T.C.
HARRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

KÜBİK BAĞ İNTERPOLASYONU VE DERİN AĞLARDAN ELDE EDİLEN HİBRİT ÖZNİTELİK VEKTÖRLERİYLE EPİLEPTİK NÖBET TESPİTİ

Emre Can KURAN

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ŞANLIURFA
2022

T.C.
HARRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

KÜBİK BAĞ İNTERPOLASYONU VE DERİN AĞLARDAN ELDE EDİLEN HİBRİT ÖZNİTELİK VEKTÖRLERİYLE EPİLEPTİK NÖBET TESPİTİ

Emre Can KURAN

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ŞANLIURFA
2022

İÇİNDEKİLER

Sayfa No

ÖZET i
ABSTRACT ii
TEŞEKKÜR iii
ŞEKİLLER DİZİNİ iv
ÇİZELGELER DİZİNİ v
SİMGELER ve KISALTMALAR DİZİNİ vi
1. GİRİŞ 1
2. ÖNCEKİ ÇALIŞMALAR 4
3. MATERYAL ve YÖNTEM 7
3.1. Materyal 8
3.1.1. Veri seti 8
3.2. Yöntem 18
3.2.1. Ön işleme 18
3.2.2. Kübik bağ interpolasyonu ile öznitelik çıkarımı 18
3.2.3. İstatistiksel öznitelik çıkarımı 21
3.2.4. Sinyal-gürültü oranının tespiti 22
3.2.5. Önerilen konvolüsyonel sinir ağı modeli ile öznitelik çıkarımı 23
3.2.6. Sınıflandırma 28
3.2.6.1. K-en yakın komşular 28
3.2.6.2. Karar ağaçları 30
3.2.6.3. Destek vektör makineleri 31
4. ARAŞTIRMA BULGULARI ve TARTIŞMA 34
4.1. Değerlendirme Ölçütleri 34
4.2. Deneysel Sonuçlar 34
4.3. Konvolüsyonel Sinir Ağının Tek Başına Performansının Değerlendirilmesi 42
5. SONUÇLAR ve ÖNERİLER 43
KAYNAKLAR 44

ÖZET

Yüksek Lisans Tezi

KÜBİK BAĞ İNTERPOLASYONU VE DERİN AĞLARDAN ELDE EDİLEN HİBRİT ÖZNİTELİK VEKTÖRLERİYLE EPİLEPTİK NÖBET TESPİTİ

Emre Can KURAN

Harran Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Mehmet Bilal ER
Yıl: 2022, Sayfa: 52

Epilepsi, tekrarlayan ve periyodik olarak ortaya çıkabilen geçici nöbetlere neden olabilen nörolojik bir hastalıktır. Elektroensefalogram (EEG), epileptik nöbet hastalıklarını tespit etmek için en önemli izleme tekniklerinden biridir. Bu çalışmada, EEG sinyallerine dayalı epileptik nöbet tespiti, Bonn Üniversitesi Epileptoloji Bölümü'nden alınan bir EEG veri seti kullanılarak değerlendirilmektedir. Önerilen yöntem üç temel adımdan oluşmaktadır. İlk adım için ön işleme yapılmıştır. Daha sonra, kübik bağ interpolasyonu kullanılarak üst ve alt zarflar çıkarılır. İkinci adımda, öznitelik vektörlerinin değerlerinin büyüme hızını azaltmak ve sinyallerin özelliklerini genelleştirmek için üst ve alt zarf değerlerine ait ortalamanın logaritması alınır. Ayrıca önerilen konvolüsyonel sinir ağı (KSA) modeli kullanılarak her bir EEG sinyali için başka bir öznitelik vektörü (derin öznitelikler) elde edilir. Daha sonra, bu öznitelik vektörleri, ön işlemeye tabi tutulmuş ham sinyallerden elde edilen istatistiksel ve zaman alanı öznitelikleri ile birleştirilir. Üçüncü adımda öznitelik vektörleri Destek Vektör Makineleri (DVM), K-en yakın Komşular (KNN) ve Karar Ağaçları (KA) kullanılarak sınıflandırılır.

ANAHTAR KELİMELER: EEG, epilepsi, KSA, kübik bağ interpolasyonu

ABSTRACT

MSc Thesis

EPILEPTIC SEIZURE DETECTION WITH HYBRID FEATURE VECTORS OBTAINED FROM CUBIC SPLINE INTERPOLATION AND DEEP NETWORKS

Emre Can KURAN

Harran University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Assist. Prof. Dr. Mehmet Bilal ER
Year: 2022, Page: 52

Epilepsy is a neurological disorder which can cause temporary seizures that are recurrent and can ocur periodically. Electroencephalogram (EEG) is one of the most significant monitoring techniques to detect epileptic seizure diseases. In this study, epileptic seizure detection based on EEG signals is assessed by using an EEG dataset which is taken from the Department of Epileptology, Bonn University. The proposed method consists of three fundamental steps.For the first step, preprocessing is made. Then,upper and lower envelopes are extracted by employing cubic spline interpolation. In the second step, the logarithm of the mean belongs to the upper and lower envelopes' values are taken in order to reduce growing rate of the feature vectors' values and generalize characteristics of the signals. In addition, using the proposed convolutional neural network (CNN) model, another feature vector (deep features) is obtained for each EEG signal. Then, these feature vectors are combined with statistical and time-domain features obtained from the preprocessed raw signals. In the third step, feature vectors are classified using Support Vector Machines (SVM), K-nearest Neighbors (KNN) and Decision Trees (DT).

KEY WORDS: EEG, epilepsy, CNN, cubic spline interpolation

TEŞEKKÜR

Bana yüksek lisans eğitimim süresince danışmanlık yaptığından, bilgilerini ve deneyimlerini aktardığından, tez konusunun seçimi ve yürütülmesi konusundaki yardımları, tezle ilgili olan çalışmalarıma katkıları ve yakın ilgisinden dolayı tez danışmanım Sayın Dr. Öğr. Üyesi Mehmet Bilal ER'e, yine yüksek lisans ile ilgili çalışmalarımdaki katkılarından dolayı Sayın Öğr. Gör. Umut KURAN'a, tez jürimde görev alan hocalarıma, ders döneminde ders aldığım tüm hocalarıma ve bana her zaman desteklerini esirgemeyen ailemdeki herkese ayrı ayrı teşekkür ederim.

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 3.1. Önerilen yöntemin akış çizelgesi 8
Şekil 3.2. Sinyalin alt ve üst zarfları 9
Şekil 3.3. Maksimum havuzlama tekniği 10
Şekil 3.4. Ortalama havuzlama tekniği 10
Şekil 3.5. Bir boyutta maksimum havuzlama tekniği 11
Şekil 3.6. Örnek bir kümeleme: mavi kareler ve kırmızı daireler farklı sınıfları temsil etmekte.. 11
Şekil 3.7. Örnek bir karar ağacı 12
Şekil 3.8. Örnek bir destek vektör makinesi 12
Şekil 3.9. A sınıfı için örnek sinyaller 13
Şekil 3.10. B sınıfı için örnek sinyaller 14
Şekil 3.11. C sınıfı için örnek sinyaller 14
Şekil 3.12. D sınıfı için örnek sinyaller 15
Şekil 3.13. E sınıfı için örnek sinyaller 16
Şekil 3.14. A sınıfı için alt ve üst zarflar 16
Şekil 3.15. B sınıfı için alt ve üst zarflar 17
Şekil 3.16. C sınıfı için alt ve üst zarflar 17
Şekil 3.17. D sınıfı için alt ve üst zarflar 21
Şekil 3.18. E sınıfı için alt ve üst zarflar 24
Şekil 3.19. A sınıfı için çıkartılan öznitelik vektörü 25
Şekil 3.20. B sınıfı için çıkartılan öznitelik vektörü 26
Şekil 3.21. C sınıfı için çıkartılan öznitelik vektörü 30
Şekil 3.22. D sınıfı için çıkartılan öznitelik vektörü 31
Şekil 3.23. E sınıfı için çıkartılan öznitelik vektörü 32
Şekil 4.1. AB-E sınıfı için karmaşıklık matrisi 38
Şekil 4.2. A-E için sınıflandırma sonuçları 38
Şekil 4.3. AB-E için sınıflandırma sonuçları 39
Şekil 4.4. ABCD-E için sınıflandırma sonuçları 39
Şekil 4.5. C-E için sınıflandırma sonuçları 40
Şekil 4.6. CD-E için sınıflandırma sonuçları 40
Şekil 4.7. AB-E için eğitim (mavi) ve test (turuncu) doğruluk eğrileri 42

ÇİZELGELER DİZİNİ

Sayfa No

Çizelge 3.1. Önerilen KSA mimarisi 9
Çizelge 3.2. Önerilen KSA mimarisine ait çıktı boyutları 27
Çizelge 3.3. Bonn EEG veri setine genel bakış..... 27
Çizelge 4.1. Oluşturulan sınıflandırma veri kümeleri 35
Çizelge 4.2. A-E için sınıflandırma sonuçları 36
Çizelge 4.3. AB-E için sınıflandırma sonuçları 36
Çizelge 4.4. ABCD-E için sınıflandırma sonuçları 37
Çizelge 4.5. C-E için sınıflandırma sonuçları 37
Çizelge 4.6. CD-E için sınıflandırma sonuçları 37
Çizelge 4.7. Önceki çalışmalarla karşılaştırma 41

SİMGELER ve KISALTMALAR DİZİNİ

AA	Ateşböceği Algoritması
ADD	Ayrık Dalgacık Dönüşümü
AFD	Ayrık Fourier Dönüşümü
AGA	Aşırı Gradyan Artırma
AK-ÇAADD	Artıklık Kaldırılmış-Çift Ağaçlı Ayrık Dalgacık Dönüşümü
BDT	Bilgisayar Destekli Tasarım
ÇÖE	Çok Ölçekli Entropi
DLB	Doğrultulmuş Lineer Birim
DVM	Desktek Vektör Makineler
EEG	Elektroensefalogram
FSSD	Fourier Senkro-Sıkıştırılmış Dönüşümü
GÖD	Grafik Öz Ayrışması
GSBOM	Gri-Seviye Birlikte Oluşum Matrisi
HFD	Hızlı Fourier Dönüşümü
İÇE	İkili Çapraz Entropi
KA	Karar Ağacı
KNN	K-en Yakın Komşular
KSA	Konvolüsyonel Sinir Ağları
MÇÖE	Modifiye Edilmiş Çok Ölçekli Entropi
PSO	Parçacık Sürü Optimizasyonu
SNR	Sinyal-gürültü Oranı
SÖİS	Sıralı Öne İlerleyen Seçim
TB	Tam Bağlı
TTAMA	Tamamlayıcı Topluluk Ampirik Mod Ayrışımı
UKSB	Uzun Kısa Süreli Bellek
VMA	Varyasyonel Mod Ayrıştırma

1. GİRİŞ

Epilepsi, tekrarlayan geçici nöbetlere sebep olabilen nörolojik bir hastalıktır (Suwanto ve ark., 2019). Fiest ve ark. (2017), aktif epilepsi vakalarının nokta prevalansının 1000 kişide 6,38 olduğunu göstermektedir. Dünyada yaklaşık 65 milyon kişi epilepsi bozukluğundan etkilenmektedir. Bu nedenle, epilepsi dünyadaki en yaygın nörolojik bozukluklardan biridir (Lin ve ark., 2018). Beyinde anormal bir elektriksel aktivite olursa, epileptik nöbete neden olabilir. Kişi bu nöbetleri defalarca deneyimlediğinde buna epilepsi adı verilir. Dolayısıyla epilepsi, beyindeki anormal nöronsal aktivite nedeniyle geçici bir belirti ve/veya semptom oluşumudur. Hastalar nöbetlerden nadiren haberdar olur ve bu durum fiziksel yaralanma riskini artırır (Ahmadi ve ark., 2020).

EEG, beyindeki elektriksel aktivitenin ortalamasıdır. Daha doğrusu beyindeki nöronların hücre dışı akım akışlarının toplamıdır. EEG sinyallerinin ölçümü esas olarak elektrotların kafa yüzeyine (kafa derisi EEG olarak adlandırılır) yerleştirilmesiyle veya cerrahi bir operasyondan sonra (intrakraniyal EEG olarak adlandırılır) elektrotların beynin içine yerleştirilmesiyle elde edilir (Podgorelec, 2012). Rutin bir EEG yaklaşık 20-30 dakika sürer, epilepsi teşhisine yardımcı olur (Benbadis ve ark., 2020). EEG, dalgalar, fokal sivri uçlar veya iki taraflı sivri uçlu dalgalar gibi anormal elektriksel aktiviteleri tespit edebilir. EEG kaydı uyku, uyanıklık gibi farklı bilinç durumlarını içerir çünkü epilepsiye bağlı anormallikler bu durumlarda farklılık gösterebilir. Epilepsisi olan bir kişide EEG sonuçları normal olabilir, bu durumda cerrahi operasyondan önce intrakraniyal EEG de gereklidir (Stafstrom ve Carmant, 2015).

Epilepsi bozukluğunun teşhisi genellikle EEG sinyallerinin manuel olarak incelenmesiyle yapılır. Bu zor bir iştir ve bu nedenle yetenekli bir nörofizyolog gerektirir. Ayrıca, bir EEG sinyal kaydının uzun bir aralığını incelemek zaman alıcı bir süreçtir. Bu nedenle, EEG sinyallerini analiz etmek ve epileptik nöbetleri tespit etmek için BDT aracı gereklidir. EEG sinyallerinden epileptik nöbetleri tespit eden

tekniklerin çoğu iki aşamadan oluşur. İlk aşama, ham EEG sinyalinden önemli bilgilerin çıkarılmasıyla ilgilidir ve zaman alanında, frekans alanında veya zaman-frekans alanında uygulanabilir. Diğer aşama, özniteliklerin sınıflandırılmasıyla ilgilidir (Sharaf ve ark., 2018). Epileptik nöbet tespiti, başlangıç tespiti veya nöbet olay tespiti olmak üzere iki şekilde yapılabilir. Başlangıç tespitinin amacı, nöbetin mümkün olan en kısa gecikmeyle başlamasını tanımaktır. Nöbet olayı tespitinin amacı, nöbetleri en yüksek doğrulukla tespit etmektir (Gandhi ve ark., 2010; Niknazar ve ark., 2010). Epileptik nöbet tespiti için çok sayıda istatistik tabanlı model önerilmiştir. Örüntü tanıma alanında da epilepsi teşhisi dikkat çekmiştir (Göksu, 2018). Varsayılan olarak, öznitelik çıkarma ve örüntü sınıflandırmasına dayanır. Bununla birlikte, sürekli (gerçek zamanlı) izlenen bir EEG sinyaline nöbet tespiti veya epilepsi teşhisi uygulamak için sınırlamalar vardır. Öznitelik çıkarma ve örüntü sınıflandırmasına dayanan epilepsi teşhisi, güvenilir olmasına rağmen hesaplama için uzun bir zamana ihtiyaç duyar (Z. Chen ve ark., 2020).

Araştırmacılar, EEG sinyallerini sınıflandırmak için birçok teknik kullanmışlardır. Alan dönüşümü için ADD (D. Chen ve ark., 2017), HFD (Delimayanti ve ark., 2020) ve AFD (Tripathi ve ark., 2019) gibi yöntemler kullanmışlardır. Araştırmacılar, doğruluğu artırmak için AA (Liu ve ark., 2017) ve yapay sinir ağlarını sınıflandırma amaçlı optimize etmek için PSO gibi algoritmaları da kullanmıştır (Satapathy ve ark., 2017). Ek olarak DVM (Sai ve ark., 2019), KNN (Amin ve ark., 2017) ve KA (Torres-Ramos ve ark., 2020) gibi makine öğrenmesi algoritmaları da kullanılmıştır. Bazı araştırmacılar, derin öğrenme yöntemlerini de kullanmıştır (Al-Nafjan ve ark., 2017; Asghar ve ark., 2019). KSA, EEG sinyalleri ile ilgili çalışmalarda kullanılmıştır. (Tayeb ve ark., 2019) tarafından yapılan çalışmada, motor görüntü hareketlerini çözmek için hem UKSB hem de KSA kullanılır. Bu şekilde manuel olarak öznitelik çıkarmaya ihtiyaç duyulmaz.

Bu çalışma, ön işlemeden sonra işlenmemiş EEG sinyallerinin alt ve üst zarflarını ele almakta, ardından Bölüm 3'te ayrıntılı olarak açıklanan aritmetik işlemleri kullanarak zarflardan EEG sinyallerinin özniteliklerini genelleştirmeye çalışmaktadır.

Bu çalışmada birden çok öznitelik birleştirilir, bu nedenle veri kümeleri için hibrit öznitelik vektörleri elde edilir. EEG sinyal verileri, Bonn Üniversitesi Epileptoloji Bölümü'ne ait Bonn epilepsi veri tabanından alınmıştır. Bonn veri seti beş veri kümesi içerir, bu nedenle çalışma farklı kümeler arasındaki doğruluk sonuçlarını karşılaştırmıştır. Bu yazıda önerilen teknik, nöbet geçiren epilepsi hastalarına karşı farklı epilepsi hastaları / sağlıklı insan gruplarını sınıflandırmak için kullanılabilir. Deneysel sonuçlardan, sınıflandırma görevinin önerilen yöntemin (%100'e yakın) doğruluk oranının en üst düzeye çıktığı görülmektedir.

Bu çalışmanın geri kalanı aşağıdaki şekilde düzenlenmiştir. Bölüm 2'de güncel literatürdeki EEG sinyallerinden nöbet tespiti ile ilgili çalışmalar gözden geçirilmiş ve başarılarından bahsedilmiştir. Bölüm 3'te kullanılan malzemeler, önerilen yöntem ve önerilen yöntemin ayrıntılı açıklamaları açıklanmıştır. Bölüm 4'te, önerilen yöntemin bilimsel yönünü açıklığa kavuşturmak için deneysel sonuçlar, veri setiyle ilgili ayrıntılar ve yardımcı grafikler verilmiştir. Bölüm 5'te sonuçlar özetlenmiş ve bir sonuç çıkarılmıştır.

2. ÖNCEKİ ÇALIŞMALAR

Epileptik nöbetleri en yüksek doğrulukla tespit etmek için EEG sinyallerinden öznitelik çıkarımı çok önemlidir. Bu bağlamda bazı önemli çalışmalar yapıldığından bu bölümde ortaya konulacaktır.

Ahammad ve ark. (2014) tarafından yapılan çalışmada, epileptik nöbet tespiti için Bonn Üniversitesi veri tabanı kullanılmaktadır. Dalgacık özniteliklerine ve istatistiksel özniteliklere dayanan, nöbetlerin otomatik tespiti için bir yöntem önermişlerdir. Üç tür EEG sinyali sınıflandırılmıştır. Bu sinyaller sırasıyla sağlıklı kişilerden, epilepsili ancak nöbetsiz kişilerden, nöbet sırasında epilepsili kişilerden kaydedilen sinyallerden oluşmaktadır. Minimum, maksimum, entropi, standart sapma, enerji ve ortalama gibi öznitelikler, sinyalin farklı alt bantlarından hesaplanıp doğrusal sınıflandırıcı kullanılarak %84,20 genel doğruluk oranı elde edilmiştir. Chandani (2017) tarafından yapılan çalışmada, EEG sinyallerinden epileptik nöbeti tespit etmek için sinir ağı analizine dayanan bir sınıflandırıcı kullanılmıştır. Sırasıyla gözleri açık sağlıklı bireye ve epilepsiye sahip bireye ait olan seçilmiş iki tip EEG sinyali kullanılmıştır. Sinyaller yeniden işlenmiştir ve ayrıştırma için AFD kullanılmıştır. Sinyal sınıflandırması amacıyla medyan, ortalama, entropi, çarpıklık, standart sapma hesaplanmıştır. Bonn Üniversitesi tarafından sağlanan veri setini kullanarak neredeyse %100 doğruluk oranına ulaşılmıştır. Molla ve ark. (2020) tarafından yapılan çalışmada, EEG sinyali, sinyalin kısa zaman dilimlerine bölünmesinden sonra ele alınmıştır. AFD, çerçeveleri belirli sayıda alt banda ayrıştırmak için kullanılmıştır. Öznitelikler, alt bantlardan çıkarılmıştır ve ardından birleştirilmiştir. Ayırt edici öznitelikler, GÖD tabanlı bir yaklaşım kullanılarak öznitelik vektöründen seçilmiştir. Seçilen öznitelikler yapay sinir ağına verilmiştir ve önerilen nöbet tespit yöntemi Bonn Üniversitesi veri seti kullanılarak %99,55'lik bir doğruluk oranına ulaşmıştır. Zhao ve ark. (2020) tarafından yapılan çalışmada, araştırmacılar, nöbetleri tespit etmek için tek boyutlu derin sinir ağını kullanan güçlü bir yöntem önermişlerdir. Derin sinir ağı, 3 evrişimli blok ve 3 tamamen bağlı katmandan oluşmaktadır. Derin sinir ağlarında kullanılan evrişimli blokların her biri, evrişimli katman, toplu normalleştirme katmanı,

doğrusal olmayan etkinleştirme katmanı, bırakma katmanı ve maksimum havuzlama katmanı gibi beş tür katman içermektedir. Modelin performansı,%97.63-%99.52 arası doğruluk oranına ulaşılan Bonn Üniversitesi veri seti kullanılarak değerlendirilmiştir.

Amin ve ark. (2020) tarafından, AFD ve aritmetik kodlamaya dayalı bilgisayar destekli bir teşhis yöntemi önerilmiştir. Yöntemin amacı, nöbetsiz sinyalleri epileptik sinyallerden ayırt etmektir. Bonn Üniversitesi'nin yayınladığı veri setini kullanarak, sınıflandırma performansı olarak %100 doğruluk oranı elde edilmiştir. Savadkoohi ve ark. (2020) tarafından yapılan çalışmada, Bonn Üniversitesi veri tabanı kullanılarak 2 adımda bir öznitelik çıkarımı yapılmıştır ve daha sonra öznitelikler KNN ve DVM tarafından ayrı ayrı sınıflandırılmıştır. İlk adımda Butterworth filtresi, Fourier Dönüşümü ve Dalgacık Dönüşümü sırasıyla zaman alanı, frekans alanı ve zaman-frekans alanında öznitelik çıkarımı için kullanılmıştır. İkinci adımda, öznitelikler T-testi ve SÖİS ile seçilmiştir. KNN ve DVM tarafından elde edilen en yüksek doğruluk oranları sırasıyla %99,50 ve %100'dür. Hussein ve ark. (2019) tarafından yapılan çalışmada, Bonn Üniversitesi tarafından yayımlanan EEG sinyalleri epileptik nöbetlerin tespiti için kullanılmıştır. Önerilen yöntemde, ilk adım olarak, EEG sinyallerinin yüksek seviyeli temsillerini öğrenmek için UKSB ağı kullanılmıştır. Bundan sonra, epileptik nöbetlerle ilgili öznitelikleri çıkarmak için TB katman kullanılmıştır. Son adımda, tahmin çıktılarını (sınıflandırma) almak için öznitelikler softmax katmanına verilmiştir. Önerilen yöntemle %100 doğruluk oranı elde edilmiştir. Akyol (2020) tarafından yapılan çalışmada, Bonn Üniversitesi tarafından yayınlanan EEG veri seti kullanılmıştır. Epileptiform aktiviteyi tespit etmek için araştırmacılar yeni bir teknik sunmuşlardır. EEG sinyallerinin ön işleme aşamasından sonra, zaman, frekans ve zaman-frekans alanında yapılan öznitelik çıkarımını tercih etmişlerdir. Çıkarılan öznitelikler, daha ayırt edilebilir oldukları için birkaç frekans alt bandına aittir. Daha sonra dağılım matrisleri kullanılarak, öznitelik uzayının boyutu 2'ye indirilmiştir. Kuadratik sınıflandırıcılar ile %98.70'lik bir doğruluk oranı elde edilmiştir.

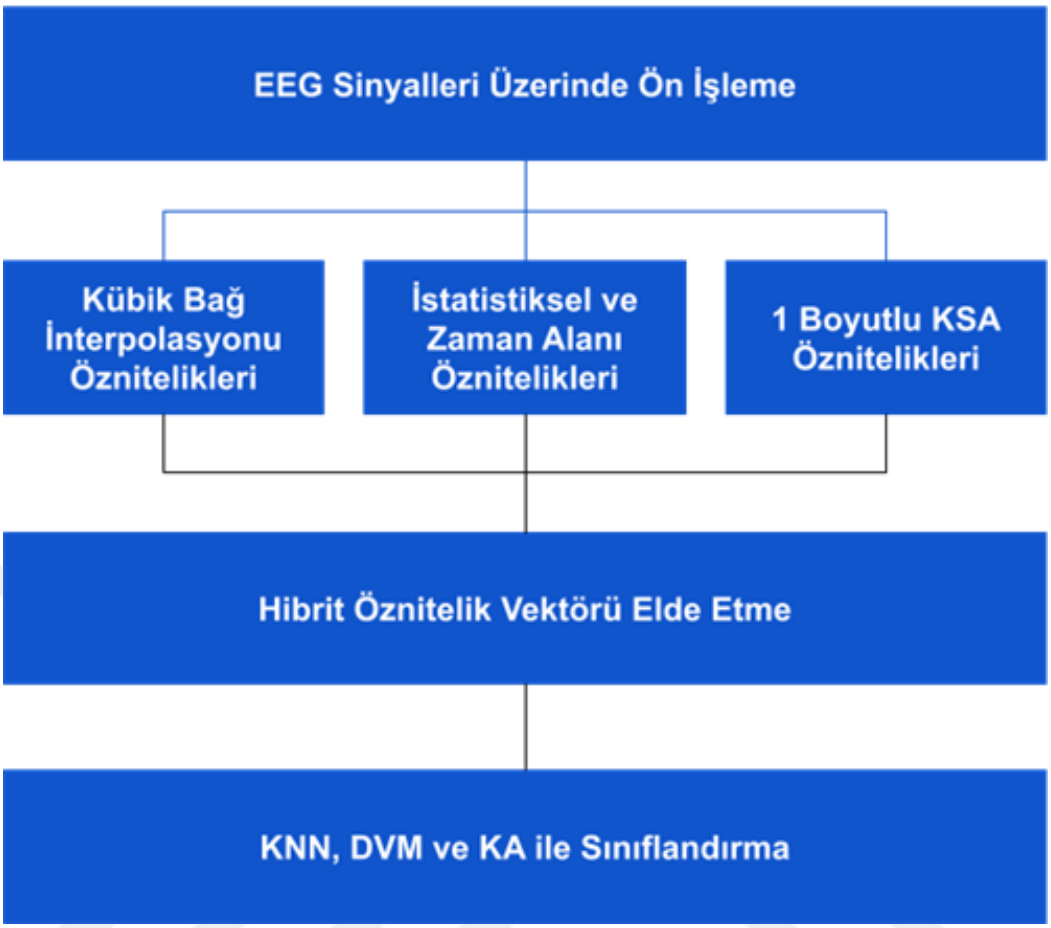
Wu ve ark. (2020) tarafından yapılan çalışmada, araştırmacılar iki veri kümesi kullanmışlardır ve veri kümelerinden birinin Bonn Üniversitesi'ne ait olduğu

bilinmektedir. Epileptik nöbetleri doğru bir şekilde tespit etmek için, TTAMA-AGA adı verilen TTAMA ve AGA entegre edilmiştir. Bonn veri setine ait farklı özne sınıfları için yaklaşık %100 doğruluk oranları elde edilmiştir. Wang ve ark. (2017) tarafından yapılan çalışmada, araştırmacılar, çok alanlı öznitelik çıkarma ve doğrusal olmayan analiz kombinasyonuna dayalı otomatik bir epilepsi tanı çerçevesi (framework) önermişlerdir. Her şeyden önce sinyaller önceden işlenmiştir. Daha sonra zaman, frekans ve zaman-frekans alanından öznitelikler çıkarılmıştır. Bundan sonra, öznitelikler klinik ilgisine göre beş frekans alt bandından çıkarılmış ve ardından boyutsallık azaltma uygulanmıştır. Önerilen yöntem %99,25 doğruluk oranına ulaşmıştır. Ahammed ve Ahmed (2020) tarafından yapılan çalışmada, araştırmacılar, epileptik nöbetleri tanımlamak için ÇÖE tabanlı doğrusal olmayan bir yöntem önermişlerdir. ÇÖE kullanarak EEG sinyallerinin karmaşıklığını karakterize etmişlerdir. Önerilen yöntem, nöbet geçiren ve ele geçirmeyen özneleri içeren Bonn veri kümesine uygulanmıştır. DVM ve istatistiksel testler kullanılarak %91,70 doğruluk oranı elde edilmiştir. Jiang ve ark. (2019) tarafından yapılan çalışmada, araştırmacılar tarafından AK-ÇAADD adlı bir çerçeve önerilmiştir. İkili ağaç dalgacık alanında, enerji ve MÇÖE gibi öznitelikler çıkartılmıştır. Daha sonra artıklık bilgileri kaldırılmıştır. Khaleelulla ve Rajesh Kumar (2019) tarafından yapılan çalışmada, VMA, ReliefF ve makine öğrenimine dayalı yeni bir teknik önerilmektedir. Veri seti Almanya Bonn üniversitesi hastanesinden alınmıştır. Öncelikle EEG sinyalinden VMA ile öznitelikler çıkarılır. Ardından en iyi öznitelikler ReliefF algoritması tarafından seçilir. Son olarak, seçilen öznitelikler YSA, KNN ve DVM'ye verilir. Bu yöntem ise % 96.60 genel doğruluk oranına ulaşmıştır.

3. MATERYAL ve YÖNTEM

Bu çalışmada önerilen yöntem, sınıflandırma için zarf öznitelikleri, derin öznitelikler, istatistiksel öznitelikler ve zaman alanı özniteliklerini kullanır. Bazı çalışmalarda, çoklu alan öznitelikleri diğer ilgili özniteliklerle birleştirilmiştir (Gajic ve ark., 2015; Wang ve ark., 2017; Wu ve ark., 2020). Bu çalışmalardan bazıları öznitelik seçme aşamasını içerirken bazıları içermemektedir. Öznitelik seçiminin önemi, öznitelik seçiminin, özniteliklerin yalnızca küçük bir alt kümesini kullanarak sorunu çözmeyi amaçlamasıdır. Öznitelik seçimi problemin boyutunu azaltabilir, öğrenme sürecini hızlandırabilir ve performansı artırabilir (Xue ve ark., 2016). Fakat bu çalışmada modelin daha genelleştirilmiş bir yapıya sahip olması amacıyla tercih edilmemiştir.

Önerilen yöntem üç aşamadan oluşmaktadır. İlk aşama için, ham EEG sinyalleri üzerinde düşük geçişli filtre ile ön işleme yapılır. Daha sonra, EEG sinyallerinin tepe noktalarında kübik bağ interpolasyonu kullanılarak sinyallerin üst ve alt zarfları çıkartılır. İkinci aşamada, bu iki zarfın ortak özniteliklerinin genelleştirilmesi için ilk olarak üst zarftan alt zarfa olan mesafe hesaplanır, bu da zarf değerlerinin Manhattan Uzaklığı hesaplanarak elde edilir. Bundan sonra, öznitelikleri normalize etmek için uzaklığın logaritması alınır ve 2'ye bölünür, böylece çok büyük sayılardan kaçınılmış olur. 2 burada ölçeklendirme katsayısıdır ve keyfi olarak seçilebilir. Bunun yanı sıra, önerilen otokorelasyon tabanlı bir boyutlu KSA modeli kullanılarak KSA katmanından öznitelikler çıkartılır. Daha sonra, zarf özniteliklerinden oluşan öznitelik vektörleri, KSA ile elde edilen öznitelikler, çeşitli yeni istatistiksel öznitelikler ve önceden işlenmiş orijinal sinyallerden çıkarılan zaman alanı öznitelikleri ile birleştirilir. Daha sonra üçüncü aşamada hibrit vektörlerle sınıflandırma yapılır. Önerilen yöntemin akış çizelgesi Şekil 3.1.'de verilmiştir.



Şekil 3.1. Önerilen yöntemin akış çizelgesi

3.1. Materyal

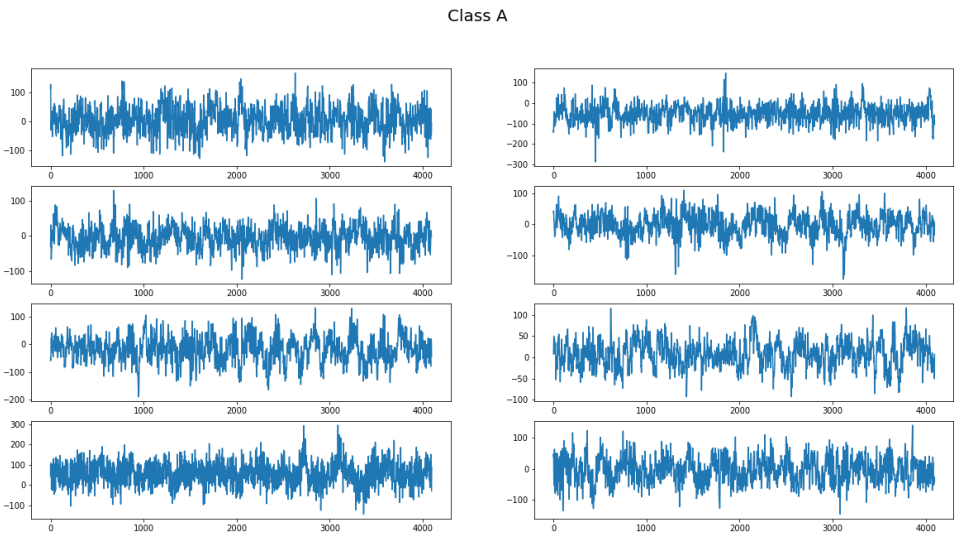
3.1.1. Veri seti

Bu çalışmada kullanılan veri kümesi Bonn Üniversitesi, Epileptoloji Bölümü'nden alınmıştır (Andrzejak ve ark., 2001). Seçilen veri seti sırasıyla A (Z), B (O), C (N), D (F) ve E (S) olarak adlandırılan 5 sınıftan oluşur. Sınıfların her biri 100 tek kanallı bölüm içerir ve bu bölümler 173.61 Hertz örnekleme hızında kaydedilir. A ve B sınıfları, gözleri açık ve gözleri kapalı durumdaki sağlıklı kişilerden alınan örnekleri içerir. C, D ve E sınıfları epilepsi hastalarının örneklerini içerir. C ve D nöbetsiz epilepsiyken, E sınıfındaki numuneler epileptik nöbet sırasında kaydedilmiştir. Kullanılan veri setine genel bir bakış Çizelge 3.1.'de verilmiştir.

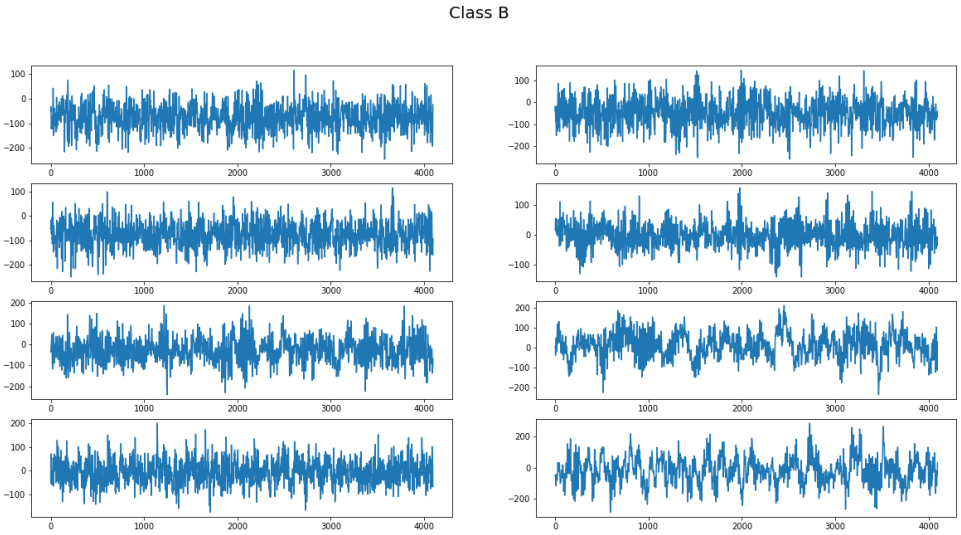
Çizelge 3.1. Bonn EEG veri setine genel bakış

	Set A (Z)	Set B (O)	Set C (N)	Set D (F)	Set E (S)
Denek türü	Sağlıklı	Sağlıklı	Nöbetsiz epilepsi hastası	Nöbetsiz epilepsi hastası	Nöbetli epilepsi hastası
Denek durumu	Uyanık ve gözler açık	Uyanık ve gözler kapalı	Nöbetler arası	Nöbetler arası	Nöbet esnasında
Elektrod Yerleşimi	10-20 sistemi	10-20 sistemi	Yarım kürenin karşı yönündeki hipokampüs	Epileptojenik bölge	Epileptojenik bölge

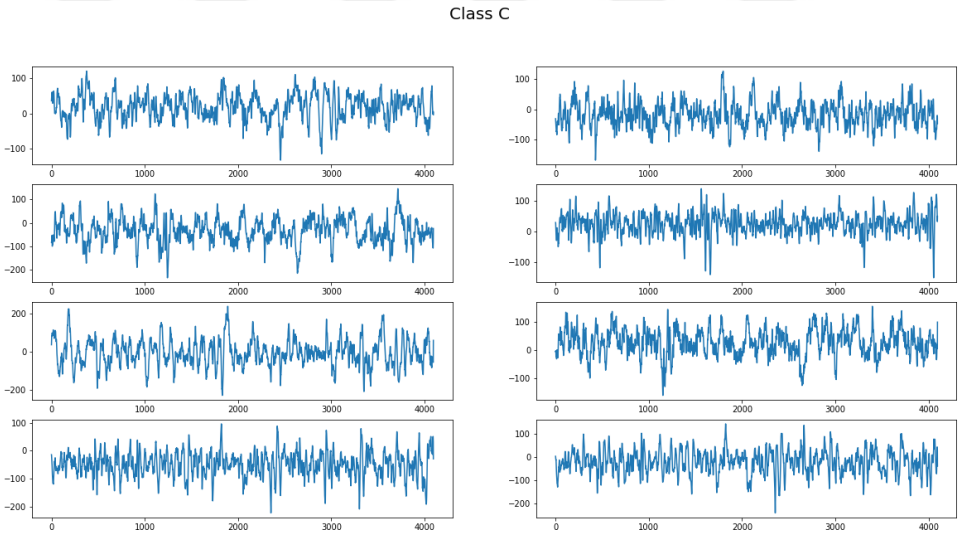
A, B, C, D, ve E sınıfları için örnek sinyaller sırasıyla Şekil 3.2., Şekil 3.3., Şekil 3.4., Şekil 3.5. ve Şekil 3.6. ile verilmiştir. Şekillerden anlaşıldığı gibi, özellikle epileptik nöbeti temsil eden örneklerle sağlıklı örnekler arasında çok belirgin bir fark bulunmaktadır. Epileptik nöbet örnekleri daha düzensizdir.



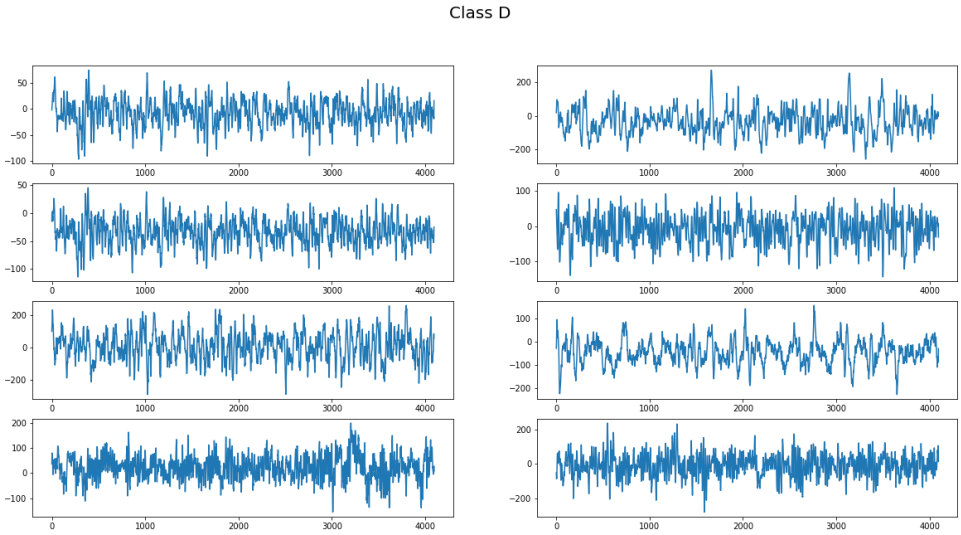
Şekil 3.2. A sınıfı için örnek sinyaller



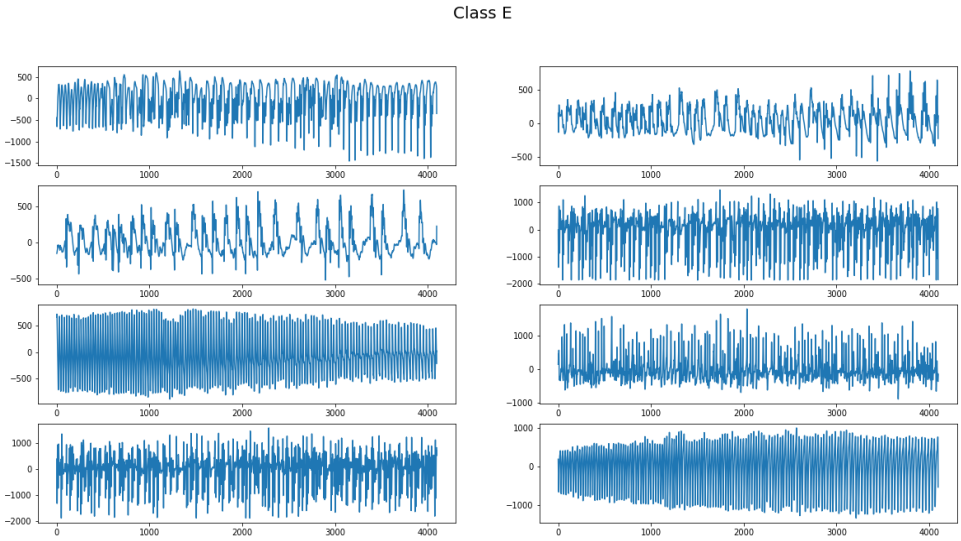
Şekil 3.3. B sınıfı için örnek sinyaller



Şekil 3.4. C sınıfı için örnek sinyaller

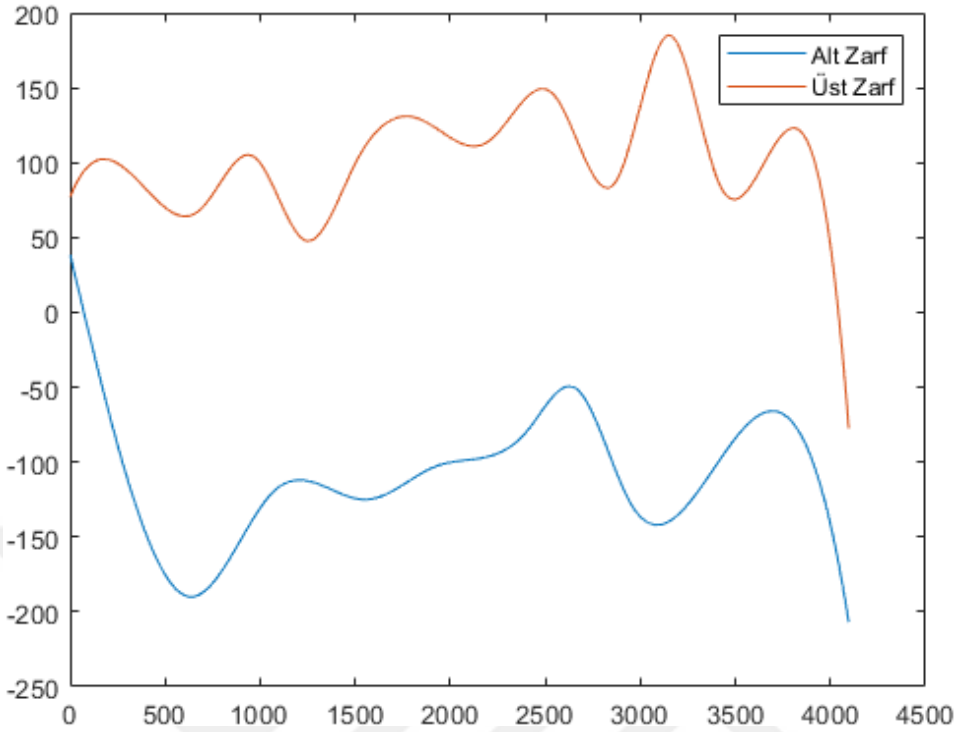


Şekil 3.5. D sınıfı için örnek sinyaller

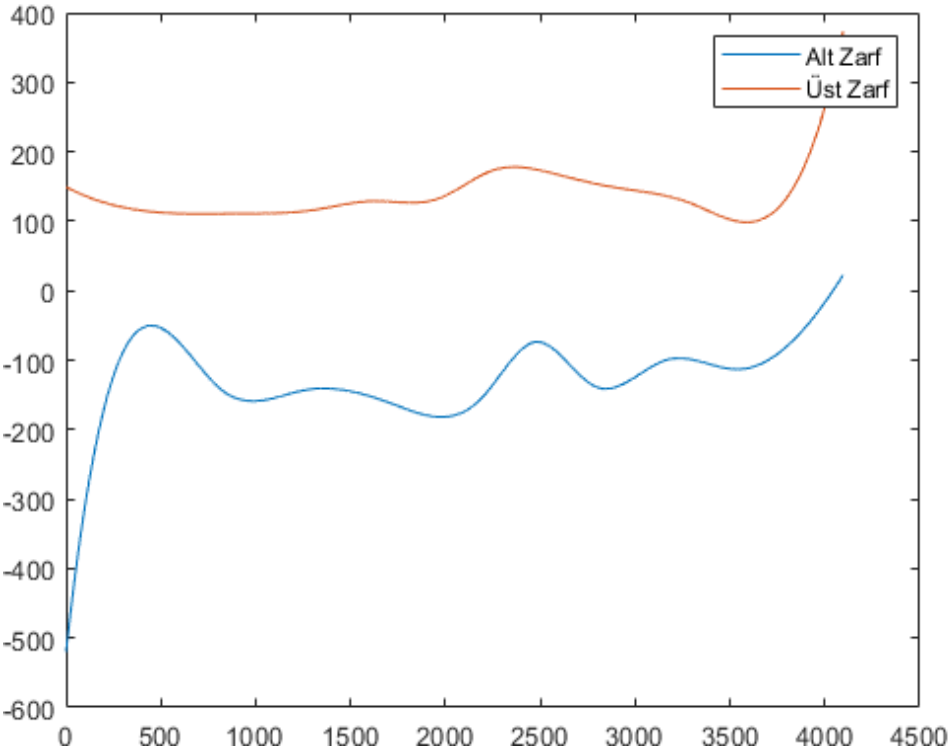


Şekil 3.6. E sınıfı için örnek sinyaller

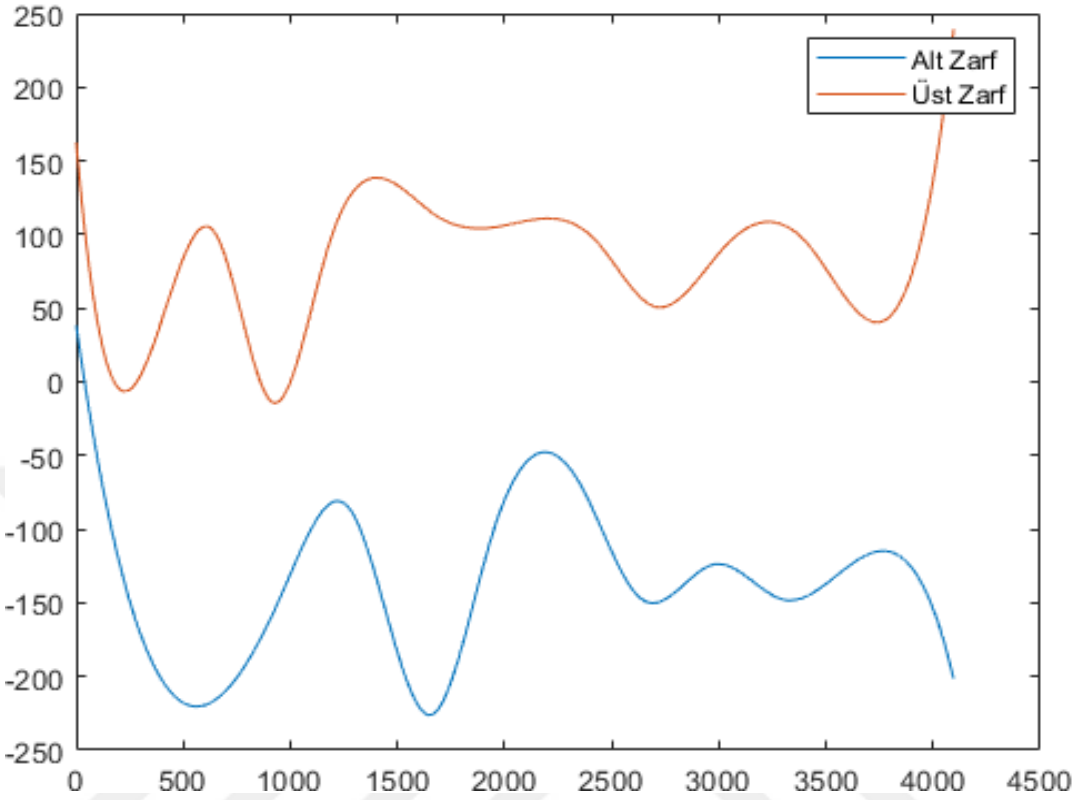
Yine sırasıyla, A, B, C, D, ve E sınıfları için sırasıyla Şekil 3.7., Şekil 3.8., Şekil 3.9., Şekil 3.10. ve Şekil 3.11. ile kübik bağ interpolasyonu kullanılarak oluşturulan alt ve üst zarflar verilmiştir.



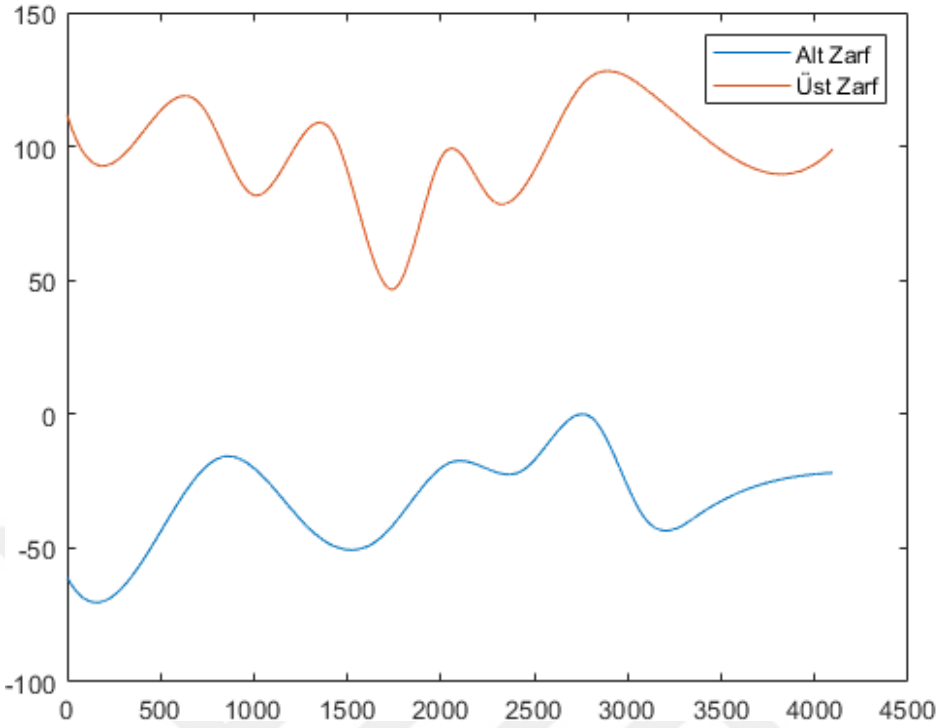
Şekil 3.7. A sınıfı için alt ve üst zarflar



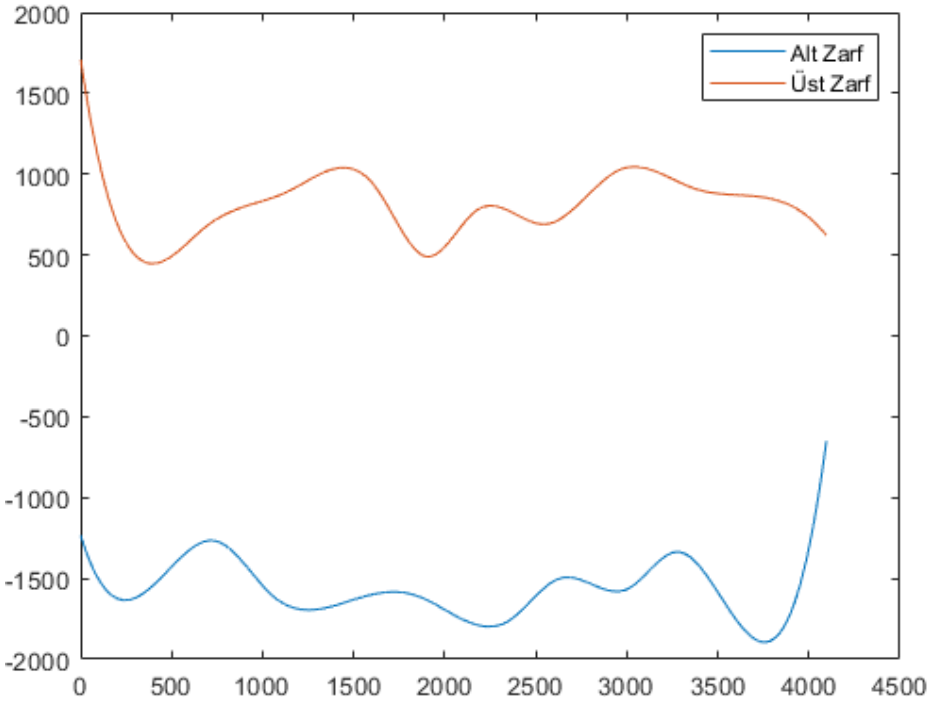
Şekil 3.8. B sınıfı için alt ve üst zarflar



Şekil 3.9. C sınıfı için alt ve üst zarflar

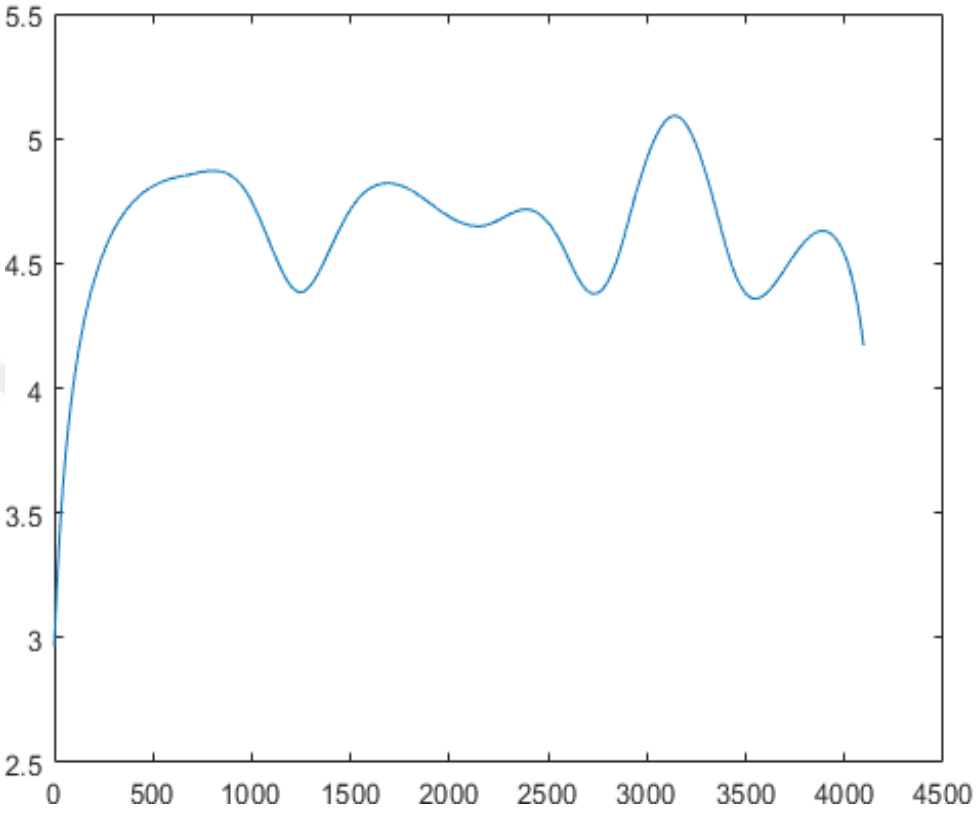


Şekil 3.10. D sınıfı için alt ve üst zarflar

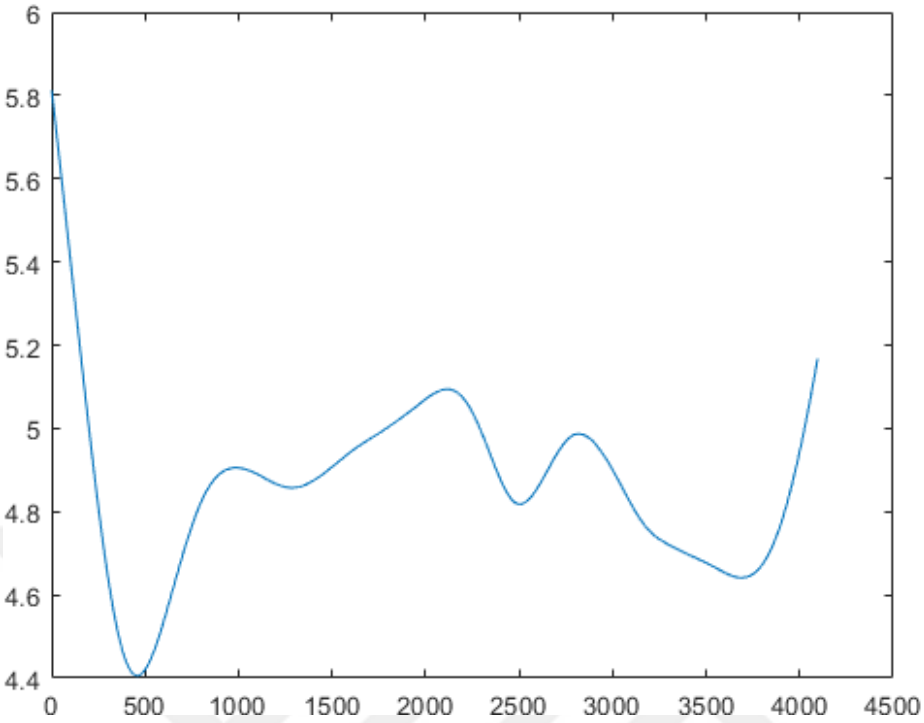


Şekil 3.11. E sınıfı için alt ve üst zarflar

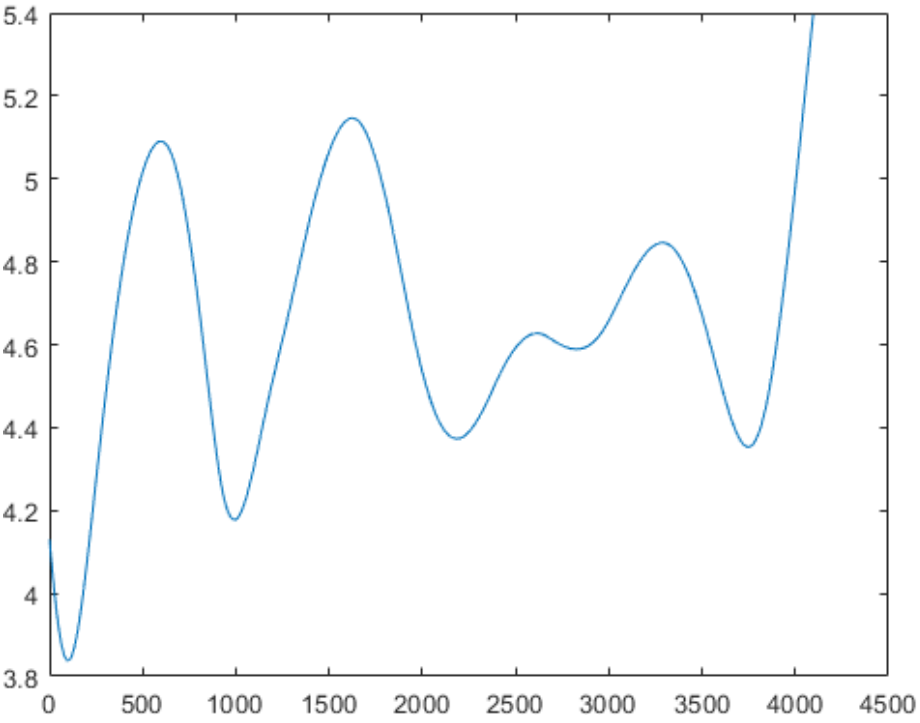
A, B, C, D, ve E sınıfları için sırasıyla Şekil 3.12., Şekil 3.13., Şekil 3.14., Şekil 3.15. ve Şekil 3.16. ile birleştirilen zarflar gösterilmiştir.



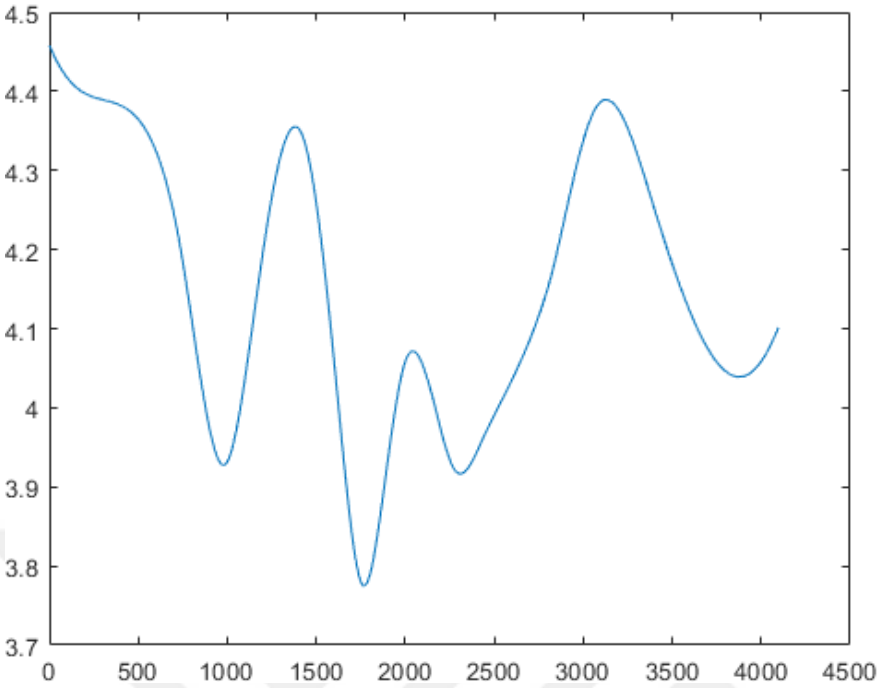
Şekil 3.12. A sınıfı için çıkartılan öznitelik vektörü



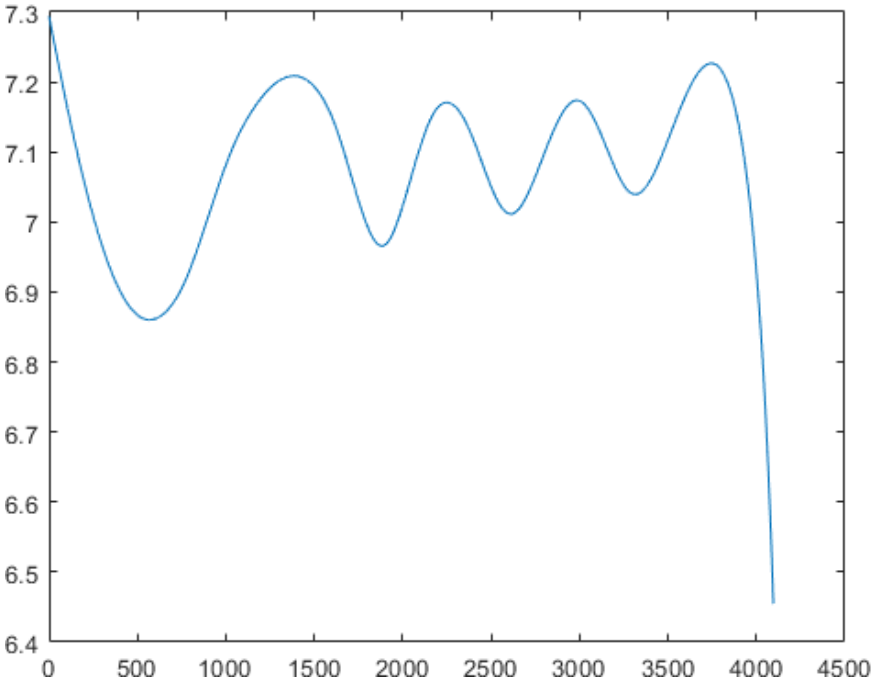
Şekil 3.13. B sınıfı için çıkartılan öznitelik vektörü



Şekil 3.14. C sınıfı için çıkartılan öznitelik vektörü



Şekil 3.15. D sınıfı için çıkartılan öznitelik vektörü



Şekil 3.16. E sınıfı için çıkartılan öznitelik vektörü

3.2. Yöntem

3.2.1. Ön işleme

Genellikle, sinyalde var olan gürültünün bastırılması veya giderilmesi için, bu gürültünün tanımlanması gerekir. Böylece sinyal kalitesi iyileştirilebilir. Bu amaçla her dosyanın 4097 örnekten oluştuğu veri setindeki dosyalardan sinyal verisi okunmuştur, bu çalışmada 4096 örnek alınmıştır. Ham EEG sinyallerine 40 hertz kesme frekansı ve 173.61 hertz örnekleme frekansına sahip düşük geçişli bir Butterworth filtresi uygulanır. Veri kümesindeki her sınıf için 1x4096 boyutunda öznitelik vektörleri elde edilir. Böylelikle ilk aşamada toplam 4096 öznitelik elde edilir.

3.2.2. Kübik bağ interpolasyonu ile öznitelik çıkarımı

Sistemler, öznitelikler aracılığıyla EEG sinyallerini karakterize etmeye dayanır ve bu işleme öznitelik çıkarma adı verilir. Öznitelik çıkarımı zaman alanında, frekans alanında ve zaman-frekans alanında yapılabilir. Ayrıca öznitelik çıkarma işlemi, güç spektral yoğunluğu, fraktal boyutlar, entropiler ve diğer bazı öznitelikler gibi öznitelikleri içerebilir (Bao ve ark., 2011). Bu çalışmada, öznitelik çıkarımı, sinyalin hem üst hem de alt zarflarından ve önceden işlenmiş olan ham sinyalden yapılmıştır. Kübik bağ interpolasyonu kullanılarak yeniden örnekleme yapılır. EEG'nin yeniden örneklenmesi, veri analizi süreci için hem uyumluluk hem de özelleştirme sağlar. EEG'yi yeniden örneklemek için, x koordinatlarını yeni tahmini y değerleriyle eşleştirmek amacıyla yeni bir aralık belirlenmelidir. Bu genellikle, (orijinal örnekler olan) bilinen noktalar arasındaki boşlukta bir fonksiyonun (buradaki sinyalin kendisidir) değerinin interpolasyonu ile yapılır. Kübik bağ interpolasyonu, özel bir kübik polinom interpolasyonu türüdür. Ek olarak, kübik bağ interpolasyonu, verilen veri noktalarında elementel fonksiyonun ilk türevinin sürekli olmasını gerektirmesiyle polinom interpolasyonundan farklıdır. Böylece interpolasyonlu fonksiyon, yeni yapay ani yükselmeler oluşturmayacak, fakat fonksiyonun daha yumuşak (düzgün) geçişlere

sahip olduğunu varsayacaktır. Kübik bağ interpolasyonu, belirlenmesi gereken iki uç nokta için ikinci türevi de alır. Genellikle uç noktalarda türev sıfıra ayarlanır (Congedo ve ark., 2002).

Kübik interpolasyonun sonucunu bulmak için izlenecek adımlar aşağıdaki gibidir. İlk olarak, [a, b] aralığında bulunan n adet veri noktasının $a = x_0 < x_1 < \ldots < x_n = b$ olacak şekilde elde edilmesi gerekir. Bir kübik fonksiyon, iki bitişik nokta arasındaki aralığı belirtmek için Denklem 3.1' de verildiği gibi tanımlanır.

$$f_i(x) = a_i + b_i(x - x_i) + c_i(x-x_i)^2 + d_i(x-x_i)^3 \quad (3.1)$$

Bağların her biri Denklem 3.2.' de belirtildiği gibi verilen y_i veri noktalarından geçmelidir.

$$f_i(x_i) = y_i \text{ ve } f_{n-1}(x_n) = y_n \quad (3.2)$$

Denklem 3.3.'te verildiği gibi, her bir bağ arasında yer alan iç veri noktaları sürekli olmalıdır.

$$f_{i+1}(x_{i+1}) = f_i(x_{i+1}) \quad (3.3)$$

Denklem 3.4. ve Denklem 3.5. ile verildiği gibi, bağlara ait birinci ve ikinci türevler sırasıyla iç veri noktaları üzerinde sürekli olmak zorundadır.

$$f'_{i+1}(x_{i+1}) = f'_i(x_{i+1}) \quad (3.4)$$

$$f''_{i+1}(x_{i+1}) = f''_i(x_{i+1}) \quad (3.5)$$

2 ek sınır koşulu vardır ve sınırlardaki fonksiyonların türeviyle ilgili olarak yerine getirilmesi gerekir $x_0 = a$ ve $x_n = b$. Sırasıyla Denklem 3.6.'da ve Denklem 3.7.'de verilen doğal sınır koşulu ve kenetlenmiş (clamped) sınır koşulu olarak isimlendirilmiştir. D_0 ve D_n, bilinmeyen fonksiyonların birinci türevlerine ait değerlerdir.

$$f''_0(x_0)=f''_{n-1}(x_n)=0 \tag{3.6}$$

$$f'_0(x_0)= D_0 \text{ ve } f'_{n-1}(x_n)= D_n \tag{3.7}$$

Sonuç olarak a_i, b_i, c_i ve d_i katsayılarını bulmak için aşağıdaki adımlar izlenir. İlk adım olarak, i = 0, 1, 2, … , n için $a_i = y_i$ olarak kabul edilir. Daha sonra verilen koşullar için Denklem 3.8. (i=1 için), Denklem 3.9. (i=2, … , n-2 için) ve Denklem 3.10. (i=1, 2, … , n-1 için) kullanılır.

$$(h_0+2h_1)c_1+ (h_1-h_0)c_2=\frac{3}{h_0+h_1}\left[(a_2-a_1)- \frac{h_1}{h_0}(a_1-a_0)\right] \tag{3.8}$$

$$h_{i-1}c_{i-1}+ 2c_i(h_{i-1}+h_1) + h_ic_{i+1}=\frac{3}{h_i}(a_{i+1}-a_i)-\frac{3}{h_{i-1}}(a_i-a_{i-1}) \tag{3.9}$$

$$\frac{3}{h_{n-1}+h_{n-2}}\left[\frac{h_{n-2}}{h_{n-1}}(a_n-a_{n-1})-(a_{n-1}-a_{n-2})\right] \tag{3.10}$$

Dikkat edilmelidir ki i = 1, 2, … , n-1 için $h_i = x_{i+1} - x_i$ olmaktadır. Denklem 3.11., Denklem 3.12., Denklem 3.13. ve Denklem 3.14. ise aşağıdaki gibi verilir.

$$c_0= c_1+\frac{h_0}{h_1}(c_1-c_2) \tag{3.11}$$

$$c_n= c_{n-1}+\frac{h_{n-1}}{h_{n-2}}(c_{n-1}-c_{n-2}) \tag{3.12}$$

$$b_i= \frac{1}{h_i}(a_{i+1}-a_i)-\frac{h_i}{3}(c_{i+1}-2c_i),\ \ i=0, 1, 2, \ldots, n-1 \tag{3.13}$$

$$d_i= \frac{1}{3h_i}(c_{i+1}-c_i),\ \ i=0, 1, 2,\ldots,n-1 \tag{3.14}$$

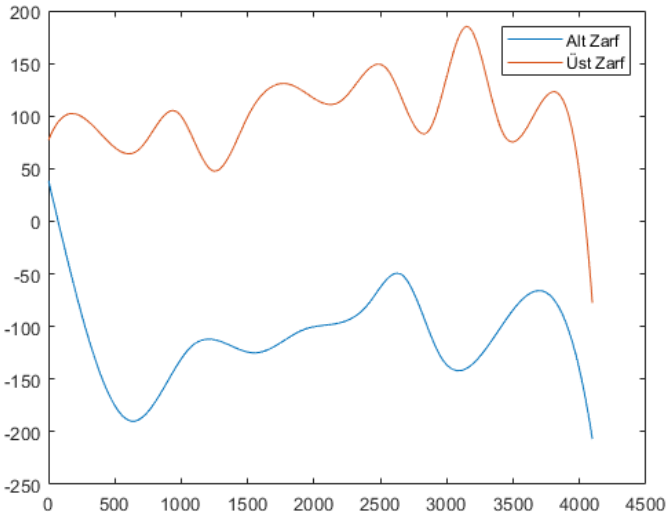
Katsayılar yukarıdaki denklemlerle elde edilebilir (Prasad ve ark., 2018). Denklem 3.1'den Denklem 3.14'e kadar olan denklemler için Congedo ve ark. (2002) tarafından yapılan çalışmaya başvurulabilir. Bu interpolasyon türü kullanılarak alt ve üst zarflar Şekil 3.17.'deki gibi sinyalin uç noktalarından çıkartılır. Bu noktalar

Denklem 3.15. (noktalar i olarak verilmiştir) ile bir mesafe öznitelik vektörü (D) tek bir öznitelik vektörüne dönüştürülür.

$$D_i=|a_i-b_i| \tag{3.15}$$

Denklem 3.15. ile elde edilen öznitelik vektöründeki değerler, Denklem 3.16. ile logaritmik normalizasyon işleminden geçirilir. Burada öznitelik vektöründeki noktaların ikiye bölünmesi tercihidir, farklı bir katsayı seçilebilir.

$$y_i= \ln\frac{D_i}{2} \tag{3.16}$$



Şekil 3.17. Sinyalin alt ve üst zarfları

Sonuç olarak, Denklem 3.16. ile işlemden geçirildikten sonra, veri setindeki her sınıf için 4096 öznitelik (orijinal öznitelik boyutu ile aynı) elde edilmiş olunur. Bu yöntem daha önceki bir çalışmada Kuran ve ark. (2021) tarafından önerilmiştir, Denklem 3.15. ve Denklem 3.16. için de bu çalışmaya bakılabilir.

3.2.3. İstatistiksel öznitelik çıkarımı

Kübik bağ interpolasyonu ile öznitelik çıkartıldıktan sonra ön işleme yapılmış sinyallerden ayrıca istatistiksel öznitelikler de çıkartılmıştır. Çıkartılan öznitelikler maksimum, minimum, medyan, ranj, ortalama ve normdur. Maksimum, sinyaldeki en

büyük, minimum ise sinyaldeki en küçük değerdir. Ranj, maksimum değerden minimum değer çıkartılarak elde edilir. Medyanın formülü Denklem 3.17. ile verilmiştir.

$$\text{Medyan}=\begin{cases}\left(\frac{N+1}{2}\right).\ \text{terim} & ,\ \text{eğer n tek ise}\\ \frac{\left(\frac{N}{2}\right).\ \text{terim}+\left(\frac{N}{2}+1\right).\ \text{terim}}{2} & ,\ \text{eğer n çift ise}\end{cases} \tag{3.17}$$

Denklem 3.17.'de N sinyaldeki sayısal veri (nokta) sayısıdır. Denklem 3.18. ile ortalama formülü verilmiştir. Denklem 3.17. için Zheng ve ark. (2017) tarafından yapılan çalışmaya, Denklem 3.18. için Ahammad ve ark. (2014) tarafından yapılan çalışmaya bakılabilir.

$$\mu=\frac{\sum_{i=1}^{N} X_i}{N} \tag{3.18}$$

Denklem 3.18.'de μ ortalamayı, N sinyaldeki sayısal veri (nokta) sayısını, X_i ise X sinyal olmak üzere sinyaldeki i. noktadaki sayısal değeri ifade eder. Norm, sinyaldeki sayısal değerlerin büyüklüğünü ölçmek için hesaplanmıştır ve formülü Denklem 3.19. ile verilmiştir.

$$||X||=\sqrt{\sum_{i=1}^{N} |X_i|^2} \tag{3.19}$$

Denklem 3.19.'da ||X|| norm değerini, N, sinyaldeki sayısal veri (nokta) sayısını, X_i ise X sinyal olmak üzere sinyaldeki i. noktadaki sayısal değeri ifade eder. Denklem 3.19. için Celebi ve ark. (2011) tarafından yapılan çalışmaya bakılabilir.

3.2.4. Sinyal-gürültü oranının tespiti

SNR, fiziksel sistemlerde yaygın bir ölçüdür. Gürültünün varyansına göre sinyalin varyansıdır. Denklem 3.20. ile verilmiştir.

$$\text{SNR}=\frac{P_s}{P_n} \tag{3.20}$$

Denklem 3.20.'de P_s sinyalin gücü, P_n gürültünün gücüdür. Eklenen tüm bu özniteliklerle birlikte toplam öznitelik vektörü uzunluğu 4103' e yükselmiştir. Denklem 3.20 için Welvaert ve Rosseel (2013) tarafından yapılan çalışmaya bakılabilir.

3.2.5. Önerilen konvolüsyonel sinir ağı modeli ile öznitelik çıkarımı

KSA, klasik YSA mimarisinden farklı bir mimariye sahiptir (LeCun ve Bengio, 1995). KSA'nın ara katmanlarında genelde konvolüsyon katmanları bulunmaktadır. Konvolüsyon için filtre adını verdiğimiz matrisler kullanılmaktadır. Filtreler başlangıçta rastgele değerler alabilir, fakat eğitim aşamasında değerleri ağ tarafından öğrenilerek değiştirilir. Bu sebeple filtreler YSA'da olduğu gibi ağırlık görevi görürler. Filtrelerin boyutları da değişebilmektedir. Boyutlarının yanında, filtreler aynı zamanda dolgu ve kaydırma adımı gibi parametrelerle de çalışır. Öncelikle, iki boyutlu konvolüsyonun ayrık tanımı Denklem 3.21.'de verilmiştir.

$$y[m, n]= x[m, n]* h[m, n]= \sum_{-\infty}^{\infty} \sum_{-\infty}^{\infty} x[i,j]\times h[m-i,n-j] \quad (3.21)$$

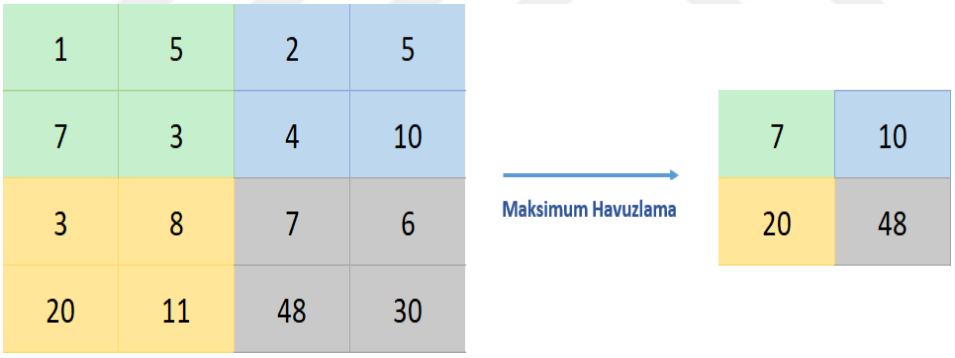
Denklem 3.21.'de y çıktı görüntü, x girdi görüntü, h ilgili filtre, i ve j ilgili filtrenin indisleri, m ve n ise orijinal görüntüye ait olan indislerdir. Denklem 3.21. için Er (2020) tarafından yapılan çalışmaya bakılabilir.

Filtreler yukarıda verilen konvolüsyon formülü kullanılarak görüntüler üzerinden geçirilir. Bunun sonucu olarak görüntülerin morfolojik yapıları değişebilir. Konvolüsyonun amacı görüntüyü bulanıklaştırmak, keskinleştirmek, kenarları tespit etmek vb. işlemler olabilir. Uygulanan filtreler sayesinde öznitelikler elde edilir ve bu öznitelikler ayırt edici olduklarından sınıflandırmada başarılı bir şekilde kullanılabilir. Konvolüsyon katmanları haricinde, KSA birçok katman barındırır. Bu katmanlar aşağıdaki paragraflarda açıklanmıştır.

Tam Bağlı Katman: Bu katman, klasik YSA yapısında bulunan bir katmandır. İleri besleme ve geri besleme fonksiyonları sayesinde hem aktivasyon fonksiyonu aracılığı ile girdileri bir sonraki katmana taşıyabilir, hem de hatayı geriye yayıp azaltabilir. Basit bir ileri besleme denklemi, Denklem 3.22. ile verilebilir. Geri besleme ise katman sayısına ve yapısına göre değişmekle birlikte hatayı belirtir, ayrıca YSA ağırlıklarının güncellenmesini sağlar. Denklem 3.22. ve YSA işleyişi için Yang ve Ma (2019) tarafından yapılan çalışmaya başvurulabilir.

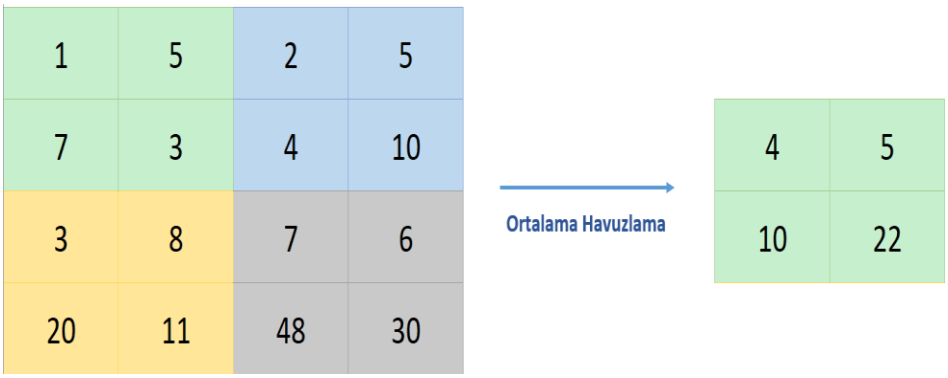
$$z^l = W^l o^{l-1} \tag{3.22}$$

Maksimum Havuzlama Katmanı: Genellikle konvolüsyon işleminin sonucu oldukça büyük bir matris olur. Bu katman, matriste (görüntüde) belli boyuttaki bir pencere ile gezilerek boyutun azaltılmasını sağlar. Görüntü pencerelerle dolaşılarak bu pencere içindeki en büyük değer alınır, böylece konvolüsyon sonucu oluşan matris küçültülür. Maksimum havuzlamanın bir örneği Şekil 3.18. ile verilmiştir.



Şekil 3.18. Maksimum havuzlama tekniği

Ortalama Havuzlama Katmanı: Maksimum havuzlama katmanına benzerdir, fakat en büyük değeri almak yerine penceredeki değerlerin ortalaması alınır. Ortalama havuzlamanın bir örneği Şekil 3.19. ile verilmiştir. Maksimum havuzlama ve ortalama havuzlama ile ilgili olarak Hao ve ark. (2021) tarafından yapılan çalışmaya bakılabilir.



Şekil 3.19. Ortalama havuzlama tekniği

DLB Katmanı: Ağın yapısındaki lineerliği azaltır; doğrusal olmayan bir yapı kazandırır. Denklem 3.23. ile verilen DLB aktivasyon fonksiyonu bu katmanda kullanılır, x burada fonksiyona gelen girdidir. Denklem 3.23. için Jiang ve ark. (2018) tarafından yapılan çalışmaya bakılabilir.

$$DLB(x)=maksimum(0,x) \tag{3.23}$$

Bırakma Katmanı: Nöronların bir kısmını pasifize ederek ağın farklı türde örneklere karşı daha iyi bir sınıflandırıcı olmasını sağlar. Böylece model bir veri setini ezberleyip kendini sadece o veri setine göre ayarlamamış olur. Bırakma katmanı hakkında Krizhevsky ve ark. (2017) tarafından yapılan çalışmaya başvurulabilir.

Aktivasyon Fonksiyonu: Aktivasyon fonksiyonu, katmanın çıktılarını alarak bir nöronun aktif edilip edilmeyeceğini belirler. Yani nöronun ağdaki rolünü ve önemini belirler. Birçok aktivasyon fonksiyonu mevcuttur, bu çalışmada Denklem 3.24. ile verilen sigmoid aktivasyon fonksiyonu kullanılmıştır, bu fonksiyonda x fonksiyona gelen girdidir. Sigmoid fonksiyonu için Marreiros ve ark. (2008) tarafından yapılan çalışmaya bakılabilir.

$$\sigma(x)=\frac{1}{1+e^{-x}} \tag{3.24}$$

Kayıp Fonksiyonu: Ağın kendisini belli bir kayıp fonksiyonuna göre optimize etmesi sağlanır. Böylece modelin kayıp fonksiyonuna göre ne kadar iyi tahminde bulunup bulunmadığı anlaşılabilir. Bu çalışmada, Denklem 3.25. ile verilen İÇE kullanılmıştır. Denklem 3.25.'de L kayıp, $p(y_i)$ ise y_i tahmininin gerçekleşme olasılığıdır. Denklem 3.25. ve İÇE için Bai ve ark. (2022) tarafından yapılan çalışmaya başvurulabilir.

$$L=-\frac{1}{\text{çıktı boyutu}}\sum_{i=1}^{\text{çıktı boyutu}} y_i \times \log\left(p(y_i)\right)+(1-y_i)\times\log(1-p(y_i)) \quad (3.25)$$

Bu çalışmada, bir boyutlu bir KSA kullanılmıştır ve konvolüsyon katmanı özelleştirilerek KSA için başarı oranı artırılmaya çalışılmıştır. Bir boyutlu KSA, iki boyutta ve üç boyutta işlem yapan KSA' dan farklı olarak, tüm işlemleri bir boyutta yapar. Bu sebeple EEG sinyallerinin bir boyutlu yapısına daha uygundur ve daha anlamlı öznitelikler, bir boyutlu KSA ile çıkartılabilir. Bir boyutlu konvolüsyon Denklem 3.26.'daki gibi verilebilir. Denklem 3.26.'da x girdi sinyal, h ilgili filtre, i ilgili filtrenin indisi, n ise sinyale ait olan indistir.

$$y[n]= x[n]* h[n]= \sum_{-\infty}^{\infty} x[i]\times h[n-i] \quad (3.26)$$

Maksimum havuzlama vb. birçok işlem de tek boyutlu olarak yapılır. Bir boyutta maksimum havuzlama Şekil 3.20.'de verilmiştir.



Şekil 3.20. Bir boyutta maksimum havuzlama tekniği

Denklem 3.26. için Pan ve ark. (2018) tarafından yapılan çalışmaya ve bir boyutlu KSA yapısındaki işlemler için Cheikhrouhou ve ark. (2021) tarafından yapılan çalışmaya başvurulabilir. Literatürde otokorelasyon birçok çalışmada kullanılmıştır (Hayashi ve Uchida 2019; Liu ve ark., 2021). Bir sinyalin otokorelasyonu, o sinyalin bir gecikme fonksiyonuyla geciktirilmiş halidir. Bu durumda, sinyalin birden fazla durumdaki halleri göz önünde bulundurularak, zamandan bağımsız olan daha çok genelleştirilmiş bir model oluşturulabilir. Bu durumdan hareketle, konvolüsyon katmanında otokorelasyon özelliği kullanılarak daha anlamlı öznitelikler çıkartılması hedeflenmiştir. Otokorelasyon için genel bir formül Denklem 3.27.'deki gibi verilebilir. Denklem 3.27. için Ping ve ark. (2004) tarafından yapılan çalışmaya bakılabilir.

$$r_k= \frac{\sum_{t=k+1}^{n}(y_1-\bar{y})(y_{t-k}-\bar{y})}{\sum_{t=1}^{n}(y_t-\bar{y})^2} \quad (3.27)$$

Denklem 3.27.'de r_k, k gecikmesine sahip otokorelasyonu alınmış sinyaldir. Konvolüsyon katmanında konvolüsyon işlemi uygulanmadan hemen öncesinde, sinyallere otokorelasyon işlemi uygulanarak, sinyallerin zamanda geciktirilmiş versiyonları elde edilir. Otokorelasyon ile özelleştirilmiş katmanların haricinde, farklı katmanlar da KSA mimarisine dahil edilerek ağın daha karmaşık problemlere karşı başarısı artırılmak istenmiştir. Çizelge 3.2'de KSA mimarisine dahil olan katmanlar sırasıyla verilmiştir. Her katmana kendine özgü bir etiket (isim) verilmiştir. Çizelge 3.3.'de ise KSA mimarisindeki katmanlara ait çıktı boyutları verilmiştir. Çizelge 3.3.'de parantezin içindeki ikinci değer filtre sayısını gösterir.

Çizelge 3.2. Önerilen KSA mimarisi

Katman türü	Katman Etiketi	Katman Sırası
1 Boyutlu Konvolüsyon Katmanı	1BKonvolüsyon1	1
1 Boyutlu Maksimum Havuzlama Katmanı	1BMH1	2
Otokorelasyonlu 1 Boyutlu Konvolüsyon Katmanı	1BKonvolüsyonOT1	3
1 Boyutlu Maksimum Havuzlama Katmanı	1BMH2	4
1 Boyutlu Konvolüsyon Katmanı	1BKonvolüsyon2	5
1 Boyutlu Maksimum Havuzlama Katmanı	1BMH3	6
1 Boyutlu Konvolüsyon Katmanı	1BKonvolüsyon3	7
1 Boyutlu Ortalama Havuzlama Katmanı	1BAH1	8
Bırakma Katmanı	DO1	9
Tam Bağlı Katman	TB1	10

Çizelge 3.3. Önerilen KSA mimarisine ait çıktı boyutları

Katman Etiketi	Çıktı Boyutu

Çizelge 3.3. **(devam)**

1BKonvolüsyon1	(4088, 64)
1BMH1	(2044, 64)
1BKonvolüsyonOT1	(2040, 124)
1BMH2	(1020, 124)
1BKonvolüsyon2	(203, 256)
1BMH3	(101, 256)
1BKonvolüsyon3	(19, 512)
1BAH1	512
DO1	512
TB1	1

KSA kullanılarak toplamda 1BKonvolüsyon3 etiketli katmandan 19 adet öznitelik çıkartılmış ve toplam öznitelik sayısı 4122'ye yükselmiştir.

3.2.6. Sınıflandırma

Sınıflandırma amaçlı üç sınıflandırıcı kullanılmıştır: DVM, KNN ve KA. Bu bölümün alt bölümlerinde, ilgili sınıflandırıcılar açıklanacaktır.

3.2.6.1. K-en yakın komşular

Makine öğrenmesi alanında, KNN yaygın olarak kullanılan bir algoritmadır. KNN, Fix ve Hodges (1989) tarafından öne sürülmüş ve Altman (1992) tarafından genişletilmiştir. Sınıflandırma için, girdi K-en yakın eğitim örneklerini içerir. Buna göre, sınıflandırmanın çıktısı sınıf etiketidir. Örnekler k en yakın komşularına göre sınıflandırılır, burada k, bir sınıflandırma problemi için sınıf sayısıdır. KNN, verilerden ayırt edici bir işlev oluşturmaz, bunun yerine verileri ezberler. Bir tahminin yapılması gerektiğinde, KNN eğitim verilerinde en yakın komşuları arar. Yeni tahmin için en yakın komşuların kararlarına bağlıdır. KNN algoritmasının çalışma mantığı bu bölümde adım adım verilecektir.

Adım 1: KNN algoritması için k parametresi seçilir. Bu parametre değerlendirilecek komşu sayısını belirler.

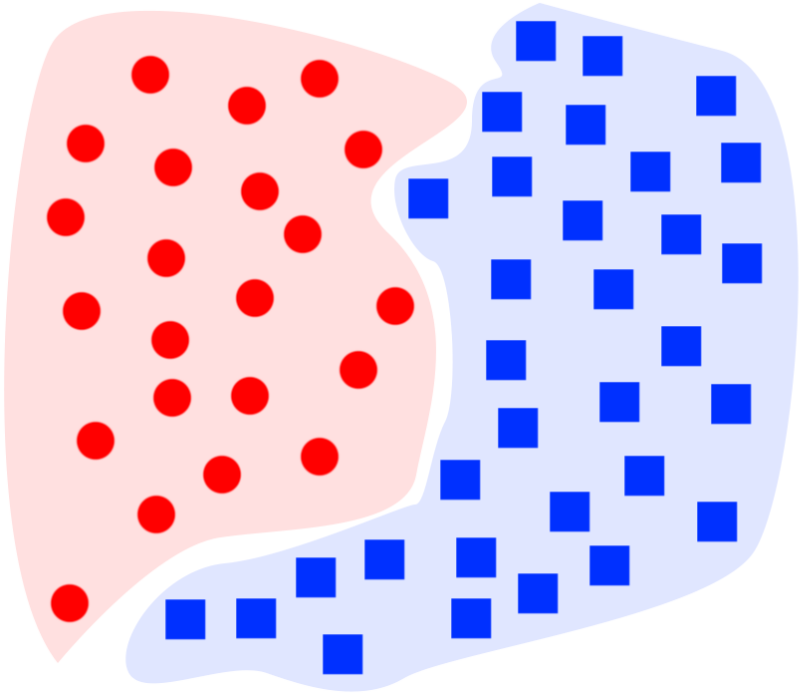
Adım 2: Komşuların mesafeleri Öklid mesafesi ile Denklem 3.28.'de verildiği gibi hesaplanır, denklemde d mesafeyi, p ve q örnekleri, i ise örneklerin ilgili boyuttaki elemanının indisini gösterir. Denklem 3.28. için Elen ve Avuçlu (2021) tarafından yapılan çalışmaya başvurulabilir.

$$d(p,q)=\sqrt{\sum_{i=1}^{n}(q_i-p_i)^2} \tag{3.28}$$

Adım 3: Mesafeleri hesaplanan k kadar komşudan, her kategorideki örneklerin sayısı belirlenir.

Yeni bir örnek geldiğinde ilgili kategorilerden k kadar komşu sayısı en fazla olan kategoriye atama yapılır. Model bu şekilde hazır hale gelmiş olur.

KNN, özellikle gürültü verilerde etkili olan bir algoritmadır. Ayrıca büyük veri setleri için de tercih edilebilmektedir. Örnek bir kümeleme Şekil 3.21.'de gösterilmiştir.



Şekil 3.21. Örnek bir kümeleme: mavi kareler ve kırmızı daireler farklı sınıfları temsil etmekte

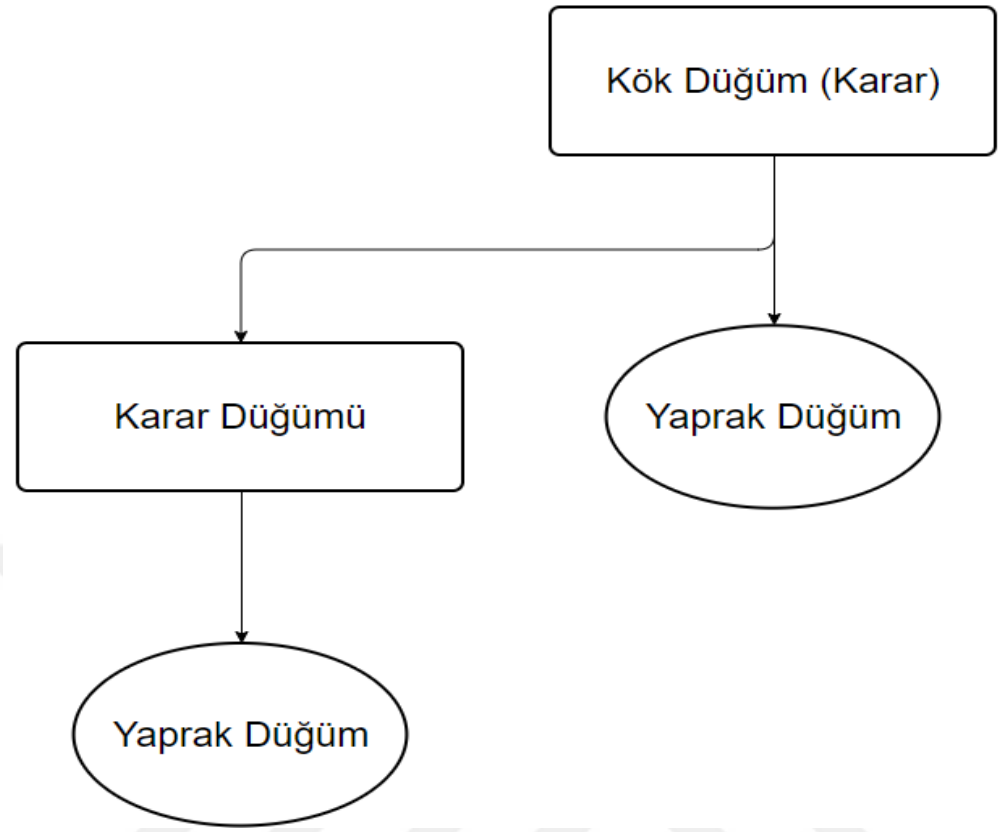
3.2.6.2. Karar ağaçları

KA sınıflandırıcı, veri kümesi benzerliğini kontrol eder ve sınıfları atar. Kararları kökten yaprak düğümüne kadar takip eder. Nitelikler farklı dallara bölünmüştür. Yaprak düğümü uygun yanıtı içerir ve bir sınıflandırma ağacı için bu yanıtlar nominaldir, doğru veya yanlış olabilir. Bundan dolayı ağaç yapısında tasarlanır.

Örnek bir KA yapısı Şekil 3.22.'de gösterilmiştir. Kök düğüm karar ağacının başladığı düğümdür ve tüm veri setini temsil eder, alt ağaçlara ayrılabilir. Yaprak düğümler son çıktıları ifade eder. Oluşan alt karar düğümleri alt ağaçlara ait olur, bir düğümün üst düğümü ebeveyn düğüm olarak bilinir. Alt düğümü ise çocuk düğüm olarak bilinir. Bölünmeler çeşitli şartlara göre yapılır. Bu çalışmada Gini endeksi kullanılmıştır. Gini endeksi saflığın ölçütüdür, bir özniteliğin ne gibi bir olasılıkla rastgele bir şekilde yanlış sınıflandırılmış olabileceğini ölçer. Gini endeksi Denklem 3.29. ile verilmiştir.

$$I_G = 1 - \sum_{i=1}^{L} (p_i)^2 \quad (3.29)$$

Denklemde I_G Gini endeksi, L sınıf etiketi sayısı, p_i ise i. sınıfın mevcut olasılığıdır (oranıdır). Denklem 3.29. için Tangirala (2020) tarafından yapılan çalışmaya bakılabilir.

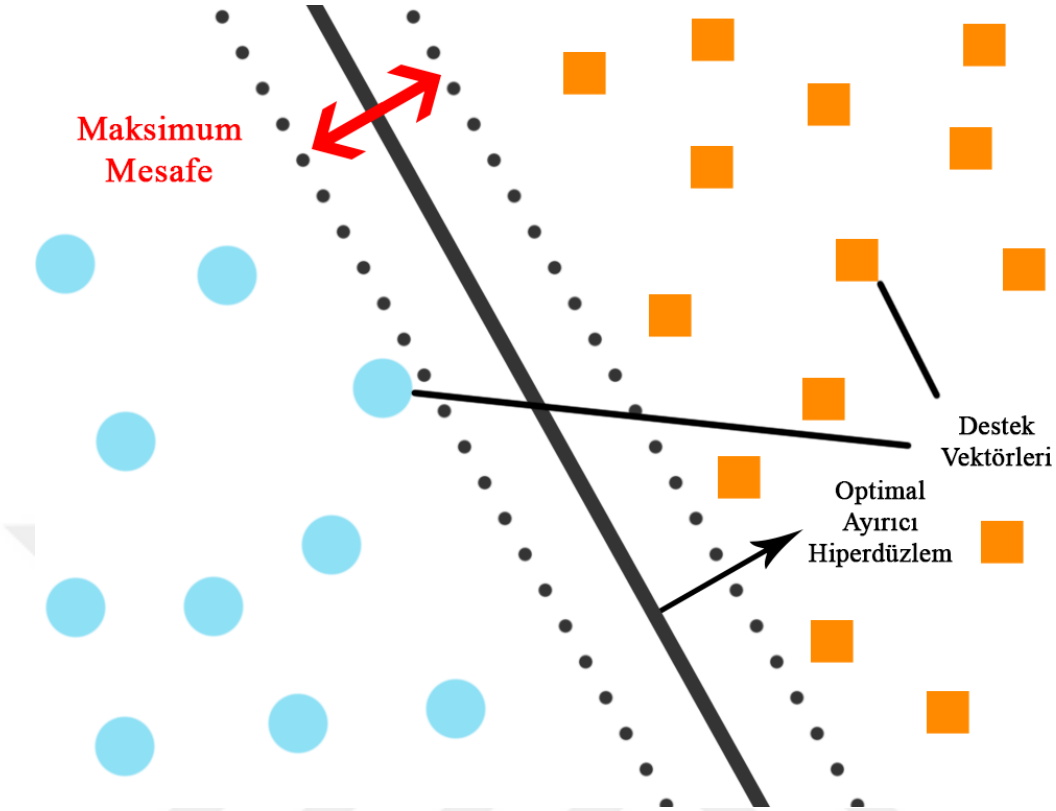


Şekil 3.22. Örnek bir karar ağacı

Bu çalışmada, nitelikler için 20'den fazla bölünmeye izin vermeyen KA kullanılmıştır. Bölünme sayısı, verilerin değerlendirilmesini etkileyen KA için bir parametredir. DT tıbbi, ekonomik veya diğer bilimsel problemlerde kullanılmaktadır (Rissanen, 1996).

3.2.6.3. Destek vektör makineleri

DVM, Cortes ve Vapnik (1995) tarafından geliştirilen sınıflandırma veya regresyon amaçlı kullanılabilen bir gözetmenli öğrenme algoritmasıdır. DVM, kendisine verilecek olan yeni veri için doğru sınıfı belirlemek amacıyla n-boyutlu uzayı sınıflara ayırabilen en iyi karar sınırını oluşturmaya çalışır. Bu sınıra hiper düzlem adı da verilir. Hiper düzlemi oluşturmak için destek vektörleri seçilir, bu vektörler uç noktalar olarak da bilinir. Örnek bir DVM şeması aşağıdaki Şekil 3.23.'de verilmiştir. DVM farklı türlere ayrılır.



Şekil 3.23. Örnek bir destek vektör makinesi

Doğrusal DVM: Doğrusal DVM, doğrusal olarak ayrılabilir veriler için kullanılır, bir veri seti doğrusal olarak iki sınıfa ayrılabiliyorsa, bu tür veri setleri doğrusal olarak ayrılabilir olmaktadır, Doğrusal DVM bu verileri sınıflandırabilir.

Doğrusal Olmayan DVM: Doğrusal olmayan DVM, doğrusal olmayan ayrılmış veriler için kullanılır, yani bir veri kümesi düz bir çizgi kullanılarak sınıflandırılamıyorsa, doğrusal olmayan DVM kullanılabilir.

Doğrusal olmayan DVM sınıflandırıcıları çekirdek (kernel) adı verilen bir yöntem kullanılarak yapılır. Çekirdek sayesinde girdi uzayı daha yüksek boyutta bir uzayla ilişkilendirilir, x girdi uzayından Φ (x) öznitelik uzayına geçiş yapılabilir. Öznitelik uzayında lineer olan model, girdi uzayında lineer değilmiş gibi davranmış olur. Bu çalışmada kullanılan çekirdekler Denklem 3.30. ile verilen lineer çekirdek, Denklem 3.31. ile verilen kuadratik çekirdek ve Denklem 3.32. ile verilen kübik

çekirdektir. Denklem 3.30., Denklem 3.31. ve Denklem 3.32. için (lineer ve polinomsal çekirdekler) Er (2020) tarafından yapılan çalışmaya bakılabilir.

$$K(a,b)=\left(1+\sum_j a_j b_j\right) \tag{3.30}$$

$$K(a,b)=\left(1+\sum_j a_j b_j\right)^2 \tag{3.31}$$

$$K(a,b)=\left(1+\sum_j a_j b_j\right)^3 \tag{3.32}$$

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

4.1. Değerlendirme Ölçütleri

Sonuçları değerlendirmek ve sınıflandırıcıların performansını karşılaştırmak için bu çalışmada kullanılan bazı değerlendirme ölçütleri bu bölümde verilmiştir. Doğruluk, kesinlik, özgüllük ve hassaslık bu amaç için kullanılan ölçütlerdir ve bu ölçütlerin formülleri sırasıyla Denklem 4.1., Denklem 4.2., Denklem 4.3. ve Denklem 4.4. ile verilmiştir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \tag{4.1}$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \tag{4.2}$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \tag{4.3}$$

$$\text{Hassaslık} = \frac{TP}{TP+FN} \tag{4.4}$$

Denklem 4.1., Denklem 4.2., Denklem 4.3. ve Denklem 4.4. ile verilen formüllerde TP'nin gerçek pozitif olduğu, TN'nin gerçek negatif olduğu, FP'nin yanlış pozitif olduğu ve FN'nin yanlış negatif olduğu kabul edilmektedir ve bu denklemler için Maeda-Gutiérrez ve ark. (2020) tarafından yapılan çalışmaya başvurulabilir.

4.2. Deneysel Sonuçlar

Önerilen yöntemin deneysel uygulaması Intel (R) Core (TM) i7-6500U 2.50Ghz işlemci, 8GB bellek ve Intel HD Graphics 520 grafik kartına sahip bir bilgisayar ile yapılmıştır. Kaynak kodu Python ile yazılmıştır. Python dili için geliştirilen TensorFlow ve NumPy kütüphaneleri kullanılmıştır. İstatistiksel, zaman alanı ve zarf özniteliklerinden oluşan bir hibrit öznitelik vektörü hazırlanarak sınıflandırma için etiketlenmiştir.

5 farklı sınıflandırma veri kümesi hazırlanmıştır. Daha kesin olmak gerekirse, hazırlanan setler farklı sınıflardan karıştırılmıştır. İlk veri kümesi A-E'dir, burada A gözleri açık sağlıklı denekler kümesidir ve E epileptik nöbeti olan denekler kümesidir (A'ya karşı E). İkinci veri kümesi AB-E'dir, burada B, B'ye ait olan konuların kapalı gözlerle olması bakımından A'dan farklıdır. Dolayısıyla, A ve B bir sınıf ve E başka bir sınıftır (AB'ye karşı E). Üçüncü veri kümesi, ABCD'nin sağlıklı deneklerden ve nöbetsiz epileptik deneklerden oluştuğu ve E'nin epileptik nöbeti olan denekleri (ABCD'ye karşı E) içerdiği ABCD-E'dir. Dördüncü veri kümesi C-E'dir, burada nöbetsiz epilepsi hastaları, hipokampüs elektrotların hemisferin karşısına yerleştirilmiş olup nöbet geçiren deneklere karşıdır (C'ye karşı E). Beşinci veri kümesi, dördüncü veri kümesi ile karşılaştırıldığında (CD'ye karşı E) deneklerin epileptojenik bölgesine elektrotlar yerleştirilerek nöbetsiz deneklerden alınan D setindeki örnekleri ek olarak içeren CD-E'dir. Farklı sınıflandırma görevleri için hazırlanan veri kümelerine genel bir bakış Çizelge 4.1.'de verilmiştir.

Çizelge 4.1. Oluşturulan sınıflandırma veri kümeleri

	A-E	AB-E	ABCD-E	C-E	CD-E
Denek tipleri	Sağlıklı-epileptik nöbetleri olan	Sağlıklı-epileptik nöbetli epilepsi	Sağlıklı ya da nöbetsiz epilepsi- nöbetli epilepsi	Nöbetsiz epilepsi-nöbetli epilepsi	Nöbetsiz epilepsi vs nöbetli epilepsi
Birinci sınıftaki denek sayısı-ikinci sınıftaki denek sayısı	100-100	200-100	400-100	100-100	200-100

Lineer DVM, Kuadratik DVM, Kübik DVM, Hassas KNN, Orta KNN, Kaba KNN ve Orta KA bu çalışmada kullanılan sınıflandırıcılardır. Eğitim aşaması ve test aşaması için verileri ayırmak amacıyla, 10 katlamalı çapraz doğrulama kullanılmıştır. Önerilen yöntemin sınıflandırma performansı değerlendirilmiştir ve Çizelge 4.2., Çizelge 4.3., Çizelge 4.4., Çizelge 4.5. ve Çizelge 4.6.'daki Bonn EEG veri setinden örnekler içeren her set için doğruluk, kesinlik, özgüllük ve duyarlılığa dayalı olarak karşılaştırılmıştır.

A-E seti için en iyi sınıflandırma sonucu, %99.50 doğruluk oranına ulaşan Lineer DVM, Kuadratik DVM, Kübik DVM, KNN ve KA kullanılarak elde edildi. AB-E seti için en iyi sınıflandırma sonucu, %99.67 doğruluk oranına ulaşan Lineer DVM, Kuadratik DVM, Kübik DVM ve KA ile elde edildi. ABCD-E seti için en iyi sınıflandırma sonucu, %99.60 doğruluk oranına ulaşan Lineer DVM, Kuadratik DVM ve Kübik DVM kullanılarak elde edilir. C-E seti için en iyi sınıflandırma sonucu, %99.00 doğruluk oranına ulaşan Lineer DVM, Kuadratik DVM, Kübik DVM, KNN ve KA kullanılarak elde edildi. CD-E seti için en iyi sınıflandırma sonucuna Lineer DVM, Kuadratik DVM ve Kübik DVM %99.33 ile ulaşılmıştır. Şekil 4.1 ile tüm sınıflar içinde en iyi sınıflandırma sonucuna sahip olan AB-E sınıfının karmaşıklık matrisi, Şekil 4.2 ile A-E sınıfı için sınıflandırma sonuçları, Şekil 4.3 ile AB-E için sınıflandırma sonuçları, Şekil 4.4 ile ABCD-E için sınıflandırma sonuçları, Şekil 4.5 ile C-E için sınıflandırma sonuçları ve Şekil 4.6 ile CD-E için sınıflandırma sonuçları verilmiştir.

Çizelge 4.2. A-E için sınıflandırma sonuçları

Modeller	Doğruluk %	Kesinlik %	Özgüllük %	Hassaslık %
Lineer DVM	99.50	100.00	100.00	99.00
Kuadratik DVM	99.50	100.00	100.00	99.00
Kübik DVM	99.50	100.00	100.00	99.00
KNN	99.50	100.00	100.00	99.00
KA	99.50	100.00	100.00	99.00

Çizelge 4.3. AB-E için sınıflandırma sonuçları

Modeller	Doğruluk %	Kesinlik %	Özgüllük %	Hassaslık %
Lineer DVM	99.67	100.00	100.00	99.00
Kuadratik DVM	99.67	100.00	100.00	99.00
Kübik DVM	99.67	100.00	100.00	99.00

Çizelge 4.3. **(devam)**

KNN	99.00	100.00	100.00	99.00
KA	99.67	100.00	100.00	99.00

Çizelge 4.4. ABCD-E için sınıflandırma sonuçları

Modeller	Doğruluk %	Kesinlik %	Özgüllük %	Hassaslık %
Lineer DVM	99.60	99.75	99.00	99.75
Kuadratik DVM	99.60	99.75	99.00	99.75
Kübik DVM	99.60	99.75	99.00	99.75
KNN	99.40	99.50	98.00	99.75
KA	99.20	99.50	98.00	99.50

Çizelge 4.5. C-E için sınıflandırma sonuçları

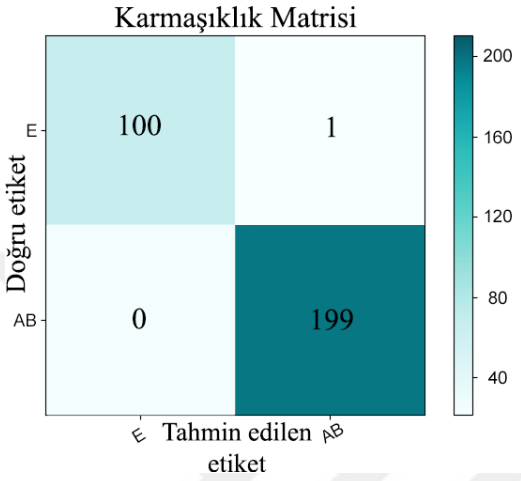
Modeller	Doğruluk %	Kesinlik %	Özgüllük %	Hassaslık %
Lineer DVM	99.00	99.00	99.00	99.00
Kuadratik DVM	99.00	99.00	99.00	99.00
Kübik DVM	99.00	99.00	99.00	99.00
KNN	99.00	99.00	99.00	99.00
KA	99.00	99.00	99.00	99.00

Çizelge 4.6. CD-E için sınıflandırma sonuçları

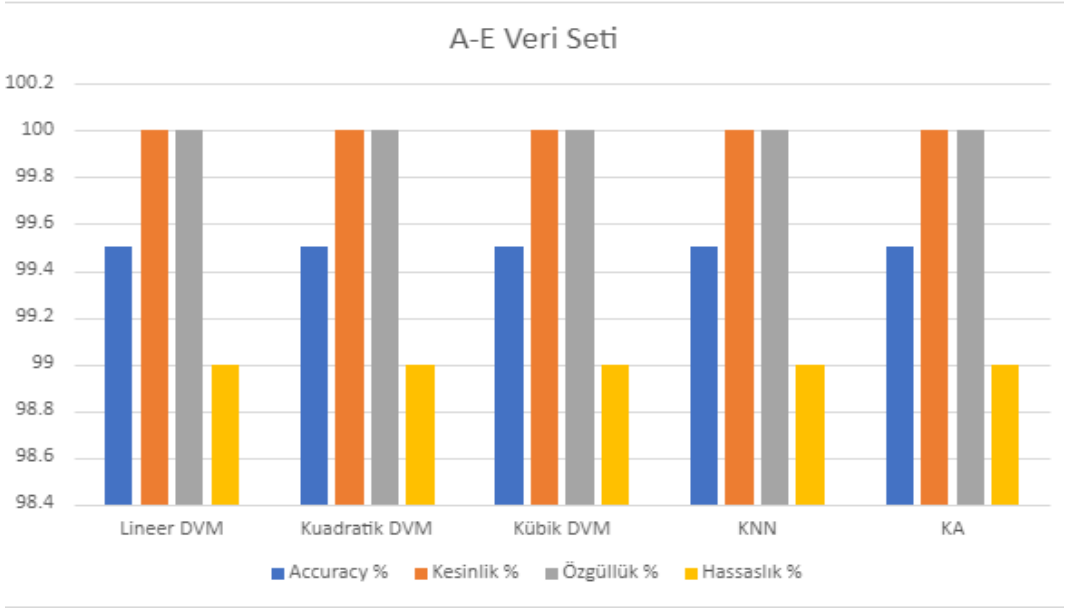
Modeller	Doğruluk %	Kesinlik %	Özgüllük %	Hassaslık %
Lineer DVM	99.33	99.50	99.00	99.50
Kuadratik DVM	99.33	99.50	99.00	99.50
Kübik DVM	99.33	99.50	99.00	99.50
KNN	99.00	99.00	98.00	99.50

Çizelge 4.6. **(devam)**

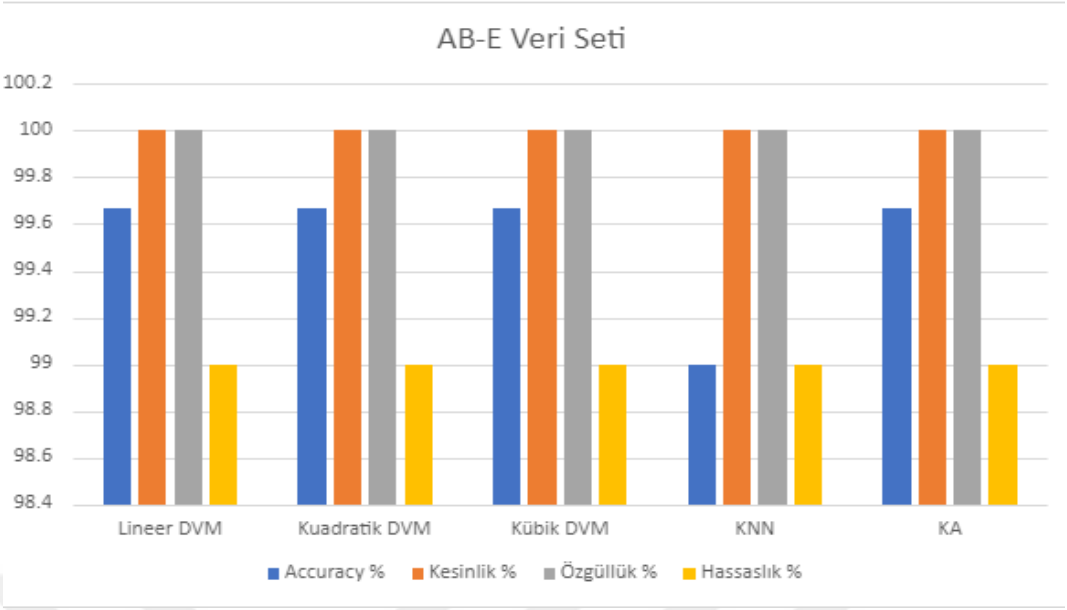
KA	98.67	99.00	98.00	99.00



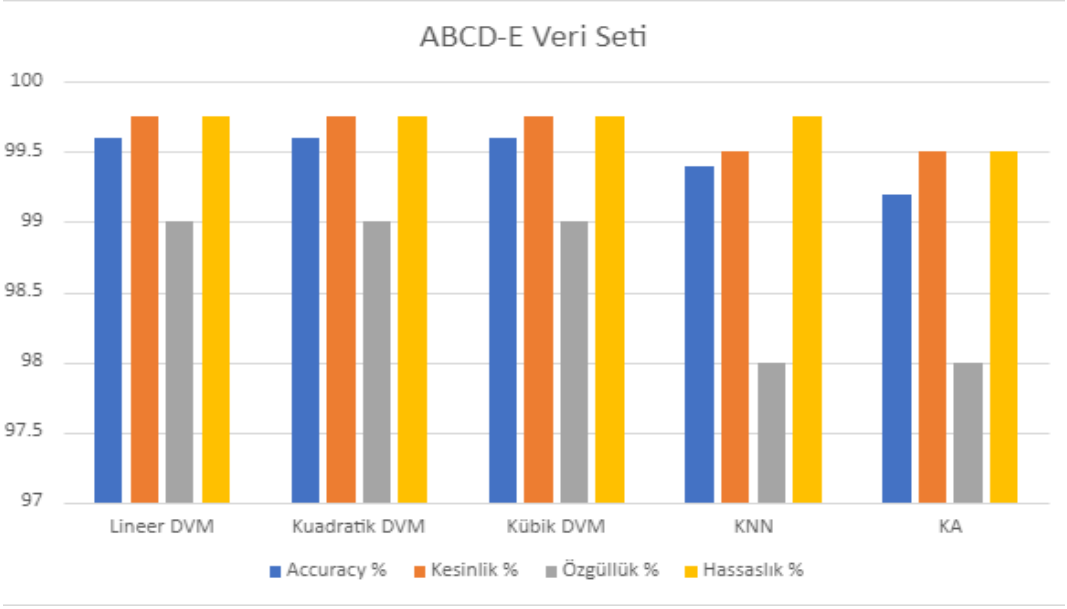
Şekil 4.1. AB-E sınıfı için karmaşıklık matrisi



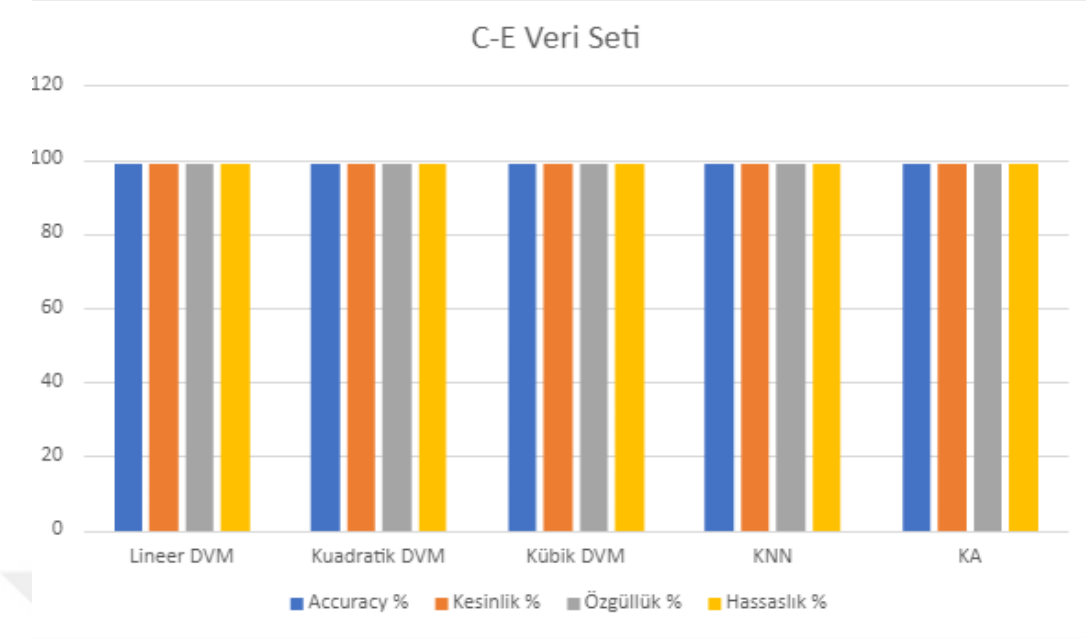
Şekil 4.2. A-E için sınıflandırma sonuçları



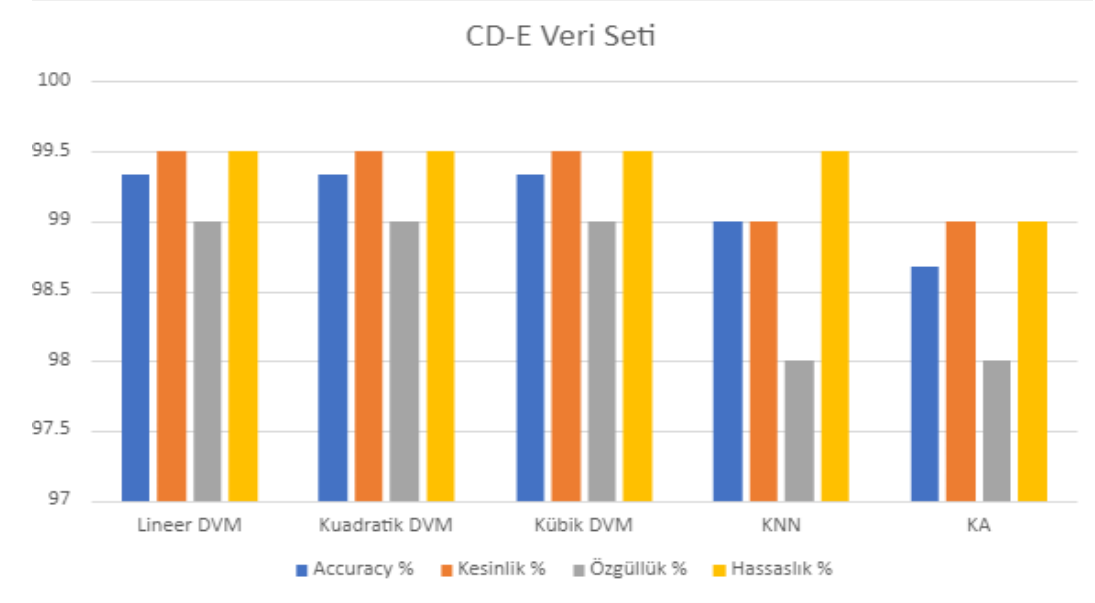
Şekil 4.3. AB-E için sınıflandırma sonuçları



Şekil 4.4. ABCD-E için sınıflandırma sonuçları



Şekil 4.5. C-E için sınıflandırma sonuçları



Şekil 4.6. CD-E için sınıflandırma sonuçları

Araştırmacılar tarafından, epilepsi tespiti için Bonn EEG veri seti üzerinde birçok teknik kullanılmıştır. Çizelge 4.7.'de güncel farklı yaklaşımlar, en yüksek doğruluk sonucunu veren kümeler ve yazarlar verilmiştir. Sonuçlar, bu çalışmada önerilen yöntemin literatürde önerilen son teknoloji yöntemlerin çoğunu başarı açısından geçtiğini göstermektedir. Liu ve Fu (2020) tarafından yapılan çalışmada,

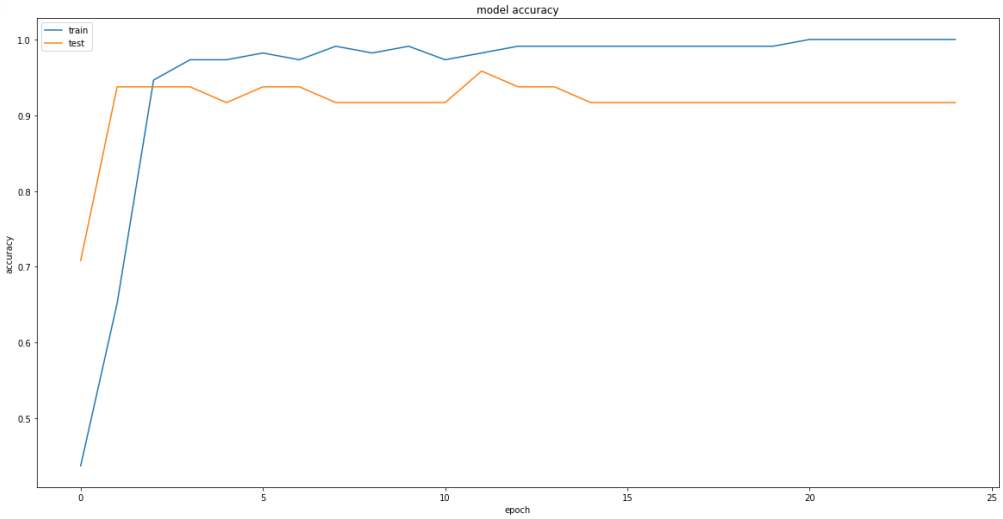
koşullu entropi ile A-E için %95.00 doğruluk oranına ulaşılmıştır. Raghu ve ark. (2019) tarafından yapılan çalışmada, YSA ve matris determinantı öznitelikleri birlikte A-E seti üzerinde kullanılmıştır ve %99.45 doğruluk oranına ulaşılmıştır, ayrıca ABCD-E seti için %97.20 doğruluk oranı elde edilmiştir. Mamli ve Kalbkhani (2019) tarafından yapılan çalışmada, FSSD ve GSBOM, DVM ile birlikte kullanılarak, A-E seti için %100.00 doğruluk oranı, ABCD-E seti için %97.38 doğruluk oranı elde edilmiştir. Yalçın ve ark. (2015) YSA ve PSO algoritmalarını birlikte kullanılarak A-E seti için %99.67 doğruluk oranı elde edilmiştir. Wu ve ark. (2020) TTAMA-AGA yöntemi ile ABCD-E seti için %99.60, A-E seti için ise %100.00 doğruluk oranları elde etmişlerdir. TTAMA yöntemini ayırma amacıyla, AGA yöntemini ise modeli oluşturmak amacıyla kullanmışlardır. Tablodan da görüldüğü üzere, önerilen yöntem, diğer birçok yöntemle rekabet halinde veya daha iyi durumdadır.

Çizelge 4.7. Önceki çalışmalarla karşılaştırma

Yazar(lar)	Yöntem	Kullanılan Setler	Doğruluk %
Liu ve Fu (2020)	Sıralı örüntülerin ve DVM' in koşullu entropisi	A-E	95.00
Raghu ve ark. (2019)	YSA + Matris Determinantı Öznitelikleri	A-E	99.45
Raghu ve ark. (2019)	YSA + Matris Determinantı Öznitelikleri	ABCD-E	97.20
Mamli ve Kalbkhani (2019)	FSSD + GSBOM+ DVM	A-E	100.00
Mamli ve Kalbkhani (2019)	FSSD + GSBOM + DVM	ABCD-E	97.38
Yalçın ve ark. (2015)	YSA ve PSO	A-E	99.67
Wu ve ark. (2020)	TTAMA-AGA	A-E	100.00
Wu ve ark. (2020)	TTAMA-AGA	ABCD-E	99.60
Bizim Çalışmamız	Önerilen Yöntem	A-E	99.50
Bizim Çalışmamız	Önerilen Yöntem	AB-E	99.67
Bizim Çalışmamız	Önerilen Yöntem	ABCD-E	99.60
Bizim Çalışmamız	Önerilen Yöntem	C-E	99.00
Bizim Çalışmamız	Önerilen Yöntem	CD-E	99.33

4.3. Konvolüsyonel Sinir Ağının Tek Başına Performansının Değerlendirilmesi

Bu bölümde, hibrit öznitelik vektörü oluşturmanın gerekli olduğunu göstermek amacıyla önerilen KSA modelinin performans analizi yapılmıştır. EEG sinyalleri sınıflandırılmış, test doğruluk oranları, A-E seti için %95.83, AB-E seti için %98.62 ABCD-E seti için %97.50, C-E seti için %97.92, CD-E seti için %93.06 olarak elde edilmiştir. En iyi sınıflandırma sonucu AB-E için elde edilmiştir, fakat Şekil 4.7.'de eğitim ve test doğruluk eğrilerinden görüldüğü üzere modelin veriyi ezberlemesi söz konusu olabilmektedir ve tek başına yeterli değildir.



Şekil 4.7. AB-E için eğitim (mavi) ve test (turuncu) doğruluk eğrileri

5. SONUÇLAR ve ÖNERİLER

Bu çalışmada, yeni bir öznitelik çıkarma ile kübik bağ interpolasyonuna dayalı bir yöntem önerilmiştir. Önerilen yöntem, literatürde yaygın olarak kullanılan Bonn EEG veri kümesi kullanılarak değerlendirilmiştir. Yöntem üç aşamadan oluşmaktadır. İlk aşamada ön işlem yapılır. Ardından, üst ve alt zarflar, sinyalin tepe noktaları için kübik bağ interpolasyonu kullanılarak çıkarılır. İkinci aşamada, özniteliklerin çıkarılması ve genelleme için zarflar üzerinde aritmetik işlemler yapılır. Ardından, bu öznitelik vektörleri, KSA ile elde edilen öznitelikler, önceden işlenmiş ham sinyalden elde edilen istatistiksel öznitelikler ve zaman alanı öznitelikleriyle birleştirilir. Üçüncü aşamada, Lineer DVM, Kuadratik DVM, Kübik DVM, KNN ve KA bu hibrit öznitelik vektörünü sınıflandırmak için kullanılmıştır. A-E seti için, %99.50 doğruluk oranına ulaşılmıştır. AB-E seti için, KNN hariç tüm sınıflandırıcılar %99.67 doğruluk oranına ulaşılmıştır. ABCD-E ve C-E setleri için, ulaşılan en iyi doğruluk oranları %99.60 ve %99.00'dur. En yüksek doğruluk oranlarına DVM sınıflandırıcıların sahip olduğu ABCD-E seti için gözlemlenebilmektedir. CD-E seti için, en yüksek doğruluk oranı %99.33'dür. Sonuçlar, DVM sınıflandırıcılarının en başarılı sınıflandırıcılar olduğunu göstermektedir. Deneysel sonuçlar göstermektedir ki, daha ileri düzeydeki araştırmalar için, sınıflandırma doğruluğunu artırmak için istatistiksel özniteliklerle birlikte sinyal ayrıştırma tekniklerinin de kullanılması önerilebilir. Yöntem her ne kadar çok fazla öznitelik sınıflandırıldığından dolayı maliyete sebep olsa da, güvenilirlik açısından yüksek doğruluk oranlarına sahiptir ve epileptik nöbet tespiti için kullanılabilir.

KAYNAKLAR

Ahammad, N., Fathima, T., and Joseph, P. 2014. Detection of Epileptic Seizure Event and Onset Using EEG. BioMed Research International, 2014: 1–7.

Ahammed, K. and Ahmed, M. U. 2020. Epileptic Seizure Detection Based on Complexity Feature of EEG. Journal of Biomedical Analytics, 3(1): 1–11.

Ahmadi, N., Pei, Y., Carrette, E., Aldenkamp, A. P., and Pechenizkiy, M. 2020. EEG-based classification of epilepsy and PNES: EEG microstate and functional brain network features. Brain informatics, 7(1): 6.

Akyol, K. 2020. Stacking ensemble based deep neural networks modeling for effective epileptic seizure detection. Expert Systems with Applications, 148: 113239.

Al-Nafjan, A., Hosny, M., Al-Wabil, A., and Al-Ohali, Y. 2017. Classification of Human Emotions from Electroencephalogram (EEG) Signal using Deep Neural Network. International Journal of Advanced Computer Science and Applications, 8(9): 419–425.

Altman, N. S. 1992. An introduction to kernel and nearest-neighbor nonparametric regression. American Statistician, 46(3): 175–185.

Amin, H. U., Mumtaz, W., Subhani, A. R., Saad, M. N. M., and Malik, A. S. 2017. Classification of EEG Signals Based on Pattern Recognition Approach. Frontiers in Computational Neuroscience, 11.

Amin, H. U., Yusoff, M. Z., and Ahmad, R. F. 2020. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. Biomedical Signal Processing and Control, 56: 101707.

Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., and 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(6): 061907.

Asghar, M. A., Khan, M. J., Fawad, Amin, Y., Rizwan, M., Rahman, M., Badnava, S., and Mirjavadi, S. S. 2019. EEG-Based Multi-Modal Emotion Recognition using Bag of Deep Features: An Optimal Feature Selection Approach. Sensors, 19(23):

5218.

Bai, Z., Wang, J., Zhang, X.-L., and Chen, J. 2022. End-to-End Speaker Verification via Curriculum Bipartite Ranking Weighted Binary Cross-Entropy. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 30: 1330–1344.

Bao, F. S., Liu, X., and Zhang, C. 2011. PyEEG: An Open Source Python Module for EEG/MEG Feature Extraction. Computational Intelligence and Neuroscience, 2011(2): 1–7.

Benbadis, S. R., Beniczky, S., Bertram, E., MacIver, S., and Moshé, S. L. 2020. The role of EEG in patients with suspected epilepsy. Epileptic Disorders, 22(2): 143–155.

Celebi, M. E., Celiker, F., and Kingravi, H. A. 2011. On Euclidean norm approximations. Pattern Recognition, 44(2): 278–283.

Chandani, M. 2017. Classification of EEG Physiological Signal for the Detection of Epileptic Seizure by Using DWT Feature Extraction and Neural Network. International Journal of Neurologic Physical Therapy, 3(5): 38–43.

Cheikhrouhou, O., Mahmud, R., Zouari, R., Ibrahim, M., Zaguia, A., and Gia, T. N. 2021. One-Dimensional CNN Approach for ECG Arrhythmia Analysis in Fog-Cloud Environments. IEEE Access, 9.

Chen, D., Wan, S., Xiang, J., and Bao, F. S. 2017. A high-performance seizure detection algorithm based on Discrete Wavelet Transform (DWT) and EEG. PLOS ONE, 12(3): e0173138.

Chen, Z., Lu, G., Xie, Z., and Shang, W. 2020. A Unified Framework and Method for EEG-Based Early Epileptic Seizure Detection and Epilepsy Diagnosis. IEEE Access, 8: 20080–20092.

Congedo, M., Özen, C., and Sherlin, L. 2002. Notes on EEG resampling by natural cubic spline interpolation. Journal of Neurotherapy, 6(4): 73–80.

Cortes, C. and Vapnik, V. (1995). Support-Vector Networks. Machine Learning, 20(3): 273–297.

Delimayanti, M. K., Purnama, B., Nguyen, N. G., Faisal, M. R., Mahmudah, K. R., Indriani, F., Kubo, M., and Satou, K. 2020. Classification of Brainwaves for Sleep Stages by High-Dimensional FFT Features from EEG Signals. Applied Sciences, 10(5): 1797.

Elen, A. and Avuçlu, E. 2021. Standardized Variable Distances: A distance-based machine learning method. Applied Soft Computing, 98: 106855.

Er, M. B. 2020. A Novel Approach for Classification of Speech Emotions Based on Deep and Acoustic Features. IEEE Access, 8: 221640–221653.

Fiest, K. M., Sauro, K. M., Wiebe, S., Patten, S. B., Kwon, C. S., Dykeman, J., Pringsheim, T., Lorenzetti, D. L., and Jetté, N. 2017. Prevalence and incidence of epilepsy. Neurology, 88(3): 296-303.

Fix, E. and Hodges, J. L. 1989. Discriminatory Analysis. Nonparametric Discrimination: Consistency Properties. International Statistical Review / Revue Internationale de Statistique, 57(3): 238.

Gajic, D., Djurovic, Z., Gligorijevic, J., Di Gennaro, S., and Savic-Gajic, I. 2015. Detection of epileptiform activity in EEG signals based on time-frequency and non-linear analysis. Frontiers in Computational Neuroscience, 9(MAR).

Gandhi, T., Panigrahi, B. K., Bhatia, M., and Anand, S. 2010. Expert model for detection of epileptic activity in EEG signature. Expert Systems with Applications, 37(4): 3513–3520.

Göksu, H. 2018. EEG based epileptiform pattern recognition inside and outside the seizure states. Biomedical Signal Processing and Control, 43: 204–215.

Hao, K., Lin, S., Qiao, J., and Tu, Y. 2021. A Generalized Pooling for Brain Tumor Segmentation. IEEE Access, 9: 159283–159290.

Hayashi, H. and Uchida, S. 2019. A Trainable Multiplication Layer for Auto-correlation and Co-occurrence Extraction. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 11362 LNCS: 414–30.

Hussein, R., Palangi, H., Ward, R. K., and Wang, Z. J. 2019. Optimized deep neural network architecture for robust detection of epileptic seizures using EEG signals. Clinical Neurophysiology, 130(1): 25–37.

Jiang, X., Pang, Y., Li, X., Pan, J., and Xie, Y. 2018. Deep neural networks with Elastic Rectified Linear Units for object recognition. Neurocomputing, 275: 1132–1139.

Jiang, X., Xu, K., Zhang, R., Ren, H., and Chen, W. 2019. Redundancy Removed Dual-Tree Discrete Wavelet Transform to Construct Compact Representations for Automated Seizure Detection. Applied Sciences, 9(23): 5215.

Khaleelulla, S. E. and Rajesh Kumar, P. 2019. Epilepsy identification based on VMD, RELIEFF algorithm and machine learning classification techniques. International Journal of Recent Technology and Engineering, 8(3): 6180–6185.

Krizhevsky, A., Sutskever, I., and Hinton, G. E. 2017. ImageNet classification with deep convolutional neural networks. Communications of the ACM, 60(6): 84–90.

Kuran, E. C., Er M. B., ve Kuran U., 2021. Epileptic Seizure Detection via EEG Signals with Feature Extraction Technique Based on Cubic Spline Interpolation (In English). 2021 29th Signal Processing and Communications Applications Conference (SIU), 9-11 Haziran, İstanbul, s. 1–4.

LeCun, Y. and Bengio, Y. 1995. Convolutional networks for images, speech, and time series. The handbook of brain theory and neural networks, 3361: 255–258.

Lin, S.-K., Istiqomah, Wang, L.-C., Lin, C.-Y., and Chiueh, H. 2018. An Ultra-Low Power Smart Headband for Real-Time Epileptic Seizure Detection. IEEE Journal of Translational Engineering in Health and Medicine, 6: 1–10.

Liu, A., Chen, K., Liu, Q., Ai, Q., Xie, Y., and Chen, A. 2017. Feature Selection for Motor Imagery EEG Classification Based on Firefly Algorithm and Learning Automata. Sensors, 17(11): 2576.

Liu, X. and Fu, Z. 2020. A novel recognition strategy for epilepsy eeg signals based on conditional entropy of ordinal patterns. Entropy, 22(10): 1–20.

Liu, Y., Niu, H., Li, Z., and Wang, M. 2021. Deep-learning source localization using autocorrelation functions from a single hydrophone in deep ocean. JASA Express Letters, 1(3): 036002.

Maeda-Gutiérrez, V., Galván-Tejada, C. E., Zanella-Calzada, L. A., Celaya-Padilla, J. M., Galván-Tejada, J. I., Gamboa-Rosales, H., Luna-García, H., Magallanes-Quintanar, R., Guerrero Méndez C.A., and Olvera-Olvera, C. A. 2020. Comparison of Convolutional Neural Network Architectures for Classification of Tomato Plant Diseases. Applied Sciences, 10(4): 1245.

Mamli, S. and Kalbkhani, H. 2019. Gray-level co-occurrence matrix of Fourier synchro-squeezed transform for epileptic seizure detection. Biocybernetics and Biomedical Engineering, 39(1): 87–99.

Marreiros, A. C., Daunizeau, J., Kiebel, S. J., and Friston, K. J. 2008. Population

dynamics: Variance and the sigmoid activation function. NeuroImage, 42(1): 147-157.

Molla, M. K. I., Hassan, K. M., Islam, M. R., and Tanaka, T. 2020. Graph eigen decomposition-based feature-selection method for epileptic seizure detection using electroencephalography. Sensors (Switzerland), 20(16): 1–23.

Niknazar, M., Mousavi, S. R., Vosoughi Vahdat, B., Shamsollahi, M. B., and Sayyah, M. 2010. A new dissimilarity index of EEG signals for epileptic seizure detection. 2010 4th International Symposium on Communications, Control and Signal Processing (ISCCSP), 3-5 Mart, Limassol, s. 1–5.

Pan, H., He, X., Tang, S., and Meng, F. 2018. An improved bearing fault diagnosis method using one-dimensional CNN and LSTM. Journal of Mechanical Engineering, 64(7–8): 443–452.

Ping, J. L., Green, C. J., Zartman, R. E., and Bronson, K. F. 2004. Exploring spatial dependence of cotton yield using global and local autocorrelation statistics. Field Crops Research, 89(2–3): 219–236.

Podgorelec, V. 2012. Analyzing EEG signals with machine learning for diagnosing alzheimer's disease. Elektronika ir Elektrotechnika, 18(8): 61–64.

Prasad, A., Manmohan, A., Shanmugam, P. K., and D.P., K. 2018. Application of Cubic Spline Interpolation Technique in Power Systems: A Review. In Topics in Splines and Applications. InTech.

Raghu, S., Sriraam, N., Hegde, A. S., and Kubben, P. L. 2019. A novel approach for classification of epileptic seizures using matrix determinant. Expert Systems with Applications, 127: 323–341.

Rissanen, J. J. 1996. Fisher information and stochastic complexity. IEEE Transactions on Information Theory, 42(1): 40–47.

Sai, C. Y., Mokhtar, N., Yip, H. W., Bak, L. L. M., Hasan, M. S., Arof, H., Cumming, P., and Mat Adenan, N. A. 2019. Objective identification of pain due to uterine contraction during the first stage of labour using continuous EEG signals and SVM. Sādhanā, 44(4): 87.

Satapathy, S. K., Dehuri, S., and Jagadev, A. K. 2017. EEG signal classification using PSO trained RBF neural network for epilepsy identification. Informatics in Medicine Unlocked, 6: 1–11.

Savadkoohi, M., Oladunni, T., and Thompson, L. 2020. A machine learning approach to epileptic seizure prediction using Electroencephalogram (EEG) Signal. Biocybernetics and Biomedical Engineering, 40(3): 1328–1341.

Sharaf, A. I., El-Soud, M. A., and El-Henawy, I. M. 2018. An Automated Approach for Epilepsy Detection Based on Tunable Q -Wavelet and Firefly Feature Selection Algorithm. International Journal of Biomedical Imaging, 2018: 1–12.

Stafstrom, C. E. and Carmant, L. 2015. Seizures and epilepsy: An overview for neuroscientists. Cold Spring Harbor Perspectives in Biology, 7(5): 1–19.

Suwanto, S., Bisri, M. H., Novitasari, D. C. R., and Asyhar, A. H. 2019. Classification of EEG Signals using Fast Fourier Transform (FFT) and Adaptive Neuro Fuzzy Inference System (ANFIS). Jurnal Matematika "MANTIK", 5(1): 35–44.

Tangirala, S. 2020. Evaluating the Impact of GINI Index and Information Gain on Classification using Decision Tree Classifier Algorithm*. International Journal of Advanced Computer Science and Applications, 11(2): 612–619.

Tayeb, Z., Fedjaev, J., Ghaboosi, N., Richter, C., Everding, L., Qu, X., Wu, Y., Cheng, G., and Conradt, J. 2019. Validating Deep Neural Networks for Online Decoding of Motor Imagery Movements from EEG Signals. Sensors, 19(1): 210.

Torres-Ramos, S., Salido-Ruiz, R. A., Espinoza-Valdez, A., Gómez-Velázquez, F. R., González-Garrido, A. A., and Román-Godínez, I. 2020. A brain connectivity characterization of children with different levels of mathematical achievement based on graph metrics. PLOS ONE, 15(1), e0227613.

Tripathi, A., Srivastava, G., Singh, K. K., and Maurya, P. K. 2019. DFT analysis of power spectral density on EEG signals for diagnostic understanding of epilepsy. ARPN Journal of Engineering and Applied Sciences, 14(10): 1904–1907.

Wang, L., Xue, W., Li, Y., Luo, M., Huang, J., Cui, W., and Huang, C. 2017. Automatic Epileptic Seizure Detection in EEG Signals Using Multi-Domain Feature Extraction and Nonlinear Analysis. Entropy, 19(6): 222.

Welvaert, M. and Rosseel, Y. 2013. On the definition of signal-to-noise ratio and contrast-to-noise ratio for fMRI data. PLoS ONE, 8(11): e77089.

Wu, J., Zhou, T., and Li, T. 2020. Detecting Epileptic Seizures in EEG Signals with Complementary Ensemble Empirical Mode Decomposition and Extreme Gradient Boosting. Entropy, 22(2): 140.

Xue, B., Zhang, M., Browne, W. N., and Yao, X. 2016. A Survey on Evolutionary Computation Approaches to Feature Selection. IEEE Transactions on Evolutionary Computation, 20(4): 606–626.

Yalçin, N., Tezel, G., and Karakuzu, C. 2015. Epilepsy diagnosis using artificial neural network learned by PSO. Turkish Journal of Electrical Engineering and Computer Sciences, 23(2): 421–432.

Yang, J. and Ma, J. 2019. Feed-forward neural network training using sparse representation. Expert Systems with Applications, 116: 255–264.

Zhao, W., Zhao, W., Wang, W., Jiang, X., Zhang, X., Peng, Y., Zhang, B., and Zhang, G. (2020). A Novel Deep Neural Network for Robust Detection of Seizures Using EEG Signals. Computational and Mathematical Methods in Medicine, 2020, 1–9.

Zheng, S., Mogusu, E., Veeranki, S. P., Quinn, M., and Cao, Y. 2017. The relationship between the mean, median, and mode with grouped data. Communications in Statistics - Theory and Methods, 46(9): 4285-4295.