T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ

YÜKSEK FREKANS OSİLASYONLARIN (HFO) EPİLEPTOJENİK ALANDA BİYOMARKER OLARAK KULLANIMI

Pelin SARI TEKTEN

DANIŞMAN
Prof. Dr. Fırat KAÇAR

Biyomedikal Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

Ocak, 2024

TEZ KABUL VE ONAYI

Pelin SARI TEKTEN tarafından, **Prof. Dr. Fırat KAÇAR** danışmanlığında hazırlanan **"Yüksek Frekans Osilasyonların (HFO) Epileptojenik Alanda Biyomarker Olarak Kullanımı"** başlıklı bu çalışma, jürimiz tarafından **12/01/2024** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Doktora Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	**Sonuç**
DANIŞMAN	Prof. Dr. Fırat KAÇAR İstanbul Üniversitesi-Cerrahpaşa Elektrik Elektronik Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Prof. Dr. Çiğdem ÖZKARA İstanbul Üniversitesi-Cerrahpaşa Nöroloji Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Prof. Dr. Onur OSMAN İstanbul Topkapı Üniversitesi Elektrik Elektronik Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Prof. Dr. Aydın AKAN İzmir Ekonomi Üniversitesi Elektrik Elektronik Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Doç. Dr. Cengiz Polat Uzunoğlu İstanbul Üniversitesi-Cerrahpaşa Elektrik Elektronik Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret

İTHAF

Tez çalışmamın her aşamasında desteğini hiç esirgemeyen sevgili aileme ve oğlum Ali Mert Tekten'e ithaf ediyorum…

BÜTÇE DESTEKLERİ

Yüksek Frekans Osilasyonların (HFO) Epileptojenik Alanda Biyomarker Olarak Kullanımı

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

Öncelikle tez çalışmamın her aşamasında engin bilgisi ve tecrübelerinden faydalandığım tezimin her aşamasındaki desteklerinden dolayı danışman hocam Sayın Prof. Dr. Fırat Kaçar'a sağladığı katkılardan dolayı, Değerli hocam Sayın Prof Dr.Aydın Akan'a rehberliğinden dolayı çok teşekkür eder, hürmetlerimi sunarım.

Tez izleme komitemdeki Sayın Prof. Dr. Çiğdem Özkara ve Sayın Prof. Dr. Onur Osman hocama tez çalışması boyunca sağladıkları katkılardan dolayı ve tez savunmamdaki komite üyesi hocalarıma müteşekkirim. Ayrıca sürekli teşvik ve desteği için Dr. Soner Kotan'a teşekkür ederim.

Son olarak bana tez çalışması süresince sonsuz sevgi ve anlayışla her türlü desteği sağlayan annem Müfide Sarı, ablam Gamze Sarı, abim Ahmet Celil Sarı ve eşim Tansu Tekten'e çok teşekkür ederim.

Ocak 2024 **Pelin SARI TEKTEN**

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ..... **ii**
BEYAN ..... Hata! Yer işareti tanımlanmamış.**i**
İTHAF ..... **iv**
BÜTÇE DESTEKLERİ ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİL LİSTESİ ..... **ix**
TABLO LİSTESİ ..... **xii**
SİMGE VE KISALTMA LİSTESİ ..... **xiv**
ÖZET ..... **xvi**
ABSTRACT ..... **xviii**
1. GİRİŞ **1**
2. KAVRAMSAL ÇERÇEVE **4**
3. YÖNTEM **11**
3.1. ÖZNİTELİKLER 12
3.1.1. Ortalama 12
3.1.2. Ortalama Güç 12
3.1.3. Çarpıklık 12
3.1.4. Basıklık 13
3.1.5. Hjorth Parametresi-Aktivite 13
3.1.6. Hjorth Parametresi-Mobilite 13
3.1.7. Hjorth Parametresi-Karmaşıklık 14
3.1.8. Yaklaşık Entropi (ApEn) 14
3.1.9. Varyans 16
3.1.10. Hurst Üsteli 16
3.1.11. Dalgalanma İndeksi 18
3.2. SINIFLANDIRMA 19
3.2.1. Makine Öğrenmesi 19

4. BULGULAR 40
4.1. İSTATİSTİKSEL VE YAPISAL ÖZNİTELİKLERE GÖRE SINIFLANDIRMA 40
4.2. KANALLARA GÖRE SINIFLANDIRMA 47
4.3. HFO TABANLI ÖZNİTELİKLERE GÖRE SINIFLANDIRMA 49
5. TARTIŞMA 81
6. SONUÇ VE ÖNERİLER 84
KAYNAKLAR 86
İNTİHAL RAPORU İLK SAYFASI 98
ETİK KURUL İZİN YAZISI 99
KURUM İZNİ YAZILARI 100
ÖZGEÇMİŞ 101

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: İntrakraniyel EEG kaydı sırasında bulunan bir HFO örneği 4

Şekil 2.2: İntrakraniyal Elektrotlar a. Strip Elektrot b. Grid Elektrot c. Derinlik Elektrodu ... 8

Şekil 3.1: Çalışmanın diyagramı 11

Şekil 3.2: Yapay zeka ile bazı makine öğrenmesi sınıflandırıcıları arasındaki ilişki 19

Şekil 3.3: Makine öğrenmesi ile EEG analizinin genel adımları 20

Şekil 3.4: Makine öğrenmesi teknikleri 21

Şekil 3.5: Pekiştirmeli öğrenme modeli 23

Şekil 3.6 : k-NN sınıflandırıcısı A. k-NN sınıflandırıcısına yeni gelen verinin sınıflandırmaya girmesi B. Yeni verinin en yakın komşuluğa göre A sınıfına atanması 25

Şekil 3.7: Bayes sınıflandırıcısı modeli 27

Şekil 3.8: Bayes teoreminin tipik anlatımı 28

Şekil 3.9: Rastgele orman sınıflandırıcısı 30

Şekil 3.10: Doğrusal ve doğrusal olmayan destek makineleri sınıflandırıcısı 32

Şekil 3.11: DVM'de hiper düzlem yapısı 34

Şekil 3.12: Eşik mantık birimi(TLU) 38

Şekil 3.13: ÇKA yapısı 39

Şekil 4.1: Nöbet öncesi 35. örneğe ait 8. kanalın frekans gösterimi 50

Şekil 4.2: Nöbet öncesi 35. örneğe ait 12. kanalın frekans gösterimi 51

Şekil 4.3: Nöbet öncesi 35. örneğe ait 14. kanalın frekans gösterimi 51

Şekil 4.4: Nöbet sınıfı 35. örneğe ait 14. kanalın frekans gösterimi 52

Şekil 4.5: Nöbet sonrası 35. örneğe ait 14. kanalın frekans gösterimi 52

Şekil 4.6: Nöbet sınıfı 20. örneğe ait 8. kanalın frekans gösterimi.....53

Şekil 4.7: Nöbet sınıfı 20. örneğe ait 12. kanalın frekans gösterimi.....53

Şekil 4.8: Nöbet sınıfı 20. örneğe ait 14. kanalın frekans gösterimi.....54

Şekil 4.9: Nöbet sonrası 20. örneğe ait 14. kanalın frekans gösterimi.....54

Şekil 4.10: Nöbet öncesi 20. örneğe ait 8. kanalın frekans gösterimi.....55

Şekil 4.11: Nöbet öncesi 20. örneğe ait 12. kanalın frekans gösterimi.....55

Şekil 4.12: Nöbet öncesi 20. örneğe ait 14. kanalın frekans gösterimi.....56

Şekil 4.13: Nöbet öncesi 50. örneğe ait 12. kanalın frekans gösterimi.....57

Şekil 4.14: Nöbet sınıfı 50. örneğe ait 12. kanalın frekans gösterimi.....57

Şekil 4.15: Nöbet sonrası 50. örneğe ait 12. kanalın frekans gösterimi.....58

Şekil 4.16: Nöbet öncesi 50. örneğe ait 8. kanalın frekans gösterimi.....58

Şekil 4.17: Nöbet öncesi 50. örneğe ait 14. kanalın frekans gösterimi.....59

Şekil 4.18: Nöbet sınıfı 50. örneğe ait 8. kanalın frekans gösterimi.....59

Şekil 4.19: Nöbet sınıfı 50. örneğe ait 14. kanalın frekans gösterimi.....60

Şekil 4.20: Nöbet sonrası 50. örneğe ait 8. kanalın frekans gösterimi.....60

Şekil 4.21: Nöbet sonrası 50. örneğe ait 14. kanalın frekans gösterimi.....61

Şekil 4.22: Nöbet sonrası 16. örneğe ait 8. kanalın frekans gösterimi.....61

Şekil 4.23: Nöbet sonrası 16. örneğe ait 12. kanalın frekans gösterimi.....62

Şekil 4.24: Nöbet sonrası 16. örneğe ait 14. kanalın frekans gösterimi.....62

Şekil 4.25: Nöbet sınıfı 16 örneğe ait 14. kanalın frekans gösterimi.....63

Şekil 4.26: Nöbet öncesi 16. örneğe ait 8. kanalın frekans gösterimi.....63

Şekil 4.27: Nöbet öncesi 16. örneğe ait 12. kanalın frekans gösterimi.....64

Şekil 4.28: Nöbet öncesi 16. örneğe ait 14. kanalın frekans gösterimi.....64

Şekil 4.29: Nöbet sonrası 45. örneğe ait 8. kanalın frekans gösterimi.....65

Şekil 4.30: Nöbet sonrası 45. örneğe ait 12. kanalın frekans gösterimi.....65

Şekil 4.31: Nöbet sonrası 45. örneğe ait 14. kanalın frekans gösterimi.....66

Şekil 4.32: Nöbet öncesi 45. örneğe ait 8. kanalın frekans gösterimi 66

Şekil 4.33: Nöbet öncesi 45. örneğe ait 12. kanalın frekans gösterimi 67

Şekil 4.34: Nöbet öncesi 45. örneğe ait 14. kanalın frekans gösterimi 67

Şekil 4.35: Nöbet sınıfı 45. örneğe ait 14. kanalın frekans gösterimi 68

Şekil 4.36: Nöbet öncesi 3. örneğe ait 8. kanalın frekans gösterimi 68

Şekil 4.37: Nöbet öncesi 3. örneğe ait 12. kanalın frekans gösterimi 69

Şekil 4.38: Nöbet öncesi 3. örneğe ait 14. kanalın frekans gösterimi 69

Şekil 4.39: Nöbet sonrası 3. örneğe ait 14. kanalın frekans gösterimi 70

Şekil 4.40: Nöbet öncesi 5. örneğe ait 8. kanalın frekans gösterimi 70

Şekil 4.41: Nöbet öncesi 5. örneğe ait 12. kanalın frekans gösterimi 71

Şekil 4.42: Nöbet öncesi 5. örneğe ait 14. kanalın frekans gösterimi 71

Şekil 4.43: Nöbet sonrası 5. örneğe ait 14. kanalın frekans gösterimi 72

Şekil 4.44: Nöbet öncesi 40. örneğe ait 8. kanalın frekans gösterimi 72

Şekil 4.45: Nöbet öncesi 40. örneğe ait 12. kanalın frekans gösterimi 73

Şekil 4.46: Nöbet öncesi 40. örneğe ait 14. kanalın frekans gösterimi 73

Şekil 4.47: Nöbet öncesi 43. örneğe ait 14. kanalın frekans gösterimi 74

Şekil 4.48: Nöbet sonrası 43. örneğe ait 14. kanalın frekans gösterimi 74

TABLO LİSTESİ

Sayfa No

Tablo 4.1: İstatiksel ve yapısal özniteliklere göre ÇKA sınıflandırıcısı.....40

Tablo 4.2: İstatiksel ve yapısal özniteliklere göre ÇKA sınıflandırıcısına ait hata matrisi.....41

Tablo 4.3: İstatiksel ve yapısal özniteliklere göre K-NN sınıflandırıcısı sonuçları 41

Tablo 4.4: İstatiksel ve yapısal özniteliklere göre K-NN sınıflandırıcısı hata matrisi 42

Tablo 4.5: İstatiksel ve yapısal özniteliklere göre RF sınıflandırıcısı sonuçları.....42

Tablo 4.6: İstatiksel ve yapısal özniteliklere göre RF sınıflandırıcısı için hata matrisi 43

Tablo 4.7: İstatiksel ve yapısal özniteliklere göre Bayes sınıflandırıcısı sonuçları.....43

Tablo 4.8: İstatiksel ve yapısal özniteliklere göre Bayes sınıflandırıcısı için hata matrisi.....44

Tablo 4.9: İstatiksel ve yapısal özniteliklere göre DVM sınıflandırıcısı sonuçları 44

Tablo 4.10: İstatiksel ve yapısal özniteliklere göre DVM sınıflandırıcısı için hata matrisi 45

Tablo 4.11: İstatistiksel ve yapısal özniteliklere göre sınıflandırıcı doğruluk oranları 45

Tablo 4.12: Özniteliklerin her birine göre sınıflandırıcı sonuçları.....46

Tablo 4.13: Kanallara göre sınıflandırıcı sonuçları 47

Tablo 4.14: Sınıflandırıcılara göre kanalların ortalama değerleri 48

Tablo 4.15: Kanallara göre ortalama değerler.....49

Tablo 4.16: HFO tabanlı özniteliklere göre RF sınıflandırıcısı sonuçları 75

Tablo 4.17: HFO tabanlı özniteliklere göre RF sınıflandırıcısı için hata matrisi.....75

Tablo 4.18: HFO tabanlı özniteliklere göre Bayes sınıflandırıcısı sonuçları 76

Tablo 4.19: HFO tabanlı özniteliklere göre Bayes sınıflandırıcısı için hata matrisi 76

Tablo 4.20: HFO tabanlı özniteliklere göre K-NN sınıflandırıcısı sonuçları 77

Tablo 4.21: HFO tabanlı özniteliklere göre K-NN sınıflandırıcısı için hata matrisi 77

Tablo 4.22: HFO tabanlı özniteliklere göre DVM sınıflandırıcısı sonuçları..... 78

Tablo 4.23: HFO tabanlı özniteliklere göre DVM sınıflandırıcısı için hata matrisi..... 78

Tablo 4.24: HFO tabanlı özniteliklere göre ÇKA sınıflandırıcısı sonuçları..... 79

Tablo 4.25: HFO tabanlı özniteliklere göre ÇKA sınıflandırıcısı için hata matrisi 79

Tablo 4.26: HFO tabanlı öznitelikler için sınıflandırıcılara göre doğruluk oranları 80

SİMGE VE KISALTMA LİSTESİ

Simgeler		Açıklama
μ	:	Ortalama
E	:	Enerji
P	:	Güç
F	:	Fonksiyon
σ	:	Varyans
N	:	Örnek Sayısı
b	:	Sabit Katsayı
w	:	Ağırlık Vektörü
C	:	Düzenleme Parametresi
Σ	:	Toplam
Ç	:	Yanlış Sınıflandırılan Veri Noktası
ω	:	Tahmin Edilmesi Gereken Gerçek Değer
L	:	ÇKA Katmanları sayısı
E	:	Gradyan kayıp fonksiyonu

Kısaltmalar		Açıklama
EEG	:	Elektroensefalografi
HFO	:	Yüksek Frekans Osilasyonları
iEEG	:	İntrakraniyal Elektrosefalografi
SNR	:	Sinyal Gürültü Oranı
FbEEG	:	Fullband EEG
ApEn	:	Yaklaşık Entropi
FCM	:	Bulanık Bölünmeli Kümeleme
SampEn	:	Örnek Entropi
H	:	Hurst Üsteli
R/S Analizi	:	Yeniden Ölçeklendirilmiş Aralık Analizi
D	:	Fraktal Boyut
FI	:	Dalgalanma İndeksi

K-NN : K En Yakın Komşu

DVM : Destek Vektör Makineleri

RF : Rastgele Orman

ÇKA : Çok Katlı Algılayıcı

PCA : Temel Bileşenler Analizi

DAG : Yönlendirilmiş asiklik grafik

RBF : Radyal Taban Fonksiyonu

GDA : Garadyan İniş Algoritması

TLU : Eşik Mantık Birimi

ReLU : Rektifiye Doğrusal Birim

TP Rate : Gerçek Doğru Oranı

FP Rate : Yanlış Doğru Oranı

MEG : Manyetoensefalografi

SPC-HFA : Mekansal Örüntü Kümelemesi

ÖZET

DOKTORA TEZİ

YÜKSEK FREKANS OSİLASYONLARIN (HFO) EPİLEPTOJENİK ALANDA BİYOMARKER OLARAK KULLANIMI

Pelin SARI TEKTEN

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

Danışman : Prof. Dr. Fırat KAÇAR

Epilepsi nöbet şeklinde kendini gösteren ve tekrarlayan nörolojik bir hastalıktır. Hastalık, beyinde bazı nöronların anormal aktivitesi sonucu ortaya çıkar. Epilepsi çocukluk çağında veya yetişkinlikte her yaşta görülebilen ve herkeste farklı semptomlar gösterebilen bir hastalıktır. Epilepsi nöbetleri genellikle kas spazmı, bilinç kaybı ve bayılma şeklinde görülür. Dolayısıyla insanların günlük yaşamlarını, yapabileceği aktiviteleri etkileyebilir. Epilepsi ömür boyu devam edebilir, ancak uygun tedavi ve ilaçlarla nöbetler kontrol altına alınabilir ve kişi normal yaşantısını sürdürebilir. Bazı hastalarda hastanın durumu uygun ise cerrahi yönteme başvurulur. Epilepsi cerrahisi ciddi bir işlemdir, bu nedenle hastalar çok dikkatli değerlendirilir. Hastanın cerrahi işleme uygunluğunu belirlemek amacıyla nörolog ve beyin cerrahlarının birlikte çalıştığı multidisipliner bir ekip tarafından değerlendirme yapılır. Epilepsi cerrahisi ile nöbet odaklarının yerine ve durumuna bağlı olarak farklı prosedürler uygulanır ve nöbetlerin azalması amaçlanır. Bu çalışmada nöbetlerden önce bir belirteç olabilecek olan yüksek frekans osilasyonlarının varlığı araştırılmıştır. Elektroensefalogram verisi; nöbet öncesi, nöbet sırası ve nöbet sonrası olarak üç ayrı sınıfa ayrılmış, sinyal işleme teknikleri kullanılarak öznitelikleri

çıkartılmış, çıkarılan bu istatistiksel ve yapısal özniteliklere göre sınıflandırması yapılmıştır. Ayrıca her bir sınıf için önemli olduğu düşünülen 14 kanal belirlenmiş ve bu kanallara göre sınıflandırma çalışması yapılmıştır. HFO varlıkları belirlendikten sonra, HFO tabanlı özniteliklere göre de sınıflandırma işlemi yapılmıştır. Sınıflandırma amacıyla Bayes, K-En Yakın Komşu, Destek Vektör Makineleri, Çok Katlı Algılayıcı, Rastgele Orman Sınıflandırıcısı kullanılmıştır. Sınıflandırma sonuçlarında rastgele orman sınıflandırıcısı ile istatistiksel ve yapısal öznitelikler için %83, HFO tabanlı öznitelikler için %77,43 ve kanallar için %77,97 doğruluk oranları elde edilmiştir.

Ocak 2024 , 120. sayfa.

Anahtar kelimeler: Yüksek frekans osilasyonları, epilepsi, elektroensefalogram, sınıflandırma, makine öğrenmesi, intrakraniyel EEG

ABSTRACT

Ph.D. THESIS

THE USE OF HIGH FREQUENCY OSCILLATIONS (HFO) AS BIOMARKERS IN EPILEPTOGENIC ZONE

Pelin SARI TEKTEN

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Biomedical Engineering

Biomedical Engineering Programme

Supervisor : Prof. Dr. Fırat KAÇAR

Epilepsy is a neurological disorder characterized by seizures that present themselves in a recurring pattern. The disease arises from abnormal activity in certain neurons in the brain. Epilepsy can be observed at any age, whether in childhood or adulthood, and presents with varying symptoms in different individuals. Seizures in epilepsy are commonly observed as muscle spasms, loss of consciousness, and fainting. Consequently, these can impact people's daily lives and their ability to engage in activities. Epilepsy can persist throughout life; however, with proper treatment and medications, seizures can be controlled, allowing individuals to lead a normal life. In some cases where suitable, surgery may be considered for the patient. Epilepsy surgery is a serious procedure, and therefore, patients are carefully evaluated. A multidisciplinary team comprising neurologists and neurosurgeons collaborates to assess the patient's suitability for the surgical procedure. In epilepsy surgery, different procedures are applied based on the location and condition of seizure foci with the aim of reducing seizures. This study investigated the presence of high-frequency oscillations that could potentially serve as a precursor to seizures. The Electroencephalography (EEG) data has been categorized into three distinct classes: pre-seizure, moment of seizure, and post-seizure. Features were extracted

using signal processing techniques, and classification was performed based on these derived statistical and structural features. Additionally, 14 channels deemed important for each class were identified, and a classification study was conducted based on these channels. Following the determination of High-Frequency Oscillation (HFO) presence, a classification process was carried out based on HFO-based features. For classification purposes, Bayesian, k-Nearest Neighbors, Support Vector Machines, Multilayer Perceptron, and Random Forest Classifiers were utilized. In the classification results, the Random Forest Classifier achieved an accuracy rate of 83% for statistical and structural features, 77.43% for HFO-based features, and 77.97% for channels.

January 2024, 120. pages.

Keywords: high frequency oscillations, epilepsy, electroencephalogram, classification, machine learning, intracranial EEG

1. GİRİŞ

Günümüzde çeşitli semptomlarla görülen nörolojik hastalıkların tanı ve tedavisi için yapılan çalışmaların çoğunda hastalık teşhisi konulmasından, tedavi planlarının oluşturulmasına kadar geçen süreçte çeşitli yöntemlerden, teknik ve cihazlardan faydalanılmıştır. Bu amaçla yapılan araştırmaların sürekli artmakta olduğu ve gelişmekte olan yenilikleri de devamlı takip ettiği göz önüne alınırsa, bu hastalıkların tespitinde ve sağaltımında belirleyici ve önemli olan biyomarkerların saptanması ve desteklenmesi çok önemli bir yer teşkil etmektedir.

Özellikle nörolojik bozukluklardan etkilenen ve nöronlarla etkileşim halinde birçok elektriksel ve kimyasal faaliyetlerle oluşan beyin aktivitelerini anlamak, bu aktivitelerdeki anormal durumları ve işlevsel bozukluklarını ilişkilendirebilmek önem arz etmektedir. Bu amaçla seçici ve ayırıcı olması açısından kritik olan biyolojik belirteçlerin saptanması için yapılan araştırmalar son zamanlarda yoğunluk kazanmaktadır. Bilhassa nörolojik hastalıkların klinik uygulamalarda çok sayıda olduğu göz önüne alınırsa hem hızlı ve kesin teşhis koyabilme hem de en uygun tedavi seçenekleri oluşturabilme açısından gereklilik haline gelmektedir.

Epilepsi hastalığının klinik uygulamalarda en yaygın görülen nörolojik bozukluklardan biri olduğu, bazı beyin nöronlarında birdenbire aşırı veya bazen yinelenen elektriksel boşalmalar sebebiyle, dengesiz ve istemsiz beden hareketleri, bilişsel fonksiyon azalmaları, çeşitli duyusal değişiklikler ve şuur kaybı şekillenebilen, nörolojik bir hastalık olduğu tanımlanmıştır [1-2]. Birçok hastalıkta olduğu gibi yaşam kalitesini olumsuz etkileyen nörolojik bozukluklardan biri olan epilepsi hastalığının teşhis ve tedavisi için çeşitli cihaz ve yöntemlerden yararlanılmıştır.

Elektroensefalografi (EEG) uygulamaları, beyin nöronlarında aşırı yada senkronize deşarj sonucu oluşan epileptik nöbetleri saptamak, beynin fizyolojik ve karmaşık elektriksel ağ yapısı hakkında veri sağlamak için kullanılırken, uzmanlar tarafından görsel değerlendirilen EEG kayıtlarının, epilepsi hastalığı tespitinde anlamlı bir yer teşkil ettiği ancak EEG zemininde görsel işaretlemenin hasta sayısı düşünülünce, sürecin hızlanması ve depo dataların azaltılması gerektiğinden, otomatik ve hassas sistem oluşturmak için EEG izleme sistemlerinde korelasyon fonksiyonu, zaman alanı analizi, frekans bölgesi analizi, zaman-frekans bölgesi analizi, yapay sinir ağına dayalı analiz, seyrek olarak bulanık mantık temelli analiz gibi farklı yöntemler

geliştirilmiş ve ayrıca nöbet saptama projelerinde sıklıkla iki aşamalı etap olduğu, birinci etapta spesifiklerin epileptik şahıslardan ve sağlıklı şahıslardan elde edinildiği, diğer etapta deneyimli sistem, ayrıştırılmış yapının her ilmeğinden evvelki adımlardan edindiği spesifikleri ortaya çıkardığı ileri sürülmüştür [3]. Dolayısıyla epilepsi hastalığı teşhis ve sınıflandırılmasında EEG sinyal izleme analiz yöntemleri çeşitli amaçlarla sıklıkla kullanılmıştır.

Beyin nöronlarında deşarjlar sonucu gelişen elektriksel bozukluklar olan tekrarlayıcı atakların, bütün beyni ya da beynin bir kısmından başlayıp diğer bölümlerine genişleyebilen, bazen yaygın bazen ise odaksal çeşitlilikte olduğu, 24 saat süre ile kaydedilen EEG sinyallerinde nöroloji uzmanları tarafından tespitinin gerektiği, normalde diken dalgalar, keskin dalgalar ya da süreksizlikler beklenmeyip sinyal bozukluklarında görüldüğü ve otomatik saptamada anlamlı bulunan EEG sinyal analiz yöntemlerinin spektral, istatiksel ya da zaman-frekans spesifiklerini, karar destek sistemlerini içerdiği ve otoregresif modellerde ise EEG sinyalleri güç spektrumunu belirleme olasılığıyla epileptik nöbet alanları tespitindeki uygunluğu değerlendirilmiştir [4]. Beyindeki sinirlerin anormal elektriksel aktivitesi olan nöbetler esnasında, EEG sinyallerinin normalden farklılığı, EEG sinyalleri frekans içeriğinin epileptik atak öncesinde ve sonrasında değişik formda olması, EEG sinyal parametrelerinin epileptik nöbet otomatik saptamada ve spesifik kriterlerle belirleyici veriler elde edinmede ilişkisine işaret edilerek, EEG sinyal analizinin klinik uygulamada epilepsi hastalığı tespitinde ayrıcalığı öngörülmüştür [5].

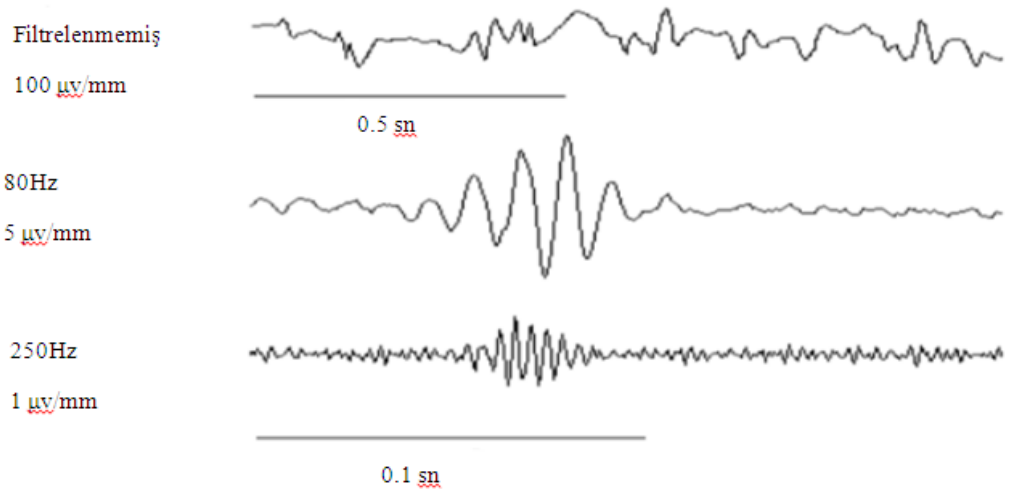
Elektroensefalografi (EEG) sinyalleri, çoğunlukla beyin faaliyetlerini gözlemlemek amacıyla değerlendirilirken, önceleri EEG sinyali frekans içeriklerinin süreyle değiştiği bir nevi EEG sinyalinin durağan olmadığı belirtilmiş ve Fourier dönüşümü temelli analizde ise merkezde ayrıcalıklı olan çözümlenecek sinyalin sabitliği olmuş, epileptik nöbetlerin saptanması içinde EEG sinyallerinden birçok zaman-frekans domeni merkezli yöntemler önerilerek; kısa zamanlı Fourier dönüşümü, dalgacık dönüşümü, çoklu dalgacık dönüşümü, yumuşatılmış sahte Wigner-Ville dağılımı, çok fraktal analiz ve dalgacık dönüşümlerini kapsadığı ve lineer tahmini hata enerjisini değerlendirerek epileptik nöbet saptama olanağı sunulmuştur [6]. Dolayısıyla Fourier dönüşümü temelli spektral parametreler epileptik nöbet EEG sinyallerinin skorlanmasında ve tespitinde sık kullanılan spesifikler olarak incelenmiştir.

Yüksek frekans osilasyonları (HFO'lar), epilepsi hastalığının biyomarkerları olarak özellikle iktal başlangıç dokusunun biyoişaretleri ve preiktal döneminde biyolojik belirteçleri olabileceği incelenirken epilepsi hastalığında potansiyel biyomarkerlar olarak önem kazanmıştır [7]. Klinik uygulamada epileptojenik sahada HFO'ların tespiti ve spesifik

özelliklerini belirlemek için yapılan son yıllardaki bazı çalışmalar biyolojik belirteç olarak görev üstlendiklerine dair olan görüşlere katkı sağlamış ve bu amaçla görsel skorlamada otomatik veya yarı otomatik saptama amacı düşünülerek çeşitli algoritmalar geliştirilmiştir [8]. Yüksek geçiren filtre uygulamayla EEG sinyallerinde görülen HFO'lar, nöronal faaliyetin kısa senkronize alan potansiyelini belirtirken, epileptogenezde anlamlı parametreleriyle epilepsi ilk aşamasını öngörerek, epileptik nöbet start alanında biyolojik işaret olan ufak ölçekli aksiyonel potansiyel alanların epileptik atak başlamasına öncü patolojik HFO'lar olduğu, kendiliğinden nöbetler gelişen bölgelerde interiktal diken dalgalarla beraber kaydedilip hızlı dalgalanmalarla nöbet başlama yerindeki spesifikliğiyle, dalgalanmaların en sık hareketli olmayan uyanıklık dönemi ile yavaş dalgada uyku döneminde saptanması ve bu dilimdeki HFO'ların bellek ve veri oluşturmada ölçüt teşkil ederek çoğunlukla bütün hızlı dalgalı HFO'ların, polar temporal-lob ve medial lob epilepsi kaynaklı atak oluşturan sahalarda kaydedildiği ve dalgalanmaların bu sahada saptanmasının nöbet oluşturan yapıda anlamlı bir kıstas olduğu belirtilerek, patolojik HFO'ların, epileptik nöbet başlama lokalizasyonu biyolojik belirteci olarak hastalık tedavisinde operasyon kararı almada etkisi değerlendirilmiştir [9].

2. KAVRAMSAL ÇERÇEVE

Yüksek frekans osilasyonları (HFO'lar); 80 Hz'den yüksek frekansta kısa süreli salınımlar olarak (80-250 Hz) olan dalgalanmalar ve (250-500 Hz) olan hızlı dalgalanmalar şeklinde ayrılmakta ve klinikte anlamlı olan nöbet başlama alan tespiti için incelendiğinde HFO'ların diken dalgalarla genelde beraber olup, diken dalgalı veya dikenli olmayan HFO'ların, epileptik nöbet start lokalizasyonunu diken dalgalara kıyasla daha net belirlediği, HFO'ların epileptik faaliyetle daha uyumlu olduğu ancak non-invaziv EEG sinyal analizinin düşük sinyal-gürültü oranının yani SNR'nin bu HFO'ların görsel ispatını güçleştirdiğinden, HFO'ların algılanması için yapılan birçok araştırmanın intrakraniyal raporlarla desteklendiği ve bazı araştırmalarda kafatası derisinin EEG'sinde HFO ölçümlerinin etkili olduğu lakin standart olan 10-20 sistemine göre elektrot sayısının azlığından dolayı düşük uzaysal filtre teknolojisi saçlı olan cilt derisi EEG analizini zorlaştırdığı bildirilmektedir [10].



Şekil 2.1: İntrakraniyel EEG kaydı sırasında bulunan bir HFO örneği. [11]

Şekilde üstte filtrelenme olmayan sinyal, ortada filtre uygulanan 80 Hz yüksek geçiren aynı sinyal yani zaman ve genlikte büyütülmüş hali, bu osilasyon dalgalanmadır, en altta da hızlı dalgalanma yani ortadaki sinyalin 250 Hz filtre uygulanmış halidir. [10]

Klinik irdelemelerde EEG data değerlendirmeleri Berger frekans bandı (1-25 Hz bandı) versiyonuyla kısıtlandırılmış ancak ilerleme analog uygulamadan dijital uygulamaya geçişin ötesini gerektirdiğinden, hem dar bant aralığı EEG hem de geniş bant aralığı EEG (50-70 Hz'in ilerisi) 'FULLBAND EEG' (FbEEG) gelişimi sonucunda FbEEG ; yavaş frekans salınımları (0.01-0.1Hz), alt delta frekans analizi (0.1-0.9), konvansiyonel frekans analizi (CFA:1-70 Hz), yüksek frekans salınımları (500-600 Hz), ultra yüksek frekans salınımları (>600-1000 Hz) kapsamakta ve HFO'lar hücre dışı lokalize olan potansiyeller (LFP) içeriğinde alt milimetre ölçekli hacimlerden oluştuğu varsayılan kısa düşük genlik transientleri olarak önceleri HFO'lar derinlik araştırmalarında sık incelenirken son zamanlarda yüksek örnekleme hızında ve uyumlu filtrelerle kayıt olan kafatası derisi EEG'lerinde örneklenerek, HFO haritalaması için parametre ediniminde donanım ve yazılımdaki filtre teknolojisi önemi vurgulanmış ve sistem 256 Hz'lik en az frekansta fazla örnekleme hızına (>1024 Hz) müsaade ederek yani örnekleme hızı ve donanım filtreleri daha yüksek frekansların kaydedilmesine imkan sunmalı denilerek HFO'ların işaretlenmesinde manuel olarak görselde izlenmesi, yarı otomatik ve tam otomatik algoritmalarla algılanması gibi çeşitli metotlar ileri sürülmüştür [12].

HFO'ları temsil eden global ve resmi bir ifade yer almadığından, HFO'lar için kavramsal anlayış, önceleri görsel şekilde ya da dedektörlerle olabilmekte dolayısıyla EEG sinyalinin düşük olmayan frekans bandında filtrelenmesi, kavramın ilk aşamasını oluşturmakta ve enerjisi düşük olmayan frekanslara yayılabilen, artefaktlar, diken dalgalar ya da bant kısıtsız belirgin aktiviteler gibi diğer sinyal aksiyonları filtrelenmiş sinyalde hatalı salınımla algılama diliminin farklılaşabileceği düşünülerek nedenin keskin geçişlerin filtreden süzülerek kısa salınımlara yani filtre dürtüsü tepkisine yakınlığı, bunun da gerçek salınımlarla ayırt etme zorluğu şeklinde ifade edilmiştir. Dalgaların % 60'tan çoğu (80-250 Hz) ve hızlı dalgalanmaların % 50'ye yakını (250-500 Hz) diken dalgalarda ortaya çıkması ve diken dalgaların % 40'tan fazlasının dalgalanmalar göstermesi, diken dalgaların neredeyse % 30'unun hızlı dalgalanmalarla beraber olması, diken dalgalarla beraber olan HFO'ların ne kadarının doğru ve ne kadarının aşırı kesilmiş geçişlerin filtresinden meydana gelebileceği teorisiyle birlikte bazı araştırmalar kavramada görsel ve otomatik olarak keskin geçişlerin gerçek dalgalanmalar benzeri sahte salınımları ekarte olmasında HFO'larda en az sayıda salınım bulunması gerekliliğini, filtrenin impuls tepkisinin belirlenmiş olan çevrim sayısından daha az

salınımda olduğunun tespitini gerekli kılmış, bazı çalışmalarda ise, gerçek bir HFO'nın ham sinyalde görsel saptanmasını yoksa atılmasını, başka araştırmacılarda bir HFO'nın doğru veya sahte olduğunu belirlemede HFO'ların zaman-frekans izlenimi analizini öne sürerek, gerçek bir HFO için (80-500 Hz) frekans bandında zaman-frekans lokalizasyonunda izole pik ile belirtildiğini ve bu metodun görsel skorlamayı ispatlayabilmek için sıklıkla kullanıldığını göstermektedir [13].

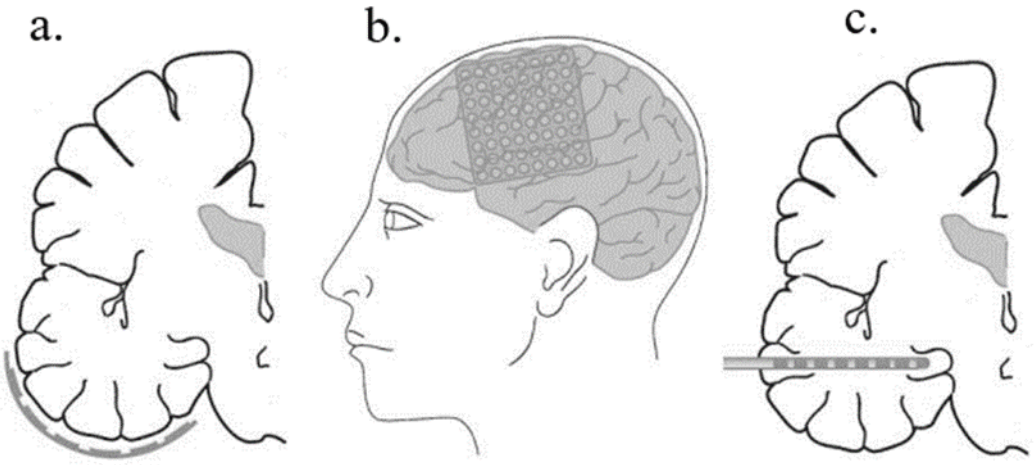
Epileptogenezde patolojik HFO'lar, (80-500 Hz) bandında düşük genlikli kısa süreli salınımlar olarak incelenirken, klinik uygulamada önemli adlandırılan (40 yada 70 Hz' e kadar) standart EEG frekans bantlarının gözden geçirilmesine sebep olmuş ve hızlı dalgalanmaların etki görmüş hipokampüste yoğunluğu araştırılarak, HFO'ların epileptik nöbetin ortaya çıkmasıyla ve bölgesinin epileptik nöbet merkezine bağlılığı düşünülerek, hem dalgalanmaların hem de hızlı dalgalanmaların epileptik nöbetin başlama lokalizasyonuyla ilişkili olduğu, üstelik HFO'ların epileptik nöbetler esnasında ve interiktal dönemde, genellikle non-REM uykusu sırasında görüldüğü, interiktal dönemler sırasında epileptik nöbet başlama alanında öbür alanlara göre daha fazla HFO oranları saptandığı gerekçesiyle HFO'ların epileptojenik yapılarda diken dalgalardan daha önemli biyoişaret olduğunu ve epileptik nöbetin oluşmasındaki aksiyonuyla, HFO oranlarının epileptik nöbetlerin başlama lokalizasyonu ile diken dalgalara göre daha yoğun odaklı olduğu görüşünü taşıdığı dolayısıyla HFO sayısının hastalık faaliyetini gösteriyor olduğu düşüncesini destekleyerek epileptik nöbet alanı tahmini ve uygun tedavi seçeneği planlanmasında oldukça önemli olduğunu göstermiştir [13-14] .

HFO'lar öncelikle implante mikro elektrotlarla sonra intrakraniyal makro elektrotlarla kayıt altına alınırken HFO'ların sıklıkla invaziv halde kayıt altındayken olduğu lakin anormal olan dalgalanmaların epileptiform diken dalgayla kafatası derisi EEG'lerinde olabileceği ihtimali de düşünülmüş ve yoğunlukla interiktal epileptiform deşarjlarının veya diken dalgalar olan saçlı cilt derisi EEG'lerinde patolojik olarak dalgalanmaların görüldüğü, invaziv kaydedilmemiş olan dalgaların genliğinin yüksek olmaması ve kas yapılarının olmasıyla kafatası derisi EEG'sinde dalgalanmaları ayırt etme güçlüğü sebebiyle hem kas artefaktlarının sinyalleri saklayabileceği dolayısıyla hatalı negatiflik gösterebilmesinin eksik dalgalanmalara neden olabileceği hem de kısa olan kas oluşumlarının düşük olmayan frekans bileşeni şeklinde dalgalanmalara benzeme ihtimaliyle işaretlendiğinde hatalı pozitiflik anlamına gelebileceği belirtilerek uyku zamanında kas artefaktının daha düşük olması yani uyku sırasında kas faaliyetinin azaldığı gerekçesiyle fazla artefakttan sakınarak, epileptik diken dalgalarda gelişen patolojik dalgalanmaların saptanmasının mümkün olabileceği ön görülmüştür [15].

iEEG yani invaziv intrakraniyal elektroensefalografi, iktal kayıtlarda nöbet başlangıç yeri ve nöbet oluşan lokal bölge için öncü görev yapmasıyla, epileptojenik alan belirlenmesinde veriler sağlamasıyla ve ameliyat öncesi standartta vazgeçilmez olan biyomarker gerekliliğinin daha kapsamlı algılanması fikrini desteklemesiyle teşhis ve ayırıcı tanıda anlamlı bir yer teşkil ederek, derinlik EEG elektrotlarıyla revize edilmiş mikroelektrotlar kullanılan araştırmalarda, epilepsi hastalarında HFO varlığını tanımlayarak, iktal ve interiktal süreçlerde belli makroelektrodlar seçilerek belirlenmesiyle daha fazla önem kazanmış, ve son zamanlarda yapılan bazı çalışmaların raporlarına göre HFO'ların interiktal epileptiform boşalmalarını oluşturan alanın irrite edici alana göre daha hassas ve spesifik olduğunu, HFO oluşturan bu dokuların ameliyatla alınmasının, epileptik atakları oluşturan başlangıç alanının ya da irrite edici maddenin alınmasından çok daha olumlu sonuçlar alındığını göstermiş, üstelik rezektif cerrahi ihtiyacı görülen hastaların çoğunda, nöbet aralığında ve atak oluşumunda azalma saptanırken, epileptojenik alan korteks bölgesi özenle belirlenmesi gerektiğinde diğer korteks sahaları gösteren çeşitli testlerin parametreleriyle uygunluğu hesaplanan verilerle de desteklenerek önemli bir yer edinmiş, ancak iEGG uygulamasında enfeksiyon ve kanama olasılığı veya implantasyonda nörolojik riskler gibi hasta yaklaşımında bazı ihtimalleri taşısa da HFO'lar için kraniyal cilt derisi kayıtlarında non-invaziv olarak tanı ve bölgesel tespitte birçok zorlukların olması, elektrotların sinyal kaynağından uzaklığı, arka plan gürültüsünün sinyalleri etkileyebileceği ve sinyallerin kas artefaktları ile netleşememe durumu, normal insan beyin dokusunda da dalgalanmaların ve hızlı dalgalanmaların bulunabileceği gibi olağan ve olağan olmayan HFO'ları ayırt etme güçlüğü değerlendirilerek epilepsi hastalığı teşhisinde invaziv intrakraniyal elektroensefalografinin gerekliliği ve ayrıcalıklı olduğu gösterilmiştir [16].

Cerrahi yöntem ile nöbet oluşumunun engellenmesi veya en azından azaltılması uygun olan epilepsi teşhisi konmuş hastalarda, saçlı deri EEG'si yöntemiyle nöbet bölgesi belirlenemiyorsa, müdahale edilecek olan nöbet bölgesinin tespiti için intrakraniyal EEG'nin (iEEG) uygulanması gereklidir. İnvaziv yöntemle yerleştirilmiş olan elektrotlar sayesinde epileptojenik alan tespiti mümkün olabilir. iEEG çekim süresi hastanın nöbet aktivitesine göre belirlenir. iEEG uygulaması öncesinde hastaya belirli tetkikler yapılır, tomografi ve MR çekimleri ile intrakraniyal elektrodların en az hata payı ile yerleştirilmesi planlanır, böylece cerrahi işlem için epileptojenik alanın en doğru şekilde belirlenmesi hedeflenir. Referans işaretleyiciler kullanılırsa, lokalizasyon hatası en aza indirgenir. İntrakraniyal elektrotlar

olarak; strip, grid veya derinlik elektrodları tercih edilebilir. Strip elektrotlar kafatasına çapak delikleri açılması vasıtasıyla yerleştirilir. Grid elektrotlar ise kraniyotomi ile yerleştirilir. Geniş yüzey alanına sahip olan grid elektrodları ile korteksin haritalaması işlevsel olarak sağlanabilir. Strip ve grid elektrotlar, disk şeklinde iletken elektrot kontaklarından oluşur. Strip ve grid elektrotların yerleştirilmesi epidural veya subdural olarak yapıldığından, EEG aktivitesi doğrudan beyin yüzeyinden kaydedilir. Derinlik elektrotları ise eşit aralıklı iletken elektrod kontakları içeren bir çeşit tel benzeri problardır. Derinlik elektrotlarının EEG aktivitesi, medial frontal lob, amigdala ve hipokampüs gibi derin beyin yapılarında kaydedebilirler [17].



Şekil 2.2: İntrakraniyal Elektrotlar a. Strip Elektrot b. Grid Elektrot c. Derinlik Elektrodu [17].

Pearce ve diğerlerinin [18] yaptıkları başka bir çalışma ortaya koymuştur ki, her bir hasta nöbetlerle ilgili çok farklı HFO paternlerine sahiptir; bu bulgular, HFO analizine dayanan herhangi bir klinik kararın her bir hastaya göre özelleştirilmesi gerektiğini göstermektedir.

Lai ve diğerleri, [19] HFO'ların tespiti için doğru ve evrensel bir metod olarak konvolüsyonel sinir ağının kullanılabileceğini gösteren bir çalışma yapmışlardır. Yalnızca temporal EEG sinyalini kullanan CNN tabanlı HFO dedektörü ile yapılan çalışmalarla karşılaştırıldığında, önerdikleri yöntem HFO'ların 2D zaman frekans haritası üzerinde derin CNN sınıflandırıcısını kullanarak daha yüksek bir doğruluk elde etmiş, böylece sadece zaman alanında değil, aynı zamanda spektrum alanında ve güç enerjisinde de daha spesifik bilgileri dikkate almıştır. Geliştirdikleri yöntemle farklı hastaların HFO olaylarının ortak özelliklerini otomatik olarak çıkarabilmişlerdir.

Wang ve diğerleri [20] yaptıkları çalışmanın sonucunda genel olarak, hızlı dalgalanmaların orta düzeyde teşhis doğruluğuna sahip olarak, epileptojenik bölgenin yararlı

bir biyobelirteci olduğunu göstermişlerdir, ancak 80-250 Hz aralığında yer alan dalgalanmaların ise çok fazla etkili olmadığı sonucuna varmışlardır.

Travnicek ve diğerleri [21] çalışmalarında iEEG mikroelektrot kayıtlarındaki aşırı yüksek frekanslı salınımları tespit edebilen bir dedektör tasarlamışlardır. Bu salınımların şu ana kadar nörolojide klinik bir yorumu olmamasına rağmen, 1 kHz'in üzerindeki salınımların nöbet üreten dokuyu standart HFO'dan daha iyi tespit ettiğini göstermişlerdir. Standart klinik makro elektrotlar kullanılarak kaydedilen çok hızlı dalgalanlamalar (500-1000 Hz) ve ultra hızlı dalgalanlamaların (1000-2000Hz) epileptojenik bölge için daha spesifik oldukları gösterilmiştir.

Wu ve diğerleri [22] klinik koşullardan elde edilen iEEG verileri kullanılarak gerçekleştirdikleri çalışmada, HFO adaylarını oluşturmak için HFO'ları arka plan faaliyetlerinden ayıran bir ilk tespit yöntemi kullanılmışlardır. HFO'ları arka plan faaliyetlerinden ayırmak için çıkarılan özniteliklerden dört tane seçilmiştir. Bu özniteliklerle oluşturulan bir öznitelik vektörünü, FCM-QEM tabanlı EM-GMM kümeleme algoritmasının girdisi olarak kullanmışlardır. Tespit edilen HFO'ların yoğunlukları ile epileptik nöbet başlangıç bölgelerini lokalize etmişlerdir. Oluşturdukları bu dedektör ile yüksek hassasiyet ve spesifiklik elde etmişlerdir.

Lopez-Cuevas ve diğerleri [23] elektrofizyolojik sinyallerde HFO'nun tespiti için bir algoritma önermişlerdir. Önerdikleri algoritma ile veri analizi süresini kısaltarak beyindeki hızlı salınımların incelenmesinde olumlu bir etkiye sahip olabileceğini ortaya çıkarmışlardır. Çalışmalarında da kullandıkları ApEn kriterinin öznitelik çıkarımı için etkili bir yöntem olduğu ve kolay hesaplanması nedeniyle uygulama için uygun olduğu gösterilmiştir. HFO'nun varlığı ile interiktal durumdan iktal duruma geçiş arasında bir korelasyon olduğunu görmüşler ve bu nedenle, çalışmalarında önerdikleri gibi bir algoritmanın, nöbetleri tahmin etmek ve önlemek için beynin aktivitesini dikkate alan elektrik stimülasyon cihazlarında kullanılmaya uygun olabileceğini ortaya koymuşlardır.

Lui ve diğerlerinin [24] geliştirdiği dedektör ile HFO tespit performansı, HFO etkinliklerinin oranından etkilenmemiştir ve klinikte farklı hastaların teşhisi için yararlı olan ön eğitim veya ayarlama gerektirmemiştir. Çok sayıda intrakraniyal elektrot implante edilmiş epileptik hastalar için 1 dakikalık iEEG kaydı saatlerce manuel görsel işaretleme gerektirir. Önerdikleri dedektör ile onlarca iEEG kayıt kanalından HFO'ları tespit etmek yalnızca yaklaşık 20 dakika sürmektedir; bu da klinik uzmanların yardımcı bir teşhis aracı olarak verimliliğini büyük ölçüde artırabilir.

Wang ve diğerleri [25] çalışmalarında HFO'ları diğer aktivitelerden ayırmak için dört öznitelik belirlemişlerdir. Bu öznitelikler spektral sentroid, çizgi uzunluğu, güç oranları ve ortalama tekil değerlerdir. Zaman alanı, frekans alanı ve zaman-frekans domeninden elde edilen bu öznitelikler, gelişmiş FCM kümeleme algoritması ile kümelenmiş öznitelik vektörleri olarak arttırılmıştır. Tespit edilen HFO'ların yoğunlukları göz önünde bulundurularak nöbet başlangıç bölgesi tespit edilmiştir. Geliştirdikleri dedektör ile yüksek spesifiklik ve hassasiyet elde etmişlerdir.

3. YÖNTEM

Bu çalışmada kullanılan EEG verisi İstanbul Üniversitesi-Cerrahpaşa, Cerrahpaşa Tıp Fakültesi Nöroloji Anabilim Dalı'nda bulunan 64 kanallı Micromed marka EEG cihazı ile kayıt edilmiş intrakraniyal EEG verisidir. Verinin örnekleme frekansı 1024 Hz'dir. Gürültülü elektrodları görsel olarak belirledik ve bu elektrodları analizden çıkardık. Elimizde kalan 32 kanalın her biri için nöbet geçirilen ve önemli olduğu düşünülen ortak 14 kanal belirledik. Bu kanallar 1,2,3,4,9,11,12,13,25,26,27,29,51 ve 52. kanallardır. Bu 14 kanalın her biri için nöbet öncesi, nöbet ve nöbet sonrası için kanallarda ne gibi farklılıklar olduğunu inceledik. Her bir veri için belirlediğimiz 11 öznitelik çıkardık.



Şekil 3.1: Çalışmanın diyagramı

3.1.ÖZNİTELİKLER

3.1.1.Ortalama

Bir verinin ortalaması, veriye ait bütün örneklerin birbirine eklenerek, toplam veri sayısına bölünmesiyle elde edilir [26].

$$\mu=\frac{1}{N}\sum_{i=0}^{N-1} Xi \tag{3.1}$$

3.1.2.Ortalama Güç

Bazı sinyallerin sonsuz ortalama gücü veya enerjisi veya her ikisi de vardır. Eğer bir sinyal $E_\infty<\infty$ ise enerji sinyali, eğer $0 < P_\infty<\infty$ ise güç sinyalidir. Güç ve enerji, sinyali karakterize etmek için kullanılır [27]. Ortalama güç formülü ise;

$$P=\lim_{N\to\infty}\left(\frac{1}{2N+1}\sum_{n=-N}^{N}|X(n)|\right)^2 \text{ 'dir} \tag{3.2}$$

3.1.3.Çarpıklık

Çarpıklık, bir değişken dağılımında, dağılımın simetrisinin ne ölçüde simetrik olduğunu ölçmek için elde edilen bir değerdir. Değişkene ait veriler sol tarafta yoğunlukta ise, kuyruk sola uzanıyorsa sola çarpık, değişkene ait veriler sağ tarafta yoğunlukta ise, kuyruk sağa uzanıyorsa sağa çarpık olarak nitelendirilir. Bir rastgele değişkenin normal dağılımda veya simetrik bir veri kümesinde çarpıklığı 0'a eşittir. Eğer çarpıklık değeri -0.5 ile 0.5 arasındaysa oldukça simetrik, 1 ile 0.5 veya -1 ile -0.5 arasındaysa orta düzeyde çarpık, -1'den düşük veya 1'den yüksekse yüksek derecede çarpıktır [28]. Çarpıklık EEG verileri için de verilerin zaman içindeki simetrisini ölçmekte kullanılabilir [29] . Aşağıdaki formülde μ ortalama, σ^2 varyans değerleridir. Buna göre çarpıklık;

$$\text{Çarpıklık(x)}=\alpha_3=\int_{i=1}^{N}\frac{(x_i-\mu)^3}{\sigma^3}\,f(x)dx \text{ 'dır.} \tag{3.3}$$

3.1.4.Basıklık

Basıklık, değişken dağılımındaki düzlük veya tepe noktasının derecesi için bir ölçüdür. Verilerin normal dağılıma göre düz mü yoksa tepe noktada mı olduğunu ölçer. Yüksek basıklığa sahip EEG veri setleri ortalamaya yakın belirgin bir tepe noktasına sahip olma, oldukça hızlı düşme ve ağır kuyruklara sahip olma eğilimindeyken, düşük basıklık keskin bir tepe noktası yerine ortalamaya yakın düz bir tepe noktasına sahip olma eğilimindedir [30]. Rastgele bir değişkenin normal dağılımında basıklık sıfıra yakındır ve mezokurtik olarak nitelendirilir. Eğer sıfırdan düşükse dağılımın hafif kuyrukları olur ve platikurtik olarak adlandırılır. Eğer dağılım sıfırdan büyükse ağır kuyrukları olur ve leptokurtik olarak adlandırılır [28].

$$\text{Basıklık (x)}=\alpha_4=\int_{i=1}^{N}\frac{(x_i-\mu)^4}{\sigma^4}\,f(x)dx \tag{3.4}$$

3.1.5.Hjorth Parametresi-Aktivite

Son yıllarda yapılan birçok çalışma, EEG sinyalleri de dahil olmak üzere farklı biyo sinyallerden bilgi çıkarmak ve tanımlamak için istatistik hesaplamalara dayalı olan ve doğrusal olmayan özelliklere sahip, Hjorth parametrelerini kullanmış ve bunun sonucunda başarılı sonuçlar elde etmişlerdir. Hjorth, zaman alanındaki sinyal karmaşıklığını hesaplar ve biyolojik sinyallerde yaygın olarak kullanılır [31]. Zaman fonksiyonunun varyansı hjorth parametrelerinden biri olan aktivitedir ve güç spektrumunun frekans alanındaki yüzeyini gösterir. Sinyalin yüksek frekans bileşenleri çok sayıda ise yüksek bir aktivite değeri, az sayıda ise düşük bir aktivite değeri ortaya çıkar [32].

$$\text{Aktivite}_i^m=\frac{1}{N}\sum_{n=0}^{N-1}[\varphi_m^i(n)-\overline{\varphi_i}]^2 \tag{3.5}$$

3.1.6.Hjorth Parametresi-Mobilite

Hjorth parametrelerinden biri olup, EEG sinyallerinin baskın frekansını hesaplamak için kullanılabilir [33]. Hareketlilik parametresi sinyallerin birinci dereceden türevleri ile standart sapmalarının oranının karekökü̈dür [34]. Hareketlilik parametresi sinyallerin hareketliliğini gösterir ve sinyal durumunun değişimini ölçer [35] .

$$\text{Mobilite}_i^m=\sqrt{\frac{\text{Aktivite}(\frac{d\varphi_i^m}{dt})}{\text{Aktivite}_i^m}} \tag{3.6}$$

3.1.7.Hjorth Parametresi-Karmaşıklık

Karmaşıklık, frekans alanının dördüncü dereceden spektral momentini kullanarak sinyalin bant genişliğinin tahminini ve frekanstaki değişimi ölçmeye çalışır. Karmaşıklık parametresi, bir zaman serisinin veya sinyalin saf sinüs dalgasına yakınlığını yani ona ne kadar benzediğini göstermek için kullanılabilir. Karmaşıklık değeri, sinyalin şekli saf bir sinüs dalgasına benzedikçe 1 değerine yaklaşır [36-37].

$$\text{Karmaşıklık}\{x\}_i^m = \sqrt{\frac{\text{Mobilite}(\frac{d\varphi_i^m}{dt})}{\text{Mobilite}_i^m}} \tag{3.7}$$

Hjorth parametreleri olan bu üç parametre sinyallerin zaman domeninde analiz edilmesinde kullanılır ve bir sinyalin frekans spektrumu hakkında bilgi verir. EEG sinyallerinin istatistiksel varyansını verir [38]. Hjorth parametreleri varyansa dayalı olduğu için kolayca hesaplanabilir ve uygulamayı rahatlatır [39].

3.1.8.Yaklaşık Entropi (ApEn)

Fizyolojik sinyallerde yapılan entropi analizi ile ortalama veya spektral analizde görülemeyen bazı bilgiler ortaya çıkarılabilmektedir. Entropi analizi sinyalin rastgeleliği, düzenliliği ve karmaşıklığı hakkında bilgi verir, bu durum EEG sinyallerinde entropi analizinde, güç analizine kıyasla avantaj sağlamaktadır. Güç spektrumu analizi, durağan sinyalleri analiz etmek için daha elverişlidir, çünkü sadece sinyalin frekans dağılımı hakkında bilgi verir. Entropi analizi ise zaman içinde sabit bir frekans dağılımına sahip olmayan sinyaller için de uygundur, böylece EEG sinyallerine uygulanabilir. EEG sinyallerindeki doğrusal olmayan dinamiklere karşı duyarlıdır, EEG sinyallerindeki karmaşıklığı belirleyebilmektedir. Ayrıca güç spektrumu analizi ile karşılaştırıldığında EEG sinyallerindeki artefaktlara ve gürültüye karşı daha duyarsızdır, çünkü entropi analizi sinyal değerlerinin dağılımına dayanmaktadır. Bununla birlikte entropi analizi ile benzer güç spektrumlarına sahip farklı sinyal türlerinin ayrımı yapılabilir. Beyin aktivitelerinin incelenmesinde en çok seçilen özniteliklerden biri yaklaşık entropidir (ApEn). Patolojik ve fizyolojik koşullar altında, beyinde meydana gelen değişimleri tespit etmek çeşitli çalışmalarda kullanılmıştır [40].

Diğer entropi ölçümlerine kıyasla ApEn uygulaması kolaydır. Sinyallerde istenmeyen gürültü artefaktlarından pek etkilenmez, bileşik ve stokastik süreçler için sonludur ve

genliklerle tespit edilemeyen epizodik davranıştaki değişiklikleri belirleyebilir. ApEn ayrıca, zaman serisinde fizyolojik parametrelerin rastgelelik derecelerini değerlendirmede kullanılmaktadır. Serebral sistemlerin karmaşık ve dinamik özellikleri olduğundan dolayı, beyin fonksiyonlarının anlaşılmasında ApEn çok faydalı bir parametredir [41].

Küçük bir ApEn değeri, tekrarlayan ölçüm modellerinin peşi sıra benzer ölçümlerin geleceğine işaret eder. Düzensiz bir zaman serisinde, tekrarlayan kalıpların tahmini zordur, bu karmaşık durumda ApEn değeri büyüktür. ApEn ile ayrıca bir zaman serisinde yer alan noktaların zamansal sırası da açıklanabilir. Zaman serisi çok düzensizse, ileride benzer modellerin ortaya çıkma olasılığı daha azdır [42].

ApEn, boyut arttırıldığında yeni model olasılığını ve ayrıca zaman dizisindeki yeni bilginin görülebilme sıklığını tespit eder. ApEn'in sahip olduğu ölçek ile değişmeme ve modelden bağımsız özellikleri sayesinde, Lyapunov üsteli ve korelasyon boyutu gibi diğer doğrusal olmayan parametrelere nazaran kısa ve gürültülü verileri daha doğru analiz eder [43].
N sayıda veri noktası içeren veri dizisi X olmak üzere, X=[x(1),x(2),x(3),……x(N)]
X(1),….X(N-m+1) m vektörleri ve bu vektörlerle tanımlanan x(i)=[x(i),x(i+1),….x(i+m-1]
X(i) ve X(j) arasındaki mesafe yani skaler bileşenler arasındaki maksimum mutlak fark, d[X(i),X(j)] ile gösterilirse, X(i) için, d[X(i),X(j)]≤r'nin Mm(i) olarak gösterileceği (j=1,...,N-m+1,j≠i) sayısı bulunur, i=1,2...,N-m+1 için bu vektörler i noktasından itibaren m ardışık x değerini temsil eder.

C_r^m(i) parametresi, r toleransı ve m pencere uzunluğu olmak üzere, benzer patternlerin sıklığını ölçer. her r(r>0) için, her i değeri için i=1,2,…N-m+1

$$d[X(i),X(j)]=max_{k=1,\dots m}|x(i+k-1)-x(j+k-1)| \quad (3.8.)$$

$$C_r^m(i)=\frac{M^m(i)}{N-m+n} \quad (3.9.)$$

Φm(r) hesaplamak için, C_r^m(i)'nin logaritması alınır ve 3.10'daki formül uygulanır.

$$\phi_r^m(r) =\frac{1}{N-m+1}\sum_{i=1}^{N-m+1} \ln C_r^m(i) \quad (3.10)$$

Boyut m+1'e yükseltilerek, . C_r^{m+1}(i) ve ϕ_r^{m+1}(r) elde edilebilmesi için (3.8)-(3.10) arasındaki bütün adımlar tekrarlanır. Bu hesaplamalar sonunda yaklaşık entropi;

$$ApEn(m,r,N)=\phi^m(r) -\phi^{m+1}(r) \text{ olarak bulunur [43-44].} \quad (3.11)$$

ApEn değeri, epileptik aktivite esnasında aniden düşer, bu nedenle epilepsinin otomatik tespitinde kullanılmak için çok uygundur. ApEn diğer parametrelere kıyasla daha az veri noktası gerektirir, gürültüye karşı dayanıklıdır ve hem deterministik hem de stokastik süreçlere uygulanabilir [45].

Yaklaşık entropi (ApEn) ve örnek entropi (SampEn), farklı EEG verilerinden nicel entropi özelliklerini çıkarmak için kullanılmaktadır. Epileptik zaman serileri için ApEn ve SampEn'in ortalama değeri epileptik olmayan zaman serilerine göre daha düşüktür [44] .

3.1.9.Varyans

Bir sinyalin varyansı, sinyalin genliklerinin ortalama değerlerinden ne kadar yayıldığını yani uzaklaştığını ölçmeye yardım eder ve epilepsi hastalarında nöbet ve nöbet dışı sinyalleri karakterize etmek için kullanılabilir [46] .

Standart sapma ve varyans, sinyal içindeki dağılım ve değişkenliği gösterir [47]. İntrakraniyel EEG sinyallerinin n'inci alt bandının her bir kanalını X olarak tanımlarsak, N; X'in uzunluğu olmak üzere varyans;

$$\text{Var(X)}=\frac{1}{N-1}\sum_{i=1}^{N}(X_i-\mu)^2 \text{ 'dir.} \qquad (3.12)$$

3.1.10.Hurst Üsteli

Hurst üsteli (H), bir zaman serisinde uzun süreli hafıza hakkında bilgi sahibi olmak, uzun süreli hafıza derecesini belirlemek, verilerin karmaşıklığını anlamak ve verilerin öngörülebilirliğini belirlemek amacıyla kullanılan doğrusal olmayan bir parametredir. Hurst üsteli ve fraktal boyut ile EEG sinyallerinin öngörülebilirliği ve karmaşıklığı ölçülebilir. H'nin zaman serilerini öngörülebilirliğe dayalı olarak sınıflandırabilmesi, nöbet bölgelerindeki beyin aktivitesi değişimleri hakkında bilgi sahibi olabilmek adına, hurst üstelinin zaman serilerini öngörülebilirlik için sınıflandırabilmesi önemlidir [48]. Hurst üsteli doğrusal ayrımcı analizi için kullanılan istatistiksel bir parametredir. Logaritmik ölçek ile değerlendirilir, yani değerleri 0 ile 1 arasında değişir [49].

Öngörülebilirliği ve uzun süreli hafızanın derecesini 0 ile 1 arasındaki değerlere göre belirler ve pürüzlülük hakkında bilgi de verebilir. Zaman serilerini kalıcı, kalıcı olmayan ve rastgele olarak sınıflandırır. Hurst üsteli, zaman serisi verilerindeki öngörülebilirliği ve uzun vadeli hafızanın derecesini 0 ile 1 arasında değişen değerlere dayanarak belirler, kümelenme eğilimini ölçer. Eğer zaman serisi 0 ile 0,5 arasında H'ye sahip ise karmaşık, ve kalıcı olmayan

bir tutum sergiler. Kalıcı olmayan bir tutum sergilemesi, uzun vadeli negatif korelasyonu gösterir. Sonraki dönemde trendde olan bir artışın, önceki dönemdekinin aksine olarak, trendde bir düşüşe işaret eder, yani yüksek bir değeri, düşük bir değer takip eder ve sonraki değer muhtemelen yine yüksek olur. Böylelikle yüksek ve düşük değerler arasında sürekli bir osilasyon söz konusudur. Zaman serileri, H 0,5'e yakın veya eşitse, Brownian hareketi olarak adlandırılır ve şimdiki zamanın gelecek hakkında hiçbir bilgi içermediği varsayılır, süreçler ilişkisizdir. H değeri 0,5 ile 1 arasında ise zaman serisi için kalıcı olduğu söylenir. Bir sonraki dönemde trenddeki artışın, bir önceki ile aynı kalacağına işaret eder, yüksek bir değerden sonra yine yüksek bir değer olur. Bu durum, güçlü uzun vadeli pozitif korelasyonu gösterir. Güçlü uzun aralıklı pozitif korelasyon bugün ve geçmiş hakkında önemli bilgiler sağlar, böylece iyi bir öngülebilirlik ortaya çıkar [48-50].

Yeniden ölçeklendirilmiş aralık analizi (R/S analizi), doğal süreçlerde uzun vadeli korelasyonları tespit etmek ve ölçmek için kullanılan istatistiksel bir yöntemdir. Bu yöntem ile Hurst üssü tahmin edilebilir. Daha az değişken ve pürüzsüz zaman serisinde karmaşıklık azalmıştır. Zaman serisindeki karmaşıklık azaldıkça Hurst üsteli artar [50]. Zaman alanı tabanlı özellik olan hurst üsteli, yüksek ise tahmin edilebilirlik artar, düşük ise tahmin edilebilirlik azalır [51].

İstatiki bir yöntem olan, uzun vadeli korelasyonları tespit etmek ve de ölçmek için kullanılan yeniden ölçeklendirilmiş aralık analizi (R/S analizi) ile Hurst üsteli tahmin edilebilir [52]. N; olay sayısı, c; sabit sayı olmak üzere, hurst üsteli için formül;

$$H=\frac{\log\left(\frac{R}{S}\right)-\log C}{\log N}\text{'dır.} \tag{3.13}$$

Hurst üsteli ve fraktal boyut, bir zaman alanı serisindeki benzerlik ve korelasyonlar ile ilişkilidir. Hurst üstelinin tahmini, logaritmik ölçekte regresyon çizgilerinin eğimine bakılarak değerlendirilir [53]. Fraktal boyuta göre hurst denklem 3.14'deki gibi hesaplanabilir.

$$D=2-H \tag{3.14}$$

Zaman serilerinin uzun vadeli hafızasının bir ölçüsü olmasıyla Hurst üsteli, bir zaman serisinin salınımlı yapısını kendisiyle karşılaştırarak, zaman serisinin kendine benzerliğini tahmin eder. H değeri 0,5'ten küçük olduğunda, seri kararlılık eğilimindedir ve zaman içinde istikrarlı ve öngörülemeyen bir şekilde salınır. H değeri 0,5'e eşit veya yakın olduğunda, Brownian hareketi veya rastgele yürüyüş olarak adlandırılan salınımlara sahiptir. H değeri 1

olduğunda, seri kendisine çok benzer bir salınım sergiler. H değeri 0 olduğunda ise veriler, herhangi bir istatistiksel kurala uymaz, kaotiktir [54].

Doğrusal olmayan Hurst değeri, 0,5 değerinin altındaysa kısa hafızalı seriler olarak da adlandırılır. Hurst değeri 0,5'ten büyük olduğunda, seri orta vadeli hafızaya sahiptir ve seri için 'Hurst Etkisi'ne sahip denir. Hurst aralığının iki ucunda zıt kutuplar yer alır, geçici ya da kararlı olsalar da devamlılık için enerji gereklidir [55].

3.1.11.Dalgalanma İndeksi

Dalgalanma indeksi, zaman serisi verilerindeki salınımları ölçer, yani bir sinyalin genliğindeki değişimin derecesini ölçmede yardımcı olan istatistiksel bir özelliktir. Dalgalanma indeksindeki yüksek değer, incelenen sinyale ait genliğin daha sık değiştiğine ve genlikteki yüksek dalgalanmaya işaret eder. EEG sinyallerinde meydana gelen osilasyonlar, EEG sinyallerinin spektrumundan elde edilen frekans bileşenleri ile doğrudan ilişkilidir. Sinyal özellikleri göz önüne alındığında, epileptik EEG verilerinin nöbet içermeyen EEG verilerine kıyasla daha fazla dalgalanmaya sahip olduğu görülmüştür ve böylece epileptik EEG verisinin dalgalanma indeksi, normal EEG'ye nazaran daha yüksektir [56-57]. Dalgalanma indeksi FI (3.15)'teki gibi hesaplanabilir.

$$\mathrm{FI}=\frac{1}{N}\sum_{i=1}^{n-1}|f(i+1)-f(i)| \tag{3.15}$$

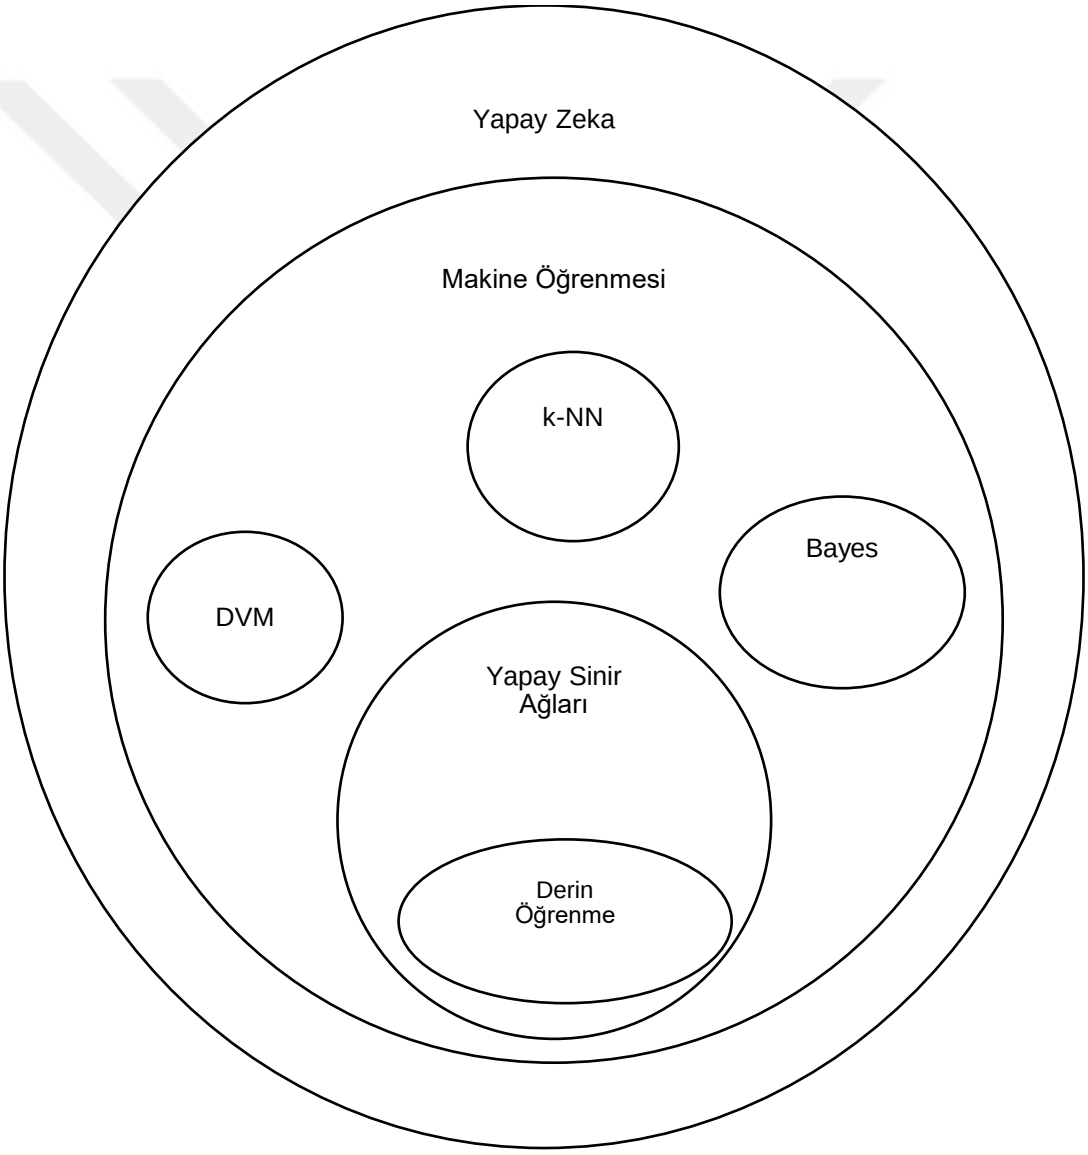
Dalgalanma indeksi, genel olarak EEG ve iEEG sinyallerinin dalgalanma yoğunluğunu ölçmede kullanılabilir. Dalgalanma indeksinin giderek yükselmesi nöbetin belirteci olabilir. Analiz edilecek olan EEG verisine ait dalgalanma indeksinin arka planının, ortalama dalgalanma indeksine oranı hesaplanması ile arka plana göre dalgalanma indeksi de bulunabilir. Dalgalanma indeksinin hesaplama yükü düşüktür, bu sayede gerçek zamanlı bir nöbet tespit sistemi geliştirilmesi mümkün olabilir [58]. İktal iEEG'lerdeki dalgalanma indeksi interiktal iEEG'ye nazaran daha büyüktür. Frekans ve genlikteki sinyal değişimleri göz önünde bulundurularak iEEG özniteliklerinden biri olarak dalgalanma indeksi seçilebilir [59].

Epileptik nöbetlerde beyinde, artmış genlik ve yüksek dalgalanmalara sahip sinyaller, yaygın sivri uçlar görülür. Böylelikle dalgalanma indeksi, nöbet dönemleri ile standart EEG sinyalleri arasındaki farkı etkili bir şekilde temsil edebilen doğrusal olarak çıkarılmış özellik vektörleridir [60].

3.2. SINIFLANDIRMA

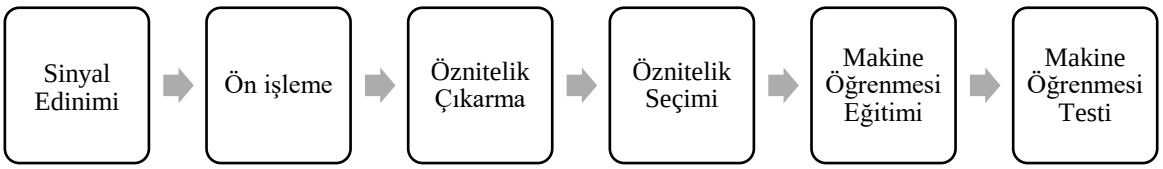
3.2.1.Makine Öğrenmesi

Makine öğrenimi, yapay zekanın bir dalı olup, bilgisayar tabanlı sistemlerde, öğrenimi veri ile yaparak, deneyimlere dayalı bir model oluşturur. Oluşturduğu modeller ile öğrenme algoritmaları sayesinde yeni veriler üzerinde tahmin sağlanır [61].



Şekil 3.2: Yapay zeka ile bazı makine öğrenmesi sınıflandırıcıları arasındaki ilişki

Şekil 3.2, Veri setlerinden istenen sınıflandırmayı elde etmek için makine öğreniminin nasıl uygulandığının genel akışını açıklamaktadır.



Şekil 3.3: Makine öğrenmesi ile EEG analizinin genel adımları [62].

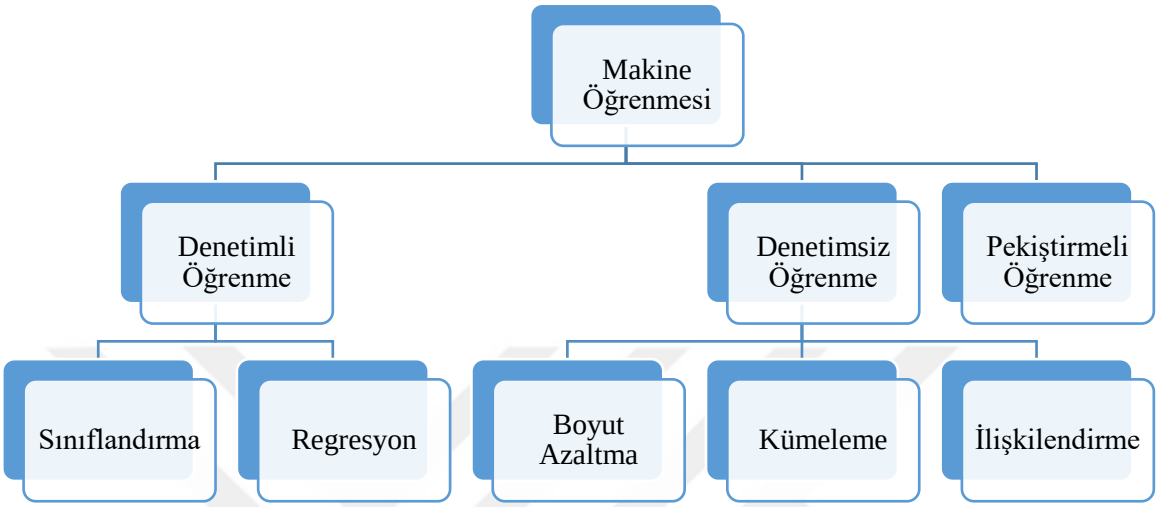
Makine öğrenimi aşamalarında ilk adım sinyalin elde edilmesidir. Analiz edilecek olan ham veri alındıktan sonra, ön sinyal işlemesi yapılır, ön sinyal işleme aşamasında istenmeyen sinyaller olan gürültü giderilir. Ön sinyal işlemeden sonraki aşama öznitelik çıkarmadır. Öznitelik çıkarmada verinin spektrumu ve özellikleri belirlenir. Daha sonra öznitelik seçimi yapılır, makine öğrenimi tarafından eğitim amacıyla kullanılacak sınıflandırıcıların seçilmesidir. Eğitim aşamasında eğitim için veri setleri kullanılır ve test olarak ta gerçek veri setleri kullanılır [62].

Tıbbi verilerin yapısı karmaşıktır, bu nedenle bu fizyolojik verilerin analiz edilebilmesi amacıyla makine öğrenimi kullanılmaktadır. Makine öğrenmesi ile hastalıkların tahmini ve otomatik teşhis konulabilmesi amacıyla çalışmalar yapılmıştır. Makine öğrenmesi özellikle radyolojik, kardiyolojik gibi büyük boyutlu biyomedikal verilerinde, hastalıkların tahmini, otomatik teşhisi ve sınıflandırılmalarında kullanılmaktadır. [63].

Yapay zeka, makine öğrenimi ve yapay sinir ağlarından biri olan derin öğrenme yöntemlerindeki geliştirmeler ve ilerlemeler ile klinik açıdan fayda sağlaması açısından, bu teknikler EEG verilerine de çokça uygulanmaktadır [64].

Bu makine öğrenmesi teknikleri sayesinde EEG analizi otomatik hale getirilebilir ve bu konuda pek çok çalışma yapılmaktadır. Özellikle epilepsi hastalarını, nöbet konusunda önceden uyarabilmek amacıyla, nöbet tespit ve tahmin yöntemleri üzerinde faydalı olabilir. Uyarlanabilmesi kolay olduklarından EEG sinyallerinin sınıflandırılması için makine öğrenmesi uygulamaları önemlidir [65].

Makine öğrenmesi denetimli, denetimsiz ve pekiştirmeli öğrenme olmak üzere üçe ayrılır.



Şekil 3.4: Makine öğrenmesi teknikleri [66].

Makine öğrenme tekniklerinden biri olan denetimli öğrenme, bir girdi seti ile bir çıktı setini eşleyerek, yani hem girdi hem de çıktı verileri ile bir tahmin modeli oluşturur. Bunun için etiketlenmiş eğitim verilerini kullanır, model ve modeli oluştururken öğrenilen parametreler algoritmanın daha önce karşılaşmadığı yeni verilere uygulanır ve bu yeni veriler için sınıf tahmini yapılır. Denetimli öğrenme, sınıflandırma ve regresyon olarak iki alt bölüme ayrılır [65-67].

Hem etiketli hem de etiketlenmemiş verilerin kullanıldığı, ancak etiketlenmiş verilerin fazla olmadığı durumlarda, yarı denetimli öğrenme olarak adlandırılan öğrenme modeli uygulanır. Özellikle büyük veri setlerinde, modelde daha fazla veri eğitilmiş olur, bu durum büyük veri seti için tahmini kolaylaştırır [62].

Sınıflandırma; ilk olarak eğitim süreciyle başlar, veri setindeki veriler etiketlenir ve bu verilere göre bir model oluşturulur, sonrasında yeni gelen verinin hangi sınıfa ait olduğu sınıflandırıcılar aracılığıyla yapılır. Regresyon ise; genellikle zaman serisi modellemelerinde, bir bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi tanımlayan istatistiksel bir

yöntemdir. Sınıflandırma amacıyla aynı bilginin tekrarlanarak öğretilmesi aşırı uyuma sebep olur, özellikler seçilirken regresyon yöntemi uygulanması performansı arttırır [66].

Denetimsiz öğrenme ise, etiketlenmemiş giriş verileri ile tahminler oluşturan bir algoritmadır. Bu etiketsiz verilerde eğitim yapar, modelin özellikleri arasındaki ilişkileri, benzer özellikleri gruplandırır ve bir çıktı oluşturur. Veri hakkında fazla bilgiye sahip olmadığından denetimsiz öğrenme algoritmaları karmaşıktır. Bu algoritmalar, insanların duygusal durumları karmaşık olduğundan, EEG'ye dayalı duygu tespit çalışmalarında, nörofizyolojik hastalıkların tanımı ve sınıflandırılmasında kullanılmaktadır [63-68]. Denetimsiz öğrenme yöntemi de; boyut azaltma, ilişkilendirme ve kümeleme olmak üzere üç alt bölüme ayrılır.

Boyut azaltmada; rastgele değişkene sahip büyük veri setlerinin işlem süresini azaltmak, verileri uygun şekilde işleyebilmek ve sınıflandırılmasının kolaylığı için yüksek veri boyutlarının azaltılması gereklidir. Verilerin incelenen özelliklerini tanımlamak için gereken en az parametre sayısı içsel boyutluluk olarak nitelendirilir. Veri için ideal olan, içsel boyutluluğuna eş bir boyutluluğa sahip olmasıdır. Temel Bileşenler Analizi (PCA) doğrusal tekniklerle boyut azaltma işlemine örnektir [69].

Öğrenme algoritmalarının doğruluğunu iyileştirmek, eğitim süresini kısaltmak amacıyla gerekli olmayan veri ve özellikleri, alakasız verileri, gürültüyü ortadan kaldıran bir ön işleme adımı olarak nitelendirilebilir. Özellik çıkarımı ve özellik seçimi yöntemlerine dayalı olarak yapılmaktadır. Bu azaltılan düşük boyutlu veri setinde, bazı örüntüler gider ancak, önemli özellikler kaybolmaz. Temel özelliklerin varyansı korunur [70].

Kümeleme yöntemi, kümelerdeki benzerlik ve farklılıklara bağlı olarak gruplandırmayı hedefler. Genel olarak, olasılık modeli tabanlı ve parametrik olmayan yaklaşımlar olarak ayrılır. Olasılık modeli tabanlı yaklaşımlar, veri noktaları için olasılık dağılımların karışım modelinden geldiğini varsayar. Olasılık modelli yaklaşımlar için en çok kullanılan algoritma beklenti ve maksimizasyon algoritmasıdır. Parametrik olmayan yaklaşımlar için ise, benzerlik ölçütlerinin fonksiyonuna dayanır [71].

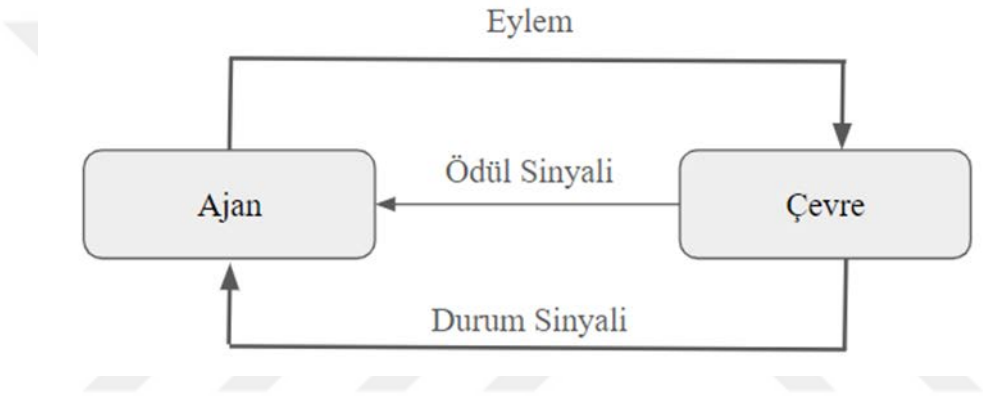
Kümeleme algoritmalarında, girdi verisi ile hangi kümeleme yönteminin en iyi şekilde eşleşebileceğinin bilinmemesi sorun teşkil etmektedir. Kümeleme topluluğu, kümeyi oluşturan topluluk üyelerinin bir alt kümesini seçer, bu alt küme daha iyi performans elde eder [72].

İlişkilendirme kuralı, veri kümesindeki değişkenler arasında bulunan korelasyonları ve ilişkileri belirleyebilmek için kullanılan bir denetimsiz makine öğrenimi yöntemidir. Bir verinin

başka bir veriye bağımlılığını kontrol ederek, daha kararlı bir yapı oluşturabilmek için eşleştirir [73].

Pekiştirmeli öğrenmedeki gelecekteki ödül için, ödülün mevcut durumuna bakılarak, yapılacak eylemin değerlendirilebilmesi en önemli özelliklerindendir [74].

Pekiştirmeli öğrenme, denetimli ve denetimsiz öğrenmeden farklı olarak hedef çıktı yerine bir eylem sonucunda elde edilen bir ceza veya ödül sinyali vardır. Ödül sinyalini maksimize edecek olan eylemi seçmeyi amaçlar. Markov karar süreci açısından, bir problem için ajan, çevre, durum, eylem, ödülün soyutlanması ve örneklenmesi gereklidir [75].



Şekil 3.5: Pekiştirmeli öğrenme modeli [75].

Bu modelde, bir ajan çevreye doğru hareket eder. Çevre ise ödül ve durum sinyallerini gönderir. Ödül sinyali, eylemin ne kadar iyi olduğunu, eylemin mevcut durumu iyileşmesi, kötüleşmesi veya aynı durumda kalması hakkında bilgi verir. Aşağıda belirtildiği üzere, eylem (a), durum (s), geçiş olasılığı (Pr), ödül (r) ve değer fonksiyonundan (V) oluşur [75].

Pekiştirmeli Öğrenme$\rightarrow\{a, s, Pr, r, V\}$

Pekiştirmeli öğrenme uzun süreli bir öğrenme sürecidir [76].

3.2.1.1. K-En Yakın Komşu (K-NN)

K-en yakın komşu algoritması, çok boyutlu bir uzayda sınıflandırma amacıyla, eğitim kümelerinden en yakın komşuyu seçen örnek tabanlı bir makine öğrenimi yöntemidir [77] .

K-NN algoritması, sınıflandırılacak veriyi, en yakın örneklere bakarak sınıflandıran parametrik olmayan bir yöntemdir. Veri, eğitim setindeki diğer verilere göre bir uzaklık ölçümü yapılır. Bu mesafe ile yeni veri için en doğru sınıf en yakın "k" komşusuna göre bulunur. Bu

iki nokta arasındaki mesafeyi hesaplamak amacıyla Manhattan, Minkowski ve Öklid metrikleri kullanılan fonksiyonlardandır. Yeni veriler en yakın sınıfa atanır [78].

x=($x_{1,}x_{2,}\ldots x_n$) ve y=($y_{1,}y_{2,}\ldots.. y_n$) noktaları arasındaki Öklid mesafesi, n özellik sayısı olmak üzere denklem (3.16) ile hesaplanabilir [79].

$$d(x,y)=\sum_{i=1}^{N}\sqrt{(x_1-y_1)^2+\ (x_2-y_2)^2+\ (x_n-y_n)^2} \quad (3.16.)$$

Bu algoritmada performans, uygun bir benzerlik fonksiyonuna ve k için uygun bir değere bağlı olarak belirlenir [80] .

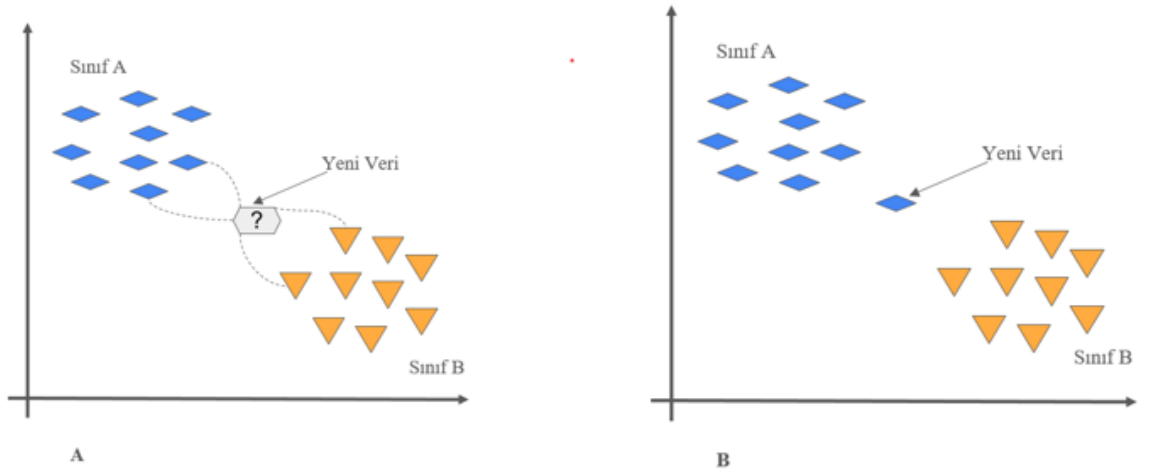
En yakın komşu (NN) sınıflandırıcısı, basit olmasıyla örüntü tanıma işlemlerinde sık kullanılmaktadır. Yeni değişken, eğitim veri kümesine yerleştirilir ve en yakın mesafede hangi küme varsa, o kümeye sınıflandırılır. K değeri yeni değişkenin, kaç en yakın komşunun kullanıldığını gösterir. Sınıflandırıcıdaki k değeri, sonuç için önemlidir, ancak optimum değeri saptamak zordur. Bu dezavantajı indirgemek amacıyla ağırlıklı k-NN geliştirilmiştir. Ağırlıklı k-NN algoritması, komşunun karesel öklid uzaklığına göre, üstel olarak değişen komşu ağırlığın eklenmesiyle meydana gelmiştir [81]. Ağırlıklı öklid mesafesinin denklemi (3.17)'de verilmiştir [82].

$$d(x,y)=\sum_{i=1}^{N}\sqrt{w_1(x_1-y_1)^2+\ w_2(x_2-y_2)^2+w_n\ (x_n-y_n)^2} \quad (3.17.)$$

K-NN sınıflandırıcısı verileri kategorize etmek amacıyla bir hiper düzlem kullanır. Sonrasında veri üzerinde eğitilir. Hiper düzlem, veri kümesi ile kendi arasında olan olan maksimum boşluğa göre optimize edilir. Veriler, en yakın komşularının uzaklıklarına bağlı olarak sıralanır. Algoritma ile önceden etiketlenmiş eğitim örnekleri ve özelliklerine göre yeni örnekler tanımlanır [83].

K-NN regresyon algoritmalarından biridir. K-NN algoritmasında yeni bir veri sınıflandırılırken, o verinin daha önce etiketlenmiş diğer verilerden hangisine daha yakın olduğuna bakılarak, o kümenin etiketini alarak sınıflandırılır. K-NN algoritmasının temel özelliği giriş vektörleri için uzaklığıdır. En çok kullanılan uzaklık metriği, Öklid uzaklığıdır, Hamming, Pearson ve Spearman gibi farklı metrikler de kullanılabilir. Bu algoritmada görülen temel sorun, çok kullanılan kategorilerin, az olanlara baskın olmasından dolayı, sınıflandırma hatası çıkartabilmesidir. Bu durumu çözmek amacıyla metrik ağırlıkları kullanılmaktadır, çıkış

etiketi komşu uzaklığın tersi ile ağırlığın çarpımı neticesinde ortaya çıkar. Yakın olan komşular, uzak olanlara nazaran sınıflandırmada daha fazla etkiye sahip olmaktadır [84].



Şekil 3.6 : K-NN sınıflandırıcısı **A.** K-NN sınıflandırıcısına yeni gelen verinin sınıflandırmaya girmesi **B.** Yeni verinin en yakın komşuluğa göre A sınıfına atanması [85].

Özellik sayısı arttıkça, veri daha karmaşık hale gelmektedir ve EEG verileri yüksek boyutludur. Bu durumda K-NN algoritmasının verimliliğini azalır. Verimliliğinin arttırılabilmesi için rastgele alt uzay topluluk sınıflandırıcısı eklenebilir. Rastgele veri alt uzaylarından bireysel sınıflandırıcılar üretilir. Bu her bir bağımsız sınıflandırıcı, çoğunluk oyuna göre sonuç oluşturur [86] .

K-NN veriye bağlı olarak karar sınırı oluşturur, yeterince k değeri ve eğitim örneği ile K-NN, doğrusal olmayan karar sınırları oluşturabilir. K-NN algoritmasının en önemli avantajı basitliğidir [87].

Ağırlıklı K-NN, K-NN'nin Öklidyen uzaklığında ağırlıklandırılarak geliştirilmesidir. Bu yöntem en yakın komşuyu belirleyebilir. Yeni değişkenin sınıfına, yeni değişkenlerden öğrenme verilerine en yakın mesafe oylaması kullanılarak karar verilecektir [88].

3.2.1.2.Bayes Sınıflandırıcısı

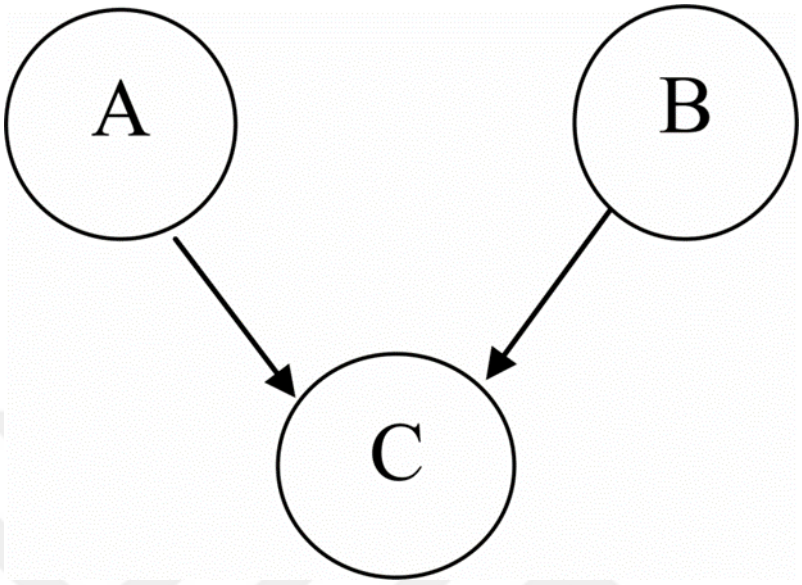
Bayes ağları, olasılık modelleri temsil eden grafik yapılardır. Bayes grafik modelleri, belirsizlik ilişkilerinde, bilgiyi temsil eder. Bayes ağlarında, rastgele bir değişkeni temsil eden düğümler ve bu düğümler arasında kalan ve bunları birbirine bağlayan, rastgele değişkenler arasındaki olasılıksal ilişkileri temsil eden kenarlar bulunmaktadır. Değişkenler arasındaki bu koşullu olasılık ilişkileri, istatistiksel ve hesaplama yöntemleri ile tahmin edilir. Veri tabanlarındaki temel bilgiler ağ yapısında gösterilir. Bu yapı düğümler ve kenarlardan oluşur. Bu birbirine bağlı düğümler ve kenarlardan oluşan grafik türüne yönlendirilmiş asiklik grafik (DAG) denir. Düğümler rastgele değişkenleri, kenarlar bu değişkenler arasındaki bağımlılığı temsil eder. Kenarlar, düğümler arası oklarla ifade edilir [89] .

Bayes ağı da, rastgele değişkenlerin birbirleriyle ilişkilerini göstermek için DAG yapısını kullanır. X= (x_1, x_2,..., x_n) rastgele değişkenler olmak üzere, X üzerindeki bir Bayes ağı (A;B) olarak belirtilirse, B ortak dağılım olmak üzere ve A= (D; E); düğüm kümesi D=(d_1, d_2, ...) ve kenar kümesi E= (e_1,, e_2,,...) olan bir grafik yapısını temsil eder [90].

Eğer d_i'den d_j'ye bir ok varsa, ($d_{i,}d$) = e_k ∈ E, d_i'nin bir ebeveyn düğümü olduğunu ve d_j'nin d_i'nin çocuk düğümü olduğunu varsayabiliriz. Bu durumda d_i düğümü x_i değişkenine karşılık gelir ve ebeveynleri göz önüne alındığında her değişken, kendisinden sonra gelenlerden koşullu olarak bağımsızdır. Eğer x_k düğümü x_j'nin ebeveyn düğümü ise; p($x_i|x_j$, x_k) =p($x_i|x_j$) 'dir. Bayes ağında öğrenme; yapıyı öğrenme ve parametre tahmini olarak ayrılır. Yapı öğrenilirken değişkenler arasında, koşullu bağımsızlık ilişkisi bulunur, ancak grafik yapısı bu değişkenler arasındaki koşullu bağımsızlıkları kısıtlar. Bu sebeple, belirli bir nedensel yapıya bakarak, değişkenler arasında belirli koşullu bağımsızlık modelleri ortaya çıkabilir. Bayes ağı hem bağımsızlıkları hem de düğüm ve kenarlar arasında neden sonuç ilişkilerini göstermek için kullanılabilir. Parametreler ise, ağ topolojisi için koşullu olasılık dağılımlarını belirler ve en yüksek düzeyde doğru tahmini hedefler [90-91].

Grafikte bir değişken, ebeveynlerine göre alt sıralarda yer alan değişkenlerden bağımsız ise, koşullu bağımsızlığı ifade eder. Bu durum, değişkenlerin birleşik olasılık dağılımını belirlemek için parametre sayısını azaltmak için kullanılabilir, böylece büyük sistemlerde karmaşıklık azaltılarak, etkin bir hesaplama sağlanmış olur. DAG yapısı, grafik modelin nitel kısmını temsil eder, birleşik olasılık dağılımı için nicel parametreler de eklenmelidir. Parametreler, her bir düğümdeki koşullu olasılık dağılımını belirler. Ayrık rastgele değişkenlerde koşullu olasılık bir alt düğümün, ebeveynlerinin değerlerine bağlı olarak belirlenir. Bir değişkenler topluluğunun ortak dağılımı için koşullu olasılık tabloları kullanılır.

Bayes ağı, her bir düğüm ile ilişkili olasılık dağılımı bilgisi sayesinde karmaşık nedensel ilişkilerin olasılıklarını modelleyebilir [89-92].



Şekil 3.7: Bayes sınıflandırıcısı modeli [93].

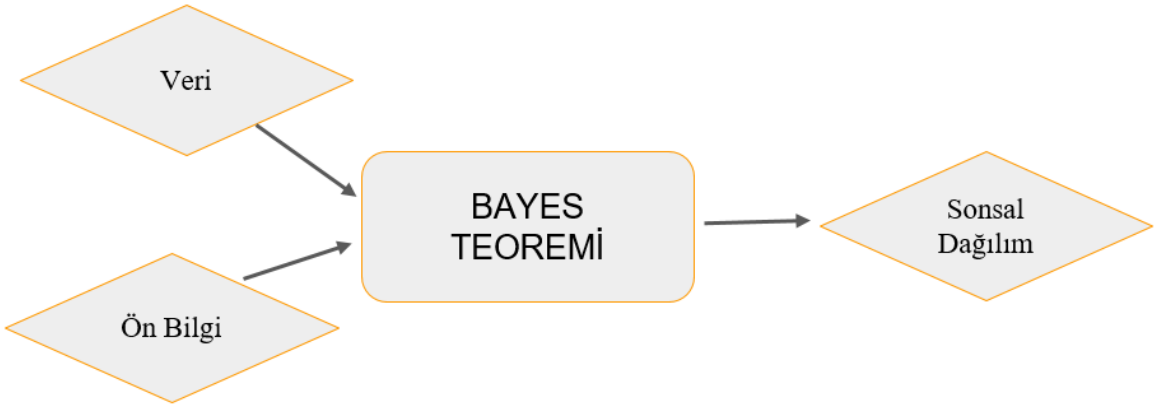
Şekilde A,B,C düğümlerinin ve aralarındaki bağımlılığı temsil eden oklarla basit bir Bayes ağı gösterilmektedir. Şekildeki ağın her bir düğümü bir değişkene karşılık gelmektedir ve kenarlar bu olaylar arasındaki nedenselliği temsil eder. A düğümünden C düğümüne giden bir kenar, bu değişkenler arasında istatiksel bir bağımlılık olduğunu gösterir. A ile C ve B ile C, birbirleri ile bağımlı ancak A ve B birbirinden koşullu bağımsızdır, C bilinirse bağımlı hale gelir. Ok, C düğümü tarafından alınan bir değerin A düğümü tarafından gelene bağlı olduğunu gösterir. Bu durumda A düğümü C'nin ebeveynidir. Bu değişkenlerin ortak olasılığı ise [93]

$$P(A, B, C)=P(C/A,B).P(A).P(B)\text{'dir.} \quad (3.18)$$

Bayes ağı kalite ölçütü ve arama algoritması kullanarak eğitilir [94]. Bayes ağı, iki farklı düğüm arasındaki bağımsızlığı tanımlarken, Bayes ağında bağlantısı olmayan bir düğüm, küçük bir olasılıkla bir üst düğüme sahip olacaktır [95]. Bayes ağı, örüntü sınıflandırma yaparken karar problemi ile ilgili tüm olasılık değerlerinin bilindiğini varsayar ve olasılıksal terimlerle ifade edilen bir karar teorisidir. Değişkenler arasındaki bağımlılıkları kodlarken, veri girişlerinin eksik olduğu noktaları da inceler [96] .

Y'ye dayalı olarak, X'in olasılığını belirlemek için koşullu olasılıklar denklemde verildiği gibi kullanılır [97].

$$P(X/Y)=\frac{P(Y/X)P(X)}{P(Y)} \tag{3.19}$$



Şekil 3.8: Bayes teoreminin tipik anlatımı [98].

Değişkenler arasındaki olasılıksal ilişkiler için grafiksel bir model olan Bayes ağı; ön bilgi, veri ve benzerlik parametresinin birleşmesi ile sonsal olasılık dolayısıyla değişkenler arasındaki ilişki hakkında doğru bilgiler verir [96].

P(X) ilk dağılım olmak üzere, X verileri verildiğinde Y' nin sonsal dağılımını denklem 3.20'de verildiği gibidir [99].

$$P(Y)=\int P(Y/X)dX \tag{3.20}$$

Bayes ağları, belirsizlik koşullarında özellikle karar destek sistemlerinde önemli ölçüde kullanılmaktadır. Bir Bayes ağı, bir dizi stokastik değişken göz önüne alındığında ortak bir olasılık dağılımının özlü bir modelidir. Bir Bayes ağında, M düğümünden N düğümüne giden bir ok için M'nin N'ye neden olduğu söylenir. n sayıda düğümden oluşan bir Bayes ağı için, ve i düğümünün ebeveynlerini gösteren küme p_i ve i düğümü ile ilişkili yerel koşullu olasılık dağılımı $p(x_i|x_{pi})$olmak üzere, ortak olasılık dağılımı; [100]

$$p(x_1, x_2, \dots\dots x_n)=\prod_{i=1}^{n} p(x_i|x_{pi})\text{'dır.} \tag{3.21}$$

Eğer kenarlar yönlendirilmemiş ise, bu grafik modeller Markov ağları ismini alır. Markov ağları, iki farklı düğüm arasındaki bağımsızlığı tanımlar. Bir Bayes ağında, Markov sınırı, bir

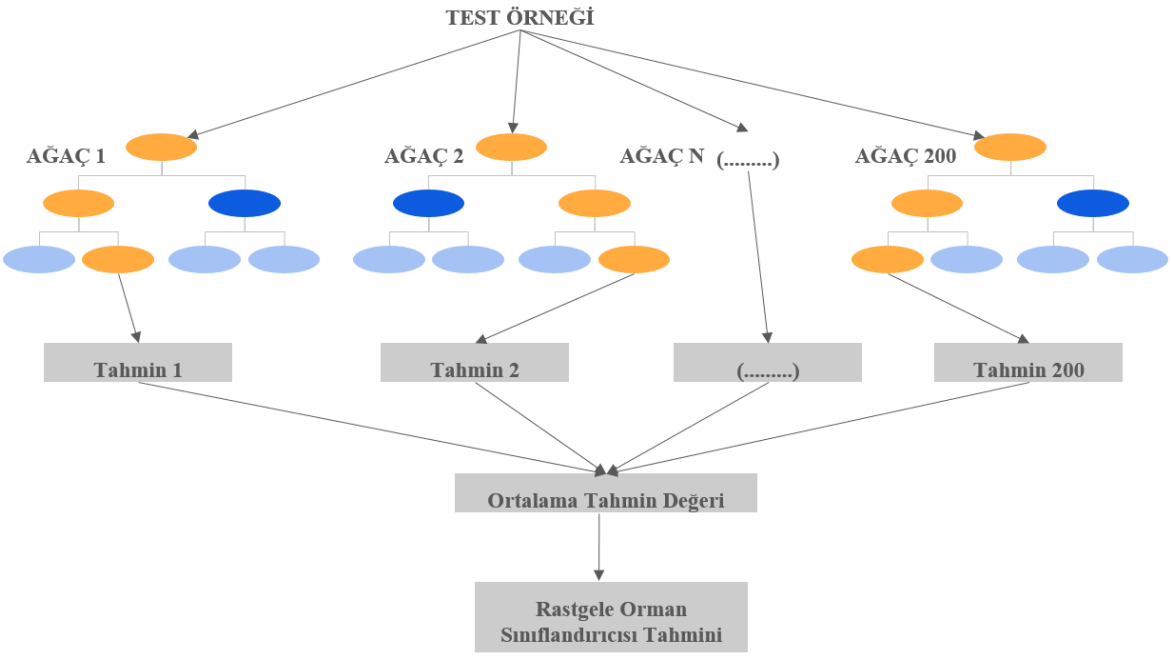
sürecin gelecekteki durumunun, sürecin anlık durumuna bağlı olduğunu belirten bir kavramdır, geçmiş durumları dikkate almaz. Bayes ağında, bu sınır hedef için nedensel ilişkileri gösterir. Bayes ağlarının yorumlanması kolaydır, bu nedenle çokça kullanılmaktadır ancak, mevcut markov sınırı keşif algoritmaları gerçek pozitifleri doğru tanımlayamamaktadır. Bu durum uygulamalarında düşük performansa neden olabilir [101].

3.2.1.3.Rastgele Orman Sınıflandırıcısı

Denetimli makine öğrenimi algoritmalarından biri olan rastgele karar ormanları, birden fazla karar ağacı sınıflandırıcısının bir araya gelmesiyle oluşturulmuştur. Ayrıca rastgele orman sınıflandırıcısı, topluluk tipi öğrenme yöntemlerinden olan bagging algoritmalarından birini kullanır [102].

Rastgele orman sınıflandırıcısında (RF) eğitim süreci içerisinde tanıma algoritması, çok sayıda hiper-parametre üretir. RF'deki karar ağaçlarının sayısı, performans üzerinde etkilidir. Farklı veriler için her bir modele göre optimum performansa göre ağaç sayısı farklılaşır. RF yüksek boyutlu verileri için uygundur. Epileptik EEG sinyalini yüksek doğrulukla tanıyabilmesi için parametreler optimize edilmelidir. Parametreleri optimize etmek ve yapılandırmak için farklı algoritmalar önerilmiştir [103].

Topluluk öğrenme yöntemlerinden olan RF sınıflandırıcı, sınıflandırma ve regresyon işlemlerinde geniş olarak kullanılır. Karar ağaçlarından her biri, eğitim verilerinden rastgele bir eğitim seti üzerine inşa edilir. Her bir düğümde en iyi bölünmenin sağlanması için rastgele bir değişken alt kümesi kullanılır. RF modeli eğitilir ve tüm ağaçlar oluşturulduktan sonra, en son karar çoğunluğa göre yapılan sınıflandırma veya ortalamaya dayalı olan regresyona göre verilir. Alınan bu karar, bilinmeyen verilerin tahmininde kullanılır. Modelin genelleme hatasına karşı ise torba dışı hata denilen bir parametre kullanılır. Bu hata tahmini için verinin bir kısmı her ağacın eğitimine katılmaz. Bu eğitime katılmayan veri yerine ise, model oluşturulan ağaç ile tahmin edilen test verileri olarak kullanılır [104].



Şekil 3.9: Rastgele orman sınıflandırıcısı [105].

RF yöntemi; parametrik, etkin ve yorumlanmasının kolay olması sebebiyle ve yüksek doğruluk tahmini ile çok boyutlu değişkenlerde ve çok katmanlı verilerde sıkça kullanılmaktadır. RF algoritmasının doğruluk performansının lojistik regresyondan daha iyi olduğu bazı çalışmalarda ortaya çıkmıştır. RF algoritmasının parametreleri ise, toplulukta bulunan ağaç sayısı ve her bir düğümdeki rastgele değişken sayısıdır. Ağaç topluluğunun oluşturulabilmesi için RF iki rastgelelik seviyesi kullanır. Örneklem alma olarak nitelendirilen ve torbalamanın (bagging) bir parçası olan bootstrap toplamada, veri setinden rastgele örnekler alarak kendini eğitir ve karar ağaçları oluşturur. Her bir örneklem ile birden fazla veri alt kümesi oluşturabilir. Daha sonra ise, algoritma grup sınıflandırması yapabilmek adına bir karar ağacı büyütürken, her düğümde bölünecek bir rastgele özellik alt kümesi seçer. Sınıflandırma doğruluğunu en üst düzeye çıkarabilmek için, her bir iç düğümde özellik alt kümeleri arasından tek bir en iyi özellik seçilir. Bu özellik seçme işlemi ağaç belirli derinliğe gelene kadar veya düğümdeki örnek sayısı eşik değerinden az olana kadar veya tüm örnekler aynı sınıfta toplanana kadar sürekli tekrarlanır. Veri setinden rastgele örneklem alma ve bu örneklemlerin birleştirilmesiyle daha güçlü modeller oluşturulur. En sonda ise meydana gelen modellerin tahminleri birleştirilerek sınıflandırma yapılır. RF sınıflandırma yönteminin önemli kavramları bulunmaktadır. Ağaçlar; verileri sınıflandırmak için, tek bir sonuca ulaşan birden fazla karar ağaçlarını temsil eder. Her bir ağaç rastgele örneklere dayanarak oluşturulur. Düğüm, bir ağaçta

ikili sonuçlara neden olan bir özelliğin test edilesi sonucunda bölünmenin meydana geldiği noktadır. Her bir düğümde verinin belirli bir özelliği kullanılarak veri bölünür. Bölme işlemi için, bir özellik ve o özelliğin eşiği seçilir, böylece daha küçük alt gruplara ayrılır. Dal; bir karar ağacında test sonucu bir veya birden fazla dal ile oluşur. Rasgele orman topluluğu, her bir karar ağacından gelen tahminleri toplamak amacıyla ağaçların toplanmasıdır. Tahminler oylanarak, tek bir sonuç elde edilir. Torbalama; rastgele seçilen eğitim verilerinin sınıflandırmalarının birleştirilmesi yöntemidir. Torba dışı hata kestirimi; torba dışı hatanın, alt örneğe dayalı sınıflandırma hatasının tahminidir. Rastgele orman modelinin bir doğrulamasıdır. Gini düşüşü; sınıflandırma için belirli bir özelliğin önemini temsil eder. Özelliğin bölme yapılmasının ne ölçüde önemli olduğunu belirten bir parametredir. Değişkenin düğüm sınıflandırma hatasındaki ortalama azalmayı gösterir. Doğruluk azalması; belirli bir özellik dikkate alınmadığında ortalamada meydana gelen düşüşü temsil eder. Ortalama minimum derinlik, ana düğümden en yakın yaprak düğüme kadar olan en kısa mesafedeki düğüm sayısıdır. Mtry; her bir karar ağacının oluşmasında kullanılacak olan ve her bir düğümü bölmek için rastgele seçilen özelliklerin sayısını belirleyen bir hiper parametredir. Ntree; belirli bir model için büyütülecek olan önceden ayarlanmış toplam ağaç sayısını temsil eder. Daha büyük 'ntree' daha kararlı model ve güvenilir tahminler ortaya çıkarır. Düğüm sayısı; belirli bir özelliği bölmek için kullanılan toplam düğüm sayısıdır. P- değeri; elde edilen başarı sayısının, teorik başarı sayısına göre olasılık değeridir. [106]

Rastgele orman sınıflandırıcısı ile en önemli değişkenler hakkında doğrudan sonuçlar çıkarılabilmektedir. Bootstrap örneklerinin her biri için, budanmamış veya regresyon ağacı her düğümde, en iyi bölünmeyi seçmek yerine, tahmin edicilerin mtry'sini rastgele örnekler ve bu değişkenler arasından en iyi bölünmeyi seçer [107].

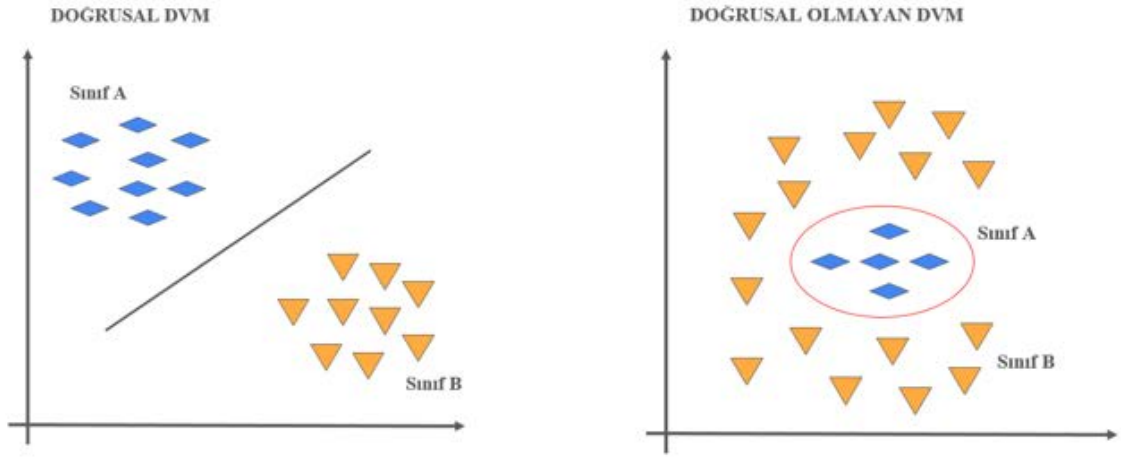
Her ağaç eğitilirken başlangıç veri satırlarının rastgele seçimi, bazı satırların birden fazla kez seçilebileceğini bazılarının ise hiç seçilemeyeceğini gösterir. Tüm ağaçlardan elde edilen sonuçlar ile tek bir karar ağacı veya herhangi bir tek sınıflandırıcı ile elde edilenden daha doğru çözümler elde edilir. Rastgele orman sınıflandırıcısının çeşitli seçimlere göre farklı versiyonları bulunmaktadır [108].

3.2.1.4.Destek Vektör Makineleri (DVM)

Destek vektör makineleri (DVM), denetimli öğrenme yöntemlerinden biridir. DVM'lerin, performansının yüksek ve verimliğinin iyi olması sebebiyle, makine öğrenmesi,

regresyon analizi ve sınıflandırma için kullanılan örüntüleri tanımlamada çokça kullanılır. DVM algoritmasının temeli, yapısal risk minimizasyonu ilkesine dayandırılmıştır [109-110].

DVM sınıflandırma yaparken yüksek boyutlu bir uzayda hiper düzlemleri kullanır. y = f(x) fonksiyonu ile n boyutlu özellik vektörü, daha yüksek boyutlu bir uzaya eşlenir. Ayrılabilirlik marjı; destek vektör makineleri bir sınıflandırma yaparken, iki sınıf arasında karar sınırı belirlemeye çalışırken oluşturduğu boşluktur. Fonksiyon, sınıflar arasında ayrılabilirlik marjını en üst düzeye çıkarmayı hedefler. Sınıflandırmanın doğrusal bir fonksiyon kullanılarak gerçekleştirilebildiği en basit durum için hiper düzlem denklemi tarafından verilir. Çok özellikli veri kümelerinde, özellik ve sınıf ilişkisi doğrusal değil ise, doğrusal bir hiper düzlem ile sınıf ayrımı yapılamayabilir. Bu durumda DVM, doğrusal olmayan sınıflandırma problemini çözmek için kernel fonksiyonlarını kullanır. Bu doğrusal olmayan verileri, daha yüksek uzaylarda bulunan doğrusal hiper düzlemler yardımıyla çok boyutlu bir uzaya dönüştürür. Sınıflandırma için, ilk olarak örnekler eğitilir. Eğitim vektöründeki her örnek, kernel fonksiyonu ile n boyutlu bir uzaya yansıtılır, böylece veriler arasındaki ilişkiler daha iyi tanımlanabilir. DVM bir model oluşturur ve yüksek boyutlu uzayda doğrusal bir ayırıcı hiper düzlem oluşturur. Eğitim veri setindeki noktalar, paralel iki hiper düzlem arasında iki kategoriye ayrılır. Paralel hiper düzlemler arasındaki mesafe büyüdükçe, DVM hata oranı azalır [111].



Şekil 3.10: Doğrusal ve doğrusal olmayan destek makineleri sınıflandırıcısı [112].

DVM, hem ikili sınıflandırma hem de çoklu sınıf problemlerini çözebilir. Verileri d-boyutlu değişkenlerden oluşan bir eğitim seti;

$(x_1, y_1, x_2, y_2 \ldots\ldots x_m, y_m)$ olarak tanımlandığında, burada, $x_i \in R^d$ ve $y_i \in (-1, 1)$, w; hiper düzlemin ağırlık vektörü ve b sabit katsayı olmak üzere, hiper düzlemi aşağıda verilen fonksiyon ile verebiliriz.

$$f(x) = w^T.x+b=0 \quad (3.22)$$

$y \in (-1, 1)$, olduğundan, eğitim verileri aşağıdaki eşitliklere uymalıdır.

$$w^T.x_i + b \geq 1 \quad y_i=1 \quad (3.23)$$

$$w^T.x_i + b \leq 1 \quad y_i=-1 \quad (3.24)$$

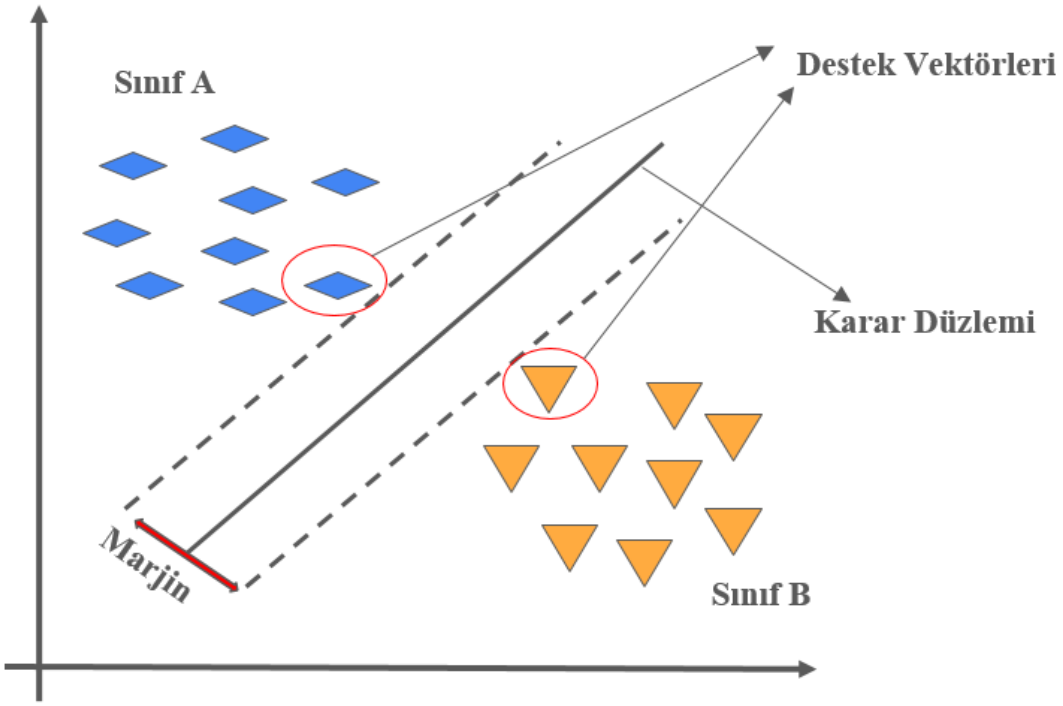
Bir sınır ile karar düzlemi arasındaki mesafe $(\frac{1}{||w||})$ 'dir. $||w||=\sqrt{w^T.w}$ göz önünde bulundurularak, mesafeyi maksimize etmek için $(\frac{2}{||w||})$ minize etmek için ise $(\frac{||w|^2}{2})$ uygulanır.

Veri noktası ile hiper düzlem arasındaki mesafenin denklemi ise (3.25)'te verilmiştir.

$$d((w.b), x_i) = [(y_i (x_i.w + b))/ ||w||] \geq (1/||w||) \quad (3.25)$$

Hiper düzlem (w,b) kullanılarak x verilerinin sınıflandırılması; (3.26)'da verilen fonksiyon ile yapılır [113].

$f(x) = sgn(w^T x + b)$ fonksiyonu ile yapılır. (3.26)



Şekil 3.11: DVM'de hiper düzlem yapısı [114].

Şekilde optimal hiper düzlem, optimal olmayan hiper düzlem destek vektörler ile sınıflandırılması istenen veriler gösterilmiştir.

Optimal hiper düzleminin yapısı W^T.X+b=0 olarak belirtilir ve şekildeki gibi bir örnekte verileri iki gruba ayırır. W ağırlık vektörünü, b katsayıyı ifade etmektedir. En optimal hiper düzlem, destek vektörlerinden yani, en yakın sınıf noktalarından en uzak marja göre seçilir. Marj maksimize edilirken, sınıflar en doğru şekilde ayrılabilir [114].

DVM sınıfların ayrılmasını, aralarındaki marjinal mesafeyi maksimize etmek için bir optimizasyon problemi olarak ele alır. Maksimum mesafe, marj ile tanımlanır. Marj bir destek vektörü ile hiper düzlem (karar düzlemi) arasındaki dik olan mesafedir. Karar düzlemine en yakın noktalar destek vektörleridir. DVM algoritması, doğrusal kernel ve Radyal Taban Fonksiyonu (RBF) gibi çeşitli çekirdek fonksiyonlarını kullanır. RBF kernel doğrusal olmayan değişkenlerle başa çıkmak ve doğrusal olmayan karar sınırlarını aramak için kullanılabilir. DVM algoritmasının performansı yüksek olsa da, doğrusal olmayan DVM durumunda düzenleme parametresi ve kernel parametresinden performans etkilenir. DVM'den iyi bir performans elde etmek için düzenleme parametresi ve kernel parametresinin dikkatli belirlenmesi gerekmektedir. DVM'nin optimizasyonu sırasında, sınıflandırma hatalarını temsil

eden yanlış sınıflandırma sayısı ile marj genişliği arasındaki dengeyi ayarlayan bir düzenleme parametresi vardır. Düzenleme parametresi (C) ve yanlış sınıflandırılan veri noktaları ς_i olmak üzere, (3.27)'de verilen denklem ile açıklanabilir [115-116].

$$\text{Min}\ \frac{1}{2}||w||^2 + C\sum_i \varsigma_i \tag{3.27}$$

Düzenleme parametresinin değeri doğru ayarlanmazsa, verilerde aşırı uyum veya yetersiz uyum nedeniyle performans azalabilir. Yani, düzenleme parametresinin değeri büyük alınırsa, küçük marjı olan bir hiper düzleme, yüksek varyansa neden olur, böylece verilere aşırı uyum gerçekleşir. Eğer bu değer, küçük bir alınırsa büyük marjlı bir hiper düzleme ve düşük varyansa neden olur, bu durum da verilere yetersiz uyum sonucunu doğurur. DVM algoritmasını eğitirken düzenleme parametresini optimize etmek, algoritmanın performansı için çok önemli bir adımdır. Doğrusal olmayan DVM'de performansı etkileyen bir diğer parametre çekirdek parametresidir. Giriş verileri uzayından, yüksek boyutlu uzaya doğrusal olmayan eşleme çekirdek parametresi ile yapılır. Çekirdek parametresinin yüksek değeri, uzaktaki verileri görmezden gelir, küçük değeri ise uzaktaki verileri dahil eder [115-116].

EEG sinyalleri zaman içinde sürekli olarak değişen dinamik bir sinyaldir. Bu sinyallerin durağan olmaması, sınıflandırmadaki doğruluk oranını etkileyebilir, bu nedenle bu durumu düzeltmek için adaptif sinyal işleme yöntemlerine çokça başvurulur. EEG sinyallerindeki değişiklikleri gözlemlemek, sınıflandırmak ve işlemek için çevrimiçi güncellenen uyarlanabilir sınıflandırıcılar kullanılmaktadır. Uyarlanabilir sınıflandırıcının çevrimiçi öğrenme yeteneğine sahip olması, az miktarda çevrimdışı eğitim verisi ile çalışmasına olanak sağlar. DVM ile EEG sinyalinin özellik vektörlerini yüksek boyutlu uzayda ayıran bir hiper-düzlem sayesinde, EEG verilerinin sınıflandırılmasında yüksek performansta sonuçlar elde edilebilir [117].

DVM'de hiper düzlem, çok boyutlu bir alanda düzlemi ayırmasıyla, her sınıfa ait uygun bölgeyi hazırlar. Her sınıfa ait verileri bulmanın asıl amacı, her sınıfa ait örnekleri, yeterince geniş alanda bölmektir. DVM'de görülebilecek fazla uyum veya yetersiz uyum gibi problemleri K-kat çapraz doğrulama yöntemiyle tespit edilebilir [118-119].

3.4.1.5. Çok Katlı Algılayıcı (ÇKA)

Tek katmanlı algılayıcı yarım düzlemli karar bölgeleri oluşturur, çok katmanlı algılayıcı ise karmaşık karar bölgeleri meydana getirir. Biyomedikal sinyallerde özellikle EEG sinyallerini işlemede ve sınıflandırılmasında yararlıdır. ÇKA sınıflandırma yaparken, sınıflar arasında bir sınır belirler ve ölçtüğü özelliklere göre etiketler. Özellik vektörü ile tanımlanan

giriş modelini belirlenmiş olan sınıfa gönderir [120]. Çok katmanlı algılayıcılar giriş, gizli ve çıkış olmak üzere üç tür katmandan oluşan ileri beslemeli ağlardandır. ÇKA'lar, fazla sayıda nöron ve gizli katman eklenerek geliştirilebilir, ancak bu durum eğitim verilerinde aşırı uyumuna, dolayısıyla da performansta sorun teşkil edebilir [121].

ÇKA'nın katmanlarından biri olan giriş katmanı, dışarıdan aldığı bilgiyi nöronlara aktarır ve bu bilgiyi gizli katmana iletir. Gizli katman ise, giriş katmanından aldığı bilgileri işler ve çıkış katmanına iletir. Çıkış katmanı ise, gizli katmandan aldığı işlenmiş bilgi ile veriler için tahmin yaparak çıktı haline getirir. Nöronların aktivasyonu için eşik görevi yapan bias, gizli katman ve çıkış katmanındaki her bir nörona bağlanır [120].

Doğrusal olarak ayrılabilir durumdaki veriler, algılayıcılı olarak nitelendirilen sınıflandırıcı ile basit bir şekilde sınıflandırılabilir. Algılayıcının veri vektörü olarak x, ağırlık vektörü olarak ω, tahmin edilmesi gereken gerçek değer δx ve ω_1 , ω_2 sınıfları için δx sırasıyla + 1 ve - 1 olduğunda, modelin performansını ölçmek amacıyla kayıp fonksiyonu

$$J(\omega)=\sum_x \delta x \omega^T x\text{'dir.} \tag{3.28}$$

Optimizasyon amacıyla ağırlıklar güncellemesi gerekebilmektedir. ω(t) t. iterasyon adımındaki ağırlık vektörü tahmini ve ρ_t güncelleme işleminde ağırlıkların değişimini kontrol eden değer olmak üzere, güncelleme denklemi;

$$\omega(t+1)= \omega(t)-\rho_t \sum_x \delta_x X\text{'dir.} \tag{3.29}$$

Algoritma en uygun çözüme ulaşıncaya kadar tekrarlanır.

$\omega^T X+W_0>0$ x'i ω_1e atarsak (3.30)

$\omega^T X+W_0<0$ x'i ω_2e atarsak (3.31)

Ağırlıkların güncellenmesi tamamlandığında ise bütün veriler için doğru sınıflandırma yapılmış olur. Veriler doğrusal olarak ayrıştırılamadığında ise algılayıcılar, bu verileri ayırt edebilen katmanlar meydana getirebilmek için birleşir ve çok katmanlı algılayıcı yapısı oluşmuş olur [122]. Lojistik regresyona ek olarak bir işlem katmanıyla genelleştirilmesi olarak varsayılabilir [123]. Çok katmanlı algılayıcılar, denetimli öğrenme yöntemlerinden olan sınıflandırma veya regresyon için doğrusal olarak ayrılamayan veri kümelerinde öğrenme gerçekleştirebilir [124].

ÇKA'nın avantajları uygulanması kolay, hızlı ve küçük eğitim setleri ile çalışabilmesidir. ÇKA, iki öklid uzayı elamanlarını birbirine bağlar. Öklid uzayları dizisi; R^{n_1}, R^{n_2} , … … . R^{n_L} ÇKA katmanları sayısı L, olmak üzere uzayları bağlayan F 'in tanımı,

$$F_1{:}R^{n_1}\rightarrow R^{n_1}, F_2{:}R^{n_1}\rightarrow R^{n_1}\ldots\ldots F_{L-1}{:}\ R^{n_{L-1}}\rightarrow R^{n_L} \tag{3.32}$$

Çok katmanlı algılayıcılardaki katmanlar en az bir nörondan meydana gelir. ÇKA, gizli katmanlar ve ağırlıklar ile sigmoidal çekirdek fonksiyonları kullanır. ÇKA'lar birbirine bağlı doğrusal olmayan yapılardır, doğrusal olmayan sınıflandırma için çok uygundur. Özellik vektörlerinin eğitilirken ağırlıklar, istenen ile hesaplanan çıktılar arasındaki hatayı azaltabilmek adına sürekli güncellenir [125].

Bu yapay sinir ağını eğitmek için geri yayılım algoritması olan gradyan iniş verimli bir algoritmadır. Ağ eğitilirken, ağın doğruluğunu artırarak doğru sonuçlar elde etmek için ağırlıklar güncellenir. GDA, kayıp fonksiyonunda ağırlıklara göre hata fonksiyonunun türevi alınır ve ardından ağırlıklar negatif bir gradyana doğru güncellenir. N toplam iterasyon sayısı, q_m beklenen, y_m istenen değer olmak üzere, gradyan kayıp fonksiyonu; [126]

$$\text{E}=\frac{1}{N}\sum_{m=1}^{N}\|q_m - y_m\|^2\text{'dir.} \tag{3.33}$$

ÇKA'larda, eşik mantık birimi (TLU), girişlerdeki her değeri bir ağırlıkla ilişkilendirir ve ağırlıklı toplamı hesaplar.

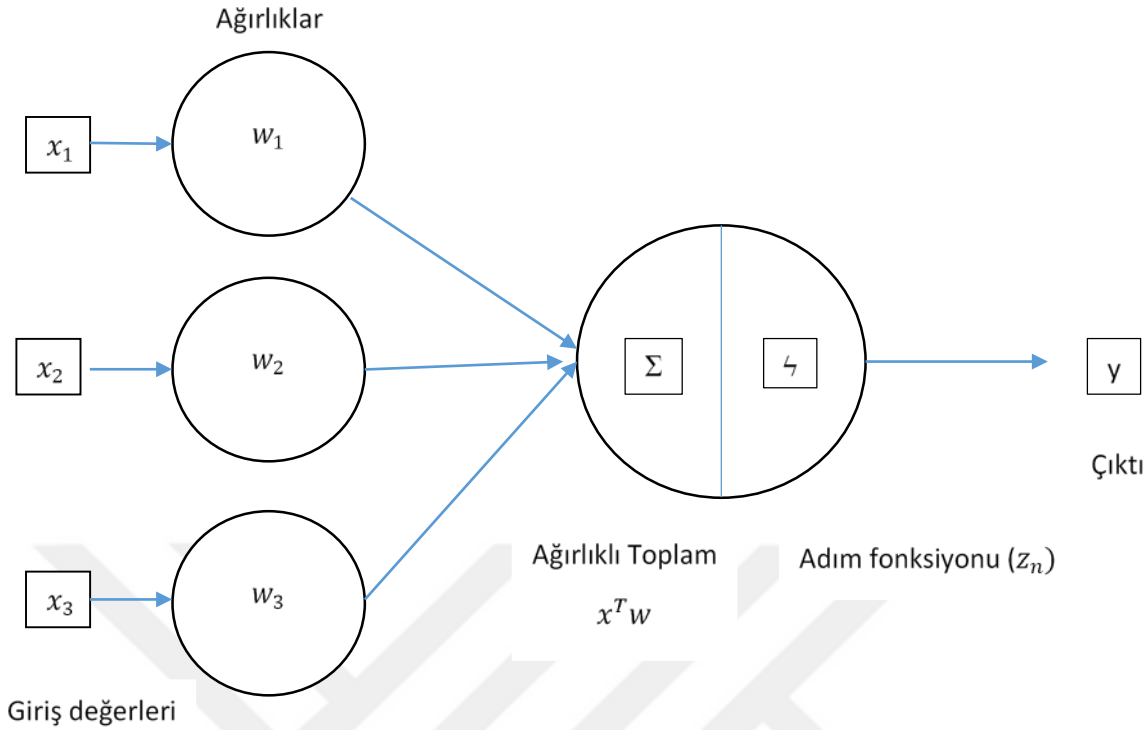
$$\text{Z}=w_1\ x_1+w_2\ x_2+\ldots\ldots w_n\ x_n+=x^T w \tag{3.34}$$

Elde edilen bu toplama bir adım fonksiyonu uygular ve çıktı olarak sonuç elde edilir.

$$y_w(x)=\text{ f }(\sum w_n{*}z_n) \tag{3.35}$$

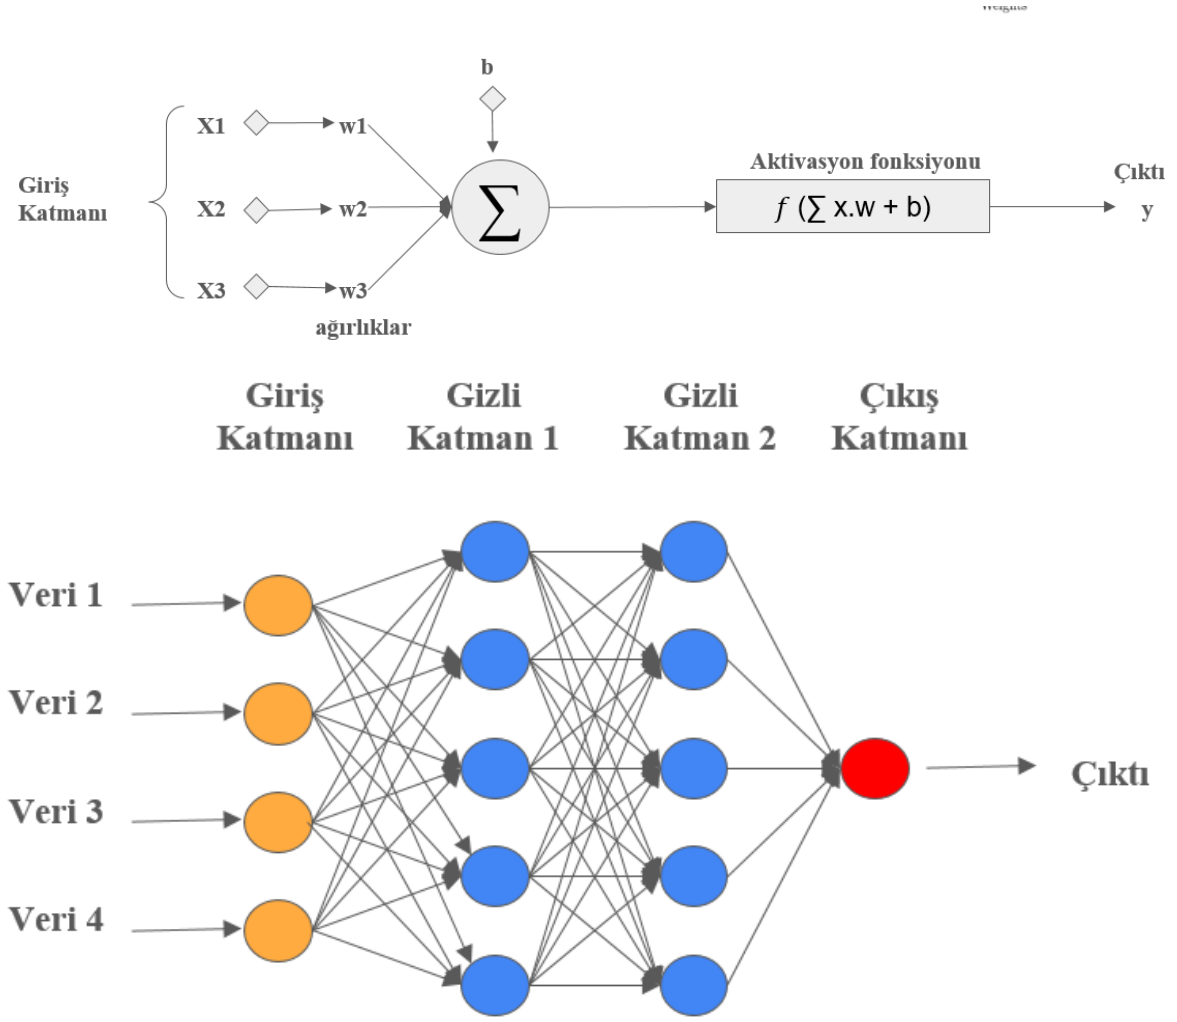
Bir algılayıcı, girişlere bağlı olan bir tane TLU katmanından oluşur.

Şekil 3.12'de x; giriş değerlerini, w; ağırlıkları, z; adım fonksiyonunu, f aktivasyon fonksiyonunu ve y; çıkışı temsil etmektedir. Her x bilgisinin ayrı bir ağırlığı vardır.



Şekil 3.12: Eşik mantık birimi (TLU) [127].

Çok katmanlı algılayıcı, ileri beslemeli bir yapay sinir ağıdır, derin öğrenme yapısına sahiptir. Eğitim aşamasında, geri yayılım algoritması kullanan denetimli öğrenme yöntemlerinden biridir. Gizli katman bir veya birden fazla katmandan oluşabilir ancak, gizli katmandaki düğümleri, kendinden önceki ve sonraki düğümlerle eşleşir. Düğümler aynı katmandaki düğümlerle bağlantı oluşturamaz. Bağlantıların rastgele başlatılan bu ağırlıkları bağlantının gücünü ifade eder. Ağ çıkışı ve gerçek çıktı arasındaki farkı en aza indirmek için ağırlıklar güncellenir. Düğüm girişi ve çıkışı arasında bulunan doğrusal olmayan ilişki aktivasyon fonksiyonu ile gösterilir [128].



Şekil 3.13: ÇKA yapısı [129].

Her katmanın nöronlarının girişini çıkışa eşlemek için bir transfer fonksiyonu kullanılır. Gizli katmanda giriş verileri doğrusal olmayan dönüşüm fonksiyonu kullanılarak doğrusal hale getirilir [130]. Gizli katmanda kullanılan rektifiye doğrusal birim (ReLu) ve çıkış katmanda kullanılan sigmoid en çok kullanılan en yüksek performans gösteren aktivasyon fonksiyonlarındandır [131].

4. BULGULAR

Sınıflandırma amacıyla nöbet öncesi, nöbet ve nöbet sonrası sınıflar için 11 özniteliğe göre topluca bir sınıflandırma yapılmıştır. Daha sonra her bir öznitelik için ayrı ayrı sınıflandırma yapılıp, hangi özniteliklerin çalışma için faydalı olduğu saptanmıştır. Bir diğer sınıflandırma ise, kanallara göre yapılmış olup, en iyi kanal belirlenmeye çalışılmıştır. Ayrıca HFO tabanlı özniteliklere göre de sınıflandırma yapılmıştır.

4.1. İSTATİKSEL VE YAPISAL ÖZNİTELİKLERE GÖRE SINIFLANDIRMA

Tez çalışmasında dalgalanma indeksi (fluctuation index), aktivite (activity), hareketlilik (mobility), karmaşıklık (complexity), ortalama (mean), varyans (variance), ortalama güç (mean power), çarpıklık (skewness), baskınlık (kurtosis), hurst üsteli (hurst exponent) ve ortalama entropy (approximate entropy) öznitelikleri çıkartılmıştır. Nöbet öncesi, nöbet ve nöbet sonrası olmak üzere üç ayrı sınıfın her biri için 56 bölünmüş veri ile çalışılmıştır. Toplam 14 kanalın her biri ile bu üç sınıf için belirlenen 11 öznitelik için sınıflandırma çalışması yapılmıştır.

Tablo 4.1: İstatiksel ve yapısal özniteliklere göre ÇKA sınıflandırıcısı sonuçları

ÇKA	TP Rate	FP Rate	ROC Alanı	PRC Alanı
Nöbet Öncesi	0,857	0,045	0,981	0,961
Nöbet	0,750	0,080	0,930	0,847
Nöbet Sonrası	0,768	0,188	0,880	0,797

ÇKA sınıflandırıcısının özniteliklere göre bakıldığında %78.33 doğruluk oranına sahip olduğu görülmüştür. Ortalama mutlak değer 0.1401 olup, toplam 168 örnekten 133 tanesi doğru sınıflandırılmıştır. Standart sapma ise 1,9 olarak hesaplanmıştır.

Tablo 4.2: İstatiksel ve yapısal özniteliklere göre ÇKA sınıflandırıcısına ait hata matrisi

Nöbet Öncesi	Nöbet	Nöbet Sonrası	Sınıf
48	1	7	**a**
0	42	14	**b**
5	8	43	**c**

Hata matrisi incelendiğinde, ÇKA sınıflandırıcısı, a sınıfı nöbet öncesi olmak üzere 56 nöbet öncesi örneğinden 48 tanesini nöbet öncesi, 1 tanesini nöbet ve 7 tanesini nöbet sonrası olarak sınıflandırmıştır. Sınıflandırıcı b nöbet sınıfı olmak üzere; 56 nöbet verisinin 42 tanesini nöbet ve 14 tanesini nöbet sonrası olarak sınıflandırmıştır. 56 nöbet sonrası verisinden ise c nöbet sonrası sınıfı olmak üzere, 43 tanesini nöbet sonrası, 5 tanesini nöbet öncesi ve 8 tanesini nöbet olarak sınıflandırmıştır. En yüksek doğruluk oranı nöbet öncesi sınıfta elde edilmiştir.

Tablo 4.3: İstatiksel ve yapısal özniteliklere göre K-NN sınıflandırıcısı sonuçları

K-NN	TP Rate	FP Rate	ROC Alanı	PRC Alanı
Nöbet Öncesi	0,839	0,054	0,963	0,927
Nöbet	0,768	0,045	0,926	0,846
Nöbet Sonrası	0,839	0,179	0,905	0,861

k-NN sınıflandırıcısının % 80,77 doğruluk oranına sahip olduğu görülmüştür. Ortalama mutlak hata değeri 0.1809 olup, standart sapma 1,24 olarak hesaplanmıştır. Toplam 168 örnekten 137 tanesi doğru sınıflandırılmıştır.

Tablo 4.4: İstatiksel ve yapısal özniteliklere göre K-NN sınıflandırıcısı hata matrisi

Nöbet Öncesi	Nöbet	Nöbet Sonrası	Sınıf
47	0	9	**a**
2	43	11	**b**
4	5	47	**c**

k-NN sınıflandırıcısı incelendiğinde 56 nöbet öncesi verisinden 47 tanesi nöbet öncesi, 9 tanesi nöbet sonrası, 56 nöbet verisinden 43 tanesi nöbet, 2 tanesi nöbet öncesi ve 11 tanesi nöbet sonrası olarak sınıflandırılmıştır. Yine 56 nöbet sonrası verisinden ise 47 tanesi nöbet sonrası, 4 tanesi nöbet öncesi ve 5 tanesi nöbet olarak sınıflandırılmıştır. En yüksek doğruluk nöbet öncesi ve nöbet sonrası sınıflarında elde edilmiştir.

Tablo 4.5: İstatiksel ve yapısal özniteliklere göre RF sınıflandırıcısı sonuçları

RF	TP	FP	ROC Alanı	PRC Alanı
Nöbet Öncesi	0,875	0,027	0,984	0,972
Nöbet	0,839	0,080	0,948	0,886
Nöbet Sonrası	0,786	0,143	0,902	0,839

Rastgele Orman sınıflandırıcısı için doğruluk oranı %83.145, standart sapma 1.88 çıkmıştır. Ortalama mutlak değer ise 0.288'dir. 168 örnekten 140 tanesi doğru sınıflandırılmıştır.

Tablo 4.6: İstatiksel ve yapısal özniteliklere göre RF sınıflandırıcısı için hata matrisi

Nöbet Öncesi	Nöbet	Nöbet Sonrası	Sınıf
49	0	7	**a**
0	47	9	**b**
3	9	44	**c**

Hata matrisi incelendiğinde rastgele orman sınıflandırıcı, 56 nöbet öncesi verisinin 49 tanesini nöbet öncesi ve 7 tanesini nöbet sonrası olarak sınıflandırmıştır. Yine 56 nöbet verisinin 47 tanesini nöbet, 9 tanesini de nöbet sonrası olarak sınıflandırmıştır. 56 nöbet sonrası verisinin ise 44 tanesini nöbet sonrası, 3 tanesini nöbet öncesi ve 9 tanesini nöbet olarak sınıflandırmıştır. En doğru oranlar nöbet öncesi veriler için çıkmıştır.

Tablo 4.7: İstatiksel ve yapısal özniteliklere göre Bayes sınıflandırıcısı sonuçları

Bayes	TP	FP	ROC Alanı	PRC Alanı
Nöbet Öncesi	0,786	0,089	0,916	0,776
Nöbet	0,786	0,080	0,921	0,789
Nöbet Sonrası	0,679	0,205	0,737	0,530

Sınıflandırıcı için doğruluk oranı %74.28, standart sapma 1,77 hesaplanmıştır. Ortalama mutlak hata 0.2817 bulunmuştur. Toplam 168 örnekten 126 tanesini doğru sınıflandırmıştır.

Tablo 4.8: İstatiksel ve yapısal özniteliklere göre Bayes sınıflandırıcısı için hata matrisi

Nöbet Öncesi	Nöbet	Nöbet Sonrası	Sınıf
44	1	11	**a**
0	44	12	**b**
10	8	38	**c**

Hata matrisi için 56 nöbet öncesi verisinden 44 tanesi nöbet öncesi, 1 tanesi nöbet ve 11 tanesi nöbet sonrası olarak bulunmuştur. 56 nöbet verisinden 44 tanesi nöbet ve 12 tanesi nöbet sonrası olarak bulunmuştur. 56 nöbet sonrası verisinden 38 tanesi nöbet sonrası, 10 tanesi nöbet öncesi ve 8 tanesi nöbet olarak bulunmuştur. En yüksek değerler, nöbet öncesi ve nöbet sınıflarında çıkmıştır.

Tablo 4.9: İstatiksel ve yapısal özniteliklere göre DVM sınıflandırıcısı sonuçları

DVM	TP	FP	ROC Alanı	PRC Alanı
Nöbet Öncesi	0,839	0,036	0,963	0,940
Nöbet	0,821	0,080	0,956	0,897
Nöbet Sonrası	0,786	0,161	0,871	0,788

DVM sınıflandırıcısı ile %80,249 doğruluk oranı elde edilmiştir. Standart sapma 0,775, ortalama mutlak hata değeri 0,1243 çıkmıştır. Toplam 168 örneğin 138 tanesi doğru sınıflandırılmıştır.

Tablo 4.10: İstatiksel ve yapısal özniteliklere göre DVM sınıflandırıcısı için hata matrisi

Nöbet Öncesi	Nöbet	Nöbet Sonrası	Sınıf
47	0	9	**a**
0	46	9	**b**
9	9	44	**c**

DVM sınıflandırıcısının hata matrisinde 56 nöbet öncesi örneğinden 47 tanesi nöbet öncesi, 9 tanesi nöbet sonrası olarak sınıflandırılmıştır. 56 nöbet verisinden 46 tanesi nöbet, 1 tanesi nöbet öncesi ve 9 tanesi nöbet sonrası olarak sınıflandırılmıştır. 56 nöbet sonrası verisinden 44 tanesi nöbet sonrası, 3 tanesi nöbet öncesi ve 9 tanesi nöbet verisi olarak sınıflandırılmıştır. En doğru sınıflandırılan nöbet öncesi sınıfıdır.

Tablo 4.11: İstatistiksel ve yapısal özniteliklere göre sınıflandırıcı doğruluk oranları

Sınıflandırıcı	Doğruluk Oranı (%)
Rastgele Orman	83,145
K-NN	80,77
DVM	80,249
ÇKA	78,33
Bayes	74,28

İstatistiksel ve yapısal özniteliklere göre özniteliklere göre sınıflandırıcılara bakıldığında, en yüksek doğruluk oranı %83,145 ile rastgele orman sınıflandırıcısına aittir.

Tablo 4.12: Özniteliklerin her birine göre sınıflandırıcı sonuçları

	RF (%)	k-NN (%)	BAYES (%)	DVM (%)	ÇKA (%)
ORTALAMA	57,6±1,4	53±1,2	61±1,4	35,3±1	42,1±0,9
ORTALAMA GÜÇ	75,1±0,6	66,9±1	71,3±1,5	37±0,4	45,9±1,8
VARYANS	72,6±0,8	63,46±2	69,8±1,7	36,78±1,1	43±1,9
YAKLAŞIK ENTROPİ	78,9±2,5	76,3±1,1	54,4±1,4	57,7±0,65	77,8±2,2
HURST ÜSTELİ	70,5±0,6	72,7±0,9	61,5±0,7	70±0,8	72,2±1,5
AKTİVİTE	72,6±0,65	55,68±0,9	69,2±1,5	34,8±1	42,7±3,4
MOBİLİTE	64,3±1,6	62,9±1,4	51,4±1,8	53,5±0,9	70,2±2,4
KARMAŞILIKLIK	79±2,5	76,3±1	65,7±1,3	67,6±1	77,8±2,1
ÇARPIKLIK	50,1±3,3	39,2±1	41±1,3	48,4±1,2	45,9±2,9
BASIKLIK	50,9±2,3	53,2±2,4	40,7±2,1	45,7±1	47,9±3,2
DALGALANMA İNDEKSİ	46,1±4,1	46±1,2	40,5±1,6	36,8±2,1	38,9±2,1

Ortalama özniteliği için, en iyi sınıflandırma sonucu Bayes sınıflandırıcısında elde edilmiş olup, ortalama özniteliğinin sınıflandırıcılara göre ortalama değeri 49,8 olarak belirlenmiştir. Ortalama güç için en yüksek değer rastgele orman sınıflandırıcısında çıkmış olup, ortalama güç özniteliğinin ortalaması 59,24'tür. Varyans için en iyi değer çok katlı algılayıcı ile çok yakın olmakla birlikte rastgele orman sınıflandırıcısında elde edilmiştir. Varyansın ortalama değeri 57,13 olarak hesaplanmıştır. Yaklaşık entropi için en iyi sonuç yine rastgele orman sınıflandırıcısında elde edilmiştir. Yaklaşık entropinin sınıflandırıcılar içinde ortalaması 69,02'dir. Hurst üstelinin en iyi sınıflandırılması k-NN sınıflandırıcısı ile elde edilmiştir. Hurst üstelinin tüm sınıflandırıcılarda ortalaması ise, 69,38 olarak elde edilmiştir. Hjorth parametrelerinden olan aktivite için en yüksek değerde sonuç rastgele orman

sınıflandırıcısı ile çıkmıştır, sınıflandırıcılar içindeki ortalaması ise 55'tir. Diğer bir hjorth parametresi olan mobilitenin en yüksek sınıflandırma değeri çok katmanlı algılayıcıda elde edilmiş olup, ortalaması 60,46'dır.Yine hjorth parametrelerinden olan karmaşıklığın en yüksek değeri rastgele orman sınıflandırıcısında elde edilmiştir. Karmaşıklığın diğer sınıflandırıcılarla birlikte ortalaması 73,28'dir. Çarpıklık için en iyi sınıflandırma değeri rastgele orman sınıflandırıcısında çıkmış olup, ortalama değeri 44,92 olarak hesaplanmıştır. Basıklık için K-NN sınıflandırıcısı en iyi değeri vermiş olup, ortalama basıklık değeri 47,68'dir. Son olarak basıklık özniteliği için rastgele orman ve k-NN sınıflandırıcısı değerleri çok yakın olmakla birlikte rastgele orman sınıflandırıcısında daha yüsek çıkmıştır, ancak standart sapma değerlerine bakıldığında K-NN sınıflandırıcısında daha iyi olduğu görülmüştür. Özniteliklere bakıldığında çalışılan veri seti için karmaşıklık özniteliği %79 ile en yüksek değere sahip olup, rastgele orman sınıflandırıcısı ile elde edilmiştir.

4.2. KANALLARA GÖRE SINIFLANDIRMA

Belirlenen 14 kanal için, öznitelikler için kullanılan sınıflandırıcılar uygulanmıştır.

Tablo 4.13: Kanallara göre sınıflandırıcı sonuçları

	BAYES (%)	**DVM (%)**	**K-NN (%)**	**RF (%)**	**ÇKA (%)**
1.Kanal	71,25±2,35	71,19±0,76	71,07±1,20	77,97±2,03	71,90±1,63
2.Kanal	71,72±1,36	73,62±0,96	76,25±1,29	77,56±1,16	72,14±1,18
3. Kanal	74,88±1,95	67,26±0,80	73,45±1,51	77,79±2,06	73,27±2,09
4. Kanal	64,94±2,05	59,82±1,04	71,13±0,93	74,46±1,69	71,78±2,44
5 .Kanal	70,65±1,0	64,52±0,66	67,55±1,14	75,17±1,81	70,53±2,49
6.Kanal	66,13±3,22	70±1,17	67,38±0,74	72,32±1,71	69,34±2,07
7.Kanal	71,13±1,49	63,63±1,54	70,23±1,92	77,56±0,96	69,40±1,60
8.Kanal	73,69±1,22	59,70±1,44	63,21±1,76	75,35±1,89	64,70±2,31

9.Kanal	63,81±1,97	55,23±1,02	63,51±1,31	71,42±2,15	65,06±3,51
10.Kanal	66,84±1,62	52,14±0,97	65,47±1,64	73,69±1,24	64,28±1,94
11.Kanal	70,83±1,53	56,48±1,59	64,40±1,24	73,39±1,39	65,18±2,72
12.Kanal	60,29±1,71	42,62±2,41	68,69±1,51	65,12±1,67	58,33±1,70
13.Kanal	55,29±2,20	53,80±2,37	68,45±0,90	70,95±1,74	67,67±1,43
14.Kanal	60,41±2,56	59,76±1,77	68,86±1,07	69,52±1,52	67,20±3,24

Tablo 4.13. (Devam)

Veri seti için seçilmiş 14 kanalın sınıflandırması incelendiğinde kanalların genel olarak ortalama değerleri birbirine yakın olmakla birlikte, en yüksek sınıflandırma değeri rastgele orman sınıflandırıcısı ile %77,97 değerine sahip olarak 1. kanalda elde edilmiştir. En düşük değer ise %42,62 ile 12. Kanalda DVM sınıflandırıcısı ile çıkmıştır. Bütün kanallarda en yüksek sınıflandırma değeri yine rastgele orman sınıflandırıcı ile elde edilmiştir. Kanallara ait ortalama değerler aşağıdaki tablo 4.15.'te belirtilmiştir.

Tablo 4.14: Sınıflandırıcılara göre kanalların ortalama değerleri

Bayes	69,50%
DVM	60,69%
K-NN	73,55%
RF	73,73%
ÇKA	67,91%

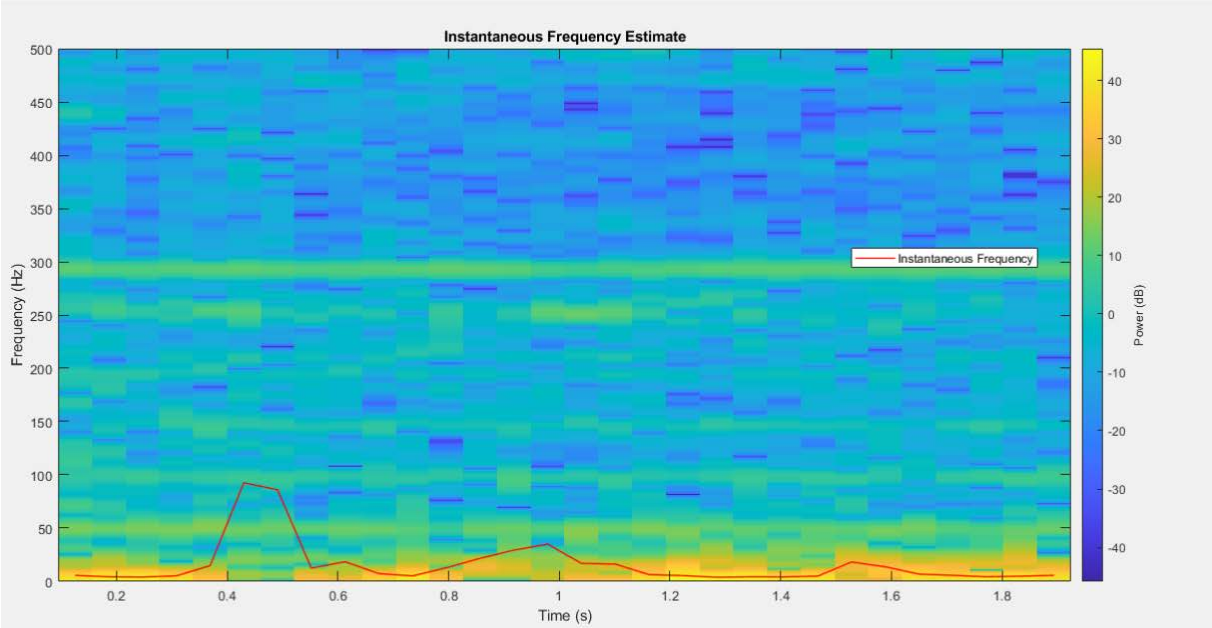
Tablo 4.15: Kanallara göre ortalama değerler

Kanallar	Ortalama Değer (%)
1.Kanal	72,68
2.Kanal	74,26
3. Kanal	73,33
4. Kanal	68,43
5 .Kanal	69,68
6.Kanal	69,03
7.Kanal	70,39
8.Kanal	67,33
9.Kanal	63,81
10.Kanal	64,48
11.Kanal	66,06
12.Kanal	59,01
13.Kanal	63,23
14.Kanal	65,15

4.3. HFO TABANLI ÖZNİTELİKLERE GÖRE SINIFLANDIRMA

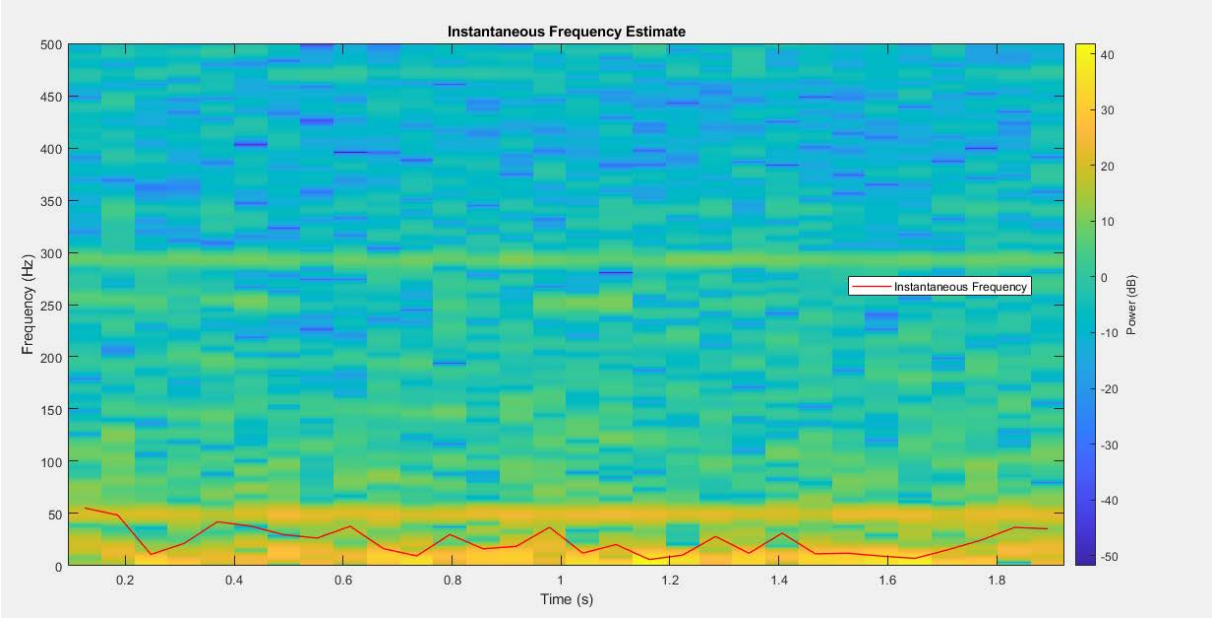
İntrakraniyel EEG veri setinden belirlenen 14 kanala göre, nöbet öncesi, nöbet ve nöbet sonrası sınıflar için Matlab 2021b programı ile edf formatında alınan veriler incelenmiştir. Öncelikle her bir sınıf ve her bir örnek için ayrı ayrı HFO incelenmesi yapılmıştır. Görsel inceleme sonucunda 14 kanal içinde en iyi kanallar 8., 12., ve 14. kanal olarak seçilmiş olup, daha sonra bu kanallara ait sınıflandırmalar da yapılmıştır.

Baz alınan aynı kanallarda nöbet öncesi, nöbet ve nöbet sınıflarındaki farklılıklar aşağıdaki şekillerde verilmiştir. Öncelikle nöbet öncesi sınıfında önemli olduğu düşünülen bir örneğe ait 8.,12.,ve 14. kanallara ait şekiller verilmiştir. Daha sonra aynı kanallar için aynı örnekteki durum diğer sınıflar için karşılaştırılmıştır.



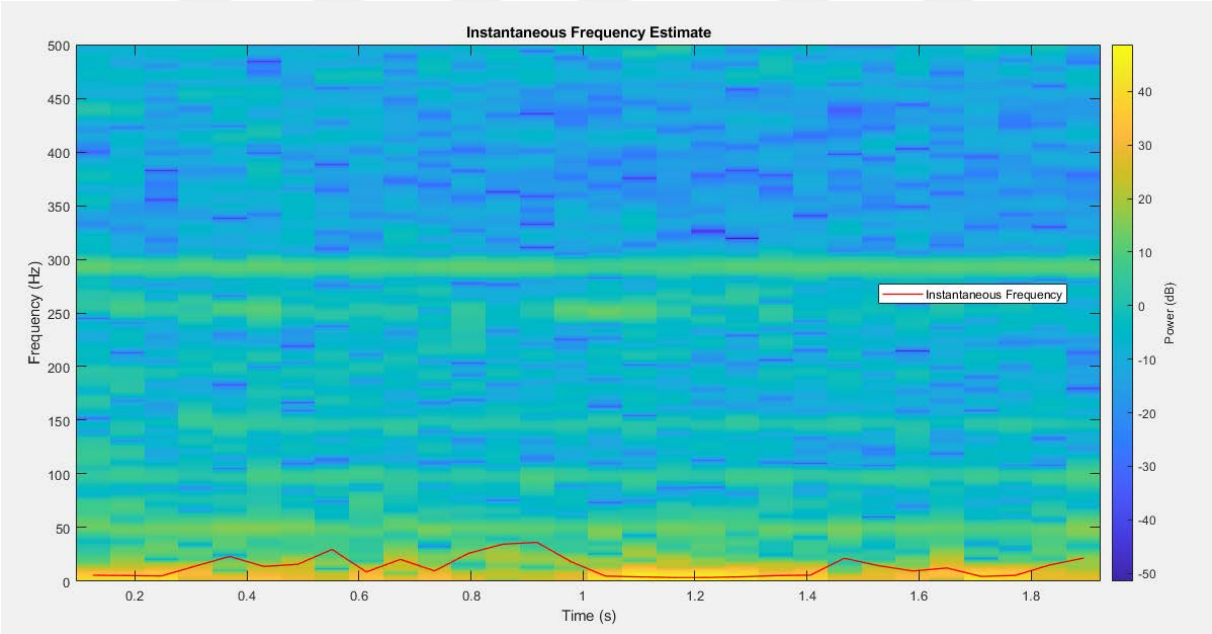
Şekil 4.1: Nöbet öncesi 35. örneğe ait 8. kanalın frekans gösterimi

Şekil 4.1.'de nöbet öncesi sınıfından 35. örneğe ait verinin 8. Kanalına ait frekans gösteriminde band halinde 100 Hz,150 hz, 250 hz ve 300 Hz'de frekans yoğunlukları incelenmektedir.



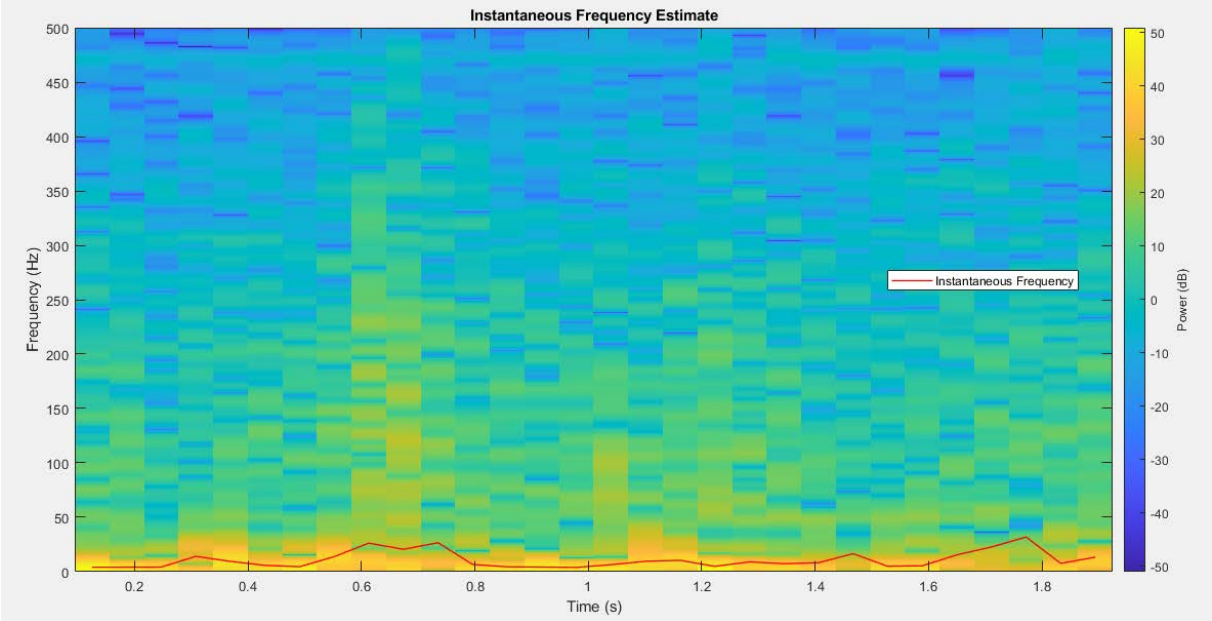
Şekil 4.2: Nöbet öncesi 35. örneğe ait 12. kanalın frekans gösterimi

Aynı örneğin 12. kanalındaki frekans dağılımı şekil 4.2.'de izlenmektedir. Yine 8. kanalda olduğu gibi frekans gösterimleri benzerdir.



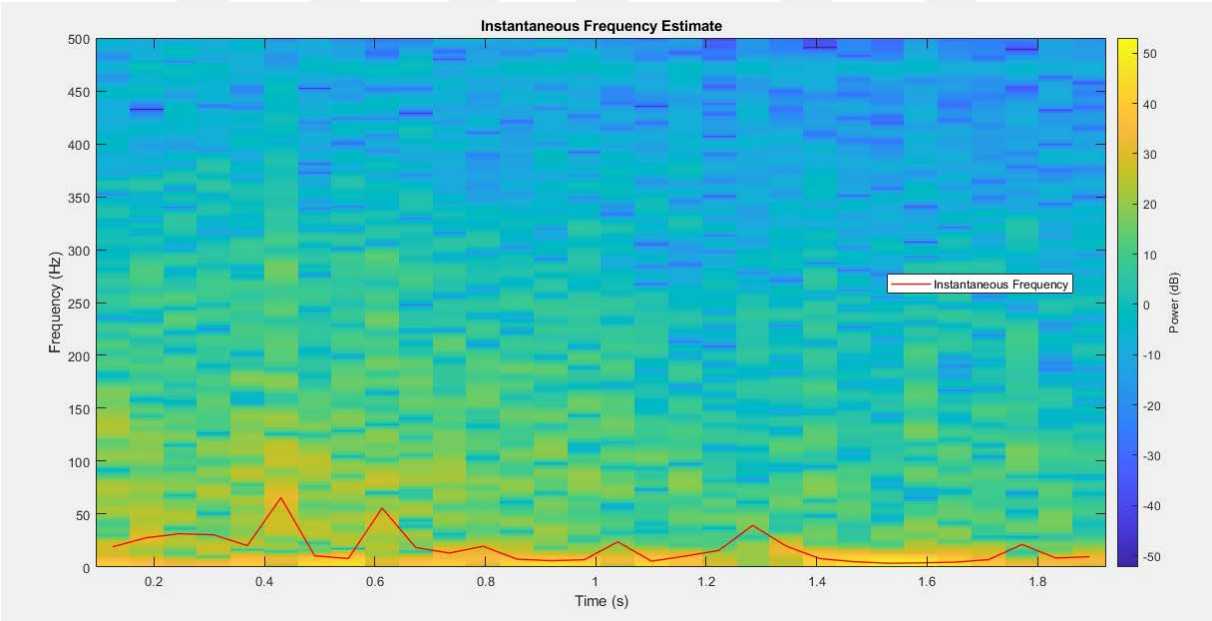
Şekil 4.3: Nöbet öncesi 35. örneğe ait 14. kanalın frekans gösterimi

Nöbet öncesi sınıfın 35. örneğinin 14. kanalında yine aynı dağılımları görmekteyiz. Bu örnek için, bu önemli olan üç kanalın frekans benzerlikleri bulunmaktadır.



Şekil 4.4: Nöbet sınıfı 35. örneğe ait 14. kanalın frekans gösterimi

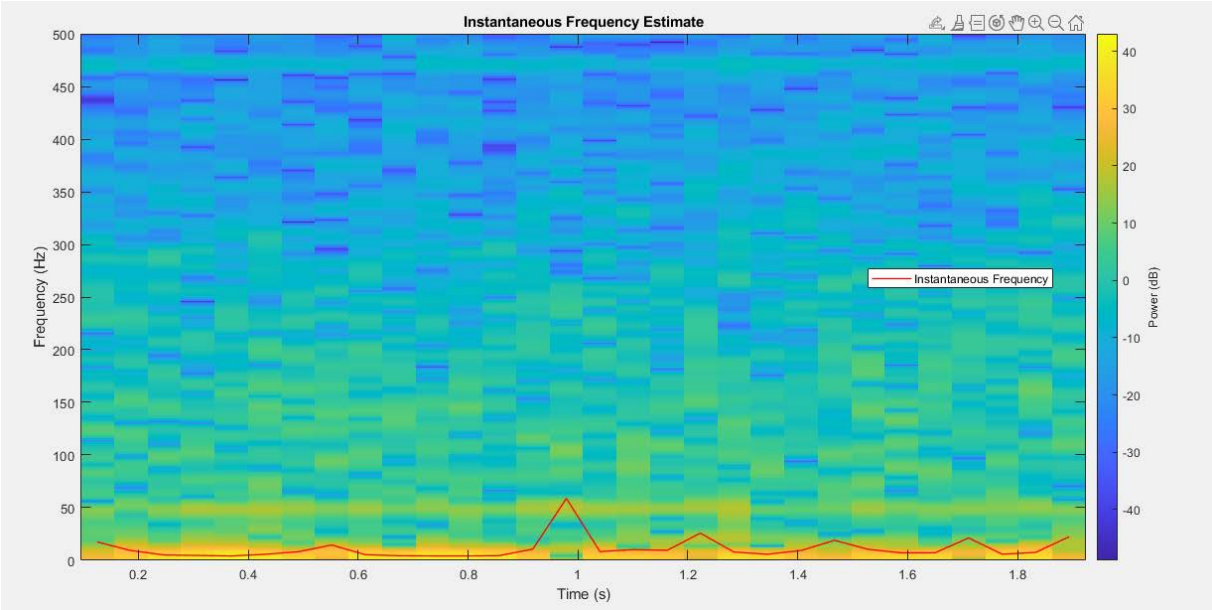
Nöbet öncesi sınıfında her üç kanalda da yüksek frekansları gösteren örnek, nöbet sınıfında her üç kanalda da herhangi bir benzer frekans dağılımı göstermemiştir.



Şekil 4.5: Nöbet sonrası 35. örneğe ait 14. kanalın frekans gösterimi

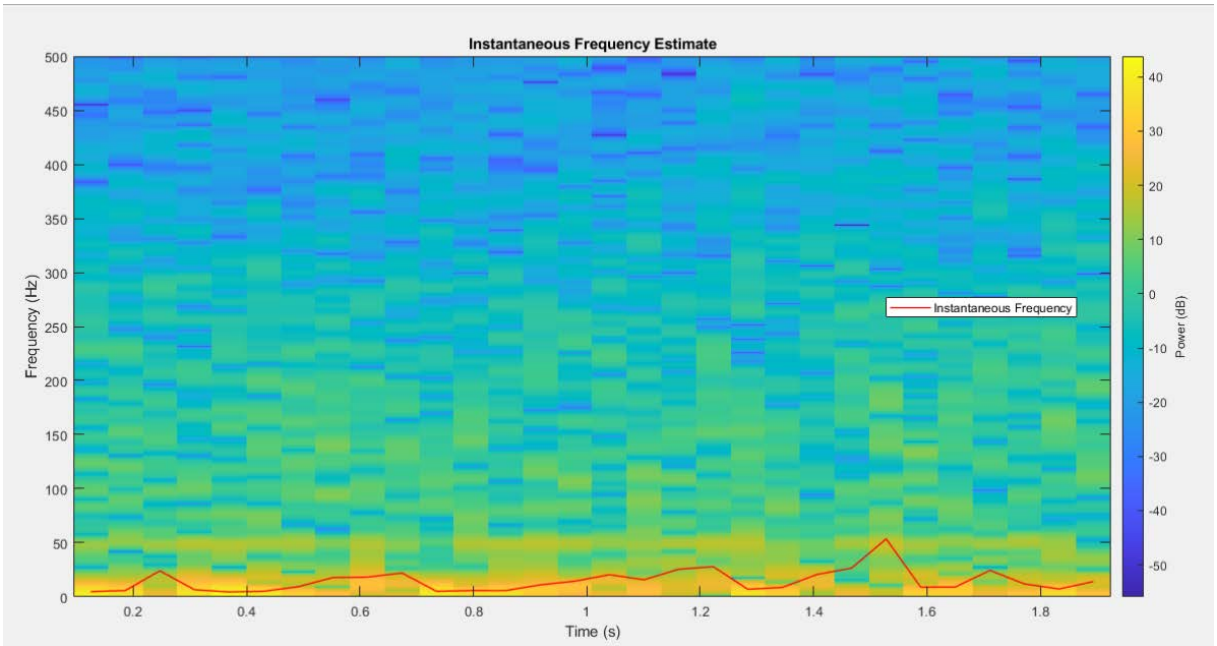
Nöbet sonrası sınıfında da yine nöbet sınıfında olduğu gibi herhangi bir HFO aktivitesi görülmemiştir.

Şekil 4.6, 4.7, ve 4.8.'de nöbet verisinden aynı örneğe ait farklı kanallardaki frekans karşılaştırması görülmektedir.



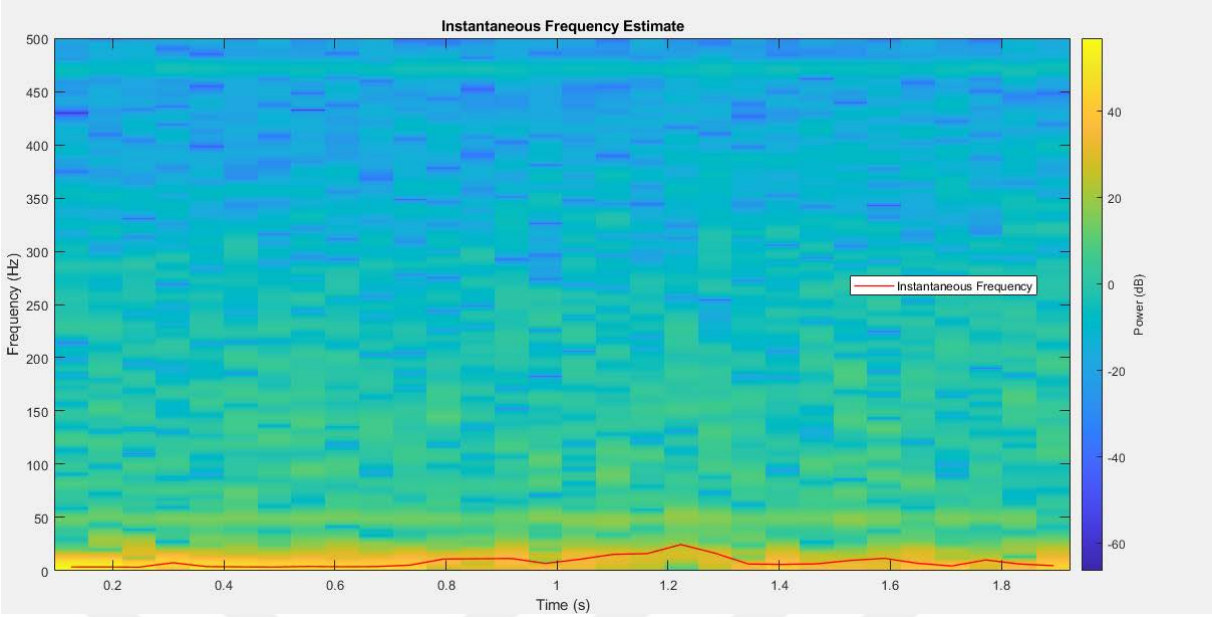
Şekil 4.6: Nöbet sınıfı 20. örneğe ait 8. kanalın frekans gösterimi

Nöbet verisinin 20. örneğinde 8. kanalındaki frekans gösterimi şekilde görülmektedir. 450-500 Hz bandında frekans aktivitesi görülmektedir.



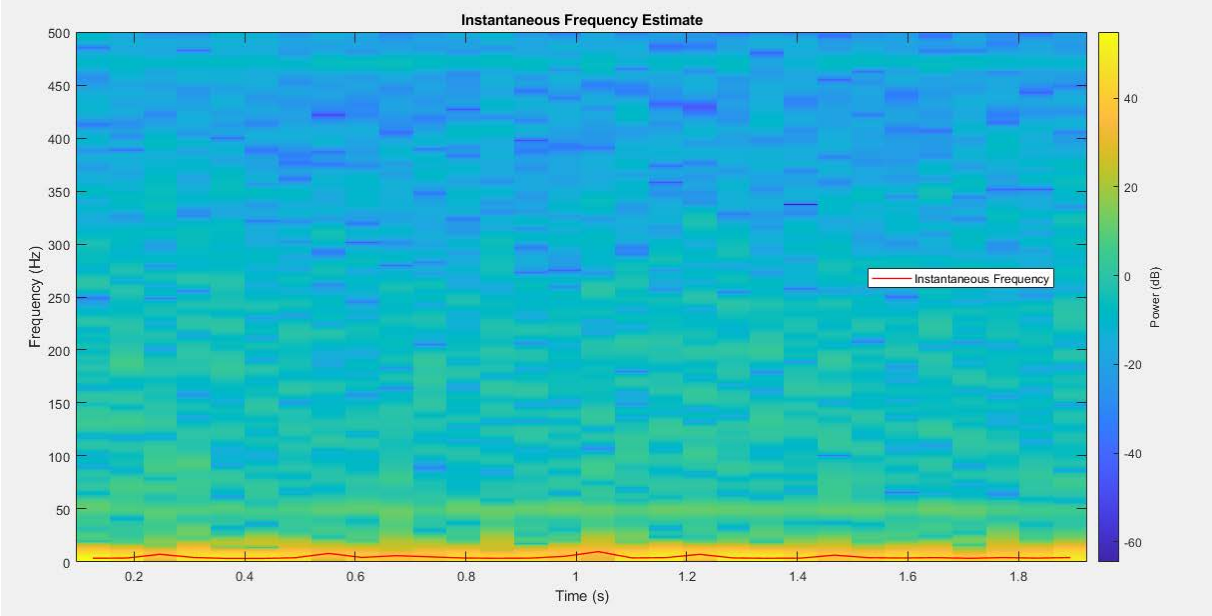
Şekil 4.7: Nöbet sınıfı 20. örneğe ait 12. kanalın frekans gösterimi

Nöbet verisi 20. örneğin 12. kanalında ise herhangi bir aşırı aktivite görülmemektedir.



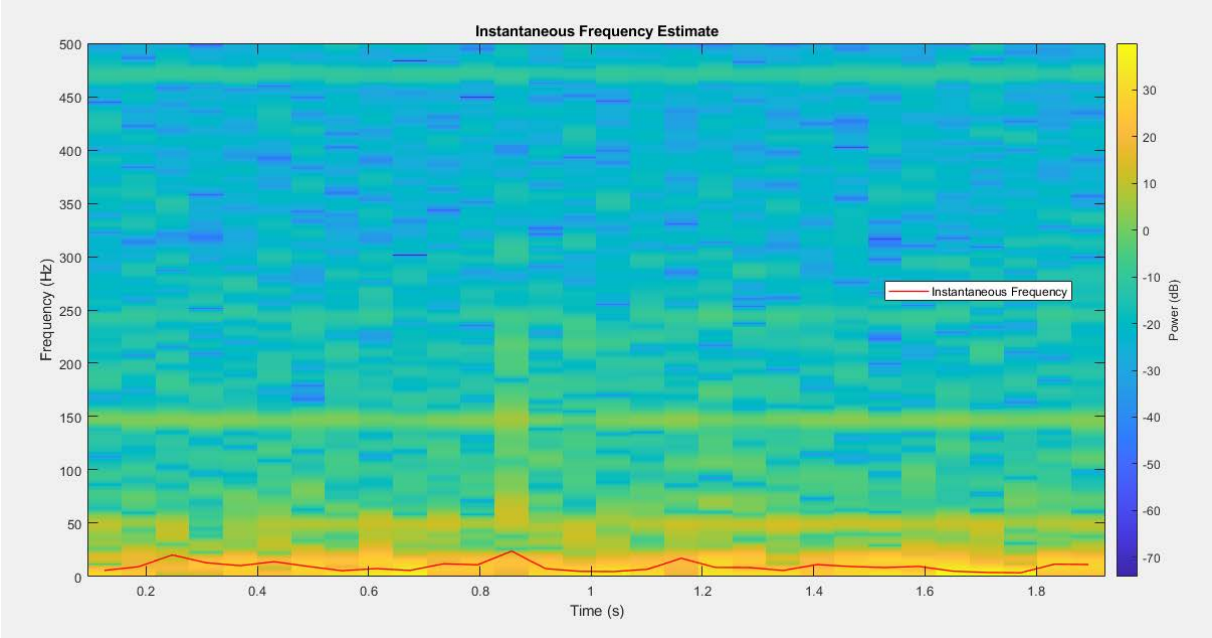
Şekil 4.8: Nöbet sınıfı 20. örneğe ait 14. kanalın frekans gösterimi

Nöbet verisi 20. örneğin 14. kanalına bakıldığında yine 400-500 Hz aralığında yüksek frekans aktivitesi görülmektedir. Kanallar arasındaki yukarıdaki üç şekil de 20. örneğe ait nöbet verisidir.14. ve 8. kanalda HFO bandı görülürken,12. kanalda görülememektedir.



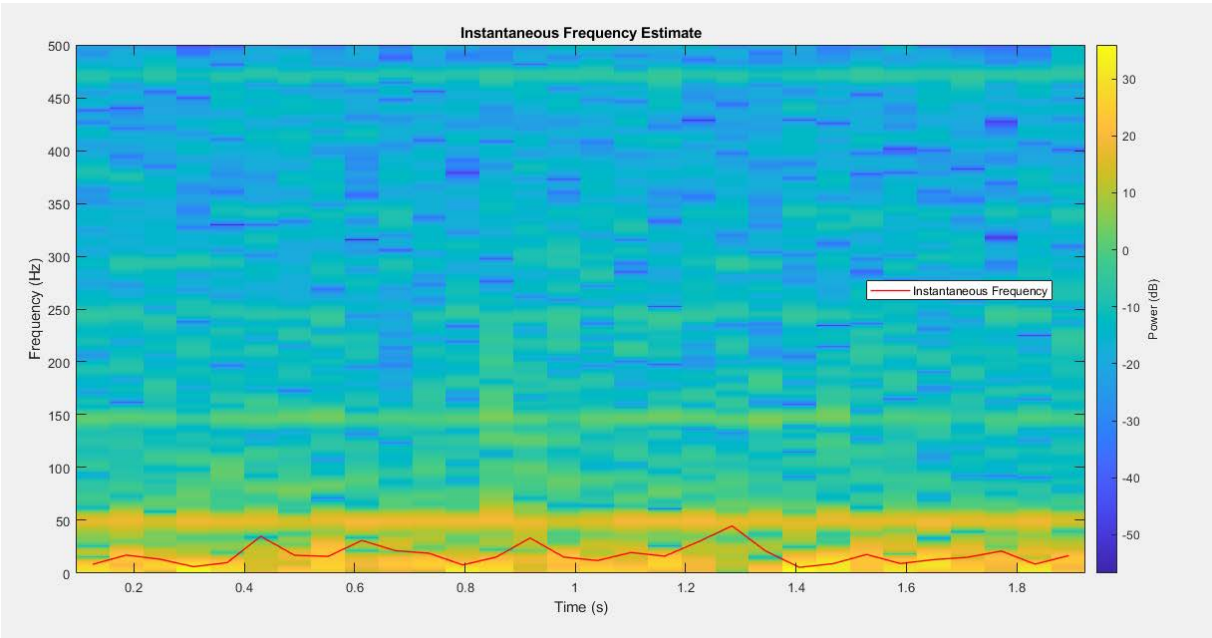
Şekil 4.9: Nöbet sonrası 20. örneğe ait 14. kanalın frekans gösterimi

Nöbet verisinde incelenen 20. örneğin nöbet sonrası verisine bakıldığında 8. ve 12. kanallarda herhangi bir yüksek frekans aktivitesi görülmemiştir ancak şekil 4.8'de görüldüğü gibi 14. kanalda yine 450-500 Hz'de hafif de olsa bir aktivite görülebilmektedir.



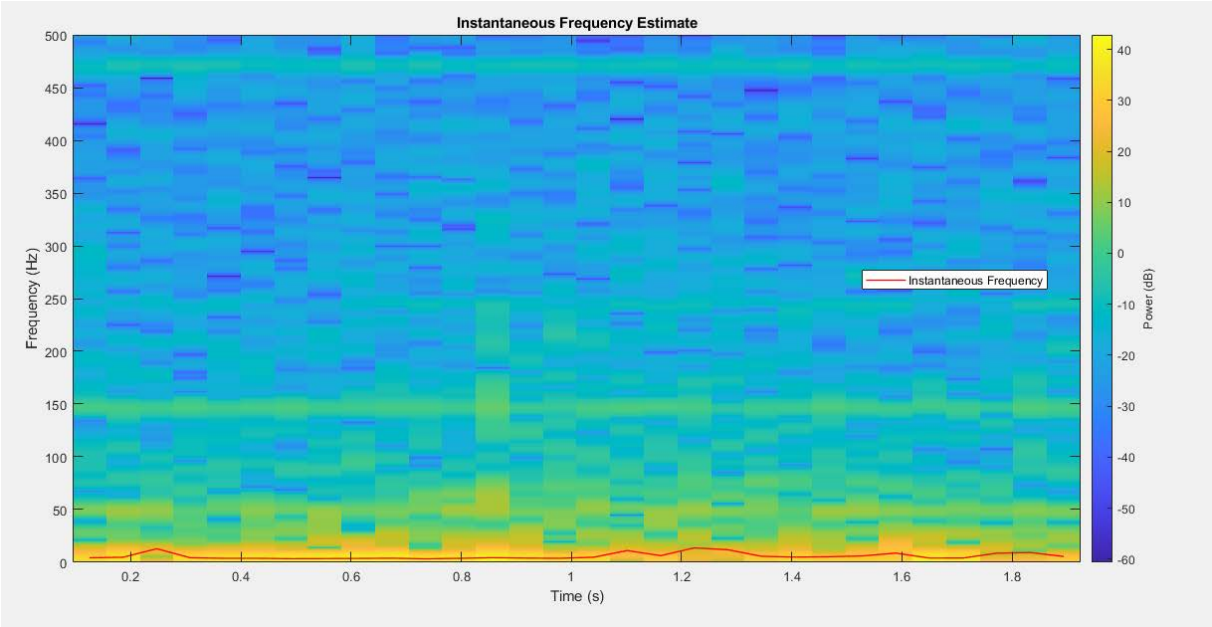
Şekil 4.10: Nöbet öncesi 20. örneğe ait 8. kanalın frekans gösterimi

EEG verilerinden 20. örneğin nöbet öncesi 8. kanalı için frekansı incelendiğinde özellikle 150 Hz' de ve 450-500 Hz aralığında yüksek frekans aktiviteleri görülebilmektedir.



Şekil 4.11: Nöbet öncesi 20. örneğe ait 12. kanalın frekans gösterimi

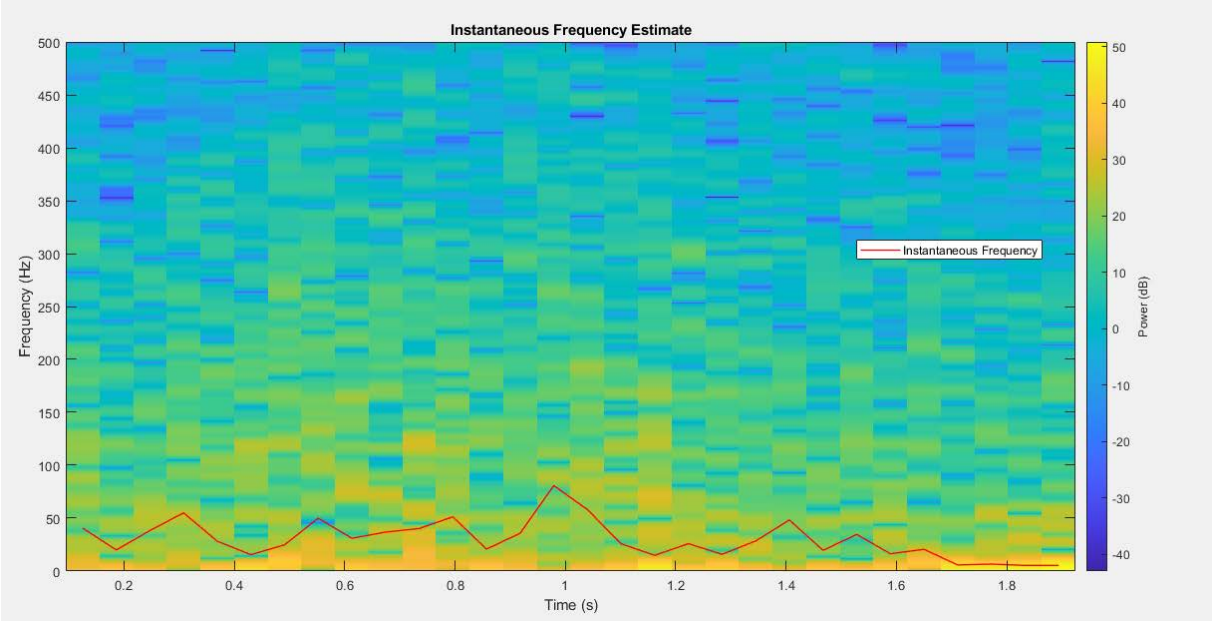
20. örneğin nöbet öncesi 12. kanalı için frekansı için de yine 8. kanalında olduğu gibi, 150 Hz' de ve 450-500 Hz aralığında yüksek frekans aktiviteleri görülebilmektedir



Şekil 4.12: Nöbet öncesi 20. örneğe ait 14. kanalın frekans gösterimi

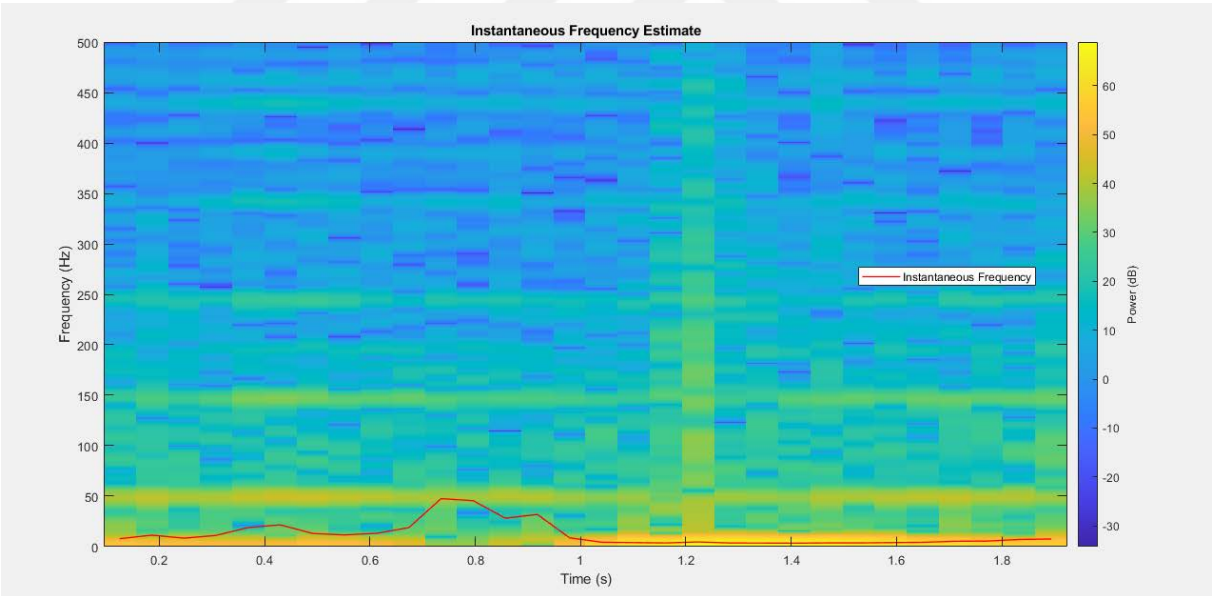
20. örneğin nöbet öncesi 14. kanalında ise 8. ve 12. kanalda olduğu gibi diğer iki kanaldaki aynı frekans aralıkları gözlenmiştir. 20. örnek için, nöbet öncesi sınıfında net olarak yüksek frekans bandları görülmekte olup, nöbet sınıfı için de iki kanal da nöbet öncesindeki kadar net ve yoğun olmasa da aktiviteler izlenebilmektedir, ancak nöbet sonrası verisinde her üç kanalda da herhangi bir aktivite yoktur.

Bir sonraki veri örneğinde ve aynı kanallarda nöbet öncesi, nöbet ve nöbet sonrası durumları karşılaştırılmıştır.



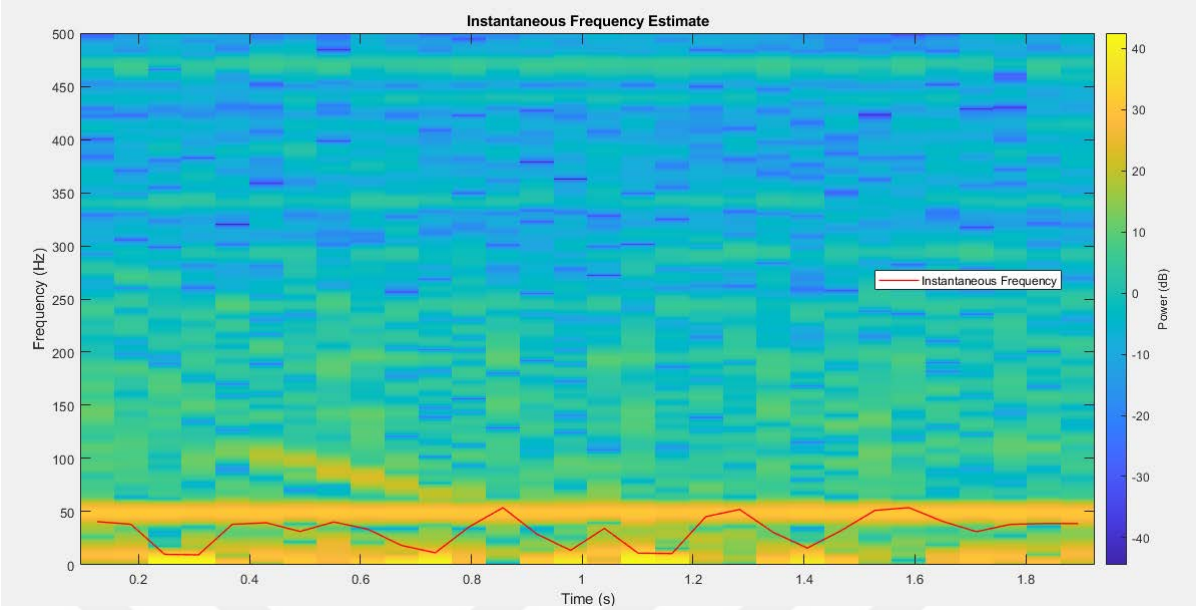
Şekil 4.13: Nöbet öncesi 50. örneğe ait 12. kanalın frekans gösterimi

50 . örneğin nöbet öncesi 12. kanalında yüksek frekans aktivitesi görülmemektedir.



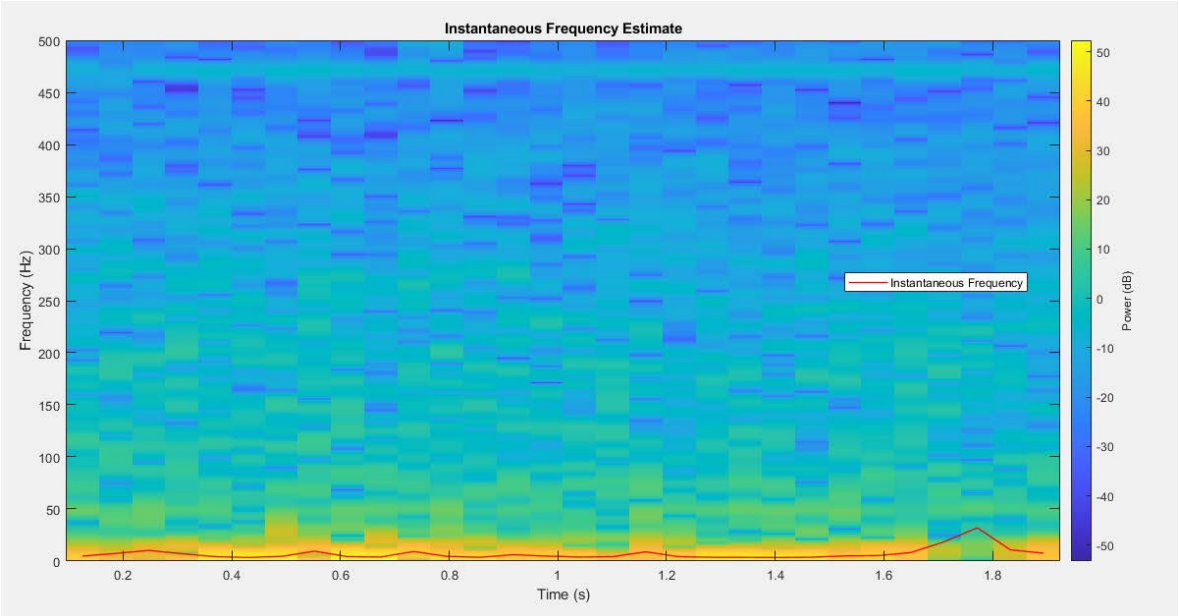
Şekil 4.14: Nöbet sınıfı 50. örneğe ait 12. kanalın frekans gösterimi

50. örneğin nöbet verisinde ise 12. Kanalda 150 Hz, 250 Hz, 350 Hz ve 450-500 Hz aralıklarında yüksek frekans aktiviteleri yer almaktadır.



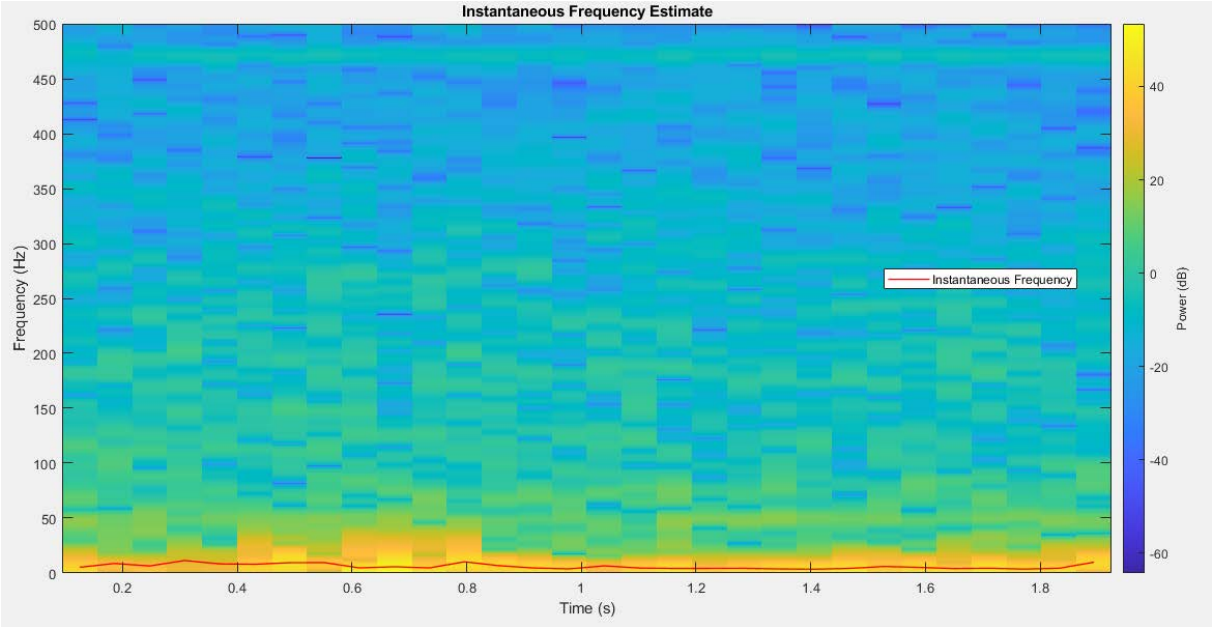
Şekil 4.15: Nöbet sonrası 50. örneğe ait 12. kanalın frekans gösterimi

50. örneğin nöbet sonrası verisinde yine 12. kanalda 150 Hz, 250 Hz, 350 Hz ve 450-500 Hz aralıklarında yüksek frekans aktiviteleri yer almaktadır. 50. örnekte 12. kanalda nöbet öncesi için yüksek frekans aktivitesi yok iken diğer gruplarda yer almaktadır. Bu nedenle aynı verinin bu üç sınıf için diğer kanallardaki durumları incelenmiştir.



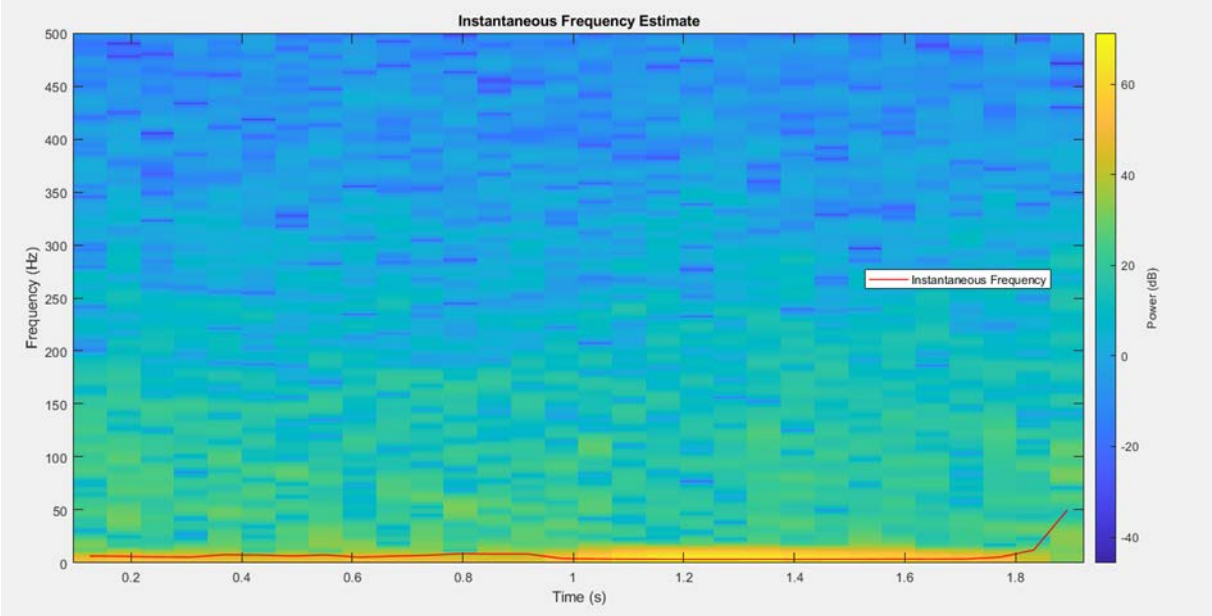
Şekil 4.16: Nöbet öncesi 50. örneğe ait 8. kanalın frekans gösterimi

50.örneğin nöbet öncesi verisinde 8. kanalda 450-500 Hz'de yüksek frekans aktivitesi görülmektedir.



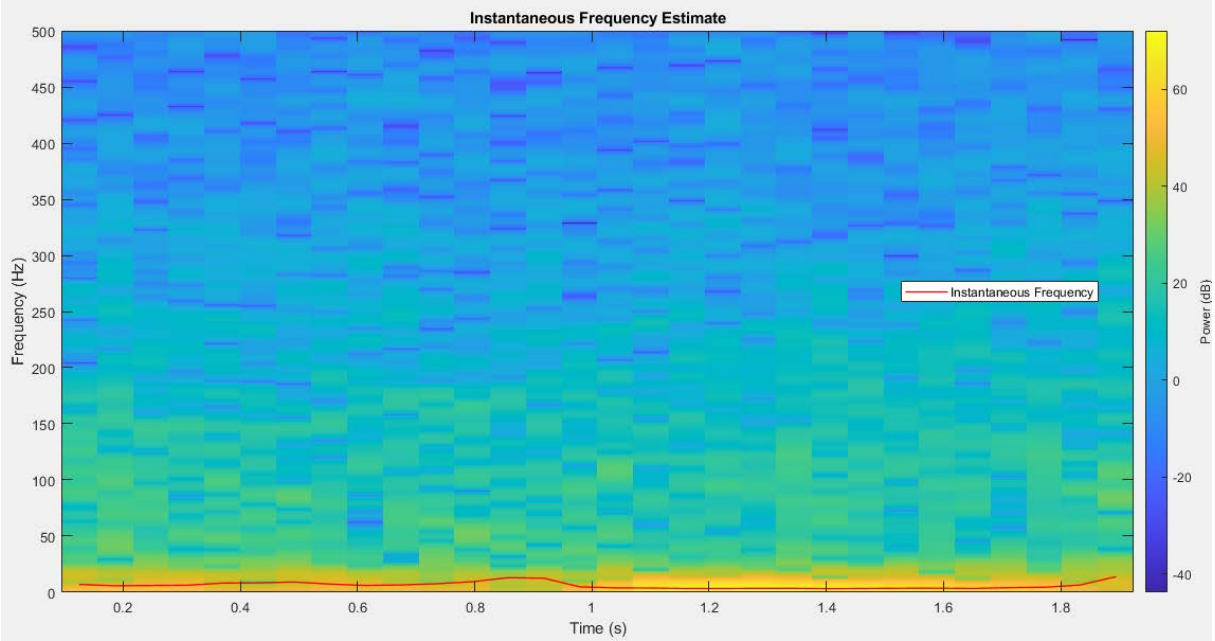
Şekil 4.17: Nöbet öncesi 50. örneğe ait 14. kanalın frekans gösterimi

50.örneğin nöbet öncesi verisinde 14. kanalda yine 450-500 Hz'de yüksek frekans aktivitesi görülmektedir.

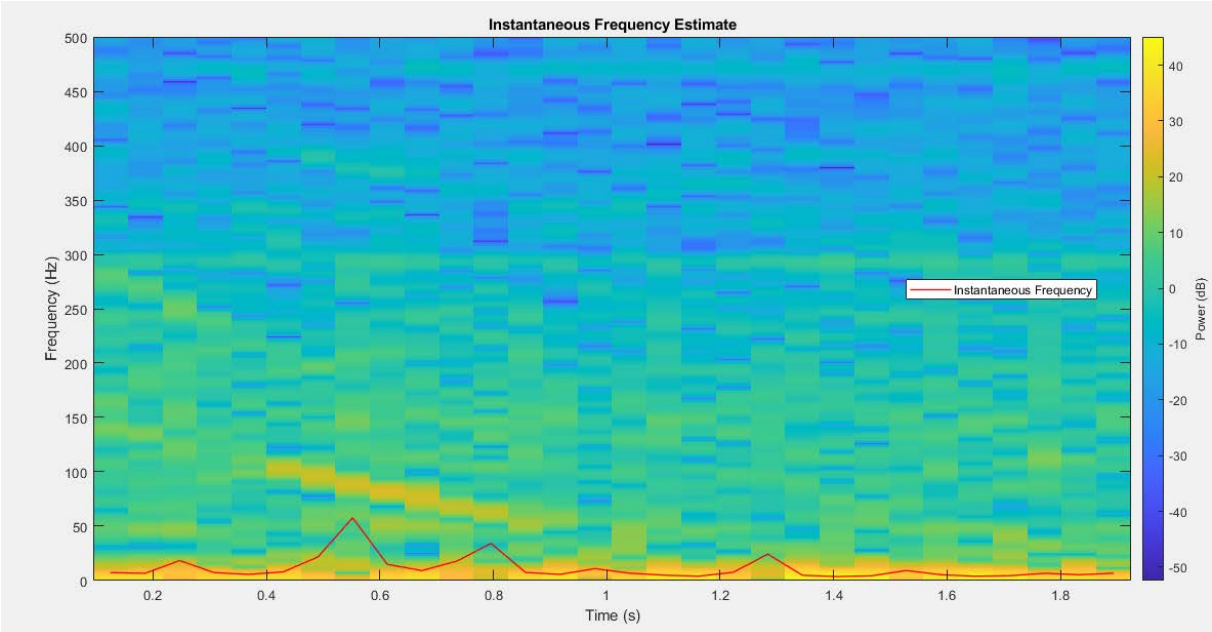


Şekil 4.18: Nöbet sınıfı 50. örneğe ait 8. kanalın frekans gösterimi

50.örneğin 12. kanalında yüksek frekans aktivitesi yer alırken 8. kanalda görülmemektedir. Yine aynı şekilde 14. kanalda da herhangi bir yüksek frekans aktivitesi yoktur.

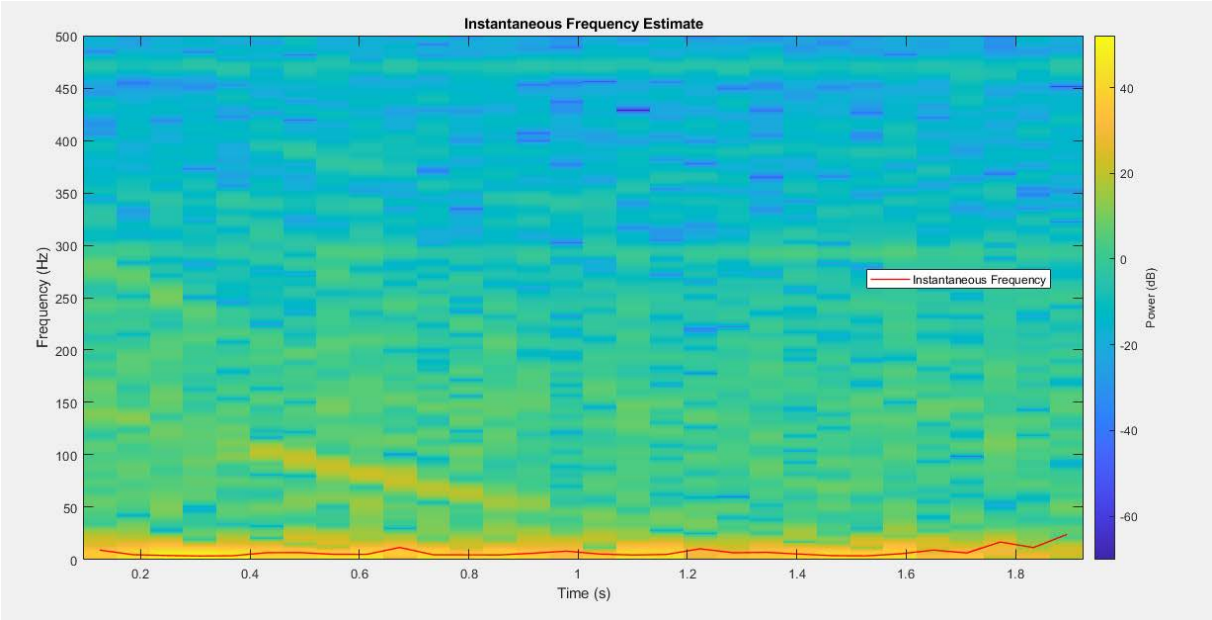


Şekil 4.19: Nöbet sınıfı 50. örneğe ait 14. kanalın frekans gösterimi



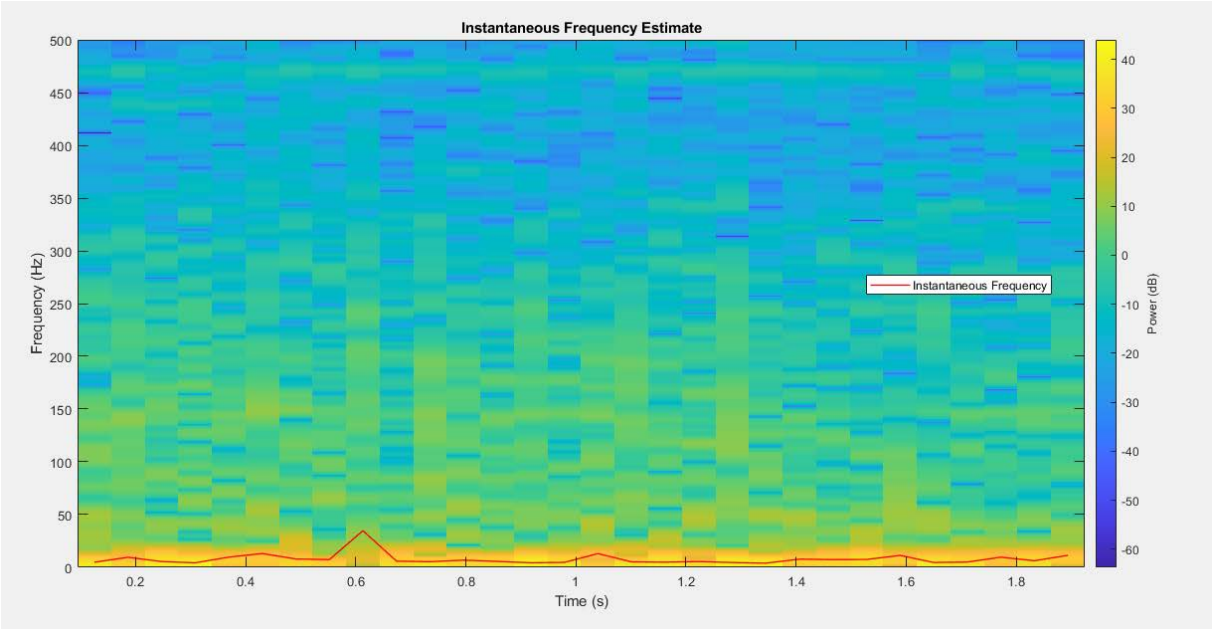
Şekil 4.20: Nöbet sonrası 50. örneğe ait 8. kanalın frekans gösterimi

Nöbet sonrasında 50. örnek için 8. kanalda ve 14. kanalda yüksek frekans aktiviteleri yer almıştır.



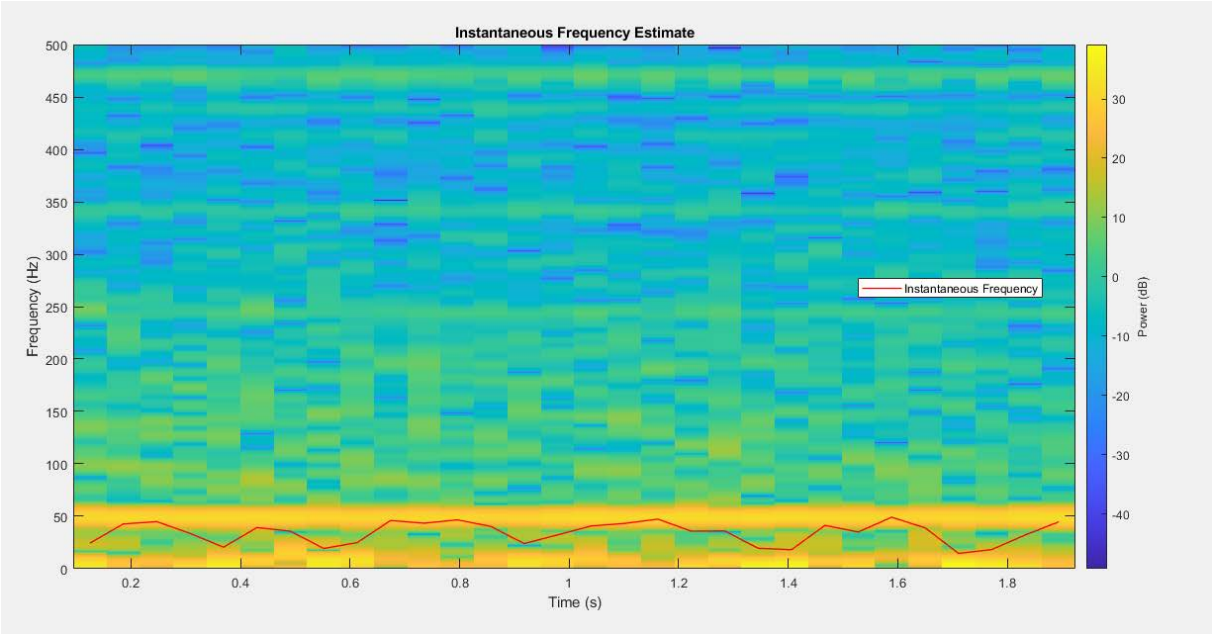
Şekil 4.21: Nöbet sonrası 50. örneğe ait 14. kanalın frekans gösterimi

50. örnek için nöbet öncesinde 8., ve 14. kanalda yüksek frekans aktiviteleri yer alır iken 12. kanalında görülmemektedir. Nöbet sınıfında sadece 12. kanalda nöbet sonrasında ise en yoğun 12. kanal olmakla birlikte, her üç kanalda da aktiviteler yer almaktadır.



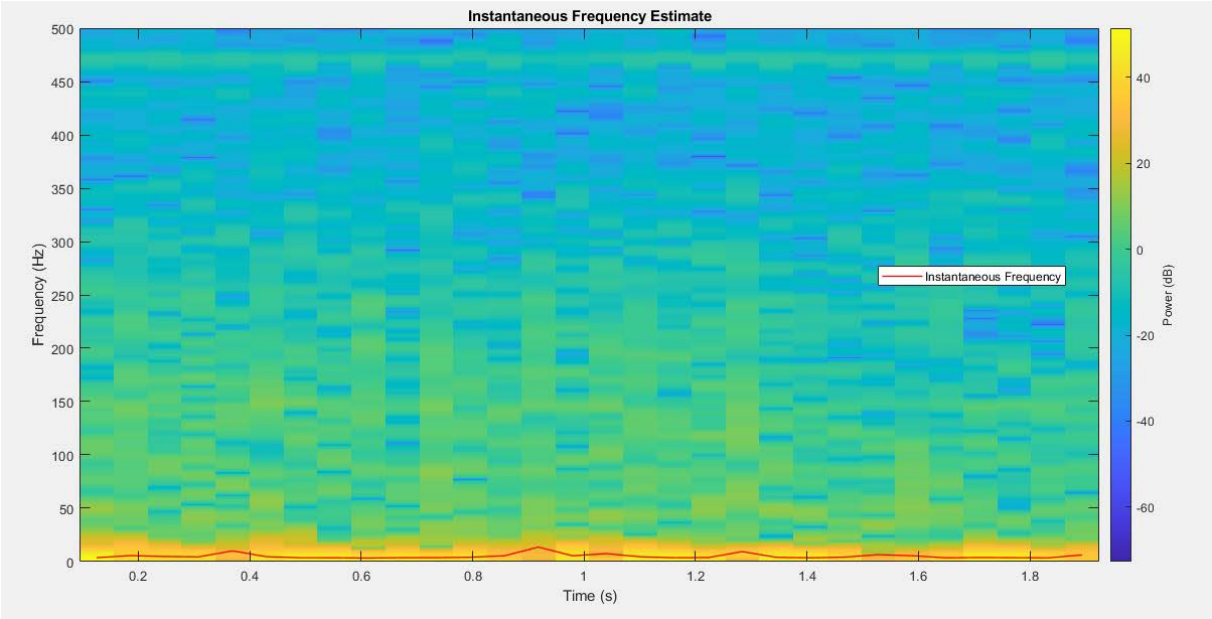
Şekil 4.22: Nöbet sonrası 16. örneğe ait 8. kanalın frekans gösterimi

16. örneğin 8. kanalında nöbet sonrası için 450-500 Hz bandında yüksek frekans aktivitesi yer almaktadır.



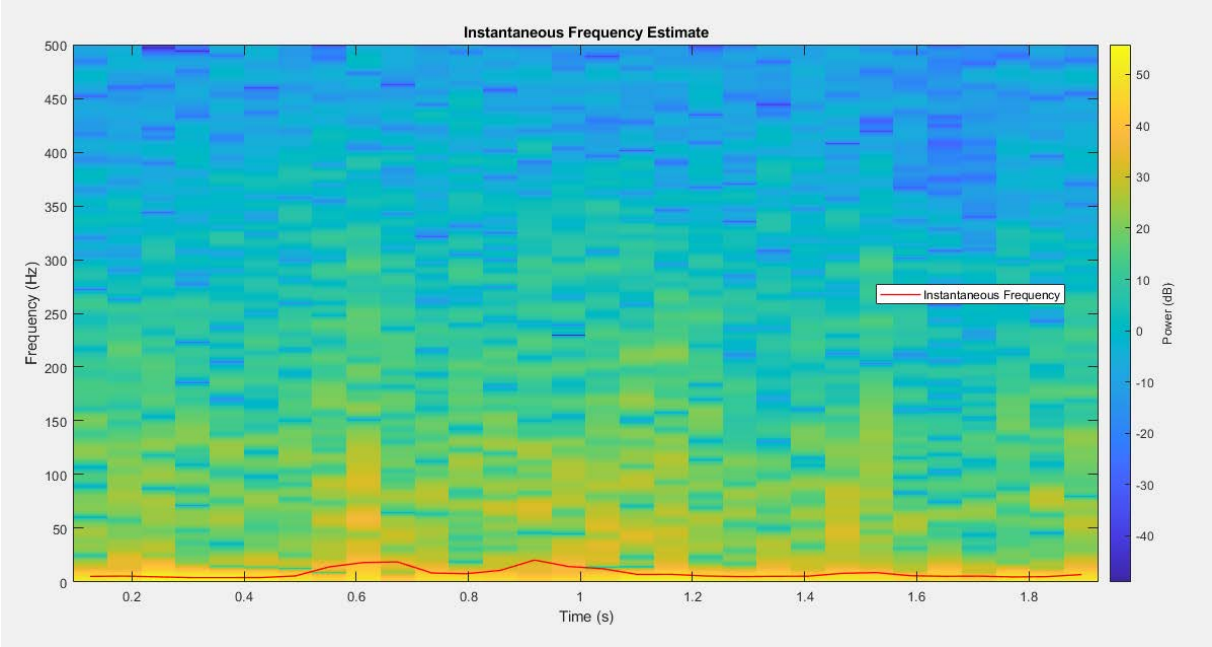
Şekil 4.23: Nöbet sonrası 16. örneğe ait 12. kanalın frekans gösterimi

16. örneğin nöbet sonrası için 250 Hz, 350 Hz ve 450-500 Hz bandında yüksek frekans aktiviteleri yer almaktadır.

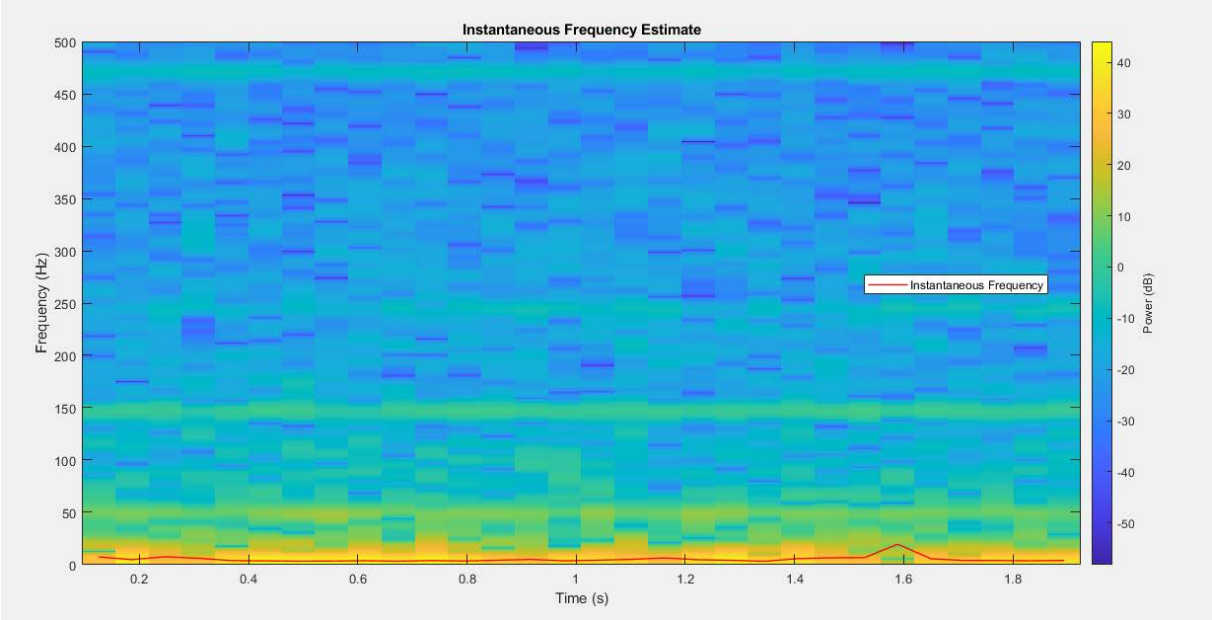


Şekil 4.24: Nöbet sonrası 16. örneğe ait 14. kanalın frekans gösterimi

16. örneğin 14. kanalında ise sadece 450-500 Hz aralığında yüksek frekans aktiviteleri yer almıştır. Nöbet sonrasında görülen bu aktivite için nöbet verisinde herhangi bir aktivite görülmemiştir.

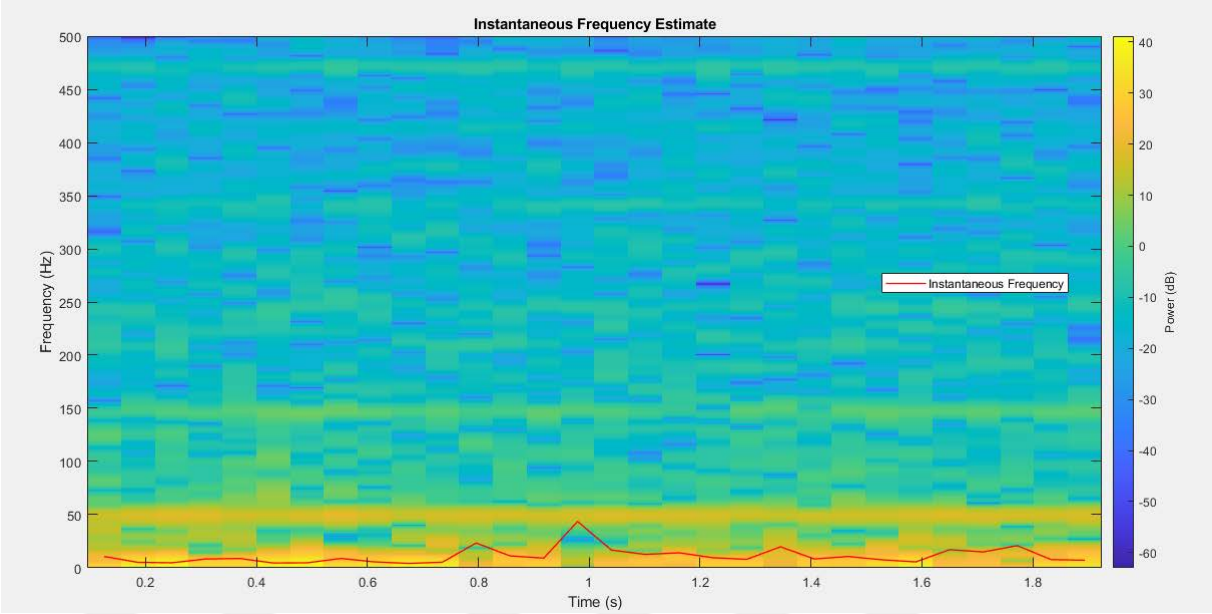


Şekil 4.25: Nöbet sınıfı 16. örneğe ait 14. kanalın frekans gösterimi



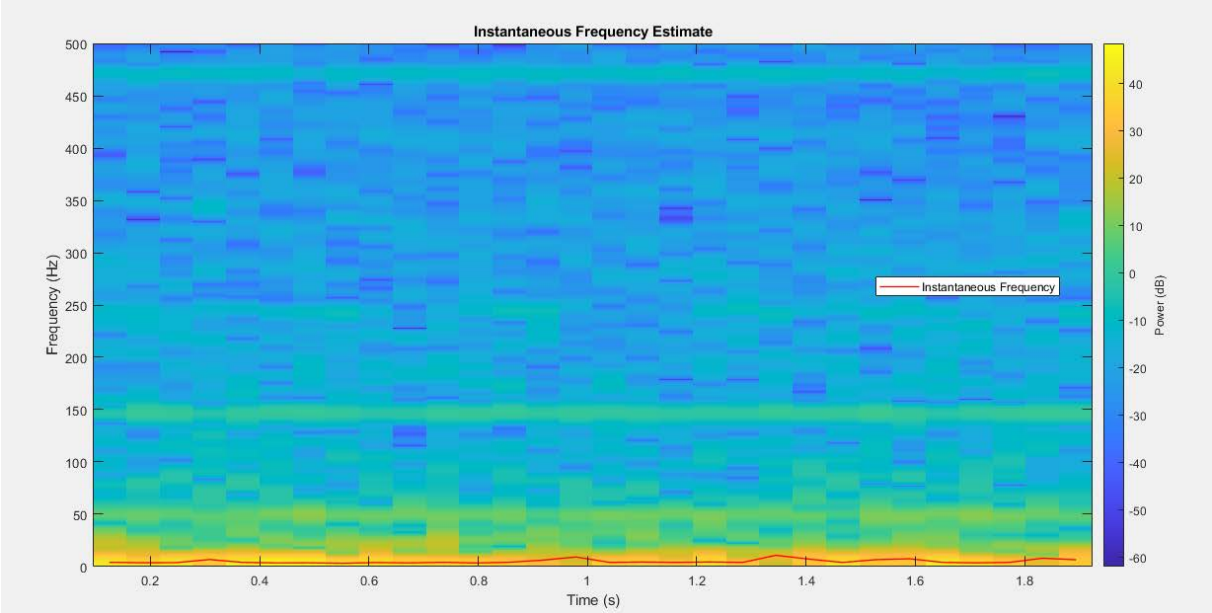
Şekil 4.26: Nöbet öncesi 16. örneğe ait 8. kanalın frekans gösterimi

16. örneğin nöbet öncesi sınıfında 150 Hz, 250 Hz, 450-500 Hz'de yüksek frekans aktiviteleri yer almaktadır.



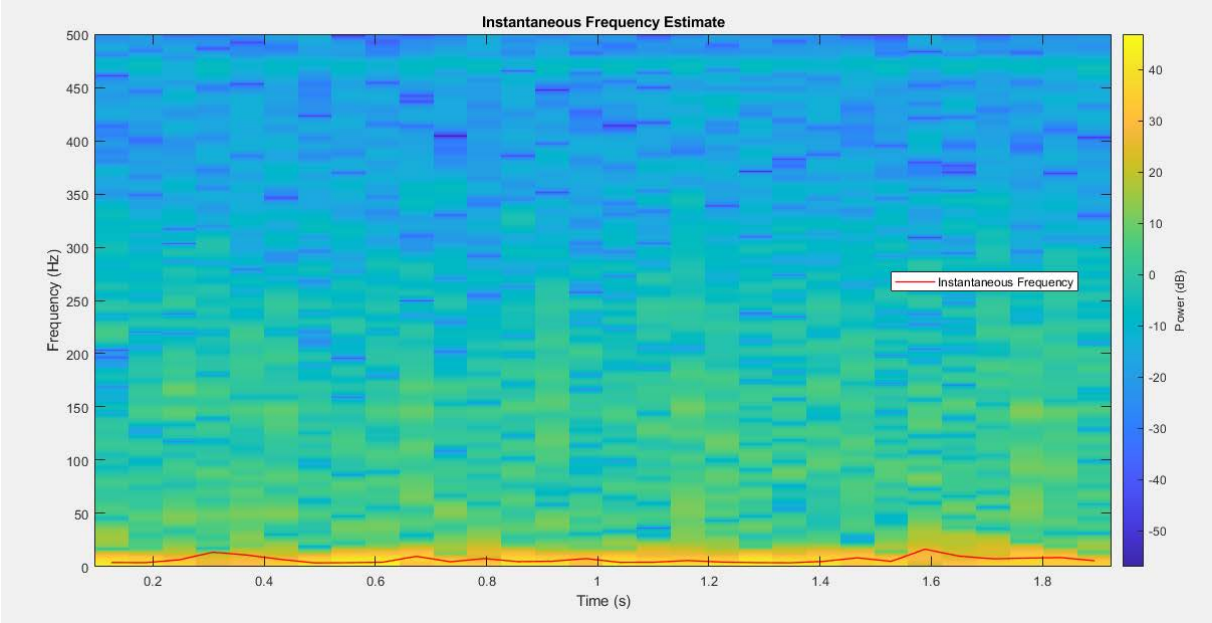
Şekil 4.27: Nöbet öncesi 16. örneğe ait 12. kanalın frekans gösterimi

Aynı örneğin 12. kanalında 8. kanaldaki frekans aralıklarına ek olarak 350 Hz'de de aktivite görülmüştür.



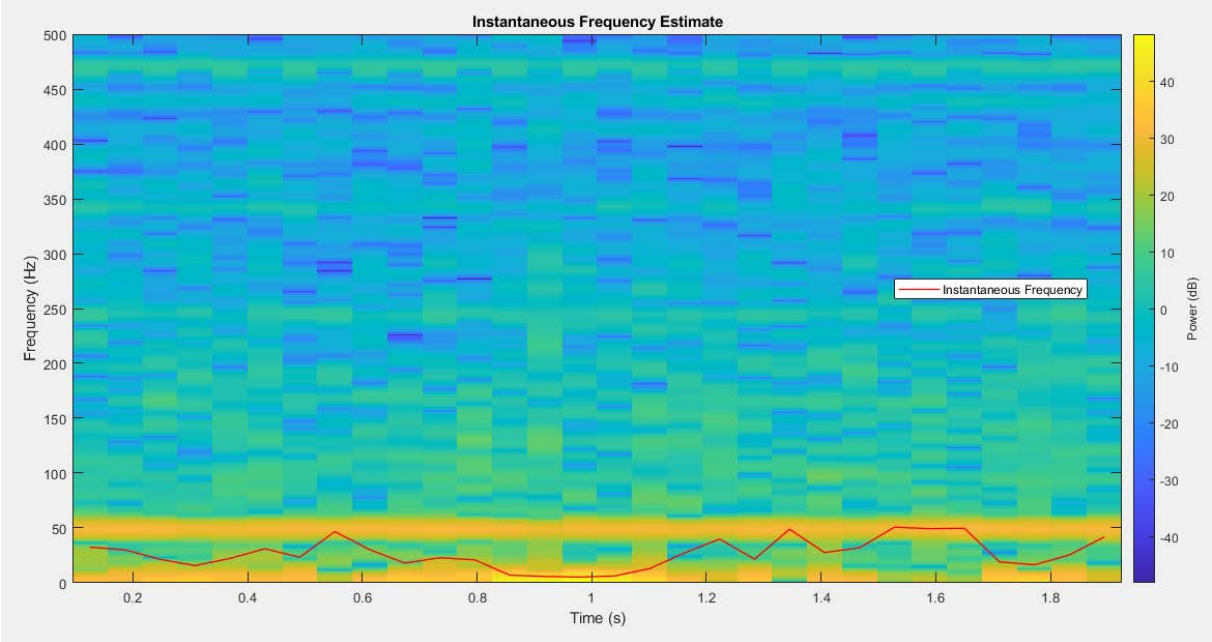
Şekil 4.28: Nöbet öncesi 16. örneğe ait 14. kanalın frekans gösterimi

14. kanalda ise 12. kanala benzer dağılım söz konusudur.16. örnek için nöbet öncesinde yüksek frekans aktiviteleri her üç kanalda da yer almıştır, nöbet sınıfında herhangi bir aktivite yoktur ancak nöbet sonrasında iki kanalda gözlenmiştir.



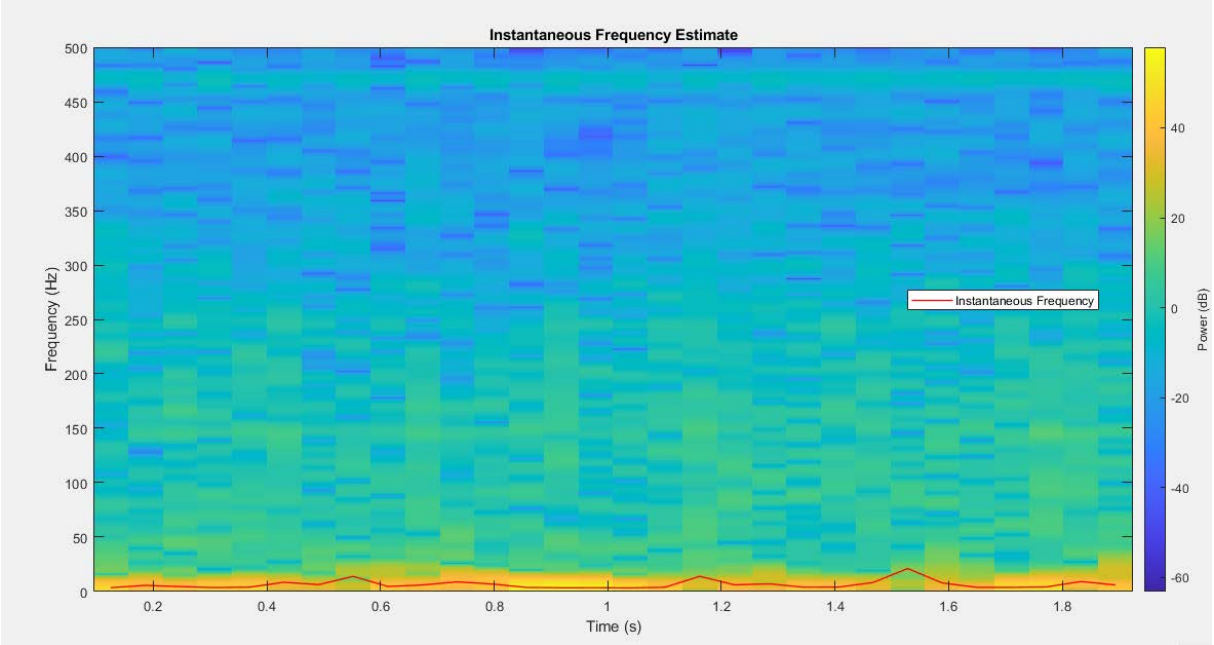
Şekil 4.29: Nöbet sonrası 45. örneğe ait 8. kanalın frekans gösterimi

45. örneğin nöbet verisi için 8. kanalda 450-500 Hz'de aktiviteler görülmüştür.



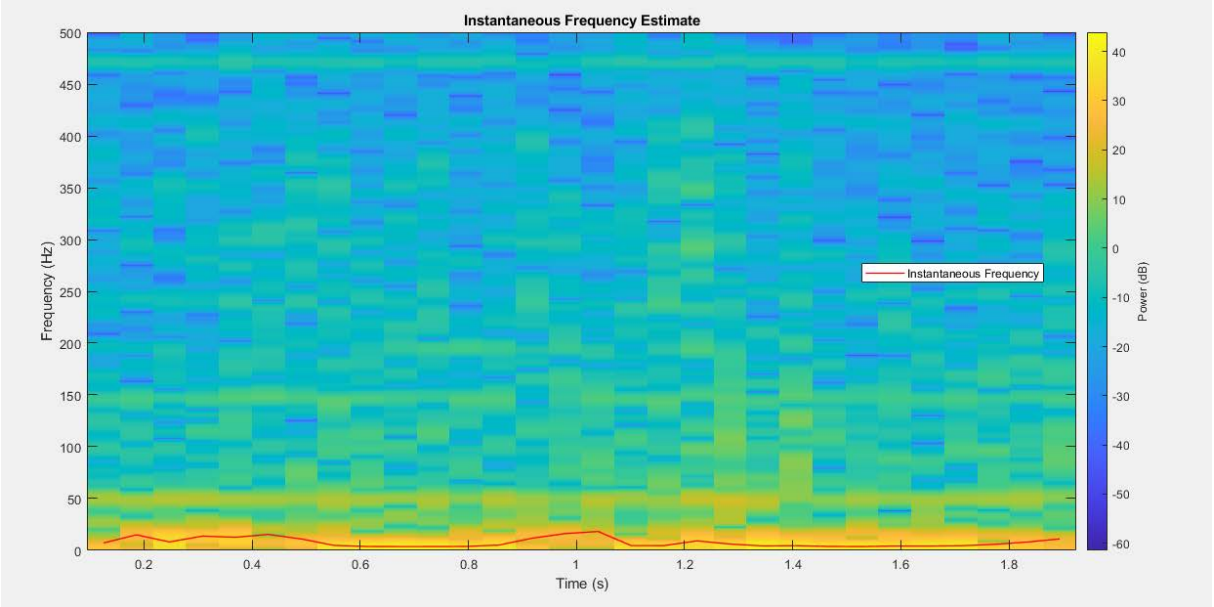
Şekil 4.30: Nöbet sonrası 45. örneğe ait 12. kanalın frekans gösterimi

45. örneğin 12. kanalında ise nöbet sonrasında 250 Hz,350 Hz ve 450-500 Hz aralıklarında yüksek frekans aktiviteleri yer almıştır.



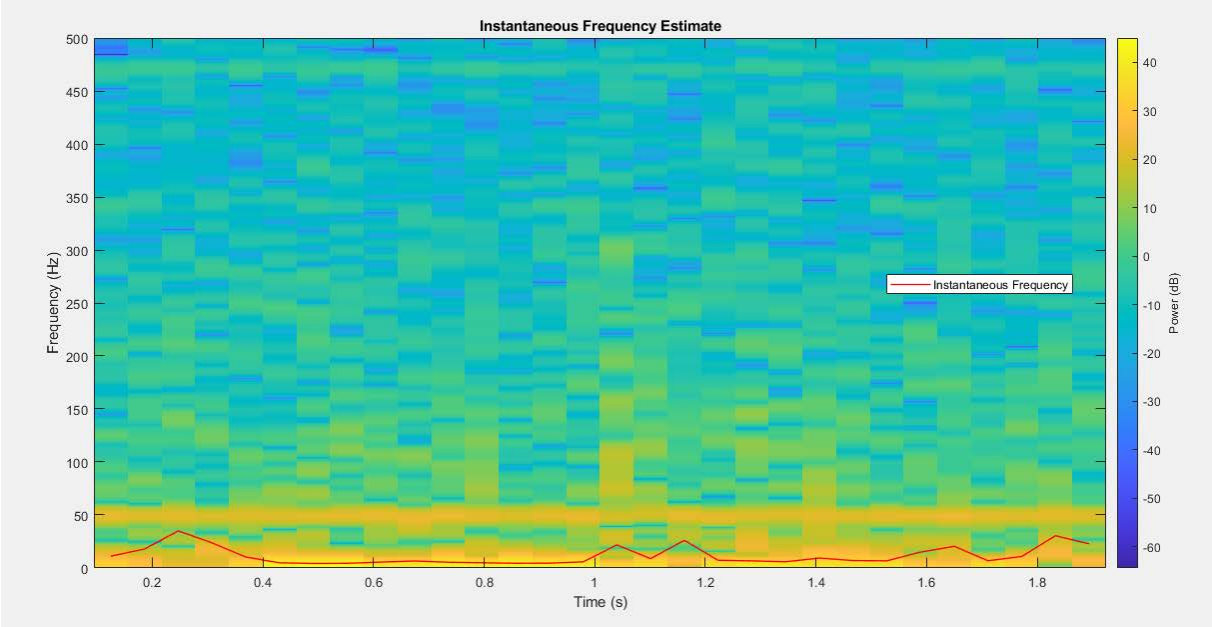
Şekil 4.31: Nöbet sonrası 45. örneğe ait 14. kanalın frekans gösterimi

Nöbet sonrası 45. örneğin 14. kanalında 450-500 Hz bandında yüksek frekans aktivitesi görülmektedir.



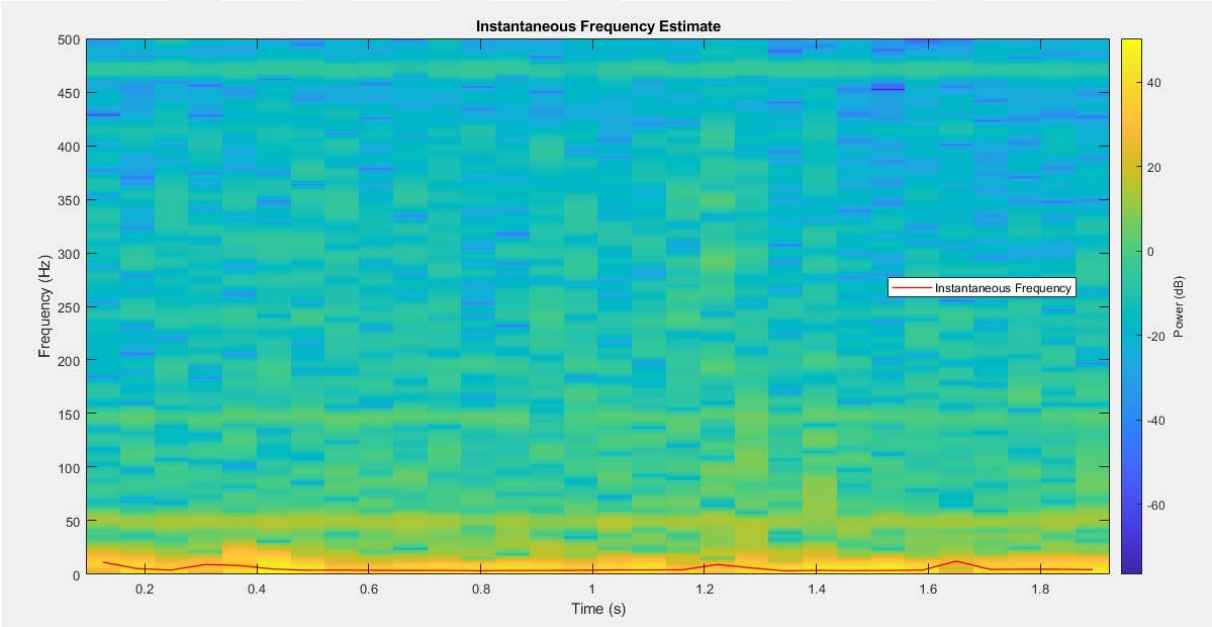
Şekil 4.32: Nöbet öncesi 45. örneğe ait 8. kanalın frekans gösterimi

Nöbet öncesi 45. örneğin 8. kanalda 150 Hz ve 450-500 Hz aralığında yüksek frekans aktiviteleri görülmüştür.



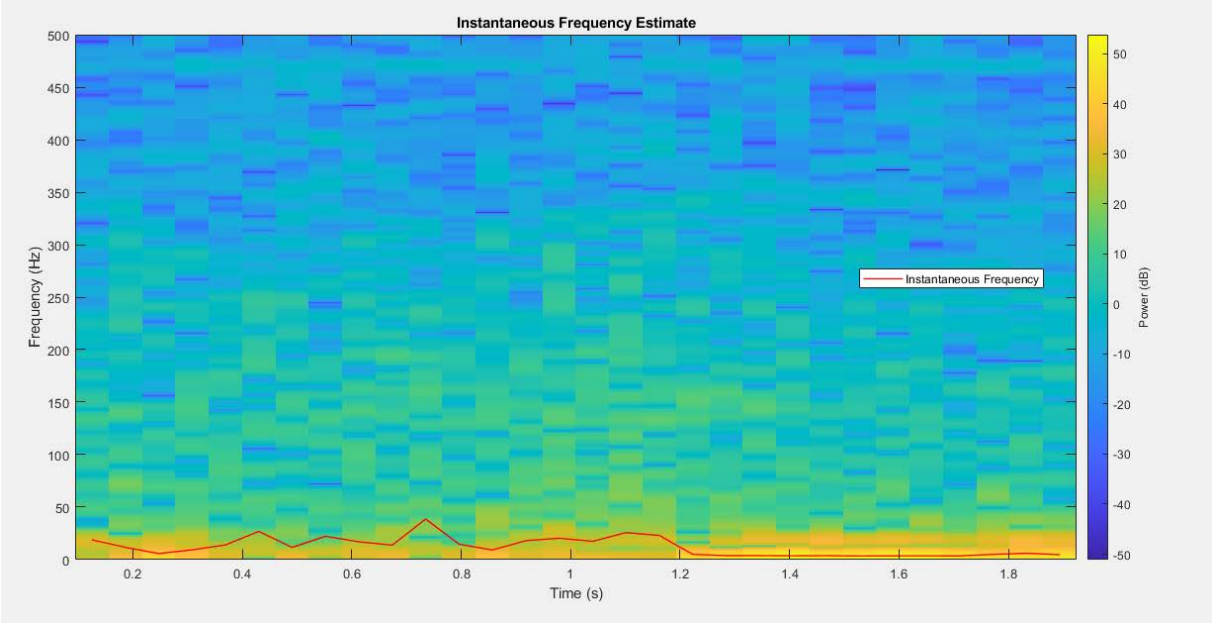
Şekil 4.33: Nöbet öncesi 45. örneğe ait 12. kanalın frekans gösterimi

Nöbet öncesi 45. örneğin 12. kanalında 450-500 Hz aralığında yüksek frekans aktiviteleri izlenmiştir.



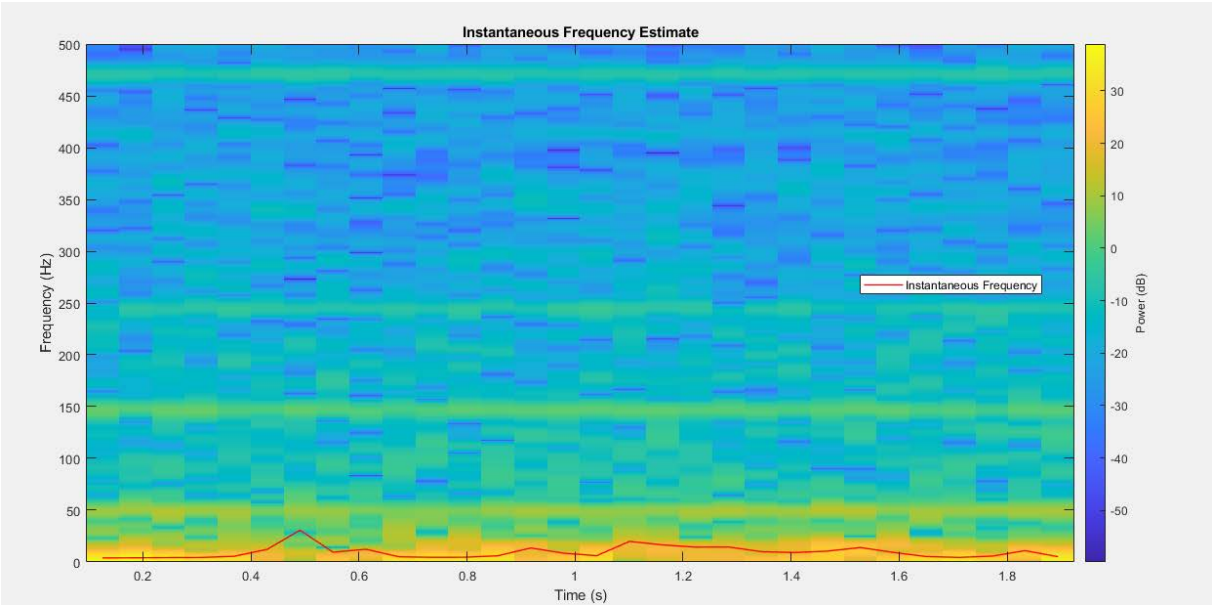
Şekil 4.34: Nöbet öncesi 45. örneğe ait 14. kanalın frekans gösterimi

45. örneğin nöbet öncesi 14. kanalında, en belirgin olarak 150 Hz ve 450-500 Hz bandında yüksek frekans aktiviteleri gözlenmiştir.



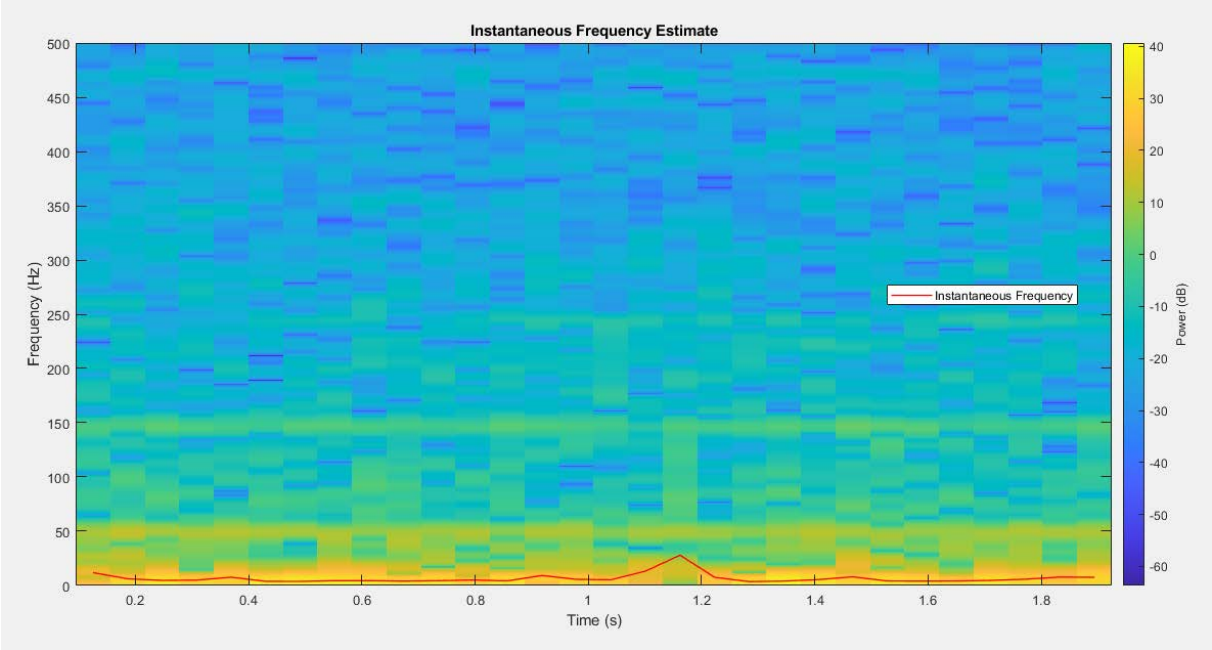
Şekil 4.35: Nöbet sınıfı 45. örneğe ait 14. kanalın frekans gösterimi

45. örnek için nöbet verilerinde yüksek frekans aktivitesi izlenmemiştir. Nöbet öncesinde görülüp, nöbette izlenmeyen ancak nöbet sonrasında tekrar izlenebilen yüksek frekans aktiviteleri görülmüştür.



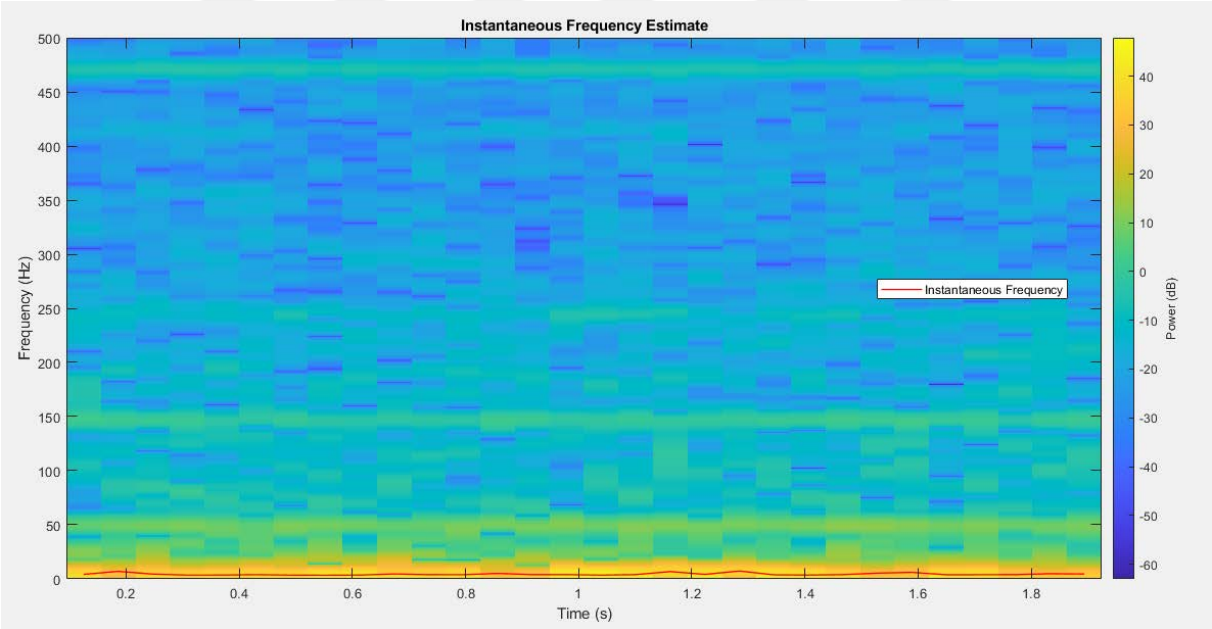
Şekil 4.36: Nöbet öncesi 3. örneğe ait 8. kanalın frekans gösterimi

Nöbet öncesi 3. örneğin, 8. kanalında 150 Hz, 250 Hz ve 450-500 Hz frekans aralıklarında yüksek frekans aktivitesi görülmüştür.



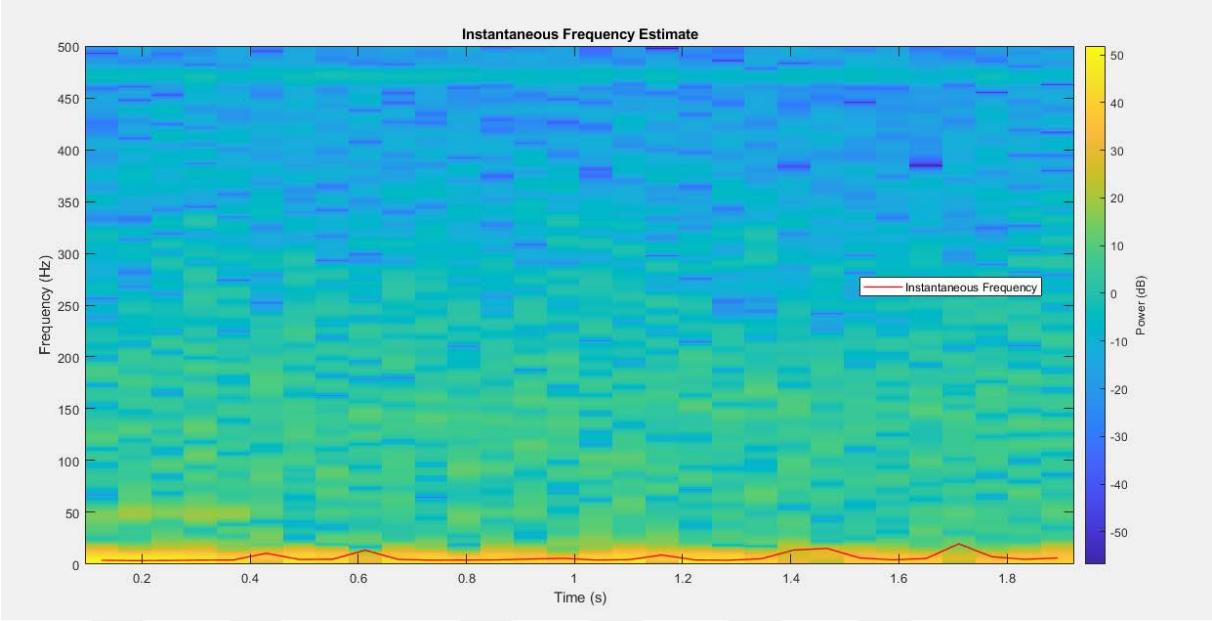
Şekil 4.37: Nöbet öncesi 3. örneğe ait 12. kanalın frekans gösterimi

12. kanalda sadece 150 Hz'de yüksek frekans aktivitesi görülmektedir.



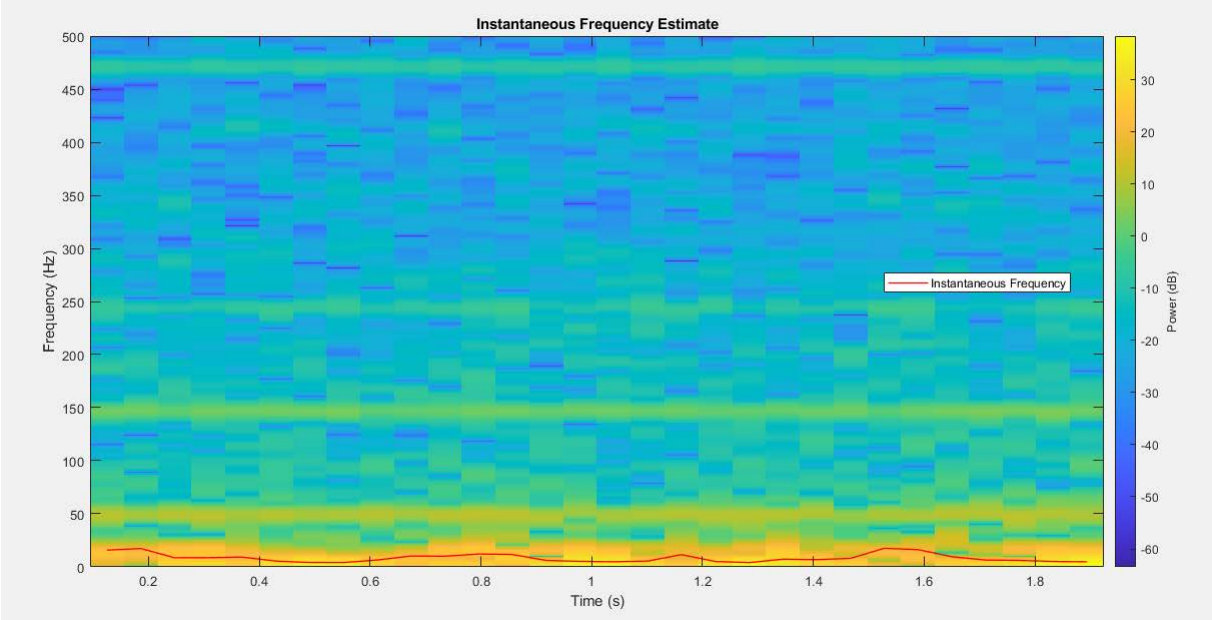
Şekil 4.38: Nöbet öncesi 3. örneğe ait 14. kanalın frekans gösterimi

14. kanalda ise 8. kanal ile aynı frekans aralıklarına benzer aktiviteler izlenmiştir.



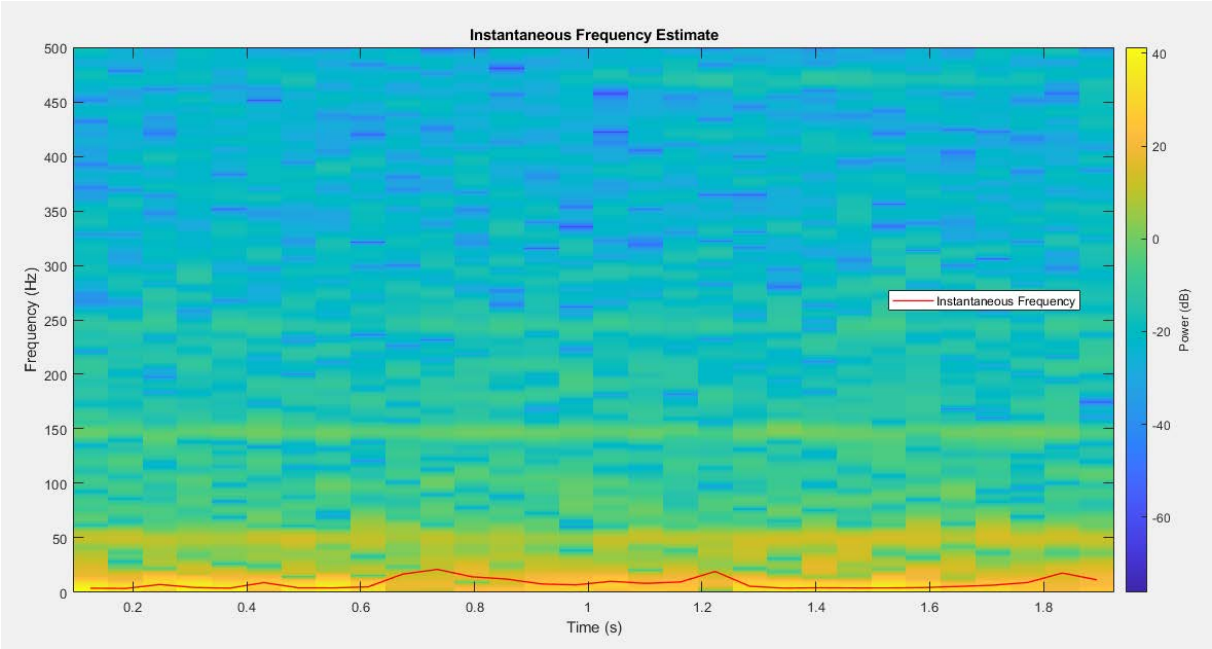
Şekil 4.39: Nöbet sonrası 3. örneğe ait 14. kanalın frekans gösterimi

Nöbet sonrası için 12. kanalda frekans aktivitesi görülmezken 8. ve 14. kanallarda benzer olup şekilde örnek olarak 14. kanal verilmiştir. Nöbet için ise bu örnekte her üç kanalda da yüksek frekans aktivitesi görülememiştir.

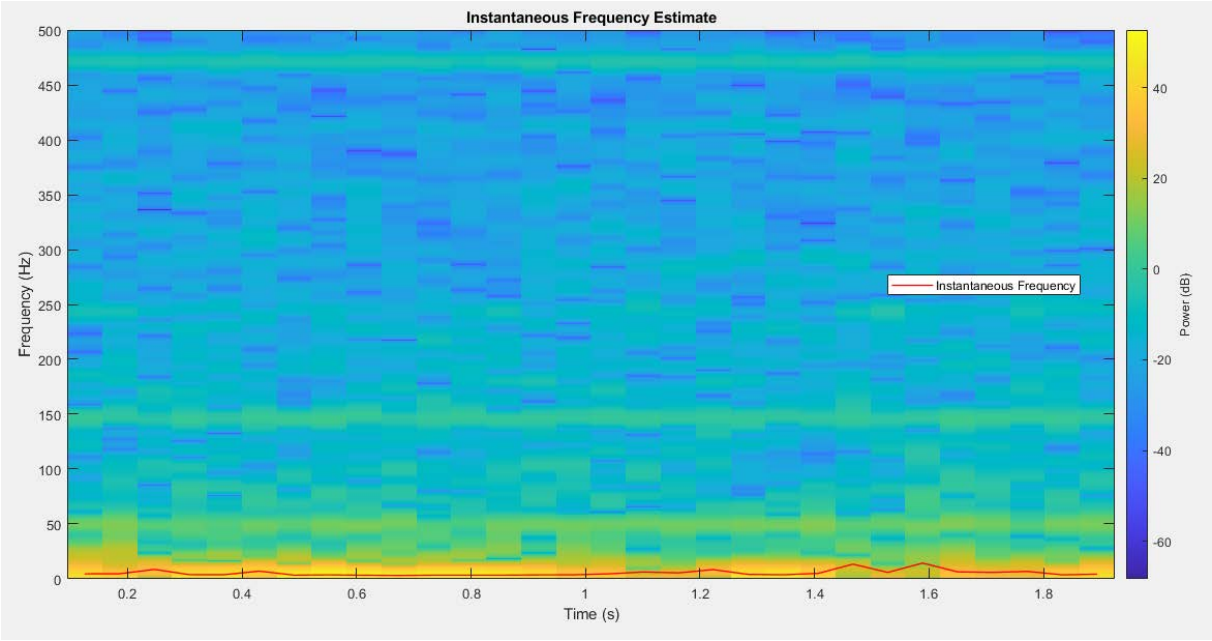


Şekil 4.40: Nöbet öncesi 5. örneğe ait 8. kanalın frekans gösterimi

Nöbet öncesi 5. örnek için; 150 Hz, 250 Hz ve 450-500 Hz'de yüksek frekans aktiviteleri yer almaktadır.

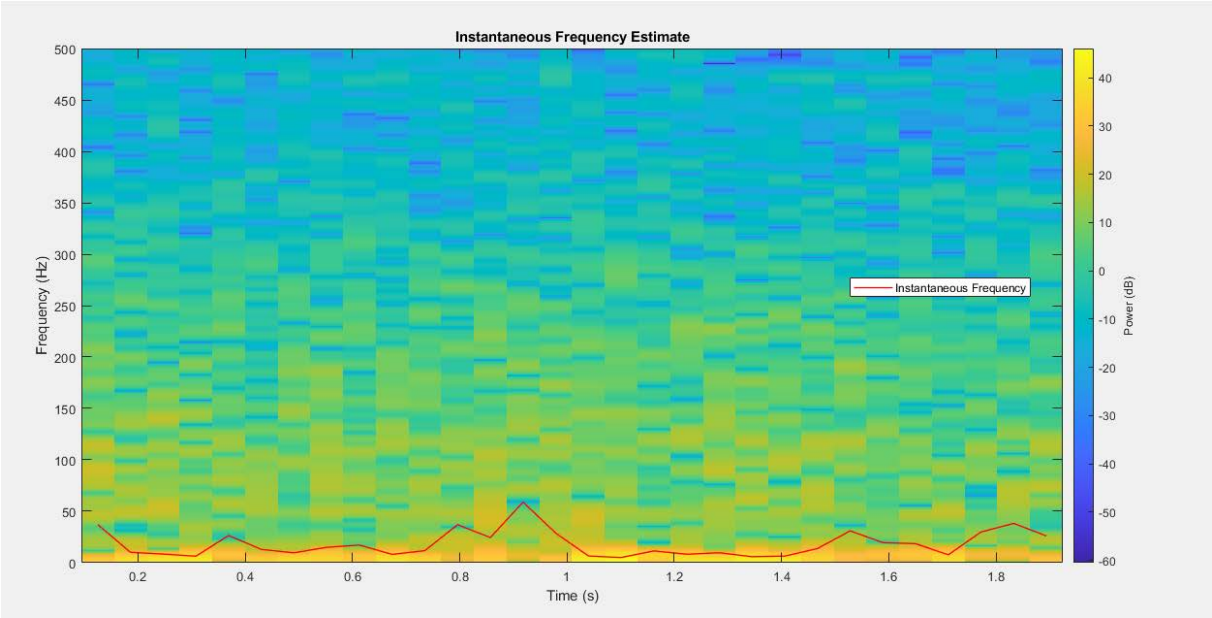


Şekil 4.41: Nöbet öncesi 5. örneğe ait 12. kanalın frekans gösterimi



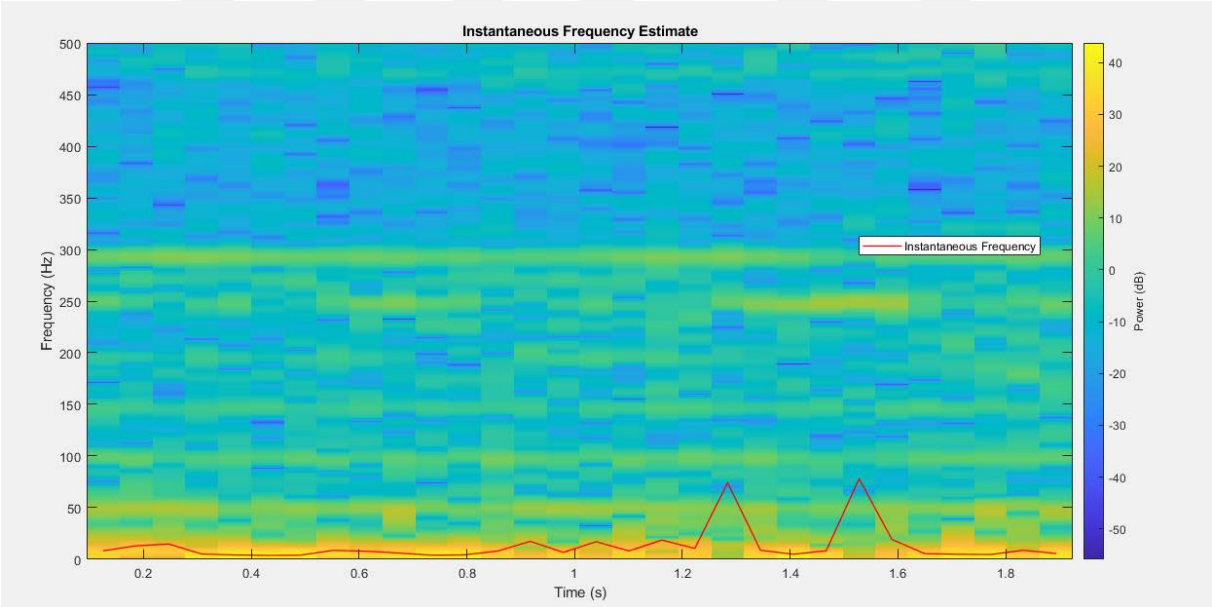
Şekil 4.42: Nöbet öncesi 5. örneğe ait 14. kanalın frekans gösterimi

.



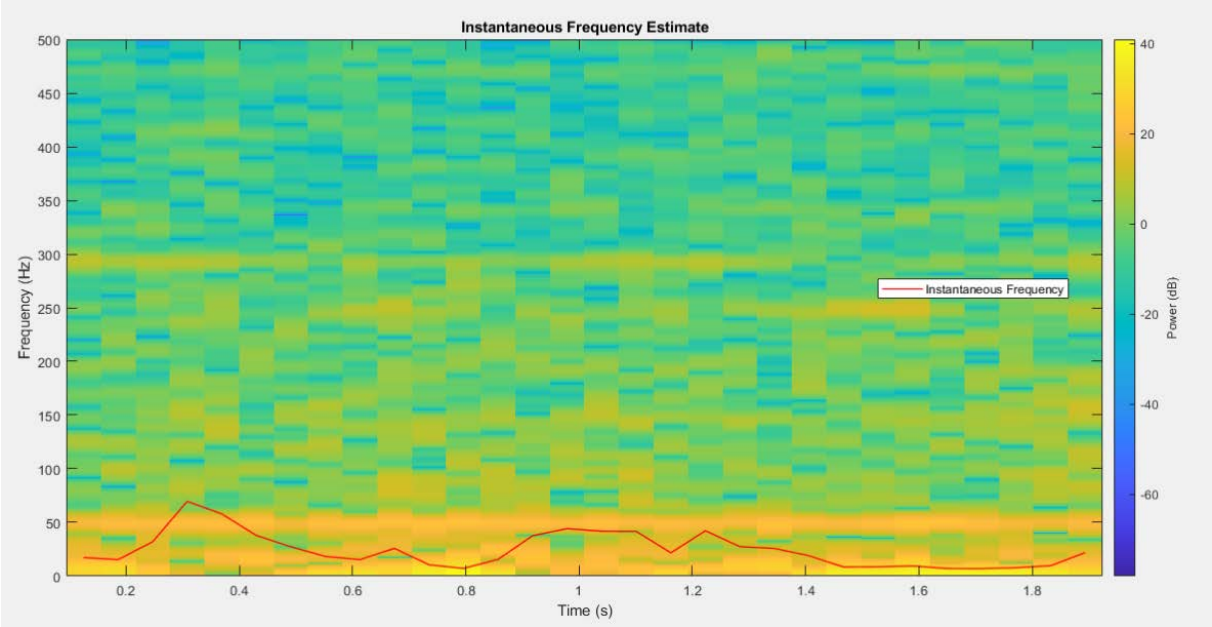
Şekil 4.43: Nöbet sonrası 5. örneğe ait 14. kanalın frekans gösterimi

5. örnekte nöbet öncesinde her üç kanalda da yüksek frekans aktiviteleri izlenirken, nöbet ve nöbet sonrası sınıflarda her üç kanal için de aktivite görülememiştir

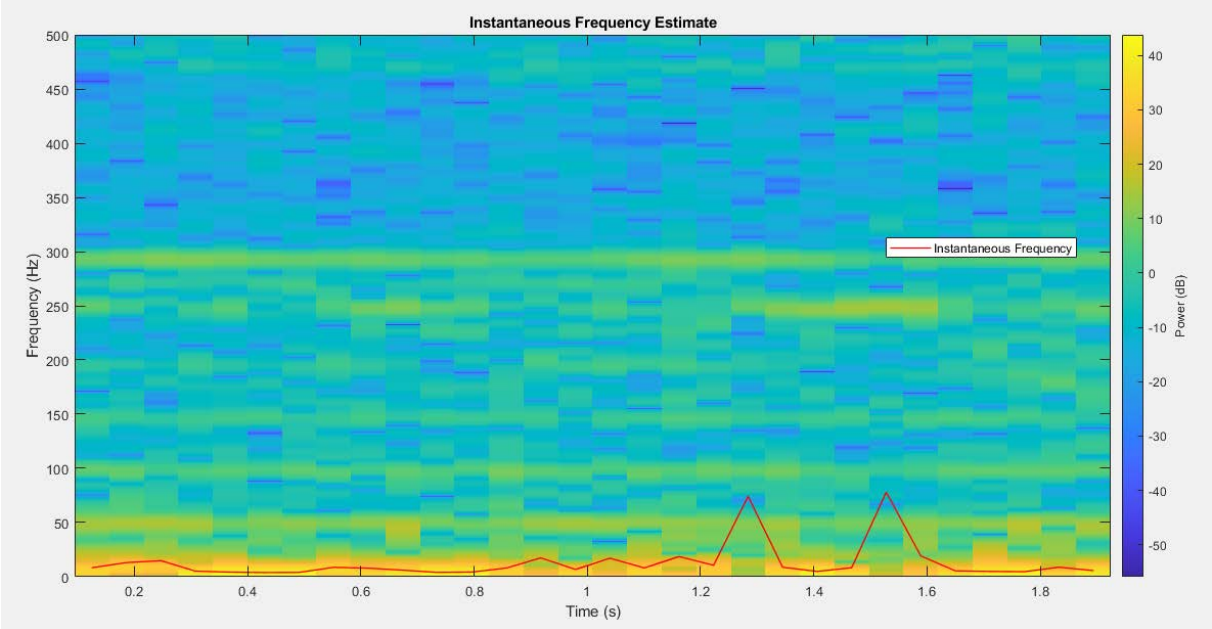


Şekil 4.44: Nöbet öncesi 40. örneğe ait 8. kanalın frekans gösterimi

40. örnek için, 8. kanalda net olarak görülen frekans aktiviteleri, 12. kanalda yüksek frekans yoğunluğundan dolayı band halinde gözlem pek mümkün olmasa da, yine de 300 Hz'de aktivite izlenmektedir.

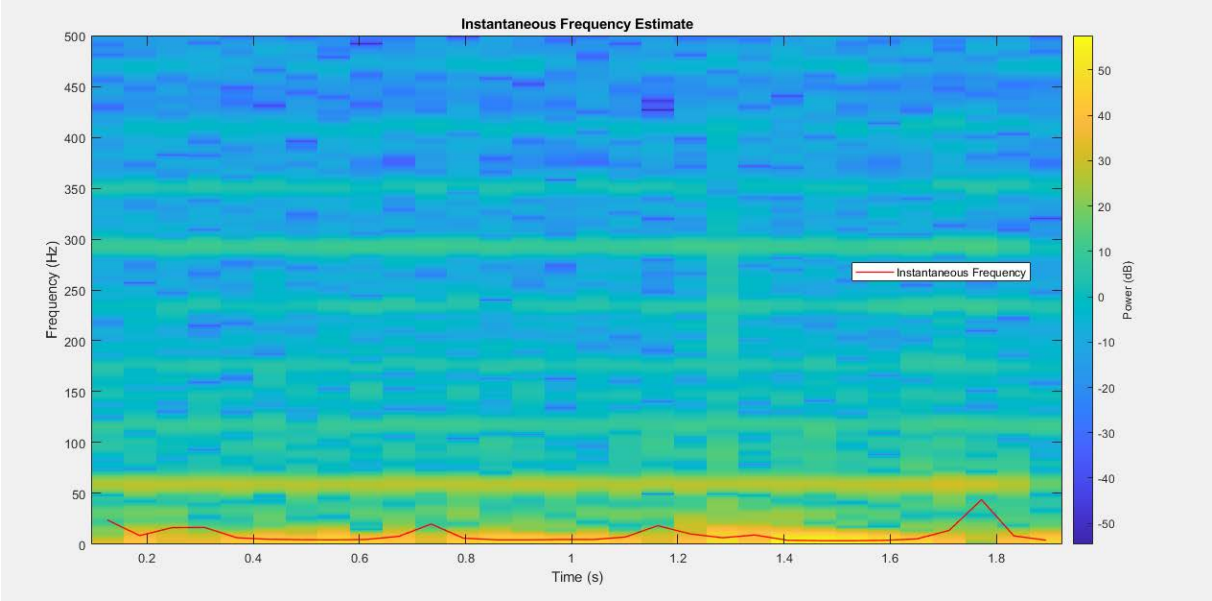


Şekil 4.45: Nöbet öncesi 40. örneğe ait 12. kanalın frekans gösterimi



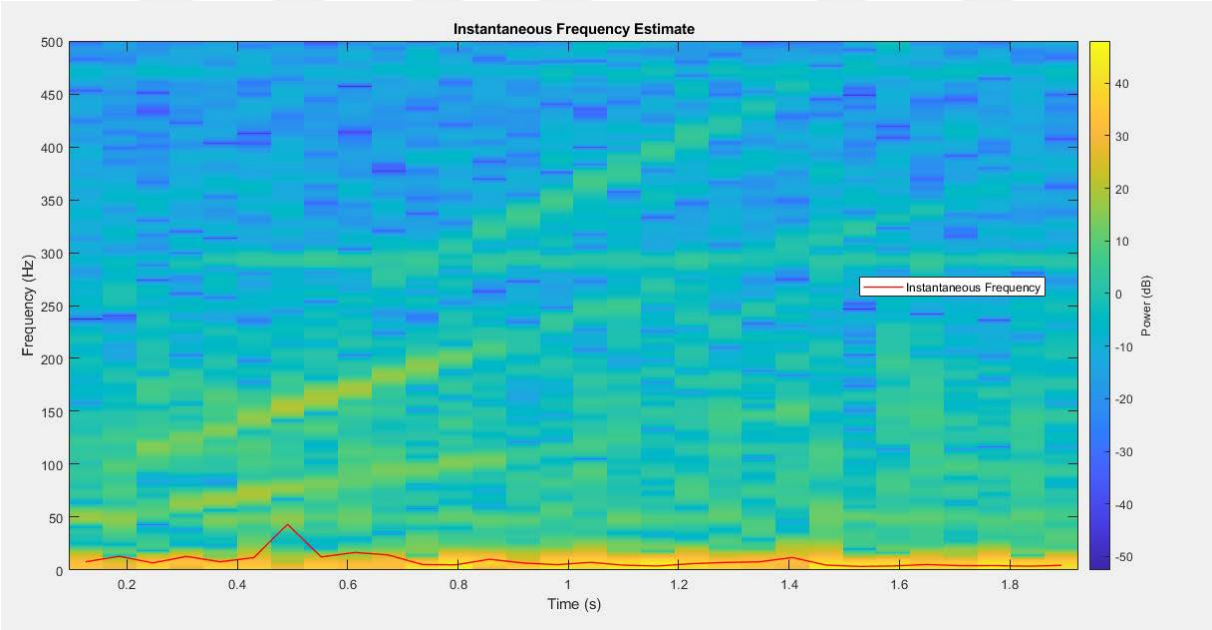
Şekil 4.46: Nöbet öncesi 40. örneğe ait 14. kanalın frekans gösterimi

14. kanal ve 8. kanal benzer özellikler göstermiştir. Nöbet ve nöbet sonrası sınıflar için yüksek frekans aktivitesi izlenmemiştir.



Şekil 4.47: Nöbet öncesi 43. örneğe ait 14. kanalın frekans gösterimi

43. örnekte görüldüğü üzere pek çok frekans bandında yüksek frekans aktivitesi vardır, ancak nöbette izlenmemiş, nöbet sonrasında ise 12. kanalda yokken 8. ve 14. kanalda benzerlik görülmüştür.



Şekil 4.48: Nöbet sonrası 43. örneğe ait 14. kanalın frekans gösterimi

Her bir sınıfa ait her bir kanal için HFO analizi yapıldıktan sonra, özniteliklere göre sınıflandırma işlemine geçilmiştir. İstatistiksel ve yapısal özniteliklere göre sınıflandırma işleminde uygulanan DVM, Rastgele orman, K-NN, ÇKA ve Bayes sınıflandırıcıları bu sınıflandırma işleminde de uygulanmıştır. Rastgele orman sınıflandırıcı uygulandıktan sonra çıkan sonuçlar Tablo 4.15. ve 4.16.'da verilmiştir.

Tablo 4.16: HFO tabanlı özniteliklere göre RF sınıflandırıcısı sonuçları

Rastgele orman	**TP Rate**	**FP Rate**	**ROC Alanı**	**PRC Alanı**
Nöbet Öncesi	0,768	0,027	0,924	0,911
Nöbet	0,732	0,080	0,891	0,712
Nöbet Sonrası	0,821	0,232	0,839	0,751

Sonuçlara göre doğruluk oranı %77.436, standart sapma 1.289 ve ortalama mutlak hata 0.2038 bulunmuştur. Toplam 168 örnekten 130 tanesini doğru sınıflandırmıştır.

Tablo 4.16.'da verilen hata matrisinde a; nöbet öncesi, b; nöbet ve c; nöbet sonrası sınıfları temsil etmektedir.

Tablo 4.17: HFO tabanlı özniteliklere göre RF sınıflandırıcısı için hata matrisi

Nöbet	**Nöbet Öncesi**	**Nöbet Sonrası**	**Sınıf**
43	2	11	**a**
0	41	15	**b**
3	7	46	**c**

Hata matrisi incelendiğinde 56 nöbet öncesi verisinin 43 tanesini nöbet öncesi, 2 tanesini nöbet ve 11 tanesini nöbet sonrası olarak sınıflandırmıştır. Yine 56 nöbet verisinin 41 tanesini nöbet, 15 tanesini de nöbet sonrası olarak sınıflandırmıştır. 56 nöbet sonrası verisinin ise 46

tanesini nöbet sonrası, 3 tanesini nöbet öncesi 7 tanesini nöbet olarak sınıflandırmıştır. En doğru oranlar nöbet sonrası veriler için çıkmıştır.

Bayes sınıflandırıcısı için çıkan sonuçlar Tablo 4.17 ve Tablo 4.18.'de verilmiştir.

Tablo 4.18: HFO tabanlı özniteliklere göre Bayes sınıflandırıcısı sonuçları

Bayes	TP Rate	FP Rate	ROC Alanı	PRC Alanı
Nöbet Öncesi	0,804	0,27	0,915	0,901
Nöbet	0,696	0,80	0,893	0,746
Nöbet Sonrası	0,821	0,232	0,822	0,653

Bayes sınıflandırıcısı için doğruluk oranı %77.142, standart sapma 0.402 ve ortalama mutlak hata 0.1721 bulunmuştur. Toplam 168 örnekten 130 tanesini doğru sınıflandırmıştır.

Bayes sınıflandırıcı için verilen hata matrisinde a; nöbet öncesi, b; nöbet ve c; nöbet sonrası sınıfları temsil etmektedir.

Tablo 4.19: HFO tabanlı özniteliklere göre Bayes sınıflandırıcısı için hata matrisi

Nöbet	Nöbet Öncesi	Nöbet Sonrası	Sınıf
45	2	9	a
0	39	17	b
3	7	46	c

Bayes için hata matrisi incelendiğinde 56 nöbet öncesi verisinden 45 tanesi nöbet öncesi, 2 tanesi nöbet ve 9 tanesi nöbet sonrası olarak sınıflandırılmıştır. 56 nöbet verisinden ise 39 tanesi nöbet, 17 tanesi de nöbet sonrası olarak sınıflandırılmıştır. 56 nöbet sonrası verisinden de 46 tanesi nöbet sonrası, 3 tanesi nöbet öncesi 7 tanesi nöbet olarak sınıflandırılmıştır. En doğru oranlar nöbet öncesi ile çok yakın olmakla birlikte nöbet sonrası veriler için çıkmıştır.

Tablo 4.20: HFO tabanlı özniteliklere göre K-NN sınıflandırıcısı sonuçları

K-NN	TP	FP	ROC Alanı	PRC Alanı
Nöbet Öncesi	0,786	0,09	0,922	0,912
Nöbet	0,714	0,116	0,878	0,727
Nöbet Sonrası	0,804	0,223	0,834	0,727

K-NN sınıflandırıcısı için çıkan sonuçlara göre doğruluk oranı %77.329, standart sapma 1.36 ve ortalama mutlak hata 0.2025 bulunmuştur. Toplam 168 örnekten 129 tanesini doğru sınıflandırmıştır.

Tablo 4.21: HFO tabanlı özniteliklere göre K-NN sınıflandırıcısı için hata matrisi

Nöbet	Nöbet Öncesi	Nöbet Sonrası	Sınıf
44	3	9	**a**
0	40	16	**b**
1	10	45	**c**

K-NN sınıflandırıcısı için hata matrisi incelendiğinde a; nöbet öncesi, b; nöbet ve c; nöbet sonrası olmak üzere 56 nöbet öncesi verisinin 44 tanesini nöbet öncesi, 3 tanesini nöbet ve 9 tanesini nöbet sonrası olarak sınıflandırmıştır. Yine 56 nöbet verisinin 40 tanesini nöbet, 16 tanesini de nöbet sonrası olarak sınıflandırmıştır. 56 nöbet sonrası verisinin ise 45 tanesini nöbet sonrası, 1 tanesini nöbet öncesi 10 tanesini nöbet olarak sınıflandırmıştır. En doğru oranlar nöbet sonrası veriler için çıkmıştır.

Tablo 4.21 ve Tablo 4.22'de DVM sınıflandırıcısı için çıkan sonuçlar gösterilmiştir. Buna göre;

Tablo 4.22: HFO tabanlı özniteliklere göre DVM sınıflandırıcısı sonuçları

DVM	TP	FP	ROC Alanı	PRC Alanı
Nöbet Öncesi	0,804	0,036	0,895	0,850
Nöbet	0,679	0,071	0,892	0,738
Nöbet Sonrası	0,804	0,250	0,777	0,561

DVM sınıflandırıcısı için doğruluk oranı %75.42, standart sapma 1.201 çıkmıştır. Ortalama mutlak değer ise 0.2884'dür. 168 örnekten 128 tanesi doğru sınıflandırılmıştır.

Tablo 4.23: HFO tabanlı özniteliklere göre DVM sınıflandırıcısı için hata matrisi

Nöbet	Nöbet Öncesi	Nöbet Sonrası	Sınıf
45	1	10	a
0	38	18	b
4	7	45	c

DVM için hata matrisi a; nöbet öncesi, b; nöbet ve c; nöbet sonrası olmak üzere, 56 nöbet öncesi verisinden 45 tanesi nöbet öncesi, 1 tanesi nöbet ve 10 tanesi nöbet sonrası olarak sınıflandırılmıştır. 56 nöbet verisinden ise 38 tanesi nöbet, 18 tanesi de nöbet sonrası olarak sınıflandırılmıştır. 56 nöbet sonrası verisinden de 45 tanesi nöbet sonrası, 4 tanesi nöbet öncesi 7 tanesi nöbet olarak sınıflandırılmıştır. En yüksek doğruluk oranları nöbet öncesi ile nöbet sonrası verilerde çıkmıştır.

Tablo 4.24: HFO tabanlı özniteliklere göre ÇKA sınıflandırıcısı sonuçları

ÇKA	TP	FP	ROC Alanı	PRC Alanı
Nöbet Öncesi	0,786	0,036	0,900	0,876
Nöbet	0,750	0,143	0,885	0,685
Nöbet Sonrası	0,732	0,188	0,814	0,744

ÇKA sınıflandırıcısı için doğruluk oranı %75.058, standart sapma 1.402 çıkmıştır. Ortalama mutlak değer ise 0.2074'dür. 168 örnekten 127 tanesi doğru sınıflandırılmıştır.

Tablo 4.25: HFO tabanlı özniteliklere göre ÇKA sınıflandırıcısı için hata matrisi

Nöbet	Nöbet Öncesi	Nöbet Sonrası	Sınıf
44	5	7	a
0	42	14	b
4	11	41	c

ÇKA için hata matrisinde, 56 nöbet öncesi verisinden 44 tanesi nöbet öncesi, 5 tanesi nöbet ve 7 tanesi nöbet sonrası olarak sınıflandırılmıştır. 56 nöbet verisinden ise 42 tanesi nöbet, 14 tanesi de nöbet sonrası olarak sınıflandırılmıştır. 56 nöbet sonrası verisinden de 41 tanesi nöbet sonrası, 4 tanesi nöbet öncesi 11 tanesi nöbet olarak sınıflandırılmıştır. En yüksek doğru oranı nöbet öncesi verilerde çıkmıştır. Sınıflar a; nöbet öncesi, b; nöbet ve c; nöbet sonrası için etiketlenmiştir.

Tablo 4.26: HFO tabanlı öznitelikler için sınıflandırıcılara göre doğruluk oranları

Sınıflandırıcı	**Doğruluk Oranı (%)**
K-NN	%77.329
Bayes	%77.142
RF	%77.436
ÇKA	%75.058
DVM	%75.42

HFO tabanlı öznitelikler için sınıflandırıcılar karşılaştırıldığında, doğruluk oranları K-NN, Bayes ve Rastgele orman için çok yakın olmakla birlikte en yüksek doğruluk oranı %77.436 ile rastgele orman sınıflandırıcısına aittir.

5. TARTIŞMA

Ciu ve diğerleri [132] epileptik manyetoensefalografi (MEG) sinyallerinde HFO olaylarını otomatik tespit etmek, kaynaklarını belirleyebilmek ve bu çalışmaları görsel hale getirmek için bilgisayar tabanlı grafik kullanıcı arayüzü geliştirmeye çalışmışlardır. Geliştirdikleri sistem ile %80 oranında verim elde etmişler ve klinik amaçlı kullanabileceğini belirtmişlerdir.

Shen ve diğerleri [133] yüksek frekans aktivitelerini göz önünde bulundurarak, bu aktivitelerin mekansal örüntü kümelemesini (SPC-HFA) geliştirmişlerdir. Bu yöntemin, çarpıklık ve uzamsal kümelenme yoluyla epileptik doku lokalizasyonu ve ilaç dirençli epilepsili hastalarda, cerrahi öncesi değerlendirmede kullanılabileceğini belirtmişlerdir.

Zhau ve diğerleri [134] nöbet bölgesi alanı ve nöbet bölgesi olmayan verilere ait sınıflandırma gerçekleştirmişlerdir. Öznitelik çıkarımı aşamasında entropi hesaplamalı filtreleme ve STFT kullanılmışlardır. Önerdikleri yöntem ile sınıflandırma aşamasında farklı veri setleri ile DVM, K-NN kullanmışlardır. Bir veri setinde DVM ile %92, başka bir veri seti ile de K-NN ile %91'lik başarı elde etmişlerdir.

Rosell [135] yaptığı çalışmada, HFO'lara bağlı olarak nöbet başlangıç bölgesinde, iEEG verileri ile patolojik salınımları tanımlayabilmek adına denetimli bir makine öğrenimi yöntemlerinden DVM'yi kullanmıştır. Patolojik HFO'yu tanımlamaya çalışırken, iyi öznitelikleri bulmayı da hedeflemiş ve frekans alanı özelliklerinin iyi sonuçlar verdiğini elde etmiştir. DVM ile %85'lik bir başarı elde etmiştir.

Cimbalnik ve diğerleri [136] fizyolojik ve patolojik HFO'ları ile yaptıkları çalışmada nöbet başlangıç bölgesinde patolojik HFO'ların güçlü şekilde ilişkili olduklarını ve çalışmadaki epilepsi hastalarının %70'inde nöbet başlangıç bölgesi elektrotlarında sayısının arttığını tespit etmişlerdir. Nöbet başlangıç bölgesini kullanarak DVM ile yaptıkları bireysel elektrot sınıflandırmasında %63,9 duyarlılık ve %73,7 özgüllük olranları elde etmişlerdir.

Migliorelli ve diğerleri [137] uzmanlar tarafından etiketleme yapılmasını gerektiren denetimsiz bir algoritma önermişlerdir. Zaman-frekans özelliklerine ve Gauss karışım modelleri ile kümelemeye dayanan bu algoritma ile iEEG verilerinde HFO'yu karakterize etmeye çalışmışlardır. Önerdikleri algoritma ile % 94 değerinde hassasiyet elde etmişlerdir.

Sameer ve diğerleri [138] epileptik nöbetlerin tespiti için Haralick özellikleri vasıtasıyla gama bandı (30-60 Hz) kullanılmışlardır. Diğer yöntemlerden farklı olarak tüm frekans spektrumunu değil, yüksek frekanslı (EEG) alt bandını kullanmışlar ve verimli sonuçlar elde etmişlerdir.

Daoud ve Bayoumi [139] nöbet ile ilintili EEG kanallarını belirleyebilmek adına bir kanal seçim algoritması önermişler ve ÇKA algoritması ile % 83 doğruluk elde etmişlerdir.

Al-jumaili ve diğerleri [140] epileptik nöbetlerin tanımı için sınıflandırıcılara FFT özellikleri uygulamış, DVM ile % 96, k-NN ile de % 92 doğruluk elde etmişlerdir. Daha sonra aynı sınıflandırıcılara entropi ve yaklaşık entropi özellikleri uygulanmış ve % 91 DVM, % 88 K-NN sınıflandırıcısı ile doğruluk elde etmişlerdir.

Kumar ve diğerleri [141] EEG sinyallerinden uyarlanabilir mod ayrıştırma yöntemi ile öznitelikleri çıkarmış, öznitelikleri sınıflandırarak epilepsi nöbetlerini tespit etmek için akıllı bir sistem tasarlamaya çalışmıştır. İki farklı veri setinde ÇKA sınıflandırıcısı ile % 99 ve % 100 oranlarında doğruluk elde etmişlerdir.

Wan ve diğerleri [142] nöbet başlangıç bölgesi tahmini ve HFO'ları tespit etmek amacıyla bir bulanık c-ortalama kümeleme algoritması kullanmışlardır. Bu algoritma ile HFO'ların tespiti ve lokalizasyonu bulunmaya çalışılmıştır. Önerdikleri dedektör ile %72 hassasiyet ve % 94 özgüllük elde etmişlerdir.

Sadek ve diğerleri [143] intrakraniyal EEG verilerinden konvolüsyonal sinir ağları ile öznitelikleri elde etmişler, öznitelik çıkarımından sonra kümeleme yöntemini uygulamış ve veri setleri için nöbet başlangıç bölgesini belirlemeyi başarmışlardır.

Broti ve diğerleri [144] elektrokortikogram verileri için konvolüsyonel sinir ağı tabanlı bir HFO tespit yöntemi geliştirmişlerdir. Derin öğrenme metodu ile bu verilerden öznitelik seçimi yapmış ve doğrusal ayrımcılık analizi algoritması ile % 87 doğruluk elde etmişlerdir.

Rafik ve Larbi [145] nöbet geçiren ve nöbet geçirmeyen EEG verilerinde ampirik mod ayrıştırması yöntemi ile öznitelik çıkarmaya çalışmış ve normal, iktal ve interiktal EEG sinyalleri için sınıflandırma yapmak amacıyla çok katmanlı algılayıcı sinir ağı kullanarak % 98 doğruluk oranı elde etmişlerdir.

Scott ve diğerleri [146] yaptıkları çalışma ile elde ettikleri ortalama HFO oranı, nöbet başlangıç bölgesi kanallarındaki tüm epoklar için diğer kanallara göre yüksek çıkmıştır. Çalışmalarında yer alan hastalarda preiktal ve interiktal epoklar sırasında, ortalama HFO oranında istatistiksel olarak anlamlı bir fark elde edilememiştir. Nöbet başlangıç bölgesi

kanallarındaki sürekli HFO oranları için, preiktal trendlerde interiktal dönemlere göre önemli artışlar elde edilmiştir.

EEG sinyallerinin tanımlanabilmesi, HFO analizi ve özellikle nöbet tahmini için pek çok çalışma yapılmış ve yapılmaya devam edilmektedir. Çoğu çalışmada otomatik nöbet tahmini algoritması tasarlanmaya çalışılmaktadır. Bu çalışmada ise intrakraniyal EEG verisinden nöbet öncesi, nöbet ve nöbet sonrası sınıflarına dair; öznitelik, en uygun kanallar ve HFO çalışması yapılmıştır.

6. SONUÇ VE ÖNERİLER

Bu tez çalışmasında epilepsi teşhisi konulmuş hastalar için nöbet oluşmadan önce bir biyobelirteç olduğu düşünülen yüksek frekans osilasyonları araştırılmıştır. Nöbet biyobelirteci olduğu geçmişte yapılmış bir çok çalışma ile gösterilmiş HFO'ların tespit edilebilmesi ve bir araç haline getirilebilmesi bu hastalıktan müzdarip olan kişiler için çok faydalı olacaktır.

HFO'ların nöbet öncesi, sırası ve sonrası değişimlerini belirleyebilmek için intrakranial EEG sinyallerinden zaman-frekans analizi yardımıyla HFO tespiti yapılmıştır. Tespit edilen HFO'lar 100 Hz – 150 Hz, 200 Hz – 250 Hz, 300-350 Hz ve 400 Hz -500 Hz bandlarından hangisinde yer aldığına göre etiketlenmiştir ve bu veri HFO tabanlı öznitelik olarak isimlendirilmiştir.

İstatistiksel ve yapısal özniteliklerin nöbet öncesi, sırası ve sonrası değişimlerini belirlemek için toplam 11 adet öznitelik seçilmiştir. Öznitelik sınıflandırmasında, yapılan sınıflandırma ile rastgele orman sınıflandırıcısı ile % 83,145, K-NN ile % 80,77, DVM ile % 80,249, ÇKA ile % 78,33 ve Bayes ile % 74,28 doğruluk oranları elde edilmiştir.

Öznitelik sınıflandırmasında, farklı özniteliklerin farklı sınıflandırıcılarda iyi sonuçlar vermesine rağmen çoğu öznitelik için en yüksek doğruluk oranını yine rastgele orman sınıflandırıcısı vermiştir.

HFO tabanlı özniteliklere göre sınıflandırmada, öncelikle EEG verilerinden yine aynı sınıflandırıcılar kullanılmış olup, rastgele orman sınıflandırıcısında % 77,436, K-NN sınıflandırıcısında % 77,329, Bayes'te % 77,142, DVM'de % 75,42 ve ÇKA'da % 75,058 doğruluk sonuçları elde edilmiştir. HFO tabanlı öznitelikler sınıflandırmasında sınıflandırıcılar birbirine yaklaşık değerler vermiş olmakla birlikte en yüksek doğruluk yine rastgele orman sınıflandırıcısı ile elde edilmiştir.

Farklı EEG kanallarının nöbet öncesi, sırası ve sonrası değişimlerini belirlemek üzere kanallara göre sınıflandırma yapılmıştır. Kanallara göre sınıflandırmada ise klinik uzman desteği ile yararlı olabilecek kanallar seçilmiştir. Seçilen 14 kanal için yapılan sınıflandırma sonucunda, ortalama doğruluk oranı 67,27 olmakla birlikte en yüksek doğruluk rastgele orman sınıflandırıcısında, % 77,97 oran ile 1. kanalda elde edilmiştir. Tüm kanallarda ortalama olarak Bayes sınıflandırıcısı için % 69.50, DVM için % 60.69, k-NN için % 73.55, rastgele orman sınıflandırıcısı için % 73.73 ve çok katlı algılayıcı için % 67.91 doğruluk oranları elde edilmiştir

Sonuç olarak; çalışmada HFO tespiti ve öznitelik sınıflandırması açılarından önceki çalışmalarla karşılaştırıldığında tatmin edici sonuçlar elde edilmiştir. Sınıflandırma aşamasında 10-kat çapraz doğrulama ve her bir sınıflandırma işlemi için 10 defa veriyi karıştır-sınıflandır işlemi yapılmıştır. Nihai doğruluk oranları bu işlemlerin ortalama ve standart sapmaları hesaplanarak verilmiştir.

Bununla birlikte, tüm işlemler tek bir veri seti üzerinden yapıldığından, bu işlemlerin farklı veri setleriyle doğrulanması da önem taşımaktadır. Yapılan bu çalışmanın, ileride yapılacak farklı çalışmalara yeni bir bakış açısı kazandırabileceği düşünülmektedir. Elde edilen bu doğruluk oranlarının, HFO tespiti, nöbet sınıflandırması ve kanal tespitlerindeki sonuçları ile, klinik amaçlar için otomatik tespit ve bir araç tasarlanması için yol gösterici olabileceği düşünülmektedir.

KAYNAKLAR

[1]. Bowman, J., Dudek, F.E., Spitz, M., 2009, *Epilepsy*, http://onlinelibrary.wiley.com, [Ziyaret Tarihi:16.10.2023]

[2]. Yazdanpour-Naeini R., 2012, *Automatic Detection of High Frequency Oscillations of Neural Signals in Epileptic Patients*, Thesis (Msc.), Concordia University.

[3]. Gandhi ,T., Panigrahi, B.K., Bhatia, M., Anan, S., 2010, Expert model for detection of epileptic activity in EEG signature, *Expert Systems with Applications*, 37 (4), 3513-3520.

[4]. Altunay, S., Telatar, Z., Erogul, O., 2010, Epileptic EEG detection using the linear prediction error energy, *Expert Systems with Applications*, 37 (8), 5661-5665.

[5]. Kaya, Y., Ertuğrul, Ö.F., Tekin, R., 2012, Epileptik EEG İşaretlerinin Sınıflandırılmasında Karar Kuralları ve Karar Ağaçlarının Kullanılması, *Batman Üniversitesi Yaşam Bilimleri Dergisi*, 1 (2), 403-413.

[6]. Joshi, V., Pachoria, R.B., Vijesh, A., 2014, Classification of ictal and seizure-free EEG signals using fractional linear prediction, *Biomedical Signal Processing and Control*, 9 (1), 1-5.

[7]. Gliske, S.V., Irwin, T.Z., Chestek, C., Stacey, C.W., 2016, Effect of sampling rate and filter settings on High Frequency Oscillation detections, *Clinical Neurophysiology*, 127 (9), 3042-3050.

[8]. Burnos, S., Hilfiker, P., Sürücü, O., Scholkmann, F., Krayenbühl, N., Grunwald, T., Sarnthein, J., 2014, Human Intracranial High Frequency Oscillations (HFOs) Detected by Automatic Time-Frequency Analysis, *Plos One*, 9 (4), 1-12.

[9]. Huang, L., Ni, X., Ditto, L.W., Spano, M., Carney, P.R., Lai, Y., 2017, Detecting and characterizing high frequency oscillations in epilepsy: a case study of big data analysis, *Royal Society open science*, DOI: 10.1098/rsos.160741.

[10]. Van Rosmalen, F., 2015, *Automatic detection of the HFO zone in epilepsy using magnetoencephalography*, Thesis (Msc.), University of Twente.

[11]. Liu, S., Sha, Z., Sencer, A., Aydoseli, A., Bebek, N., Abosch, A., Henry, T., Gurses, C., Ince, N.İ., 2016, Exploring the time–frequency content of high frequency oscillations for automated identification of seizure onset zone in epilepsy, *Journal of Neural Engineering*, 13 (2), 1-15.

[12]. Chaitanyaa, G., Sinhab,, S., Narayanan, M., Satishchandra, P., 2015, Scalp high frequency oscillations (HFOs) in absence epilepsy:An independent component analysis (ICA), *Epilepsy Research*, 115, 133-140.

[13]. Amiri, M., Lina, J., Pizzo, F., Gotman, J., 2016, High Frequency Oscillations and spikes: Separating real HFOs from false oscillations, *Clinical Neurophysiology.* 127 (1), 187-196

[14]. Zijlmans, M., Jacobs, J., Zelmann, R., Dubeau, F.J., Gotman, J., 2009, High-frequency oscillations mirror disease activity in patients with epilepsy, *Neurology,* 72 (11), 979–986.

[15]. Mooij, A.H., Raijmann, R.C.M.A, Jansen, F.E., Braun, K.P.J., Zijlmans, M., 2017, Physiological Ripples (± 100 Hz) in Spike-Free Scalp EEGs of Children With and Without Epilepsy, *Brain Topography,* 30 (6), 739–746.

[16]. Papadelis, C., Tamilia, E., Stufflebeam, S., Grant, P.E., Madsen, J.R., Pearl, P.L., Tanaka, N., 2016, Interictal High Frequency Oscillations Detected with Simultaneous Magnetoencephalography and Electroencephalography as Biomarker of Pediatric Epilepsy, *Journal Of Visualized Experiments*, 118.

[17]. Lachner, D., 2022, *Distinguishing between epileptic and physiologic high-frequency brain activity using automatically detected EEG patterns*, Thesis (PhD.), Albert Ludwigs University.

[18]. Pearce, A., Wulsin D., Blanco, J.A., Krieger, A., Litt ,B., Stacey, W.C., 2013,Temporal changes of neocortical high frequency oscillations in epilepsy, *Journal of Neurophysiology,* 110(5), 1167-1179.

[19]. Lai, D., Zhang, X., Kefei, M. K., Chen, Z., Chen, W., Zhang, H., Yuan, H., Ding, L., 2019, Automated Detection of High Frequency Oscillations in Intracranial EEG Using the Combination of Short-Time Energy and Convolutional Neural Networks, Special Section on Neural Engineering Informatic, *IEEE*, 7:1-1, 82501 – 82511.

[20]. Wang, Y., Xu, J, Liu, T., Chen, F., Chen, S., Yuan, L., Zhai, F., Liang, S., 2022, Diagnostic value of high-frequency oscillations for the epileptogenic zone: A systematic review and meta-analysis, *Seizure: European Journal of Epilepsy,* 99, 82–90.

[21]. Travnicek, V., Jurak, P, Cimbalnik, J, Klimes, P, Daniel, P, Brazdil, M., 2021, Ultra-fast oscillation detection in EEG signal from deep-brain microelectrodes, *43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, 1-5 November 2021, Mexico, IEEE, 978-1-7281-1180-3, 265-268.

[22]. Wu, M., Wan, T., Ding, M., Wan, X., Du, Y., She, J., 2018, A New Unsupervised Detector of High-Frequency Oscillations in Accurate Localization of Epileptic Seizure Onset Zones, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(12), 2280-2289.

[23]. López-Cuevas, A., Castillo-Toledo, B., Medina-Cejab, L., Ventura-Mejíab, C., Pardo-Pena K., 2013, An algorithm for on-line detection of high frequency oscillations related to epilepsy, *Computer Methods and Programs in Biomedicine,*110 (3), 354-360.

[24]. Liu ,X., Hu, L., Xu, C., Xu, S., Wang, S., Chen, Z., Shen, J., 2021, An Automatic HFO Detection Method Combining Visual Inspection Features with Multi-Domain Features, *Neuroscience Bulletin,* 37, 777–788.

[25]. Wan, X., Fang, Z., Wu, M., Du, Y., 2020, Automatic detection of HFOs based on singular value decomposition and improved fuzzy c-means clustering for localization of seizure onset zones, *Neurocomputing*, 400, 1-10.

[26]. Kotan, S., 2019, *EEG Sinyalleri İşlenerek Multipl Skleroz Hastalığının Tespiti Ve Sınıflandırılması*, Doktora Tezi, İstanbul Üniversitesi-Cerrahpaşa.

[27]. Signal_energy_power.png (1015×787) (projectrhea.org)] Ziyaret Tarihi 27.11.2023]

[28]. Hatem, G., Zeidan, J., Goossens, M., Moreira, C., 2022, Normality Testing Methods and the Importance of Skewness and Kurtosis in Statistical Analysis, *BAU Journal - Science and Technology*, 3(2), 1-5.

[29]. Sharma, N., Kolekar, M.H., Jha, K., Kumar, Y., 2019, EEG and Cognitive Biomarkers Based Mild Cognitive Impairment Diagnosis, *Innovation and Research in BioMedical engineering*, 40(2), 113-121.

[30]. Fu, K., Qu, J., Chai, Y., 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.

[31]. Safi, M.S., Safi, S.M.M., 2021, Early detection of Alzheimer's disease from EEG signals using Hjorth parameters, *Biomedical Signal Processing and Control*, 65, 1-8.

[32]. Oh, S.H., Lee, Y.R., Kim, H.N., 2014, A Novel EEG Feature Extraction Method Using Hjorth Parameter, *International Journal of Electronics and Electrical Engineering*, 2(2) , 106-110.

[33]. Cecchin, T., R. Ranta, R, Koessler, L., O. Caspary, O., Vespignani, H., Maillard, L., 2010, Seizure lateralization in scalp EEG using Hjorth parameters, *Clinical Neurophysiology*,121(3), 290-300.

[34]. Yu, M., Fang, M., 2022, Feature extraction of rolling bearing multiple faults based on correlation coefficient and Hjorth parameter, *ISA Transactions*, 129(B), 442-458.

[35]. Yu, M., Chen, W., Lu, Y., 2022, Fault diagnosis and location identification of rotor–stator rub-impact based on Hjorth parameters, *Engineering Failure Analysis*, 138, 1-15.

[36]. Kaushik, G., Gaur,P., Sharma, R.R., Pachori, R.B., 2022, EEG signal based seizure detection focused on Hjorth parameters from tunable-Q wavelet sub-bands, Biomedical Signal Processing and Control, 76, 1-8.

[37]. Horr, N.K., Mousavi, B.,Han, K., Li, A., Tang, R., 2023, Human behavior in free search online shopping scenarios can be predicted from EEG activation using Hjorth parameters, *Frontiers in Neuroscience*, 17, 1-15.

[38]. Mehmood R.M., Bilal M., Vimal S., Lee S.W., 2022, EEG-based affective state recognition from human brain signals by using Hjorth-activity, *Measurement*, 202, 1-11.

[39]. Tanveer M., Pachori R.B., Angami N.V., 2018, Classification of seizure and seizure-free EEG signals using Hjorth parameters,*2018 IEEE Symposium Series on Computational Intelligence (SSCI 8*, 18-21 November 2018, India, IEEE, 978-1-5386-9276-9, 2180-2185.

[40]. Cacciotti A., Pappalettera C., Miraglia F., Valeriani L., Judica E., Rossini P.M., Vecchio F., 2023, Complexity analysis from EEG data in congestive heart failure: A study via approximate entropy, *Acta Physiologica*, 238(2), 1-14.

[41]. Pappalettera C., Miraglia F., Cotelli M., Rossini P.M., Vecchio F., 2022, Analysis of complexity in the EEG activity of Parkinson's disease patients by means of approximate entropy, *GeroScience*, 44, 1599-1607.

[42]. Padma, Shri, T.K., Sriraam, N., Bhat,V., 2014, Characterization of EEG signals for identification of alcoholics using ANOVA ranked approximate entropy and classifiers, *International Conference on Circuits, Communication, Control and Computing,* 21-22 November 2014, India, IEEE, 978-1-4799-6546-5, 109-112.

[43]. Zhang, Z., Zhou, Y., Mei, T., Chen, Z., Zhou, Y., Du, S., Tian, X., 2013, Localization of epileptic foci based on scalp EEG and approximate entropy, *2013 6th International Conference on Biomedical Engineering and Informatics*, 16-18 December 2013, China, IEEE, 978-1-4799-2761-6, 240-244.

[44]. Kale, K.K., Gawande, J.P. Automated feature extraction of epileptic EEG using Approximate Entropy, IEEE, *12th International Conference on Hybrid Intelligent Sy*stems *(HIS)*, 04-07 December 2012, India, 978-1-4673-5116-4,474-477.

[45]. Kumar, Y., Dewal, M.L., Anand, R.S., Features extraction of EEG signals using approximate and sample entropy, *2012 IEEE Students' Conference on Electrical, Electronics and Computer Science*, IEEE, 01-02 March 2012, 978-1-4673-1515-9, India, 1-5.

[46]. Sheuli Akter, S., Islam, R., Tanaka, T., Iimura, Y., Mitsuhashi, T., Sugano, H., Wang, D., Molla, K.I., 2020, Statistical Features in High-Frequency Bands of Interictal iEEG Work Efficiently in Identifying the Seizure Onset Zone in Patients with Focal Epilepsy, *Entropy*, 22(12), 1-25.

[47]. Khan, S.U., Jan, S.U., Koo, I., 2023, Robust Epileptic Seizure Detection Using Long Short-Term Memory and Feature Fusion of Compressed Time–Frequency EEG Images, *Sensors*, 23, 1-19.

[48]. Skaria S., Savithryamma K.S., 2023, Nonlinear Analysis of the Dynamical Characteristics of EEG Sgnals in Epileptic Brains, *Journal of Korean Academy of Physchiatric and Mental Health Nursing*, 5(4), 513-534.

[49]. Ahamed, M.Z., Mastani, S.A., 2023, Power and Area Optimized Deep Learning Framework for Accurate Automatic Epileptic Seizure Detection, *Indian Journal of Science and Technology* 16(43), 3838-3845.

[50]. Kim, H.R., 2023, Characteristics of ceaselessly generable biological time series, *Journal of the Korean Physical Society*, 83, 814–827

[51]. Al-Qazzaz, N., Alrahhal, M., Jaafer, S., Ali, S., Ahmad, S., 2023, Automatic Diagnosis of Epileptic Seizures using Entropy-based Features and Multimodel Deep Learning Approaches. *Preprints*, 1, 1-16.

[52]. Korvin, G., 2022, *Rescaled Range Analysis*, Encylopedia of Mathematical Geosciences, In:Daya Sagar, B.S., Cheng, Q., McKinley, J., Agterberg, F.,(ed.),Springer Nature, Switzerland, ISBN:1871-756X, 1213-1217.

[53]. Djemili, R., Djemili, I., 2023, Nonlinear and chaos features over EMD/VMD decomposition methods for ictal EEG signals detection, *Computer Methods in Biomechanics and Biomedical Engineering*, 1-20.

[54]. Obukhov, A., Krasnyanskiy, M., Volkov, A., Nazarova, A., ,Teselkin, D., Patutin, K., Zajceva, D., 2023, Method for Assessing the Influence of Phobic Stimuli in Virtual Simulators, Journal of Imaging, 9(10), 1-40.

[55]. Diaz, M.A.H., Cordova, F., On the meaning of Hurst entropy applied to EEG data series, 2022, *Procedia Computer Science*, 199,1385-1392.

[56]. Akbari, H., Sadiq, M.T.,Siuly, S., Li.,Y., Wen, P., 2021, An Automatic Scheme with Diagnostic Index for Identification of Normal and Depression EEG Signals, *10th International Conference, HIS 2021*, 25-28 2021, Melbourne, VIC, Australia, 59–70.

[57]. Hassan, M. K., Islam, R., Tanaka., T., Molla, K.I., 2019, Epileptic Seizure Detection from EEG Signals Using Multiband Features with Feedforward Neural Network, *IEEE*, 02-04 October 2019, Japan, IEEE, 978-1-7281-2297-7, 231-238.

[58]. Yuan, Q., Zhou W., Liu,Y., Wang, J, 2012, Epileptic seizure detection in EEG using mutual information-based best individual feature selection, *Epilepsy&Behaviour*, 24(4), 415-421.

[59]. Liu Y., Weidong Zhou, W., Yuan, Q., Chen, S., 2012, Automatic Seizure Detection Using Wavelet Transform and SVM in Long-Term Intracranial EEG, *IEEE Transactions on Neural Systems and Rehabilitation Engineering* ,20(6), 749 – 7558.

[60]. Wang, X., Ling, Y., Ling, X., Li, X., Li, Z., Hu, K., Dai, M., Zhu, J., Du, Y., Yang, Q., 2022, A particle swarm algorithm optimization-based SVM–KNN algorithm for epileptic EEG recognition, *International Journal Of Intelligent Systems*, 37(12), 11233-11249.

[61]. Zhou, Z., 2021, *Machine Learning*, Tsinghua University Press,978-981-15-1966-6.

[62]. Hosseini, M.P., Amin Hosseini, A., Kiarash Ahi, K., 2020, A Review on Machine Learning for EEG Signal Processing in Bioengineering, *IEEE Reviews in Biomedical Engineering*, 14, 204 – 218.

[63]. Rasheed, K., Qayyum, A., Qadir, J., Sivathamboo, S., Kwa, P., Kuhlmann, L., O'Brien,T., Razi, A., 2020, Machine Learning for Predicting Epileptic Seizures Using EEG Signals: A Review, I*EEE Reviews in Biomedical Engineering*, 14, 139 – 155.

[64]. Gemein, A.W.L., Schirrmeister, R.T., Chrabąszcz, P., Wilson, D., Boedecker, J., Schulze-Bonhage, A., Hutter, F., Ball, T., 2020, Machine-learning-based diagnostics of EEG pathology, *NeuroImage*, 220, 1-16.

[65]. Saeidi, M., Karwowski, W., Farahani, F.V., Fiok, K., Taiar, R.P.A. Hancock, P. A., Awad Al-Juaid, A., 2021, Neural Decoding of EEG Signals with Machine Learning: A Systematic Review, *Brain Sciences*, 11(11), 1-44.

[66]. Aggarwal, S., Chugh, N., 2022, Review of Machine Learning Techniques for EEG Based Brain Computer Interface, *Archives of Computational Methods in Engineering*, 29, 3001-3020.

[67]. Sarker, I.H., 2021, Machine Learning: Algorithms, Real-World Applications and Research Directions, *SN Computer Science*, 2(160), 1-21.

[68]. Dadebayev, D., Goh W.W., Xion Tan X.E., 2022, EEG-based emotion recognition: Review of commercial EEG devices and machine learning techniques Journal of King Saud University - Computer and Information Sciences, 34(7), 4385-4401.

[69]. Van der Maaten, L.J.P., Postma,E.O., Van den Herik, H.J., 2008, Dimensionality Reduction: A Comparative Review, Masstricht University, 1-22.

[70]. Zebari, R.R., Abdulazeez,A.M., Zeebaree, D.Z., Zebari, D.A., Saeed,J.N., 2020, A Comprehensive Review of Dimensionality Reduction Techniques for Feature Selection and Feature Extraction, *Journal Of Applied Science and Technology Trends*, 1(2), 56-70.

[71]. Sinaga, K.P., Yang, M. S., 2020, Unsupervised K-Means Clustering Algorithm, in *IEEE Access*, vol. 8, pp. 80716-80727

[72]. Golalipour, K., Akbari , E., Hamidi.,S. S., Malrey Lee, M., Rasul EnayatifarR., 2021, From clustering to clustering ensemble selection: A review, Engineering Applications of Artificial Intelligence, 104, 1-21.

[73].Berka, P., Rauch, J., 2010, Machine Learning and Association Rules,University of Economics.

[74]. Ming,Y., Wu, D., Wang,Y.K., Shi Y., Lin, C.T., 2021, EEG-Based Drowsiness Estimation for Driving Safety Using Deep Q-Learning, in *IEEE Transactions on Emerging Topics in Computational Intelligence*, 5(4), 583-594.

[75]. Manjunatha, H., Esfahani, E.T., 2020, *Application of Reinforcement and Deep Learning Techniques in Brain–Machine Interfaces.* Advances in Motor Neuroprostheses, In: Vinjamuri, R.(ed). Springer, Switzerland, ISBN 978-3-030-38739-6, 1-15.

[76]. Kar, R., Ghosh, L., Konar, A., Chakraborty, A., Nagar, A.K., 2022, EEG-Induced Autonomous Game-Teaching to a Robot Arm by Human Trainers Using Reinforcement Learning, in IEEE Transactions on Games, 14(4) , 610-622,

[77]. Ninenko, I., Gritsenko, G., Bukreev, N., Ossadtchi, A., Lebedev, M., 2021, Brain-computer interface for olfaction: machine learning decoding odors from EEG, Third International Conference Neurotechnologies and Neurointerfaces (CNN), 13-15 September 2021, Russian Federation, IEEE, ISBN: 978-1-6654-2474-5,74-75

[78]. Göker, H., 2023, Multi-channel EEG-based classification of consumer preferences using multitaper spectral analysis and deep learning model, *Multimed Tools and Applications*, 1-19.

[79]. Asghar, M.A., Khan, J.M., Fawad, F., Amin, Y., ,Rizwan, M., Rahman, M., Badnava, S., Mirjavadi, S.S., 2019, EEG-Based Multi-Modal Emotion Recognition using Bag of Deep Features: An Optimal Feature Selection Approach, *Sensors*, 19(23), 1-16.

[80]. Slimen,I.B., Boubchir,L., Mbarki, Z., Seddik, H., 2020, EEG epileptic seizure detection and classification based on dual-tree complex wavelet transform and machine learning algorithms, *The Journal Of Biomedical Research*, 34(3), 151–161.,

[81]. Kusumaningrum, T.D., Faqih, A., Kusumoputro,B., 2019, Emotion Recognition Based on DEAP Database using EEG Time-Frequency Features and Machine Learning Methods, *Journal of Physics: Conference Series,* 1501,1-8.

[82]. Rodrigues, J.C., , Filho, P.P.R., Peixoto, E., Kumar N.A., de Albuquerque,V.H.C., 2019, Classification of EEG signals to detect alcoholism using machine learning techniques, *Pattern Recognition Letters,* 125,140-149.

[83]. Insight - Data Science Society, IMI, New Delhi: Image (wordpress.com), [Ziyaret Tarihi: 24.12.2023]

[84]. Fouad, I A., Labib, F.Z. M., 2023, Identification of Alzheimer's disease from central lobe EEG signals utilizing machine learning and residual neural network, Biomedical Signal Processing and Control, 86(B), 1-16.

[85]. Jukic, S., Saracevic, M., Subasi, A., Kevric, J., 2020, Comparison of Ensemble Machine Learning Methods for Automated Classification of Focal and Non-Focal Epileptic EEG Signals, *Mathematics*, 8(9), 1-16.

[86]. Rashid, M., Mustafa, M., Norizam Sulaiman, N., Abdullah, N.R,H., Samad, R., 2021, Random Subspace K-NN Based Ensemble Classifier for Driver Fatigue Detection Utilizing Selected EEG Channels, *Traitement du Signal*, 38(5), 1259-1270.

[87]. Rashid, M., Sulaiman, N., Mahfuzah, M., Khatun, S., Bari,B.S., 2019, The Classification of EEG Signal Using Different Machine Learning Techniques for BCI Application, *Robot Intelligence Technology and Applications*, 1015, 207–221.

[88]. Diah,T.K., Faqih, A., Kusumoputro, B., 2019, Exploring the Feature Selection of the EEG Signal Time and Frequency Domain Features for k - NN and Weighted k-NN, *IEEE R10 Humanitarian Technology Conference*, 12-14 November 2019, IEEE, Indonesia, ISSN: 2572-7621, 196-199.

[89]. Deepa, V.B., Thangaraj, P., 2011, Classification of EEG data using FHT and SVM based on Bayesian Network, *IJCSI International Journal of Computer Science Issues*, 8(5), 239-243.

[90]. He, L., Hu, D., Wan, M., Wen, Y., Deneen, K.M., Zhou, M.C., Common Bayesian Network for Classification of EEG-Based Multiclass Motor Imagery BCI, *IEEE Transactions on Systems, Man, and Cybernetics: Systems* , 46(6), 843 – 854.

[91]. He, L., Liu, B., Hu, D., Wen, Y., Wan, M., Lon, J., Motor imagery EEG signals analysis based on Bayesian network with Gaussian distribution, *Neurocomputing*, 5, 217-224.

[92]. Rezaei, S., Tavakolian, K., Nasrabadi, A.M., Setarehdan, S.K., 2006, Different classification techniques considering brain computer interface applications, *Journal of Neural Engineering, ,* 3(2), 139-144.

[93]. Sagee, G.S., Hema, S., 2017, EEG feature extraction and classification in multiclass multiuser motor imagery brain computer interface using Bayesian Network and ANN, *2017*

International Conference on Intelligent Computing, Instrumentation and Control Technologies (ICICICT), 06-07 July 2017, Kerala, India, IEEE, 938-943.

[94]. Antoniou, E., Bozios, P., Christou, V., Tzimourta, K.D., Kalafatakis, K., Tsipouras, M.G., Giannakeas, N., Tzallas, A.T., 2021, EEG-Based Eye Movement Recognition Using Brain–Computer Interface and Random Forests ,Sensors, *21*(7), 1-12.

[95]. Varone, G., Gasparini, S., Ferlazzo, E., Ascoli, M., Tripodi, G.G., Zucco, C., Calabrese, B., Cannataro, M., Aguglia, U., A Comprehensive Machine-Learning-Based Software Pipeline to Classify EEG Signals: A Case Study on PNES vs. Control Subjects, *Sensors, 20*(4), 1-12.

[96]. Malar, E., Gauthaam, M., 2020, Wavelet analysis of EEG for the identification of alcoholics using probabilistic classifiers and neural networks, *International Journal of Intelligence and Sustainable Computing*, 1(1), 3-18.

[97]. Bird, J.J., Ekart, A., Buckingham,C.D., Faria, D.R., Mental Emotional Sentiment Classification with an EEG based Brain-Machine Interface, The International Conference on Digital Image & Signal Processing (DISP'19), 29-30 April 2019, Oxford University, UK,1-7.

[98]. https:// genproresearch.com/components of bayesian approach, [Ziyaret Tarihi:23.12.2023].

[99]. Huang, W., Yan, G., Chang, W., Zhang, Y., Yuan, Y., 2023, EEG-based classification combining Bayesian convolutional neural networks with recurrence plot for motor movement/imagery, *Pattern Recognition*, 144, 1-16.

[100]. Ko, K.E., Yang, H.C., Sim, K.B., 2009, Emotion Recognition using EEG Signals with Relative Power Values and Bayesian Network, *International Journal of Control, Automation, and Systems*, 7(5), 865-870.

[101]. Wu, X., Jiang, B.,Yu ,K., Chen, H., 2021, Separation and recovery Markov boundary discovery and its application in EEG-based emotion recognition, *Information Sciences*, 571, 262-278.

[102]. Kumar, J.L., M., Rashid, M., Musa, R.M., Razman, M.A.M., Sulaiman, N., Jailani, R., Abdul Majeed, A.P.P., 2021, The classification of EEG-based winking signals: a transfer learning and random forest pipeline, *Peer J*, 9(2).

[103]. Wang, X., Gong, G., Li1, N., Qiu, S., 2019, Detection Analysis of Epileptic EEG Using a Novel Random Forest Model Combined With Grid Search Optimization Frontiers in Human Neuroscience, *Frontiers in Human Neurosci*ence, 13(52), 1-13.

[104]. Dimitriadis, S.I., Salis, I.S., Liparas, D., 2021, An automatic sleep disorder detection based on EEG cross-frequency coupling and random forest model, *Journal of Neural Engineering*, 18(4), 1-14.

[105]. https://corporatefinanceinstitute.com/resources/data-science/random-forest/, [Ziyaret Tarihi:22.12.2023].

[106]. Kamarajan, C., Ardekani, B.A., Pandey, A.K., Chorlian, D.B., Kinreich, S., Pandey, G., Meyers, J.L., Zhang, J., Kuang, W., Stimus, A.T., Porjesz, B., 2020 Random Forest Classification of Alcohol Use Disorder Using EEG Source Functional Connectivity, Neuropsychological Functioning, and Impulsivity Measures, *Behavioral Sciences* 10 (3), 1-32.

[1079. Rieg, T., Frick, J., Hitzler, M., Buettner, R., 2019, High-performance detection of alcoholism by unfolding the amalgamated EEG spectra using the Random Forests method, *52nd Hawaii International Conference on System Sciences*, 08-11 January 2019, USA, ISBN: 978-0-9981331-2-6, 3769-3777.

[108]. Malek, A., G., Mansoori, M., Omranpour, H., 2020, Random forest and rotation forest ensemble methods for classification of epileptic EEG signals based on improved 1D-LBP feature extraction, *International Journal of Imaging Systems and Technology*, 31(1), 189-203.

[109]. Omidvar, M., Zahedi, A., Bakhshi., H., 2021, EEG signal processing for epilepsy seizure detection using 5-level Db4 discrete wavelet transform, GA-based feature selection and ANN/SVM classifiers, *Journal of Ambient Intelligence and Humanized Computing*, 12, 10395-10403.

[110]. Lee H., Choi S., 2003, PCA+HMM+SVM for EEG pattern classification,,*Seventh International Symposium on Signal Processing and Its Applications*, 04 July 2003, France, IEEE, ISBN 0-7803-7946-2., 541-544.

[111]. Upadhyay P.K., Nagpal C., 2020, Wavelet Based Performance Analysis of SVM and RBF Kernel for Classifying Stress Conditions of Sleep EEG, *Romanıan Journal of Information Science and Technology*, 23(3), 292–310.

[112]. https://copyassignment.com/support-vector-machine-svm-in-machine-learning/

[Ziyaret Tarihi: 20.12.2023].

[113]. Abdulbaqi, A.S., Younis M.T., Younus , Y.T. , Obaid, A.J, 2022, A hybrid technique for EEG signals evaluation and classification as a step towards to neurological and cerebral disorders diagnosis, *International Journal of Nonlinear Analysis and Applications*, 13(1), 773-881.

[114]. Yasoda, K., Ponmagal, R.S., Bhuvaneshwari, K.S., Venkatachalam, K., 2020, Automatic detection and classification of EEG artifacts using fuzzy kernel SVM and wavelet ICA (WICA), *Soft Computing*, 24, 16011-16019.

[115]. Sharma, L.D., Bohat, V.K., Habib, M., Al-Zoubi, A.M., Faris H., Aljarah I., 2022, Evolutionary inspired approach for mental stress detection using EEG signal, *Expert Systems with Applications*, 197, 116634.

[116]. Sha'abani, M.N.A.H.N., Jamal, F.N., Ismail, M.F., 2020, kNN and SVM Classification for EEG: A Review, *International Conference on Electrical, Control & Computer Engineering,(InECCE2019), Lecture Notes in Electrical Engineering*, Springer, Singapore, ISBN: 978-981-15-2317-5, 632, 555–565.

[117]. Antony, M.J., Sankaralingam, B.P., Mahendran, R.K., Gardezi, A.A., Shafiq, M., Choi, J.G., Hamam, H., 2022, Classification of EEG Using Adaptive SVM Classifier with CSP and Online Recursive Independent Component Analysis, *Sensors,* 22(19), 1-17.

[118]. Kang, J., Han, X., Song, J., Niu, Z., Li, X., 2020, The identification of children with autism spectrum disorder by SVM approach on EEG and eye-tracking data, *Computers in Biology and Medicine,* 120, 1-5.

[119]. Priya, S., Shruthi, R.P.R.V., Pooja, R., Swarna, S., 2021, *Early detection of Parkinson's disease using data mining techniques from multimodal clinical data, Advanced Machine Vision Paradigms for Medical Image Analysis, Hybrid Computational Intelligence for Pattern Analysis and Understanding,* Tapan Gandhi, Siddhartha Bhattacharyya, Sourav De, Debanjan Konar, Sandip Dey, (ed), Chapter 8, Academic Press, ISBN 978-0-12-819295-5 ,213-228

[120]. Atangana R., Tchiotsop, D., Kenne, G., DjoufackNkengfack, L.C., 2020, EEG Signal Classification Using Lda and Mlp Classifier, *Health Informatics - An International Journal (HIIJ)*, 9(1), 14-32.

[121]. Li, C., Shao, C., Song, R., Xu, G., Liu, X., R., Qian, R., Chen, X., 2023, Spatio-temporal MLP network for seizure prediction using EEG signals, *Measurement,* 206, 1-14.

[122]. Jacob, J.E., Nair, G.K., 2019, EEG entropies as estimators for the diagnosis of encephalopathy, *Analog Integrated Circuits and Signal Processing*, 101, 463-474.

[123]. Čukić, M., Stokić, M., Simić, S., Pokrajac, D., 2020, The successful discrimination of depression from EEG could be attributed to proper feature extraction and not to a particular classification method, *Cognitive Neurodynamics,* 14, 443-455.

[124]. Xing, B., Zhang, H., Zhang, K., Zhang, L., Wu, X., Shi, X., Yu, S., Zhang, S., 2019, Exploiting EEG Signals and Audiovisual Feature Fusion for Video Emotion Recognition, *IEEE Access,* 7, 59844 – 59861

[125]. Gauthaam, M., Malar, E., 2020, Wavelet analysis of EEG for the identification of alcoholics using probabilistic classifiers and neural networks, *International Journal of Intelligence and Sustainable Computing*, 1(1), 3 – 18.

[126]. Abbasi, S. F., Ahmad, J., Tahir, A., Awais, M., Chen, C., Irfan, M., Siddiqa, H.A., 2020, EEG-Based Neonatal Sleep-Wake Classification Using Multilayer Perceptron Neural Network, *IEEE*, ISSN: 2169-3536, 8, 183025 – 183034.

[127]. Sharma, R., Kim, M., Gupta, A., 2022, Motor imagery classification in brain-machine interface with machine learning algorithms: Classical approach to multi-layer perceptron model, *Biomedical Signal Processing and Control,* 71, 1-10.

[128]. Kunjan, S., Grummett, T.S., Pope, K.J, Powers, D.M.W., Fitzgibbon, S.P., Bastiampillai, T., Battersby, M., Lewis, T.W., 2021, *The Necessity of Leave One Subject Out (LOSO) Cross Validation for EEG Disease Diagnosis*, Brain Informatics. BI 2021. Lecture Notes in Computer Science , Mahmud, M., Kaiser, M.S., Vassanelli, S., Dai, Q., Zhong, N. (eds), Springer, ISBN 978-3-030-86992-2, 12960, 558–567.

[129]. Enciso, M.P., Zingaretti, L.M., 2019, Review A Guide for Using Deep Learning for Complex Trait Genomic Prediction, *Genes*, 10, 1-19.

[130]. Arsalan, A., Majid, M., Butt, A.R., Anwar, S.M., 2019, IEEE Journal of Biomedical and Health Informatics, November 2019, Classification of Perceived Mental Stress Using A Commercially Available EEG Headband, *IEEE*, 23(6) ISSN: 2168-2194, 2257 – 2264.

[131]. Saeedi, M., Saeedi, A., Maghsoudi A., 2020, Major depressive disorder assessment via enhanced k-nearest neighbor method and EEG signals, *Physical and Engineering Sciences in Medicine*, 43, 1007–1018.

[132]. Cui, W., Cao, M., Wang, X., Zheng, L., Cen, Z., Teng, P., Luan, G., Gao, J., 2022, EMHapp: a pipeline for the automatic detection, localization and visualization of epileptic magnetoencephalographic high-frequency oscillations, Journal of *Neural Engineering*,19, 1-15.

[133]. Shen, M., Niu, H., Xia, Q., Zou, B., Zheng, Y., Zhao, Y., Li, L., Liu, X., Zhang, L., 2023, Automatic Epileptic Tissue Localization Through Spatial Pattern Clustering of High Frequency Activity, *EEE Transactıons on NeuraL Systems and Rehabilitation Engineering*, 31, 981-990.

[134]. Zhao, X., Zhao, Q., Tanaka, T., Casals, J.S., Zhou, G., Mitsuhashi, T., Sugano, H., Yoshida, N., Cao, J., 2023, Classification of the Epileptic Seizure Onset Zone Based on Partial Annotation , *Cognitive Neurodynamics*, 17, 703–713.

[135]. Rosell, S., 2020, Detection of Pathological HFO Using Supervised Machine Learning and iEEG Data, Thesis (M.Sc), Technological University Dublin, 1-94.

[136]. Cimbalnik, J., Brinkmann, B., Kremen, V., Jurak, P., Berry, B., Gompel, J.V., Stead, M., Worrell, G., 2018, Physiological and pathological high frequency oscillations in focal epilepsy, *Annals of Clinical and Translational Neurology*, 5(9), 1062-1076.

[137]. Migliorelli, C., Bachiller, A., Alonso, J.F., Romero, S., Aparicio, J., Van, J.J., Mañanas, M.A., Arce, V.S.A., 2020, SGM: a novel time-frequency algorithm based on unsupervised learning improves high-frequency oscillation detection in epilepsy, *Journal of Neural Engineering*, 17, 1-12.

[138]. Sameer, M., Gupta, A.K., Chakraborty, C., Gupta, B., 2020, ROC Analysis for detection of Epileptical Seizures using Haralick features of Gamma band, *2020 National Conference on Communications (NCC)*, 21-23 February 2020, India, 1-5.

[139]. Daoud, H., Bayoumi, M.A., 2019, Efficient Epileptic Seizure Prediction Based on Deep Learning, *IEEE Transactions on Biomedical Circuits and Systems*, 13(5), ISSN: 1932-4545, 804-813.

[140]. Al-jumaili, S., Duru, A.D., Ibrahim, A.A., Uçan, O.N., 2023, Investigation of Epileptic Seizure Signatures Classification in EEG Using Supervised Machine Learning Algorithms, *Traitement du Signal*, February 2023, 40(1), 43-54.

[141]. Kumar, G., Chander, S., Almadhor, A., 2022, An intelligent epilepsy seizure detection system using adaptive mode decomposition of EEG signals, *Physical and Engineering Sciences in Medicine*, 45, 261–272.

[142]. Wan, X., Fanga, Z., Wua, M., Du, Y., 2020, Automatic detection of HFOs based on singular value decomposition and improved fuzzy c-means clustering for localization of seizure onset zones, *Neurocomputing*, 400, 1-10.

[143]. Sadek, Z., Hadriche, A., Jmail, N., *Clustering of high frequency oscillations HFO in epilepsy using pretrained neural networks*, Intelligent Systems Design and Applications. ISDA 2022. Lecture Notes in Networks and Systems, In: Abraham, A., Pllana, S., Casalino, G., Ma, K., Bajaj, A. (eds), Springer, ISBN: 978-3-031-35500-4, 100-107

[144]. Broti, N., M., Sawada, M., Takayama, Y., Iwasaki, M., Ono, Y., 2023, Detection of high-frequency biomarker signals of epilepsy by combined deep-learning feature selection and linear discrimination analysis, *The 37th Annual Conference of the Japanese Society for Artificial Intelligence*,06-09 June 2023, Japan, Online ISSN : 2758-7347, 1-4.

[145]. Rafik, D., Larbi, B., 2019, Autoregressive Modeling Based Empirical Mode Decomposition (EMD) for Epileptic Seizures Detection Using EEG Signals, *Traitement du Signal*, 36(3), 273-279.

[146]. Scott, J.M., Ren, S., Gliske, S.V., Stacey,W.C., 2020, Preictal variability of high-frequency oscillation rates in refractory epilepsy,Epilepsia, 61(11), 2521-2533.

İNTİHAL RAPORU İLK SAYFASI

Pelin SARI TEKTEN

ORİJİNALLİK RAPORU

%1	%1	%1	%0
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	acikbilim.yok.gov.tr İnternet Kaynağı	<%1
2	dspace.ankara.edu.tr İnternet Kaynağı	<%1
3	essay.utwente.nl İnternet Kaynağı	<%1
4	aperta.ulakbim.gov.tr İnternet Kaynağı	<%1
5	Submitted to Eskisehir Osmangazi University Öğrenci Ödevi	<%1
6	dspace.gazi.edu.tr İnternet Kaynağı	<%1
7	harvest.usask.ca İnternet Kaynağı	<%1
8	Abdullah Ammar Karcioglu, Hasan Bulut. "Performance Evaluation of Classification Algorithms Using Hyperparameter Optimization", 2021 6th International	<%1