

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**EEG İŞARETLERİNİN EPİLEPTİK NÖBET
KESTİRİMİNDE MODERN YÖNTEMLERLE ANALİZİ
VE SINIFLANDIRILMASI**

DOKTORA TEZİ

Erhan BERGİL

Enstitü Anabilim Dalı : **ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ**
Enstitü Bilim Dalı : **ELEKTRONİK**
Tez Danışmanı : **Doç. Dr. Mehmet Recep BOZKURT**

Şubat 2018

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

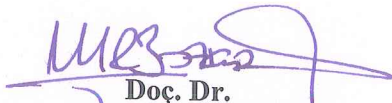
EEG İŞARETLERİNİN EPİLEPTİK NÖBET
KESTİRİMİNDE MODERN YÖNTEMLERLE ANALİZİ
VE SINIFLANDIRILMASI


DOKTORA TEZİ

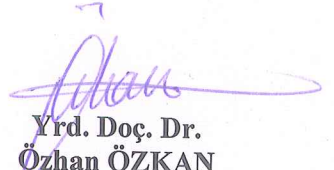
Erhan BERGİL

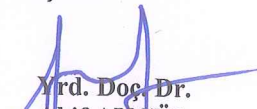
Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ

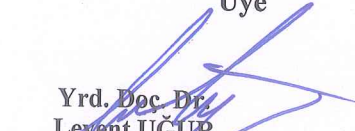
Bu tez 07 / 02 /2018 tarihinde aşağıdaki jüri tarafından Oybirliği ile kabul edilmiştir.


Doç. Dr.
Mehmet Recep BOZKURT
Jüri Başkanı


Yrd. Doç. Dr.
Engin Ufuk ERGÜL
Üye


Yrd. Doç. Dr.
Özhan ÖZKAN
Üye


Yrd. Doç. Dr.
Akif AKGÜL
Üye


Yrd. Doç. Dr.
Levent UĞUR
Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Erhan BERGİL

07.02.2018

TEŐEKKÜR

Doktora eđitimim süresince bilgi ve deneyimlerinden yararlandığım, danışmanım Doç. Dr. Mehmet Recep BOZKURT'a, Dr. Murat YILDIZ'a, Yrd. Doç. Dr. Engin Ufuk ERGÜL'e, Yrd. Doç. Dr. Özhan ÖZKAN'a, Yrd. Doç. Dr. Levent UĞUR'a ve Yrd. Doç. Dr. Akif AKGÜL'e teşekkürlerimi sunarım.

Çalışmanın bu aşamaya gelmesinde büyük katkıları olan, arkadaşım Canan ORAL'a çok teşekkür ederim. Bu günlere gelmemi sağlayan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen anneme, babama ve kardeşlerime çok teşekkür ederim.

Zor zamanlarımda hep yanımda olan sevgili eşim Ayfer SU BERGİL'e, bu çalışma esnasında gösterdiği emsalsiz anlayış ve dayanışmadan dolayı çok teşekkür ederim. Son olarak oyun zamanlarından feragat eden kızlarım Yarensu ve Cansu'ya, geleceğe umutla ve mutlulukla bakmamı sağlayan dünyalar güzeli kızlarıma çok teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	iv
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ	ix
ÖZET	xi
SUMMARY	xii
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
KAYNAK ARAŞTIRMASI.....	5
2.1. Epilepsi	5
2.2. Elektroensafalogram İşaretleri ve Özellikleri	6
2.2.1. Klinik EEG	10
2.2.3. Anormal EEG	13
2.3. Literatür Özeti.....	17
BÖLÜM 3.	
MATERYAL VE YÖNTEMLER	25
3.1. Veri Edinimi ve Ön işlem.....	25
3.2. Öznitelik Çıkarımı	27
3.2.1. Aritmetik ortalama.....	28
3.2.2. Standart sapma	28
3.2.3. Varyans	28

3.2.4. Güç	29
3.2.5. Sıfır geiş oranı	29
3.2.6. Öz baėlanım modeli	30
3.2.7. Hjorth parametreleri	30
3.2.8. Shannon entropi.....	31
3.2.9. Renyi entropi	32
3.3. Boyut İndirgeme ve Öznitelik Seçimi.....	32
3.3.1. Temel bileşenler analizi.....	33
3.3.2. İki boyutlu veri kümesi için TBA yönteminin uygulanması	34
3.4. Kanal Seçimi.....	38
3.5. Sınıflandırma.....	39
3.5.1. Doğrusal diskiriminant analizi	40
3.5.2. k- En yakın komşu algoritması.....	45
3.5.3. Destek vektör makineleri.....	48
3.5.3.1. Doğrusal destek vektör makineleri.....	48
3.5.3.1. Doğrusal olmayan destek vektör makineleri.....	53
3.5.4. Çok katmanlı yapay sinir aėları.....	59
3.5.4.1. Çok katmanlı yapay sinir aėı yapısı	61
3.6. Sınıflandırma başarıml ölçütleri.....	68
BÖLÜM 4.	
ARAŞTIRMA BULGULARI	72
BÖLÜM 5.	
SONUÇLAR VE ÖNERİLER	102
KAYNAKLAR.....	109
ÖZGEÇMİŞ	115

SİMGELER VE KISALTMALAR LİSTESİ

AO	: Aritmetik ortalama
b	: Destek vektör makinelerinde sapma değeri
C	: Düzenleyici parametre
ÇKYSA	: Çok katmanlı yapay sinir ağları
d	: Mesafe
DDA	: Doğrusal diskriminant analizi
DVM	: Destek vektör makineleri
E	: Toplam karesel hata değeri
e	: Sinir çıkışındaki hata değeri
EAA	: Eğri altındaki alan
EEG	: Elektroensefalogram
f(x)	: Karar fonksiyonu
GN	: Gerçek negatif
GP	: Gerçek pozitif
HA	: Hjorth aktivitesi
HH	: Hjorth hareketliliği
HK	: Hjorth karmaşıklığı
Hz	: Hertz
I	: Sinir hücresinin ağırlıklı toplamı
İKE	: İşlem karakteristik eğrisi
J(w)	: Amaç fonksiyonu
K	: Kovaryans matrisi
KKT	: Karush-Kuhn-Tucker koşulları
k-EYK	: k- en yakın komşu
K(x _i ,x _j)	: Çekirdek fonksiyonu
MRG	: Manyetik rezonans görüntüleme

O	: Sinir hücresi çıkışı
ÖBM	: Öz bağlantım modeli
P	: Güç
p	: Çıkış katmanındaki hücre sayısı
PET	: Pozitron emisyon tomografi
RE	: Renyi entropi
RTF	: Radyal tabanlı fonksiyon
s	: Saniye
SE	: Shannon entropi
SGO	: Sıfır geçiş oranı
S_W	: Sınıf içi dağılım matrisi
S_B	: Sınıflar arası dağılım matrisi
TBA	: Temel bileşenler analizi
V	: Özvektör
VAR	: Varyans
YN	: Yanlış negatif
YP	: Yanlış pozitif
YSA	: Yapay sinir ağları
λ	: Özdeğer
μV	: Mikro volt
θ	: Yönelme açısı
α_i	: Lagrange çarpanı
β	: Öğrenme oranı
ε	: Beyaz gürültü
$\phi(x_i)$: Doğrusal olmayan haritalama fonksiyonu
w	: Ağırlık katsayısı
σ	: Standart sapma
δ	: Sinir hücresi eğimi
ξ	: Gevşek değişken
$\psi(\cdot)$: Etkinleştirme fonksiyonu

ŞEKİLLER LİSTESİ

Şekil 2.1. Farklı epilepsi nöbetleri ve göz kırpma anına ait EEG örnekleri ve alt bantlar.....	8
Şekil 2.2. Epilepsili bir bireyden normal dönemde (nöbetsiz) kaydedilen 5 s'lik EEG örneği ve alt bantları	10
Şekil 2.3. Uluslar arası EEG toplulukları federasyonu tarafından önerilen 10-20 elektrot yerleşimi.....	11
Şekil 2.4. Genişletilmiş 10-20 sistemi elektrot dağılımı	11
Şekil 2.5. Normal, nöbet öncesi ve nöbetli dönemlere ait EEG örnekleri	16
Şekil 3.1. Tasarlanan sistemin öbek çizgesi.....	25
Şekil 3.2. Veri kümesinin grafiksel gösterimi	35
Şekil 3.3. Dönüşüm sonucunda elde edilen veri kümesinin grafiksel gösterimi.....	37
Şekil 3.4. DDA örnek uzayı.....	42
Şekil 3.5. Örnek uzayı ve yüksek özdeğerli özvektör için izdüşümü eksenini.....	43
Şekil 3.6. Örnek uzayı ve düşük özdeğerli özvektör için izdüşümü.....	44
Şekil 3.7. k- en yakın komşu algoritması sınıflandırma örneği.....	45
Şekil 3.8. (5,8) noktasının en yakın 3 komşusu.....	47
Şekil 3.9. a) Doğrusal olarak ayırabilen hiper düzlemler b) İki farklı hiper düzlem için sınır genişlikleri.....	49
Şekil 3.10. En uygun hiper düzlem.....	49
Şekil 3.11. En uygun hiper düzlem için geometrik yaklaşım.....	51
Şekil 3.12. Eğitim verilerinin doğrusal olarak ayıramadığı durum örneği.....	54
Şekil 3.13. Verilerin giriş uzayından özellik uzayına aktarımı.....	57
Şekil 3.14. DVM Ağ yapısı.....	59
Şekil 3.15. Yapay sinir hücresi modeli.....	60
Şekil 3.16. ÇKYSA ağ mimarisi.....	62
Şekil 3.17. Etkinleştirme fonksiyonları.....	67

Şekil 3.18. İşlem karakteristik eğrisi.....	70
Şekil 4.1. Kanalların ortalama doğruluklarının dağılımları.....	75
Şekil 4.2. Hasta 1'e ait test verisinin temel bileşenler dağılımı.....	77
Şekil 4.3. Hasta 1'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri..	78
Şekil 4.4. Hasta 2'ye ait test verisinin temel bileşenler dağılımı.....	79
Şekil 4.5. Hasta 2'ye ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri.....	80
Şekil 4.6. Hasta 3'e ait test verisinin temel bileşenler dağılımı.....	80
Şekil 4.7. Hasta 3'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri..	81
Şekil 4.8. Hasta 4'e ait test verisinin temel bileşenler dağılımı.....	82
Şekil 4.9. Hasta 4'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri..	83
Şekil 4.10. Hasta 5'e ait test verisinin temel bileşenler dağılımı.....	83
Şekil 4.11. Hasta 5'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri.	85
Şekil 4.12. Hasta 6'ya ait test verisinin temel bileşenler dağılımı.....	85
Şekil 4.13. Hasta 6'ya ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri.....	86
Şekil 4.14. Hasta 7'ye ait test verisinin temel bileşenler dağılımı.....	87
Şekil 4.15. Hasta 7'ye ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri.....	88
Şekil 4.16. Hasta 8'e ait test verisinin temel bileşenler dağılımı.....	89
Şekil 4.17. Hasta 8'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri.....	90
Şekil 4.18. Hasta 9'a ait test verisinin temel bileşenler dağılımı.....	90
Şekil 4.19. Hasta 9'a ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri.....	91
Şekil 4.20. Hasta 10'a ait test verisinin temel bileşenler dağılımı.....	92
Şekil 4.21. Hasta 10'a ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri.....	93
Şekil 4.22. Hasta 11'e ait test verisinin temel bileşenler dağılımı.....	94
Şekil 4.23. Hasta 11'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri.....	95
Şekil 4.24. Hasta 12'ye ait test verisinin temel bileşenler dağılımı.....	96

Şekil 4.25. Hasta 12'ye ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri.....	97
Şekil 4.26. Hasta 13'e ait test verisinin temel bileşenler dağılımı.....	97
Şekil 4.27. Hasta 13'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri.....	99
Şekil 4.28. Hasta 14'e ait test verisinin temel bileşenler dağılımı.....	99
Şekil 4.29. Hasta 14'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri.....	101

TABLolar LİSTESİ

Tablo 2.1. EEG alt bantları ve frekans aralıkları.....	7
Tablo 3.1. Demografik bilgiler.....	26
Tablo 3.2. Hastalara ait örnek sayıları.....	26
Tablo 3.3. Öznitelikler.....	27
Tablo 3.4. Güç hesaplanan alt bantlar ve bant genişlikleri.....	29
Tablo 3.5. (a) örnek veri kümesi, (b) sıfıra ortalanmış veri kümesi.....	35
Tablo 3.6. Dönüşüm sonucunda elde edilen veri kümesi.....	36
Tablo 3.7. Dönüşüm sonucunda elde edilen indirgenmiş veri kümesi.....	37
Tablo 3.8. Ön sınıflandırma işlemi gerçekleştirilen kanallar.....	38
Tablo 3.9. DDA uygulaması için iki boyutlu örnek uzayı ve sınıf bilgileri.....	41
Tablo 3.10. k-EYK uygulaması için iki boyutlu örnek uzayı ve sınıf bilgileri.....	46
Tablo 3.11. (5,8) noktası için hesaplanan mesafeler.....	47
Tablo 3.12. Çekirdek fonksiyonları.....	59
Tablo 3.13. Karışıklık matrisi yapısı.....	68
Tablo 3.14. Karışıklık matrisi örneği.....	70
Tablo 4.1. Ön sınıflandırma işlemi için ortalama doğruluk ve standart sapma değerleri.....	73
Tablo 4.2. Ön sınıflandırma işlemi sonucunda hastalara ait kanal ortalama doğruluğu dalgalanma yüzdeleri.....	75
Tablo 4.3. Ön sınıflandırma işlemi sonucunda belirlenen kanallar.....	76
Tablo 4.4. Eğitim seti ve test seti örnek sayıları.....	76
Tablo 4.5. Hasta 1 için sınıflandırıcıların karışıklık matrisi.....	77
Tablo 4.6. Hasta 1 için sınıflandırma başarımları.....	78
Tablo 4.7. Hasta 2 için sınıflandırıcıların karışıklık matrisi.....	79
Tablo 4.8. Hasta 2 için sınıflandırma başarımları.....	79
Tablo 4.9. Hasta 3 için sınıflandırıcıların karışıklık matrisi.....	81

Tablo 4.10. Hasta 3 için sınıflandırma başarımları.....	81
Tablo 4.11. Hasta 4 için sınıflandırıcıların karışıklık matrisi.....	82
Tablo 4.12. Hasta 4 için sınıflandırma başarımları.....	82
Tablo 4.13. Hasta 5 için sınıflandırıcıların karışıklık matrisi.....	84
Tablo 4.14. Hasta 5 için sınıflandırma başarımları.....	84
Tablo 4.15. Hasta 6 için sınıflandırıcıların karışıklık matrisi.....	86
Tablo 4.16. Hasta 6 için sınıflandırma başarımları.....	86
Tablo 4.17. Hasta 7 için sınıflandırıcıların karışıklık matrisi.....	87
Tablo 4.18. Hasta 7 için sınıflandırma başarımları.....	87
Tablo 4.19. Hasta 8 için sınıflandırıcıların karışıklık matrisi.....	89
Tablo 4.20. Hasta 8 için sınıflandırma başarımları.....	89
Tablo 4.21. Hasta 9 için sınıflandırıcıların karışıklık matrisi.....	91
Tablo 4.22. Hasta 9 için sınıflandırma başarımları.....	91
Tablo 4.23. Hasta 10 için sınıflandırıcıların karışıklık matrisi.....	92
Tablo 4.24. Hasta 10 için sınıflandırma başarımları.....	92
Tablo 4.25. Hasta 11 için sınıflandırıcıların karışıklık matrisi.....	94
Tablo 4.26. Hasta 11 için sınıflandırma başarımları.....	94
Tablo 4.27. Hasta 12 için sınıflandırıcıların karışıklık matrisi.....	96
Tablo 4.28. Hasta 12 için sınıflandırma başarımları.....	96
Tablo 4.29. Hasta 13 için sınıflandırıcıların karışıklık matrisi.....	98
Tablo 4.30. Hasta 13 için sınıflandırma başarımları.....	98
Tablo 4.31. Hasta 14 için sınıflandırıcıların karışıklık matrisi.....	100
Tablo 4.32. Hasta 14 için sınıflandırma başarımları.....	100
Tablo 4.33. Ortalama sınıflandırma başarımları.....	101
Tablo 5.1. Performans karşılaştırması.....	106

ÖZET

Anahtar kelimeler: EEG, epilepsi, nöbet, sınıflandırma, nöbet kestirimi

Epilepsi en sık görülen nörolojik hastalıklardan birisidir. Öngörülemeyen zamanlarda ortaya çıkan nöbetler hastalara zor anlar yaşatabilmekte, bazı durumlarda ölümlere neden olmaktadır. Güvenilir nöbet kestirim sistemlerinin geliştirilmesi hastalar için hayati önem taşımaktadır. EEG işaretlerinin epileptik analizinde, çoğunlukla nöbetli ve normal olarak ayrıştırılması problemine çözüm üretilmeye çalışılmaktadır. Bu tezde, EEG işaretleri, sadece nöbet ve normal olarak ayrıştırılmamış, nöbet öncesi döneme ait EEG örnekleri de dikkate alınmıştır. Bu amaçla iki sınıflı bir sınıflandırma işlemi (normal-nöbet) yerine üç sınıflı (normal, nöbet öncesi ve nöbet dönemi) bir sınıflandırma gerçekleştirilmiştir. Nöbet kestirimi için hayati önem taşıyan nöbet öncesi dönem EEG kayıtlarının etiketlenmesi işleminde, klasik ve modern sınıflandırıcıların davranış biçimleri incelenerek, kestirim için uygun olanlar tespit edilmeye çalışılmıştır. 21 kanaldan baskın olanı belirlemek için yinelemeli ön sınıflandırma gerçekleştirilmiştir. Böylelikle, kanal seçiminin nöbet kestirimi üzerindeki etkileri değerlendirilmiştir. Baskın kanala ait EEG işaretleri dört yöntem kullanılarak sınıflandırılmıştır. Sınıflandırma sonuçları karşılaştırılarak, yöntemlerin üstünlükleri ve zayıf yönleri belirlenmiştir.

Sınıflandırma sonuçları değerlendirildiğinde, destek vektör makineleri yönteminin yüksek doğruluk özelliğiyle öne çıktığı gözlemlenmektedir. Bu yöntem ile ortalama %93,51 doğrulukta sınıflandırma gerçekleştirilmiştir. Nöbet kestirimi açısından, nöbet öncesi dönem duyarlılığı oldukça anlamlıdır. Bu bağlamda doğrusal diskriminant analizi yöntemi diğer yöntemlere göre daha başarılıdır. Nöbet öncesi dönemler, doğrusal diskriminant analizi yöntemiyle ortalama %89,10 duyarlılıkla tespit edilmiştir. Doğruluk ve duyarlılık ölçütleri dikkate alındığında k- en yakın komşuluk yönteminin yapay sinir ağlarına göre daha başarılı olduğu görülmektedir. Sınıflandırma sonuçları epilepsinin türüne ve karakteristiğine bağlı olarak kimi hastalarda nöbet kestiriminin güç olmayacağını göstermektedir. Bu aşamada en önemli nokta, hastalığın karakterini belirleyebilecek yeterlikte EEG işaretini temin etmektir. Araştırmada elde edilen bulgular, güncel bilgi ve iletişim teknolojileriyle uyumlu, etkili nöbet kestirim sistemlerinin geliştirilmesi noktasında umut vericidir.

THE ANALYSIS AND CLASSIFICATION OF EEG SIGNALS IN THE EPILEPTIC SEIZURE PREDICTION BY MODERN METHODS

SUMMARY

Keywords: EEG, epilepsy, seizure, classification, seizure prediction

Epilepsy is one of the most common neurological diseases. The seizures occurred in unpredictable occasions may cause the patients to have difficult times and in some cases it may result in death. The design of safe seizure prediction systems has vital importance for patients. Mostly, it is aimed to provide solutions to the problem of discriminating the signals as normal or ictal in the epileptic analysis of EEG signals. In this dissertation, the EEG signals haven't been analyzed regarding as ictal and normal but also the EEG records belonging to the pre-ictal stage have been taken into consideration. For this purpose, instead of using the two-class classification process (normal-ictal), a three-class classification (normal, pre-ictal and ictal) has been implemented. In the process of labeling the pre-ictal EEG records which have vital importance in the seizure prediction, the characteristics of conventional and modern classifiers have been investigated and the appropriate classifiers for prediction have been tried to determine. In order to detect the most dominant one from 21 channels, recurrent pre-classification has been carried out. By this way, the effect of channel selection on seizure prediction has been evaluated. EEG signals belonging to the dominant channel have been classified through four methods. The advantages and disadvantages of the methods have been specified by comparing the results of the classification.

When the classification results have been evaluated, it is observed that the method of support vector machines come into prominence with the high accuracy performance. With this method, classification has been carried out with average 93,51 % accuracy. In terms of seizure prediction, the sensitivity of pre-ictal period has been reasonably significant. In this sense, the method of linear discriminant analysis has the best performance. Pre-ictal stages have detected with average 89,10 % sensitivity via the method of linear discriminant analysis. According to sensitivity and accuracy parameters, it has been seen that k-nearest neighbor method is more successful than artificial neural networks. The results of the classification show that in some cases the seizure prediction is not difficult based on the type and characteristics of the epilepsy. At this process the most important factor is to provide EEG signals which are enough to determine the characteristics of the disease. The findings of the dissertation are promising in the development of the effective, seizure prediction systems also compatible with current information and communication technologies.

BÖLÜM 1. GİRİŞ

Epilepsi tekrarlayan nöbetler ile karakterize edilen kronik bir hastalıktır. Beynin elektriksel faaliyetlerindeki geçici anormallikler nöbet olarak adlandırılmaktadır. Merkezi sinir sistemi bozukluğu olan epilepsili bireyler, öngörülemeyen zamanlarda, belirti vermeksizin ortaya çıkan nöbetler yüzünden sıkıntı yaşamaktadırlar. Nöbetler çarpınmalara ve dikkat dağınıklığına neden olabilmektedir. Nöbetler yaralanmalara yol açabilmekte, hatta bazı durumlarda ölümle sonuçlanabilmektedir (Shoeb ve Guttag, 2010; World Health Organization, 2017).

Epilepsi en yaygın rastlanan nörolojik hastalıklardan birisidir. Dünya genelinde yaklaşık 50 milyon epilepsi hastası bulunmaktadır. Epilepsi vakalarının yaklaşık %80'lik kısmına gelişmekte olan ülkelerde rastlanmaktadır. Hastaların %70'i tedaviye yanıt vermektedir. Düşük ve orta gelirli ülkelerde yaşayan epilepsili bireylerin yaklaşık dörtte üçü ihtiyaç duydukları tedaviyi alamamaktadır. Epilepsi hastaları ve hasta yakınları dünyanın birçok bölgesinde ayrımcılığa maruz kalmakta ve dışlanmaktadır (World Health Organization, 2017).

Türkiye'de 700.000 epilepsi hastasının olduğu tahmin edilmektedir. Epilepsi hastaları günlük hayatlarından iş yaşamlarına kadar birçok zorlukla karşılaşmaktadır. Bu hastalar arasındaki genç işsizlik oranı sağlıklı bireyler arasındaki genç işsizlik oranının 3 katıdır. Özellikle epilepsili çocuklar durumlarının farkında olamayışlarından ve ifade edememelerinden dolayı çok daha zor durumdadırlar. Hastalık bireylerin yaşam kalitesini düşürmekle kalmamakta, ölümlere yol açmaktadır. Aynı zamanda büyük bir ekonomik maliyeti de beraberinde getirmektedir (Türk Epilepsi ile Savaş Derneği, 2017).

Klinik analizler ve epilepsi arařtırmaları için, epileptik nöbet algılaması ve kestirimi ilginç bir konu haline almıřtır. Bu bize yeni tanı yaklařımları ve oluřacak nöbetten sakınmak için denetim iřareti saęlayacaktır. Nöbet kestiriminde güvenilir yöntemlerin bulunması epilepsili bireylerin güvenliğini saęlayacak ve yařam kalitesini arttıracaktır. Dięer taraftan nöbet öncesinde epilepsinin altında yatan mekanizmayı keřfetmek için yararlı olacaęı düşünölmektedir (Ouyang ve ark., 2007).

Epilepsi nöbetinin teřhisi için elektroensefalografi, manyetik rezonans görüntöleme (MRG) ve pozitron emisyon tomografi (PET) gibi birçok yöntem bulunmaktadır. EEG kayıt sistemleri epilepsi hastalıęı teřhisinde yaygın olarak kullanılmaktadır (Mohseni, Maghsoudi ve Shamsollahi, 2006; Sivasankari ve Thanushkodi, 2009; Vavadi, Ayatollahi ve Mirzaei, 2010). Bu sistemler beyin aktivitelerini sayısal veri olarak kaydetmektedir. Elektroensefalogram (EEG) iřaretlerinin içerdięi genlik ve frekans gibi temel özellikler, farklı özellik çıkarımı yöntemleri kullanılarak birkaç öznitelige sıkıřtırılabilir.

Bu ařamada birçok arařtırmacı tarafından, EEG iřaretlerinin farklı özellikleri kullanılarak analizler yapılmıřtır. Non-lineer özellikler, entropi tabanlı özellikler, zaman düzlemi özellikleri, frekans düzlemi özellikleri, güç spektrumu, zaman-frekans daęılımları yaygın olarak kullanılan öznitelik gruplarıdır. Gerek duyulduęu takdirde özniteliklerden ayırt edici bilgi vermeyenler elenerek boyut azaltılabilir. Temel bileřenler analizi, baęımsız bileřenler analizi ve doęrusal ayırt edici boyut azaltmak için kullanılan yöntemlere örnek olarak gösterilebilir. Filtre tabanlı ve sezgisel öznitelik seçme yöntemleri de bu amaçla kullanılmaktadır. Boyut azaltma iřlemi özellikle gerçek zamanlı uygulamalarda, iřlemci destekli düzeneklerdeki iřlem yükünü hafifleterek sistemin tepki hızını arttırmaktadır.

Kullanılacak özniteliklere karar verdikten sonra, eldeki verinin sınıflandırma iřlemi yapılır. Bu sınıflandırma neticesinde deęerlendirilen iřaretin epileptik nöbet olup olmadığına karar verilir. Bu iřlemler nöbet öncesi ve nöbet sonrası evrelerin tespit edilmesi için de gerçekteřtirilmektedir. Destek vektör makineleri, yapay sinir aęları,

k-en yakın komşu algoritması ve karar ağaçları yaygın olarak kullanılan sınıflandırıcılara örnek olarak gösterilebilir.

Elektronik ve bilgisayar teknolojileri ile işaret işleme yöntemlerindeki gelişmeler, tıp elektroniği alanında son zamanlarda yaygın olarak kullanılmaya başlanmıştır. Bu çalışma kapsamında yukarıda bahsedilen gelişmelerden faydalanarak, EEG işaretlerini etkin bir şekilde değerlendirme becerisine sahip, bir epileptik nöbetin kestirimini, algılanmasını ve izlemesini yapabilecek bir dizge tasarlanması amaçlanmıştır.

Farklı epileptik evrelere ait EEG verilerinin tespit edilmesinde, literatürde sıkça kullanılan özellik çıkarımı yöntemleriyle öznitelik kümeleri oluşturulmuştur. Bu öznitelik kümeleri için temel bileşenler analiziyle boyut indirgeme işlemi gerçekleştirilmiştir. Elde edilen indirgenmiş öznitelik kümeleri, çapraz geçerlik yöntemi kullanılarak eğitim verisi ve test verisi şeklinde bölünmüştür. Klasik ve modern yöntemlerle gerçekleştirilen sınıflandırma işlemlerinin sonucunda, farklı evrelere ait EEG işaretlerinin ayrışma düzeyleri değerlendirilmiştir.

EEG işaretlerinin epileptik analizinde, çoğunlukla nöbetli ve normal olarak ayrıştırılması problemine çözüm üretilmeye çalışılmaktadır. Bu tezde, EEG işaretleri, sadece nöbet ve normal olarak ayrıştırılmamış, nöbet öncesi döneme ait EEG örnekleri de dikkate alınmıştır. Bu amaçla, sınıflandırma üç sınıflı (normal, nöbet öncesi ve nöbet dönemi) olarak gerçekleştirilmiştir. Böylece epilepsili bireylerin nöbete geçiş anlarındaki beyin aktiviteleri ve bu aktivitelerdeki farklılaşmaların değerlendirilebilmesine olanak sağlanmıştır. Nöbet öncesi dönemlerdeki beyin aktivitelerinin analiz edilmesiyle, epileptik nöbet kestirimi yapabilecek ve onun olumsuz etkilerinden epilepsi hastalarını koruyabilecek ya da etki düzeyini azaltabilecek performansla sahip portatif ve giyilebilir bir sistem tasarlanabilecektir.

Analizler 14 epilepsi hastası için, hastaya özel olarak gerçekleştirilmiştir. Analizlerin hastaya özel olarak yapılmasında, hastalığının karakteristiğinin hastaya bağlı olarak farklılaşabilmesi etkili olmuştur. 21 farklı kanala ait EEG işaretlerinden ayırt

ediciliđi yüksek olanı tespit etmek için, yinelemeli ön sınıflandırma uygulanmıştır. Bu işlem sonucunda seçilen kanal için sınıflandırma gerçekleştirilmiştir. Sınıflandırma aşamasında kullanılan test verileri, en ağırlıklı ilk üç temel bileşenin oluşturduğu düzleme yansıtılmıştır. Bu sayede normal, nöbet ve nöbet öncesi dönemlere ait EEG örneklerinin ayırışma düzeyleri ve aynı dönemlerin kümelenme seviyeleri değerlendirilmiştir. Sınıflandırıcı olarak Çok Katmanlı Yapay Sinir Ağları (ÇKYSA), Doğrusal Diskiriminant Analizi (DDA), k- En Yakın Komşu (k-EYK) ve Destek Vektör Makineleri (DVM) yöntemleri kullanılmıştır. Sınıflandırıcı performansları her bir epileptik evre için irdelenerek, sınıflandırma başarımları karşılaştırılmıştır. Sınıflandırıcı çıkışları ve temel bileşen dağılımları birlikte analiz edilmiştir. Nöbet kestirimi için hayati önem taşıyan nöbet öncesi dönem EEG kayıtlarının etiketlenmesi işleminde, klasik ve modern sınıflandırıcıların başarımları karşılaştırılarak, nöbet kestirim için uygun olan sınıflandırıcılar belirlenmiştir.

Çalışmanın ikinci bölümünde, epilepsi, elektroensefalogram ve elektroensefalografi ile ilgili genel kavramlara değinilmiştir. EEG işaretlerinden elde edilen öznelikler kullanılarak nöbet algılaması ve kestirimi yapılan önceki çalışmalar hakkında bilgiler verilmiştir. Çalışmanın üçüncü bölümünde, tasarlanan sistemin bölümleri açıklanmıştır. EEG analizinde kullanılan yöntemler hakkında bilgiler verilmiştir. Çalışmanın dördüncü bölümünde, uygulama sonuçları verilmiş ve elde edilen sonuçlar irdelenmiştir. Çalışmanın son bölümünde tasarlanan sistemin sonuçları değerlendirilmiş ve sistem performansı önceki çalışmalarla karşılaştırılmıştır.

BÖLÜM 2. KAYNAK ARAŞTIRMASI

2.1. Epilepsi

Epilepsi merkezi sinir sisteminin bir bölgesinde veya tamamındaki kontrolsüz ve aşırı faaliyetle karakterize edilen nörolojik bir hastalık türüdür. Bu istem dışı durumun ortaya çıkmasından sona ermesine kadar geçen dönem nöbet olarak adlandırılmaktadır. Beyindeki aşırı faaliyetin gerçekleştiği bölgeye göre nöbetler farklı sonuçlar ortaya çıkarırlar. Merkezi sinir sisteminde kol ve bacak hareketlerinin denetimini sağlayan bölgede oluşan nöbet, istemsiz kasılmalara neden olmaktadır. Tek bir nöbet bireyin epilepsi hastası olduğu anlamına gelmemektedir. Dünya nüfusunun %10'u hayatları boyunca 1 nöbet geçirmektedir (World Health Organization, 2017).

Nöbetler kısmi ve genel nöbetler olarak sınıflandırılmaktadır. Genel nöbetlerde beynin tamamında aşırı faaliyet söz konusudur. Bilinç kaybından dolayı genel nöbet geçiren epilepsili bireyler, nöbet anında yaşadıklarını hatırlamamaktadır. Beynin belli bir bölgesindeki sinirsel faaliyet sonucunda oluşan nöbetler, kısmi nöbet olarak adlandırılmaktadır. Bu nöbet türleri beyin bölgesine bağlı olarak farklı sonuçlar ortaya çıkarırlar. Bazı durumlarda bilinç yerindedir. Kısmi nöbetler kendi aralarında basit, kompleks ve sekonder jeneralize nöbetler olarak gruplandırılır. Sekonder jeneralize nöbetler genel bir nöbetin oluşmasına sebep olurlar (Clark, 2009; Türk Epilepsi ile Savaş Derneği-2, 2017).

Epilepsi, herhangi bir yaş ve cinsiyet ayrımı göstermeksizin tüm bireylerde görülebilir. Epilepsinin oluşumunda birçok unsur etkili olabilmektedir. Birçok vakada epilepsinin nedeni bilinmemektedir. Bu vakalar idiyopatik epilepsi olarak adlandırılmaktadır. Araştırmalara göre; menenjit gibi bir rahatsızlık geçirmiş olmak,

bazı genetik sendromlar, beyin tümörü, beyin travması, oksijensiz kalma veya doğum anında bebeğin merkezi sinir sisteminin hasar alması epilepsiye neden olabilmektedir. Bu vakalar ise semptomatik epilepsi olarak adlandırılmaktadır. Epilepsi bulaşıcı bir hastalık değildir (World Health Organization, 2017).

Epilepsi hastalarında nöbeti durduran, etkisini azaltan veya nöbet oluşumunu önleyen bazı ilaç tedavileri uygulanmaktadır. Epilepsi nöbetinin teşhisinde elektroensefalografi, magnetik rezonans görüntüleme ve pozitron emisyon tomografi gibi birçok yöntem kullanılmaktadır. Elektroensefalografi yönteminin, uygulama maliyeti, kolaylığı ve hasta üzerindeki olası olumsuz etkiler gibi parametreler dikkate alındığında birçok avantaja sahip olduğu görülmektedir (Mohseni, Maghsoudi ve Shamsollahi, 2006; Sivasankari ve Thanushkodi, 2009; Vavadi, Ayatollahi ve Mirzaei, 2010).

2.2. Elektroensefalogram İşaretleri ve Özellikleri

Beyindeki sinirsel faaliyetler sonucunda oluşan biyoelektrik işaretlere elektroensefalogram (EEG) adı verilmektedir. EEG işaretleri farklı epilepsi türlerinin teşhis edilmesinde ve epileptik faaliyetlerin olduğu beyin bölgesinin belirlenmesinde kullanılan en önemli klinik bileşenlerden biridir. EEG işaretleri karmaşık bir yapıya sahiptir ve yorumlanmaları güçtür. Yüzey elektrotlarıyla elde edilen EEG işaretleri, deri altındaki birçok noktada ve serebral korteksin geniş bir bölgesinde oluşan gerilimlerin bileşkesidir (Yazgan ve Korürek, 1996; Clark, 2009).

Beyindeki elektriksel faaliyetler ilk kez Caton tarafından 1875 yılında, hayvanlar üzerinde yapılan deneyler sonucunda belirlenmiştir. Hans Berger 1929 yılında, elektrotlar ve galvanometre ile insan beynindeki elektriksel aktiviteyi tespit etmiştir. Berger 1930'da EEG işaretlerinin göz açıp kapamayla değiştiğini göstermiştir. Elektronikte yaşanan gelişmeler sonucunda, Adrian ve Matthews 1934'te elektrotlar yardımıyla ölçtükleri EEG işaretlerini kuvvetlendirerek kaydetmişlerdir. Davis 1939'da uyanık insanın EEG'sinde sesli uyarılara bağlı olarak değişimler olduğunu bulmuştur. Aynı yıl, Davis ve arkadaşları sesli uyarılar sonucunda oluşan durumun

uyuyan insanlarda da geçerli olduğunu ortaya koymuşlardır. Takip eden yıllarda elektronik ve bilgisayar alanlarında yaşanan gelişmelerin olumlu etkileri kendisini tip alanında da göstermiştir. Klinik EEG uygulamaları geliştirilmiştir. İşaretlerin analizi ve tanımlanması çalışmaları hız kazanmıştır.


Yapılan deneyler, EEG işaretlerinin frekanslarının zihinsel faaliyetlere bağlı olarak değiştiğini göstermektedir. Uykudan kalkan ve düşünmeye başlayan bireyde uykuda etkin olan alfa bandı ritmi yerini senkronize olmayan bir biçimde, genellikle beta bandı ritmine bırakır. EEG işaretlerinin frekans bileşenleri, genlik bilgileri ve farklı bölgelerden elde edilen işaretler arasındaki faz ilişkilerine bakılarak analizleri gerçekleştirilmektedir. Beynin çalışma biçimini ortaya koymak için bu alanda birçok güncel çalışma yürütülmektedir.

Yüzey elektrotlarıyla edinilen EEG işaretleri 1-100 μ V tepeden tepeye genlik değerlerine ve 0,5-100 Hz frekans bandına sahiptirler. Beyin üzerinden direkt yapılan ölçümlerde genlik 10 kat kadar artmaktadır. EEG işaretlerinin frekanslarındaki farklılaşmanın nedeni henüz tam olarak anlaşılamamıştır. EEG işaretleri elektromiyogram ve elektrokardiyogram işaretlerindeki gibi şekil olarak değil, işaretin frekans bileşenlerine göre analiz edilmektedir. Periyodik özelliğe sahip olmayan EEG işaretlerinde genlik, frekans ve faz sürekli değişmektedir. EEG işaretleri kapsadıkları frekans bantlarına bağlı olarak alt bantlara ayrılmaktadır (Yazgan ve Korürek, 1996). Farklı frekans bantları, göz kırpma anı ve farklı epilepsi türleri için elde edilen EEG örnekleri Şekil 2.1.'de gösterilmektedir.

Frekans bileşenlerine göre EEG işaretleri dört gruba ayrılmaktadır. Bu bantlar ve kapsadıkları frekans aralığı Tablo 2.1.'de verilmiştir.

Tablo 2.1. EEG alt bantları ve frekans aralıkları (Clark, 2009)

Bant Adı	Frekans Aralığı (Hz)
Delta	0,5-3,5
Teta	4-7
Alfa	8-13
Beta	14-30



Şekil 2.1.Farklı epilepsi nöbetleri ve göz kırpma anına ait EEG örnekleri ve alt bantlar (Guyton, 1976)

Delta Dalgaları: Süt çocuklarında ve ağır organik beyin rahatsızlıklarında görülen dalga türüdür. 3,5 Hz'in altındaki frekans bileşenlerinden oluşmaktadır. Tepeden tepeye genlik değerleri (V_{p-p}) 100 μV 'tan küçüktür (Yazgan ve Korürek, 1996; Clark, 2009).


Teta Dalgaları: 4-7 Hz frekans bandına sahip dalga türüdür. Genellikle çocuklarda parietal ve temporal bölgelerde görülmekle birlikte, yetişkinlerde de ağır stres altında ya da düş kırıklıklarında ortaya çıkmaktadır. Tepeden tepeye genlik değerleri 100 μV 'tan küçüktür (Yazgan ve Korürek, 1996; Clark, 2009).

Alfa Dalgaları: 8-13 Hz frekans aralığına sahip dalga türüdür. Uyanık, sakin ve dinlenme durumundaki bireylerde görülmektedir. Ağırlıklı olarak oksipital bölgede ortaya çıkmakla birlikte parietal ve frontal bölgede de gözlenirler. Alfa dalgalarının genlikleri 20-200 μV aralığında değişmektedir. Uyku anında kaybolmaktadırlar. Bazı mental aktivitelerde ve dikkat durumlarında alfa dalgaları düşük genlikli fakat daha yüksek frekanslı dalgalarla yer değiştirirler (Yazgan ve Korürek, 1996; Clark, 2009).

Beta Dalgaları: 14-30 Hz frekans aralığına sahip beyin dalgalarıdır. Yoğun mental aktivite durumlarında 50 Hz'e kadar uzanırlar. Parietal ve frontal bölgede belirgin olarak gözlemlenirler. Beta-I ve Beta-II olmak üzere iki türe ayrılırlar. Beta-I dalgaları alfa dalgalarının iki katı frekansa sahiptirler. Zihinsel faaliyetlerin artmasına bağlı olarak kaybolan bu dalgalar, yerlerini senkron olmayan daha düşük genlikli dalgalara bırakırlar. Beta-II dalgaları merkezi sinir sisteminin yoğun faaliyet gösterdiği durumlarda ve stres altında ortaya çıkmaktadır. Böylelikle beta aktivitesinin bir türü (Beta-I) zihinsel aktivite tarafından ortaya çıkarılırken, diğer beta aktivitesi (Beta-II) tarafından engellenmektedir.

Yukarıda dalga türleri arasında verilmemiş olmakla birlikte, kimi araştırmacılar tarafından Gamma dalgaları da kullanılmaktadır. V_{p-p} değerleri 2 μV 'tan küçük olan bu dalga türü uykunun karakteristik özelliğini göstermektedir. Bu dalga türü yerine araştırmacılar Beta-II dalgalarını kullanabilmektedir (Yazgan ve Korürek, 1996).


Fp1-F7 kanalından elde edilen 5 s'lik EEG örneği ve bu örneğe ait delta, teta, alfa ve beta dalgaları Şekil 2.2.'de gösterilmiştir.




Şekil 2.2. Epilepsili bir bireyden normal dönemde (nöbetsiz) kaydedilen 5 s'lik EEG örneği ve alt bantları

2.2.1. Klinik EEG

Klinik EEG izlemesi için uluslararası elektrot yerleşimi olan ve Şekil 2.3.'te gösterilen 10-20 sistemi sıkça kullanılmaktadır. Bu sistem, EEG elektrotlarının yerleştirilmesini standartlaştırmak amacıyla belirli anatomik yerleri kullanmaktadır ve EEG kanallarının temsili yerleşimi olarak isimlendirilir. Genişletilmiş 10-20 elektrot yerleşimine ait görsel Şekil 2.4.'te verilmektedir.



Şekil 2.3. Uluslararası EEG toplulukları federasyonu tarafından önerilen 10-20 elektrot yerleşimi (Jasper, 1958; Malmivuo ve Plonsey, 1995)



Şekil 2.4. Genişletilmiş 10-20 sistemi elektrot dağılımı (Malmivuo ve Plonsey, 1995)

Çift kutuplu yerleşimde, her kanal iki bitişik elektrot arasındaki farkı ölçmektedir. Referans yerleşimde, her kanal bir elektrot ile referans olarak belirlenen başka bir elektrot arasındaki farkı ölçmektedir. Referans noktası olarak kulağa yerleştirilen bir elektrot örnek olarak verilebilir. Ortalama referans yerleşimde, her kanal bir elektrot ile diğer tüm elektrotların ortalaması arasındaki farkı ölçer. Laplasyen yerleşiminde, her kanal bir elektrot ile o elektrotu çevreleyen elektrotların ağırlıklı ortalaması arasındaki farkı ölçer. Fark yükselteci elektrot bağlantı girişlerine ek olarak ayrı bir topraklama elektrotuna ihtiyaç duymaktadır. Birbirine yakın elektrotlar arasındaki fark kaydı kullanmanın avantajı, her iki elektrotta da ortak olan uzak saha aktivitesinin devre dışı bırakılmasıdır. Her ne kadar aynı elektrik olaylar kaydedilse de, her durumda farklı bir biçimde görünürler. Ortaya çıkan potansiyel değişimler, yüksek kazançlı, kapasitif kuplajlı fark yükselteçleri ile güçlendirilir. Çıkış işareti kaydedilir ve göstergeye aktarılır (Clark, 2009).

Rutin klinik EEG kayıtlarında elektrotlar problem teşkil etmektedir. Elektrotlar küçük olmalı, saçları en az düzeyde rahatsız edecek şekilde deriye kolayca yapıştırılabilir, rahatsızlığa neden olmamalı ve uzun süre yerinde kalabilmelidir. Teknisyenler deri yüzeyini alkolle temizleyerek bölgeye elektrolit çözelti uygularlar. Polarize olmayan Ag/AgCl elektrotları tutkalla saç derisine yapıştırır ve kauçuk ya da tutucu bantlarla yerine oturtulurlar. Bazı uygulamalarda bütün elektrotları içeren kauçuk kepler kullanılmaktadır (Clark, 2009).

EEG genellikle hastalar uyanırken kaydedilir. Hastalar sırtüstü yaslanmış ve gözleri kapalı vaziyettedir. Yüzde, boyunda, kulaklarda vb. meydana gelen kas aktivitesi, duyuşsal bir uyarıcı veya beynin devam etmekte olan aktivitesi EEG kayıtlarında bozucu bir etki oluşturabilir. Örneğin yüz kaslarının hafif kasılmasıyla oluşan alanın frekans spektrumu nominal EEG aralığının frekans bileşenlerini (0,5-100 Hz) içermektedir (Clark, 2009).

2.2.2. Anormal EEG

Epilepsiye yatkın bir birey, merkezi sinir sisteminin bir kısmında veya tamamındaki faaliyet düzeyi belli bir eşik değerinin üzerine çıktığında nöbet geçirmektedir. Telaş düzeyi bu eşik değerinin altında olduğu sürece bir nöbet durumu ortaya çıkmayacaktır. Epilepsi genel ve kısmi olmak üzere iki çeşittir (Clark, 2009).

Genel epilepsi kendi arasında grand mal epilepsi (büyük nöbet) ve petit mal epilepsi (küçük nöbet) olmak üzere iki gruba ayrılmaktadır. Grand mal epilepsi retiküler aktivasyon sisteminin beyin sapı bölgesindeki aşırı nöron deşarjından kaynaklanmaktadır. Bu deşarjlar korteks boyunca beynin daha derinlerine hatta omuriliğe yayılmakta, kasıntı ve çarpınmalara neden olmaktadır. Grand mal nöbeti bilinç kaybı ve yere düşmeyle başlamaktadır. Devamında 15-20 s'lik adale sertliği dönemi (tonik safha) ve 1-2 dakikalık şiddetli ritmik havaleler (klonik safha) gelmektedir. Nöbet evresi, birkaç dakikalık derin ve rahat uyku sonunda, bilincin yerine gelmesi ve arkasından nöbeti hatırlamayıp uyanma ile tamamlanmaktadır. Hastalar nöbet sonrası baş ağrısı, uyuklama ve zihin bulanıklığı hissedebilmektedir (Sağlıklı Dünya, 2017). Şekil 2.1.'de grand mal epilepsi nöbetine ait EEG işareti gösterilmiştir. Bu tepki hemen hemen tüm kortekste gözlemlenir. Kaydedilen potansiyel yüksek genlikli, senkron ve alfa dalgalarına benzer periyodik özelliindedir.

Petit mal epilepsi ve grand mal epilepsi yakından ilgilidir. Bu epilepsi türünde görülen hafif şiddetli nöbetler tüm beyne yayılırlar. Nöbetlerin sıklığı artarsa yaşamı etkileyebilir. Erişkinlerde nadir olarak görülen nöbetler, çoğunlukla 6-12 yaş arasında görülmektedir. Bu nöbet türüne kadınlarda daha sık rastlanmaktadır. Çocukların hayal görmeleri bu nöbetlerin tespitini zorlaştırmaktadır. Bir günde yüzlerce defa nöbet yaşanabilir. Bu durum okul hayatını ve çeşitli etkinliklere katılımı zorlaştırabilir. Çocuk cümlelerin başını duyarken sonunu duymayabilir. Bu durum davranış bozukluğu olduğu algısına neden olabilmektedir. Derin derin soluk alıp verme durumunda bu tip nöbetlerde artış görülmektedir. Bu nedenle tanı için, hastaya derin derin nefes alıp verdirerek EEG kaydı yapılmaktadır. Nöbet anında yapılan kayıt hastalığın tanısında anahtar işlevi görmektedir (Türk Epilepsi ile Savaş

Derneği-3, 2017). Şekil 2.1.'de petit mal epilepsi nöbetine ait EEG işareti gösterilmiştir.

Kısmi epilepsi, korteksin belli bölgeleri ya da hem beyin hem de beyin sapının daha derinlerinde olmak üzere herhangi bir parçasını içerebilir. Bu epilepsi türü basit, kompleks ve sekonder nöbetleri içermektedir. Basit kısmi nöbetlerde bilinç tümüyle açıktır. Fakat bu durum, kişinin nöbeti durdurabileceği veya kontrol altına alabileceği anlamına gelmemektedir. Nöbete yol açan faaliyet beynin küçük bir kısmında oluşmaktadır. Bireylerde nöbet anında yaşananlar, nöbetin etkilediği beyin bölgesine göre farklılaşmaktadır (Clark, 2009; Türk Epilepsi ile Savaş Derneği-2, 2017).

Temporal lobda çok değişik işlevler görüldüğü için, buradan kaynaklanan basit kısmi nöbette birçok belirti görülebilir. Ani korku, gerçeklik duygusunu kaybetme (olmuş bir olayı olmamış kabul etme veya tersi, tanıdıklarını tanımama veya tanımadıklarını tanıdığı biriyle eşleştirme), farklı duyu durumları sıkça rastlanan belirtilerdir. Bu belirtiler aura olarak isimlendirilirler. Olası sekonder bir nöbet durumunda gerekli tedbirleri almak için bir uyarıcı olarak değerlendirilebilirler.


Frontal lobdan kaynaklanan nöbetler, hareket becerileriyle ilgili belirtiler gösterirler. Bu nedenle bu nöbet türleri motor nöbetler olarak adlandırılırlar. Şekil 2.1.'de psikomotor nöbete ait EEG işareti gösterilmektedir. Kolun yukarı kalkması, başın çevrilmesi, uzuvlarda sıçrayıcı ve kasılıp gevşeme şeklinde hareketler görülebilir. Nöbet anında kişi sola dönüyorsa, sol kolda kasılma veya hareket oluyorsa bu durum nöbetin sağ frontal lobdan kaynaklandığı anlamına gelmektedir. Konuşma merkezi bu lobda bulunduğundan konuşma becerilerinde geçici kayıp ya da bozulma yaşanabilmektedir. Bu tür nöbetler kısa süreli güçsüzlük veya geçici felç gibi durumlara da yol açabilmektedir.

Parietal lob vücut duyularını algılamaktadır. Dolayısıyla bu bölgenin sebep olduğu nöbetler garip duygulara neden olmaktadır. Geçici uyuşukluk gibi belirtiler görülebilmektedir. Görme işlevi oksipital lobda yerine getirilmektedir. Bu bölgeden kaynaklanan nöbetler halüsinasyon, körlük ve göz kırpma gibi durumlara yol

açmaktadır. Nöbet belirtileri değerlendirilerek epileptik atağın beyin hangi bölgesini etkilediği belirlenmektedir. Bu nedenle hasta ve yakınlarının bu belirtilere dikkat etmeleri ve doktora aktarmaları oldukça önemlidir (Türk Epilepsi ile Savaş Derneği-2, 2017).

Kompleks kısmi nöbetlerde bilinç etkilenmektedir. Nöbet sırasında bilincin etkilenmesi her zaman hastanın yere düşmesine neden olmaz. Hasta nöbeti hatırlayamayabilir ya da geçici hafıza kusuru görülebilmektedir. Bu nöbet türünde yalanma, çiğneme, yutkunma, bir şey arar gibi şaşkın bakınma gibi durumlar oluşabilmektedir. Hasta elbiselerini çekeştirebilir, etrafta gezinebilir ve kendine geldiğinde hiçbir şey hatırlamaz. Kompleks kısmi nöbet diğer beyin bölgelerine yayılarak sekonder jeneralize nöbete dönüşmektedir. Nöbet yayılımının çok hızlı olduğu durumlarda nöbet başlangıcının belirlenmesi güçleşir ve genel nöbet izlenimi verebilir. Dolayısıyla bu gibi durumlar ve beyin karmaşık yapısı nöbetin beyin neresinden başladığını tespit etmeyi zorlaştırmaktadır (Türk Epilepsi ile Savaş Derneği-2, 2017).

Literatürde farklı epileptik dönemlerden elde edilen EEG örneklerinin tespit edilmesi için birçok sistem önerilmiştir. Bu çalışmalarda ağırlıklı olarak nöbetli EEG örneklerinin normal EEG örneklerinden ayrıştırılması işlemi gerçekleştirilmiştir. Bu tez çalışmasında normal ve nöbetli dönem örneklerinin yanı sıra nöbetten önceki 80 saniyelik evreden elde edilen nöbet öncesi örnekler de analiz edilerek sınıflandırma işlemi gerçekleştirilmiştir. Epilepsili bir bireyin normal, nöbet öncesi ve nöbetli dönemde kaydedilen EEG örnekleri Şekil 2.5.'te gösterilmektedir.



Şekil 2.5. Normal, nöbet öncesi ve nöbetli dönemlere ait EEG örnekleri

2.3. Literatür Özeti

Beyin aktivitelerini yansıtan EEG kayıtlarından istatistiksel analiz yöntemlerini kullanarak nöbet algılaması veya kestirimi gerçekleştirmek nörolojik çalışmaların önemli bir kısmını oluşturmaktadır. İşaret işleme teknikleri ve bilgi teknolojilerindeki gelişmeler, bu alanlarda çalışmalar gerçekleştiren araştırmacılar için ciddi bir motivasyon kaynağıdır. İlk dönemlerde ağırlıklı olarak nöbet algılama üzerine çalışmalar gerçekleştirilmiştir. Yukarıda bahsedilen gelişmeler sayesinde nöbet kestirim çalışmalarının hız kazandığı görülmektedir. Bu bağlamda nöbet algılaması ve kestirimine yönelik olarak literatüre katkı sağlayan çalışmalardan bazıları aşağıda verilmiştir.

Mohseni ve arkadaşları, farklı özellik çıkarma yöntemlerini kullanarak nöbet algılama işlemi gerçekleştirmişlerdir. Non-linear tabanlı özellikler (Lyapunov üstelleri), entropi tabanlı özellikler, dalgacık tabanlı özellikler, zaman-frekans dağılımları, yerel varyans ve güç spektrumu tabanlı özellikleri ayrı ayrı kullanarak sınıflandırmışlardır. Herhangi bir sınıflandırıcı kullanmadıkları çalışmalarında nöbet algılama işlemi sabit varyans eşikleme yöntemiyle gerçekleştirmişlerdir. Dalgacık özellikleri için en düşük doğruluk değeri (%86,25) elde edilirken, en yüksek doğruluk değerine (%100) yerel varyans tabanlı özellikler kullanılarak ulaşılmıştır (Mohseni, Maghsoudi ve Shamsollahi, 2006).

Subaşı, ayrık dalgacık dönüşümüyle uzman modellerin karışımı bir sistem önermiştir. Daubechies 4 dalgacık fonksiyonunu kullanarak 5 seviyeli dönüşüm gerçekleştirmiştir. Özellik çıkarımı aşamasında frekans aralıklarını değerlendirerek, D3-D5 detay katsayılarını ve A5 yakınlık katsayılarını dikkate almıştır. Belirlenen her bir alt bandın dalgacık katsayılarının mutlak değerlerinin ortalamasını, ortalama gücünü, standart sapmasını ve ardışık bantlar için mutlak ortalama değerlerin oranını özellik olarak hesaplamıştır. Sınıflandırma aşamasında çok katmanlı yapay sinir ağı ve uzman sistemlerin karışımı olan yöntemini kullanmıştır. EEG işaretleri sınıflandırma sonucunda her iki yöntem için sırasıyla %93,2 ve %94,5 doğrulukla nöbet ve normal olarak etiketlenmiştir. Uzman sistemle gerçekleştirilen

sınıflandırmada, sonuçlar çok katmanlı yapay sinir ağı sonuçlarına göre daha yüksek duyarlılık ve özgünlük değerlerine sahiptir (Subaşı, 2007).

Tzallas ve arkadaşları, EEG işaretlerinin epileptik analizi için zaman-frekans analizi tabanlı bir yöntem önermişlerdir. Wigner-ville dağılımını kullanarak zaman-frekans yöntemiyle işaretin spektrumunu elde etmişlerdir. Farklı frekans çözünürlükleri, farklı genişlikte zaman dilimleri ve farklı frekans bantları için özellikler hesaplamışlardır. Özellik olarak, zaman-frekans düzleminde gerçekleştirdikleri bölümlenme sonrasında her bir bölümün enerjisini hesaplamışlardır. Farklı zaman ve frekans bölümlenmeleri için sınıflandırma işlemi gerçekleştirdiklerinden özellik kümelerinin boyutları her bir durum için farklı olmuştur. Boyut indirgemesi için temel bileşenler analizi yöntemini kullanmışlardır. Hesapladıkları özellik kümelerini ileri beslemeli yapay sinir ağlarına giriş olarak uygulamışlardır. Farklı epileptik durumlar (epileptik durumlar için 4 farklı kombinasyon oluşturulmuş) ve farklı bölümlenme biçimlerine göre elde ettikleri sınıflandırma başarımlarını değerlendirmişlerdir. Sınıflandırma başarımlarını önceki çalışmalarda elde edilen sonuçlarla karşılaştırmışlardır. İki sınıflı (normal ve nöbet) durum için % 100 doğrulukla sınıflandırma gerçekleştirmişlerdir (Tzallas, Tsipouras ve Fotiadis, 2007).

Sivasankari ve Thaushkodi, EEG işaretlerinden otomatik nöbet tespiti yapmak için yeni bir yaklaşım önermişlerdir. Araştırmacılar, bağımsız bileşenler analizini kullanarak EEG işaretlerindeki nöbetlerle ilişkili bileşenleri elde etmeye çalışmışlardır. İlk aşamada işaretleri önerdikleri yöntemle alt bileşenlerine ayırmışlardır. Sonrasında yapay sinir ağları yöntemiyle sınıflandırma gerçekleştirmişlerdir. Geriye yayımlı yapay sinir ağlarıyla gerçekleştirdikleri sınıflandırma sonucunda sırasıyla %76,5 ve %66 duyarlılıkla nöbetli ve normal EEG işareti tespit etmişlerdir (Sivasankari ve Thanushkodi, 2009).

Ocak, sağlıklı ve epilepsili bireylerden kaydedilen EEG işaretlerinden epileptik nöbet algılaması yapan bir sistem geliştirmiştir. Önerdiği yöntem ayrık dalgacık dönüşümü ve entropi tabanlıdır. Yönteminde, EEG işaretleri alt bantlara ayrılmakta, detay ve yakınlık katsayıları için entropi hesaplanmaktadır. Hesaplanan entropiler belli bir

eşik değere göre sınıflandırılmaktadır. Sınıflandırma işlemi orijinal işaret ve dalgacık dönüşümüyle elde edilen alt bantlar için ayrı ayrı uygulanmış, sonuçlar karşılaştırmalı olarak verilmiştir. Ön işlem yani dalgacık dönüşümü uygulanmadığı durum için elde edilen sınıflandırma başarımı düşük seviyededir. Araştırmacı D1 (43,4–86,8 Hz) alt bandına ait entropi değerleri için sırasıyla %93,7 ve %96 duyarlılıkla normal ve nöbetli dönem algılaması gerçekleştirmiştir (Ocak, 2009).

Netoff ve arkadaşları güç spektrumu özelliklerini kullanarak nöbet öncesi ve nöbetler arası dönemleri ayırmak için bir sistem önermişlerdir. 6 kanal ve 9 farklı frekans bandı için hesaplanan güç değerlerini kullanarak özellik kümeleri oluşturmuşlardır. En iyi sınıflandırma performansını elde etmek için çift çapraz geçerlilik yöntemiyle eğitim ve test verisini seçmişlerdir. Destek vektör makineleri yöntemini kullanarak sınıflandırma yapmışlardır. Son işleme bölümünde ardışık dönemler için sınıflandırıcı çıkışlarının çoğunluk oylamasına bakarak (3/5) kestirim gerçekleştirmişlerdir. 9 hasta için, iğne elektrotlarıyla elde edilmiş EEG kayıtlarını hastaya özel olarak analiz etmişlerdir. Yanlış pozitif alarm vermeyen yöntemleriyle 45 nöbetin 35 tanesini (%77,8 duyarlılıkla) kestirebilmişlerdir (Netoff, Park ve Parhi, 2009).

Liang ve arkadaşları, epileptik analiz için bir sistem önermişlerdir. İğne elektrotlarıyla elde edilmiş sağlıklı, nöbet arası ve nöbetli kayıtlar için sınıflandırma gerçekleştirmişlerdir. Özellik çıkarımı aşamasında hızlı fourier dönüşümüyle EEG işaretlerini 15 alt banda ayırmışlardır. EEG işaretlerinin öz bağlanım modeliyle birlikte ölçeklenmiş alt frekans bantlarının yakınlık entropilerini ve güçlerini özellik olarak kullanmışlardır. Genetik algoritmalar ve temel bileşenler analiziyle boyut indirgeme gerçekleştirmişlerdir. Farklı epileptik evreler için hesaplanan özelliklerin kombinasyonlarını kullanarak sınıflandırmışlardır. Sınıflandırma aşamasında lineer diskriminant analizi, geri yayımlı yapay sinir ağları, lineer en küçük kareler yöntemi ve destek vektör makineleri sınıflandırıcılarını kullanmışlardır. Farklı özellikler ve özellik indirgeme yöntemleriyle elde edilen veriler için elde ettikleri sınıflandırma başarımlarını birbirleriyle ve önceki çalışmalarda elde edilen sonuçlarla karşılaştırmışlardır (Liang, Wang ve Chang, 2010).

Subaşı ve Gürsoy, ayrık dalgacık dönüşümüyle elde ettikleri alt bantlara ait mutlak değerlerin ortalamasını, ortalama gücü, standart sapma ve ardışık bantlar için mutlak ortalama değerlerin oranını özellik olarak kullanmışlardır. Temel bileşenler analizi, bağımsız bileşenler analizi ve doğrusal diskiriminant analizi yöntemlerini kullanarak boyut indirgeme gerçekleştirmişlerdir. Farklı boyut indirgeme yöntemleriyle elde edilen özellik uzaylarını destek vektör makineleriyle sınıflandırmışlardır. Üç farklı özellik çıkarımı için sınıflandırma başarımlarını karşılaştırmışlardır. En yüksek başarıma hatasız bir sınıflandırma gerçekleştirdikleri doğrusal diskiriminant analiziyle ulaşmışlardır (Subaşı ve Gürsoy, 2010).

Park ve arkadaşları hastaya özel nöbet kestirim yöntemi önermişlerdir. Yöntemleri ön işlem, özellik çıkarımı, sınıflandırma ve son işlem aşamalarından oluşmaktadır. İğne elektrotlarla kaydedilen EEG işaretleri ön işlemde geçirilerek artifaklardan temizlenmiştir. Ön işleme sonucunda referans yerleşimine göre orijinal işaretler, çift kutuplu yerleşime göre orijinal işaretler ve her iki durum için zaman-fark biçimine göre düzenlenmiş işaretler olmak üzere, dört farklı özellik kümesi oluşturmak için kayıtları hazır hale getirmişlerdir. Ön işlemde geçirdikleri EEG işaretlerini 9 banda ayırmışlardır. Bantlar EEG alt bantlarını kapsamaktadır. Gamma bandını dörde bölmüşlerdir. Nöbet öncesi ve nöbetler arası dönemlerden elde edilen kayıtlara ait alt bantlar için spektral güç hesabı yaparak özellik kümeleri oluşturmuşlardır. Alt bantlara ait güç değerleri ve toplam gücü özellik olarak kullanmışlardır. Çapraz geçerlik yöntemiyle elde ettikleri özellik kümelerini eğitim ve test verisi olarak ayırdıkları araştırmalarında, en iyi eğitim ve test kümelerini belirledikten sonra destek vektör makineleriyle sınıflandırma gerçekleştirmişlerdir. Sınıflandırma sonuçlarını kalman filtre kullanarak son işlemeden geçirip yanlış alarmları engellemişlerdir. Sınıflandırma sonucunda nöbet öncesi ve nöbet arası örneklerin ayrışma düzeylerini değerlendirmişlerdir. En iyi kestirim performansına çift kutuplu EEG işaretlerini kullanarak ulaşmışlardır. Bu ön işleme yöntemiyle %97,5 duyarlılıkla nöbet kestirimi gerçekleştirmişlerdir. Araştırmacılar, epileptik nöbet kestirimi için yüksek frekanslı bileşenlerin kullanılmasının daha faydalı olacağını belirtmişlerdir (Park ve ark., 2011).

Ju'arez-Guerra ve arkadaşları Daubechies 2, Daubechies 4 ve Haar dalgacık fonksiyonlarını kullanarak nöbet algılamışlardır. Değişik filtreler ve dalgacık fonksiyonları için elde ettikleri özellik kümelerini yapay sinir ağları yöntemiyle sınıflandırdıkları çalışmalarında; filtre, dalgacık fonksiyonu ve gizli katman sayısına bağlı olarak değişen performansları karşılaştırmışlardır. Haar dalgacık fonksiyonu, Chebyshev II filtresi ve 18 gizli düğüm için %99,26 doğruluk, %98,93 duyarlılık ve %99,59 özgüllükle nöbet tespiti gerçekleştirmişlerdir (Juarez-Guerra, Alarcon-Aquino ve Gomez-Gil, 2013).

Blanco ve arkadaşları spektral entropinin epileptik nöbet kestirimi üzerindeki etkilerini incelemişlerdir. Entropi hesaplamak için EEG işaretlerini düşük, orta ve yüksek frekans olarak adlandırdıkları alt bantlara ayırmışlardır. Düşük bant 0,1-12 Hz, orta bant 12-32 Hz ve yüksek bant 32-128 Hz frekans aralığına sahiptir. Elde ettikleri alt bantlar için spektral entropi hesaplayan araştırmacılar, nöbet öncesi dönemlerdeki entropi değişimlerini değerlendirmişlerdir. Yaptıkları analizler neticesinde nöbet öncesi dönemlere ait yüksek frekans bantlarındaki spektral entropi değişimlerinin anlamlı olduğu ve nöbet kestirimi için önemli bir potansiyele sahip olduğu sonucuna ulaşmışlardır (Blanco, Garay ve Coulombie, 2013).

Rasekhi ve arkadaşları farklı ön işleme ve normalizasyon yöntemlerini kullanarak nöbet kestirimi gerçekleştirmişlerdir. Nöbet bölgesinden ve nöbete uzak bölgelerden üçer elektrot kullanarak kaydedilen EEG işaretlerinden 22 doğrusal tek değişkenli özellik hesaplamışlardır. Kayıtlar yüzey elektrotları ve iğne elektrotları kullanılarak elde edilmiştir. Özellik kümesi spektral güç özellikleri, istatistik tabanlı özellikler, hjorth parametreleri, uzun dönem enerji, öz bağlanım temelli özellikler, sıfır geçiş temelli özellikler, spektral kenar frekansı ve kenar gücü ile dalgacık temelli özelliklerden oluşmaktadır. Sınıflandırma işlemi için destek vektör makineleri yöntemini kullanmışlardır. Farklı ön işleme ve normalizasyon yöntemlerinin farklı birleşimleri için yaptıkları sınıflandırma sonuçlarını değerlendirmişlerdir. Analizleri hastaya özel olarak uygulamışlardır. Toplamda 46 nöbetin 34 tanesini (%73,91 duyarlılık) tespit etmişlerdir (Rasekhi ve ark., 2013).

Zandi ve arkadaşları pozitif sıfır geçiş aralıklarının analizini kullandıkları, hastaya özel yeni bir nöbet kestirim yöntemi önermişlerdir. Çalışmalarında 17 hastaya ait, 10-20 elektrot sistemiyle ve yüzey elektrotlarıyla kaydedilmiş EEG işaretlerini kullanmışlardır. Araştırmacılar kayan pencere analiziyle güncel döneme ait pozitif sıfır geçiş aralığının histogramını elde edip, belirli kutulara karşılık gelenleri gözlem olarak seçmişlerdir. Değişken bayesyan gausyen birleşik model tabanlı benzerlik ve farklılık ölçütlerini hesaplayarak, son beş dakika için elde ettikleri gözlem kümesini, nöbet öncesi ve nöbet arası dönemler için belirledikleri referans değerlerle karşılaştırmışlardır. Sonraki aşamada birleşik indeks hesaplayarak, hastaya özel olarak belirledikleri, her kanal için bir alarm dizisi oluşturmak amacıyla kullanılan kümülatif ölçümlerin sonucu olan bir eşik değeriyle karşılaştırmışlardır. Son olarak kanal tabanlı bilgiyi nöbet kestirim alarmı üretmek için kullanmışlardır. Önerdikleri yöntemle ortalama %88,34 duyarlılıkla nöbet kestirimi gerçekleştirmişlerdir (Zandi ve ark., 2013).

Husain ve Rao nöbetli ve nöbetsiz EEG işaretlerini sınıflandırmak için Hilbert-Huang dönüşümü ve ampirik mod ayrışımı yöntemlerini kullanmışlardır. Önerdikleri nöbet algılama sisteminde ilk olarak ampirik mod ayrışımıyla 5 s'lik nöbetli ve nöbetsiz EEG işaretlerini içsel mod fonksiyonlarına ayırmışlardır. Özellik çıkarımında kullanılacak olan içsel mod fonksiyonlarını seçerken iki epileptik durum için (nöbetli-nöbetsiz) hesapladıkları ortalama ağırlıklı frekans değerlerini dikkate almışlardır. Bu işlem sonucunda 2, 3 ve 4 numaralı içsel mod fonksiyonlarını özellik çıkarımında kullanmışlardır. Ortalama mutlak sapma, zarf genliğinin değişim oranı, çeyrekler arası aralık ve ortanca mutlak sapma değerlerini seçilen 3 içsel mod fonksiyonu için hesaplayarak 12 özellikli özellik kümesi oluşturmuşlardır. Sınıflandırıcı olarak yapay sinir ağlarını kullanmışlardır. %99,8 doğrulukta sınıflandırma başarımına ulaşmışlardır (Husain ve Rao, 2014).

Özdemir ve Yıldırım otomatik nöbet kestirimi için Hilbert-Huang dönüşümü ve bayesyan sınıflandırıcı tabanlı bir sistem geliştirmişlerdir. İğne elektrotlarıyla elde edilen EEG işaretlerini kullanarak nöbet öncesi ve nöbetler arası dönem tespiti gerçekleştirmişlerdir. Ön işleme aşamasında kayıtlardaki artifaktları temizleyerek

bölümleme yapmışlardır. 6 kanal için bölümlenen 30 s'lik EEG işaretlerini ampirik mod dönüşümü yöntemiyle içsel mod fonksiyonlarına ayrıştırıp, Hilbert Spektrumlarını elde etmişlerdir. Alt bantlara ait enerjiler hesaplanarak özellik kümeleri oluşturmuşlardır. En iyi ilk arama algoritmasıyla, ilişki tabanlı özellik seçme yöntemini uygulayarak anlamlılık düzeyi yüksek özellikleri belirlemeye çalışmışlardır. Bayesyen sınıflandırıcıyla özellik seçimi yapılan ve yapılmayan durumlar için sınıflandırma gerçekleştirmişlerdir. Toplamda 87 nöbet için, özellik seçimi yaparak %96,55 duyarlılıkla kestirim gerçekleştirmişlerdir. Özellik seçimi yapılmayan durumlar için başarı daha düşük seviyede kalmıştır (Özdemir ve Yıldırım, 2014).

Ghaderyan ve arkadaşları epileptik nöbet kestirimi yapabilen ve işlem karmaşıklığını azaltan optimize edilmiş yeni bir yöntem önermişlerdir. İğne elektrotlarla kaydedilen EEG işaretlerini 8 alt frekans bandına bölerek, her bir bant için istatistik ve güç spektrumu tabanlı özellik çıkarımı (toplamda 48 özellik) gerçekleştirmişlerdir. Özellik hesaplama işlemini 6 kanal için tekrarlayan araştırmacılar, boyut indirgeme için temel bileşenler analizini uygulamışlardır. Destek vektör makineleri yöntemiyle sınıflandırma işlemi gerçekleştirmişlerdir. Sınıflandırma işlemi özelliklerin farklı birleşimleri için tekrarlamışlardır. Bu sayede özellik gruplarının nöbet kestirim yeteneklerini belirlemeyi amaçlamışlardır. Sınıflandırıcı çıkışlarını güvenli değerlere dönüştürmek için son işleme uygulamışlardır. Bu aşamada sınıflandırıcı çıkışındaki gürültüyü ortanca filtre ve kayan ortalama filtre kullanarak elemişlerdir. 18 hasta için gerçekleştirdikleri analizler sonucunda ortalama %100 duyarlılık ve %93,21 özgüllükle nöbet kestirimi gerçekleştirmişlerdir (Ghaderyan, Abbasi ve Sedaaghi, 2014).

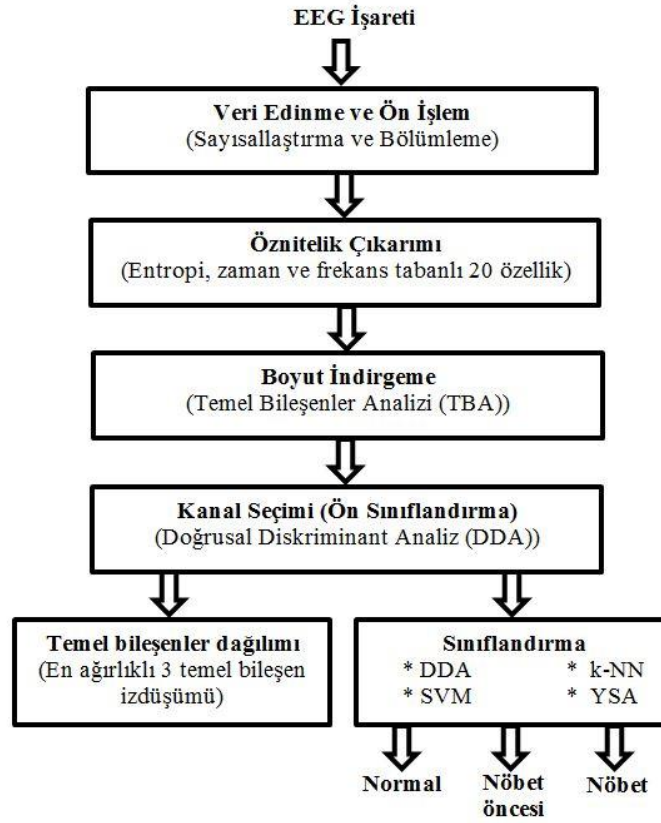
Anwar nöbet kestirimi için entropi tabanlı bir yöntem önermiştir. Nöbetsiz ve nöbet öncesi dönemlere ait EEG kayıtlarını ayırt ettiği çalışmasında farklı entropi türlerini özellik olarak hesaplamıştır. Bir dakikalık bölümlere ayırdığı EEG işaretleri için kritik entropi değerlerini tespit etmeye çalışmıştır. Bu kritik entropi değerlerini nöbetin başlama anını belirlemede kullanmayı amaçladığı çalışmasında, destek vektör makineleri yöntemiyle sınıflandırma gerçekleştirmiştir. Tek hasta için farklı

zaman aralıklarında elde edilmiş EEG kayıtlarından sırasıyla %100, %97,67 ve %86,11 doğruluklarında nöbet olmayan dönem ve nöbet öncesi dönem tespiti gerçekleştirmiştir. Duyarlılık değerlerini sırasıyla %100, %95,65 ve %73,10 olarak elde etmiştir. Araştırmacı nöbet olmayan dönemlerde entropi değerinin kritik değerin altında ve neredeyse sabit kalmasına karşın, nöbet öncesi dönemlerde kademeli olarak azaldığını tespit etmiştir (Anwar, 2015).

Behbahani ve arkadaşları, güvenilir epileptik nöbet kestirimi için kalp hızı değişkenliği tabanlı bir yöntem önermişlerdir. Çalışmalarında 16 hastaya ait 170 nöbet içeren EEG kaydı kullanmışlardır. Nöbet öncesi dönemlerde EEG kayıtlarında ortaya çıkan dinamik değişimleri dikkate alarak nöbetlerin ortaya çıkışını kestirmişlerdir. 5 dakikalık kayıt bölümleri için zaman ve frekans tabanlı özellikler kullandıkları çalışmalarında, uyarlanabilir karar eşikleme yöntemiyle nöbet öncesi dönem tespiti gerçekleştirmişlerdir. Araştırmacılar %78,59 duyarlılıkla ve saat başı 0,21 yanlış alarm oranıyla nöbet kestirimi yapmayı başarmışlardır (Behbahani ve ark., 2016).

BÖLÜM 3. MATERYAL VE YÖNTEMLER

Bu bölümde EEG işaretlerinin epileptik analizi için tasarlanan sistem ve sistemi test etmek için kullanılan işaretlerin sağlandığı veri tabanı açıklanacaktır. Sisteme ait blok şema Şekil 3.1.'de verilmiştir. Sistem ön işlem, öznelik çıkarımı, boyut indirgeme, kanal seçimi ve sınıflandırma bölümlerinden oluşmaktadır.



Şekil 3.1. Tasarlanan sistemin öbek çizgesi

3.1. Veri Edinme ve Ön İşlem

Bu tez çalışmasında kullanılan EEG işaretleri PhysioNet veri tabanından alınmıştır. Veri tabanı yaşları 3 ve 22 arasında değişen 5 erkekle, yaşları 1,5 ve 19 arasında değişen 17 kadın epilepsili birey olmak üzere 22 hastaya ait EEG kayıtlarından

oluşmaktadır. Kayıtlar 24 vaka olarak gruplandırılmıştır. 1 ve 21 numaralı kayıtlar aynı hasta için 1,5 yıl arayla gerçekleştirilmiştir. 24 numaralı EEG kayıtlarının alındığı hastaya ait bilgiler bulunmamaktadır. EEG işaretleri uluslararası 10-20 sistemiyle yüzey elektrotları kullanılarak elde edilmiştir. İşaretler 256 Hz'de ve 16 bit çözünürlükte örneklenmiştir. EEG işaretlerindeki nöbetler için, başlangıç anları ve toplam nöbet süreleri uzmanlar tarafından belirlenmiştir (PhysioNet., 2011). Bu çalışmada sadece on dört hastaya ait kayıtlar kullanılmıştır. Seçilen hastalarda ölçümler 21 farklı kanal için gerçekleştirilmiştir. Hastalar ölçüm kanalları, nöbet sayıları ve nöbet süreleri dikkate alınarak seçilmiştir. Çalışmada EEG işaretleri kullanılan hastaların demografik bilgileri Tablo 3.1.'de verilmiştir.

Tablo 3.1. Demografik bilgiler

Hasta No	Cinsiyet	Yaş	Hasta No	Cinsiyet	Yaş
1	Kadın	11	8	Kadın	2
2	Kadın	14	9	Kadın	3
3	Erkek	22	10	Erkek	16
4	Kadın	7	11	Kadın	18
5	Erkek	3.5	12	Kadın	6
6	Kadın	10	13	Kadın	6
7	Erkek	3	14	Belirtilmemiş	

Ön işlem aşamasında, nöbet öncesi dönemler, nöbet dönemleri ve nöbet olmayan dönemler beş saniyelik bölümlere ayrılmıştır. Nöbet öncesi veriler, nöbet başlangıcı öncesindeki 80 saniyelik zaman aralıklarından elde edilmiştir. Üç farklı epileptik evreden, her bir hasta için elde edilen örnek sayıları Tablo 3.2.'de verilmiştir.

Tablo 3.2. Hastalara ait örnek sayıları

Hasta No	Normal	Nöbet Öncesi	Nöbet	Hasta No	Normal	Nöbet Öncesi	Nöbet
1	192	112	88	8	192	176	110
2	192	112	78	9	192	160	86
3	192	64	75	10	540	320	395
4	192	80	108	11	192	96	64
5	192	80	182	12	192	128	60
6	192	64	55	13	192	112	84
7	192	112	88	14	192	192	100

3.2. Öznitelik Çıkarımı

Öznitelik çıkarımı bir veri setine ait ayırt edici özelliği bulunmayan ve dikkat dağıtan bölümleri elemek amacıyla yapılan bir ön işlem olarak düşünülebilir. Bu gereksiz bölümlerin çıkarılmasıyla bellek ihtiyacı azaltılırken, sınıflandırma ya da kestirim işleminin performansı iyileştirilir (Motoda ve Liu, 2002; Burges, 2010; Azlan ve Low, 2014).

İşaretin taşıdığı bilgiler farklı öznitelikler çıkarılarak özellik kümesine taşınır. EEG işaretlerinin analizinde birçok öznitelik çıkarım yöntemi kullanılmaktadır. Bu aşamada birçok araştırmacı tarafından, EEG işaretlerinin farklı özellikleri kullanılarak değerlendirmeler yapılmıştır. Doğrusal olmayan özellikler, entropi tabanlı özellikler, zaman düzlemi özellikleri, frekans düzlemi özellikleri, güç spektrumu ve zaman-frekans dağılımları sıkça kullanılan öznitelik gruplarıdır.

Bu tez çalışmasında normal, nöbet öncesi ve nöbet esnasında elde edilen her bir EEG işareti için yirmi öznitelik hesaplanarak özellik kümeleri oluşturulmuştur. Elde edilen özellik kümelerinin boyutu temel bileşenler analizi kullanılarak yirmiden sekize indirgenmiştir. İndirgenen öznitelik kümeleri kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. Çalışmada kullanılan öznitelikler Tablo 3.3.'te verilmiştir.

Tablo 3.3. Öznitelikler

No	Öznitelik	No	Öznitelik
1	Aritmetik Ortalama	11	Öz bağlanım katsayısı-2
2	Standart sapma	12	Öz bağlanım katsayısı-3
3	Varyans	13	Öz bağlanım katsayısı-4
4	Hjorth karışıklığı	14	Öz bağlanım katsayısı-5
5	Hjorth hareketliliği	15	Öz bağlanım katsayısı-6
6	Delta bandı gücü	16	Öz bağlanım katsayısı-7
7	Teta bandı gücü	17	Öz bağlanım katsayısı-8
8	Alfa bandı gücü	18	Entropi
9	Beta bandı gücü	19	Renyi entropi
10	Öz bağlanım katsayısı-1	20	Sıfır geçiş oranı

3.2.1. Aritmetik ortalama

Aritmetik ortalama (AO) sıklıkla kullanılan merkezi eğilim ölçülerinden birisidir. Bir örnekleme ait veri değerlerinin toplamının örneklemdaki veri sayısına bölünmesiyle elde edilen bir betimsel istatistik ölçüsüdür (Albayrak ve ark., 2005). Bir rastlantısal dağılımın merkezi konum değerine karşılık gelmektedir (Denklem 3.1).

$$AO = \frac{1}{N} \sum_{n=1}^N x_n \quad (3.1)$$

3.2.2. Standart sapma

Bir olasılık dağılımı ya da rastlantısal bir değişkene ait verilerin yayılımını özetlemek için kullanılan istatistiksel bir ölçüdür (Denklem 3.2). Eğer standart sapma değeri küçük ise, dağılımdaki verilerin ortalama değere yakın olduğu, başka bir ifadeyle yayılımın dar alanda gerçekleştiği anlaşılmaktadır. Standart sapma (σ) ölçüsünün birimi veri birimi ile aynıdır (Albayrak ve ark., 2005).

$$\sigma = \sqrt{\frac{\sum_{n=1}^N (x_n - M)^2}{N-1}} \quad (3.2)$$

3.2.3. Varyans

Varyans (VAR) olasılık ve istatistikte kullanılan bir dağılım ölçüsüdür. Mümkün bütün değerlerin ortalamadan uzaklıklarının karelerinin ortalamasıyla hesaplanmaktadır (Denklem 3.3). Varyans ölçü birimi değişkenin biriminin karesidir (Sipahi, Yurtkoru ve Çinko, 2006).

$$VAR = \frac{\sum_{n=1}^N (x_n - M)^2}{N-1} \quad (3.3)$$

3.2.4. Güç

Güç EEG işaretinin genlik ölçüsüdür (Denklem 3.4). Güç (P) aynı zamanda birim zaman başına tüketilen enerji miktarı olarak da tanımlanır (Panat, Patil ve Deshmukh, 2014).

$$P = \frac{1}{N} \sum_{i=1}^N |x_i|^2 \quad (3.4)$$

Bu çalışmada, EEG işaretlerinin farklı frekans bileşenleri için filtreleme işlemi gerçekleştirilerek güç değerleri hesaplanmıştır. Alfa, , Beta, Teta ve Gama bantları için elde edilen güç değerlerine ait frekans bilgileri Tablo 3.4.'te verilmiştir.

Tablo 3.4. Güç hesaplanan alt bantlar ve bant genişlikleri

No	Frekans Bandı	Frekans Aralığı
1	Delta Bandı	0,5-4 Hz
2	Teta Bandı	4-8 Hz
3	Alfa Bandı	8-13 Hz
4	Beta Bandı	13-30 Hz

3.2.5. Sıfır geçiş oranı

Bir işaretin belli bir dönemdeki dinamik değişimlerini tanımlayan bir ölçüttür. EEG işaretleri artı ve eksi genlikler arasında sürekli değişen değerlere sahiptirler. Sıfır Geçiş Oranı (SGO) işaretin sıfır genlik ekseninden geçiş oranını ifade etmektedir (Denklem 3.5). (Chang ve ark., 1996; Boostani ve Moradi, 2003; Engin, Taşan ve Engin, 2015)

$$SGO = \frac{1}{2N} \sum_{n=0}^{N-1} |\text{sgn}[x(n)] - \text{sgn}[x(n-1)]| \quad (3.5)$$

3.2.6. Öz bağlantım modeli

Bir değişkene ait güncel değer in o değişkene ait önceki değerlerle ilişkisini belirleyen en önemli rastlantısal modellerden birisidir. Herhangi bir andaki çıkış değeri önceki çıkış değerlerinin belirli oranlarının ve tahmini hata değerinin doğrusal birleşimleri olarak elde edilmektedir (Boulenouar, Hayashibe ve Dutta, 2014). Model katsayıları doğrusal denklemlerin çözümüyle kolaylıkla elde edildiğinden sıklıkla kullanılmaktadır. İşaret, girişi beyaz gürültü olan nedensel, tüm-kutuplu ayırık filtre çıkışı olarak modellenebilir (Alkan, Subaşı ve Kıymık, 2005). Derecesi p olan öz bağlantım modeli (ÖBM) Denklem 3.6'da verilmektedir.

$$\text{ÖBM} = - \sum_{i=1}^p a_p(i)x(n-i) + \varepsilon(n) \quad (3.6)$$

Genlik oranlarını belirleyen öz bağlantım katsayılarını hesaplamak için farklı yöntemler kullanılmaktadır. Bu çalışmada Burg Yöntemi kullanılmıştır. Bu yöntemde öz bağlantım katsayılarının belirlenmesi ileri-geri tahmin hatalarının en aza indirgenmesi ve yansıma katsayılarının kestirimi esasına dayanmaktadır (Günay ve Alkan, 2010).

3.2.7. Hjorth parametreleri

Hjorth parametreleri zaman düzlemindeki bir işaretin istatistiksel özelliklerini göstermek için kullanılmaktadır. Hjort EEG işaretlerini zaman düzleminde tanımlamak için üç değişken belirlemiştir. Hjort parametreleri olarak adlandırılan bu değişkenler aktivite, hareketlilik ve karmaşıklık olarak adlandırılmaktadır (Hjorth, 1970; Oh, Lee ve Kim, 2014).

Parametreler işaretin birinci ve ikinci dereceden türevleri alınarak hesaplandığı için normalize edilmiş eğim açıklayıcıları olarak da isimlendirilirler. Hjorth Aktivitesi (HA) işaretin ortalama enerjisine karşılık gelmektedir. Hjorth Hareketliliği (HH) ortalama frekans değerinin kestirimidir. Güç tayfının standart sapmasını tanımlamak için kullanılmaktadır. Hjorth Karmaşıklığı (HK) parametresi bant genişliğinin

kestirimi için kullanılmaktadır (Avşar, 2009). İşaretin biçimi saf sinüs biçimine yaklaştıkça bu parametrenin değeri 1 değerine yaklaşmaktadır. σ_0 işaretin varyansı, σ_1 işaretin birinci türevinin varyansı ve σ_2 işaretin ikinci türevinin varyansı olmak üzere: HA, HH ve HK parametrelerine ait eşitlikler aşağıda verilmiştir. Varyans özneliği kullanıldığı için HA kullanılmamıştır.

$$HA = \sigma_0^2 \quad (3.7)$$

$$HH = \sigma_1/\sigma_0 \quad (3.8)$$

$$HK = \sqrt{(\sigma_2/\sigma_1)^2 - (\sigma_1/\sigma_0)^2} \quad (3.9)$$

3.2.8. Shannon entropi

Entropi bilgi kuramında belirsizliğin ölçüsü olarak tanımlanmaktadır. Herhangi bir sistemin karmaşıklık düzeyini ölçmek için kullanılmaktadır. Zaman düzlemindeki bir işaretin karmaşıklık derecesini belirten doğrusal olmayan bir ölçüttür (Phung ve ark., 2014). Bir X olasılık deneyinde, $p(x_i)$ x_i sonucunun ortaya çıkma olasılığına karşılık gelmektedir. Shannon Entropi (SE)'ye göre bu deneydeki bilgi miktarı Denklem 3.10.'da verilmektedir.

$$SE = - \sum_{i=1}^N p(x_i) \cdot \log_2 p(x_i) \quad (3.10)$$

Birçok araştırmada EEG işaretlerinin kaotik yapıda olduğu düşünülmektedir. Doğrusal olmayan dinamikler ve deterministik kaos teorisi beynin karmaşık yapısı ve EEG dinamiklerinin etkili olarak tanımlanmasında bir kaynak olabilir. Temel olarak yüksek entropi sistemin karmaşıklık düzeyinin yüksek olduğunu ifade etmektedir. Bu durum düşük seviyeli bir öngörülebilirlik olarak değerlendirilebilir (Kumar ve Dewal, 2011).

3.2.9. Renyi entropi

Renyi entropisi (RE), spektral entropinin özel bir durumuna karşılık gelmektedir. Spektral entropi zaman serisindeki spektral karmaşıklıkları belirlemek için kullanılan bir ölçüdür. İşaretin gücü frekansın bir fonksiyonu olarak ifade edilmektedir. Renyi entropisi özellikle düşük frekanslı işaretlerde spektral entropiye göre daha faydalı bilgi sağlamaktadır (Kannathal ve ark., 2005).

$$RE = \frac{1}{1-q} \cdot \ln \sum_{i=1}^N x_i^q \quad [q \neq 1 \text{ ve } q > 0] \quad (3.11)$$

Bu çalışmada $q=2$ alınmıştır. Bu özel durum kuadratik renyi entropi olarak adlandırılmaktadır.

3.3. Boyut İndirgeme ve Öznitelik Seçimi

Örüntü tanıma sistemlerinin performanslarını arttırmak ve tepki hızlarını geliştirmek için boyut indirgeme ve özellik seçme işlemleri sıklıkla kullanılmaktadır. Bu işlemler yardımıyla ayırt edici bilgi içermeyen özellikler, öğrenme başarımını etkilemeden atılabilmektedir. Gereksiz özellikler elenerek işlem yükü azaltılmakta ve sistemin tepki hızı arttırılmaktadır (Liu ve Motoda, 2008).

Özellik seçimiyle farklı sınıflara ait örüntüler için en iyi ayırt edici özelliklerin alt kümesi belirlenmektedir. Etkili özelliklerin seçilmesiyle özellik kümesinin boyutu indirgenmektedir. Bu işlem sınıflandırma performansı, sınıflandırma zamanı ve ihtiyaç duyulan örnek sayısı üzerinde oldukça etkilidir. Boyut indirgeme ve özellik seçimi uygulanarak veri sadeleşmekte, böylelikle ihtiyaç duyulan sistem belleği kapasitesi azalmakta, öğrenme süresi kısalmakta ve sınıflandırma başarımı artmaktadır (Meyer-Base, 2004; Saeys, Inza ve Larranaga, 2007; Zheng ve Xue, 2009; Chizi ve Maimon, 2010).

Boyut indirgeme ve özellik seçimi için birçok yöntem kullanılmaktadır. Dal ve sınır yöntemi, temel bileşenler analizi, lineer diskriminant analizi, bağımsız bileşenler

analizi, genetik algoritma, sıralı geriye seçim ve sıralı ileriye seçim bu yöntemlerden bazılarıdır. Bunlardan genetik algoritmalar, sıralı ileriye seçim ve sıralı geriye seçim yöntemleri, özellikleri ayırt ediciliğine göre sıralamaktadır. Diğer yöntemlerde özellik kümeleri bütün özelliklerin doğrusal birleşimi elde edilerek ayırt ediciliği yüksek ve daha düşük boyutlu bir uzaya dönüştürülmektedir (Oral, 2011).

Bu çalışmada temel bileşenler analizi kullanılarak 20 özellikten oluşan özellik kümelerinin boyutu 8'e indirgenmiştir.

3.3.1. Temel bileşenler analizi

Temel bileşenler analizi (TBA) en eski ve en iyi bilinen çok değişkenli analiz tekniklerinden birisidir. İlk olarak Pearson tarafından ortaya atılmış (1901), ve Hotelling tarafından geliştirilmiştir(1933). Birçok çok değişkenli yöntem gibi, sadece elektronik bilgisayarların geliştirilmesine kadar kullanılmamış, günümüzde de tüm istatistiksel bilgisayar paketlerine yerleştirilmiştir (Jolliffe, 2002). TBA birbiri ile ilişkili veri kümesini doğrusal olarak ayrıştırarak aynı boyutta birbiri ile ilişkili olmayan farklı bir uzaya haritalayan doğrusal bir dönüşüm olarak tanımlanır.

Temel bileşenler analizinin ana fikri, birbiri ile ilişkili çok sayıda değişkenden oluşan veri setinin boyutunu, veri setinin özelliklerini mümkün olduğu kadar koruyarak azaltmaktır. Orijinal veri daha küçük boyutlu bir uzaya yansıtılmaktadır (Jolliffe, 2002; Meyer-Base, 2004; Han ve Kamber, 2006).

Bu işlem, orijinal değişkenler birbirleri ile ilişkili olmayan yeni değişkenlere dönüştürülerek gerçekleştirilir. TBA giriş verisi için temel oluşturan k tane ortogonal vektörü hesaplar. Bu vektörler özvektörler matrisini oluşturmaktadır. Vektörler her noktası diğerlerine dik olan birim vektörlerdir ve temel bileşenler olarak adlandırılır. Giriş verisi, elde edilen temel bileşenlerin doğrusal birleşimidir. Veri setinin boyutu yüksek varyanslı değişkenlerin korunması ve düşük varyanslı değişkenlerin elenmesiyle azaltılmaktadır (Duda, Hart ve Stork, 2001; Jolliffe, 2002).

TBA aşağıdaki adımlar uygulanarak gerçekleştirilir (Smith, 2002).

- Veri seti normalize edilir. Böylece bütün özellikler aynı değişim aralığına aktarılır.
- Her bir özellik için ortalama değer hesaplanır. Hesaplanan ortalama değerler ait olduğu özellikten çıkarılır. Böylelikle sıfıra ortalanmış özellik kümesi hesaplanmış olur.
- Sıfıra ortalanmış özellik kümesi, devriği ile çarpılarak kovaryans matrisi bulunur. Bu matris veri setindeki özellikler arasındaki ilişkiyi belirlemektedir.
- Kovaryans matrisinin özvektörleri ve özdeğerleri hesaplanır.
- Özvektörler, özdeğerleri dikkate alınarak yüksekten düşüğe doğru sıralanır. Boyut azaltımı için yüksek özdeğerli özellikler seçilir. Yeni özellik sayısı seçilirken, seçilen özelliklerin özdeğerleri toplamının bütün özellikler için elde edilen özdeğerler toplamına göre yüzdesel oranı dikkate alınır. Bu oranın %70 ve %95 arasında olması gerekmektedir.
- Belirlenen temel bileşenlerin oluşturduğu dönüşüm matrisi, sıfıra ortalanmış matrisle çarpılarak yeni özellik kümesi elde edilir.

Bazı özelliklerin elenmesi sonucunda bir miktar veri kaybı yaşansa da amaç en az veri kaybı ile veri boyutunu indirmektedir. Dönüşüm sayesinde yüksek boyutlu veriyi daha düşük boyutlu bir uzayda temsil etmek mümkün olmaktadır.


3.3.2. İki boyutlu veri kümesi için TBA yönteminin uygulanması

Her bir özelliğe ait ortalama değer hesaplanarak, her özellikten o özelliğin ortalaması çıkarılarak veri kümesi sıfıra ortalanmış biçime getirilmektedir. Örnek veri kümesi ve sıfıra ortalanmış veri kümesi aşağıda Tablo 3.5.'te verilmektedir. Özellikler sırasıyla 2,175 ve 2,13 ortalama değerlere sahiptirler.

Tablo 3.5. (a) örnek veri kümesi, (b) sıfıra ortalananmış veri kümesi

(a)		(b)	
x	y	x	y
1,50	1,40	-0,675	-0,73
0,8	0,90	-1,375	-1,23
4,20	3,10	2,025	0,97
2,60	2,90	0,425	0,77
3,80	3,20	1,625	1,07
0,70	1,30	-1,475	-0,83
1,00	1,20	-1,175	-0,93
1,80	2,40	-0,375	0,27
2,25	2,00	0,075	-0,13
3,10	2,90	0,925	0,77

Giriş veri kümesinin grafiksel gösterimi aşağıda Şekil 3.2.'de verilmektedir.



Şekil 3.2. Veri kümesinin grafiksel gösterimi

Sıfıra ortalananmış veri kümesinin kovaryans matrisi hesaplanır. Kovaryans matrisi aşağıda verilmektedir.

$$K = \begin{bmatrix} 1,53625000000000 & 1,01472222222222 \\ 1,01472222222222 & 0,773444444444445 \end{bmatrix}$$

Daha sonra kovaryans matrisin özdeğerleri ve özvektörleri (temel bileşenleri) hesaplanmaktadır.

Özdeğer matrisi;

$$\lambda = \begin{bmatrix} 0,070813427929715 & 0 \\ 0 & 2,23888101651473 \end{bmatrix}$$

Özvektör matrisi;


$$V = \begin{bmatrix} 0,569281735049918 & -0,822142509628687 \\ -0,822142509628687 & -0,569281735049918 \end{bmatrix}$$

Özdeğerler büyükten küçüğe doğru sıralanır. Son adımda sıfıra ortalananmış özellik kümesi ile özvektör matrisi çarpılarak yeni özellik kümesi elde edilir. Dönüşüm sonucunda elde edilen yeni özellik kümesi, ağırlıklarına göre sıralı olarak Tablo 3.6.'da verilmektedir.

Tablo 3.6. Dönüşüm sonucunda elde edilen veri kümesi

X	Y
0,970521860585803	0,215898860870247
1,83066248485084	0,228472901149648
-2,21704186499651	0,355317279136257
-0,787757502580629	-0,391104995017874
-1,94511303465003	0,0453903341534213
1,68516404179374	-0,157312276206819
1,49544946241013	0,0956864952710254
0,15459737264728	-0,435459128243464
0,0123459373343376	0,149574656380473
-1,19882875739497	-0,106464127492915

Dönüşüm sonucunda elde edilen yeni veri kümesinin grafiksel gösterimi Şekil 3.3.'te verilmektedir.



Şekil 3.3. Dönüşüm sonucunda elde edilen veri kümesinin grafiksel gösterimi

Boyut azaltımı için yüksek özdeğer seçilir, diğeri atılır. Atılan özdeğer ne kadar küçük olursa bilgi kaybı da o kadar az olacaktır. Örnekte ikinci özdeğer daha büyük değerli olduğu için ona ait özvektör temel bileşen olarak kullanılmaktadır. Özvektörlerin varyanslarına bakıldığında 2. Özvektör toplam varyansın yaklaşık %97'sini, 1. Özvektör ise %3'ünü içermektedir. Dönüşüm sonucunda elde edilen indirgenmiş veri kümesi Tablo 3.7.'de verilmektedir.

Tablo 3.7. Dönüşüm sonucunda elde edilen indirgenmiş veri kümesi

X
0,970521860585803
1,83066248485084
-2,21704186499651
-0,787757502580629
-1,94511303465003
1,68516404179374
1,49544946241013
0,15459737264728
0,0123459373343376
-1,19882875739497

3.4. Kanal Seçimi

EEG işaretleri genellikle çok kanallı olarak ölçülmektedir. Farklı elektrot yerleşimleri kullanılarak beynin ilgilenilen bölgelerindeki elektriksel aktiviteler elde edilmektedir. Bununla birlikte, gürültülü ve gereksiz bilgi içeren işaretler performansı düşürmektedir. Ayrıca sistemin tepki hızının yavaşlamasına neden olmaktadır (Arvaneh ve ark., 2011).

Özellikle gerçek zamanlı uygulamalarda işlemci yükünü azaltmak için sıklıkla kanal seçme işlemi gerçekleştirilmektedir. Çok kanallı ölçüm sistemlerinden elde edilen işaretlerden ayırt ediciliği yüksek olanların kanal seçme işlemiyle belirlenmesi amaçlanmaktadır. Böylece nöbet algılama işleminde performans kaybı olmaksızın, yüksek hızlı karar organlarının tasarlanabilmesi mümkün olmaktadır (Yıldız ve Bergil, 2015).

Bu çalışmada, epilepsili bireyler için 21 farklı kanaldan yapılan ölçümlerden ayırt ediciliği yüksek olanları belirlemek için ön sınıflandırma yapılmıştır. Ön sınıflandırma işlemi gerçekleştirilen kanallar Tablo 3.8.'de verilmektedir.

Tablo 3.8. Ön sınıflandırma işlemi gerçekleştirilen kanallar

No	Kanal	No	Kanal	No	Kanal
1	Fp1-F7	8	P3-O1	15	T8-P8
2	F7-T7	9	Fp2-F4	16	P8-O2
3	T7-P7	10	F4-C4	17	Fz-Cz
4	P7-O1	11	C4-P4	18	Cz-Pz
5	Fp1-F3	12	P4-O2	19	T7-Ft9
6	F3-C3	13	Fp2-F8	20	Ft9-Ft10
7	C3-P3	14	F8-T8	21	Ft10-T8

Ön sınıflandırma aşamasında doğrusal diskiriminant analizi kullanılmıştır. Doğrusal diskiriminant analizi yöntemi sınıflandırma bölümünde ayrıntılı olarak açıklanmıştır. Öncelikle 21 kanaldan elde edilen işaretlerden, 20 öznelikten oluşan özellik kümeleri ayrı ayrı hesaplanmıştır. Hesaplanan özellik kümelerinin boyutları TBA yöntemiyle 20'den 8'e indirgenmiştir. İndirgenmiş özellik kümelerinden çapraz

geçerlilik yöntemiyle elde edilen 100 farklı eğitim ve test verisi için sınıflandırma işlemi tekrarlanmıştır. Yinelemeli ön sınıflandırma sonucunda her kanala ait ortalama sınıflandırma doğruluğu ve sınıflandırma doğruluklarının standart sapması hesaplanmıştır. En yüksek ortalama doğruluğa sahip kanal belirlenerek sınıflandırma aşamasında kullanılmıştır.

3.5. Sınıflandırma

Bir örüntünün ait olduğu sınıfın, o örüntünün özellikleri değerlendirilerek belirlenmesi işlemi sınıflandırma olarak adlandırılmaktadır. Burada amaç bir karar mekanizması oluşturarak, sınıf bilgisi bilinmeyen örüntüleri en az hata ile en yakın sınıflara eşleştirmektir (Michie, Spiegelhalter ve Taylor, 1994; Meyer-Base, 2004; Zheng ve Xue, 2009).

Sınıflandırma işleminde eğitici öğrenme ve eğitici öğrenme olmak üzere iki farklı algoritma kullanılmaktadır. Eğitici öğrenme algoritmalarında sınıf bilgisi belli olan örüntüler kullanılarak, girişler ve çıkışlar arasında bir model oluşturulmaktadır. Destek vektör makineleri, yapay sinir ağları ve karar ağaçları eğitici öğrenme yöntemlerine örnek olarak verilebilir. Eğitici öğrenme algoritmalarında karar modeli oluşturulurken örüntülerin sınıf bilgisi kullanılmamaktadır. Eğitim verileri arasındaki mesafe ve benzerlik gibi özelliklere bakılarak sınıf ataması yapılmaktadır. Bu öğrenme yöntemi aynı zamanda kümeleme algoritması olarak da bilinmektedir (Michie, Spiegelhalter ve Taylor, 1994; Meyer-Base, 2004; Fielding, 2007; Kotsiantis, 2007).

Bu çalışmada farklı epileptik evrelerden elde edilen EEG örnekleri sınıflandırılmaktadır. Normal, nöbet öncesi ve nöbet dönemlerinden elde edilen örnekler k-en yakın komşu, doğrusal diskriminant analizi, destek vektör makineleri ve yapay sinir ağları sınıflandırıcıları kullanılarak sınıflandırılmıştır.

3.5.1. Doğrusal diskiriminant analizi

Doğrusal diskiriminant analizi (DDA), istatistik ve makine öğrenmesi alanlarında yaygın olarak kullanılan sınıflandırma yöntemlerinden biridir. Ronald Aylmer Fischer tarafından 1936 yılında geliştirilmiştir. DDA, iki ya da daha fazla sınıfa ait örnekleri ayırmak için doğrusal bir sınıflandırıcı olarak kullanılabilen özelliklerin doğrusal birleşimini bulmaya çalışan bir yöntemdir. Bir başka ifadeyle DDA, sınıfları birbirinden en iyi ayırt eden uzaya ait vektörleri bulmaya çalışır (Panahi ve ark., 2011; Junoh ve Mansor, 2012).

Diskriminant analizi ayırt edici fonksiyonları saptayarak, gruplar arası ayrıştırmada en etkili ayırıcı değişkenleri belirlemekte ve grup bilgisi belli olmayan bir birimin hangi gruba ait olduğunu saptamada kullanılan bir analizdir (Ünsal, 2000; Fielding, 2007; Panahi ve ark., 2011; Fraz ve ark., 2013). Bu yöntem; farklı sınıflara ait veri noktalarını birbirinden uzaklaştıran ve aynı sınıfta bulunan veri noktalarını birbirine yakınlığa getiren, mevcut verilerin bileşkesi olan yeni bir değişken üretmektedir. İlk tanımlanan sınıfların yeni değişkene göre aralarındaki farklılıkları maksimumlaştırmayı amaçlar (Fielding, 2007; Panahi ve ark., 2011; Fraz ve ark., 2013).

DDA'da öncelikli olarak farklı sınıflara ait olan noktalar bir başka düzleme, sınıflar birbirlerinden olabildiğince ayrı olacak şekilde iz düşürülmektedir. Bu işlemi mevcut veri kümesinin yardımıyla izdüşüm (dönüşüm) matrisini hesaplayarak gerçekleştirir. Dönüşüm matrisi hesaplandıktan sonra veri kümesi dönüşüm matrisi kullanılarak sınıflar arası mesafeyi maksimum yapacak şekilde farklı bir uzaya haritalanır (Johnson ve Wichern, 2007; Panahi ve ark., 2011; Junoh ve Mansor, 2012). Bunun için her bir sınıftaki her bir x noktası;

$$y_i = V^T x \quad (3.12)$$

olacak şekilde değiştirilmektedir. V , izdüşümü matrisini temsil etmektedir (Ünsal, 2000; Johnson ve Wichern, 2007).

Bütün sınıfların bütün örnekleri için sınıf içi dağılım matrisi ve sınıflar arası dağılım matrisi tanımlanır. Amaç sınıf içi ölçümü minimumlaştırırken sınıflar arası ölçümü maksimumlaştırmaktır (Bishop, 2006; Panahi ve ark., 2011; Junoh ve Mansor, 2012). Buradan sınıf içi dağılım matrisi S_W ve sınıflar arası dağılım matrisi S_B aşağıda verilen eşitlikler ile hesaplanır.

$$S_W = \sum_{i=1}^c \sum_{x_k \in \text{sınıf}_i} (x_k - \mu_i)(x_k - \mu_i)^T \quad (3.13)$$

$$S_B = \sum_{i=1}^c n_i (\mu_i - \mu) (\mu_i - \mu)^T \quad (3.14)$$

n sınıftan oluşan bir veri grubu için; n_i , i . sınıfa ait örneklerin sayısını, n , toplam örnek sayısını, c , sınıf parametresini, μ_i , i . sınıfa ait örneklerin ortalama değerini, μ , tüm sınıflara ait örneklerin ortalama değerini, x_k , i . sınıfa ait örnekleri göstermektedir.


En uygun dönüşüm matrisi V aşağıda verilen eşitliği sağlamalıdır:

$$S_B V = \lambda S_W V \quad (3.15)$$

V 'nin bulunabilmesi için $S_W^{-1} S_B$ 'nin özvektörleri hesaplanır. V bulunduktan sonra eğitim veri seti V vektörü kullanılarak DDA uzayına taşınır. Bir test verisi geldiğinde sentezlenen sinyalin c parametrelerinin hangi sınıfa ait olduğunun bulunması için ilk olarak hesaplanan V matrisi kullanılarak c parametresi DDA uzayına geçirilir. DDA uzayında bu noktanın her bir sınıfa olan uzaklığı hesaplanır. Daha sonra bu uzaklığa göre veri uygun gruba dahil edilir (Ünsal, 2000; Panahi ve ark., 2011; Junoh ve Mansor, 2012). Yukarıda açıklanan bilgiler doğrultusunda, Tablo 3.9.'da verilen örnek uzay için DDA yöntemi uygulanmıştır. Örnek uzay dağılımı Şekil 3.4.'te gösterilmektedir.

Tablo 3.9. DDA uygulaması için iki boyutlu örnek uzayı ve sınıf bilgileri

x	3	2	1	4	3	6	9	7	8	10
y	1	4	1	3	2	8	10	8	6	8
sınıf	A	A	A	A	A	B	B	B	B	B



Şekil 3.4. DDA örnek uzayı

Sınıflara ait ortalama değerler (μ_1, μ_2), kovaryans matrisleri (S_1, S_2), sınıf içi dağılım matrisi (S_W) ve sınıflar arası dağılım matrisi (S_B) hesaplanmıştır. Elde edilen sonuçlar aşağıda verilmiştir.

$$\mu_1 = \begin{bmatrix} 2,6 \\ 2,2 \end{bmatrix}$$

$$\mu_2 = \begin{bmatrix} 8 \\ 8 \end{bmatrix}$$

$$S_1 = \begin{bmatrix} 1,3 & 0,35 \\ 0,35 & 1,7 \end{bmatrix}$$

$$S_2 = \begin{bmatrix} 2,5 & 0,5 \\ 0,5 & 2 \end{bmatrix}$$

$$S_W = \begin{bmatrix} 3,8 & 0,85 \\ 0,85 & 3,7 \end{bmatrix}$$

$$S_B = \begin{bmatrix} 29,16 & 31,32 \\ 31,32 & 33,64 \end{bmatrix}$$

Özdeğerler ve özvektörler;

$$\lambda_1 = -8,88178419700125e - 16$$

$$\lambda_2 = 13,6817244611059$$


$$V = \begin{bmatrix} -0,731893974431350 & -0,653111295182436 \\ 0,681418527918843 & -0,757261933616844 \end{bmatrix}$$

olarak hesaplanmıştır. Daha yüksek ayırt ediciliğe sahip olduğu için büyük özdeğere ait özvektör doğrultusunda izdüşümü alınır.

Dönüşüm matrisi olarak;


$$w = \begin{bmatrix} -0,653111295182436 \\ -0,757261933616844 \end{bmatrix}$$

elde edilir. Yüksek özdeğerli özvektör için elde edilen izdüşümü eksenini Şekil 3.5.'te verilmiştir. Bu iz düşüme göre A ve B sınıfına ait örneklerin birbirlerinden net bir şekilde ayırt edilebildiği görülmektedir.



Şekil 3.5. Örnek uzayı ve yüksek özdeğerli özvektör için izdüşümü eksenini

Düşük özdeğerli özvektör için elde edilen izdüşümü eksenini Şekil 3.6.'da verilmiştir. Bu dönüşümde örnekler net olarak ayırt edilememektedir.



Şekil 3.6. Örnek uzayı ve düşük özdeğerli özvektör için izdüşümü eksenini

DDA ile sınıflandırma yapılırken, sınıf bilgisi belli olmayan herhangi bir örnek için (3.16) eşitliği yardımıyla her bir sınıfa olan ortalama vektör uzaklığı hesaplanır. A sınıfı için ortalama vektör uzaklığı;

$$S_A^2 = (V^T X_i - V^T \mu_1)^2 \quad (3.16)$$

eşitliği kullanılarak hesaplanır. B sınıfı için ortalama vektör uzaklığı;

$$S_B^2 = (V^T X_i - V^T \mu_2)^2 \quad (3.17)$$

eşitliği kullanılarak hesaplanır.

Hesaplanan vektör uzaklıklarına bakılarak örneğin hangi sınıfa dahil edileceğine karar verilir. A sınıfına ait (2,4) örneği için sınıflandırma işleminin aşamaları aşağıda gösterilmiştir. Öncelikle sınıfı bilinmeyen örneğin her bir sınıfa olan ortalama vektör uzaklığı hesaplanır.

$$S_A^2 = \left([-0,653111295182436 \quad -0,757261933616844] \begin{bmatrix} 2 - 2,6 \\ 4 - 2,2 \end{bmatrix} \right)^2 = 0,9432$$


$$S_B^2 = \left([-0,653111295182436 \quad -0,757261933616844] \begin{bmatrix} 2 - 8 \\ 4 - 8 \end{bmatrix} \right)^2 = 48,2708$$

Yukarıda hesaplanan değerlere göre örneğin A sınıfına olan ortalama vektör uzaklığı daha küçük olduğundan sınıflandırıcı örneği A sınıfına atayacaktır.

3.5.2. k- En yakın komşu algoritması

k-En Yakın Komşu (k-EYK) algoritması, yaygın olarak kullanılan en basit sınıflandırma yöntemlerinden birisidir. Örnek tabanlı sınıflandırıcılardan olan bu yöntemde sınıflandırma işlemi, örüntünün eğitim setindeki örneklerle olan uzaklıklarına bakılarak yapılmaktadır. Eğitim setini oluşturan örnekler, boyutu özellik sayısı ile belirlenen bir uzayda temsil edilmektedir. Örnekler bu uzayda bir noktaya karşılık gelmektedir. Yöntem sınıf bilgisi bilinmeyen bir örüntünün hangi sınıfa ait olacağını belirlerken, eğitim setinden ilgili örüntüye en yakın k tane örnek tespit edilir. Örüntünün hangi sınıfa ait olacağına, belirlenen k tane en yakın komşunun çoğunluk oylamasına, başka bir ifadeyle bu komşuların sınıf bilgilerinin dağılımına bakılarak karar verilir. Sınıflandırma başarımını etkileyen başlıca unsur, çoğunluk oylamasına katılacak olan komşu sayısıdır (Mitchell, 1997; Han ve Kamber, 2006; Joshi ve Shetty, 2015).

Şekil 3.7.'de sınıf etiketi bilinmeyen x örüntüsü için eğitim verilerinin iki boyutlu örnek uzayda dağılımları gösterilmektedir. En yakın komşu sayısının sırasıyla 3 ve 5 seçilmesine bağlı olarak etiketi bilinmeyen örüntünün farklı sınıflara dahil edilebileceği görülmektedir.



Şekil 3.7. k- en yakın komşu algoritması sınıflandırma örneği

Minkowski, Öklid, Manhattan, Chebyshev (maksimum değer uzaklığı) ve Dilca (Distance Learning in Categorical Attribute) mesafe ölçütlerinden birisi kullanılarak en yakın komşular belirlenmektedir (Taşcı ve Onan, 2016). İki örnek ya da nokta arasındaki Öklid mesafesi, $X_1=(x_{11},x_{12},\dots,x_{1n})$ ve $X_2=(x_{21},x_{22},\dots,x_{2n})$ n boyutlu uzayda iki nokta olmak üzere;

$$d(X_1, X_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \quad (3.18)$$

eşitliği ile hesaplanır.

Yukarıda verilen bilgiler doğrultusunda örnek bir uygulama; Tablo 3.10.'da verilen örnek uzay için (5,8) noktasının hangi sınıfa ait olacağına k-en yakın komşu algoritması ile karar verilmiştir.

Tablo 3.10. k-EYK uygulaması için iki boyutlu örnek uzayı ve sınıf bilgileri

x	1	7	8	3	7	9	5	2	4	10
y	5	2	10	7	3	6	1	8	5	9
sınıf	A	B	A	B	A	B	A	B	A	B

1. Adım: k değeri belirlenir. Bu uygulamada k=3 kabul edilmiştir.
2. Adım: Denklem(3.18) kullanılarak örnek uzaydaki her noktanın (5,8) noktasına olan Öklid mesafeleri hesaplanır.

$$d((1,5), (5,8)) = \sqrt{(1-5)^2 + (5-8)^2} = 5.00$$

$$d((7,2), (5,8)) = \sqrt{(7-5)^2 + (2-8)^2} = 6.32$$

$$d((8,10), (5,8)) = \sqrt{(8-5)^2 + (10-8)^2} = 3.61$$

$$d((3,7), (5,8)) = \sqrt{(3-5)^2 + (7-8)^2} = 2.24$$

$$d((7,3), (5,8)) = \sqrt{(7-5)^2 + (3-8)^2} = 5.39$$

$$d((9,6), (5,8)) = \sqrt{(9-5)^2 + (6-8)^2} = 4.47$$

$$d((5,1), (5,8)) = \sqrt{(5-5)^2 + (1-8)^2} = 7.00$$

$$d((2,8), (5,8)) = \sqrt{(2-5)^2 + (8-8)^2} = 3.00$$

$$d((4,5), (5,8)) = \sqrt{(4-5)^2 + (5-8)^2} = 3.16$$


$$d((10,5), (9,8)) = \sqrt{(10-5)^2 + (9-8)^2} = 5.10$$

3. Adım: Öklid mesafelerine bakılarak en yakın 3 komşu belirlenir. En yakın 3 komşu Tablo 3.11.'de işaretlenmiştir.

Tablo 3.11. (5,8) noktası için hesaplanan mesafeler

x	1	7	8	3	7	9	5	2	4	10
y	5	2	10	7	3	6	1	8	5	9
mesafe	5.00	6.32	3.61	2.24	5.39	4.47	7.00	3.00	3.16	5.10
sınıf	A	B	A	B	A	B	A	B	A	B

4. Adım: En yakın 3 komşunun çoğunluk oylamasıyla (5,8) noktasının sınıfı belirlenir. En yakın 3 komşunun 2 tanesi ((3,7) ve (2,8) noktaları) B sınıfına 1 tanesi (4,5) A sınıfına aittir. Sınıf bilgisi bilinmeyen örüntü eğitim verilerinin özellik uzayındaki dağılımları ve en yakın komşular Şekil 3.8.'de gösterilmektedir. (5,8) noktası çoğunluk oylamasıyla B sınıfına dahil edilir.



Şekil 3.8. (5,8) noktasının en yakın 3 komşusu

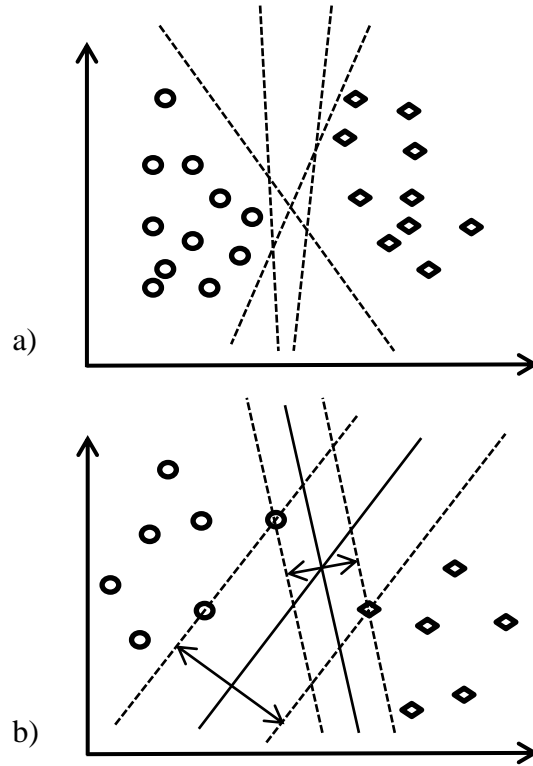
3.5.3. Destek vektör makineleri

Destek vektör makineleri (DVM) örüntü tanımada kullanılan etkili ve basit yöntemlerden birisidir. İstatistiksel öğrenme tabanlı ve denetimli bir öğrenme yöntemi olan DVM'nin temelleri, 1963 yılında Vladimir N. Vapnik tarafından atılmıştır (Vapnik, 1998). Yöntem yapısal riski en aza indirerek, sınıflandırma ve eğri uydurma problemlerini çözmek üzere geliştirilmiştir. Kanserli doku tanısı, nesne tanıma, yüz tanıma, ses tanıma ve el yazısı tanıma gibi birçok alanda yaygın olarak kullanılmaktadır (Burges, 1998).

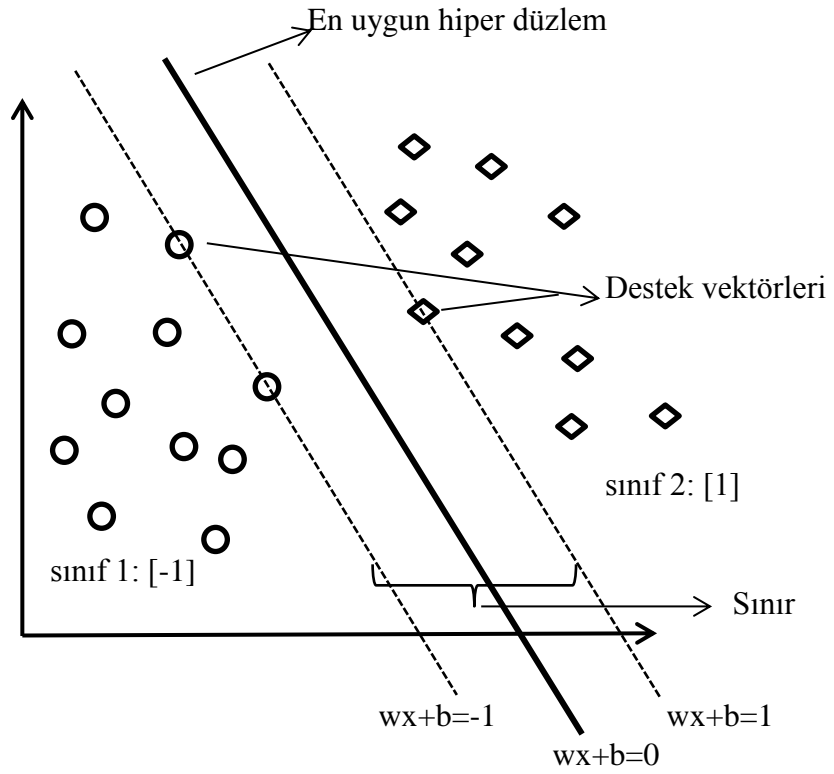
Denetimli öğrenme yöntemlerinde, eğitim verilerinin hangi sınıfa ait oldukları bilinmektedir. İki sınıf arasında çizilecek olan sınır ile sınıfların birbirinden ayrılması hedeflenmektedir. Bu aşamada DVM bu sınırın nasıl çizileceğine karar vermektedir. Sınır iki grup üyelerine de en uzak mesafede olacak şekilde çizilmelidir. Yöntem, sınıfları ayıran en uygun hiper düzlemi belirlemektedir. Yöntemin genelleme hataları hiper düzlemin verileri ayırdığı sınırın genişliğine bağlıdır. Örnek uzay dağılımına bağlı olarak sınıflar doğrusal olarak birbirlerinden ayrılabilir. Sınıfların doğrusal olarak ayrıştırılmadığı durumlarda, örnek uzay yüksek boyutlu başka bir uzaya yansıtılarak, doğrusal olarak ayırt edilebilir bir yapıya dönüştürülmektedir (Burges, 1998; Zheng ve Xue, 2009; Abe, 2010).

3.5.3.1. Doğrusal destek vektör makineleri

Doğrusal olarak ayrılabilen bir yapıya sahip iki sınıflı veri seti için, sonsuz sayıda hiper düzlem söz konusudur. DVM, eğitim verilerini hatasız olarak ayırabilen en geniş sınırlara sahip hiper düzlemi belirlemektedir (Şekil 3.9.). Sınırlar, oluşturulan karar düzlemine en yakın uç noktalarıdır ve destek vektörleri olarak adlandırılırlar. İki sınıflı ve iki boyutlu bir örnek uzay dağılımına ait en uygun hiper düzlem ve destek vektörleri Şekil 3.10.'da gösterilmektedir.



Şekil 3.9. a) Doğrusal olarak ayrılabilen hiper düzlemler b) İki farklı hiper düzlem için sınır genişlikleri



Şekil 3.10. En uygun hiper düzlem

x_i eğitim kümesine ait örnekler, y_i ise örneklerin sınıf bilgisi ($y_i \in \{-1, +1\}$) ve $\{x_i, y_i\}$ $i=1,2,\dots,l$ olmak üzere; hiper düzlem üzerine karşılık gelen noktalar Denklem 3.19'u sağlayacaktır.

$$wx + b = 0 \quad (3.19)$$

$\|w\|$, w vektörünün normu (denklem 3.20), $|b|/\|w\|$ aşırı düzlemin orijinine olan dik uzaklığı ve b sapma değeri olmak üzere, x noktasının $w^T x + b = 0$ düzlemine olan dik uzaklığı Denklem 3.21 kullanılarak hesaplanır.

$$\|w\| = \sqrt{\langle w, w \rangle} = \sqrt{w^T w} \quad (3.20)$$

$$\frac{w^T x + b}{\|w\|} \quad (3.21)$$


Sınıf 1'in destek vektörünü oluşturan noktanın karar fonksiyonunda aldığı değer -1 ; Sınıf 2'nin destek vektörünü oluşturan noktanın karar fonksiyonunda aldığı değer $+1$ 'e eşittir. Hiper düzlemin iki tarafındaki en yakın örneklere diğer bir ifadeyle destek vektörlerine dik uzaklığı Denklem 3.22 ile hesaplanır.

$$\frac{|w^T x + b|}{\|w\|} = \frac{1}{\|w\|} \quad (3.22)$$

Denklem 3.23 ile verilen dik uzaklıkların toplamı, sınır olarak adlandırılır.

$$m = \frac{2}{\|w\|} \quad (3.23)$$

Destek vektör algoritması, öğrenme hatasını minimum yapmayı amaçlamaktadır. Bunun için en geniş sınırlı hiper düzlemi belirleyerek sınıflandırma işlemini gerçekleştirir. Geometrik ve grafiksel yaklaşımlardan faydalanarak ağırlıklar vektörü normu $\|w\|$ ile sınır arasındaki ilişki gösterilebilir. Şekil 3.11.'de sınırlar x_1 ve x_2 noktalarıdır. Destek vektörler bu iki noktanın orijin ile oluşturdukları yönlü vektörleri temsil etmektedir.



Şekil 3.11. En uygun hiper düzlem için geometrik yaklaşım

D_1 ve D_2 dik uzaklıkları arasındaki fark M mesafesine karşılık gelmektedir. D_1 , D_2 ve M mesafelerine ait eşitlikler aşağıda verilmektedir.

$$D_1 = \|x_1\| \cos(\alpha) \quad (3.24)$$

$$D_2 = \|x_2\| \cos(\beta) \quad (3.25)$$

$$M = D_1 - D_2 \quad (3.26)$$

Denklem 3.27 ve Denklem 3.28'de $\cos(\alpha)$ ve $\cos(\beta)$ 'nin matematiksel karşılıkları verilmiştir.

$$\cos(\alpha) = \frac{x_1^T w}{\|x_1\| \|w\|} \quad (3.27)$$

$$\cos(\beta) = \frac{x_2^T w}{\|x_2\| \|w\|} \quad (3.28)$$

Denklem (3.24), (3.25), (3.27) ve (3.28) kullanılarak Denklem 3.26'da verilen mesafe eşitliği yeniden düzenlenirse, Denklem 3.29 elde edilir.

$$M = \frac{x_1^T w - x_2^T w}{\|w\|} \quad (3.29)$$

x_1 ve x_2 destek vektörleri için; $y_j |w^T x_j + b| = 1$, $j=1,2$ yani $w^T x_1 + b = 1$ ve $w^T x_2 + b = -1$ kullanıldığında; Denklem 3.29, Denklem 3.23'e dönüşür. Sınırı maksimum yapmak için Denklem 3.30'da verilen amaç fonksiyonu Denklem 3.31'de belirtilen kısıtlar altında minimize edilir.

$$J(w) = \frac{1}{2} \|w\|^2 \quad (3.30)$$

$$y_i (w^T x_i + b) \geq 1 \quad (3.31)$$

Lagrange çarpanları yöntemi ile $J(w)$ ifadesi minimize edilmektedir. Kısıt denklemleri pozitif Lagrange çarpanlarıyla çarpılıp amaç fonksiyonundan çıkarılarak Denklem 3.32 elde edilir. Denklem 3.32 ifadesini çözmek için Lagrange çarpanları yöntemi kullanılır.

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i [y_i (w^T x_i + b) - 1] \quad (3.32)$$

Lagrange Çarpanları yöntemi (Lagrange's Multipliers); Denklem 3.33'teki amaç fonksiyonunu, Denklem 3.34'te verilen kısıtta minimize veya maksimize etmek için $H(x, y, z, t) = f(x, y, z) \pm t g(x, y, z)$ yardımcı fonksiyonu kullanılmaktadır. Bu fonksiyonun x, y, z ve t 'ye göre kısmi türevlerinin sıfır olmasını sağlayan x, y, z, t değerleri hesaplanır. Maksimum için $+$, minimum için $-$ işaret alınır. w, b parametrelerini elimine etmek için Denklem 3.32'deki $L(w, b, a)$ ifadesinin w ve b 'ye göre kısmi türevi alınıp sıfıra eşitlenir.

$$\min / \max f(x, y, z) \quad (3.33)$$

$$g(x, y, z) \quad (3.34)$$

$$\frac{\partial L(w, b, \alpha)}{\partial w} = 0 \rightarrow w = \sum_{i=1}^N \alpha_i y_i x_i \quad (3.35)$$

$$\frac{\partial L(w, b, \alpha)}{\partial b} = 0 \rightarrow \sum_{i=1}^N \alpha_i y_i = 0 \quad (3.36)$$

Bunlar birleştirilirse;

$$L(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (3.37)$$

Karush-Khun-Tucker (KKT) şartına göre (Abe, 2010),

$$\alpha_i \geq 0 \quad (3.38)$$


$$y_i(w^T x_i + b) - 1 \geq 0 \quad (3.39)$$

$$\alpha_i [y_i(w^T x_i + b) - 1] = 0 \quad (3.40)$$

Her örnek için Denklem 3.38, 3.39 ve 3.40 sağlanmalıdır. Yani $\alpha_i = 0$ durumunda i . veri destek vektörü değildir. Bir başka ifadeyle yeni verilerin sınıflandırılmasında hiçbir etkisi bulunmamaktadır. Eğer $\alpha_i \neq 0$ durumunda ise i . destek vektörü olarak adlandırılır.

3.5.3.2. Doğrusal olmayan destek vektör makineleri

Eğitim için kullanılan örnekleri doğrusal olarak ayırmak her zaman mümkün olmayabilir. Şekil 3.12.'de doğrusal olarak ayrılamayan bir örnek uzay gösterilmektedir. Bu durumda kısıtlamaları gevşetmek için pozitif gevşek değişkenler ($\xi_i \geq 0$) tanımlanmaktadır (Vapnik, 1998; Burges, 1998; Abe, 2010; Zheng ve Xue, 2009).



Şekil 3.12. Eğitim verilerinin doğrusal olarak ayrılamadığı durum örneği

Buna göre Denklem 3.41’de belirtilen kısıtlamalar altında $J(w)$ amaç fonksiyonu aşağıdaki gibi yazılabilir.

$$J(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad (3.40)$$

$$y_i(w^T x_i + b) \geq 1 - \xi_i \quad \xi_i \geq 0 \quad i = 1, 2, \dots, l \quad (3.41)$$

Denklem 3.40’taki ikinci terim yanlış sınıflandırma durumunu kontrol etmektedir. Bu parametre (C) kullanıcı tarafından belirlenmektedir. Doğrusal olarak ayrılabılır durumlarda olduğu gibi Lagrange çarpanları yöntemleri kullanılarak Denklem 3.40. minimize edilir. Lagrange fonksiyonu;

$$L(w, b, \xi, \alpha, \beta) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i - \sum_{i=1}^l \alpha_i (y_i(w^T x_i + b) - 1 + \xi_i) - \sum_{i=1}^l \beta_i \xi_i \quad (3.42)$$

olarak yazılmaktadır. Burada α_i ve β_i Lagrange çarpanlarını temsil etmektedir. β_i, ξ_i değerlerinin pozitif olmasını sağlamaktadır. $L(w, b, \xi, \alpha, \beta)$ Fonksiyonunun w, b ve ξ değerlerine göre en küçük noktalarını hesaplamak için

w, b ve ξ değerlerine göre türevleri alınarak sıfıra eşitlenir. Türev eşitlikleri aşağıda verilmektedir.

$$\frac{\partial L(w, b, \xi, \alpha, \beta)}{\partial w} = 0 \rightarrow w = \sum_{i=1}^l \alpha_i y_i x_i \quad (3.43)$$

$$\frac{\partial L(w, b, \xi, \alpha, \beta)}{\partial b} = 0 \rightarrow \sum_{i=1}^l \alpha_i y_i = 0 \quad (3.44)$$

$$\frac{\partial L(w, b, \xi, \alpha, \beta)}{\partial \xi} = 0 \rightarrow C = \alpha_i + \beta_i \quad (3.45)$$

Buna göre Karush-Kuhn-Tucker (KKT) koşulları ile kısıtlamalar aşağıda verilmektedir (Vapnik, 1998; Burges, 1998; Abe, 2010; Zheng ve Xue, 2009) ;

$$\frac{\partial L(w, b, \xi, \alpha, \beta)}{\partial w} = 0 \quad (3.46)$$

$$\frac{\partial L(w, b, \xi, \alpha, \beta)}{\partial b} = 0 \quad (3.47)$$

$$\frac{\partial L(w, b, \xi, \alpha, \beta)}{\partial \xi} = 0 \quad (3.48)$$

$$\alpha_i (y_i (w^T x_i + b) - 1 + \xi_i) = 0 \quad i = 1, 2, \dots, l \text{ için} \quad (3.49)$$

$$\beta_i \xi_i = 0 \quad i = 1, 2, \dots, l \text{ için} \quad (3.50)$$

$$\alpha_i \geq 0, \beta_i \geq 0, \xi_i \geq 0 \quad i = 1, 2, \dots, l \text{ için} \quad (3.51)$$

Lagrange fonksiyonunda KKT koşulları yerleştirildiğinde;

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (3.52)$$

olarak düzenlenmektedir.

Denklem 3.52 aşağıda verilen kısıtlamaları sağlamalıdır.

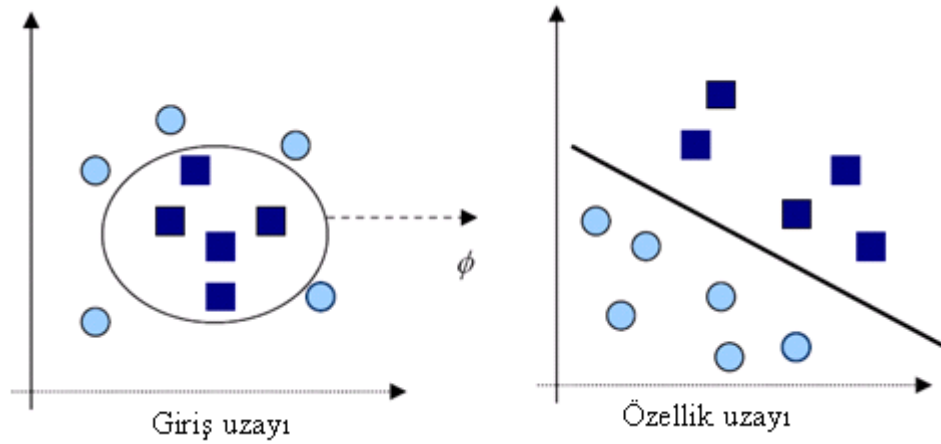
$$\sum_{i=1}^l y_i \alpha_i = 0, \quad C \geq \alpha_i \geq 0 \quad i = 1, 2, \dots, l \text{ için} \quad (3.53)$$

Denklem 3.52'ye göre $\alpha_i \neq 0$ durumunu sağlayan her x_i giriş destek vektörüdür. Doğrusal olarak ayrılan ve ayrılamayan destek vektör makineleri arasındaki tek fark, doğrusal olmayan durumlarda α_i 'nin C'den küçük olması gerektiğidir.

Sıfırdan farklı α_i 'ler kullanılarak (3.19) eşitliğinde (3.43) eşitliği yerleştirilerek karar fonksiyonu yeniden düzenlenmektedir (Vapnik, 1998; Burges, 1998; Abe, 2010; Zheng ve Xue, 2009).

$$f(x) = \text{sign}(\sum_{\text{destek vektörleri}} \alpha_i y_i x_i^T x_j + b) \quad (3.54)$$

Birçok uygulamada örneklerin doğrusal bir karar fonksiyonu ile hatasız olarak ayrılabilmesi mümkün olmamaktadır. Bu durumlarda, doğrusal olmayan haritalamadan yararlanılarak giriş uzayı, özellik uzayı olarak isimlendirilen yüksek boyutlu başka bir uzaya haritalanmaktadır. Bu durum Şekil 3.13.'te gösterilmektedir. Yüksek boyutlu bu uzayda, örnekler doğrusal olarak ayrılabilen bir yapıdadır (Vapnik, 1998; Burges, 1998; Abe, 2010; Zheng ve Xue, 2009).



Şekil 3.13. Verilerin giriş uzayından özellik uzayına aktarımı

Şekil 3.13. doğrusal olarak ayrılamayan giriş uzayının, yüksek dereceli özellik uzayına dönüştürülerek doğrusal olarak ayırt edilebileceğini göstermektedir. $\Phi(x_i) = \{\phi_1(x_i), \phi_2(x_i), \dots, \phi_l(x_i)\}$, $i = 1, 2, \dots, l$, doğrusal olmayan haritalama fonksiyonu yani dönüşüm fonksiyonu sayesinde l boyutlu x giriş vektörü, m boyutlu özellik uzayına aktarılır. Bu özellik uzayı için doğrusal karar fonksiyonu aşağıda verilmektedir (Burges, 1998; Vapnik, 1998; Zheng ve Xue, 2009; Abe, 2010).

$$f(x) = w^T \Phi(x) + b \quad (3.55)$$

Denklem 3.55'te w , l boyutlu ağırlık vektörüne, b ise eşik değerine karşılık gelmektedir. Buna göre en uygun hiper-düzlemi belirlemek için, $J(w, \xi)$ fonksiyonu Denklem 3.57'de verilen kısıtlamalar altında en küçük yapılır.

$$J(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad (3.56)$$

$$y_i(w^T \Phi(x_i) + b) \geq 1 - \xi_i \quad \xi_i \geq 0, \quad i = 1, 2, \dots, l \text{ için} \quad (3.57)$$

Lagrange çarpımları yöntemi kullanılarak KKT koşullarına göre ağırlık vektörü, $\Phi(x_i)$ dönüşüm fonksiyonunun doğrusal birleşimi olarak yazılmaktadır.

$$w = \sum_{i=1}^l \alpha_i y_i \Phi(x_i) \quad (3.58)$$

En uygun ayırıcı düzlemi bulmak için yüksek boyutlu özellik uzayında iç çarpımın tanımlanması gerekmektedir. (3.55) ve (3.58) eşitlikleri birleştirilerek:

$$f(x) = \sum_{i=1}^l \alpha_i y_i \phi^T(x_i) \phi(x_j) + b = \sum_{i=1}^l \alpha_i y_i K(x_i, x_j) + b \quad (3.59)$$

elde edilir. Yüksek boyutlu öznelik uzayındaki $\phi^T(x_i)\phi(x)$ iç çarpımının hesaplanması çok güçtür. Bunun yerine düşük boyutlu giriş uzayında, çekirdek fonksiyonunun hesaplanması yeterli olacaktır. $K(x_i, x_j)$ çekirdek fonksiyonu olarak adlandırılmakta ve aşağıdaki biçimde ifade edilmektedir (Burges, 1998; Zheng ve Xue, 2009; Abe, 2010).

$$K(x_i, x) = \phi^T(x_i)\phi(x_j) \quad (3.60)$$

Çekirdek fonksiyonu kullanılarak aşağıda (Denklem 3.62) verilen kısıtlamalar altında Lagrange fonksiyonu çözülerek Lagrange çarpımları hesaplanabilmektedir.

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (3.61)$$

$$\sum_{i=1}^l y_i \alpha_i = 0 \text{ ve } 0 \leq \alpha_i \leq C \quad i = 1, 2, \dots, l \quad (3.62)$$

Denklem 3.62'ye göre $\alpha_i \neq 0$ ve $\alpha_i \leq C$ durumunda x_i girişi destek vektörü olarak adlandırılmaktadır. Buna göre karar fonksiyonu:

$$f(x) = \text{sign}(\sum_{\text{destek vektörleri}} \alpha_i y_i K(x_i, x_j) + b) \quad (3.63)$$

olarak ifade edilir.

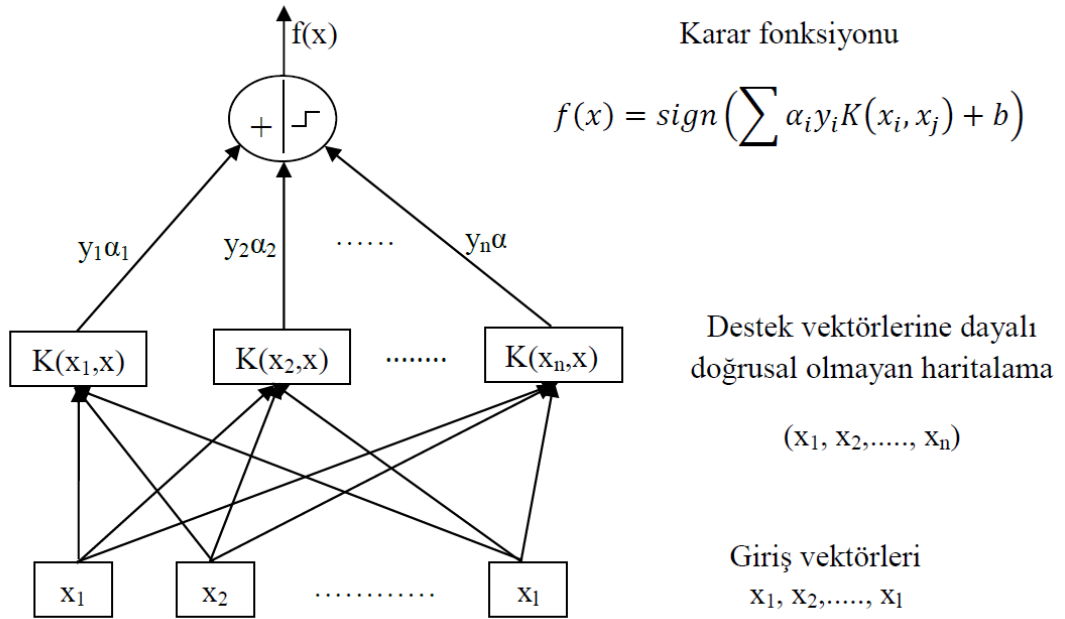
Doğrusal olarak ayırt edilemeyen durumlar için çekirdek fonksiyonlarının seçimi, sınıflandırma performansını etkilemektedir (Vapnik, 1998; Burges, 1998; El-Naqa, 2002; Abe, 2010; Zheng ve Xue, 2009). Destek vektör makineleri yönteminde sıkça

kullanılan çekirdek fonksiyonları Tablo 3.12.'de verilmektedir (Burges, 1998; Zheng ve Xue, 2009; Abe, 2010).

Tablo 3.12. Çekirdek fonksiyonları

Çekirdek Fonksiyonu	$K(x_i, x_j)$
Doğrusal	$x_i^T x_j$
Çok terimli	$(x_i^T x_j + 1)^p$
Radyal tabanlı fonksiyon (RTF)	$\exp(-\frac{1}{2\sigma^2} \ x - y\ ^2)$

Doğrusal olmayan bir DVM sınıflandırıcısının ağ yapısı aşağıda Şekil 3.14.'te gösterilmektedir.



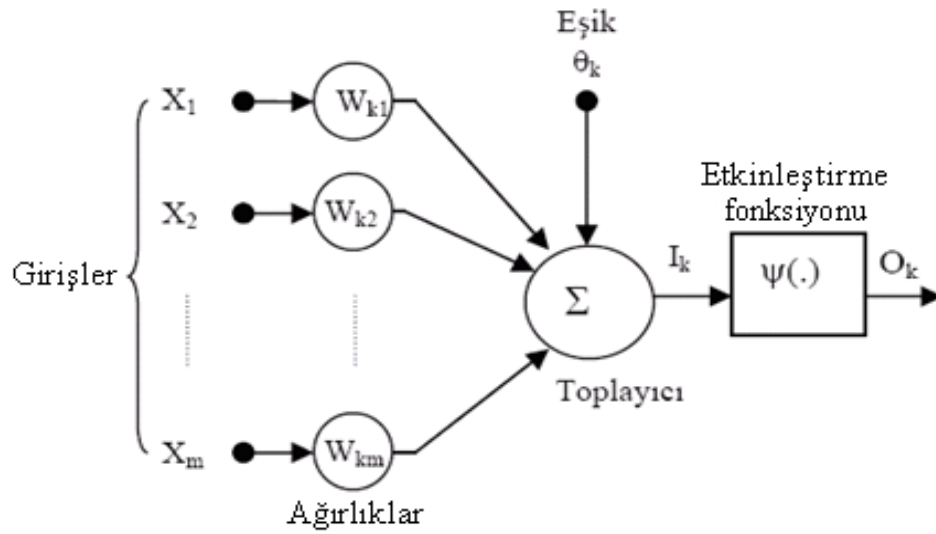
Şekil 3.14. DVM Ağ yapısı (Vapnik, 1998)

3.5.4. Çok katmanlı yapay sinir ağları

Yapay sinir ağı (YSA), biyolojik sinir sistemi çalışma ilkesinden esinlenerek ortaya çıkmış, basit işlevler içeren birçok yapay sinir hücresinin, çeşitli ağırlık ve eşik

değerleri ile birbirine bağlanması sonucu oluşan bir sistem olarak tanımlanmaktadır (Meyer-Base, 2004).

YSA'lar paralel dağıtılmış bilgi işleme yapısı, öğrenebilme ve genelleme yapabilme becerileri sayesinde birçok karmaşık problemin çözümünde kullanılmaktadırlar. Örüntü tanıma, optimizasyon, sınıflandırma, kestirim, sistem tanımlama ve denetimi gibi birçok alanda uygulanmaktadır (Mitchell, 1997; Haykin, 1999). Yapay sinir hücresi modeli aşağıda Şekil 3.15.'te verilmektedir.



Şekil 3.15. Yapay sinir hücresi modeli (Haykin, 1999)

Şekil 3.15.'te verilen modelde k . sinir hücresinin ağırlıklı toplamı ve çıkışı aşağıda verilmektedir.

$$I_k = \sum_{j=1}^m x_j w_{kj} + \theta_k \quad (3.64)$$

$$O_k = \psi(I_k) \quad (3.65)$$


Yukarıda verilen (3.64) ve (3.65) eşitliklerinde x_1, x_2, \dots, x_m giriş verilerini, $w_{k1}, w_{k2}, \dots, w_{km}$ sinir hücresinin k . ağırlıklarını, I_k giriş verilerinin doğrusal birleşimini, θ_k eşik değeri, $\psi(\cdot)$ etkinleştirme fonksiyonunu ve O_k yapay sinir hücresinin çıkışını temsil etmektedir (Zurada, 1992; Haykin, 1999).

Literatürde birçok yapay sinir ağı modeli geliştirilmiştir. Genel olarak yapay sinir ağları ileri beslemeli ve geri beslemeli olarak yapılandırılmaktadır. İleri beslemeli ağlarda, bilgi ağ girişinden ağ çıkışına kadar tek yönlü olarak işlenerek iletilir. Yüksek tepki hızları nedeniyle özellikle örüntü tanıma uygulamalarında yaygın olarak kullanılmaktadırlar. Geri beslemeli ağlar ise hücre çıkışının kendisine ya da başka hücrelere giriş olarak verildiği bir döngü içermektedir. Bu döngü sebebiyle giriş verisinin karşılığı yavaş bir şekilde oluşmakta ve tepki hızı düşmektedir. Bu nedenle optimizasyon problemlerinin çözümünde tercih edilmektedir. Bu çalışmada en yaygın kullanılan çok katmanlı ileri beslemeli ağlar kullanılmıştır.

3.5.4.1. Çok katmanlı yapay sinir ağı yapısı

Bir giriş katmanı, en az bir gizli katman ve bir çıkış katmanından oluşan, giriş ve çıkış arasında doğrusal olmayan haritalama tekniğini kullanan sinir ağlarıdır. Her bir katmanda en az bir sinir hücresi bulunmaktadır. Giriş katmanına verilen bilgi herhangi bir işleme uğramaksızın, gizli katmana aktarılmaktadır. Gizli katman ve çıkış katında yapılan işlemler ile ağın çıkışı belirlenmektedir (Haykin, 1999; Meyer-Base, 2004). Tek gizli katmanlı çok katmanlı sinir ağı yapısı Şekil 3.16.'da gösterilmektedir.

Çok katmanlı yapay sinir ağları (ÇKYSA), eğiticili öğrenme yöntemini kullandığı için, girişler ve bu girişlere karşılık gelen hedef çıkışlar ağa verilmektedir. Yöntem bu bilgiler doğrultusunda genellemeler yaparak bir çözüm uzayı oluşturmaktadır. ÇKYSA modelinde, geriye yayılım öğrenme yöntemi (genelleştirilmiş delta kuralı) kullanılmaktadır. Geriye yayılım öğrenme yöntemi hatayı minimize etmeye çalışan bir yöntem olarak ifade edilebilir.



Şekil 3.16. ÇKYSA ağ mimarisi (Oral, 2011)

Hata azaltma işlemi, ağırlıklar değiştirilerek gerçekleştirildiğinden dolayı, bir başka deyişle çıkış hatasını geriye yaydığı için “Geriye Yayılım” olarak adlandırılmaktadır (Freeman ve Skapura, 1991; Fausett, 1994; Haykin, 1999).

Geriye yayılım yöntemi aşağıdaki adımlardan oluşmaktadır (Fausett, 1994; Oral, 2011).

1. İleri doğru hesaplama: Giriş eğitim verisinin ileriye doğru yayılması ve ağın çıkışının hesaplanması,
2. Verilen hedef değerler için hatanın hesaplanması,
3. Geriye doğru hesaplama: Hatanın geriye doğru yayılarak ağırlıkların güncellenmesi

ÇKYSA modelinde ilk olarak eğitim veri kümesi ve bu veri kümesine karşılık hedef çıkışlar belirlenmelidir. Hedef çıkışlar, eğitim veri kümesindeki her bir girişin sınıf bilgisine karşılık gelmektedir (Freeman ve Skapura, 1991; Mitchell, 1997; Haykin, 1999). Maksimum yineleme sayısı, katmanlardaki düğüm sayısı, öğrenme oranı ve en küçük hata ölçüt değeri de tanımlanmalıdır.

Geriye yayılım öğrenme işlem adımları;

1. Adım (İleriye doğru yayılma): Bu adımda giriş katmanından çıkış katmanına doğru sinir hücrelerinin giriş ve çıkışları, geriye yayılma algoritmasına göre hesaplanmaktadır. Öncelikle eğitim veri kümesinin herhangi bir giriş verisi (x_1, x_2, \dots, x_m) ve bu girişe karşılık ağın üretmesi beklenen hedef çıkış verisi (d_1, d_2, \dots, d_p) ağa sunulmaktadır. Giriş katmanına uygulanan girişler, hiçbir işlem uygulanmadan gizli katmana iletilmektedir. Gizli katmandaki her sinir hücresi, giriş katmanından gelen bilgileri, ağırlıklarına göre kabul etmektedir. Gizli katmanda bulunan herhangi bir j . sinir hücresinin ağırlıklı girişlerinin toplamı eşitlik (3.66) te gösterildiği gibi ifade edilmektedir (Freeman ve Skapura, 1991; Fausett, 1994; Haykin, 1999).

$$I_j(u) = \sum_{i=1}^t w_{ji} O_i(u) + \theta_j \quad (3.66)$$

(3.66) eşitliğinde t , bir önceki katmanda bulunan düğüm sayısı, w_{ji} j . yapay sinir hücresinin bir önceki katmanda bulunan i . yapay sinir hücresi arasındaki bağlantı ağırlığının değeri, O_i bir önceki katmanda bulunan yapay sinir hücresi çıkışı ve θ_j eşik elemanın ağırlık değerini göstermektedir. O_j yapay sinir hücresi çıkışı, ağırlıklı girişlerin toplamı I_j 'nin etkinleştirme fonksiyonuna ($\psi(\cdot)$) uygulanarak hesaplanmaktadır.

$$O_j(u) = \psi(I_j(u)) \quad (3.67)$$

Eşitlik (3.66) ve (3.67) kullanılarak gizli katmanda ve çıkış katmanında bulunan bütün yapay sinirlerin ağırlıklı giriş değerleri I_j ve yapay sinir hücresi çıkış değerleri O_j bulunmaktadır.

2. Adım (Hatanın hesaplanması ve geriye yayılması): Ağın ürettiği çıkış ve hedef çıkış arasındaki fark bütün yapay sinirlerin ağırlıklarına yansıtılmaktadır. Bunun için, ağın ürettiği çıkış ($O_j(u)$) ile bu veriye karşılık istenilen hedef çıkış değeri ($d_j(u)$), karşılaştırılmaktadır. Aradaki fark, $e_j(u)$, u . giriş için j . çıkış yapay sinirindeki hata değerini ifade etmektedir. Toplam hata, eğitim veri kümesinde bulunan bütün girişler

için, e_j hatalarının kareleri toplanarak elde edilir. Eğitimle amaçlanan, ağ parametreleri değiştirilerek, toplam karesel hata değerini (E) en aza indirmektir (Freeman ve Skapura, 1991; Zurada, 1992; Fausett, 1994; Mitchell, 1997; Haykin, 1999).

$$e_j(u) = d_j(u) - O_j(u) \quad (3.68)$$

$$E = \frac{1}{2} \sum_{j=1}^p e_j(u)^2 \quad (3.69)$$

Çıkış katmanındaki bütün yapay sinirler için hata değeri ($e_j(u)$) hesaplandıktan sonra ağırlıkların değiştirilmesi için gerekli eğim değerleri çıkış katmanından gizli katmana doğru hesaplanmaktadır (Freeman ve Skapura, 1991; Zurada, 1992; Fausett, 1994; Mitchell, 1997; Haykin, 1999).

Çıkış katmanındaki bir sinir hücresi için eğim, δ_j , sinir hücresinin e_j hata değeri ve etkinleştirme fonksiyonunun ($\psi(\cdot)$) türevi aşağıdaki biçimde hesaplanmaktadır.

$$\delta_j = -\frac{\partial E}{\partial I_j} \quad (3.70)$$

$$\frac{\partial E}{\partial I_j} = -\frac{\partial E}{\partial O_j} \frac{\partial O_j}{\partial I_j} \quad (3.71)$$

$$\frac{\partial E}{\partial O_j} = \frac{\partial E}{\partial e_j} \frac{\partial e_j}{\partial O_j} = -e_j \quad (3.72)$$

(3.67) eşitliğine göre;

$$\frac{\partial O_j}{\partial I_j} = \psi'(I_j) \quad (3.73)$$

olarak yazılmaktadır.

Böylelikle çıkış katmanındaki j . sinir hücresinin eğimi aşağıdaki biçimde hesaplanmaktadır (Freeman ve Skapura, 1991; Zurada, 1992; Fausett, 1994; Mitchell, 1997; Haykin, 1999).

$$\delta_j = e_j \psi'(I_j) \quad (3.74)$$

Çıkış katmanındaki sinir hücreleri için eğimler hesaplandıktan sonra, aynı işlem gizli katman sinir hücreleri için gerçekleştirilir. Gizli katmanda bulunan herhangi bir sinir hücresi çıkış katmanındaki bütün sinirlerle bağlantılıdır. Dolayısıyla herhangi bir gizli katman sinir hücresinin eğimi çıkıştaki tüm sinir hücrelerinden etkilenmektedir.

$$\frac{\partial E}{\partial I_j} = - \sum_{i=1}^p \frac{\partial E}{\partial I_i} \frac{\partial I_i}{\partial I_j} \quad (3.75)$$

(3.75) eşitliğinde p çıkış katmanında bulunan sinir hücresi sayısını, I_j , gizli katman sinir hücresinin girişini ve I_i ise çıkış katmanında bulunan sinir hücresinin girişini göstermektedir.

$$\frac{\partial I_i}{\partial I_j} = \frac{\partial I_i}{\partial O_j} \frac{\partial O_j}{\partial I_j} \quad (3.76)$$

(3.75) ve (3.76) eşitlikleri kullanılarak hesaplanan gizli katmanda bulunan sinirler için eğim ifadesi aşağıda verilmektedir.

$$\delta_j = \psi'(I_j) \sum_{i=1}^p (\delta_i w_{ij}) \quad (3.77)$$

Burada δ_i çıkış katmanındaki i . düğümün eğimi ve w_{ij} çıkış katmanındaki i . sinir hücresi ile gizli katmandaki j . sinir hücresi arasındaki bağlantı ağırlığını temsil etmektedir.

3. Adım (Ağırlıkların Güncellenmesi): Bu adımda ise hesaplanan eğim değerlerine bağlı olarak ağda bulunan bütün ağırlıklar güncellenmektedir. Yeni ağırlık değerini bulabilmek için; karesel hata E 'nin ağırlığa (w) göre birinci türevi alınarak ağırlıktaki

değişim miktarı hesaplanmaktadır (Freeman ve Skapura, 1991; Mitchell, 1997; Haykin, 1999;).

$$w_{ji}^{s+1} = w_{ji}^s + \beta \Delta w_{ij} \quad (3.78)$$

$$\Delta w_{ji} = - \frac{\partial E}{\partial w_{ji}} \quad (3.79)$$

$$\frac{\partial E}{\partial w_{ji}} = - \frac{\partial E}{\partial I_j} \frac{\partial I_j}{\partial w_{ji}} \quad (3.80)$$

Yukarıda verilen eşitliklerde, w_{ji}^{s+1} , ağırlığın alacağı yeni değeri, w_{ji}^s ağırlığın önceki değerini, β öğrenme oranını ve Δw_{ji} ağırlık değerlerinde olması gereken değişim miktarını temsil etmektedir. Ağırlık değişim miktarı;

$$\Delta w_{ji} = \delta_j O_j \quad (3.81)$$

olarak ifade edilmektedir. (3.88) eşitliğinde O_i bir önceki katmanda bulunan i . sinir hücresinin çıkış değerini ve δ_j çalışılan katmandaki j . sinir eğimini ifade etmektedir. (Freeman ve Skapura, 1991; Mitchell, 1997; Haykin, 1999).

Sinir hücrelerine ait eşik ağırlık değerleri, sınırlar arasındaki bağlantı ağırlık değeri ile aynı şekilde hesaplanmaktadır.

$$\theta_{ji}^{s+1} = \theta_{ji}^s + \beta \Delta \theta_{ji} \quad (3.82)$$

$$\Delta \theta_{ji} = - \frac{\partial E}{\partial \theta_{ji}} \quad (3.83)$$

$$\frac{\partial E}{\partial \theta_{ji}} = - \frac{\partial E}{\partial I_j} \frac{\partial I_j}{\partial \theta_{ji}} \quad (3.84)$$


Eşik ağırlıklarındaki değişim miktarı $\Delta \theta_{ji}$ eşitlik (3.85)'te verilmektedir.

$$\Delta\theta_{ji} = \delta_j \quad (3.85)$$

Böylece (3.78)-(3.85) arasındaki eşitlikler kullanılarak bağlantı ağırlık değerleri ve eşik ağırlık değerleri değiştirilmektedir.

Yukarıda anlatılan adımlar, ağı eğitilmesi tamamlanıncaya kadar devam etmektedir. Bir başka ifadeyle hesaplanan ağ çıkışları ile hedef ağ çıkışları arasındaki hata, kabul edilebilir düzeye ininceye kadar yinelenmektedir. ÇKYSA modellerinde durdurma ölçütü olarak maksimum yineme sayısı ve kabul edilebilir hata değeri (minimum hata kriteri) kullanılmaktadır. Maksimum yineme sayısına kadar, her yineme sonunda hesaplanan karesel hata değeri minimum hata ölçütü ile karşılaştırılarak öğrenmenin gerçekleşip gerçekleşmediği kontrol edilmektedir.

Ağa uygulanan giriş için, hedeflenen çıkışa ulaşılmasını sağlayan ağırlık değerleri bulunarak ağı eğitimi tamamlanmaktadır. Eğitimi tamamlanan ağ için test veri kümesi kullanılarak başarımlar ölçülür. ÇKYSA'da yaygın olarak kullanılan etkinleştirme fonksiyonları Şekil 3.17.'de gösterilmiştir.



Şekil 3.17. Etkinleştirme fonksiyonları (Haykin, 1999)

3.6. Sınıflandırma Başarım Ölçütleri

Sınıflandırıcı performanslarının değerlendirilmesi aşamasında, her bir yöntem için karışıklık matrisleri oluşturulmuştur (Bradley, 1997; Fawcett, 2006). Bu matrislerden faydalanılarak duyarlılık, özgüllük ve doğruluk ölçütleri hesaplanmıştır. Aynı zamanda sınıflandırıcıların nöbet öncesi dönemleri tespit etme becerilerini değerlendirmek için karakteristik işlem eğrileri (Receiver Operating Characteristic Curve: ROC Curve) ve eğri altındaki alan (EAA) değerleri (Area Under Curve: AUC) kullanılmıştır. Örnek bir karışıklık matrisi Tablo 3.13.'te verilmektedir.

Tablo 3.13. Karışıklık matrisi yapısı

		Gerçek Sonuçlar	
		Pozitif	Negatif
Tahmin	Pozitif	GP	YP
	Negatif	YN	GN

Karışıklık matrisini oluşturan elemanlar aşağıda açıklanmıştır.

Gerçek Pozitif (GP): Tanı sisteminin doğru olarak tespit ettiği gerçek hasta sayısına karşılık gelmektedir.

Yanlış Negatif (YN): Tanı sisteminin doğru tespit edemediği, sağlıklı olarak etiketlediği hasta sayısına karşılık gelmektedir.

Yanlış Pozitif (YP): Sağlıklı olmasına rağmen tanı sisteminin hasta olarak algıladığı bireylerin sayısına karşılık gelmektedir.

Gerçek Negatif (GN): Tanı sistemi tarafından doğru olarak tespit edilen sağlıklı birey sayısına karşılık gelmektedir.

Karışıklık matrisi bileşenleri kullanılarak Denklem(3.86), Denklem(3.87), ve Denklem(3.88)'de verilen başarım ölçütleri hesaplanmıştır.

Doğruluk (Accuracy): Tanı sisteminin gerçekte hasta ve sağlıklı olarak tespit ettiği doğru tanı sayısının birey sayısına oranı olarak tanımlanmaktadır (Bradley, 1997; Fawcett, 2006; Coşkun ve Baykal, 2011; Nizam ve Akın, 2014).

$$\text{doğruluk} = \frac{(GP+GN)}{(GP+YP+YN+GN)} \cdot 100 \quad (3.86)$$

Duyarlılık (Sensitivity): Tanı sisteminin gerçek hastalar içinden hastaları ayırma oranıdır (Bradley, 1997; Fawcett, 2006; Coşkun ve Baykal, 2011; Nizam ve Akın, 2014).

$$\text{duyarlılık} = \frac{GP}{GP+YN} \cdot 100 \quad (3.87)$$

Özgüllük (Specificity): Tanı sisteminin sağlıklı bireyler içinden sağlıklıları ayırma oranıdır (Bradley, 1997; Fawcett, 2006).

$$\text{özgüllük} = \frac{GN}{GN+YP} \cdot 100 \quad (3.88)$$

İşlem Karakteristik Eğrisi ve Eğri Altındaki Alan: İşlem karakteristik eğrisi bir testin tanı performansını, başka bir ifadeyle hastalıklı durumları sağlıklı durumlardan ayırabilme becerisini değerlendirmek amacıyla geliştirilmiş bir yöntemdir. Yalnızca duyarlılık ve özgüllük ölçütlerini dikkate alarak tanı koymanın neden olabileceği olumsuzlukları gidermek amacıyla geliştirilmiştir (Metz, 1978).


İşlem karakteristik eğrileri, farklı eşik değerleri için duyarlılık ölçütünün dikey eksen üzerinde ve yanlış pozitiflik oranının (1 – özgüllük) yatay eksen üzerinde temsil edildiği bir eğridir. Eğri en yüksek doğruluk değerine sahip kesim noktasını belirlemektedir (Zweig ve Campbell, 1993; Erkel ve Pattynama, 1998; Zou, O'Malley ve Mauri, 2007). Bu çalışmada kesim noktası sol üst köşeye en yakın nokta seçilmiştir.

Duyarlılık ve özgüllük arasında denge gözetilmelidir. Duyarlılığın baskın olması hastalığın teşhisinin kolaylaşmasını sağlarken, yanlış pozitif sonuçların sayısının artmasına da neden olacaktır. Uygun tedavilerin mümkün olduğu hastalıklar için, hasta olmayanlara tedavinin olumsuz sonuçlarının olmadığı durumlarda duyarlılık yüksek tutulmalıdır. Ağır yan etkileri sahip hastalıklarda özgüllük yüksek tutularak

yanlış pozitif algılamalar azaltılmalıdır. Testin performansı yükseldikçe eğri yukarıya (yüksek duyarlılık bölgesine) ve sola (düşük yanlış pozitif oranı bölgesine) doğru kayacaktır (Dirican, 2001). Tablo 3.14.'te verilen karışıklık matrisi örneği için elde edilen işlem karakteristik eğrisi Şekil 3.18.'de gösterilmektedir.

Tablo 3.14. Karışıklık matrisi örneği

Uygulama Sonuçları	Hasta	Gerçek Sonuçlar	
		Hasta	Sağlıklı
Hasta		45	10
Sağlıklı		5	40



Şekil 3.18. İşlem karakteristik eğrisi

Şekil 3.18.'de gösterilen kesim noktası için x ve y değerleri aşağıda hesaplanmıştır.

$$x = \frac{YP}{GN+YP} = \frac{10}{40+10} = 0,2$$

$$y = \frac{GP}{GP+YN} = \frac{45}{45+5} = 0,9$$

İşlem karakteristik eğrileri ayırt ediciliği göstermektedir. Farklı tanı sistemlerinin performanslarını karşılaştırmak için eğri altındaki alan değerleri kullanılmaktadır

(Tomak ve Bek, 2010). Şekil 3.18.'de verilen işlem karakteristik eğrisinin altında kalan alan değeri Denklem(3.89) ile elde edilir.

$$EAA = \frac{x \times y}{2} + ((1 - x) \times y) + \frac{(1-x) \times (1-y)}{2} \quad (3.89)$$

Bu eşitliğe göre;

$$EAA = \frac{0,2 \times 0,9}{2} + ((1 - 0,2) \times 0,9) + \frac{(1-0,2) \times (1-0,9)}{2} = 0,85$$

olarak hesaplanır.

Bu çalışmada işlem karakteristik eğrisi ve eğri altındaki alan değeri kullanılarak sınıflandırıcıların nöbet öncesi dönemleri algılama performansları değerlendirilmiştir. Sınıflandırma işlemi üç farklı sınıfa ait EEG işaretleri için gerçekleştirilmiştir. Buna karşın işlem karakteristik eğrileri ve eğri altındaki alan değerleri, EEG işaretleri nöbet öncesi döneme ait olan (sınıf-1) ve ait olmayan (sınıf-2) olmak üzere iki sınıflı bir sınıflandırma için hesaplanmıştır. Kısacası sınıflandırıcının nöbet öncesi dönem algılama becerisi değerlendirilirken, normal ve nöbetli dönemler bir sınıf olarak kabul edilmiştir.

BÖLÜM 4. ARAŞTIRMA BULGULARI

Bu tez çalışmasında, farklı epileptik evrelerden elde edilen EEG işaretleri çeşitli yöntemler kullanılarak sınıflandırılmıştır. Bu sınıflandırma sonucunda normal, nöbet öncesi ve nöbetli dönemlere ait EEG işaretlerinin tespit edilmesi amaçlanmıştır. Analizler hastaya özel olarak gerçekleştirilmiştir. Bu bölümde her bir yöntem için ulaşılan sınıflandırma sonuçları verilerek, yöntemlerin sınıflandırma başarımları karşılaştırmalı olarak değerlendirilmiştir.

Öncelikle her bir hastaya ait normal, nöbet öncesi ve nöbetli dönemleri içeren EEG işaretleri ön işleme ile beş saniyelik bölümlere ayrılmıştır. 21 farklı kanal ölçümü için, bölümlenmiş EEG işaretlerinden öznitelikler hesaplanarak ayrı ayrı özellik kümeleri oluşturulmuştur. Bu özellik kümelerinin boyutları TBA yöntemiyle indirgenmiştir. Öznitelik sayısı, bu dönüşüm tekniği kullanılarak 20'den 8'e düşürülmüştür. Bir sonraki aşamada her kanal için elde edilen indirgenmiş özellik kümeleriyle ayrı ayrı ön sınıflandırma yapılmıştır. Ön sınıflandırma işlemi her kanal için, ilgili kanala ait özellik kümelerinden elde edilen 100 farklı eğitim ve test verisi kullanılarak gerçekleştirilmiştir. DDA yöntemiyle yapılan ön sınıflandırma sonucunda ayırt ediciliği yüksek kanallar tespit edilmiştir.


Son aşamada, ön sınıflandırmada yüksek doğruluğa sahip kanallar için k-EYK, DDA, DVM ve ÇKYSA sınıflandırıcılarıyla sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırıcı çıkışları önceki bölümde açıklanan başarımlar ölçütleri kullanılarak karşılaştırmalı olarak değerlendirilmiştir. Ön sınıflandırma sonucunda (100 tekrarlı) 21 kanal için elde edilen ortalama doğruluk değerleri ve standart sapmalar Tablo 4.1.'de verilmiştir. En yüksek doğrulukla sınıflandırma yapılan kanallar işaretlenmiştir. Kanal etkisinin analizler üzerindeki olası etkileri Şekil 4.1.'de gösterilmiştir.

Tablo 4.1. Ön sınıflandırma işlemi için ortalama doğruluk ve standart sapma değerleri

Kanal	Hasta 1	Hasta 2	Hasta 3	Hasta 4	Hasta 5	Hasta 6	Hasta 7
Fp1-F7	89,54 1,62	88,84 1,52	61,53 2,45	71,08 2,59	72,07 2,12	69,09 2,37	70,27 2,33
F7-T7	79,81 2,32	89,33 1,59	68,90 2,65	70,39 3,17	78,11 1,73	71,19 2,62	64,79 2,57
T7-P7	89,14 1,68	87,77 1,81	64,87 3,23	68,72 2,44	82,40 1,66	64,48 2,46	75,51 2,08
P7-O1	95,38 1,20	88,68 1,75	65,49 2,64	76,14 1,93	79,22 1,68	65,06 2,90	72,51 2,49
Fp1-F3	94,26 1,24	85,20 1,67	67,03 2,25	71,18 2,37	68,79 1,96	65,48 3,03	67,70 2,57
F3-C3	96,24 1,02	87,17 1,77	67,82 2,85	75,99 2,17	79,77 1,67	69,49 2,33	65,87 2,27
C3-P3	96,01 1,24	89,33 1,49	67,06 2,42	84,72 1,85	83,46 1,54	67,47 2,74	77,23 2,17
P3-O1	97,00 1,11	92,65 1,37	65,59 2,48	80,54 1,94	84,10 1,59	65,68 2,95	74,45 2,06
Fp2-F4	96,95 0,80	85,52 1,88	66,93 2,55	71,09 2,41	76,03 1,99	61,23 2,78	60,67 2,56
F4-C4	92,07 1,44	84,45 1,87	63,48 2,55	71,66 2,48	84,60 1,64	70,10 2,59	64,28 2,27
C4-P4	92,59 1,24	85,02 1,84	67,18 2,35	72,41 2,27	89,97 1,24	67,69 2,78	73,39 2,03
P4-O2	89,52 1,60	90,09 1,41	63,90 2,55	77,09 2,09	83,74 1,63	70,82 2,84	71,75 2,45
Fp2-F8	89,92 1,45	84,81 1,77	68,49 2,21	74,48 3,06	74,97 2,18	62,42 2,98	62,42 2,84
F8-T8	85,34 2,05	84,81 1,84	69,56 2,55	75,08 2,20	82,46 1,65	65,50 3,19	62,60 2,67
T8-P8	91,70 1,75	83,46 2,01	65,16 2,77	66,96 2,62	84,90 1,58	63,92 2,98	65,63 2,55
P8-O2	73,69 2,16	87,97 1,61	58,91 2,46	77,03 2,02	83,44 1,87	75,68 2,92	74,11 2,42
Fz-Cz	95,16 1,03	90,57 1,76	64,89 2,58	77,79 2,16	80,94 1,79	71,21 2,55	64,01 2,58
Cz-Pz	94,67 1,15	84,21 1,75	66,33 3,17	78,91 2,29	81,58 1,60	67,25 2,93	68,62 2,40
T7-Ft9	82,81 2,01	88,54 1,42	66,14 2,40	72,31 2,11	80,48 1,96	73,87 2,17	63,99 2,02
Ft9-Ft10	85,03 1,59	90,91 1,37	64,33 2,50	72,31 2,62	74,12 1,80	73,61 3,14	65,59 2,62
Ft10-T8	81,68 2,07	88,91 1,77	67,01 2,57	69,06 2,51	83,31 1,49	84,01 1,84	62,25 2,62

Tablo 4.1. (Devami)

Kanal	Hasta 8	Hasta 9	Hasta 10	Hasta 11	Hasta 12	Hasta 13	Hasta 14
Fp1-F7	66,59 2,42	77,00 1,89	67,06 1,25	70,81 2,62	87,03 1,52	73,38 2,52	63,67 2,08
F7-T7	77,31 1,74	75,33 1,74	72,73 1,17	72,25 1,96	86,51 1,81	77,18 2,13	69,68 1,82
T7-P7	80,91 1,67	72,54 2,07	82,67 0,80	66,81 2,61	89,64 1,61	82,54 1,77	69,69 2,00
P7-O1	79,34 1,54	68,43 2,48	80,34 1,04	69,94 2,31	89,10 1,55	83,55 1,99	70,50 1,96
Fp1-F3	66,01 2,07	72,17 2,18	61,80 1,42	74,29 2,23	92,45 1,30	75,52 2,16	69,83 2,07
F3-C3	77,18 1,90	78,04 1,95	68,06 1,11	71,00 2,30	88,78 1,70	83,60 1,90	69,80 2,30
C3-P3	87,41 1,90	65,15 2,43	66,35 1,39	64,74 2,55	92,31 1,32	82,44 1,70	68,14 2,07
P3-O1	75,72 1,71	68,25 2,30	79,93 1,02	70,34 2,25	89,81 1,44	80,43 2,16	69,18 2,10
Fp2-F4	71,35 1,89	80,35 2,02	66,96 1,08	73,26 2,46	85,98 1,50	75,07 2,42	67,57 1,98
F4-C4	83,30 1,81	65,95 1,99	69,80 1,01	72,39 2,57	92,44 1,40	78,48 2,01	70,75 2,32
C4-P4	88,62 1,31	71,97 2,37	66,94 1,16	68,67 2,75	93,54 1,19	81,30 2,08	74,42 1,69
P4-O2	85,97 1,72	70,91 2,09	65,93 1,06	75,17 2,20	93,26 1,49	79,51 2,01	73,64 2,03
Fp2-F8	72,17 2,22	78,72 2,06	67,98 1,23	68,10 2,38	85,91 1,73	75,12 2,16	67,53 1,93
F8-T8	85,83 1,52	67,41 2,28	69,18 0,94	73,05 2,07	87,40 1,89	75,11 2,17	68,47 1,85
T8-P8	90,08 1,20	68,38 1,84	70,23 1,08	72,23 2,11	88,92 1,54	76,47 1,97	70,87 2,17
P8-O2	84,98 1,27	71,75 2,05	69,32 1,23	73,76 2,42	94,50 1,14	78,53 2,13	72,80 1,97
Fz-Cz	86,46 1,53	76,97 1,91	68,26 1,25	73,37 2,12	90,93 1,50	66,55 2,27	78,34 2,12
Cz-Pz	84,00 1,74	67,09 1,89	72,20 1,04	82,36 1,99	90,85 1,44	65,61 2,52	74,32 1,86
T7-Ft9	78,29 1,72	65,67 2,24	62,72 1,54	67,73 2,48	84,38 1,67	81,71 1,88	73,32 1,92
Ft9-Ft10	64,65 2,15	68,72 2,60	60,20 1,55	72,55 2,58	84,73 1,57	73,74 2,06	72,80 1,86
Ft10-T8	80,87 1,78	69,02 2,58	53,19 1,55	73,19 2,33	85,90 1,92	77,64 2,05	70,53 2,04



Şekil 4.1. Kanalların ortalama doğruluklarının dağılımları

Şekil 4.1. incelendiğinde 2, 3 ve 12 numaralı hastaların kanal etkisinden daha az etkilenebilecekleri söylenebilir. Hasta-2 kanal doğrulukları arasındaki dalgalanmanın en az olduğu hastadır. 1, 5, 6, 8 ve 10 numaralı hastalar kanal seçiminden daha fazla etkilenebilir potansiyeline sahiptirler. Hasta-10 için kanal seçiminden en fazla etkilenebilecek hasta olduğu söylenebilir. Her bir hasta için kanallara ait ortalama doğrulukların bağıl dalgalanma değerleri Tablo 4.2.'de verilmiştir. 3, 6, 10 ve 13 numaralı hastalar, genel eğilimin dışında davranan aykırı kanallara sahiptirler. Standart sapma değerlerine bakılarak sınıflandırma sonuçlarının eğitim ve test verilerine bağımlılığı değerlendirilebilir. Bu noktada yüksek ortalama doğruluğa sahip kanalların çoğunluğunda standart sapma değerinin diğer kanallara göre küçük olduğu gözlenmiştir. 2, 4, 5, 6, 8, 10 ve 12 numaralı hastalarda en yüksek ortalama doğruluğa sahip kanallar, aynı zamanda standart sapma değerleri en küçük kanallardır.

Tablo 4.2. Ön sınıflandırma işlemi sonucunda hastalara ait kanal ortalama doğruluğu dalgalanma yüzdeleri

Hasta No	Dalgalanma Yüzdesi	Hasta No	Dalgalanma Yüzdesi
1	23,31	8	25,43
2	9,19	9	15,2
3	10,65	10	29,48
4	17,76	11	17,62
5	21,18	12	10,12
6	22,78	13	17,99
7	16,56	14	14,67

Ön sınıflandırma işlemi sonucunda en yüksek ortalama sınıflandırma doğruluğuna sahip kanallar belirlenmiştir. Hastalara göre en yüksek ortalama sınıflandırma doğruluğuna sahip kanallar Tablo 4.3.'te gösterilmiştir.

Tablo 4.3. Ön sınıflandırma işlemi sonucunda belirlenen kanallar

Hasta No	Kanal	Hasta No	Kanal
1	P3-O1	8	T8-P8
2	P3-O1	9	Fp2-F4
3	F8-T8	10	T7-P7
4	C3-P3	11	Cz-Pz
5	C4-P4	12	P8-O2
6	Ft10-T8	13	F3-C3
7	C3-P3	14	Fz-Cz


Sınıflandırma aşamasında ön sınıflandırma işlemiyle belirlenen kanallar için hesaplanan özellik kümeleri eğitim verisi (%67) ve test verisi (%33) olarak bölünmüştür. Bu işlem çapraz geçerlilik yöntemi ile gerçekleştirilmiştir. Farklı epileptik evreler için eğitim ve test verisi olarak belirlenen örnek sayıları Tablo 4.4.'te verilmektedir.

Tablo 4.4. Eğitim seti ve test seti örnek sayıları

Hasta No	Normal		Nöbet öncesi		Nöbet	
	Eğitim	Test	Eğitim	Test	Eğitim	Test
1	128	64	74	38	59	29
2	128	64	74	38	52	26
3	128	64	43	21	50	25
4	128	64	53	27	72	36
5	128	64	53	27	121	61
6	128	64	42	22	36	19
7	128	64	74	38	58	30
8	128	64	117	59	73	37
9	128	64	106	54	58	28
10	360	180	214	106	263	132
11	128	64	64	32	42	22
12	128	64	86	42	40	20
13	128	64	75	37	56	28
14	128	64	128	64	66	34

Çapraz geçerlilik yöntemiyle oluşturulan eğitim ve test verileri kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırıcı olarak DDA, k-EYK, DVM ve ÇKYSA yöntemleri kullanılmıştır. Sınıflandırıcı girişine uygulanan test setleri en ağırlıklı üç temel bileşenin oluşturduğu düzleme yansıtılmıştır. Böylece sınıflandırıcı davranışlarını grafiksel olarak analiz etme imkânı elde edilmiştir. Sınıflandırıcı çıktılarına gösteren karışıklık matrisi, sınıflandırma başarımları ölçütleri ve temel bileşenler dağılımı birlikte karşılaştırmalı olarak değerlendirilmiştir.

Hasta 1 için elde edilen temel bileşenler dağılımı Şekil 4.2.'de gösterilmektedir. Bu hastaya ait karışıklık matrisi ve sınıflandırma başarımları Tablo 4.5. ve Tablo 4.6.'da verilmektedir.



Şekil 4.2. Hasta 1'e ait test verisinin temel bileşenler dağılımı


Tablo 4.5. Hasta 1 için sınıflandırıcıların karışıklık matrisi

Gerçek değer	Normal			Nöbet öncesi			Nöbet			
	Tahmini değer	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet
Sınıflandırıcı	DDA	64	0	0	0	38	0	0	0	29
	k-EYK	64	0	0	0	38	0	0	0	29
	DVM	64	0	0	0	38	0	0	0	29
	YSA	64	0	0	0	38	0	0	0	29

Tablo 4.6. Hasta 1 için sınıflandırma başarımları


Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	100,00	100,00	100,00	100,00	100,00	100,00	100,00
k-EYK	100,00	100,00	100,00	100,00	100,00	100,00	100,00
DVM	100,00	100,00	100,00	100,00	100,00	100,00	100,00
YSA	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Şekil 4.2.'de farklı evrelere ait örneklerin birbirinden açık bir şekilde ayrıştığı görülmektedir. Sınıflandırma sonuçları temel bileşenler dağılımını desteklemektedir. Bütün sınıflandırıcılar normal, nöbet öncesi ve nöbet dönemlerine ait örnekleri hatasız olarak tespit etmişlerdir. Nöbet öncesi dönemlerin tespitine ait işlem karakteristik eğrileri ve eğri altında kalan alan değerleri Şekil 4.3.'te gösterilmektedir.



Şekil 4.3. Hasta 1'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Hasta 2 için elde edilen temel bileşenler dağılımı Şekil 4.4.'te gösterilmektedir. Temel bileşenler dağılımında nöbet dönemlerinin, normal ve nöbet öncesi dönemlerden ayrıştığı gözlenmektedir. Normal ve nöbet öncesi dönemlere ait bazı örnekler birbirine karışmıştır. Nöbetli dönemlerden elde edilen EEG örneklerinin diğer dönemlere göre daha iyi bir kümelenme düzeyine sahip olduğu görülmektedir. Bu hastaya ait karışıklık matrisi ve sınıflandırma başarımları Tablo 4.7. ve Tablo 4.8.'de verilmektedir.



Şekil 4.4. Hasta 2'ye ait test verisinin temel bileşenler dağılımı

Tablo 4.7. Hasta 2 için sınıflandırıcıların karışıklık matrisi


Gerçek değer	Normal			Nöbet öncesi			Nöbet			
	Tahmini değer	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet
Sınıflandırıcı	DDA	63	1	0	0	37	1	0	0	26
	k-EYK	63	1	0	3	34	1	0	0	26
	DVM	64	0	0	1	36	1	0	1	25
	YSA	64	0	0	5	31	2	1	0	25

Tablo 4.8. Hasta 2 için sınıflandırma başarımları

Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	98,44	100,00	97,37	98,89	100,00	99,02	98,44
k-EYK	98,44	95,31	89,47	98,89	100,00	99,02	96,09
DVM	100,00	98,44	94,74	98,89	96,15	99,02	97,66
YSA	100,00	90,63	81,58	100,00	96,15	98,04	93,75


Hasta 2 için en yüksek doğrulukla sınıflandırma DDA yöntemiyle elde edilmiştir. Sınıflandırıcılar özellikle normal ve nöbet öncesi dönemleri ayırırken hatalar yapmışlardır. YSA sınıflandırıcısı 5 nöbet öncesi döneme ait örneği normal olarak algılamıştır. k-EYK sınıflandırıcısı, 3 nöbet öncesi döneme ait EEG örneğini normal dönem olarak algılamıştır. Nöbet öncesi dönemlerin tespitine ait işlem karakteristik

eğrileri ve eğri altında kalan alan değerleri Şekil 4.5.'te gösterilmektedir. DDA sınıflandırıcısı, nöbet öncesi dönemlerin algılanmasında da en başarılı yöntem olmuştur. Eğri altındaki alan değeri 0,9813 olarak hesaplanmıştır.



Şekil 4.5. Hasta 2'ye ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Hasta 3 için elde edilen temel bileşenler dağılımı Şekil 4.6.'da gösterilmektedir. Bu hastaya ait karışıklık matrisi ve sınıflandırma başarımları Tablo 4.9. ve Tablo 4.10.'da verilmektedir.



Şekil 4.6. Hasta 3'e ait test verisinin temel bileşenler dağılımı


Tablo 4.9. Hasta 3 için sınıflandırıcıların karışıklık matrisi

Gerçek değer	Tahmini değer	Normal			Nöbet öncesi			Nöbet		
		Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet
Sınıflandırıcı	DDA	52	11	1	6	15	0	1	2	22
	k-EYK	62	1	1	9	11	1	5	1	19
	DVM	60	2	2	5	13	3	1	1	23
	YSA	59	2	3	7	8	6	1	0	24

Tablo 4.10. Hasta 3 için sınıflandırma başarımları


Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Toplam Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	81,25	84,78	71,43	85,39	88,00	98,82	80,91
k-EYK	96,88	69,57	52,38	97,75	76,00	97,65	83,64
DVM	93,75	86,96	61,90	96,63	92,00	94,12	87,27
YSA	92,19	82,61	38,10	97,75	96,00	89,41	82,73

Hasta 3'e ait temel bileşenler dağılımında epileptik evrelerin birbirine karıştığı görülmektedir. Özellikle normal ve nöbet öncesi evreler birbirine girişim yapmış durumdadır. Sınıflandırma sonuçları temel bileşenler dağılımını doğrulamaktadır. DDA 11 normal dönemi nöbet öncesi olarak algılarken, 6 nöbet öncesi dönemi normal olarak etiketlemiştir. En yüksek doğrulukla algılama DVM sınıflandırıcısıyla gerçekleştirilmiştir. Nöbet öncesi dönemlerin tespitine ait işlem karakteristik eğrileri ve eğri altında kalan alan değerleri Şekil 4.7.'de gösterilmektedir.



Şekil 4.7. Hasta 3'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Hasta 4 için elde edilen temel bileşenler dağılımı Şekil 4.8.'de gösterilmektedir. Bu hastaya ait karışıklık matrisi ve sınıflandırma başarımları Tablo 4.11. ve Tablo 4.12.'de verilmektedir. Hasta 4'ün temel bileşenler dağılımında normal, nöbet öncesi ve nöbet dönemlerinin karıştığı görülmektedir.



Şekil 4.8. Hasta 4'e ait test verisinin temel bileşenler dağılımı


Tablo 4.11. Hasta 4 için sınıflandırıcıların karışıklık matrisi

Gerçek değer	Normal			Nöbet öncesi			Nöbet			
	Tahmini değer	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet
Sınıflandırıcı	DDA	62	2	0	5	21	1	0	1	35
	k-EYK	64	0	0	7	19	1	3	0	33
	DVM	64	0	0	5	18	4	1	1	34
	YSA	62	0	2	8	18	1	0	0	36

Tablo 4.12. Hasta 4 için sınıflandırma başarımları


Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	96,88	92,06	77,78	97,00	97,22	98,90	92,91
k-EYK	100,00	84,13	70,37	100,00	91,67	98,90	91,34
DVM	100,00	90,48	66,67	99,00	94,44	95,60	91,34
YSA	96,88	87,30	66,67	100,00	100,00	96,70	91,34

Sınıflandırıcı doğrulukları birbirine yakın olmakla birlikte, en yüksek doğruluk DDA sınıflandırıcısıyla (%92,91) elde edilmiştir. Nöbet öncesi dönemler için en yüksek duyarlılıkta DDA sınıflandırıcısına aittir. Nöbet öncesi dönemlerin tespitine ait işlem karakteristik eğrileri ve eğri altında kalan alan değerleri Şekil 4.9.'da gösterilmektedir. En yüksek eğri altındaki alan değeri (0,8739) DDA sınıflandırıcısına aittir.



Şekil 4.9. Hasta 4'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Hasta 5'e ait temel bileşenler dağılımı Şekil 4.10.'da gösterilmektedir. Karışıklık matrisi ve sınıflandırma başarımları Tablo 4.13. ve Tablo 4.14.'te verilmektedir.



Şekil 4.10. Hasta 5'e ait test verisinin temel bileşenler dağılımı


Tablo 4.13. Hasta 5 için sınıflandırıcıların karışıklık matrisi

Gerçek değer	Tahmini değer	Normal		Nöbet öncesi			Nöbet			
		Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet
Sınıflandırıcı	DDA	61	2	1	0	27	0	1	1	59
	k-EYK	64	0	0	9	18	0	0	0	61
	DVM	62	1	1	0	27	0	0	1	60
	YSA	64	0	0	4	19	4	1	0	60

Tablo 4.14. Hasta 5 için sınıflandırma başarımları


Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	95,31	98,86	100,00	97,60	96,72	98,90	96,71
k-EYK	100,00	89,77	66,67	100,00	100,00	100,00	94,08
DVM	96,88	100,00	100,00	98,40	98,36	98,90	98,03
YSA	100,00	94,32	70,37	100,00	98,36	95,60	94,08

Temel bileşenler dağılımından epileptik evrelerin büyük oranda ayrıştığı görülmektedir. DVM sınıflandırıcısıyla %98,03 'lük sınıflandırma doğruluğuna ulaşılmıştır. DVM ve DDA sınıflandırıcısıyla %100 duyarlılıkta nöbet öncesi dönem algılaması gerçekleştirilmiştir. Özellikle k-EYK sınıflandırıcısı normal ve nöbet öncesi dönemleri ayırmakta zorlanmıştır. Bu sınıflandırıcı 9 nöbet öncesi dönemi normal dönem olarak algılamıştır. Nöbet öncesi dönemlerin tespitine ait işlem karakteristik eğrileri ve eğri altında kalan alan değerleri Şekil 4.11.'de gösterilmektedir.



Şekil 4.11. Hasta 5'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Hasta 6'ya ait temel bileşenler dağılımı Şekil 4.12.'de gösterilmektedir. Bu hastaya ait karışıklık matrisi ve sınıflandırma başarımları Tablo 4.15. ve Tablo 4.16.'da verilmektedir. Şekil 4.12. incelendiğinde nöbet dönemlerine ait örneklerin normal ve nöbet öncesi dönemlerden ayrıştığı görülmektedir. Nöbet öncesi ve normal dönemlerden elde edilen örneklerde karışmalar meydana gelmiştir.



Şekil 4.12. Hasta 6'ya ait test verisinin temel bileşenler dağılımı


Tablo 4.15. Hasta 6 için sınıflandırıcıların karışıklık matrisi

Gerçek değer	Tahmini değer	Normal			Nöbet öncesi			Nöbet		
		Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet	
Sınıflandırıcı	DDA	60	4	0	3	19	0	0	0	19
	k-EYK	63	1	0	3	19	0	0	0	19
	DVM	64	0	0	2	19	1	1	0	18
	YSA	63	1	0	1	18	3	0	0	19

Tablo 4.16. Hasta 6 için sınıflandırma başarımları


Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	93,75	92,68	86,36	95,18	100,00	100,00	93,33
k-EYK	98,44	92,68	86,36	98,80	100,00	100,00	96,19
DVM	100,00	92,68	86,36	100,00	94,74	98,84	96,19
YSA	98,44	97,56	81,82	98,80	100,00	96,51	95,24

DVM ve k-EYK sınıflandırıcıları daha yüksek sınıflandırma doğruluğuna ulaşmışlardır. DDA sınıflandırıcısı normal ve nöbet öncesi dönemleri ayırmakta zorlanmıştır. Hasta 6 için nöbet öncesi dönemlerin tespitine ait işlem karakteristik eğrileri ve eğri altında kalan alan değerleri Şekil 4.13.'te gösterilmektedir.



Şekil 4.13. Hasta 6'ya ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Hasta 7'ye ait temel bileşenler dağılımı Şekil 4.14.'te gösterilmektedir. Bu hastaya ait karışıklık matrisi ve sınıflandırma başarımları Tablo 4.17. ve Tablo 4.18.'de verilmektedir.



Şekil 4.14. Hasta 7'ye ait test verisinin temel bileşenler dağılımı

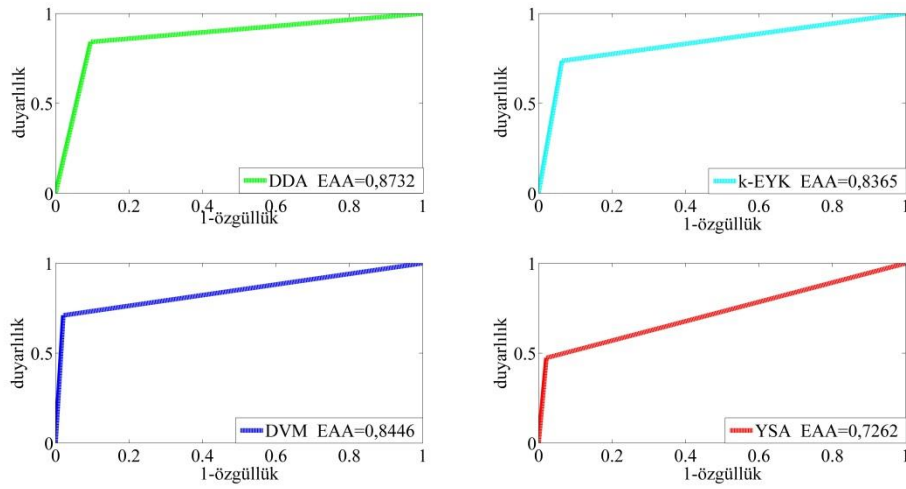
Tablo 4.17. Hasta 7 için sınıflandırıcıların karışıklık matrisi

Gerçek değer	Normal			Nöbet öncesi			Nöbet			
	Tahmini değer	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet
Sınıflandırıcı	DDA	57	6	1	6	32	0	1	3	26
	k-EYK	58	6	0	10	28	0	2	0	28
	DVM	63	1	0	10	27	1	0	1	29
	YSA	58	2	4	16	18	4	0	0	30

Tablo 4.18. Hasta 7 için sınıflandırma başarımları


Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	89,06	89,71	84,21	90,43	86,67	99,02	87,12
k-EYK	90,63	82,35	73,68	93,62	93,33	100,00	86,36
DVM	98,44	85,29	71,05	97,87	96,67	99,02	90,15
YSA	90,63	76,47	47,37	97,87	100,00	92,16	80,30

Şekil 4.14. incelendiğinde nöbet dönemlerinin diğer evrelerden ayırırken, normal ve nöbet öncesi evrelerin karıştığı görülmektedir. Bu hasta için sınıflandırıcılar normal ve nöbet öncesi dönemleri ayırmakta oldukça zorlanmıştır. En yükdek sınıflandırma doğruluğu DVM sınıflandırıcısına aittir. YSA bu hasta için en başarısız sınıflandırıcıdır. Nöbet öncesi dönemler için en yüksek duyarlılık DDA sınıflandırıcısına aittir. Hasta 7 için nöbet öncesi dönemlerin tespitine ait işlem karakteristik eğrileri ve eğri altında kalan alan değerleri Şekil 4.15.'te gösterilmektedir.



Şekil 4.15. Hasta 7'ye ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Hasta 8'e ait temel bileşenler dağılımı Şekil 4.16.'da gösterilmektedir. Hasta 8 bütün epileptik evrelere ait örneklerin birbirine karıştığı bir temel bileşenler dağılımına sahiptir. Önceki hastalarda özellikle nöbetli dönemlerin diğer dönemlerden büyük oranda ayrıştığı gözlemlenmiştir. Bu hastaya ait karışıklık matrisi ve sınıflandırma başarımları Tablo 4.19. ve Tablo 4.20.'de verilmektedir.



Şekil 4.16. Hasta 8'e ait test verisinin temel bileşenler dağılımı

Tablo 4.19. Hasta 8 için sınıflandırıcıların karışıklık matrisi


Gerçek değer	Normal			Nöbet öncesi			Nöbet			
	Tahmini değer	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet
Sınıflandırıcı	DDA	64	0	0	2	55	2	1	1	35
	k-EYK	64	0	0	3	55	1	3	2	32
	DVM	64	0	0	1	58	0	1	1	35
	YSA	64	0	0	3	47	9	1	2	34

Tablo 4.20. Hasta 8 için sınıflandırma başarımları

Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	100,00	96,88	93,22	99,01	94,59	98,37	96,25
k-EYK	100,00	93,75	93,22	98,02	86,49	99,19	94,38
DVM	100,00	97,92	98,31	99,01	94,59	100,00	98,13
YSA	100,00	95,83	79,66	98,02	91,89	92,68	90,63


DVM sınıflandırıcısıyla en yüksek doğruluklu sınıflandırma gerçekleştirilmiştir. Sınıflandırıcı çıktıları incelendiğinde sonuçların temel bileşenler dağılımını desteklediği görülmektedir. Hasta 8 için nöbet öncesi dönemlerin tespitine ait işlem karakteristik eğrileri ve eğri altında kalan alan değerleri Şekil 4.17.'de

gösterilmektedir. Nöbet öncesi dönemlerin algılanmasında da en yüksek başarımlı DVM sınıflandırıcısına aittir.



Şekil 4.17. Hasta 8'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Hasta 9'a ait temel bileşenler dağılımı Şekil 4.18.'de gösterilmektedir. Karışıklık matrisi ve sınıflandırma başarımları Tablo 4.21. ve Tablo 4.22.'de verilmektedir.



Şekil 4.18. Hasta 9'a ait test verisinin temel bileşenler dağılımı


Tablo 4.21. Hasta 9 için sınıflandırıcıların karışıklık matrisi

Gerçek değer	Tahmini değer	Normal			Nöbet öncesi			Nöbet		
		Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet
Sınıflandırıcı	DDA	56	6	2	3	48	3	2	1	25
	k-EYK	63	1	0	6	45	3	2	2	24
	DVM	63	0	1	6	46	2	1	3	24
	YSA	59	2	3	8	35	11	2	0	26

Tablo 4.22. Hasta 9 için sınıflandırma başarımları


Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	87,50	93,90	88,89	92,39	89,29	95,76	88,36
k-EYK	98,44	90,24	83,33	96,74	85,71	97,46	90,41
DVM	98,44	91,46	85,19	96,74	85,71	97,46	91,10
YSA	92,19	87,80	64,81	97,83	92,86	88,14	82,19

Hasta 9 için elde edilen temel bileşenler dağılımında normal, nöbet öncesi ve normal dönemlerin karıştığı görülmektedir. Sınıflandırma sonuçları da bunu desteklemektedir. Nöbet öncesi dönemler için en yüksek duyarlılık (%88,89) DDA sınıflandırıcısına aittir. En yüksek doğrulukla sınıflandırma (%91,10) DVM sınıflandırıcısıyla gerçekleştirilmiştir. Hasta 9 için nöbet öncesi dönemlerin tespitine ait işlem karakteristik eğrileri ve eğri altında kalan alan değerleri Şekil 4.19.'da gösterilmektedir.



Şekil 4.19. Hasta 9'a ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Nöbet öncesi dönemlerin algılanmasında da en yüksek eğri altındaki alan değeri (0,9096) DVM sınıflandırıcısına aittir. Hasta 10'a ait temel bileşenler dağılımı Şekil 4.20.'de gösterilmektedir. Karışıklık matrisi ve sınıflandırma başarımları Tablo 4.23. ve Tablo 4.24.'te verilmektedir.



Şekil 4.20. Hasta 10'a ait test verisinin temel bileşenler dağılımı


Tablo 4.23. Hasta 10 için sınıflandırıcıların karışıklık matrisi

Gerçek değer	Normal			Nöbet öncesi			Nöbet			
	Tahmini değer	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet
Sınıflandırıcı	DDA	172	7	1	22	77	7	7	6	119
	k-EYK	179	1	0	21	83	2	4	11	117
	DVM	178	1	1	23	81	2	3	9	120
	YSA	166	1	13	24	67	15	9	2	121

Tablo 4.24. Hasta 10 için sınıflandırma başarımları


Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	95,56	87,82	72,64	95,83	90,15	97,20	88,04
k-EYK	99,44	89,50	78,30	96,15	88,64	99,30	90,67
DVM	98,89	89,08	76,42	96,79	90,91	98,95	90,67
YSA	92,22	86,13	63,21	99,04	91,67	90,21	84,69

Temel bileşenler dağılımında farklı epileptik evrelerin karıştığı gözlenen Hasta 10 için, en yüksek doğrulukla (%90,67) sınıflandırma DVM ve k-EYK yöntemleriyle gerçekleştirilmiştir. Nöbet öncesi dönem algılamada en yüksek duyarlılık (%78,30) k-EYK sınıflandırıcısına aittir. Hasta 10 için nöbet öncesi dönemlerin tespitine ait işlem karakteristik eğrileri ve eğri altında kalan alan değerleri Şekil 4.21.'de gösterilmektedir. Nöbet öncesi dönemlerin algılanmasında da en yüksek eğri altındaki alan değeri (0,8723) k-EYK sınıflandırıcısına aittir.



Şekil 4.21. Hasta 10'a ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Hasta 11'e ait temel bileşenler dağılımı Şekil 4.22.'de gösterilmektedir. Karışıklık matrisi ve sınıflandırma başarımları Tablo 4.25. ve Tablo 4.26.'da verilmektedir. Temel bileşenler dağılımında özellikle normal ve nöbet öncesi dönemlere ait EEG örneklerinin karıştığı gözlemlenmiştir.



Şekil 4.22. Hasta 11'e ait test verisinin temel bileşenler dağılımı

Tablo 4.25. Hasta 11 için sınıflandırıcıların karışıklık matrisi

Gerçek değer	Normal			Nöbet öncesi			Nöbet			
	Tahmini değer	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet
Sınıflandırıcı	DDA	61	1	2	5	27	0	0	3	19
	k-EYK	63	1	0	8	24	0	3	2	17
	DVM	63	1	0	8	24	0	0	3	19
	YSA	56	4	4	7	17	8	0	3	19


Tablo 4.26. Hasta 11 için sınıflandırma başarımları

Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Toplam Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	95,31	90,74	84,38	95,35	86,36	97,92	90,68
k-EYK	98,44	79,63	75,00	96,51	77,27	100,00	88,14
DVM	98,44	85,19	75,00	95,35	86,36	100,00	89,83
YSA	87,50	87,04	53,13	91,86	86,36	87,50	77,97

En yüksek doğrulukla (%90,68) sınıflandırma işlemi DDA yöntemiyle gerçekleştirilmiştir. Bu yöntem aynı zamanda nöbet öncesi dönemler için en yüksek duyarlılığa (%84,38) sahiptir. Sınıflandırıcılar nöbet öncesi dönemleri normal


dönemlerden ayırmakta zorlanmışlardır. YSA sınıflandırıcısı nöbet öncesi dönemlere ait 8 örneği nöbet olarak sınıflandırırken, 7 nöbet öncesi örneği normal olarak sınıflandırmıştır.

Hasta 11 için nöbet öncesi dönemlerin tespitine ait işlem karakteristik eğrileri ve eğri altında kalan alan değerleri Şekil 4.23.'te gösterilmektedir. Nöbet öncesi dönemlerin algılanmasında da en yüksek eğri altındaki alan değeri (0,8986) DDA sınıflandırıcısına aittir.



Şekil 4.23. Hasta 11'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Hasta 12'ye ait temel bileşenler dağılımı Şekil 4.24.'te gösterilmektedir. Karışıklık matrisi ve sınıflandırma başarımları Tablo 4.27. ve Tablo 4.28.'de verilmektedir. Epileptik evreler birbirlerinden büyük oranda ayrılmaktadır. DDA sınıflandırıcısıyla normal, nöbet öncesi ve nöbet dönemlerine ait EEG örnekleri hatasız şekilde sınıflandırılmıştır.



Şekil 4.24. Hasta 12'ye ait test verisinin temel bileşenler dağılımı


Tablo 4.27. Hasta 12 için sınıflandırıcıların karışıklık matrisi

Gerçek değer	Tahmini değer	Normal			Nöbet öncesi			Nöbet		
		Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet
Sınıflandırıcı	DDA	64	0	0	0	42	0	0	0	20
	k-EYK	64	0	0	0	41	1	2	0	18
	DVM	64	0	0	0	42	0	2	0	18
	YSA	64	0	0	0	42	0	1	0	19

Tablo 4.28. Hasta 12 için sınıflandırma başarımları


Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	100,00	100,00	100,00	100,00	100,00	100,00	100,00
k-EYK	100,00	96,77	97,62	100,00	90,00	99,06	97,62
DVM	100,00	96,77	100,00	100,00	90,00	100,00	98,41
YSA	100,00	98,39	100,00	100,00	95,00	100,00	99,21

Hasta 12 için nöbet öncesi dönemlerin tespitine ait işlem karakteristik eğrileri ve eğri altında kalan alan değerleri Şekil 4.25.'te gösterilmektedir.



Şekil 4.25. Hasta 12'ye ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Hasta 13'e ait temel bileşenler dağılımı Şekil 4.26.'da gösterilmektedir. Karışıklık matrisi ve sınıflandırma başarımları Tablo 4.29. ve Tablo 4.30.'da verilmektedir. Temel bileşenler dağılımında nöbetli evrelerin diğer evrelerden ayrıştığı görülmektedir. Normal ve nöbet öncesi evrelerde bölgesel karışmalar olduğu gözlenmektedir. Sınıflandırma sonuçları temel bileşenler dağılımını desteklemektedir.



Şekil 4.26. Hasta 13'e ait test verisinin temel bileşenler dağılımı


Tablo 4.29. Hasta 13 için sınıflandırıcıların karışıklık matrisi

	Gerçek değer	Normal			Nöbet öncesi			Nöbet		
		Tahmini değer	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Nöbet	
Sınıflandırıcı	DDA	55	8	1	1	36	0	0	0	28
	k-EYK	58	6	0	4	32	1	0	2	26
	DVM	61	3	0	2	34	1	3	2	23
	YSA	59	4	1	8	26	3	0	0	28

Tablo 4.30. Hasta 13 için sınıflandırma başarımları


Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Toplam Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	85,94	98,46	97,30	91,30	100,00	99,01	92,25
k-EYK	90,63	93,85	86,49	91,30	92,86	99,01	89,92
DVM	95,31	92,31	91,89	94,57	82,14	99,01	91,47
YSA	92,19	87,69	70,27	95,65	100,00	96,04	87,60

Sınıflandırıcılar ağırlıklı olarak normal ve nöbet öncesi dönemleri ayırt etmekte zorlanmıştır. En yüksek doğrulukla sınıflandırma (%92,25) DDA sınıflandırıcısıyla gerçekleştirilmiştir. Bu yöntem aynı zamanda nöbet öncesi dönemlerin algılanmasında en yüksek duyarlılığa (%97,30) sahiptir. Bu sınıflandırıcı 8 normal döneme ait EEG örneğini nöbet öncesi dönem olarak sınıflandırmıştır. Hasta 13 için nöbet öncesi dönemlerin tespitine ait işlem karakteristik eğrileri ve eğri altında kalan alan değerleri Şekil 4.27.'de gösterilmektedir. En yüksek eğri altındaki alana (0,9430) DDA sınıflandırıcısı sahiptir.



Şekil 4.27. Hasta 13'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Hasta 14'e ait temel bileşenler dağılımı Şekil 4.28.'de gösterilmektedir.



Şekil 4.28. Hasta 14'e ait test verisinin temel bileşenler dağılımı

Karışıklık matrisi ve sınıflandırma başarımları Tablo 4.31. ve Tablo 4.32.'de verilmektedir.


Tablo 4.31. Hasta 14 için sınıflandırıcıların karışıklık matrisi

	Gerçek değer	Normal			Nöbet öncesi			Nöbet		
		Tahmini değer	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi	Nöbet	Normal	Nöbet öncesi
Sınıflandırıcı	DDA	50	13	1	4	60	0	1	2	31
	k-EYK	51	12	1	5	58	1	1	3	30
	DVM	55	9	0	4	59	1	1	3	30
	YSA	53	1	10	15	32	17	2	0	32

Tablo 4.32. Hasta 14 için sınıflandırma başarımları

Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	78,13	94,90	93,75	84,69	91,18	99,22	87,04
k-EYK	79,69	93,88	90,63	84,69	88,24	98,44	85,80
DVM	85,94	94,90	92,19	87,76	88,24	99,22	88,89
YSA	82,81	82,65	50,00	98,98	94,12	78,91	72,22

Temel bileşenler dağılımında normal ve nöbet öncesi dönemler iç içe geçmiştir. Nöbet dönemlerine ait örnekler diğer dönemlerden ayrılmaktadır. Sınıflandırma sonuçlarına göre en yüksek doğruluk (%88,89) DVM sınıflandırıcısına aittir. Nöbet öncesi dönem algılamada en yüksek duyarlılığa (%93,75) DDA sınıflandırıcısı sahiptir. Hasta 14 için nöbet öncesi dönemlerin tespitine ait işlem karakteristik eğrileri ve eğri altında kalan alan değerleri Şekil 4.29.'da gösterilmektedir. En yüksek eğri altındaki alan değeri (0,8997) DVM sınıflandırıcısıyla elde edilmiştir. Nöbet öncesi dönemlerin algılanmasında en yüksek duyarlılığa DDA sınıflandırıcısı sahipken, nöbet öncesi olmayan durumların algılanmasında DVM sınıflandırıcısı daha başarılıdır.



Şekil 4.29. Hasta 14'e ait işlem karakteristik eğrileri ve eğri altındaki alan değerleri

Bütün hastalar için hesaplanan sınıflandırma başarımlarının ortalamaları Tablo 4.33.'de verilmektedir.

Tablo 4.33. Ortalama sınıflandırma başarımları

Sınıflandırıcı	Normal		Nöbet öncesi		Nöbet		Doğruluk (%)
	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	
DDA	92,65	94,34	89,10	94,50	94,30	98,72	92,29
k-EYK	96,50	89,39	81,68	96,61	90,73	99,15	91,76
DVM	97,58	92,96	85,69	97,22	92,17	98,58	93,51
YSA	94,65	89,60	69,07	98,27	95,89	92,99	88,00

Ortalama başarımlar incelendiğinde en yüksek doğrulukla (%93,51) sınıflandırma işleminin DVM sınıflandırıcısıyla yapıldığı görülmektedir. DVM için en başarılı sınıflandırma performansı radyal tabanlı çekirdek fonksiyonunun kullanıldığı durumlarda elde edilmiştir. Nöbet öncesi dönemlerin tespit edilmesi aşamasında en yüksek duyarlılık değerine (%89,10) DDA sınıflandırıcısıyla ulaşılmıştır. Nöbet duyarlılığı en fazla olan YSA sınıflandırıcısında aktivasyon fonksiyonu olarak tanjant sigmoid kullanılmıştır.

BÖLÜM 5. SONUÇLAR VE ÖNERİLER

Epilepsi dünya genelinde karşılaşılan en yaygın nörolojik rahatsızlıklardan birisidir. Epileptik nöbetler hasta bireyler üzerinde son derece olumsuz durumlara neden olabilmekte, bazı nöbetler ölümlerle sonuçlanabilmektedir. Güncel bilgi teknolojileri ve işaret işleme alanında yaşanan gelişmeler, EEG işaretlerinin etkin bir şekilde epileptik analizinin yapılmasına olanak sağlamaktadır. Epilepsili bireyin değişik durumlarına ait EEG kayıtlarının analiz edilmesinin, beyin çalışma biçimi ve hastalığın ortaya çıkma mekanizmasının belirlenmesine de katkı sağlayacağı düşünülmektedir. Olası epileptik nöbetleri önceden tahmin ederek, onun muhtemel olumsuz etkilerinden hasta bireyleri koruyacak veya etki düzeyini azaltacak teknolojiler tasarlamak için çalışmalar gerçekleştirilmektedir. Bu çalışmalar sonucunda tasarlanacak olan taşınabilir veya giyilebilir dizgeler sayesinde bireylerin can güvenliğinin sağlanması ve yaşam kalitelerinin artırılması nihai hedef olarak belirlenmektedir.

Geçmiş yıllarda uzun süreli EEG kayıtlarından epileptik nöbet tespiti yapmak üzere tasarlanmış birçok sistem gerçekleştirilmiştir. Bu çalışmaların ortak özellikleri ağırlıklı olarak sağlıklı dönemlerden elde edilen EEG kayıtlarını ve nöbet anındaki EEG kayıtlarını birbirlerinden ayırmaya çalışmalarıdır. Bu amaçla gerçekleştirilen çalışmalarda, araştırmacılar birçok yöntem önermiştir. Farklı ön işleme, özellik çıkarımı, özellik seçme, boyut indirgeme, sınıflandırma ve son işleme yöntemleri kullanılarak değişik türde sistemler geliştirilmiştir. Bu sistemlerden bazılarıyla hatasız nöbet algılama işlemi gerçekleştirilmiştir.

Bu tez çalışmasında, modern yöntemler kullanılarak değişik epileptik evrelere ait EEG işaretlerinin ayrışma düzeyleri incelenmiştir. Ön işlem olarak EEG kayıtları için bölümlenme işlemi yapılmıştır. Literatürde yaygın olarak kullanılan ve ayırt etme

potansiyeli yüksek özellik çıkarım yöntemlerinden faydalanılarak, bölümlenmiş EEG kayıtları için öznitelikler hesaplanmıştır. Hesaplanan özellik kümelerindeki gereksiz bilgileri elemek amacıyla boyut indirgeme işlemi gerçekleştirilmiştir. Bütün bu işlemler 21 farklı kanala ait EEG işaretleri için tekrarlanmıştır. Temel bileşenler analizi kullanılarak elde edilen indirgenmiş özellik kümeleri, en uygun kanalı tespit etmek için doğrusal bir sınıflandırıcı olan doğrusal diskriminant analizi yöntemiyle sınıflandırılmıştır. Farklı test ve eğitim verileri için yinelemeli olarak gerçekleştirilen ön sınıflandırma sonuçları değerlendirilerek, uygun olan kanallar belirlenmiştir. Ön sınıflandırma sonucunda belirlenen kanal için DDA, k-EYK, DVM ve YSA yöntemleriyle son sınıflandırma işlemi gerçekleştirilerek, sınıflandırma başarımları karşılaştırılmıştır. Performansları değerlendirmek için doğruluk, duyarlılık, özgüllük, İKE ve EAA değerleri ölçüt olarak kullanılmıştır.

EEG işaretlerinin epileptik açıdan analiz edilmesi çalışmalarında, yoğun olarak nöbetli ve nöbetsiz kayıtların ayrıştırılması problemine çözüm üretilmeye çalışılmaktadır. Bu tezde sadece nöbetsiz kayıtlardan elde edilen EEG işaretleri ve nöbet dönem kayıtları değerlendirilmemiş, nöbet öncesi döneme ait EEG örnekleri de dikkate alınmıştır. Literatürdeki birçok çalışmada olduğu gibi iki sınıflı bir sınıflandırma işlemi (nöbet arası- nöbet öncesi veya sağlıklı-nöbet vb) yerine üç sınıflı (normal, nöbet öncesi ve nöbet dönemi) bir sınıflandırma işlemi gerçekleştirilmiştir. Nöbet kestirimi için hayati önem taşıyan nöbet öncesi dönem EEG kayıtlarının etiketlenmesi işleminde, klasik ve modern sınıflandırıcıların davranış biçimleri incelenerek, kestirim için uygun olanlar tespit edilmeye çalışılmıştır. Aynı zamanda sınıflandırma yöntemleri ayrıntılı olarak karşılaştırılmıştır. Bütün bu analizler, epilepsi hastalığının bireylerde farklı eğilim göstermesinden dolayı hastaya özel olarak gerçekleştirilmiştir.

Kanal seçimi için gerçekleştirilen 100 tekrarlı ön sınıflandırma sonucunda; ortalama doğruluk değerleri ve sınıflandırma doğruluklarına ait standart sapmalar dikkate alındığında en yüksek doğruluğa sahip kanalların diğer kanallara göre düşük standart sapma değerlerine sahip olduğu gözlemlenmiştir. Hastaların yarısında (2, 4, 5, 6, 8,10 ve 12 numaralı hastalar) en yüksek ortalama doğruluğa sahip kanallar aynı

zamanda en düşük standart sapmalı kanallar olmuştur. Standart sapma değerlerine göre, yüksek ortalama doğruluğa sahip kanalların eğitim ve test verilerine olan bağışıklığının daha iyi olduğu değerlendirilebilir. Hasta 10, kanal seçiminden en fazla etkilenme potansiyeline sahip hasta olmuştur. Kanal seçimine karşın bağışıklığı en yüksek hasta olarak Hasta 2 gösterilebilir. Hasta 2 ve hasta 10 için kanal doğruluklarında sırasıyla %9,19 ve %29,48 dalgalanma meydana gelmiştir. Kanal performanslarındaki farklılaşmada nöbet türleri ve nöbet yerlerinin dağılımı etkilidir.

Analiz için uygunluğu tespit edilen kanallara ait ölçümlerle 4 farklı sınıflandırma yöntemi kullanılarak, epileptik evrelerin ayrışma durumları irdelenmiştir. Hastalara ait test verileri, en ağırlıklı ilk üç temel bileşenin oluşturduğu uzaya yansıtılmıştır. Bu dağılım sınıflandırıcı davranışlarının daha etkili bir şekilde değerlendirilmesine olanak sağlamıştır. Sınıflandırıcıların ayırmakta zorlandığı evrelerin beklendiği gibi, temel bileşenler dağılımında girişim yapan evreler olduğu gözlenmiştir. Sınıflandırma sonuçları yöntemden bağımsız olarak değerlendirildiğinde, en yüksek sınıflandırma doğrulukları %87,27 ve %100 arasında değişmektedir. Karışıklık matrisleri, sınıflandırma başarımları ve temel bileşen dağılımları birlikte değerlendirildiğinde, sınıflandırıcıların ağırlıklı olarak normal ve nöbet öncesi evreleri ayırmakta zorlandığı söylenebilir. Temel bileşen dağılımları nöbetli dönem örneklerinin diğer evrelerdeki örneklerden büyük ölçüde ayrıştığını göstermektedir. Sınıflandırma sonuçları ve temel bileşen dağılımları birbirlerini desteklemektedir.

Ortalama sınıflandırma başarımları dikkate alındığında DVM en yüksek doğruluğa (%93,51) sahip sınıflandırıcı olmuştur. Bu sınıflandırıcıyı sırasıyla DDA (%92,29), k-EYK (%91,76) ve YSA (%88) takip etmektedir. Özellikle nöbet kestirimi çalışmalarına katkı sağlamak amacıyla, nöbet öncesi dönemlerin diğer evrelerden ayrışma durumlarına da odaklanılmıştır. Bu bağlamda nöbet öncesi dönem için ortalama duyarlılık değerleri büyük önem teşkil etmektedir. Nöbet öncesi dönem tespitinde en yüksek duyarlılık değeri DDA (%89,10) yöntemine aittir. Bu yöntemi sırasıyla DVM (%85,69), k-EYK (%81,68) ve YSA (%69,07) takip etmektedir. YSA nöbet öncesi dönem hassasiyeti en düşük yöntem olmasına rağmen, en yüksek özgüllüğe (%98,27) sahip sınıflandırıcıdır. İşlem karakteristik eğrileri ve eğri

altındaki alan değerleri de bu sonucu desteklemektedir. DDA yönteminin nöbet öncesi dönem algılamada sergilediği yüksek hassasiyete Hasta 7 için elde edilen sonuçlar çarpıcı bir örnek olarak gösterilebilir. Bu hasta için en yüksek sınıflandırma doğruluğu %90,15 ile DVM'ye aittir. DDA %87,12 doğrulukla ikinci sıradadır. Nöbet öncesi dönem duyarlılığı açısından %84,21 ile DDA birinci, %71,05 ile DVM ikinci sıradadır. Yüksek sınıflandırma doğruluğuna rağmen, nöbet öncesi dönem duyarlılığı nedeniyle DDA 0,8732 olan eğri altındaki alan değeri ile DVM sınıflandırıcısını (0,8446) geride bırakmıştır.

Normal dönem algılamada en yüksek ortalama duyarlılık %97,58 ile DVM sınıflandırıcısına aittir. k-EYK sınıflandırıcısı %96,50 duyarlılıkla ikinci sıradadır. Normal dönem algılamada en yüksek ortalama özgüllük değeri %94,34 ile DDA sınıflandırıcısıdır. Nöbet dönemlerinin tespitinde en yüksek ortalama duyarlılığı %95,89 ile YSA sınıflandırıcısı göstermiştir. k-EYK sınıflandırıcısı %90,73 ile en düşük nöbet dönemi duyarlılığına sahip olmasına karşın, özgüllük sıralamasında %99,15 değeriyle birinci olmuştur. Sınıflandırma performansları bir bütünlük içerisinde değerlendirildiğinde; yüksek doğruluk özelliğiyle DVM yöntemi ve yüksek nöbet öncesi dönem hassasiyeti sebebiyle DDA yöntemi ön plana çıkmaktadır. Doğruluk ve duyarlılık ölçütleri birlikte değerlendirildiğinde ikili yani melez bir karar organının oluşturulması sistem performansının geliştirilmesine katkı sağlayacaktır. Aynı şekilde belirli bir düzeye kadar yanlış alarmlar göz ardı edilerek karar organlarının duyarlılığı artırılabilir.

Literatür kısmında verilen çalışmalar incelendiğinde %77,8 - %100 arasında duyarlılık değerleriyle nöbet öncesi dönem tespiti gerçekleştirildiği gözlemlenmektedir. Önceki çalışmalar ve bu tez çalışmasında ulaşılan sonuçlar Tablo 5.1.'de verilmektedir. Çalışmalarda analiz edilen EEG işaretlerinin elde edilmesinde kullanılan elektrotlarda, hasta sayılarında, kullanılan kanal sayılarında ve tespit edilen sınıf sayılarında farklılaşmalar söz konusudur. Bu parametreler sistem performansı üzerinde önemli bir etkiye sahiptirler. Dolayısıyla performansların yukarıda açıklanan farklılaşmalar dikkate alınarak karşılaştırılması

gerekmektedir. Aynı şekilde veri tabanına göre epileptik nöbet karakteristiklerinin de değişeceği unutulmamalıdır.

Tablo 5.1. Performans karşılaştırması

No	Çalışma	Hasta Sayısı	Kanal Sayısı	EEG İşareti	Sınıflar	Duyarlılık
1	Netoff ve ark.	9	6	i-EEG	Nöbet öncesi Nöbet arası	77,8
2	Park ve ark.	18	6	i-EEG	Nöbet öncesi Nöbet arası	97,5
3	Rasekhi ve ark.	10	6	i-EEG s-EEG	Nöbet öncesi Nöbet arası	73,91
4	Zandi ve Ark.	20	-	s-EEG	Nöbet öncesi Nöbet arası	88,34
5	Özdemir ve Ark.	21	6	i-EEG	Nöbet öncesi Nöbet arası	96,55
6	Ghaderyan ve Ark.	18	6	i-EEG	Nöbet öncesi Nöbet arası (Normal)	100
7	Anwar	12	1	s-EEG	Nöbet öncesi Nöbet arası (Normal)	100 - 96,65 - 73,1 (ortalama 89,87)
8	Behbahani ve Ark.	16	-	i-EEG s-EEG	Nöbet öncesi Normal	78,59
9	Önerilen sistem	14	1	s-EEG	Nöbet öncesi Nöbet arası (Normal) Nöbet	89,10

Bu tez çalışmasında ortalama %89,1 duyarlılıkta nöbet öncesi dönem tespit edilmiştir. Bazı hastalar için (1, 5 ve 12 numaralı hastalar) %100 duyarlılığa ulaşılmıştır. Ortalama %93,51 doğrulukla üç farklı epileptik evre için sınıflandırma gerçekleştirilmiştir. Yüzey elektrotlarıyla oluşturulan veri tabanları dikkate alındığında, Anwar üç farklı zaman aralıkları için ortalama %89,87 duyarlılıkla nöbet kestirimi gerçekleştirmiştir. Aynı veri tabanını kullandığımız Anwar ile ulaşılan sonuçların benzediği görülmektedir. Fakat bu tez çalışmasında analizler 14 hasta ve 3

sınıf için gerçekleştirilirken, Anwar 12 hasta için 2 sınıflı bir analiz gerçekleştirmiştir. Daha yüksek duyarlılıkla nöbet kestirimi yapan sistemlerde (2,5 ve 6) iğne elektrotlarıyla elde edilen EEG işaretlerinin kullanıldığı görülmektedir. Bu çalışmaların bir başka ortak özelliği ise analizlerin 6 kanal için gerçekleştirilmiş olmasıdır. İşaretleri normal ve nöbet öncesi olarak sınıflandırmışlardır.

Bu tez çalışması, nöbet kestirimi için kullanılan sınıflandırıcıların performanslarının değerlendirilmesine ve kanal etkisinin belirlenmesine olanak sağlaması açısından da farklılaşmaktadır. Dört farklı yöntemle sınıflandırma yapılarak ve 21 kanala ait EEG verileri analiz edilerek bu sağlanmıştır. Ayrıca çalışmada verilen kestirim performansları 5s'lik EEG dönemleri birbirinden bağımsız olarak değerlendirilerek hesaplanmıştır. Nöbete geçiş esnasında yaşanan EEG değişimleri anlamlandırılmaya çalışıldığı için, üç sınıflı bir tasarım yapılmıştır. Tasarlanan sistemin duyarlılığı belli oranda yanlış alarma izin vermek koşuluyla artırılabilir. Ayrıca belirli sayıda ardışık çıkışlar için çoğunluk oylaması yapılarak sistem duyarlılığı geliştirilebilir.

Hastaya özel olarak yapılan analizler; hastalığın karakteristiğine bağlı olarak, yakın gelecekte klasik ve modern yöntemlerle, yüksek duyarlılıklı nöbet kestirim sistemlerinin tasarlanabilmesi konusunda umut verici sonuçlar ortaya koymaktadır. Bu tez çalışmasında, Hasta 1 ve Hasta 12 için hatasız nöbet öncesi dönem tespiti gerçekleştirilmiştir. Hasta 3 ve Hasta 14 dışındaki bütün bireylerde %90,00 ve üzerinde doğrulukla sınıflandırma yapılmış olması bunun en büyük göstergesidir. Bu bağlamda epilepsili bireylerle yapılacak olan klinik çalışmalarla hastalığın karakteristiğinin belirlenmesi hayati önem taşımaktadır. Epilepsili bireyler bu amaçla kliniklere gitmeye teşvik edilmeli, varsa eğer klinik erişim problemleri giderilmelidir. Kestirim için gerekli olan ayırt etme becerisi yüksek EEG işaretlerinin elde edilmesiyle birlikte, epilepsili bireyler için etkin bir uyarı sistemi tasarlanabilecektir. Taşınabilir ya da giyilebilir özellikteki bu teknolojiler sayesinde epilepsili bireylerin can güvenliği sağlanabilecek, yaşam kaliteleri arttırılacaktır. Yapılacak olan çalışmalar bu amaç doğrultusunda planlanmaktadır.

Çalışmada ön sınıflandırma yapılarak kanal seçimi gerçekleştirilmiştir. Ön sınıflandırma sonuçlarının ölçüm bölgelerine yönelik değerlendirmesi yapılmamıştır. Nöbet öncesi evrede, beyin faaliyetlerinde meydana gelen değişimlerin haritalanmasına yönelik çalışmalar planlanmaktadır. Farklı özellik ve kanal seçme metotları kullanılarak elde edilen kombinasyonlar ile sistem başarımının artırılması hedeflenmektedir.

Sınıflandırıcılar normal ve nöbet öncesi dönemleri ayırmakta zorlanmaktadır. Literatürde önerilen özellikler normal ve nöbetli dönemleri ayırma sürecinde başarılıdır. Fakat nöbet öncesi dönemler değerlendirildiğinde özellik grupları aynı başarı düzeyine ulaşamamaktadır. Bu nedenle bir diğer çalışma alanı olarak, özellikle normal ve nöbet öncesi dönemleri ayırma potansiyeline sahip yeni özellik çıkarma yöntemleri üzerinde çalışılması düşünülmektedir. Sınıflandırıcı performansını değerlendirmede kullanılan ölçütler için, uzman görüşleri alınarak bir ağırlık dağılımı oluşturulması hedeflenmektedir. Bu sayede farklı sistemler için daha objektif bir performans karşılaştırması mümkün olacaktır.

KAYNAKLAR

- Abe, S. 2010. Support Vector Machines for Pattern Classification, Springer-Verlag London Limited, Springer.
- Albayrak, A. S. Erođlu, A., Kalaycı, Ş., Küçüksille, E., Ak, B., Karaatlı, M., Keskin, H. Ü., Çiçek, E. U. 2005. SPSS Uygulamalı Çok Deđişkenli İstatistik Teknikleri. 1. baskı. Edited by Ş. Kalaycı. Ankara: Asil Yayın Dađıtım LTD ŞTİ.
- Alkan, A. Subaşı, A., Kıymık, M. K. 2005. Epilepsi Tanısında MUSIC ve AR Yöntemlerinin Karşılaştırılması, IEEE 13. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Kayseri, 1–3.
- Anwar, A. 2015. An entropy-based feature in epileptic seizure prediction algorithm. IOSR Journal of Computer Engineering, 17(6), pp. 47–54.
- Arvaneh, M. Guan, C., Ang, K. K., Quek, C. 2011. Optimizing the channel selection and classification accuracy in EEG-based BCI. IEEE Transactions on Biomedical Engineering, 58(6): 1865–1873.
- Avşar, E. 2009. Tek-sınıf destek vektör makineleri kullanılarak epileptik EEG işaretlerinin sınıflandırılması. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı, Biyomedikal Mühendisliği Programı, Yüksek Lisans Tezi.
- Azlan, W. A. W., Low, Y. F. 2014. Feature Extraction of Electroencephalogram (EEG) Signal - A Review. 2014 IEEE Conference on Biomedical Engineering and Sciences, Sarawak, 801–806.
- Behbahani, S. Dabanloo, N. J., Nasrabadi, A. M., Durado, A. 2016. Prediction of epileptic seizures based on heart rate variability. Technology and Health Care, 24(6): 795–810.
- Bishop, C. M. 2006. Pattern Recognition and Machine Learning, Springer.
- Blanco, S. Garay, A., Coulombie, D. 2013. Comparison of frequency bands using spectral entropy for epileptic seizure prediction. ISRN Neurology, 2013: 1–5.
- Boostani, R. Moradi, M. H. 2003. Evaluation of the forearm EMG signal features for the control of a prosthetic hand. Physiological Measurement, 24(2003): 309–319.
- Boulouvar, R. S., Hayashibe, M., Dutta, A. 2014. EEG-EMG features extraction for brain computer interface. Research Report, Universite de Montpellier.
- Bradley, A. P. 1997. The use of the area under the ROC curve in the evaluation of machine learning algorithms. Pattern Recognition, 30(7): 1145–1159.

- Burges, C. J. C. 1998. A Tutorial on Support Vector Machines for Pattern Recognition. İçinde: Data Mining and Knowledge Discovery 2, Kluwer Academic Publisher, Boston, 121–167.
- Burges, C. J. C. 2010. Geometric Methods for Feature Extraction and Dimensional Reduction-A Guided Tour. İçinde: Data Mining and Knowledge Discovery Handbook, 2. Baskı, Springer, 53–82.
- Chang, G. C. Kang, W. J., Luh, J. J., Cheng, C. K., Lai, J. S., Chen, J. J. J., Kuo, T. S. 1996. Real-time implementation of electromyogram pattern recognition as a control command of man-machine interface. Medical Engineering and Physics, 18(7): 529–537.
- Chizi, B. Maimon, O. 2010. Dimension Reduction and Feature Selection. İçinde: Data Mining and Knowledge Discovery Handbook, 2. Baskı, Springer, 83–100.
- Clark, J. W. 2009. Medical instrumentation: Application and design, John Wiley & Sons, Inc.
- Coşkun, C. Baykal, A. 2011. Veri Madenciliğinde Sınıflandırma Algoritmalarının Bir Örnek Üzerinde Karşılaştırılması. Akademik Bilişim 2011, Malatya.
- Dirican, A. 2001. Tanı testi performanslarının değerlendirilmesi ve kıyaslanması. Cerrahpaşa Tıp Dergisi, 32(1): 25–30.
- Duda, R. O. Hart, P. E., Stork, D. G. 2001. Pattern Classification, Wiley-Interscience.
- Engin, E. Z. Taşan, D., Engin, M. 2015. Çok işlevli protez el kontrolü için önkol elektromiyografi işaretlerinin sınıflandırılması. Fen ve Mühendislik Dergisi, 1(49): 35–46.
- Erkel, A. R. V., Pattynama, P. M.T. 1998. Receiver operating characteristic (ROC) analysis: basic principles and applications in radiology. European Journal of Radiology, 27(1998): 88–94.
- Fausett, L. 1994. Fundamentals of Neural Networks: Algorithms, Architectures and Applications, Prentice Hall.
- Fawcett, T. 2006. An introduction to ROC analysis. Pattern Recognition Letters, 27(2006): 861–874.
- Fielding, A. H. 2007. Cluster and classification techniques for the biosciences, Cambridge University Press.
- Fraz, M. M. Remagnino, P., Hoppe, A., Barman, S. A. 2013. Retinal Image Analysis Aimed at Extraction of Vascular Structure Using Linear Discriminant Classifier. International Conference on Computer Medical Applications ICCMA 2013, 1–6.
- Freeman, J. A. Skapura, D. M. 1991. Neural Networks Algorithms, Applications, and Programming Techniques. Addison-Wesley Publishing Company.
- Ghaderyan, P. Abbasi, A., Sedaaghi, M. H. 2014. An efficient seizure prediction method using KNN-based undersampling and linear frequency measures. Journal of Neuroscience Methods, 232(2014): 134–142.

- Guyton, A. C. 1976. *Structure and Function of the Nervous System*, 2. Baskı, W.B. Saunders Company.
- Günay, M. Alkan, A. 2010. Spektral yöntemler ve dvm sınıflandırıcı ile EMG işaretlerinin tasnifi. *KSÜ Mühendislik Bilimleri Dergisi*, 13(2): 63–69.
- Han, J. Kamber, M. 2006. *Data Mining: Concepts and Techniques*, 2. Baskı, Elsevier, San Francisco: Morgan Kaufmann Publishers.
- Haykin, S. 1999. *Neural Networks - A Comprehensive Foundation*, 2. Baskı, New Jersey, Prentice-Hall International Inc.
- Hjorth, B. 1970. EEG analysis based on time domain properties, *Electroencephalography and Clinical Neurophysiology*, 29(3): 306–310.
- Husain, S. J. Rao, K. S. 2014. An artificial neural network model for classification of epileptic seizures using Huang- Hilbert Transform. *International Journal on Soft Computing*, 5(3): 23–33.
- Jasper, H. H. 1958. The Ten-Twenty Electrode System of the International Federation in Electroencephalography and Clinical Neurophysiology, *EEG Journal*, 10:371–375.
- Johnson, R. A., Wichern, D. W. 2007. *Applied Multivariate Statistical Analysis*. 6. Baskı, New Jersey, Pearson Prentice Hall.
- Jolliffe, I. T. 2002. *Principal Component Analysis*. 2. Baskı, Springer.
- Joshi, S. Shetty, S. R. P. 2015. Performance analysis of different classification methods in data mining for diabetes dataset using WEKA Tool. *International Journal on Recent and Innovation Trends in Computing and Communication*, 3(3): 1168–1173.
- Juarez-Guerra, E. Alarcon-Aquino, V., Gomez-Gil, P. 2013. Epilepsy Seizure Detection in EEG Signals Using Wavelet Transforms and Neural Networks. *The Virtual International Joint Conferences on Computer, Information and Systems Sciences and Engineering*, 1–6.
- Junoh, A. K. Mansor, M. N. 2012. Safety System Based on Linear Discriminant Analysis. *International Symposium on Instrumentation & Measurement, Sensor Network and Automation, Sanya*, 32–34.
- Kannathal, N. Choo, M. L., Acharya, U. R., Sadasivan, P. K. 2005. Entropies for detection of epilepsy in EEG. *Computer Methods and Programs in Biomedicine*, 80(3): 187–194.
- Kotsiantis, S. B. 2007. Supervised machine learning: a review of classification techniques. *Informatica*, 31(2007): 249–268.
- Kumar, Y. Dewal, M. L. 2011. Complexity measures for normal and epileptic EEG signals using ApEn, SampEn and SEN. *International Journal of Computer & Communication Technology*, 2(7): 6–12.
- Liang, S. Wang, H., Chang, W. 2010. Combination of EEG complexity and spectral analysis for epilepsy diagnosis and seizure detection. *EURASIP Journal on Advances in Signal Processing*, 2010: 1–15.

- Liu, H., Motoda, H. 2008. Introduction and Background. *Çinde: Computational Methods of Feature Selection*, Chapman & Hall/CRC, pp. 3–17.
- Malmivuo, J. Plonsey, R. 1995. *Bioelectromagnetism*, Oxford University Press.
- Metz, C. E. 1978. Basic principles of ROC analysis. *Seminars in Nuclear Medicine*, 8(4): pp. 283–298.
- Meyer-Base, A. 2004. *Pattern Recognition in Medical Imaging*, California, Elsevier Academic Press.
- Michie, D. Spiegelhalter, D. J., Taylor, C. C. 1994. *Machine Learning , Neural and Statistical Classification*, Prentice Hall.
- Mitchell, T. M. 1997. *Machine learning*, McGraw-Hill Science/Engineering/Math.
- Mohseni, H. R. Maghsoudi, A., Shamsollahi, M. B. 2006. Seizure Detection in EEG Signals: A Comparison of Different Approaches. 28th IEEE EMBS Annual International Conference, New York, 6724–6727.
- Motoda, H. Liu, H. 2002. Feature selection, extraction and construction. *Communication of Instute of Information and Computing Machinery*, 5(2): 67–72.
- Netoff, T. Park, Y., Parhi, K. 2009. Seizure Prediction Using Cost-Sensitive Support Vector Machine. 31st Annual International Conference of the IEEE EMBS. Minnesota, 3322–3325.
- Nizam, H. Akin, S. S. 2014. Sosyal Medyada Makine Öğrenmesi ile Duygu Analizinde Dengeli ve Dengesiz Veri Setlerinin Performanslarının Karşılaştırılması. 19. Türkiye’de İnternet Konferansı, İzmir.
- Ocak, H. 2009. Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy. *Expert Systems With Applications*, 36(2009): 2027–2036.
- 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.
- Oral, C. 2011. Sayısal mamografi görüntülerine yapay zeka yöntemlerinin uygulanması. Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Bölümü, Doktora Tezi.
- Ouyang, G. Li, X., Li, Y., Guan, X. 2007. Application of wavelet-based similarity analysis to epileptic seizures prediction. *Computers in Biology and Medicine*, 37: 430–437.
- Özdemir, N. Yıldırım, E. 2014. Patient specific seizure prediction system using hilbert spectrum and bayesian networks classifiers. *Computational and Mathematical Methods in Medicine*, 2014: 1–10.
- Panahi, N. Shayesteh, M. G., Mihandoost, S., Varghahan, B.Z. 2011. Recognition of Different Datasets Using PCA, LDA, and Various Classifiers. 5th International Conference on Application of Information and Communication Technologies, Baku, 1-5.

- Panat, A. Patil, A., Deshmukh, G. 2014. Feature Extraction of EEG Signals in Different Emotional States. 8th IRF International Conference, Pune, 63–67.
- Park, Y. Luo, L., Parhi, K. K., Netoff, T. 2011. Seizure prediction with spectral power of EEG using cost-sensitive support vector machines. *Epilepsia*, 52(10): 1761–1770.
- Phung, D. Tran, D., Ma, W., Nguyen, P., Pham, T. 2014. Using Shannon Entropy as EEG Signal Feature for Fast Person Identification. European Symposium on Artificial Neural Networks Computational Intelligence and Machine Learning, Bruges, 23–25.
- Physionet, CHB-MIT Scalp EEG Database, <http://www.physionet.org/physiobank/database/chbmit/> Eriřim Tarihi: 06.12.2011.
- Rasekhi, J. Mollaei, M.R.K., Bandarabadi, M., Teixeira, C. A., Dourado, A. 2013. Preprocessing effects of 22 linear univariate features on the performance of seizure prediction methods. *Journal of Neuroscience Methods*, 217(2013): 9–16.
- Saeyns, Y. Inza, I., Larranaga, P. 2007. A review of feature selection techniques in bioinformatics. *Bioinformatics*, 23(19): 2507–2517.
- Saęlıklı Dünya <https://sagliklidunya.com/makaleler/noroloji-beyin-ve-sinir-hastaliklari/norolojik-hastaliklar/grand-mal-nobeti>, Eriřim Tarihi: 03.07.2017.
- Shoeb, A. Guttag, J. 2010. Application of Machine Learning To Epileptic Seizure Detection. The 27th International Conference on Machine Learning (ICML-10), Haifa, 975–982.
- Sipahi, B., Yurtkoru, E. S., ınko, M. 2006. Sosyal Bilimlerde SPSS’le Veri Analizi, Beta Basım Yayım Daęıtım A.ř.
- Sivasankari, N. Thanushkodi, K. 2009. Automated epileptic seizure detection in EEG signals using fastICA and neural network. *Int. Journal Advance. Soft Comput. Appl.*, 1(2): 1–14.
- Smith, L. I. 2002. A tutorial on principal components analysis introduction. http://www.cs.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf Eriřim Tarihi: 10.11.2016.
- Subařı, A. 2007. EEG signal classification using wavelet feature extraction and a mixture of expert model. *Expert Systems with Applications* 32 (2007): 1084–1093.
- Subařı, A. Grsoy, M. I. 2010. EEG signal classification using pca , ica , lda and support vector machines. *Expert Systems With Applications*, Elsevier Ltd, 37(2010): 8659–8666.
- Tařcı, E. Onan, A. 2016. K- En Yakın Komřu Algoritması Parametrelerinin Sınıflandırma Performansı zerine Etkisinin İncelenmesi. XVIII. Akademik Biliřim Konferansı, Aydın.
- Tomak, L. Bek, Y. 2010. İřlem karakteristik eęrisi analizi ve eęri altında kalan alanların karřılařtırılması. *On Dokuz Mayıs niversitesi, Deneysel ve Klinik Tıp Dergisi*, 27(2): 58–65.

- Türk Epilepsi ile Savaş Derneği. <http://www.turkepilepsi.org.tr>, Erişim Tarihi: 21.07.2017.
- Türk Epilepsi ile Savaş Derneği-2. 2017. <http://www.turkepilepsi.org.tr/menu/33/parsiyel-nobet>, Erişim tarihi: 04.07.2017.
- Türk Epilepsi ile Savaş Derneği-3. 2017. <http://www.turkepilepsi.org.tr/menu/35/absans-nobetleri>, Erişim Tarihi: 04.07.2017.
- Tzallas, A. T. Tsipouras, M. G., Fotiadis, D. I. 2007. Automatic seizure detection based on time-frequency analysis and artificial neural networks. *Computational Intelligence and Neuroscience*, 2007: 1–13.
- Ünsal, A. 2000. Diskriminant analizi ve uygulaması üzerine bir örnek. *Gazi Üniversitesi İ.İ.B.F Dergisi*, 3(2000): 19–36.
- Vapnik, V. N. 1998. *Statistical Learning Theory*, Wiley-Interscience Publication.
- Vavadi, H. Ayatollahi, A., Mirzaei, A. 2010. A wavelet-approximate entropy method for epileptic activity detection from EEG and its sub-bands. *Journal Biomedical Science and Engineering*, 2010(3): 1182–1189.
- World Health Organization. 2017. <http://www.who.int/mediacentre/factsheets/fs999/en/> Erişim Tarihi: 21.06.2017.
- Yazgan, E. Korürek, M. 1996. *Tıp elektroniği*, İstanbul Teknik Üniversitesi.
- Yıldız, M. Bergil, E. 2015. The investigation of channel selection effects on epileptic analysis of EEG signals. *Balkan Journal of Electrical and Computer Engineering*, 3(4): 236–241.
- Zandi, A. S. Tafreshi, R., Javidan, M., Dumont, G. A. 2013. Predicting epileptic seizures in scalp EEG based on a variational bayesian gaussian mixture model of zero-crossing intervals. *IEEE Transactions on Biomedical Engineering*, 60(5): 1401–1413.
- Zheng, N., Xue, J. 2009. *Statistical Learning and Pattern Analysis for Image and Video Processing*, Springer.
- Zou, K. H. O'Malley, A. J., Mauri, L. 2007, Receiver-operating characteristic analysis for evaluating diagnostic tests and predictive models. *Circulation*, 115(5): 654–657.
- Zurada, J. M. 1992. *Introduction to Artificial Neural Systems*, West Publishing Company.
- Zweig, M. H. Campbell, G. 1993. Receiver-operating characteristic (ROC) plots: a fundamental evaluation tool in clinical medicine. *Clinical Chemistry*, 39(4): 561–577.

ÖZGEÇMİŞ

Erhan BERGİL, 03.07.1980'de Sivas'ta doğdu. İlk, orta ve lise eğitimini Sivas'ta tamamladı. 1997 yılında Ulaş Lisesi'nden mezun oldu. 2001 yılında Ondokuz Mayıs Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nü bitirdi. Yüksek lisansını 2009 yılında Ondokuz Mayıs Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda tamamladı. 2002-2006 yılları arasında Ondokuz Mayıs Üniversitesi Amasya Meslek Yüksekokulu'nda öğretim görevlisi olarak çalıştı. 2006 yılından günümüze kadar Amasya Üniversitesi, Amasya Teknik Bilimler Meslek Yüksekokulu, Elektronik ve Otomasyon Bölümünde öğretim görevlisi olarak çalışmaktadır. Evli ve iki çocuk babasıdır.