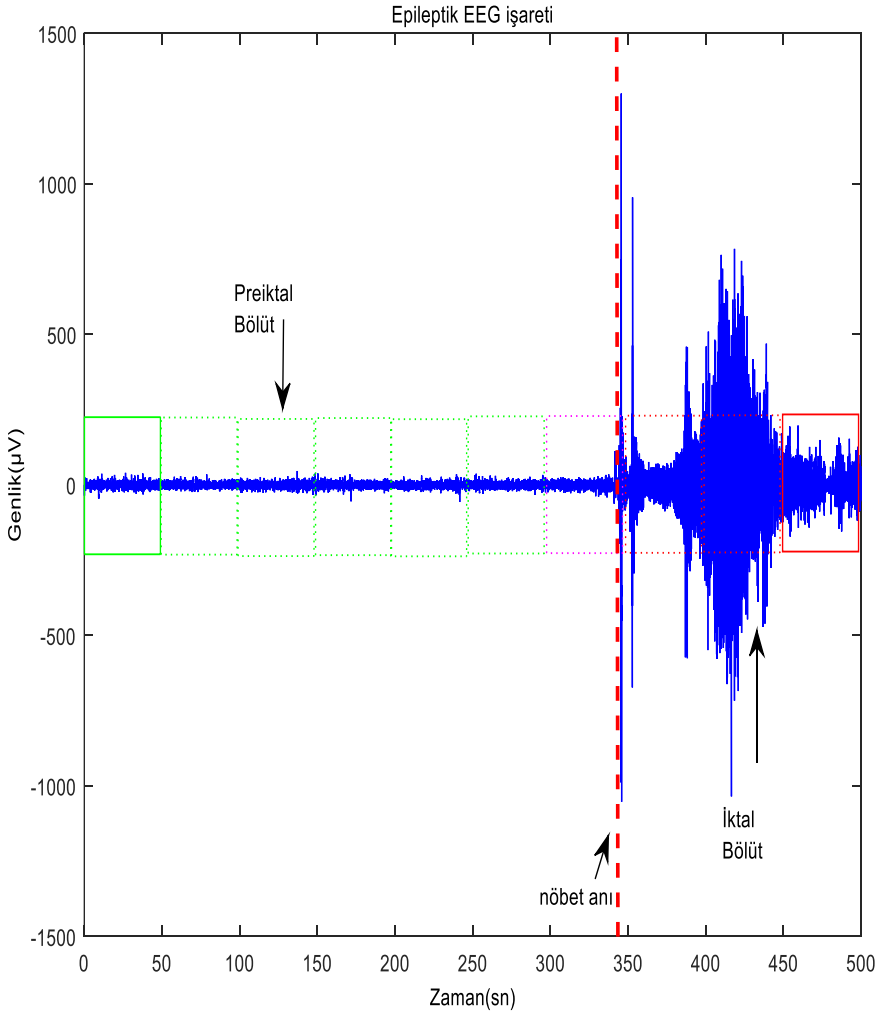
Bu çalışmada, epileptik EEG işaretlerini kullanarak, epilepsi hastalarının nöbet zamanını tespit etmeye yönelik metotlar araştırılmıştır. Bu amaca yönelik hipotezler ortaya konulmuş ve bu hipotezlerin doğrulanması için Literatürden de yararlanarak gerekli inceleme ve araştırma yapılmıştır. Buradaki amaç nöbet anını tespit etmek olduğu için incelenen ve geliştirilen metotların tümü de EEG işaretinin zamanla karakteristik yapısının değişimini dikkate almaktadır. Bu da Şekil 3.9'da sistematik olarak gösterildiği gibi uzun bir süre nöbet öncesinden başlayarak EEG işareti üzerinde bir pencere konarak ve EEG işaretinin gelişimiyle beraber bu pencere de işaret üzerinde kaydırılarak ve dolayısıyla pencereler içerisinde kalan işaret parçasının özelliklerinin nöbet anına yaklaşırken değişimi değerlendirilerek nöbet anını kestirme şeklindedir. Bu metotlar detaylı bir şekilde aşağıda verilmiştir.



Şekil 3.9 Temsili EEG işaretinin pencereleme sürecini gösteren grafik

Şekil 3.9'da temsili bir EEG işaretinin nöbet anı dâhil temsili pencerelerin kaydırılmasıyla analiz şekli resmedilmiştir. Diğer bir değişle tüm işaret belirli pencerelere bölütlenerek (segmentasyon) ve pencerelerle oluşturulan her bir bölüt (segment) Tez kapsamında geliştirilen metotlarla analiz edilip elde edilen bulgular değerlendirilecektir.

Şekil 3.10'da epileptik EEG işaretinin nöbet öncesi, nöbet anı ve nöbet sonrası pencerelerin kaydırılmasıyla analiz şekli gösterilmiştir.



Şekil 3.10 Epileptik EEG işaretinin pencereleme sürecini gösteren grafik

Preiktal, iktal ve postiktal bölütler Tez kapsamında zaman alanında 224 örneklik bölütlere ayrılmıştır. Her üç segment için elde edilen bu bölütlerin MATLAB ortamında skalogramları alınıp derin öğrenme metotlarıyla sınıflandırılmıştır.

3.5 Kaotik Sistem Analizi

Kaotik sistem analizi yapılabilmesi için evvela, zaman serisinin (sinyal) faz uzayı oluşturulur. Kaosu niceliksel belirleyen iki temel yöntem vardır. Bunlar Lyapunov üsteli ve entropidir. Lyapunov üsteli bu çalışmanın kapsamı dışında olduğundan bu konuya Tez'de yer verilmemiştir.

Aşağıda faz uzayı ile ilgili detaylı bilgiler verilmiştir.

3.5.1 Faz uzayı

Faz uzayı, sistemin değişkenlerinin ve bu değişkenlerin zaman içindeki evrimine karşılık gelen noktalar topluluğunun oluşturduğu bir uzaydır. Örneğin bir sistemin dinamiğini belirleyen m tane değişken, o sistemin faz uzayının değişkenlerini ve bu değişkenlerin evriminden oluşan m tane koordinatını da belirler. Faz uzayındaki her bir nokta o sistemin zaman evrimi içindeki bir durumunu temsil eder. Yani bir sistemin faz uzayında çizdiği yörüngelerini inceleyerek o sistemin davranışları hakkında önemli bilgiler elde edilebilmektedir [64].

Durum değişkenleri ve durum değişken türevlerinin oluşturduğu uzay "faz uzayı" olarak adlandırılır. Zamanla durum uzayındaki bir nokta "yörünge" olarak adlandırılan bir yol izler [65].

Dinamik bir sistemdeki bir nokta, kartezyen sistemde [x(t), y(t), z(t)] şeklinde yazarak açıklanır. Hareket ve dinamikleri aşağıdaki denklem (3.1) takımı ile belirtilir.

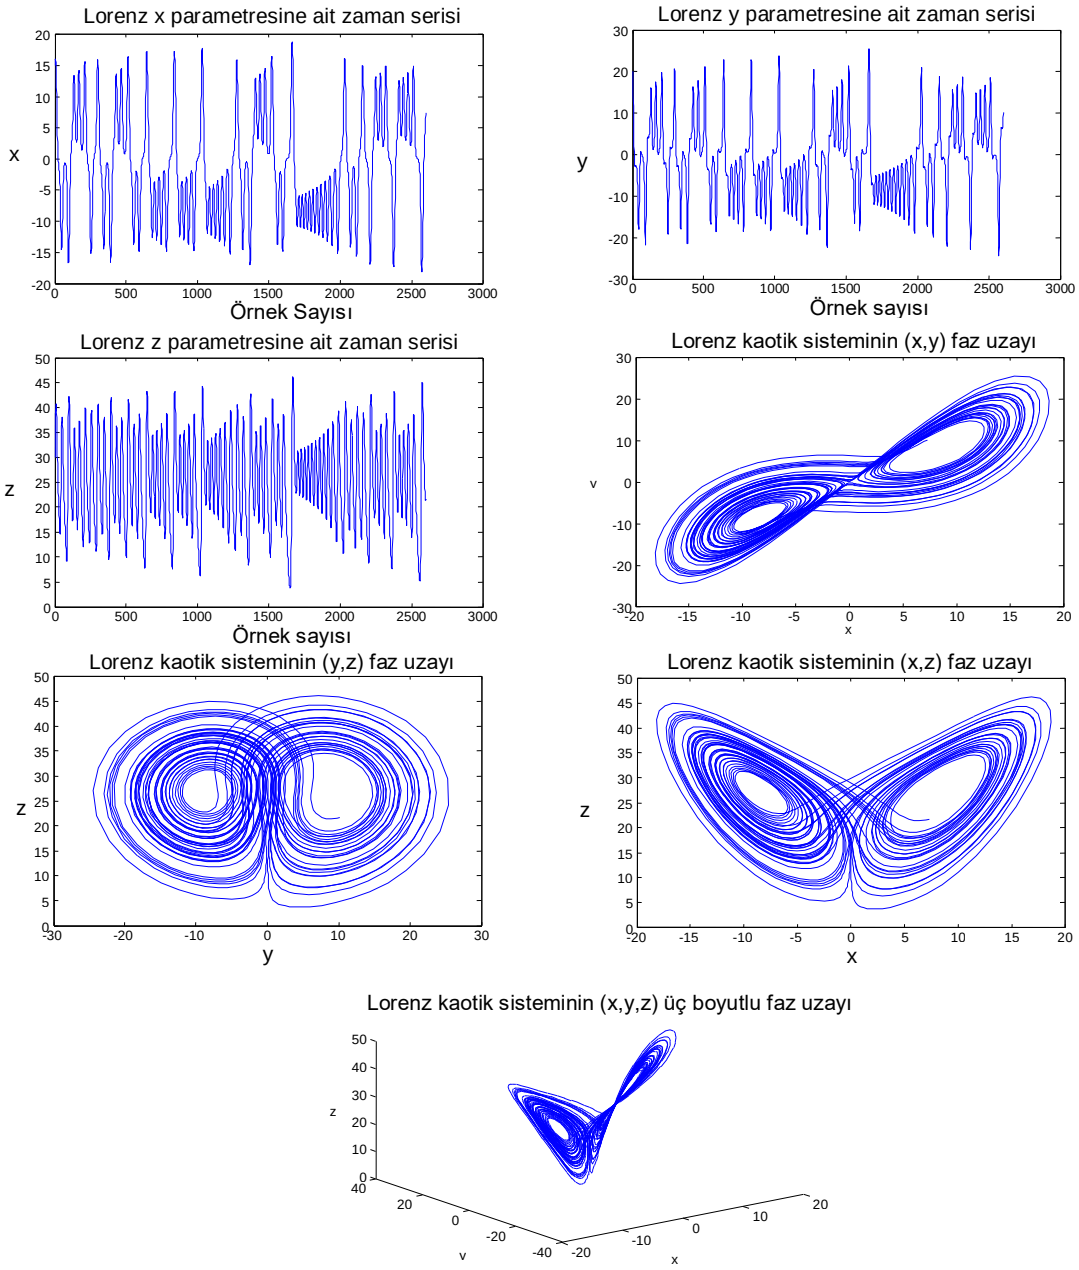
$$\begin{aligned} dx/dt &= f(x, y, z) \\ dy/dt &= f(x, y, z) \\ dz/dt &= f(x, y, z) \end{aligned} \tag{3.1}$$

Lorenz'in önerdiği diferansiyel denklem takımı aşağıdaki denklem (3.2) takımıyla gösterilmiştir.

$$\begin{aligned} dx/dt &= a(-x + y) \\ dy/dt &= bx - y - xz) \\ dz/dt &= xy - cz) \end{aligned} \tag{3.2}$$

Denklem (3.2) takımı xy ve xz nonlineer olmak üzere toplam 7 terim içermektedir. Kaotik çözüm için parametreler a=10, b=28 ve c=8/3 olarak alınmıştır. İlk koşullara ise $x_{0=}$0,5, y_0=0,5 ve z_0=0,5 girilmiştir.

Şekil 3.11'de Lorenz kaotik sisteminin zaman ve faz uzay grafikleri gösterilmiştir.



Şekil 3.11 Lorenz kaotik sisteminin zaman ve faz uzay grafikleri

Şekil 3.11'de gösterilen "x", "y" ve "z" Lorenz kaotik sistemine ait zaman parametrelerini, (x, y), (x, z) ve (y, z) iki boyutlu, (x, y, z) ise üç boyutlu faz uzayını temsil etmektedir. Şekilden görüldüğü gibi zaman ekseninde karışık görülen işaretler, faz uzayında ilginç şekiller oluşturmaktadır. Bu olay Kaosun temel özelliklerindendir ve "düzensizlik içindeki düzen" olarak bilinmektedir.

Zamanla değişen bir sistemi görsel hale getirmek sık başvurulan bir metottur. Bu durum için en çok kullanılan araçlardan biri, sistem değişkeninin zaman grafiğidir. Ancak bu grafik kaotik zaman serilerini diğer zaman serilerinden ayırmak için yeterli değildir. Koordinatlarının sistemin her bir değişkenini temsil ettiği faz uzayı bu iş için daha uygundur. Faz uzayının iki önemli özelliği vardır. Klasik zaman serisindeki karmaşık ve anlamsız bir yapı faz uzayında çarpıcı bir yapıya dönüşebilmektedir. İkinci olarak da çok uzun zaman serilerini belli bir alanda yoğunlaştırarak analizi kolaylaştırmaktadır [63]. Kısacası, faz uzayının bu özelliği üzerinde çalışılan sinyalin topyekûn değerlendirilmesini sağlamaktadır.

Sisteme ilişkin bütün bu bilgiler sistemin zaman içindeki belirli bir andaki durumunu tek bir noktaya indirgemektedir. Bu nokta, o andaki sistemin kendisidir. Faz uzayında sistemin o anındaki tüm bilgilerini taşıyan nokta, bir sonraki anda çok küçük de olsa yerinden oynayacaktır. Bu yerinden oynama faz uzayında kendini bir yörünge ile gösterecektir. Bu yörünge ise sistemin herhangi bir durumunu tespit etmek için bize yardımcı olacaktır. Dinamik sistemin bağımsız olarak hareket edebilen her bir parçasının bir serbestlik derecesi olduğu düşünüldüğünde her serbestlik derecesinin faz uzayında ayrı bir boyuta sahip olması gerekmektedir. Aksi takdirde faz uzayındaki tek bir noktanın, sistemin hangi durumunda olduğunu belirlemek için yeterli miktarda bilgi içermesi mümkün olmamaktadır [66]. Faz uzayındaki nokta veya noktalar kümesi, dinamik sistem zaman içinde var oldukça, yörüngeleri kendi üzerine çeken özgün desenler oluşturmaktadır. Bu özgün desenler, yörüngeleri kendi üzerlerine çekmelerinden dolayı sistemin çekicisi olarak adlandırılmaktadır. Farklı başlangıç koşullarına karşı gelen yörüngelerin faz uzayında kapsadığı alan çekicinin çekim bölgesini oluşturmaktadır [67]. Dolayısıyla, Kaos anlık bir durum değil bir süreçtir.

Çekiciler dinamik sistemin davranışına bağlı olarak farklı şekillerde olabilmektedir [57]. Herhangi bir başlangıç koşuluna sahip olan bir dinamik sistem, kararlı bir sistem

ise faz uzayındaki çekicisi geçici bir durumdan sonra kararlı durumu gösteren noktaya ulaşıp o noktada kalmaktadır. Bir noktadan oluşan bu çekiciler "nokta çekici" olarak adlandırılmaktadır. Periyodik davranış gösteren dinamik sistemlerin faz uzaylarındaki çekicileri ise "periyodik çekici" olarak adlandırılırlar. Periyodik çekicilerin faz uzayındaki bütün başlangıç değerlerine karşılık gelen yörüngeleri kapalı bir yörünge izler. Nokta ve periyodik çekicilerin en önemli özelliklerinden biri, çizdikleri yörüngeler arasındaki mesafelerin sabit bir orana sahip olmasıdır. Böylelikle sistemin sahip olduğu, birbirine bağlı olarak değişen değişkenleri sayesinde, sistemin bir sonraki durumu, önceki durumları yardımıyla belirlenebilmekte ve uzun vadede sistemin öngörüsü yapılabilmektedir [67]. İşaretin zaman ekseninde görülemeyen örüntüsü bu sayede faz uzayında kendisini gösterebilmektedir.

Kaotik davranış faz uzayındaki yakın yörüngelerin ayrılması ile karakterize edilmektedir. Zamanın fonksiyonu olarak, iki yakın yörünge arasındaki ayrılma üssel şeklinde artar. Kaotik davranışa sahip üç ya da daha fazla boyutlu faz uzayının önemli özelliği; yörüngelerin kesişmeksizin birbirlerini sararak ve kendilerini tekrar etmeksizin sınırlı bir bölge içerisinde kalmalarıdır. Bu tip dinamik hareketler garip çeker olarak adlandırılmaktadır. Eğer çeker üzerindeki davranış kaotik ise yani çeker üzerindeki yörüngeler yakınlarındaki yörüngelerden üssel olarak uzaklaşıyorsa çekerin kaotik olduğu söylenmektedir [68]. Kaotik çekicilerde örüntüden dolayı ilginç şekiller oluşmaktadır. Çekicinin acayip olması sistemde Kaosun varlığına işarettir.

Elimizde incelediğimiz sistemin sadece bir değişkeninin değerleri olduğunda çok değişkenli sistemlerin faz uzayını çizmek mümkün olmamaktadır. Bundan dolayı Takens [69], aynı değişkenin farklı zamanlardaki değerlerini koordinat olarak kullandığı psödo faz uzayını ortaya koymuş ve bu uzayda genellikle bir koordinat orijinal zaman serisinden, diğerleri de zaman serisinin gecikmiş değerlerinden oluşmaktadır. Buradaki önemli nokta, en uygun gecikme değerinin ve koordinat sayısının bulunmasıdır.

Kaotik dinamiklerin hesaplanması için, zaman serisinin durum uzayında yeniden oluşturulması gerekir. Durum uzayında aynı zaman diliminde iki veya daha fazla fonksiyonun birbiriyle karşılaştırılması yapıldığı için, faz uzayını yapılandırmak için en az iki fonksiyon gereklidir. Takens'a [69] göre yalnızca bir zaman serisi varsa,

zaman serisinin bir veya daha çok türevleri kullanılarak denklem (3,3)'teki gibi durum veya faz uzayı gerçekleştirilebilir.

$$X = [x(t)^T, x(t+\tau)^T, x(t+2\tau)^T, \dots, x(t+(m-1)\tau)^T] \qquad (3.3)$$

Zaman serisinin durum uzayında oluşturulmasının nedeni daha büyük bir Öklid uzayı oluşturarak çekerin yapısını herhangi bir belirsizlik olmadan görebilmekte yatar. Yukarıdaki denklem (3.3)'te kullanılan m gömülü (yerleştirme) boyutu, τ zaman gecikmesi ve *T* ise vektörel transpozdur. Gömülü boyut m, en yakın yanlış komşuluklar metodu ile zaman gecikmesi τ ise karşılıklı bilgi fonksiyonun ilk yerel minimumundan hesaplanır. İşareti durum uzayına yerleştirmek için seçilecek τ değeri, veri kümesindeki noktalar ne birbirinden ayırt edilemeyecek kadar küçük ne de istatistiksel anlamda birbirinden tamamen bağımsız olacak şekilde büyük seçilmelidir [70]. Zaman gecikmesi τ değeri küçük olduğu zaman çeker lineerleşerek, büyük olduğu zaman da faz uzayında dağılarak özelliğini kaybeder. Faz uzayının yeniden oluşturulması için zaman gecikmesi ve gömülü boyut önem arz ettiğinden aşağıda bu kavramlar ayrıca açıklanmıştır.

3.5.1.1 Zaman gecikmesinin belirlenmesi

Durum uzayının yeniden oluşturulması için rastgele seçilecek bir zaman gecikmesi, sinyalden bilgileri çıkarmak için uygun olmayabilir. Bu nedenle zaman gecikmesinin seçimi önemlidir. Zaman gecikmesinin hesaplanmasında en çok kullanılan yöntem karşılıklı bilgi fonksiyonu yöntemidir.

Karşılıklı bilgi fonksiyonu, muhtemel bütün ölçümlerin ortalaması olarak kabul edilir. Ölçüm değerleri x(n) birinci küme, τ kadar bir zaman gecikmesi sonra alınan ölçüm ise x(n+ τ) ikinci küme olmak üzere, n ve (n+ τ)'deki ölçümler arasındaki karşılıklı bilgi fonksiyonu denklem (3.4) ile hesaplanabilir [71].

$$I(\tau) = \sum_{n=1}^{N} P(x(n), x(n+\tau)) \log_2 \left[\frac{P(x(n), x(n+\tau))}{P(x(n))P(x(n+\tau))}\right] \qquad I(\tau) \geq 0 \qquad (3.4)$$

Eğer zaman gecikmesi çok küçük seçilirse x(n) ve x(n+ τ) ölçümleri birbirlerine yakınlaşarak, çok büyük seçilmesi durumunda ise x(n) ve x(n+ τ) ölçümleri birbirlerinden uzaklaşarak faz uzayına dağılırlar. Zaman gecikmesi, I(τ)'nin ilk yerel minimum değeri seçilirse uygun bir seçim olur. Unutulmaması gereken önemli bir

nokta da şudur. Ölçümler bir dereceye kadar bağımsız olmakla beraber istatistiksel olarak bağımsız olmamaktadırlar [71].

3.5.1.2 Gömülü boyutun belirlenmesi

İşaretin durum uzayında yeniden oluşturulmasındaki amaç, yeteri kadar büyük bir öklit uzayı (R^m) sağlayarak, sisteme ait çekerin yapısını herhangi bir belirsizlik olmadan görebilmektir. Böylece m boyutunda birbirine çok yakın olan iki nokta, m'nin daha büyük değerlerine sahip bir uzay içinde görünür hale gelebilmektedir. R^m uzayı, çekicinin gömülü boyutunu göstermektedir [72]. Gömülü boyutu belirleyebilmek için yaygın kullanılan metot, en yakın yanlış komşuluklar metodudur.

Cao'nun [73] metoduna göre; *xi(m)* m gömülü boyutuna, *xi(m+1)* ise m+1 boyutuna ve τ zaman gecikmesine sahip durum uzayındaki i'inci vektörler ve n(i,m), i ve m'ye bağlı bir sayaç ($1 \leq n(i, m) \leq N - m\tau$) olarak kabul edilebilir. Bu durum denklem (3.5)'te gösterilmiştir.

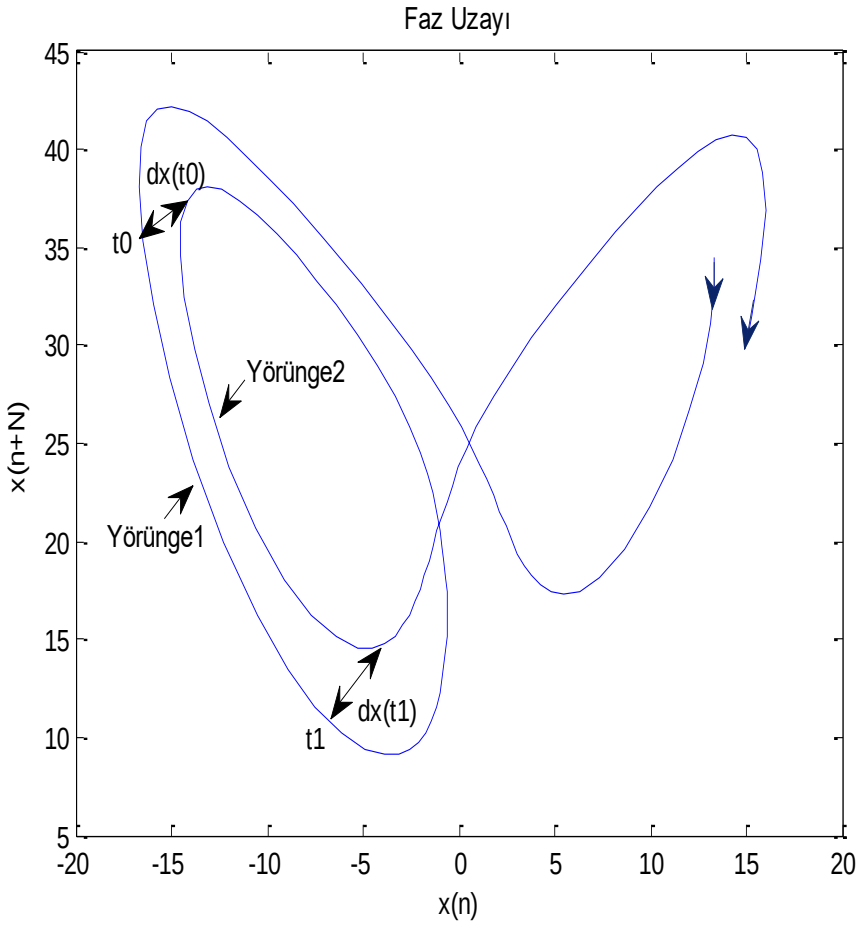
$$a(i,m)=\frac{\|x_i(m+1)-x_{n(i,m)}(m+1)\|}{\|x_i(m)-x_{n(i,m)}(m)\|} \ , i = 1,2,3, \dots N - m\tau \qquad (3.5)$$

Dolayısıyla "m" parametresinin, iyi belirlenmesi durumunda "m" boyutta birbirine yakın olan herhangi iki nokta "m+1" boyutta oluşturulan durum uzayında da birbirine yakın olabilmektedir. Bu tür nokta çiftlerine doğru komşular, böyle değilse yanlış komşular adı verilmektedir. Eğer işaret(veri) faz uzayına iyi bir biçimde gömülmüş ise yanlış komşu olmayabilecektir. Bu durumu oluşturabilmek için Cao'nun metodunda eşitlikte gösterilen bütün a(i,m)'lerin ortalama değeri kullanılarak gömülü boyut hesaplanabilmektedir.

$$E(m) = \frac{1}{N-m\tau}\sum_{i=1}^{N-m\tau} a(i,m) \qquad (3.6)$$

$$E1(m) = \frac{E(m+1)}{E(m)} \qquad (3.7)$$

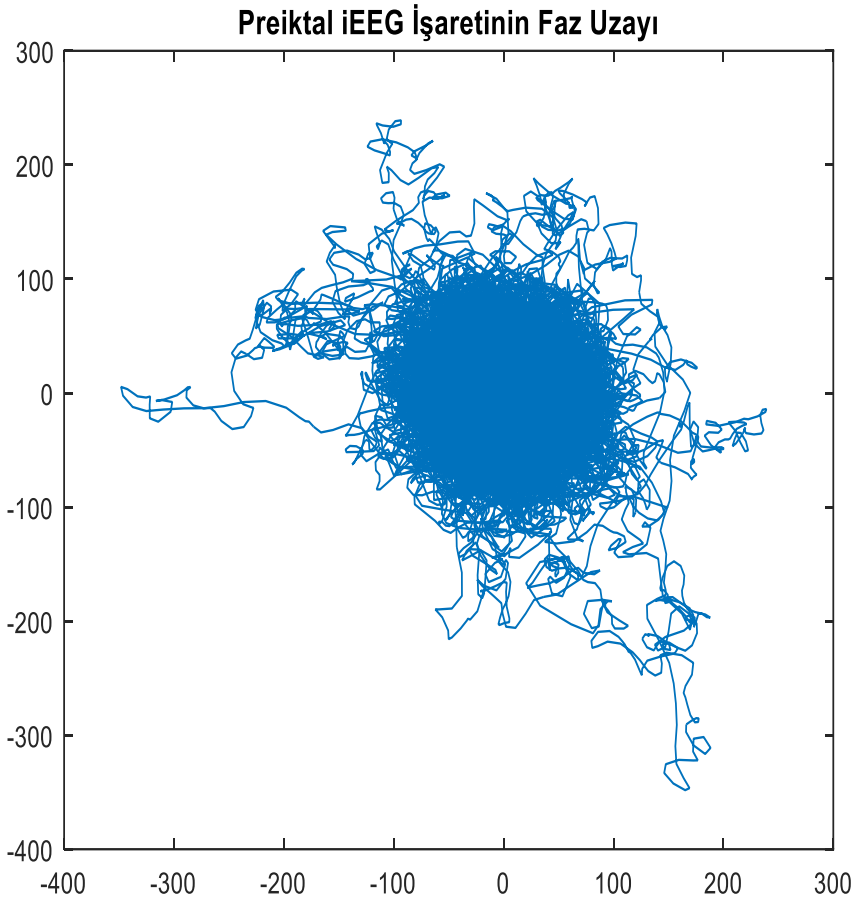
Denklem (3.6)'te görüldüğü gibi E(m) yalnızca "m" boyutuna ve "τ" zaman gecikmesine bağlıdır. Bu durumun "m"'den "m+1"'e değişimini incelemek için denklem (3.7) eşitliği kullanılabilir. Eğer zaman serisi bir çeker (atraktör, çekici) haline gelmişse E1(m)'nin değişimi, "m" bir m_0 değerinden daha büyük olduğunda durabilecektir. (m_0+1) ise minimum gömülü boyut olarak belirlenebilmektedir [73].



Şekil 3.12 Faz uzayında yörünge gösterimi

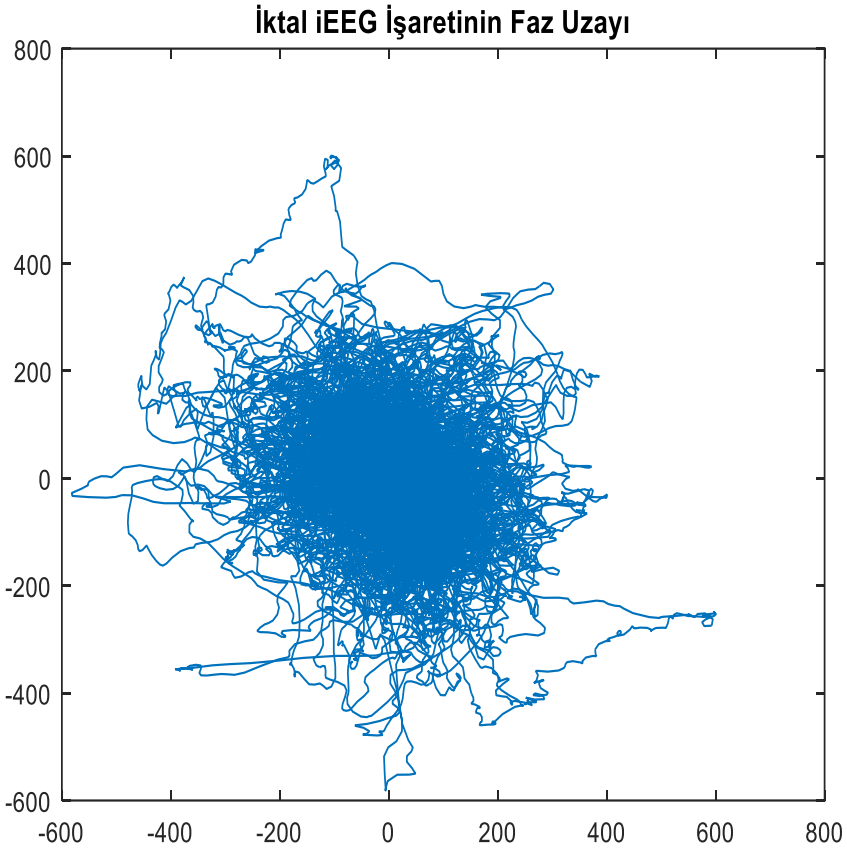
Şekil 3.12'de faz uzayında yörüngelerin zamanla değişimi gösterilmiştir. Lyapunov üstellerinde iki yörünge arasındaki yakınlaşma/uzaklaşma oranları hesaplanırken bu gösterim kullanılmaktadır. Şekildeki başlangıç zamanı t_0 ve "t" zaman sonrası t_1 ile gösterilmiştir. Başlangıç zamanında iki yörünge arasındaki mesafe $d(t_0)$ ve "t" zaman sonundaki mesafe ise $d(t_1)$ olarak sembolize edilmiştir.

Şekil 3.13'de preiktal iEEG işaretinin faz uzay grafiği gösterilmiştir. Şekil 3.13 incelendiğinde faz uzayının yoğun olarak "-100 µV" ile "+100 µV" arasında osilasyon yaptığını görmek mümkündür.



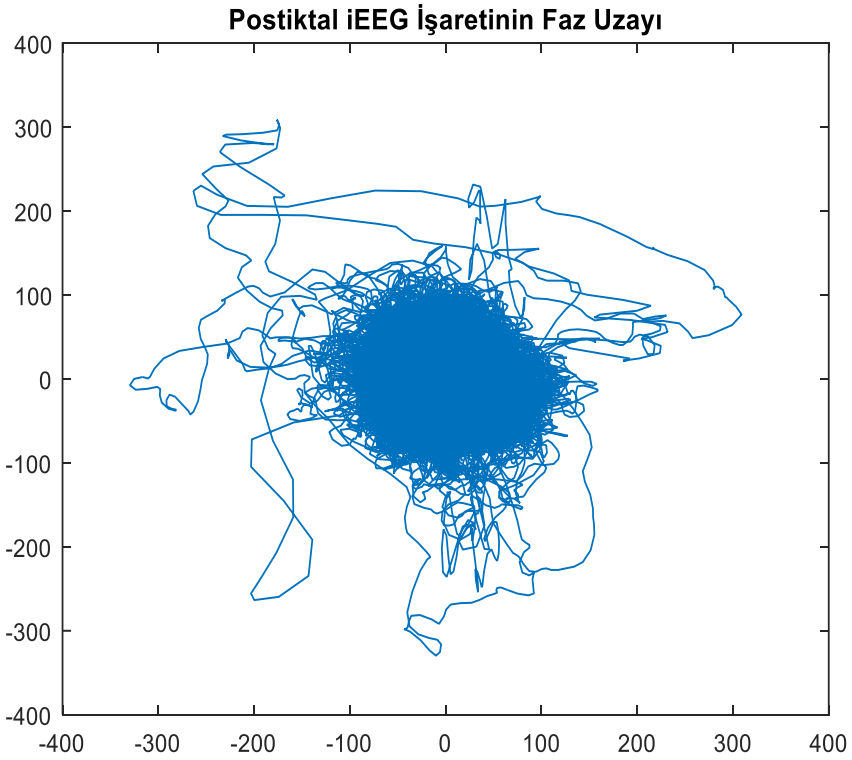
Şekil 3.13 Preiktal iEEG işareti faz uzay grafiği

Şekil 3.14'te iktal iEEG işaretinin faz uzay grafiği gösterilmiştir. Şekil 3.14 incelendiğinde faz uzayının yoğun olarak "-300 µV" ile "+300" µV arasında osilasyon yaptığını görmek mümkündür.



Şekil 3.14 İktal iEEG işareti faz uzay grafiği

Şekil 3.15'te postiktal iEEG işaretinin faz uzay grafiği gösterilmiştir. Şekil 3.15 incelendiğinde faz uzayının yoğun olarak "-100 µV" ile "+100 µV" arasında osilasyon yaptığını görmek mümkündür. Bu değerler zaman bölgesindeki değerleri topyekûn görmemizi sağlamaktadır. İşaret uzunluğu ne olursa olsun sınırlı bir bölgeye genlik değerleri yansımakta ve adeta zaman bölgesindeki işaretin resmini görmek mümkün olmaktadır. Bu, bize daha sınırlı alanda işareti değerlendirme fırsatı sunmaktadır.



Şekil 3.15 Postiktal iEEG işareti faz uzay grafiği

3.6 Entropi

Entropi, bir sistemin düzen/düzensizliğinin ölçüsü olarak tanımlanır. Entropi kavramının iletişim teorisindeki kullanımı Shannon [74] ile 1940'larda başlamıştır. O tarihten günümüze, başta işaret işleme olmak üzere, birçok alanda entropi tekniği yaygın olarak kullanılmıştır. İşaret işleme açısından bakıldığında, durağan olmayan bir işaretin düzen/düzensizlik bilgisinin derecesini ölçmek için uygun bir araç olarak kabul edilir. Sinyal durağan ise frekans bölgesinde dar bir spektrum ile düşük bir entropi değerine sahip olur. Sinyal durağan değilse, frekans spektrumu geniş bir banda yayılarak yüksek entropi değerine sahip olur [74]. Sinyal işlemede en yaygın olarak kullanılan entropi hesaplama türleri arasında Shannon entropi tekniği yer alır.

Beyin sinyalleri durağan olmayan sinyaller grubuna girdiğinden ve bu tip sinyallere entropi tekniği başarılı bir şekilde uygulandığından [75-77] bu metodu kullanma ve geliştirme isteği doğmuştur. Aşağıda entropi tekniği anlatılmıştır.

Bir sistemin entropisi denklem (3.8)'deki Shannon entropi yöntemiyle hesaplanabilmektedir [78].

$$S = -\sum_{j} P_j \ln P_j \tag{3.8}$$

Denklem (3.8)'deki "*Pj*" olasılık fonksiyonu olup bu çalışmada normalize enerjiyi temsil etmektedir. Burada elde edilen entropi değeri "*S*", sistemin düzensizliğinin ölçüsü olarak tanımlanır. Bu ölçütün, sistem hakkında genel bir bilgi sunduğu düşünüldüğünden, yaygın kullanım alanına sahiptir.

3.7 Dalgacık Dönüşümü

EEG verileri zaman bölgesinde yalın halde incelendiğinde birçok bilgiyi görmek zorlaşır. Bunun için sinyalin güç ve faz bilgisine başvurmak gerekir. Bu metotlardan Literatürde yaygın kullanılanı Dalgacık Dönüşümüdür (DD). Bu metot, sinyalin zamana bağlı frekans değişimlerini ele alır. İlk olarak Dennis Morlet tarafından ortaya konmuş ve günümüzde yoğun bir şekilde kullanılmaktadır. Dalgacık dönüşümü, temel işaret ve çekirdek sinyalin yer aldığı bir evrişim işlemidir. Dalgacıklar, diğer çekirdek sinyallerinden farklı olarak zamanda kısa bir sürede varlık gösterip, sıfır yükseklik değeriyle başlayıp ve yine sıfır yüksekliğe yaklaşırlar. Ölçekleme işlemini istenilen zaman parçası büyüklüğünde gerçekleştirmek için Dalgacık dönüşümü kullanılır. Bu sayede sinyal bileşenlerinin, frekans-zaman alanındaki ilişkileri daha detaylı olarak incelenebilir [62, 79]. Bu dönüşüm, durağan olmayan veriler üzerinde etkili olan bir metottur. Bu avantajından dolayı; sinyal işleme, görüntü işleme, görüntü sıkıştırma, gürültülü verilerin filtrelenmesi ve benzeri veri işleme uygulamalarında dalgacık dönüşümü günümüzde yoğun bir şekilde kullanılmaktadır. Dalgacık dönüşümü, temel olarak sürekli ve ayrık olmak üzere iki şekilde incelenmektedir.

Bu tez çalışmasında, ESA modeli için oluşturulan giriş desenleri, Sürekli dalgacık dönüşümü (SDD) kullanılarak elde edilen iEEG delta altbant frekans-zaman skalogram görüntülerinden ibarettir.

3.7.1 Sürekli dalgacık dönüşümü

Dalgacık Dönüşümünde, Kısa Zamanlı Fourier Dönüşümü (KZFD) 'den farklı olarak pencereleme işlevini ana dalgacık üstlenir ve bu dalgacık, dönüşüm olayı boyunca hem ölçekleme ve hem de öteleme işlevi görür. Daha iyi bir frekans-zaman çözünürlüğü sağlamak için; alçak frekanslarda uzun zaman peryotlu, yüksek frekanslarda ise kısa

zaman peryotlu pencereleme seçilmelidir [79, 80]. Bu dönüşüm EEG verileri gibi durağan olmayan sinyaller üzerinde etkili bir metottur [79, 80].

Farklı parametreler üretilebileceği gibi literatürde sık kullanılan dalgacık çeşitleri de vardır. Bu çalışmada nörolojik sinyallerin zaman-frekans analizlerinin gerçekleştirilmesinde önemi olan ve durağan olmayan sinyallerin (işaretlerin, verilerin) spektrum analizi açısından diğer dalgacıklara göre daha çok kullanılan Morlet dalgacığı tercih edilmiştir [81, 82].

3.7.2 Ayrık dalgacık dönüşümü

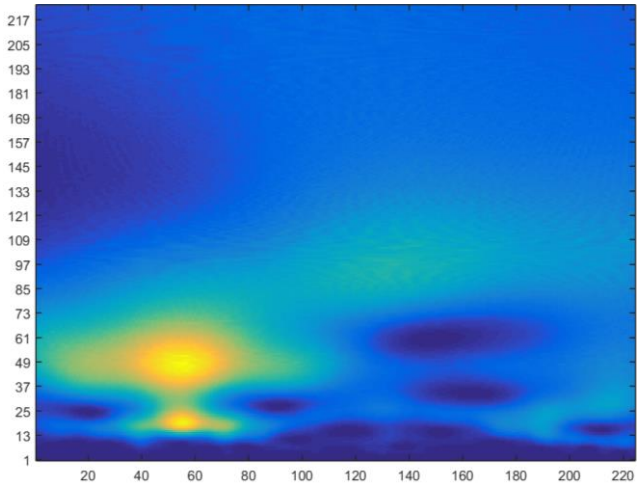
Ayrık Dalgacık dönüşümü (ADD)'nde, ayrıştırılacak veriye düşük ve yüksek geçiren dalgacık filtreleri uygulanarak yaklaşık ve detay bileşenlerine ayrıştırılma yoluna gidilir. Ayrıştırmada elde edilen yaklaşık bileşenleri, düşük frekanslı ve yüksek ölçekli olur. Detay bileşenleri ise yüksek frekanslı ve alçak ölçekli olmaktadır. ADD dönüşüm işleminde, SDD yönteminin temel özelliklerini temsil eden öteleme ve ölçekleme parametreleri belli kriterlere göre seçilirse ADD fonksiyonu elde edilir.

Literatürde EEG verilerinin ayrıştırılmasında dalgacık dönüşümü sık olarak kullanılmaktadır [83, 84, 85]. Çalışmada, dalgacık dönüşümüyle iEEG verileri zaman-frekans bölgelerinde incelenmiş ve ESA modeline giriş verisi hazırlamakta kullanılmıştır.

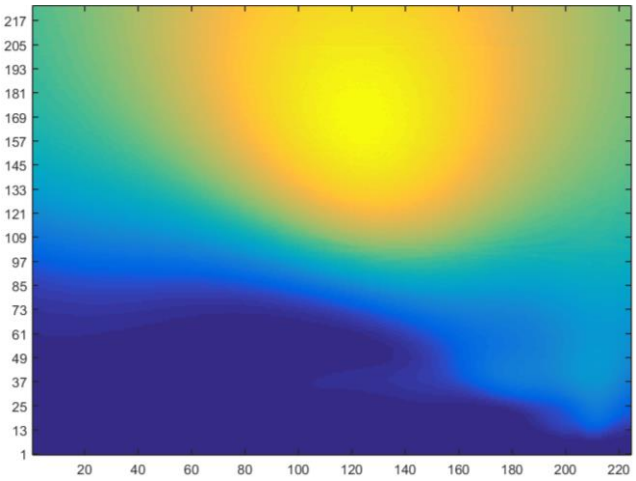
3.8 Skalogram

Sinyali görselleştirmek için, orijinal sinyal üzerinde gerçekleştirilen Sürekli Dalgacık Dönüşümünün (SDD) ölçekli bir temsili olan Skalogramlara dönüştürmektir. SDD, sinyal ile farklı frekanslardaki örnek dalga arasındaki evrişime karşılık gelen birkaç değer üretir - aynı zamanda "ana dalgacık" olarak da bilinir.

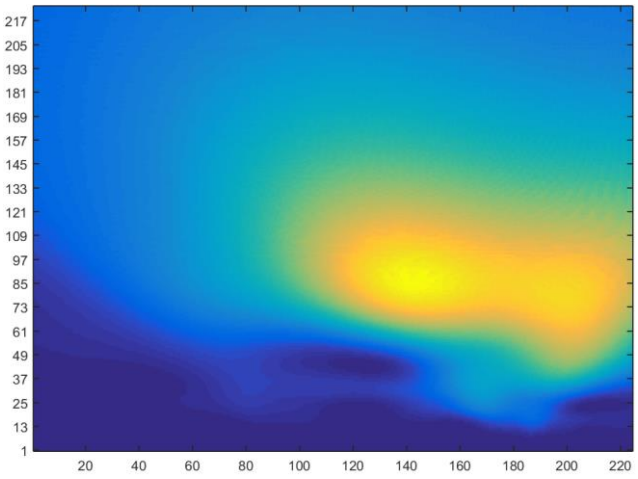
Epileptik bir hastanın (Hasta1) iEEG verisinin bir kanalının 224x224 boyutundaki a) preiktal, b) iktal ve c) postiktal skalogram görüntüsü Şekil 3.16'da gösterilmiştir. Bu görüntüler elde edilmeden önce epileptik iEEG sinyali preiktal, iktal ve postiktal bölütlerine ayrılmış ve daha sonra bu bölütlerden 224x224 boyutundaki skalogram görüntüleri elde edilmiştir.



(a)



(b)



(c)

Şekil 3.16 Epileptik iEEG sinyalinin a) preiktal, b) iktal ve c) postiktal skalogram görüntüleri

Tablo 3.2'de ESA modelinin eğitim ve testi için kullanılan skalogram grafiklerinin % ve sayısı gösterilmiştir. Toplam 3300 adet iEEG bölütünün MATLAB ortamında skalogram görüntüleri elde edilmiş ve ESA modeline giriş verisi olarak verilmiştir. Giriş verilerinin % 80 eğitim için kullanılırken % 20 test ve eğitim verilerinin de % 20 ise doğrulama için kullanılmıştır. Bu veriler preiktal, iktal ve postiktal bölütlerini aynı oranda içermektedir.

Tablo 3.2 ESA modelinin eğitim ve testi için kullanılan skalogram görüntü çizelgesi

	%	**Adet**
Eğitim	80	2640
Test	20	660
Toplam	100	3300

Tablo 3.3'te ESA modelinin eğitiminin doğrulaması için kullanılan skalogram grafiklerinin % ve sayısı gösterilmiştir.

Tablo 3.3 ESA modelinin eğitiminin doğrulaması için kullanılan skalogram görüntü çizelgesi

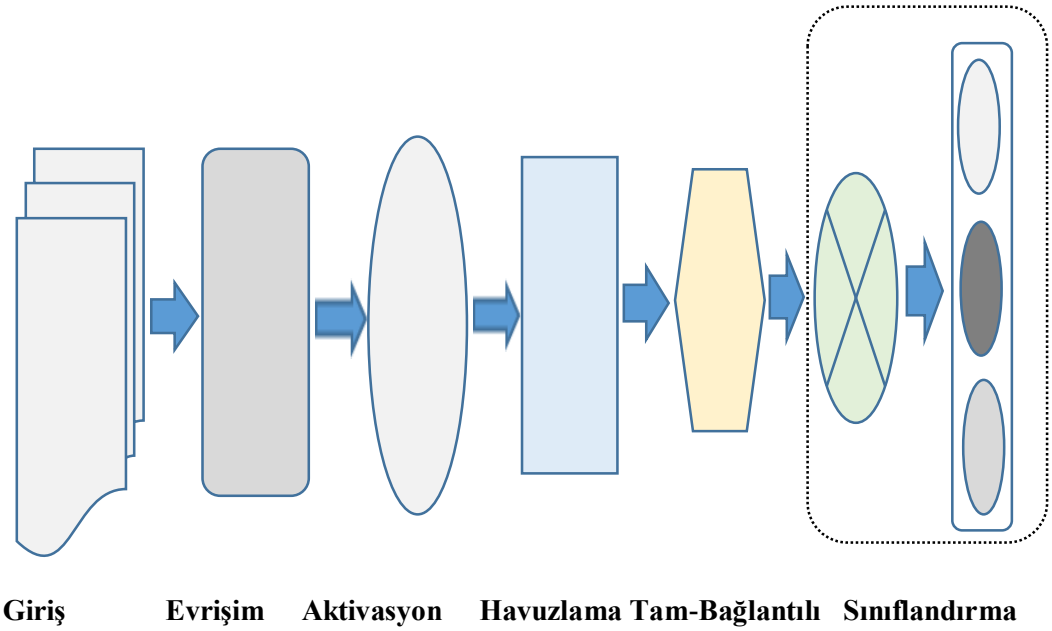
	Eğitim Verilerinin % si	**Adet**
Doğrulama	20	528

Genel olarak skalogram, sürekli dalgacık katsayılarının mutlak değerleri olarak tanımlanabilir. Ayrıca skalogram görüntülerinin frekans ve zaman olmak üzere iki ekseni vardır. Tüm skalogram görüntüleri MATLAB yazılımında 224x224 boyutlu olarak elde edilmiştir. Çalışmada 3300 skalogram görüntüsü kullanılmıştır. Görsellerin % 80'i (2640) eğitim için, % 20'si ise (660) test için kullanılmıştır. Ayrıca eğitim görsellerinin % 20'si (528) doğrulama için kullanılmıştır. Skalogram görüntüleri RGB görüntüleridir (R, G, B olarak 3 kanal) ve görüntülerin boyutları 224x224'tür. Ayrıca RESNET modeli 224x224x3 renkli görüntülere ihtiyaç duyar.

3.9 Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağlarının temel katmanları aşağıda listelenmiş ve kısaca açıklanmıştır.

Şekil 3.17'de ESA modelinin katmanları gösterilmiştir.



Şekil 3.17 Evrişimsel Sinir Ağları modelinin temel katmanları

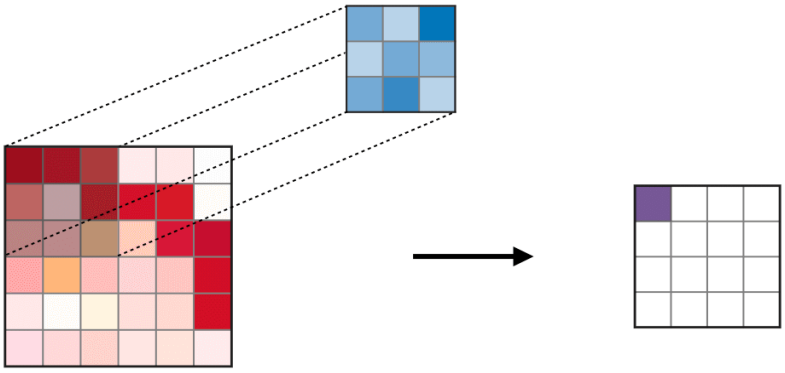
3.9.1 Giriş katmanı

Giriş katmanı ESA'nın ilk katmanı olup iyi bir başarım için boyutsal ve nitelik olarak bu katmanın titizlikle seçilmesi önem arz eder. Giriş katmanı parametresi oluşturmak için öncelikle preiktal, iktal ve postiktal durumları içeren ham epileptik iEEG verisi sırasıyla preiktal, iktal ve postiktal olarak bölütlenmiştir. Sonra bu bölütler 224 örnek oluşturacak epoklara ayrılmıştır. Daha sonra bu epoklar, MATLAB ortamında ayrık dalgacık dönüşümü ile altbantlarına ayrıştırılmıştır. Beş altbanda ayrıştırılan bölütlerin delta altbandının skalogramları alınıp ESA'ya giriş verisi oluşturulmuştur.

3.9.2 Evrişim katmanı

Evrişim katmanında evrişim yapılarak bir taraftan veri boyutu düşürülürken diğer taraftan da verideki saklı özellikler ortaya çıkarılır. Bu katmanda giriş verisindeki özellikler ortaya çıkarılıp veriye kimlik kazandırılır.

Şekil 3.18'de evrişim katmanının işlem aşamaları gösterilmiştir. Seçilen küçük boyutlu filtre tüm matrisin üzerinden kaydırılarak evrişim işlemi gerçekleştirilmektedir.



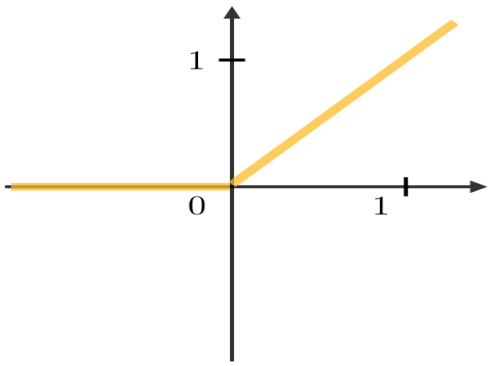
Şekil 3.18 Evrişim işlem aşamaları

ESA modelinin bu katmanında, çeşitli öznitelik haritalarını oluşturmak, tüm görüntüyü bu öznitelik haritalarında birleştirmek için çeşitli süzgeçler kullanılır. Konvolüsyonun üç ana avantajı şöyle sıralanır: a) Benzer özellik haritasındaki ağırlık paylaşım mekanizmaları, parametreleri azaltmakta, b) Lokal bağlantı sayesinde, komşu pikseller arasındaki bağlantılar öğrenilmekte ve c) Desenin durumuna göre değişmezdir [86].

3.9.3 Aktivasyon katmanı

Bu katmanda genellikle doğrultulmuş lineer birim(ReLu) kullanılır. Bu katmanda negatif değerler sıfıra çekilerek ağa, doğrusal olmayan bir yapı kazandırılır ve ağın daha hızlı öğrenmesi sağlanır. Bu çalışmada, aktivasyon katmanı olarak ReLu kullanılmıştır.

Şekil 3.19'da doğrultulmuş lineer birim grafiği gösterilmiştir.



Şekil 3.19 Doğrultulmuş lineer birim grafiği

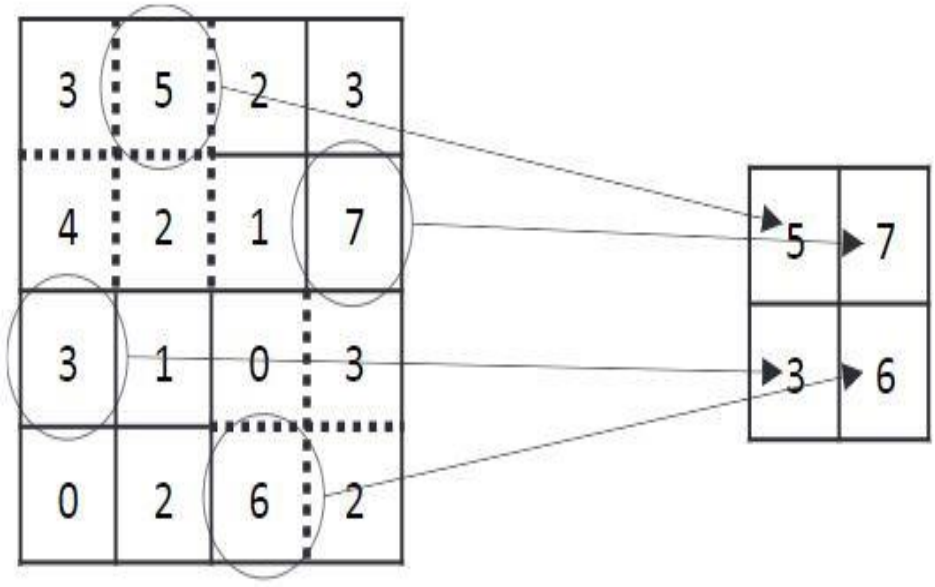
ESA modellerinde, konvolüsyondan sonra aktivasyon işlemi gerçekleşmektedir. Derin öğrenme yöntemlerinde aktivasyon işleminde yoğun bir şekilde, Doğrultulmuş Lineer Birim (Rectified Linear Unit, ReLU) kullanılmaktadır [87].

3.9.4 Havuzlama katmanı

Bu katman, özelliklerin belirlendiği ve boyutun azaltılarak ezberlemenin önüne geçildiği katmandır. Minimum, maksimum ve ortalama havuzlama olmak üzere genelde üç şekilde kullanılmasına karşın en çok maksimum havuzlama tercih edilir. Çalışmamızda, havuzlama katmanı olarak maksimum havuzlama kullanılmıştır.

Havuzlama katmanında, ESA modeline verilen görüntülerin küçültülmesi ve parametre sayısının azaltılması amaçlanır. Havuzlama katmanı, örüntü haritasındaki komşu nöronların çıktılarını özetler. Bu katman, doğrusal olmayan alt örneklemenin bir biçimi olarak kabul edilir. Havuzlama işleminde, giriş görüntüsünden örtüşmeyen dörtgenler kümesi oluşturulmaktadır. Oluşturulan bu her alt bölgenin maksimum veya ortalama değeri elde edilmektedir. Bu metot kullanılarak, desenlerin istenildiği kadar küçültülmesi sağlanabilmesi mümkündür [86, 88].

Havuzlama işlemi Şekil 3.20'de gösterilmiştir.



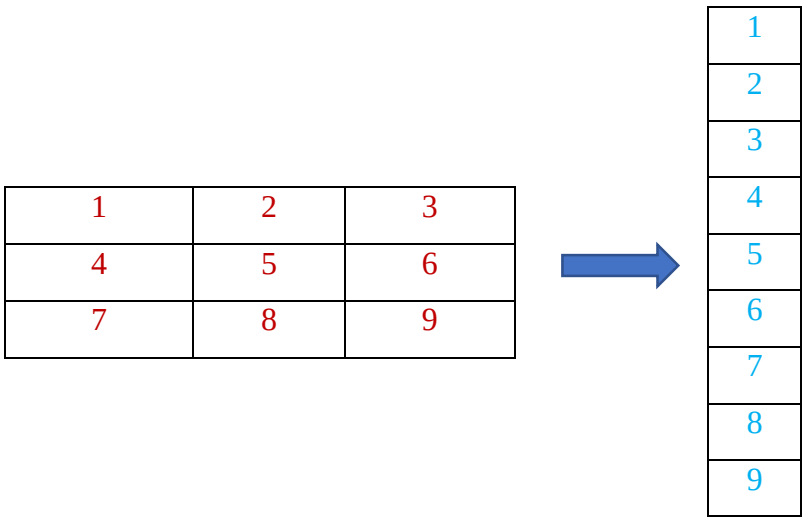
Şekil 3.20 Havuzlama işlem aşamaları

3.9.5 Tam-bağlantılı katman

Bu katmanda, evrişim, aktivasyon ve havuzlama katmanlarında oluşan özellik matrisi, vektör matrisine çevrilir. Tam bağlantılı katman, bir sinir ağı gibi performans göstermekte ve bir ESA modelindeki parametrelerin yaklaşık % 90'ını içermektedir. Önceki katmandan gelen çok boyutlu veriler, tam bağlantılı katmana uygulanabilmesi

için önceden tanımlanmış uzunluktaki bir vektöre dönüşümü sağlanmakta ve bu sayede, verinin desenine ilişkin özellikler, bir boyutlu öznitelik vektörlerine dönüştürülmektedir [89]. Bu işlem vektörizasyon olarak adlandırılır. Tam bağlantılı katmanın, fazla parametre içerdiğinden dolayı, hesaplama yükünün de paralelinde arttığı unutulmamalıdır.

Şekil 3.21'de tam bağlantılı katmanın görsel hali yer almaktadır.



Şekil 3.21 Tam-bağlantılı katmanda tek girişli veri elde edilmesi

3.9.6 Sınıflama katmanı

Bu katmanda adından da anlaşılacağı üzere sınıflama yapılır. Tam bağlantılı sinir ağı katmanları, Softmax parametresini sınıflandırma katmanı olarak kullanmaktadır. Burada farklı sınıflandırıcılar kullanılmasına rağmen softmax daha çok tercih edilir. Sınıflandırıcı, sınıflaması yapılacakları 0-1 arasında değerler vererek sınıflandırır. Ağın en iyi tahmini, 1'e yakın olan değerdir. Bu çalışmada, softmax ile iEEG verileri preiktal, iktal ve postiktal olmak üzere üç ana sınıfa ayrıştırılmıştır.

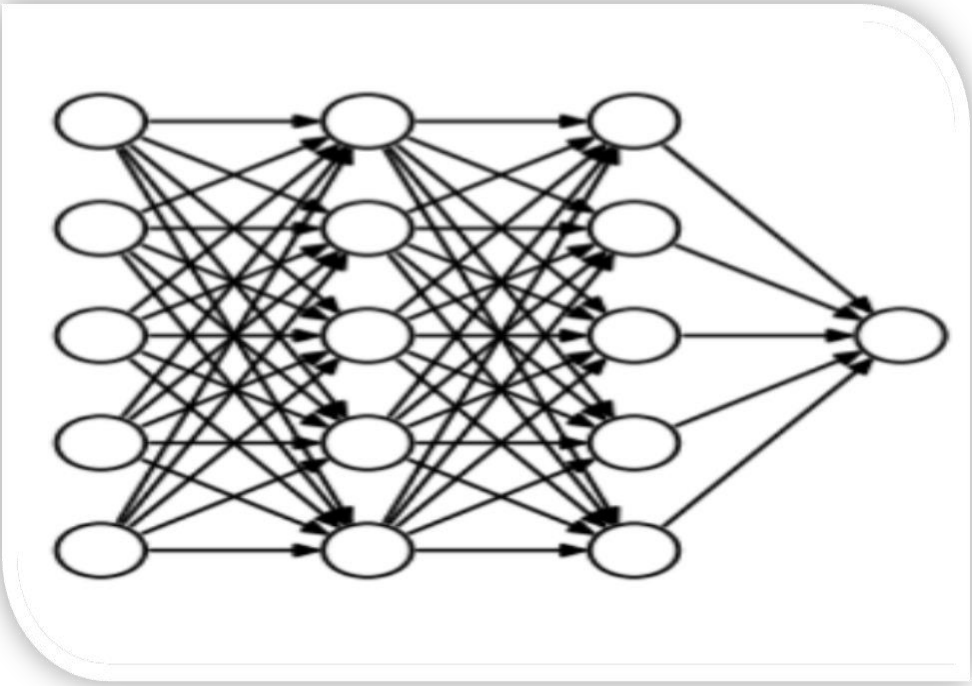
3.9.7 Aktivasyon kesici

Derin öğrenme yöntemleri, diğer bilinen öğrenme metotlarıyla karşılaştırıldığında analizi yapılacak desenlerden daha özetlenmiş bilgiyi derin mimarisiyle çıkarabilir. Ancak derin modeller konvansiyonel yöntemlere göre daha fazla parametre içerdiğinden bazı dezavantajlara sahiptir. En önemli dezavantajlardan başında

ezberleme gelir. Diğer bir değişle algoritma esas sorunu çözmekten uzaklaşır ve kendisine verilen hedefleri tutturmaya çabasına girer. Anlık çözümlerde daha iyi sonuçlar oluşturmasına rağmen, asıl çözmesi gerekenleri çözmekten uzaklaşır. ESA modelinde yukarıda bahsi edilen ezberleme durumundan kaçınmak için aktivasyon kesici (Dropout) uygulanır [90].

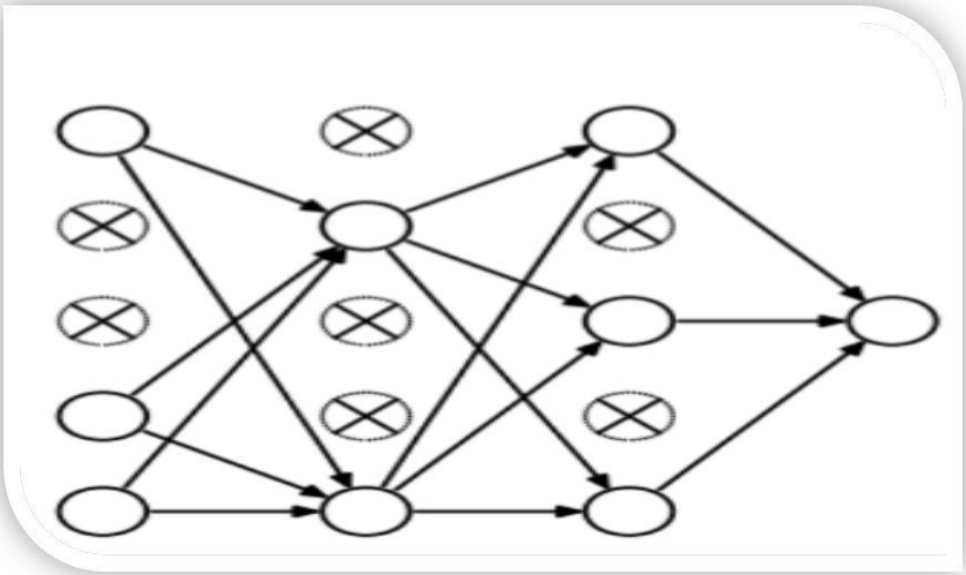
Derin ağ modelinde aktivasyon kesici metodu, ağın aşırı öğrenmesini engellemek için kullanılmaktadır. Bu amaçla ağ yapısının gizli katmanlarındaki bazı nöronların bağlantıları kesilmektedir. Bağlantısı kesilen bu nöronlar ağ dışında bırakılmaktadır. Dropout oranı 0,3 alındığında, gizli katmandaki nöronların % 30 oranı kullanılmayacak anlamına gelmektedir. Böylece küçülen ağ ile aşırı öğrenmenin önüne geçilmiş olunur ve ezberleme işlevini kaybeder [91].

Şekil 3.22'de klasik ağ grafiği gösterilmiştir.



Şekil 3.22 Klasik ağ grafiği

Şekil 3.23'te ise aktivasyon kesici uygulanan ağ grafiği gösterilmiştir. Ağdaki bazı nöronlar devre dışı bırakılarak ağın ezberlenmesinin önüne geçilmesi hedeflenmektedir.



Şekil 3.23 Aktivasyon kesici uygulanmış ağ grafiği

3.10 Performans Değerlendirmesi

Sistemin performansını değerlendirmek için denklem (3.9)'da verilen başarım değerlendirme ölçütü kullanılmıştır.

$$\text{Doğruluk}=(GN+GP)/(GN+GP+YN+YP) \quad (3.9)$$

Burada çalışmada kullanılan YP (Yanlış Pozitif), GP (Gerçek Pozitif), GN (Gerçek Negatif) ve YN (Yanlış Negatif) olarak kodlanmıştır [92].

Tablo 3.4'te karışıklık matrisindeki her sütun, gerçek sınıftaki örnekleri temsil ederken, her satır, tahmin edilen sınıfın örneklerini temsil eder. Bu karışıklık matrisinde üç sınıfa karşılık dokuz hücremiz vardır.

Gerçek / Yanlış kelimeleri bize tahminlerin doğru olup olmadığını ve İktal / Postiktal / Preiktal kelimeleri bize gerçek sınıfı söyler.

Tablo 3.4'te üç boyutlu karışıklık matrisi gösterilmiştir.

Tablo 3.4 Üç boyutlu karışıklık matrisi

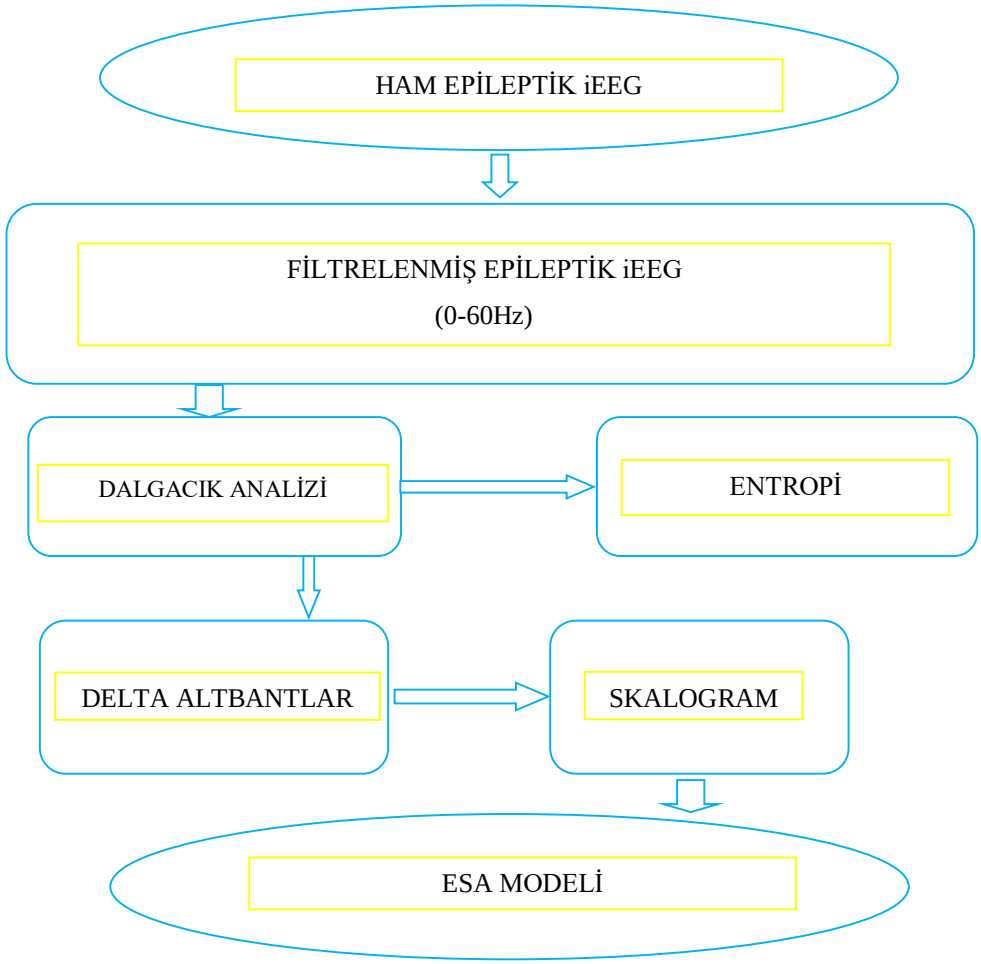
	TAHMİN			
GERÇEK	**İktal olup tahmini de iktal**	İktal olup tahmini postiktal	İktal olup tahmini preiktal	**İKTAL**
	Postiktal olup tahmini iktal	**Postiktal olup tahmini de postiktal**	Postiktal olup tahmini preiktal	**POSTİKTAL**
	Preiktal olup tahmini iktal	Preiktal olup tahmini postiktal	**Preiktal olup tahmini de preiktal**	**PREİKTAL**
	İKTAL	**POSTİKTAL**	**PREİKTAL**	

Karışıklık matrisindeki satırlar gerçek değerleri sütunlar ise tahmini değerleri göstermektedir. Bu çalışma preiktal, iktal ve postiktal olmak üzere toplam üç sınıf içerdiğinden Tablo 3.4'teki üç boyutlu karışıklık matrisi kullanılması ve tablodaki açıklamalara yer verilmiştir.

4. BULGULAR VE TARTIŞMA

Bu bölümde epileptik iEEG sinyallerinin nöbet öncesi, nöbet anı ve nöbet sonrası durumu entropi, dalgacık analizi, skalogram ve Evrişimsel sinir ağları yöntemiyle incelenmiştir. Bu amaç doğrultusunda öncelikle epilepsili deneklerden alınan iEEG verileri (sinyalleri) dalgacık analizi ile altbantlarına ayrıştırılmıştır. Sonra, entropi yöntemi kullanılarak hastalara ait iEEG sinyallerinin altbant entropi değerleri hesaplanmıştır. Daha sonra delta altbantlarına ait iEEG sinyalleri preiktal, iktal ve postiktal safhalarına ayrıştırılmıştır. Daha sonra da MATLAB ortamında bu safhaların skalogram görüntüleri elde edilmiştir. Son olarak da elde edilen preiktal, iktal ve postiktal delta altbantlarının skalogram görüntüleri Evrişimsel sinir ağları yöntemiyle sınıflandırılmıştır.

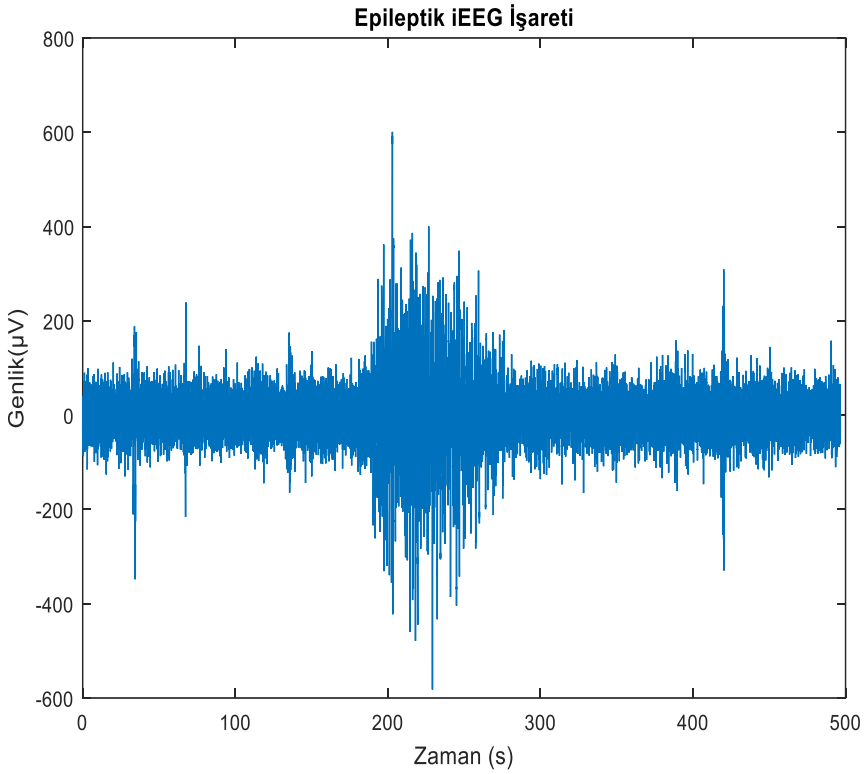
Şekil 4.1'de Bulgular ve Tartışma bölümünün içeriği şematik olarak gösterilmiştir.



Şekil 4.1 Bulgular ve Tartışma bölümünün şematik gösterimi

Bu çalışmayla, epilepsi hastalığını karakterize eden çok kanallı epileptik iEEG verileri ve modern matematiksel yöntem olan ESA modeli kullanılarak, iEEG verileri, preiktal, iktal ve postiktal olmak üzere üç sınıfa ayrıştırılmıştır.

Şekil 4.2'de epileptik bir hastaya ait 47 kanallık iEEG sinyalinin bir kanalı gösterilmiştir. Bu kanal toplam 485 sn'lik bir kayıttan oluşmaktadır. Bu kaydın ilk 180 saniyesi preiktal, daha sonraki 125 saniyesi iktal ve son 180 saniyesi ise postiktaldir.



Şekil 4.2 Preiktal, iktal ve postiktal safhaları içeren iEEG sinyali

Şekil 4.2'deki ilk 180 saniyelik nöbet öncesi safha, preiktal safhası olarak kabul edilir. Bu safhadan sonra genlikte yükselmeler olmuş ve 125 s boyunca sürmüştür. Bu 125 sn'lik kısım nöbetin geçirildiği andır. Bu, iktal safhası olarak tanımlanır. Bu safhadan sonra genlikte düşüş başlamış ve eski değer aralığına inmiştir. Nöbet bitimindeki bu safha da postiktal safhası olarak kabul edilir.

Hastaların geçirdiği nöbetlerin süresi birbirinden farklı olmaktadır. En kısa nöbet anı Hasta 1'e ait olup 13 s boyunca sürmektedir. Bundan dolayı Hasta 1'in nöbeti referans olarak alınmıştır. Örnekleme frekansımız 512 olduğundan, preiktal, iktal ve postiktal safhalar 13 s olarak alınmış ve bu da 13x512=6656 örneğe tekabül etmektedir. Yani

tüm hastaların bölütü 13 s olarak alınarak iEEG bölütleri 6656 örnek olarak seçilmiş ve bu her bir bölüt, beş altbanda ayrıştırılmıştır. Sonra, her bir hastaya ait tüm kanalların altbant Shannon entropi değerleri hesaplanmış ve ortalama entropi değerleri Tablo 4.1'de gösterilmiştir.

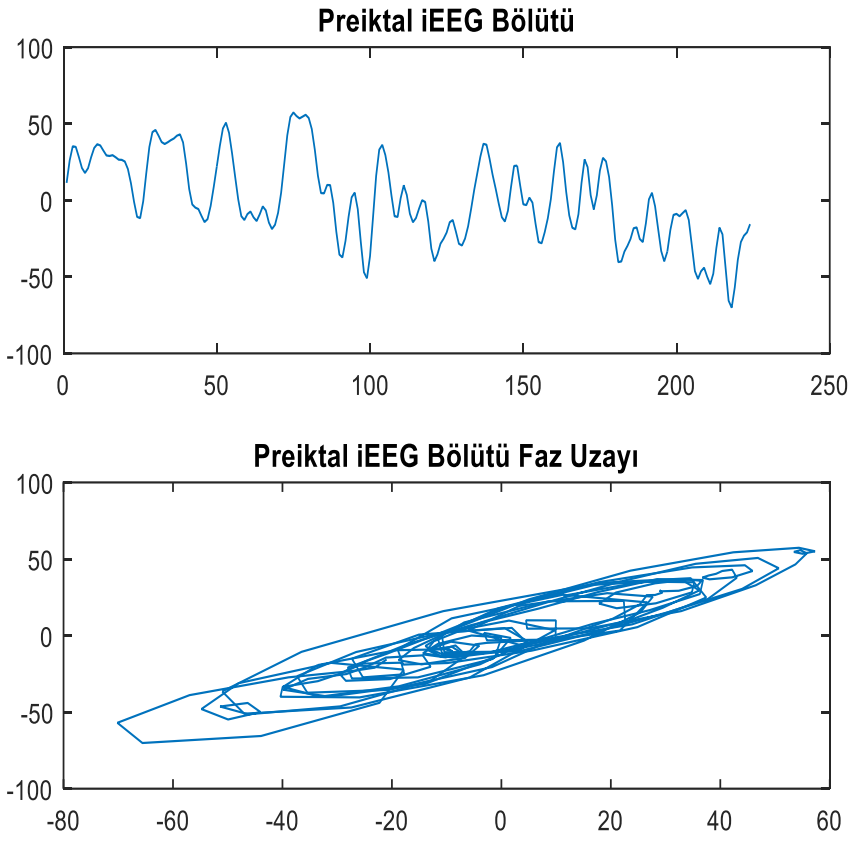
Tablo 4.1'de epileptik hastalara ait iEEG'nin tüm kanallara ait beş altbandının ortalama Shannon entropi değerleri verilmiştir.

Tablo 4.1 Epileptik iEEG'nin beş altbandının Shannon entropi değerleri

Hasta	**Segment Entropi**	**Delta Entropi**	**Teta Entropi**	**Alfa Entropi**	**Beta Entropi**	**Gama Entropi**
Hasta 1	1.2481	1.2103	2.1211	2.6312	3.5024	4.6420
Hasta 2	1.1942	1.0956	1.4324	1.9783	2.7890	4.4341
Hasta 3	1.1839	1.2180	1.8912	2.6126	3.3132	4.5193
Hasta 4	1.2540	1.1248	1.7541	2.2047	3.0112	4.4347
Hasta 5	1.1356	1.1156	1.3406	1.7981	2.2153	3.8154
Hasta 6	1.1885	1.2105	2.1438	2.5408	3.0724	4.4545
Hasta 7	1.1299	1.1602	1.9513	2.3246	2.9105	4.3129
Hasta 8	1.1279	1.1216	2.0745	2.4458	3.0641	4.4966
Hasta 9	1.1805	1.1934	1.8094	1.9031	2.2134	3.5417
Hasta 10	1.1207	1.1761	1.6089	1.9978	2.6876	3.9073
Hasta 11	1.1763	1.1980	1.8743	2.4067	3.3207	4.5087
Hasta 12	1.1787	1.1767	1.6242	2.4103	3.1987	4.7856
Hasta 13	1.1305	1.1497	1.9851	2.2586	2.7354	4.3342
Hasta 14	1.3676	1.7690	2.3607	3.1230	3.7404	4.5975
Hasta 15	1.1943	1.2117	2.0276	2.4323	2.4532	4.1207
Hasta 16	1.2306	1.2419	2.2683	2.4678	3.0076	4.8971
Ortalama	1.1901	1.2108	1.8917	2.3460	2.9522	4.3626
Standart Deviasyon	0.0632	0.1548	0.2869	0.3281	0.4295	0.3580
Kovariyans		0.077	0.0090	0.0136	0.0159	0.0094
Korelasyon		0.7870	0.4963	0.6558	0.5857	0.4154

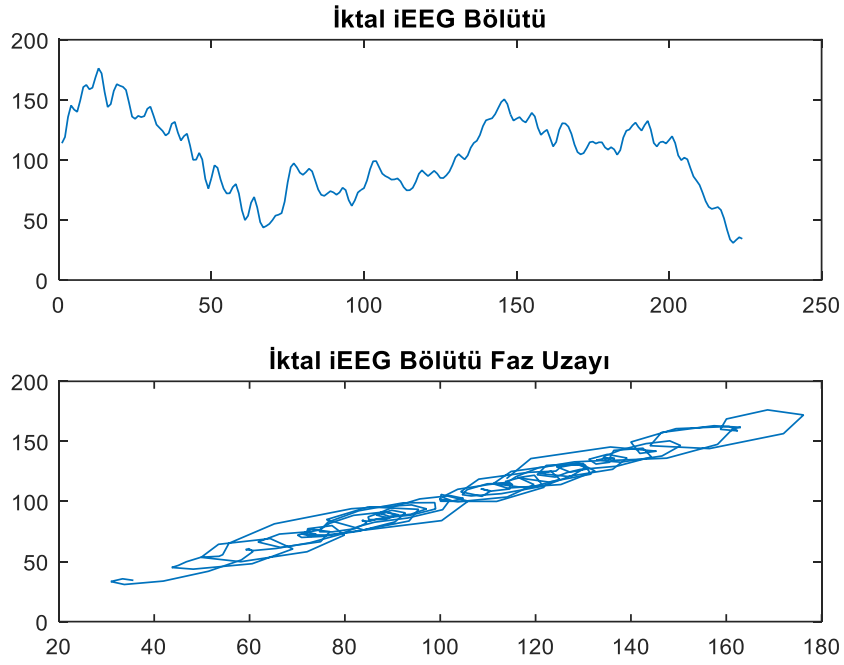
Tablo 4.1 incelendiğinde, delta altbandının entropi değerinin diğer altbant değerlerine göre daha düşük olduğu görülür. Yani delta altbandı diğer altbantlara göre daha düzenli veya daha az kaotik özellik gösterdiğinden bu altbandın skalogramları alınmış ve ESA modeline uygulanmıştır. Verinin az kaotik olması daha çok öngörülebilirliği anlamına gelir. Kaotiklik derecesi yükseldikçe verinin öngörülebilirlik seviyesi düşmektedir.

Şekil 4.3'te iEEG işaretinin preiktal safhasına ait 224 örneklik bir bölüt ile buna ait faz uzay grafiği gösterilmiştir. Preiktal iEEG bölütünün yatay ekseni örnek bazında zamanı dikey eksen ise µV düzeyinde genliği göstermektedir. Faz uzayının ise her iki ekseni de µV düzeyinde genliği göstermektedir.



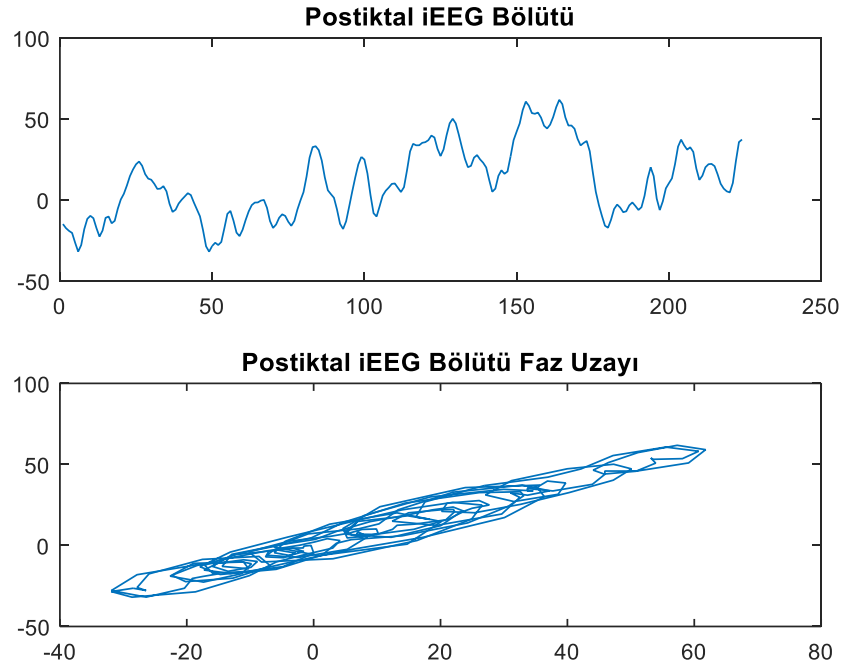
Şekil 4.3 Preiktal safhasını içeren iEEG bölütü ve faz uzay grafiği

Şekil 4.4'te iEEG işaretinin iktal safhasına ait 224 örneklik bölüt ile buna ait faz uzay grafiği gösterilmiştir. İktal iEEG bölütünün yatay eksenleri örnek bazında zamanı dikey ekseni ise µV düzeyinde genliği göstermektedir. Faz uzayının ise her iki ekseni de µV düzeyinde genliği göstermektedir.



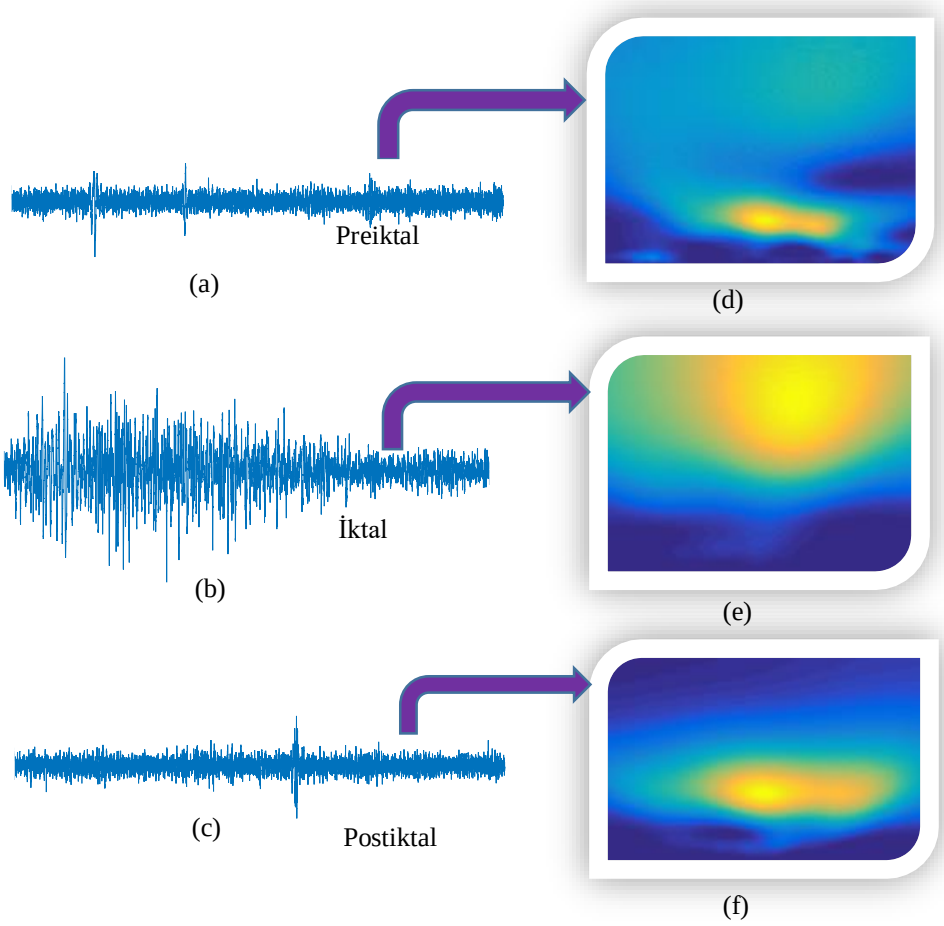
Şekil 4.4 İktal safhasını içeren iEEG bölütü ve faz uzay grafiği

Şekil 4.5'te iEEG işaretinin postiktal safhasına ait 224 örneklik bölüt ile buna ait faz uzay grafiği gösterilmiştir.



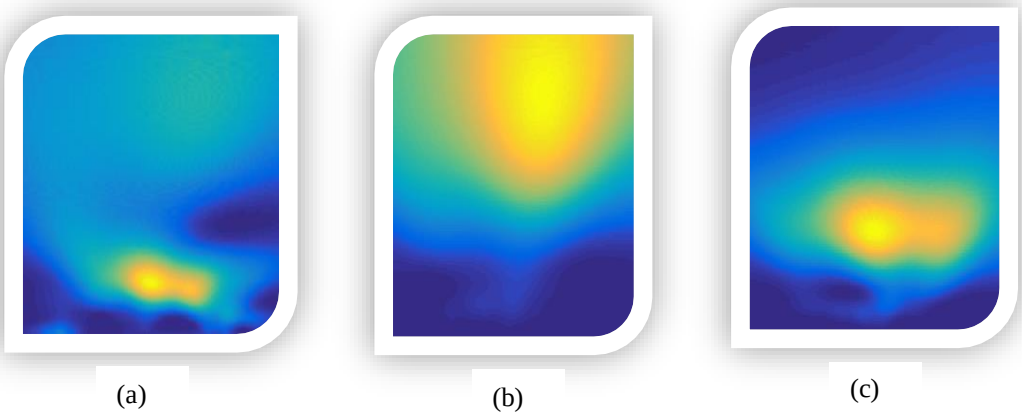
Şekil 4.5 Postiktal safhasını içeren iEEG bölütü ve faz uzay grafiği

Şekil 4.6'nın sol tarafındaki zaman grafikleri preiktal, iktal ve postiktal safhalara ait bir kanala ait tüm işareti kapsarken sağ tarafında yer alan skalogram grafikleri sadece 224 örneğe ait bir bölütü içermektedir.



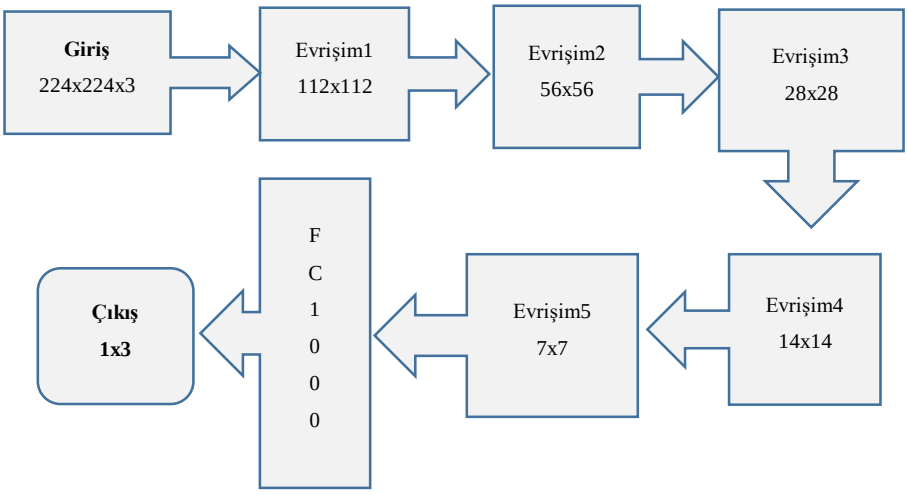
Şekil 4.6 Epileptik bir hastanın bir kanalına ait iEEG işaretinin a) preiktal, b) iktal ve c) postiktal zaman grafikleri ile 224x224 boyutundaki d) preiktal, e)iktal ve f) postiktal skalogram grafikleri

Epileptik bir hastanın (Hasta1) iEEG verisinin bir kanalının 224x224 boyutundaki delta alt bandının a) preiktal, b) iktal ve c) postiktal skalogram grafikleri Şekil 4.7'de gösterilmiştir.



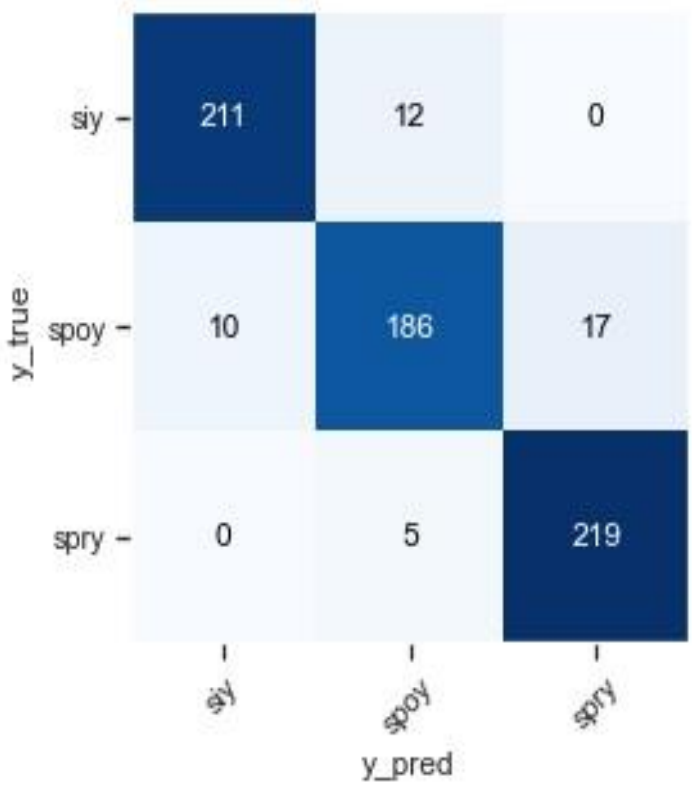
Şekil 4.7 Epileptik hastanın bir kanalına ait iEEG sinyalinin 224x224 boyutundaki delta alt bandının a) preiktal, b) iktal ve c) postiktal skalogram grafikleri

Çalışmada kullanılan Resnet50 ESA modeli Şekil 4.8'de gösterilmiştir. ESA'nın giriş verileri hastalara ait preiktal, iktal ve postiktalin delta alt bandının 224x224 boyutundaki toplam 3300 adet skalogramlarından oluşturulmuştur. Çalışmadaki ESA modelinde, Adam optimizer kullanılmış olup, loss için categorical_crossentropy tercih edilmiş ve learning_rate, 0,001 olarak alınmıştır. Giriş verileri, 5. dereceden konvüle edilerek ağ eğitilmiş ve yapılan testte % 93,33 doğruluk oranına ulaşılmıştır.



Şekil 4.8 Resnet50 ESA modeli

Şekil 4.9'da ESA modelinden elde edilen karışıklık matrisi gösterilmiştir. Preiktal: spry, iktal: siy ve postiktal: spoy olarak işaretlenmiştir. En iyi tahmin preiktal, en kötü tahmin ise postiktal safhasına aittir.

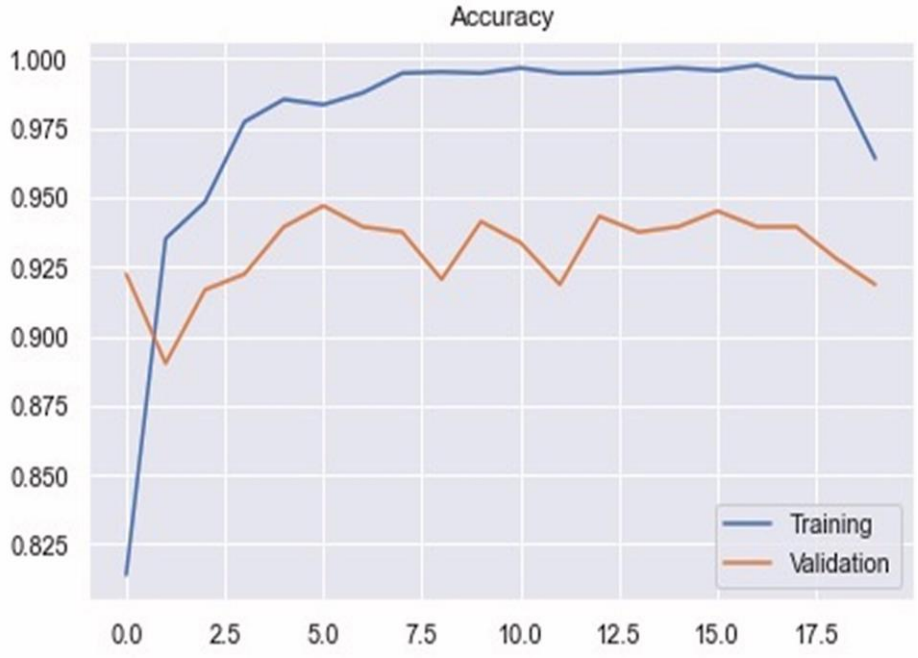


Şekil 4.9 ESA modelinden elde edilen karışıklık matrisi

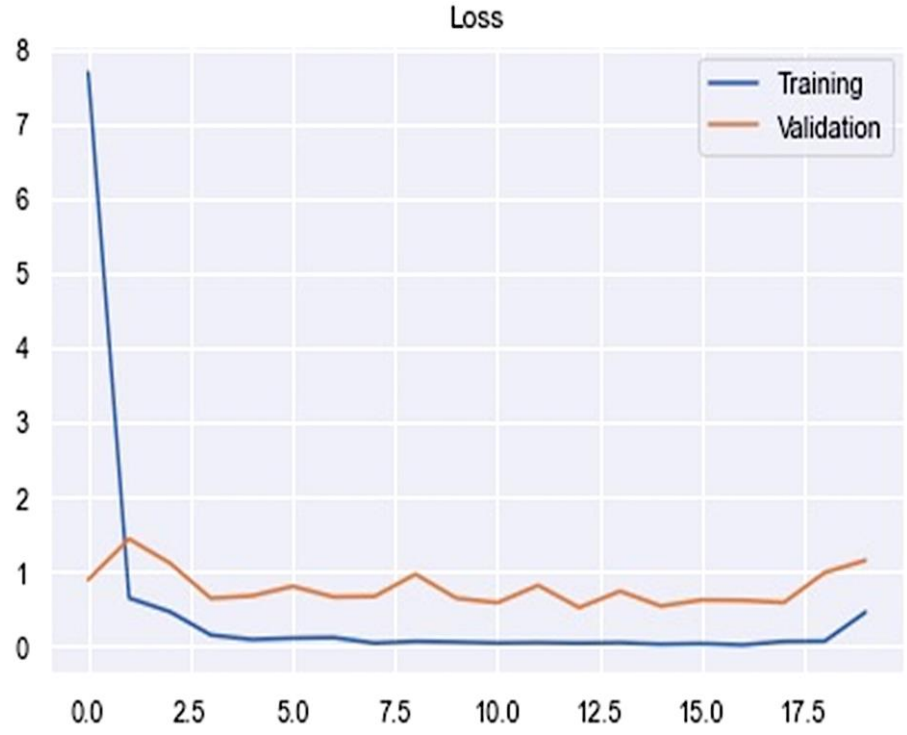
Şekil 4.9'daki üç boyutlu karışıklık matrisinden çıkarılabilecek çıkarımlar aşağıda sıralanmıştır.

- Model, 660 skalogram görüntüsünün yalnızca 616'ını doğru tahmin etmiştir (sınıflandırmıştır). İktal içeren doğru tahmin edilmiş 211 skalogram, postiktal içeren doğru tahmin edilmiş 186 skalogram ve preiktal içeren doğru tahmin edilmiş 219 skalogram görüntüsü vardır.
- Tüm yanlış sınıflandırılmış skalogramlardan, iktal olarak tahmin edilen ancak aslında postiktal içeren 10 skalogram, postiktal olarak tahmin edilen ancak aslında iktal içeren 12 skalogram, preiktal olarak tahmin edilen ancak aslında postiktal içeren 17 skalogram, postiktal olarak tahmin edilen beş skalogram aslında preiktal içeriyor.
- Gerçekte iktal olup preiktal tahmin edilen ve gerçekte preiktal olup iktal tahmin edilen skalogram yoktur.

Şekil 4.10'da ESA modelinin doğruluk (accuracy) ve kayıp (loss) grafikleri gösterilmiştir.



(a)

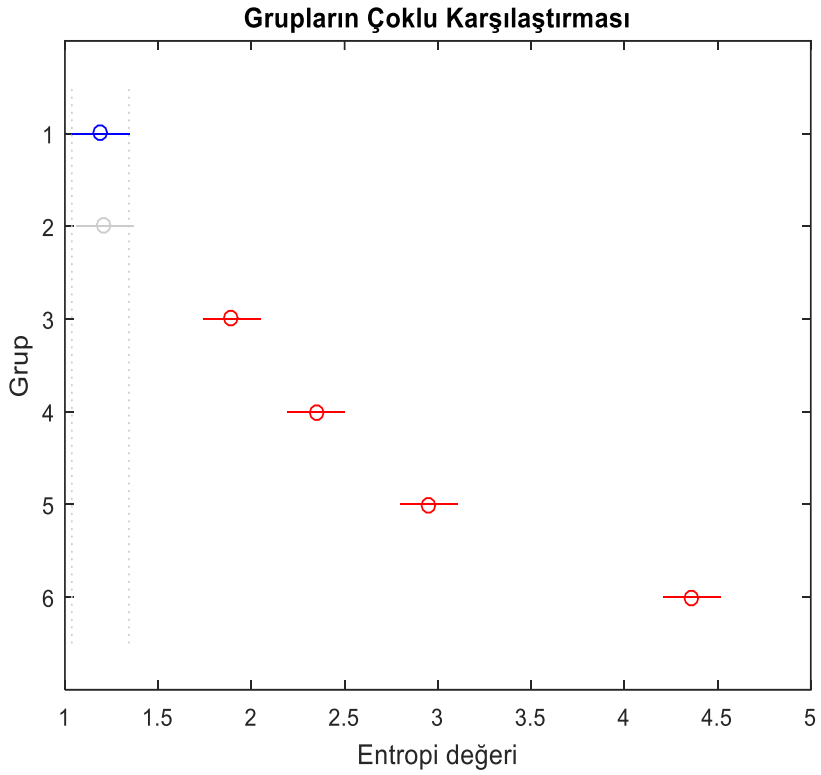


(b)

Şekil 4.10 ESA modelinin a) doğruluk ve b) kayıp grafikleri

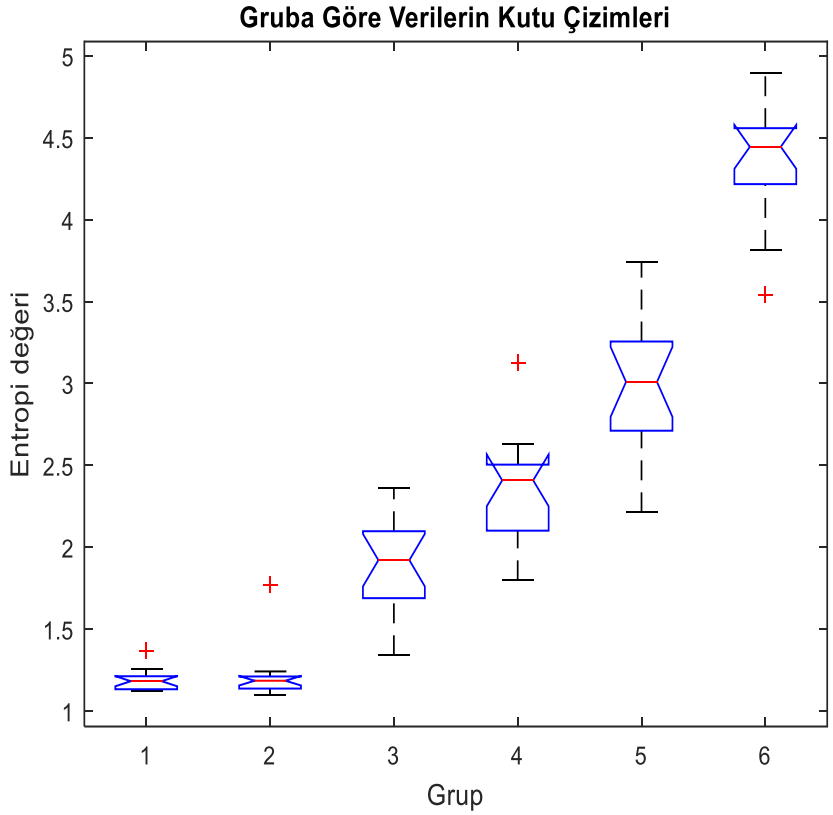
İstatiksel Test: Tablo 4.1'deki 16 hastanın segment entropi ve alt bant entropi değerleri istatistiksel olarak test edilip sonuçlar Şekil 4.11 ve 4.12'de gösterilmiştir. Shannon entropi değerlerinin karşılaştırılması için Tablo 4.1'deki tek yönlü varyans analizi (ANOVA) testi tercih edilmiş olup p değerleri<0,0001 olarak alınmıştır.

Şekil 4.11'deki dikey eksendeki altı grup, 16 epileptik hastanın; 1: segment entropisi, 2: delta entropisi, 3: teta entropisi, 4: alfa entropisi, 5: beta entropisi ve 6: gama entropisinin ortalama değerini göstermektedir. Tablo 4.1'de delta entropi değeri ile segment entropi değerinin birbirine yakın olduğu ancak diğer grupların farklı olduğu açıkça görülmektedir.



Şekil 4.11 Grupların çoklu karşılaştırması

Şekil 4.12'de yer alan yatay eksendeki altı grup, 16 epileptik hastaya ait; 1: segment entropisi, 2: delta altbant entropisi, 3: teta entropisi, 4: alfa entropisi, 5: beta entropisi ve 6: gama entropisinin medyanlarını göstermektedir. Tablo 4.1'de delta entropi değerinin segment entropi değerine çok yakın olduğu açıkça görülmektedir.



Şekil 4.12 Gruba göre verilerin kutu çizimleri

Tablo 4.1 incelendiğinde delta entropi değerlerinin segment entropi değerlerine yakın olduğu, diğer alt bantların entropi değerlerinin segment entropi değerlerinden farklı olduğu görülmektedir. Delta entropi değerleri segment entropi değerlerine yakın olduğu için bu çalışmada olduğu gibi epileptik iEEG sinyallerinin sadece delta alt bantlarının kullanılması uygun görülmüştür.

Bu çalışmada ESA kullanılarak epileptik deşarjın preiktal, iktal ve postiktal durumları sınıflandırılmış, iEEG verilerinin daha düşük frekans bandına sahip delta bantlarının skalogram görüntülerine uygulanmış ve preiktalin daha yüksek doğrulukla tespit edildiği görülmüştür (Şekil 4.9). Ayrıca kaosu (belirsizliği) nicel olarak belirleyen entropi parametresi kullanılmış ve delta altbant entropi değerlerinin diğer altbant entropi değerlerinden daha düşük olduğu görülmüştür (Tablo 4.1).

Epileptik EEG sinyallerinin ESA yöntemi ile sınıflandırma başarımı Tablo 4.2'de verilmiştir. Epileptik EEG verisinin ESA ile sınıflamalarında genellikle, normal, preiktal, iktal ve interiktal safhaların sınıflaması yapılmıştır. Bu çalışmada, preiktal,

iktal ve postiktal safhalarının sınıflaması yapılmış ve sadece düşük frekanslı delta altbadının skalogramlarıyla sınıflama yoluna gidilmiştir.

Tablo 4.2'de epileptik EEG verilerine ESA yöntemi uygulayan güncel çalışmalar yer almıştır.

Tablo 4.2 Epileptik EEG sinyallerine ESA yöntemi uygulanan güncel çalışmalar

NO	Yazar	Sınıflar	Başarım	Yıl
1	Acharya ve ark. [3]	Normal, preiktal ve iktal	88.67	2017
2	Zhou ve ark. [7]	Preiktal, iktal, ve interiktal	97.50	2018
3	Hu ve ark. [19]	Preiktal, iktal, ve interiktal	86.25	2019
4	Gao ve ark. [10]	Normal, interiktal ve iktal	99.26	2019
5	Türk ve Özerdem [12]	Normal, interiktal ve iktal	99,50	2019
6	Emami ve ark. [13]	Nöbetli ve nöbetsiz	100	2019
7	Abiyev ve ark. [14]	Normal, preiktal ve iktal	98.67	2020
8	Raghu ve ark. [15]	Sekiz epileptik sınıfı	88.30	2020
9	Prathaban ve Balasubramanian [17]	Preiktal, iktal, ve interiktal	98	2021
10	Yıldız ve ark. [18]	Normal, interiktal ve iktal	100	2021

Normal EEG sinyalleri yanında preiktal, iktal ve interiktallere Evrişimsel sinir ağları modelinin uygulanıp elde edilen başarım değerleri Tablo 4.2'de gösterilmiştir. Bu çalışmalarda başarım performansı % 88,30 ile % 100 arasında değişmektedir. Bu, farklı veri kullanılmasından kaynaklıdır. Bizim çalışmada ise iEEG verilerinin altbantları kullanılmış ve delta altbantlarının skalogram görüntüleri ESA yöntemiyle sınıflandırılıp % 93,33 başarım değeri elde edilmiştir.

İleride yapılacak çalışmalarda düşük frekanslı (delta) iEEG verileri kullanılarak preiktal verilere odaklanılması ve uzun süreli iEEG verileri kullanılarak preiktal bölütündeki değişiklikler üzerinde çalışılarak nöbetin başlamadan önce yüksek doğrulukla tahmin edilmesi hedeflenmektedir.

5. SONUÇLAR VE ÖNERİLER

Bu çalışmada, düşük frekanslı iEEG verilerinden oluşan delta altbant skalogram görüntüleriyle preiktal, iktal ve postiktal safhaları sınıflandırılmıştır. Yapılan sınıflamada % 93,33 doğruluk oranına ulaşılmıştır (Şekil 4.10).

Entropi, kaotik bir nicelik olup, sistemin düzensizliğinin ölçüsü olarak ifade edilir. Değerinin düşük olması sistemin daha az karmaşık ve kaotik, yüksek olması ise sistemin daha çok karmaşık ve kaotik olduğu anlamını taşır. Bu özellik temel alınarak, epileptik iEEG verileri altbantlarına ayrıştırılmış ve her bir altbandın entropi değeri bulunmuştur (Tablo 4.1). Tablo 4.1 incelendiğinde, hastalara ait delta altbant entropi değerlerinin diğer altbant entropi değerlerine göre daha düşük olduğu görülmüştür. Bu da delta altbantlarının daha düzenli bir yapı sergilediği anlamına gelir. Sistemin (verinin) düzenli olması onun daha öngörülebilir olduğu anlamını taşır. Bu özellik temel alınarak bölütün skalogramı yerine sadece delta altbandının skalogram görüntüsü MATLAB ortamında oluşturulmuş ve ESA modeline giriş verisi olarak verilmiştir.

Çalışmamızda sadece düşük frekanslı altbantlar olan delta altbant skalogram görüntülerine ESA uygulanarak preiktal, iktal ve postiktal sınıflandırması yapılmış ve başarılı bir sonuç elde edilmiştir. Ayrıca bu çalışmadan elde edilen sonuçlardan biri de delta altbant entropi değerlerinin diğer altbant entropi değerlerinden önemli ölçüde düşük olmasıdır. Bu da delta altbant düzensizliğinin diğerlerinden daha az olduğunu gösterir. Başka bir deyişle, iEEG sinyalinin delta altbandı daha düzenli ve kararlıdır.

Preiktal, iktal ve postiktal evrelerinin belirlenmesi can güvenliği açısından önemlidir ve epileptik nöbetleri diğer rahatsızlık ve hastalıklardan ayırt eder.

Gelecekte yapılabilecek çalışmalar aşağıda sıralanmıştır.

- Uzun süreli epileptik iEEG kayıtları kullanılarak preiktal fazdaki değişiklikler incelenebilir.
- Preiktal fazdan iktal faza geçişte güç yoğunluğu eğrilerindeki değişiklikler incelenebilir.
- Bu çalışmanın pratik uygulaması düşük maliyetli FPGA kartlara (Pynq-z2, zed board vb.) uygulanarak daha başarılı nöbet sınıflaması ve belirlenmesi yapılabilir.

- Kaosu niceliksel belirleyen parametrelerden biri olan Lyapunov üsteli kullanılarak preiktal safhasındaki değişimler izlenebilir.
- Kısa süreli Lyapunov üsteli, kısa süreli faz ve genlik entropisi kullanılarak preiktal safhasındaki değişim izlenebilir.

KAYNAKLAR

[1] M. Hajinorooji, Z.Mao, C.T. Jung, Y. Huang, EEG-based prediction of driver's cognitive performance by deep convolutional neural networks. Signal Processing: Image communication, 47, 2016, 549-555.

[2] R.T. Schirrmeister, J.T. Sprinbergerg, L.D.J. Fiederer, M. Glasstetter, K. Egensperger, M. Tangermann, F. Hutter, W. Burgard, T. Ball, Deep learning with CNN for EEG decoding and visuzlization. Human Brain Mapping, 38, 2017, 5391-5420.

[3] U.R. Acharya, S.L. Oh, Y. Hagiwara, J.H. Tan, H. Adeli, Deep CNN fort he automated detection and diagnosis of seizure using EEG signals. Computers in Biology and Medicine, 2017, doi: 10.1016/j.compbiomed.2017.09.017.

[4] Y. Li, H. Huang, N. Zhong, Human emotion recognition with electroencephalographic multidimensional features by hybrid deep neural networks. Applied sci., 7, 2017, 1060.

[5] V.J. Lawhern, A.J. Solon, N.R. Waytowich, S.M. Gordon, C.P. Hung, B.J. Lance, EEGnet: a compact CNN for EEG-based brain-computer interfaces. J. Neural Eng., 15, 2018, 056013.

[6] C. T.M. Cloostermans, R.C.V. Carvalho, M.J.A.M. Putten, Epileptiform discharges from scalp EEG recordings. Clinical Neurophysiology, 129, 2018, 2191-2196.

[7] M. Zhou, C. Tian, R. Cao, B. Wang, Y. Niu, T. Hu, H. Guo, J. Xiang, Epileptic seizure detection based on EEG signals and CNN. Frontiers in Neuroinformatics, 12, 2018, 95.

[8] R. Hussein, H. Polangi, R.K. Ward, Z.J. Wang, Optimized deep neural network architecture for robust detection of epileptic seizure using EEG signals. Clinical Neurophysiology, 130, 2019, 25-37.

[9] W. Hu, J. Cao, X. Lai, J. Liu, Mean amplitude spectrum based epileptic state classification for seizure prediction using CNN. J. of ambient intel. and human computing, doi: 10.1017/512652-019-01220-6.

[10] X. Gao, X. Yan, P. Gao, X. Gao, S. Zhang, Automatic detection of epileptic seizure based on approximate entropy, recurrence quantification analysis and CNN. Artificial Intelligence in Medicine, doi: 10.1016/j.artmed.2019.101711.

[11] Z. Wei, J. Zou, J. Zhang, J. Xu, Automatic epileptic EEG detection using CNN with improvements in time-domain. Biomed. Signal processing and control, 53, 2019, 101551.

[12] Ö. Türk, M.S. Özerdem, Epilepsy detection by using scalogram based CNN from EEG signals. Brain sci., 9, 2019, 115.

[13] A. Emami, N. Kunii, T. Matsuo, T. Shinozaki, K. Kawai, Seizure detection by CNN-based analysis scalp EEG plot images. NeuroImage: Clinical, 22, 2019, 101684.

[14] R. Abiyev, M. Aslan, J.B. Idoko, B. Sekeroglu, A. Ilhan, Identification of epileptic EEG signals using CNN. Applied Sciences, 10, 2020, 4089.

[15] S. Raghu, N. Siriraam, Y. Temel, S.V. Rao, P.L. Kubben, EEG-based multi-class seizure type classification using CNN and transfer learning. Neural Networks, 124, 2020, 202-212.

[16] Y. Gao, B. Gao, Q. Chen, J. Liu, Y. Zhang, Deep CNN-based epileptic EEG signal calssification. Frontiers in Neurology, doi: 10.3389/fneur.2020.00375.

[17] B.P. Prathaban, R. Balasubramanian, Dynamic learning framework for epileptic seizure prediction using sparsity based EEG reconstruction with optimized CNN. Expert Sys. with Appli., 170, 2021, 114533.

[18] A. Yildiz, H. Zan, S. Said, Classification and analysis of epileptic EEG recordings using CNN and class activation mapping. Biomedical signal processing and control, 68, 2021, 102720.

[19] D. Lai, X. Zhang, K. Ma, Z. Chen, W. Chen, H. Zhang, H. Yuan, and L. Ding, Automated detection of high frequency oscillation, in intracranial EEG using the combination of short-time energy and convolutional neural networks. Special section on neural engineering informatics, IEEE Access, 2019, doi: 10.1109/ACCESS.2019.2923281.

[20] C.L. Liu, B. Xiao, W. H. Hsaio, and V.S. Tseng, Epileptic seizure prediction with multi-view convolutional neural networks, IEEE Access, 2019, doi: 10.1109/ACCESS.2019.2955285.

[21] M.G. Tsipouras, Spectral information of EEG signals with respect to epilepsy classification, EURASIP Journal on advances in signal processing, 2019, doi: 10.1186/s13634-019-0606-8.

[22] J. Lian, Y. Zhang, R. Luo, G. Han, W. Jia, and C. Li, Pair-wise matching of EEG signlas for epileptic identification via convolutional neural network, IEEE Access, 2020, doi: 10.1109/ACCESS.2020.2976751.

[23] A. Bahr, M. Schneider, M.A. Francis, H.M. Lehmann, I. Barg, A.S. Buschhoff, P. Wulff, T. Strunskus, and F. Faupel, Epileptic seizure detection on an ultra-low - power embedded RISC-V processor using a convolutional neural network, biosensors, 11, 2021, 203, https:/doi.org/10.3390/bios11070203.

[24] J. Graley, E. Johnson, C. Jouny, A. Venkataraman, Automated inter-patient seizure detection using multichannel convolutional and recurrent neural networks, Biomedical signal processing and control, 64, 2021,102360.

[25] A. Abdelhameed and M. Bayoumi, A deep learning approach for automatic seizure detection in children with epilepsy, Frontiers in computational neurascience, 2021, doi: 10.3389/fncom.2021.650050.

[26] M. Ma, Y. Cheng, X. Wei, and Y. Zhou, Research on epileptic EEG recognition based on improved residual networks of 1-D CNN and indRNN, BMC Medical informatics and decisionm making, 21(2): 100, 2021, https://doi.org/10.1186/s12911-021-01438-5.

[27] S. Naseem, K. Javed, M. J. Khan, S. Rubab, M. A. Khan, Y. Nam, Integrated CWT-CNN for epilepsy detection using multiclass EEG dataset, Computers, materials and continua, 2021, doi: 10.32604/cmc.2021.018239.

[28] D. Johnston, and S.M. Wu, Foundations of Cellular Neurophysilogy, MIT Press, Cambridge, Massachuseets, 1995.

[29] D. Kindersley, The Concise Encyclopedia of the Human Body, New York, 1995, 59.

[30] A.C. Guyton, Textbook of Medical Physiology, Seventh Edition, Dreibelbis, D., W.B. Saunders Company, Philedelphia, 1986.

[31] B. Hille, Ionic Channels of Excitable Membranes, Sunderlend, MA: Sinauer Associates, 1992.

[32] A.L. Hodgkin, and A.F. Huxley, A quantitative description of membrane current and its application to conduction and excitation in nevre, J. Physiol., 117(1952) 500–544.

[33] T.F. Weiss, Cellular Biophysics, MIT Press, Cambridge, London, England, 1996.

[34] G.M. Shepherd, The Synaptic Organization of the Brain, First Ed. Oxford University Press, London, 1974, 288–328.

[35] D. Purves, G.J. Augustine, D. Fitzpatrick, L.C. Katz, A.S. LaMantia, J.O. McNamara, S.M. Williams, Neuroscience, 2nd Ed. Sinauer Associates Inc. Publishers, Massachusetts, USA, 2001.

[36] ER. Kandel, JH. Schwartz, TM. Jessell, Principles of Neural Science, In: Martin JH(eds), The Electroencephalogram and the Mechanism of Epilepsy. New York: Harvard University Pres; 1991 777-785.

[37] H. Berger, Über das Elektroenkephalogram des Menschen. Arch. f. Psychiat, 87(1929) 527-70.

[38] R. Polikar (1999), The engineer's ultimate guide to wavelet analysis the wavelet tutorial, http://engineering.rowan.edu/~polikar/wavelets/wtpart3.html.

[39] F. Pehlivan, Biyofizik, Hacettepe-Taş, 1997 412.

[40] E. Yazgan, Koryürek, M. Tıp elektroniği, İ.T.Ü. ofset baskı atölyesi, 1996, 220.

[41] The Sleep-Wake-Epilepsy-Center (SWEC) of the University Department of Neurology at the Inselspital Bern. http://ieeg-swez.ethz.ch/

[42] M. Bayram, H. Acar, EEG Sınıflandırma Amaçlı Bir Kompozit Sistem, Dicle Üniversitesi Mühendislik Fakültesi Dergisi, Cilt 4, Sayı 1, Diyarbakır, 2013.

[43] A. Yadollahpour, M. Jalilifar, Seizure prediction methods: Areview of the current predicting techniques, Biomedical and pharmacology journal, 7(1), 2014, 153-162.

[44] E. Niedermeyer, Epilepsy Guide, (Epilepsi Rehberi), Çevirenler: T. Zileli, A. Ciger, MF. Öztekin, Hacettepe Üniversitesi Yayınları (1987) 3-5.

[45] T.G. Bolwig, Classification of Psychiatric Disturbances in Epilepsy. Aspects of Epilepsy and Psychiatry, (Ed. Trimble, M.R., Bowlig, T.G.) de, John Wiley & Sons Ltd. New York, 1986 1.

[46] Epilepsi (sara) Hastalığı(2006), Nationaal Epilepsie Fonds, http://www.epilepsie.nl/attachments/epilepsieinhetkortturks.pdf

[47] J.O. McNamara, Emerging insights into genesis of epilepsy, Nature, 399(1999) 15–22.

[48] O. Creutzfeldt, S. Watanabe, H.D. Lux, Relations between EEG-phenomena and potentials of single cortical cells. I. Evoked responses after thalamic and epicortical stimulation. II. Spontaneous and convulsoid activity, Electroencephcim Neurophysiol., 20, 1966, 1-37.

[49] B. Göksan, Epilepside tanı yöntemleri İ.Ü. Cerrahpaşla Tıp Fakültesi Sürekli Tıp Eğitimi Etkinlikleri (Epilepsilerde Tanı ve Tedavi Sempozyumu) İstanbul, 1998 39- 50.

[50] R. Kara, Nonlineer Dinamik Sistemlerde Kaos, Dallanma ve Fraktallar, YLT, İTÜ, 2006.

[51] G.L. Baker, J.P. Gollup, Chaotic Dynamics(an introduction), Cambridge University Press, 1990.

[52] S.N. Rasband, Chaotic Dynamics of Nonlinear Systems, John Wiley& Sons, 1990.

[53] M. Hüner, Karmaşık Sistemlerde Faz değişimi, YLT, İTÜ, 1993.

[54] C. Bernice, Edge of Chaos, John Wiley& Sons, New York, 1997.

[55] N.B. Tufillarol, An Experimental Approach to Nonlinear Dynamics and Chaos, Addison Wesley, Reilly Boston, 1992.

[56] E.R. Scheiner, Invitation to Dynamical Systems, The John Hopkins University Press, 1996.

[57] J. Gleick, Kaos, TÜBİTAK yayınları, 2003, 412.

[58] G.P. Williams, Chaos Theory Tamed, Taylor & Francis, London, 1997.

[59] S. Ablameyko, L. Goras, M. Gori, V. Piuri, Neural Networks for Insrumentation, Measurement and Related Industrial Applications, IOS Press, Crema, 2003.

[60] S.H. Strogatz, Nonlinear Dynamics and Chaos, Perseus Books Publishing, New York, 1994 498.

[61] N.R.C. Hilbor, Chaos and Nonlinear Dynamics, Oxford University Press, 2000 650.

[62] S. Emiroğlu, Güç Elektroniği Devrelerinde doğrusal Olmayan Olayların Analizi ve Kontrolü, YLT, SÜ, 2011.

[63] U. Fırat, Kaotik Zaman Serilerinin Yapay Sinir Ağlarıyla Kestirimi: Deprem Verisi Durumu, YLT, YTÜ, 2006.

[64] G.Ç. Yalçın, Kaotik Fiziksel Sistemler ve Acayip Çekiciler, YLT, İÜ, 2000.

[65] A.B. Çambel, Applied Chaos Theory: A Paradigm for Complexity, Academic Press, Boston, 1993.

[66] B. Ünsal, Fiziksel Sistemlerin Kaotik Dinamiği, YLT, Ankara Üni., 1996.

[67] G.Ç. Yalçın, Kaotik Fiziksel Sistemler ve Acayip Çekiciler, YLT, İÜ, 2000.

[68] R.C. Hilborn, Chaos and Nonlinear Dynamics, Oxford University Press, New York, 1994.

[69] F. Takens, Detecting Strange Attractors in Turbulunce, Lecture Notes in Mathematics, 1981 366-381.

[70] D. Yılmaz, ve M. Yıldız Kalp Hızı Değişkenliği Üzerindeki Cep Telefonu Etkisinin Lyapunov Üsteli ile Hesaplanması ile Değerlendirilmesi, SİU, Eskişehir, 2007.

[71] A.M. Fraser, H.L. Swinney, Independent coordinates for strange attractor from mutual information, Physics Reviews A, 33(1986) 1134.

[72] H.D.I. Abarbanel, R. Brown, J.J. Sidorowich, L.S. Tsimring, The Analysis of Observed Chaotic Data in Physical Systems, Reviews of Modern Physics, 65:4(1993) 1331-1392.

[73] L. Cao, Practical method for determining the mininmum embedding dimension of a scalar time series, Physica D, 110:1(1997) 43-50.

[74] C.E. Shannon, A mathematical theory of communication, Bell System Techcical Journal. 1948, 27, 623–656.

[75] L. Guo, D. Rivero, A. Pazos, Epileptic seizure detection, using multiwavelet transform based approximate entropy and artificial neural Networks, J. Of Neoroscience Methods. 2010, 193, 156-163.

[76] U.R. Acharya, H. Fujita, V.K. Sudarshan, S. Bhat, J.E.W. Koh, Application of entropies for automated diagnosis of epilepsy using EEG signals: A review, Kowledge-Based Systems, 2015, 88, 85-96.

[77] Z. Mu, J. Hu, J. Min, Driver fatigue detection system using electroenchephaology raphy signals based on combined entropy features, Applied sciences. 2017, 7, 150, doi: 10.3390/app7020150.

[78] J. Yordanova, V. Kolev, O.A. Rosso, Schürmann, M.; Sakowitz,O.W.; Özgören, M.; Başar, E.Wavelet entropy analysis of event-related potentials indicates modality-independent theta dominance, J. Neuroscience Met. 2002, 117, 99-109.

[79] M. Misiti, Y. Misiti, G. Oppenheim, J.M. Poggi, 2013. Wavelets and their Applications, John Wiley & Sons: Great Britain, 2013.

[80] Y. Falamarzi, N. Palizdan, Y. F. Huang, T. S. Lee, Estimating evapotranspiration from temperature and wind speed data using artificial and wavelet neural networks (WNNs). Agricultural Water Management, 140, 2014, 26-36.

[81] A. Kareem, T. Kijewski, Time-frequency analysis of wind effects on structures. J. Wind Eng. Ind. Aerod., 90, 2002, 1435–1452.

[82] D. Yi, Z. Lei, S. Liao, S. Z. Li, Deep metric learning for person re-identification, In proceedings of 2014 22nd International Conference on Pattern Recognition, Stockholm, Sweden, 24-28 August 2014, IEEE: Piscataway, NJ, USA, pp. 34–39.

[83] M. Unser, A. Aldroubi, A review of wavelets in biomedical applications. Proceedings of the IEEE, 84(4), 1996, 626-638.

[84] M. Tolić, F. Jović, Classification of wavelet transformed EEG signals with Neural network for imagined mental and motor tasks. Kinesiology: International journal of fundamental and applied kinesiology, 45(1), 2013, 130-138.

[85] O. Faust, U. R. Acharya, H. Adeli, A. Adeli, Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis. Seizure, 26, 2015, 56-64.

[86] X. Jia, Image recognition method based on deep learning. In Control And Decision Conference (CCDC), 2017 29th Chinese (pp. 4730-4735). IEEE.

[87] P. Bashivan, I. Rish, M. Yeasin, N. Codella, Learning representations from EEG with deep recurrent-convolutional neural Networks. *(arXiv:1511.06448)*, 2015.

[88] T. Uktveris, V. Jusas, Application of Convolutional Neural Networks to Four-Class Motor Imagery Classification Problem. Inf. Technol., *46*, 2017,260–273.

[89] M. Lin, Q. Chen, S. Yan, 2013. Network in network. Erişim: [https://arxiv.org/abs/1312.4400]. Erişim Tarihi: 19.12.2018.

[90] L. Wan, M. Zeiler, S. Zhang, Y. Le Cun, R. Fergus, 2013, February. Regularization of neural networks using dropconnect. In International Conference on Machine Learning (pp. 1058-1066).

[91] Ö. Türk, EEG İşaretlerinden Epilepsi Türlerinin Sınıflandırılmasında Skalogram Tabanlı Derin Öğrenme Yaklaşımı, Doktora Tezi, Dicle Üniversitesi FBE, Diyarbakır, Temmuz, 2019.

[92] A. Subaşı, Automatic recognition of alertness level from EEG by using neural network and wavelet coefficients, Expert Systems with Applications, 1-11, 2004.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyad, Ad	BAYRAM, Muhittin
Web sayfası	

Eğitim Bilgileri

Derece	Kurum	Mezuniyet Yılı
Yüksek Lisans	Dicle Üniversitesi, Elektrik Elektronik Mühendisliği ABD	2003
Lisans	Gaziantep Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü	1995
Lise	Diyarbakır İHL	1988

Yabancı Dil

İngilizce

Yayınlar

1. M. Bayram, H. Acar, EEG Sınıflandırma Amaçlı Bir Kompozit Sistem, Dicle Üniversitesi Mühendislik Fakültesi Dergisi, Cilt 4, Sayı 1, Diyarbakır, Nisan 2013.

2. M. Bayram, Assessment of EEG signals using chaos analysis methods, International journal of research studies in science, engineering and technology (IJRSSET), ISSN 2349-4751, Vol.2, Issue 7, PP:1-12, July 2015.

3. M. Bayram, D. Arslan, Is there a relationship between consciousness and epilepsy, BRAIN. Broad research in artificial intelligence and neuroscience, ISSN 2067-3957, Vol.7, Issue 4, PP:63-68, November 2016.

4. M. Bayram, M.A. Arserim, "Analysis of Epileptic iEEG Data by Applying Convolutional Neural Networks to Low-Frequency Scalograms", IEEE Access, 2021, DOI: 10.1109/ACCESS.2021.3132128.

Özel İlgiler

Kuantum-Kaotik ve Nörokaotik Sistemler

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ BENZERLİK BİLDİRİMİ FORMU

Öğrencinin Adı, Soyadı	Muhittin BAYRAM		
Öğrenci No	18805503		
Ana Bilim Dalı	Elektrik Elektronik Mühendisliği		
Program Türü	Proje ☐	Yüksek Lisans ☐	Doktora ☒
Tez Danışmanı (Ünvanı, Adı, Soyadı)	Dr. Öğr. Üyesi Muhammet Ali ARSERİM		
Tez Başlığı	Çok Kanallı iEEG Sinyallerinin Evrişimsel Sinir Ağlarıyla Analizi		
RAPOR BİLGİLERİ			
Raporlama Aşaması	Tez Savunma Sınavı Sonrası		
Sayfa Sayısı	72		
Raporlama Tarihi	20.12.2021		
Benzerlik Oranı (%)	14		

Yukarıda bilgileri verilen tez çalışmamın toplam 72 sayfalık kısmına ilişkin, 20 / 12 / 2021 tarihinde tez danışmanım tarafından Turnitin isimli intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı % 14 olarak tespit edilmiştir.

Uygulanan filtrelemeler:

☒Başlangıç Bölümleri (Kabul ve Onay sayfası) hariç

☒Kaynaklar hariç

☒Alıntılar hariç

☐Diğer (Açıklayınız)

Tezimin benzerlik oranı, Dicle Üniversitesi Fen Bilimleri Enstitüsü İntihal Raporu Uygulama Esaslarında belirtilen üst sınır benzerlik oranını aşmamaktadır. Benzerlik oranım üst sınır benzerlik oranının altında olsa dahi aksinin tespit edilmesi durumunda her türlü yasal sorumluğu kabul ettiğimi ve hukuki sonuçlarına razı olduğumu bildirir, gereğini arz ederim.

Öğrencinin Adı, Soyadı: Muhittin BAYRAM
Tarih: 20.12.2021
İmza:

Danışman Adı, Soyadı: Dr. Öğr. Üyesi Muhammet Ali ARSERİM Tarih: 20.12.2021	İmza:
Ana Bilim Dalı Başkanı Adı, Soyadı: Doç. Dr. Bilal GÜMÜŞ Tarih: 20.12.2021	İmza: