T.C.
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MFCC DESTEKLİ MAKİNA ÖĞRENMESİ ALGORİTMALARI İLE FOKAL/NON-FOKAL EEG KAYITLARININ SINIFLANDIRILMASI

Delal ŞEKER

YÜKSEK LİSANS TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DİYARBAKIR
Temmuz-2021

T.C.
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MFCC DESTEKLİ MAKİNA ÖĞRENMESİ ALGORİTMALARI İLE FOKAL/NON-FOKAL EEG KAYITLARININ SINIFLANDIRILMASI

Delal ŞEKER

YÜKSEK LİSANS TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DİYARBAKIR
Temmuz-2021

T.C.

DİCLE ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ

DİYARBAKIR

Delal ŞEKER tarafından yapılan "MFCC Destekli Makina Öğrenmesi Algoritmaları ile Fokal/Non-fokal EEG Kayıtlarının Sınıflandırılması" konulu bu çalışma, jürimiz tarafından Elektrik-Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Mehmet Siraç ÖZERDEM

Üye : Dr. Öğr. Üyesi Abdulnasır YILDIZ

Üye : Dr. Öğr. Üyesi Ömer TÜRK

Tez Savunma Sınavı Tarihi: 13/07/2021

Yukarıdaki bilgilerin doğruluğunu onaylarım.

.../...../.....

Prof. Dr. Neslihan DALKILIÇ

ENSTİTÜ MÜDÜR V.

TEŞEKKÜR

Bu tez çalışması boyunca birikimlerini ve tecrübelerini benden esirgemeyen değerli danışmanım Prof. Dr. Mehmet Siraç ÖZERDEM'e yol göstericiliği adına teşekkürlerimi sunuyorum.

Her durumda desteğini, gücünü, sevgisini ve inancını üzerimde hissettiğim güçlü anneme, yardımlarıyla ve yoluma fener tutan ışığıyla beni aydınlattığı için değerli eşim ve aynı zamanda meslektaşım Mesut ŞEKER'e, bu uzun ve meşakkatli süreçte bize bir sürpriz olarak gelen oğlum Mustafa Mesut'a minnet doluyum.

İÇİNDEKİLER

		Sayfa
TEŞEKKÜR……		I
İÇİNDEKİLER……		II
ÖZET……		III
ABSTRACT……		IV
ÇİZELGE LİSTESİ……		V
ŞEKİL LİSTESİ……		VI
KISALTMA VE SİMGELER……		VII
1.	**GİRİŞ**……	1
1.1.	Tez Çalışmasının Amacı ve İzlenilen Yöntem……	6
1.2.	Tez Çalışmasının İçeriği……	7
2.	**KAYNAK ÖZETLERİ**……	9
2.1.	MFCC Özniteliğinin EEG Çalışmalarındaki Performansı……	9
2.2	Bern Barcelona Veri Seti İçeren Fokal / Non-Fokal EEG Çalışmaları……	12
2.3	Hauz Khas Veri Seti İçeren İktal / Pre-iktal / İnter-iktal EEG Çalışmaları……	17
3.	**MATERYAL VE METOT**……	19
3.1.	Kullanılan Veri Setleri ……	18
3.2.	Metot……	22
3.2.1.	Mel Frekansı Kepstrum Analizi……	23
3.2.2	Z Skor Normalizasyonu ve Temel Bileşenler Analizi……	26
3.2.3	Sınıflandırıcılar……	27
3.2.4.	Performans Ölçümleri……	32
4.	**BULGULAR VE TARTIŞMA**……	35
4.1.	Hauz Khas EEG Kayıtlarının (Pre-iktal / İktal / İnter-iktal EEG) Sınıflandırılmasından Elde Edilen Bulgular……	36
4.2.	Bern Barcelona EEG Kayıtlarının (Fokal / Non-fokal EEG) Sınıflandırılmasından Elde Edilen Bulgular……	38
5.	**SONUÇ VE ÖNERİLER**……	45
6.	**KAYNAKLAR**……	49
ÖZGEÇMİŞ……		55

ÖZET

MFCC DESTEKLİ MAKİNA ÖĞRENMESİ ALGORİTMALARI İLE FOKAL/NON-FOKAL EEG KAYITLARININ SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Delal ŞEKER

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

2021

Beyinde anormal elektriksel yayılma sonucu meydana gelen ve tekrarlı nöbetler şeklinde davranış sergileyen epilepsi önemli bir nörolojik hastalık olarak kabul edilmektedir. Dünya sağlık örgütünün (WHO) raporlarına göre dünya genelinde 50 milyondan fazla kişide bu hastalık bulunmaktadır. Epilepsi hastalığına gelişkin ilaç teknolojilerine rağmen hastaların %33' ü ilaç tedavisine cevap vermemekte ve gelecekte onları hastalığın tahmin edilemez diğer boyutları beklemektedir.

Epilepsi hastalarının tespitinde kullanılan EEG, beynin elektriksel aktivitesi hakkında bilgi verme kabiliyetine sahip olduğu için epileptik nöbetlerin varlığı ve diğer anomalilerin tespitinde elverişli bir standart olarak göze çarpar. Lokasyon olarak epilepsi genel anlamda 2 türe ayrılır. Fokal epilepside beynin spesifik bir bölümü hastalıktan etkilenir. Diğer taraftan non-fokal epilepside (jeneralize) nöbetlerde direkt etkilenmeseler bile beynin birçok alanı lokal anlamda etkilenir. Bunlara ek olarak EEG iktal ve inter-iktal aktivitelerin tespitinde de kullanılır. İktal EEG iğneciklerden oluşan nöbet anını, inter-iktal EEG ise nöbet arası süreyi ifade eder. EEG kayıtlarının gözlemsel olarak analizi hem zaman kaybı hem de hastalık teşhisinde insan kaynaklı hata nedenlerinden biridir. Otomatik bir sınıflandırma yaklaşımı, farklı sinyal karakteristiklerini ayırt etmede ve klinisyenlere karar aşamasında yardım etme durumunda bir ihtiyaç haline gelmiştir.

Bu tez çalışmada, Mel Frekansı Kepstral katsayıları (MFCC) ve makine öğrenmesi algoritmaları ile Bern Barcelona veri seti kapsamındaki fokal/non-fokal epileptik EEG kayıtlarının sınıflandırılması amaçlanmıştır. Bu amaç doğrultusunda, MFCC destekli makine öğrenmesi algoritmaları ile Hauz Khas veri seti kapsamındaki pre-iktal / iktal / inter-iktal EEG kayıtlarının sınıflandırılması sonrası MFCC'nin zor bir veri seti üzerindeki başarı performansı teyit edilmiştir. Başarılı bulunan MFCC destekli makine öğrenmesi algoritmaları ile Bern Barcelona veri seti kapsamındaki fokal/non-fokal EEG kayıtlarının sınıflandırılması amaçlanmıştır. Çalışmada MFCC öznitelik kümelerine z-score normalizasyonu ve Temel Bileşen Analizi uygulanarak normalize edilmiş optimum alt öznitelik kümelerine ulaşılmıştır. Sınıflandırma aşamasında ise 7 farklı konvansiyonel makina öğrenmesi yönteminden faydalanılmıştır.

Çalışma sonucunda iktal vs. inter-iktal, iktal vs. pre-iktal ve inter-iktal vs. pre-iktal sınıflandırmada grupların tümü Quadratik Diskriminant Analiz, Lojistik Regresyon ve Kübik DVM ile %100 oranında doğruluk, hassasiyet, özgüllük ve f1-skor performans metriklerine ulaşılmıştır. Çoklu sınıflandırma olan iktal vs. pre-iktal vs. inter-iktal aşamasında ise sadece Quadratik Diskriminant Analiz algoritması verilerin tümünü doğru ayrıştırabilmiştir. Fokal vs. Non-fokal EEG sınıflandırılmasında Quadratik Diskriminant Analiz, Lojistik Regresyon ve Kübik DVM ile tüm sınıflar doğru olarak ayrıştırılmıştır.

Mevcut tez çalışması farklı nörolojik hastalıklara uygulanarak tez çalışmasında önerilen yöntemin ve belirtilen çıkarımların daha netlik kazanacağı öngörülmektedir. Klinisyenler ve hekimler mevcut metodolojiyi kendi verilerine uygulayıp daha önce elde ettikleri sonuçlarla karşılaştırabilir ve validasyon yoluna gidebilirler.

Anahtar Kelimeler: epilepsi, fokal/non-fokal EEG, MFCC, sınıflandırma, makine öğrenmesi

ABSTRACT

FOCAL/NON-FOCAL EEG RECORDS CLASSIFICATION WITH MFCC BASED MACHINE LEARNING ALGORITHMS

MsC THESIS

Delal ŞEKER

DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING
INSTITUTE OF NATURAL AND APPLIED SCIENCES
UNIVERSITY OF DICLE

2021

Epilepsy, which occurs as a result of abnormal electrical spread in the brain and behaves as repetitive seizures, is accepted as an important neurological disease. According to the reports of the World Health Organization (WHO), more than 50 million people worldwide have this disease. Despite advanced drug technologies for epilepsy, 33% of patients do not respond to drug treatment and other unpredictable dimensions of the disease await them in the future.

EEG, which is used in the detection of epilepsy patients, stands out as a convenient standard for the presence of epileptic seizures and other anomalies, as it has the ability to provide content for the electrical activity of the brain. In terms of location, epilepsy is generally divided into 2 types. In focal epilepsy, a specific part of the brain is affected by the disease. On the other hand, many parts of the brain are affected locally, even if they are not directly affected in non-focal epilepsy (generalized) seizures. In addition to these, EEG is also used to detect ictal and inter-ictal activities. Ictal EEG refers to the moment of seizure consisting of pins, and inter-ictal EEG refers to the time between seizures. Observational analysis of EEG recordings is both a waste of time and one of the causes of human error in disease diagnosis. An automated classification approach has become a necessity in distinguishing between different signal characteristics and assisting clinicians in decision making.

In this thesis, it is aimed to classify the focal/non-focal epileptic EEG recordings within the Bern Barcelona dataset with Mel Frequency Cepstral Coefficients (MFCC) and machine learning algorithms. For this purpose, the high performance of MFCC on a difficult data set was confirmed after the classification of pre-ictal / ictal / inter-ictal EEG recordings in the Hauz Khas dataset with MFCC based machine learning algorithms. It is aimed to classify the focal/non-focal EEG recordings within the Bern Barcelona dataset with the provided MFCC supported machine learning algorithms. In the study, normalized optimum sub-feature sets were obtained by applying z-score normalization and Principal Component Analysis to MFCC feature sets. In the classification stage, 7 different conventional machine learning methods were used.

As a result of the study, ictal vs. inter-ictal, ictal vs. pre-ictal vs inter-ictal vs. pre-ictal classification, 100% accuracy, sensitivity, specificity, and f1-score performance metrics were achieved for all groups with Quadratic Discriminant Analysis, Logistic Regression and Cubic SVM. For multi-way classification approach of ictal vs. pre-ictal vs. inter-ictal , only the Quadratic Discriminant Analysis algorithm was able to parse all the data correctly. Focal vs. non-focal EEG classification, all classes were correctly differentiated by Quadratic Discriminant Analysis, Logistic Regression and Cubic SVM. It is predicted that the method proposed in the thesis study and the stated inferences will become clearer by applying the current thesis study to different neurological diseases. Clinicians and physicians can apply the current methodology to their own data, compare it with their previous results and have a chance for validation.

Keywords: epilepsy, focal/non-focal EEG, MFCC, classification, machine learning

ÇİZELGE LİSTESİ

Çizelge No		Sayfa
Çizelge 3.1.	İkili sınıflandırma performans ölçümü için kullanılan metrikler	33
Çizelge 3.2.	Çoklu sınıflandırma performans ölçümü için kullanılan metrikler	34
Çizelge 4.1.	Pre-iktal / İnter-iktal sınıflandırma sonuçları ve performans metrikleri	36
Çizelge 4.2.	Pre-iktal / iktal sınıflandırma sonuçları ve performans metrikleri	37
Çizelge 4.3.	İnter-iktal / iktal sınıflandırma sonuçları ve performans metrikleri	37
Çizelge 4.4.	Pre-iktal / İnter-iktal / İktal sınıflandırma sonuçları ve performans metrikleri	38
Çizelge 4.5.	Fokal / Non-fokal sınıflandırma sonuçları ve performans metrikleri	39
Çizelge 4.6.	Tez kapsamında değerlendirilen EEG veri setleri ile literatürde yapılan diğer çalışmalar.	41

ŞEKİL LİSTESİ

Şekil No		Sayfa
Şekil 1.1.	Fokal epilepsi hastası bir bireyden alınan EEG kayıtları. En sol: Elektrot lokasyonları, orta: hastaya ait inter-iktal deşarj kayıtları, sağ: ok'la gösterilen nöbet başlangıç anı.	3
Şekil 1.2.	Genel olarak bilinen epileptik form EEG örüntüleri	4
Şekil 1.3.	Epilepsi hastalarında nöbet anının başlangıcında görülen yaygın EEG örüntüleri	4
Şekil 1.4.	Ameliyat öncesi fokal epilepsi olan bir hastadan alınan EEG kayıtları. Nöbet başladığı an (*), sırasıyla arka plan aktivitesinde azalma, hızlı bir aktivite seyri ve ardından gerçekleşen düşük potansiyel seyri görülmektedir.	5
Şekil 1.5.	Tez çalışması süresince izlenilen işlem adımları	6
Şekil 3.1.	(a) 5'er saniyelik x-y Fokal / Non-fokal EEG veri çiftlerine ait örnek kayıtları (b) Çıkarılan 13 adet MFCC özniteliklerine ait katsayı değerleri	20
Şekil 3.2.	(a) Pre-iktal / İnter-iktal / İktal EEG kayıtlarına ait 5.12 saniyelik örnek kayıt (b) Çıkarılan 13 adet MFCC özniteliklerine ait katsayı değerleri	21
Şekil 3.3.	Tez kapsamında gerçeklenen EEG sınıflandırma çalışmalarındaki işlem adımları	23
Şekil 3.4.	Kepstrum katsayılarının hesaplanmasında izlenilen yol	24
Şekil 3.5.	Karar ağacı örneği	27
Şekil 3.6.	Giriş vektörünü özellik uzayına ayrılabilir düzeyde aktarma	30
Şekil 3.7.	Veri sınıfının belirlenme süreci	31
Şekil 3.8.	Verinin sınıflandırılması	31

KISALTMA VE SİMGELER

EEG : Elektroensefalogram
MFCC : Mel Frekansı Kesptrum Katsayısı
AKD : Ayrık Kosinüs Dönüşümü
AFD : Ayrık Fourier Dönüşümü
LDA : Lineer Diskriminant Analiz
DVM : Destek Vektör Makinası
FFT : Hızlı Fourier Dönüşümü
PCA : Temel Bileşen Analizi
LDA : Doğrusal Ayrımcılık Analizi
FD : Fourier Dönüşümü
QDA : Qadratik Diskriminant Analiz
LR : Lojistik Regresyon
NB : Naive Bayes
k-NN : k En Yakın Komşuluk
ROC : Alıcı Çalışma Karakteristiği
AUC : Eğri Altında Kalan Alan
FT : Fine Tree
BT : Bagged Treess
Hz : Hertz
GP : Gerçek Pozitif
GN : Gerçek Negatif
YN : Yanlış Negatif
YP : Yanlış Pozitif
c_j : Kepstrum Katsayısı
X[k] : Frekans Spektrumu
X'[k] : Logaritmik Büyüklük
$x[n]$: Zaman Sinyali
A_r : Mel Filtre Katsayısı
g[n] : Alçak geçiren filtre
h[n] : Yüksek geçiren filtre
n : Öznitelik Sayısı
t : Gözlem Sayısı
λ_i : Eigen Değeri

1.GİRİŞ

Tekrarlı nöbetler sonucu karakterize olan epilepsi önemli bir nörolojik hastalık olarak kabul edilip, günümüzde kesin tanı ve tedavisinin mümkün olmadığı bilinmektedir. Normal şartlarda beyin elektriksel impulsları tüm vücuda nöronlar ve nöro-transmitter maddeler aracılığıyla iletir. Fakat epileptik bir nöbet sırasında bu elektriksel dalgalar bozunuma uğrayarak vücutta dengesiz bir reaksiyona sebebiyet verir (Rahman ve ark. 2019). Anormal elektriksel yayılma sonucu meydana gelen epilepsi nöbetlerinin yanında kişilerin fark edemeyeceği kadar hafif seyreden nöbet çeşitleri de bulunmaktadır. Bu nedenle epilepsi nöbetleri hastaya özgü farklılıklar gösterebilir. Dünya sağlık örgütünün (World Health Organization, WHO) raporlarına göre dünya genelinde 50 milyondan fazla kişi bu hastalıktan muzdariptir ve hastaların %80' i düşük ve orta gelirli ülkelerde yaşamaktır. Epilepsi hastalığına gelişkin ilaç teknolojilerine rağmen hastaların %33' ü ilaç tedavisine cevap vermemekte ve gelecekte onları hastalığın tahmin edilemez diğer boyutları beklemektedir. Epilepsi hastalığında nöbet türüne göre tedavi tercihleri değişmektedir. Hastalık tedavisinde etkili ilacın belirlenmesi ve doğru tanının konması, sahip olunan epileptik nöbet türü hakkında detaylı bilgi ile mümkündür.

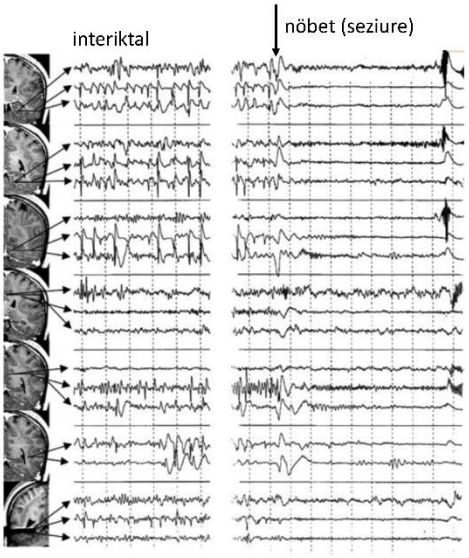
Lokasyon olarak epilepsi genel anlamda 2 türe ayrılır: fokal ve non-fokal (jeneralize) epilepsi. Fokal epilepside beynin spesifik bir bölümü (örneğin beynin bir yarım küresi gibi) hastalıktan etkilenir. Diğer taraftan non-fokal epilepside nöbetlerde doğrudan etkilenmeseler bile beynin birçok alanı lokal anlamda etkilenir (Hussain ve ark. 2018).

Epileptik nöbet tipleri; i) basit parsiyel nöbetler, ii) kompleks parsiyel nöbetler, iii) jeneralize nöbetler ve iv) absans nöbetler şeklinde sınıflandırılabilir. Basit parsiyel nöbetlerde bilinç tamamen açıktır. Nöbet nedeni, beynin ilgili küçük bir alanından kaynaklanır. Temporal, frontal, Parietal ve oksipital lob gibi türleri bulunmaktadır. Kişi; temporal lob epilepside ani korku, olmamış bir olayı olmuş gibi hissetme, hoş olmayan koku ve tat alma, kişileri tanımada güçlük gibi aura olarak adlandırılan belirtiler görür. Frontal lob epilepsi, genelde motor nöron kaynaklı vücut hareketlerine dayalı kasılma ve anormal hareketlere dayalıdır. Hastanın vücudu sola doğru dönüyor veya kasılıyorsa, nöbet sol frontal lob kaynaklıdır. Benzer çaprazlama, sağ frontal lob kaynaklı epilepsi türü için de geçerlidir. Parietal lob epilepsi kaynaklı nöbetlerle hastalar duyusal kaynaklı

garip hislere kapılırlar. Oksipital lob kaynaklı nöbet sırasında ise görme duyusu aracılığı ile farklı renkler, flaş şeklinde parlaklıklar hissedilir. Kompleks parsiyel nöbetlerde; hastada bilinç kaybı ile birlikte çiğneme, yutkunma gibi yeti kayıpları görülebildiği gibi aynı zamanda hasta, düşme kaynaklı fiziki zararlara maruz kalabilir. Diğer bir tür olan jeneralize nöbetler, beynin tüm bölgelerine yayılmış vaziyettedir. Bu nöbet öncesi herhangi bir uyarı veya belirti türü olmadığı için hastalar çeşitli tehlikelere maruz kalabilir. Son olarak absans nöbet ise en sık görülen primer jeneralize (bilateral simetrik) epilepsi nöbetidir. Basit absans; aurasız, ani başlangıçlı ve bitişli, 5-20 saniye süren, nadiren daha uzun süreli şuur kaybı ile karakterize bir nöbet türüdür.

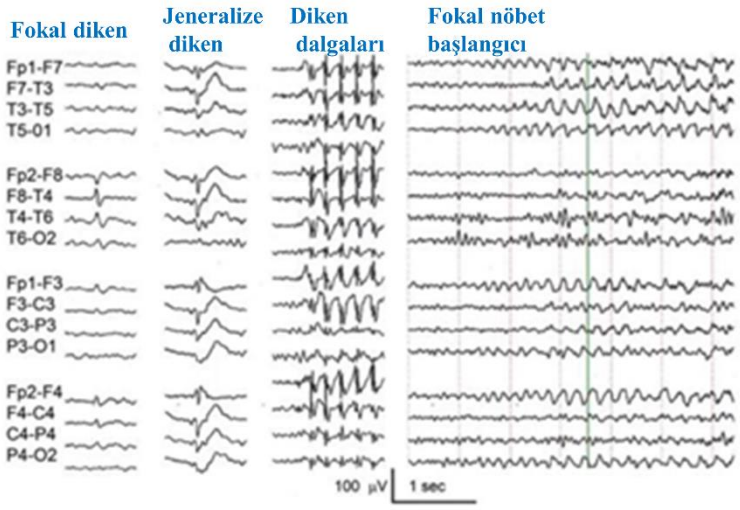
Epilepsi hastalarının çoğunluğu ilaçlara direnç gösterdiğinden diğer bir tabirle ilaç tedavisine cevap vermediğinden tedavi amacıyla çeşitli operasyonlar gereklidir (Pati ve Alexopoulos 2010). Sonuç olarak ameliyat öncesi nöbet ile ilgili bölgenin lokal olarak tespiti, beyne invaziv etki edebilecek riskleri azaltır.

Epilepsi hastalarının tespitinde çeşitli tanı yöntemleri bulunmaktadır. Elektroensefalografi (EEG), manyetik rezonans görüntüleme ve çeşitli kan tetkikleri bunlardan bazılarıdır. EEG, beynin elektriksel aktivitesi hakkında bilgi verme kabiliyetine sahip olduğu için epileptik nöbetlerin varlığı ve diğer anomalilerin tespitinde elverişli bir standart olarak göze çarpar (Ono ve ark. 2018). EEG sayesinde epileptik kayıtlar alınır. Böylece nöbetin kökeni ve ilgili olduğu alan tespit edilerek bu 2 epilepsi türü (fokal / non-fokal) ayrıştırılabilir. Bunlara ek olarak EEG; pre-iktal (epileptik nöbet öncesi dönem), iktal (epileptik nöbet anı), post-iktal (epileptik nöbet sonrası) ve inter-iktal (iki epileptik nöbet arası) kayıt süreçlerindeki farklılıkların tespiti için de kullanılır. İktal EEG; dikenlerden oluşan bir dalga formu çizer. Diğer taraftan inter-iktal EEG ise geçici keskin dalga formlarından oluşur. Şekil 1.1'de farklı elektrot konumlarından alınmış inter-iktal kayıtlar ve ardından başlayan nöbet anı gösterilmiştir.

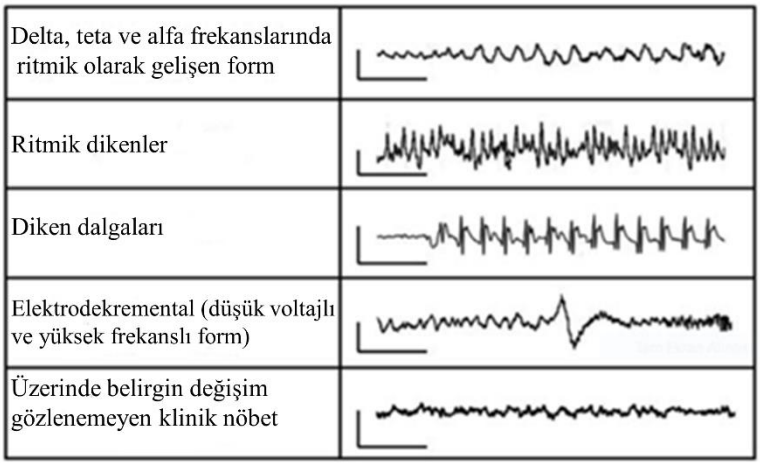


Şekil 1.1. Fokal epilepsi hastası bir bireyden alınan EEG kayıtları. En sol: Elektrot lokasyonları, orta: hastaya ait inter-iktal deşarj kayıtları, sağ: ok'la gösterilen nöbet başlangıç anı

Klinisyenler genelde uzun süreli EEG kayıtlarını analiz ederek sinyalleri daha derinden tespit eder ve nöbetin kaynağını lokalize etmeye çalışır (Hussain ve ark. 2018, Ono ve ark. 2018). Şekil 1.2.'de yaygın olarak görülen ve tez kapsamında bahsi geçen çeşitli dalga formları gösterilmiştir. Buna ek olarak epilepsi hastalarında nöbet başlangıç anı her hasta için farklı dalga formlarında gösterebilmektedir. Dalga formlarına ait detaylar Şekil 1.3.'de verilmiştir. Klinisyenler ve hekimler EEG kayıtlarının göz ile analizinde bunlara benzer örüntüleri kullanmaktadırlar.



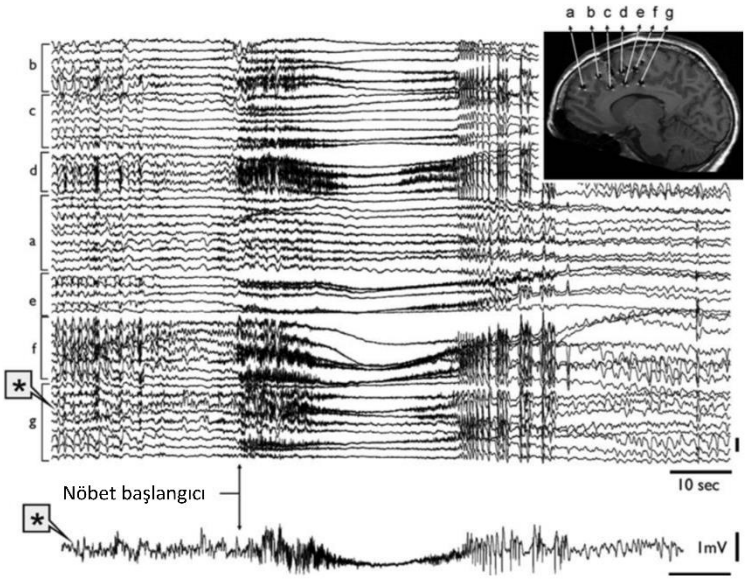
Şekil 1.2. Genel olarak bilinen epileptik form EEG örüntüleri



Şekil 1.3. Epilepsi hastalarında nöbet anının başlangıcında görülen yaygın EEG örüntüleri

Fokal / non-fokal epileptik EEG kayıtlarının gözlemsel olarak analizi tıp doktorları tarafından zaman kaybı olarak görülür. Buna ek olarak birden fazla uzman hastalara ait EEG örüntüleri konusunda farklı fikirlere sahip olabilir. Böyle bir durumda hastalık teşhisinde insan kaynaklı hataların sayısı artabilir (Raghu ve Sriraam 2018). Sonuç olarak muhtemel bir ameliyat öncesi otomatik bir sınıflandırma yaklaşımı, farklı sinyal karakteristiklerini ayırt etmede ve klinisyenlere karar aşamasında yardım etme durumunda bir ihtiyaç haline gelmiştir. Şekil 1.4.'deki örnek gösterimde ameliyat öncesi bir fokal epilepsi hastasından elektrotlar aracılığı ile alınan örnek kayıtta nöbetin gerçekleştiği elektrot ve başlangıç anı gösterilmiştir.

Klinisyenlere gözle belirgin nöbetlerin dışında yine nöbet davranışı gösteren ama gözle kolayca tespit edilemeyen bir karar sistemi geliştirmek, hastalık türü ve lokasyonu belirleme açısından ciddi kolaylıklar sağlayacaktır.



Şekil 1.4. Ameliyat öncesi fokal epilepsi olan bir hastadan alınan EEG kayıtları. Nöbet başladığı an (*), sırasıyla arka plan aktivitesinde azalma, hızlı bir aktivite seyri ve ardından gerçekleşen düşük potansiyel seyri görülmektedir

EEG kayıtları araştırmacılar tarafından popüler bir beyin görüntüleme yöntemi olarak tercih edilmektedir. Bu metot invaziv olmayan bir kuruluma sahiptir, kayıtlara ait zaman çözünürlüğü yüksektir ve fiyat performans açısından pratik çözümler sunmaktadır. Bu anlamda, epileptik EEG kayıtlarının ayrıştırılmasında birçok metoda ait literatür çalışması bulunmaktadır. Wavelet tabanlı (You ve ark. 2020) öznitelikler, Ampirik Mod Ayrışımı (San-Segundo ve ark. 2019), entropi algoritmaları (Arunkumar ve ark. 2018), derin nöral ağ mimarileri (Madhavan ve ark. 2020, Tjepkema-Cloostermans ve ark. 2018) ve bir arada olan çoklu (Sriraam ve Raghu 2017) öznitelikler bu amaçla kullanılan işaretçiler ve algoritmalardır. Bu tez çalışmasında Mel Frekansı Kepstral Katsayıları (MFCC) epileptik EEG kayıtlarının analizi için öznitelik vektörlerinin hesaplanmasında bir yöntem olarak önerilmiştir.

1.1.Tez Çalışmasının Amacı ve İzlenilen Yöntem

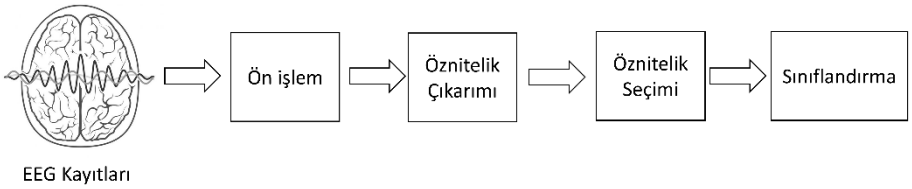
Bu tez çalışmasında, Mel Frekansı Kepstral katsayıları (MFCC) ve makine öğrenmesi algoritmaları ile Bern Barcelona veri seti kapsamındaki fokal / non-fokal

epileptik EEG kayıtlarının sınıflandırılması amaçlanmıştır. Bu amacın gerçeklenmesinde, belirlenen hedefler aşağıda listelenmiştir.

i) MFCC destekli makine öğrenmesi algoritmaları ile Hauz Khas veri seti kapsamındaki pre-iktal / iktal / inter-iktal EEG kayıtlarının sınıflandırılması. Bu çalışma ile MFCC'nin zor bir veri seti üzerindeki başarı performansının tespiti hedeflenmiştir. Bu hedef ile MFCC'nin söz konusu alandaki yetisi belirlenmiştir.

ii) Başarısı teyit edilen MFCC destekli makine öğrenmesi algoritmaları ile Bern Barcelona veri seti kapsamındaki fokal / non-fokal epileptik EEG kayıtlarının sınıflandırılması hedeflenmiştir.

Genel olarak EEG verilerinin sınıflandırılmasında izlenilen işlem adımları Şekil 1.5'de gösterilmiştir. Literatür desteli bu temel yaklaşım, bu tez çalışmasında da uygulanmıştır.



Şekil 1.5. Tez çalışması süresince izlenilen işlem adımları

Şekil 1.5' de görüldüğü üzere, EEG kayıtlarının ön işlemden sonra öznitelik çıkarımı gerçeklenmiştir. EEG bölütlerinden öznitelik çıkarımı, MFCC markerlarının hesaplanması ile sağlanmıştır. Bahsi geçen Kepstral analiz yöntemiyle EEG bileşenleri içinde bulunan tekrarlı örüntüler ve harmonik davranış gösteren dalga türleri özgün bileşenler olarak hesaplanmıştır. Literatürdeki çalışmalar incelendiğinde, ilgili özellik çıkarım yönteminin hem Bern Barcelona hem de Hauz Khas veri setine uygulanmadığı gözlemlenmiştir. Bir sonraki adım olarak çıkarılan MFCC öznitelikleri normalize edilmiş ve normalize edilmiş öznitelik kümesinden en ilgili alt öznitelik kümesi elde edilerek boyut azaltımına gidilmiştir. Bu tez çalışmasında, sınıflandırıcı olarak Fine Tree, Qadratik Diskriminant analizi, Lojistik Regrasyon, Gauss Tabanlı Naive Bayes, Kübik Destek Vektör Makinesi, Ağırlıklandırılmış K en yakın komşuluk ve son olarak bir ensemble yöntem olan Bagged Tree algoritması kullanılmış ve farklı performans

metrikleri hesaplanmıştır. Çalışmada eğitim ve test kümeleri k=10 çapraz doğrulama ile birbirinden ayrılmıştır.

1.2.Tez Çalışmasının İçeriği

Bu tez çalışması tezin amacına ve izlenilen yönteme yönelik olarak 5 bölümden oluşmaktadır. Literatür taraması kısmında; MFCC özniteliğinin kullanıldığı farklı veri setlerine ait çalışmalara, Bern Barcelona ile Hauz Khas verilerinin MFCC özniteliği dışındaki özniteliklerin kullanıldığı araştırmalara yer verilmiştir. Materyal ve metot kısmında; analiz edilen EEG veri setlerine, Kepstral katsayılarının hesaplanma adımlarına, normalizasyon ve boyut azaltım yöntemi ile birlikte son olarak da sınıflandırma algoritmalarına ait detaylara yer verilmiştir. Elde edilen performans metrikleri ve sonuçlar literatürdeki çalışmalarla karşılaştırılarak bulgular ve tartışma kısmında detaylandırılmıştır. Ayrıca çalışmanın avantajlarına ve dezavantajlarına değinilmiştir. Son olarak sonuçlar ve öneriler bölümü ile tez çalışması tamamlanmış ve ileriye yönelik potansiyel çalışma hedeflerine yer verilmiştir.

1. GİRİŞ

2. KAYNAK ÖZETLERİ

Bu tez çalışmada, Mel Frekansı Kepstral katsayıları (MFCC) ve makine öğrenmesi algoritmaları ile Bern Barcelona veri seti kapsamındaki fokal / non-fokal epileptik EEG kayıtlarının sınıflandırılması amaçlanmıştır. Bu amaç doğrultusunda, öncelikle MFCC'nin EEG veri setlerinin sınıflandırılmasında uygun öznitelikler üreterek gerekli yetiye sahip olup olmadığının tespiti hedeflenmiştir. Bu hedef için MFCC destekli makine öğrenmesi algoritmaları ile Hauz Khas veri seti kapsamındaki pre-iktal / iktal / inter-iktal EEG kayıtları sınıflandırılmıştır. Dolayısıyla bu bölümde konu ile ilişkili literatür bilgilerine yer verilmiştir.

Literatür araştırıldığında, epilepsi hastalığının insanlar üzerinde geçmişten bugüne pek çok fizyolojik hasar, psikolojik ve travmatik etkiler bıraktığı görülmüştür. Mühendislik açsından bakıldığında, bu çalışmaların büyük bir bölümünde; hastalık ile ilişkili anomalilerin tespiti ve tespit edilen anomali ile ilişkili özniteliklerin hastalık ile olan ilişkisi araştırılmaktadır. Bu temel bilgiler ışığında, tez ile ilişkili literatür taraması üç (3) alt başlık altında değerlendirilmiştir.

i) MFCC özniteliğinin EEG çalışmalarındaki performansı: Bu alt başlık kapsamında, tezde kullanılmayan EEG veri setleri için elde edilen MFCC destekli yaklaşımların başarı performanslarını içeren çalışmalar değerlendirilmiştir.

ii) Bern Barcelona veri seti içeren Fokal / Non-fokal EEG Çalışmaları: Bu alt başlık kapsamında, tezde kullanılan veri setinin fokal / non-fokal açısından değerlendirilen çalışmalara yer verilmiştir.

iii) Hauz Khas veri seti içeren iktal / pre-iktal / inter-iktal EEG çalışmaları: Bu alt başlık kapsamında, tezde kullanılan veri seti ile ilişkili çalışmalara yer verilmiştir. Literatürde bu veri seti ile ilişkili çok az sayıda çalışma olduğu ve kapsamlarında ise iktal / pre-iktal / inter-iktal EEG olmak üzere üç farklı sınıfa ayırabilme işlemleri yer almaktadır.

2.1. MFCC Özniteliğinin EEG Çalışmalarındaki Performansı:

Literatürde mevcut tezin konusunu kapsayan ve farklı EEG veri setlerine uygulanmış MFCC öznitelik çıkarım metoduna dayalı çalışmalar mevcuttur. Bu bölümde, MFCC özniteliğinden diğer öznitelikler karşısında ne denli üstün başarımlar elde edildiğine dair çalışmalara yer verilmiştir.

Cooney ve ark. (2018), çalışmalarında Karaone veri setini kullanarak 11 farklı duruma ait hayali EEG konuşma kayıtlarını doğruluk derecelerine göre sınıflandırmışlardır. Veriden MFCC' ye ait doğrusal özellik, doğrusal olmayan özellik ve sadece MFCC katsayılarını içermek üzere 3 farklı hesaplama yapılmıştır. Her özellik seti Karar Ağaçları sınıflandırıcısı ve Destek Vektör Makinası (DVM) sınıflandırıcısıyla eğitilmiştir. Sonuç olarak MFCC özniteliğinin hayali EEG konuşma kayıtlarına %33 doğruluk değeri kazandırdığı görülmüştür. MFCC öznitelikleri karar ağaçlarında ve DVM' de sırasıyla %19.69, %20.80 doğruluk oranı vererek doğrusal ve doğrusal olmayan özniteliklere göre daha başarılı bir sınıflandırma oranı sağlamıştır.

Mini ve ark. (2021), çalışmalarında Karaone veri setini kullanarak hayali ve duyusal verilere bağlı beyin bilgisayar ara yüzünü geliştirmeyi amaçlamışlardır. Öznitelik çıkarım metodu olarak MFCC, Linear Predictive Cepstral Coefficient (LPCC) ve Sequency Mapped Real Transform (SMRT) katsayılarını, sınıflandırıcı olarak ise ANN kullanmışlardır. Çalışmada ilgili özniteliklerin hibrit versiyonları da uygulanmıştır. MFCC ve LPCC birleştirilerek MLC; SMRT ve MFCC birleştirilerek SMC; SMRT ve LPCC birleştirilerek SLC diye adlandırılan hibrit öznitelikler oluşturulmuştur. Çalışmada Ensemble Average (EA) ve Time Average (TA) tabanlı ilgili özniteliklerden istatistiksel parametreler çıkarılmıştır. Bu parametreler enerjiye ait ortalama değer, ortalama, standart sapma, çarpıklık ve karmaşıklık değerleridir. Oluşturulan tüm bu özniteliklere Temel Bileşenler Analizi uygulanarak boyut azaltımına gidilmiştir. Öznitelik kümeleri hem hayali EEG (EEG-i) ve vokal EEG (EEG-v) için hesaplanmıştır. Sonuç olarak en yüksek doğruluk oranı TA tabanlı SMC ile EEG-i için %77.37; EEG-v için %62.57 olarak elde edilmiştir. Çıkarılan SMC ve SLC hibrit öznitelikleri karşılaştırıldığında MFCC ile entegre edilmiş olan SMC özniteliğinin başarım oranının SLC özniteliğine göre daha etkin olduğu belirlenmiştir.

Ren ve ark. (2018), çalışmalarında Bonn veri setine Local Mean Decomposition (LMD) ve MFCC özniteliklerini uygulamışlardır. İlgili veri seti A (sağlıklı gözler açık), B (sağlıklı gözler kapalı), C (non-seizure), D (inter ictal) ve E (seizure) gruplarından oluşmaktadır. LMD EEG'nin durağan olmayan yapısıyla ilgili; MFCC doğrusal olmayan yapısıyla ilgili problemi çözmeye yönelik kullanılmıştır. LMD bir tür zaman frekans alt örnekleme analizi olup kayda ait düşük, orta ve yüksek frekans bileşenlerinin analizinde kullanılır. Çalışmada EEG bölütlerine ilk olarak LMD uygulanmış

sonrasında frekans bileşenlerinin MFCC katsayıları alınarak doğrusal bir dönüşüm sağlanmıştır. Sınıflandırma algoritmaları olarak geri beslemeye yönelik sinir ağı, SVM, LDA, KNN, karar ağaçları kullanılmış olup AE, BE, CE, DE, ABCD-E, AB-CD-E, CD-E, A-B-C-D-E doğruluk değerleri sırasıyla %100, %100, %99.86, %99.78, %99.46, %97.85, %99.83 ve %97.43 şeklindedir. Zang ve Chen (2017), çalışmalarında Bonn veri setine ait LMD özniteliğini ve aynı sınıflandırıcıları kullanmış olup AE, DE, ABCD-E, A-D-E, AB-CD-E doğruluk değerlerini sırasıyla %100, %98.10, %98.87, %98.47, %98.40 bulmuşlardır.

Kiranyaz ve ark. (2014), çalışmalarında CHB-MIT veri setini Zaman (max, min, std. vb), Frekans (spektral entropi, güç spektruma ait min, max değerleri vb.), Zaman-Frekans (kısa zamanlı fourier dönüşümü ile frekans bantlarına ait istatistiksel değerler), Doğrusal Olmayan (Lyapunov exponent), MFCC (5 EEG frekansının 1. ve 2. türevine ait katsayılar) öznitelikleriyle analiz etmişlerdir. Sınıflandırıcı olarak Collective Network of Binary Classifiers (CNBC) kullanıp, duyarlılık ve hassasiyet değerleri ise %89 ve %93 bulunmuştur.

Dissanneyeka ve ark. (2021), çalışmalarında CHB-MIT veri setini kullanarak 2 farklı derin öğrenme ağ mimarisi ile katılımcılardan bağımsız yaklaşık 1 saatlik kayıtların analizi gerçekleştirmişlerdir. İlgili mimarileri giriş olarak MFCC katsayılarını içeren haritaları uygulamışlardır. Hesaplamalarda ilk 13 MFCC katsayısı göz önünde bulundurulmuştur. İlk mimaride preiktal-interiktal doğruluk, duyarlılık ve hassasiyet değerleri sırasıyla %88.81, %93.45 ve %81.64; ikinci mimaride ise doğruluk, duyarlılık ve hassasiyet değerleri sırasıyla %91.54, %89.94 ve %89.94 olarak bulunmuştur.

Rajesh D (2016), çalışmasında CHB-MIT veri setine MFCC özniteliği uygulanarak normal ve normal olmayan EEG verileri ANN kullanılarak ayrıştırılmıştır. Çalışmada 15, 25 ve 35 kepstral katsayıları kullanılmıştır. En iyi sonuç duyarlılık ve özgüllük değerleri sırasıyla %98 ve %96 olarak 25 katsayılı öznitelikten elde edilmiştir.

Yavuz ve ark. (2018), çalışmalarında MFCC özniteliğini Bonn EEG verisinde kullanmışlardır. İlgili EEG verisi Z (sağlıklı gözler açık), O (sağlıklı gözler kapalı), N (non-seizure), F (inter ictal) ve S (seizure) gruplarından oluşmaktadır. Her grup 23.6 saniyelik 100 EEG segmentinden oluşmaktadır. MFCC hesabında 13, 25, 30 ve 40 katsayıdan oluşan farklı hesap grupları oluşturulmuştur. Sınıflandırıcı olarak Generalized Regression Neural Network (GRlNN) ve Feed Forward Neural Network

kullanılmıştır. Eğitim ve test setleri k=2, 5 ve 10 için belirlenmiştir. Çalışma sonucunda Z-S (doğruluk: %99), Z-F (doğruluk: %99.6), ZNF-S (doğruluk: %98.72), ZONF-S (doğruluk: %99), Z-F-S (doğruluk: %98.07) ve ZO-NF-S (doğruluk: %98.67) bulgularına varılmıştır.

Dwi Saputro ve ark (2019), çalışmalarında Temple Üniversitesi Hastanesine ait nöbet veri setini kullanmışlardır. İlgili EEG kayıtları jeneralize spesifik olmayan nöbet (GNSZ, 20 eğitim-20 test), fokal spesifik olmayan nöbet (FNSZ, 50 eğitim- 50 test), tonik-klonik nöbet (TCSZ, 25 eğitim-5 test) ve normal (25 eğitim-5 test) gruplardan oluşmaktadır. Sınıflandırıcı olarak SVM, öznitelik olarak MFCC, Hjort parametreleri ve Independent Compenent Analyzes (ICA) kullanılmıştır. Çalışma sonucunda sırası ile %90.25, %97.83 ve %91.4 duyarlılık, özgüllük, doğruluk değerlerine ulaşılmıştır.

2.2. Bern Barcelona Veri Seti İçeren Fokal / Non-fokal EEG Çalışmaları:

Literatürde fokal / non-fokal EEG çiftlerini içeren Bern Barcelona veri setini MFCC dışında diğer öznitelik çıkarım yöntemleriyle analiz eden birçok öncü çalışma bulunmaktadır. Bu çalışmalar genel anlamda frekans, zaman ve frekans-zaman tabanlı öznitelikleri içerir. Çalışmaların başlıcaları şunlardır:

Deivasigamani ve ark. (2016), çalışmalarında 50 fokal, 50 non-fokal EEG kayıt çifti kullanmışlardır. Öznitelikler, EEG kayıtlarının Dual Tree Complex Wavelet Transform (DT-CWT) ile ayrıştırılıp katsayıların hesaplanmasıyla elde edilmiştir. İlgili öznitelikler Adaptive Neuro Fuzzy Interface System (ANFIS) ile eğitilmiş ve sınıflandırılmıştır. Çalışmada %98 duyarlılık, %100 özgüllük, %99 doğruluk elde edilmiştir

Singh ve ark. (2017), çalışmalarında fokal non-fokal 50 ve 750 EEG kayıt çifti kullanıp sınıflandırma oranlarını sırasıyla %89.7 ve %89.52 bulmuşlardır. Çalışmada kullanılan öznitelikler Discrete Fourier Transform (DFT) tabanlı özniteliklerdir. Sınıflandırıcı olarak Least Squares Support Vector Machine (LS-SVM) sınıflandırıcısını kullanmışlar.

Sriraam ve Raghu (2017), çalışmalarında 3750 fokal 3750 non fokal EEG kayıt çifti kullanmışlardır. 5 farklı sınıflandırma yapıp, 26 farklı özellik çıkarmışlardır. Wilcoxon kullanarak özelliklerin istatistiksel anlamlılığını çıkarıp en önemli özellikleri seçmişlerdir. Sonuç olarak çıkarılan dönüşüm tabanlı 21 özelliği SVM ile

sınıflandırmışlardır. Ulaşılan duyarlılık, özgüllük ve doğruluk değerleri sırası ile %94.56, %89.74 ve %92.15 olarak hesaplanmıştır.

Gupta ve ark. (2017), çalışmalarında 3750 fokal 3750 non-fokal kayıt çifti kullanarak farklılaştırma ve Flexible Analytic Wavelet Transform (FAWT) tekniğini hedef almışlardır. EEG kayıtları FAWT' nin 15 seviyesine tabi tutulmuştur. EEG kayıtlarının Kruskal–Wallis testi ile anlamlılığı incelenmiştir. KNN ve LS-SVM sınıflandırıcıları kullanılmıştır. Doğruluk oranını %94.41 bulunmuştur.

Siriraam ve Raghu (2020), çalışmalarında tek boyutlu quad binary pattern (QBP) kullanarak en etkili epileptik bölgeye ulaşmayı hedeflemişlerdir. Bununla birlikte 3750 kayıt çifti kullanarak daha kapsamlı sonuçlara ulaşmayı amaçlamışlardır. Zaman domainindeki EEG kayıtlarını QBP domainine dönüştürüp histogram analizi yapmışlardır. Sonrasında doğrusal olmayan öznitelikler elde etmişlerdir. Sınıflandırıcı olarak ANN sınıflandırıcısı kullanıp %95.74 başarım oranı elde etmişlerdir.

You ve ark. (2019), çalışmalarında yeni bir otomatik fokal EEG tespiti için FAWT ve entropiyi birleştiren yeni bir algoritma öne sürdüler. Bunun yanında çalışmayı güçlendirmek adına ANOVA testi gibi istatistiksel testler uyguladılar. Sınıflandırıcı olarak ise beş farklı sınıflandırma işlemi yaptılar. Ve en ayırt edici sınıflandırıcı olarak LS-SVM sınıflandırıcısını belirleyip doğruluk değerini %94.80 buldular.

Rahman ve ark (2019) çalışmalarında değişken mod ayrışımı (VMD) ve DWT' dan çıkarılan özniteliklere ek olarak düzeltilmiş kompozit çok ölçekli dağılım entropisi, düzeltilmiş bileşik çok boyutlu bulanık entropi ve otoregesif model katsayıları (AR) da uygulamışlardır. Ayrıca ANOVA testi ile çalışmayı istatistiksel olarak güçlendirmişlerdir. Çalışmalarında 3750 kayıt çifti kullanıp duyarlılık, özgüllük ve doğruluk değerlerini sırasıyla %96.1, %94.4, %95.2 bulmuşlardır.

Hussein ve ark. (2018), çalışmalarında genellikle epilepsi nöbetlerinin önceden belirlenmesinin geliştirilmesindeki teknikleri entropi, EMD, WT ve dinamik analizler olarak belirlemişlerdir. Mevcut olan bu algoritmaları karşılaştırıp pratik ve güvenilir bir algoritmaya dikkati çekmişlerdir.

Bajaj ve ark. (2017), çalışmalarında fokal / non-fokal EEG sınıflandırmasında Hilbert-Huang dönüşümünü kullanmışlardır. EMD sonucu elde edilen IMF'lere Hilbert dönüşümü uygulanmıştır. Çalışmada Pearson ve Spearman korelasyon katsayıları elde

edilmiştir ve bunlar LS-SVM ile sınıflandırılmıştır. Çalışmada 750 fokal / non-fokal kayıt çifti kullanılmış ve %99.2 doğruluk oranı elde edilmiştir.

Bhattacharyya ve ark. (2018), çalışmalarında emprical wavelet transform tekniğini kullanarak EEG kayıtlarını ayrıştırmışlardır. Sonrasında iki boyutlu projeksyonlarla faz uzayı elde edilmiştir. Central tendency ölçümleri (CTM) ile iki boyutlu projeksiyonların alan hesabı yapılmıştır. Alan parametreleri LS-SVM ile sınıflandırılıp fokal / non-fokal EEG kayıtları ayrıştırılmıştır. Çalışma sonucunda 50 EEG çifti kullanılarak doğruluk, duyarlılık ve özgüllük değerleri sırasıyla %90, %88 ve %82 olarak bulunmuştur. Aynı yöntem ile 750 EEG çiftinde bu sonuçlar %82.53, %81.60 ve %83.46 olarak bulunmuştur.

Zeng ve ark. (2019), çalışmalarında EMD kullanarak 3. ve 4. IMF' lere ait enerji değerlerini hesaplamışlardır. Elde edilen değerlere ait faz uzayları oluşturulmuştur. Çalışmada sınıflandırıcı olarak nöral ağlar kullanılmıştır. Eğitim ve test aşamasında 10 çapraz doğrulama yapılmıştır. 50 EEG çiftinde %96, 3750 EEG çiftinde %95.3 doğruluk değeri elde edilmiştir.

Deivasigamani ve ark. (2020), çalışmalarında sürekli dalgacık dönüşümü (CWT) katsayılarından mobility, complexity, skewness, curtosis, anfis, özelliklerini çıkarmışlardır. Fokal / non-fokal EEG kayıtlarını ayrıştırmak için neural network sınıflandırıcısını kullanmışlardır. Çalışmalarında ulaşılan doğruluk, duyarlılık ve özgüllük değerleri ise sırasıyla %99.7, %96.7 ve %98.1 olarak bulunmuştur.

Chatterjee ve ark. (2017), çalışmalarında Multifraktal küçültülmüş dalgalanma analizine dayalı (MFDFA) öznitelikleri ile 50 fokal / 50 non-fokal EEG çifti k-NN ve SVM sınıflandırıcıları kullanılarak sınıflandırılmıştır. En yüksek başarım oranını SVM linear ile %92.18 olarak bulmuşlardır.

Sharma ve ark. (2015), çalışmalarında entropi ölçümleri kullanarak EMD özniteliği ile özellik çıkarımı yapmışlardır. Fokal / non-fokal EEG kayıtlarının farklı İMF değerlerinden ortalama Shannon entropi, ortalama Renyi's entropi, ortalama yaklaşık entropi, ortalama örnek entropi ve ortalama faz entropisi kullanılmıştır. Sınıflandırıcı olarak LS-SVM sınıflandırıcısı kullanılıp %87 başarım oranı elde edilmiştir.

Acharya ve ark. (2019) fokal EEG kayıtlarının belirlenmesini geliştirmek ve doğrusal olmayan fokal / non-fokal kayıtları ayırt etmek için 3750 kayıt çifti kullanarak

CAD sistem uygulamayı hedeflemişlerdir. Doğrusal olmayan özellik çıkarımlarından sonra farklı sınıflandırmalar uygulayıp sırasıyla doğruluk, duyarlılık ve özgüllük değerlerini %87.93, %89.97 ve %85.89 bulmuşlardır.

Das, A. B. and Bhuiyan (2016), çalışmalarında kapsamlı olarak EMD ve DWT kullanmışlardır. EMD ve DWT' de Shanon entropi, log enerji entropi ve Renyi entropi gibi bir dizi spektral tabanlı entropi hesabı yapılmıştır. Hesaplama açısından hızlı olduklarını ileri sürmüşlerdir. Bu işlemlerin ardından fokal / non-fokal EEG kayıtlarının etkinliği araştırılmıştır. KNN sınıflandırıcısı ile 3750 kayıt çifti kullanılarak %89.4 doğruluk değeri hesaplanmıştır.

Arunkumar ve ark. (2018), çalışmalarında fokal / non-fokal EEG' yi yaklaşık entropi, Sample entropi ve Fuzzy entropi gibi entropi türlerini birkaç farklı sınıflandırıcıyla besleyerek sınıflandırmayı amaçlamışlardır. Sınıflandırıcı olarak Non Nested Generalized Exemplers (NNge) sınıflandırıcısını tercih etmiş olup, doğruluk, duyarlılık ve özgüllük değerlerini sırasıyla %99, %99 ve %99 bulmuşlardır.

San-Segundo ve ark. (2019), çalışmalarında dönüşüm tabanlı yaklaşımlar olan Fourier, wavelet ve EMD'yi derin öğrenme sınıflandırıcısının girişi için farklı EEG veri setlerini (Bern Barcelona ve Bonn) uygulamak üzere kullanmışlardır. Bern Barcelona EEG veri setinin EMD kullanılarak verdiği doğruluk oranını 98.9% bulurken Bonn veri seti için Fourier kullanıldığında en yüksek değerleri vermiştir. Elde edilen en yüksek başarım oranı %99.5' tir.

Tjepkema-Cloostermans ve ark. (2018), çalışmalarında epileptiform deşarjlarının varolma olasılığını saptamak için CNN ve RNN' in farklı kombinasyonlarını uygulamışlardır. Test setindeki ROC eğrisi,7 bağımsız EEG' de fokal epileptiform ve 12 normal EEG ile doğrulanmıştır. Çalışmalar sonucunda ROC altında kalan alan 0.94, özgüllük değeri ise %98 olarak elde edilmiştir.

Fraiwan, L. ve Alkhodari (2020), çalışmalarında uzun kısa süreli bellek (LSTM) kullanarak fokal ve non-fokal epileptik EEG kayıtlarının arasındaki ayrımı otomatik olarak sınıflandırmak için derin öğrenme yaklaşımı ile konuyu ele almışlardır. 3750 kayıt çifti kullanıp Cohens kappa, doğrulluk, duyarlılık ve özgüllük değerlerini %99.20, %99.60, %99.55 ve %99.65 olarak bulmuşlardır.

Siddharth ve ark. (2019), çalışmalarında sliding mode singular spektrum analizi (SM-SSA) kullanarak EEG kaydının rekonstrüksiyon bileşenlerinin (RCs) ayrışmasına

dayanan bir yöntem ele almayı amaçlamışlardır. SM-SSA kullanarak her EEG kaydından toplamda 5 RCs özellik çıkarmışlardır. Daha sonra radyal tabanlı sinir ağı (RBFN) ve seyrek otoencoder (SAE)'ı birleştirerek bir sınıflandırıcı tasarlamışlardır. SAE-RBFN sınıflandırıcısı doğruluk, duyarlılık ve özgüllük değerlerini sırasıyla %99.11, %98.52 ve %99.70 bulmuştur.

Madhavan ve ark. (2020), çalışmalarında fokal / non-fokal EEG kayıtlarını Fourier Snkron Sıkıştırma Dönüşümü (FSST) ve Wavelet Senkron Sıkıştırma Dönüşümü kullanarak (WSST) zaman-frekans düzlemine aktarmışlardır. Makine öğrenmesi olarak CNN kullanmışlardır. Çalışma sonucunda %99' un üzerinde doğruluk, duyarlılık ve özgüllük elde edilmiştir.

Raghu ve Sriraam (2018), tanımladıkları çalışmaya fokal epileptik nöbetlerin bilgisayarla otomatik olarak belirlenmesi (CADFES) adını vermişlerdir. Neighborhood bileşen analizi (NCA) kullanarak 28 önemli öznitelik belirlemişlerdir. Dört farklı sınıflandırıcı kullanıp en iyi sınıflandırıcı olarak DVM' yi belirlemişlerdir. Duyarlılık, özgüllük, doğruluk, pozitif tahmin oranı, negatif tahmin oranı ve eğri altında kalan alan sırasıyla %97.6, %94.4, %96.1, %92.9, %98.8 ve 0.96'dır.

Gupta, V. and Pachori (2020), çalışmalarında otomatik fokal kayıt sınıflandırma yapmak için wavelet transform kapsamında uygun zaman frekansına dayalı Fourier-Bessel serisi genleşmesi (FBSE) yardımıyla bu metodu geliştirmişlerdir. Bu metotta fokal enerji kayıtlarının sınıflandırılması için karışım correntropi (MC) ve üstel enerji (EE) içeren özellikler kullanılmıştır. Sınıflandırıcı olarak LS-SVM kullanılıp doğruluk, duyarlılık ve özgüllük değerleri sırasıyla %95.85, %95.47 ve %96.24 bulunmuştur.

Sriraam ve Raghu (2017), çalışmalarında enerji, güç, karmaşıklık, fraktal boyut ve istatiksel tabanlı 26 öznitelik kullanmışlardır. Wilcoxon ve z-skor ($p<0.05$) kullanılarak kullanılacak öznitelik boyutu 21'e düşürülmüştür. Sınıflandırıcı olarak optimize edilmiş DVM 10 kat çapraz doğrulama ile kullanılmıştır. Çalışmada 3750 fokal / non-fokal EEG çiftinin tamamı kullanılmıştır. Sonuç olarak sırası ile %94.56, %89.74, %92.15 duyarlılık, özgüllük ve gerçeklik elde edilmiştir.

Ravi Kumar ve Srinivasa Rao (2019), çalışmalarında Bern Barcelona ve Bonn EEG epilepsi veri setlerini kullanarak normal ve anormal kayıtları analiz etmişlerdir. Çalışmada varyasyonel mod ayrışımı (VMD) kullanılmış, buradan farksal entropi, ortalama kare oranlarının genliği gibi semantik öznitelikler kullanılmıştır. Öznitelik

vektörü %80 eğitim %20 test verisine ayrılmıştır. Sınıflandırıcı olarak rastgele orman algoritması kullanılmıştır. Fokal EEG çiftleri için duyarlılık ve özgüllük değerleri %90, %100; non-fokal için duyarlılık ve özgüllük değerleri ise %100 ve %90 olarak değerlendirilmiştir.

2.3. Hauz Khas Veri Seti İçeren İktal / Pre-iktal / İnter-iktal EEG Çalışmaları:

Bu bölümde Hauz Khas New Delhi nöroloji ve uyku merkezinden temin edilmiş iktal, inter-iktal ve pre-iktal olmak üzere 3 farklı sınıfa ait EEG kayıtlarını analiz eden ve literatürde az sayıda olan çalışmalara yer verilmiştir. Taranan iki adet çalışmanın detayları aşağıdaki gibidir:

Qaisar ve Hussain (2021), çalışmalarında epileptik nöbet tespitinde EEG örneklerine ait alt bant tabanlı istatistiksel öznitelik seçimi ve makine öğrenmesi içeren bir mobil sağlık bakım sistemi geliştirmişlerdir. Çalışmada Bonn ve Hauz Khas olmak üzere 2 farklı veri seti kullanılmıştır. Geliştirilen bir algoritma ile aktif bir segmentasyon uygulanmıştır. Filtrelerden arındırılan segmentler ayrık dalgacık dönüşümü ile alt bantlara ayrılmış ve bu alt bantlardan istatistiksel öznitelik çıkarılmıştır. İnformation gain (İG) analizi ile sınıflandırmaya katkısı büyük olan öznitelikler seçilmiş ve boyut azaltılmıştır. İlgili öznitelik kümelerine makine öğrenme algoritmaları uygulanmıştır. Bu algoritmalardan başlıcaları k-NN, ANN, SVM, Random Forest ve Bagging kullanılmıştır. Eğitim ve test veri kümeleri 10 çapraz doğrulamayla elde edilmiştir. Hesaplanan performans metrikleri mikro-ortalama precission, normalize ortak bilgi, f-measure, kappa indeks ve özgüllük şeklindedir. Çalışma sonucunda %100 varan doğruluk değerine ulaşılmıştır.

Tuncer ve ark. (2020), çalışmalarında epileptik EEG kayıtlarının analizinde lokal grafik yapı (LGS) tabanlı özgün bir öznitelik sınıflandırma yöntemi önermişlerdir. Bu LGS yapıları dikey, yatay, simetrik, zigzag-yatay, zigzag-düşey gibi varyasyonlarına sahiptir. EEG kayıtları ayrık dalgacık dönüşümü sayesinde iki boyutlu hale getirilmiştir. Çalışmada RF, ANN, SVM, LDA, k-NN gibi sınıflandırıcılar kullanılmıştır. Hauz Khas veri seti durum 1: pre-iktal vs. inter-iktal; durum 2: inter-iktal vs. iktal; durum 3: pre-iktal vs. iktal vs. inter-iktal şeklinde sınıflandırılmıştır. Durum 1 ANN ile durum 2 k-NN %100 doğruluk değeri ile sınıflandırılmıştır. Durum 3 ise ANN ile %98.67 doğruluk oranında sınıflandırılmıştır.

Bu tez çalışmasında, 2 farklı EEG veri seti kullanılmıştır. İlk olarak analiz edilen veri seti iktal / inter-iktal / pre-iktal EEG kayıtları olup, MFCC'nin sınıflandırmadaki performansı belirlenmiştir. Bu kayıtta, her grup için 50 EEG segmenti bulunmaktadır. Her EEG segmenti 1024 örnekleme uzunluğunda (5,12 saniye) olup, örnekleme frekansı ise 200 Hz'dir. Ardından analiz edilen diğer bir veri seti ise tezin konusu olan fokal ve non-fokal EEG kayıtlarıdır. Her grupta 3750 EEG çifti bulunmaktadır. Mevcut veri seti 512 Hz. örnekleme frekansına sahiptir ve 20 saniye uzunluğundadır. Bu çalışmada her iki veri seti için de Mel Frekans Kepstrum Katsayıları hesaplanmıştır. 14 adet MFCC, 14 tane delta, 14 tane delta-delta hesaplaması yapılmıştır. Çıkarılan öznitelik kümesi Z-normalizasyon işlemi ile normalize edilmiştir. Özellik vektörlerine ait varyansın %95'ni açıklayacak şekilde temel bileşenler analizi yapılarak boyut azaltımına gidilmiştir. Çalışmada fine tree, quadratik diskriminant analiz, lojistik regresyon, gauss tabanlı naive bayes, kübik destek vektör makinesi, ağırlıklandırılmış en yakın komşuluk, bagged trees gibi çoklu öğrenmeye dayalı sınıflandırıcılar kullanılmıştır. Sınıflandırma grupları ilk veri seti için fokal vs. non-fokal, ikinci veri seti için iktal vs. inter-iktal; iktal vs. pre-iktal; inter-iktal vs. pre-iktal ve son olarak iktal vs. inter-iktal vs. pre-iktal şeklindedir. Tüm işlemler MATLAB 2019A' da gerçeklenmiştir.

3. MATERYAL VE METOT

Bu çalışmada, MFCC ve makine öğrenmesi algoritmaları ile Bern Barcelona veri seti kapsamındaki fokal / non-fokal epileptik EEG kayıtlarının sınıflandırılması amaçlanmıştır. Bu amaç doğrultusunda, öncelikle MFCC'nin EEG veri setlerinin sınıflandırılmasında uygun öznitelikler üreterek gerekli yetiye sahip olup olmadığının tespiti hedeflenmiştir. Bu hedef için MFCC destekli makine öğrenmesi algoritmaları ile Hauz Khas veri seti kapsamındaki pre-iktal / iktal / inter-iktal EEG kayıtları sınıflandırılmıştır. Bu bölümde; tez çalışmasında kullanılan veri setleri, öznitelik çıkarım yöntemi, ön işlemler ve sınıflandırıcılar ayrıntılı bir şekilde anlatılmıştır.

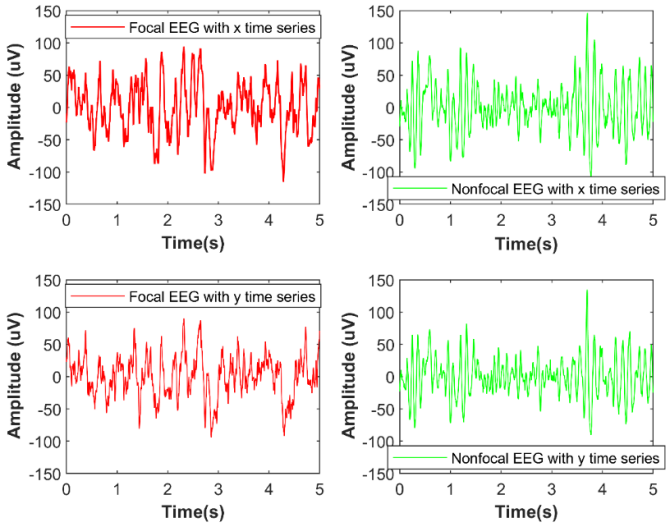
3.1. Kullanılan Veri Setleri

Bu tez çalışmasında iki farklı veri seti kullanılmıştır. Bunlar şu şekilde sıralanabilir;

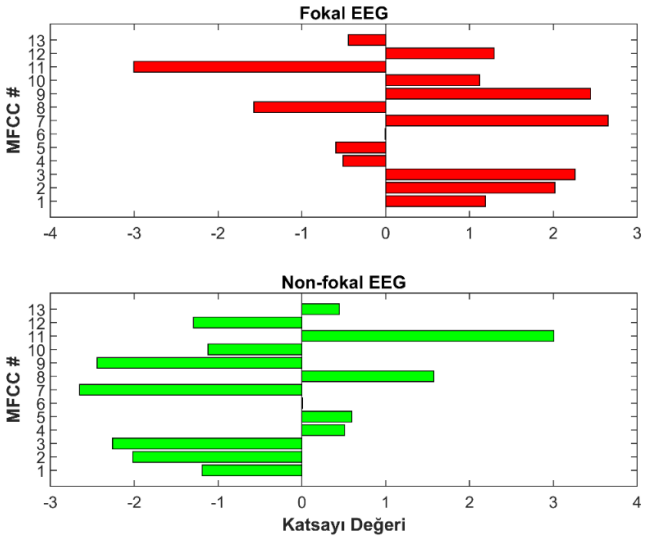
a) Bern Barcelona Epilepsi Veri Seti

İlgili tez çalışmasında fokal/non-fokal EEG bölütlerini içeren umuma açık Bern Barcelona EEG veri seti kullanılmıştır. İlgili veri setine www.dtic.upf.edu/ralph/sc/ linkinden ulaşılabilir. Mevcut kayıtlar İsviçre'nin Bern şehrinde yer alan Bern Üniversitesi Nöroloji Ana Bilim Dalındaki epileptik hastalardan alınan kayıtlardır (Andrzejak ve ark. 2012). Kayıtların toplandığı hasta grupları ilaçla tedaviye direnç gösteren ve operasyonla müdahale gereken 5 adet temporal lob epilepsiye sahip katılımcı içermektedir. Kayıtlar alınırken AD-TECH intakranial şerit elektrotlar beynin derin bölgelerine yerleştirilmiştir. Bu yöntem epilepsi cerrahisinde invaziv monitörizasyon türüdür. Alınan tüm kayıtları 512 Hz örnekleme frekansına sahiptir. Fokal ve Non-fokal EEG türlerinden 41.66 saat süresince kayıtlar toplanmıştır. Her EEG kaydı birbirine komşu kanallar olarak kabul edilen x ve y sinyal çiftlerinden oluşmaktadır. Bu şekilde hem fokal hem de non-fokal gruplar için 3750 kayıt bulunmaktadır. İlgili kayıt çiftleri 20 sn. uzunluğunda ve 10240 örneklem sayısına sahiptir. Veri seti 4. dereceden band geçiren Butterwoth filtresinden geçirilerek 0.5-150 Hz arası frekans bileşenlerine sahip olacak şekilde mevcut tüm gürültülerden arındırılmıştır. Bundan dolayı analiz edilecek veri setlerine ayrı bir filtreleme uygulamaya gerek kalmamıştır. MFCC özniteliği hesaplanırken her bir kayıt için x ve y kanalları (sütunları) benzer örüntüler içerdiğinden alt alta konumlanmıştır. 3750 adet kayıtların her biri için (10240x2) uzunluğunda tek bir sütun oluşturulmuştur. Buradaki

amaç 3750 adet MFCC katsayısı elde etmektir. 20480 örneklem uzunlukları ilgili bölütlere (epoklara) ayrılmıştır. Her bir epok uzunluğu $2^n \leq 0.03 * f_s$ formülasyonundaki n adet örneklem içerecek şekilde oluşturulmuştur. Hesaplanan MFCC katsayılarını içeren vektördeki değerlerin ortalaması alınarak tek bir MFCC değeri her kayda atanmıştır. Şekil 3.1' de 5 s uzunluğundaki örnek Fokal / Non-fokal EEG kayıtları (a) ve 13 katsayı için 3750 adet MFCC katsayılarının tümünün ortalamasını içeren çubuk grafikleri (b) verilmiştir.



(a)

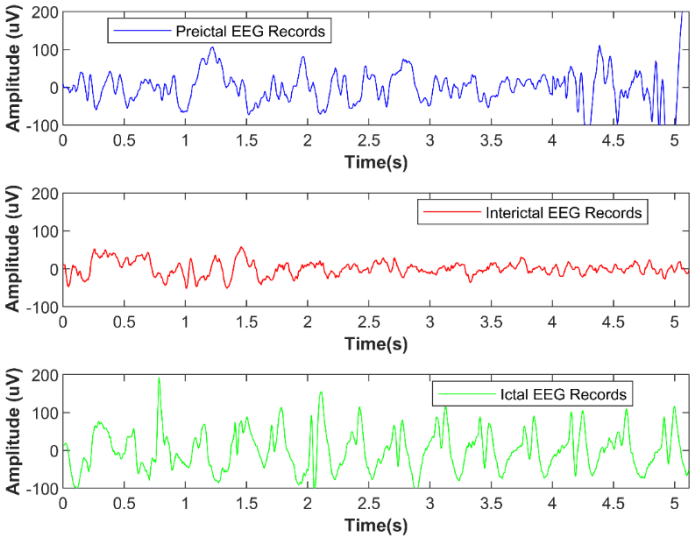


(b)

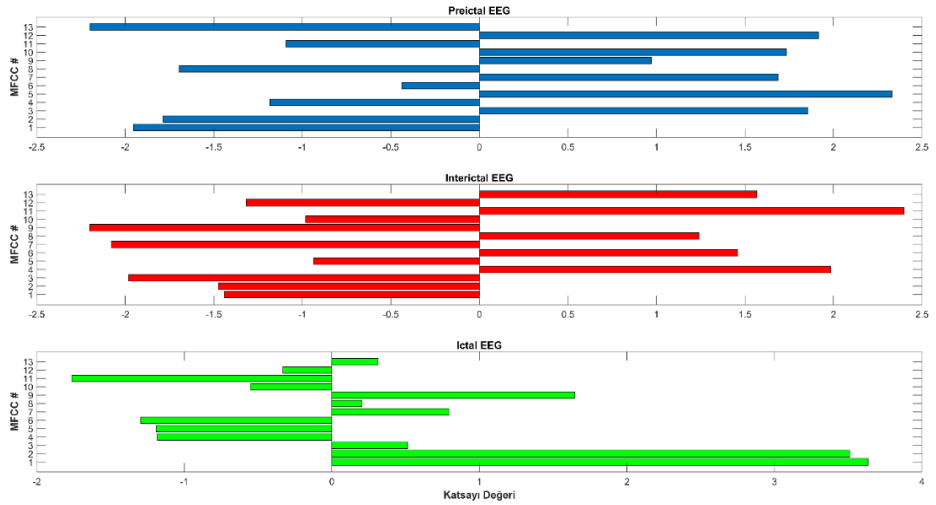
Şekil 3.1. (a) 5'er saniyelik x-y Fokal / Non-fokal EEG veri çiftlerine ait örnek kayıtları (b) Çıkarılan 13 adet MFCC özniteliklerine ait katsayı değerleri

b) Yeni Delhi Hauz Khas Epilepsi Veri Seti

İlgili veri seti Hauz Khas, Yeni Delhi Nöroloji ve Uyku Merkezi'nde 10 adet epilepsi hastasından derlenen EEG zaman serisi segmentlerini içermektedir. Kayıtlar herkes tarafından https://www.researchgate.net/publication/308719109 adresinden indirilebilir. Kayıtlar Grass Telefactor Comet AS40 Amplifikatör Sistemi kullanılarak 200 Hz örnekleme frekansı ile alınmıştır. Kayıtlar 0.5-70 Hz kesim frekansına sahip band geçiren filtreden geçirilmiştir ve türlerine göre preiktal, interiktal ve iktal EEG segmentlerine ayrılmıştır. İlgili veri seti segmentlerden oluştuğu için kanal bilgisi bulundurmamaktadır. Pre-iktal, inter-iktal ve iktal gruplarından her biri 5.12 s uzunluğundan 1024 örneklemden oluşan 50 adet EEG segmentine sahiptir. Sonuç olarak her grup 1024x50 uzunluğundadır. Bu veri setinde de epok uzunluğu benzer şekilde $2^n \leq 0.03 * f_s$ formülasyonundaki n adet örneklem içerecek şekilde oluşturulmuştur. 1024 örneklem uzunluklarının MFCC vektörleri elde edilerek 50 adet tek bir MFCC değeri her grup için elde edilecektir. Şekil 3.2' de 5.12 s uzunluğunda örnek pre-iktal / inter-iktal / iktal EEG kayıtları (a) ve 13 katsayı için 50 adet MFCC katsayılarının tümünün ortalamasını içeren çubuk grafikleri (b) verilmiştir. Mevcut analizler 3'lü bir sınıflandırma problemi olan pre-iktal vs. inter-iktal vs. iktal gibi zor bir sınıflandırma problemi adına denendikten sonra izlenilen yöntem fokal/non-fokal EEG kayıtlarının sınıflandırılmasında da kullanılacaktır.



(a)



(b)

Şekil 3.2 (a) Pre-iktal / İnter-iktal / İktal EEG kayıtlarına ait 5.12 saniyelik örnek kayıt (b) Çıkarılan 13 adet MFCC özniteliklerine ait katsayı değerleri

3.2. Metot

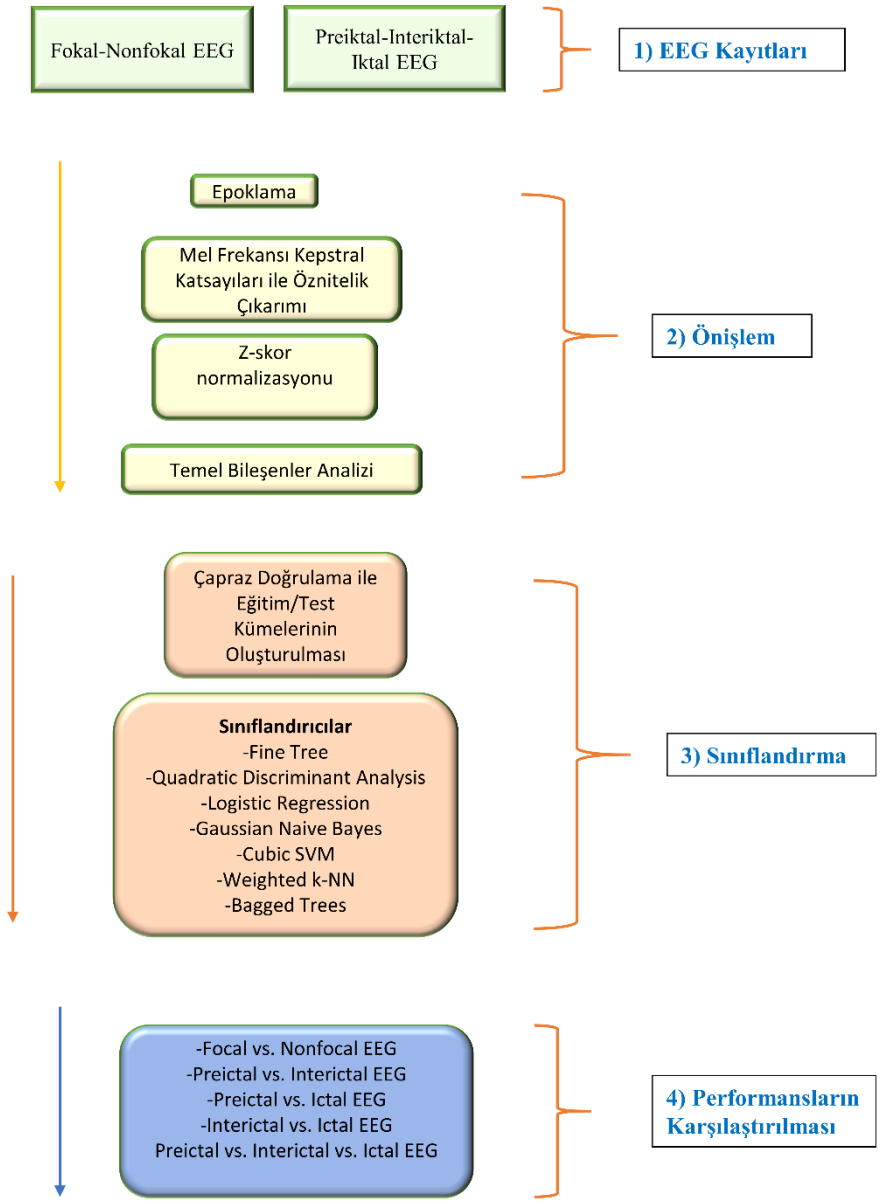
Tez konusu olan Fokal/non-Fokal EEG kayıtlarının sınıflandırılması ve MFCC yöntemine ilişkin yetisinin tespiti için kullanılan pre-iktal / iktal / inter-iktal EEG kayıtlarının sınıflandırılması sürecinde izlenen yaklaşım, tez kapsamında önerilen yaklaşım olup, toplam 4 ana adımdan oluşmaktadır.

i) EEG kayıtlarının elde edilmesi,

ii) EEG kayıtlarının bölütlere ayrılması, bölütlerden özniteliklerin hesaplanması ve normalizasyonu ile birlikte en uygun alt özellik kümesinin eldesi için boyut azaltımı,

iii) Özniteliklerin eğitim / test kümelerine ayrılması, belirlenen makine öğrenmesi algoritmaları ile sınıflandırma çalışmalarının yapılması ve sınıflandırma performanslarının karşılaştırılması,

iv) İkili sınıflandırma kapsamında; fokal vs. non-fokal EEG, pre-iktal vs. iktal, pre-iktal vs. inter-iktal, inter-iktal vs. iktal performanslarının belirlenmesi, ayrıca çoklu sınıflandırma kapsamında ise iktal vs. preiktal vs. inter-iktal performansının elde edilmesidir. Son olarak algoritmaların bu performansları kendi içinde karşılaştırılması gerçeklenmiştir. EEG kayıtlarının sınıflandırılmasında takip edilen adımlar Şekil 3.3.' de gösterilmektedir.



Şekil 3.3. Tez kapsamında gerçeklenen EEG sınıflandırma çalışmalarındaki işlem adımları

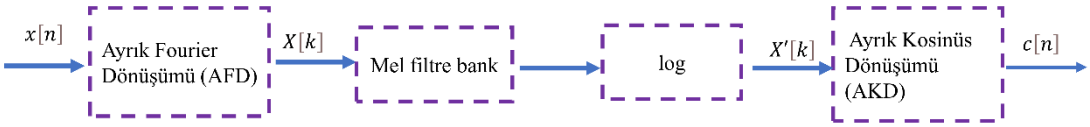
3. 2.1. Mel Frekansı Kepstrum Analizi

Bir sinyalde herhangi bir bileşene ait harmoniklik veya periyodiklik söz konusu ise, diğer bir deyişle sinyalin içeriğinde kendini sıkça tekrarlayan örüntüler var ise, bu işaretler kepstruma ait spektral analizde önemli bir bileşen olarak kabul edilir. Sinyalde kendini sıkça tekrar eden harmoniklerin var olması üst üste binmelerden dolayı analizlerde karışıklığa neden olacaktır. Bu tekrarlı zaman örüntüleri kepstral spektrum

ile sinyalden ayrıştırılabilir. Kepstrum analizi genel anlamda konuşma tanıma ve sismik sinyallerin analizinde kullanılır. Tanım olarak hesaplanan spektrum değerlerine ait logaritmik ifadelerin ters Fourier dönüşümü olarak da bilinmektedir. Bir sinyalin tekrarlı ve harmonik örüntüler içermesi, sinyale uygulanacak kepstrum analizini güçlü bir işaretçi haline getirmektedir (Oppenheim ve Schafer 2004). Bir sinyalin kepstral domeini aktarımına ilişkin izlenen adımlar Şekil 3.4.' de verilmiştir. x$[n]$ bir zaman sinyalidir ve EEG sinyaline tekabül etmektedir. X$[k]$, x$[n]$' nin frekans spektrumunu temsil etmektedir. X'$[k]$ ise hesaplanan spektrum değerlerine ait filtre banklarından elde edilen enerji değerlerine ait logaritmik bir büyüklüktür. c$[n]$, X'$[k]$' nın Ayrık Kosinüs Dönüşümü sonrası elde edilen kepstrum değeridir. Kepstrum katsayısı c_j Denklem (1)' de gösterildiği üzere, Mel filtresinin çıkışına ait değerlerden hesaplanır.

$$c_j=\sqrt{\frac{2}{N}}\sum_{i=1}^{N} A_i \cos\left(\frac{\pi j(i-0.5)}{N}\right) \quad 0 \leq \mathrm{j} \leq \mathrm{N} \tag{1}$$

Denklemde yer alan c_j terimi, *j.'* ci kepstral katsayısı ve A_i terimi ise filtre banklarına ait en kararlı filtre banklarından birinin logaritmik değerini ifade eder.



Şekil 3.4. Kepstrum katsayılarının hesaplanmasında izlenilen yol

R=1, 2, … r için spesifik bir n zamanında Mel frekansına ait spektrum, Denklem 2' deki gibi hesaplanır.

$$\mathrm{M}F_n[r]=\frac{1}{A_r}\sum_{k=L_r}^{U_r}|V_r[k]X_n[k]|^2 \tag{2}$$

$V_r[k]$ ifadesi r. dereceden filtrenin üçgen ağırlıklandırılmış fonksiyonu ve ayrık Fourier Dönüşümünün (AFD) indeksi olan k ise L_r ile U_r arasındadır. Buna ek olarak A_r terimi r. dereceden normalize edilmiş Mel filtre katsayısıdır ve Denklem (3)'te belirtilmiştir.

$$A_r=\sum_{k=L_r}^{U_r}|V_r[k]|^2 \tag{3}$$

Mel frekans kepstral katsayıları filtre çıkışlarına ait logaritmik değerlerin ayrık kosinüs dönüşümü şeklinde hesaplanır. Detaylar Denklem (4)' te verilmiştir.

$$MFCC_n[m] = \frac{1}{R}\sum_{r=1}^{R} \log\left(MF_n[r]\right) cos\left[\frac{2\pi}{R}\left(r+\frac{1}{2}\right)m\right] \quad (4)$$

Yukarıda da belirtildiği üzere R=1, 2, …, r ve $MF_n[r]$ spesifik bir n zamanında Mel frekansına ait spektrum değeridir.

MFCC özniteliklerinin hesaplanması şu şekilde özetlenebilir: ilgili EEG kayıtları istatiksel olarak daha durağan ve içerdiği örneklerin zaman içinde pek değişmediği için daha küçük segmentlere bölünür. İlgili bölütlerdeki frekans değişimlerinin gözlemi güç spektrum hesabı ile elde edilir. Burada AFD tabanlı spektrum kestirim yöntemleri de kullanılabilir. Sonrasında farklı frekanslarda ne kadar enerjinin var olduğunun hesabı Mel filtre banklarının uygulanması ile gerçekleştirilir. Örnek vermek gerekirse 1. Filtre bankı 0 Hz. dolaylarında var olan enerjiyi hesaplayan çok dar bir yapıdadır. Frekans değerleri arttıkça ilgili filtre de genişlemektedir. Elde edilen enerji değerlerinin logaritmik değeri hesaplanarak kepstral ortalama değerleri tüm değerlerden çıkarılacak sıkıştırma işlemine benzer bir normalizasyon işlemi yapılır. Filtre banklarının örtüşen şekilde dizilmesi, hesaplanan enerji değerleri arasında bir korelasyona sebebiyet verir. Bu etkileşimin azaltılması için Ayrık Kosinüs Dönüşümü (AKD) kullanılarak 26 adet AKD katsayısı hesaplanır. Bu katsayılardan ilk 12 adedi tutulup gerisi atılır. Bunun nedeni 12.'den sonraki yüksek katsayılarına ait filtre bank enerjilerinde hızlı değişimler gözlemlenebilir. Bu değişimler elde edilecek performans verilerinde düşüşe sebebiyet olabilir. Bu nedenle tez çalışmasında 0. katsayıyı da içermek şartıyla 13 adet kepstral katsayı hesaplanmıştır. Tez çalışmasında kepstral katsayıların elde edilmesinde Mike Brokes tarafından düzenlenen MATLAB tabanlı Voicebox Toolbox (http://www.ee.ic.ac.uk/hp/staff/dmb/voicebox/voicebox.html)'ı kullanılmıştır (Brokes 2010). İlgili Toolbox ses analizi üzerine konuşma analizi ve sentezi, frekans tabanlı spektrum hesaplamaları, vektörel hesaplamalar, bilgisayarlı görü vb. gibi alt başlıklar içermektedir. Bu tez çalışmasında kepstral katsayıların hesaplanmasında v_melcepst.m fonksiyonundan faydalanılmıştır. Genel itibari ile ilk 12 katsayıya ek olarak enerji katsayısının da eklenmesiyle 13 statik parametre şeklinde katsayıları hesaplanır. Çalışmanın gürbüzlüğünü ve kararlılığını arttırmak amacı ile dinamik parametreler de hesaba katılarak ardışık zaman çerçevelerine ait bilgilerin edinilmesi sağlanmış ve bu amaçla 1. dereceden zaman türevi ('delta') ve 2. dereceden zaman türevi ('delta-delta') katsayıları da eklenmiştir. Toplamda hem fokal / non-fokal EEG kayıtları hem de iktal / pre-iktal / inter-iktal EEG veri setleri için 42 adet katsayı hesabı yapılarak öznitelik

vektörleri elde edilmiştir. Literatürdeki çalışmalardan bazıları tüm katsayıları analiz ederek daha yüksek başarım değerleri elde etmişlerdir (Yavuz ve ark 2018). Tüm bu işlem adımlarında güç spektrum kestiriminde Hamming penceresi, Mel domeninde ise üçgen şekilli filtreler uygulanmıştır.

3.2.2 Z-Skor normalizasyonu ve Temel Bileşenler Analizi

Bu tez çalışmasında kullanılan veri setine ait değişkenler farklı skalalara ait olduğu için çalışmada normalizasyon işlemi kullanılmıştır. Normalizasyon, sinyal işleme tekniklerinde verilerin dengeli bir ölçekte değerlendirilmesi ve örüntü sınıflandırma performansını artırma amacıyla oldukça yaygın kullanılan bir yöntemdir. Genellikle çok büyük verileri minimize edip çok küçük verileri maksimize ederek veriler arasındaki ortalamayı sağlar. Bu kapsamda eğitim örüntülerinin boyutunu küçültmek amacıyla Temel Bileşen Analizi kullanılmış ve bu yöntemi kullanabilmek için verilerin düzgün dağılıma sahip olması gerekmektedir. Bundan dolayı normalizasyon işleminde, Z-skor normalizasyonu seçilmiştir. Ortalama μ standart sapması σ herhangi bir X değişkeni için Z-skor normalizasyonu denklem (5)' te belirtilmiştir.

$$Z=\frac{(x-\mu)}{\sigma} \tag{5}$$

Temel bileşenler analizi oldukça yaygın kullanılan çok değişkenli istatistiksel bir yöntemdir. Aynı zamanda en eski çok değişkenli tekniklerden biridir. Genel olarak birbiriyle bağlantılı değişkenler bir araya gelir ve ortaya çıkan bağımlı dizinler, veri tablosu analizinde kullanılır. Burada hedeflenen verilerden önemli bilgileri elde etmektir. Temel bileşenler analizi ayrıca gözlemlerin benzerlik modelini ve değişkenleri haritalarda noktalar halinde göstererek temsil eder (Abdi ve Williams, 2010).

Temel bileşenler analizi $C_x = XX^T$ kovaryans matristen eigen (özgün) değerleri hesabına dayanır. Burada, X ifadesi (nxt) boyutlarında bir matris kümesi olup, n terimi öznitelik sayısını ve t terimi ise gözlem sayısı olarak ifade edilir. Denklem (6)' da ilk p adet bileşene ait varyansın tüm öznitelik kümesindeki varyansa oranı hesaplanmıştır.

$$\mathrm{R}V_{1:n}=\frac{\sum_{i-1}^{p}\lambda_i}{\sum_{i-1}^{n}\lambda_i} \tag{6}$$

Denklemde yer alan $\lambda_i$terimi; i. temel bileşene ait eigen değerini ifade eder.

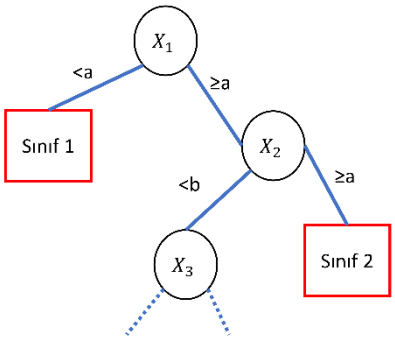
Temel bileşen sayısı verinin büyük bir kısmını açıklayabilecek varyans değerine bağlıdır. Bu tez çalışmasında 42 katsayı arasından 11 bileşen toplam varyansın %95'ni

açıklamaktadır. Bu nedenle boyut azaltımında ilk 11 temel bileşen kullanılacaktır. Sonuç olarak fokal/non-fokal EEG sınıflandırma probleminde öznitelik vektör boyutu 7500 x 12 (11 temel bileşene ek olarak sınıf etiketi); inter-iktal, pre-iktal ve iktal grupların her biri için 50x12 (11 temel bileşene ek olarak sınıf etiketi) şeklindedir.

3.2.3 Sınıflandırıcılar

i) Fine Tree

Karar ağaçları büyük miktardaki girişleri bazı karar verme kuralları uygulayarak daha küçük alt yapılara bölme mekanizmasına sahiptir. Bir karar ağacı önceden tanımlanmış hedef değerlerine sahiptir ve yapıları gereği yukarıdan aşağıya doğru bir strateji sağlar. Karar ağaçları kolaylıkla uygulanabilir, numerik ve kategorik verileri kolayca işleyebilir. Karar ağaçları aynı zamanda düşük miktarda performans metrikleri sunabilir ve sınıflandırmaya ait sonuç ezberleme ile sonuçlandırılabilir. Bu problemler daha basit ağaç yapıları ile çözülebilir. Buna ek olarak maksimum sayıda dallanma veya budaklanma sayısı ile ağacın derinliği kontrol edilebilir. Şekil 3.5.'de örnek bir karar ağacı şeması gösterilmiştir. X değerleri karar düğümleridir. Her bir düğüm bir özellikle bağlantılıdır. A ve b değerleri ise ilgili özellikleri farklı karar dallarına ayıran nominal ve nümerik olabilen değerlerdir. Sınıf değerleri ağacın yapraklarını temsil eder ve analiz sonucu sınıflandırılacak objeler bu sınıflara atanır.



Şekil 3.5. Karar ağacı örneği

Bu tez çalışmasında sınıflandırıcı olarak Fine Tree kullanmamızın sebebi algoritmaya ait hızlı tahmin, kolay uygulanabilirlik ve sınıfları ayırt etmede modele ait esnekliktir (Joga ve ark. 2021). Mevcut modelde farklı sayılar seçilmiş olup en iyi sınıflandırma başarım oranı olarak maksimum bölünme sayısı 100 seçilmiştir ve bölünme ölçütü olarak Gini çeşitlilik indeksi kullanılmıştır.

ii) Quadratik Diskriminant Analiz

Diskriminant analizi sınıfları hiper düzlemler aracılığıyla maksimum 'likelihood' kuralı ile birbirinden ayırır. 2 veya daha fazla grubu çok değişkenli teknikle birbirinden ayırır ve kullandığı algoritma hızlı, kesin ve kolay uygulanabilir türdendir. Bunlara ek olarak diskriminant analiz, büyük veri setleri için oldukça avantajlıdır. Bir sınıflandırıcıyı eğitmek için farklı Gauss dağılımları üretilir ve bu dağılımlara ait parametrelerin uygunluk fonksiyonları tahmin edilir. En yaygın algoritma türleri lineer (LDA) ve quadratik diskriminant analiz (QDA) şeklindedir. QDA quadratik karar sınırlarında kullanılır ve tahmin kabiliyeti lineer olana göre daha yüksektir. QDA her bir giriş sınıfına ait kovaryans matrisleri tahmin eder (Canizo ve ark. 2019). LDA ve QDA verinin k adet sınıf için P $(X|y = k)$ sınıflara şartlı dağılım olan olasılıksal bir modelden türetilir. Tahminler Bayes kuralına dayanır ve genel gösterimi Denklem (7)'deki gibidir:

$$\mathrm{P}\,(y = k|x) = \frac{\mathrm{P}\,(x|y=k)P(y=k)}{P(x)} = \frac{\mathrm{P}\,(x|y=k)P(y=k)}{\sum_l \mathrm{P}\,(x|y=l)P(y=l)} \quad (7)$$

Denklem (7)'deki sonsal olasılığı maksimize eden k sınıfı seçilir.

iii) Lojistik Regresyon

Lojistik regresyon (LR) bir ikili sınıflandırma algoritmasıdır ve lineer tahminlere ait kombinasyonları içeren lojistik fonksiyonları kullanarak sınıflara ait olasılıkları modeller (Şeker ve ark. 2021). LR tahmin edilecek değişkenler ancak kategorik ise kullanılabilir. İlgili sınıflandırma türünde y değişkeninin olma olasılığı ile veri setindeki x markerları arasındaki ilişkiyi açıklamaya yardıINT olur. Bu ilişki Denklem (8)'deki gibi açıklanabilir:

$$\mathrm{P}\,(\mathrm{y}=1|x) = \frac{e^{\beta_0+\beta_1 x}}{1+ e^{\beta_0+\beta_1 x}} \quad (8)$$

Denklem (8)'deki β_n değerleri regresyon katsayılarına ait kümelerdir. İşlem sonucu elde edilecek değer bir olasılık değeri olduğu için sigmoid fonksiyonu kullanılarak değer [0-1] arasına getirilir. LR' de birçok parametre arasından ilgili veri setinin görülme olasılığını en üst düzeye çıkaran Maksimum Likehood yöntemi kullanılarak en iyi parametreler seçilir.

iv) Gauss Naive Bayes

Naive bayes (NB) örüntü tanıma problemlerinde kullanılır ve bayes teoremine dayanır. Bu sınıflandırıcıda belli miktardaki eğitilmiş veri, giriş olarak uygulanır.

Eğitim için verilen bu veri, bir sınıfa veya kategoriye sahip olmalıdır. Eğitilmiş verideki olasılıksal işlemlerle yeni test verisinin kategorisi belirlenir. Eğitilmiş verinin sayısı ne kadar çok artarsa test verinin ait olduğu sınıfı tanımlamak daha etkili hale gelecektir (Siuly ve ark. 2016).

Her k özellik için n adet sınıf varsayılır ve çalışılan veri setinin bu sınıfa ait olduğu düşünülür. Sınıfı belirli olmayan Y verisi Denklem (9)'da gösterilmiştir. Buna göre, bu verinin tüm sınıflar için ait olma olasılıkları hesaplanır. Sonuçlardan büyük olan hedef alınır ve verinin hangi sınıfa ait olduğu belirlenir. Bu tez çalışmasında numerik tahminler için Gauss dağılımı ve çok değişkenli çok boyutlu kategorik tahminciler uygulanmıştır.

$$P(S_i \mid Y) = \frac{P(Y \mid S_i) * P(S_i)}{P(Y)} \tag{9}$$

$P(S_i \mid Y)$: Y için S' nin olasılığı

$P(Y \mid S_i)$: S için Y' nin olasılığı

$P(Y), P(S_i)$: Y ve S için gerçekleme olasılığı

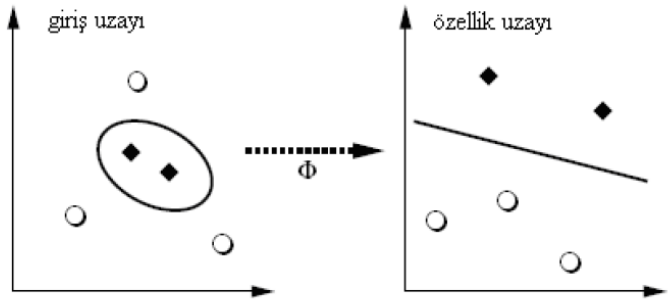
Her Y verisi sınıflandırmada eşit duruma sahiptir. Bu sebeple $P(Y)$ değeri her örnek veri için aynı olur. Sonuç olarak Denklem (9)' da yeniden yazılabilir.

$$P(S_i \mid Y) = P(Y \mid S_i) * P(S_i) \tag{10}$$

Denklem (10) her sınıf için elde edilmiş olup değerlerine göre örnek sınıfı belirlenmiştir.

v) Kübik Destek Vektör Makinası

İstatistiksel öğrenme tabanlı destek vektör makinası ilk olarak ikili bir sınıflandırma işlemi için Cortes ve Vatnik tarafından uygulanmıştır. Destek vektör makinasının (DVM) amacı lineer olarak ayrılamayan örnekleri çekirdek fonksiyonları kullanarak daha üst bir boyuta taşımak ve mevcut örnekleri quadratik optimizasyon problemlerinin çözümü yardımıyla ayırabilecek bir hiper düzlem tanımlamaktır (Djoufack ve ark. 2020). Normalde doğrusal olarak ayrıştırılamayan verilerin çekirdek fonksiyonu kullanarak özellik uzayına aktarım işlemi Şekil 3.6.'da gösterilmiştir.



Şekil 3.6. Giriş vektörünü özellik uzayına ayrılabilir düzeyde aktarma

d boyutlu giriş uzayına ait eğitim kümesini yüksek boyutlu *H* Euclid özellik uzayına aktaran Φ fonksiyonu Denklem (11)'deki gibi yazılır:

$$\Phi: R^d \rightarrow H \tag{11}$$

H uzayına ait verilerin $\Phi(x_i)$. $\Phi(x_j)$ şeklindeki iç çarpanı DVM'nin eğitim aşamasını doğrudan etkiler. H uzayındaki bu iç çarpımın hesapsal yükü olduğundan çekirdek fonksiyonları ile düşük boyutlu giriş uzayında bu işlem gerçekleştirilir. K ile ifade edilen çekirdek fonksiyonların genel ifadesi Denklem (12)'deki gibidir:

$$K(x_i, x_j) = \Phi(x_i).\ \Phi(x_j) \tag{12}$$

Mevcut tez çalışmasında kübik çekirdek fonksiyonu kullanılmıştır. Çekirdeğe ait ölçek otomatik olarak tanımlanmış ve 'box constraint' seviyesi 1 olarak sabitlenmiştir. Doğrusal olmayan veri kümesini yüksek boyutlu özellik uzayında ayırt edici düzlemin belirlenmesinde aşağıda ifade edilen optimizasyon problemi rol alır:

$$\text{Minimizasyon } L_{ikincil}(\alpha_i) = \sum_{i=1}^{k} \alpha_i - \frac{1}{2} \sum_{i,j=1}^{k} \alpha_i\, \alpha_j\, y_i\, y_j\, K(x_i, x_j) \tag{13}$$

$$\text{Kısıtlamalar: } \sum_{i=1}^{k} \alpha_i\, y_i = 0,\ 0 \leq \alpha_i \leq C \quad i = 1, \ldots, k \tag{14}$$

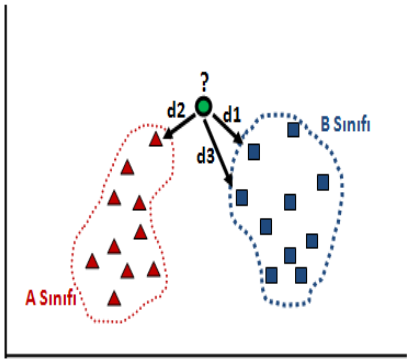
Minimizasyon ile verilen eşitlik çözülecek problemi, kısıtlamalar ise problemin hangi koşullar altında çözüleceğini gösterir. Kısaca buradaki işlem 2. Dereceden bir optimizasyon işlemidir. Fokal / non-fokal EEG kayıtlarının ayrıştırılmasında ikili sınıflandırma metodu kullanılmıştır.

vi) Ağırlıklandırılmış En Yakın Komşuluk

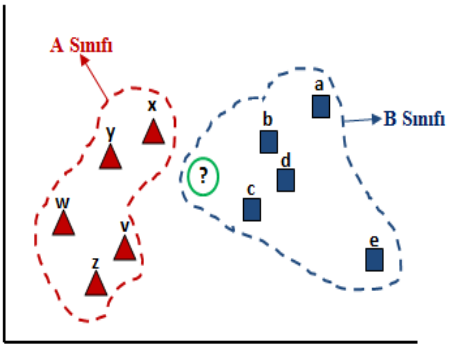
Bu sınıflandırma türü parametrik, lineer olmayan ve kısmen basit bir algoritmadır. Sınıflandırmaya ait adımla Şekil 3.7-3.8'de verilmiştir. k-NN büyük veri setleri için üstün başarı sağlayabilir. Algoritma genel anlamda eğitim ve test kümelerinin birbirlerine olan benzerliklerine dayanır. Bir sınıfa atanan herhangi bir

verinin tanımlanması k adet ilgili komşu veri kontrol edilerek yapılır. K çok küçük seçilirse algoritma çok hassas davranabilir. K çok büyük seçilirse bir sınıf diğer sınıfa ait çok fazla veriyi kapsayabilir. Ağırlıklandırılmış k-NN' de her komşu örneğin test verisine olan mesafesine göre bir ağırlığı vardır. Daha yakın noktalar oylama aşamasında daha büyük ağırlıklara sahiptir (Tang ve ark. 2016). Mevcut tez çalışmasında komşuluk sayısı 10, mesafe metriği öklit ve mesafe ağırlığı 'squert inverse', diğer bir deyişle ağırlık $1/mesafe^2$ olarak tanımlanır. Öklit uzaklığı Denklem (15)' te gösterildiği gibidir.

$$d(x,y) = \sqrt{\sum_{i=1}^{n}(X_i - Y_i)^2} \tag{15}$$



Şekil 3.7. Veri sınıfının belirlenme süreci



Şekil 3.8. Verinin sınıflandırılması

vii) Bagged Trees

Bagged trees (BT) bir çeşit çoklu sınıflandırıcı türü olup karar ağaçları ile rastgele orman algoritmalarını bir arada kullanır (Pavlov 2019). Bu çalışmada Breiman tarafından önerilen algoritma özellik kümelerine uygulanmıştır. Bagg işleminin tercih edilme sebebi karar ağaçlarına ait varyans değerlerini azaltmasıdır. Eğitim kümesinden birçok alt küme rastgele seçilir ve bu alt kümelerden her biri kendi karar ağaçlarını

eğitir. Sonuç olarak farklı modeller içeren bir çoklu öğrenme modeli oluşturulur. Ağaçlardan elde edilen tahminlerin ortalaması alınır, bir tane karar ağacından ziyade daha gürbüz bir tahmine ulaşılır.

C (S, x) x giriş değerleri için sınıf etiketi tahmini yapan ve eğitim kümesi S' e dayalı bir ağaçlı temelli sınıflandırıcı olarak düşünülürse, C adına bagg işlemi için her biri N boyutunda $S^{*1}, \ldots, S^{*B}$ boostrap örnekleri ile aşağıdaki gibi elde edilir:

$$C_{bag}(x) = \text{Çoğunluklu Oylama } \{C(S^{*B}, x)\}_{b=1}^{B} \quad (16)$$

Bu çalışmada çoklu öğrenme metodu bagg, öğrenme türü karar ağacı ve öğrenen sayısı 30 olarak belirlenmiştir.

3.2.4 Performans Ölçümleri

i)İkili sınıflandırmaya dayalı ölçümler

Bu tez çalışmasında, sınıflandırılma performanslarının değerlendirilmesi için doğruluk, duyarlılık, özgüllük, F1-skor değeri ve Alıcı Çalışma Karakteristiği (ROC) Eğrisi Altında Kalan Alan (AUC) değerleri hesaplanmıştır. Performans ölçümlerinin hesaplanması Çizelge 3.1'de gösterilmiştir.

Çizelge 3.1. İkili sınıflandırma performans ölçümü için kullanılan metrikler

		Tahminlenen		
		Pozitif	**Negatif**	
Gerçekleşen	**Pozitif**	Gerçek Pozitif (GP)	Yanlış Negatif (YN)	Duyarlılık $\frac{GP}{GP+YN}$
	Negatif	Yanlış Pozitif (YP)	Gerçek Negatif (GN)	Özgüllük $\frac{GN}{GN+YP}$
		Kesinlik $\frac{GP}{GP+YP}$	Duyarlılık $\frac{GP}{GP+YN}$	Doğruluk $\frac{GP+GN}{GP+YP+YN+GN}$

$$Doğruluk = \frac{GP+GN}{GP+YP+YN+GN} \quad (17)$$

$$Duyarlılık = \frac{GP}{GP+YN} \quad (18)$$

$$Özgüllük = \frac{GN}{GN+YP} \quad (19)$$

$$F1 - skor = 2 * \frac{Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık} \quad (20)$$

Hesaplanacak AUC değerlerinin hesabı ise şu şekildedir: her fold değeri için (bu tez çalışmasında k=10 fold) AUC değerleri hesaplanıp sonrasında elde edilen skorların ortalaması alınarak tek bir AUC değeri hesaplanarak analizlerde yerini almıştır. Bir veya birden fazla fold'da AUC değerinin düşük çıkması ortalamayı genel itibari ile düşürebilir. Bu metod dezavantajlı gibi görünse de her fold'un etkisini ortalama yansıtması itibari ile daha realistik bir yaklaşımdır.

Yukarıdaki performans metrikleri fokal/non-fokal EEG kayıtlarının sınıflandırılması adına şöyle açıklanabilir: Eğer bir bölüte fokal denilir ve o bölüt fokal ise GP, bir bölüt fokal değil denilir (non-fokal ise) ve o bölüt fokal değilse GN, bir bölüt fokal olup non-fokal olarak belirlenirse YN ve son olarak bir bölüt fokal olmayıp (non-fokal) fokal olarak seçilirse YP şeklinde ifade edilir.

Doğruluk ifadesi doğru tahmin edilen alanların toplam veri kümesine oranıdır. Fokal ve Non-fokal EEG bölütlerinin olduğu veri kümesinde belirli miktar fokal EEG tespiti yapılıp verinin geri kalan kısmında fokal olup tespit edilemeyen (YN) bölütlerin tespiti adına diğer metriklere de bakmak gerekir. Duyarlılık değeri YN olarak tahminlenen kısmın yüksek olduğu durumlarda yardımcı olan bir metriktir. Mümkün olduğunca yüksek olması gerekir. Özgüllük metriği fokal olmayan bir bölüte fokal değil teşhisi koyma oranını belirtir. F1-skor kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır ve böylelikle uç değerlerin durumları da göz ardı edilmez. Tüm hata maliyetlerini içeren bir ölçme metriği olan F1-skor doğruluk yerine kullanılan güvenilir bir ölçümdür.

ii) Çoklu sınıflandırmaya dayalı ölçümler

Tez çalışmasında ikili sınıflandırmanın yanı sıra preiktal vs. interiktal vs. iktal gibi çoklu bir sınıflandırma için de doğruluk, duyarlılık, özgüllük ve F1-skor gibi metriklerin hesaplanması gerekmektedir. Çizelge 3.2'deki karmaşıklık matrisinde 3'lü sınıflandırma için GP, GN, YP ve YN değerleri belirtilmiştir. Bu değerler Denklem (17-20)'ye uygulanarak çoklu sınıflandırma için yeni performans metrikleri elde edilmiştir.

Çizelge 3.2.Çoklu sınıflandırma performans ölçümü için kullanılan metrikler

		Tahminlenen				
		IK	INT	PR	**YN**	**GN**
Gerçekleşen	IK	**GP IK:** IK-IK	IK-INT	IK-PR	IK-INT+ IK-PR	INT-INT+ INT-PR+ PR-INT+ PR-PR
	INT	INT-IK	**GP INT:** INT-INT	INT-PR	INT-IK+ INT-PR	IK-IK+ IK-PR+ PR-IK+ PR-PR
	PR	PR-IK	PR-INT	**GP PR:** PR-PR	PR-IK+ PR-INT	IK-IK+ IK-INT+ INT-IK+ INT-INT
	YP	INT-IK+ PR-IK	IK-INT+ PR-INT	IK-PR+ INT+PR		

PR: Preiktal, INT: Interiktal, IK: İktal, GP: Gerçek Positif, GN: Gerçek Negatif, YN: Yanlış Negatif, YP: Yanlış Positif

4. BULGULAR VE TARTIŞMA

Bu çalışmada, MFCC ve makine öğrenmesi algoritmaları ile Bern Barcelona veri seti kapsamındaki fokal / non-fokal epileptik EEG kayıtlarının sınıflandırılması amaçlanmıştır. Bu amaç doğrultusunda, öncelikle MFCC'nin EEG veri setlerinin sınıflandırılmasında uygun öznitelikler üreterek gerekli yetiye sahip olup olmadığının tespiti hedeflenmiştir. Bu hedef için MFCC destekli makine öğrenmesi algoritmaları ile Hauz Khas veri seti kapsamındaki pre-iktal / iktal / inter-iktal EEG kayıtları sınıflandırılmıştır. Bu bölümde yapılan analizler sonucunda elde edilen bulgular ve tartışma yer almaktadır.

Tez kapsamında literatürde yaygın kullanıma sahip 2 adet veri seti irdelenmiştir. Bern Barcelona veriseti, Fokal ve Non-Fokal EEG kayıtları olmak üzere iki (binary) sınıftan oluşmaktadır. New Delphi, Hauz Khas veriseti ise pre-iktal, iktal ve inter-iktal EEG kayıtları olmak üzere üç sınıftan oluşmaktadır. Bu verisetlerinin analizinde ve sınıflandırılmasında MFCC katsayıları kullanılmıştır. Elde edilen öznitelik kümelerine z-skor normalizasyon uygulanarak katsayıların dağılımı belirli bir aralığa indirgenmiş, sonrasında Temel Bileşen Analiz yöntemiyle çıkarılan öznitelik kümelerini en optimum düzeyde karşılayan alt veri kümelerine indirgenmiştir. Sınıflandırma aşamasında ise farklı konvansiyonel sınıflandırıcı gruplarından birer adet seçilerek epileptik gruplara ait EEG kayıtları birbirinden ayrıştırılmıştır.

Sınıflandırma algoritmalarına ilişkin başarım sonuçlarının karşılaştırılmasında ve değerlendirilmesinde; doğruluk, duyarlılık, özgüllük, F1-skor ve ROC eğrisi altında kalan alan gibi literatürde genel olarak başvurulan performans metriklerine bu bölümde yer verilmiştir. Doğruluk parametresi tek başına güvenilir bir metrik değildir. F1-skor hesabında, duyarlılık ve özgüllük parametreleri de yer almaktadır. Bu nedenle literatürde en güvenilir performans metriklerinden biridir. Analizlerle ilgili yorumlar bu bilgi ışığında değerlendirilmiştir.

Öncelikle MFCC'nin EEG veri setlerinin sınıflandırılmasında uygun öznitelikler üreterek gerekli yetiye sahip olup olmadığının tespiti hedeflenmiş olduğundan, Hauz Khas veri seti kapsamındaki pre-iktal / iktal / inter-iktal EEG kayıtları MFCC destekli makine öğrenmesi algoritmaları ile sınıflandırılmıştır. Elde edilen bulgular 4.1 alt bölümünde verilmiştir.

4.1. Hauz Khas EEG Kayıtlarının (Pre-iktal, İnter-iktal ve İktal EEG) Sınıflandırılmasından Elde Edilen Bulgular

a) Sınıflandırma Sonuçları ve Performans Metrikleri

Hauz Khas EEG veri setinde pre-iktal, inter-iktal ve iktal EEG gruplarından her biri 50 epoktan oluşmaktadır. Benzer bir düşünce ile her epoktan 1 adet MFCC katsayısı hesaplanarak öznitelik kümeleri oluşturulmuştur. Oluşturulan karmaşıklık matrisleri bölütler bazlı sınıflandırma şeklinde temellendirilmiştir. Mevcut EEG kayıtlarının sınıflandırılmasında ikili ve çoklu örüntüler mevcuttur. İkili sınıflandırma pre-iktal vs. inter-iktal, pre-iktal vs. iktal, inter-iktal vs. iktal; daha bir zorlu olan çoklu sınıflandırma ise pre-iktal vs. inter-iktal vs. iktal şeklindedir.

Çizelge 4.1'de pre-iktal vs. inter-iktal EEG kayıtlarına ait sınıflandırma metriklerine yer verilmiştir. Qadratik Diskriminant Analiz (QDA), Lojistik Regresyon (LR) ve kübik Destek Vektör Makinası (DVM) ile tüm pre-iktal ve inter-iktal epokları doğru olarak sınıflandırılmıştır. Bagged Trees (BT) bu aşamada en düşük performansı gösteren algoritma olarak göze çarpmaktadır. 50 pre-iktal EEG bölütünden 3'ü inter-iktal; 50 inter-iktal EEG segmetinden 8'i ise pre-iktal olarak sınıflandırılmıştır. Doğruluk %89, duyarlılık %85.4, özgüllük %93.33, F1-skor 0.89 ve AUC 0.96 olarak elde edilmiştir.

Çizelge 4.1 Pre-iktal / İnter-iktal sınıflandırma sonuçları ve performans metrikleri

		Tahminlenen		Performans Metrikleri				
Sınıflandırıcı	**Gerçekleşen Sınıf**	**Preiktal**	**interiktal**	**Doğruluk (%)**	**Duyarlılık (%)**	**Özgüllük (%)**	**F1-skor**	**AUC**
Fine Tree	**preiktal**	46	4	93	93.8	92.15	0.92	0.93
	interiktal	3	47					
Quadratic Discriminant Analiz	**preiktal**	50	0	100	100	100	1	1
	interiktal	0	50					
Lojistic Regresyon	**preiktal**	50	0	100	100	100	1	1
	interiktal	0	50					
Gaussian Naive Bayes	**preiktal**	50	0	98	96.15	100	0.98	1
	interiktal	2	48					
Kübik DVM	**preiktal**	50	0	100	100	100	1	1
	İnteriktal	0	50					
Ağırlıklandırılmış k-NN	**Preiktal**	49	1	99	100	98	0.99	1
	interiktal	0	50					
Bagged Trees	**preiktal**	47	3	89	85.4	93.33	0.89	0.96
	interiktal	8	42					

Çizelge 4.2.'de pre-iktal vs. iktal EEG kayıtlarına ait sınıflandırma metriklerine yer verilmiştir. QDA, LR ve kübik DVM ile tüm pre-iktal ve iktal epokları doğru olarak sınıflandırılmıştır. Fine Tree (FT) bu aşamada en düşük performansı gösteren algoritma

olarak göze çarpmaktadır. 50 pre-iktal EEG bölütünden 6'sı iktal; 50 iktal EEG segmetinden 7'si ise pre-iktal olarak sınıflandırılmıştır. Doğruluk %87, duyarlılık %86.27, özgüllük %87.75, F1-skor 0.87 ve AUC 0.89 olarak elde edilmiştir.

Çizelge 4.2. Pre-iktal / iktal sınıflandırma sonuçları ve performans metrikleri

		Tahminlenen Sınıf		Performans Metrikleri				
Sınıflandırıcı	**Gerçekleşen sınıf**	**preiktal**	**iktal**	**Doğruluk (%)**	**Duyarlılık (%)**	**Özgüllük (%)**	**F1-skor**	**AUC**
Fine Tree	**preiktal**	44	6	87	86.27	87.75	0.87	0.89
	iktal	7	43					
Quadratik Diskriminant Analiz	**preiktal**	50	0	100	100	100	1	1
	iktal	0	50					
Lojistic Regresyon	**preiktal**	50	0	100	100	100	1	1
	iktal	0	50					
Gaussian Naive Bayes	**preiktal**	49	1	96	94.23	97.91	0.96	0.97
	iktal	3	47					
Kübik DVM	**preiktal**	50	0	100	100	100	1	1
	iktal	0	50					
Ağırlıklandırılmış k-NN	**preiktal**	46	4	96	100	92.59	0.95	1
	iktal	0	50					
Bagged Trees	**preiktal**	46	4	92	92	92	0.92	0.96
	iktal	4	46					

Çizelge 4.3.'de inter-iktal vs. iktal EEG kayıtlarına ait sınıflandırma metriklerine yer verilmiştir. QDA, LR ve kübik DVM ile tüm inter-iktal ve iktal epokları doğru olarak sınıflandırılmıştır. FT bu aşamada en düşük performansı gösteren algoritma olarak göze çarpmaktadır. 50 inter-iktal EEG bölütünden 11'i iktal; 50 iktal EEG segmetinden 5'i ise iktal olarak sınıflandırılmıştır. Doğruluk %84, duyarlılık %88.63, özgüllük %80.35, F1-skor 0.82 ve AUC 0.85 olarak elde edilmiştir.

Çizelge 4.3. İnter-iktal / iktal sınıflandırma sonuçları ve performans metrikleri

		Tahminlenen Sınıf		Performans Metrikleri				
Sınıflandırıcı	**Gerçekleşen sınıf**	**interiktal**	**iktal**	**Doğruluk (%)**	**Duyarlılık (%)**	**Özgüllük (%)**	**F1-skor**	**AUC**
Fine Tree	**interiktal**	39	11	84	88.63	80.35	0.82	0.85
	iktal	5	45					
Quadratik Diskriminant Analiz	**interiktal**	50	0	100	100	100	1	1
	iktal	0	50					
Lojistic Regresyon	**interiktal**	50	0	100	100	100	1	1
	iktal	0	50					
Gaussian Naive Bayes	**interiktal**	49	1	98	98	98	0.98	0.98
	iktal	1	49					
Kübik DVM	**interiktal**	50	0	100	100	100	1	1
	iktal	0	50					
Ağırlıklandırılmış k-NN	**interiktal**	49	1	99	100	98	0.99	1
	iktal	0	50					
Bagged Trees	**interiktal**	47	3	89	85.45	93.33	0.89	0.96
	iktal	8	42					

Son olarak Çizelge 4.4' de pre-iktal vs. inter-iktal vs. iktal EEG kayıtlarına ait çoklu sınıflandırma metriklerine yer verilmiştir. Bu aşamada LR 2'li sınıflandırma mantığına dayanan bir yöntem olarak bilindiği için çoklu sınıflandırmada tercih edilmemiştir. QDA tüm epileptik gruplara ait epokları 3 sınıf için de doğru olarak sınıflandırılmıştır. FT ve BT çoklu sınıflandırmada en düşük performansı gösteren algoritmalar olarak göze çarpmaktadır.

Çizelge 4.4. Pre-iktal / İnter-iktal / İktal sınıflandırma sonuçları ve performans metrikleri

		Tahminlenen Sınıf			Performans Metrikleri				
Sınıflandırıcı	**Gerçekleşen sınıf**	**preiktal**	**interiktal**	**iktal**	**Doğruluk (%)**	**Duyarlılık (%)**	**Özgüllük (%)**	**F1-skor**	**AUC**
Fine Tree	**preiktal**	44	2	4	82.48	88	79.31	0.785	0.91
	interiktal	11	32	7	81.29	64	91.01	0.711	
	iktal	7	6	37	82.48	74	87.35	0.755	
Quadratic Discriminant Analiz	**preiktal**	50	0	0	100	100	100	1	1
	interiktal	0	50	0	100	100	100	1	
	iktal	0	0	50	100	100	100	1	
Gaussian Naive Bayes	**preiktal**	47	3	0	94.52	94	94.79	0.921	0.99
	interiktal	3	46	1	93.24	92	93.87	0.901	
	iktal	2	3	45	95.83	90	98.93	0.937	
Kübik DVM	**preiktal**	49	1	0	98.66	98	99	0.98	1
	interiktal	1	49	0	98.66	98	99	0.98	
	iktal	0	0	50	100	100	100	1	
Ağırlıklandırılmış k-NN	**preiktal**	48	2	0	97.16	96	97.8	0.96	1
	interiktal	2	45	3	91.33	90	92	0.873	
	iktal	0	6	44	93.83	88	96.87	0.907	
Bagged Trees	**preiktal**	43	0	7	89.6	86	92	0.868	0.95
	interiktal	4	34	12	79.43	68	85.71	0.7	
	iktal	2	13	35	76.71	70	80	0.673	

b) Hauz Khas EEG Veri Seti ile İlgili Literatür Çalışmaları:

Hauz Khas EEG veri seti literatürde diğer veri setleri kadar yaygın olarak yer almamaktadır. Pre-iktal / inter-iktal / iktal EEG analizinde en çok Bonn EEG veri seti tercih edilmiştir. Turker ve ark. (2020) Lokal grafik yapı tabanlı özgün bir öznitelik ile Pre-iktal vs. inter-iktal (Doğruluk= %100); İnter-iktal vs. iktal (Doğruluk = %100); Pre-iktal vs. inter-iktal vs. iktal (Doğruluk= %98.67) başarımlarını elde etmişlerdir. Qaisar ve Hussain (2021), çalışmalarında ilgili veri setinde EEG alt bantlarına ait istatiksel öznitelikler elde etmişlerdir. Çalışma sonucunda farklı kombinasyonlarla oluşturulan epileptik EEG gruplarını ayrıştırma oranlarının çoğunda doğruluk değeri olarak %100'e ulaşmıştır. Bu tez çalışmasında, ilgili EEG veri seti ile yapılan çalışmaların azlığı bilindiğinden, MFCC katsayıları analizi ile hem ikili hem de çoklu olarak oluşturulmuş tüm kombinasyonlarda pre-iktal / inter-iktal / iktal EEG verilerinin tamamı doğru olarak sınıflandırılmış ve güncel literatüre bu anlamda katkı sunulmuştur.

Literatürden zor bir veriseti olarak bilinen New Delphi, Hauz Khas verisetinin kapsamında yer alan pre-iktal, iktal ve inter-iktal EEG kayıtları MFCC tabanlı olarak farklı kombinasyonlarında sınıflandırılma işlemi yapılmış ve elde edilen neticeler, MFCC yönteminin EEG sınıflandırmasında yetisinin olduğu tespit edilmiştir. Çizelge 4.6.'da 2016-2021 yılları arasında Bern Barcelona Fokal / Non-fokal EEG veri seti ile Hauz Khas Nöroloji ve Uyku Merkezi'nde alınan pre-iktal / inter-iktal / iktal EEG kayıtlarına ait güncel çalışmalar listelenmiştir. MFCC'nin yetisinin tespiti sonrası, tez konusu olan fokal ve non-fokal EEG kayıtlarının sınıflandırılması aşamasına geçilmiş ve detaylar 4.2 alt başlığında verilmiştir.

4.2. Bern Barcelona EEG Kayıtlarının (Fokal / Non-fokal EEG) Sınıflandırılmasından Elde Edilen Bulgular

a) Sınıflandırma Sonuçları ve Performans Metrikleri

Fokal / Non-fokal EEG kayıtlarının her biri 3750 adet EEG çiftinden oluşmaktadır. Her bir veri çiftine ait tüm bölütlerin MFCC hesabı yapılmış, tek bir değer elde etmek adına katsayıların ortalaması alınmıştır. Bu şekilde kayıt çifti olarak karmaşıklık matrisi oluşturulması mümkün hale gelerek kayıtların doğru sınıfa atanıp atanmadığının tayini kolaylıkla gözlemlenmiştir. Çizelge 4.5.'de Bern Barcelona EEG veri setine ait performans metrikleri verilmiştir. Bulgular incelendiğinde QDA, LR ve kübik DVM fokal / non-fokal kayıtlarının hepsini tamamen ayrıştırmıştır. En düşük performans metrikleri ise FT sınıflandırıcısına aittir. Karmaşıklık matrisi incelendiğinde 3750 Fokal EEG kayıt çiftinden 17'si Non-fokal; benzer şekilde 3750 adet Non-Fokal EEG kayıt çiftinden 14'ü Fokal EEG olarak sınıflandırılmıştır. Doğruluk: %99.6, duyarlılık %99.62, özgüllük %99.57, F1-skor 0.995 ve AUC: 1 şeklindedir.

Çizelge 4.5. Fokal / Non-fokal sınıflandırma sonuçları ve performans metrikleri

		Tahminlenen Sınıf		**Performans Metrikleri**				
Sınıflandırıcı	**Gerçekleşen Sınıf**	**fokal**	**Non-fokal**	**Doğruluk (%)**	**Duyarlılık (%)**	**Özgüllük (%)**	**F1-skor**	**AUC**
Fine Tree	**fokal**	3733	17	99.6	99.62	99.57	0.995	1
	Non-fokal	14	3736					
Quadratic Discriminant Analiz	**fokal**	3750	0	100	100	100	1	1
	Non-fokal	0	3750					
Lojistic Regresyon	**fokal**	3750	0	100	100	100	1	1
	Non-fokal	0	3750					
Gaussian Naive Bayes	**fokal**	3750	0	99.9	99.76	100	0.998	1
	Non-fokal	9	3741					

Çizelge 4.5. Fokal / Non-fokal sınıflandırma sonuçları ve performans metrikleri (devamı)

Kübik DVM	**fokal**	3750	0	100	100	100	1	1
	Non-fokal	0	3750					
Ağırlıklandırılmış k-NN	**fokal**	3749	1	100	99.97	99.97	0.999	1
	Non-fokal	1	3749					
Bagged Trees	**fokal**	3741	9	99.7	99.62	99.75	0.996	1
	Non-fokal	14	3736					

a) Bern-Barcelona EEG Veri Seti ile İlgili Literatür Çalışmaları:

İlgili veri seti ile tamamlanmış çalışmaların çoğu veri setinin tamamı olan 3750 fokal / 3750 non-fokal EEG veri çifti kullanırken, çalışmaların azınlığı ise 50 fokal / 50 non-fokal EEG çiftini analiz etmişlerdir. Önerilen EEG markerların çoğu Wavelet Dönüşümü, Ampirik Mod Ayırma, entropi algoritmaları, Fourier Dönüşümü ve spektral öznitelikler tabanlıdır. Literatüre bakıldığında derin öğrenme yaklaşımlı uygulamalar da ayrıca göze çarpmaktadır. Derin öğrenme temelli çalışmaların yanında Destek Vektör Makinası, Sinir Ağı, ve k en yakın komşuluk gibi konvansiyonel yöntemler fokal / non-fokal EEG analizinde en sık başvurulan sınıflandırıcılar arasındadır. Eğitim ve test kümelerinin belirlenmesinde en çok k=10 çapraz korelasyon tercih edilmiştir. Madhavan ve ark. %99'un üzerinde doğruluk, hassasiyet ve özgüllük değerlerine 2B Evrişimsel Sinir Ağı ile synchro-squeezing dönüşümü kullanarak ulaşmışlardır. Arunkumar ve ark. entropi algoritmalarını kullanarak elde ettikleri öznitelik kümelerine konvansiyonel sınıflandırıcılar uygulayarak %99 doğruluk, hassasiyet ve özgüllük değerleri elde etmişlerdir. Mevcut tez çalışmasında ise veri seti kullanılarak %100 oranında doğruluk, hassasiyet, özgüllük ve f1-skor performans metriklerine ulaşılmıştır. Literatürdeki çalışmalarda çok sayıda öznitelik çıkarım yöntemi bir arada kullanılarak ilgili markerlar arasından en uygununu tespit edip başarım oranlarını yükseltmişlerdir. Mevcut tez çalışmasında ise MFCC katsayıları tek bir öznitelik olarak önerilip daha az hesap yükü sağlanmış, uygulamadaki pratiklik arttırılmış ve EEG zaman serilerini direkt olarak işleme imkanı sunmuştur. Mevcut tez çalışmasında kullanılan ve farklı yöntemlerden birer adet olmak üzere seçilen sınıflandırma algoritmalarının büyük çoğunluğu fokal / non-fokal EEG sınıflandırma işleminde üstün başarı göstermiştir. Bu da önerilen yöntemin gürbüz olduğunun açık bir göstergesidir. z-skor normalizasyonu ve Temel Bileşen Analizi yöntemi ile en ilgili alt öznitelik kümelerinin belirlenmesi çalışmanın performansını arttıran önemli unsurlardır.

Çizelge 4.6. Tez kapsamında değerlendirilen EEG veri setleri ile literatürde yapılan diğer çalışmalar

Yazarlar (Yıl)	**EEG Veriseti**	**EEG İşareti**	**Sınıflandırıcılar/ Çapraz validasyon**	**Performans Değerleri**
Sairamya ve ark. (2021) (2)	3750 F 3750 N	Wavelet Package Decomposition, Quad Binary Pattern Entropies	ANN/k=10 çapraz korelasyon	Doğruluk=%95.74 Duyarlılık =%81.94 Hassasiyet =%78.81
Sharma ve ark. (2020) (3)	3750 F 3750 N	Third-order cumulant	SVM with cubic kernel / k=10 çapraz korelasyon	Doğruluk=%99 Duyarlılık =%98.68 Hassasiyet. =%99.32 F-skor =0.99
You ve ark. (2019) (4)	3750 F 3750 N	Flexible Analytic Wavelet Transform, Log energy entropy, Fuzzy distribution entropy	GRNN, RF, SVM, LS-SVM, KNN, fuzzy KNN/ k=10 çapraz korelasyon	Doğruluk =%94.80 Duyarlılık =%92.27 Hassasiyet =96.10%
San-Segundo ve ark. (2019) (6)	3750 F 3750 N/ Bonn EEG Veri seti	Fourier Transform, Wavelet Transform, Empirical Mode Decomposition	CNN	Sağlıklı vs. İktal Doğruluk =%99.8 Non-iktal vs. İktal Doğruluk =%99.5 Sağlıklı vs. Interiktal Doğruluk =%96.5 Sağlıklı vs. Interiktal vs. İktal Doğruluk =%95.7
Rahman ve ark. (2019) (7)	3750 F 3750 N	Variational Mode Decomposition, Discrete Wavelet Transform, Refined Composite Multiscale Dispersion, Refined Composite Multiscale Fuzzy Entropy, Autoregressive Model Coefficient	Stacked SVM/ k=5 çapraz korelasyon	Doğruluk =%95.2 Duyarlılık =%96.1 Hassasiyet. =%94.4 AUC=0.989
Raghu ve Sriraam (2018) (8)	3750 F 3750 N	NCA ile 28 özellik	SVM, KNN, RF, AdaBoost / k=10 çapraz korelasyon	Doğruluk =%96.1 Duyarlılık =%97.6 Hassasiyet. =%94.4 AUC=0.96
Gupta ve Pachori (2020) (9)	3750 F 3750 N	Wavelet Transform, Corr-entropy, Exponential Energy	LS-SVM/ k=10 çapraz korelasyon	Doğruluk =%95.85 Duyarlılık =%95.47 Hassasiyet =%96.24
Tjepkema-Clostermans ve ark. (2018) (10)	50 F 50 N	-	Combinations of convolutional and recurrent neural networks	AUC =0.94
Das ve Bhuiyan (2016) 11	3750 F 3750 N	EMD-DWT, log energy entropy	k-NN city block distance	Doğruluk =%89.4 Duyarlılık =%90.7 Hassasiyet =%88.1
Arunkumar ve ark. (2018) 12	50 F 50 N	Entropy	Naive Bayes, Radial Based Function, Best First Decision Tree, KNN, SVM, Non- Nested Generalized Exemplars/ k=10 çapraz korelasyon	Doğruluk =%99 Duyarlılık =%99 Hassasiyet =%99
Fraiwan ve Alkhodari (2020) 14	3750 F 3750 N	Bi-directional Long Short-Term Memory	BDLSTM/ k=4, 6, 10 çapraz korelasyon	Doğruluk =%99.24 Duyarlılık =%99.55 Hassasiyet =%99.65
Siddharth ve ark. (2019) 15	3750 F 3750 N	Sliding Mode - Singular Spectrum Analysis	Sparse-autoencoder Radial Bases Function Neural Network/ k=10 çapraz korelasyon	Doğruluk =%99.11 Duyarlılık =%98.52 Hassasiyet =%99.70
Chetterje ve ark. (2017) 17	50 F 50 N	Multifractal Detrended Fluctuation Analysis	KNN, SVM/ k=10 çapraz korelasyon	Doğruluk =%92.18 Duyarlılık =%92.50 Hassasiyet =%92.69
Bajaj ve ark (2017) 18	750 F 750 N	Rhythm Based Correlation Features	LS-SVM/ k=10 çapraz korelasyon	Doğruluk =%99.20 Duyarlılık =%99.73 Hassasiyet =%98.68

Çizelge 4.6. Tez kapsamında değerlendirilen EEG veri setleri ile literatürde yapılan diğer çalışmalar (devamı)

Madhavan ve ark. (2020) 19	3750 F 3750 N	Synchro-squeezing Transform	2B Deep Convolutional Neural Network/ k=5 çapraz korelasyon	Doğruluk =%99.94 Duyarlılık =%99.94 Hassasiyet =%99.94
Bhattacharrya ve ark. (2016) 21	50 F 50 N/ 750 F 750 N	Empirical Wavelet Transform	Least square SVM/ k=10 çapraz korelasyon	Doğruluk =%90 Duyarlılık =%88 Hassasiyet =%92 (50 çift)
Zeng ve ark. (2019) 23	50 F 50 N/ 3750 F 3750 N	Empirical mode Decomposition, Phase Space Reconstruction	Least square SVM/ k=10 çapraz korelasyon	Doğruluk =%96 (50 çift)
Sriraam ve Raghu (2017) 24	3750 F 3750 N	21 Multi features	SVM/ k=10 çapraz korelasyon	Doğruluk =%92.15 Duyarlılık =%94.56 Hassasiyet =%89.74
Tuncer ve ark. (2020) 28	50 İktal, 50 İnteriktal, 50 Preiktal (Hauz Khas EEG Veri seti) / Bonn EEG Veri seti	Local Graph Structure, Discrete Wavelet Transform	KNN, SVM, RF, LDA, ANN/ k=10 çapraz korelasyon	Pre-iktal vs. inter-iktal Doğruluk= %100 İnter-iktal vs. iktal Doğruluk = %100 Pre-iktal vs. inter-iktal vs. iktal %98.67
Qaisar ve Hussain (2021) 29	50 İktal, 50 İnteriktal, 50 Preiktal (Hauz Khas EEG Veri seti) / Bonn EEG Veri seti	Statistical features from approximate detail coefficient	KNN, SVM, ANN, RF, Bagging/ k=5,10 çapraz korelasyon	Birçok 2'li ve çoklu sınıflandırma için Doğruluk =%100
Mevcut Çalışma:	3750 F 3750 N (Bern Barcelona Veri Seti) / 50 İktal, 50 İnteriktal, 50 Preiktal (Hauz Khas EEG Veri seti)	MFCC	Fine Tree, Quadratic Discriminant Analysis, Logistic Regression, Gaussian Naïve Bayes, Cubic Support Vector Machine, weighted k-NN, Bagged Trees / k=10 çapraz korelasyon	Doğruluk = Duyarlılık = Hassasiyet = F1-skor = %100 AUC=1

Mevcut tez çalışması ile önerilen yöntemin 2 farklı EEG veri setine uygulanması, mevcut yöntemin genelleme kabiliyetini arttırmaktadır. Bu durumda MFCC markerının hem fokal / non-fokal EEG tespiti hem de iktal / pre-iktal ile sağlıklı kontrollerin ayırt edilmesinde kullanışlı bir yöntem olduğu görülmektedir. Bu tez çalışması ile 2 veri seti MFCC katsayıları ile ilk kez analiz edilmiş ve oldukça başarılı sonuçlar elde edilmiştir. Mevcut bu bağlamda yenilikçi ve özgündür. Mevcut tez çalışmasının limitlerinden şu şekilde bahsedilebilir: MFCC katsayıları her ne kadar yeterli ölçüde performans metrikleri üretmiş olsa da literatürdeki önerilen diğer markerların içinde MFCC özniteliklerinin olduğu ve olmadığı 2 farklı senaryo ile denenerek MFCC katsayılarının epileptik EEG formlarını ayırt etmedeki kabiliyeti sınanabilir. Bunlara ek olarak sınıflandırma algoritmalarında kullanılan parametreler ampirik olarak seçilmiş, bu konuda en iyi parametreleri belirleyecek bir optimizasyon

metodu uygulanmamıştır. Bu nedenle optimal parametreler bulunarak performans metriklerinin üzerine olan etkisinin incelenmesi ayrı bir araştırma konusudur.

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, Mel Frekansı Kepstral katsayıları (MFCC) ve makine öğrenmesi algoritmaları ile Bern Barcelona veri seti kapsamındaki fokal / non-fokal epileptik EEG kayıtlarının sınıflandırılması amaçlanmıştır. Bu amaca ulaşmak için yapılan analizler;

i) MFCC destekli makine öğrenmesi algoritmaları ile Hauz Khas veriseti kapsamındaki pre-iktal / iktal / inter-iktal EEG kayıtları başarıyla sınıflandırılarak, MFCC yönteminin söz konusu alanda ihtiyaç duyulan öznitelikleri sağlayabildiği tespit edilmiştir. Dolayısıyla, bu hedef ile MFCC'nin söz konusu alandaki yetisi belirlenmiştir.

ii) Başarısı teyit edilen MFCC destekli makine öğrenmesi algoritmaları ile Bern Barcelona veriseti kapsamındaki fokal / non-fokal epileptik EEG kayıtlarının sınıflandırılması başarıyla gerçeklenmiştir.

Bu tez çalışmasında Mel Frekansı Kepstral Katsayıları (MFCC) tabanlı makine öğrenmesi yöntemleri ile farklı epileptik EEG kayıtları (fokal / non-fokal, pre-iktal / inter-iktal / iktal) başarıyla sınıflandırılmıştır. Burada söz konusu öznitelik çıkarım yöntemi olan MFCC'nin bir işaretçi (marker) olarak kullanılabileceği bulgulardan yola çıkılarak yorumlanmıştır.

MFCC katsayıları doğrudan epileptik zaman serilerinden hesaplanarak, mevcut kayıtların lineer olmayan davranışı ve henüz öngörülemeyen örüntüsü analiz edilebilmektedir. Dolayısıyla, hem fokal / non-fokal EEG kayıtları ve hem de pre-iktal / inter-iktal / iktal EEG kayıtları yüksek bir doğruluk oranıyla sınıflandırılmıştır. Önerilen metodoloji ile elde edilen sonuçlar, literatürdeki en yüksek başarım oranını yakalamıştır.

Çalışma boyunca elde edilen bulgular aşağıda belirtildiği gibi yorumlanabilir:

1) Epilepsi teşhisinde bir işaretçi (marker) olarak MFCC: MFCC katsayıları ilk kez bu tez çalışmasında hem fokal / non-fokal gruplar içeren Bern-Barcelona, hem de iktal / inter-iktal / pre-iktal EEG grupları içeren Hauz Khas veri setine ilk kez uygulanmıştır. Literatürde MFCC katsayılarının epileptik veri analizinde sadece Bonn

veri setinde kullanıldığından bahsedilmişti. Bu kapsamda çalışma yenilikçi ve özgün bir içeriğe sahiptir.

2) Hesap yükünün azaltılması: Epileptik EEG işaretlerinden MFCC katsayıları elde edilmiş ve özellik vektörleri oluşturulmuştur. Temel Bileşenler Analizi ile ilgili veri setine ait boyut azalışına gidilerek sadece önemli özellik bileşenlerini içeren alt kümeler elde edilmiştir. Böylece çalışmada önerilen sınıflandırma algoritmalarının işlem yükü azaltılmıştır.

3) Sınıflandırma başarımları: Çalışmada sınıflandırma işlemleri 2 farklı epileptik veri seti için uygulanmıştır. Fokal / Non-fokal EEG sınıflandırılmasında Quadratik Diskriminant Analiz (QDA), Lojistik Regresyon (LR) ve Kübik DVM ile tüm sınıflar doğru olarak ayrıştırılmıştır. Diğer veri setine ait iktal vs. inter-iktal, iktal vs. pre-iktal ve inter-iktal vs. pre-iktal sınıflandırmada benzer şekilde grupların tümü QDA, LR ve Kübik DVM ile tüm sınıflar doğru olarak sınıflandırılmıştır. Çoklu sınıflandırma olan iktal vs. pre-iktal vs. inter-iktal aşamasında ise sadece QDA algoritması verilerin tümünü doğru ayrıştırabilmiştir. Epileptik kayıtların MFCC işaretçileri (markerları) ile sınıflandırılmasında QDA en başarılı sınıflandırıcıdır.

4) Çalışmada sınıflandırma başarımını arttırmaya yönelik uygulanan yöntemler: Tez çalışmasının ilk evrelerinde sadece MFCC işaretçileri (markerları) çıkarılarak eğitilen ve test edilen sınıflandırma işlemlerinde başarım oranı mevcut duruma göre düşük seviyede gözlemlenmiştir. Z-skor normalizasyon ile veri setlerinin belirli bir değer aralığına çekilmesi ve ardından Temel Bileşen Analizi ile en önemli alt öznitelik bileşenlerini seçmek adına boyut azaltımına gidilmesi, çalışmadaki başarımı arttıran temel faktörlerdir.

5) Mevcut çalışmanın farklı nörolojik hastalıklara uygulanması ve mevcut çıkarılan işaretçilere (markerlara) yeni özniteliklerin eklenmesi ile yukarıda belirtilen çıkarımların daha netlik kazanacağı öngörülmektedir.

Tez çalışmasında önerilen yöntem epilepsi türlerinin dışında Alzheimer, Parkinson, Şizofreni gibi diğer nörolojik hastalıklar ve motor nöron bozuklukları, inme gibi fizyolojik rahatsızlıkların analizinde de kullanılabilir. Böylelikle mevcut

hastalıkların erken teşhisi ile tedavi süreci de hızlanabilecektir. İleriki çalışmalarda MFCC katsayıları bir derin öğrenme ağının girişine direk uygulanabilir. MFCC markerlarından spektrum görüntüleri oluşturmak da mümkündür. Frekans domeninde uygulanabilecek bazı görüntü dönüştürme teknikleri ile derin öğrenme ağ mimarilerini test etmek mümkündür.

6. KAYNAKLAR

Abdi, H. and Williams, L. J. (2010) 'Principal component analysis', ***Wiley Interdisciplinary Reviews: Computational Statistics***, 2(4), pp. 433–459. doi: 10.1002/wics.101.

Acharya, U. R. *et al.* 2019. 'Characterization of focal EEG signals: A review', ***Future Generation Computer Systems.*** Elsevier B.V., 91, pp. 290–299. doi: 10.1016/j.future.2018.08.044.

Andrzejak RG, Schindler K, Rummel C (2012). Nonrandomness, nonlinear dependence, and nonstationarity of electroencephalographic recordings from epilepsy patients. Phys. Rev. E, 86, 046206

Arunkumar, N., Ram Kumar, K. and Venkataraman, V. (2018) 'Entropy features for focal EEG and non focal EEG', ***Journal of Computational Science.*** Elsevier B.V., 27, pp. 440–444. doi: 10.1016/j.jocs.2018.02.002.

Bajaj, V. *et al.* (2017) 'Rhythm-based features for classification of focal and non-focal EEG signals', ***IET Signal Processing***, 11(6), pp. 743–748. doi: 10.1049/iet-spr.2016.0435.

Bhattacharyya, A. *et al.* (2018) 'A novel approach for automated detection of focal EEG signals using empirical wavelet transform', ***Neural Computing and Applications***. Springer London, 29(8), pp. 47–57. doi: 10.1007/s00521-016-2646-4.

Canizo, B. V *et al.* (2019) '10 - Quality Monitoring and Authenticity Assessment of Wines: Analytical and Chemometric Methods', in Grumezescu, A. M. and Holban, A. M. (eds) *Quality Control in the Beverage Industry*. Academic Press, pp. 335–384. doi: https://doi.org/10.1016/B978-0-12-816681-9.00010-2.

Chatterjee, S., Pratiher, S. and Bose, R. (2017) 'Multifractal detrended fluctuation analysis based novel feature extraction technique for automated detection of focal and non-focal electroencephalogram signals', ***IET Science, Measurement and Technology***, 11(8), pp. 1014–1021. doi: 10.1049/iet-smt.2017.0117.

Cooney, C., Folli, R. and Coyle, D. (2018) 'Mel frequency cepstral coefficients enhance imagined speech decoding accuracy from EEG', 29th Irish Signals and Systems Conference, *ISSC 2018*. IEEE. doi: 10.1109/ISSC.2018.8585291.

D, G. R. (2016) 'Analysis of Mfcc Features for Eeg Signal Classification', ***International Journal of Advances in Signal and Image Sciences***, 2(2), p. 14. doi: 10.29284/ijasis.2.2.2016.14-20.

Das, A. B. and Bhuiyan, M. I. H. (2016) 'Discrimination and classification of focal and non-focal EEG signals using entropy-based features in the EMD-DWT domain', ***Biomedical Signal Processing and Control.*** Elsevier Ltd, 29, pp. 11–21. doi: 10.1016/j.bspc.2016.05.004.

6. KAYNAKLAR

Deivasigamani, S., Senthilpari, C. and Yong, W. H. 2016. 'Classification of focal and nonfocal EEG signals using ANFIS classifier for epilepsy detection', ***International Journal of Imaging Systems and Technology***, 26(4), pp. 277–283. doi: 10.1002/ima.22199.

Deivasigamani, S., Senthilpari, C. and Yong, W. H. (2020) 'Machine learning method based detection and diagnosis for epilepsy in EEG signal', ***Journal of Ambient Intelligence and Humanized Computing***. Springer Berlin Heidelberg, (0123456789). doi: 10.1007/s12652-020-01816-3.

Djoufack Nkengfack, L. C. *et al.* (2020) 'EEG signals analysis for epileptic seizures detection using polynomial transforms, linear discriminant analysis and support vector machines', ***Biomedical Signal Processing and Control***, 62(July). doi: 10.1016/j.bspc.2020.102141.

Dissanayake, T. *et al.* (2021) 'Deep Learning for Patient-Independent Epileptic Seizure Prediction Using Scalp EEG Signals', ***IEEE Sensors Journal***, 21(7), pp. 9377–9388. doi: 10.1109/JSEN.2021.3057076.

Dwi Saputro, I. R. *et al.* (2019) 'Seizure Type Classification on EEG Signal using Support Vector Machine', ***Journal of Physics: Conference Series***, 1201(1). doi: 10.1088/1742-6596/1201/1/012065.

Fraiwan, L. and Alkhodari, M. (2020) 'Classification of Focal and Non-Focal Epileptic Patients Using Single Channel EEG and Long Short-Term Memory Learning System', ***IEEE Access***, 8, pp. 77255–77262. doi: 10.1109/ACCESS.2020.2989442.

Gandhi, T. K. *et al.* (2012) 'Discrete harmony search based expert model for epileptic seizure detection in electroencephalography', ***Expert Systems with Applications***. Elsevier Ltd, 39(4), pp. 4055–4062. doi: 10.1016/j.eswa.2011.09.093.

Gupta, V. et al. 2017. 'Automated detection of focal EEG signals using features extracted from flexible analytic wavelet transform', ***Pattern Recognition Letters.*** Elsevier B.V., 94, pp. 180–188. doi: 10.1016/j.patrec.2017.03.017.

Gupta, V. and Pachori, R. B. 2020. 'Classification of focal EEG signals using FBSE based flexible time-frequency coverage wavelet transform', ***Biomedical Signal Processing and Control.*** Elsevier Ltd, 62(August), p. 102124. doi: 10.1016/j.bspc.2020.102124.

Hussein, A. F. *et al.* (2018) 'Focal and non-focal epilepsy localization: A review', ***IEEE Access. IEEE***, 6, pp. 49306–49324. doi: 10.1109/ACCESS.2018.2867078.

Joga, S. R. K., Sinha, P. and Maharana, M. K. (2021) 'Performance Study of Various Machine Learning Classifiers for Arc Fault Detection in AC Microgrid', ***IOP Conference Series: Materials Science and Engineering***, 1131(1), p. 012012. doi: 10.1088/1757-899x/1131/1/012012.

Kiranyaz, S. *et al.* (2014) 'Automated patient-specific classification of long-term Electroencephalography', ***Journal of Biomedical Informatics***. Elsevier Inc., 49, pp. 16–31. doi: 10.1016/j.jbi.2014.02.005.

Madhavan, S., Tripathy, R. K. and Pachori, R. B. (2020) 'Time-Frequency Domain Deep Convolutional Neural Network for the Classification of Focal and Non-Focal EEG Signals', ***IEEE Sensors Journal***, 20(6), pp. 3078–3086. doi: 10.1109/JSEN.2019.2956072.

Mike Brookes, (2010) http://www.ee.ic.ac.uk/hp/staff/dmb/voicebox/voicebox.html

Mini, P. P., Thomas, T. and Gopikakumari, R. (2021) 'EEG based direct speech BCI system using a fusion of SMRT and MFCC/LPCC features with ANN classifier', ***Biomedical Signal Processing and Control***. Elsevier Ltd, 68(April), p. 102625. doi: 10.1016/j.bspc.2021.102625.

Oppenheim, A. V. and Schafer, R. W. (2004) 'From frequency to quefrency: A history of the cepstrum', ***IEEE Signal Processing Magazine***, 21(5). doi: 10.1109/MSP.2004.1328092.

Pavlov, Y. L. (2019) 'Random forests', *Random Forests*, pp. 1–122. doi: 10.1201/9780429469275-8.

Raghu, S. and Sriraam, N. 2018. 'Classification of focal and non-focal EEG signals using neighborhood component analysis and machine learning algorithms', ***Expert Systems with Applications.*** Elsevier Ltd, 113, pp. 18–32. doi: 10.1016/j.eswa.2018.06.031.

Rahman, M. M., Hassan Bhuiyan, M. I. and Das, A. B. 2019. 'Classification of focal and non-focal EEG signals in VMD-DWT domain using ensemble stacking', ***Biomedical Signal Processing and Control.*** Elsevier Ltd, 50, pp. 72–82. doi: 10.1016/j.bspc.2019.01.012.

Ravi Kumar, M. and Srinivasa Rao, Y. (2019) 'Epileptic seizures classification in EEG signal based on semantic features and variational mode decomposition', ***Cluster Computing***. Springer US, 22(s6), pp. 13521–13531. doi: 10.1007/s10586-018-1995-4.

Ren, H. *et al.* (2018) 'Cepstrum coefficient analysis from low-frequency to high-frequency applied to automatic epileptic seizure detection with bio-electrical signals', ***Applied Sciences (Switzerland)***, 8(9), pp. 1–25. doi: 10.3390/app8091528.

Sairamya, N. J. et al. 2021. 'Biomedical Signal Processing and Control A new approach for automatic detection of focal EEG signals using wavelet packet decomposition and quad binary pattern method', ***Biomedical Signal Processing and Control***. Elsevier Ltd, 63, p. 102096. doi: 10.1016/j.bspc.2020.102096.

San-Segundo, R. et al. 2019. 'Classification of epileptic EEG recordings using signal transforms and convolutional neural networks', ***Computers in Biology and Medicine.*** Elsevier Ltd, 109(March), pp. 148–158. doi: 10.1016/j.compbiomed.2019.04.031.

6. KAYNAKLAR

Sharma, R., Pachori, R. B. and Acharya, U. R. 2015. 'Application of entropy measures on intrinsic mode functions for the automated identification of focal electroencephalogram signals', **Entropy**, 17(2), pp. 669–691. doi: 10.3390/e17020669.

Siddharth, T., Tripathy, R. K. and Pachori, R. B. (2019) 'Discrimination of Focal and Non-Focal Seizures from EEG Signals Using Sliding Mode Singular Spectrum Analysis', ***IEEE Sensors Journal***. IEEE, 19(24), pp. 12286–12296. doi: 10.1109/JSEN.2019.2939908.

Singh, P. and Pachori, Ra. B. 2017. 'Classification of focal and nonfocal EEG signals using features derived from fourier-based rhythms', ***Journal of Mechanics in Medicine and Biology,*** 17(7). doi: 10.1142/S0219519417400024.

Siuly, Wang, H. and Zhang, Y. (2016) 'Detection of motor imagery EEG signals employing Naïve Bayes based learning process', ***Measurement: Journal of the International Measurement Confederation***. Elsevier Ltd, 86, pp. 148–158. doi: 10.1016/j.measurement.2016.02.059.

Sriraam, N. and Raghu, S. 2017. 'Classification of Focal and Non Focal Epileptic Seizures Using Multi-Features and SVM Classifier'. ***Journal of Medical Systems***. doi: 10.1007/s10916-017-0800-x.

Şeker, M. *et al.* (2021) 'Complexity of EEG Dynamics for Early Diagnosis of Alzheimer Disease Using Permutation Entropy Neuromarker', ***Computer Methods and Programs in Biomedicine***, 206, p. 106116. doi: 10.1016/j.cmpb.2021.106116.

Tang, Y. *et al.* (2016) 'A multiple-point spatially weighted k-NN method for object-based classification', ***International Journal of Applied Earth Observation and Geoinformation***. Elsevier B.V., 52, pp. 263–274. doi: 10.1016/j.jag.2016.06.017.

Tjepkema-Cloostermans, M. C., de Carvalho, R. C. V. and van Putten, M. J. A. M. 2018. 'Deep learning for detection of focal epileptiform discharges from scalp EEG recordings', ***Clinical Neurophysiology. International Federation of Clinical Neurophysiology,*** 129(10), pp. 2191–2196. doi: 10.1016/j.clinph.2018.06.024.

Tuncer, T. *et al.* (2020) 'A novel ensemble local graph structure based feature extraction network for EEG signal analysis', ***Biomedical Signal Processing and Control***. Elsevier Ltd, 61, p. 102006. doi: 10.1016/j.bspc.2020.102006.

Qaisar, S. M. and Hussain, S. F. (2021) 'Effective epileptic seizure detection by using level-crossing EEG sampling sub-bands statistical features selection and machine learning for mobile healthcare', ***Computer Methods and Programs in Biomedicine.*** Elsevier B.V., 203, p. 106034. doi: 10.1016/j.cmpb.2021.106034.

Yavuz, E. *et al.* (2018) 'An epileptic seizure detection system based on cepstral analysis and generalized regression neural network', ***Biocybernetics and Biomedical Engineering***, 38(2), pp. 201–216. doi: 10.1016/j.bbe.2018.01.002.

You, Y. *et al.* 2020. 'Automatic focal and non-focal EEG detection using entropy-based features from flexible analytic wavelet transform', ***Biomedical Signal Processing and Control.*** Elsevier Ltd, 57, p. 101761. doi: 10.1016/j.bspc.2019.101761.

Zeng, W. *et al.* (2019) 'Classification of focal and non focal EEG signals using empirical mode decomposition (EMD), phase space reconstruction (PSR) and neural networks', ***Artificial Intelligence Review***. Springer Netherlands, 52(1), pp. 625–647. doi: 10.1007/s10462-019-09698-4.

Zhang, T. and Chen, W. (2017) 'LMD Based Features for the Automatic Seizure Detection of EEG Signals Using SVM', ***IEEE Transactions on Neural Systems and Rehabilitation Engineering***, 25(8), pp. 1100–1108. doi: 10.1109/TNSRE.2016.2611601.

6. KAYNAKLAR

ÖZGEÇMİŞ

Eğitim Bilgileri:

Lise Eğitimi:

Okulun Adı: Rekabet Kurumu Anadolu Lisesi (2007-2011)

Lisans Eğitimi:

Okulun Adı: Dicle Üniversitesi

Bölümü: Elektrik-Elektronik Mühendisliği (2012-2017)

Diploma Notu: 67.04

İlgi Alanları:

Araştırma Alanları: Elektrik Tesis Kurulumu, Aydınlatma Projeleri, Makine Öğrenmesi, Mikroişlemciler, Görüntü İşleme Teknikleri, Görüntüde Kenar Belirleme Yöntemleri ve Obje Takibi

Kullanabildiği Programlar: Microsoft Office, MATLAB, AUTOCAD

Yazılım Dilleri: C, Assembly PIC programlama, Arduino

Stajlar:

1. Diyarbakır Organize Sanayii Bölgesi (Aydınoğlu Elektrik)
2. Dicle Elektrik Dağıtım Anonim Şirketi (DEDAŞ)

Projeler:

1. Lisans Araştırma Projesi: Görüntü İmgelerinde Kenar Belirleme
2. Bitirme Projesi: Görüntü İşleme Teknikleri İle Obje Tanıma, Yüz Tespiti ve Takibi

Bildiriler:

D. Şeker ve M. S. Özerdem, "Classification and Statistical Analysis of Schizophrenic and Normal EEG Time Series," 2020 Medical Technologies Congress (TIPTEKNO), 2020, pp. 1-4, doi: 10.1109/TIPTEKNO50054.2020.9299246.

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ İNTİHAL FORMU

ÖĞRENCİ BİLGİLERİ	
ADI VE SOYADI	Delal Şeker
ÖĞRENCİ NO	19805004
EĞİTİM – ÖĞRETİM YILI	2020-2021
YARIYIL	☐ Güz ☒ Bahar
ANABİLİM DALI	
PROGRAM	Yüksek Lisans
TEZ KONUSU	MFCC DESTEKLİ MAKİNA ÖĞRENMESİ ALGORİTMALARI İLE FOKAL/NON-FOKAL EEG KAYITLARININ SINIFLANDIRILMASI
İNTİHAL RAPORU BİLGİLERİ	
RAPOR TÜRÜ	Tez Savunma Sınavı Sonrası
SAYFA SAYISI	55
BENZERLİK ORANI	%14
RAPORLAMA TARİHİ	26/07/2021

Yukarıda başlığı/konusu gösterilen tez çalışmamın kapak sayfası, giriş, ana bölümler, sonuç ve tartışma kısımlarından oluşan toplam 55 sayfalık kısmına ilişkin, 26/07/2021 tarihinde tez danışmanım tarafından *Turnitin* adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı %14 'tür.

Uygulanan filtrelemeler:

☐Kabul/Onay sayfaları hariç,
☐Kaynakça hariç
☐Alıntılar hariç/dâhil
☐Diğer

Dicle Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Programlarda Tez Çalışması İntihal Raporu Uygulama Esaslarını inceledim ve bu Uygulama Esaslarında belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edilmesi durumunda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

Öğrencinin
Adı ve Soyadı: Delal Şeker
Tarih: 29/07/2021
İmza:

Tez Danışmanı	**Anabilim Dalı Başkanı**
Adı ve Soyadı: Prof. Dr. Mehmet Siraç Özerdem Tarih: 02/08/2021 İmza:	Adı ve Soyadı: Doç. Dr. Bilal Gümüş Tarih: 02/08/2021 İmza:

Formdaki bilgiler, bilgisayar ortamında doldurulmalıdır. El yazısı ile doldurulan formlar geçersizdir.