



T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



MAKİNE ÖĞRENMESİ YÖNTEMLERİ
KULLANILARAK EEG SİNYALİNDEN
EPİLEPTİK NÖBETLERİN TESPİTİ

ESMİRA ABDULLAYEVA

YÜKSEK LİSANS TEZİ

BİLİŞİM TEKNOLOJİLERİ MÜHENDİSLİĞİ
Anabilim Dalı

Ocak-2023
KONYA
Her Hakkı Saklıdır

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

ESMİRA ABDULLAYEVA

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK EEG SİNYALİNDEN EPİLEPTİK NÖBETLERİN TESPİTİ

ESMİRA ABDULLAYEVA

Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Bilişim Teknolojileri Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Humar KAHRAMANLI ÖRNEK

2023, 40 Sayfa

Jüri

Dr. Öğr. Üyesi Serkan ÖRÜCÜ
Doç. Dr. Humar KAHRAMANLI ÖRNEK
Dr. Öğr. Üyesi Züleyha YILMAZ ACAR

Epilepsi, sık görülen bir nörolojik hastalıktır. Epilepside beyinde bulunan nöronlarda ani ve kontrolsüz boşalmalar (deşarjlar) oluşur. Bunun sonucunda hastada istemsiz kasılmalar, duyuşal değişiklikler ve bilinç değişiklikleri meydana gelir. Epilepsi nöbetler halinde olan bir hastalıktır. Nöbet aralarında hasta sağlıklıdır. Bu çalışmada EEG sinyalleri kullanılarak kişinin nöbet geçirip geçirmediğinin tespit edilmesi hedeflenmiştir. Çalışmada Bonn EEG veri kümesi web sitesindeki halka açık veri kümesi kullanılmıştır. Bu çalışmada A ve E kümeleri kullanılmıştır. A kümesi sağlıklı kişilerden, E kümesi ise epilepsi hastalarının nöbet aktivitesi verilerinden oluşmaktadır. Çalışmada sinyal ön işleme için Welch yöntemi kullanılmıştır. Welch işlemi sonucunda 129 özellik çıkarılmıştır. Sınıflandırma aşamasında ise Destek Vektör Makinesi (DVM), Naive Bayes (NB), Rastgele Orman (RO), Levenberg-Marquardt (LM) algoritmaları ve Uzun Kısa Süreli Bellek (LSTM) sinir ağı kullanılmıştır. Sınıflandırmadan elde edilen sonuçları değerlendirmek için doğruluk, kesinlik, duyarlılık, f1-skor istatistikleri ve k-kez çapraz doğrulama kullanılmıştır. K-kez çapraz doğrulamada k parametresi 10 olarak belirlenmiştir. Çalışmada DVM algoritması ile elde edilen ortalama doğruluk %97,91, kesinlik %96,09, duyarlılık %100, f1-skor %98 olmuştur. RO algoritması ile elde edilen ortalama doğruluk oranı %99,86, kesinlik %99,85, duyarlılık %99,88, f1-skor %99,86 olmuştur. NB algoritmasının ulaştığı ortalama doğruluk %97,67, ortalama kesinlik %98,80, ortalama duyarlılık %96,43, ortalama f1-skor ise %97,28 olmuştur. LM algoritması ile elde edilen ortalama doğruluk %98,83, kesinlik %97,86, duyarlılık %99,97, f1-skor %98,88 olmuştur. LSTM algoritması ile elde edilen ortalama doğruluk %99,38, kesinlik %99,52, duyarlılık %99,31, f1-skor %99,39 olmuştur.

Anahtar Kelimeler: EEG, Epilepsi, DVM, NB, LM, RO, LSTM, Welch yöntemi.

ABSTRACT

MS THESIS

DETECTION OF EPILEPTIC SEIZURES FROM EEG SIGNAL USING MACHINE LEARNING METHODS

ESMİRA ABDULLAYEVA

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
SELÇUK UNIVERSITY**

**THE DEGREE OF MASTER OF SCIENCE
INFORMATION TECHNOLOGY ENGINEERING**

Advisor: Assoc. Prof. Dr. Humar KAHRAMANLI ÖRNEK

2023, 40 Pages

Jury

Assoc. Prof. Dr. Humar KAHRAMANLI ÖRNEK

Assist. Prof. Dr. Serkan ÖRÜCÜ

Assist. Prof. Dr. Züleyha YILMAZ ACAR

Epilepsy is a common neurological disease. In epilepsy, sudden and uncontrolled discharges occur in neurons in the brain. As a result, involuntary contractions, sensory changes and changes in consciousness occur in the patient. Epilepsy is a disease that occurs in seizures. Between seizures, the patient is healthy. In this study, it is aimed to determine whether the person has a seizure by using EEG signals. In the study, the public dataset from the Bonn EEG dataset website was used. A and E folds were used in this study. Fold A consists of healthy people, fold E consists of seizure activity data of diseased people. In the study Welch method was used for signal preprocessing. As a result of Welch, 129 features were extracted. In the classification phase, Support Vector Machine (SVM), Naive Bayes (NB), Random Forest (RF), Levenberg-Marquardt (LM) algorithms and Long Term Short Term Memory (LSTM) neural network were used. Accuracy, precision, recall, f1-score statistics and k-times cross validation were used to evaluate the results from the classification. In k-times cross validation, the k parameter is set to 10. In the study, the average accuracy obtained with the SVM algorithm was 97.91%, the precision was 96.09%, the recall was 100%, and the f1-score was 98%. The average accuracy rate obtained with the RF algorithm was 99.86%, precision 99.85%, recall 99.88%, f1-score 99.86%. The average accuracy reached by the NB algorithm was 97.67%, the average precision was 98.80%, the average recall was 96.43%, and the average f1-score was 97.28%. The average accuracy obtained with the LM algorithm was 98.83%, precision 97.86%, recall 99.97%, f1-score 98.88%. The average accuracy obtained with the LSTM algorithm was 99.38%, precision 99.52%, recall 99.31%, f1-score 99.39%.

Keywords: EEG, Epilepsy, SVM, NB, LM, RF, LSTM, Welch method.

ÖNSÖZ

Bu tez çalışması, Selçuk Üniversitesi Bilişim Mühendisliği Anabilim Dalı Yüksek Lisans Programı'nda hazırlanmıştır. Tez çalışmasında EEG sinyalleri kullanılarak kişinin nöbet geçirip geçirmediğinin tespit edilmesi hedeflenmiştir.

Tez çalışmamın hayata geçirilmesi sürecinde bilgi ve tecrübelerinden faydalandığım, araştırmanın her bir aşamasında görüşleriyle beni destekleyen, samimiyetini her zaman hissettiren ve beni doğru yönde yönlendiren danışman hocam Doç. Dr. Humar KAHRAMANLI ÖRNEK'e, sonsuz teşekkürlerimi sunarım.

Eğitim ve öğretim hayatımın tamamında benden hiçbir desteğini esirgemeyen sevgili aileme teşekkürü bir borç bilirim.

ESMİRA ABDULLAYEVA
KONYA-2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ÇİZELGE LİSTESİ.....	viii
ŞEKİL LİSTESİ.....	ix
SİMGELER VE KISALTMALAR	x
1. GİRİŞ	1
1.1. Beyin Elektriksel Aktivitesi.....	2
2. KAYNAK ARAŞTIRMASI	6
3. EPİLEPSİ	15
3.1. Epileptik Nöbet	15
4. MATERYAL VE YÖNTEM.....	16
4.1. Materyal	16
4.2. Yöntem.....	16
4.2.1 Welch yöntemi	16
4.2.2 Destek Vektör Makine (DVM) Algoritması	17
4.2.3 Rastgele Orman (RO) Algoritması	18
4.2.4 Naive Bayes (NB) Algoritması	18
4.2.5 Levenberg-Marquardt (LM) Algoritması	18
4.2.6 Uzun Kısa Süreli Bellek (LSTM) Sinir Ağı	19
4.3 Performans Değerlendirme Yöntemleri.....	20
4.3.1 10-kat çapraz doğrulama.....	20
4.3.2 Doğruluk, kesinlik, duyarlılık, f1-skor	21
5. UYGULAMA	22
6. SONUÇLAR VE ÖNERİLER	35
KAYNAKLAR	36
ÖZGEÇMİŞ	40

ÇİZELGE LİSTESİ

Çizelge 5.1. DVM algoritmasının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri	24
Çizelge 5.2. RO algoritmasının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri	25
Çizelge 5.3. NB algoritmasının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri	27
Çizelge 5.4. LM algoritmasının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri	28
Çizelge 5.5. LSTM algoritmasının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri	30
Çizelge 5.6. Sınıflandırıcıların doğruluk ortalama sonuçları	31
Çizelge 5.7. DVM algoritmasının konfüzyon matrisi	32
Çizelge 5.8. RO algoritmasının konfüzyon matrisi	33
Çizelge 5.9. NB algoritmasının konfüzyon matrisi	33
Çizelge 5.10. LM algoritmasının konfüzyon matrisi	33
Çizelge 5.11. LSTM algoritmasının konfüzyon matrisi	33
Çizelge 5.12. Epileptik nöbetleri teşhis etmek için yöntemimizin ve yazarlar tarafından kullanılan yöntemler ve sonuçlar	34

ŞEKİL LİSTESİ

Şekil 1.1. Tipik normal EEG sinyali.....	2
Şekil 1.2. Beta, alfa, teta, delta ve gama dalgaları.....	3
Şekil 1.3. 10-20 sistemine göre elektrotların yerleştirilmesi.....	4
Şekil 1.4. Artefakt çeşitleri	5
Şekil 4.1. Uzun kısa süreli bellek hücresi.....	19
Şekil 4.2. 10-kat çapraz doğrulama	21
Şekil 5.1. Pencereleme yöntemi	22
Şekil 5.2. Uygulamanın akış şeması.....	23
Şekil 5.3. DVM algoritmasının doğruluk sonuçları	24
Şekil 5.4. RO algoritmasının doğruluk sonuçları	26
Şekil 5.5. NB algoritmasının doğruluk sonuçları	27
Şekil 5.6. LM algoritmasının doğruluk sonuçları.....	29
Şekil 5.7. LSTM algoritmasının doğruluk sonuçları	31
Şekil 5.8. Sınıflandırıcıların doğruluk ortalama sonuçları	32

SİMGELER VE KISALTMALAR

Simgeler

Δ	: Delta
e	: Euler Sayısı
ϵ	: Eleman
Hz	: Hertz
μV	: Mikrovolt
μ	: Mikrometre
π	: Pi
Σ	: Sigma
tanh	: Hiperbolik Tanjant
uV	: Ultraviyole

Kısaltmalar

AH	: Alzheimer Hastalığı
ADD	: Ayrık Dalgacık Dönüşümü
AMA	: Ampirik Mod Ayırıştırması
AQDD	: Ayarlanabilir Q-Dalgacık Dönüşümü
BCO	: Bulanık C-Ortalamalar Algoritması
BEÖ	: Beklenen Etkinlik Ölçümü
BDTS	: Bilgisayar Destekli Teşhis Sistemi
BDT	: Bilgisayar Destekli Teşhis
1B-YGM	: Bir Boyutlu Yerel Gradyan Model
1B-YDD	: Bir Boyutlu Yerel Degrade Deseni
1B-YİM	: Bir boyutlu Yerel İkili Model
1B-ESA	: Bir Boyutlu Evrişimsel Sinir Ağı
BG	: Bant Gücü
ÇSDVM	: Çok Sınıflı DVM
ÇKA	: Çok Katmanlı Algılayıcı
DVM	: Destek Vektör Makinesi
DÖ	: Derin Öğrenme
DP	: Doğru Pozitif
DN	: Doğru Negatif
DESA	: Derin Evrişimli Sinir Ağı
DD	: Dalgacık Dönüşüm
EEG	: Elektroensefalografi
EK-DVM	: En Küçük Kareler Destek Vektör Makinesi
ESA	: Evrişimli Sinir Ağı
GMM	: Gizli Markov Modeli
GSY	: Güç Spektrumu Yoğunluğu
GTB	: Geçitli Tekrarlayan Birim
HFD	: Hızlı Fourier Dönüşümü
İPSO	: İkili Parçacık Sürü Optimizasyonu
İSA	: İleri Beslemeli Sinir Ağı
İBYSA	: İleri Beslemeli Yapay Sinir Ağı

K-NN	: K-En Yakın Komşu
KA	: Karar Ağacı
KDH	: Kendini Düzenleyen Haritalar
KSFD	: Kısa Süreli Fourier Dönüşümü
LM	: Levenberg-Marguardt
LSTM	: Uzun Kısa Süreli Bellek
MDD	: Majör Depresif Bozukluk
NB	: Naive Bayes
OSA	: Olasılıksal Sinir Ağı
PSO	: Parçacık Sürüsü Optimizasyon
PE	: Permütasyon Entropi
PEON	: Psikojenik Epileptik Olmayan Nöbetler
RO	: Rastgele Orman
TÜH	: Temple Üniversitesi Hastanesi
TSA	: Tekrarlayan Sinir Ağı
SE	: Shannon Entropi
SP	: Standart Sapma
UVTEA	: Uzun Vadeli Tekrarlayan Evrişim Ağ
UDRS	: Uluslararası Duyuşsal Resim Sistemi
UNBÇS	: Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi
UVTEA	: Uzun Vadeli Tekrarlayan Evrişim Ağ
USÖ	: Uyarlanabilir Sentetik Örnekleme
YKTM	: Yerel Komşu Tanımlayıcı Model
YSA	: Yapay Sinir Ağı
YP	: Yanlış Pozitif
YN	: Yanlış Negatif
YKTM	: Yerel Komşu Tanımlayıcı Model
YG	: Yineleme Grafik

1. GİRİŞ

Elektroensefalografi (EEG), insan beyninin elektriksel aktivitesini yansıtan potansiyellerin bir ölçümüdür. EEG, doktorlar ve bilim adamları tarafından beyin fonksiyonlarını incelemek ve nörolojik bozuklukları teşhis etmek için yaygın olarak kullanılmaktadır. Beynin elektriksel aktivitesinin EEG kayıtları aracılığıyla incelenmesi, epilepsi, beyin tümörleri, kafa travması, uyku bozuklukları, demans gibi nörolojik hastalıkların teşhisinde ve ameliyat sırasında anestezi derinliğinin izlenmesinde en önemli araçlardan biridir. Ayrıca anormalliklerin, davranış bozukluklarının (örn., otizm), dikkat bozukluklarının, öğrenme sorunlarının ve dil gecikmesinin tedavisinde de kullanılmaktadır. İlk EEG kayıt makinesi 1929 yılında Hans Berger tarafından dünyaya tanıtıldı. Almanya'daki Jena Üniversitesi'nde bir nöropsikiyatrist olan Berger, beyinde üretilen elektrik akımlarının grafiksel temsillerini tanımlamak için Almanca "elektroensefalogram" terimini kullandı. Beynin uyku, anestezi ve epilepsi gibi fonksiyonel durumuna bağlı olarak beyin akımlarının değiştiğini öne sürdü.


Epilepsi dünya çapında en sık görülen nörolojik hastalıklardan biridir (Supriya ve ark., 2016). Epilepsinin ayırt edici özelliği, "epileptik nöbetler" olarak adlandırılan tekrarlayan nöbetlerdir (Tzallas ve ark., 2012). Nöbetler, beynin elektriksel işleyişinde, bilinç kaybı, sarsıntılı hareketler, geçici nefes kaybı ve hafıza kaybı gibi değişen davranışlarla sonuçlanan ani değişiklikler olarak tanımlanır. Bunlar genellikle kortekste veya beynin dış kenarında olur. Epilepsi, garip hislere, duygulara ve davranışlara veya bazen konvülsiyonlara, kas spazmlarına ve bilinç kaybına neden olabilir.

Bir "nöbet", beyindeki nöronların aşırı, hipersenkron deşarjının neden olduğu nörolojik fonksiyonun paroksismal bir değişikliğidir (Shorvon ve ark., 2011). Nöbet olarak bilinen epileptik nöbet, beyindeki anormal derecede aşırı veya senkronize nöronal aktiviteye bağlı bir semptom dönemidir (Fisher ve ark., 2014). Dışa dönük etkiler, bilinç kaybı olan vücudun çoğunu içeren kontrolsüz sarsıntı hareketlerinden (tonik-klonik nöbet), değişken bilinç düzeylerine sahip vücudun sadece bir kısmını içeren sarsıntı hareketlerine (fokal nöbet) bir anlık farkındalık kaybına (yokluk nöbeti) kadar değişir (Misulis ve Murray, 2017). Çoğu zaman bu ataklar iki dakikadan kısa sürer ve hastanın normale dönmesi biraz zaman alır.

1.1. Beyin Elektriksel Aktivitesi

Bir beynin elektriksel aktivitesi, güçlü doğrusal olmayan ve dinamik özelliklere sahip önemli karmaşık davranışlar sergiler. Beyin hücrelerindeki iletişim elektriksel uyarılar yoluyla gerçekleşir. Kortikal sinir hücresi inhibitörü ve uyarıcı postsinaptik potansiyeller, EEG sinyallerini üretir. Bu postsinaptik potansiyeller kortekste toplanır ve EEG olarak kaydedildikleri kafa derisi yüzeyine uzanır. Kafa derisinden ölçülen tipik bir EEG sinyali, yaklaşık 10 uV ila 100 uV arasında bir genliğe ve 1Hz ila yaklaşık 100Hz aralığında bir frekansa sahiptir (Subha ve ark., 2010).

EEG sinyalleri durağan değildir ve doğrusal olmayan bir yapıya sahiptir. EEG, beyinle ilgili hastalıkları ve semptomları teşhis etmek için kullanılan invaziv olmayan bir tekniktir. Epilepsi, tümör, serebrovasküler lezyonlar, depresyon ve travmaya bağlı problemler gibi birçok nörolojik hastalığın teşhisine yardımcı olur. EEG izleri farklı beyin aktiviteleri için farklıdır. Şekil 1.1, tipik bir normal EEG sinyalinin göstermektedir.



Şekil 1.1 Tipik normal EEG sinyali (Subha ve ark., 2010)

EEG sinyalleri kafa derisine yerleştirilen elektrotlardan kaydedilir. Monopolar ve bipolar olmak üzere iki tür EEG kaydı vardır. Monopolar kayıt, kafa derisindeki aktif elektrot ile kulak memesindeki referans elektrot arasındaki voltaj farkını algılar. Bipolar elektrotlar, iki kafa derisi elektrotu arasındaki voltaj farkını verir. EEG sinyalleri şu ritimlerle karakterize edilir: delta dalgaları, teta dalgaları, alfa dalgaları ve beta dalgaları. Bu dalgalar Şekil 1.2’de gösterilmiştir.


1. Delta aktivitesinin frekans aralığı 3Hz veya altındadır ve ağırlıklı olarak 1 yaşına kadar olan bebeklerde ve normal yetişkinlerin derin uyku evrelerinde bulunur.

2. Teta aktivitesi 4Hz ila 8Hz frekans aralığına sahiptir. Normal bebeklerde ve çocuklarda olduğu gibi yetişkinlerde uyuşukluk ve uyku sırasında bulunur. Uyanık yetişkinlerde yüksek teta aktivitesinin varlığı, anormal ve patolojik durumları düşündürür.

3. Alfa dalgaları 8Hz ila 13Hz frekans aralığına sahiptir. Genellikle başın arka bölgelerinde, baskın tarafta daha yüksek genlik olmak üzere her iki tarafta görülür.

Genlik çoğunlukla 50 μ V'den azdır ve oksipital sinirlerde bulunur. Bu normal rahat yetişkinlerde görülen önemli bir ritimdir.


4. Beta ritimleri 13Hz ila 30Hz frekans aralığına sahiptir ve ön kısımda baskındır. Bu ritim, uyanık veya endişeli deneklerde mevcuttur (Subha ve ark., 2010).



Şekil 1.2. Beta, alfa, teta, delta ve gama dalgaları (Siuly ve ark., 2016)

EEG hastanın uyku ya da uyanıklık halinde oluşuna bakmayarak her zaman çekilmesi mümkün olan bir testtir. EEG'nin doğruluğu için EEG'nin bireyin hem uyku hem de uyanıklık halinde çekilmesi gerekir. EEG çekilecek olan bireyin saçlarının temiz olması gereklidir. Saçların kirli oluşu sinyallerin beyne iletilmesini engeller ve doğru sonuç almayı önler. Temiz saç dışında saça hiçbir madde (krem, yağ, jöle) sürülmemelidir. Hastanın saçlı derisine kendine özel yapıştırıcı maddesiyle yapıştırılan elektrot adı verilen aletler yardımıyla beynin dalgaları ölçülür ve bu dalgalar kablolar aracılığıyla monitöre aktarılır ve bu şekilde beynin dalgalarının görüntülenmesi sağlanır. Elektrotların kafa derisi üzerinde doğru noktalara yerleştirilmesi daha net ve doğru veri elde edilmesi için önemlidir. Rutin EEG'de bu veriler ortalama 20 ile 40 dakika arasında elde edilir.

Kafa derisi elektrot lokalizasyonu için kullanılan standart yöntem, uluslararası 10-20 elektrot sistemidir. Burada "10" ve "20", komşu elektrotlar arasındaki gerçek mesafeleri temsil eder. Şekil 1.3 uluslararası 10-20 sistemine göre beyindeki elektrot konumunu göstermektedir. Her konum, lobu tanımlamak için bir harf ve yarım küre konumunu belirlemek için bir sayı ile ifade edilir. F, T, C, P ve O harfleri sırasıyla Frontal, Temporal, Central, Parietal ve Occipital'i temsil eder. "Z", orta hatta yerleştirilmiş elektrot anlamına gelir. Çift sayılar sağ hemisferdeki elektrot konumlarına atıfta bulunurken, tek sayılar sol hemisferdekilere karşılık gelir. Bir EEG voltaj sinyali iki elektrottaki voltajlar arasındaki farkı temsil ettiğinden, EEG okuma makinesi için EEG gösterimi birkaç yolla ayarlanır. Elektrotların yerleştirilmesi montaj olarak adlandırılır (Siuly ve ark., 2016).



Şekil 1.3. 10-20 Sistemine göre elektrotların yerleştirilmesi (Siuly ve ark., 2016)


EEG kaydı sırasında birçok noktada artefakt olarak adlandırılan hatalar (beyin ile ilgili olmayan sinyaller) oluşabilir. Bunlardan bir kısmı denek ile ilgili (hareket, göz hareketleri, terleme, heyecan vb.) olabileceği gibi bazıları da teknik sebeplerden (50/60Hz artefaktı, kabloların oynaması, elektrotların iyi yerleşmemesi vb.) meydana gelebilir.

Göz kırpması: EEG kayıtlarında rastlanan en yaygın artefaktlardan biridir. Normal EEG sinyalinden daha fazla genliğe sahiptir (Knight, 2003).

Göz hareketi: Gözün hareket etmesinden kaynaklanan artefaktların kafatası üzerindeki yayılımı göz kırpmasından daha fazladır. Göz kırpması ve hareketleri yakın aralıklarla ortaya çıkar (Knight, 2003).

Kas hareketi: Bu tip artefaktlar geniş frekanslara sahiptir ve kişi kendini kastığı zaman kasın bulunduğu noktaya yakın kanallarda ortaya çıkar (Knight, 2003).

Hat gürültüsü: Çevredeki elektriksel düzeneklerden kaynaklanan 50 veya 60 Hz'lik şebeke gürültüsü EEG sinyalinin içine karışabilir, bu tip artefaktlar notch filtresi olarak adlandırılan bir filtre yardımı ile temizlenir (Knight, 2003). Kayıt sırasında oluşan artefaktların görüntüsü Şekil 1.4'deki gibidir.



2. KAYNAK ARAŞTIRMASI

Güler ve Übeyli (2005) çalışmalarında, EEG sinyallerinin sınıflandırılması için Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (UNBÇS) modelini uygulamışlar. Çalışmada Bonn Üniversitesi EEG veri kümesini kullanmışlar. UNBÇS veri kümesindeki özellikleri öğrenmektedir. Sonuç olarak %98,68 doğruluk elde etmişler.

Kannathal ve ark., (2005) çalışmalarında, EEG sinyallerinin kaotik dinamikleri entropi ölçümleri kullanarak analiz etmişler. Sınıflandırıcı UNBÇS kullanmışlar. Entropi ölçümlerinin sınıflandırma yeteneğini, UNBÇS sınıflandırıcısı kullanarak test etmişler. Çalışmada Bonn Üniversitesi EEG veri kümesini kullanmışlar. Sonuç olarak %92,20 doğruluk elde etmişler.

Polat ve Güneş (2007) çalışmalarında, karar ağacı (KA) sınıflandırıcısı ve Hızlı Fourier Dönüşümüne (HFD) dayalı hibrit bir sistem kullanarak EEG sinyallerinde epileptik nöbeti tespit etmişler. Bu çalışmada, iki aşamalı bir hibrit sistem önermişler: HFD kullanarak özellik çıkarımı ve KA sınıflandırıcısı kullanarak karar verme. Bu çalışmada, Bonn Üniversitesi EEG veri kümesini kullanmışlar. Önerilen sistem, k-kat çapraz doğrulama, sınıflandırma doğruluğu, duyarlılık ve özgüllük değerleri kullanarak değerlendirilmiştir. 5 ve 10-kat çapraz doğrulama kullanarak %98,68 ve %98,72 sınıflandırma doğruluğu elde edilmiştir.

Tzallas ve ark., (2009) çalışmalarında, EEG segmentlerini sınıflandırmak için zaman-frekans analizini sunmuşlar. İleri Beslemeli Yapay Sinir Ağını (İBYSA) kullanarak sınıflandırmışlar. Bonn Üniversitesi EEG veri kümesini kullanmışlar. Sonuç olarak %89 doğruluk elde etmişler.

Li ve ark., (2009) çalışmalarında, Hilbert-Huang Dönüşümü (HHD) kullanarak EEG sinyallerinin otomatik uyku evresi sınıflandırma tekniğini önermişler. Uyku-EEG veri kümesini kullanmışlar. Uyku aşamasını sınıflandırmak için k-en yakın komşu (K-NN) yöntemini kullanmışlar. 560 uyku EEG örneğinin deneysel sonuçlarına göre, yöntemin ortalama doğruluk oranı %81,70 elde edilmiştir.

Hosseini ve Khalilzadeh (2010) çalışmalarında, çok modlu biyo-sinyalleri kullanan yeni bir duygusal stres tanıma sistemi önermişler. EEG beyin aktivitesinin yansımaları olduğu ve klinik tanı ve biyomedikal araştırmalarda yaygın olarak kullanıldığı için ana sinyal olarak kullanmışlar. Uygun EEG kanallarını seçmek için beyin duygusal stres altındaki bilişsel modelini kullanmışlar. Psikofizyolojik sinyallerin nitel ve nicel olarak değerlendirilmesi, duygusal stres tanıma sisteminin

etkinliğini ve performansını artırmak için uygun EEG sinyali segmentlerini seçmeye çalışmışlar. Çalışmada uygulama amacı ile kullanılan veri kümesi yazarlar tarafından oluşturulmuştur. Sinyallerin ön işlenmesinden sonra, EEG parametrelerini çıkarmak için hem doğrusal hem de doğrusal olmayan özellikler kullanmışlar. Elman sınıflandırıcısı kullanılarak iki duygu durumundaki sınıflandırma doğruluğunu %82,70 elde edilmiştir.

Murugappan ve ark., (2011) çalışmalarında, EEG sinyallerini kullanarak insan duygu değerlendirmesini sunmuşlar. Bu çalışmada, duyguları sınıflandırmak için EEG sinyalinden istatistiksel öznitelikleri çıkarmak için “db8”, “sym8” ve “coif5” olmak üzere üç farklı dalgacık fonksiyonu kullanmışlar. Çalışmada uygulama amacı ile kullanılan veri kümesi yazarlar tarafından videolardan oluşturulmuştur. İstatistiksel özelliklerin doğrulanması 5-kat çapraz doğrulama kullanılarak gerçekleştirildi. Bu çalışmada, K-NN, 62 kanalda %83,04 ve 24 kanalda %79,17 ortalama elde edilmiştir.

Acharya ve ark., (2012) çalışmalarında, doğrusal olmayan özellikler kullanarak normal ve alkolik EEG sinyallerinin otomatik olarak tanımlanması için bir Bilgisayar Destekli Teşhis (BDT) tekniği önermişler. Sınıflandırıcı olarak Destek Vektör Makinesi (DVM) kullanmışlar. Bu çalışmada kullanılan EEG veri kümesi, Kaliforniya Üniversitesi, Irvine veri kümelerinden bilgi keşfi (UCI KDD) arşivinden almışlar. Sonuç olarak %91,70 doğruluk elde etmişler.

Nicolaou ve Georgiou (2012) çalışmalarında, otomatik epileptik nöbet tespiti için bir özellik olarak Permütasyon Entropisini (PE) kullanmışlar. Çalışmada Bonn Üniversitesi EEG veri kümesini kullanmışlar. Normal ve epileptik EEG segmentlerini PE değerlerine göre sınıflandırmak için DVM kullanmışlar. Epileptik ve nöbetsiz EEG'yi karakterize etmek için bir özellik olarak PE kullanarak %94,38 duyarlılık ve %93,23 özgüllük elde edilmiştir.

Nasehi ve ark., (2012) çalışmalarında, spektral özelliklere ve sinir ağı sınıflandırıcılarına dayanan optimal bir EEG tabanlı duygu tanıma algoritması önermişler. Bu algorithmada Gabor fonksiyonları ve dalgacık dönüşümü uygulanarak duyguya bağlı EEG sinyallerinden spektral, uzamsal ve zamansal özellikler seçilmiştir. Daha sonra, altı temel duygudan çıkarılan özellikler arasındaki optimal doğrusal olmayan karar sınırını belirlemek için geliştirilmiş Parçacık Sürüşü Optimizasyonu (PSO) ve Olasılıksal Sinir Ağı (OSA) gibi sinir ağı sınıflandırıcıları geliştirmişler. En iyi sonuç, Gabor tabanlı öznitelikler ve OSA sınıflandırıcı kullanıldığında elde edilmiştir. Çalışmada uygulama amacı ile kullanılan veri kümesi yazarlar tarafından oluşturulmuştur. Çalışmada ortalama %64,78 doğruluk elde edilmiştir.

Hsu ve ark., (2013) çalışmalarında, Fpz-Cz kanalının EEG sinyalinden alınan enerji özelliklerine dayalı olarak uyku aşamalarını otomatik olarak sınıflandırmak için tekrarlayan bir sinirsel sınıflandırıcı sunmuşlar. Çalışmada Uyku-EDF veri kümesini kullanmışlar. Sonuç olarak ortalama sınıflandırma başarısı olarak %87,20 elde etmişler.

Hosseini ve ark., (2013) çalışmalarında, beyin aktivitesinin epileptik davranışının karakterizasyonu için EEG sinyallerinin analizini sunmuşlar. Çalışmada EEG veri kümesini kullanmışlar. UNBÇS sınıflandırıcısını kullanmışlar. Sonuç olarak %96,90 doğruluk elde etmişler.

Obayya ve Abou-Chadi (2014) çalışmalarında uyanık, evre 1, evre 2, evre 3, evre 4 ve REMS olmak üzere altı uyku evresi sınıflandırmışlar. Spektral analiz, dalgacık dönüşümü ve Bulanık c-ortalama algoritmalarına (BCO) dayalı bulanık kümeleme kullanmışlar. Sonuç olarak ortalama sınıflandırma oranı %92,27 elde edilmiştir.

Ahammad ve ark., (2014) çalışmalarında, epileptik nöbet olay ve başlangıcını otomatik olarak tespit etme yöntemlerini sunmuşlar. Normal ve epileptik EEG sinyalleri doğrusal sınıflandırıcı kullanarak sınıflandırmışlar. Nöbet olaylarının tespiti için Bonn Üniversitesi EEG veri kümesini kullanmışlar. Çalışmada %84,20 doğruluk elde edilmiştir.

Fu ve ark., (2014), HHD ve DVM kullanarak EEG sinyallerinin nöbet sınıflandırması için teknik sunmuşlar. EEG sinyallerini sınıflandırmak için DVM kullanılmıştır. Uygulama aşamasında Bonn Üniversitesi EEG veri kümesini kullanmışlar. Çalışmada sınıflandırma doğruluğu %99,125 elde edilmiştir.

Sharma ve ark., (2014) çalışmalarında, fokal ve fokal olmayan EEG sinyallerinin sınıflandırılması için bir yöntem sunmuşlar. En Küçük Kareler Destek Vektör Makinesi (EK-DVM) sınıflandırıcısını kullanmışlar. Çalışmada Bern-Barcelona EEG veri kümesini uygulama amacı ile kullanmışlar. Sonuç olarak %87 doğruluk elde etmişler.

Juárez-Guerra ve ark., (2015) çalışmalarında, EEG'yi girdi olarak kullanarak epilepsi nöbetlerini tanımlayabilen sinir ağları ve dalgacık analizine dayalı bir sistem sunmuşlar. Sınıflandırıcı olarak İBYSA kullanmışlar. Çalışmada Bonn Üniversitesi EEG veri kümesini kullanmışlar. Sonuç olarak %99,26 bir doğruluk elde etmişler.

Almuhammadi ve ark., (2015) çalışmalarında, EEG sinyali kullanarak Obstrüktif Uyku Apnesi (OUA) tespitini incelemişler. Bu çalışmada kullanılan EEG sinyallerinin veri kümesi, Physionet web sitesinde bulunan MIT-BIH Polisomnografik veri

kümesidir. Sınıflandırıcı olarak DVM kullanmışlar. Çalışmada %97,14 doğruluk elde etmişler.

Xiang ve ark., (2015), çalışmalarında iki açık kaynaklı EEG veri kümesini kullanmışlar. Biri CHB-MIT veri kümesi, diğeri ise Bonn veri kümesidir. Çalışmada ön işlem olarak FuzzyEn yöntemini kullanmışlar. Sınıflandırma amacı ile DVM sınıflandırıcısı kullanılmıştır. CHB-MIT veri kümesinde %98,31 doğruluk, %98,27 duyarlılık, %98,36 özgüllük elde edilmiştir. Bonn veri kümesinde ise doğruluk, duyarlılık ve özgüllük hepsi %100 elde edilmiştir.

Kumar ve ark., (2015), nöbet ve nöbetsiz EEG sinyallerinin sınıflandırılması için bir Boyutlu Yerel İkili Model (1B-YİM) tabanlı öznitelikler kullanmışlar. Bonn Üniversitesi EEG veri kümesini kullanmışlar. Çalışmada %98,33 doğruluk elde edilmiştir.

Vijayan ve ark., (2015) çalışmalarında, shannon entropisi, çapraz korelasyon ve otoregresif modelleme kullanarak EEG tabanlı duygu tanıma yönelik yeni bir yaklaşım incelemişler. DEAP veri kümesini kullanmışlar. Çok Sınıflı DVM (ÇSDVM) kullanarak sınıflandırmışlar. Sonuç olarak %94,097 doğruluk elde edilmiştir.

Aguinaga ve ark., (2015) çalışmalarında, EEG sinyallerinin sınıflandırılması için Dalgacık Dönüşüm (DD) metodolojisini önermişler. Çalışmada sınıflandırıcı olarak DVM kullanmışlar. DEAP veri kümesini kullanmışlar. Sonuç olarak %81,46 doğruluk elde etmişler.

Aboalayon ve ark., (2015) çalışmalarında, EEG sinyali için uyku aşamalarını sınıflandırmak için KA önermişler. Çalışmada Uyku-EDF veri kümesini kullanmışlar. Sonuç olarak %97,30 elde etmişler.

Dhif ve ark., (2017) çalışmalarında, EEG'de epilepsi krizlerini otomatik olarak tespit etmek için yeni bir yaklaşım önermişler. Özellik çıkarma yöntemi olarak her katsayı için bir Beklenen Etkinlik Ölçümü (BEÖ) hesaplamışlar. YSA sınıflandırıcısını kullanmışlar. Çalışmada Bonn Üniversitesi EEG veri kümesini kullanmışlar. Epileptik nöbetlerin tespiti için %99,44 doğruluk elde etmişler.

Patidar ve ark., (2017) çalışmalarında, EEG sinyallerinden türetilen Ayarlanabilir Q-Dalgacık Dönüşümü (AQDD) tabanlı özellikleri kullanarak alkolizm teşhisi için yeni bir yol sunmuşlar. Çalışmada sınıflandırma amacı ile En Küçük Kareler Destek Vektör Makinesini (EK-DVM) kullanmışlar. Bu çalışmada kullanılan EEG veri kümesi, Kaliforniya Üniversitesi, UCI KDD arşivinden almışlar. Sonuç olarak %97,02 doğruluk, %96,53 duyarlılık, %97,50 özgüllük elde etmişler.

Jaiswal ve Banka (2017), epileptik EEG sinyal sınıflandırması için yerel örüntü dönüşümüne dayalı iki etkili öznelik çıkarma tekniği Yerel Komşu Tanımlayıcı Model (YKTM) ve bir Boyutlu Yerel Gradyan Modeli (1B-YGM) kullanmışlar. Her iki teknik de yerel kalıplara odaklanır ve sınıflandırma için bilgilendirici özellikler çıkarır. Önerilen teknikler, hesaplama açısından basit ve uygulanması kolaydır. Kullanılan makine öğrenimi sınıflandırıcıları KNN, DVM, Yapay Sinir Ağı (YSA) ve KA'dır. Çalışmada Bonn Üniversitesi tarafından sağlanan epilepsi EEG veri kümesini kullanmışlar. Normal ve epileptik EEG sinyalleri arasındaki sınıflandırma için, YKTM ve bir Boyutlu Yerel Degrade Deseni (1B-YDD) %99,82 ve %99,80 sınıflandırma doğruluğu elde edilmiştir.

Das ve Mudoi (2017) çalışmalarında, EEG sinyallerinden epileptik nöbetin saptanması için bir Ampirik Mod Ayırıştırma (AMA) yöntemini sunmuşlar. Bu çalışmada Bonn Üniversitesi EEG veri kümesini kullanmışlar. Sınıflandırıcı olarak DVM algoritmasını kullanmışlar. Çalışmada %100 doğruluk elde etmişler.

Sharma ve ark., (2018) çalışmalarında, alkollü ve normal bireylerin EEG sinyallerinin sınıflandırılması için otomatik bir sistem geliştirmişler. Çalışmada 10-kat çapraz doğrulama kullanmışlar. Bu çalışmada kullanılan EEG veri kümesi UCI KDD arşivinden alınmıştır. Sınıflandırıcı olarak EK-DVM ile kullanılmıştır. Sonuç olarak %97,08 doğruluk elde etmişler.

Acharya ve ark., (2018) çalışmalarında, normal, preiktal ve nöbet sınıflarını tespit etmek için 13 katmanlı derin Evrişimli Sinir Ağı (ESA) algoritması uygulamıştır. Bonn Üniversitesi veri kümesinden EEG sinyalleri kullanmışlar. Çalışmada doğruluk %88,67, özgüllük %90 ve duyarlılık %95 elde edilmiştir.

Sharmila ve ark., (2018) çalışmalarında, EEG sinyallerinin ayrıştırılması için Ayırık Dalgacık Dönüşüm (ADD) tekniğini uygulamışlar. Sınıflandırıcı olarak DVM kullanmışlar. Bonn Üniversitesi EEG veri kümesini kullanmışlar. Sonuç olarak %100 doğruluk elde etmişler.

Bhattacharyya ve ark., (2018) çalışmalarında, fokal ve fokal olmayan gruplarının EEG sinyallerini saptamak için otomatik bir yaklaşım sunmuşlar. Bu çalışmada Bern Barselona veri kümesini kullanmışlar. Sınıflandırıcı olarak EK-DVM ile kullanılmıştır. Çalışmada %90 doğruluk, duyarlılık %88 ve özgüllük %92 elde edilmiştir.

Yuan ve ark., (2018) çalışmalarında, epilepsi veri kümesinde otomatik EEG nöbet tespiti için Derin Öğrenme (DÖ) kullanmışlar. Genel nöbet tespit algoritmasını

kullanmışlar. Çalışmada CHB-MIT EEG veri kümesini kullanmışlar. 5-kat çapraz doğrulama kullanarak %94,37 doğruluk ve %85,34 f1-skor elde etmişler.

Daoud ve ark., (2018) çalışmalarında EEG kayıtlarından otomatik epileptik nöbet tespiti için yöntemler sunmuşlar. Sınıflandırıcı Derin Evrişimli Sinir Ağı (DESA) kullanmışlar. Çalışmada kullanılan EEG verileri Bonn Üniversitesi Epileptoloji Bölümü veri kümesinden alınmıştır. Sınıflandırma doğruluğu %98,60 elde etmişler.

İbrahim ve ark., (2018) çalışmalarında, epilepsi ve Otizm Spektrum Bozukluğu (OSB) tanısına yardımcı olmak için farklı EEG özellik çıkarma ve sınıflandırma tekniklerini araştırmışlar. OSB yöntemi, beyindeki farklılıklardan kaynaklanan bir gelişimsel yetersizliktir. Ön işlem olarak EEG sinyali, ADD kullanarak birkaç EEG alt bandına ayrıştırılmadan ana artefaktları çıkarmışlar. ADD ve çapraz korelasyon yaklaşımları, EEG sinyallerinden özellikler çıkarmak için kullanmışlar. ADD'yi Standart Sapma (SP), Bant Gücü (BG), Shannon Entropi (SE) dahil olmak üzere çeşitli işlevlerle birleştirmişler. Epilepsi teşhisi için sınıflandırıcı olarak K-NN ve DVM kullanmışlar. Önerilen yöntemleri doğrulamak için bu çalışmada farklı EEG veri kümeleri kullanmışlar. Epilepsi teşhisi için Bonn EEG veri kümesini kullanmışlar. Sonuç olarak %100 doğruluk elde etmişler. OSB'den özellikler çıkarmak için ADD ve SE yaklaşımlarını kullanmışlar. Otizm teşhisi için sınıflandırıcı YSA kullanmışlar. Otizm teşhisi için Suudi Arabistanda bulunan Kral Abdülaziz Üniversitesi (KAU) tarafından sağlanan veri kümesi kullanılmıştır. Sonuç olarak OSB için %99,71 doğruluk elde etmişler.

Thara ve ark., (2019), Almanyada bulunan Bonn Üniversitesinden toplanan veri kümesini kullanarak nöbet tespit yöntemi sunmuşlar. DVM ve K-NN sınıflandırıcıları kullanmışlar. Sonuç olarak %94 ve %79,70 sınıflandırma doğruluğu elde edilmiştir.

Torse ve ark., (2019), Yineleme Grafiklerine (YG) dayalı doğrusal olmayan bir EEG özellik çıkarma tekniği önermişler. YG, doğrusal olmayan veri analizinin gelişmiş bir tekniktir. DVM kullanarak sınıflandırmışlar. Çalışmada Bonn Üniversitesi EEG veri kümesini kullanmışlar. Çalışmada %91,20 doğruluk elde etmişler.

Wei ve ark., (2019), epileptik nöbetleri tahmin etmek için EEG verilerini analiz eden Uzun Vadeli Tekrarlayan Evrişim Ağını (UVTEA) araştırmışlar. Çalışmada UVTEA sınıflandırıcısını kullanmışlar. Epileptik nöbet tahminlerini saptamak için Bonn Üniversitesi EEG veri kümesini kullanmışlar. Çalışmada %93,40 doğruluk elde edilmiştir.

Romaissa ve ark., (2019) çalışmalarında, ADD ile öznitelik çıkarımının gerçekleştirildiği EEG sinyalinden epileptik nöbeti tespit etmişler. Çalışmada Bonn Üniversitesi EEG veri kümesini kullanmışlar. Sınıflandırıcı olarak KNN algoritmasını kullanmışlar. Sınıflandırma doğruluğu %99,57 elde etmişler.

Nandy ve ark., (2019) çalışmalarında, nöbet olmayan sinyallerden nöbet tespiti için tam otomatik bir sistem sunmuşlar. Sınıflandırma için DVM sınıflandırıcı kullanmışlar. Çalışmada CHB-MIT veri kümesini kullanmışlar. Sonuç olarak %97,05 doğruluk elde etmişler.

George ve ark., (2019) çalışmalarında, zaman-frekans alanı istatistiksel özelliklerine dayalı bir duygu tespit yöntemi önermişler. DVM sınıflandırıcısını kullanmışlar. Çalışmada DEAP veri kümesini kullanmışlar. Çalışmada %92,36 doğruluk elde etmişler.

Yıldırım ve ark., (2020) çalışmalarında, anormal EEG sinyallerinin otomatik tespiti için bir Boyutlu Evrişimsel Sinir Ağı (1B-ESA) tabanlı bir yaklaşım önermişler. Temple Üniversitesi Hastanesi (TÜH) EEG veri kümesinden alınan EEG sinyalleri kullanmışlar. EEG sinyallerinin sınıflandırmak için derin evrişimli sinir ağı modelini kullanmışlar. Çalışmada %79,34 doğruluk, %79,64 kesinlik ve %78,71 duyarlılık elde edilmiştir.

Dash ve ark., (2020), nöbet tespitinin doğruluğunu artırmak için EEG sinyallerinin yinelemeli filtreleme tabanlı bir ayrıştırmasını gerçekleştirmeyi amaçlamışlar. Nöbeti sınıflandırmak için Gizli Markov Modelini (GMM) uygulamışlar. Çalışmada CHB-MIT veri kümesini kullanmışlar. Sonuç olarak %99,60 doğruluk elde edilmiştir.

Ramos-Aguilar ve ark., (2020) çalışmalarında, spektrogramlara dayalı olarak EEG sinyallerinden özelliklerin çıkarılması için bir yaklaşım önermişler: İlk olarak, EEG sinyal frekansına dayalı olarak pencere uzunluğu ve tipi gibi parametrelerin denendiği zaman-frekans temsillerini elde etmek için EEG'ye Kısa Süreli Fourier Dönüşüm (KSFD) uygulamışlar. Bu çalışmada EEG sinyal spektrogramlarından özellikler elde etmişler. EEG'den özelliklerin çıkarılması için üç yol sunmuşlar: Frekans ve yüzeylere dayalı, özellikleri çıkarmak için k-ortalamlar kullanımı ile ve Yerel Üçlü Model (YÜM) ve son olarak pencerenin maksimum tepe noktalarını kullanmışlar. Epileptik nöbet geçiren hastaların EEG'lerini analiz etmek için yaygın olarak kullanılan zaman-frekans dağılımını sunmuşlar. Bonn Üniversitesi EEG veri kümesini kullanmışlar. EEG sinyallerinden, sağlıklı insanlardan ve epileptik nöbet geçirenlerden

özellikleri sınıflandırmak için çok katmanlı algılayıcı (ÇKA), K-NN ve DVM kullanmışlar. Çalışmada ÇKA ve DVM sınıflandırıcıları için %100, K-NN sınıflandırıcısı için ise %99,5 doğruluk elde etmişler.

De la O Serna ve ark., (2020) çalışmalarında, EEG sinyalinde epilepsinin saptanması ve sınıflandırılması için O-spline'larla uygulanan EEG ritmine özgü Taylor-Fourier filtre bankası geliştirmişler. DVM sınıflandırıcısının Bonn Üniversitesi veri kümesinden EEG sinyallerini kullanarak % 94,88 doğruluk elde etmişler.

Narin (2020), 2D-skalogram görüntüleri ve AlexNet, VGG16, ResNet50, Inception-Resnetv3 ve Inception-ResNetV2 gibi modelleri kullanarak fokal ve fokal olmayan epileptik nöbetleri sınıflandırmıştır. Bern-Barcelona veri kümesindeki 1B-EEG sinyalleri, sürekli zaman dalgacık dönüşümü yardımıyla 2B-skalograma dönüştürülmüştür. Alex Net modelinin doğruluğu %86,47, INC-ResNetV2 %91,33, Inception V3 %92,27, ResNet50 %90,27 ve VGG16 %86,27 elde edilmiştir.

Alhalaseh ve Alasasfeh (2020) çalışmalarında, EEG sinyallerine dayalı olarak duyguları tanımlamak için model sunmuşlar. Çalışmada sınıflandırıcı olarak ESA'nı kullanmışlar. DEAP veri kümesini kullanmışlar. Sonuç olarak %92,44% doğruluk elde etmişler.

Nath ve ark., (2020) çalışmalarında, EEG tabanlı duygu tanıma için Uzun Kısa Süreli Bellek (LSTM) modelinin performansını araştırmayı amaçlamışlar. DEAP veri kümesini kullanmışlar. Sonuç olarak %94,69 doğruluk elde etmişler.

Varone ve ark., (2021), psikojenik epileptik olmayan nöbetlerden (PEON) etkilenen beyinlerdeki anormallikleri değerlendirmek için dinlenme durumundaki EEG'lerde Güç Spektrumu Yoğunluğunu (GSY) araştırmışlar. EEG veri kümelerini kullanmışlar. ÇKA sınıflandırıcı kullanarak %85,73 kesinlik, %86,57 duyarlılık, %78,98 f1-skor ve %91,02 doğruluk elde edilmiştir.

Bahr ve ark., (2021) çalışmalarında, epileptik nöbet tespiti için bir ESA sunmuşlar. ESA, Matlab'da uygulanmış ve optimize edilmiştir. Sınıflandırıcı ESA'nı kullanmışlar. Önerilen ESA'nin eğitimi, optimizasyonu ve değerlendirilmesi için CHB-MIT veri kümesi kullanılmıştır. Çalışmada %90 duyarlılık ve %99 kesinlik elde edilmiştir.

Indira ve Krishna (2021) optimize edilmiş UNBÇS yöntemini kullanarak etkili bir nöbet saptama çerçevesi önermişler. İkili Parçacık Sürü Optimizasyonu (İPSO) sınıflandırma algoritmasını kullanmışlar. CHB-MIT veri kümesini kullanmışlar. UNBÇS yönteminin doğruluğu %99,25 elde edilmiştir.

Mehla ve ark., (2021) çalışmalarında, Fourier ayrıştırma yöntemi kullanarak durağan olmayan EEG sinyallerini ayrıştırmışlar. Sınıflandırıcı olarak DVM kullanmışlar. Çalışmada Bonn ve CHB-MIT veri kümesini kullanmışlar. Sırasıyla %99,96 ve %99,94 doğruluk elde etmişler.

Tor ve ark., (2021) çalışmalarında, dikkat eksikliği hiperaktivite bozukluğu ve davranış bozukluğu tanısında klinisyenlere yardımcı olmak için otomatik bir sistem geliştirmişler. Çalışmada Uyarlanabilir Sentetik Örneklem (USÖ) veri kümesini kullanmışlar. KNN sınıflandırıcısını kullanarak %97,88 doğruluk elde etmişler.

Qatmh ve ark., (2021), epileptik nöbetleri tespit etmek için EEG sinyalinden çıkarılan dört özelliği, esas olarak MATLAB kullanarak hem ADD hem de YSA kullanmışlar. Bonn Üniversitesi EEG veri kümesini kullanmışlar. Çalışmada %98,70 doğruluk elde etmişler.

Chakraborty ve Mitra (2021) çalışmalarında, Değişken Mod Ayrışımına (DMA) dayalı otomatik bir nöbet saptama yöntemi sunmuşlar. Çalışmada Rastgele Orman (RO) sınıflandırıcısını kullanmışlar. Bonn Üniversitesi EEG veri kümesini kullanmışlar. Sonuç olarak %98,70 doğruluk elde etmişler.

Tarafder ve ark., (2022) çalışmalarında, uyanık ve uyku durumları arasında sınıflandırma yapmak için EEG oküler artefaktlarından öznitelik çıkarma olasılığını incelemişler. Bu çalışmada, 12 katılımcıdan toplanan ham EEG sinyallerini içeren genel bir veri kümesinden göz kırpmayla ilgili 25 özelliği çıkarmak için BLINKER algoritmasını kullanmışlar. Çalışmada %91,10 doğruluk elde edilmiştir.

Chowdary ve ark., (2022) çalışmalarında tekrarlayan sinir ağı mimarilerini kullanarak EEG sinyallerinden duyguları sınıflandırmışlar. Bu çalışmada 3 tip mimari kullanmışlar: Tekrarlayan Sinir Ağı (TSA), LSTM ve Geçitli Tekrarlayan Birim (GTB). Çalışmada Bonn Üniversitesi EEG veri kümesini kullanmışlar. TSA için %95, LSTM için %97 ve GTB için %96 ortalama doğruluk elde etmişler.

Aslam ve ark., (2022) çalışmalarında, epileptik hastalarda nöbet tahmini için bir yöntem önermişler. CHB-MIT veri kümesini kullanmışlar. LSTM sınıflandırıcısını kullanmışlar. Çalışmada %94 doğruluk, %93,80 duyarlılık ve %91,20 özgüllük elde edilmiştir.

3. EPİLEPSİ

Epilepsi veya diğer adıyla sara, bir bölgedeki beyin sinir hücrelerinin anormal bir şekilde deşarj olmalarıyla kendini gösteren nörolojik bir hastalıktır. Epilepsi, kortikal nöronlardaki üst düzey elektriksel deşarj olma sonrasında açığa çıkan ani, tekrarlayan, tanımlanabilir bir durumla tetiklenmemiş epilepsi nöbetleri ile karakterize olmuş bir bozukluk durumudur. Epilepsi, beynin normal aktivitesinin, sinir hücrelerinde kalıcı olmayan surette açığa çıkan normal olmayan elektriksel aktivitesi sonucunda hasar görmesi ile meydana gelen bir rahatsızlıktır. Epilepsi hastalarında nöbet geçirme sıklığı ve şiddeti hastadan hastaya farklılık göstermektedir. Nörologlar tarafından hastalık şiddetinin belirlenmesi ve ona göre tedavi yönteminin uygulanması son derece önemlidir (Sezgin, 2016).

Epilepsili kişilerin %60-70'inin nöbetleri ilaçla kontrol edilir. Çoğu durumda, tedavi ikinci bir nöbet oluşana kadar ertelenir. Tek bir nöbetin ardından genel tekrarlama riski %27 ile %71 arasında değişmektedir. Prospektif çalışmalarda ortalama nöbet nüksü riskinin %40'a karşılık retrospektif çalışmalarda %52 olduğu bulunmuştur (Berg ve Shinnar, 1991). Bu nükslerin %80'i ilk nöbetten sonraki 2 yılda meydana gelir. Çocuklarda da benzer sayılar gözlenmektedir (Shinnar ve ark., 2000). Erken tedavinin uzun vadeli prognozu etkilediğine dair bir kanıt yoktur, ancak tedaviden önce 10'dan fazla provoke edilmemiş nöbet geçiren çocukların sonuçları daha kötü görünmektedir (Camfield ve ark., 1996).

3.1. Epileptik Nöbet

Epileptik nöbetler ilk olarak M.Ö. 2000 tarihli bir Akad metninde tanımlanmıştır (Magiorkinis ve ark., 2010). İnsanların %10 kadarı en az bir kere epileptik nöbet geçirmektedir. Bir nöbetten sonra ikinci nöbet geçirme olasılığı %50 civarındadır.

Nöbetler provoke edilebilir ve edilmeyebilir olarak ayrılabilir. Provoke nöbetler “akut semptomatik nöbetler” veya “reaktif nöbetler” olarak da bilinir. Provoke edilmemiş nöbetler "refleks nöbetler" olarak da bilinir (Fisher ve ark., 2014).

EEG, yalnızca epileptik nöbet geçirme olasılığı bulunanlarda önerilir ve mevcut nöbet veya sendromun tipini belirlemeye yardımcı olabilir. Çocuklarda genellikle sadece ikinci bir nöbetten sonra ihtiyaç duyulur.

4. MATERYAL VE YÖNTEM

Materyal bölümünde uygulama kısmında kullanılan veriden bahsedilmiştir.

4.1. Materyal

Çalışmada kullanılan veri kümesi Bonn EEG web sitesindeki kamuya açık veri tabanından alınmıştır (Andrzejak ve ark., 2001). Tam veri kümesi, her biri 100 tek kanallı EEG segmenti içeren beş kümeden (A-E ile gösterilir) oluşmaktadır. Bu segmentler, örneğin kas aktivitesi veya göz hareketleri nedeniyle artefaktlar için görsel incelemeden sonra sürekli çok kanallı EEG kayıtlarından seçilmiş ve çıkarılmıştır. Gönüllüler gözleri açık yatarken A kümesi, gözleri kapalı yatarken B kümesi oluşturulmuştur. C-E kümeleri, EEG cerrahi öncesi tanı arşivinden alınmıştır. D kümesindeki segmentler epileptojenik bölgenin içinden ve C kümesindekiler beynin karşı yarımküresinin hipokampal oluşumundan kaydedilmiştir. C ve D kümeleri yalnızca nöbetsiz aralıklarla ölçülen aktiviteyi içerirken, E kümesi yalnızca nöbet aktivitesini içermektedir. Burada segmentler, iktal aktivite sergileyen tüm kayıt alanlarından seçilmiştir. Tüm EEG sinyalleri, ortalama bir ortak referans kullanılarak aynı 128 kanallı amplifikatör sistemiyle kaydedilmiştir. Bu çalışmada, iki veri kümesi (A ve E) kullanılmıştır.

4.2. Yöntem

Yöntem bölümünde Welch yöntemi, DVM, RO, NB, LM ve LSTM algoritmaları hakkında kısa bilgi verilmiştir.

4.2.1 Welch yöntemi

Welch yönteminde, kesikli giriş sinyali belirli uzunluktaki dilimlere bölünür. Her bir dilimin, isteğe bağlı olarak seçilmiş bir pencere fonksiyonuyla çarpıldıktan sonra yumuşatılmış periodogramları hesaplanır. Ardından, i . yumuşatılmış periodogram ifadesi Denklem 1'deki gibi gösterilir.

$$\hat{P}_i(f) = \frac{1}{M} \frac{1}{H} \left[\sum_{n=0}^{M-1} w[n] x_i[n] e^{-j2\pi f n} \right]^2 \quad (1)$$

Denklem 1'deki $w[n]$ ifadesi, isteğe bağlı olarak seçilen herhangi bir pencere fonksiyonudur. Genellikle “hamming” penceresi tercih edilir. M ifadesi, dilim uzunluğudur ve her bir dilim için eşittir. H ifadesi pencere fonksiyonunun normalize edilmiş halidir ve Denklem 2’te gösterilmiştir.

$$H = \frac{1}{M} \sum_{n=0}^{M-1} w[n]^2 \quad (2)$$

Welch’in güç spektral tahmini, yumuşatılmış periodogramların ortalaması alınarak elde edilir ve Denklem 3’teki gibi gösterilir (Alkan ve Kiymik, 2006).

$$\hat{P}_{welch}(f) = \frac{1}{S} \sum_{i=1}^S \hat{P}_i(f) \quad (3)$$

4.2.2 Destek Vektör Makine (DVM) Algoritması

Destek Vektör Makinesi (DVM) denetimli makine öğrenme algoritmasıdır. DVM, hem doğrusal sınıflandırma hem de doğrusal olmayan sınıflandırma gerçekleştirir (Rani ve ark., 2022). Doğrusal olarak ayrılabilir veriler için DVM, verileri en büyük marjla ayıran bir hiperdüzlem bulur. Doğrusal olarak ayrılamaz veriler için, ayırma hiperdüzlemini bulmak için I girdi uzayındaki x verisini, çekirdek fonksiyonu $\phi(x)$ ile yüksek boyutlu bir $H - x \in R^I \rightarrow \phi(x) \in R^H$ uzayına eşler.

DVM başlangıçta iki sınıflı sınıflandırma problemleri için geliştirilmiştir. Daha sonra, çok sınıflı problemler için DVM’ler geliştirilmiştir. Her DVM, kalan tüm sınıflardan tek bir sınıfı ayırır. Her DVM, tek bir sınıfın tüm örneklerini diğer tüm sınıfların örneklerinden ayırt edecek şekilde eğitilmiştir. Test sırasında, bir x sınıf modelinin y sınıf etiketi şu şekilde belirlenir: (Jothilakshmi ve Gudivada, 2016)

$$y = \begin{cases} n, & \text{eğer } d_n(x) + t_l \geq 0 \\ 0, & \text{eğer } d_n(x) + t_l \leq 0 \end{cases} \quad (4)$$

4.2.3 Rastgele Orman (RO) Algoritması

Rastgele Orman (RO) 2001 yılında Leo Breiman tarafından geliştirilmiştir. RO, KA'nın temel sınıflandırıcı olarak alan bir topluluk öğrenme modelidir. RO, torbalama yöntemi ve Tim Kam Ho tarafından önerilen rastgele alt uzay yöntemlerinin birleşiminden oluşmaktadır. RO, parametrik olmayan bir sınıflandırma yöntemidir ve verilerle yönlendirilir. Rastgele alt uzay yönteminde en uygun dallara bölünmeyi sağlayacak değişken tüm değişkenler arasından rastgele seçilmiş az sayıda değişken tarafından belirlenir (Uzbaş, 2017).

4.2.4 Naive Bayes (NB) Algoritması

Naive Bayes Sınıflandırıcısı en bilinen ve kullanılan sınıflandırma yöntemlerinden biridir. Naive Bayes sınıflandırmasının temel özelliği, herhangi bir koşul veya olay için güçlü bir hipotez elde etmektir.

Bayes Teoremi, $P(H)$, $P(X)$ ve $P(X|H)$ olasılığını kullanarak $P(H|X)$ sonsal olasılığını hesaplamının bir yolunu sağlar. Temel bağıntı denklem (5)'de gösterilmiştir: (Shatovskaya ve ark., 2006)

$$P(H|X) = P(X|H) \cdot P(H) / P(X) \quad (5)$$

4.2.5 Levenberg-Marquardt (LM) Algoritması

Levenberg-Marquardt (LM) algoritması optimizasyon algoritmalarından biridir. LM algoritması, doğrusal olmayan gerçek değerli fonksiyonların karelerinin toplamı olarak ifade edilen çok değişkenli bir fonksiyonun minimumunu belirleyen yinelemeli bir tekniktir (Levenberg, 1944, Marquardt, 1963). Geniş bir disiplin yelpazesinde yaygın olarak benimsenen, doğrusal olmayan en küçük kareler problemleri için standart bir teknik haline gelmiştir (Mittelman, 2004). Çok çeşitli problemlerde basit gradyan iniş ve diğer eşlenik gradyan yöntemlerinden daha iyi performans gösterir.

Dik iniş ve Newton algoritmalarından türetilen LM algoritması güncellemesi (6)'da verilmiştir.


$$\Delta w = (J^T J + \mu I)^{-1} J^T e \quad (6)$$

Burada w ağırlık vektörü, I birim matris, μ kombinasyon katsayısıdır. $J (P \times M) \times N$ boyutunda Jacobian matrisini, $e (P \times M) \times 1$ boyutunda hata vektörünü göstermektedir. P eğitim örnek sayısını, M çıkış sayısını ve N ağırlık sayısını göstermektedir. μ ayarlanabilir bir parametredir. Eğer bu parametre çok büyükse yöntem dik iniş metodu gibi çok küçükse Newton metodu gibi davranmaktadır. Bu parametre için uyarlamalı bir yapı (7)'de verilmiştir.

$$\mu(n) = \begin{cases} \mu(n-1)k & E(n) > E(n-1) \\ \mu(n-1)/k & E(n) \leq E(n-1) \end{cases} \quad (7)$$

4.2.6 Uzun Kısa Süreli Bellek (LSTM) Sinir Ağı

RNN mimarisinin bir türü olan LSTM ilk defa Hochreiter & Schmidhuber (1997) tarafından ortaya konmuştur ve ilerleyen zamanlarda birçok kişi tarafından geliştirilmiştir (Hochreiter ve Schmidhuber, 1997). Şekil 4.1, tek bir LSTM hücreni göstermektedir. Üç kapının ve hücre durumunun değerlerini hesaplamak için denklemleri açıklamaktadır.



Şekil 4.1. Uzun Kısa Süreli Bellek Hücresi

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (8)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad (9)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (10)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_{t-1} + b_o) \quad (11)$$

$$h_t = o_t \tanh(c_t) \quad (12)$$

σ lojistik sigmoid fonksiyonudur ve i , f , o ve c sırasıyla giriş kapısı, unutma kapısı, çıkış kapısı ve hücre durumudur. W_{ci} , W_{cf} ve W_{co} ağırlık matrisleridir. LSTM'de üç kapı (i , f , o) bilgi akışını kontrol eder. Giriş kapısı, giriş oranını belirler. Hücre durumu hesaplanırken bu oran denklem (10) üzerinde etkilidir. Unutma kapısı, önceki


bellek h_{t-1} 'i geçer veya geçmez. Önceki belleğin oranı denklem (9)'da hesaplanır ve denklem (10) için kullanılır. Çıkış kapısı, bellek hücresinin çıkışının geçip geçmediğini belirler. Denklem (12) bu işlemi gösterir. LSTM-RNN mimarisinde, tekrarlayan gizli katman, LSTM hücresi ile değiştirilir (Kim ve ark., 2016).

4.3 Performans Değerlendirme Yöntemleri

Epileptik nöbet tanısının performansını değerlendirmek için beş istatistik kullanıldı. Bu istatistikler doğruluk, kesinlik, duyarlılık, f1-skor analizi ve 10 kat çapraz doğrulamadır. Bu yöntemler aşağıda açıklanmıştır.

4.3.1 10-kat çapraz doğrulama

Çapraz doğrulama, tekrarlanan rastgele alt örnekleme yöntemine benzer, ancak örnekleme, iki test küme çakışmayacak şekilde yapılır. K-katlı çapraz doğrulamada, mevcut küme, yaklaşık olarak eşit büyüklükte k ayrık alt kümeye bölünür. Model, eğitim kümesini temsil eden $k - 1$ adet alt küme kullanılarak eğitilir. Daha sonra model, doğrulama kümesi olarak gösterilen kalan alt kümeye uygulanır ve performans ölçülür. Bu prosedür, k alt kümesinin her biri doğrulama kümesi olarak kullanılana kadar tekrarlanır. K doğrulama kümelerindeki performans ölçümlerinin ortalaması çapraz doğrulanmış performanstır. Şekil 4.2, bu işlemi $k = 10$, yani 10-kat çapraz doğrulama için göstermektedir. İlk katta, ilk alt küme $D_{\text{değer},1}$ doğrulama kümesi olarak hizmet eder ve kalan dokuz alt küme, $D_{\text{eğitim},1}$ eğitim kümesi olarak hizmet eder. İkinci bölümde, ikinci alt küme doğrulama kümesidir ve kalan alt kümeler eğitim kümesidir. Çapraz doğrulanmış doğruluk, doğrulama kümelerinde elde edilen on doğruluğun hepsinin ortalamasıdır (Refaeilzadeh ve ark., 2009).



Şekil 4.2.10-kat çapraz doğrulama.

4.3.2 Doğruluk, kesinlik, duyarlılık, f1-skör

Bu çalışmada, algoritmaların sınıflandırma başarısını ölçmek için doğruluk, kesinlik, duyarlılık ve f1-skör istatistikleri kullanılmıştır. Bu istatistiklere ait denklemler aşağıda gösterilmiştir:

$$\text{Doğruluk} = \frac{DN+DP}{DN+YP+DP+YN} \quad (13)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (14)$$


$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (15)$$

$$\text{F1-skör} = 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (16)$$

Burada DP, DN, YP ve YN sırasıyla doğru pozitifleri, doğru negatifleri, yanlış pozitifleri ve yanlış negatifleri gösterir. Doğru pozitif, modelin pozitif sınıfı doğru tahmin ettiği bir sonuçtur. Benzer şekilde, doğru negatif, modelin negatif sınıfı doğru tahmin ettiği bir sonuçtur. Yanlış pozitif, modelin pozitif sınıfı yanlış tahmin ettiği bir sonuçtur. Yanlış negatif ise, modelin negatif sınıfı yanlış tahmin ettiği bir sonuçtur.


5. UYGULAMA

Uygulama 3 aşamadan oluşmaktadır: Veri ön işleme, sınıflandırma ve sonuçların değerlendirilmesi. Veri ön işleme olarak Welch yöntemi kullanılmıştır. Her bir segment 4096 uzunluğunda olup, 256 örnekten oluşan pencerelere bölünmüştür. Örtüşme miktarı olarak 128 belirlenmiştir. Şekil 5.1’de pencereleme yöntemi verilmiştir. Sonuç olarak her segmentten 31 tane alt segment oluşturulmuştur. Bir sonraki aşamada elde edilen alt segmentlere Welch yöntemi uygulanmıştır. Welch sonucunda her alt segmentten 129 özellik çıkarılmıştır. Çalışmada A ve E kümeleri kullanılmıştır. Bu kümelerin her biri 100 veriden oluşmaktadır. A kümesi sağlıklı kişilerden alınmış verilerden, E kümesi ise epilepsi hastası kişilerin nöbet aktivitesi verilerinden oluşmaktadır. Her segmentten 31 alt segment üretildiği için 200 segmentten toplam 6200 veri elde edilmiştir. 6200 veri 10-kat çapraz doğrulama uygulanacağı için 10 kümeye bölünmüştür.



Şekil 5.1. Pencereleme yöntemi

2. aşamada sınıflandırma işlemi yapılmıştır. Bunun için, DVM, NB, Rastgele Orman, LM ve LSTM olmak üzere toplam 5 algoritma kullanılmıştır. 3. aşamada sınıflandırma sonucu elde edilen sonuçlar değerlendirilmiştir. Uygulamanın akış şeması Şekil 5.2’de verilmiştir.




Şekil 5.2. Uygulamanın akış şeması

Sınıflandırma algoritmalarının sonuçları doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç metrikleri kullanılarak değerlendirilmiştir.

DVM algoritmasının sınıflandırma doğruluğu olarak 1. kümede %97,42, 2. kümede %96,61, 3. kümede %97,75, 4. kümede %99,03, 5. kümede %99,84, 6. kümede %96,45, 7. kümede %95,32, 9. kümede %97,09 ve 10. kümede %99,52 olarak elde edilmiştir. En yüksek sınıflandırma doğruluğu 8. kümede %100 olarak elde edilmiştir. Çizelge 5.1'de DVM algoritmasının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri verilmiştir. Çizelge 5.1'de kümelere bakıldığında dengeli başarı oranı görülmektedir. Ortalama sonuç olarak %97,91 başarı elde edilmiştir. Şekil 5.3'de DVM algoritmasının doğruluk sonuçlarını gösterilmektedir.

Çizelge 5.1. DVM algoritmasının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri.

	Doğruluk	Kesinlik	Duyarlılık	F1-skor
küme 1	97,42	95,13	100	97,51
küme 2	96,61	93,72	100	96,76
küme 3	97,75	95,72	100	97,82
küme 4	99,03	98,11	100	99,05
küme 5	99,84	99,69	100	99,85
küme 6	96,45	93,44	100	96,61
küme 7	95,32	91,53	100	95,58
küme 8	100	100	100	100
küme 9	97,09	94,57	100	97,20
küme 10	99,52	99,05	100	99,53
Ortalama sonuç	97,91	96,09	100	98



Şekil 5.3. DVM algoritmasının doğruluk sonuçları

Algoritmanın sınıflandırma kesinliği olarak 1. kümede %95,13, 2. kümede %93,72, 3. kümede %95,72, 4.kümede %98,11, 5. kümede %99,69, 6. kümede %93,44 elde edilmiştir. 7. kümede %91,53 en düşük sonuç olarak elde edilmiştir. 8. kümede %100 en yüksek sonuç olarak elde edilmiştir. 9. kümede %94,57, 10. kümede %99,05

sonuçlar elde edilmiştir. Çizelge 5.1'e bakıldığında kesinlik için yakın değerler elde edildiği görülmektedir. Duyarlılık için ortalama %96,09 elde edilmiştir.


Duyarlılık sonuçlarına bakıldığında ise tüm kümelerde %100 sonuç elde edilmiştir. Bu da tüm kümelerde YN değerinin 0 olduğunu göstermektedir. Kesinlik için ortalama %100 elde edilmiştir.

F1-skor sonuçları 1. kümede %97,51, 2. kümede %96,76, 3. kümede %97,82, 4. kümede %99,05, 5. kümede %99,85, 6. kümede %96,61, 7. kümede %95,58, 9. kümede %97,2, 10. kümede %99,53 elde edilmiştir. 8. kümede %100 en yüksek sonuç olarak elde edilmiştir. Ortalama F1-skor %98,41 elde edilmiştir.

RO algoritmasının sınıflandırma doğruluğu 2., 3., 4., 5, 6. ve 7. kümelerde %100'e eşit olup, en yüksek sonuçlar elde edilmiştir. 1. ve 10. kümelerde %99,84 eşit sonuç elde edilmiştir. Algoritma 8. kümede %99,52, 9. kümede %99,35 doğruluk oranına ulaşmıştır. RO algoritmasının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri Çizelge 5.2'de gösterilmiştir. Çizelge 5.2'de sonuçlara bakıldığında kümelerin neredeyse tamamında aynı sonuçlar elde edildiği görülmektedir. Ortalama olarak %99,86 başarı elde edilmiştir. Şekil 5.4'te RO sınıflandırıcı algoritmasının doğruluk sonuçları verilmiştir.

Çizelge 5.2. RO algoritmasının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri.

	Doğruluk	Kesinlik	Duyarlılık	F1-skor
küme 1	99,84	99,69	100	99,85
küme 2	100	100	100	100
küme 3	100	100	100	100
küme 4	100	100	100	100
küme 5	100	100	100	100
küme 5	100	100	100	100
küme 6	100	100	100	100
küme 7	100	100	100	100
küme 8	99,52	100	99,04	99,52
küme 9	99,35	98,74	100	99,36
küme 10	99,84	100	99,69	99,84
Ortalama sonuç	99,86	99,85	99,88	99,86



Şekil 5.4. RO algoritmasının doğruluk sonuçları

Algoritmanın sınıflandırma kesinliği olarak 1. kümede %99,69 elde edilmiştir. 2., 3., 4., 5., 6., 7., 8. ve 10. kümelerde %100'e eşit en yüksek sonuçlar olarak elde edilmiştir. 9. kümede ise %98,74 sonuç elde edilmiştir. Ortalama sonuç olarak %99,85 elde edilmiştir.


Duyarlılık sonuçlarına bakıldığında 1., 2., 3., 4., 5., 6., 7. ve 9. kümelerde %100'e eşit en yüksek sonuçlar olarak elde edilmiştir. 8. kümede %99,04, 10. kümede %99,69 sonuçlar elde edilmiştir. Çizelge 5.2'ye bakıldığında ortalama sonuç %99,88 edildiği görülmektedir.

RO algoritmasının f1-skor sonucu 1. kümede %99,85, 8. kümede %99,52, 9. kümede %99,36, 10. kümede %99,84 elde edilmiştir. 8. ve 9. kümelerde %99,52 eşit sonuçlar elde edilmiştir. 2., 3., 4., 5., 6. ve 7. kümelerde %100'e eşit en yüksek sonuçlar elde edilmiştir.

NB algoritmasının sınıflandırma doğruluğu 1. ve 6. kümelerde %99,68'e eşit sonuçlar elde edilmiştir. 2. kümede %99,52, 3. kümede %98,71, 7. kümede %99,22, 9. kümede %96,94 olarak elde edilmiştir. 4., 5. ve 10. kümelerde %99,84 olarak eşit sonuçlar elde edilmiştir. 8. kümede en düşük sonuç olarak %83,37 elde edilmiştir. Çizelge 5.3'te NB algoritmasının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri verilmiştir. Çizelge 5.3'te görüldüğü üzere 9 kümede nerdeyse eşit sonuçlar üretmesine rağmen kümenin birinde düşük sonuca ulaşılmıştır. Ortalama sonuç olarak %97,67 başarı elde edilmiştir. Şekil 5.5'de NB sınıflandırıcı algoritmasının doğruluk sonuçları verilmiştir.

Çizelge 5.3. NB algoritmasının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri.

	Doğruluk	Kesinlik	Duyarlılık	F1-skor
küme 1	99,68	99,36	100	99,69
küme 2	99,52	99,05	100	99,53
küme 3	98,71	97,51	100	98,74
küme 4	99,84	99,69	100	99,85
küme 5	99,84	100	99,68	99,84
küme 6	99,68	99,37	100	99,69
küme 7	99,22	98,71	97,77	98,23
küme 8	83,37	100	67,09	80,30
küme 9	96,94	94,27	100	97,05
küme 10	99,84	100	99,69	99,84
Ortalama sonuç	97,67	98,80	96,43	97,28



Şekil 5.5. NB algoritmasının doğruluk sonuçları

Kesinlik sonuçları 1. kümede %99,36, 2. kümede %99,05, 3. kümede %97,51, 4. kümede %99,69 olarak elde edilmiştir. 6. kümede %99,37 en düşük sonuç elde edilmiştir. Algoritmanın kesinlik sonuçları 7. kümede %98,71 ve 9. kümede %94,27 elde edilmiştir. 8. ve 10. kümelerde sonuçlar %100 olarak elde edilmiştir. Ortalama sonuç olarak %98,80 elde edilmiştir.


Duyarlılık sonuçlarına bakıldığında 1., 2., 3., 4., 6. ve 9. kümelerde %100 eşit en yüksek sonuçlar elde edilmiştir. 5. kümede %99,68, 7. kümede %97,77 sonuçları elde edilmiştir. 8. kümede %67,09 en düşük sonuç elde edilmiştir. 10. kümede %99,69 sonuç elde edilmiştir. Ortalama sonuç olarak %96,43 elde edilmiştir.

NB algoritmasının sınıflandırma f1-skor 1. ve 6. kümelerde %99,69 eşit sonuçlar elde edilmiştir. 2. kümede %99,53, 3. kümede %98,74, 4. kümede %99,85, 7. kümede %98,23, 9. kümede %97,05 sonuçlar elde edilmiştir. 5. ve 10. kümelerde %99,84'e eşit en yüksek sonuçlar elde edilmiştir. 8. kümede %80,3 en düşük sonuç elde edilmiştir. Ortalama sonuç olarak en düşük sonuç %97,28 elde edilmiştir.

LM algoritmasının sınıflandırma doğruluğu olarak 1., 4., 5. ve 8. kümelerde %99,84 sonuçları elde edilmiştir. 2. kümede %94,19, 6. kümede %99,52, 10. kümede %99,35 olarak sonuçlar elde edilmiştir. 7. ve 9. kümelerde %97,91 sonuçları elde edilmiştir. En yüksek sınıflandırma doğruluğu 3. kümede %100 olarak elde edilmiştir. Çizelge 5.4'de LM algoritmasının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri verilmiştir. Ortalama sonuç olarak %98,83 başarı elde edilmiştir. Şekil 5.6'da sınıflandırıcı LM algoritmasının doğruluk sonuçlarını görülmektedir.

Çizelge 5.4. LM algoritmasının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri.

	Doğruluk	Kesinlik	Duyarlılık	F1-skor
küme 1	99,84	99,69	100	99,85
küme 2	94,19	89,69	100	94,57
küme 3	100	100	100	100
küme 4	99,84	99,69	100	99,85
küme 5	99,84	99,69	100	99,85
küme 6	99,52	99,05	100	99,53
küme 7	97,91	96,29	99,69	97,96
küme 8	99,84	99,69	100	99,85
küme 9	97,91	96,01	100	97,97
küme 10	99,35	98,74	100	99,36
Ortalama sonuç	98,83	97,86	99,97	98,88



Şekil 5.6. LM doğruluk sonuçları

Algoritmanın sınıflandırma kesinliği olarak 1., 4., 5. ve 8. kümelerde %99,69'e eşit sonuçlar elde edilmiştir. 2. kümede en düşük sonuç olarak %89,69 elde edilmiştir. 3. kümede %100 en yüksek sonuç olarak elde edilmiştir. 6. kümede %99,05, 7. kümede %96,29, 9. kümede %96,01, 10. kümede %98,74 sonuçları elde edilmiştir. Kesinlik için ortalama %97,86 elde edilmiştir.

Duyarlılık sonuçlarına bakıldığında ise 8. kümede %99,69 elde edilmiştir. Kalan tüm kümelerde %100'e eşit sonuçlar elde edilmiştir. Duyarlılık için ortalama sonuç %99,97 elde edilmiştir.

F1-skor sonuçları 1., 4., 5. ve 8. kümelerde %99,85 elde edilmiştir. 2. kümede %94,57, 6. kümede %99,53, 7. kümede %97,96, 9. kümede %97,97, 10. kümede %99,36 sonuçları elde edilmiştir. En yüksek sınıflandırma doğruluğu 3. kümede %100 olarak elde edilmiştir. Ortalama f1-skor %98,88 elde edilmiştir.

LSTM sinir ağının sınıflandırma doğruluğu 1. kümede ve 6. kümede %99,84 olarak eşit elde edilmiştir. 2. kümede %98,06, 7. kümede %99,19, 8. kümede %99,87, 9. kümede %99,35 olarak elde edilmiştir. 3., 4., 5. ve 10. kümelerde sinir ağının doğruluğu %100'e eşit sonuçlar olarak elde edilmiştir. LSTM sinir ağının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri Çizelge 5.5'de gösterilmektedir. Şekil 5.7'de LSTM sınıflandırıcısının doğruluk sonuçları verilmiştir. Ortalama sonuç olarak %99,30 elde edilmiştir.


Kesinlik sonuçları 1., 2., 3., 4., 5., 6., 7., 9. ve 10. kümelerde %100 olarak eşit sonuçlar elde edilmiştir. 8. Kümede ise %95,20 elde edilmiştir. Ortalama sonuç olarak %99,52 sonuç elde edilmiştir.

Duyarlılık sonuçlarına bakıldığında 1. ve 6. kümelerde %99,69 eşit sonuçlar elde edilmiştir. 2.kümede %96,30, 7.kümede %98,43, 9. kümede %98,74 sonuçlar elde edilmiştir. 3., 4., 5., 8. ve 10. kümelerde %100'e eşit sonuçlar elde edilmiştir. Ortalama sonuç olarak %99,67 elde edilmiştir.

F1-skor sonuçları olarak 1. kümede %99,85, 2. kümede %98,12, 6. kümede %99,85, 7. kümede %99,20, 8. kümede %97,55, 9. kümede %99,36 elde edilmiştir. 3., 4., 5. ve 10. kümelerde %100 eşit sonuçlar elde edilmiştir. Ortalama sonuç olarak %99,31 elde edilmiştir.

Çizelge 5.5. LSTM sinir ağının doğruluk, kesinlik, duyarlılık, f1-skor ve ortalama sonuç değerleri.

	Doğruluk	Kesinlik	Duyarlılık	F1-skor
küme 1	99,84	100	99,69	99,85
küme 2	98,06	100	96,30	98,12
küme 3	100	100	100	100
küme 4	100	100	100	100
küme 5	100	100	100	100
küme 6	99,84	100	99,69	99,85
küme 7	99,19	100	98,43	99,20
küme 8	97,58	95,20	100	97,55
küme 9	99,35	100	98,74	99,36
küme 10	100	100	100	100
Ortalama sonuç	99,38	99,52	99,31	99,39




Şekil 5.7. LSTM doğruluk sonuçları

Çizelge 5.6 sınıflandırıcıların ortalama doğruluk sonuçlarını göstermektedir.

Çizelge 5.6. Sınıflandırıcıların doğruluk ortalama sonuçları.

	Ortalama doğruluk sonuçları
DVM	97,91
RO	99,86
NB	97,67
LM	98,83
LSTM	99,38

Şekil 5.8 sınıflandırıcıların doğruluk ortalama sonuçlarını göstermektedir.



Şekil 5.8. Sınıflandırıcıların ortalama doğruluk sonuçlarını

Konfüzyon matrisi, makine öğrenimi alanında ve özellikle istatistiksel sınıflandırma probleminde, hata matrisi olarak da bilinen bir karışıklık matrisidir. Bir algoritmanın performansının görselleştirilmesini sağlayan özel bir tablo düzenidir. Karışıklık matrisi, tahmin modelinin performansını görselleştirmenin yoludur. Karışıklık matrisindeki her veri sınıfları doğru veya yanlış sınıflandırmış olsun, model tarafından yapılan tahminlerin sayısını gösterir. Karışıklık matrisinin satırları örneklerin gerçek değerlerine sütunları ise sınıflandırma sonucu elde edilen sonuçlara karşılık gelmektedir. Bu çalışmada konfüzyon matrisini kullanılmıştır.

DVM algoritmasının konfüzyon matrisine bakıldığında sağlıklı bireyler sınıfına (1) ait 3130 kişi tamamı doğru sınıflandırıldığı görülmektedir. Nöbet aktiviteli (0) 3070 veriden 2940'nı doğru ve 130'nu yanlış yanlış tahmin etmiştir. DVM algoritmasının konfüzyon matrisi Çizelge 5.7'de verilmiştir.

Çizelge 5.7. DVM algoritmasının konfüzyon matrisi

	0	1
0	2940	130
1	0	3130

RO algoritmasının konfüzyon matrisine bakıldığında sağlıklı bireyler sınıfına (1) ait 3130 veriden 3124'nün doğru ve 6'nı yanlış sınıflandırıldığı görülmektedir. Nöbet aktiviteli (0) 3070 veriden 3066 adedini doğru ve 4 adedini yanlış tahmin etmiştir. RO algoritmasının konfüzyon matrisi Çizelge 5.8'de verilmiştir.

Çizelge 5.8. RO algoritmasının konfüzyon matrisi

	0	1
0	3066	4
1	6	3124

NB algoritmasının konfüzyon matrisine bakıldığında sağlıklı bireyler sınıfına (1) ait 3130 veriden 3018'nin doğru ve 112'nin yanlış sınıflandırıldığı görülmektedir. Nöbet aktiviteli (0) 3070 veriden 3031 adedini doğru ve 39 adedini yanlış tahmin etmiştir. NB algoritmasının konfüzyon matrisi Çizelge 5.9'da verilmiştir.

Çizelge 5.9. NB algoritmasının konfüzyon matrisi

	0	1
0	3031	39
1	112	3018

LM algoritmasının konfüzyon matrisine bakıldığında sağlıklı bireyler sınıfına (1) ait 3130 veriden 3129'u doğru ve 1'i yanlış sınıflandırılmıştır. Nöbet aktiviteli (0) 3070 veriden 2998'inin doğru ve 72'nin yanlış tahmin edildiği görülmektedir. LM algoritmasının konfüzyon matrisi Çizelge 5.10'da verilmiştir.

Çizelge 5.10. LM algoritmasının konfüzyon matrisi

	0	1
0	2998	72
1	1	3129

LSTM sinir ağının konfüzyon matrisine bakıldığında sağlıklı bireyler sınıfına (1) ait 3130 veriden 3115'nin doğru ve 15'nin yanlış sınıflandırıldığı görülmektedir. Nöbet aktiviteli (0) 3070 veriden 3047'nin doğru ve 23'nün yanlış tahmin edildiği görülmektedir. LSTM sinir ağının konfüzyon matrisi Çizelge 5.11'de verilmiştir.

Çizelge 5.11. LSTM sinir ağının konfüzyon matrisi

	0	1
0	3047	23
1	15	3115

Çizelge 5.12’de tez çalışmasında elde edilen sonuçların literatürle karşılaştırması görülmektedir.

Çizelge 5.12. Epileptik nöbetleri teşhis etmek için yöntemimizin ve yazarlar tarafından kullanılan yöntemler ve sonuçlar

Çalışma	Yöntem	Sonuç
Güler ve Übeyli (2005)	UNBÇS	%98,68
Kannathal ve ark., (2005)	UNBÇS	%92,20
Polat ve Güneş (2007)	KA, HFD, 5-kat ve 10-kat çapraz doğrulama	%98,68 %98,72
Tzallas ve ark., (2009)	İBYSA	%89
Hosseini ve Khalilzadeh (2010)	Elman sınıflandırıcı	%82,70
Murugappan ve ark., (2011)	5-kat çapraz doğrulama, K-NN 62 kanal, K-NN 74 kanal	%83,04 %79,17
Nicolaou ve Georgiou (2012)	PE, DVM	%94,38 %93,23
Ahammad ve ark., (2014)	Doğrusal sınıflandırıcı	%84,20
Fu ve ark., (2014)	HHD, DVM	%99,125
Xiang ve ark., (2015)	FuzzyEn, DVM	%100 %100 %100
Kumar ve ark., (2015)	1B-YİM	%98,33
Dhif ve ark., (2017)	BEÖ, YSA	%99,44
Jaiswal ve Banka (2017)	YKTM, 1B-YGM, KNN, DVM, YSA, KA	%99,82 %99,80
Das ve Mudoi (2017)	AMA, DVM	%100
Acharya ve ark., (2018)	ESA	%88,67 %90 %95
Sharmila ve ark., (2018)	ADD, DVM	%100
Ibrahim ve ark., (2018)	OSB, ADD, K-NN, DVM	%100
Thara ve ark., (2019)	DVM, K-NN	%94 %79,70
Torse ve ark., (2019)	YG, DVM	%91,20
Wei ve ark., (2019)	UVTEA	%93,40
Romaissa ve ark., (2019)	K-NN, ADD	%99,57
Ramos-Aguilar ve ark., (2020)	ÇKA, K-NN, DVM, KSFD	%100 %99,50
De la O Serna ve ark., (2020)	Taylor-Fourier filtre bankası, DVM	% 94,88
Varone ve ark., (2021)	GSY, ÇKA	%85,73 %86,57 %78,98 %91,02
Mehla ve ark., (2021)	Fourier ayrıştırma, DVM	%99,96
Qatmh ve ark., (2021)	ADD, YSA	%98,70
Chakraborty ve Mitra (2021)	DMA, RO	%98,70
Chowdary ve ark., (2022)	TSA, LSTM, GTB	%95 %97 %96
Bu tez çalışması	Welch yöntem + DVM, RO, NB, LM algoritma, LSTM sinir ağı	%100 %100 %99,84 %99,84 %100

6. SONUÇLAR VE ÖNERİLER

Epilepsi, sık görülen bir nörolojik hastalıktır. Epilepside beyinde bulunan nöronlarda ani ve kontrolsüz boşalmalar olur. Bunun sonucunda hastada istemsiz kasılmalar, bilinç değişiklikleri meydana gelir. Epilepsi beyin sistemini etkilendiğinden beyinin yönettiği birçok fonksiyon bozulmaktadır. Beyindeki sinir hücrelerinde dengeli olan elektrik akımında normal dışı hareketlerin meydana gelmesi kişide şuur kaybı, bedenini kontrol edememe gibi durumlar yaratır.

Bu çalışmada, sınıflandırıcı algoritmaları, DÖ'yü ve Welch yöntemini kullanarak EEG sinyalinde epileptik nöbetlerin tespitini amaçlanmıştır. Veriler Bonn EEG veri kümesi web sitesindeki kamuya açık veri tabanından alınmıştır. Tüm veriler, sağlıklı deneklerin ve epilepsi hastalığından muzdarip kişilerin EEG sinyallerinden elde edilmiştir. Çalışmada veri kümesinde bulunan 5 kümeden ikisi: A ve E kümeleri kullanıldı. A kümesi sağlıklı kişilerden, E kümesi ise epilepsi hastası kişilerin nöbet aktivitesi verilerinden alınmıştır. Segment, bir yapının birbirine benzeyen parçalarından her biridir. Her bir segment 4096 uzunluğunda olup, 256 örnekten oluşan pencerelere bölündü. Örtüşme miktarı olarak 128 belirlendi. Sonuç olarak her segmentten 31 tane alt segment oluştu. Bir sonraki aşamada elde edilen alt segmentlere welch yöntemi uygulandı. Welch sonucunda 129 tane özellik çıkarıldı ve sınıflandırma algoritmaları kullanıldı. Her segmentten 31 alt segment üretildiği için 200 segmentten toplam 6200 veri elde edildi. 6200 veri 10-kat çapraz doğrulama uygulandığı için 10 kümeye bölündü. Çalışmada veriler DVM, NB, RO, LM algoritmaları ve LSTM sinir ağı kullanılarak sınıflandırıldı. Sınıflandırmadan elde edilen sonuçları değerlendirmek için doğruluk, kesinlik, duyarlılık ve f1-skor istatistikleri kullanıldı. RO ve LSTM'in bazı kümelerinde doğruluk, kesinlik, duyarlılık ve f1-skore sonuçları %100 elde edildi.

Tez çalışmasında temel olarak EEG sinyalleri ile epileptik nöbetlerin otomatik olarak belirlenebilmesi için çeşitli yöntemler önerilmiştir. Çalışmada önerilen algoritmalarının performansını ölçmek için Bonn EEG veri kümesi kullanılmıştır. Epileptik nöbetlerin teşhisinin gerekli olduğu durumda makine öğrenmesi sınıflandırma yöntemlerinin oldukça iyi performans sergilediği görülmektedir. Uzmanlara destek olarak makine öğrenmesi yöntemleri kullanılarak EEG sinyalinde epileptik nöbetlerin teşhisi konusunda faydalanılabilir.

KAYNAKLAR

- Aboalayon, K. A., Almuhammadi, W. S. ve Faezipour, M. A comparison of different machine learning algorithms using single channel EEG signal for classifying human sleep stages. 2015 Long Island Systems, Applications and Technology, 2015. IEEE, 1-6.
- Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H. ve Adeli, H. 2018. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. *Computers in biology and medicine*, 100, 270-278.
- Acharya, U. R., Sree, S. V., Chattopadhyay, S. ve Suri, J. S. 2012. Automated diagnosis of normal and alcoholic EEG signals. *International journal of neural systems*, 22, 1250011.
- Aguinaga, A. R., Ramírez, M. L. ve Flores, M. D. R. B. 2015. Classification model of arousal and valence mental states by EEG signals analysis and Brodmann correlations. *Int. J. Adv. Comput. Sci. Appl*, 6, 230-238.
- Ahammad, N., Fathima, T. ve Joseph, P. 2014. Detection of epileptic seizure event and onset using EEG. *BioMed research international*, 2014.
- Alhalaseh, R. ve Alasasfeh, S. 2020. Machine-learning-based emotion recognition system using EEG signals. *Computers*, 9, 95.
- Alkan, A. ve Kiymik, M. K. 2006. Comparison of AR and Welch methods in epileptic seizure detection. *Journal of Medical Systems*, 30, 413-419.
- Almuhammadi, W. S., Aboalayon, K. A. ve Faezipour, M. Efficient obstructive sleep apnea classification based on EEG signals. 2015 Long Island Systems, Applications and Technology, 2015. IEEE, 1-6.
- Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P. ve Elger, C. E. 2001. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. *Physical Review E*, 64, 061907.
- Aslam, M. H., Usman, S. M., Khalid, S., Anwar, A., Alroobaea, R., Hussain, S., Almotiri, J., Ullah, S. S. ve Yasin, A. 2022. Classification of EEG signals for prediction of epileptic seizures. *Applied Sciences*, 12, 7251.
- Bahr, A., Schneider, M., Francis, M. A., Lehmann, H. M., Barg, I., Buschhoff, A.-S., Wulff, P., Strunskus, T. ve Faupel, F. 2021. Epileptic seizure detection on an ultra-low-power embedded RISC-V processor using a convolutional neural network. *Biosensors*, 11, 203.
- Basar, E. 2004. *Memory and brain dynamics: Oscillations integrating attention, perception, learning, and memory*, CRC press.
- Berg, A. T. ve Shinnar, S. 1991. The risk of seizure recurrence following a first unprovoked seizure: a quantitative review. *Neurology*, 41, 965-965.
- Bhattacharyya, A., Sharma, M., Pachori, R. B., Sircar, P. ve Acharya, U. R. 2018. A novel approach for automated detection of focal EEG signals using empirical wavelet transform. *Neural Computing and Applications*, 29, 47-57.
- Camfield, C., Camfield, P., Gordon, K. ve Dooley, J. 1996. Does the number of seizures before treatment influence ease of control or remission of childhood epilepsy? Not if the number is 10 or less. *Neurology*, 46, 41-44.
- Chakraborty, M. ve Mitra, D. 2021. Epilepsy seizure detection using kurtosis based VMD's parameters selection and bandwidth features. *Biomedical Signal Processing and Control*, 64, 102255.
- Chowdary, M. K., Anitha, J. ve Hemanth, D. J. 2022. Emotion Recognition from EEG Signals Using Recurrent Neural Networks. *Electronics*, 11, 2387.
- Daoud, H. G., Abdelhameed, A. M. ve Bayoumi, M. Automatic epileptic seizure detection based on empirical mode decomposition and deep neural network. 2018 IEEE 14th International Colloquium on Signal Processing & Its Applications (CSPA), 2018. IEEE, 182-186.
- Das, K. ve Mudoi, R. Analysis of EEG signals using empirical mode decomposition and support vector machine. 2017 IEEE International Conference on Power, Control, Signals and Instrumentation Engineering (ICPCSI), 2017. IEEE, 358-362.
- Dash, D. P., Kolekar, M. H. ve Jha, K. 2020. Multi-channel EEG based automatic epileptic seizure detection using iterative filtering decomposition and Hidden Markov Model. *Computers in biology and medicine*, 116, 103571.
- De La O Serna, J. A., Paternina, M. R. A., Zamora-Méndez, A., Tripathy, R. K. ve Pachori, R. B. 2020. EEG-rhythm specific Taylor–Fourier filter bank implemented with O-splines for the detection of epilepsy using EEG signals. *IEEE Sensors Journal*, 20, 6542-6551.
- Dhif, I., Hachicha, K., Pinna, A., Hochberg, S., Mhedhbi, I. ve Garda, P. Epileptic seizure detection based on expected activity measurement and neural network classification. 2017 39th Annual International

- Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2017. IEEE, 2814-2817.
- Fisher, R. S., Acevedo, C., Arzimanoglou, A., Bogacz, A., Cross, J. H., Elger, C. E., Engel Jr, J., Forsgren, L., French, J. A. ve Glynn, M. 2014. ILAE official report: a practical clinical definition of epilepsy. *Epilepsia*, 55, 475-482.
- Fu, K., Qu, J., Chai, Y. ve Dong, Y. 2014. Classification of seizure based on the time-frequency image of EEG signals using HHT and SVM. *Biomedical Signal Processing and Control*, 13, 15-22.
- George, F. P., Shaikat, I. M., Ferdawoos, P. S., Parvez, M. Z. ve Uddin, J. 2019. Recognition of emotional states using EEG signals based on time-frequency analysis and SVM classifier. *International Journal of Electrical & Computer Engineering (2088-8708)*, 9.
- Güler, I. ve Übeyli, E. D. 2005. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients. *Journal of neuroscience methods*, 148, 113-121.
- Hochreiter, S. ve Schmidhuber, J. 1997. Long short-term memory. *Neural computation*, 9, 1735-1780.
- Hosseini, S. A., Akbarzadeh-T, M. ve Naghibi-Sistani, M. B. 2013. Qualitative and quantitative evaluation of EEG signals in epileptic seizure recognition. *International Journal of Intelligent Systems and Applications*, 5, 41.
- Hosseini, S. A. ve Khalilzadeh, M. A. Emotional stress recognition system using EEG and psychophysiological signals: Using new labelling process of EEG signals in emotional stress state. 2010 international conference on biomedical engineering and computer science, 2010. IEEE, 1-6.
- Hsu, Y.-L., Yang, Y.-T., Wang, J.-S. ve Hsu, C.-Y. 2013. Automatic sleep stage recurrent neural classifier using energy features of EEG signals. *Neurocomputing*, 104, 105-114.
- Ibrahim, S., Djemal, R. ve Alsuwailem, A. 2018. Electroencephalography (EEG) signal processing for epilepsy and autism spectrum disorder diagnosis. *Biocybernetics and Biomedical Engineering*, 38, 16-26.
- Indira, P. B. ve Krishna, R. D. 2021. Optimized adaptive neuro fuzzy inference system (OANFIS) based EEG signal analysis for seizure recognition on FPGA. *Biomedical Signal Processing and Control*, 66, 102484.
- Jaiswal, A. K. ve Banka, H. 2017. Local pattern transformation based feature extraction techniques for classification of epileptic EEG signals. *Biomedical Signal Processing and Control*, 34, 81-92.
- Jothilakshmi, S. ve Gudivada, V. 2016. Large scale data enabled evolution of spoken language research and applications. *Handbook of Statistics*. Elsevier.
- Juárez-Guerra, E., Alarcon-Aquino, V. ve Gomez-Gil, P. 2015. Epilepsy seizure detection in EEG signals using wavelet transforms and neural networks. *New trends in networking, computing, E-learning, systems sciences, and engineering*. Springer.
- Kannathal, N., Choo, M. L., Acharya, U. R. ve Sadasivan, P. 2005. Entropies for detection of epilepsy in EEG. *Computer methods and programs in biomedicine*, 80, 187-194.
- Kim, J., Kim, J., Thu, H. L. T. ve Kim, H. Long short term memory recurrent neural network classifier for intrusion detection. 2016 international conference on platform technology and service (PlatCon), 2016. IEEE, 1-5.
- Knight, J. N. 2003. *Signal fraction analysis and artifact removal in EEG*. Citeseer.
- Kumar, T. S., Kanhangad, V. ve Pachori, R. B. 2015. Classification of seizure and seizure-free EEG signals using local binary patterns. *Biomedical Signal Processing and Control*, 15, 33-40.
- Levenberg, K. 1944. A method for the solution of certain non-linear problems in least squares. *Quarterly of applied mathematics*, 2, 164-168.
- Li, Y., Yingle, F., Gu, L. ve Qinye, T. Sleep stage classification based on EEG Hilbert-Huang transform. 2009 4th IEEE Conference on Industrial Electronics and Applications, 2009. IEEE, 3676-3681.
- Magiorkinis, E., Sidiropoulou, K. ve Diamantis, A. 2010. Hallmarks in the history of epilepsy: epilepsy in antiquity. *Epilepsy & behavior*, 17, 103-108.
- Marquardt, D. W. 1963. An algorithm for least-squares estimation of nonlinear parameters. *Journal of the society for Industrial and Applied Mathematics*, 11, 431-441.
- Mehla, V. K., Singhal, A., Singh, P. ve Pachori, R. B. 2021. An efficient method for identification of epileptic seizures from EEG signals using Fourier analysis. *Physical and Engineering Sciences in Medicine*, 44, 443-456.
- Misulis, K. E. ve Murray, E. L. 2017. *Essentials of Hospital Neurology*, Oxford University Press.
- Mittelman, H. 2004. The Least Squares Problem.[web page] <http://plato.asu.edu/topics/problems/nlolsq.html>. Jul.
- Murugappan, M., Nagarajan, R. ve Yaacob, S. 2011. Combining spatial filtering and wavelet transform for classifying human emotions using EEG Signals. *Journal of Medical and Biological Engineering*, 31, 45-51.

- Nandy, A., Alahe, M. A., Uddin, S. N., Alam, S., Nahid, A.-A. ve Awal, M. A. Feature extraction and classification of EEG signals for seizure detection. 2019 International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST), 2019. IEEE, 480-485.
- Narin, A. 2020. Detection of focal and non-focal epileptic seizure using continuous wavelet transform-based scalogram images and pre-trained deep neural networks. *Irbm*.
- Nasehi, S., Pourghassem, H. ve Isfahan, I. 2012. An optimal EEG-based emotion recognition algorithm using gabor. *WSEAS transactions on signal processing*, 3, 87-99.
- Nath, D., Singh, M., Sethia, D., Kalra, D. ve Indu, S. An efficient approach to eeg-based emotion recognition using lstm network. 2020 16th IEEE international colloquium on signal processing & its applications (CSPA), 2020. IEEE, 88-92.
- Nicolaou, N. ve Georgiou, J. 2012. Detection of epileptic electroencephalogram based on permutation entropy and support vector machines. *Expert Systems with Applications*, 39, 202-209.
- Obayya, M. ve Abou-Chadi, F. Automatic classification of sleep stages using EEG records based on Fuzzy c-means (FCM) algorithm. 2014 31st National radio science conference (NRSC), 2014. IEEE, 265-272.
- Patidar, S., Pachori, R. B., Upadhyay, A. ve Acharya, U. R. 2017. An integrated alcoholic index using tunable-Q wavelet transform based features extracted from EEG signals for diagnosis of alcoholism. *Applied Soft Computing*, 50, 71-78.
- Polat, K. ve Güneş, S. 2007. Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform. *Applied Mathematics and Computation*, 187, 1017-1026.
- Qatmh, M., Bonny, T., Nasir, N., Al-Shabi, M. ve Al-Shammaa, A. Detection of epileptic seizure using discrete wavelet transform on gamma band and artificial neural network. 2021 14th International Conference on Developments in eSystems Engineering (DeSE), 2021. IEEE, 401-406.
- Ramos-Aguilar, R., Olvera-López, J. A., Olmos-Pineda, I. ve Sánchez-Urrieta, S. 2020. Feature extraction from EEG spectrograms for epileptic seizure detection. *Pattern Recognition Letters*, 133, 202-209.
- Rani, A., Kumar, N., Kumar, J. ve Sinha, N. K. 2022. Machine learning for soil moisture assessment. *Deep Learning for Sustainable Agriculture*. Elsevier.
- Refaeilzadeh, P., Tang, L. ve Liu, H. 2009. Cross-validation. *Encyclopedia of database systems*, 5, 532-538.
- Romaissa, D., El Habib, M. ve Chikh, M. A. Epileptic seizure detection from imbalanced EEG signal. 2019 International Conference on Advanced Electrical Engineering (ICAEE), 2019. IEEE, 1-6.
- Sezgin, N. 2016. Epileptik EG İşaretlerin Aşırı Öğrenme Makineleri ile Sınıflandırılması. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 7, 481-490.
- Sharma, M., Deb, D. ve Acharya, U. R. 2018. A novel three-band orthogonal wavelet filter bank method for an automated identification of alcoholic EEG signals. *Applied Intelligence*, 48, 1368-1378.
- Sharma, R., Pachori, R. B. ve Acharya, U. R. 2014. Application of entropy measures on intrinsic mode functions for the automated identification of focal electroencephalogram signals. *Entropy*, 17, 669-691.
- Sharmila, A., Aman Raj, S., Shashank, P. ve Mahalakshmi, P. 2018. Epileptic seizure detection using DWT-based approximate entropy, Shannon entropy and support vector machine: a case study. *Journal of medical engineering & technology*, 42, 1-8.
- Shatovskaya, T., Repka, V. ve Good, A. Application of the Bayesian Networks in the informational modeling. 2006 international conference-modern problems of radio engineering, telecommunications, and computer science, 2006. IEEE, 108-108.
- Shinnar, S., Berg, A. T., O'dell, C., Newstein, D., Moshe, S. L. ve Hauser, W. A. 2000. Predictors of multiple seizures in a cohort of children prospectively followed from the time of their first unprovoked seizure. *Annals of Neurology: Official Journal of the American Neurological Association and the Child Neurology Society*, 48, 140-147.
- Shorvon, S. D., Andermann, F. ve Guerrini, R. 2011. *The causes of epilepsy: common and uncommon causes in adults and children*, Cambridge University Press.
- Siuly, S., Li, Y. ve Zhang, Y. 2016. EEG signal analysis and classification. *IEEE Trans Neural Syst Rehabil Eng*, 11, 141-144.
- Subha, D. P., Joseph, P. K., Acharya U, R. ve Lim, C. M. 2010. EEG signal analysis: a survey. *Journal of medical systems*, 34, 195-212.
- Supriya, S., Siuly, S. ve Zhang, Y. 2016. Automatic epilepsy detection from EEG introducing a new edge weight method in the complex network. *Electronics Letters*, 52, 1430-1432.
- Tarafder, S., Badruddin, N., Yahya, N. ve Nasution, A. H. 2022. Drowsiness detection using ocular indices from EEG signal. *Sensors*, 22, 4764.

- Thara, D., Premasudha, B. ve Xiong, F. 2019. Auto-detection of epileptic seizure events using deep neural network with different feature scaling techniques. *Pattern Recognition Letters*, 128, 544-550.
- Tor, H. T., Ooi, C. P., Lim-Ashworth, N. S., Wei, J. K. E., Jahmunah, V., Oh, S. L., Acharya, U. R. ve Fung, D. S. S. 2021. Automated detection of conduct disorder and attention deficit hyperactivity disorder using decomposition and nonlinear techniques with EEG signals. *Computer Methods and Programs in Biomedicine*, 200, 105941.
- Torse, D. A., Khanai, R. ve Desai, V. V. Classification of epileptic seizures using recurrence plots and machine learning techniques. 2019 International Conference on Communication and Signal Processing (ICCSP), 2019. IEEE, 0611-0615.
- Tzallas, A. T., Tsipouras, M. G. ve Fotiadis, D. I. 2009. Epileptic seizure detection in EEGs using time–frequency analysis. *IEEE transactions on information technology in biomedicine*, 13, 703-710.
- Tzallas, A. T., Tsipouras, M. G., Tsalikakis, D. G., Karvounis, E. C., Astrakas, L., Konitsiotis, S. ve Tzaphlidou, M. 2012. Automated epileptic seizure detection methods: a review study. *Epilepsy–Histological, Electroencephalographic and Psychological Aspects*, 2027-2036.
- Uzbaş, B. 2017. Sayısal dental modellerden otomatik cinsiyet tespiti. *Konya (Doktora Tezi)*.
- Varone, G., Boulila, W., Lo Giudice, M., Benjdira, B., Mammone, N., Ieracitano, C., Dashtipour, K., Neri, S., Gasparini, S. ve Morabito, F. C. 2021. A Machine Learning Approach Involving Functional Connectivity Features to Classify Rest-EEG Psychogenic Non-Epileptic Seizures from Healthy Controls. *Sensors*, 22, 129.
- Vijayan, A. E., Sen, D. ve Sudheer, A. EEG-based emotion recognition using statistical measures and auto-regressive modeling. 2015 IEEE international conference on computational intelligence & communication technology, 2015. IEEE, 587-591.
- Wei, X., Zhou, L., Zhang, Z., Chen, Z. ve Zhou, Y. 2019. Early prediction of epileptic seizures using a long-term recurrent convolutional network. *Journal of neuroscience methods*, 327, 108395.
- Xiang, J., Li, C., Li, H., Cao, R., Wang, B., Han, X. ve Chen, J. 2015. The detection of epileptic seizure signals based on fuzzy entropy. *Journal of neuroscience methods*, 243, 18-25.
- Yıldırım, Ö., Baloglu, U. B. ve Acharya, U. R. 2020. A deep convolutional neural network model for automated identification of abnormal EEG signals. *Neural Computing and Applications*, 32, 15857-15868.
- Yuan, Y., Xun, G., Jia, K. ve Zhang, A. 2018. A multi-view deep learning framework for EEG seizure detection. *IEEE journal of biomedical and health informatics*, 23, 83-94.