T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ

EEG SİNYALLERİ İŞLENEREK MULTİPL SKLEROZ HASTALIĞININ TESPİTİ VE SINIFLANDIRILMASI

Soner KOTAN

DANIŞMAN
Prof. Dr. Fırat KAÇAR

II. DANIŞMAN
Prof. Dr. Aydın AKAN

Biyomedikal Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

İSTANBUL-2019

Bu çalışma 25.10.2019 Tarihinde aşağıdaki jüri tarafından Biyomedikal Mühendisliği Anabilim Dalı, Biyomedikal Mühendisliği Programı Doktora Tezi olarak kabul edilmiştir.

TEZ JÜRİSİ

Prof. Dr. Fırat KAÇAR
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Prof. Dr. Mukden UĞUR
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Prof. Dr. Onur OSMAN
İstanbul Arel Üniversitesi
Mimarlık-Mühendislik Fakültesi

Doç. Dr. Yasin ÖZÇELEP
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Dr.Öğr.Üyesi Dilek GÖKSEL DURU
İstanbul Arel Üniversitesi
Mimarlık-Mühendislik Fakültesi

20.04.2016 tarihli Resmi Gazete'de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa'nın abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

ÖNSÖZ

Akademik hayatım süresince bilgi ve deneyimlerinden yararlandığım ve kendisinden insani anlamda çok şey öğrendiğim eş danışmanım Prof. Dr. Aydın AKAN'a ve gerek lisans hayatım gerekse doktora çalışmalarım boyunca akademik ve insani anlamda çözüm odaklı önerilerini ve yardımlarını esirgemeyen danışmanım Prof. Dr. Fırat KAÇAR'a değerli katkılarından dolayı teşekkür ederim.

Tez çalışmamda kullandığım verinin sağlanmasında ve çalışmam sırasında verdikleri destek ve katkılardan dolayı Doç. Dr. Jeroen Van Schependom ve Prof. Dr. Guy Nagels'a,

Tez çalışmalarım boyunca manevi anlamda desteklerini esirgemeyen meslektaşlarım Dr. Merve DOĞRUYOL BAŞAR, Dr. Mehmet ELİBOL ve Dr. Derya ERYİĞİT'e

Ve öğrenim hayatım boyunca desteğini hep yanımda hissettiğim anneme teşekkürlerimi sunarım.

Ekim 2019 Soner KOTAN

İÇİNDEKİLER

Sayfa No

ÖNSÖZ ..... **iv**
İÇİNDEKİLER ..... **v**
ŞEKİL LİSTESİ ..... **vii**
TABLO LİSTESİ ..... **ix**
SİMGE VE KISALTMA LİSTESİ ..... **x**
ÖZET ..... **xi**
SUMMARY ..... **xiii**
1. GİRİŞ **1**
1.1. TEZİN AMACI VE KATKILARI 7
2. GENEL KISIMLAR **9**
2.1. MS'TE ERKEN TEŞHİSİN ÖNEMİ VE HASTALIĞIN SEYRİNİN TAKİBİ 9
2.1.1. Primer testler 9
2.1.2. Sekonder testler 9
2.1.3. Diğer testler 9
2.1.4. MS takibinde kullanılan Bilişsel ve Fonksiyonel Ölçekler 10
2.1.5. MS'te erken teşhisin önemi 10
2.2. ELEKTROANSEFALOGRAFİ 12
3. MALZEME VE YÖNTEM **16**
3.1. ÇALIŞMADA KULLANILAN EEG VERİSİ VE ÖN İŞLEME 17
3.2. GÖRGÜL KİP AYRIŞTIRMA 18
3.3. ÇOK DEĞİŞKENLİ GÖRGÜL KİP AYRIŞTIRMA 22
3.4. ÖZ KİP FONKSİYONU SEÇME 24
3.5. ÇALIŞMADA KULLANILAN ÖZNİTELİKLER 29
3.5.1. Ortalama 29
3.5.2. Standart sapma 29
3.5.3. Ortalama Sinyal Gücü 29
3.5.4. Hjorth Parametreleri (Aktivite, mobilite, kompleksite) 29
3.5.5. Çarpıklık 30
3.5.6. Sivrilik (Kurtosis) 30

3.5.7. Hurst üssü 31
3.5.8. Fraktal Boyutlar 32
3.6. SINIFLANDIRMA 33
3.6.1. k-en yakın komşu (k-NN) 34
3.6.2. Doğrusal Ayrımcılık Analizi 37
3.6.3. Rastgele Orman Sınıflandırıcı 43
3.6.4. Çok katmanlı algılayıcı (ÇKA) 45
3.7. ÇAPRAZ - DOĞRULAMA 52
4. BULGULAR 53
4.1. ÇDGKA KULLANILARAK MS KESTİRİMİ 53
4.2. ÇDGKA KULLANILARAK MS HASTALARINDA BİLİŞSEL ENGELLİLİK KESTİRİMİ 54
4.3. ÖZNİTELİK BAŞARIMLARI AÇISINDAN DEĞERLENDİRME 55
4.4. EEG KANALLARININ BAŞARIMLARI AÇISINDAN DEĞERLENDİRME 56
4.5. ÖZ KİP FONKSİYONU SEÇME YÖNTEMLERİ AÇISINDAN DEĞERLENDİRME 58
4.6. SEÇİLEN ÖKF'LERİN SINIFLANDIRMA BAŞARIMINA ETKİSİ 59
4.7. EEG SİNYALİ VEYA ÇDGKA YAKLAŞIMININ SINIFLANDIRMA BAŞARIMINA ETKİSİ 60
5. TARTIŞMA VE SONUÇ 63
KAYNAKLAR 66
ÖZGEÇMİŞ 72

ŞEKİL LİSTESİ

Sayfa No

Şekil 1.1: Sinir hücresinin yapısı 1

Şekil 1.2: MS nedeniyle hasar görmüş miyelin kılıflar. 2

Şekil 1.3: MS türlerinin zaman içerisindeki ilerlemeleri. 4

Şekil 2.1: MS'te lezyonların MRG ile görüntülenmesi [28].....11

Şekil 2.2: BOS analizi [29]. 11

Şekil 2.3: OKT ile retina arkasının görüntülenmesi [30].....12

Şekil 2.4: (a) Bir EEG kaydının temsili gösterimi (b) Uluslararası 10-20 elektrot dizilim düzeni [34].....13

Şekil 2.5: EEG cihazına ait elektronik devre blok diyagramı.....13

Şekil 2.6: EEG alt bantları. 15

Şekil 3.1: Çalışmanın blok diyagramı.....17

Şekil 3.2: GKA akış diyagramı. 20

Şekil 3.3: 1000 örneğe sahip bir EEG sinyali. 21

Şekil 3.4: 1000 örnekli bir EEG sinyalinden elde edilmiş olan ÖKF'ler. 21

Şekil 3.5: 1000 örneğe sahip EEG sinyali için ÖKF'lerin güç yoğunluk spektrumları. 22

Şekil 3.6: 21 kanalın her biri için elde edilmiş 17 adet ÖKF.....24

Şekil 3.7: Bir EEG sinyalinden elde edilmiş 14 adet ÖKF'nin enerji seviyeleri.....26

Şekil 3.8: Bir EEG sinyalinden elde edilmiş 14 adet ÖKF'nin korelasyon katsayıları. 27

Şekil 3.9: Bir EEG sinyalinden elde edilmiş 14 adet ÖKF'nin GYS benzerlik oranları. 28

Şekil 3.10: ÖKKF seçim sonucu ortaya çıkan yeni durum.....28

Şekil 3.11: sınıflandırma öncesi her bir kişi için elde edilen sınıflandırma verisi.....32

Şekil 3.12: yapay zekâ ve alt dalları.....33

Şekil 3.13: Makine öğrenmesi haritası.....34

Şekil 3.14: k-NN algoritmasının çalışma prensibi. 35

Şekil 3.15: İki sınıf için farklı doğrular üzerine iz düşüm. 39

Şekil 3.16: X_2 daha iyi sınıf ayırt ediciliği sağlarken X_1'deki mesafe daha fazladır. 40

Şekil 3.17: Sınıf içi dağılım minimum ve ortalama mesafesinin maksimum olduğu doğru. 41

Şekil 3.18: Basit bir karar ağacı yapısı.....43

Şekil 3.19: Bir sinir hücresinden bilgi akışı. 45

Şekil 3.20: Yapay sinir ağının matematiksel nörona benzetimi. 46

Şekil 3.21: Tek bir gizli katmana ve bu katmanda dört tane düğüme sahip ağ.....47

Şekil 3.22: İki adet gizli katmana ve bu katmanlarda dört tane düğüme sahip ağ. 47

Şekil 3.23: Düğümlerde kullanılan Bazı transfer fonksiyonları.....48

Şekil 3.24: İki ağırlığa sahip bir ÇKA'ya ait hata yüzeyi. 49

Şekil 3.25: Geri yayılım algoritması. 50

Şekil 3.26: Hata minimizasyonu için ağa eklenen düğümler. 51

Şekil 4.1: EEG kanallarından elde edilen sınıflandırma doğruluklarının dağılımı. 58

TABLO LİSTESİ

Sayfa No

Tablo 1.1: MS'te ortaya çıkan belirtiler 2

Tablo 2.1: EEG alt Bandlarının normal ve patolojik işaretçileri. 14

Tablo 4.1: ÇDGKA kullanılarak MS kestirimi. 54

Tablo 4.2: En iyi doğruluk oranı için sınıflandırma parametreleri. 54

Tablo 4.3: ÇDGKA kullanılarak MS'te bilişsel engellilik kestirimi. 55

Tablo 4.4: En iyi sınıflandırma doğruluğu için bazı parametreler. 55

Tablo 4.5: Farklı öznitelikler için sınıflandırma doğruluk oranları ve standart sapmalar. 56

Tablo 4.6: Farklı EEG kanalları için sınıflandırma doğruluk oranları ve standart sapmaları. 57

Tablo 4.7: Farklı ÖKF seçim yöntemlerinin sınıflandırma doğruluğu açısından karşılaştırılması. 59

Tablo 4.8: Farklı seçim yöntemlerinin önerdiği ÖKF önem sıralamaları. 59

Tablo 4.9: Seçilen ÖKF'lerin kendi arasında kıyaslanması. 60

Tablo 4.10: Sınıflandırma doğruluğu açısından orijinal EEG – ÖKF kullanımı karşılaştırması. 61

Tablo 4.11: Öznitelikten arındırılmış orijinal EEG – GKA karşılaştırması. 62

SİMGE VE KISALTMA LİSTESİ

Simgeler **Açıklama**

Kısaltmalar **Açıklama**

MS : Multipl Skleroz
SSS : Merkezi sinir sistemi
KİS : Klinik izole sendrom
RRMS : Ataklarla seyreden MS
SPMS : İkincil progresif seyreden MS
PPMS : Birincil progresif seyreden MS
PRMS : Progresif ataklarla seyreden MS
EEG : Elektroansefalografi
FFT : Fast Fourier Transform
MRG : Manyetik rezonans görüntüleme
EDSS : Genişletilmiş engellilik durumu ölçeği
NSBMS : MS için nöropsikolojik tarama ölçeği
BOS : Beyin Omurilik Sıvısı
GKA : Görgül kip ayrışıtırma
ÖKF : Öz kip fonksiyonları
ÇD-GKA : Çok değişkenli görgül kip ayrışıtırma
GYS : Güç yoğunluk spektrumu
k-NN : k-en yakın komşu
DAA : Doğrusal ayrımcılık analizi
ÇKA : Çok katmanlı algılayıcı
YSA : Yapay sinir ağı

ÖZET

DOKTORA TEZİ

EEG SİNYALLERİ İŞLENEREK MULTİPL SKLEROZ HASTALIĞININ TESPİTİ VE SINIFLANDIRILMASI

Soner KOTAN

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Danışman : Prof. Dr. Fırat KAÇAR

II. Danışman : Prof. Dr. Aydın AKAN

Multipl skleroz (MS), merkezi sinir sistemini etkileyen kronik bir bağışıklık sistemi hastalığıdır. Hastalık, sinir hücrelerinde hasar meydana gelmesine neden olarak kişide çeşitli bilişsel ve fonksiyonel engelliliklerin oluşmasına neden olur. Merkezi sinir sisteminden onarılamaz hasarlara neden olabilen ve hızı değişmekle birlikte sürekli olarak ilerleme eğiliminde olan bu hastalık için erken tedavi büyük önem taşır. MS belirtileri gösteren bir hastaya kesin MS teşhisi konulabilmesi için, hastanın uzun zaman alan, zahmetli ve ekonomik maliyeti yüksek bazı testlerden geçmesi gerekmektedir. Bu durum, bir yandan teşhis için zaman kaybına, diğer yandan ise yüksek maliyetlere neden olmaktadır.

Bu tezde MS hastalığının daha hızlı, daha kolay ve daha az maliyetli bir şekilde teşhisi için, hastalara ait elektroansefalografi (EEG) sinyallerinin işlenmesine dayanan bir yöntem önerilmektedir. Bu amaçla MS hastaları ve sağlıklı bireylerden dinlenme durumunda kaydedilen EEG sinyallerinden çeşitli sinyal parametreleri elde edilerek sınıflandırma için kullanılmışlardır. Bununla birlikte, EEG sinyallerinden hesaplanan öznitelikler kullanılarak MS hastalarının kendi içerisinde bilişsel engelli/bilişsel korunmuş sınıflandırması da yapılmıştır.

Yapılan analizlerde orijinal EEG sinyallerinin yanı sıra, bu sinyallere uygulanan çok değişkenli görgül kip ayrıştırma işlemi sonucu elde edilen alt bileşenleri de kullanılmıştır. Elde edilen sonuçlarda, elektroansefalografi sinyalleri kullanılarak MS hastalığının teşhisinde yüksek

doğruluk oranlarına ulaşılabildiği görülmüştür. Nispeten daha düşük doğruluk oranlarına sahip olmakla birlikte, MS hastalarının bilişsel engellilik bakımından sınıflandırılmasının da EEG sinyalleri kullanılarak gerçekleştirilebileceği sonucuna ulaşılmıştır.

Çalışmada sınıflandırma işlemleri haricinde, gelecekte yapılacak benzer çalışmalarda yol gösterici olması açısından yararlı olacağı düşünülen farklı analizler de yapılmıştır. Bu amaçla; EEG sinyalleri ile yapılan sınıflandırmalarda kullanılan kanalların, özniteliklerin, öz kip fonksiyonlarının ve bu fonksiyonları seçme yöntemlerinin sınıflandırma doğruluğuna etkileri karşılaştırılmıştır.

Ekim 2019, 86 sayfa.

Anahtar kelimeler: multipl skleroz, elektroansefalografi, sınıflandırma, görgül kip ayrıştırma

SUMMARY

Ph.D. THESIS

DETECTION AND CLASSIFICATION OF MULTIPLE SCLEROSIS DISEASE BY PROCESSING OF EEG SIGNALS

Soner KOTAN

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Biomedical Engineering

Supervisor : Prof. Dr. Fırat KAÇAR

Co-Supervisor : Prof. Dr. Aydın AKAN

Multiple Sclerosis is a very common chronic disease that affects central nervous system. The disease causes axonal damage and neuronal loss by corrupting myelin sheaths. Cognitive and functional impairment is the common effect of neurological damage. Due to it causes irreversible damages over central nervous system, early diagnosis is very important. Time consuming, difficult and high cost examinations are needed for determination of multiple sclerosis. This procedures causes loss of time, which is very important to start early treatment.

In this study, we have used electroencephalography signals in the detection of multiple sclerosis. The method we proposed is faster, easier and low cost when compared with the current diagnostic procedures. We have classified electroencephalography signals recorded from multiple sclerosis patients and healthy volunters. We also classified multiple sclerosis patients as cognitively impaired/intact by using features extracted from electroencephalography signals.

In classification, we have used original electroencephalography signals while we also used components of electroencephalography signals which are obtained by using empirical mode

decomposition. We reached a high accuracy rate in the detection of multiple sclerosis. We also reached a relatively low but good accuracy in the cognitive impairment classification.

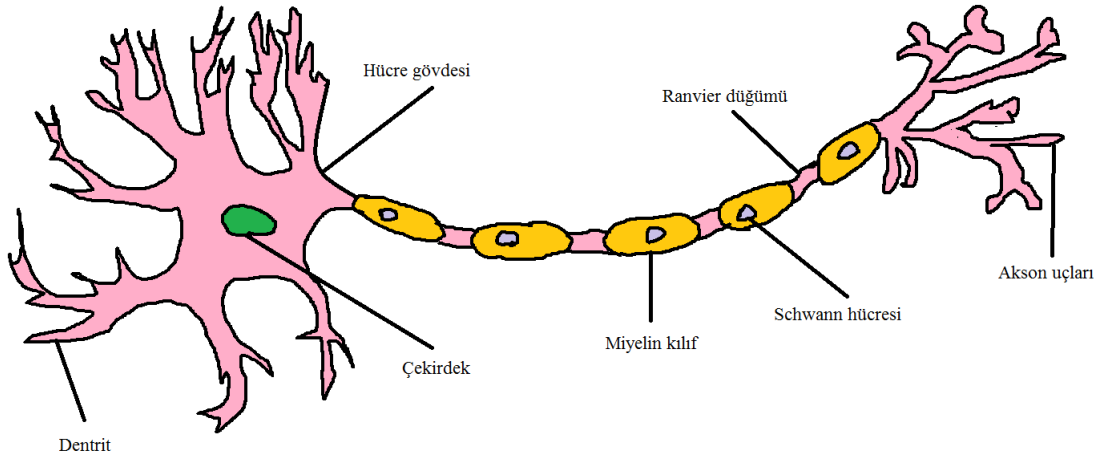
Besides classification, we also made some other analyses which could be guiding in future works. For this purpose, we have compared the electroansephalography channels, features, intrinsic mode functions and intrinsic mode function selection methods in terms of classification accuracy.

October 2019, 86 pages.

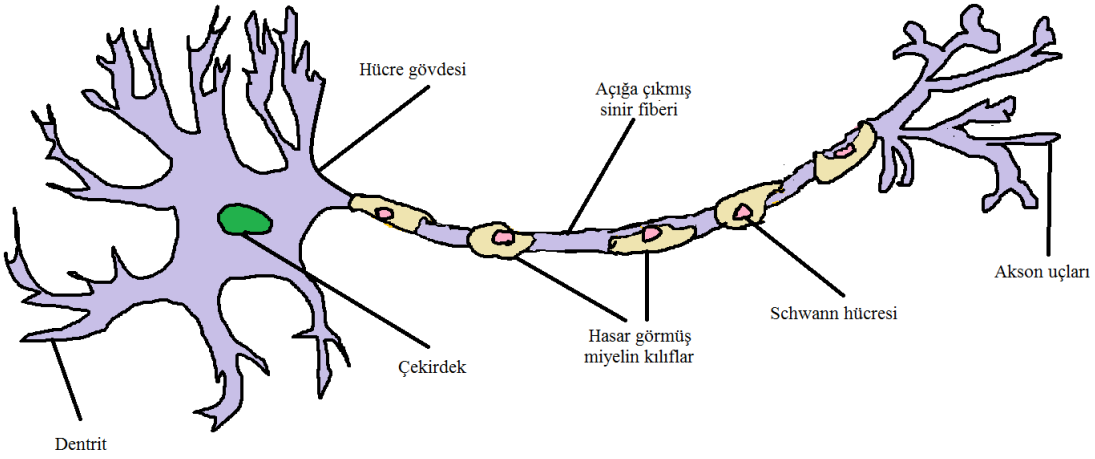
Keywords: Multiple sclerosis, electroencephalography, classification, emprical mode decomposition

1. GİRİŞ

Multipl Skleroz (MS), enflamasyon, demiyelinizasyon ve akson hasarı şeklinde ortaya çıkan, kronik bir merkezi sinir sistemi (SSS) hastalığıdır. Hastalığın asıl nedeni bilinmemekle birlikte; çevresel [1] ve genetik [2, 3] faktörlerin hastalığa yatkınlıkta rol oynadığına dair çalışmalar mevcuttur. Hastalıkta belirtilerin başlaması, beynin kanın içerisindeki olası zararlı maddelerden korunmasını sağlayan damar yapısı olan kan beyin bariyerinin bozulması sonrasında ortaya çıkmaktadır. Enflamatuar mediyatörler, ranvier boğumu denilen sinir hücresi bölgesinde sinir iletiminin engellenmesine ve aksonlarda bulunan miyelin kılıfın bozunmasına neden olur [4]. Bu sürecin şiddeti, ölçeği ve miyelin kılıfın tamir edilme hızı; hastalığın süresini, belirtilerin şiddetini ve iyileşme miktarını belirler [5]. Sinir hücrelerinde meydana gelen bu bozulmalar, beyindeki gri ve beyaz maddelerde ve omurilikte demiyelinizasyon kaynaklı lezyonlar ortaya çıkmasına neden olur. Şekil 1.1'de normal bir sinir hücresi ve şekil 1.2'de MS nedeniyle miyelin kılıfı zarar görmüş sinir hücresi gösterilmiştir.



Şekil 1.1: Sinir hücresinin yapısı



Şekil 1.2: MS nedeniyle hasar görmüş miyelin kılıflar.

MS'in SSS üzerindeki hasarına bağlı olarak, kimileri sık kimileri ise seyrek görülen çeşitli belirtiler ortaya çıkar [6]:

Tablo 1.1: MS'te ortaya çıkan belirtiler

Sık Görülen Belirtiler	**Seyrek Görülen Belirtiler**
Yorgunluk	Konuşma problemleri
Yürüme güçlüğü	Yutma problemleri
Uyuşukluk veya karıncalanma	Kontrol dışı titreme
Kas spazmları	Nöbetler
Güçsüzlük	Solunum problemleri
Görme problemleri	İşitme kaybı
Baş dönmesi ve vertigo	
Mesane problemleri	
Cinsel güç kaybı	
Bağırsak sorunları	
Ağrı ve kaşıntı	
Bilişsel değişimler	
Duygusal değişimler	
Depresyon	

MS'in klinik belirtileri ve seyri, hastadan hastaya değişkenlik gösterir; çoğu hastada, başlangıçta birkaç gün veya hafta devam eden nörolojik bozukluklar (ataklar olarak adlandırılır) görülür. Bu aşamada, manyetik rezonans görüntüleme (MRG) ile MS'i düşündürten

semptomatik veya sessiz (asemptomatik) lezyonlar gözlenebilir. Hastalığın bu aşamaları klinik izole sendrom (KİS) olarak isimlendirilir [7].

MS hastalığı, hastalığın seyrine göre, nörologların üzerinde hemfikir oldukları dört ana alt kategoriye ayrılabilir [8]:

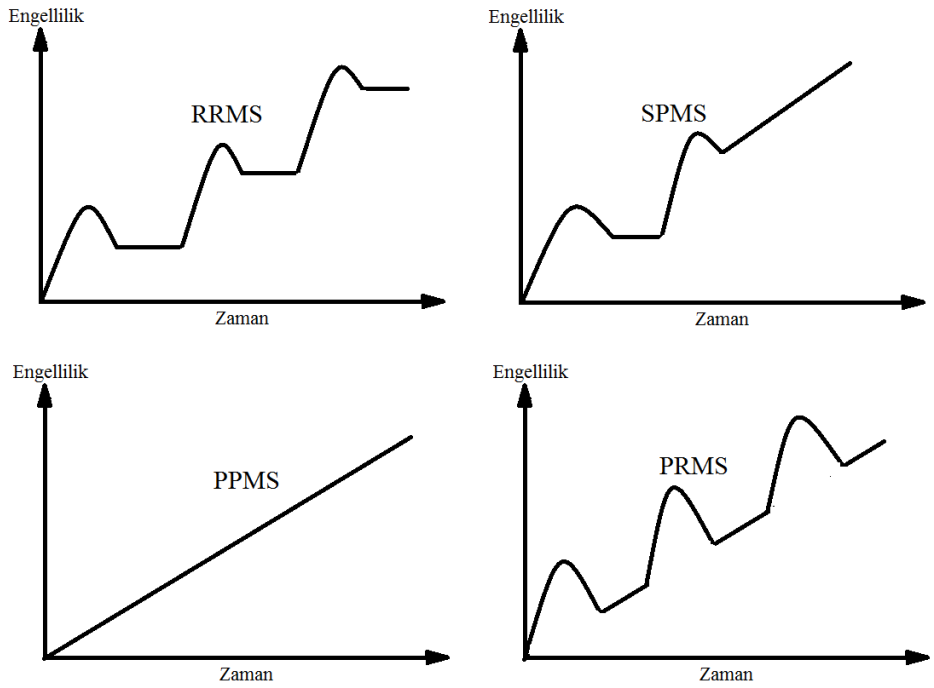
1. Ataklarla seyreden MS (RRMS): MS hastalarının yaklaşık %85'ini etkileyen en sık görülen türüdür. Belirtilerin yoğunlaşması ve ardından gelen düzelme periyodları şeklinde seyreder. Ataklar arasında hastalıkta ilerleme görülmez.

2. İkincil progresif seyreden MS (SPMS): RRMS görülen kimi hastalarda ortaya çıkar. Hastalık seyri periyodlarla veya periyodlar olmaksızın kötüye gidebilir veya semptomların şiddeti azalabilir.

3. Birincil progresif seyreden MS (PPMS): MS hastalarının yaklaşık % 10'unu etkiler. Semptomlar başlangıçtan itibaren aşamalı olarak kötüleşir. Ataklar veya düzelmeler yoktur fakat nadir durağanlıklar görülebilir. MS'in bu türü, hastalığın tedavi edilmesinde kullanılan ilaçlara karşı daha dirençlidir.

4. Progresif ataklarla seyreden MS (PRMS): MS'in çok sık görülmeyen, hastaların yaklaşık %5'ini etkileyen formudur. Başlangıçtan itibaren progresiftir ve kötüleşme belirtileri ataksız ve sürekli olarak artar. İyiye gitme periyodları yoktur.

Şekil 1.3'te MS'in türüne göre zaman içerisinde hastada meydana getirdiği engellilik durumu grafiklerle verilmiştir.



Şekil 1.3: MS türlerinin zaman içerisindeki ilerlemeleri.

MS teşhisi için belirli bir tanısal test bulunmamaktadır [9]. 2000 yılında Amerikan ulusal Multipl Skleroz Topluluğu ve Uluslararası Multipl Skleroz Dernekleri Federasyonu ortaklığında düzenlenmiş olan uluslararası panelde, MS tanısı için belirli kriterler önerilmiştir. Panel sonucunda önerilen bu kriterler, paneli yöneten W. Ian McDonald'ın adı ile McDonald kriterleri olarak adlandırılmıştır [10]. Bu kriterler daha sonra 2005 [11], 2010 [12] ve 2017 [13] yıllarında güncellenerek günümüzde kullanılan tanı yöntemlerinin oluşması sağlanmıştır.

Günümüzde MS teşhisi, şu üç bulgunun varlığında geçerlilik kazanmaktadır:

1. Merkezi sinir sisteminin beyaz madde olarak isimlendirilen kısmında en az iki farklı lezyona rastlanması.

2. Hastalık seyrinde en az iki farklı fazın görülmesi (zamana yayılma kriteri)

3. Merkezi sinir sisteminde kronik inflamasyon

MS ömür boyu devam eden, gelişim şiddeti değişken ve tahmin edilemez bir hastalıktır. KİS görülen bir hastaların %80'ine daha sonradan kesinleşmiş MS teşhisi konulmakla birlikte; KİS, müdahaleye başlamak için yeterli bir ölçüt olarak görülmemekte ve yukarıda bahsedilen bulguların ortaya çıkması beklenmektedir [14]. MS'in SSS üzerindeki etkisi geri onarılamaz

olduğundan, erken teşhis ve acilen müdahaleye başlanması önem kazanmaktadır. KİS görülen bir hastaya kesin MS tanısı konulması için uygulanması gereken yukarıda bahsedilen prosedürler, gerek zaman gerekse maliyet açısından oldukça verimsizdir. Bu nedenle MS teşhisinde gerek daha hızlı sonuç veren, gerekse düşük maliyetli uygulamalara ihtiyaç duyulmaktadır. Bu amaca yönelik çalışmalarda, son zamanlarda beyindeki nöronların faaliyetleri sonucu ortaya çıkan elektriksel aktivitenin kayıt edilmesi prensibine dayanan elektroansefalografi (EEG) önem kazanmaya başlamıştır. MS tanısında EEG kullanımı son zamanlarda önem kazanmaya başlamakla birlikte, yapılan çalışmaların sayısı oldukça azdır.

Leocani ve diğ. MS hastalığında EEG sinyalindeki bağlantısallığı, bilişsel bozulma ve MR görüntülerinden elde edilen lezyon yükleriyle destekleyerek ele almıştır [15]. 28 MS hastası ile yapılan çalışmada, 20 kanaldan 10'ar dakikalık dinlenme durumu EEG'si kaydedilmiştir. 1'er saniyelik gürültüsüz EEG bölümlerinden FFT gücü ve bağlantısallık hesaplanmış ve 22 kontrol katılımcısı ile karşılaştırılmıştır. Hastalar ayrıca MRG ve nörofizyolojik muayeneye tabi tutulmuşlardır. Kontrol katılımcıları ile karşılaştırıldığında; MS hastalarının bazı beyin bölgelerde theta gücünün arttığını, theta bandı bağlantısallığının ise azaldığını; ayrıca alfa bant bağlantısallığının da yerel ve uzun mesafe bağlantılarında azaldığı sonucunu gözlemlemişlerdir.

Fuhr ve diğ, MS'in seyri ile hastalara uyarılmış potansiyellerin değişimi arasındaki ilişkiyi ölçmek için görsel ve motor uyarılmış potansiyellerden yararlanmıştır [16]. RRMSS ve SPMS hastalarından oluşan 30 kişiyle yapılan çalışmada, EDSS skorları ile uyarılmış potansiyeller, hastalığın başlangıcında ve sırasıyla 6, 12 ve 24 ay sonra ölçülmüştür. İstatistiksel analiz yöntemi olarak Spearman sıra korelasyonu kullanılmıştır. Çalışma sonucunda uyarılmış potansiyellerin, EDSS skorları ile her 4 ölçüm için de ilişkili olduğu sonucuna varılmıştır.

Lenne ve diğ. RRMS hastaları ve sağlıklı katılımcıların yer aldığı çalışmada; dinlenme durumunda kaydedilmiş EEG sinyallerini kullanarak, delta, theta, alpha, beta ve gamma bantlarının bağlantısallıklarını ve bipolar EEG çiftlerini kullanarak karşılıklı bilgi (mutual information) parametrelerini karşılaştırmıştır [17]. Çalışma sonucunda; MS hastaları ile sağlıklı katılımcıların bağlantısallık indekslerinde herhangi bir farklılığa rastlanmamıştır. Diğer taraftan, MS hastalarının, yarımküreler arası ve sağ yarım küre bakımından kontrol katılımcılarına göre daha düşük karşılıklı bilgiye sahip oldukları sonucuna varılmıştır. Ayrıca,

hastalığın devam süresi arttıkça yarımküreler arası karşılıklı bilginin belirgin bir şekilde azaldığı görülmüştür.

Gschwind ve diğ., dinlenme anında EEG sinyalindeki rastgele sapmaların bir işaretçi olabileceği bilgisinden yola çıkarak, milisaniyenin onda biri uzunluğundaki "mikro-durum" adı verilen zamansal sapmaların, RRMS hastalarında herhangi bir değişikliğe uğrayıp uğramadıklarını araştırmışlardır [18]. Çalışmanın diğer bir amacı da mikro-durumlar kullanılarak hastanın klinik özellikleri hakkında kestirimlerde bulunulup bulunulamayacağının belirlenmesidir. Çalışmada 53 RRMS hastası ve 49 sağlıklı kontrol katılımcısından, uyanık dinlenme durumunda 256 kanallı EEG kayıtları alınmıştır. Çalışma sonucunda, RRMS hastalarında mikro-durumlarının daha görünür hale geldiği ve süresinin de uzadığı belirlenmiştir. Buradan yola çıkılarak; MS hastalarına ait hastalık süresi, yıllık atak sıklığı, engellilik skoru, depresyon skoru ve bilişsel zayıflama hakkında kestirimlerde bulunulabileceğini göstermişlerdir.

Van Schependom ve diğ. MS'te görülen bilişsel engellilik ile EEG sinyallerinin bağlantısallıkları arasındaki ilişki üzerine yoğunlaşmışlardır [19]. 308 MS hastasıyla yaptıkları çalışmada, hastalar bilişsel engelli ve bilişsel korunmuş olmak üzere iki sınıfa ayrılmışlardır. Farklı bağlantısallık (korelasyon, frekans alanı korelasyonu, kısmi korelasyon, tutarlılık, faz gecikme endeksi ve tutarlılığın sanal kısmı) parametrelerini kullanarak, oluşturulan ağlar üzerinde ağ analizleri yapmışlar ve iki grupta bu parametreleri karşılaştırmışlardır. Analizler sonucunda bilişsel engelli hastaların theta ve delta bağlantısallıklarının oldukça düşük olduğu ortaya çıkmıştır. Korelasyon, theta ve delta tutarlılığı ve frekans alanı korelasyonunda ise çok küçük farklılıklar görülmüştür.

Torabi ve diğ. ise, MS teşhisi için dikkat gerektiren görevlerin icrası sırasında kaydedilen EEG sinyallerinden yararlanmışlardır [20]. Hareket yönü ve renk parlaklığı algılama görevi sırasında kaydedilen EEG sinyalleri, orijinal halleri ve alt bantlara ayrılmış olarak iki farklı şekilde analiz edilmiştir. Araştırmacılar, EEG sinyalinin doğrusal olmayışından yola çıkarak, kestirimde kullanacakları öznitelikleri de doğrusal sinyalin doğrusal olmayan parametrelerini yansıtacak şekilde seçmişlerdir. Elde edilen sinyallerden; Lyapunov üssü, approximate entropy, sample entropy, Hurst üssü, fraktal boyutlar ve l-z complexity parametreleri, öznitelik olarak kullanılmak üzere çıkarılmıştır. Destek vektör makinaları ve k-NN sınıflandırıcılarıyla birlikte, her iki görev sırasında kaydedilen EEG sinyallerinin kullanıldığı sınıflandırma işlemleri

sonucunda; hareket yönü tabanlı ve renk parlaklığı tabanlı görevlerde sırasıyla % 93.08 ve %79.79 doğrulukla kestirim yapılmıştır.

MS hastalığının teşhisi veya MS hastalarının kendi içerisinde sınıflandırılması üzerine yapılmış olan çalışmalarda çoğunlukla dinlenme sırasında, aktif görev sırasında ve uyarılmış potansiyeller ile kaydedilmiş EEG sinyalleri kullanılmıştır. Dinlenme durumu EEG'lerinde genellikle bağlantısallık, korelasyon ve tutarlılık gibi parametreler ve kimi zaman da mikro-durum gibi zamansal parametrelerden yararlanılmıştır. Uyarılmış potansiyeller ve görev esnası EEG'leri kullanılarak yapılan kimi çalışmalarda sinyalden çıkarılan öznitelikler sınıflandırmada kullanılırken, kimi çalışmalarda ise bağlantısallık üzerinden sınıflandırma işlemi yapılmıştır.

1.1.TEZİN AMACI VE KATKILARI

Bu çalışmada, MS hastalığının teşhisi ve MS hastalarının kendi içerisinde bilişsel engelli/korunmuş olarak sınıflandırılması için dinlenme halindeki EEG sinyalleri kullanılmıştır. Orijinal EEG sinyalleri haricinde, bu sinyallerin görgül kip ayrışıtırma (GKA) kullanılarak bileşenlerine ayrıştırılmasıyla elde edilmiş olan sinyal bileşenleri de aynı amaçla kullanılmıştır. Çalışma kapsamında ayrıca; Farklı sınıflandırıcı türlerinin, EEG kanal seçiminin ve sınıflandırma için kullanılacak olan özniteliklerin seçiminin sınıflandırma doğruluğu üzerindeki etkileri incelenmiştir.

MS, zamanla şiddeti artan bir şekilde engelliliğe yol açan bir hastalık olduğundan, erken teşhis oldukça önemlidir. Fakat belirtilerin çok geniş bir yelpazede görülüyor olması teşhisi zorlaştırmaktadır. McDonald teşhis kriterleri göz önüne alındığında, lezyonların zamansal ve alansal yayılımlarının teşhis için büyük önem taşıdığı görülmektedir. Bu yayılmaların takibi ise ortalama üç ayda bir yapılan MRG taramaları ile izlenmektedir. Bu süre teşhis için zaman kaybı oluşturmaktadır. Bununla birlikte; MRG sonuçları kimi zaman yanlış yorumlanabilmekte ve bu da yanlış teşhise neden olabilmektedir. Bu nedenlerden dolayı, MS teşhisinin farklı yöntemlerle de desteklenmesi gerektiği açıktır.

Bu çalışmada, MS teşhisinde zaman kaybını önlemek, maliyeti azaltmak ve yanlış teşhislerin önüne geçebilmek için gerekli olan farklı teşhis araçlarından biri olarak EEG sinyallerinin kullanılması önerilmiştir. EEG sinyal kaydı düşük maliyetli, hızlı ve güvenli bir fizyolojik veri toplama aracıdır. Çalışmada, MS hastaları ve sağlıklı katılımcılardan dinlenme durumunda

kaydedilmiş olan EEG verileri kullanılarak; MS/sağlıklı sınıflandırması ve MS hastalarının bilişsel engelli/korunmuş sınıflandırmasının yapılması amaçlanmıştır.

Bunların yanında, MS hastalığında EEG sinyalleri ile çalışılırken: EEG kanal seçiminin, kullanılan özniteliklerin, kullanılan sınıflandırıcıların, kullanılan öz kip seçim yöntemlerinin, kullanılan öz kiplerin ve sinyali alt bileşenlere ayırarak kullanmanın, sınıflandırma doğruluğu üzerindeki etkileri araştırılmıştır. Çalışmanın bu kısmından elde edilmiş olan verilerin, gelecekteki benzer çalışmalara yol gösterici olması amaçlanmıştır.

2. GENEL KISIMLAR

2.1.MS'TE ERKEN TEŞHİSİN ÖNEMİ VE HASTALIĞIN SEYRİNİN TAKİBİ

MS tanısında kullanılan tetkikler, primer tetkikler, sekonder tetkikler ve diğer tetkikler olmak üzere üç gruba ayrılabilir. Primer testler, McDonald kriterlerinin sağlanıp sağlanmadığının tespiti açısından önemlidir. Primer testler ile kesin MS tanısı konulamayan hastalara sekonder ve diğer testler sırasıyla uygulanır. MS teşhisinden kullanılan tetkikler şu şekilde gruplanabilir [21]:

2.1.1. Primer testler

- ✓ Kan tetkikleri
- ✓ MRG
- ✓ BOS analizleri

2.1.2. Sekonder testler

- ✓ Uyarılmış potansiyeller (Görsel, somatosensoryel)
- ✓ Optik Koherens Tomografi
- ✓ Ürodinami
- ✓ Nörokognitif testler

2.1.3. Diğer testler

- ✓ Biopsi (Deri, lenf modülü, beyin-leptomeninks, diğerleri)
- ✓ Angiografi (serebral, fluorescein, MR)
- ✓ Elektrofizyoloji (Sinir iletimleri, EMG)
- ✓ Akciğer grafisi (hiler adenopati)
- ✓ Diğerleri (Schirmer testi, tükrük bezi sintigrafisi, SPECT, Kveim testi, Gallium scan gibi)

2.1.4. MS takibinde kullanılan Bilişsel ve Fonksiyonel Ölçekler

MS'in merkezi sinir sistemindeki nöronları tahrip etmesi sonucu, hastalarda bilişsel ve fonksiyonel bozulmalar ortaya çıkabilir. Bu bozulmalar, hekimlere hastalığın seyri hakkında önemli bilgiler verir. Hastalarda meydana gelen bu bozulmaların derecesinin ölçülmesi için geliştirilmiş birçok ölçek bulunmaktadır. Bu ölçeklerden en çok kullanılan ikisi; bilişsel bozuklukların ölçülmesinde kullanılan *MS için nöropsikolojik tarama ölçeği (NSBMS)* ve fonksiyonel bozuklukların ölçümünde kullanılan *genişletilmiş engellilik durumu ölçeğidir (EDSS).*

NSBMS, MS'te en sık görülen bilişsel hasar türlerinin değerlendirilmesini sağlayan dört alt alandan oluşur: işitme işleme hızı, çalışma hafızası, sözel akıcılık ve motor işlevler. NSBMS skoru, hastanın başarılı olduğu test sayısı baz alınarak hesaplanır [22]. Test skoru 0 veya 1 olan hastalar bilişsel bozulmuş, 3 veya 4 olan hastalar ise bilişsel korunmuş olarak değerlendirilir. Skoru 2 olan hastalar ise herhangi bir sınıfa dâhil edilmez.

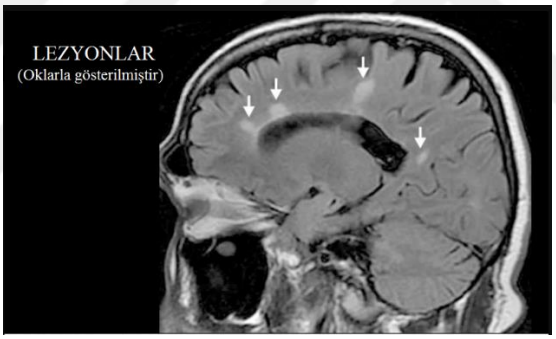
1955 yılında J. F. Kurtzke tarafından MS hastalarının fonksiyonel engellilik durumlarını ölçmek için geliştirilmiş olan engellilik durum ölçeği (DSS) [23], 1983 yılında güncellenmiş ve şimdiki halini (EDSS) almıştır [24]. Ölçek, engellilik durumunu; piramidal fonksiyonlar, beyin fonksiyonları, beyin sapı fonksiyonları, duyusal fonksiyonlar, bağırsak ve mesane fonksiyonları, görsel fonksiyonlar, mental fonksiyonlar ve diğer fonksiyonlar olmak üzere değerlendirir. Farklı fonksiyon kayıpları için değişen derecelerde puanlama yapılarak bir toplam puan elde edilir. Sonuç 0-10 aralığında 0,5 puan aralıklarla değişen bir skalada değerlendirilir. Skalada 0 puan "normal" olarak değerlendirilirken; 10 puan "MSe bağlı ölüm" olarak değerlendirilir. EDSS skorunun SSS'deki lezyon sayısıyla doğru orantılı olarak arttığı bilinmektedir [24].

2.1.5. MS'te erken teşhisin önemi

MS teşhisi için günümüzde de kullanılmakta olan McDonald kriterleri, MRG'nin teşhiste birincil parametre olarak kullanılmasını önermektedir. Buna göre 3-6 ay aralıklarla çekilen MR görüntülerinde, lezyonların sayısının zamanla artıyor olması ve yeni lezyonların SSS'nin farklı bölgelerinde ortaya çıkıyor olması bir teşhis kriteri olarak önerilmiştir. Bu nedenle klinik olarak kesinleşmiş MS tanısı kimi zaman yıllar almaktadır. KİS görülen bir hastaya ait MRG'deki değişiklikler ilk anda herhangi bir tanısal özellik ihtiva etmemektedir. Örneğin

demiyelinizasyon başlangıcı görülen bir hastanın (optik nörosit, serebral sendrom veya omurilik sendromu gibi), kesinleşmiş MS tanısı konulması için zamanla değişimler göstermesi beklenir [25].

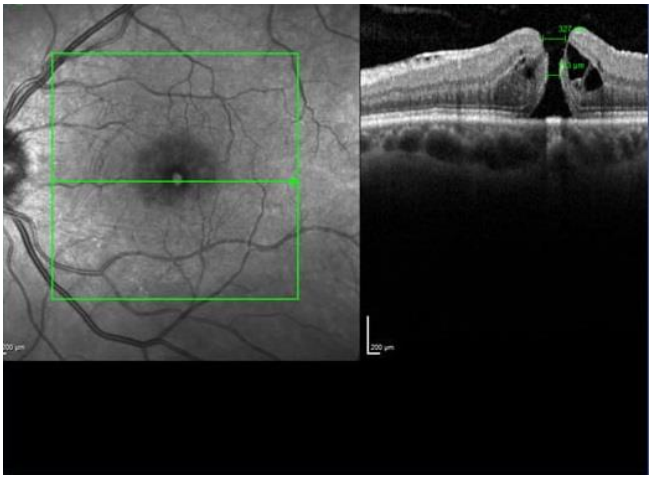
MS gibi şiddetli ve hastada engellilik durumu oluşturan belirtiler gösteren hastalıklarda, belirtilerin altında yatan mekanizmalar tam olarak anlaşılıncaya kadar hasta kontrol altında tutulmaktadır. Bu durum kişinin sosyal ve ekonomik hayatını olumsuz yönden etkilerken; diğer taraftan da sağlık hizmeti giderlerini arttırmaktadır[26]. MS'te erken müdahale hayati önem taşımaktadır. Uygun yaşam tarzı müdahaleleri ve tedavilere başlanması hastalığın aktivitesini azaltırken, olası farklı tedavilere geçilmesi için de zemin oluşturacaktır [27]. MS'in erken teşhisinin sağlayacağı faydaların çokluğu, araştırmacıları farklı teşhis yöntemleri aramaya itmiştir. MRG, BOS ve uyarılmış potansiyeller gibi yoğun olarak çalışılan teşhis yöntemlerine, son zamanlarda elektroansefalografi (EEG) de eklenmiştir.



Şekil 2.1: MS'te lezyonların MRG ile görüntülenmesi [28].



Şekil 2.2: BOS analizi [29].

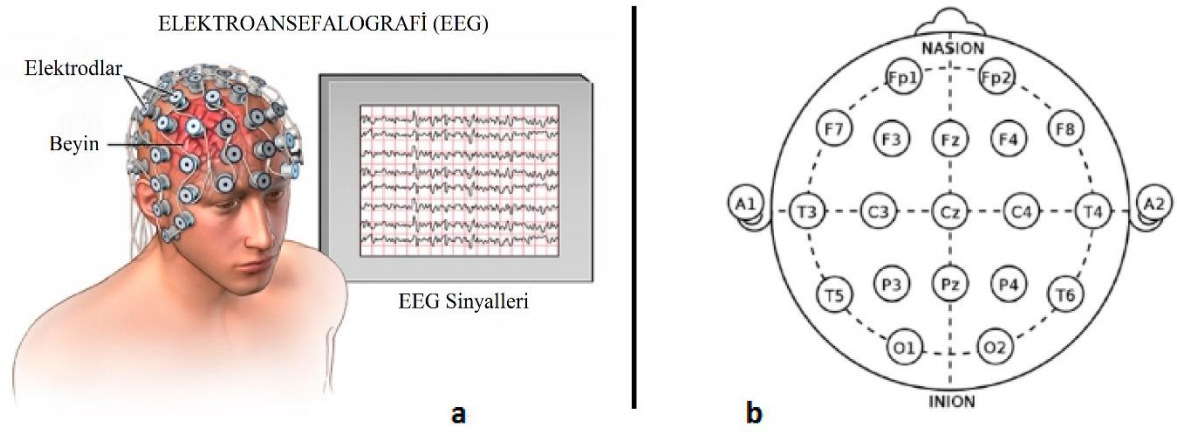


Şekil 2.3: OKT ile retina arkasının görüntülenmesi [30].

2.2.ELEKTROANSEFALOGRAFİ

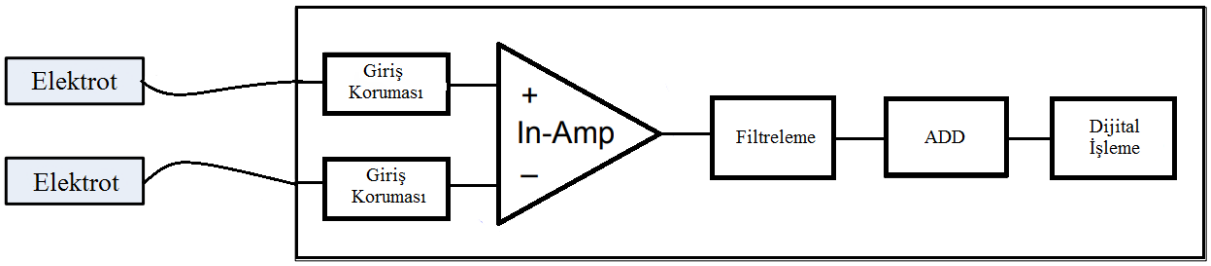
Elektroansefalografi (EEG), beyindeki nöronların faaliyetleri sonucu ortaya çıkan elektriksel aktivitenin kayıt edilmesi işlemidir [31]. Klinik olarak EEG, kafa derisi yüzeyinde farklı bölgelere yerleştirilen elektrotlar aracılığı ile beynin anlık aktivitelerinin, genellikle 20-40 dakikalık zaman dilimi boyunca kayıt altına alınması işlemidir. Nörolojide EEG'nin birincil kullanım alanı üzerinde fark edilir anormallikler oluşturması nedeniyle epilepsidir [32]. EEG'nin ikincil klinik kullanım alanları ise koma, beyin anormallikleri, beyin ölümü ve uyku bozukluklarının teşhisidir. Son zamanlarda EEG, beyin-bilgisayar ara yüzü uygulamalarında da sıklıkla kullanılmaya başlanmıştır.

Geleneksel EEG, elektrotların iletken bir jel veya macun ile kafa derisinin yüzeyine tutturulması ve bu yüzeyden elektriksel sinyallerin kaydedilmesi şeklinde uygulanır. Elektrotların kafa yüzeyindeki konumları genellikle uluslararası 10-20 sistemine göre dizilir [33]. Bu elektrotların her biri bir EEG kanalıdır ve ayırt edilebilmeleri için isimlendirilmişlerdir. Günümüzde EEG kanal sayısı 512 kanala kadar çıkmakla birlikte, en sık kullanılanları 32 ve 64 kanallı olanlarıdır.



Şekil 2.4: (a) Bir EEG kaydının temsili gösterimi (b) Uluslararası 10-20 elektrot dizilim düzeni [34].

Elektrokardiyogramın aksine, EEG sinyallerinin belirli bir şekli yoktur. Kişinin o anki duyusal ve motor işlevlerine göre farklı ritim ve şekillere sahip olabilir. Elektrotlar aracılığı ile alınan sinyaller, mikro voltlar (μV) ile ifade edilecek kadar küçük genliklere sahiptirler. Bu nedenle öncelikle bir kuvvetlendiriciden geçirilerek diğer işlemler için yeterli genliğe çıkarılırlar. Ardından, kullanılacağı işleme göre değişmekle birlikte, genellikle [0,5 – 45] Hz aralığında bir bant geçiren filtreleme işlemine tabi tutulurlar. Filtreleme ardından analog sinyaller, elektronik ortama aktarılabilmesi için bir analog-dijital dönüştürücüden geçirilerek dijital hale getirilirler. Dijital sinyal bilgisayarlar aracılığı ile kayıt edildikten sonra, dijital sinyal işleme uygulamaları için hazır hale gelmiş olur.



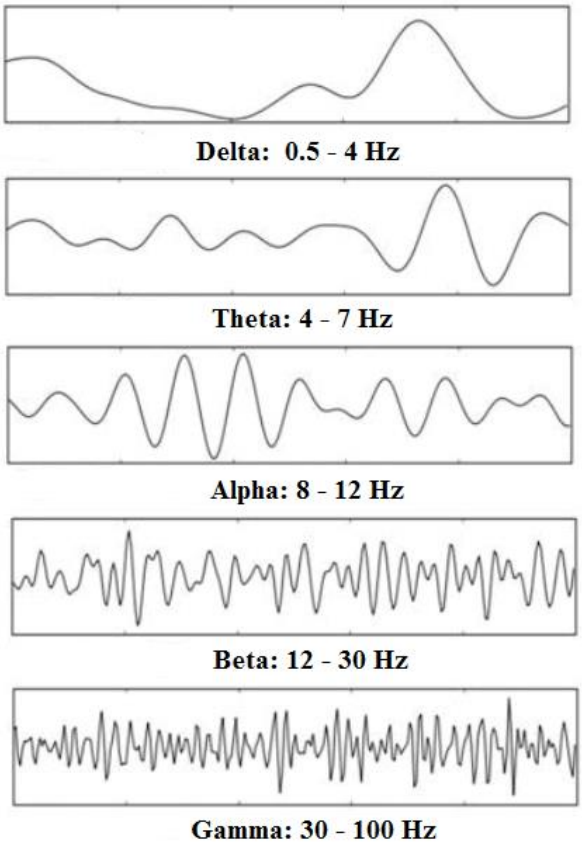
Şekil 2.5: EEG cihazına ait elektronik devre blok diyagramı.

EEG genellikle ritmik aktivite ve geçici aktivite olarak iki kısımda incelenir. Ritmik aktiviteler frekansına göre alt bantlara bölünür. Bu frekans bantları, belirli biyolojik aktivitelerin işaretçileridir. EEG sinyalleri bu açıdan beş alt bantta incelenir [35]. Aşağıda bu bantlar ve işret ettikleri normal ve patolojik durumlar verilmiştir:

Tablo 2.1: EEG alt Bandlarının normal ve patolojik işaretçileri.

Tür	Frekans (Hz)	Normal	Patolojik
Delta	0.5 – 4 Hz	✓ Yetişkin hafif dalga uykusu ✓ Bebeklerde ✓ Sürekli dikkat gerektiren görevler	✓ Korteksaltı lezyonlar ✓ Difüze lezyonlar ✓ Derin orta hat lezyonları ✓ Beynin su toplaması
Theta	4 – 7 Hz	✓ Küçük çocuklarda ✓ Daha büyük çocuklarda ve yetişkinlerde uyuşukluk veya uyarılma ✓ Serbest dinlenme	✓ Fokal korteksaltı lezyonlar ✓ Metabolik ensefalopati ✓ Derin orta hat bozuklukları ✓ Bazı beyin su toplama durumları
Alpha	8 – 12 Hz	✓ Rahatlama/Gevşeme ✓ Gözleri kapama	✓ Koma
Beta	12 – 30 Hz	✓ Çalışma/alarm durumu ✓ Aktif, yoğun veya endişeli düşünme, aktif yoğunlaşma	✓ Benzodiazepinler
Gamma	30 – 100+	✓ Tanınan nesnelerin, seslerin veya dokunsal hislerin kısa süreli hafıza eşleşmesi sırasında ✓ Farklı iki duyuyu birleştiren algı sırasında (ses ve görme gibi)	✓ Bilişsel gerilemeye bağlı olarak gama bandı aktivitesinde azalma olabilir

Şekil 2.6'da birbirlerine göre farklılıklarının görülebilmesi amacıyla EEG alt bantları bir arada verilmiştir.



Şekil 2.6: EEG alt bantları.

3. MALZEME VE YÖNTEM

Bu çalışmada, dinlenme durumundaki EEG sinyalleri kullanılarak MS tespiti yapmak amaçlanmıştır. Çalışmanın diğer bir amacı ise yine EEG sinyallerinden yararlanarak MS hastalarının bilişsel engelli/bilişsel korunmuş şeklinde sınıflandırılmasıdır. Bu sınıflandırmalar yapılırken, gelecekte yapılacak benzer çalışmalara ışık tutması açısından;

- EEG kanallarının sınıflandırma doğruluğuna etkileri açısından karşılaştırması
- Sınıflandırmada kullanılan özniteliklerin sınıflandırma doğruluğuna etkileri açısından karşılaştırılması
- Orijinal EEG sinyalleri ile GKA kullanılarak bileşenlerine ayrıştırılmış EEG sinyallerinin kullanılmasının, sınıflandırma doğruluğuna etkileri açısından karşılaştırılması
- GKA sonucu elde edilen ÖKF'lerin seçimi için kullanılan yöntemlerin, sınıflandırma doğruluğuna etkileri açısından karşılaştırması
- GKA sonucu elde edilen ÖKF'lerin sınıflandırma doğruluğuna etkileri açısından karşılaştırılması

Çalışmaları da yapılmıştır. Ayrıca sınıflandırma işlemlerinden dört farklı tip sınıflandırıcı kullanılmış ve sınıflandırma performansı açısından karşılaştırılmışlardır. Şekil 3.1'de çalışmaya ait akış diyagramı verilmiştir. Diyagramdan görüleceği gibi, iki çalışma paralel yürütülmüş, bir taraftan EEG sinyalleri GKA kullanılarak bileşenlerine ayrıldıktan sonra öznitelik çıkarma işlemi yapılırken; diğer taraftan doğrudan orijinal EEG sinyalleri üzerinden öznitelik çıkarma işlemi yapılmıştır. Akış diyagramında "ön sinyal işleme" adımından "öznitelik çıkarma" adımına giden doğru, bu süreci temsil etmektedir.



Şekil 3.1: Çalışmanın blok diyagramı.

3.1.ÇALIŞMADA KULLANILAN EEG VERİSİ VE ÖN İŞLEME

Çalışmada kullanılan Multipl Skleroz hastalarına ait EEG verisi, Melsbroek Edmus veri tabanından sağlanmıştır. 164 MS hastasından Brainlab Measure Station model cihaz kullanılarak 21 kanaldan, gözler kapalı dinlenme halinde kaydedilmiştir. Kayıt sırasında 10-20 elektrot konumlama sistemi kullanılmış ve örnekleme frekansı olarak 250 Hz seçilmiştir. Kayıt sırasında kullanılan elektrotlar kanal numaralarına göre sırasıyla: $F_{P1}, F_{P2}, F_7, F_3, F_Z, F_4, F_8, T_3, C_3, C_Z, C_4, T_4, T_5, P_3, P_Z, P_4, T_6, O_1, O_2, A_1, A_2$ elektrotlarıdır. EEG sinyalleri kayıt sonrasında, EEG için önemli bantların yer aldığı frekans aralığı olan [1, 30] Hz aralığında bant geçiren filtre kullanılarak filtrelenmiştir. Bununla birlikte, güç hattından kaynaklanan gürültülerin bastırılması için de 50 Hz'lik bir bant durduran filtre uygulanmıştır. Her sinyal için DC bileşenler sinyalden çıkarılmış ve sinyal ortalamaları yaklaşık sıfıra eşitlenmiştir.

Kullanılan veri, EEG sinyalleri haricinde; hastalara ait EDSS ve NSBMS skorları, yaş, MS başlangıç tarihi, hastalara ait eğitim durumu, EEG kayır tarihleri ve bu tarihlerdeki bilişsel engellilik durumu gibi bilgiler de içermektedir.

Çalışmada kullanılan sağlıklı EEG verileri ise, PhysioNet veri tabanından sağlanmıştır [36]. Kayıtlar 109 sağlıklı katılımcıdan, dinlenme anında gözler kapalı bir şekilde alınmış, kayıt süresince katılımcıların uyumaması sağlanmıştır. Bu kayıt 64 kanal üzerinden yapıldığından; öncelikle MS verisinde kullanılan kanallarla aynı konumdaki kanallar seçilmiş ve tüm işlemler bu kanallar üzerinden yapılmıştır. MS verisine benzer ön işleme teknikleri, sağlıklı sinyaller için de uygulanmıştır.

3.2.GÖRGÜL KİP AYRIŞTIRMA

Görgül kip ayrıştırma (GKA), doğrusal ve durağan olmayan sinyallerin yaklaşık harmoniklere ayrıştırılmasında kullanılan, tamamen veri güdümlü bir sinyal işleme aracıdır [37]. Bu ayrıştırma aracında, sinyalin herhangi bir kısmının, birbirinden farklı frekanslara sahip birçok salınım kipinin toplamından oluştuğu kabul edilir. İşlemin çıkışında yavaş değişen genlik ve frekanslara sahip öz kip fonksiyonları (ÖKF) adı verilen alt sinyaller elde edilir. Elde edilen bu sinyaller şu iki koşulu sağlıyor olmalıdır: (1) Sinyaldeki ekstremumların sayısı ile sıfır geçişlerinin sayısı eşit olmalı veya bu sayılar arasındaki fark en fazla bir olmalı. (2) Herhangi bir noktasında, yerel maksimumlarla hesaplanan üst zarf ve yerel minimumlarla hesaplanan alt zarfın ortalama değeri sıfır olmalıdır.

GKA, aşağıdaki döngü ile ilerler;

1. Öncelikle *x(n)* sinyaline ait tüm yerel minimum ve yerel maksimum noktalar bulunur. Bulunan yerel minimumlar interpole edilerek sinyale ait alt zarf (Z_{ALT}); yerel maksimumlar interpole edilerek sinyale ait üst zarf ($Z_{ÜST}$) elde edilir.

2. Elde edilen alt ve üst zarfların ortalamaları hesaplanır.

$$m(n) = \frac{Z_{ALT}(n)+Z_{ÜST}(n)}{2} \tag{3.1}$$

3. Hesaplanan ortalama, orijinal sinyalden çıkarılır. Kalan sinyal *h(n)*, ÖKF olma koşullarını sağlıyorsa, ÖKF olarak kaydedilir ve giriş sinyalinden çıkarılarak yeni giriş sinyali elde edilir.

$$h(n) = x(n) - m(n) \tag{3.2}$$

4. ÖKF olma koşulları sağlanmıyorsa, ilk adıma dönülür ve *h(n)* için adımlar ÖKF olma koşulları sağlanana kadar devam ettirilir.

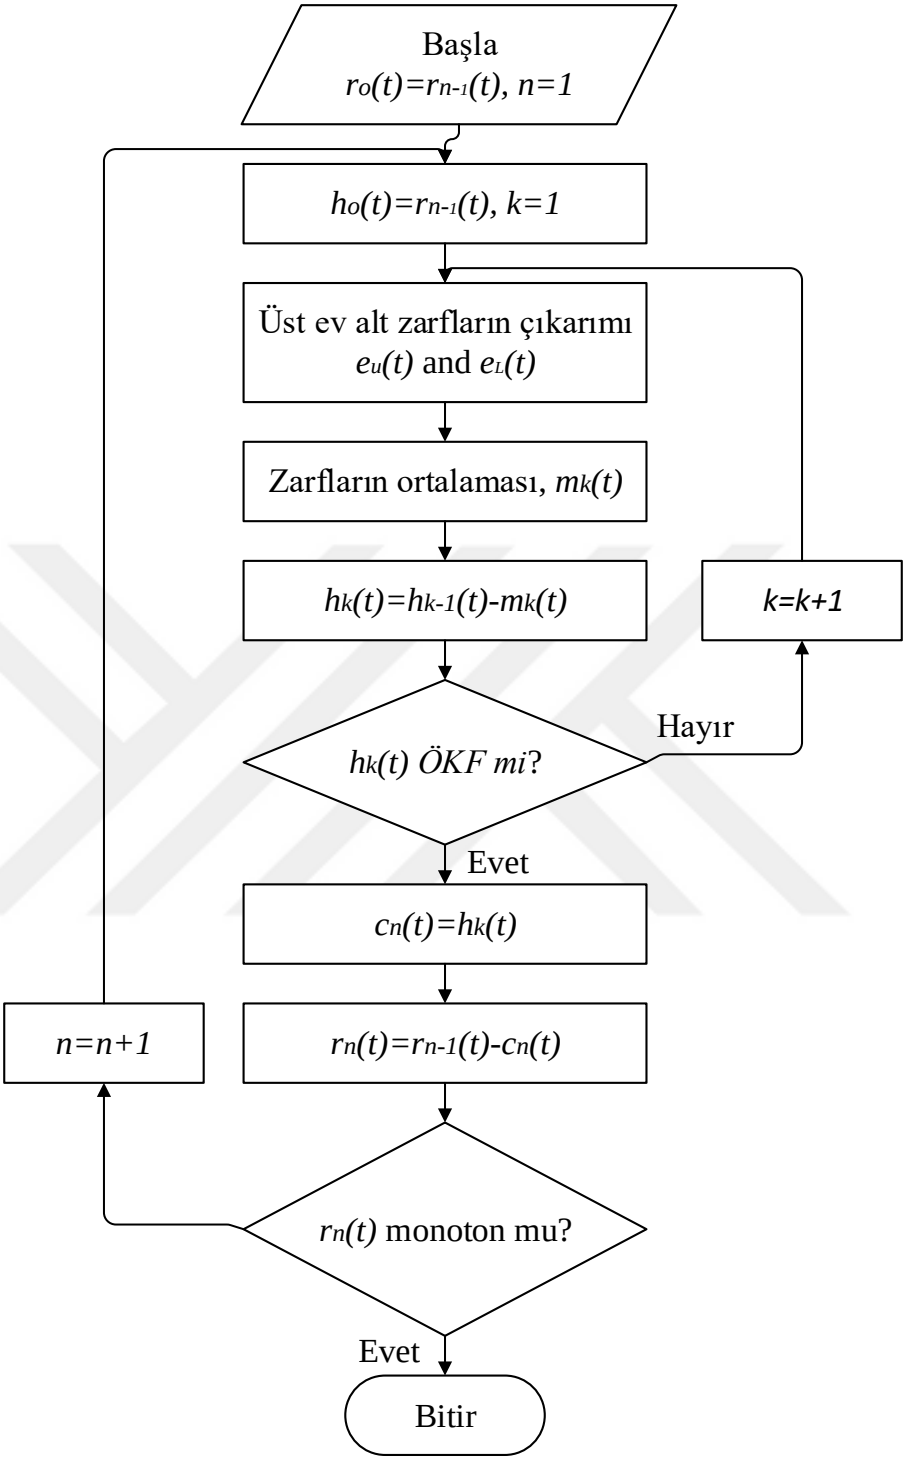
5. Bir ÖKF, $\varphi_i(n)$, elde edildiğinde bu ÖKF sinyalden çıkarılır ve kalan sinyal yeni giriş sinyali olarak girişe verilir. Bu işlemlere, kalan sinyal monoton fonksiyon halini alana ve artık yeni ÖKF'ler elde edilemeyinceye kadar devam edilir.

$$x(n) = x(n) - \varphi_i(n) \tag{3.3}$$

6. GKA işlemi sonucu elde edilen ÖKF'lerin toplamı orijinal sinyali verir.

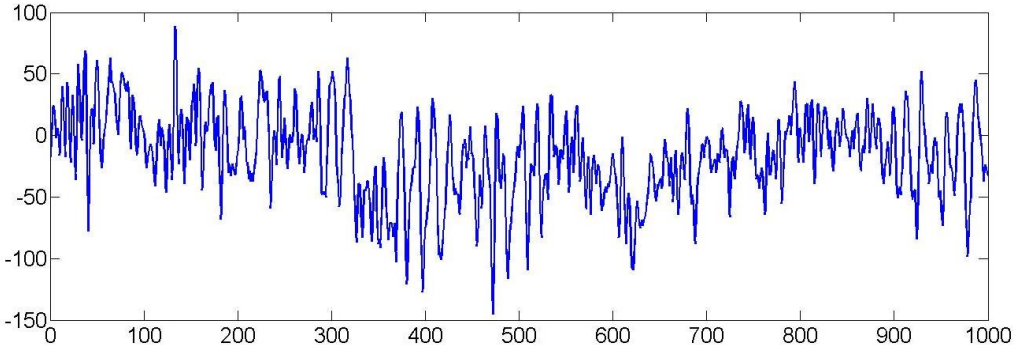
$$x(n) = \sum_{i=1}^{L} \varphi_i(n) + r(n) \tag{3.4}$$

Eşitlikte $\varphi_i(n)$ i. ÖKF ve $r(n)$ tüm ÖKF'ler elde edildikten sonra geriye kalan sinyaldir. GKA algoritması şekil 3.2'de akış diyagramı şeklinde gösterilmiştir.

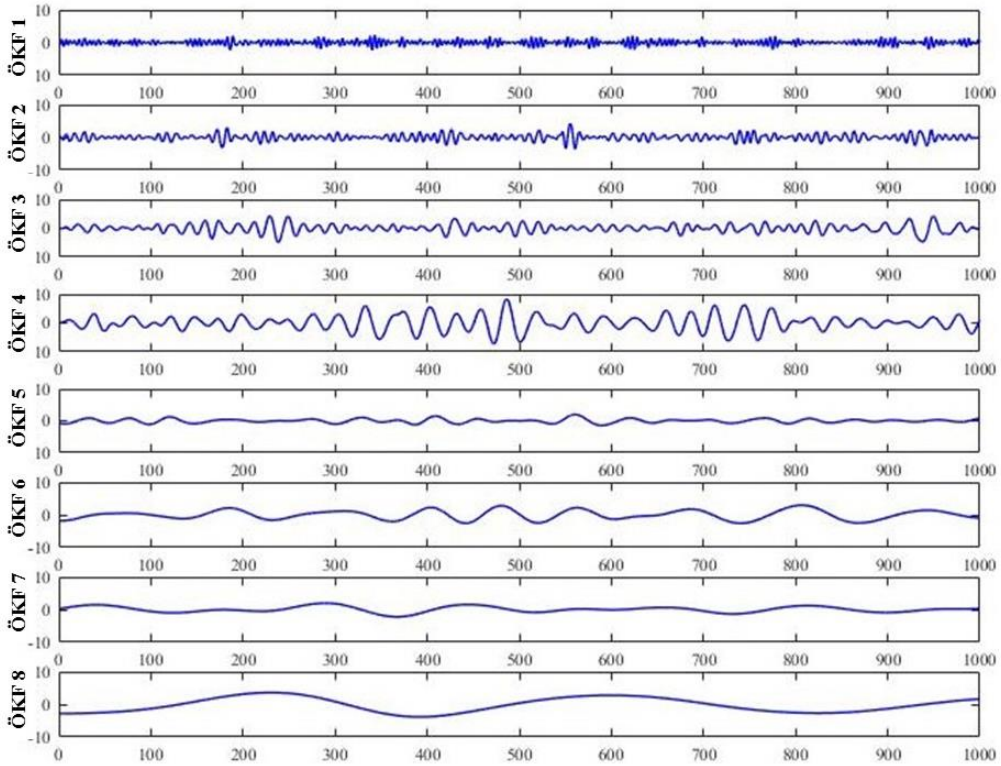


Şekil 3.2: GKA akış diyagramı.

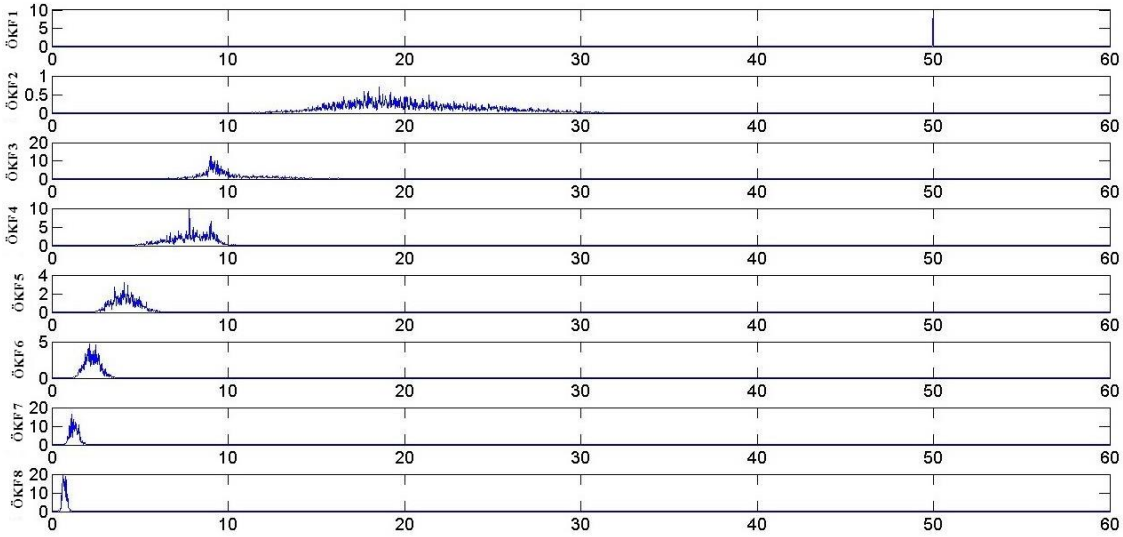
Şekil 3.3'te bir EEG sinyali ve şekil 3.4'te bu sinyalden GKA kullanılarak elde edilmiş ÖKF'ler verilmiştir.



Şekil 3.3: 1000 örneğe sahip bir EEG sinyali.



Şekil 3.4: 1000 örnekli bir EEG sinyalinden elde edilmiş olan ÖKF'ler.



Şekil 3.5: 1000 örneğe sahip EEG sinyali için ÖKF'lerin güç yoğunluk spektrumları.

Şekil 3.4'te, şekil 3.3'te verilen EEG sinyaline ait ÖKF'lerden ilk 10 tanesi verilmiştir. ÖKF 1 olarak isimlendirilmiş olan ilk ÖKF, diğerlerine göre daha yüksek frekans bileşenlerine sahiptir. Sonraki ÖKF'lerin frekanslarının gittikçe azaldıkları görülmektedir. Ayrıca farklı ÖKF'lerin farklı genliklere sahip oldukları, dolayısıyla sinyaldeki ağırlıklarının da farklı olduğu söylenebilir. Şekil 3.5'te ise bu ÖKF'ler ait güç yoğunluk spektrumları verilmiştir. ÖKF 1'in 50 Hz şebeke frekansında büyük bir bileşene sahip olduğu görülmektedir. ÖKF 2 yaklaşık olarak 12 – 30 Hz aralığındaki beta bandına karşılık geldiği de şekilden görülmektedir. ÖKF 3'ün 8 – 12 Hz aralığındaki alfa bandına, ÖKF 4 ve ÖKF 5'in 4 – 7 Hz aralığındaki theta bandına ve kalan ÖKF'lerin delta bandına karşılık geldikleri görülmektedir.

3.3.ÇOK DEĞİŞKENLİ GÖRGÜL KİP AYRIŞTIRMA

GKA tekniği, yalnızca reel değerlere sahip sinyallere uygulanabilecek şekilde tasarlanmıştır. Tekniğin kullanım alanının genişletilebilmesi için Tanaka ve Mandic tarafından kompleks değerli sinyallerle çalışabilecek bir GKA (KGKA) önerilmiştir [38]. Alfat ve diğ. ise aynı amaçla rotasyon-bağımsız GKA'yı (RB-GKA) önermişlerdir [39]. Fakat bu yöntem, zarfların yerel ortalamaları hesaplanırken yalnızca sinyalin kompleks kısmı kullanıldığı için doğruluk yeterince iyi değildir. Doğruluğun arttırılması için, Rilling ve diğ. tarafından sinyalin hem reel hem de kompleks kısmının zarf hesaplamada kullanıldığı iki değişkenli GKA (İD-GKA) önerilmiştir [40]. Önerilen bu yöntemin, RB-GKA'ya göre daha doğru kestirimde bulunduğu sonucuna varılmıştır. Diğer çok değişkenli GKA ise Rehman ve Mandic tarafından önerilmiştir

[41]. Giriş sinyaline ait yerel zarf ortalamalarının, üç boyutlu uzayda quaternion özelliği kullanılarak çok doğrultulu iz düşümlerle kestirildiği bu yönteme üç değişkenli GKA (ÜD-GKA) adı verilmiştir. Yöntem, üç değişkene sahip sinyallere ait ÖKF'lerin, üç değişkene ait ortak zarflar kullanılarak elde edilebilmesini sağlamıştır.

Çok değişkenli sinyallerin zarflarının elde edilebilmesi ve daha genel bir kullanım için, Rehman ve Mandic çok değişkenli GKA'yı (ÇDGKA) önermişlerdir [42]. ÇDGKA aşağıdaki gibi ifade edilebilir:

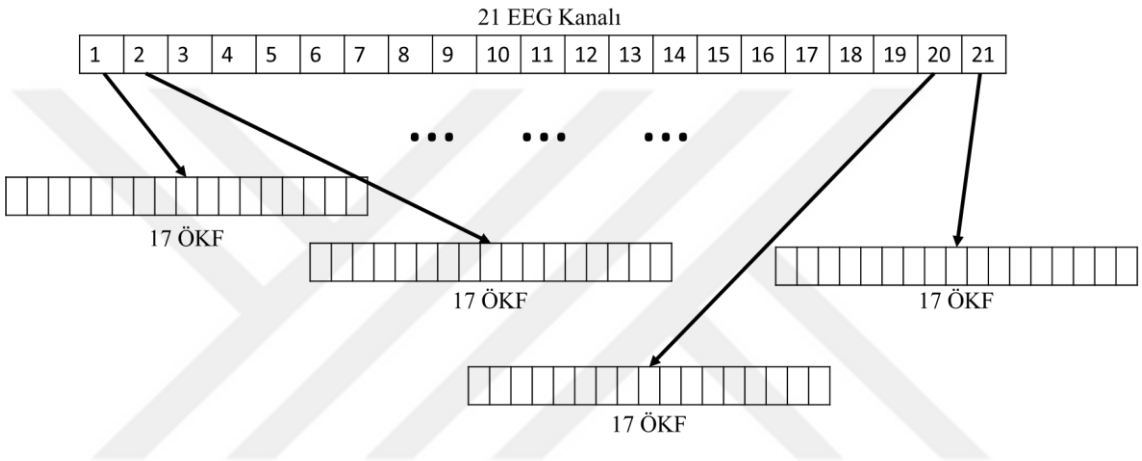
- *(n-1)* *n*-boyutlu bir vektör dizisini ele alalım; $\{v(t)\}_{t=1}^{t=T} = \{v_1(t), v_2(t), \dots, v_n(t)\}$, n bileşenli bir çok değişkenli sinyale karşılık gelmektedir. $\boldsymbol{x}^{\theta_k} = \{x_1^k, x_2^k, \dots, x_n^k\}$ ise $\theta^k = \{\theta_1^k, \theta_2^k, \dots, \theta_n^k\}$ açıları ile verilen yönlerdeki doğrultu vektörleri dizisidir.
- *(n-1)* boyutlu hiper-kürede uygun bir nokta kümesi seçilir.
- Tüm k değerleri için, $\boldsymbol{x}^{\theta_k}$ doğrultu vektörü boyunca $\{v(t)\}_{t=1}^{t=T}$ giriş sinyaline ait izdüşümü hesaplanır.
- Yansıtılmış $\{p^{\theta_k}(t)\}_{k=1}^{K}$ sinyal seti için, maksimum noktalara ait $t_i^{\theta_k}$ anları bulunur.
- $\{e^{\theta_k}(t)\}_{k=1}^{K}$ çok değişkenli zarf eğrileri elde etmek için $\left[t_i^{\theta_k}, v(t_i^{\theta_k})\right]$ interpolasyonu yapılır.
- K doğrultu vektörleri seti için, zarf eğrilerinin ortalaması hesaplanır: $m(t) = \frac{1}{K}\sum_{k=1}^{K} e^{\theta_k}(t)$
- Ortalama, sinyalden çıkarılarak 'detay', *d(t)* elde edilir: $d(t) = x(t) - m(t)$
- Eğer d(t), ÇD-GKA için durdurma kriterini sağlıyorsa, yukarıdaki prosedür $x(t) - d(t)$ sinyaline uygulanır.

Görgül kip ayrıştırma işlemi, araştırmacılar tarafından geçmişte EEG sinyalleri ile birlikte kullanılmış ve olumlu sonuçlar elde edildiği rapor edilmiştir. Zahra ve diğ. çok değişkenli görgül kip ayrıştırma yöntemini, epileptik EEG sinyallerinin ayrıştırılmasında kullanmışlardır [43]. Ayrıştırma sonucu elde ettikleri ÖKF'lerden çeşitli öznitelikler çıkarmışlar ve bu öznitelikleri hasta ve sağlıklı katılımcıları ayırmada kullanmışlardır. Hassan ve diğ. ise uyku aşamalarını sınıflandırmada, GKA'nın farklı bir uzantısı olan topluluk görgül kip ayrıştırma işleminden yararlanmışlardır [44]. Mert ve Akan, ÇDGKA ile ayrıştırdıkları EEG

sinyallerinden çeşitli öznitelikler elde etmişler ve bu öznitelikleri duygu kestirimi için kullanmışlardır [45].

Bu çalışmada ÇDGKA işlemi, gerek MS kestirimi, gerekse MS hastalarının bilişsel engelli/bilişsel korunmuş sınıflandırması sırasında kullanılmıştır.

21 kanallı EEG sinyallerine GKA uygulanması sonucunda, EEG sinyallerinin uzunluğu ve frekans bileşenlerine göre değişen sayılarda öz kip fonksiyonları elde edilmiştir. 21 kanalın her biri için elde edilen ÖKF'ler şekil 3.6'da grafiksel olarak verilmiştir.



Şekil 3.6: 21 kanalın her biri için elde edilmiş 17 adet ÖKF.

Elde edilen ÖKF'lerin sayısı 14-17 arasında değişmektedir. Çok değişkenli görgül kip ayrıştırma işlemi kullanılmaması durumunda, bu kanallardan her biri farklı sayılarda ÖKF'ye sahip olacaklardı. 17 ÖKF için düşünüldüğünde, yalnızca 1 kişiye ait EEG sinyali için; 21x17 adet, yani 357 adet ÖKF elde edilecektir. Fakat bu ÖKF'lerin tümü sınıflandırma için kullanışlı değildir ve sınıflandırma doğruluğunu olumsuz yönde etkileyebilecektir. Bunlardan kullanışlı olanlarının seçimi için geçmişte çeşitli seçim yöntemleri önerilmiştir.

3.4.ÖZ KİP FONKSİYONU SEÇME

GKA işlemi sonucunda, doğrusal ve durağan olmayan sinyaller, sınırlı sayıda ÖKF'ye ayrıştırılır; fakat bu sinyallerin orijinal sinyale dair taşıdıkları bilgi aynı seviyede değildir. Kimi ÖKF'ler orijinal sinyalin karakteristiğini daha iyi yansıtırken; kimileri daha kullanışsız bilgiler taşımaktadırlar [46]. Bu nedenle GKA işlemi sonucunda elde edilmiş olan ÖKF'ler içerisinden daha fazla bilgi taşıyanlarının seçilmesi önemli bir işlem haline gelmiştir [47]. Aksi durumda,

yapılacak işlemde kullanılacak olan gereksiz ÖKF'ler, işlemi olumsuz yönde etkileyecektir. ÖKF seçmenin diğer bir faydası ise, işleme sokulacak sinyallerin sayısını azaltması nedeniyle hesaplama maliyetini düşürmesidir. Geçmişte yapılmış birçok çalışmada, ÖKF seçimi manuel olarak tamamen araştırmacının deneyimine bağlı olarak yapılmıştır [48]. Bu yöntem hem zaman alıcı hem de hataya açık olduğundan, ÖKF'lerin otomatik olarak seçimi için farklı yöntemler önerilmiştir.

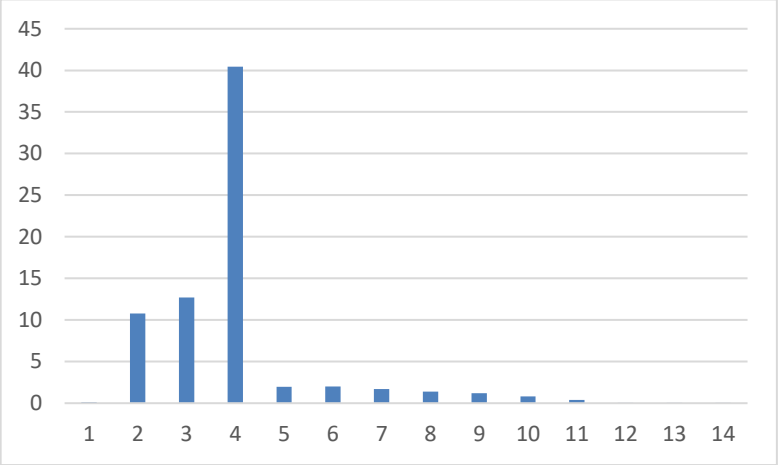
Junsheng ve diğ., ÖKF'nin taşıdığı enerji miktarını baz alan bir yöntem önermişlerdir [47]. Yöntem, en fazla enerjiye sahip ÖKF'nin orijinal sinyali en iyi temsil eden sinyal olduğu kabulüne dayanır. Bir sinyalden elde edilen ÖKF'lerin sahip oldukları enerjilerin toplamı, o sinyalin sahip olduğu toplam enerjiye eşittir:

$$E_{x(t)} = \sum_{j=1}^{n} E_{c_j(t)} \tag{3.5}$$

Eşitlikte *n* sinyalden elde edilmiş olan ÖKF sayısını ve $E_{c_j(t)}$, j. ÖKF'nin enerji içeriğini temsil etmektedir. Bir ÖKF'nin sahip olduğu enerji ise şu şekilde ifade edilebilir:

$$E_{c_j(t)} = \sum_{i=1}^{N} \left| c_j(i) \right|^2 \tag{3.6}$$

Eşitlikte *N* ÖKF'nin sahip olduğu sinyal örneği sayısı ve $c_j(i)$ ise j. ÖKF'nin i. örneğidir. Eğer birden fazla sayıda ÖKF seçilecek ise, en yüksek enerjiye sahip ÖKF'den en düşük enerjiye sahip olanına doğru sıralama yapılarak seçilir. Şekil 3.6'da bir EEG sinyalinden GKA kullanılarak elde edilmiş ÖKF'ler ve bu ÖKF'lere ait enerji miktarları grafiksel olarak verilmiştir. Grafikten görüldüğü gibi; en yüksek enerjiye sahip ÖKF, 4 numaralı ÖKF'dir. Bu ÖKF'yi sırasıyla 3, 2 ve 5 numaralı ÖKF'ler izlemektedir.



Şekil 3.7: Bir EEG sinyalinden elde edilmiş 14 adet ÖKF'nin enerji seviyeleri.

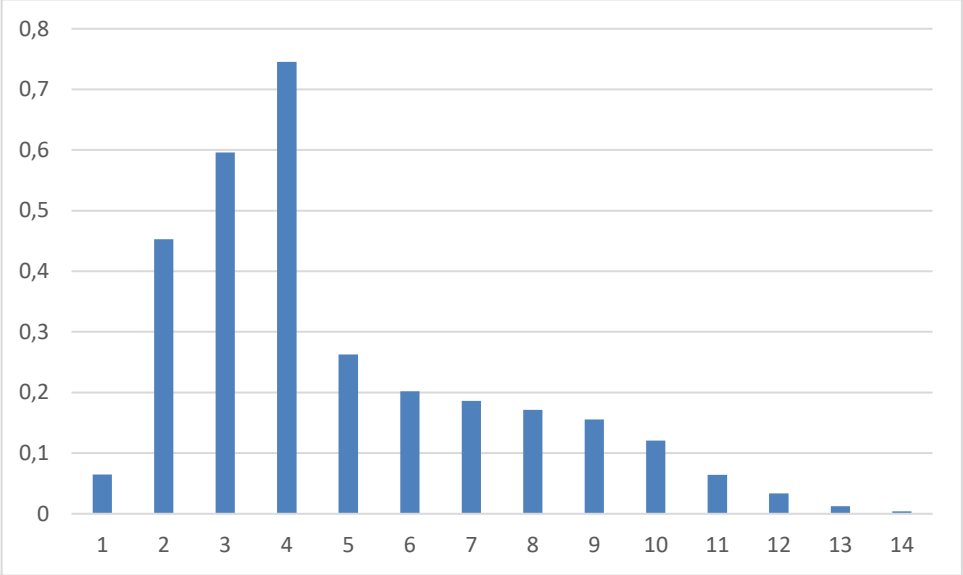
ÖKF seçim yöntemlerinden sık kullanılan bir diğeri ise, Peng ve diğ. tarafından önerilmiş olan korelasyon tabanlı seçim yöntemidir [49]. Bu seçim yöntemine göre; Orijinal sinyal ile en büyük korelasyon katsayısına sahip olan, yani en çok benzeşen ÖKF, orijinal sinyali en iyi temsil edendir. Korelasyon katsayısı, iki sinyal arasındaki benzerliğin bir ölçüsüdür ve şu şekilde ifade edilebilir:

$$\rho_{x(t)c_j(t)} = \frac{c_{x(t)c_j(t)}}{\sigma_{x(t)}\sigma_{c_j(t)}} \tag{3.7}$$

Eşitlikte $\sigma_{x(t)}$ ve $\sigma_{c_j(t)}$, $x(t)$ sinyaline ve j. ÖKF olan $c_j(t)$'ye ait standart sapmalar, $c_{x(t)c_j(t)}$ ise bu sinyallerin kovaryansıdır. Sinyaller ayrık değerlere sahip olduklarından, korelasyon katsayısı ayrık olarak ifade edilebilir:

$$\rho_{xc_j} = \frac{\sum_{i=1}^{N}(x(t)-\bar{x})(c_j(i)-\bar{c_j})}{\left[\sum_{i=1}^{N}(x(i)-\bar{x})^2-\sum_{i=1}^{N}(c_j(i)-\bar{c_j})^2\right]^{1/2}} \tag{3.8}$$

Şekil 3.7'de yukarıda enerji seviyeleri verilen ÖKF'lerin, orijinal sinyal ile olan korelasyonları verilmiştir.



Şekil 3.8: Bir EEG sinyalinden elde edilmiş 14 adet ÖKF'nin korelasyon katsayıları.

Grafikten, 4. ÖKF'nin orijinal sinyalle korelasyon katsayısının, diğer ÖKF'lerden büyük olduğu görülmektedir.

Kotan & Akan ise güç yoğunluk spektrumu (GYS) tabanlı bir ÖKF seçim yöntemi önermişlerdir [50]. Yönteme göre; Orijinal sinyal ile bu sinyalden elde edilmiş olan ÖKF'lerin GYS'lerinin mesafeleri, ÖKF'nin taşıdığı orijinal sinyale ait bilgi miktarı ile ters orantılıdır. Yani ÖKF'nin taşıdığı kullanışlı bilgi ne kadar fazla ise, GYS'lerinin benzerlikleri de o kadar fazladır. Bir sinyalin GYS'si, o sinyale ait gücün, farklı frekanslar üzerinde nasıl bir dağılıma sahip olduğunu verir:

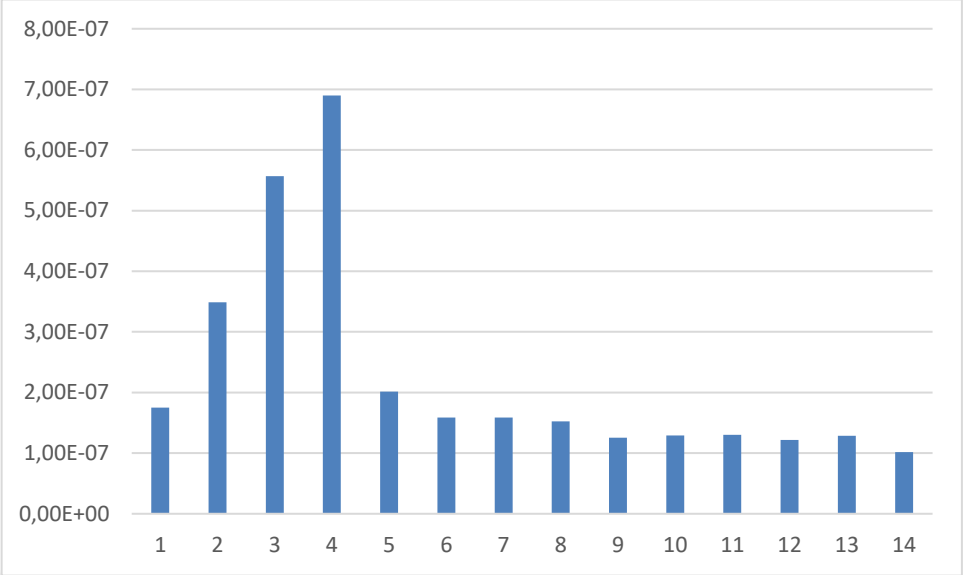
$$S_x(f) = \lim_{t\to\infty} E\left\{\frac{1}{2T}\left|\int_{-T}^{T} x(t)e^{-j2\pi ft}dt\right|^2\right\} \tag{3.9}$$

Çalışmada GYS'ler arası mesafenin hesaplanması için Kullback-Leibler mesafesi (KL-mesafesi) kullanılmıştır. Herhangi i $f(x)$ki $f(x)$ ve $g(y)$ fonksiyonu arasındaki KL-mesafesi:

$$M(f \parallel g) = \int f(x) \log \frac{f(x)}{g(y)} dx \tag{3.10}$$

Bu mesafe kullanılarak, bir $x(t)$ sinyali ve bu sinyalden elde edilmiş bir ÖKF arasındaki GYS benzerliği şu şekilde ifade edilebilir:

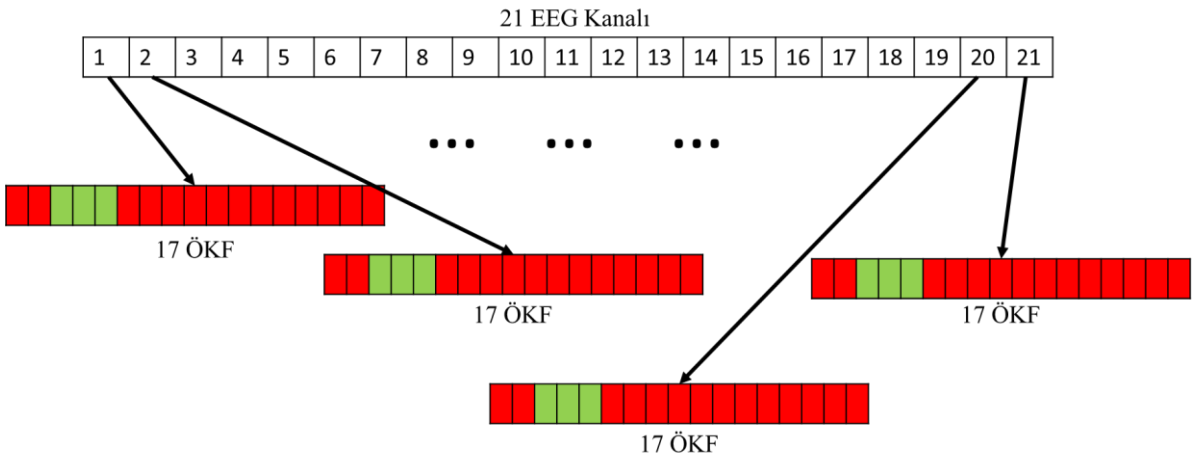
$$GYS_{benzerlik} = M(GYS(x(t)) \parallel GYS(\ddot{O}KF_i(t))) \tag{3.11}$$



Şekil 3.9: Bir EEG sinyalinden elde edilmiş 14 adet ÖKF'nin GYS benzerlik oranları.

Şekil 3.8'de bir EEG sinyalinden elde edilmiş olan 14 adet ÖKF'nin, orijinal sinyalle olan güç yoğunluk spektrumu benzerliği verilmiştir. Grafikten, 4. ÖKF'nin orijinal sinyalle en fazla GYS benzerliğine sahip olduğu anlaşılmaktadır.

Bu çalışmada, yukarıda bahsedilen yöntemlerin ortak olarak önerdikleri 3, 4 ve 5 numaralı ÖKF'ler seçilmiştir. Seçim sonucunda ortaya çıkan yeni durum şekil 3.10'da verilmiştir.



Şekil 3.10: ÖKKF seçim sonucu ortaya çıkan yeni durum.

Şekilde her kanal için 17 ÖKF'den 3 tanesinin seçildiği görülmektedir. Böylece seçme içlemi sonucunda tek bir EEG sinyaline ait ÖKF sayısı 63 adede (21x3) düşer.

3.5.ÇALIŞMADA KULLANILAN ÖZNİTELİKLER

Çalışmada bazı analizler için 10, bazıları için ise 3 farklı öznitelik sınıflandırma için kullanılmıştır. Kullanılan bu öznitelikler aşağıdaki verilmiştir:

3.5.1. Ortalama

Bir sayısal sinyalin ortalaması, o sinyale ait tüm örneklerin birbirine eklenerek daha sonra örnek sayısına bölünmesiyle elde edilir:

$$\mu = \frac{1}{N}\sum_{i=0}^{N-1} x_i \tag{3.12}$$

3.5.2. Standart sapma

Standart sapma, bir sinyaldeki örneklerin, o sinyalin ortalamasından ne ölçüde sapma gösterdiğinin bir ölçüsüdür. Küçük bir standart sapma, örneklerin ortalamaya yakın bir alanda toplandığı anlamına gelirken; büyük bir standart sapma değeri, sinyaldeki örneklerin geniş bir alanda dağıldığını gösterir. Standart sapma şu şekilde ifade edilebilir:

$$\sigma = \sqrt{\frac{1}{N-1}\sum_{i=1}^{N-1}(x_i - \mu)^2} \tag{3.13}$$

3.5.3. Ortalama Sinyal Gücü

Bir sinyale ait güç ve enerji parametreleri, o sinyali karakterize etmek için kullanılır ve gerçek güç ve enerjiyi vermezler. Sayısal bir sinyale ait güç:

$$P = \lim_{N\to\infty}\left(\frac{1}{2N+1}\sum_{n=-N}^{N}|x(n)|^2\right) \tag{3.14}$$

3.5.4. Hjorth Parametreleri (Aktivite, mobilite, kompleksite)

Hjorth parametreleri, bir sinyalin zaman alanındaki istatistiksel özellikleri işaret etmek için kullanılır ve üç çeşit parametreye sahiptir: aktivite, mobilite ve kompleksite [51].

Aktivite parametresi, zaman fonksiyonunun varyansıdır. Frekans alanında ise güç spektrumunun yüzeyini verir. Eğer sinyalin sahip olduğu yüksek frekans bileşenleri fazla ise

büyük bir aktivite değeri; yüksek frekans bileşenleri az ise küçük bir aktivite değeri alır. Bir zaman sinyali için aktivite:

$$Aktivite_i{}^m = \frac{1}{N}\sum_{n=0}^{N-1}[\varphi_i{}^m(n) - \bar{\varphi}_i]^2 \tag{3.15}$$

Mobilite parametresi, sinyalin birinci türevinin varyansı ile sinyalin varyansının oranının kareköküdür. Bu parametre, sinyalin güç spektrumunun standart sapması ile orantılıdır:

$$Mobilite_i{}^m = \sqrt{\frac{Aktivite\left(\frac{d\varphi_i{}^m}{dt}\right)}{Aktivite_i{}^m}} \tag{3.16}$$

Kompleksite parametresi, sinyalin saf sinüzoidal sinyale hangi oranda benzediğinin bir göstergesidir. Bu parametrenin değeri, sinyalin sinüzoidal sinyal ile benzerliği arttıkça 1'e yaklaşır. Kompleksite parametresi şu şekilde ifade edilebilir:

$$Kompleksite\{x\}_i{}^m = \sqrt{\frac{Mobilite\left(\frac{d\varphi_i{}^m}{dt}\right)}{Mobilite_i{}^m}} \tag{3.17}$$

3.5.5. Çarpıklık

Çarpıklık, bir dağılımın sahip olduğu simetrinin ölçülmesinde kullanılan ölçüdür. Eğer bir dağılımda verinin çoğu sol tarafta ve dağılımın kuyruğu sola uzanmakta ise, bu dağılım *sağa çarpık* veya *pozitif çarpık* olduğu söylenir. Eğer dağılımın tepesi sağ tarafta ve sol kuyruk daha uzunsa, dağılımın *sola çarpık* veya *negatif çarpık* olduğu söylenir [52]. Çarpıklık ayrıca bir rastgele değişkenin üçüncü merkezi momentine eşittir. μ rastgele değişkene ait ortalama, σ standart sapma ve σ^2rastgele değişkenin varyansı olmak üzere; bir sinyale ait çarpıklık:

$$çarpıklık(x) = \alpha_3 = \int_{i=1}^{N} \frac{(x_i-\mu)^3}{\sigma^3} f(x)dx \tag{3.18}$$

3.5.6. Sivrilik (Kurtosis)

Sivrilik, bir dağılımda tepe noktasının yükseklik ve sivriliğinin bir ölçüsüdür. Yüksek sivrilik değerleri daha yüksek ve sivri bir tepeye işaret ederken; düşük sivrilik değerleri alçak ve basık tepeye işaret eder. Sivrilik, bir rastgele değişkenin dördüncü merkezi momentine eşittir:

$$sivrilik(x) = \alpha_4 = \int_{i=1}^{N} \frac{(x_i-\mu)^4}{\sigma^4} f(x)dx \quad (3.19)$$

3.5.7. Hurst üssü

Hurst üssü, bir zaman serisinde, farklı ölçeklerdeki öz-benzerliğin bir ölçüsüdür [53]. Hurst üssü değerinin 0,5'e eşit olması durumunda zaman serisinin rastgele seri olduğu kabul edilir. 0,5 ila 1 arasında değişen değerler uzun-dönem pozitif oto-korelasyon anlamına; 0 ila 0,5 arasında değişen değerleri ise zaman serisi arttırıldıkça, oto-korelasyonun azaldığı anlamına gelir [54].

Hurst üssü, yeniden ölçeklenmiş menzil analizi (R/S analizi) kullanılarak hesaplanabilir [55]. R/S analizi, bir $X = X_1, X_2, \ldots$ serisi için 6 adımda aşağıdaki gibi hesaplanabilir:

(1) Ortalama değer hesaplanır:

$$m = \frac{1}{n}\sum_{i=1}^{n} X_i \quad (3.20)$$

(2) Ortalama ayarlı Y serisi hesaplanır:

$$Y_t = X_t - m, \ t = 1, 2, \ldots, n \quad (3.21)$$

(3) Topluluk sapması hesaplanır:

$$Z_t = \sum_{i=1}^{t} Y_i, \qquad t = 1, 2, \ldots, n \quad (3.22)$$

(4) Menzil serisi R hesaplanır:

$$S_t = \max(Z_1, Z_2, \ldots, Z_t) - \min(Z_1, Z_2, \ldots, Z_t), \quad t = 1, 2, \ldots, n \quad (3.23)$$

(5) S serisinin standart sapması hesaplanır:

$$S_t = \sqrt{\frac{1}{t}\sum_{i=1}^{t}(X_i - u)^2}, \quad t = 1, 2, \ldots, n \quad (3.24)$$

Eşitlikte u değeri, X_1'den X_t'ye kadar olan değerlerin ortalamasıdır.

(6) R/S analizi hesaplanır:

$$(R/S)_t = R_t/S_t, \qquad t = 1, 2, \ldots, n \quad (3.25)$$

3.5.8. Fraktal Boyutlar

Fraktal boyutlar, zaman serileri için öz-benzerliği ve kompleksliği gösteren ölçüdür. Fraktal boyutlar değerini hesaplamak için birçok yöntem önerilmiştir. Bu çalışmada Higuchi tarafından önerilmiş olan hesaplama yöntemi kullanılmış olup; şu gibi gösterilebilir [56]: $X = X(1), X(2), \dots, X(n)$ zaman serisi için k adet yeni zaman serisi aşağıdaki gibi oluşturulur:

$$X_k^m : X(m), X(m+k), X(m+2k), \dots, X\left(m + \left[\frac{N-m}{k}\right].k\right), \qquad \text{(m=1, 2, …, k)} \qquad (3.26)$$

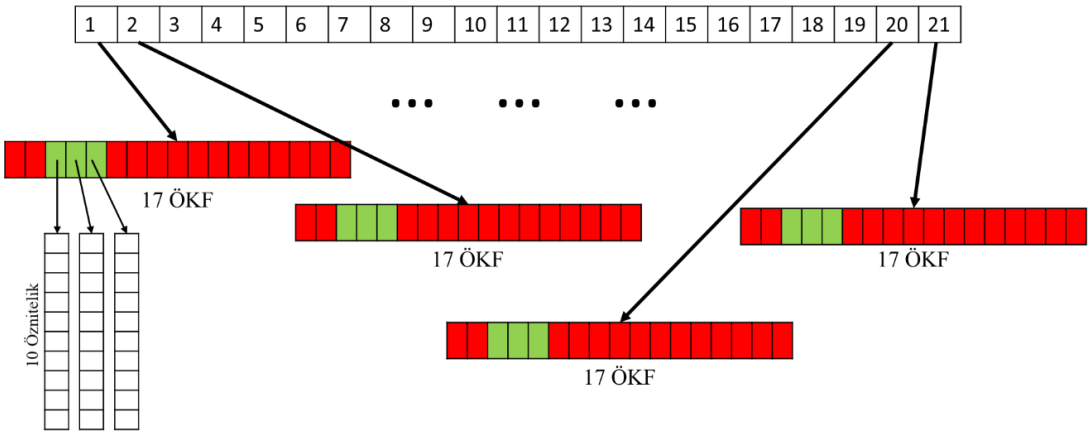
Her bir yeni zaman serisi için, ortalama uzunluk:

$$L_m(k) = \left\{\left(\sum_{i=1}^{\left[\frac{N-m}{k}\right]} |X(m+ik) - X(m+(i-1).k|\right)\frac{N-1}{\left[\frac{N-m}{k}\right].k}\right\}/k \qquad (3.27)$$

$$L(k) = \frac{1}{k} \times \sum_{m=1}^{k} L_m(k) \qquad (3.28)$$

Eğer L(k)'nın logaritmasına karşılık log(1/k), k=1'den k_{max}.'a kadar çizdirilirse, Higuchi Fraktal boyutlar bu çiftler arasındaki doğrunun eğimine eşit olacaktır. Fraktal boyutlar'ın doyuma ulaştığı nokta k_{max} olarak isimlendirilir.

Çıkarılan 10 adet özniteliğin ardından, sınıflandırma için kişi başına elde edilen veri, şekil 3.11'de verilmiştir.



Şekil 3.11: sınıflandırma öncesi her bir kişi için elde edilen sınıflandırma verisi.

Şekilde, her EEG sinyalinin her bir kanalından elde edilen ÖKF'lerden 3 tanesi seçilmiş, daha sonra seçilen ÖKF'lerden 10'ar adet öznitelik çıkarılmıştır. Böylece her katılımcı için 630 adet (21x3x10) öznitelik çıkarılmıştır.

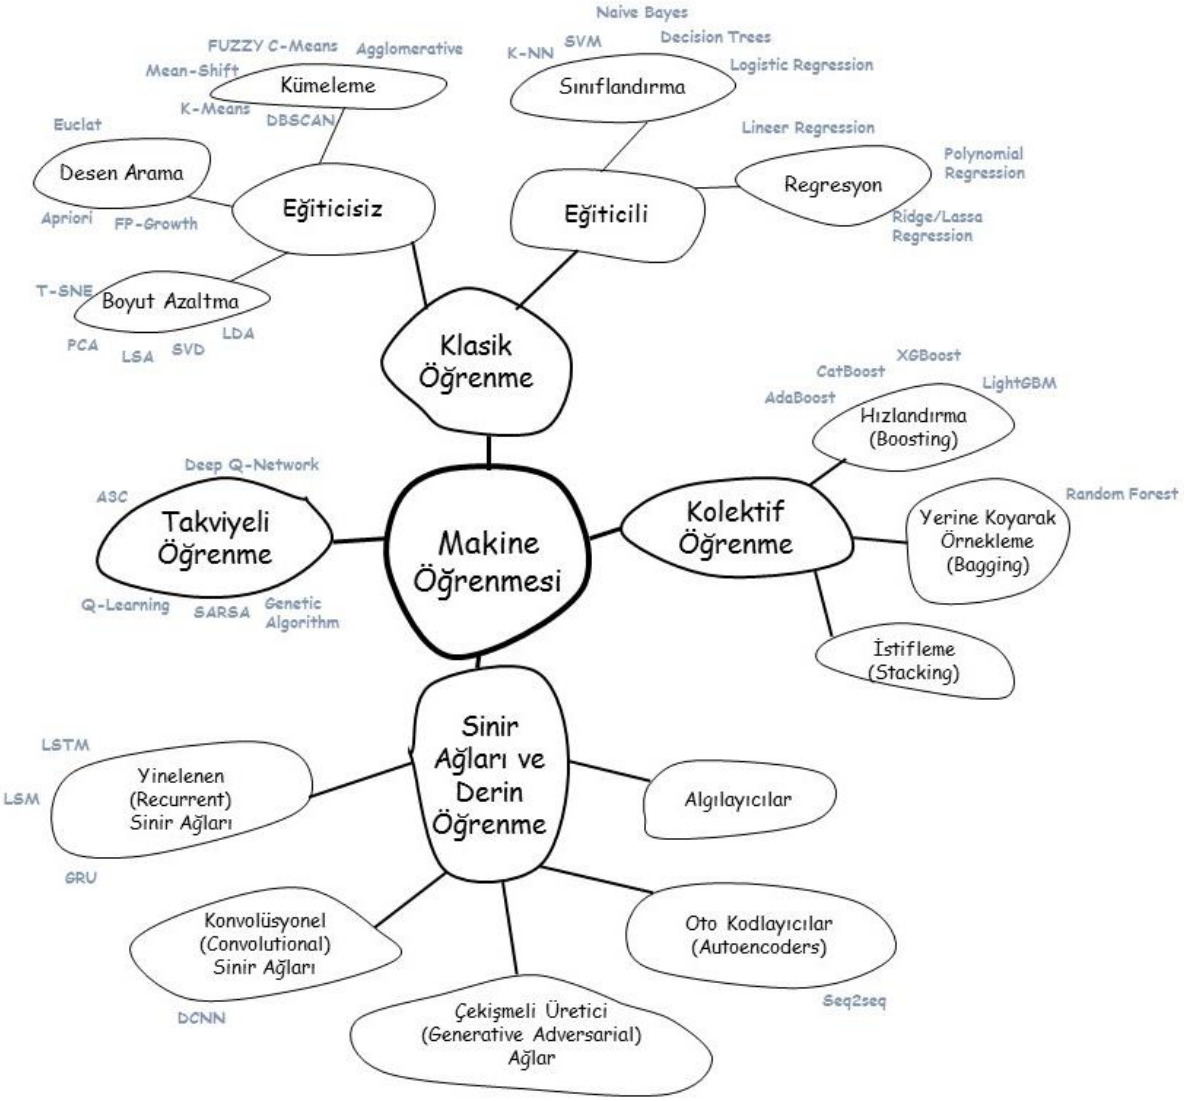
3.6.SINIFLANDIRMA

Makine Öğrenmesi, makinelerin akıllı yazılımları kullanarak çeşitli işleri ustaca yapabilmesini amaçlayan, yapay zekânın bir dalıdır [57]. Yapay zekâ ise bu bilim alanının tamamına verilen isimdir. Makine öğrenmesi ile yapay zekâ arasındaki ilişki şekil 3,9'daki gibi gösterilebilir:



Şekil 3.12: yapay zekâ ve alt dalları.

Günümüzde makine öğrenmesi; bilgisayar destekli teşhis, bilgisayarlı nesne tanıma, sürücüsüz araçlar, yüz tanıma ve güvenlik, konuşma tanıma, yazı tanıma, reklam ve pazarlama, sosyal medya, robotik kontrol ve kişisel asistan gibi onlarca uygulama alanında kullanılmaktadır. Makine öğrenmesi için geliştirilmiş birçok yöntem bulunmaktadır. Şekil 3.10'da makine öğrenmesine ait alt dallar ve yöntemler gösterilmiştir.

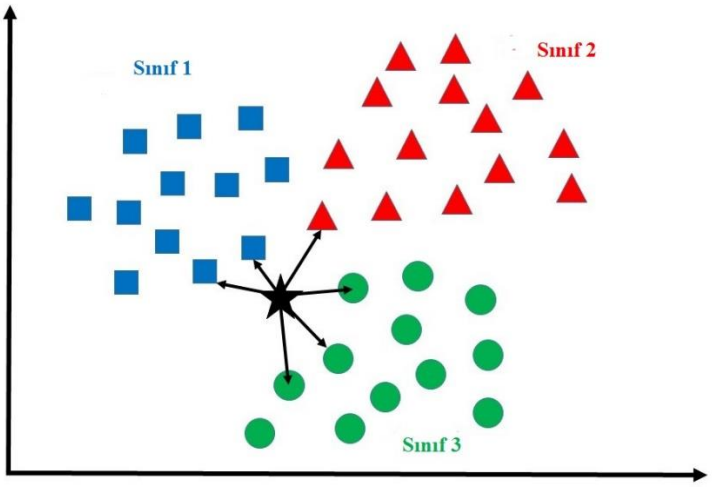


Şekil 3.13: Makine öğrenmesi haritası.

Bu çalışmada eğiticili sınıflandırıcılardan k-en yakın komşu, eğiticisiz sınıflandırıcılardan doğrusal diskriminant analizi, kolektif öğrenme yöntemlerinden biri olan rastgele orman sınıflandırıcı ve yapay sinir ağlarına dâhil sınıflandırıcılardan biri olan çok katmanlı algılayıcı sınıflandırıcılar olarak kullanılmışlardır.

3.6.1. k-en yakın komşu (k-NN)

k-NN temel olarak her yeni örneğin, çevresindeki en yakın örneklerin sınıfı göz önünde bulundurularak sınıflandırıldığı sınıflandırma algoritmasıdır [58]. Karar doğrudan eğitilen örneklere bağlı olduğundan, örnek tabanlı sınıflandırma veya durum tabanlı sınıflandırma olarak nitelendirilir. Algoritmanın temel fikri şekilde gösterilmiştir:



Şekil 3.14: k-NN algoritmasının çalışma prensibi.

Şekilde k=6 durumu için, üç farklı sınıfın bulunduğu bir veri setinde, yeni bir örnek sınıflandırılmaktadır. Şekilde, yıldız ile gösterilen yeni örneğin sınıfı belirlenecektir. Bunun için mesafe olarak kendisine en yakın 6 komşusunun hangi sınıfa dâhil olduğuna bakılır. En yakın 6 komşudan 1 tanesi sınıf 2'ye, 2 tanesi sınıf 1'e ve 3 tanesi sınıf 3'e dâhildir. Buna göre yeni örneğin sınıf 3'e dâhil olduğuna karar verilecektir.

$(\boldsymbol{x}_i)_{i\in[1,|D|]}$ eğitim örneklerinden oluşmuş bir D veri kümesine sahip olduğumuzu varsayalım. Bu örnekler F öznitelikler kümesiyle ifade edilsin ve [0,1] aralığında normalize edilmiş olsunlar. Her bir örnek bir $y_j \in Y$ sınıfıyla sınıfı ile etiketlenmiş olsun. Yapılması gereken işlem, sınıfı bilinmeyen yeni bir q örneğinin, hangi sınıfa dâhil olacağını kestirmektir. Eğitim kümesindeki her bir $x_i \in D$ için, q ile x_i'ler arasındaki mesafe şu şekilde hesaplanabilir:

$$d(q, x_i) = \sum_{f\in F} w_f \delta(q_f x_{if}) \tag{3.29}$$

Burada mesafe ölçümü için kullanılabilecek birçok olasılık bulunmaktadır. Bu da yeni q örneğinin sınıfının belirlenmesi için birçok yolun olduğu anlamına gelmektedir.

Hesaplama sırasında en yakın komşuya, karar için kullanılmak üzere en büyük ağırlık atanır. Yani q örneğine y_1 sınıfından çok yakın bir örnek varsa, ikinci ve üçüncü en yakın komşular ise y_2 sınıfından ise fakat en yakın örneğe göre oldukça uzak bir noktada iseler; bu durumda q örneğinin y_1 sınıfına dâhil olduğu sonucuna varılabilir. Burada kullanılacak oylama işlemi şu eşitlikle gösterilebilir:

$$Oylama(y_j) = \sum_{c=1}^{k} \frac{1}{d(q,x_c)^n} 1(y_j y_c) \quad (3.30)$$

Eşitlikte; y_j sınıfı oylaması için x_c komşuluğu ile mesafesine bölünmekte, $1(y_j, y_i)$ ifadesi sınıf uyuşması durumunda 1'e, aksi durumda 0'a gitmektedir. Eşitlikteki n değişkeni genellikle 1 alınmakla birlikte, mesafenin sınıflandırma üzerindeki etkisine göre farklı değerler alabilmektedir. Oylama için diğer bir yaklaşım ise, mesafenin tersi yerine üssel olarak almaktır [59]:

$$Oylama(y_j) = \sum_{c=1}^{k} e^{-\frac{d(q,x_c)}{h}} 1(y_j y_c) \quad (3.31)$$

k-NN sınıflandırmada mesafe ve benzerlik ölçümünde farklı metrikler kullanılabilmektedir. En sık kullanılan mesafe metriği, Minkowski Mesafe metriğidir. Minkowski mesafesinin genel eşitliği şu şekilde verilebilir:

$$MM_p(q, x_i) = \left(\sum_{f \in F} |q_f - x_{if}|^p\right)^{\frac{1}{p}} \quad (3.32)$$

Eşitlik; L1 norm için Manhattan mesafesi veya Şehir blokları ve L2 norm için Öklid mesafesi adını alır. *p* değerinin 2'den büyük olduğu durumlar nadiren kullanılsa da, mesafeye göre daha büyük oranda farklılık gösteren katsayılar verileceği durumlarda kullanılabilir. L1 norm için mesafe aşağıdaki gibi ifade edilebilir:

$$ŞB_p(q, x_i) = \left(\sum_{f \in F} |q_f - x_{if}|\right) \quad (3.33)$$

L2 norm için ise ifade Öklid mesafesi olarak ise mesafe aşağıdaki gibi ifade edilir:

$$ÖM_p(q, x_i) = \left(\sum_{f \in F} |q_f - x_{if}|^2\right)^{1/2} \quad (3.34)$$

Minkowski mesafesi, verinin öznitelik vektörleri şeklinde olduğu durumlar için k-NN sınıflandırıcıda yaygın olarak kullanılmakta ve ihtiyacı karşılamaktadır. Mesafe hesaplamada kullanılan diğer popüler ölçüler ise KL-mesafesidir [60]. KL-mesafesi genellikle dağılımların karşılaştırılması için kullanılır ve şu şekilde ifade edilebilir:

$$d_{KL}(H, K) = \sum_{i}^{N} h_i \log \frac{h_i}{k_i} \quad (3.35)$$

Eşitlikte *H* ve *K* iki dağılım, *h* ve *k* ilgili vektörlerdir.

3.6.2. Doğrusal Ayrımcılık Analizi

Doğrusal ayrımcılık analizi (DAA), yüksek boyutlu gözlemleri düşük boyutlu uzaya izdüşümünü amaçlayan çok değişkenli bir istatistik yöntemidir [61]. Koşulları sağlandığında, örtülü uzayda optimal doğrusal karar sınırlarının tanımlanmasını sağlar. DAA, temel bileşenler analizinden farklı olarak, boyut azaltma işleminde olabilecek en fazla sınıf ayrıştırıcı bilgiyi korur.

$A \in \mathbb{R}^{Nxn}$ bir veri matrisi olmak üzere DAA, $1 \leq i \leq n$ için *A*'daki her bir α_i sütununu $G\epsilon\mathbb{R}^{Nxl}$ dönüşümü yaparak N-boyutlu uzaydan *l*-boyutlu bir uzaydaki b_i vektörüne dönüştürmeyi amaçlar. Yani $G: a_i \in \mathbb{R}^N \rightarrow b_i = G^T a_i \epsilon \mathbb{R}^l (l < N)$. Buna eşdeğer olarak, klasik DAA $\{g_i\}_{i=1}^{l}$ tarafından kapsanan bir $\mathcal{G}$ vektör uzayı bulmayı amaçlar. Burada $G = [g_1, \dots, g_l]$, öyle ki; her α_i, $(g_1^T . a_i, \dots, g_l^T . a_i)^T \epsilon \mathbb{R}^l$ kullanılarak $\mathcal{G}$ üzerine izdüşürülür.

A matrisindeki orijinal verinin $A = \{\Pi_1, \dots, \Pi_k\}$ şeklinde k sınıfa bölündüğünü kabul edelim. Burada Π_i, *i.* sınıftan n_i tane veri noktasına sahiptir ve $\sum_{i=1}^{k} n_i = n$ 'dir. DAA, yüksek-boyutlu uzaydaki sınıf yapısının düşük-boyutlu uzayda da korunacağı optimal *G* dönüşümünü bulmayı amaçlar.

Genel olarak, eğer bir sınıf sıkı gruplanmış fakat diğer sınıflardan iyi bir şekilde ayrılmış ise, sınıflandırma kalitesinin yüksek olduğu kabul edilir. Ayrımcılık analizinde sınıflandırma kalitesinin değerlendirilmesi için; sınıf-içi (S_w) ve sınıflar-arası (S_b) olarak isimlendirilen iki dağılım matrisi tanımlanır [62]:

$$S_w = \sum_{i=1}^{k} \sum_{x\epsilon\Pi_i} (x - m_i)(x - m_i)^T \tag{3.36}$$

$$S_b = \sum_{i=1}^{k} n_i (m_i - m)(m_i - m)^T \tag{3.37}$$

Eşitliklerde $m_i = \frac{1}{n_i} \sum_{x\epsilon\Pi_i} x$ i. sınıfın ortalaması ve $m = \frac{1}{n} \sum_{i=1}^{k} \sum_{x\epsilon\Pi_i} x$ global ortalamadır. Eşitliklere bakıldığında, (S_w)'in sınıf içi vektörlerin yakınlığını ölçtüğü, (S_b)'in ise sınıflar arası ayrımı ölçtüğü görülmektedir. *G* doğrusal dönüşümünden elde edilen düşük-boyutlu uzayda, sınıf içi ve sınıflar arası matrisler $S_b^L = G^T S_b G$ ve $S_w^L = G^T S_w G$ şekline dönüşür. Optimal bir

G dönüşümü iz(S_b^L)'i maksimize ederken, iz(S_w^L)'i minimize eder. Bu bir optimizasyon problemidir ve şu şekilde ifade edilebilir:

$$\max_G\{iz((S_w^L)^{-1} - S_b^L)\} \tag{3.38}$$

$$\min_G\{iz((S_b^L)^{-1} - S_w^L)\} \tag{3.39}$$

Eşitlikteki optimizasyon problemi şu özdeğer problemine eşittir: $S_b x = \lambda S_w x,\ \lambda \neq 0$. Çözüm, eğer S_w tekil değil ise $S_w^{-1}S_b$ matrisine, veya S_b tekil değil ise $S_b^{-1}S_w$ matrisine özdeğer ayrıştırması uygulanarak elde edilebilir. S_b matrisinin rankı yukarıdan $k-1$ ile sınırlanmış olduğundan sıfırdan farklı özdeğerlere karşılık gelen en fazla $k-1$ özdeğer vardır. Bu nedenle klasik DAA'da uzay boyutu en fazla $k-1$ kadar olur.

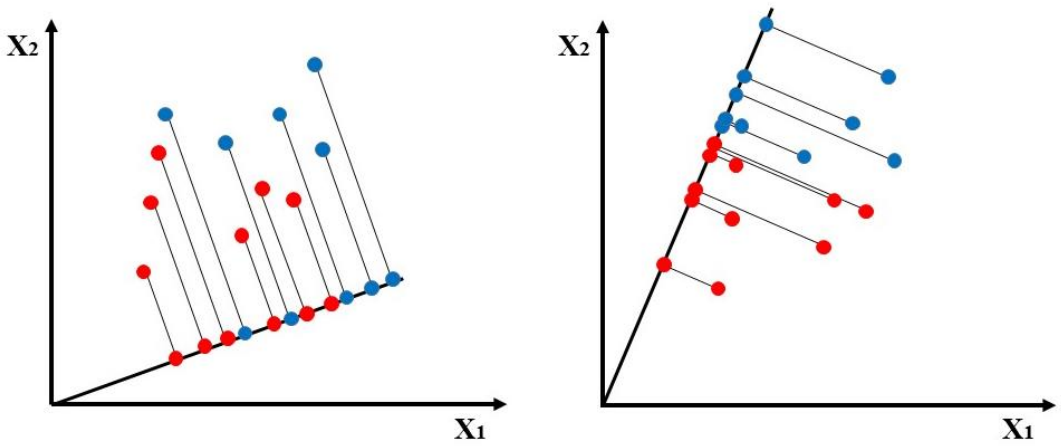
Daha kolay anlaşılması için iki sınıfa sahip bir veri kümesi için düşünecek olursak; $\{x^1, x^2, \dots, x^N\}$ m-boyutlu örneklere sahip olduğumuzu varsayalım. Bu örneklerden N_1tanesi ω_1 sınıfına, N_2tanesi ise ω_2 sınıfına dâhil olsun. DDA kullanarak yapmak istediğimiz; x örneklerini bir doğru (C-1 uzayı, C=2) üzerine iz düşürecek bir skaler bulmaktır.

$$y = w^T x \tag{3.40}$$

$$x = \begin{bmatrix} x_1 \\ \vdots \\ x_m \end{bmatrix} \tag{3.41}$$

$$w = \begin{bmatrix} w_1 \\ \vdots \\ w_m \end{bmatrix} \tag{3.42}$$

w, x'i y üzerine iz düşürmek için kullanılan iz düşüm vektörüdür. Burada, olası tüm doğrular içerisinden, sınıfların ayırt edilebilirliğini maksimize edenini seçmeyi amaçlanmaktadır. İyi bir iz düşüm vektörü bulabilmek için, iz düşümler arasındaki ayrıştırmayı tanımlayacak bir ölçü tanımlanmalıdır. Şekil 3.12'de iki sınıf ve iki boyut için doğru üzerine iz düşümler sembolik olarak gösterilmiştir. Şekilden görüleceği gibi; soldaki düzlemde doğru üzerine yapılan iz düşüm, sınıf ayırıcılığı bakımından herhangi bir avantaj sunmamaktadır. Sağdaki düzlemde ise, iz düşüm farklı bir doğru üzerine yapılmış ve daha iyi sınıf ayırıcılığı sağlanmıştır.



Şekil 3.15: İki sınıf için farklı doğrular üzerine iz düşüm.

x ve y öznitelik uzayında bulunan her bir sınıftaki ortalama vektörü:

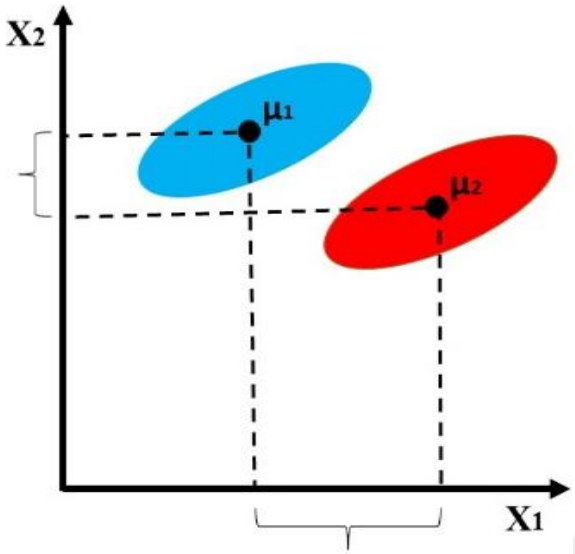
$$\mu_i = \frac{1}{N_i}\sum_{x\epsilon\omega_i} x \tag{3.43}$$

$$\tilde{\mu}_i = \frac{1}{N_i}\sum_{y\epsilon\omega_i} y = \frac{1}{N_i}\sum_{x\epsilon\omega_i} w^T x = w^T \frac{1}{N_i}\sum_{x\epsilon\omega_i} x = w^T \mu_i \tag{3.44}$$

Eşitlik, x'in y üzerine iz düşürülmesinin aynı zamanda x'in ortalamasının y'nin ortalamasına iz düşürülmesi anlamına geldiğini gösterir. Burada iki ortalama arasındaki mesafe sınıf ayırt ediciliği için bir ölçü olarak seçilebilir.

$$J(w) = |\tilde{\mu}_1 - \tilde{\mu}_2| = |w^T\mu_1 - w^T\mu_2| = |w^T(\mu_1 - \mu_2)| \tag{3.45}$$

Fakat iz düşürülmüş ortalamalar arasındaki mesafe, sınıf içi standart sapmayı hesaba katmadığı için yeterli değildir. Şekil 3.13'te, iki ortalama arasındaki mesafe X_1 ekseni üzerine yapılacak olan iz düşüm için daha fazla, X_2 ekseni için ise daha yakındır. Buna rağmen, standart sapma dikkate alındığında, X_2 üzerindeki iz düşüm için sınıf ayırıcılığının daha iyi olduğu görülür.



Şekil 3.16: X_2 daha iyi sınıf ayırt ediciliği sağlarken X_1'deki mesafe daha fazladır.

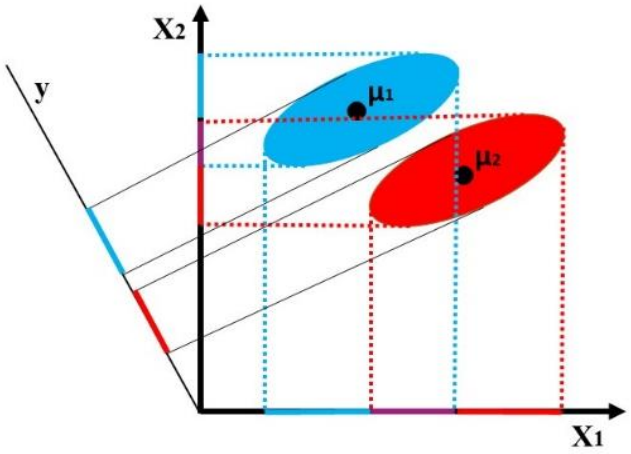
Bu problem için Fisher; ortalamalar arasındaki mesafe fonksiyonunu maksimize eden, sınıf içi dağılım (saçılma) ölçüsü ile normalize edilmiş bir çözüm önermiştir. Bu çözüme göre; her sınıf için varyansa eş bir saçılım tanımlanır:

$$\tilde{s}_i^{\,2} = \sum_{y \epsilon \omega_i} (y - \tilde{\mu}_i)^2 \tag{3.46}$$

$\tilde{s}_i^{\,2}$, y-uzayına iz düşürüldükten sonraki ω_i sınıfının değişkenliği (saçılmayı) ölçer. Böylece, $\tilde{s}_1^{\,2} + \tilde{s}_2^{\,2}$ iz düşüm sonrası iki sınıfın iç değişkenliğini ölçer ve *sınıf-içi saçılma* adını alır. Fisher doğrusal diskriminantı $w^T x$'in doğrusal bir fonksiyonu olarak tanımlanır ve eşitlikteki kriter fonksiyonunu maksimize eder:

$$J(w) = \frac{|\tilde{\mu}_1 - \tilde{\mu}_2|^2}{\tilde{s}_1^{\,2} + \tilde{s}_2^{\,2}} \tag{3.47}$$

Eşitlikten de görüleceği üzere; aynı sınıftan olan iz düşümleri birbirine çok yakın, aynı zamanda, iz düşüm ortalamaları birbirinden olabildiğince ayrılmış örneklere sahip iz düşümler bulmak amaçlanmaktadır. Şekil 3.14'te, optimum sınıf ayırıcılığı için gerekli iz düşüm verilmiştir.



Şekil 3.17: Sınıf içi dağılım minimum ve ortalama mesafesinin maksimum olduğu doğru.

Optimum bir w^* iz düşümü bulabilmek için $J(w)$ w'nin açık bir fonksiyonu olarak ifade edilmelidir. Öncelikle, çok değişkenli öznitelik uzayı olan x'te *saçılma matrisleri* olarak bilinen saçılma ölçüsü tanımlanmalıdır:

$$S_i = \sum_{x\epsilon\omega_i}(x-\mu_i)(x-\mu_i)^T \tag{3.48}$$

$$S_w = S_1 + S_2 \tag{3.49}$$

Eşitlikte S_i, ω_i sınıfına ait kovaryans matrisi ve S_w sınıf-içi saçılım matrisidir. Böylece artık y iz düşümünün saçılımı, x uzayının saçılım matrisinin bir fonksiyonu olarak yazılabilir:

$$\tilde{s}_i^{\,2} = \sum_{y\epsilon\omega_i}(y-\tilde{\mu}_i)^2 \tag{3.50}$$

$$= \sum_{x\epsilon\omega_i}(w^Tx - w^T\mu_i)^2$$

$$= \sum_{x\epsilon\omega_i} w^T(x-\mu_i)(x-\mu_i)^Tw$$

$$= w^T\left(\sum_{x\epsilon\omega_i}(x-\mu_i)(x-\mu_i)^T\right)w$$

$$= w^TS_iw$$

$$\tilde{s}_1^{\,2} + \tilde{s}_2^{\,2} = w^TS_1w + w^TS_2w = w^T(S_1+S_2)w = w^TS_ww = \tilde{S}_w \tag{3.51}$$

Burada $\tilde{S}_w$ iz düşüm yapılmış örneklerin sınıf-içi saçılım matrisidir. Benzer şekilde, iz düşüm ortalamaları arasındaki fark (y-uzayında), orijinal öznitelik uzayındaki (x-uzayı) ortalamalar cinsinden ifade edilebilir:

$$(\tilde{\mu}_1 - \tilde{\mu}_2)^2 = (w^T\mu_1 - w^T\mu_2)^2 = w^T(\mu_1 - \mu_2)(\mu_1 - \mu_2)^T w = w^T S_B w = \tilde{S}_B \qquad (3.52)$$

S_B orijinal öznitelik vektörünün *sınıflar arası saçılım matrisi*; $\tilde{S}_B$ ise iz düşüm y örneklerinin sınıflar arası saçılımıdır. Böylece Fisher kriteri S_w ve $S_B$cinsinden ifade edilebilir hale gelmiş olur:

$$J(w) = \frac{|\tilde{\mu}_1 - \tilde{\mu}_2|^2}{\tilde{s}_1{}^2 + \tilde{s}_2{}^2} = \frac{w^T S_B w}{w^T S_W w} \qquad (3.53)$$

$J(w)$ ortalamalar arası farkın, sınıf içi saçılma ile normalize edilmiş bir ölçüsü olduğundan, bu fonksiyonun maksimum değerini bulunarak; minimum saçılma ve maksimum ortalamalar arası uzaklık elde edilebilir. Bunun için ifadenin türevi alınarak sıfıra eşitlenir:

$$\frac{d}{dw}J(w) = \frac{d}{dw}\left(\frac{w^T S_B w}{w^T S_W w}\right) = 0 \qquad (3.54)$$

$$\Rightarrow (w^T S_W w)\frac{d}{dw}(w^T S_B w) - (w^T S_B w)\frac{d}{dw}(w^T S_W w) = 0$$

$$\Rightarrow (w^T S_W w)2S_B w - (w^T S_B w)2S_w w = 0$$

Eşitliğin her iki tarafı $2w^T S_W w$ ile bölündüğünde:

$$\Rightarrow \left(\frac{w^T S_W w}{w^T S_W w}\right) S_B w - \left(\frac{w^T S_B w}{w^T S_W w}\right) S_w w = 0$$

$$\Rightarrow S_B w - J(w) S_W w = 0$$

$$\Rightarrow S_W{}^{-1} S_B w - J(w) w = 0$$

İfade genelleştirilmiş özdeğer problemi olarak çözüldüğünde:

$$S_W{}^{-1} S_B w = \lambda w \qquad (3.55)$$

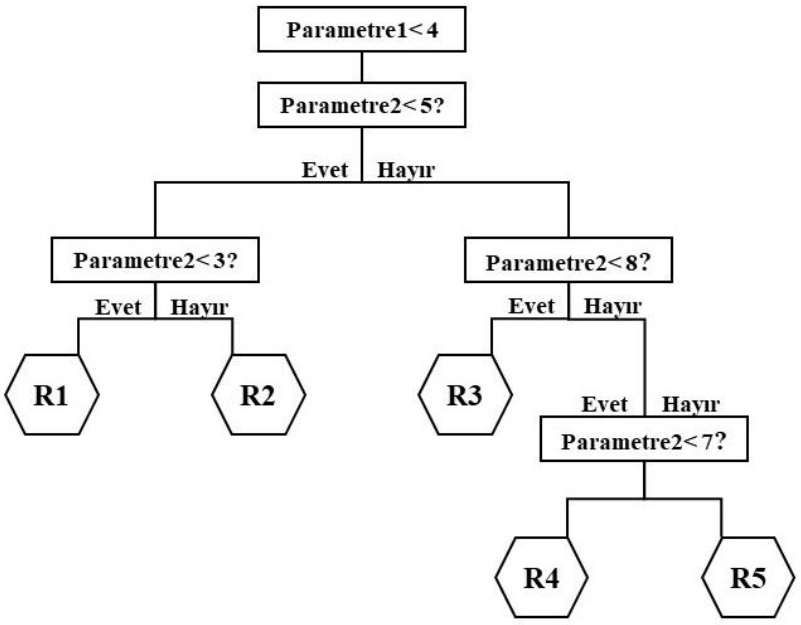
Burada $\lambda = J(w)$ =skaler bir değerdir.

$$w^* = \underset{w}{\operatorname{argmax}} J(w) = \underset{w}{\operatorname{argmax}} \left(\frac{w^T S_B w}{w^T S_W w} \right) = {S_W}^{-1}(\mu_1 - \mu_2) \tag{3.56}$$

Bu ifade Fisher'in Doğrusal Diskriminant'ı olarak bilinmektedir.

3.6.3. Rastgele Orman Sınıflandırıcı

Rastgele orman, Breinman tarafından geliştirilmiş, birbirlerinden bağımsız olarak üretilmiş geniş bir karar ağacı kümesinden oluşan bir toplu öğrenme tekniğidir [63]. Rastgele orman sınıflandırıcının karar ağaçları ile doğrudan bağlantılı olması nedeniyle, öncelikle, genel ağaç yapısından bahsetmek gerekir. Karar ağaçları, büyük bir veri setinden kullanışlı bilgi elde etmek için kullanılan ve görselleştirmede kolaylık sağlayan bir yöntemdir [64]. Karar ağacı, bir Y (0 veya 1) hedef değişkenine ve 0 ile 1 arasında değerler alan x_1 ve x_2 sürekli değişkenlerine sahiptir. Bir karar ağacının ana bileşenleri düğümler ve dallardır ve en önemli işlemler ise ayrılma, durma ve budama işlemleridir [65]. Şekilde basit bir karar ağacı yapısı verilmiştir.



Şekil 3.18: Basit bir karar ağacı yapısı.

Bir karar ağacında üç çeşit düğüm bulunur. (a) Temel düğüm (karar düğümü), tüm veriyi iki veya daha fazla ayrışık alt bölüme ayrıştıran düğümdür. (b) İç düğüm (şans düğümü), ağaç yapısının o noktasındaki olası seçeneklerden birini gösterir. (c) yaprak düğümü (bitiş düğümü),

bir karar veya durumun nihai sonuçlarını gösteren düğümdür. Ağaçtaki dallar ise, temel düğüm ve iç düğümlerden çıkarak, çeşitli durumlara uzanan yapılardır.

Bir ağaç yapısında ayrılma işlemi, düğümlerde verilen koşullara göre verinin alt dallara ayrılmasıdır. Bu işlem, önceden tanımlanmış homojenlik ve durma kriteri karşılanana kadar devam eder. Bir karar ağacında eğer durma kriterleri belirtilmemiş ise, ayrılma işlemi devam eder ve yapı çok karmaşık bir hal alabilir. Durma kuralı olarak genellikle kullanılan kriterler: (a) Bir yaprağın sahip olduğu minimum kayıt sayısı; (b) ayırma işlemi için bir düğümün sahip olması gereken minimum kayıt sayısı; (c) bir yaprağın, temel düğümden uzaklığı (adım sayısı). Durma kriterleri yapılacak analizin hedeflerine ve verinin yapısına göre seçilmelidir. Durma kuralının yeterince iyi çalışmadığı kimi durumlarda ise budama işlemine başvurulur. Budama işleminde, öncelikle büyük bir ağaç oluşturup, daha sonra az bilgi taşıyan düğümlerin silinerek optimal boyutun elde edilmesi şeklinde gerçekleştirilir.

Karar ağacında, verinin en homojen alt gruplarını elde etmek için her adımda düğüm seçimi, tahmin değişkeni ve durdurma uygulanır. Bu homojenlik Gini indeksiyle ölçülür [66]. Ayırma işlemi, her bir alt bölümün Gini indeksi artık azalmamaya başlayana kadar sürdürülür. Bu aşamaya gelmiş bir ağaç, tam yetişmiş ağaç olarak isimlendirilir ve elde edilen bölgeler terminal düğümler olarak isimlendirilir. Tipik bir budanmış sınıflandırma ağacı 3 ila 12 arasında terminal düğüme sahiptir. Ağaçtaki terminal düğümlerin sayısı arttıkça, yapılacak yorumun karmaşıklığı da artar.

Rastgele Orman sınıflandırıcı, veriyi birçok ağaç sınıflandırıcıya uygular ve daha sonra tüm ağaçların tahminlerinden, rastgele seçilen alt kümeler yardımıyla topluluklar oluşturur. Rastgele orman algoritması şu şekilde çalışır [67]:

1. Orijinal veriden $n_{ağaç}$ adet önyükleme örneği çekilir.
2. Her bir örnek için, budanmamış bir sınıflandırma ağacı yetiştirilir. Ağaç yetiştirilirken bazı modifikasyonlar yapılır: Her bir düğümde tüm kestirimciler arasından en iyisini seçmek yerine, kestirimcilerin m_{deneme} tanesini rastgele örnekle ve bu değişkenlerden en iyi ayrımı seç. m_{deneme} sayısının toplam kestirimci sayısına eşit olduğu özel duruma *paketleme* (bagging) denir.
3. $n_{ağaç}$ tane kestirimi kullanarak yeni verinin sınıfını kestir (sınıflandırma için oy çoğunluğu, regresyon için ortalama dikkate alınır).

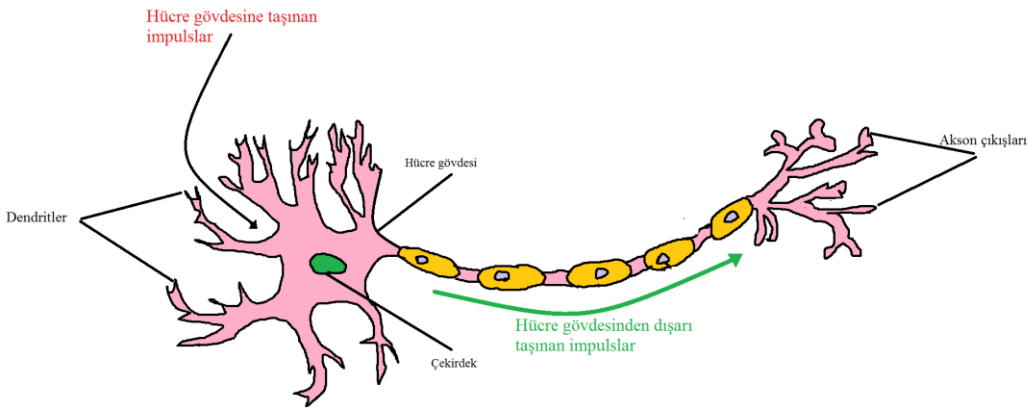
Eğitim verisine dayanan hata oranı kestirimi şu şekilde hesaplanabilir:

1. Her bir önyükleme döngüsünde önyükleme örnekleriyle yetiştirilen ağacı kullanarak, önyüklemede kullanılmayan veriyi kestir.
2. Önyükleme dışında kalan veri kestirimini kümele (Veri noktalarının ortalama %36'sı önyükleme dışında kalır). Hata oranını hesapla ve bunu önyükleme dışı hata kestirimi olarak isimlendir.

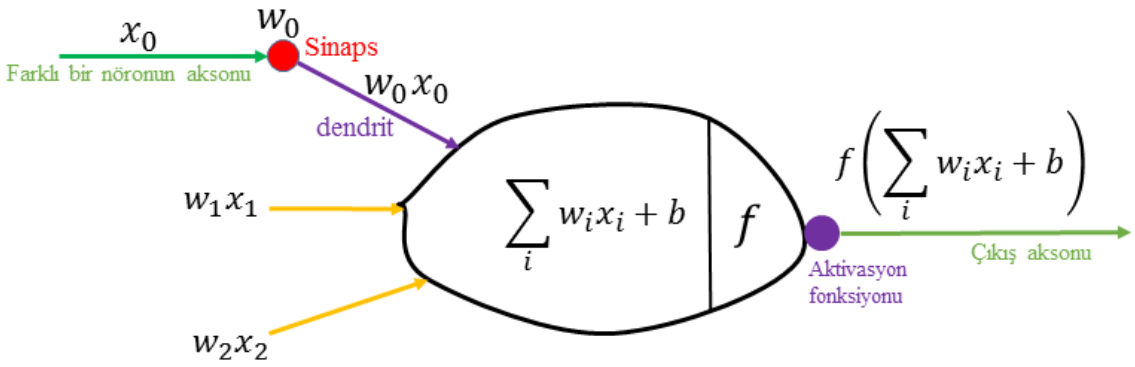
3.6.4. Çok katmanlı algılayıcı (ÇKA)

Bir yapay sinir ağının (YSA) eğitimi, sisteme verilen girişten istenilen çıkışları alabilmek için gerekli ağırlıkları bulma işlemidir. Bu işlem, ağ çıkışı ile istenen çıkış arasındaki hata fonksiyonunun minimize edilmesi olarak da düşünülebilir [68]. Çok katmanlı algılayıcı, geri yayılım ile eğitim yapan yapay sinir ağlarının en çok tercih edilen modelidir [69].

Basit bir sinir ağı, beyine benzetilebilir. Beynin temel hesap birimi nörondur. Her nöron dendritlerinden giriş sinyalini alır, nöron gövdesinde karar işlemi gerçekleştirilir ve aksona doğru çıkış sinyalini üretir. Aksonlar, diğer nöronların dendritleri ile iletişim halindedirler. Böylece bir birçok sinir hücresi bir ağ oluşturmuş olur. Her sinir hücresi, girişten aldığı sinyale karşılık çıkışında belirli bir öğrenilmiş fonksiyona göre çıkış verir. Yapay sinir ağları da bu mantıkla çalışmaktadır [70].



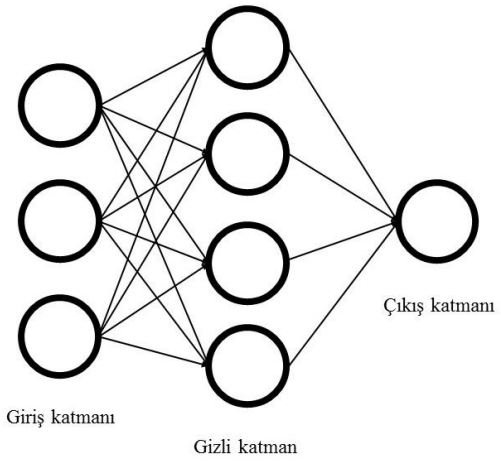
Şekil 3.19: Bir sinir hücresinden bilgi akışı.



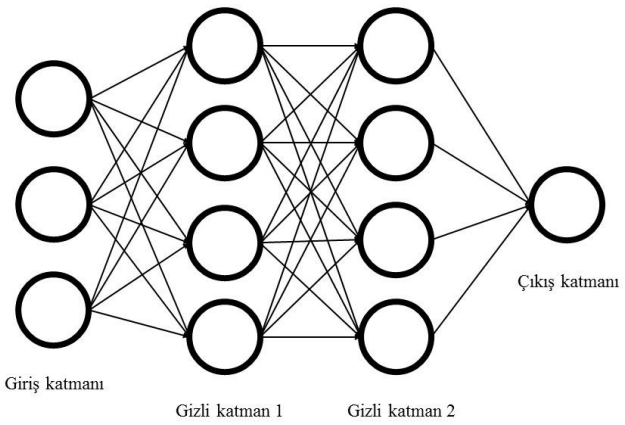
Şekil 3.20: Yapay sinir ağının matematiksel nörona benzetimi.

Sinir hücresinin her girdiye, sahip olduğu aktivasyon fonksiyonuna göre çıkış vermesine benzer şekilde, yapay sinir ağları da bir aktivasyon fonksiyonuna sahiptirler. Yapay sinir ağları, birinin çıkışı diğerinin girişi olacak şekilde modellenebilir. Fakat döngü şeklinde mimariler sonsuz döngüye neden olacağından tercih edilmezler. Ayrıca birbirinden bağımsız ve dağınık nöron yerleşimi de karışıklık yaratacağı için tercih edilmez. Bunun yerine birbirinden ayrılmış nöron katmanları şeklinde organize edilir. Bu tip topolojilerde giriş ve çıkış katmanları haricinde bir veya daha fazla sayıda ara katman bulunur. Bu ara katmanlara "gizli katman" denir. Normal sinir ağları için en sık tercih edilen katman tipi *tamamen bağlı katmanlar*dır. Bu düzende, komşu iki katmandaki nöronların tümü ikili olarak birbirleriyle bağlantılıdır [71].

Çok katmanlı algılayıcı, birbirlerine basitçe bağlanmış nöronlar veya düğümlerden oluşan, giriş vektörü ile çıkış vektörü arasında doğrusal olmayan bir haritalama oluşturan bir sistemdir. Şekilde 3.18'de tek gizli katmana, şekil 3.19'da ise iki adet gizli katmana sahip algılayıcı yapıları verilmiştir. Her iki ağ için de giriş katmanları 3, gizli katmanlar ise 4 adet düğüme (nöron) sahiptir.



Şekil 3.21: Tek bir gizli katmana ve bu katmanda dört tane düğüme sahip ağ.



Şekil 3.22: İki adet gizli katmana ve bu katmanlarda dört tane düğüme sahip ağ.

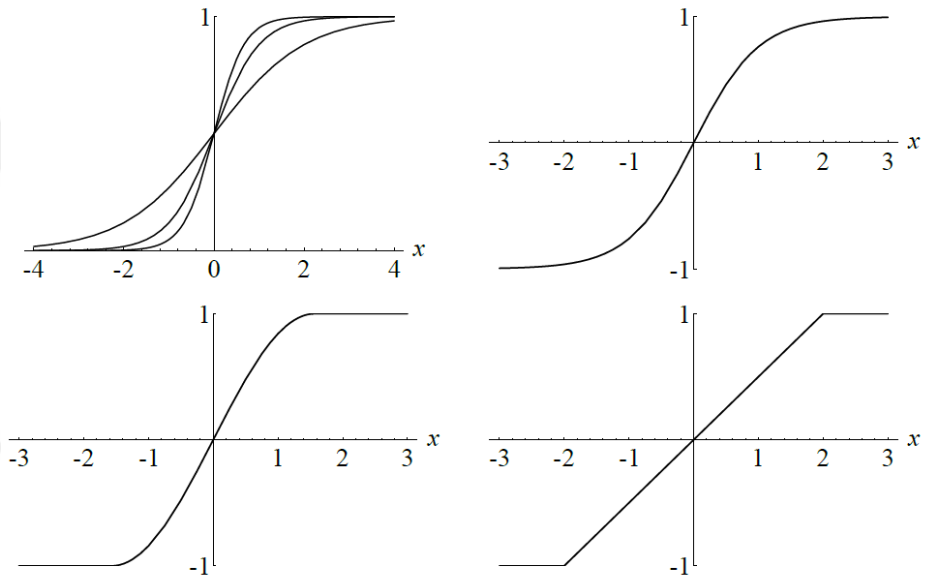
Düğümler birbirine çeşitli ağırlıklarla bağlıdır. Çıkış sinyali, basit bir transfer veya aktivasyon fonksiyonu ile düzenlenmiş olan düğümlerin çıkışlarının fonksiyonudur. Birçok basit doğrusal olmayan fonksiyonun birbirine eklenmesinden ortaya çıkması, ÇKA'nın son derece doğrusal olmayan fonksiyonlar olmasına neden olur. Kolay hesaplanan türeve sahip olmasından dolayı, transfer fonksiyonu olarak genellikle sigmoid ve benzeri fonksiyonlar kullanılır. Şekil 25'te bu fonksiyonlardan bazıları gösterilmiştir. Şekilde sol üstte sigmoid fonksiyonu verilmiştir. Tanım olarak sigmoid fonksiyonu aşağıdaki eşitlikle verilebilir:

$$s_c(x) = \frac{1}{1+e^{-cx}} \tag{3.57}$$

Sigmoid fonksiyonu geri yayılımlı ağlar için en sık kullanılan aktivasyon fonksiyonlarından biridir ve çıkışı (0, 1) aralığındadır. Fonksiyonun aldığı şekil, eşitlikteki c sabitinin değiştirilmesi ile değiştirilebilir. Sigmoid fonksiyona alternatif diğer bir fonksiyon ise simetrik sigmoid fonksiyondur. Simetrik sigmoid şu şekilde tanımlanabilir:

$$S(x) = 2s(x) - 1 = \frac{1-e^{-x}}{1+e^{-x}} \tag{3.58}$$

Şekil 3.20'de sağ üstte hiperbolik tanjant ve sağ altta rampa fonksiyonu verilmiştir.



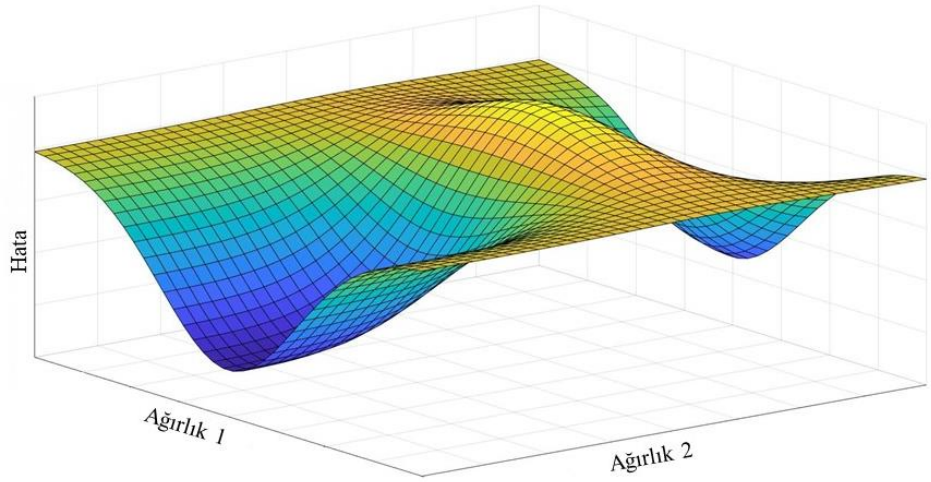
Şekil 3.23: Düğümlerde kullanılan Bazı transfer fonksiyonları.

Bir düğümün çıkışı, bağlantılı olduğu ağırlıkla ölçeklenir ve bir sonraki katmana giriş olmak üzere ileri besleme yapılır. Bu, bilgi işlemenin bir yönü olduğunu ve ÇKA için bu yönün ileri olduğunu gösterir. Bu nedenle ÇKA, ileri beslemeli olarak bilinir. ÇKA'nın mimarisi uygulamaya göre değişmekle birlikte, genellikle birçok nöron katmanından oluşur. Giriş katmanı hesaplama açısından herhangi bir rol oynamaz, görevi giriş vektörünün ağa girişini sağlamaktır. ÇKA, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanına sahiptir. Ağdaki tüm nöronlar, bulunduğu katmandan önceki ve sonraki katmandaki tüm nöronlara bağlıdır.

ÇKA, giriş ve çıkış vektörleri arasındaki fonksiyon ölçülebilir ve çok karmaşık olmadığı durumda; bu fonksiyon uygun bağlantı ağırlıkları ve transfer fonksiyonları seçilerek yaklaşık olarak elde edilebilir [72]. ÇKA'lar, eğitim sırasında öğrenirler ve bu nedenle eğitim sırasında

kullanmak üzere giriş ve onunla ilişkili çıkış eğitim verisine ihtiyaç duyarlar. Eğitim sırasında çok katmanlı algılayıcıya tekrarlı şekilde girişler verilir ve istenilen giriş-çıkış haritalaması oluşana kadar ağdaki ağırlıklar ayarlanır. Eğitim sırasında ÇKA'nın çıkışı, istenilen çıkıştan farklı olabilir. Bu nedenle istenilen ve gerçek çıkış arasındaki farkı tanımlamak üzere bir hata sinyali tanımlanır. Eğitim sırasında ağdaki ağırlıkların nasıl değiştirilmesi gerektiği ayarlanır ve böylece algılayıcının genel hata değeri düşürülür. Bir ÇKA'yı eğitmek için birçok algoritma mevcuttur. Eğitim verisi kullanılarak tüm ayarlamalar yapıldığında, girişe verilecek yeni verilere ait çıktılar genelleştirilebilir.

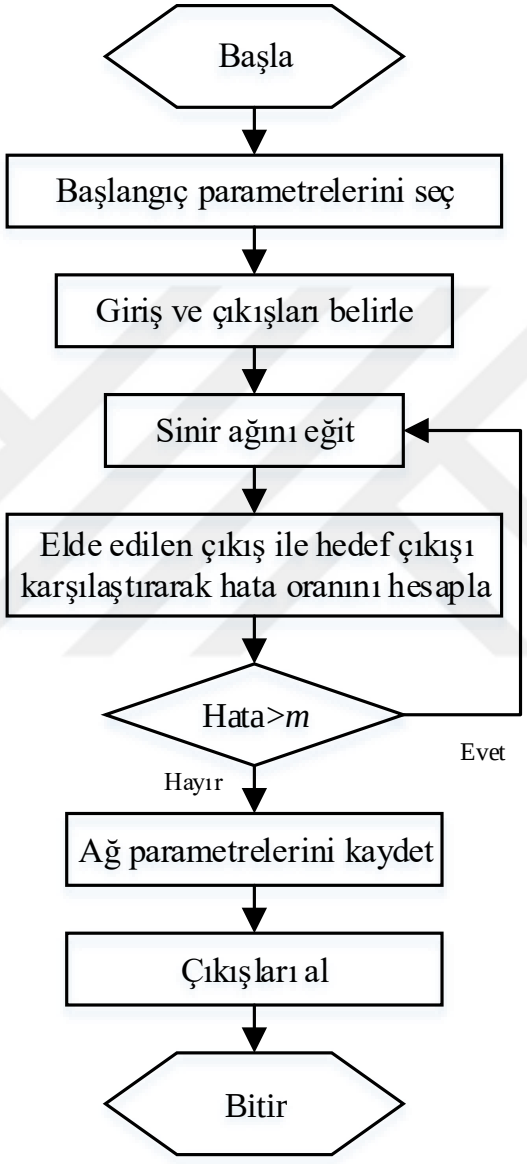
Bir ÇKA'yı eğitmek, her bir ağırlık için değerler tanımlamak anlamına gelir. Yalnızca iki adet ağırlığa sahip bir ÇKA düşünelim. Bu ağırlıkların herhangi bir kombinasyonları için hatalar tanımlanabilir. Ağırlıklar olası tüm değerlerde değiştirilerek ve bu değerlere karşılık gelen hata değerleri üç-boyutlu uzayda çizilerek şekildeki gibi bir çizim elde edebiliriz:



Şekil 3.24: İki ağırlığa sahip bir ÇKA'ya ait hata yüzeyi.

Bu tip yüzeyler *hata yüzeyi* adını alır. Eğitim sonucunda, hatanın minimum olduğu ağırlıklar kombinasyonu elde edilmek istenir. Pratikte, ağırlıkların çoklu nedeniyle bu şekilde bir çizim mümkün değildir. Bu nedenle buradaki minimum noktayı bulacak bir araca ihtiyaç vardır. Bunun için olası bir teknik, *eğim azaltma* (gradient descent) yöntemidir. Geri yayılım eğitim algoritması hatanın global minimum noktasını kestirebilmek için bu prosedürü kullanır. Rumelhart ve diğ. tarafından önerilmiş bir yöntem olan geri yayılım algoritması [73], ÇKA için hesaplama açısından en basit algoritmadır.

Algoritmada başlangıç olarak rasgele küçük ağırlıklar seçilir. Bu seçim, hata yüzeyinde rasgele bir nokta seçilmesine karşılık gelir. Daha sonra geri yayılım algoritması hata yüzeyinin yerel gradyanını hesaplar ve ağırlıkları en dik yerel gradyan doğrultusunda değiştirir. Geri yayılım algoritması şu şekilde özetlenebilir[74]:



Şekil 3.25: Geri yayılım algoritması.

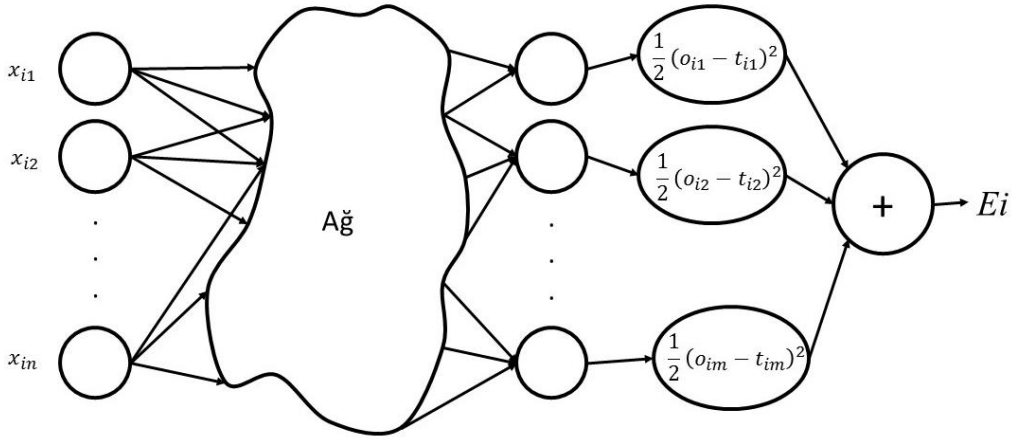
Akış diyagramında *m* ile gösterilen değer, yapılan sınıflandırmanın ulaşması istenilen doğruluk oranına göre değişiklik göstermektedir.

n giriş ve *m* çıkış birimine sahip ileri beslemeli bir yapay sinir ağını ele alalım. Gizli katman sayısından ve nöronların bağlantı desenlerinden bağımsız olarak; x giriş vektörleri ve t hedef

vektörler olmak üzere $\{(x_1, t_1), \dots, (x_p, t_p)\}$ çiftlerine sahip olduğumuzu varsayalım. Her bir nöronun sahip olduğu fonksiyon ise sürekli ve türevlenebilir olsun. Ağırlıklar, başlangıç için rasgele seçilmiş reel sayılardır. Eğitim kümesinden bir x_i girişe verildiğinde, t_i hedefinden farklı olarak bir o_i çıkışı üretilir. Burada istediğimiz durum, her $i = 1, \dots, p$ değeri için, t_i hedefi ile o_i çıktısının birbirlerine olabildiğince yakın olmasını sağlamaktır. Yani hata fonksiyonunu olabildiğince minimize etmektir. Hata fonksiyonu şu şekilde tanımlanabilir [75]:

$$E = \frac{1}{2}\sum_{i=1}^{p}\|o_i - t_i\|^2 \tag{3.59}$$

Sinir ağı, rastgele seçilmiş ağırlıkla başlatıldıktan sonra, hata fonksiyonunun değişimi (gradyan) hesaplanır ve bu değer ilk ağırlıkların düzeltilmesinde kullanılır. Bu işlem yinelemeli bir şekilde yapılır.



Şekil 3.26: Hata minimizasyonu için ağa eklenen düğümler.

Minimizasyon işleminin ilk adımı, ağı genişleterek hatayı otomatik hesaplayacak hale getirmektir. Şekilde genişletilmiş bir ağ örneği görülmektedir. Ağın m adet çıkışından her biri, $\frac{1}{2}(o_{im} - t_{im})^2$fonksiyonunu hesaplayan bir düğüme bağlanmıştır. Burada o_{im} ve t_{im}, çıkış vektörü o_i ve hedef vektörü t_i'nin m bileşenini temsil etmektedir. Eklenen m tane düğümün çıkışları, onları toplayarak toplam hata E_i'yi veren düğümde toplanır. Tüm t_i değerleri için bu işlem yapıldıktan sonra, tüm karesel hatalar toplanır ve $E = E_1 + \cdots + E_p$ hata fonksiyonu bulunur.

Sinir ağındaki ağırlıklar, hatanın küçültülmesi için değiştirilebilecek tek parametredir. E değeri hesaplanırken ağdaki düğümler ve dolayısıyla düğüm fonksiyonları kullanıldığından, ağdaki ℓ

adet ağırlığın sürekli ve türevlenebilir bir fonksiyonu olduğu söylenebilir. Bu nedenle değişim azaltma (gradient descent) işlemi yinelemeli olarak uygulanarak *E* minimize edilebilir:

$$\nabla E = \left(\frac{\partial E}{\partial w_1}, \frac{\partial E}{\partial w_2}, \ldots, \frac{\partial E}{\partial w_\ell}\right) \tag{3.60}$$

$$\Delta w_k = -\gamma \frac{\partial E}{\partial w_k} \qquad k = 1, \ldots, \ell \tag{3.61}$$

Eşitlikte γ öğrenme sabitidir. Öğrenme sabiti her bir iterasyonun negatif değişim yönünde adım uzunluğunu tanımlayan bir sabittir. Bu işlemler öğrenme problemini, ağ fonksiyonunun gradyanının ağırlıklar göz önünde bulundurularak hesaplanması problemine indirger.

3.7.ÇAPRAZ - DOĞRULAMA

Sınıflandırma uygulamalarında, sahip olunan veri kullanılarak yapılan sınıflandırma her zaman doğru sonuç vermeyebilir. Aynı sınıflandırma işlemini farklı veri kümeleriyle yaptıktan sonra hesaplanan ortalama doğruluk; yalnızca bir defa yapılan sınıflandırma sonucuna göre daha doğru bilgi verir. Bu nedenle, kestirim ve sınıflandırma problemlerinde geleneksel olarak çapraz-doğrulama yöntemi kullanılır. Çapraz doğrulama, birbirlerine göre çeşitli avantaj ve dezavantajlara sahip birçok farklı kullanıma sahip olsa da; en sık kullanılan türü k-kat çapraz-doğrulamadır [76].

k-kat çapraz doğrulamada, sınıflandırma için kullanılacak veri k adet olabildiğince eş parçalara ayrılır. Daha sonra bu parçalardan biri dışarıda tutulup, kalan parçalar eğitim verisi olarak kullanılır. Son olarak dışarıda bırakılan parça test verisi olarak kullanılır. Bu işlem tüm parçalar için tekrar edilir. k adet sınıflandırma işleminden elde edilen doğruluk oranlarının ortalaması alınarak genel doğruluk oranı bulunmuş olur. k-kat çapraz doğrulamada en sık kullanılan k değeri ise 10'dur. [77]

k-kat çapraz doğrulamanın sık kullanılan özel bir versiyonu ise birini-dışarıda-bırak çapraz doğrulamadır. Burada k değeri, verideki örnek sayısına eşittir. Böylece sınıflandırma işlemi her örnek için, o örnek test verisi olmak üzere dışarıda bırakılarak yapılır. Toplamda ise örnek sayısı kadar sınıflandırma işlemi yapılmış olur. Fakat burada, doğrulama için yapılacak işlem maliyeti, verinin sahip olduğu örnek sayısıyla orantılıdır.

4. BULGULAR

4.1. ÇDGKA KULLANILARAK MS KESTİRİMİ

Çalışma kapsamında ilk olarak MS hastaları ve sağlıklı katılımcıların EEG sinyalleri kullanılarak MS kestirimi yapılması amaçlanmıştır. 50 MS hastası ve 50 sağlıklı katılımcının dinlenme halindeki gözler kapalı şekilde alınmış EEG kayıtlarına, ön sinyal işleme uygulanmış ve sinyaller çalışma için uygun frekans aralığına ve genlik seviyesine getirilmiştir. Bu işlemler sonrasında EEG sinyalleri ÇDGKA işlemine tabi tutulmuş her sinyalin her kanalı için 15 ila 17 arasında değişen sayılarda ÖKF'ler elde edilmiştir. Elde edilen ÖKF'ler, üç farklı ÖKF seçme yöntemine tabi tutulmuş ve her üç yöntem tarafından önerilen 3, 4. ve 5. ÖKF'ler seçilmiştir. Böylece çalışmada kullanılacak ÖKF sayısı yaklaşık %80 oranında azaltılmıştır.

Seçilmiş olan ÖKF'lerden, sınıflandırma işleminde kullanılmak üzere; fraktal boyutlar, Hurst üssü ve sivrilik parametreleri elde edilmiştir. Bu parametrelerin seçilmesinin bir nedeni, geçmişte yapılmış benzer çalışmalarda iyi neticeler vermiş olmalarıdır [20, 45]. Diğer bir neden ise sinyalin farklı EEG cihazları tarafından kayıt edilmiş olan sinyallerde, cihaz farklılığından kaynaklanan değişikliklerin sınıflandırma üzerindeki etkisini azaltmaktır. Böylece toplamda 21 EEG kanalı, her kanal için 3 ÖKF ve her ÖKF için 3 öznitelik olmak üzere, örnek başına 21x3x3=189 öznitelik elde edilmiştir.

50 MS hastası ve 50 Sağlıklı katılımcıya ait EEG sinyallerinde, her katılımcı için elde edilen 189'ar adet öznitelik, 4 farklı sınıflandırıcı kullanılarak sınıflandırılmıştır. Bu işlem için kullanılmış olan sınıflandırıcılar: (1) "klasik eğiticili" öğrenme yöntemlerinden biri olan *k-en yakın komşu (k-NN).* (2) kolektif öğrenme yöntemlerinden "yerine koyarak öğrenme" grubuna dâhil olan *rastgele orman algoritması*. (3) "yapay sinir ağlarına" dâhil olan çok katmanlı algılayıcı. (4) Klasik öğrenmede "boyut azaltma" yöntemlerinden biri olan doğrusal ayrımcılık analizi kullanılmıştır.

Yapılan sınıflandırmalar, kullanılan özniteliklerin sınıflandırma üzerindeki etkilerinin daha iyi görülmesi amacıyla, yukarıda bahsedilen üç farklı sinyal parametresinin çeşitli kombinasyonları kullanılarak yapılmıştır. Tablo 4.1'de, yapılan sınıflandırmalardan elde edilmiş olan doğruluk oranları ve standart sapmalar verilmiştir.

Tablo 4.1: ÇDGKA kullanılarak MS kestirimi.

	K-Nn (%)	Çok Katmanlı Algılayıcı (%)	Rastgele Orman (%)	Doğrusal Ayrımcılık Analizi (%)
Fraktal Boyutlar	74±1,9	91±1,1	96±1,0	92±2,2
Hurst Üssü	73±1,3	92±1,2	95±1,1	85±3,1
Sivrilik	89±0,8	88±1,2	96±1,6	75±2,2
F.B + H.Ü	85±1,3	91±1,3	91±2,0	96±1,3
F.B + Sivrilik	81±1,3	89±1,1	93±2,7	74±3,5
H.Ü + Sivrilik	85±1,2	90±1,2	96±1,3	73±4,1
F.B + H.Ü + Sivrilik	86±1,1	90±1,1	97±0,9	74±2,8

Tablo 4.1'den görüleceği gibi; MS hastası/sağlıklı sınıflandırmasında rastgele orman sınıflandırıcı kullanılarak %97 oranında bir doğruluk elde edilmiştir. Bu doğruluk oranları için kullanılan özniteliklere bakıldığında her üç özniteliğin bir arada kullanılmış olduğu görülmektedir. Bu oranlara yakın olarak; yine rastgele orman sınıflandırıcının Hurst üssü ve sivrilik parametreleri ile birlikte kullanıldığı sınıflandırmada; ayrıca doğrusal ayrımcılık analizi ile fraktal boyutlar ve Hurst üssü parametrelerinin bir ara kullanıldığı sınıflandırmada % 96 oranında doğruluklar elde edildiği görülmektedir.

Rastgele orman sınıflandırıcı ve üç öznitelik bir arada kullanılarak elde edilmiş olan %97'lik doğruluğa sahip sınıflandırma için bazı parametreler Tablo 4.2'de verilmiştir.

Tablo 4.2: En iyi doğruluk oranı için sınıflandırma parametreleri.

Doğruluk (%)	FN	FP	Sen(%)	Spe(%)
97	1	1	0,97	0,98

4.2.ÇDGKA KULLANILARAK MS HASTALARINDA BİLİŞSEL ENGELLİLİK KESTİRİMİ

Çalışma kapsamında, MS hastalarının kendi aralarında bilişsel engelli ve bilişsel korunmuş şeklinde sınıflandırılması yapılmıştır. NSBMS ölçeği ile değerlendirilmiş ve buna göre bilişsel engelli/bilişsel korunmuş şeklinde sınıflandırması yapılmış MS hastalarında, aynı sınıflandırmanın EEG sinyallerinden yararlanılarak yapılması için, MS hastası/sağlıklı sınıflandırmasındaki ile benzer aşamalar izlenmiş sınıflandırma işlemi yapılmıştır. 50 bilişsel

bozulmuş ve 50 bilişsel korunmuş MS hastası ile yapılmış olan bu sınıflandırma için sonuçlar Tablo 4.3'te verilmiştir. Tablo yüzde cinsinden doğruluk oranlarını ve bu oranlara ait standart sapmaları içermektedir.

Tablo 4.3: ÇDGKA kullanılarak MS'te bilişsel engellilik kestirimi.

	k-NN (%)	**Çok Katmanlı Algılayıcı** (%)	**Rastgele Orman** (%)	**Doğrusal Ayrımcılık Analizi** (%)
Fraktal Boyutlar	66±2,4	64±3,6	64±2,7	58±3,1
Hurst Üssü	67±2,1	65±3,4	62±4,0	62±4,0
Sivrilik	65±2,4	55±3,8	58±3,9	53±4,0
F.B + H.Ü	69±2,7	64±3,7	65±3,0	56±4,2
F.B + Sivrilik	64±2,1	62±3,5	64±3,7	53±5,4
H.Ü + Sivrilik	67±2,6	63±3,9	63±3,7	53±7,7
F.B + H.Ü + Sivrilik	69±2,3	36±3,2	64±3,0	53±8,3

Tablo 4.2'den görüleceği gibi, en yüksek doğruluk oranları k-NN sınıflandırıcı kullanılarak elde edilmiştir. Her üç öznitelik birlikte kullanılarak %69'luk bir sınıflandırma doğruluna ulaşılmıştır. Diğer bir %69 doğruluk oranı ise fraktal boyutlar ve Hurst üssü pararmetreleri birlikte kullanıldığı durumda elde edilmiştir. Sınıflandırıcı performanslarına bakıldığında ise k-NN sınıflandırıcının diğerlerine göre daha yüksek doğruluk verdiği gözlenmektedir.

Her üç öznitelik ve k-NN sınıflandırıcı kullanılarak elde edilmiş olan %69'luk başarıma sahip sınıflandırma için bazı parametreler Tablo 4.4'te verilmiştir.

Tablo 4.4: En iyi sınıflandırma doğruluğu için bazı parametreler.

Doğruluk (%)	**FN**	**FP**	**Sen(%)**	**Spe(%)**
69	18	13	0,67	0,71

4.3.ÖZNİTELİK BAŞARIMLARI AÇISINDAN DEĞERLENDİRME

Çalışmada yapılan diğer bir analiz, EEG sinyallerinden elde edilmiş olan özniteliklerin sınıflandırma doğruluğuna etkileri bakımından karşılaştırmasıdır. MS hastalarının bilişsel engelli/bilişsel korunmuş olarak sınıflandırıldığı bu analizde, 10 farklı öznitelik ve 4 farklı sınıflandırıcı kullanılmıştır. Bu öznitelikler; ortalama, standart sapma, sinyal gücü, aktivite,

mobilite, kompleksite, çarpıklık, sivrilik (kurtosis), fraktal boyutlar ve Hurst üssü parametreleridir. Sinyale ait istatistiksel, şekilsel ve dağılımla ilgili özniteliklerin kullanıldığı bu analizin sonuçları, doğruluk yüzdesi ve standart sapmaları şeklinde aşağıdaki Tablo 4.5'te verilmiştir. Tablodan görüleceği üzere, kullanılan sınıflandırıcıya göre doğruluk oranları değişmekle birlikte, aktivite parametresinin k-NN sınıflandırıcıda %80'lik bir doğruluk oranına ulaştığı görülmektedir. Bunu %79 doğruluk oranıyla Hurst üssü parametresi izlemektedir. Dört farklı sınıflandırıcının ortalama değerleri hesaplandığında ise standart sapma, sinyal gücü, aktivite ve Hurst üssü parametrelerinin, diğer parametrelere olsa küçük de olsa daha yüksek başarımlar verdikleri görülmektedir.

Tablo 4.5: Farklı öznitelikler için sınıflandırma doğruluk oranları ve standart sapmalar.

	k-NN(%)	**Çok-Katmanlı Algılayıcı (%)**	**Rastgele Orman (%)**	**Doğrusal Fark Analizi (%)**	**Ortalama (%)**
Ortalama	62,8±1,2	56,7±2,7	53,7±3,6	57,1±4,3	57,6±2,9
Standart Sapma	77,4±1,4	74,1±2,7	72,5±3,3	64,5±4,7	72,1±3
Sinyal Gücü	77,4±1,4	74,1±2,7	72,5±3,3	64,5±4,7	71,3±3
Aktivite	80,3±1,4	69,2±3,5	72,3±3,6	62,6±3,5	71,1±3
Mobilite	70,5±2,7	68,5±3,7	71,2±1,6	54,6±3,5	66,2±2,9
Kompleksite	75±2,3	64,7±3,5	69,5±2,7	59±3,0	67±2,9
Çarpıklık	65,5±2,3	57,2±4,1	60,4±2,9	58,3±2,8	60,3±3
Sivrilik	65,8±3,3	57±3,1	59,4±3,1	50,1±3,1	58,1±3,1
Hurst Üssü	79,2±2,2	72,6±4,0	70,6±2,5	61±2,7	70,8±2,8
Fraktal Boyutlar	76,4±1,7	63,9±3,8	68,8±2,6	58,2±2,7	66,8±2,7

4.4.EEG KANALLARININ BAŞARIMLARI AÇISINDAN DEĞERLENDİRME

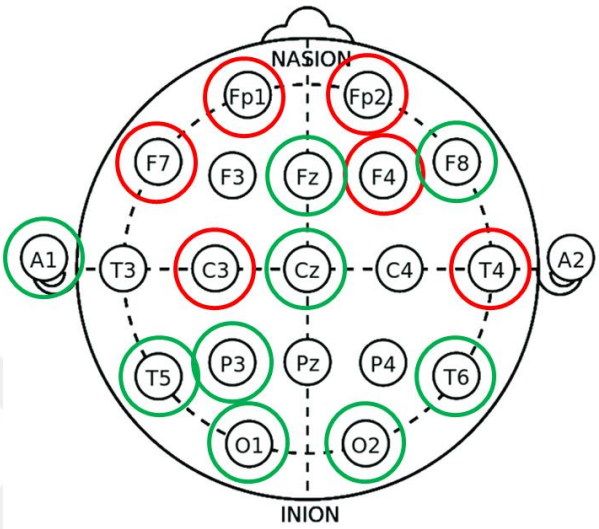
Çalışmada kullanılan EEG kayıtları, 21 kanaldan kaydedilmiştir. Bu 21 kanalın sınıflandırma doğruluklarına etkilerinin analizi için, tüm EEG kanalları ile ayı ayrı sınıflandırma yapılmıştır. MS hastalarının kendi içlerinde bilişsel engelli/bilişsel korunmuş şeklinde sınıflandırıldığı analizde; ortalama, standart sapma, sinyal gücü, Hjorth parametreleri, çarpıklık, basıklık, Hurst üssü ve fraktal boyutlar parametreleri öznitelik olarak kullanılmıştır. Sınıflandırma sonucunda elde edilen doğruluk oranları ve bu oranlara ait standart sapmalar Tablo 4.6'da verilmiştir.

Tablodan da görüleceği üzere; 7. kanal olan F_8 kanalı ve 10. kanal olan C_z kanalı, diğer kanallara göre daha yüksek doğruluk oranları vermiştir. En düşük doğruluk değerleri ise %58,2 ile F_{P1} kanalından elde edilmiştir. Bu farklılıkların nedeni tam olarak bilinmemekle birlikte, Cz kanalının 10-20 elektrot diziliş sisteminde, merkezi bir konumda olduğu görülmektedir. Dört farklı sınıflandırıcı ile yapılan sınıflandırma doğrulularının ortalamaları dikkate alındığında ise, T_5 ve T_6 kanallarının, diğer kanallara göre daha yüksek sınıflandırma başarımına sahip oldukları görülmüştür.

Tablo 4.6: Farklı EEG kanalları için sınıflandırma doğruluk oranları ve standart sapmaları.

	k-NN (%)	**Çok-Katmanlı Algılayıcı (%)**	**Rastgele Orman (%)**	**Doğrusal Fark Analizi (%)**	**Ortalama (%)**
F_{P1}	58,2±3,1	52,1±3,0	55,7±3,4	48,4±2,2	53,5±2,9
F_{P2}	70,8±2,5	51,9±3,3	56±2,7	45,5±2,3	56±2,7
F_7	68±1,7	50,6±2,0	56,2±2,6	46,6±3,5	55,3±2,4
F_3	72,2±1,1	55,6±3,3	65,1±3,6	44,4±2,7	59,3±2,7
F_Z	68,5±2,1	57±3,5	66±5,0	58,7±2,8	62,5±3,3
F_4	63,4±2,6	52,6±4,1	61±2,9	48±3,4	56,2±3,2
F_8	77,9±2,9	58,4±3,7	65,8±4,2	50±2	63±3,2
T_3	68,9±2,6	58,3±3,3	61,4±2,8	53,5±3,5	60,5±3
C_3	70,9±1,7	52,4±4,3	65,9±2,2	45,2±1,3	58,6±2,4
C_Z	76,5±1,5	53,9±4,2	66,2±3,4	55,9±3,7	63,1±3,4
C_4	64,1±1,3	55,3±1,3	66,4±2,1	53,2±3,3	59,7±2
T_4	70,9±2,2	51,5±4,7	62±1,8	46,5±3,8	57,7±3,1
T_5	73±2,2	66,5±3,6	63,1±3,3	64,1±2,9	66,7±3
P_3	67,9±1,7	57,3±4,2	67,2±1,9	58,8±3,2	62,8±3,7
P_Z	67,9±2,8	58,3±1,8	68±2,7	51,4±3,1	61,4±2,6
P_4	70,5±2,6	54,8±4,6	63,2±3,7	55,5±2,3	61±3,3
T_6	72,5±2,7	59,4±3,0	68,8±3,5	60,8±1,7	65,4±2,7
O_1	71,8±2,4	60,6±5,4	67±2,7	53±2,9	63,1±3,3
O_2	65,9±2,8	59,3±3,1	65,6±3,3	58,9±2,5	62,4±2,9
A_1	68,1±2,9	62,6±4,0	62,1±2,6	55,5±3,0	62,1±3,1
A_2	72,3±2,6	57,2±3,5	54,7±2,9	54,8±2,3	59,7 2,8

Tabloda görülen doğruluk değerlerinin ortalamaları alındığında, ortalama doğruluğun %60,4 olduğu görülmektedir. Bu ortalama değerden 2 puan yukarı ve 2 puan aşağı değerler sınır olarak kabul edilip, buna göre düşük ve nispeten yüksek doğruluk değerleri veren EEG kanalları incelendiğinde, Şekil 4.1'deki gibi bir dağılım ortaya çıkmaktadır.



Şekil 4.1: EEG kanallarından elde edilen sınıflandırma doğruluklarının dağılımı.

Şekil 4.1'den görüleceği gibi, frontal lob üzerindeki kanallar, diğer kısımlara göre daha düşük sınıflandırma doğruluğuna sahiptirler.

4.5.ÖZ KİP FONKSİYONU SEÇME YÖNTEMLERİ AÇISINDAN DEĞERLENDİRME

Çalışma kapsamında, görgül kip ayrıştırma sonucunda elde edilen öz kip fonksiyonlarının kullanışlı bilgi taşıyanlarını belirlemek amacıyla geçmişte önerilmiş yöntemlerden bazıları karşılaştırılmıştır. Güç tabanlı, korelasyon tabanlı ve güç yoğunluk spektrumu tabanlı seçim yöntemlerinin karşılaştırıldığı analizde, Tablo 4.5'te verilen doğruluk sonuçları ve bu sonuçlara ait standart sapmalar elde edilmiştir.

Tablo 4.7: Farklı ÖKF seçim yöntemlerinin sınıflandırma doğruluğu açısından karşılaştırılması.

	k-NN (%)	Çok Katmanlı Algılayıcı (%)	Rastgele Orman (%)	Ortalama (%)
Güç Tabanlı	77±2,6	67±4,2	73±3,5	72,3±2,4
Korelasyon Tabanlı	76±2,1	68±4	75±3,2	73±4,1
Gys Tabanlı	73±2,6	70±4,2	74±3,1	73,2±3,3

Tablo 4.5'te üç farklı sınıflandırıcı kullanılarak yapılan karşılaştırmada, ÖKF seçim yöntemlerinin doğruluğa etkilerinin, kullanılan sınıflandırıcıya göre değiştiği görülmektedir. k-NN sınıflandırıcı için en iyi doğruluk oranını %77 ile güç tabanlı ÖKF seçim yöntemi vermiştir. Çok katmanlı algılayıcı için en iyi doğruluk oranını %70 doğruluk oranı ile GYS tabanlı seçim yöntemi vermişken; rastgele orman sınıflandırıcıda en iyi doğruluk oranını %75 doğruluk oranı ile korelasyon tabanlı seçim yöntemi vermiştir. Sonuçlar, farklı ÖKF seçim yöntemlerinin karşılaştırılmasında, kullanılan sınıflandırıcının da büyük önem taşıdığını göstermiştir. Bununla birlikte, farklı sınıflandırıcıların ortalama sonuçları hesaplandığında, her üç ÖKF seçim yönteminin de benzer ortalama doğruluk değerleri verdikleri görülmüştür.

4.6.SEÇİLEN ÖKF'LERİN SINIFLANDIRMA BAŞARIMINA ETKİSİ

Bir önceki analizde, üç farklı ÖKF seçim yöntemi kullanılarak, bu yöntemlerin sınıflandırma doğruluğu açısından karşılaştırması yapılmıştı. Bu seçim yöntemlerinin kullanım için önerdikleri ÖKF'ler Tablo 4.6'da verilmiştir.

Tablo 4.8: Farklı seçim yöntemlerinin önerdiği ÖKF önem sıralamaları.

		Kullanılması Önerilen Yöntemlerin Öncelik Sıraları													
		1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**	**13**	**14**
ÖKF seçim yöntemleri	**Güç Tabanlı**	4	3	7	9	5	8	6	10	2	11	14	12	13	1
	Korelasyon Tabanlı	4	3	5	7	8	6	9	2	10	11	12	1	13	14
	GYS Tabanlı	4	3	5	2	6	7	8	9	10	11	1	12	13	14

Tablodan görüleceği gibi, her üç yöntem de en kullanışlı ÖKF olarak 4 numaralı ÖKF'yi ve ikinci önem sırasında da 3 numaralı ÖKF'yi önermişlerdir. Korelasyon tabanlı ve GYS tabanlı ÖKF seçim yöntemleri 5 numaralı ÖKF'yi üçüncü önem sırasında önerirken; güç tabanlı seçim

yöntemi üçüncü önem sırasında 7 numaralı ÖKF'yi önermişlerdir. Bu bilgilerden yararlanılarak; 3, 4, ve 5 numaralı ÖKF'lerin diğer ÖKF'lere göre daha kullanışlı oldukları yorumu yapılabilir.

Tablo 4.7'de üç farklı ÖKF seçim yöntemi kullanılarak kullanışlı oldukları belirlenen 3, 4 ve 5 numaralı ÖKF'lerin çeşitli kombinasyonları oluşturularak sınıflandırma işleminde kullanılmıştır. MS hastalarının bilişsel engelli/bilişsel korunmuş olma durumlarına göre yapılan sınıflandırmalarda, aşağıdaki doğruluk sonuçları ve standart sapma değerleri elde edilmiştir.

Tablo 4.9: Seçilen ÖKF'lerin kendi arasında kıyaslanması.

	k-NN (%)	**Çok Katmanlı Algılayıcı (%)**	**Rastgele Orman (%)**	**Doğrusal Fark Analizi (%)**	**Ortalama (%)**
ÖKF3	67,4±2,8	60,3±2,9	71,1±4,0	59,8±4,1	64,6±3,4
ÖKF4	63,5±1,8	59,8±4,4	61,9±2,0	52,4±2,1	59,4±2,6
ÖKF5	67,5±2,4	54,5±4,5	62,4±3,7	50,9±1,3	58,8±2,9
ÖKF34	65,9±2,3	62±5,9	60,1±5,0	59,4±4,5	61,9±4,4
ÖKF35	68,8±2,3	59,4±4,0	69,4±4,5	57,4±2,9	63,7±3,4
ÖKF45	69,3±1,8	62,9±3,9	60,4±4,3	57,1±4,1	62,4±3,5
ÖKF345	69±2,3	63±3,2	64±3,0	53±8,3	62,2±4,2

Tablodan görüleceği gibi; en iyi sınıflandırma sonucuna, %71'lik doğruluk oranıyla, yalnızca 3 numaralı ÖKF'nin ve rastgele orman sınıflandırıcının kullanıldığı sınıflandırma işlemi sonucunda ulaşılmıştır. ÖKF 3 ve ÖKF 5'in birlikte kullanılması durumu da hem rastgele orman hem de k-NN sınıflandırıcılar için % 69 doğruluk oranlarına ulaşmıştır. Sınıflandırıcılardan bağımsız bir değer elde etmek için ortalama değerler hesaplandığında ise, ÖKF 3'ün diğer ÖKF'lere göre az da olsa daha yüksek başarım sağladığı görülmüştür.

4.7.EEG SİNYALİ VEYA ÇDGKA YAKLAŞIMININ SINIFLANDIRMA BAŞARIMINA ETKİSİ

Çalışmanın son aşamasında, yapılan sınıflandırmalarda ÖKF kullanımı ile orijinal EEG sinyallerinin kullanımının, sınıflandırma doğruluğu açısından etkisi araştırılmıştır. Bunun için; hem MS/sağlıklı sınıflandırması hem de MS hastaları içerisinde bilişsel engelli/bilişsel korunmuş sınıflandırmaları yapılmıştır. Tüm sınıflandırmalar, Hurst üssü, fraktal boyutlar ve kurtosis parametrelerinin çeşitli kombinasyonları kullanılarak yapılmıştır. Öznitelikler ise

EEG'lerin 10. Kanalından elde edilen 3, 4 ve 5 numaralı ÖKF'lerden elde edilmiştir. Tablo 4.8'de bu sınıflandırmaya ilişkin sonuçlar verilmiştir.

Tablo 4.10: Sınıflandırma doğruluğu açısından orijinal EEG – ÖKF kullanımı karşılaştırması.

		ORİJİNAL EEG		**ÇDGKA**	
		MS/Sağlıklı (%)	**Bilişsel Engelli/Korunmuş (%)**	**MS/Sağlıklı (%)**	**Bilişsel Engelli/Korunmuş (%)**
k-En Yakın Komşu	**Fraktal Boyutlar**	80±1,5	79±2,3	74±1,9	66±2,4
	Hurst Üssü	86±1,4	76±1,9	73±1,3	67±2,1
	Sivrilik	77±1,6	61±2,4	89±0,8	65±2,4
	F.B + H.Ü	89±1,2	77±2	85±1,3	69±2,7
	F.B + Sivrilik	87±1	67±1,9	81±1,3	64±2,1
	H.Ü + Sivrilik	87±1,2	74±2,2	85±1,2	67±2,6
	F.B + H.Ü + Svr	91±0,9	72±2,6	86±1,1	69±2,3
	Ortalama	85,3±1,3	72±2,2	81,8±1,3	66,7±2,4
Çok katmanlı algılayıcı	**Fraktal Boyutlar**	79±2,9	60±2,4	77±2,2	63±2,4
	Hurst Üssü	84±1,1	68±3,6	80±1,6	65-2
	Sivrilik	67±2,5	52±2,7	86±1,4	55-3,6
	F.B + H.Ü	89±1,3	68±2,7	91±1,1	63-2,6
	F.B + Sivrilik	86±1,6	62±3,7	85±1,6	62-2,9
	H.Ü + Sivrilik	85±1,3	63±4,2	91±0,8	63-4
	F.B + H.Ü + Svr	94±1,3	66±3	90±1,1	64-3,7
	Ortalama	83,4±1,7	62,7±3,2	90,1±1,2	62,3±3,6

Tablo 4.8'de en yüksek doğruluğa sahip MS/sağlıklı sınıflandırmasının, Orijinal EEG sinyallerinden elde edilmiş olan üç farklı özniteliğin bir arada olduğu ve ÇKA sınıflandırıcının kullanıldığı durumda %94 doğrulukla yapıldığı görülmektedir. GKA kullanımında bu oran en fazla %91'e kadar çıkmıştır. En yüksek doğruluğa sahip bilişsel engelli/bilişsel korunmuş sınıflandırması doğruluk oranında ise %79 doğruluk oranı ile k-NN sınıflandırıcı ve orijinal EEG sinyalleri kullanıldığı durumda, öznitelik olarak yalnızca fraktal boyutlar parametresinin kullanıldığı sınıflandırma en iyi sonucu vermiştir.

Analizde daha genel bir karşılaştırma yapılabilmesi için, farklı öznitelik kombinasyonlarının kullanıldığı sınıflandırmaların doğruluk oranlarının her durum için ortalaması alınmış ve tablo öznitelikten bağımsız hale getirilmiştir.

Tablo 4.11: Öznitelikten arındırılmış orijinal EEG – GKA karşılaştırması.

	ORİJİNAL EEG		**ÇDGKA**	
	MS/Sağlıklı	**Bilişsel Engelli/Korunmuş**	**MS/Sağlıklı**	**Bilişsel Engelli/Korunmuş**
k-NN	85,2±1,2	72,2±2,1	81,8±1,3	66,7±2,3
Çok Katmanlı Algılayıcı	83,4±1,7	62,7±3,1	85,7±1,4	62,1±3

Tablo 4.9'da bu karşılaştırmaya ait sonuçlar verilmiştir. Ortalama doğruluk değerlerine bakıldığında; MS/sağlıklı sınıflandırmasında en yüksek doğruluk oranının %85,7 ile ÖKF'ler kullanılarak yapılan sınıflandırmalardan elde edildiği görülmektedir. MS hastaları arasında yapılmış bilişsel engelli/korunmuş sınıflandırmasında ise en yüksek doğruluk oranının %72 doğruluk oranı ile orijinal EEG sinyalleri kullanılarak yapılan sınıflandırma sonucunda elde edildiği görülmektedir.

5. TARTIŞMA VE SONUÇ

Bu tez çalışmasında MS hastalığının teşhisinin zaman alıcı ve maliyetli bir işlem olması probleminden yola çıkılarak, daha düşük maliyetli ve hızlı çıktılar veren EEG cihazı kullanılarak hastalık tespiti yapılması amaçlanmıştır. Ayrıca MS hastalığında ortaya çıkan ve hastalığın ilerleyişi hakkında bilgi sağlayan bilişsel engellilik durumunun EEG sinyalleri kullanılarak kestirilmesi hedeflenmiştir. 50 MS hastası ve 50 sağlıklı katılımcıya ait toplam 100 adet dinlenme durumu EEG sinyali ile yapılan sınıflandırma sonucunda, MS tespitinde %97 başarıya ulaşılmıştır. MS hastalarının kendi bilişsel engelli/bilişsel korunmuş şeklinde sınıflandırılması ise toplamda 100 MS hastasına ait EEG verileri kullanılarak yapılmış ve % 69 doğruluk oranına ulaşılmıştır.

Elde edilen bu doğruluk oranları, MS kestirimi için oldukça iyi olmakla birlikte; bilişsel engellilik durumu kestirimi için yeterince iyi değildir. Bunun nedeni, bilişsel engellilik kestirimi için kullanılan EEG sinyallerin tümünün MS hastalarından alınmış benzer özelliklerdeki sinyaller olmasıdır. Bilişsel engellilik ölçümünde kullanılan NSBMS ölçeği, 0 ila 4 puan arasında değerler almaktadır. Bu durum ise, sınıflandırma için gerekli olan farklılıkların yeterli oranda sağlanamadığı anlamına gelebilir.

Yukarıda bahsedilen iki analizin yanında, gelecek çalışmalara rehber olması açısından; EEG kanallarının, EEG sinyalinden elde edilmiş ÖKF'lerin, ÖKF seçme yöntemlerinin ve sınıflandırma için kullanılan 10 farklı özniteliğin sınıflandırma başarımı üzerindeki etkileri araştırılmıştır. Elde edilen sonuçlar, bu çalışmada kullanılmamıştır. Bunun nedeni, elde edilen analiz sonuçlarının yalnızca bu çalışmada kullanılan veri seti için geçerli olma ihtimalidir. Farklı veri setleri kullanılarak benzer sonuçlar elde edilmediği sürece, bu çalışmada elde edilen kanal, öznitelik, ÖKF seçim yöntemleri ve ÖKF verimlilikleri genelleştirilemez. Aksi takdirde bu çalışma için aşırı öğrenme durumu ortaya çıkabilir ve bu da yanıltıcı sonuçların elde edilmesine neden olabilir.

MS hastalığı, merkezi sinir sisteminin büyük bir kısmını etkileyebilmekte, belirli bir alanla sınırlı kalmamaktadır. Bu nedenle lezyonların yoğunlaştıkları bölgelere göre, EEG kanallarında meydana gelen bozulmalar değişebilmektedir. Kullanılan EEG kanallarının sınıflandırma başarımına etkisi incelendiğinde, *Cz* ve F_8 kanallarının diğer kanallara göre daha yüksek doğruluklu sonuçlar verdiği görülmüştür. 10-20 elektrot yerleşim sistemine göre bakıldığında,

Cz kanalının merkezi bir kanal olduğu ve beynin diğer bölgelerinde meydana gelen bozulmalardan mesafe orantılı bir şekilde etkileneceği varsayılabilir. Bu da *Cz* kanalı kullanımının sınıflandırma işlemi için iyi bir seçim olduğunu gösterebilir. Fakat bu kanalın yanında, herhangi bir merkezi özelliği olmayan F_8 kanalının da sınıflandırma açısından, diğer kanallara göre daha yüksek başarım göstermesi, bu varsayımı geçersiz kılabilecektir.

3 farklı ÖKF seçim yöntemi kullanılarak seçilen ÖKF'lerin sınıflandırma başarımına etkileri incelendiğinde, 4, 3 ve 5 numaralı öz kiplerin ve bunların kombinasyonlarının bir arada kullanımının, birbirlerine yakın sınıflandırma başarımı sağladıkları gözlenmiştir. Bunun nedeni, bu 3 ÖKF'nin MS hastalığından en çok etkilenen alfa, beta ve delta EEG bantlarına denk gelmesi olasıdır. Kullanılan sınıflandırıcı türünün de sınıflandırma başarımı üzerinde büyük değişimler meydana getirdiği görülmekle birlikte; ÖKF 3'ün ortalama başarım açısından diğer ÖKF'ler ve bunların kombinasyonlarına göre daha yüksek sonuçlar elde ettiği söylenebilir. Bunun da alfa bandının, bilişsel engellilik durumundan en çok etkilenen frekans bandı olduğunu gösterdiği söylenebilir.

Kullanılacak ÖKF'lerin seçimi için 3 farklı ÖKF seçim yöntemi, sınıflandırma başarımlarına olan etkileri bakımından karşılaştırılmıştır. Karşılaştırma sonucunda, enerji tabanlı, korelasyon tabanlı ve GYS tabanlı seçim yöntemlerinin birbirlerine üstünlük sağlayamadıkları, kullanılan sınıflandırıcı türüne göre başarım sıralarının değiştiği gözlemlenmiştir. Bunun yanında, ortalama başarım değerleri ele alındığında her üç seçim yönteminin de benzer başarımlara sahip oldukları sonucuna varılmıştır.

Sınıflandırma başarımında kullanılan özniteliklerin önemli bir etkisi olduğu bilinmektedir. Aşırı öğrenmenin engellenmesi açısından bu çalışma içerisinde sonuçlarından yararlanılmamakla birlikte, 10 farklı öznitelik sınıflandırma başarımları açısından karşılaştırılmıştır. Dört farklı sınıflandırıcı ile elde edilen ortalama başarımlar ele alındığında, standart sapma, sinyal gücü, aktivite, mobilite ve Hurst üssünün, kullanılan diğer özniteliklere göre daha yüksek sınıflandırma başarımları elde ettiği görülmüştür.

Çalışmada ayrıca, görgül kip ayrıştırma işleminin MS/sağlıklı sınıflandırması ve bilişsel engellilik durumu sınıflandırmasında, orijinal EEG sinyallerinin kullanıldığı durumla sınıflandırma başarımı açısından karşılaştırması yapılmıştır. Buna göre; Orijinal EEG/ÖKF kullanımının, kullanılan sınıflandırıcının türüne göre birbirlerine karşı avantaj ve

dezavantajlarının bulunduğu görülmüştür. Sınıflandırıcı etkisinden arındırılmış durum için bakıldığında ise; orijinal EEG sinyali kullanımının bilişsel engellilik tespiti açısından, GKA kullanımının ise MS tespiti açısından daha yüksek başarımlı sonuçlar verdiği görülmüştür.

Sonuç olarak; Çalışmada MS tespiti ve bilişsel engellilik durumu sınıflandırması açılarından iyi sonuçlar elde edilmiş olmakla birlikte, bu sonuçların genelleştirilemeyeceği, bu çalışmanın gelecekte yapılacak benzer çalışmalarla desteklenmesi gerektiği düşünülmektedir. Farklı veri kümeleriyle yapılacak olan benzer çalışmalarda benzer sonuçların elde edilmesi, elde edilen sonuçların genelleştirilmesi açısından gerekliliktir. Bu çalışmanın, benzer konularda gelecekte yapılacak çalışmalar için yol gösterici olacağı düşünülmektedir.

Gelecek çalışmalarda, bu çalışmadakine benzer yöntemler kullanılarak elde edilen sonuçların genelleştirilmeye yatkınlığı ölçülebilir. Bununla birlikte, benzer işlemler orijinal veya farklı yöntemlerle ayrıştırılmış EEG sinyalleri kullanılarak tekrarlanabilir. Ayrıca, bu çalışmadan farklı olarak, çeşitli derin öğrenme algoritmaları kullanılarak sınıflandırma işlemi tekrarlanabilir. Gerek iki boyutlu EEG sinyalleri gerekse bu sinyaller kullanılarak elde edilecek imgeler kullanılarak sınıflandırma işlemler yapılabilir.

KAYNAKLAR

[1]. Weinshenker, B.G., 1996. Epidemiology of multiple sclerosis. *Neurologic clinics*, *14*(2), 291-308.

[2]. Sawcer, S., Jones, H.B., Feakes, R., Gray, J., Smaldon, N., Chataway, J., Robertson, N., Clayton, D., Goodfellow, P.N. and Compston, A., 1996, A genome screen in multiple sclerosis reveals susceptibility loci on chromosome 6p21 and 17q22, *Nature genetics*, *13*(4), 464.

[3]. Haines, J.L., Ter-Minassian, M., Bazyk, A., Gusella, J.F., Kim, D.J., Terwedow, H., PericakVance, M.A., Rimmler, J.B., Haynes, C.S., Roses, A.D. and Lee, A., 1996. A complete genomic screen for multiple sclerosis underscores a role for the major histocompatability complex. *Nature genetics*, *13*(4), 469–471.

[4]. Bornstein, M.B. and Crain, S.M., 1965. Functional Studies of Cultured Brain Tissues as Related to" Demyelinative Disorders". *Science*, *148*(3674), 1242-1244.

[5]. Trapp, B.D., Peterson, J., Ransohoff, R.M., Rudick, R., Mörk, S. and Bö, L., 1998, Axonal transection in the lesions of multiple sclerosis. *New England Journal of Medicine*, *338*(5), 278-285.

[6]. Efendi, H., Kuşçu, D. Y., 2018, *Multipl skleroz tanı ve tedavi kılavuzu 2018*, Galenos, İstanbul, ISBN: 978-605-89294-9-4

[7]. Barkhof, F., Filippi, M., Miller, D.H., Scheltens, P., Campi, A., Polman, C.H., Comi, G., Ader, H.J., Losseff, N. and Valk, J., 1997. Comparison of MRI criteria at first presentation to predict conversion to clinically definite multiple sclerosis. *Brain: a journal of neurology*, *120*(11), 2059-2069.

[8]. Goldenberg, M.M., 2012, Multiple sclerosis review. *Pharmacy and Therapeutics*, *37*(3), 175–184.

[9]. Hauser, S.L. and Goodin, D.S., 2005. Multiple sclerosis and other demyelinating diseases. *Harrisons Principles of Internal Medicine*, 16(2), 1356-1358

[10]. McDonald, W.I., Compston, A., Edan, G., Goodkin, D., Hartung, H.P., Lublin, F.D., McFarland, H.F., Paty, D.W., Polman, C.H., Reingold, S.C. and Sandberg-Wollheim, M., 2001, Recommended diagnostic criteria for multiple sclerosis: guidelines from the International Panel on the diagnosis of multiple sclerosis, *Annals of Neurology: Official Journal of the American Neurological Association and the Child Neurology Society*, *50*(1), 121-127.

[11]. Polman, C.H., Reingold, S.C., Edan, G., Filippi, M., Hartung, H.P., Kappos, L., Lublin, F.D., Metz, L.M., McFarland, H.F., O'Connor, P.W. and Sandberg-Wollheim, M., 2005, Diagnostic criteria for multiple sclerosis: 2005 revisions to the "McDonald Criteria". *Annals of Neurology: Official Journal of the American Neurological Association and the Child Neurology Society*, *58*(6), 840-846.

[12]. Polman, C.H., Reingold, S.C., Banwell, B., Clanet, M., Cohen, J.A., Filippi, M., Fujihara, K., Havrdova, E., Hutchinson, M., Kappos, L. and Lublin, F.D., 2011. Diagnostic criteria for multiple sclerosis: 2010 revisions to the McDonald criteria, *Annals of neurology*, *69*(2), 292-302.

[13]. Thompson, A.J., Banwell, B.L., Barkhof, F., Carroll, W.M., Coetzee, T., Comi, G., Correale, J., Fazekas, F., Filippi, M., Freedman, M.S. and Fujihara, K., 2018, Diagnosis of multiple sclerosis: 2017 revisions of the McDonald criteria. *The Lancet Neurology*, *17*(2), 162-173.

[14]. Frohman, E.M., Havrdova, E., Lublin, F., Barkhof, F., Achiron, A., Sharief, M.K., Stuve, O., Racke, M.K., Steinman, L., Weiner, H. and Olek, M., 2006, Most patients with multiple sclerosis or a clinically isolated demyelinating syndrome should be treated at the time of diagnosis, *Archives of neurology*, *63*(4), 614-619.

[15]. Leocani, L., Locatelli, T., Martinelli, V., Rovaris, M., Falautano, M., Filippi, M., Magnani, G. and Comi, G., 2000, Electroencephalographic coherence analysis in multiple sclerosis: correlation with clinical, neuropsychological, and MRI findings, *Journal of Neurology, Neurosurgery & Psychiatry*, *69*(2), 192-198.

[16]. Fuhr, P., Borggrefe-Chappuis, A., Schindler, C. and Kappos, L., 2001, Visual and motor evoked potentials in the course of multiple sclerosis, *Brain*, *124*(11), 2162-2168.

[17]. Lenne, B., Blanc, J.L., Nandrino, J.L., Gallois, P., Hautecæur, P. and Pezard, L., 2013, Decrease of mutual information in brain electrical activity of patients with relapsing-remitting multiple sclerosis, *Behavioural neurology*, *27*(2), 201-212.

[18]. Gschwind, M., Hardmeier, M., Van De Ville, D., Tomescu, M.I., Penner, I.K., Naegelin, Y., Fuhr, P., Michel, C.M. and Seeck, M., 2016, Fluctuations of spontaneous EEG topographies predict disease state in relapsing-remitting multiple sclerosis. *NeuroImage: Clinical*, *12*, 466-477.

[19]. Van Schependom, J., Gielen, J., Laton, J., D'hooghe, M.B., De Keyser, J. and Nagels, G., 2014, Graph theoretical analysis indicates cognitive impairment in MS stems from neural disconnection. *NeuroImage: Clinical*, *4*, 403-410.

[20]. Torabi, A., Daliri, M.R. and Sabzposhan, S.H., 2017, Diagnosis of multiple sclerosis from EEG signals using nonlinear methods. *Australasian physical & engineering sciences in medicine*, *40*(4), 785-797.

[21]. Karabudak, R., Işık, N. and Siva, A., 2009, *Multiple Sklerozda Tanı ve Tedavi Kılavuzu*, Bilimsel Tıp yayınevi, Ankara, ISBN: 978-605-89294-4-9

[22]. Van Schependom, J., Gielen, J., Laton, J., D'hooghe, M.B., De Keyser, J. and Nagels, G., 2014, SVM aided detection of cognitive impairment in MS, *International Workshop on Pattern Recognition in Neuroimaging*, 4-6 June, 2014, Tübingen, 1-4

[23]. Kurtzke, J.F., 1955, A new scale for evaluating disability in multiple sclerosis. *Neurology*, *5*(8), 580-580.

[24]. Kurtzke, J.F., 1983, Rating neurologic impairment in multiple sclerosis: an expanded disability status scale (EDSS). *Neurology*, *33*(11), 1444-1444.

[25]. Miller, J.R., 2004, The importance of early diagnosis of multiple sclerosis, *Journal of managed care pharmacy*, *10*(3), S4-S11.

[26]. Kobelt, G., Thompson, A., Berg, J., Gannedahl, M., Eriksson, J., MSCOI Study Group and European Multiple Sclerosis Platform, 2017, New insights into the burden and costs of multiple sclerosis in Europe, *Multiple Sclerosis Journal*, *23*(8), 1123-1136.

[27]. Giovannoni, G., Butzkueven, H., Dhib-Jalbut, S., Hobart, J., Kobelt, G., Pepper, G., Sormani, M.P., Thalheim, C., Traboulsee, A. and Vollmer, T., 2016, Brain health: time matters in multiple sclerosis, *Multiple sclerosis and related disorders*, 9, S5-S48.

[28]. Mayo Clinic, 2019, *Multiple Sclerosis/Diagnosis*, https://www.mayoclinic.org/diseases-conditions/multiple-sclerosis/diagnosis-treatment/drc-20350274, [Ziyaret tarihi: 31 Ağustos 2019]

[29]. Shelat, A. M., 2017, *CSF cell count*, https://www.mountsinai.org/health-library/tests/csf-cell-count, [Ziyaret tarihi: 31 Ağustos 2019]

[30]. Kapran, Z., 2016, *Optik Koherens Tomografi*, https://ziyakapran.com/optik-koherens-tomografi, [Ziyaret tarihi: 31 Ağustos 2019]

[31]. Henry, J.C., 2006, Electroencephalography: basic principles, clinical applications, and related fields, *Neurology*, *67*(11), 2092-2092.

[32]. Misulis, K.E., 2013, *Atlas of EEG, seizure semiology, and management*, Oxford University Press, ISBN: 978-0199-985-906

[33]. Towle, V.L., Bolaños, J., Suarez, D., Tan, K., Grzeszczuk, R., Levin, D.N., Cakmur, R., Frank, S.A. and Spire, J.P., 1993, The spatial location of EEG electrodes: locating the best-fitting sphere relative to cortical anatomy. *Electroencephalography and clinical neurophysiology*, *86*(1), 1-6.

[34]. Kose, U., 2018, An ant-lion optimizer-trained artificial neural network system for chaotic electroencephalogram (EEG) prediction. *Applied Sciences*, *8*(9), 1613.

[35]. Sanei, S. and Chambers, J.A., 2007, *EEG signal processing*, John Wiley & Sons, London, ISBN: 978-0470025819

[36]. Goldberger, A.L., Amaral, L.A., Glass, L., Hausdorff, J.M., Ivanov, P.C., Mark, R.G., Mietus, J.E., Moody, G.B., Peng, C.K. and Stanley, H.E., 2000, PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation*, *101*(23), e215-e220.

[37]. Huang, N.E., Shen, Z., Long, S.R., Wu, M.C., Shih, H.H., Zheng, Q., Yen, N.C., Tung, C.C. and Liu, H.H., 1998, The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis, *Proceedings of the Royal Society of*

London. Series A: Mathematical, Physical and Engineering Sciences, *454*(1971), 903-995.

[38]. Tanaka, T. and Mandic, D.P., 2007, Complex empirical mode decomposition, *IEEE Signal Processing Letters*, *14*(2), 101-104.

[39]. Altaf, M.U.B., Gautama, T., Tanaka, T. and Mandic, D.P., 2007, Rotation invariant complex empirical mode decomposition. *IEEE International Conference on Acoustics, Speech and Signal Processing-ICASSP'07*, 15-20 Nisan 2014, Honolulu, Hawaii, 1-4

[40]. Rilling, G., Flandrin, P., Gonçalves, P. and Lilly, J.M., 2007, Bivariate empirical mode decomposition, *IEEE signal processing letters*, *14*(12), 936-939.

[41]. Rehman, N. and Mandic, D.P., 2009, Empirical mode decomposition for trivariate signals. *IEEE Transactions on signal processing*, *58*(3), 1059-1068.

[42]. Rehman, N. and Mandic, D.P., 2009, Multivariate empirical mode decomposition. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 466(2117), 1291-1302.

[43]. Zahra, A., Kanwal, N., ur Rehman, N., Ehsan, S. and McDonald-Maier, K.D., 2017, Seizure detection from EEG signals using multivariate empirical mode decomposition, *Computers in biology and medicine*, *88*, 132-141.

[44]. Hassan, A.R. and Bhuiyan, M.I.H., 2017, Automated identification of sleep states from EEG signals by means of ensemble empirical mode decomposition and random under sampling boosting, *Computer methods and programs in biomedicine*, *140*, 201-210.

[45] . Mert, A. and Akan, A., 2018, Emotion recognition from EEG signals by using multivariate empirical mode decomposition, *Pattern Analysis and Applications*, *21*(1), 81-89.

[46]. Singh, G., Kaur, G. and Kumar, V., 2014, ECG denoising using adaptive selection of IMFs through EMD and EEMD, *International Conference on Data Science & Engineering*, 26-28 Ağustos 2014 Kochi, IEEE, 228-231.

[47]. Junsheng, C., Dejie, Y. and Yu, Y., 2006, Research on the intrinsic mode function (IMF) criterion in EMD method, *Mechanical systems and signal processing*, *20*(4), 817-824.

[48]. Ricci, R. and Pennacchi, P., 2011, Diagnostics of gear faults based on EMD and automatic selection of intrinsic mode functions, *Mechanical Systems and Signal Processing*, *25*(3), 821-838.

[49]. Peng, Z.K., Peter, W.T. and Chu, F.L., 2005, A comparison study of improved Hilbert–Huang transform and wavelet transform: application to fault diagnosis for rolling bearing, *Mechanical systems and signal processing*, *19*(5), 974-988.

[50]. Kotan, S. and Akan, A., 2018, November. A New Intrinsic Mode Function Selection Method Based on Power Spectral Density. *2018 Medical Technologies National Congress (TIPTEKNO)*, 8-10 Kasım 2018 Magusa, IEEE, 1-4.

[51]. Oh, S.H., Lee, Y.R. and Kim, H.N., 2014, A novel EEG feature extraction method using Hjorth parameter, *International Journal of Electronics and Electrical Engineering*, *2*(2), 106-110.

[52]. Joanes, D.N. and Gill, C.A., 1998, Comparing measures of sample skewness and kurtosis. *Journal of the Royal Statistical Society: Series D (The Statistician)*, 47(1), 183-189.

[53]. Balli, T. and Palaniappan, R., 2010, Classification of biological signals using linear and nonlinear features. *Physiological measurement*, 31(7), 903-920.

[55]. Qian, B. and Rasheed, K., 2004, Hurst exponent and financial market predictability, *IASTED Conference on Financial Engineering and Applications*, 8-10 Kasım 2004 Cambridge, 203-209.

[56]. Higuchi, T., 1988, Approach to an irregular time series on the basis of the fractal theory. *Physica D: Nonlinear Phenomena*, *31*(2), 277-283.

[57]. Mohammed, M., Khan, M.B. and Bashier, E.B.M., 2016, *Machine learning: algorithms and applications*, Crc Press, Boca Raton, ISBN: 9781498705387

[58]. Cunningham, P. and Delany, S.J., 2007, k-Nearest neighbour classifiers, *Multiple Classifier Systems*, *34*(8), 1-17.

[59]. Shepard, R.N., 1987, Toward a universal law of generalization for psychological science. *Science*, *237*(4820), 1317-1323.

[60]. Kullback, S. and Leibler, R.A., 1951, On information and sufficiency. *The annals of mathematical statistics*, *22*(1), 79-86.

[61]. Fisher, R.A., 1936, The use of multiple measurements in taxonomic problems. *Annals of eugenics*, *7*(2), 179-188.

[62]. Fukuaga, K., 1990, Introduction to statistical pattern classification. *Patt. Recognit*, *30*(7), 1145-1149.

[63]. Breiman, L., 2001, Random forests, *Machine learning*, *45*(1), 5-32.

[64]. Quinlan, J.R., 1986, Induction of decision trees, *Machine learning*, 1(1), 81-106.

[65]. Song, Y.Y. and Ying, L.U., 2015, Decision tree methods: applications for classification and prediction, *Shanghai archives of psychiatry*, *27*(2), 130-135.

[66]. Cutler, D.R., Edwards Jr, T.C., Beard, K.H., Cutler, A., Hess, K.T., Gibson, J. and Lawler, J.J., 2007, Random forests for classification in ecology, *Ecology*, *88*(11), 2783-2792.

[67]. Liaw, A. and Wiener, M., 2002, Classification and regression by randomForest, *R news*, *2*(3), 18-22.

[68]. Ettaouil, M. and Ghanou, Y., 2009, Neural architectures optimization and Genetic algorithms, *Wseas Transactions On Computer*, *8*(3), 526-537.

[69]. Ramchoun, H., Idrissi, M.A.J., Ghanou, Y. and Ettaouil, M., 2016, Multilayer Perceptron: Architecture Optimization and Training, *IJIMAI*, *4*(1), 26-30.

[70]. Karpathy, A., 2018, *Convolutional Neural Networks for Visual Recognition*, http://cs231n.github.io/, [Ziyaret tarihi : 31 Ağustos 2019].

[71]. Hinton, G.E., Osindero, S. and Teh, Y.W., 2006, A fast learning algorithm for deep belief nets, *Neural computation*, *18*(7), 1527-1554.

[72]. Hornik, K., Stinchcombe, M. and White, H., 1989, Multilayer feedforward networks are universal approximators, *Neural networks*, *2*(5), 359-366.

[73]. Rumelhart, D.E., Hinton, G.E. and Williams, R.J., 1985, Learning internal representations by error propagation, *Cognitive Science*., 1-32

[74]. Bishop, C.M., 1995, *Neural networks for pattern recognition*, Oxford university press, Cambridge, ISBN: 978-0198538646

[75]. Rojas, R., 2013, *Neural networks: a systematic introduction*, Springer, Berlin, ISBN: 9783642610684

[76]. Kim, J.H., 2009. Estimating classification error rate: Repeated cross-validation, repeated hold-out and bootstrap, *Computational statistics & data analysis*, 53(11), 3735-3745.

[77]. Kohavi, R., 1995, August. A study of cross-validation and bootstrap for accuracy estimation and model selection, *Ijcai*, 14 (2), 1137-1145.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Soner Kotan
Doğum Yeri	Sarıyer
Doğum Tarihi	07.03.1986
Uyruğu	☑ T.C. ❒ Diğer:
Telefon	(216) 345 90 90 - 1331
E-Posta Adresi	sonerkotan@gmail.com
Web Adresi	https://avesis.marmara.edu.tr/soner.kotan

Eğitim Bilgileri	
Lisans	
Üniversite	İstanbul Üniversitesi
Fakülte	Mühendislik Fakültesi
Bölümü	Elektrik-Elektronik Mühendisliği
Mezuniyet Yılı	2011

Yüksek Lisans	
Üniversite	İstanbul Teknik Üniversitesi
Enstitü Adı	Fen Bilimleri Enstitüsü
Anabilim Dalı	Elektronik - Haberleşme Anabilim Dalı
Programı	Biyomedikal Mühendisliği Programı

Makale ve Bildiriler