



**EEG SİNYALİ KULLANARAK EPİLEPTİK
NÖBETLERİN GERÇEK ZAMANLI TAHMİNİ**

Nasım MOSTAFA POUR

**Yüksek Lisans Tezi
Elektrik - Elektronik Mühendisliği Anabilim Dalı
Doç. Dr. İbrahim Yücel ÖZBEK**

2019

Her hakkı saklıdır

ATATÜRK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

EEG SİNYALİ KULLANARAK EPİLEPTİK NÖBETLERİN GERÇEK
ZAMANLI TAHMİNİ

Nasım MOSTAFA POUR

ELEKTRİK - ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ERZURUM

2019

Her hakkı saklıdır



T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



TEZ ONAY FORMU

**EEG SİNYALİ KULLANARAK EPİLEPTİK NÖBETLERİN GERÇEK
ZAMANLI TAHMİNİ**

Doç. Dr. İbrahim Yücel ÖZBEK danışmanlığında, Nasım MOSTAFA POUR tarafından hazırlanan bu çalışma 25/11/2019 tarihinde aşağıdaki jüri tarafından Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda Yüksek Lisans tezi olarak **oy çokluğu (2/1) ile** kabul edilmiştir.

Başkan : Prof. Dr. Birol SOYSAL

İmza :

Üye : Doç. Dr. Bülent ÇAVUŞOĞLU

İmza :

Üye : Doç. Dr. İbrahim Yücel ÖZBEK

İmza :

Yukarıdaki sonuç;

Enstitü Yönetim Kurulu'nun 26/12/2019 tarih ve 50/43 nolu kararı ile onaylanmıştır.

Prof. Dr. Mehmet KARAKAN
Enstitü Müdürü

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

ÖZET

Yüksek Lisans Tezi

EEG SİNYALİ KULLANARAK EPİLEPTİK NÖBETLERİN GERÇEK ZAMANLI TAHMİNİ

Nasım MOSTAFA POUR

Atatürk Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik- Elektronik Mühendisliği Anabilim Dalı
Haberleşme Bilim Dalı

Danışman: Doç. Dr. İbrahim Yücel ÖZBEK

Elektroensefalografi (EEG) sinyallerinin analizi ile epileptik nöbetlerin belirlenmesi, epilepsi hastalığı tanısı için standart bir yöntem haline gelmiştir. Epileptik nöbetlerin uzman nörologlar tarafından el ile belirlenmesi yoğun çalışma gerektiren, oldukça zaman alıcı bir işlem olduğu gibi kişilerden kaynaklanan çeşitli hataların oluşmasına sebep olmaktadır. Bu sebeple epileptik nöbetlerin doğru ve otomatik bir şekilde belirlenmesine ihtiyaç duyulmaktadır. Bu amaç doğrultusunda bu tez kapsamında, EEG sinyalinden frekans tabanlı öznitelikler çıkarılmış ve kolektif öğrenmeye dayalı sınıflandırıcılar kullanılarak yeni bir yöntem önerilmiştir. Önerilen yöntemin performansı çapraz doğrulama ve çapraz hasta deneyleri kullanılarak test edilmiştir. Elde edilen deneysel sonuçlara göre çapraz doğrulama deneyi için duyarlılık, özgüllük ve doğruluk oranları yaklaşık olarak sırayla %94, %94 ve %94 ve çapraz hasta için ise %76, %90 ve %90 olarak bulunmuştur.

2019, 41 Sayfa

Anahtar Kelimeler: Epileptik, Electroencephalogram EEG, Kolektif Öğrenme, RUSBoost, RobustBoost, LogitBoost.

ABSTRACT

Master Thesis

REAL-TIME ESTIMATION OF EPILEPTIC SEIZURES USING EEG SIGNAL

Nasim MOSTAFA POUR

Ataturk University
Graduate School of Natural and Applied Sciences
Department of Electrical And Electronics Engineering
Communication Department

Supervisor: Assoc. Prof. Dr. İbrahim Yücel ÖZBEK

The detection of epileptic seizures by electroencephalography (EEG) signals has become a standard method for the diagnosis of epilepsy. Manual identification of epileptic seizures by specialist neurologists is a very time consuming and labor intensive process, which also leads to various errors. Therefore, accurate and automatic detection of epileptic seizures is needed. For this purpose, frequency-based features were extracted from the EEG signal and a various classifiers based on ensemble learning was used to detect epileptic seizures automatically. The performance of the proposed method was tested using cross-validation and cross-patient experiments. According to the experimental results, sensitivity, specificity and accuracy rates were 94%, 94% and 94% for cross validation and 76%, 90% and 90% for cross-patients, respectively.

2019, 41 pages

Keywords: Epileptic, Electroencephalogram EEG, Ensemble Aggregation, RUSBoost, RobustBoost, LogitBoost.

TEŞEKKÜR

Bu tez çalışmasında ve çalışma konusunun seçiminde bana yol gösteren, danıştığım her durumda ilgi ve yardımlarını esirgemedен büyük özveride bulunan, tez danışmanım ve değerli hocam Sayın Doç. Dr. İbrahim Yücel ÖZBEK hocama teşekkür ederim.

Nasım MOSTAFA POUR

Aralık / 2019

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
SİMGELER ve KISATLAMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	viii
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	4
2.1. Nöbet Tespit Konusunda Yapılan Araştırmalar	4
2.2. Nöbet Tahmini konusunda Yapılan Araştırmalar	6
3. MATERYAL VE YÖNTEMLER	9
3.1. Elektroensefalografi	9
3.2. EEG Frekans Bantları	10
3.3. Veri Tabanı	15
3.4. Metodoloji	16
3.5. Verilerin Ön İşlemesi	16
3.6. Mel-Frekansı Kepstral Katsayılarını (MFCC)	17
3.7. Sınıflandırıcılar	19
3.7.1. RUS Boost yöntemi	20
3.7.2. Robust Boost yöntemi	21
3.7.3. Logit Boost yöntemi	22
3.8. Deneyler	22
3.8.1. Performans ölçütleri (doğruluk, duyarlılık ve özgünlük)	24
3.9. Testler ve Sonuçlar	26
3.9.1. Çapraz doğrulama deney sonuçları	26
3.9.2. Çapraz hasta deney sonuçları	28
3.9.3. Deney sonuçlarının literatür ile karşılaştırması	34
4. SONUÇ ve ÖNERİLER	36

KAYNAKLAR	37
ÖZGEÇMİŞ	42



SİMGELER ve KISATLAMALAR DİZİNİ

Simgeler

C_i	Mell Kepstral katsayıları
FN	Epilepsi olan bölge epilepsi değil diye tahmin edilmiş
FP	Epilepsi olmayan bölge epilepsi diye tahmin edilmiş
m	Mel frekansı
n	Örnek numarası
N	Örnek sayısı
s'_n	$s(n)$ nin pencerelenmiş hali
s_n	EEG sinyali
TN	Epilepsi olmayan bölge ve epilepsi değil diye tahmin edilmiş
TP	Epilepsi olmayan bölge epilepsi değil diye tahmin edilmiş

Kısaltlamalar

BiLSTM	Bidirectional Long Short-Term Memory (İki Yönlü Uzun-KısaSüreli Hafıza)
BLDA	Bayesian Linear Discreminant Analysis (Bayesci Doğrusal Ayırma Analizi)
CHB	Children's Hospital Boston (Boston Çocuk Hastanesi)
CNN	Convolutional Neural Network (Evrimsel Sinir Ağı)
EEG	Elektroensefalografi
ELM	Extreme Learning Machine (Aşırı Öğrenme Makinesi)
LDA	Linear Discriminant Analysis (Doğrusal Ayırma Analizi)
LSTM	Long Short Term Memory (Uzun ve Kısa Süreli Hafıza)
MFCC	Mel Frequency Cepstral Coefficient (Mel-frekansı Kepstral katsayılarını)
SVM	Support Vector Machine (Destek Vektör Makinesi)
STD	Standart Sapma

ŞEKİLLER DİZİNİ

Şekil 3.1. Beyin Elektrotları Konumu (<i>G. H. Klem et al 1999</i>).....	10
Şekil 3.2. Delta dalgacığı	12
Şekil 2.3. Gama bandı	13
Şekil 3.4. Teta bandı.....	13
Şekil 3.5. Alfa bandı.....	14
Şekil 3.6. Beta bandı	15
Şekil 3.7. Kanal FP1-F3'den kaydedilen, hasta chb01'e ait EEG sinyali kırmızı bölge epileptik nöbet zaman aralığı (Chen, Duove arkadaşları, 2017).	17
Şekil 3.8. MFCC'nın EEG sinyalinden elde edilmesi	18
Şekil 3.9. Epileptik nöbetlerin performans ölçümü için çapraz doğrulama yöntemi.....	23
Şekil 3.10. Çapraz doğrulama deney yönteminin şematiğı.....	23
Şekil 3.11. Epileptik nöbetlerin performans ölçümü için Çapraz Hasta yöntemi.....	24
Şekil 3.12. Çapraz hasta deney yönteminin şematiğı.....	24
Şekil 3.13. Hata matrisinin parametreleri	25
Şekil 3.14. RUSBoost yöntemi ile çapraz hasta deneyi sonuçların grafiksel gösterimi .	30
Şekil 3.15. LogitBoost yöntemi ile çapraz hasta deneyi sonuçların grafiksel gösterimi	32
Şekil 3.16. RobustBoost yöntemi ile çapraz hasta deneyi sonuçların grafiksel gösterimi.....	34

ÇİZELGELER DİZİNİ

Çizelge 1.	RUSBoost yöntemini kullanarak elde çapraz doğrulama sonuçları.....	27
Çizelge 2.	LogitBoost yöntemini kullanarak elde çapraz doğrulama sonuçları.....	27
Çizelge 3.	RobustBoost yöntemini kullanarak elde çapraz doğrulama sonuçları.	28
Çizelge 4.	Ortalama çapraz doğrulama sonuçları.....	28
Çizelge 5.	RUSBoost yöntemi ile çapraz hasta deneyi sonuçları.....	29
Çizelge 6.	LogitBoost yöntemi ile çapraz hasta deneyi sonuçları.....	31
Çizelge 7.	RobustBoost yöntemi ile çapraz hasta deneyi sonuçları.	33
Çizelge 8.	Ortalama çapraz hasta deneyi sonuçları.....	34
Çizelge 9.	Çapraz doğrulama deney sonuçlarının literatür ile karşılaştırılması.....	35
Çizelge 10.	Çapraz hasta deney sonuçlarının literatür ile karşılaştırılması.....	35

1. GİRİŞ

Epilepsi, tekrarlayan nöbetler ile karakterize olan kronik bir beyin hastalığıdır. Vücudun bir kısmını veya tüm vücudu etkileyen istemsiz hareketin kısa uzantılarıdır ve bir grup beyin hücresindeki aşırı elektriksel boşalmalar nedeniyle oluşur. Nöbetler, yayılma mesafelerinin yanı sıra meydana gelme sürelerine ve sıklıklarına göre değişebilir. Klinik olarak tezahür etmeden önce bir nöbetin başlangıcını ortaya çıkarmanın en yaygın yolu, beynin elektriksel aktivitesinin invazif olmayan, çok kanallı bir kaydı olan kafa derisi elektroensefalogramının (EEG) analizidir. EEG'nin özellikleri hastalar arasında önemli ölçüde değişmektedir. Aslında, bir hastada nöbetin başlangıcıyla ilişkili EEG, başka bir hastanın EEG'sinde iyi huylu bir yapıya yakından benzeyebilir. Nöbet ve nöbet olmayan aktivitedeki bu çapraz hasta değişkenliği, hastaya spesifik olmayan sınıflandırıcıların bir nöbet başlangıcını bildirirken düşük doğruluk veya uzun gecikmeler sergilemelerine neden olabilir (Wilson ve arkadaşları 2004).

Dünya Sağlık Örgütü (WHO) 'ne göre, (The World Health Report 2001), Epilepsi hastalığı dünya çapında yaklaşık 50 milyondan fazla insanı etkilemektedir ve bu da onu Stroke (beyin felci) ve Alzheimer hastalıkları ile birlikte en yaygın nörolojik hastalıklardan birisi haline getirilmektedir. Her yıl, dünya genelinde yaklaşık 2,4 milyon kişiye epilepsi tanısı konmaktadır. Bilgi eksikliği, epilepsi için uygun tedavinin olmayışıyla birleştiğinde, sorunu gelişmekte olan ülke halkı için çok büyük hale getirmektedir, örneğin raporlar, Hindistan'da epilepsi tanısı alan kişilerin yalnızca %5'inin tedavi ve bakım aldığını göstermekle birlikte (U. R. Acharya et al 2013, D. K. Binder et al 2013, B. Litt and J. Echauz 2003, R. A. Scott et al 2001) ve %95 ise maddi sıkıntılardan dolayı özel tedavi göremediğini görmemektedir.

Vakaların çoğunda epilepsi ile ilişkili bilinen bir neden yoktur. Ancak bazen, bazı hastalarda beyin hasarı, inme, beyin tümörü ve gelişimsel yeteneklerin epilepsiye neden olduğu belirlenmiştir. Genç olan veya daha yaşlı nesiller, epileptik nöbetlere en çok

eğilimli kişiler olarak bilinir. Nöbetlerin tür ve büyüğü önceden tahmin edilemez olduğu için, bazı durumlarda hastaya ciddi hasar verebilir.

Bu nedenle, hastanın zihinsel durumunu izlemek ve yaklaşmakta olan bir nöbet krizinden önce hastayı uyarmak, nöbetin tespiti ve öngörülmesiyle beraber düşük maliyet, kolay erişilebilir bir bakım noktası için bir çeşit deney yöntemi gerekmektedir. Bu çalışmada, nöbetlerin tespiti ve tahmini için kullanılan mevcut tekniklerin birçoğunu inceledik. Literatür taramasında EEG verilerinin ele geçirilmesinin öngörülmesi göre analizi ve işlenmesi için birçok doğrusal ve doğrusal olmayan teknikle karşılaştık.

Yakın gelecekte yaklaşan bir epileptik nöbeti öngörebilecek gerçek zamanlı tahmin algoritması tasarlamaya çalıştık. Böyle bir algoritma, epileptik nöbetlerin öngörülmesi için bir yüksek doğruluğa sahip, maliyet açısından etkin ve ekonomik açıdan uygun bir cihaz yapımında önemli fayda sağlayabilir. Ayrıca (<https://physionet.org/content/chbmit/1.0.0/>) sitesinden alınan EDF halinde olan EEG sinyallerinin epileptik nöbet tahmini için bilgisayarda Matlab paket programını kullanarak bir yazılım oluşturmaya çalıştık.

Bu çalışma süresince tarafımızca elde edilen hedefler aşağıda kısaca belirlenmiştir:

İlk adımda:

- Literatür geçmişini kullanarak, tespiti ve tahmin için önceden var olan teknikleri gözden geçirilmesi.
- Veri tabanı tanıtımı
- EEG dalgalarının sınıflandırılması (Delta, Gama, Beta,Alfa,Teta)

- Nöbet tahmin için EEG sinyalleri için öznitelik çıkarma (MFCC)
- Öğrenme algoritması (sınıflandırıcı tanıtımı) Rus Boost, Logit Boost, Rust Boost
- Bir EEG sinyalinin nöbet bulma için MATLAB modelinin geliştirilmesi.

İkinci adımda:

- Uygun deney türlerinin seçimi (çapraz hastalık ve çapraz doğrulama)
- EEG sinyallerinin her bir deney için sonuçları.
- Deneylerden elde edilen sonuçların literatür ile karşılaştırılması

2. KAYNAK ÖZETLERİ

EEG kullanarak Epileptik Nöbetin Tespiti ve Tahmini üzerine araştırma çalışmaları 60 yıldan fazla bir süredir devam etmekte ancak 1990'ların ortasından itibaren, EEG kullanarak nöbetleri tespiti ve tahmini için kullanılan yöntemlerde önemli bir artış gerçekleşmiştir. Araştırma sürecinde ortak olan konu ise EEG sinyalinin nöbet periyodu ve öncesinde normal durumdan sapmamasıdır (*E. Magiorkinis et al 2001*). Teknolojide ve bilgidaki son gelişmeler ile öncü araştırma grupları, devam eden bir nöbeti veya daha sonradan gelen nöbetin başlangıç tespitini öngörebilecek bir sistem geliştirmeye çalışabilir ve bu sayede bir nöbete yaklaşma anında olan kişilerin nöbet zamanından önce dikkatli olmalarına, uyarılarında ve hatta nöbetin engellemeye yardım edebilir.

Birçok araştırma grubu, hastanın kendisini veya bakım verenlerini yaklaştırmakta olan bir nöbet konusunda uyarması için otomatik olarak bir uyarı sistemi görevi görmesi için beyin elektrotlarından EEG verilerini kullanarak çeşitli yöntemler tasarlamaya çalışmışlar (*J. Dorfmeister et al 1999*). Araştırmacılar ayrıca, nöbet kontrol mekanizmalarını tetiklemek için uyarı sistemi kullanmasını araştırmışlar. Hem tek değişkenli, hem de çok değişkenli veriler için makine öğrenme algoritmaları ile birleştirilmiş çeşitli doğrusal ve doğrusal olmayan sinyal işleme teknikleri, nöbet geçiren hastalar için kullanılmıştır (*A. Aarabi and B. He 2012*). Bu bölümde, geçmişte yapılan araştırmaların sonuçlardan ele edilen nöbetlerin tespiti ve tahmini için kullanılan teknikleri tartışıp ve daha sonra çalışmamızda uygulanan teknikler hakkında kısa bir genel bakış sunulacaktır.

2.1. Nöbet Tespit Konusunda Yapılan Araştırmalar

EEG'nin zihinsel durumları ile ritmik karakteri arasındaki ilişki uzun zamandan beri bilinmesine rağmen, bir kişinin zihinsel durumlarını tespit etme mekanizmaları (örneğin: nöbetler, uyku veya uyanıklık durumu) için birçok araştırma yapılmıştır. EEG veri tabanları 1990'lardan sonra oluşturmaya başlanmıştır ancak son zamanlarda, birçok

çalıřmalarda EEG kaydının nbet gerekleřmeden ncesinden nbetlerin doėru tahmin edebilmek iin EEG verileri kayıt edilmiřtir. En yaygın nbet saptama teknikleri, EEG verilerinden ıkarılan zellik setlerini eėitmek iin bir makine ėrenmesine dayalı sınıflandırıcı kullanmaktadır. Nbetlerin tespiti iin bu teknikleri kullanan drt ana alıřma ařaėıdaki gibidir.

Panda ve arkadařları (*R. Panda et al 2010*), sinyalleri farklı frekans bantlarına ayırmak iin dalgacık dnřm ve epileptik verileri ayırmak iin SVM sınıflandırıcısı kullanmıřtır. Andrzejak ve arkadařları MIT niversitesi veri setini EEG sinyallerinin eėitim ve test iin rnek olarak kullanmıřlardır (*R. G. Andrzejak et al 2001*). Tespit amacıyla yapılan bu alıřmada, EEG dalgacıklarını (DWT-db2) yntemini kullanarak ayrıřtırılan her frekans bandı iin enerji, entropi ve standart sapmayı incelemiřler ve elde edilen sonulara gre doėruluk oranı % 91,2 a kadar ulařmıřlardır. Srinivasan ve arkadařları (*V. Srinivasan et al 2007*) alıřmada, entropi lmn bir znitelik olarak kullanmıř ve EEG kaydındaki nbet varlıėını tespit etmek iin bir yapay sinir aėları temelli sınıflandırıcı kullanmıřlardır. Benzer řekilde, Ahammad ve arkadařları (*N. Ahammad et al 2014*) epelepsi nbeti ve bařlangı tespiti iin sırasıyla MIT niversitesi veri setini ve CHB-MIT veri tabanını kullanmıřlardır. Bu alıřmada EEG zellikleri, ortalama, standart sapma, entropi, g spektral yoėunluėunun yanı sıra dalga aralıėı ve ortalama mutlak sapma gibi bazı istatistiksel zellikleri de arařtırmıřlar. Bu alıřmanın sonunda doėruluk oranı % 85,6 ve doėrusal bir sınıflandırıcıda duyarlılıkla oranıysa % 84,2 olarak bulmuřlar. Gandhi ve arkadařları (2010), EEG epileptik aktivitenin tespiti iin verilerin sınıflandırılması iin olasılıksal bir sinir aėı kullanarak bir uzman modeli geliřtirmiř ve sınıflandırıcının eėitim ve test edilmesi iin klinik veri tabanı kullanılmıřtır. Uzman modelde on katlı bir apraz doėrulama deney yntemi arařtırılmıřtır. Bu modeli kullanarak %99,33'lk yksek doėruluk ve %99'luk duyarlılık oranı elde edilmiřtir.

Yuan ve arkadařları (2010), EEG sinyalinde nbetin tespiti iin SVM ve PNN sınıflandırmasını karřılařtırmıř ve SVM sınıfının, epilepsiyi ieren verileri doėru bir řekilde belirlemek iin PNN'ye kıyasladıktan sonra daha az sayıda zellik seti

gerektirdiğini göstermiştir. Ayrıca bu çalışmada, CAO yöntemini kullanarak EEG verilerinin dalga boyutlarını hesaplayıp ve çeşitli sınıflayıcıların özelliklerini araştırmışlardır.

2.2. Nöbet Tahmini Konusunda Yapılan Araştırmalar

Nöbet tahmini, uzun zamandır yaygın olan tespit ile karşılaştırıldığında nispeten yeni bir alandır. 1990'ların sonlarında, nöbetin, terapötik saldırıdan dakikalar veya saatler önce başladığına dair bir hipotezi (S. Ramgopal ve arkadaşları 2014) ve (P. R. Carney ve arkadaşları 2011) tarafından savunulmuştur. Bu bilgi daha sonra nöbetin tahmin edilmesi üzerine yapılan çalışmaları hızlandırdı. Bununla birlikte, şimdiye kadar, her durumda nöbeti öngörmek için tutarlı bir yöntem geliştirilmemiştir. Nöbet tahmini ile ilgili bildiriler diğer yazarlar tarafından sadece şansa yakın tahminler olarak gözden geçirilmiştir (F. Mormann ve arkadaşları 2007). Nöbet tahmini için çeşitli tekniklerin tartışıldığı (Carney ve arkadaşları 2011) ve (Fazel-Rezai ve arkadaşları 2009) gibi birçok çalışmalar yapılmış ve araştırma için iyi bir başlangıç noktası sağlanmıştır.

(Mormann ve arkadaşları 2000) tarafından yapılan bir çalışmada, farklı EEG kanalları arasındaki faz senkronizasyonunun, nöbet öncesi aşamayı tespit etmek için bir ölçüt olarak kullanılabileceğini söylenmiştir ve korelasyon katsayısının, EEG kanalları arasındaki faz senkronizasyonunu bulmak için istatistiksel bir araç olarak kullanılabileceği gösterilmiştir. Bu makalede, gösterilen raporlara göre 14 vakadan 12'sinde, nöbet aşamalarını önceden tahmin edilebileceği gösterilmiştir. Başka bir çalışmada, (Mormann 2003) hem lineer hem de nonlinear tekniklerin nöbet tahmini için benzer performansa sahip olduğu gösterilmiştir.

(Le Van Quyen ve arkadaşları 2001), EEG kaydının dinamik bir referans durumu ile benzerliğini ölçmeye dayanan bir yöntem kullanmışlardır. Bu çalışmada, tek değişkenli parametrelerden yararlanıp eğitim verilerinin daha çok kolaylığı için bilinen bölümlere

ayırtmışlar. Her aşama için, zaman serilerinin verisini, m-boyutlu uzayda bir nokta dizisine dönüştürmüş ve gecikmeler yöntemini kullanılmışlardır. Örnek değerleri doğrudan kullanmak ilave gürültüye daha fazla sağlamak için iki ardışık pozitif sıfır geçiş arasındaki süreyi kullanılmışlar. Araştırmacılar dinamik benzerlik, kontrolünü sağlarken sinyal pencereleri, hücreler arası aşamadan çıkarılan bir referans penceresiyle karşılaştırılıp ve bir nöbet meydana gelmeden birkaç dakika önce benzerlik endekslerinde düşüş tespit ettiler. Maiwal ve arkadaşları (2003), klinik olarak uygulamadan önce nöbet tahmin tekniklerini değerlendirmek için bir dizi kriter ve performans önem vermişlerdir. (M. Le Van Quyen ve arkadaşları 1999) tarafından yapılan çalışmalarda, temel olarak en popüler dinamik benzerlik tekniğine odaklanmışlardır. Mormann ve arkadaşları (2007), önceden tahmin için uygun olduğu düşünülen önlemlerin çoğunun rastgele bir tahminciye daha iyi performans göstermediğini belirtmiştir. Schad ve arkadaşları (2008) tarafından yapılan çalışmada, kafa derisi ve kafa içi kayıtlar kullanarak nöbetin tespiti tahminini araştırmışlardır. Bu yöntem EEG sinyalinin türevini bir özellik olarak kullanılmaktadır. Bu türevin belirli bir eşiği aştığı zamanlar tespit edilir ve bu zamanda bir darbe üretilir. Bu darbeler sızdıran nöronlarla birleştirilir ve integral değeri bir eşiğe ulaştığında entegratör sıfıra ayarlanır.

Birçok araştırmacı, Mel Frekans Kepstral Katsayılarını (MFCC'ler) konuşma sinyali için en popüler özellik çıkarma yöntemi olarak kullanmıştır ve bu yöntem EEG sinyalinden özellik çıkarmak için de uygulanmıştır (Norzaliza M. Ve arkadaşları 2011, Rathikarani ve arkadaşları 2013, Tae-Gu Kwon ve arkadaşları 2009). Mirowski ve arkadaşları (2009), EEG senkronizasyonunun 4 farklı değişken özelliğini (çapraz korelasyon, karşılıklı bağımlılık, dinamik sürüklenme ve dalgacık senkronizasyonu) çalışmışlardır. (F. Mormann ve arkadaşları 2003) faz senkronizasyon tekniğini araştırmışlar. Bu çalışmada, SVM, lojistik regresyon ve evrimsel sinir ağları gibi çeşitli makine öğrenme teknikleri kullanılmıştır ve sonuçta ise herhangi bir yanlış pozitif olmadan %71 duyarlılığa ulaştığı sonucuna varmışlardır.

(Zheng ve arkadaşları 2014), tarafından yapılan başka bir sınıflandırıcı araştırmada, her

bir EEG sinyallerinin doğru tahmini için (IMF) ve (BEMD) sınıflandırıcıları kullanmış ve nöbet başlamadan önce faz senkronizasyonunda bir artış olduğunu gözlemlenmiştir. Shufang ve arkadaşları (2013), bu çalışmada ise EEG sinyalini tahmin etmek ve Spike sinyalini almak için arka plan sinyalini orijinal sinyalden çıkarmak amacıyla bir morfoloji işlemi (Morfoloji filtresi, basit toplama ve çıkarma işlemi) olarak kullanmışlar ve böylece algoritmanın hesaplama karmaşıklığını azaltmışlardır. Bu çalışmanın sonucunda spike oranını kullanarak, %75,8 duyarlılık ve 0,09 yanlış tahmin oranı ile nöbet tahmini gerçekleştirmişlerdir. Ayrıca Guanghua ve arkadaşları (2007), Morfolojik işlemlerini kullanarak EEG sinyallerinde gelişmiş bir spike saptama algoritmasını göstermişler.

Teixeira ve arkadaşları (2014), epileptik bir hastanın EEG sinyalini 4 duruma sınıflandırmaya çalıştılar: inter-iktal, pre-iktal, iktal ve post-iktal. Çok sınıflı SVM sınıflandırıcı kullanarak ve Enerji, Ortalama, Güç, Hjorth Parametreleri, vs. gibi 22 tek değişkenli özellik ile hesaplamaya çalıştılar. Bu araştırmayı gerçekleştirmek için 278 hastadan alınan kapsamlı bir hasta veritabanını oluşturmuşlardır. EEG sinyallerinin analizlerinde sınıf dengesizliği sorununu hafifletmek için birçok teknik önerilmiştir. Bu tekniklerin birisi boosting tekniğine ait olan Rusboost yöntemidir (G. M. Weiss, 2004). Bu çalışmada Rusboost yönteminin performansı başka yöntemler ile kıyaslanmıştır. Boosting çalışmalarının devamında (Tahernezhad ve arkadaşları. 2018) ve (Bo Zhang ve arkadaşları 2017) tarafından yapılan araştırmalarda LogitBoost yöntemi incelenmiştir. İnvaziv olmayan beyin-makine arayüzü (BMI) sistemlerinin önemi ve yakın gelecekteki gelişimi göz önüne alındığında, bu makale, EEG sinyallerinin kullanıldığı (BMI) tabanlı sistemler için sınıflandırma ve logitboost yöntemi üzerine kapsamlı bir teorik ve deneysel çalışma sunmaktadır.


Bu çalışmanın amacı, EEG sinyalleri tahminleri için, MFCC kullanılarak EEG sinyallerini 10 saniyelik bölümlere bölüp daha sonra Boosting sınıflandırıcıları kullanarak çapraz doğrulama ve çapraz hasta deney yöntemleriyle epilepsi nöbet tahmini gerçekleştirmek ve sonuçları literatürdeki yöntemler ile karşılaştırmaktır.

3. MATERYAL VE YÖNTEMLER

3.1. Elektroensefalografi

EEG sinyalleri epilepsi hastalığını teşhis etmede önemli bir yere sahiptir. EEG beynin elektriksel aktivitesini kayıt eden elektrofizyolojik izleme yöntemidir. Elektrokortikografide olduğu gibi bazen invaziv elektrotlar kullanılmasına rağmen, çoğunlukla elektrotlar kafa derisi boyunca yerleştirilir ve invaziv değildir. EEG, beynin nöronları içindeki iyonik akımdan kaynaklanan voltaj dalgalanmalarını ölçer.

EEG kayıt yapmadan öncesinde elektrodların hazırlanması ve kafatası üzerine yerleşimi oldukça önemlidir. EEG Ortalama 17 adet elektrodun jel yardımıyla saçlı olan kafa derisine yerleştirilmesi gerekmektedir. EEG yöntemi tamamen ağrısız ve zararsız olan bir inceleme yöntemidir ve her yaşta olan insan için EEG kaydı yapılabilir. EEG'de Radyasyon veya her hangi bir kimyasal etkisi yoktur ve beyin zarar görmez(*G. H. Klem et al 1999*). Tüm elektrot yerleştirme bölgelerine, altta yatan beyin lobuna ve yarımküreye bağlı olarak belirli bir ad verilir. F, T, P ve O harfleri sırasıyla frontal, temporal, parietal ve oksipital olarak gösterilir. C harfi, beynin merkezi bölgesi üzerinde bulunan elektrotları tanımlamak için kullanılır. Elektrotlara atıfta bulunmak için kullanılan çift ve tek sayılar, elektrotların sırasıyla sağ ve sol hemisferlerdeki pozisyonuna işaret eder. EEG çekimi süresince, hasta sakin ve rahat bir şekilde olmalıdır ve hatta yatmalıdır. Parazitsiz ve kaliteli bir kayıt alabilmek için aksi istenmedikçe, hasta gözlerini kapatıp ve çene ve boyun kaslarını gevşek haline getirmelidir. EEG yapan teknisyenin isteklerine göre hasta söylenenleri yapmalıdır. EEG filtrelerinin düzgün ve doğru ayarlanması da çok önem taşımaktadır. Genelde aralıklı ışık uyaran ve derin nefes alıp ve verme şeklinde aktivasyon metotları düzenli olarak kullanılır. Buradaki amaç anormal aktiviteyi aktif hale veya epileptik odağı geçirmektir.



Şekil 3.1. Beyin Elektrotları Konumu (G. H. Klem et al 1999)

Şekil 3.1.'de EEG kaydını elde etmek için kafa derisi üzerindeki elektrotların yerleşimini göstermektedir. İç daire elektrot zamansal elektrot çizgisini temsil ederken, dıştaki halka burun ve iyon seviyesiler göstermektedir.

3.2. EEG Frekans Bantları


Elde edilen EEG sinyalleri daha sonra kayıt süresi boyunca beynin elektriksel durumunu incelemek için işlenir. Beynin her alanı, zihinsel duruma, hayal ettiği görevlere ve hastanın genel durumuna göre farklı bir beyin dalgası üretir. EEG sinyali, psikolojik durumları karakterize etmek ve tanımlamak için dalgalarına göre belirlenen farklı frekans bantlarından oluşur ve bu bantlar epileptik nöbetlerin belirlenmesinde de önem arz etmektedir.(E. Niedermeyer and F. L. da Silva 2005):

- Delta dalgaları: Frekans 4 Hz'e kadar değişmektedir. Genlikte en yüksek olma eğilimindedir ve yetişkinlerde yavaş dalga uykusu için normal olarak görülür.
- Teta dalgaları: Frekans 4 Hz ile 8 Hz arasında değişmektedir. Teta normalde

küçük çocuklarda görülür ve meditasyonda da söylediği gibi büyük çocuklarda ve erişkinlerde uyku hali veya uyarılma görülebilir.

- Alfa dalgaları: Frekans 8 Hz ila 13 Hz arasında değişmektedir.
- Beta dalgaları: Frekans 13 Hz ila yaklaşık 30 Hz arasında değişmektedir. Simetrik dağılımda genellikle her iki tarafta da görülür ve en önden belirgindir. Beta dalgaları hasta davranışlarıyla yakından ilişkilidir ve genellikle aktif hareketler sırasında zayıflar (*D. Kumar et al 2015*).
- Gama dalgaları: Frekans aralıkları yaklaşık 30-100 Hz'dir. Gama beyin dalgaları en hızlı beyin dalgalarıdır ve farklı beyin alanlarından gelen bilgilerin eş sinyali olarak işlenmesiyle ilgilidir ayrıca gama beyin dalgaları bilgiyi hızlı ve sessizce aktarır.

Normal Elektroensefalografi (EEG) yaşa göre değişir. Çocukluk çağında EEG genellikle yetişkin EEG'den daha yavaş frekans salınımlarına sahiptir. Daha önce, Epileptik Nöbetler bilgilerinin sadece düşük frekans bantlarında (Theta, Alpha, Beta) mevcut olduğu düşünülmüştü. Bununla birlikte, yüksek frekanslı salınımların (Gama ritimleri) de nöbet aktivitesi hakkında önemli veriler içerdiğini gösteren artan sayıda çalışma vardır (*S.-A. Lee, D. D. Spencer 2000*).




Şekil 3.2. Delta dalgacığı

Şekil 3.2 de gösterdiği gibi delta dalgaları en büyük dalga genliğine sahiptir ve derin fakat rüyasız uyku ile ilgilidir. Bebeklerde ve küçük çocuklarda çok yaygındır. Yaşlandıkça, ürettiğimiz bu beyin dalgalarının daha azını elde ederiz.


Şekil 3.3 de “Gama” kelimesini duyduğumuzda, akla ilk gelen şey, uzun dalga boyları ve yüksek elektromanyetik radyasyonları ile ünlü gama ışınlarıdır. Gama dalgaları ve gama ışınları sadece ortak olan tek bir şeye sahiptir o da çok yüksek frekanslarıdır. Gama dalgalarını bir EEG’de yakalamak çok zordur. Talamustan köken alınır ve beynin arka kısmından inanılmaz hıza doğru ilerlerler. Gama dalgaları, üst düzey bilişsel işlem görevleri ile ilişkilidir. Aşağıda gama dalgalarının ne kadar önemli olduğuna birkaç örnek ile vurgulanmıştır:

- Öğrenme tarzımız, yeni bilgi edinme kabiliyetimiz, duyularımız ve algılarımızla ilgilidir. Örneğin, zihinsel sorunları olan veya öğrenme güçlüğü çeken insanlar, Gama dalgası aktivitesinin yarısından daha azına sahip olma eğilimindedir.

- Gama dalgalarının değeri mutluluk durumlarında görülür.
- Ayrıca REM uyku fazı gama frekans aralığında yüksek düzeyde aktivite ile karakterize olma eğilimindedir.




Şekil 2.3. Gama bandı



Şekil 3.4. Teta bandı

Şekil 3.4’de ikinci tür beyin dalgaları 3,5 ila 8 Hz arasındadır ve çoğunlukla hayal gücü, düşünme ve uyku ile ilgilidir. Teta dalgaları, çok derin duyguları yaşadığımızda daha aktiftir, örneğin, çok fazla enerji harcayan bir iş ya da görevi bitirdiğimizde, rahatladığımız ve hayal gücümüzün çalışmasına izin verdiğimizde Teta dalgaları beynimizde kontrolü ele geçirir. Teta dalgalarının yüksek olmasına rağmen bir depresif bozukluk ya da dikkat eksikliği ile ilişkili olabilir. Düşük olması ise stres ve düşük duygusallığa karşılık gelebilir.


Şekil 3.5’de gösterdiği gibi alfa dalgaları, ara sıra sakin, ancak uykuda değilken, alacakaranlık zamanlarında ortaya çıkıyor. Rahat ve meditasyon için hazır olduğumuz zaman, kanepede olduğumuzda, televizyon seyredirken ya da yatakta dinlenirken, yüksek düzeyde bir Alfa dalgası bizim odaklanmamıza engel olabilir ve hatta enerjimiz olmadığını hissettirebilir. Düşük alfa dalgaları strese ve uykusuzluğa karşılık gelir.



Şekil 3.5. Alfa bandı

Şekil 3.6’da beta dalgaları görülmektedir. Düşük veya orta beyin dalgalarından daha yüksek bir seviyeye geçerek ve yoğun nöronal aktiviteden gelen daha yüksek frekanslı

dalgalarıdır.



Şekil 3.6. Beta bandı

Sonuç olarak, farklı beyin dalgalarını öğrenmek, zihinsel süreçlerimizin, duygularımızın, faaliyetlerimizin ve davranışlarımızın beynimizde “enerji” ürettiğini anlamamızı sağlar.

3.3. Veri Tabanı

Kullanılan EEG veri tabanı, Boston Çocuk Hastanesi'nde kayıt edilen CHB-MIT (<https://physionet.org/content/chbmit/1.0.0/>) veri setidir. Kayıtların çoğu bir saat sürelidir ve bazıları iki veya dört saattir. EEG kayıtları 24 bölüme ayrılır ve EDF veri formatında saklanır. Her bir EDF dosyası bir EEG kaydına karşılık gelir.

Her bir CHB-MIT veri seti, 1,5 ile 17 yaş arasında değişen 23 kişiden oluşmaktadır ve yaklaşık 686 EEG sinyal kaydı içermektedir. Kullanılan örnekleme frekansı 256 Hz'dir ve her kayıt farklı kanallara sahip bir dizi EEG sinyali içerir. Kayıtların çoğu bir saat sürelidir ve bazıları iki veya dört saattir. Bu veri tabanında 1. Kişi (Chb01) ve Chb21'inci kişi 1,5 yıl arayla kayıt alınmış aynı kişidir. Ayrıca bazı kanallardaki verilerin eksik

olduğu veri dosyaları bulunmaktadır. Örneğin, (Chb12-27.edf), (Chb12-28.edf) ve (Chb12-29.edf) diğer dosyalarından farklı kanal montajlarına sahiptir.

Bu çalışmada 17 ortak kanal seçilmiştir, yani her hasta için, 17 ortak kanalın verileri, nöbet ve nöbet dışı özniteliklerin çıkarılması için kullanıldı. Ortak kanallar sırasıyla (P4-02, FP2-F4, P7-O1, C4-P4, F7-T7, C3-P3, FP1-F7, F8-T8, FZ-CZ, CZ-PZ, F3-C3, T7-P7, P8-02, FP1-F3, F4-C4, FP2-F8 ve P3-O1) kanallarıdır.

3.4. Metodoloji

Bu bölümde, nöbet tespiti için kullanılan yöntemi detaylı bir şekilde açıklanmaktadır. Önerilen yöntem aşağıda maddeler halinde verilen dört adımdan oluşmaktadır.


1. Verilerin ön işlenmesi.
2. Verilerin ayrı frekans bantlarına ayrıştırılması.
3. Mel-Frekansı Kepstral Katsayılarını (MFCC)
4. Verilerin eğitimi ve test edilmesi.

3.5. Verilerin Ön İşlemesi

EEG sinyalleri üzerindeki sinyaller üzerindeki 50 Hz lik güç hattı gürültüsü yok etmek amaçlı, bu gürültüyü bastıracak IIR tabanlı bant geçiren filtre dizayn edildi ve EEG sinyalleri bu filtreden geçirildi. Daha sonra her bir kanaldaki EEG sinyalleri istatistiksel sıfır (0) ortalama ve standart sapması bir (1) olacak şekilde standardize edilmiştir.

3.6. Mel-Frekansı Kepstral Katsayıları (MFCC)

EEG sinyallerini daha sonra sınıflandırmada kullanılan değerlere dönüştürmek için bir özellik çıkarımı gerçekleştirildi. Çıkarılan özellikler sayesinde EEG sinyali içerisindeki fazlalık olan veriler atılır ve sınıflandırma işleminde faydalı olacak özet bilgi saklanır. Literatürde çok sayıda çalışmada çeşitli öznitelik çıkarma yöntemleri kullanılmış ve öznitelik üzerinde birçok araştırmalar yapılmıştır. Bu tez kapsamında çalışmalarda EEG sinyallerinin karakteristiğini elde edebilmek için MFCC, logaritmik mel enerjilerinden yararlanılmıştır. Şekil 3.7, bir kanalda nöbet içeren saatteki EEG kaydını göstermektedir. Nöbetin bölgesi başlangıç ve bitiş çizgiler arsındadır.




Şekil 3.7. Kanal FP1-F3'den kaydedilen, hasta chb01'e ait EEG sinyali başlangıç ve bitiş bölge epileptik nöbet zaman aralığı (Chen, Duove arkadaşları, 2017)

Bu çalışmada MFCC'nin kullanılması birçok avantaja sahiptir:

- MFCC, sinyalleri daha fazla ağırlık vererek belirli frekanslara odaklanmaya izin verdiğinde, kompakt ve anlamlı bir şekilde gösterebilir.
- Ayrıca MFCC özellikli sınıflandırıcılar, karmaşık sınıflandırma modelleri

oluşturmaya gerek kalmadan iyi bir doğruluk sağlayabilir.



Şekil 3.8. MFCC'nın EEG sinyalinde elde edilmesi

Bir EEG sinyalinde MFCC özniteliklerinin nasıl çıkarılacağı Şekil 3.8' de gösterilmektedir. Her ne kadar MFCC'ler konuşma tanıma, müzik modelleme veya duygu tanıma gibi birçok uygulamada başarılı bir şekilde kullanılmış olsalar da Epileptik nöbetlerin EEG sinyalinde bulunması uygulamasında da başarılı bir şekilde uygulanmaktadır.

- Her bir EEG sinyali s_n dizisine ile gösterildiği varsayalım. Burada n , $(0, 1, \dots, N-1)$ arasında değişmektedir, N , örneklerin sayısıdır.
- EEG sinyali öncelikle 10 s uzunluğunda çerçevelere bölünür. Bu çerçeveleme işleminde EEG sinyali daha kararludur ve her bir çerçevenin sıfır veya bir şeklinde bir etiketi vardır. Bu etiket sayesinde seçilen 10 saniyelik çerçevede epileptik nöbet var olup olmadığı etiketlenir. Konuşma işleme uygulamalarında her bir çerçeveleme işleminde örtüşme olmasına rağmen bu çalışmada çerçevelerde herhangi bir örtüşme yoktur.

- Çerçeveleme adımından sonraki adım her bir çerçeveyi pencerelemektir. Bu adımın amacı, sinyal süreksizliklerini azaltmak bu sayede EEG sinyalinin orta bölgeleri güçlendirilirken kenar bölgeleri zayıflatılır. Bu, sinyali her karenin başında ve sonunda sıfıra düşürmek için Hamming penceresini kullanarak, s_n EEG örneklerine aşağıdaki denklem uygulayarak gerçekleştirilir.

$$s'_n = \left\{ 0,54 - 0,46 \cdot \cos\left(\frac{2\pi(n-1)}{N-1}\right) \right\} \cdot s_n \quad (3.1)$$

- Bu katmanda her bir çerçevenin Fourier dönüşümü alınır ve bu sayede sinyalin frekans bileşenleri tespit edilir.
- Daha sonra sinyalin frekans bileşenleri filtre bankasında (20-30 tane üçgen filtre) geçirilir ve her bir filtrenin altında kalan enerji bileşenleri toplanarak bu enerjinin logaritması alınır.
- Sonraki aşamada önceki bölümde elde edilen değerler aşağıda formül ile ifade edilen Ayrık Kosinüs Dönüşümü (DCT) den geçirilerek MFCC'lar hesaplanmış olur.

$$c_i = \sqrt{\frac{2}{N}} \sum_{j=1}^N m_j \cdot \cos\left(\frac{\pi i}{N} (j - 0,5)\right) \quad (3.2)$$

3.7. Sınıflandırıcılar

Sınıflandırmada, bir sınıfı temsil eden örnek sayısı diğer sınıflardan oldukça az ise bu

durumda veri kümesinin dengesiz olduğu söylenebilir. Ayrıca, en az sayıda örneğe sahip olan sınıf genellikle öğrenme görevi açısından ilgilenilen sınıftır. Özellikle bu problem bu tez çalışmasında da üzerinde çalıştığımız medikal tanı problemlerinde sıkça karşılaşılan bir durumdur. Bu durumlarda, standart sınıflandırıcı öğrenme algoritmaları çok sayıda örneği olan sınıfın lehine doğru kurallar geliştirir ve çok olan örnekleri doğru tahmin eder duruma gelir diğer taraftan azınlık sınıfından bulunan örnekler genelde göz ardı edilir ve bunlar gürültü olarak dikkate alınır. Bu şekilde, azınlık sınıfı örnekleri diğer sınıflardan daha çok yanlış sınıflandırılır. Bu problemi çözmek için birçok yöntem geliştirilmiştir. Bu yöntemler üç gruba ayrılabilir.

Algoritma tabanlı yaklaşımları mevcut sınıflandırıcı öğrenme algoritmalarını öğrenmeyi azınlık sınıfına doğru yönlendirecek şekilde uyarlamaya çalışır. Veri tabanlı yaklaşımları, verileri yeniden örnekleyerek sınıf dağılımlarını dengeler. Bu şekilde, bir ön işleme aşamasıyla dengesizliğin neden olduğu etkiyi azaltmaya çalışarak öğrenme algoritmasının değiştirilmesini önlerler. Diğer yöntem ise maliyete duyarlı öğrenme yöntemidir. Bu yöntem veri ve algoritma tabanlı yaklaşımları arasında yer almaktadır. Hem veri seviyesi dönüşümlerini (örneklere maliyetler ekleyerek) hem de algoritma düzeyinde değişiklikleri (öğrenme sürecini maliyetleri kabul edecek şekilde değiştirerek) içerir. Bu çalışmada sınıf dengesizliği problemi ile başa çıkmak için kolektif öğrenme tekniklerine dayanan yöntemler kullanılmıştır. Yukarıda sayılan üç kategorinin yanı sıra, kolektif temelli yöntemler yeni bir kategori olarak sayılabilirler. Bu teknikler genellikle bir kolektif öğrenme algoritması ile yukarıdaki tekniklerden biri, özellikle de veri tabanlı ve maliyete duyarlı algoritmalar arasındaki bir kombinasyondan oluşur.

Bu çalışma kapsamında kullanılan kolektif sınıflandırıcılar RUSBoost, RobustBoost ve LogitBoost yöntemleridir. Bu yöntemler aşağıda kısaca açıklanmıştır.

3.7.1. RUSBoost yöntemi

RUS veri örnekleme teknikleri, eğitim veri setinin sınıf dağılımını ayarlayarak sınıf

dengeşizlięi sorununu hafifletmeye alıřmaktadır. Bu, oęunluk sınıfından rneklerin kaldırılması (alt rnekleme) veya azınlık sınıfına rneklerin eklenmesi (ařırı rnekleme) ile gerekleřtirilebilir. En yaygın veri rnekleme tekniklerinden biri (byk lde basitlięi nedeniyle) RUS'dir. Daha karmařık veri rnekleme algoritmalarının aksine, RUS, eęitim verilerinden rnekleri “akıllıca” kaldırmaya alıřmaz. Bunun yerine RUS, istenen sınıf daęılımına ulařılana kadar rnekleri rastgele oęunluk sınıfından kaldırır. RUSBoost algoritması SMOTEBoost'a benzer řekilde performans gsterir, ancak her yinelemedeki veri kmesini rastgele rnekleyerek rasgele sınıftan rnekleri kaldırır. Bu durumda, rneklere yeni aęırlıklar atamak gerekli deęildir. Bu sebeple RUSBoost algoritması daha hızlı model eęitim sreleri ve uygun performans ile daha basit bir algoritmadır.

3.7.2. RobustBoost yntemi

Birok klasik klasik kolektif sınıflandırıcı modelleme yntemi, pratikte nadiren karřılanan varsayımlara dayanır. rneęin, genellikle eęitim setindeki hataların normal olarak daęıtıldıęı varsayılır. Bu kabullerin sonucu olarak, klasik yntemler grltl gerek dnya verilerinde ok kt performans gsterebilir. rneęin, birok boosting algoritmasının performansının, aykırı verilerin (outlier) varlıęında dramatik bir řekilde azaldıęı bilinmektedir. rnek olarak Adaboost algoritması dikkate alındıęında, Adaboost, sonraki tekrarlamalar iin yanlıř sınıflandırılmıř eęitim rneklerini daha aęır hale getirdięinden, bir aykırı veriye sınırsız derecede byk bir aęırlık atayabilir. Bu kadar aęır aęırlıklı bir aykırı veri, ana karar verme mekanizmasını gerek eęilimden uzaklařtırabilir. Sonu olarak, ana fonksiyon zayıf tahmin performansına sahip olur. RobustBoost yntemler, aykırı verilerden etkilenmeyen modeller oluřturarak klasik yntemlere bir alternatif sunar. Klasik yntemlerde, aykırı deęerler eęitim esnasından nce tespit edilerek veri setinden ıkarılır. Yeni yntemlerde ise, bazı durumlarda, aykırı tespit mekanizmasının uyarlanma iřlemine eriřmesi ve bu procesten faydalanmasına izin vermek faydalı olabilir. Aykırı deęerler daha sonra dikkatlice seilmiř bir kayıp fonksiyonu vasıtasıyla bir sonraki srecinden ıkarılır. Bu yntem, verinin oęunluęuna

uygun bir model olarak dizayn yapılmaya çalışır. Yani, veri kümesinin küçük bir bölümü sapan değerlerden oluşsa bile kalan büyük bölüm güvenilir sonuçlar verir.


3.7.3. LogitBoost yöntemi

Makine öğrenmesi ve hesaplamalı öğrenme teorisinde LogitBoost, Jerome Friedman, tarafından formüle edilmiş bir yükseltme algoritmasıdır. Orijinal makale Ada Boost algoritmasını istatistiksel bir çerçeveye taşımaktadır. Spesifik olarak, eğer Ada Boost'u genelleştirilmiş bir katkı modeli olarak dikkate alır ve ardından lojistik regresyonun maliyet fonksiyonunu uygularsa, Logit Boost algoritmasını elde edilir. Boosting sınıflandırma metotları en önemli ve güncel gelişmelerden biridir. Birçok sınıflandırılma algoritmaları, basit strateji ve performans olarak ciddi bir artış ile sonuçlanmaktadır. Bu yöntem bilinen istatistiksel prensiplere sahip toplamsal (additive) modelleme ile yüksek olasılık arasındaki, uyumlarını göstermektedir. 2-sınıf problemi için, LogitBoosting, ölçüde Bernoulli olması (likelihood) kriter olarak, genel modele yaklaşımı olarak görülebilmektedir.


3.8. Deneyler

Bu tez çalışması kapsamında EEG verilerindeki epileptik nöbetlerinin tespiti için iki tür deney gerçekleştirilmiştir bunlar Çapraz Doğrulama ve Çapraz Hasta deneyleri bu yöntemler aşağıda kısaca özetlemektedir

1. Çapraz doğrulama (Cross-validation) deneyleri: Çapraz doğrulama deneylerinde, 24 kişiden alınan CHB-MIT'deki EEG sinyalleri 10 saniyelik uzunluğunda segmentlere ayrılır, varyasyonu azaltmak için, deneylerimizde her bir nöbet / nöbet olmayan sınıflandırma yaklaşımı için on tur çapraz doğrulama deneyi gerçekleştirilir. Şekil 3.9 ve 3-10'da bu yöntem ile bölümlendirilen veri seti şematığı görülmektedir.




Şekil 3.9. Epileptik nöbetlerin performans ölçümü için çapraz doğrulama yöntemi




Şekil 3.10. Çapraz doğrulama deney yönteminin şematığı

2. Çapraz Hasta (Cross-patient) deneyleri: Çapraz hasta deneyi, bir hastanın test ve diğer tüm hastaların eğitim ve doğrulama verisi olarak seçildiği anlamına gelir. Bu yöntemde her seferinde 23 kişinin verilerini eğitim için ve 1 kişinin verisi ise test için kullanılmaktadır. Eğitim ve doğrulama konularından elde edilen veriler bir model eğitmek ve test kısmındaki veriler eğitilen modeli test etmektir içindir. Çapraz hasta deneylerimizde, CHB-MIT'deki 23 hasta, önerilen yaklaşımımızın performansını değerlendirmek için ayrı ayrı test verisi olarak seçildi ve daha sonra 23 hasta üzerindeki genel performans analiz edilmiştir. Şekil 3.11'de bu yöntem ile bölütlendirilen veri seti şematığı görülmektedir.



Şekil 3.11. Epileptik nöbetlerin performans ölçümü için Çapraz Hasta yöntemi



Şekil 3.12. Çapraz hasta deney yönteminin şematiği

3.8.1. Performans ölçütleri (doğruluk, duyarlılık ve özgünlük)

EEG sinyali içerisinde Epileptik nöbetlerin tespiti için önerilen yöntemin performansını ölçmek için Hata matrisi, duyarlılık, özgüllük ve doğruluk değerleri hesaplanmıştır. Her bir yöntemin performansı ölçülürken yukarıda anlatılan iki farklı veri seti parçalama yöntemi için ayrı ayrı sonuçlar verilmiştir.

1. Hata Matrisi: Sınıflandırma sonucunda epilepsi ve epilepsi olmayan kısımların nasıl bulunduğunu ne tür hatalar yapıldığını Hata Matrisi ile ölçebiliriz. Bu çalışmada kullanılan genel bir hata matrisi aşağıdaki gibidir.

Tahmin Edilen Sınıf	Epilepsi	Epilepsi Değil
	TP	FP
Epilepsi Değil	FN	TN
	Epilepsi	Epilepsi Değil
	Gerçek Sınıf	

Şekil 3.13. Hata matrisinin parametreleri

Bu çizelge’de doğru pozitif sınıflandırma için TP (Epilepsi bölgesi epilepsi olarak tahmin edilmiş), gerçek negatif için TN (Epilepsi olmayan bölge epilepsi değil diye tahmin edilmiş), yanlış pozitif için FP (Epilepsi olmayan bölge epilepsi diye tahmin edilmiş) ve yanlış negatifler için FN (Epilepsi olan bölge epilepsi değil diye tahmin edilmiş) parametreleri kullanılmıştır.

2. Doğruluk: Doğru sınıflandırma başarısı olup aşağıdaki formül ile hesaplanır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.3)$$

3. Duyarlılık: TP değerinin TP ve FN değerlerinin toplamına bölünmesi ile hesaplanır

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (3.4)$$

4. Özgüllük: TN değerinin TN ve FP değerinin toplamına bölümünden elde edilir.

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (3.5)$$

3.9. Testler ve Sonuçlar

Bu bölümde tez kapsamında elde edilen deneysel sonuçlar verilmektedir. Deneysel sonuçlar üç ana başlık altında verilmiştir: Çapraz doğrulama deneysel sonuçları, Çapraz hasta deneysel sonuçları ve bu sonuçların literatürde yapılan çalışmalar ile karşılaştırılması.

3.9.1. Çapraz doğrulama deney sonuçları

Bu bölümde çapraz doğrulama deneylerinde RUSBoost, LogitBoost ve RobustBoost yöntemlerinden elde edilen sonuçlar sırasıyla Çizelge-1, Çizelge-2 ve Çizelge-3 de verilmektedir. Her bir doğrulama için duyarlılık, özgüllük ve doğruluk değerleri, her bir doğrulama için elde edilen sonuçların ortalaması ve standart sapması ilgili çizelgede görülmektedir.

Çizelge 1. RUSBoost yöntemini kullanarak elde çapraz doğrulama sonuçları

	Duyarlılık	Özgüllük	Doğruluk
1	0,795	0,815	0,815
2	0,711	0,855	0,854
3	0,72	0,803	0,803
4	0,819	0,837	0,83
5	0,760	0,787	0,789
6	0,696	0,835	0,835
7	0,695	0,845	0,845
8	0,734	0,854	0,853
9	0,666	0,854	0,854
10	0,758	0,81	0,816
Ortalama değer	0,735	0,830	0,830
STD	0,045	0,022	0,022

Çizelge 2. LogitBoost yöntemini kullanarak elde çapraz doğrulama sonuçları

	Duyarlılık	Özgüllük	Doğruluk
1	0,976	0,941	0,941
2	0,916	0,937	0,937
3	0,961	0,940	0,940
4	0,930	0,938	0,938
5	0,970	0,938	0,938
6	0,952	0,940	0,940
7	0,944	0,937	0,937
8	0,890	0,940	0,939
9	0,941	0,942	0,942
10	0,916	0,934	0,9341
Ortalama değer	0,940	0,939	0,939
STD	0,025	0,0022	0,0028

Çizelge 3. RobustBoost yöntemini kullanarak elde çapraz doğrulama sonuçları

	Duyarlılık	Özgüllük	Doğruluk
1	0,896	0,918	0,918
2	0,88	0,919	0,918
3	0,925	0,916	0,917
4	0,921	0,919	0,919
5	0,938	0,920	0,920
6	0,926	0,917	0,917
7	0,902	0,920	0,919
8	0,928	0,915	0,915
9	0,935	0,914	0,914
10	0,953	0,914	0,915
Ortalama değer	0,921	0,917	0,917
STD	0,020	0,002	0,002

Önerilen üç yönetime ait ortalama çapraz doğrulama sonuçları Çizelge-4 de verilmektedir. Bu çizelgeni incelendiğinde Çapraz doğrulama deneylerinde LogitBoost algoritmasının diğer iki algoritmaya oranla tüm değerlerde daha iyi sonuçlar verdiği görülmektedir.

Çizelge 4. Ortalama çapraz doğrulama sonuçları

	Duyarlılık	Özgüllük	Doğruluk
RUSBoost	0,735	0,830	0,830
LogitBoost	0,940	0,939	0,939
RobustBoost	0,921	0,917	0,917

3.9.2. Çapraz hasta deney sonuçları


Daha önce belirtildiği üzere çapraz hasta deneylerinde bir hastadan alınan veriler test geriye kalan diğer bütün hastalardan alınan veriler ise eğitim verisi olarak dikkate alınmaktadır. Bu işlem veri tabanında bulunan tüm kişiler tekrarlanarak sonuçlar çizelge haline getirilmiştir. Yine bu deneyde de duyarlılık, özgüllük ve doğruluk değerleri hesaplanmış ve ilgili çizelgelerde verilmiştir. Tüm kişilere ait ortalama değerler ve standart sapma değerleri de her bir çizelgenin altında verilmektedir. Ayrıca her bir kişiye

ait performans sonuçları diğer hastalar ile karşılaştırmalı bir şekilde incelenebilmesi için çizelge ile verilen sonuçlar grafiksel olarak her bir yöntemin altında gösterilmiştir.

Çapraz hasta deneylerinde RUSBoost, LogitBoost ve RobustBoost yöntemlerinden elde edilen sonuçlar sırasıyla Çizelge-5, Çizelge-6 ve Çizelge-7’de ve Şekil-3.12, Şekil-3.13 ve Şekil-3.14’te verilmektedir. Bu çizelge ve grafikler incelendiğinde özellikle 12 ve 15 kişilerin arasında duyarlılık değerleri normalin altına düştüğü görülmektedir. Bunun en önemli sebebi bu kişilerde EEG elektrotlarının farklı kombinasyonda bağlanması kaynaklanmaktadır.

Çizelge 5. RUSBoost yöntemi ile çapraz hasta deneyi sonuçları


Kişi No	Duyarlılık	Özgüllük	Doğruluk
CHB--01	0,813	0,893	0,893
CHB-02	1,000	0,828	0,828
CHB-03	0,844	0,873	0,873
CHB-04	0,833	0,604	0,604
CHB-05	0,968	0,734	0,735
CHB-06	0,480	0,785	0,784
CHB-07	0,919	0,868	0,868
CHB-08	0,837	0,596	0,599
CHB-09	0,968	0,772	0,772
CHB-10	1,000	0,900	0,900
CHB-11	0,976	0,914	0,914
CHB-12	0,536	0,785	0,781
CHB-13	0,353	0,788	0,786
CHB-14	0,333	0,841	0,840
CHB-15	0,116	0,935	0,923
CHB-16	0,529	0,667	0,667
CHB-17	0,813	0,649	0,650
CHB-18	0,289	0,946	0,944
CHB-19	1,000	0,887	0,887
CHB-20	0,711	0,933	0,933
CHB-21	0,813	0,893	0,893
CHB-22	0,860	0,870	0,870
CHB-23	0,667	0,834	0,832
Ortalama değer	0,724	0,817	0,816
STD	0,257	0,107	0,138



Şekil 3.14. RUSBoost yöntemi ile çapraz hasta deneyi sonuçlarının grafiksel gösterimi

Çizelge 6. LogitBoost yöntemi ile çapraz hasta deneyi sonuçları


Kişi No	Duyarlılık	Özgüllük	Doğruluk
CHB-01	0,827	0,957	0,957
CHB-02	1,000	0,898	0,899
CHB-03	1,000	0,970	0,970
CHB-04	0,738	0,906	0,906
CHB-05	1,000	0,701	0,702
CHB-06	0,640	0,853	0,852
CHB-07	0,973	0,942	0,942
CHB-08	0,755	0,897	0,895
CHB-09	1,000	0,766	0,767
CHB-10	1,000	0,854	0,855
CHB-11	0,819	0,964	0,963
CHB-12	0,544	0,928	0,921
CHB-13	0,265	0,878	0,874
CHB-14	0,333	0,846	0,844
CHB-15	0,074	0,990	0,976
CHB-16	0,588	0,802	0,802
CHB-17	0,875	0,884	0,883
CHB-18	0,763	0,984	0,983
CHB-19	1,000	0,983	0,983
CHB-20	0,921	0,942	0,942
CHB-21	0,827	0,957	0,957
CHB-22	0,860	0,974	0,973
CHB-23	0,742	0,941	0,940
Ortalama değer	0,763	0,905	0,904
STD	0,256	0,075	0,074



Şekil 3.15. LogitBoost yöntemi ile çapraz hasta deneyi sonuçların grafiksel gösterimi

Çizelge 7. RobustBoost yöntemi ile çapraz hasta deneyi sonuçları

Kişi No	Duyarlılık	Özgüllük	Doğruluk
CHB-01	0,840	0,948	0,948
CHB-02	1,000	0,861	0,861
CHB-03	1,000	0,959	0,959
CHB-04	0,762	0,869	0,869
CHB-05	1,000	0,675	0,677
CHB-06	0,760	0,780	0,780
CHB-07	0,973	0,941	0,941
CHB-08	0,867	0,834	0,834
CHB-09	1,000	0,797	0,797
CHB-10	1,000	0,831	0,832
CHB-11	0,843	0,961	0,960
CHB-12	0,520	0,915	0,909
CHB-13	0,309	0,846	0,843
CHB-14	0,292	0,861	0,860
CHB-15	0,037	0,988	0,974
CHB-16	0,529	0,768	0,768
CHB-17	0,969	0,856	0,856
CHB-18	0,711	0,977	0,976
CHB-19	0,963	0,979	0,979
CHB-20	0,737	0,931	0,930
CHB-21	0,840	0,948	0,948
CHB-22	0,820	0,969	0,968
CHB-23	0,727	0,917	0,916
Ortalama değer	0,761	0,887	0,886
STD	0,256	0,080	0,079



Şekil 3.16. RobustBoost yöntemi ile çapraz hasta deneyi sonuçların grafiksel gösterimi

Önerilen üç yönteme (RUSBoost, LogitBoost ve RobustBoost) ait ortalama çapraz hasta doğrulama sonuçları Çizelge-8 de verilmektedir. Bu çizelgeni incelendiğinde Çapraz hasta deneylerinde de en iyi sonuçların LogitBoost algoritmasından elde edildiği gözlenmektedir.

Çizelge 8. Ortalama çapraz hasta deneyi sonuçları

	Duyarlılık	Özgüllük	Doğruluk
RUSBoost	0,725	0,810	0,797
LogitBoost	0,762	0,905	0,903
RobustBoost	0,761	0,887	0,886

3.9.3. Deneysel sonuçların literatür ile karşılaştırması

Bu bölümde elde edilen deneysel sonuçlar literatürde yapılan benzer çalışmalar ile karşılaştırılmaktadır. Her iki deney türünde en iyi sonuçlar Logit Boost yöntemiyle elde edildiği için bu yöntemin sonuçları diğer yöntemler ile karşılaştırılmıştır. Bu karşılaştırmaya yönelik çapraz doğrulama deney sonuçları Çizelge-9'da verilmiştir. Bu

çizelgeni dikkatlice incelendiğinde önerilen yöntemin sonuçları literatürde var olan sonuçların birçoğundan daha iyi olduğu görülmektedir. Ancak literatürde var olan bazı çalışmaların sonuçları önerilen yöntemden iyi olduğu da görülmektedir. Benzer şekilde çapraz hasta sonuçları ise Çizelge-10 da verilmektedir. Bu çizelgede incelendiğinde özgüllük ve doğruluk açısından önerilen yöntem literatürdeki yöntemlerden iyi olmasının rağmen duyarlılık dikkate alındığında literatürde daha iyi sonuçlar olduğu görülmektedir.

Çizelge 9. Çapraz doğrulama deney sonuçlarının literatür ile karşılaştırılması

	Duyarlılık	Özgüllük	Doğruluk
LSTM (Xinghua Yao, et al. 2019)	0,844	0,843	0,8435
CNN (Xinghua Yao, et al. 2019)	0,848	0,81	0,829
BiLSTM (Xinghua Yao, et al. 2019)	0,87	0,886	0,878
BNN Hold-out (Aarabi et al 2006)	0,91	0,95	0,93
ME Hold-out (Subasi et al 2007)	0,95	0,94	0,945
SVM Hold-out (Chandaka et al 2009)	0,92	1,000	0,955
ELM Hold-out (Yuan et al 2010)	0,925	0,96	0,965
LDA Hold-out (Khan et al 2012)	0,836	1,000	0,918
SVM Hold-out (Nicolaou et al 2012)	0,943	0,933	0,938
BLDA Hold-out (Zhou et al. 2013)	0,952	0,967	0,966
SVM Hold-out (Kumar et al. 2014)	0,98	0,967	0,985
SVM (Song et al. 2016)	0,945	1,000	1,000
Bu çalışmada Önerilen (LogitBoost)	0,94	0,939	0,939

Çizelge 10. Çapraz hasta deney sonuçlarının literatür ile karşılaştırılması

	Duyarlılık	Özgüllük	Doğruluk
LSTM (Xinghua Yao et al. 2019)	0,863	0,828	0,845
CNN (Xinghua Yao et al. 2019)	0,834	0,887	0,86
BiLSTM (Xinghua Yao, et al. 2019)	0,87	0,886	0,878
Bu çalışmada Önerilen (LogitBoost)	0,762	0,905	0,903

4. SONUÇ ve ÖNERİLER

Bu tez çalışmasında temel olarak EEG sinyalleri ile epileptik nöbetlerin otomatik olarak belirlenebilmesi için çeşitli yöntemler önerilmiştir. Bu sayede Nörologların işlerini kolaylaştırmak ve kişiden kaynaklanan hataların azaltılması hedeflenmiştir. Bu amaç ile kolektif öğrenmeye dayalı makine öğrenme algoritmalarından RUSBoost, LogitBoost ve RobustBoost algoritmaları kullanarak öğrenme işlemi gerçekleştirilmiştir. Bu algoritmalarda öznitelik olarak MFCC katsayıları kullanılmıştır. Önerilen RUSBoost, LogitBoost ve RobustBoost algoritmalarının performansının ölçmek için literatürde kullanılan CHB-MIT veri seti kullanılmıştır. Bu veri setinde 23 kişiden alınmış çok kanallı EEG sinyalleri bulunmaktadır. Bu veri setinden 10s'lik parçalar alınarak bu parçaların MFCC katasılları çıkarılarak veri seti oluşturulmuştur. Alınan bu 10s'lik bölümde epileptik nöbet varsa bu veriye ait etiket pozitif yoksa bu veriye ait etiket negatif olarak seçilmiştir. Önerilen yöntemin performansını ölçmek için öğrenme algoritmaları eğitimi çapraz doğruluk ve çapraz hasta olmak üzere iki farklı türde yapılmış ve deneysel sonuçlar buna göre verilmiştir. Deneysel sonuçlarda bu yöntemlerden LogitBoost yönteminin daha başarılı olduğu gözlenmiştir. Ayrıca deney sonuçları literatür ile karşılaştırılmış ve elde edilen sonuçların literatürde var olan birçok yöntemden daha iyi olduğu gözlenmiştir. Bu tez çalışması kapsamında elde edilen en iyi sonuçlar çapraz doğrulama deneyi için duyarlılık, özgüllük ve doğruluk oranları yaklaşık olarak sırayla %94, %94 ve %94 ve çapraz hasta için ise %76, %90 ve %90 olarak elde edilmiştir.

KAYNAKLAR

- A. Aarabi and B. He. 2012. A rule-based seizure prediction method for focal neocortical epilepsy," *Clinical Neurophysiology*, vol. 123, no. 6, pp. 1111-1122.
- A. Aarabi, R. Fazel-Rezai, and Y. Aghakhani. 2009. A fuzzy rule-based system for epileptic seizure detection in intracranial EEG, *Clinical Neurophysiology*, vol. 120, no. 9, pp. 1648–1657.
- A. A. Dingle, R. D. Jones, G. J. Carroll, and W. R. Fright. 1993. A multistage system to detect epileptiform activity in the eeg, *Biomedical Engineering, IEEE Transactions on*, vol. 40, no. 12, pp. 1260-1268.
- A. Aarabi, R. Fazel-Rezai, and Y. Aghakhani. 2009. Eeg seizure prediction: measures and challenges, in *Engineering in Medicine and Biology Society Book*.
- A. Kumar and M. H. Kolekar. 2014. Machine learning approach for epileptic seizure detection using wavelet analysis of EEG signals, in *Medical Imaging, m-Health and Emerging Communication Systems (MedCom)*, International Conference on. IEEE, 2014, pp. 412–416.
- A. Schad, K. Schindler, B. Schelter, T. Maiwald, A. Brandt, J. Timmer, and A. Schulze-Bonhage. 2008. Application of a multivariate seizure detection and prediction method to non-invasive and intracranial long-term eeg recordings *Clinical neurophysiology*, vol. 119, no. 1, pp. 197-211.
- A. Subasi. 2007. EEG signal classification using wavelet feature extraction and a mixture of expert model, *Expert Systems with Applications*, vol. 32, no. 4, pp. 1084–1093
- B. Litt and J. Echauz. 2002. Prediction of epileptic seizures, *The Lancet Neurology*, vol. 1, no. 1, pp. 22-30.
- C. A. Teixeira, B. Direito, M. Bandarabadi, M. Le Van Quyen, M. Valderrama, B. Schelter, A. Schulze-Bonhage, V. Navarro, F. Sales, and A. Dourado. 2014. Epileptic seizure predictors based on computational intelligence techniques: A comparative study with 278 patients, *Computer methods and programs in biomedicine*, vol. 114, no. 3, pp. 324-336.
- Chen, Duo. 2017. A high-performance seizure detection algorithm based on Discrete Wavelet Transform (DWT) and EEG. *PloS one* 12.3.
- C. Seiffert, T. M. Khoshgoftar, J. Van Hulse and A. Napolitano. 2010. RUSBoost: A Hybrid Approach to Alleviating Class Imbalance, *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, vol. 40, no. 1, pp. 185-197
- D. Kumar, G. Aggarwal, R. Sehgal, A. Das, U. Lahiri, and A. Dutta. 2015. Engagementsensitive interactive neuromuscular electrical therapy system for post-stroke balance rehabilitation-a concept study.
- D. K. Binder and S. R. Haut. 2013. Toward new paradigms of seizure detection, *Epilepsy & Behavior*, vol. 26, no. 3, pp. 247-252.
- D. H. Bailey and P. N. Swartztrauber. 1991. The fractional Fourier transform and applications, *SIAM Rev.*, vol. 33, no. 3, pp. 389-404.
- E. Magiorkinis, A. Diamantis, and K. Sidiropoulou. 2011. Hallmarks in the history of epilepsy: from antiquity till the twentieth century, *intech open access Publisher*.

- E. Niedermeyer and F. L. da Silva. 2005. *Electroencephalography: basic principles, clinical applications, and related fields*. Lippincott Williams & Wilkins.
- F. Mormann, R. G. Andrzejak, C. E. Elger, and K. Lehnertz. 2007. Seizure prediction: the long and winding road," *Brain*, vol. 130, no. 2, pp. 314-333.
- F. Mormann, K. Lehnertz, P. David, and C. E. Elger. 2000. Mean phase coherence as a measure for phase synchronization and its application to the eeg of epilepsy patients, *Physica D: Nonlinear Phenomena*, vol. 144, no. 3, pp. 358-369.
- F. Mormann, T. Kreuz, R. G. Andrzejak, P. David, K. Lehnertz, and C. E. Elger. 2003. Epileptic seizures are preceded by a decrease in synchronization, *Epilepsy research*, vol. 53, no. 3, pp. 173-185.
- Friedman, J., Hastie, T., and Tibshirani, R. 2000. Special invited paper. additive logistic regression: A statistical view of boosting. *Annals of statistics*, pages 337-374.
- G. H. Klem, H. O. Luders, H. Jasper, and C. Elger. 1999. The ten-twenty electrode system of the international federation, *Electroencephalogr Clin Neurophysiol*, vol. 52, no. suppl., p. 3.
- G. M. Weiss, 2004. Mining with rarity: A unifying framework, *SIGKDD Explor.*, vol. 6, no. 1, pp. 7-19.
- G. Xu, J. Wang, Q. Zhang, S. Zhang, and J. Zhu. 2007. A spike detection method in eeg based on improved morphological filter, *Computers in biology and medicine*, vol. 37, no. 11, pp. 1647-1652.
- H. R. Mohseni, A. Maghsoudi, and M. B. Shamsollahi. 2006. Seizure detection in eeg signals: A comparison of different approaches, in *Proc. Of the 28th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, vol. Supplement.
- H. H. Lange, J. P. Lieb, J. Engel, and P. H. Crandall. 1983. Temporo-spatial patterns of pre-ictal spike activity in human temporal lobe epilepsy, *Electroencephalography and clinical neurophysiology*, vol. 56, no. 6, pp. 543-555.
- J. Dorfmeister, M. Frei, D. Lerner, I. Osorio, and J. Ralston. 1999. System for the prediction, rapid detection, warning, prevention, or control of changes in activity states in the brain of a subject, *US Patent 5,995,868*.
- L. Breiman. 1996. Bagging predictors. *Machine learning*, vol. 24, no. 2, pp. 123-140.
- M. Galar, A. Fernandez, E. Barrenechea, H. Bustince and F. Herrera. 2012. A Review on Ensembles for the Class Imbalance Problem: Bagging-, Boosting-, and Hybrid-Based Approaches, in *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 42, no. 4, pp. 463-484.
- M. Le Van Quyen, J. Martinerie, V. Navarro, P. Boon, M. D'Have, C. Adam, B. Renault, F. Varela, and M. Baulac. 2001. schad2008 application, *The Lancet*, vol. 357, no. 9251, pp. 183-188.
- M. Winterhalder, T. Maiwald, H. Voss, R. Aschenbrenner-Scheibe, J. Timmer, and A. Schulze-Bonhage. 2003. The seizure prediction characteristic: a general framework to assess and compare seizure prediction methods, *Epilepsy & Behavior*, vol. 4, no. 3, pp. 318-325.
- M. Le Van Quyen, J. Martinerie, M. Baulac, and F. Varela. 1999. Anticipating epileptic seizures in real time by a non-linear analysis of similarity between eeg recordings, *Neuroreport*, vol. 10, no. 10, pp. 2149-2155.

- N. Ahammad, T. Fathima, and P. Joseph. 2014. Detection of epileptic seizure event and onset using eeg, *BioMed research international*, vol. 2014.
- N. Nicolaou and J. Georgiou. 2012. Detection of epileptic electroencephalogram based on permutation entropy and support vector machines, *Expert Systems with Applications*, vol. 39, no. 1, pp. 202–209.
- Norzaliza M. Nor, Abdul Wahab. 2011. Norhaslinda Kamaruddin and Hariyati Majid, "Post Accident Analysis of Driver Affection, 15th International Symposium on Consumer Electronics, 978-1-61284-842.
- P. Maragos and R. W. Schafer. 1987. Morphological filters-part i: Their set-theoretic analysis and relations to linear shift-invariant filters," *Acoustics, Speech and Signal Processing, IEEE Transactions on*, vol. 35, no. 8, pp. 1153-1169.
- P. Maragos and R. W. Schafer. 1987. Morphological filters-part ii: Their relations to median, order-statistic, and stack filters," *Acoustics, Speech and Signal Processing, IEEE Transactions on*, vol. 35, no. 8, pp. 1170-1184.
- P. Mirowski, D. Madhavan, Y. LeCun, and R. Kuzniecky. 2009. Classification of patterns of eeg synchronization for seizure prediction, *Clinical neurophysiology*, vol. 120, no. 11, pp. 1927-1940..
- Q. Yuan, W. Zhou, S. Li, and D. Cai. 2011. Epileptic EEG classification based on extreme learning machine and nonlinear features, *Epilepsy research*, vol. 96, no. 1-2, pp. 29–38.
- R. A. Scott, S. D. Lhatoo, and J. W. Sander. 2001. The treatment of epilepsy in developing countries: where do we go from here, *Bulletin of the World Health Organization*, vol. 79, no. 4, pp. 344-351.
- P. R. Carney, S. Myers, and J. D. Geyer. 2011. Seizure prediction: methods," *Epilepsy & Behavior*, vol. 22, pp. S94-S101.
- R. X. Gao and R. Yan. 2011. From fourier transform to wavelet transform: A historical perspective, *Wavelets Springer*, pp. 17-32.
- R. Panda, P. Khobragade, P. Jambhule, S. Jengthe, P. Pal, and T. Gandhi, 2010. Classification of eeg signal using wavelet transform and support vector machine for epileptic seizure detection, in *Systems in Medicine and Biology (ICSMB)*, 2010 International Conference on IEEE, pp. 405-408.
- R. G. Andrzejak, K. Lehnertz, F. Mormann, C. Rieke, P. David, and C. E. Elger. 2001. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state, *Physical Review E*, vol. 64, no. 6, p. 061907.
- R. M. Haralick, S. R. Sternberg, and X. Zhuang. 2000. Image analysis using mathematical morphology," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, no. 4, pp. 532-550.
- S.-A. Lee, D. D. Spencer, and S. S. Spencer. 2000. Intracranial eeg seizure-onset patterns in neocortical epilepsy, *Epilepsia*, vol. 41, no. 3, pp. 297-307.
- S. Chandaka, A. Chatterjee, and S. Munshi. 2009. Cross-correlation aided support vector machine classifier for classification of EEG signals, *Expert Systems with Applications*, vol. 36, no. 2, pp. 1329–1336.
- S. Ramgopal, S. Thome-Souza, M. Jackson, N. E. Kadish, I. S. Fernandez, J. Klehm, W. Bosl, C. Reinsberger, S. Schachter, and T. Loddenkemper. 2014. Seizure

- detection, seizure prediction, and closed-loop warning systems in epilepsy, *Epilepsy & Behavior*, vol. 37, pp. 291-307.
- S. Li, W. Zhou, Q. Yuan, and Y. Liu. 2013. Seizure prediction using spike rate of intracranial eeg, *Neural Systems and Rehabilitation Engineering*, IEEE Transactions on, vol. 21, no. 6, pp. 880-886.
- Tae-Gu Kwon, Jeong-Hoon Shin. 2009. An analysis of Brain waves characteristic with Acupuncture Feedback using MFCC", 10th ACIS International Conference on Software Engineering, Artificial Intelligences, Networking and Parallel, Distributed Computing 978-0-7695-3642-2/09.
- Tahernezhad-Javazm, Farajollah, Vahid Azimirad, and Maryam Shoaran. 2018. A review and experimental study on the application of classifiers and evolutionary algorithms in EEG-based brain-machine interface systems." *Journal of neural engineering* 15.2, 021007.
- T. Gandhi, B. K. Panigrahi, M. Bhatia, and S. Anand. 2010. Expert model for detection of epileptic activity in eeg signature, *Expert Systems with Applications*, vol. 37, no. 4, pp. 3513-3520.
- U. R. Acharya, S. V. Sree, G. Swapna, R. J. Martis, and J. S. Suri. 2013. Automated eeg analysis of epilepsy: a review, *Knowledge-Based Systems*, vol. 45, pp. 147-165.
- V.Rathikarani, P.Dhanalakshmi, 2013. Automatic Classification of ECG signal for Identifying Arrhythmia, *International Journal of Advanced Research in Computer Science and Software Engineering* Volume 3, Issue 9.
- V. Srinivasan, C. Eswaran, and N. Sriraam. 2007. Approximate entropy-based epileptic eeg detection using arti_cial neural networks," *Information Technology in Biomedicine*, IEEE Transactions on, vol. 11, no. 3, pp. 288-295.
- Wikipedia. 2016. Mathematical morphology ,wikipedia, the free encyclopedia.
- W. H. Organization, The World Health Report 2001: Mental health: new understand- ing, new hope. World Health Organization.
- W. J. Freeman. 2000. A neurobiological interpretation of semiotics: meaning, representation, and information, *Information Sciences*, vol. 124, no. 1, pp. 93-102.
- W. Truccolo, J. A. Donoghue, L. R. Hochberg, E. N. Eskandar, J. R. Madsen, W. S. Anderson, E. N. Brown, E. Halgren, and S. S. Cash. 2011. Single-neuron dynamics in human focal epilepsy, *Nature neuroscience*, vol. 14, no. 5, pp. 635-641.
- W. Zhou, Y. Liu, Q. Yuan, and X. Li. 2013.Epileptic seizure detection using lacunarity and bayesian linear discriminant analysis in intracranial EEG, *IEEE Transactions on Biomedical Engineering*, vol. 60, no. 12, pp. 3375-3381.
- Y. Freund. 2009. A more robust boosting algorithm. arXiv preprint arXiv:0905.2138.
- Y. Yuan.2010. Detection of epileptic seizure based on eeg signals,2010. in *Image and Signal Processing (CISP)*, 2010 3rd International Congress on IEEE, vol. 9, pp. 4209-4211.
- Y. Zheng, G. Wang, K. Li, G. Bao, and J. Wang. 2004. Epileptic seizure prediction using phase synchronization based on bivariate empirical mode decomposition, *Clinical Neurophysiology*, vol. 125, no. 6, pp. 1104-1111.
- Y. U. Khan, N. Rafiuddin, and O. Farooq. 2012. Automated seizure detection in scalp EEG using multiple wavelet scales, in *Signal Processing, Computing and Control*

- (ISPPCC), 2012 IEEE International Conference on IEEE, pp. 1–5.
- Zhang, Bo. 2017. Classification based on neuroimaging data by tensor boosting. International Joint Conference on Neural Networks (IJCNN). IEEE.
- Zhang P., Lammert P.E. and Crespi V.H. 1998. Plastic Deformations of Carbon Nanotubes", *Phys. Rev. Lett.*, 81, pp.5346-5349.
- Zhang P., Huang Y., Gao H. and Hwang K.C. 2002. Fracture Nucleation in Single-wall Carbon Nanotubes Under Tension. *Continuum Analysis Incorporating Interatomic Potential*, *J. Appl. Mech. Trans. ASME*, 69, pp.454-458.
- Zhang P., Huang Y., Geubelle P.H., Klein P. and Hwang K.C. 2002b. The Elastic Modulus of Single-wall Carbon Nanotubes. *Continuum Analysis Incorporating Interatomic Potential*, *Int. J. Solids Struc.*, 39, pp.3893-3906.
- Z. Song, J. Wang, L. Cai, B. Deng, and Y. Qin. 2016. Epileptic seizure detection of electroencephalogram based on weighted-permutation entropy, in *Intelligent Control and Automation (WCICA)*, 2016 12th World Congress on. IEEE, pp. 2819–2823.
- Zhou X., Zhou J. and Ou-Yang Z. 2000. Strain Energy and Young's Modulus of Single-wall Carbon Nanotubes Calculated from Electronic Energy-bond Theory, *Phys. Rev. B*, 62, pp.13692-13696.

ÖZGEÇMİŞ

1990 yılında İRAN/Macoo'de doğdu. İlk, orta ve lise öğrenimini İRAN/Macoo'de tamamladı. 2008 yılında başladığı Orumiye İslami Azad Üniversitesi, Mühendislik Fakültesi, Elektrik - Elektronik Mühendisliği bölümünden 2012 yılında mezun oldu. Evli ve bir çocuk annesidir.

