t

T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ

BİR ve İKİ BOYUTLU BİYOMEDİKAL İŞARETLERİN DCT TABANLI ANALİZİ

Fatma DEMİREZEN YAĞMUR

DANIŞMAN
Prof. Dr. Ahmet SERTBAŞ

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

İSTANBUL-2020

Bu çalışma, [29.06.2020] tarihinde aşağıdaki jüri tarafından [Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programında [Doktora tezi] olarak kabul edilmiştir.

Tez Jürisi

[Prof. Dr.] [Ahmet SERTBAŞ](Danışman)
[İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi]

[Prof. Dr.] [Mustafa KAMAŞAK]
[İTÜ]
[Bilgisayar ve Bilişim Fakültesi]

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

[Doç. Dr.] [Gökhan BİLGİN]
[Yıldız Teknik Üniversitesi]
[Elektrik-Elektronik Fakültesi]

[Dr. Öğr. Üyesi] [Oğuzhan ÖZTAŞ]
[İstanbul Üniversitesi-Cerrahpaşa]
[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

Bilgisayar teknolojilerinin hemen hemen her alanda kullanıldığı günümüzde, tıbbi verilerin bilgisayar teknolojileriyle yorumlanması neticesinde ortaya çıkan ve hastalık teşhisine katkı sağlamasını umduğumuz bu çalışma uzun ve yorucu bir mesainin ürünüdür.

Çalışmam sırasında bilgi ve tecrübelerinden istifade ettiğim değerli tez danışmanım Prof. Dr. Ahmet SERTBAŞ'a teşekkürü bir borç bilirim. Tez yazımı sırasında karşılaştığım sorunlara çözüm üretmede bana yardımcı olan değerli Prof. Dr. Mustafa KAMAŞAK'a şükranlarımı sunarım.

Çalışmamızda kullandığımız hasta verileri Bolu Abant-İzzet Baysal Üniversitesi İzzet Baysal Eğitim ve Araştırma Hastanesi, Radyoloji ve Nöroloji Anabilim Dallarından alınmıştır. Bu bölümlerden verileri elde etme sürecinde yardımlarını gördüğüm Radyoloji Anabilim Dalı öğretim üyesi sayın Prof. Dr. Safiye GÜREL ve Nöroloji Anabilim Dalı öğretim üyesi sayın Prof. Dr. Serpil YILDIZ'ın yanı sıra adını burada anmadan geçemeyeceğim meslektaşlarım, Dr. Abdullah Talha KABAKUŞ ve doktorant Şengül BAYRAK'a müteşekkirim.

Elbette bu yorucu çalışmanın isimleri bu satırlara sığmayacak kadar çok gizli kahramanları da vardır. Her zaman yanımda manevi desteğini hissettiğim değerli eşim Dr. Ömer YAĞMUR'a, hayat serüvenimin başlangıcından beri her anımda yanımda gördüğüm annem Sırma DEMİREZEN, babam H. İsmail DEMİREZEN ve kardeşlerime ne kadar teşekkür etsem azdır.

Hayatlarının en güzel saniyelerinden alarak vücuda getirdiğim bu çalışmayı iki minik kahramanıma armağan ediyorum.

Haziran 2020 Fatma DEMİREZEN YAĞMUR

İÇİNDEKİLER

Sayfa No

ÖNSÖZ ..... **iv**
İÇİNDEKİLER ..... **v**
ŞEKİL LİSTESİ ..... **x**
TABLO LİSTESİ ..... **xiv**
SİMGE VE KISALTMA LİSTESİ ..... **xxiii**
ÖZET ..... **xxvi**
SUMMARY ..... **xxvii**
1. GİRİŞ **1**
2. GENEL KISIMLAR **4**
2.1. BEYİN YAPISI 4
2.1.1. Beyin Anatomisi 4
2.1.2. Beyin Fizyolojisi 5
2.2. BEYİN GÖRÜNTÜLEME VE İZLEME TEKNİKLERİ 5
2.2.1. EEG 5
2.2.2. MRG 8
2.2.2.1. T1 ağırlıklı 8
2.2.2.2. T2 ağırlıklı 9
2.2.2.3. Proton yoğunluğu ağırlıklı 10
2.3. EPİLEPSİ 10
2.4. LİTERATÜR ÖZETİ 11
3. MALZEME VE YÖNTEM **21**
3.1. ÖZELLİK ÇIKARIMI 21
3.2. ÖZELLİK SEÇİMİ 23
3.2.1. Temel Bileşen Analizi 23
3.2.2. Doğrusal Ayrım Analizi (DAA) 24
3.2.3. İleriye Doğru Seçim (Forward Selection) 25
3.2.4. Geriye Doğru Seçim (Backward Selection) 25
3.3. SINIFLANDIRMA 26
3.3.1. Öğreticili Öğrenme 26
3.3.1.1. Öğreticili Öğrenme Yaklaşımları 27

3.3.1.2. Doğrulama Tahmini *27*
3.3.1.3. Yapay Sinir Ağları (YSA) *28*
3.3.1.4. Destek Vektör Makineleri (DVM) *39*
3.3.1.5. K En Yakın Komşuluk Sınıflandırıcısı (KNN) *40*
3.3.1.6. Rastgele Orman Algoritması (RF) *40*
3.3.1.7. Derin Öğrenme *41*
3.4. EEG ANALİZİ YÖNTEMİ 46
3.4.1. Malzeme 46
3.4.2. Yöntem 46
3.4.3. Ham Verinin (Raw Data) Giriş ve Çıkışı 48
3.4.4. EegLab'da Ön İşlemler 48
3.4.4.1. Veri Okuma *49*
3.4.4.2. Filtreleme *49*
3.4.4.3. Kanal Temizleme *50*
3.4.4.4. Veri Temizleme *50*
3.4.4.5. Kanal Yerlerinin Belirlenmesi *54*
3.4.5. Bağımsız Bileşenler Analizi (BBA) 54
3.4.6. Özellik Çıkarımı 60
3.4.6.1. 1B Ayrık Kosinüs Dönüşümü *60*
3.4.6.2. İstatistiksel Özellik Çıkarımı *65*
3.4.7. EEG'de Karşılaşılan Sorunlar 71
3.4.7.1. Bağımsız Bileşenler Analizi Yapay Sinir Ağ Sonuçları *72*
3.4.7.2. Ayrık Kosinüs Dönüşümü Yapay Sinir Ağ Sonuçları *74*
3.5. MRG ANALİZİ YÖNTEMİ 77
3.5.1. Malzeme 77
3.5.2. Yöntem 78
3.5.3. Veri Okuma 79
3.5.4. Segmentasyon 79
3.5.5. Veri Ön İşlemleri 80
3.5.6. Özellik Çıkarımı 80
3.5.6.1. 2B Ayrık Kosinüs Dönüşümü *81*
3.5.6.2. Ortalama *82*
3.5.6.3. Ayrık Kosinüs Dönüşümü_Ortalama *82*
3.5.7. MRG'de Karşılaşılan Sorunlar 82

3.5.7.1. FS (FreeSurfer) Aracı 83
3.5.7.2. SPM12 (Statistical Parametric Mapping) Aracı....86
3.5.7.3. Dcm2nii 89
3.6. EEG VE MRG ÖZELLİK BİRLEŞİMİ YÖNTEMİ....91
3.6.1. Malzeme 91
3.6.2. Yöntem 91
4. BULGULAR....92
4.1. EEG'NİN DCT (AKD) İLE SINIFLANDIRMA SONUÇLARI....92
4.1.1. AKD'nin Temel Bileşenler Analizi (TBA) İle Sınıflandırma Sonuçları....92
4.1.1.1. YSA Sonucu....93
4.1.1.2. SVM....94
4.1.1.3. KNN....94
4.1.1.4. RF....95
4.1.2. AKD'nin Doğrusal Ayrım Analizi (DAA)....96
4.1.2.1. YSA Sonucu....96
4.1.2.2. SVM....97
4.1.2.3. KNN....98
4.1.2.4. RF....98
4.1.3. AKD Çıkarımında İleriye Doğru Seçim....99
4.1.3.1. YSA Sonucu....99
4.1.3.2. SVM....100
4.1.3.3. KNN....101
4.1.3.4. RF....101
4.1.4. AKD Çıkarımında Geriye Doğru Seçim 102
4.1.4.1. YSA Sonucu....102
4.1.4.2. SVM....103
4.1.4.3. KNN....103
4.1.4.4. RF....104
4.2. MRG'NİN DCT (AKD) İLE SINIFLANDIRMA SONUÇLARI 105
4.2.1. AKD'nin Temel Bileşenler Analizi (TBA) İle Sınıflandırma Sonuçları....105
4.2.1.1. YSA Sonucu....106
4.2.1.2. SVM....107
4.2.1.3. KNN....107
4.2.1.4. RF....108

4.2.2. AKD'nin Doğrusal Ayrım Analizi (DAA) 109
4.2.2.1. YSA Sonucu 109
4.2.2.2. SVM 110
4.2.2.3. KNN 111
4.2.2.4. RF 111
4.2.3. AKD Çıkarımında İleriye Doğru Seçim 112
4.2.3.1. YSA Sonucu 112
4.2.3.2. SVM 113
4.2.3.3. KNN 114
4.2.3.4. RF 114
4.2.4. AKD Çıkarımında Geriye Doğru Seçim 115
4.2.4.1. YSA Sonucu 115
4.2.4.2. SVM 116
4.2.4.3. KNN 117
4.2.4.4. RF 117
4.3. EEG VE MRG BİRLEŞİMİ AKD (DCT) SONUÇLARI 118
4.3.1. Temel Bileşen Analizi (TBA) 118
4.3.1.1. YSA Sonucu 119
4.3.1.2. SVM 120
4.3.1.3. KNN 120
4.3.1.4. RF 121
4.3.2. Doğrusal Ayrım Analizi (DAA) 122
4.3.2.1. YSA Sonucu 122
4.3.2.2. SVM 123
4.3.2.3. KNN 123
4.3.2.4. RF 124
4.3.3. İleriye Doğru Seçim (Forward Selection) 125
4.3.3.1. YSA Sonucu 125
4.3.3.2. SVM 126
4.3.3.3. KNN 126
4.3.3.4. RF 127
4.3.4. Geriye Doğru Seçim (Backward Selection) 128
4.3.4.1. YSA Sonucu 128
4.3.4.2. SVM 129

4.3.4.3. KNN *129*
4.3.4.4. RF *130*
4.4. EEG'NİN AKD (DCT) VE ADD (DWT) SINIFLANDIRMA SONUÇLARI ... 131
4.5. MRG'NİN AKD (DCT) VE ADD (DWT) SINIFLANDIRMA SONUÇLARI 134
4.6. EEG-MRG'NİN AKD (DCT) ÇAPRAZ DOĞRULAMA SONUÇLARI 137
4.7. LSTM SONUÇLARI 138
4.7.1. EEG verisinin LSTM Sonuçları 138
4.7.1.1. Raw EEG Verisi Tek Kanallı *138*
4.7.1.2. Raw EEG Verisi İki Kanallı *141*
4.7.1.3. AKD EEG Verisi *142*
4.7.1.4. ADD EEG Verisi *143*
4.7.2. MRG verisinin LSTM Sonuçları 144
4.7.3. EEG-MRI verisinin LSTM Sonuçları 146
4.8. CNN SONUÇLARI 148
4.8.1. EEG CNN Sonuçları 148
4.8.2. MRG CNN Sonuçları 150
4.8.3. EEG-MRG CNN Sonuçları 152
5. TARTIŞMA VE SONUÇ 155
KAYNAKLAR 160
EKLER 168
EK.1. ETİK KURUL KARARI 168
EK.2. SAĞLIK BAKANLIĞI ONAYI 169
ÖZGEÇMİŞ 170

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: (a,b) Beynin anatomik olarak şeması (Keskin, 2018)..... 4

Şekil 2.2: Sinir hücresinin yapısı. 5

Şekil 2.3: 10-20 sistemine göre elektrot konumu. 6

Şekil 2.4: (a,b,c,d,e) EEG'deki yapay etkenler. 7

Şekil 2.5: MRG-T1 örneği. 9

Şekil 2.6: MRG-T2 örneği. 9

Şekil 2.7: MRG-PD örneği. 10

Şekil 3.1: Sinir sistemi blok diyagramı. 24

Şekil 3.2: Sinir hücresi yapısı. 24

Şekil 3.3: Nöron modeli (Haykin,2009). 25

Şekil 3.4: Tek katmanlı ağ yapısı. 28

Şekil 3.5: Çok katmanlı ağ yapısı. 29

Şekil 3.6: Çıkış nöron k'nın gizli nöron j'ye doğru sinyal akış grafiği (Haykin,2009). 32

Şekil 3.7: EEG veri aktarımı. 34

Şekil 3.8: EEG verilerinin akış şeması. 35

Şekil 3.9: Nihon Kohden ortamı. 36

Şekil 3.10: EegLab'a aktarılmış veri seti. 37

Şekil 3.11: Filtrelenmiş veri. 38

Şekil 3.12: Kanal temizleme ayarları. 38

Şekil 3.13: Kanal temizleme sonuçları. 38

Şekil 3.14 (a,b,c,d,e): Veri üzerindeki yapay etkenler. 39

Şekil 3.15: Kanal mesafe ayarları. 39

Şekil 3.16: Kurtosis yönteminin sonucu. 40

Şekil 3.17: Verideki yapay etkenlerin işaretlenip silinmesi. 41

Şekil 3.18: 19 kanal yerleşimi. 42

Şekil 3.19: 16 kanal yerleşimi. 42

Şekil 3.20: EegLab BBA akış şeması. 43

Şekil 3.21: a) Göz hareketi b) göz açıp-kapama c) kas yapay etkeni. 44

Şekil 3.21: d) beyin etkeni. 45

Şekil 3.22: BBA bileşenlerin 2D gösterimi. 45

Şekil 3.23: 14. Bileşenin özellikleri. 46

Şekil 3.24: Genel BBA akışı. 46

Şekil 3.25: a) 1x50000 1. kanal, b) 1x100000 1. kanal. 50

Şekil 3.25: c) 1x200000 1. kanal. 51

Şekil 3.26: a) 1x200000 2. kanal. 51

Şekil 3.26: b) 1x200000 3. kanal, c) 1x200000 4. kanal. 52

Şekil 3.26: d) 1x200000 bütün kanallar. 53

Şekil 3.27: Yapay sinir ağ yapısı. 60

Şekil 3.28: BBA matris doğruluk oranları. 61

Şekil 3.29: Ağın başarımı. 61

Şekil 3.30: ROC (Receiver Operating Characteristic) eğrileri. 62

Şekil 3.31: AKD matris doğruluk oranları. 63

Şekil 3.32: Ağın başarımı. 63

Şekil 3.33: ROC (Receiver Operating Characteristic) eğrileri. 64

Şekil 3.34: 1.5 Tesla Siemens Magnetom Senfoni Tarayıcı (Siemens,2009). 65

Şekil 3.35: MRG akış şeması. 66

Şekil 3.36: Orijinal MRG. 68

Şekil 3.37: Segmentasyon. 68

Şekil 3.38: Boyutlandırma. 68

Şekil 3.39: Normalizasyon. 68

Şekil 3.40: AKD Katsayıları. 70

Şekil 3.41: FS-1. 72

Şekil 3.42: FS-2. 73

Şekil 3.43: FS-3. 74

Şekil 3.44: SPM-1. 75

Şekil 3.45: SPM-2. 76

Şekil 3.46: SPM-3. 77

Şekil 3.47: Dcm2nii-1. 78

Şekil 3.48: Dcm2nii-2. 78

Şekil 3.49: EEG-MRG birleşim akışı. 79

Şekil 4.1: EEG'nin TBA ile seçilen özellikleri. 92

Şekil 4.2: EEG'nin DAA ile seçilen özellikleri. 96

Şekil 4.3: MRG'nin TBA ile seçilen özellikleri. 105

Şekil 4.4: MRG'nin DAA ile seçilen özellikleri. 86

Şekil 4.5: EEG-MRG'nin TBA ile seçilen özellikleri. 89

Şekil 4.6: EEG verisinde 4. Kanal (T5-O-1) ve 10. Kanal (F4-C4) gösterimi. 135

Şekil 4.7: LSTM Akışı. 135

Şekil 4.8: LSTM_RawEGG'nin Tek Kanallı Başarı ve Kayıp Grafiği. 137

Şekil 4.9: LSTM_RawEGG'nin 2 Kanallı Başarı ve Kayıp Grafiği. 138

Şekil 4.10: LSTM_AKD_EGG'nin Başarı ve Kayıp Grafiği. 139

Şekil 4.11: LSTM_ADD_EGG'nin Başarı ve Kayıp Grafiği. 135

Şekil 4.12: LSTM-MRG Akışı. 141

Şekil 4.13: LSTM_MRG'nin Başarı ve Kayıp Grafiği. 142

Şekil 4.14: LSTM EEG-MRI Akışı. 143

Şekil 4.15: LSTM EEG-MRI'nın Başarı ve Kayıp Grafiği. 144

Şekil 4.16: CNN-EEG Akışı. 145

Şekil 4.17: CNN_EEG'nin Başarı ve Kayıp Grafiği. 146

Şekil 4.18: CNN-MRG Akışı. 147

Şekil 4.19: CNN_MRG'nin Başarı ve Kayıp Grafiği. 148

Şekil 4.20: CNN EEG-MRG Akışı. 149

TABLO LİSTESİ

Sayfa No

Tablo 3.1: Ham verinin filtrelenmiş ve temizlenmiş sonuçları. 41

Tablo 3.2: BBA uygulandıktan sonra kanal değerleri. 47

Tablo 3.3: AKD sonucu kanal değerleri. 48

Tablo 3.4: Her bir kanalın ortalama özellik değerleri. 53

Tablo 3.5: Her bir kanalın varyans özellik değerleri. 55

Tablo 3.6: Her bir kanalın standart sapma özellik değerleri. 56

Tablo 3.7: Her bir kanalın çarpıklık özellik değerleri. 57

Tablo 3.8: Her bir kanalın basıklık özellik değerleri. 58

Tablo 3.9: YSA sınıflandırma performansları. 64

Tablo 4.1: AKD'nin TBA ile özellik seçim yöntemine göre sınıflandırma doğruluk ve hata oranı. 93

Tablo 4.2: a) EEG'nin TBA -YSA ile elde edilen hata matrisi. 93

Tablo 4.2: b) EEG'nin TBA -YSA ile sınıflandırma sonuçları. 93

Tablo 4.3: a) EEG'nin TBA-SVM ile elde edilen hata matris. 94

Tablo 4.3: b) EEG'nin TBA-SVM ile sınıflandırma sonucu. 94

Tablo 4.4: a) EEG'nin TBA-KNN ile elde edilen hata matrisi. 94

Tablo 4.4: b) EEG'nin TBA-KNN ile sınıflandırma sonucu. 95

Tablo 4.5: a) EEG'nin TBA-RF ile elde edilen hata matrisi. 95

Tablo 4.5: b) EEG'nin TBA-RF ile sınıflandırma sonucu. 95

Tablo 4.6: AKD'nin DAA ile özellik seçim yöntemine göre sınıflandırma doğruluk ve hata oranı. 96

Tablo 4.7: a) EEG'nin DAA-MLP ile elde edilen hata matrisi. 96

Tablo 4.7: b) EEG'nin DAA -MLP ile sınıflandırma sonucu. 97

Tablo 4.8: a) EEG'nin DAA -SVM ile elde edilen hata matrisi. 97

Tablo 4.8: b) EEG'nin DAA-SVM ile sınıflandırma sonuçları. 97

Tablo 4.9: a) EEG'nin DAA -KNN ile elde edilen hata matrisi. 98

Tablo 4.9: b) EEG'nin DAA -KNN ile sınıflandırma sonucu. 98

Tablo 4.10: a) EEG'nin DAA -RF ile elde edilen hata matrisi. 98

Tablo 4.10: b) EEG'nin DAA -RF ile sınıflandırma sonucu. 99

Tablo 4.11: AKD'nin İleriye Doğru Seçim yöntemine göre sınıflandırma doğruluk ve hata oranı. 99

Tablo 4.12: a) EEG'nin İleriye Doğru Seçim -MLP ile elde edilen hata matrisi. 99

Tablo 4.12: b) EEG'nin İleriye Doğru Seçim -MLP ile sınıflandırma sonucu. 100

Tablo 4.13: a) EEG'nin İleriye Doğru Seçim -SVM ile elde edilen hata matrisi. 100

Tablo 4.13: b) EEG'nin İleriye Doğru Seçim -SVM ile sınıflandırma sonucu. 100

Tablo 4.14: a) EEG'nin İleriye Doğru Seçim -KNN ile elde edilen hata matrisi. 101

Tablo 4.14: b) EEG'nin İleriye Doğru Seçim -KNN ile sınıflandırma sonucu. 101

Tablo 4.15: a) EEG'nin İleriye Doğru Seçim -RF ile elde edilen hata matrisi. 101

Tablo 4.15: b) EEG'nin İleriye Doğru Seçim -RF ile sınıflandırma sonucu. 102

Tablo 4.16: AKD'nin Geriye Doğru Seçim yöntemine göre sınıflandırma doğruluk ve hata oranı. 102

Tablo 4.17: a) EEG'nin Geriye Doğru Seçim -MLP ile elde edilen hata matrisi. 102

Tablo 4.17: b) EEG'nin Geriye Doğru Seçim -MLP ile sınıflandırma sonucu. 103

Tablo 4.18: a) EEG'nin Geriye Doğru Seçim -SVM ile elde edilen hata matrisi. 103

Tablo 4.18: b) EEG'nin Geriye Doğru Seçim -SVM ile sınıflandırma sonucu. 103

Tablo 4.19: a) EEG'nin Geriye Doğru Seçim -KNN ile elde edilen hata matrisi. 104

Tablo 4.19: b) EEG'nin Geriye Doğru Seçim -KNN ile sınıflandırma sonucu. 104

Tablo 4.20: a) EEG'nin Geriye Doğru Seçim -RF ile elde edilen hata matrisi. 104

Tablo 4.20: b) EEG'nin Geriye Doğru Seçim -RF ile sınıflandırma sonucu. 105

Tablo 4.21: AKD'nin TBA ile özellik seçim yöntemine göre sınıflandırma doğruluk ve hata oranı. 106

Tablo 4.22: a) MRG'nin TBA -YSA ile elde edilen hata matrisi. 106

Tablo 4.22: b) MRG'nin TBA -YSA ile sınıflandırma sonuçları. 106

Tablo 4.23: a) MRG'nin TBA-SVM ile elde edilen hata matris. 107

Tablo 4.23: b) MRG'nin TBA-SVM ile sınıflandırma sonucu. 107

Tablo 4.24: a) MRG'nin TBA-KNN ile elde edilen hata matrisi. 107

Tablo 4.24: b) MRG'nin TBA-KNN ile sınıflandırma sonucu. 108

Tablo 4.25: a) MRG'nin TBA-RF ile elde edilen hata matrisi. 108

Tablo 4.25: b) MRG'nin TBA-RF ile sınıflandırma sonucu. 108

Tablo 4.26: AKD'nin DAA ile özellik seçim yöntemine göre sınıflandırma doğruluk ve hata oranı. 109

Tablo 4.27: a) MRG'nin DAA-MLP ile elde edilen hata matrisi. 109

Tablo 4.27: b) MRG'nin DAA -MLP ile sınıflandırma sonucu. 110

Tablo 4.28: a) MRG'nin DAA -SVM ile elde edilen hata matrisi. 110

Tablo 4.28: b) MRG'nin DAA-SVM ile sınıflandırma sonuçları. 110

Tablo 4.29: a) MRG'nin DAA -KNN ile elde edilen hata matrisi. 111

Tablo 4.29: b) MRG'nin DAA -KNN ile sınıflandırma sonucu. 111

Tablo 4.30: a) MRG'nin DAA -RF ile elde edilen hata matrisi. 111

Tablo 4.30: b) MRG'nin DAA -RF ile sınıflandırma sonucu. 112

Tablo 4.31: AKD'nin İleriye Doğru Seçim yöntemine göre sınıflandırma doğruluk ve hata oranı. 112

Tablo 4.32: a) MRG'nin İleriye Doğru Seçim -MLP ile elde edilen hata matrisi. 112

Tablo 4.32: b) MRG'nin İleriye Doğru Seçim -MLP ile sınıflandırma sonucu. 113

Tablo 4.33: a) MRG'nin İleriye Doğru Seçim -SVM ile elde edilen hata matrisi. 113

Tablo 4.33: b) MRG'nin İleriye Doğru Seçim -SVM ile sınıflandırma sonucu. 113

Tablo 4.34: a) MRG'nin İleriye Doğru Seçim -KNN ile elde edilen hata matrisi. 114

Tablo 4.34: b) MRG'nin İleriye Doğru Seçim -KNN ile sınıflandırma sonucu. 114

Tablo 4.35: a) MRG'nin İleriye Doğru Seçim -RF ile elde edilen hata matrisi. 114

Tablo 4.35: b) MRG'nin İleriye Doğru Seçim -RF ile sınıflandırma sonucu. 115

Tablo 4.36: AKD'nin Geriye Doğru Seçim yöntemine göre sınıflandırma doğruluk ve hata oranı. 115

Tablo 4.37: a) MRG'nin Geriye Doğru Seçim -MLP ile elde edilen hata matrisi. 115

Tablo 4.37: b) MRG'nin Geriye Doğru Seçim -MLP ile sınıflandırma sonucu. 116

Tablo 4.38: a) MRG'nin Geriye Doğru Seçim -SVM ile elde edilen hata matrisi. 116

Tablo 4.38: b) MRG'nin Geriye Doğru Seçim -SVM ile sınıflandırma sonucu. 116

Tablo 4.39: a) MRG'nin Geriye Doğru Seçim -KNN ile elde edilen hata matrisi. 117

Tablo 4.39: b) MRG'nin Geriye Doğru Seçim -KNN ile sınıflandırma sonucu. 117

Tablo 4.40: a) MRG'nin Geriye Doğru Seçim -RF ile elde edilen hata matrisi. 117

Tablo 4.40: b) MRG'nin Geriye Doğru Seçim -RF ile sınıflandırma sonucu. 118

Tablo 4.41: AKD'nin TBA ile özellik seçim yöntemine göre sınıflandırma doğruluk ve hata oranı. 119

Tablo 4.42: a) EEG_MRG'nin TBA -YSA ile elde edilen hata matrisi. 119

Tablo 4.42: b) EEG_MRG'nin TBA -YSA ile sınıflandırma sonuçları. 119

Tablo 4.43: a) EEG_MRG'nin TBA-SVM ile elde edilen hata matris. 120

Tablo 4.43: b) EEG_MRG'nin TBA-SVM ile sınıflandırma sonucu. 120

Tablo 4.44: a) EEG_MRG'nin TBA-KNN ile elde edilen hata matrisi. 120

Tablo 4.44: b) EEG_MRG'nin TBA-KNN ile sınıflandırma sonucu. 121

Tablo 4.45: a) EEG_MRG'nin TBA-RF ile elde edilen hata matrisi. 121

Tablo 4.45: b) EEG_MRG'nin TBA-RF ile sınıflandırma sonucu. 121

Tablo 4.46: AKD'nin DAA ile özellik seçim yöntemine göre sınıflandırma doğruluk ve hata oranı. 122

Tablo 4.47: a) EEG_MRG'nin DAA-MLP ile elde edilen hata matrisi. 122

Tablo 4.47: b) EEG_MRG'nin DAA -MLP ile sınıflandırma sonucu. 122

Tablo 4.48: a) EEG_MRG'nin DAA -SVM ile elde edilen hata matrisi. 123

Tablo 4.48: b) EEG_MRG'nin DAA-SVM ile sınıflandırma sonuçları. 123

Tablo 4.49: a) EEG_MRG'nin DAA -KNN ile elde edilen hata matrisi. 123

Tablo 4.49: b) EEG_MRG'nin DAA -KNN ile sınıflandırma sonucu. 124

Tablo 4.50: a) EEG_MRG'nin DAA -RF ile elde edilen hata matrisi. 124

Tablo 4.50: b) EEG_MRG'nin DAA -RF ile sınıflandırma sonucu. 124

Tablo 4.51: AKD'nin İleriye Doğru Seçim yöntemine göre sınıflandırma doğruluk ve hata oranı. 125

Tablo 4.52: a) EEG_MRG'nin İleriye Doğru Seçim -MLP ile elde edilen hata matrisi. ...125

Tablo 4.52: b) EEG_MRG'nin İleriye Doğru Seçim -MLP ile sınıflandırma sonucu. 125

Tablo 4.53: a) EEG_MRG'nin İleriye Doğru Seçim -SVM ile elde edilen hata matrisi. ...126

Tablo 4.53: b) EEG_MRG'nin İleriye Doğru Seçim -SVM ile sınıflandırma sonucu. 126

Tablo 4.54: a) EEG_MRG'nin İleriye Doğru Seçim -KNN ile elde edilen hata matrisi. ...126

Tablo 4.54: b) EEG_MRG'nin İleriye Doğru Seçim -KNN ile sınıflandırma sonucu. 127

Tablo 4.55: a) EEG_MRG'nin İleriye Doğru Seçim -RF ile elde edilen hata matrisi.....127

Tablo 4.55: b) EEG_MRG'nin İleriye Doğru Seçim -RF ile sınıflandırma sonucu. 127

Tablo 4.56: AKD'nin Geriye Doğru Seçim yöntemine göre sınıflandırma doğruluk ve hata oranı. 128

Tablo 4.57: a) EEG_MRG'nin Geriye Doğru Seçim -MLP ile elde edilen hata matrisi. ...128

Tablo 4.57: b) EEG_MRG'nin Geriye Doğru Seçim -MLP ile sınıflandırma sonucu. 128

Tablo 4.58: a) EEG_MRG'nin Geriye Doğru Seçim -SVM ile elde edilen hata matrisi. ..129

Tablo 4.58: b) EEG_MRG'nin Geriye Doğru Seçim -SVM ile sınıflandırma sonucu. 129

Tablo 4.59: a) EEG_MRG'nin Geriye Doğru Seçim -KNN ile elde edilen hata matrisi ...129

Tablo 4.59: b) EEG_MRG'nin Geriye Doğru Seçim -KNN ile sınıflandırma sonucu. 130

Tablo 4.60: a) EEG_MRG'nin Geriye Doğru Seçim -RF ile elde edilen hata matrisi. 130

Tablo 4.60: b) EEG_MRG'nin Geriye Doğru Seçim -RF ile sınıflandırma sonucu. 130

Tablo 4.61: AKD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (overall acuracy) sonuçları. 131

Tablo 4.62: AKD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma f-skor sonuçları. 131

Tablo 4.63: ADD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (overall acuracy) sonuçları. 131

Tablo 4.64: ADD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma f-skor sonuçları. 132

Tablo 4.65: AKD'nin özellik seçim yöntemlerine göre çapraz doğrulama sınıflandırma sonuçları. 132

Tablo 4.66: AKD'nin özellik seçim yöntemlerine göre çapraz doğrulama f-skor sonuçları. 132

Tablo 4.67: ADD'nin özellik seçim yöntemlerine göre çapraz doğrulama sınıflandırma sonuçları. 133

Tablo 4.68: ADD'nin özellik seçim yöntemlerine göre çapraz doğrulama f-skor sonuçları. 133

Tablo 4.69: AKD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (overall acuracy) sonuçları. 134

Tablo 4.70: AKD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma f-skor sonuçları. 134

Tablo 4.71: ADD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (overall acuracy) sonuçları. 135

Tablo 4.72: ADD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma f-skor sonuçları. 135

Tablo 4.73: AKD'nin özellik seçim yöntemlerine göre çapraz doğrulama sınıflandırma sonuçları. 135

Tablo 4.74: AKD'nin özellik seçim yöntemlerine göre çapraz doğrulama f-skor sonuçları. 136

Tablo 4.75: ADD'nin özellik seçim yöntemlerine göre çapraz doğrulama sınıflandırma sonuçları. 136

Tablo 4.76: ADD'nin özellik seçim yöntemlerine göre çapraz doğrulama f-skor sonuçları. 136

Tablo 4.77: AKD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (overall acuracy) sonuçları. 137

Tablo 4.78: AKD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma f-skor sonuçları. 137

Tablo 4.79: AKD'nin özellik seçim yöntemlerine göre çapraz doğrulama sınıflandırma sonuçları. 137

Tablo 4.80: AKD'nin özellik seçim yöntemlerine göre çapraz doğrulama f-skor sonuçları. 138

Tablo 4.81: LSTM EEG Ağdaki Parametreleri. 139

Tablo 4.82: LSTM_EEG Ağının Herbir İşlemdeki Sonucu. 141

Tablo 4.83: LSTM EEG 2 Kanallı Ağdaki Parametreleri. 142

Tablo 4.84: LSTM_EEG Ağının Herbir İşlemdeki Sonucu. 142

Tablo 4.85: LSTM_AKD_EEG Ağının Herbir İşlemdeki Sonucu. 143

Tablo 4.86: LSTM_ADD_EEG ağının Herbir İşlemdeki Sonucu. 144

Tablo 4.87: LSTM_MRG ağının Herbir İşlemdeki Sonucu. 145

Tablo 4.88: LSTM EEG-MRI Ağdaki Parametreleri. 146

Tablo 4.89: LSTM EEG-MRI Ağının Herbir İşlemdeki Sonucu. 147

Tablo 4.90: CNN EEG Ağdaki Parametreler. 149

Tablo 4.91: CNN_EGG ağının Herbir İşlemdeki Sonucu. 150

Tablo 4.92: CNN MRG Ağdaki Parametreler. 151

Tablo 4.93: CNN_MRG ağının Herbir İşlemdeki Sonucu. 152

Tablo 4.94: CNN EEG-MRG Ağdaki Parametreler. 153

Tablo 4.95: CNN EGG-MRG ağının Herbir İşlemdeki Sonucu. 154

Tablo 5.1: EEG verisinin doğrulama sonuçları. 155

Tablo 5.2: EEG verisinin çapraz doğrulama yapılan sonuçları. 156

Tablo 5.3: MRG verisinin doğrulama sonuçları. 156

Tablo 5.4: MRG verisinin çapraz doğrulama yapılan sonuçları. 157

Tablo 5.5: EEG-MRG verisinin doğrulama sonuçları. 158

Tablo 5.6: EEG-MRG verisinin çapraz doğrulama yapılan sonuçları. 158

Tablo 5.7: Ham EEG LSTM – CNN doğrulama sonucu. 158

Tablo 5.8: MRG LSTM – CNN doğrulama sonucu. 159

Tablo 5.9: EEG-MRG LSTM – CNN doğrulama sonucu. 159

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
x, y	: Görüntü fonksiyonu
m,n	: Görüntü matrisi
C	: Ortogonal matris
$\mathbf{C^T}$	: Ortogonal matrisin Transpozesi
G	: Temel Eksen
Z	: TBA' in Kovaryans matris
z	: LAA' nın kovaryans matrisinin özvektörünü
R	: En küçük karesel hata
I	: Seçilmeyen özellikler
S	: Seçilmiş özellikler
u	: Matrisin satır sayısı
v	: Matrisin sütun sayısı
$\mathbf{a_i}$	: i. Sınıfının ortalaması
$\mathbf{x_1}, \mathbf{x_2}$	: Giriş sinyali
$\mathbf{w_{k1}}$	: Nöron k ağırlığı
$\boldsymbol{\varphi}(.)$	: Aktivasyon Fonksiyonu
$\mathbf{y_k}$	: YSA çıkış değeri
$\mathbf{b_k}$	: Eşik Değeri
p	: Temel Bileşen Vektörü
$\mathbf{e_j}$	: Hata sinyali
E	: Enerji
2B	: İki boyutlu

Kısaltmalar	Açıklama
MRG	: Manyetik Rezonans Görüntüleme
MRI	: Magnetic Resonance Imaging
EEG	: Elektriksel Sinyal Grafiği
EEG	: Elektroensefalogram
DCT	: Discrete Cosine Transform

DWT : Discrete Wavelet Transform
AKD : Ayrık Kosinüs Dönüşümü
ICA : Independent Component Analysis
BBA : Bağımsız Bileşen Analizi
PCA : Principle Component Analysis
TBA : Temel Bileşen Analizi
LDA : Linear Discriminant Analysis
DDA : Doğrusal Ayırım Analizi
ANN : Artifical Neural Network
YSA : Yapay Sinir Ağları
LVQ : Learning Vector Quantization
AR : Öz Bağımlı
SVM : Destek Vektör Makinası
CCN : Hücresel Sinir Ağları
DWT : Discrete Wavelet Transform
ADD : Ayrık Dalgacık Dönüşümü
JADE : Öz matrislerin ortak yaklaşımla köşegenleştirmesi
PNN : Polinom Sinir Ağı
FCD : Fokal Kortikal Displazi
STFT : Kısa Zamanlı Fourier Dönüşümü
DICOM : Tıpta Dijital Görüntüleme ve İletişim
NIFTI : Neuroimaging Informatics Technology Initiative
SFFS : Sıralı İleri Özellik Seçimi
RBF : Radyal Tabanlı Fonksiyon
EBP : Elman Geri Yayılımlı
MLP : Çok Katmanlı Öğrenme
KNN : K-en yakın komşu
LSTM : Long- Short Term Memory
CCN : Convolutional Neural Network
PSO : Parçacık Sürüsü Optimizasyonu
MRBF : Çok Ölçekli Radyal Tabanlı Fonksiyon
ROC : Receiver Operating Characteristic
RF : Radyo Frekans
TR : Tekrar süresi

TE : Eko zamanı

fMRG : Fonksiyonel Manyetik Rezonans Görüntüleme ⎦

ÖZET

[DOKTORA TEZİ]

[BİR ve İKİ BOYUTLU BİYOMEDİKAL İŞARETLERİN DCT TABANLI ANALİZİ]

[Fatma DEMİREZEN YAĞMUR]

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

[Bilgisayar Mühendisliği Anabilim Dalı]

[Danışman: Prof. Dr. Ahmet SERTBAŞ]

[Bu çalışmada, AKD (Ayrık Kosinüs Dönüşümü-DCT) özellik çıkarım yöntemine dayanan 1 boyutlu (1B) ve 2 boyutlu (2B) biyomedikal işaret analizleri yapılarak yüksek doğruluklu epilepsi hastalığı teşhisi gerçeklenmiştir. Epilepsi hastalığı teşhisi amacıyla 1 boyutlu işaret analizi için EEG (Elektroensefalografi) verileri, 2 boyutlu işaret analizi için MRG (Magnetik Resonans Görüntüleme-MRI) verileri kullanılmıştır. 1 boyutlu EEG verilerine AKD ve ortalama, varyans, standart sapma, basıklık, çarpıklık gibi istatistiksel yöntemleri uygulanarak; 2 boyutlu MRG verilerine ise AKD ve ortalama istatistiksel yöntemi uygulanarak özellik vektörleri çıkarılmıştır. Elde edilen öznitelik vektörlerine TBA (Temel Bileşen Analizi-PCA), DAA (Doğrusal Ayırım Analizi-LDA), İleriye Doğru Seçim ve Geriye Doğru Seçim yöntemleri uygulanarak en etkin özellikler seçilmiştir. EEG, MRG ve EEG-MRG birleşik özellikleri kullanılarak Sağlıklı / Epilepsi şeklinde 2 kümeli sınıflandırma yapılmıştır. Tezde AKD özellik çıkarımı ile ADD (Ayrık Dalgacık Dönüşümü) karşılaştırılmış; 1B ve 2B biyomedikal işaretleri YSA, SVM, KNN ve RF makine öğrenme yöntemleri ile sınıflandırılmıştır. Ayrıca derin öğrenme ağında, LSTM ve CNN mimarilerinde veriler analiz edilmiştir. Tezimizde, EEG-MRG birleşik özelliklerinin epilepsi hastalığının teşhisinde çok etkin bir şekilde kullanılabileceği tespit edilmiştir.]

Haziran 2020, [198] sayfa.

Anahtar kelimeler: [Epilepsi, EEG, MRG, Ayrık Kosinüs Dönüşümü, Ayrık Dalgacık Dönüşümü, TBA, DAA, İleriye Doğru Seçim, Geriye Doğru Seçim, YSA, DVM, KNN, RF, LSTM, CNN]

SUMMARY

Ph.D. THESIS

DCT BASED ANALYSIS of 1D and 2D BIOMEDICAL SIGNAL

Fatma DEMİREZEN YAĞMUR

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Computer Engineering

Supervisor: Prof. Dr. Ahmet SERTBAŞ

In this study, 1-dimensional (1D) and 2-dimensional (2D) biomedical signal analysis based on the Discrete Cosine Transform (DCT) feature extraction method was performed to diagnose high-accuracy epilepsy disease. For the diagnosis of epilepsy, Electroencephalogram (EEG) data were used for 1-dimensional (1D) signal analysis and Magnetic Resonance Imaging (MRI) data were used for 2-dimensional (2D) signal analysis. In addition to DCT, statistical methods such as mean, variance, standard deviation, kurtosis, skewness were applied to 1-dimensional EEG data; on the other hand, feature vectors were obtained by applying DCT and mean statistical method to 2D MRI data. The most useful features were selected by applying PCA, LDA, Forward Selection and Backward Selection methods to the obtained feature vectors. EEG, MRI and EEG-MRI combined features of Healthy, and Epilepsy classification was made as a two-cluster. In the thesis, DCT feature extraction and DWT (Discrete Wavelet Transform) were compared. 1D and 2D biomedical signals are classified by ANN, SVM, KNN and RF machine learning methods. In addition, our data were analyzed in LSTM and CNN architectures in the deep learning network. In the dissertation, it has been established that the combined features of EEG-MRI can be used very effectively in the diagnosis of epilepsy.

June 2020, 198 pages.

Keywords: Epilepsy, MRI (Magnetik Rezonans Image), EEG (Elektroensefalogram), Discrete Cosine Transform, Discrete Wavelet Transform ICA, PCA, LDA, Forward Selection, Backward Selection, ANN, SVM, KNN, RF, LSTM, CNN

1. GİRİŞ

Bilgisayar teknolojilerinde veri iletim hızı 1965 yılından günümüze kadar katlanarak artmıştır. Buna bağlı olarak bilgisayarların gücü ve depolama kapasitesinde büyük gelişmeler kaydedilmiştir. Teknolojik gelişmeler yaşamın birçok alanında olduğu gibi, sağlık ve biyomedikal alanlarında da büyük bir etkiye sahiptir.

Toplum içinde yaşlı nüfusun oranının artması, tıbbi bakıma duyulan talep ve harcamalar, sağlık sektörüne olan ihtiyacın önemini daha da çok artırmaktadır. Yapılan araştırmalar sağlık bilgi teknolojisinin sağlık hizmetlerinin verimliliğini, kalitesini ve öte yandan maliyetini artırmada önemli bir rol oynadığı gösterilmiştir. Günümüzde büyük boyutlu medikal veriyi almak, kaydetmek ve verimli bir şekilde işlemek mümkündür. Yakın gelecekte ise otomatik karar sistemleri ve analiz teknikleri de dahil olmak üzere sağlık hizmetlerinde biyomedikal teknolojinin kullanımında hızlanan bir ilerleme beklenmektedir.

Biyomedikal verileri, bilgisayar teknolojileriyle işleyen bu tez ise epilepsi sınıflandırmasını gerçekleştiren sistemin parçalarını araştırır. Bu parçalar; ileri sinyal işleme, medikal resim işleme ve makine öğrenme tekniklerdir. Bunun tıp dilindeki karşılığı ise nörolog, epileptolog, radyolog ve psikiyatrın çeşitli teşhis teknikleri ve görüntüleme bilgilerinin bir araya getirilip bütünleştirilmesi gereken multidisipli bir alandır. Tezimizde bu yöntemlerin ikisini analiz ediyoruz: EEG (Elektroensefalografi) ve MRG (Manyetik Rezonans Görüntüleme). Bu teknikler uzun çekim seansları içerir ve elde edilen büyük verilerin yorumlanması için özel eğitilmiş personel gerektirir. Bu nedenle teşhisi destekleyen otomatik yöntemler oldukça faydalı olacaktır.

EEG, beynin yüzeyinde veya içindeki belirli yerlerde belirli bir süre boyunca devam eden nöral aktiviteyi ölçer. Çekim esnasında beyin aktivitesinin etkinliği temsil eden çok değişkenli zaman seri dizisi kaydedilir, bununla birlikte bu zaman serisi mekân ve zaman ilişkisini içeren çok önemli bilgiler taşır (Hunyadi B., 2014). MRG ise X ışınlarına ihtiyaç duymadan, dokuların son derece ayrıntılı görüntülerinin, Radyo Frekans (RF) dalgalarının vücuttaki protonlar ile etkileşimine dayanan ve görüntü oluşturulması prensibine göre çalışan bir yöntemdir (Bahadır, 2005).

Bu çalışmada, AKD (Ayrık Kosinüs Dönüşümü-DCT) özellik çıkarım yöntemine dayanan 1 boyutlu (1B) ve 2 boyutlu (2B) biyomedikal işaret analizleri yapılarak yüksek doğruluklu epilepsi hastalığı teşhisi gerçeklenmiştir. Epilepsi hastalığı teşhisi amacıyla 1 boyutlu işaret analizi için EEG verileri, 2 boyutlu işaret analizi için MRG verileri kullanılmıştır. Yöntem kısmı üç aşamada analiz edilmiştir.

3.4 no'lu başlıkta EEG Analizinde 1-boyutlu EEG verilerine AKD ve ortalama, varyans, standart sapma, basıklık, çarpıklık gibi istatistiksel yöntemleri uygulanarak özellik vektörleri çıkarılmıştır. Elde edilen öznitelik vektörlerine TBA (Temel Bileşen Analizi-PCA), DAA (Doğrusal Ayırım Analizi-LDA), İleriye Doğru Seçim ve Geriye Doğru Seçim yöntemleri uygulanarak en etkin özellikler seçilmiştir. Çok Katmanlı Algılayıcı YSA yöntemi ile sınıflandırma yapılmıştır.

3.5 no'lu başlıkta MRG Analizinde 2 boyutlu MRG verilerine ise AKD ve ortalama istatistiksel yöntemi uygulanarak özellik vektörleri çıkarılmıştır. Elde edilen öznitelik vektörlerine TBA, DAA, İleriye Doğru Seçim ve Geriye Doğru Seçim yöntemleri uygulanarak en etkin özellikler seçilmiş olup aynı YSA yöntemiyle sınıflandırma yapılmıştır.

3.6 no'lu başlıkta EEG ve MRG özellik birleşimlerinin analizinde ise 1 boyutlu (EEG) ve 2 boyutlu (MRG) olan biyomedikal işaretlerin özellik birleşimleri yapılarak analiz edilmiştir. Hem EEG de hem de MRG verilerinde gerekli önişlemler yapılıp, özellik vektörleri çıkarıldıktan sonra bu iki özellik kümesi birleştirilip tek bir özellik kümesi elde edilir. Yeni veri setinde etkin özellikler çıkarabilmek için TBA, DAA, İleriye Doğru Seçim ve Geriye Doğru Seçim özellik çıkarım yöntemleri uygulanmıştır. Seçilen özellikler Çok Katmanlı Algılayıcı YSA yöntemi ile sınıflandırma yapılmıştır. Sınıflandırma tahmin analiz metrikleri olan doğrulama, duyarlılık ve kesinlik ile değerlendirme yapılıp karşılaştırılmıştır.

EEG ve MRG yöntemlerinde özellik çıkarım yöntemi olarak AKD (Ayrık Kosinüs Dönüşümü-DCT) ve ADD (Ayrık Dalgacık Dönüşümü-DWT) kullanılmıştır. Bununla beraber literatürdeki Dönüştürülmüş Yapısal Özelliklerden gerekli olanlar kullanılmıştır. 3.1 no'lu başlıkta AKD yapısı 1B ve 2B olarak incelenmiştir.

4. no'lu Bulgular bölümünde EEG, MRG ve EEG- MRG yöntemlerinden, çıkarılan özellikler içinde, en etkin özelliklerin seçilebilmesi için TBA (Temel Bileşen Analizi-PCA), DAA (Doğrusal Ayırım Analizi-LDA), İleriye Doğru Seçim ve Geriye Doğru Seçim yöntemlerinin

sonuçları verilmiştir. Seçilen özelliklerin farklı sınıflandırma algoritmalarında (YSA, SVM, KNN, RF) ki başarı sonuçları farklı metriklere göre hesaplanmıştır. Derin Öğrenme Algoritmalarıyla (LSTM, CNN) analiz sonuçları verilmiştir.

EEG ve MRG gibi büyük boyutlu verileri işlemek için Makine Öğrenmesine ihtiyaç duyulur. 3. Bölüm 3.3 no'lu başlıkta ise Makine Öğrenmesi ilgili yaklaşımlar ele alınıp öğreticili ve öğreticisiz öğrenme yöntemlerinden bahsedilmiştir. Tezimizdeki veriler öğreticili yöntemlerden biri olan Yapay Sinir Ağları ile sınıflandırılmıştır. YSA, insan beynini model alarak geliştirilen bir sistemdir. Bu sistem, problemlerin matematiksel olarak formüle edilemeyen veya edilse bile kompleks çözümleri olan sistemlere alternatif sonuç üretir. YSA, veriler arasında ilişki kurarak sisteme eklenen yeni özelliklerle kendini yenileyebilen, analiz ve tahminlerde bulunan bir sistemdir. YSA'nın yanı sıra SVM, KNN, RF sınıflandırma algoritmaları kullanılmıştır. Derin Öğrenme kısmında ise LSTM ve CNN algoritmaları kullanılmıştır.

Bu çalışmada, EEG- MRG özellik birleşimlerinin AKD tabanlı olarak sınıflandırma yöntemiyle yüksek doğruluklu epilepsi hastalığı teşhisi gerçeklenmiştir.

2. GENEL KISIMLAR

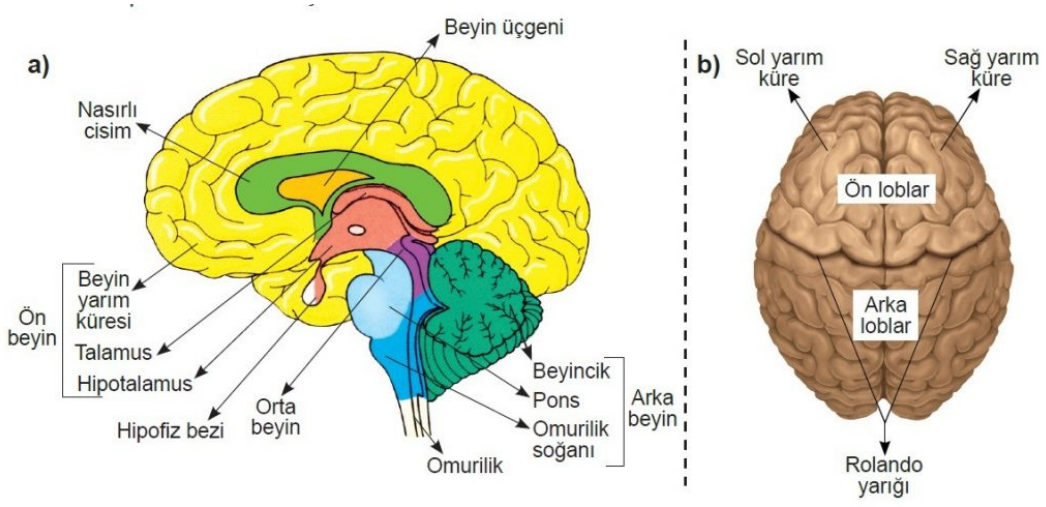
Nöron görüntüleme teknikleri, genel olarak beynin anatomisi ve işlevi hakkında bilgi edinmeyi amaçlar ve aynı zamanda anatomik veya fonksiyonel düzeyde anormallikleri tespit etmekte, epilepsi gibi çeşitli nörolojik hastalıkların teşhisinde rol alır. Bu bölüm, beyin görüntüleme, epilepsi ve teşhis konmasında uygulanan yöntemler hakkında genel bilgi vermeyi amaçlamaktadır.

2.1. BEYİN YAPISI

İnsan beyninin yapısı ve işlevi hakkında 3.3 nolu başlık Makine Öğrenmesi sayfa 22,23,24'te bilgilendirme yapılmıştır.

2.1.1. Beyin Anatomisi

Merkezi sinir sisteminin bir parçası olan beyin, davranışları kontrol edebilmek için bedenden ve çevreden alınan bilgilerin seçilmesi ve yorumlanmasından sorumludur.



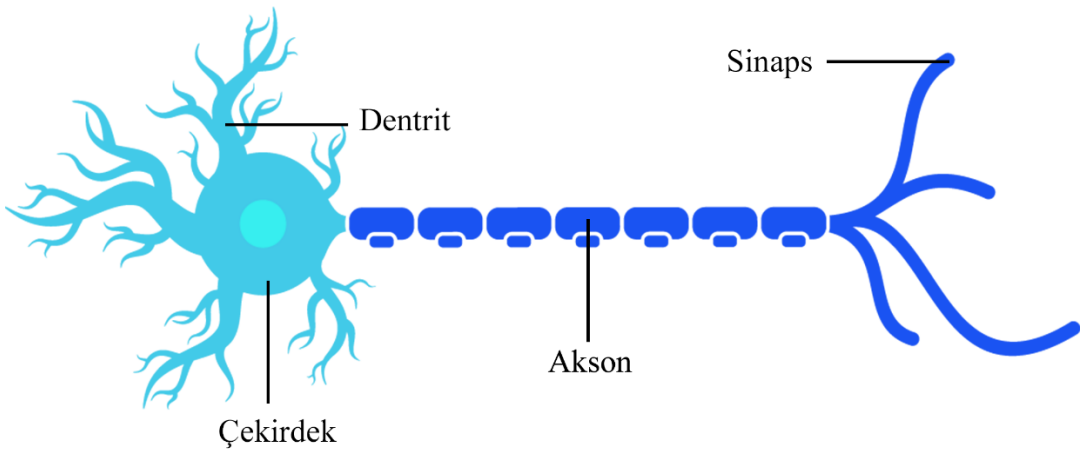
Şekil 2.1: (a,b) Beynin anatomik olarak şeması (Keskin, 2018).

Beyin, üç katmanlı yumuşak zarlarla kaplıdır. Beyin, ön beyin (beyin yarım kümesi, talamus, hipotalamus), orta beyin ve arka beyin (beyincik, pons, omirilik soğanı)'den meydana gelir (Şekil 2.1). Talamus, koku hariç bütün duyuların yönetim merkezi; hipotalamus ise dokuların

ve iç organların kontrol merkezidir. Beyinin alt kısmında bulunan beyincik, hareket ve denge merkezidir. Omirilik soğanı ise yaşamsal olayların (solunum, boşaltım) ve reflekslerin kontrollerini sağlar.

2.1.2. Beyin Fizyolojisi

İnsan beyninde bulunan hücrelere nöron adı verilir. Dentritler sinir hücrelerinden uyarılar alınmasını sağlar. Sinapslar bir hücreden diğerine elektrik iletimini sağlar. Bu sinyaller soma'da toplanır ve işleme alınır. Bilgi ve sinyaller nöronlar arasında akson bağlantıları sayesinde aktarılır. Dentritler bu sinyalleri sinapslere göndererek diğer sinyallerin hücrelere gönderilmesini sağlar. Böylece hücreler arasında bilgi akışı sağlanmış olur. Beyin Fizyolojisi ilgili detaylı bilgiler 3.3 nolu başlıkta yer almaktadır.



Şekil 2.2: Sinir hücresinin yapısı.

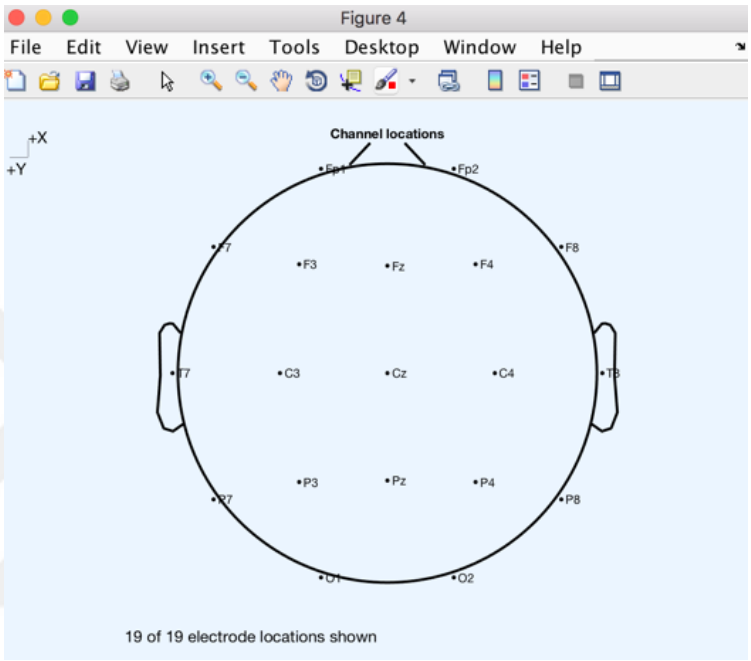
2.2. BEYİN GÖRÜNTÜLEME VE İZLEME TEKNİKLERİ

Beyin yapısı ve fonksiyonunu farklı yönlerini inceleyen çeşitli ölçüm teknikleri mevcuttur. Anatomik yapılarla birlikte lezyonlar ve hastalığın (epilepsi) neden kaynaklandığını öğrenmek için MRG verileri incelenir. Beyin tarafından üretilen sinyaller EEG ile kaydedilir.

2.2.1. EEG

Elektroensefalogram (EEG), kafa derisine yerleştirilen elektrotlar vasıtasıyla beyindeki elektriksel aktivitenin, zamanın değişkeniyle birlikte ölçülmesini sağlar. EEG, mevcut kayıttaki

ani değişiklikleri karakterize ederek iyi bir zamansal bilgi içerir. Bununla birlikte, kullanılan elektrotların sayısı kayıt esnasında daha detaylı özellikleri aktarmayı sağlar. Klasik EEG dalga genliği 10 ile 100 μV arasında ölçülür. EEG ölçüm sistemlerinde farklı elektrot yerleşimleri bulunmaktadır. Uluslararası 10-20 sistemine göre elektrotların konumları Şekil 2.3'te gösterilmiştir.



Şekil 2.3: 10-20 sistemine göre elektrot konumu.

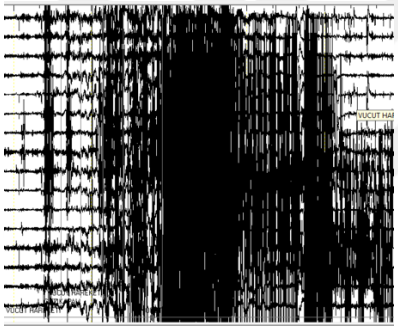
Elektrotların adları, bir harfin ve bir sayının birleşimidir. Harf, ilgili beyin bölgesini gösterir (sırasıyla F, P, O, T ve C, frontal, parietal, oksipital veya temporal lob ve merkezi çizgi için). Sayı, elektrotun orta, sağ ve sol yarımküreye yerleştiğini gösterir (sırasıyla sıfır, tek ve çift sayılar için z). Her bir EEG kanalı, iki elektrot bölgesi arasındaki potansiyel farkı ölçer. Sinyallerin yönlendirilmesi elektrotların yerleştirme durumuna göre değişir. Bu da EEG modelinin türüne göre avantaj veya dezavantaj sunmaktadır.

EEG frekans spektrumu olarak fizyolojik veya zihinsel işlemlere karşılık gelen aşağıdaki alt bantlara ayrılır.

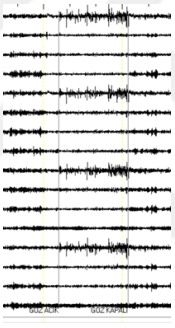
- Delta: 0.1-3.5 Hz
- Teta: 4-7.5 Hz
- Alfa: 8-13 Hz
- Beta: 14-30 Hz

Yavaş dalgalar uyanıklık ve uykunun faklı evrelerinde ortaya çıkar. Delta dalgaları derin uykuda, Teta dalgaları uyuşukluk ve hafif uyku, Alfa dalgaları ise gözler kapalı uyanık rahat bir durumda meydana gelir. Beta dalgaları oldukça heterojendir. Normal uyanıklık, endişe, uyuşukluk ve uyku başlangıcı gibi farklı fizyolojik olaylara karşılık gelen birkaç bölgede ortaya çıkabilir. Epileptik vakalar ise daha yüksek frekans bantlarında beyin aktivitesini araştırmaktadır.

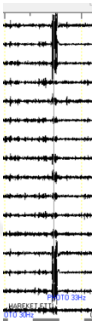
EEG'de potansiyelini yorumlamasını engelleyecek yapay etkenler (artefackts) bulunabilir. Bu yapay etkenler fizyolojik veya fizyolojik olmayan farklı etmenlerle meydana gelmiş olabilir. Fizyolojik olmayan yapay etkenler, elektrot ve cihazdan kaynaklı durumlardır. Fizyolojik yapay etkenler ise, beyin dışında vücudun kendinden kaynaklanmasından dolayı üretilen elektrik akımıdır.



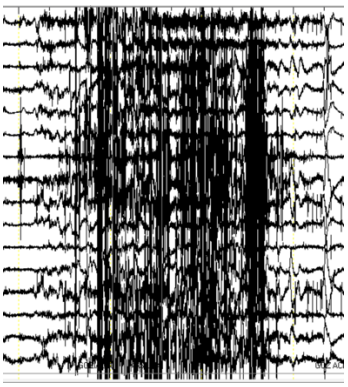
a: Vücut Hareketi



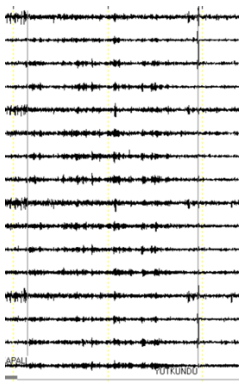
b: Göz Açıp-Kapama



c: Hareket Etme



d: Kasılma



e: Yutkunma

Şekil 2.4: (a,b,c,d,e) EEG'deki yapay etkenler.

Gözün yatay ve dikey aç-kapa yapmasından kaynaklı, vücudun hareketlerinden kaynaklı ve kas kasılmasından kaynaklı yapay etkenler Şekil 2.4'te gösterilmiştir.

2.2.2. MRG

Radyo dalgalarının kullanılmasıyla farklı biçimlere sahip anatomik yapılar (beyindeki lezyon ve tümör vb.) manyetik rezonans görüntüleme sistemi ile tespit edilebilmektedir. Büyük mıknatısların kullanılmasıyla meydana gelen güçlü manyetik alan içindeki radyo dalgalarını kullanan MRG cihazları, belirli anatomik yapıları diğer yapılardan kesin olarak ayırt etmeye yarayan, sağlıklı ve hastalıklı dokular arasındaki farklılıkları belirleyip tanımlayan tıbbi bir tespit aracıdır.

Beyin MRG'ları iki türden oluşur. Bunlar, f MRG (Fonksiyonel Manyetik Rezonans Görüntüleme) ve sMRG (Yapısal Manyetik Rezonans Görüntüleme)'dir.

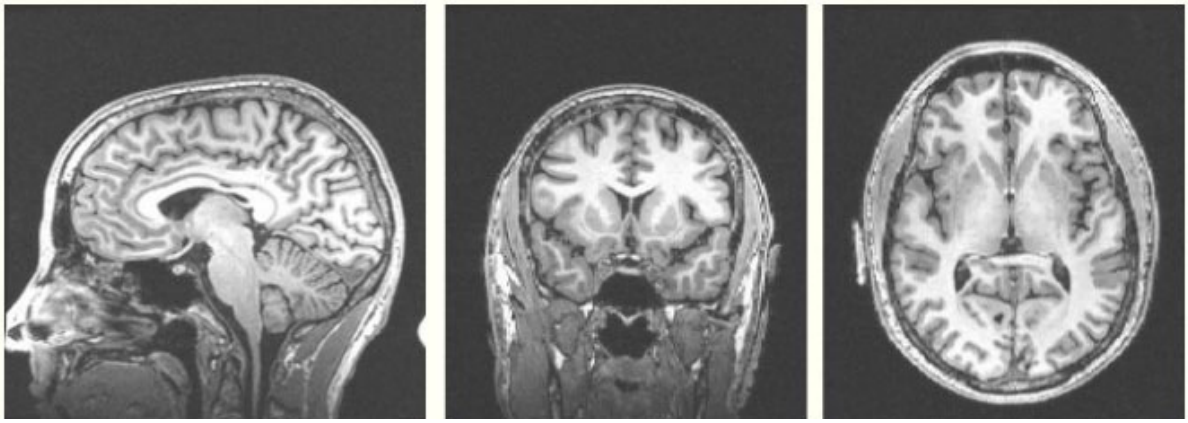
Fonksiyonel MRG, beyin aktivitesini ölçmek için kullanılan bir tekniktir. Sinirsel aktiviteye tepki olarak oluşan kan akışındaki değişimleri saptayarak çalışır. Beyinin hangi bölgesi daha aktif ise o bölgede daha fazla oksijen tüketilir. Neticede, artan talebi karşılamak amacıyla kan akışı aktif bölgeye doğru yönelir.

Yapısal MRG, beyindeki gri (gray) ve beyaz (white) madde (matter) yapılarının şekil, boyut ve bütünlüğünü nitel ve nicel olarak tanımlamak için bilgi sağlar. Gri bölge, sinir lifleriyle ilgili analizlerin, beyaz bölge ise ödem ve iltihap türü analizlerin yapıldığı bölgelerdir. Ayrıca yapısal MRG'ler fonksiyonel sinyal bilgilerinin çıkarılmasında, aktif örüntünün ve ilgili alanın görselleştirilmesinde anatomik referans sağlar. SMRG'ler sıralanma tiplerine göre değişiklik gösterir.

Normal ve anormal beyin dokusunun farklı yönlerini vurgulayan birçok nabız dizisi mevcuttur. Örneğin anatomik görüntüler, tekrar süresi (TR) ve eko zamanı (TE) gibi dizi parametrelerini değiştirerek gri ve beyaz madde arasındaki kontrastı (örn. kısa TR ve kısa TE ile T1 ağırlıklı) veya beyin dokusu ile beyin omurilik sıvısı arasındaki kontrastı vurgulayabilir (örn. T2-ağırlıklı, uzun TR ve uzun TE). Bu dizilerin ne kadar süre devam ettiğine göre de değişik verilerin elde edilmesini sağlar. Elde edilen sıralama türleri: T1, T2 ve PD'dir.

2.2.2.1. T1 ağırlıklı

Gri madde (koyu gri) ile beyaz madde (açık gri) dokuları arasında iyi kontrast sağlanabilmesi CSF sinyaline (siyah) bağlıdır.

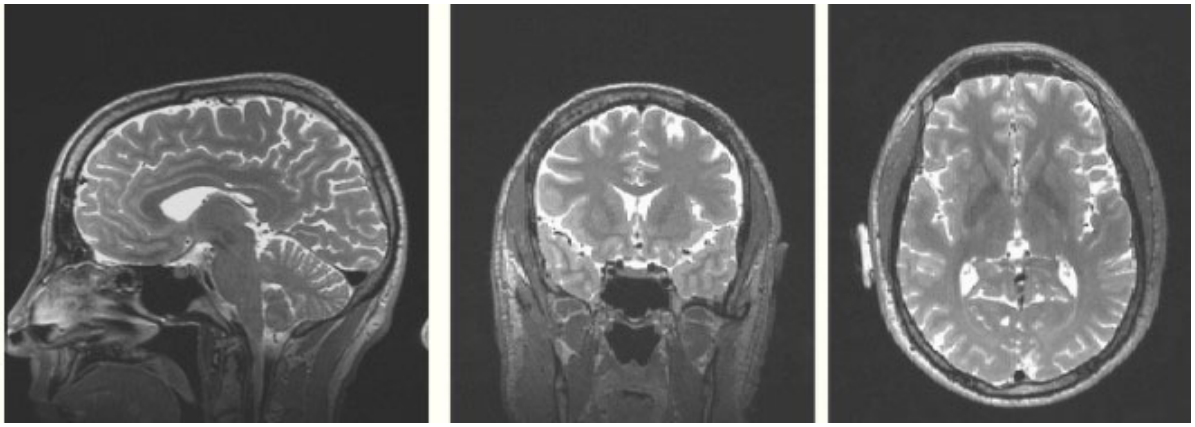


Şekil 2.5: MRG-T1 örneği.

Şekil 2.5'te su kısımları daha koyu görüntülenir; yağ kısımları ise daha açık görüntüye sahiptir. Sinir liflerinde miyelin kaybı ve iltihaplanma, dokulardaki su içeriğini artırır ve bu durum T1 sinyallerinin zayıflamasına sebep olur. Beyaz madde hastalıkları, açık gri-beyaz bölgelerde daha koyu bölgeler olarak kendini göstermektedir.

2.2.2.2. T2 ağırlıklı

CSF ile beyin dokusu (koyu renk) arasında iyi bir kontrast sağlar. Bazı T2 dizileri gri madde (daha açık gri) ve beyaz madde (daha koyu gri) arasında ilave kontrast gösterir.

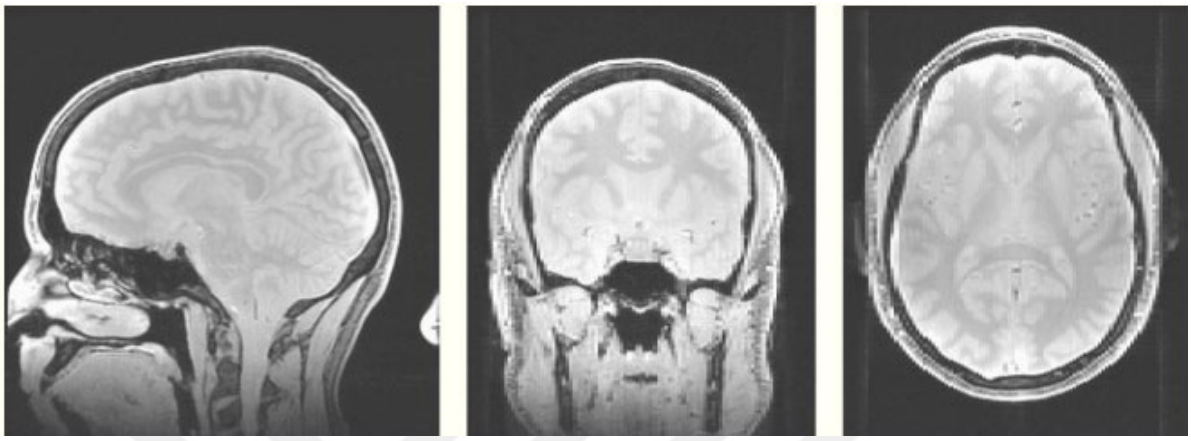


Şekil 2.6: MRG-T2 örneği.

Şekil 2.6'da su kısımları daha açık renk ile görüntülenir; yağ kısımları ise daha koyu görüntüye sahiptir. Sinir liflerinde miyelin kaybı ve iltihaplanma, T2 sinyallerinin artmasına sebep olan dokulardaki su içeriğini artırır.

2.2.2.3. Proton yoğunluğu ağırlıklı

Beyin ve CSF arasında çok az kontrastla, gri (açık) ile beyaz (koyu gri) madde arasında iyi bir kontrast sağlar.



Şekil 2.7: MRG-PD örneği.

Şekil 2.7'de su sinyalleri değişir. CSF ise genellikle gri renkte iken diğer sıvılar daha yüksek sinyal yoğunluğuna sahip olabilir. Beyaz madde içindeki lipidler gibi yağ kısımları açık renklidir; ancak gri maddeler beyaz maddeden daha parlak görünürler.

Subkortikal çekirdekler ve neokorteks, T1'e benzeme eğilimindedir. Sinir liflerinde miyelin kaybı ve iltihaplanma, dokulardaki su içeriğini artırır. Bu da PD (Proton Density) de sinyallerinin artmasına sebep olur.

2.3. EPİLEPSİ

Felçten sonra dünya nüfusunun %0,5'inden fazlasında görülen ikinci nörolojik rahatsızlık olan epilepsi (Forsgren ve diğ., 2005), tekrarlayan epileptik nöbetlerle karakterize olmuş nörolojik bir hastalıktır (Blume ve diğ., 2001). Nöbet, beyindeki anormal veya senkron nöronal aktiviteye bağlı olarak belirti veya semptomların geçici olarak ortaya çıkması olarak tanımlanır (Fisher ve diğ., 2005). Nöbet esnasında nöronlarda elektriksel aktivitenin bir anda arttığı gözlemlenir ve dengede bozulmaları aza indirmek için inhibisyon (azaltıcı tesir) mekanizması devreye girer. Bu mekanizmalar başarız olduklarında nöronlar hiper-aktif olarak yakın nöronlarla temasa girer. Anormal aktivite, normal beyin aktivitesi sağlanırken onunla birlikte diğer bölgelere yayılabilir. Epilepsi nöbeti sonlanırken bunun birçok sebebi olabilir; nöbet geçirilirken aktif

nöronların oksijen yetmezliği veya nöbeti baskılayan mekanizmanın kimyasal yapısındaki değişiklikler (Varsavsky ve diğ., 2011).

Nöbet, geçirilen bölgeye bağlı olarak hastada duyusal işlev bozukluğu, bilinç kaybı, motor otomatizmine (istem dışı hareketlerin yapılması) yol açabilir. Epilepsiye Karşı Uluslararası Dernek (ILAE) odaklı (focal) ve yayılabilen (generalised) olmak üzere iki ana epilepsi nöbeti belirlemiştir. Odaklı epileptik nöbetler bir yarımkürede sınırlı ağlardan kaynaklanırken, yayılabilen nöbetler ise karşılıklı dağınık ağ içinde bir noktadan diğerine hızlı bir şekilde yayılmaktadır (Berg ve diğ., 2010). Nöbet çeşitleri arasında uzun süreli nöbetler, iyileşmenin olmadığı, yaşamı ciddi şekilde tehdit edici türdür. Tezimizde verileri incelenen epilepsi hastalarının nöbet türleri daha çok 'odaklı' epileptik çeşittir.

2.4. LİTERATÜR ÖZETİ

Epilepsi teşhisiyle ilgili 1982'den başlayarak günümüze kadar birçok çalışma yapılmıştır.

Gotman (1982), epilepsi hastalarında klinik belirtilerden bağımsız EEG işaretlerinde nöbetlerin otomatik olarak saptanması için bir yöntem geliştirmiştir. Buna göre, 16 kanallı 44 epilepsi kaydında sayısız epileptik nöbet tipi tanımlamıştır.

Anderson ve diğ. (1995), çalışmasında 6 kanallı EEG verilerinin yarım saniyelik kısmını zihinsel durum tanımlanması amacıyla Yapay Sinir Ağları kullanmışlardır. EEG sinyalleri Öz Bağlanımlı (AR) ile modellenip iki ve üç katmanlı ileri yayılımlı ağ ile eğitilmiştir. Buradan %71 doğruluk başarısı elde edilmiştir.

Kalaycı ve Özdamar (1995), EEG verilerinin içeriği azaltılmayıp tespit performansları düşürülmeden Dalgacık Dönüşümü kullanılarak, giriş verilerinin çıkış verilerine aktarılmasıyla kurulan yapının Yapay Sinir Ağları ile daha iyi sonuç verdiğini gösteren bir çalışma ortaya koymuşlardır.

Pradhan ve diğ. (1996), Learning Vector Quantization (LVQ) ağının nörolog sitiline göre kolaylıkla ayarlanabilen, uzman analizi kadar hassas yapıda olup spesifik epileptik sinyallerin tespiti için pratik çözüm sunmuşlardır.

Subaşı ve diğ. (2004) EEG sinyallerine Öz Bağlanımlı (AR) ve Hızlı Fourier Dönüşümü kullanarak belirli katsayılar elde edip, bu katsayıları Dalgacık Dönüşümü Ağının giriş verileri olarak verip YSA ile sınıflandırma yapılmıştır.

Dohler ve diğ. (2006), 144 epilepsi hastasına ait 3-boyutlu T1-ağırlıklı MRG veri setini MPRAGE dizilimi ile 256×256 boyutlu veri matrislerine dönüştürerek hesaplamışlardır. Hücresel sinir ağlarına (Cellular Neural Networks-CNN) hesaplanan veri seti uygulanarak temporal lob epilepsisini %68 doğruluk oranı ile sınıflandırmışlardır.

Übeyli (2008), normal ve kısmi epilepsi tanımlamasını MIT-BIH heterojen veritabanındaki elektrokardiyogram sinyalleri ile yapmıştır. SVM algoritmasına db1 dalgacık katsayısı ile elde edilen özellikleri uygulayarak optimum sınıflandırma doğruluğunu %99.44 elde etmiştir.

Krishnaveni ve diğ. (2008), EEG sinyallerinin içerdiği yapay etkenleri öz matrislerin ortak yaklaşımla köşegenleştirmesi (Joint Approximation Diagonalisation of Eigen matrices- JADE) algoritmasını kullanarak BBA yöntemiyle sinyaller ayrıştırılmıştır. Özellik çıkarımı için Öz Bağımlı (AR) yöntemi kullanılmıştır. Sınıflandırma yapmak için yapay sinir ağlarının Polinom Sinir Ağı (PNN) ve İleri Yayılım Sinir Ağı yöntemleri kullanılmıştır. Sonuç olarak İleri Yayılım Sinir Ağında daha başarılı sonuç elde edilmiştir.

Loyek ve diğ. (2008) göre Fokal kortikal displazi (FCD), tıbbi olarak dirençli parsiyel epilepsinin sık görülen bir nedenidir. FCD lezyonlarının manyetik rezonans görüntülerde (MRG) görsel olarak tanımlanması standart radyolojik analizlere göre zor bir iştir. Bu çalışmada, lezyonlu dokuları tespit etmek ve fokal tahminde bulunmak için bir model geliştirilmiştir. Bu modele göre, epilepsi hastalarının Manyetik Rezonans Görüntülerine (MRG) Destek Vektör Makinaları (SVM) kullanılarak fokal lezyonları bölümleme ve doku tabanlı sınıflandırma yapılmıştır.

Ogulata ve diğ. (2009), 79 epilepsi hastasına ait EEG, yaş, cinsiyet, bilinç kaybı, nöbet zamanı bilgilerine dayanarak elde edilen veri setinden tonik klonik, absans, myoklinik, >1 nöbetleri olmak üzere epileptik nöbetleri sınıflandırmışlardır. MLP sinir ağına uygulanan veri seti için epileptik nöbetler sırasıyla %78.5, %80, %50, %91.6 olarak doğrulama başarısı elde edilmiştir.

Subaşı ve Gürsoy (2010), EEG sinyallerini DWT kullanarak frekans alt bantlarına ayrıştırıp dalgacık katsayılarının dağılımını temsil etmek için alt bantlardan bir dizi istatistiksel özellikler

çıkarmışlardır. Verilerin boyutunu azaltmak için temel bileşenler analizi (PCA), BBA (Bağımsız Bileşenler Analizi-ICA) ve Doğrusal Ayırma Analizi-LDA) kullanılır. Daha sonra bu özellikler iki ayrı çıkışa sahip bir destek vektör makinesine (SVM) giriş olarak verilir. Çıktı ise 'epileptik nöbet ya da değil' şeklindedir. Sınıflandırma işleminin farklı yöntemlerden kaynaklı performansları hesaplanır ve sınıflandırma sürecinin başarılı olduğunu göstermek için bunlar karşılaştırılır.

Gandhi ve diğ. (2012), 300 normal, 300 epilepsi hastasına ait EEG verisine Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform-DWT) uygulayarak sinyale ait enerji, entropi, standart sapma, ortalama, basıklık, çarpıklık değerlerini hesaplayarak ayrılma ağacı oluşturmuşlardır. Ağaçtaki her bir düğüme Harmony Arama Algoritması uygulayarak yeni özellik uzayı elde etmişlerdir. Olasılıksal Sinir Ağları algoritmasına elde edilen yeni özellik uzayı uygulanarak normal ve epileptik hastaları %100 doğruluk oranı ile sınıflandırmışlardır.

Kamath ve diğ. (2013), 3000 örnek pencereleme ile oluşan veri setinin zaman alanındaki hızlı frekans değişimlerini Teager Enerji ile hesaplayarak epileptik nöbetlerin teşhisinde yeni bir yaklaşımda bulunmuşlardır. Hasta ve sağlıklı bireylerin sınıflandırılmasında sinyale ait ZONF,S frekanslarını %97, NF,S frekanslarını %98.5, Z,S frekanslarını %100, ZNF,S frekanslarını %98.9 ile hesaplamışlardır.

Zainuddin ve diğ. (2013), 4097 EEG sinyal noktasına K-Ortalamalar ve Yapay C-Ortalamalar algoritmalarını uygulayarak sinyaldeki ara düğümlerin karar verilmesini sağlamışlardır. Yazarlar, bu çalışmada Yapay C-Ortalamalar algoritmasını ve Harmony Arama Algoritmasını bir arada uygulayarak hibrid yöntem önermişlerdir ve adına tip-2 demişlerdir. Çalışmalarının sonucunda epileptik nöbet ve sağlıklı bireylere ait sınıflandırma doğruluğunu 99.15 ± 0.13 olarak elde etmişlerdir.

Adam ve diğ. (2014), EEG sinyal verisine Zirve Yakalama Algoritması uygulayarak elde edilen tepe-sinyallerinden özellik uzayını çıkarmışlardır. Elde edilen özellik uzayı kural tabanlı sınıflandırıcı ile eğitilmiştir. Test işlemi için filtrelenmiş EEG sinyalinden elde edilen özellikler eğitim aşamasında oluşturulan kural tabanlı ağaca uygulanarak optimum zirve noktasını Geometrik Ortalama Metoduna göre belirlemişlerdir. Geometrik Ortalama Metoduna göre eğitim işleminin sonucunda %99.90 eğitim, test işleminin sonucunda %98.58 başarı elde edilmiştir.

Duque-Muñoz ve diğ. (2014), 40 epilepsi hastası bireye ait EEG verisine Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform-STFT) uygulayarak sinyal verisine ait stokastik değişkenleri hesaplamışlardır. STFT ile elde edilen durağan olmayan EEG davranışlarını normal; iktal ve interiktal aktivitelerini Destek Vektör Makinası ve k-en yakın komşu (k-Nearest Neighbor- kNN) algoritmaları ile sırasıyla %95.78 ve %96.58 doğruluk oranlarıyla sınıflandırmışlardır.

Dhiman ve diğ. (2014), normal ve epilepsi hastası bireylere ait toplam 100 EEG segmentine ayrık dalgacık dönüşümü (Discrete Wavelet Transform-DWT) uygulayarak sinyale ait enerji, entropi, standart sapma, ortalama, basıklık, çarpıklık değerlerini hesaplayarak optimal özellikleri genetik algoritmalar ile seçerek hibrit yaklaşımda bulunmuşlardır. Destek Vektör Makinası algoritmasına optimal özellik uzayını uygulayarak 10-çapraz doğrulama yöntemi ile %100 lük başarı elde etmişlerdir.

Kumar ve diğ. (2015), nöbet ve nöbetsiz EEG sinyallerinin sınıflandırılması için tek boyutlu lokal ikili patern (1D-LBP) tabanlı özellikler kullanmışlardır. Önerilen yöntemde, EEG sinyallerinin işlenmesi için bir grup Gabor filtresi kullanılır. İşlenmiş EEG sinyalleri daha küçük segmentlere bölünerek bu segmentlerin 1D-LBP'lerinin histogramları hesaplanır. Elde edilen EEG sinyalinin nöbetli ya da nöbetsiz kategoriye ait olduğunu belirlemek için En yakın komşu sınıflandırıcısı kullanıldı.

Fu ve diğ. (2015), Hilbert Marjinal Spektrum (HMS) analizi kullanarak EEG sinyallerinde otomatik nöbet tespiti için yeni bir teknik sunmaktadırlar. Bu çalışmada, HMS analizi kullanılmasıyla ritim frekans bantlarının spektral entropileri ve enerji özellikleri çıkarılmış ve elde edilen bu veriler EEG sinyallerinin nöbet tespiti için destek vektör makinesine (SVM) verilmiştir.

Rudie ve diğ. (2015), nöro görüntüleme verilerine makine öğrenme yöntemleri uygulayan yeni yaklaşımlar, temporal lob epilepsisi (TLE) gibi beyin temelli bozuklukların tanı ve tedavisinde yardımcı olacak kişiselleştirilmiş önlemler geliştirmeyi amaçlamaktadır. Çalışmalarında, sınıflandırma için Free Surfer (FS) ile otomatik segmentasyon yapılıp çoklu destek vektör makinesi özyinelemeli özellik seçim algoritması uygulanmıştır. Bunlar FS ile otomatik sınıflandırılmıştır.

Abhiyana ve diğ. (2016), 50 kişiye ait fokal ve fokal-olmayan bölgeden elde edilmiş EEG sinyalinin yaklaşık entropi, örnek entropi, yapay entropi, permütasyon entropi ve çok ölçekli entropi karakterizasyonuna göre hesaplamışlardır. Sıralı İleri Özellik Seçimi (Sequential Forward Feature Selection-SFFS) algoritmasına göre seçilen en önemli özellikler Radyal Tabanlı Fonksiyon Destek Vektör Makinası (RBF- SVM) algoritmasına uygulanarak normal ve fokal sinyal sınıflandırması için %82 doğruluk oranı elde edilmiştir.

Das ve diğ. (2016), ampirik modda ayrışma ve Ayrık Dalgacık Dönüşüm (DWT) alanlarında kapsamlı ve yayılabilen EEG'nin kapsamlı bir analizini yapmışlardır. DWT alanlarında Shannon entropisi, log-enerji entropisi ve Renyi entropisi gibi bir dizi spektral entropi tabanlı özellik, ampirik mod ayrıştırma hesaplanır. Hesaplanan özelliklerin KNN ve SVM'de sınıflandırma karşılaştırmaları yapılmıştır.

Spyrou ve diğ. (2016) çalışması depresyon ve nöro dejenerasyon muzdarip yaşlı katılımcıların nörofizyolojik özelliklerini değerlendirmeyi amaçlamaktadır. EEG özellikleri senkronizasyon analizi (Ortogonal Ayrık Dalgacık Dönüşümü) ile tahmin edilmiş; veri sınıflandırması için ise Rastgele Orman, Rastgele Ağaç, Çok Katmanlı Algılayıcı (MPL Ağı) ve Destek Vektör Makineleri (SVM) kullanılmıştır.

Martinez-del-Rincon ve diğ. (2017), Bonn Üniversitesi, HRUCH, FREIBURG EEG sinyal veri setleri normal ve epileptik olarak sınıflandırmışlardır. Özellik çıkarımında Sözcük Çantası (Bag of Words-BOW) modelinden esinlenerek sinyaldeki gürültü, sinyal zayıflaması ve yapay etkenler sinyalde çok sık geçen bu veriler hesaplanmıştır. Verideki dalgacık katsayılarını hesaplayarak istatistiksel veriler elde etmişlerdir. A, E EEG segmentlerinin sınıflandırılmasında BOW + Polinomsal SVM algoritması ile %99.84 sınıflandırma doğruluğu elde etmişlerdir.

Sharif ve diğ. (2017), 19 epilepsi hastasına ait EEG zaman serisine Poincare uçağı metodu uygulamayı önermişlerdir. Bu metoda göre her kanal için Genetik algoritma ve Shannon entropi hesabı ile 64 yapay kurallar tanımlanarak öznitelik uzayı elde edilmiş; yapay kurallardan varyans hesabı yapılmıştır. Varyans hesabı ile iktal nöbet özellik setini elde etmişler; elde edilen özelik setine TBA algoritmasını uygulayarak özellik seçimi yapmışlardır. Gauss RBF-SVM algoritmasına elde edilen yeni özellik uzayını uygulayarak %91.8 duyarlılık elde etmişlerdir.

Rajaguru ve diğ. (2017), 20 epilepsi hastasına ait EEG verisinden elde edilen 25,600 örnek sinyaline Hilbert Dönüşümü yöntemi uygulayarak özellik uzayını indirgemişlerdir. Elman Geri

Yayılımlı (EBP) ve Çok Katmanlı Öğrenme (MLP) algoritmalarına indirgenmiş özellik uzayı uygulanarak epileptik risk analizini, sırasıyla, %100 ve %97.9 sınıflandırma doğruluğu ile hesaplamışlardır.

Wang ve diğ. (2017), A, B normal (200 EEG segment), C, D interiktal (200 EEG Segment), E iktal (100 EEG Segment) epileptik nöbet verisi için kural tabanlı otomatik hastalık tespit sistemi geliştirmişlerdir. EEG segment verisine Durağan Sinyal Fourier Dönüşümü uygulayarak özellik çıkarımı hesaplamışlardır. Elde edilen özellikler ile C4.5, Rastgele Orman, SVM + C4.5 ve SVM + Rastgele Orman algoritmaları için ayrı ayrı kural çıkarmışlardır. SVM + Rastgele Orman algoritması ile çıkarılan kurallar %98.96 ikili segment, %96 üçlü segment, %82.6 beşli segment için sınıflandırma doğruluğu elde etmişlerdir.

Garg ve Jain (2017), EEG sinyal kanallarının seçilmesi ve bu kanalların sıkıştırılması ile ilgili yöntemler kullanmışlardır. Bu yöntemler, Temel Bileşenler Analizi (TBA), Lineer Ayrım Analizi (LAA), Bağımsız Bileşenler Analizi (BAA) ve Ayrık Kosinüs Dönüşümü (AKD)'dür. Oluşturulan sistemde veri setinin boyutunda azaltma ve sıkıştırma sağlanıp ileri beslemeli sinir ağı kullanılarak %92 sınıflandırma başarısı elde edilmiş olur.

Del Gaizo ve diğ. (2017)'nin çalışmasına göre, temporal lob epilepsisi (TLE) tanısı konulan hastalarda ekstra hasar olması yaygındır. Bununla birlikte, anormalliklerin difüzyon MRG görüntülemesi kullanılarak sınıflandırmayı sağlayacak kadar tutarlılığı belirsizdir. Bu nedenle, TLE'yi öngörmek için üç farklı görüntüleme yöntemi olan ortalama basıklık (MK), ortalama yaygınlık (MD) ve fraksiyonel anizotropi (FA)'yi uygulamışlardır. Hesaplanan özellikler Destek vektör makinesi (SVM) tabanlı sınıflandırılma yapılmıştır.

Li ve diğ. (2018), EEG sinyaline ait S, Z, N, F segmentlerine Zaman- Frekans Analizi ve Kalman filtresi metodlarını uygulayarak yüksek çözünürlükte spektral çıkarım yapmışlardır. Fourier dönüşümü ve Çok Ölçekli Radyal Tabanlı Fonksiyon (Multi Scale Radial Basis Function-MRBF) metodolojilerini Parçacık Sürüsü Optimizasyonu (Particle Swarm Optmization-PSO) ile birleştirerek sağlıklı ve epilepsi hastalarından zamandan bağımsız spektral çıkarımda bulunarak TBA (Temel Bileşenler Analizi -PCA) ile özellik uzayını elde etmişlerdir. SVM algoritmasına yeni özellik uzayı uygulayarak S-F & S-Z EEG segmentinin sınıflandırılmasında $\%100 \pm 00$, S-N&S-NF EEG segmentinin sınıflandırılmasında

%98.73 ± 0.43, S-Z EEG segmenti için %100, S-N EEG segmenti için %99.8, S-F EEG segmenti için %97.6, S ve N-F EEG segmenti için %98.73 doğruluk oranı elde etmişlerdir.

Göksu (2018), EEG verilerini geleneksel zaman ve frekans yöntemleri yerine dalgacık paket analizi (WPA) kullanır. WPA, keyfi zaman-frekans çözünürlüğü sağlayarak durağan ve durağan olmayan yapıdaki sinyallerin analiz edilmesini sağlar. Fourier analizine göre daha iyi zaman gösterimi ve Wavelet analizine göre ise daha yüksek frekans çözünürlüğü sağlayarak sinyaller analiz edilebilir. WPA alt görüntüleri Log Entropy, Norm Entropi ve Enerji özellik vektörleri elde etmek için ayrıca analiz edilir. Bu çalışmada çok katmanlı Ağ yapısı ile sınıflandırma yapılmış olup %100 doğruluk başarısı elde edilmiştir.

Tsiouris ve diğ. (2018), uzun süreli EEG kayıtlarında epileptik nöbetlerin saptanması için denetimsiz bir metodoloji sunulmaktadır. Yöntemin tasarımı, basit bir kural tabanlı nöbet algılama mantığı kullanılarak eğitim verilerinin eksikliğini gidermek amacıyla mevcut tıbbi bilgileri kullanır. Karmaşık karar verme sistemlerinden kaçınır. Kısa Süreli Fourier Dönüşümü başlangıçta delta (<4 Hz), teta (4-7 Hz) ve alfa (8–13 Hz) frekans bantları üzerinden EEG sinyal enerji dağılımını çıkarmak için uygulanır. Araştırmada bu frekans bölütlemelerine göre sınıflandırma yapılmıştır.

Sikdar ve diğ. (2018), EEG'nin lineer ve durağan olmayan davranışını göz önünde bulundurarak bu makalede sağlıklı- hasta çoklu fraktal davranışını ele almak için yeni bir doğrusal olmayan Çoklu Fraktal Saptanan Dalgalanma Analizi (MFDFA) yaklaşımı önermişlerdir. EEG'nin frekans alt bantlarına dalgacık tabanlı ayrışmasını takiben, spektrum genişliği, spektrum zirvesi, spektrum çarpıklığı ve Hurst'un üssü (exponent) olmak üzere dört özelliği çıkarmak için çoklu fraktal çıkarımı uygulanmıştır. Ayrıca, destek vektör makinesi ile bu fruplar farklı EEG alt bantları için çoklu fraktal özelliklerle sınıflandırmak üzere eğitilmiştir. EEG için %99.6'lık doğruluk gözlenmiştir.

Mutlu (2018)'ya göre epilepsi tekrarlayan nöbetlerle kendini gösteren nörolojik bir beyin fonksiyon bozukluğudur. EEG ile kaydedilen beyin aktiviteleri ve nöbetlerin lokalizasyonu tanımlanması için yaygın olarak kullanılır???ne kullanılır. Geleneksel Fourier tabanlı yöntemler ve manuel yorumlama kullanılarak EEG nöbetlerini tespit etmek genellikle zaman alıcı ve zordur. Bu çalışmada normal ve epileptik EEG kayıtlarını ayırt etmek için Hilbert titreşim ayrışmasına (HVD) dayalı yeni bir yöntem önerilir. Buna göre, epileptik nöbetleri

tanımak için en küçük kareler destek vektör makinesine (LS-SVM) verilen özellikler sınıflandırılmıştır. Çalışmadan %97.66 sınıflandırma doğruluğu elde edilmiştir.

Kaleem ve diğ. (2018), çok kanallı EEG verilerinin dalgacık ayrışmasını ve ayrıştırılan verilerden elde edilen el yapımı özellikleri kullanarak hastaya özgü yeni bir nöbet algılama yaklaşımı sunmaktadır. Her hastanın tüm kanallarının EEG verileri segment uzunluğuna bölünür ve bu segmentler, ayrı dalgacık dönüşümü kullanılarak δ, θ, α ve β EEG ritimlerine karşılık gelen dört frekans bandına ayrıştırılır. Bu özellikler farklı (LDA, SVM, NB, KNN) sınıflandırıcılar kullanılarak sırasıyla %99.6, % 99.8 ve % 99.6 doğruluk, duyarlılık ve özgüllük değerleri elde edilmiştir.

Gupta ve Pachori (2019), ağırlıklı çok aşamalı Renyi permütasyon entropisine (WMRPE) ve EEG sinyallerinin Fourier-Bessel serisi genişlemesi (FBSE) ile elde edilen ritimlere dayalı olarak epileptik nöbetlerin sınıflandırılması için yeni bir yöntem önermiştir. EEG sinyallerine WMRPE yöntemi uygulanarak özellikler çıkarılmış; daha sonra bu hesaplanan özellik değerleri EEG sinyallerinin epileptik nöbet sınıflandırılması için rasgele orman (RF), en küçük kareler destek vektör makinesi (LS-SVM) ve Regresyon gibi farklı sınıflandırıcılar kullanılmıştır.

Wang ve diğ. (2019)'ne göre epilepsi, zihinsel engelli (ID) kişilerde yaygın olarak ikincil bir engeldir. ID popülasyonunda EEG tabanlı otomatik nöbet tespiti henüz yeterince çalışılmamıştır. Sebepleri iki yönlüdür. İlk olarak, uzun vadeli EEG kayıtları davranış problemleri nedeniyle azdır. İkincisi, beyin gelişimi bozukluklarının neden olduğu karmaşık EEG sinyal anormallikleri nedeniyle EEG kayıtlarının not edilmesinin zor olduğu kanıtlanmıştır. Kişiye özel eşik değeri ve çok düzeyli analiz özellikleri çıkarılmış; sınıflandırıcı olarak LDA ve SVM kullanılmıştır.

Zhang ve diğ. (2019)'nin araştırmasına göre, Dalgacık tabanlı özellik çıkarma teknikleri epileptik EEG sınıflandırılması için çok elverişlidir. Ancak optimal dalgacık tabanının belirlenmesi zorlayıcıdır. EEG'yi ilk kez karakterize etmek için maksimum örtüşme ayrık dalgacık paketi dönüşümü (MODWPT) tanıtılıp, çalışmada çok-temelli MODWPT tabanlı özellik çıkarımı önerilmiştir. Boyut küçültmede Temel Bileşen Analizi (PCA), Bağımsız Bileşen Analizi (ICA), Çekirdek Temel Bileşen Analizi (KPCA) gibi algoritmalar; karşılaştırma olarak çoklu çekirdek öğrenme destek vektör makinesi (MKLSVM) kullanılmıştır.

Diykh ve diğ. (2019)'ne göre, odaklı ve yayılabilen EEG sinyallerinin tanınması, insan beynindeki etkilenen bölgenin lokalize edilmesi ve tıbbi tedavisine yardımcı olabilmesi için kullanılan klinik tanı için çok önemlidir. Bu çalışmada, Sinüs Kosinüs Destekli bir destek vektör makinesine (SCA-SVM kullanan FD-NG modeli) dayalı fraktal boyutun (FD) ilişkili grafiklerin (NG) adı verilen yeni bir model geliştirdiler. Buna göre her EEG sinyali kendi bölümlerine ayrılıp her bölüm bir kayar pencere tekniği kullanılarak kümelere ayrılır. Her kümenin boyutunu azaltmak için bir dizi en iyi özellik çıkarılır. Üç tür özellik dikkate alınır: doğrusal özellikler (LF), istatistiksel özellikler (SF) ve zaman alanına (TD) dayalı özellikler. EEG sinyalini odaklı ve yayılabilen bileşenlerine sınıflandırmak için SCA-SVM modeline giriş olarak kullanılmıştır.

Cheema ve Singh (2019)'in çalışmasında, psikolojik stres günümüz yaşam tarzının bir parçasıdır ve insanın bilişsel yeteneklerini etkiler. Stres ile bir dizi davranışsal ve patolojik durum arasındaki iyi kurulmuş ilişki, psikolojik stresin zamanında tespit edilmesi ihtiyacını vurgulamaktadır. EEG sinyallerine Ampirik Mod Ayrıştırma (EMD) tekniği kullanılarak içsel mod fonksiyonlarına (IMF) ayrıştırılır. Bu fonksiyonlara Kök Ortalama Kare değeri (RmsIMF), Shannon Entropisi (ShEnt) ve Bulanık Entropi (FzEnt) uygulanarak sinyal özellikleri çıkarılmış; daha sonra istatistiksel olarak önemli olan özellikler seçilip bunlar en küçük kare destek vektör makinesi (LS-SVM) sınıflandırıcısına verilmiştir.

Subasi ve diğ. (2019)'ne göre migren, ışığa duyarlılık ile vurgulanan sürekli ataklarla karakterize nörolojik bir hastalıktır. Migreni daha büyük bir sorun hâline getiren başlıca nedenlerden biri, epilepsi gibi diğer hastalıklarla çok sayıda örtüşen semptomlar nedeniyle doktorlar tarafından bunun kolaylıkla teşhis edilememesidir. Çoğu laboratuvar çalışmasında, farklı frekanslara ve zaman aralıklarına sahip EEG sinyallerinin kaydedilmesi sırasında flaş uyarımı kullanılır. Bu çalışmanın amacı, flaş uyarımının sınıflandırma doğruluğu üzerindeki etkilerinin ve EEG sinyal sınıflandırması için etkili pencere uzunluğunun nasıl bulunacağının araştırılmasıdır. Bunu için, ayrı dalgacık dönüşümü kullanılarak çıkarılan EEG sinyalleri özellikleri üzerinde farklı makine öğrenme algoritmaları (SVM, KNN, ANN, RF, DT) test edilmiştir.

Yao ve diğ. (2019)'nın çalışmalarındaki amacı, yeni tanı konmuş epilepsi hastalarının antiepileptik ilaç (AED) tedavi sonuçlarını doğru bir şekilde tahmin edebilen, denetimli bir makine öğrenimine dayalı sınıflandırıcı oluşturmaktır. Hastaları ayırt etmek için demografik

özellikler, tıbbi öykü ve yardımcı muayeneler (EEG ve MRG) gibi bir dizi özellik seçilmiştir. Beş klasik makine öğrenme algoritması, yani Karar Ağacı, Rastgele Orman, Destek Vektör Makinesi, XGBoost ve Lojistik Regresyon, sınıflandırma modellerine veri seti seçilip eğitilmesi sağlanmıştır.

Chen ve diğ. (2019), makine öğrenmesine dayalı beyin yaşı tahmini, klinik değerlerini keşfetmek için çeşitli nörolojik hastalıklara uygulanmıştır. Bu yenilikçi yaklaşımla, epilepsili hastaların erken beyin yaşlanması olduğu bildirilmiştir. Difüzyon MRI veri kümeleri aynı 3 Tesla MRG tarayıcısından elde edilmiş; beyin yaşı tahmin modelini oluşturulması amacıyla 300 sağlıklı katılımcının difüzyon MRG veri setleri, beyaz madde yaşa bağlı difüzyon indekslerini çıkarmak için işlenmiştir. Çıkarılan difüzyon indeksleri, beyaz madde beyin yaşı için tahmin modelini oluşturmak üzere Gauss süreç gerilemesine uğramıştır.

3. MALZEME VE YÖNTEM

3.1. ÖZELLİK ÇIKARIMI

Örüntü tanımada örüntünün boyutunu azaltmak için özellik çıkarım yöntemlerine ihtiyaç duyulur. Bu yöntemler özellik çıkarımı ve seçimi yapan matematiksel fonksiyonlardır. Örüntüde bir sınıfı ayırt edecek önemli özellikler olmalı ve orijinal özellik çok fazla değişime uğramamalıdır. Literatürde en çok bilinen özellik çıkarım yöntemleri dört gruba ayrılır (Ciaccio ve diğ., 1993).

Bunlar:

3.1.1. Dönüştürülmeyen Yapısal Özellikler: Momentler, güç, genlik bilgi, enerji vb.

3.1.2. Dönüştürülmüş Yapısal Özellikler: Frekans ve genlik spektrumlar, alt uzay dönüşüm yöntemleri vb.

3.1.3. Yapısal Tanımlar: Biçimsel diller ve gramerleri, ayrıştırma teknikleri vb.

3.1.4. Diyagram Tanımlayıcı: İlişkisel diyagramlar ve semantik ağlar vb.

Örüntü tanıma problemlerinde sınıflandırma yapılırken boyutlandırma en sık karşılaşılan problemlerden biridir (Duda and Hart, 2001). Düşük boyutlu veriler için kullanılan yöntemler büyük boyutlu veriler için aynı performansı göstermeyebilir. Özellik uzayındaki boyut indirgeme tekniklerinin geliştirilmesiyle problemleri daha fazla yönetme becerisi sağlanmış olur. Medikal görüntü analizlerinde özellik çıkarımıyla ilgili sorunlar yaşanması nedeniyle bir görüntü veya görüntü bölgesini olası sınıflardan birine dahil etmek için görüntü bölgelerinin özelliklerinin çıkarılması gerekmektedir. Örneğin, görüntü fonksiyonu I (x, y) olsun, her görüntü matrisi I (m, n) piksel değerini içerir. Görüntünün daha iyi algılanabilmesi için yüksek çözünürlüğe ihtiyaç vardır (Meyer-Bäse, 2004). Mesela, medikal resimlerin küçük boyuttaki 128x128'lik bir matrisi dahi olsa, bu değer 16,384 piksele karşılık gelir. Bu ise büyük boyutlu bir bilgi anlamına gelir. Bu nedenle uygun bir özellik çıkarım yöntemi kullanılarak daha düşük boyutlu bir veri elde edilmesi gereklidir.

Bu amaçla çalışmamızda yukarıda sınıflandırıldığı şekliyle "Dönüştürülmüş Yapısal Özellikler: Frekans" alt başlığında değerlendirilen ve görüntü sıkıştırma işlemlerinde önemli bir role sahip olan Ayrık Kosinüs Dönüşümü (AKD) kullanılmıştır. Ayrık Kosinüs Dönüşümü (AKD) bir boyutlu (1D) ve iki boyutlu (2D) durumlar için aşağıda şu şekillerde formüle edilmiştir:

N girişli örnek için bir boyutlu (1D) AKD:

$$y(k) = \alpha(k) \sum_{n=0}^{N-1} x(n) \cos\left[\frac{\pi(2n+1)k}{2N}\right],\ k = 0,1,\dots,N-1 \tag{3.1}$$

Ters dönüşümü:

$$x(n) = \sum_{k=0}^{N-1} \alpha(k) y(n) \cos\left[\frac{\pi(2n+1)k}{2N}\right],\ n = 0,1,\dots,N-1 \tag{3.2}$$

$$\alpha(0) = \sqrt{\frac{1}{N}},\ k = 0\ ve\ \alpha(k) = \sqrt{\frac{2}{N}},\ 1 \le k \le N-1 \tag{3.3}$$

AKD'nin vektör formu:

$$y = C^T x \tag{3.4}$$

$$C(n,k) = \sqrt{\frac{1}{N}},\ k = 0,\ 0 \le n \le N-1 \tag{3.5}$$

$$C(n,k) = \sqrt{\frac{2}{N}}, \cos\left[\frac{\pi(2n+1)k}{2N}\right],\ 1 \le k \le N-1,\ 0 \le n \le N-1$$

C ortogonal matrisi temsil etmektedir:

$$C^{-1} = C^T$$

İki boyutlu (2D) AKD formülü:

$$Y = C^T X C, \quad X = C Y C^T \tag{3.6}$$

Çalışmamızda "Dönüştürülmüş Yapısal Özellikler: Frekans" alt başlığında değerlendirilen AKD'nin yanı sıra Ayrık Dalgacık Dönüşümü (ADD) de incelenmiştir. Yapılan işlemin ve elde edilen katsayı miktarının ADD'de azaldığı görülür. Bu yöntemin asıl amacı sayısal süzgeç tekniklerini kullanarak ayrık sinyallerin zaman-ölçek gösterimini elde etmektir. ADD değişik

frekans bantlarında ve çözünürlükte analiz yapabilmektedir. Düşük frekanstaki bileşenlerin analizi için sinyal alçak geçiren filtrelerden, yüksek frekans bileşenlerinin analizi için ise yüksek geçiren filtrelerden geçirilmektedir. Böylelikle sinyal, yaklaşıklık ve ayrıntı bileşenlerine ayrılabilmektedir. Yaklaşıklık, büyük ölçekli-düşük frekanslı sinyal bileşenlerine; ayrıntı ise, küçük ölçekli-yüksek frekanslı bileşenlere karşılık gelmektedir (Misiti ve diğ. 2000). Ayrık Dalgacık Dönüşümü $W(j,k) = 2^{-j/2} \int_{-\infty}^{+\infty} X(t)\Psi\left(2^{-j}t - k\right)dt$ gösterilmiştir. Çalışmamızda, Matlab da Ayrık Dalgacık dönüşümü için kullanılan dalgacık modeli 'db4' dalgacık modu 'sym4' 'dür.

3.2. ÖZELLİK SEÇİMİ

Çalışmamızda, özellik vektörlerinin sınıflandırılması esnasında bunların doğruluk derecesini artırmak için aşağıda detaylandırılacak olan Temel Bileşen Analizi (TBA), Doğrusal Ayrım Analizi (DAA), İleriye Doğru Seçim (Forward Selection), Geriye Doğru Seçim (Backward Selection) yöntemleri olarak adlandırılan belirli özellik seçimi algoritmaları kullanılmıştır.

3.2.1. Temel Bileşen Analizi

TBA, bir veri kümesindeki boyut sayısını azaltmak için kullanılabilecek doğrusal dönüşüm tekniklerine verilen bir addır. Bu özellik seçimiyle bir veri kümesindeki maksimum varyansın ortogonal bileşen ekseni bulunmaya çalışılmaktadır (Chatterjee, 1998).

Aşağıda gösterilen Denklem 3.7'de M, t boyutlu bir özellik kümesi durumunda, n adet temel eksen G_1, G_2, ..., G_n, ve burada $1 \leq n \leq t$'dir. Bu eksenler aynı zamanda ortonormal eksenler olarak da adlandırılmaktadır. Burada $x_k \in M$, m ise bu örneklerin ortalaması ve R örnek sayısı olmak üzere kovaryans matris Z aşağıdaki gibi hesaplanmaktadır:

$$Z = \left(\frac{1}{R}\right) \sum_{k=1}^{R} (x_k - m)^T (x_k - m), \tag{3.7}$$

$$ZG_k = z_k G_k, k \in 1, \dots, n, \tag{3.8}$$

Denklem 3.8'de z_k, Z'nin; k. en büyük eigen değeridir. Buna göre $x_k \in M$'nin n adet temel bileşenleri aşağıdaki gibi verilmiştir:

$$p = [p_1, p_2, \dots, p_n] = [G_1^T x, G_2^T x, \dots, G_n^T] = G^T x \tag{3.9}$$

Denklem 3.9'da ise p, x giriş özellik vektörünün n adet temel bileşen vektörü durumundadır (Karatabak ve diğ., 2008).

3.2.2. Doğrusal Ayrım Analizi (DAA)

DAA, sayısallaştırılmamış modellerde boyutu azaltmak, hesaplama verimliliğini artırmak ve overfitting'i azaltmak için kullanılmaktadır. Bu özellikle elde edilecek alt uzay, sınıf ayrılabilirliğini en iyi duruma getirmektedir.

Özellik seçimi için Doğrusal Ayrım Analizi formülünde uyarlama yapıldığı durumda kullanılan veri setinin de C adet sınıf ve n adet eğitim örneği olduğunu varsayalım. Bu durumda DAA' nın yayılım matrisleri Denklem (3.10) ve Denklem (3.11) kullanılarak hesaplanır.

$$U_b = \sum_{i=1}^{C} \left(a_i^j - a_i\right)\left(a_i^j - a_i\right)^T. \tag{3.10}$$

$$U_t = \sum_{i=1}^{C} \sum_{j=1}^{n} \left(a_i^j - \bar{a}\right)\left(a_i^j - \bar{a}\right)^T. \tag{3.11}$$

$a_j^i, i.$ sınıfının $j.$ eğitim örneğini belirtirken, a_i $i.$ sınıfının ortalamasını ifade eder ve $\bar{a}$ tüm eğitim örneklerinin ortalamasını temsil eder. DAA 'nın öz-denklemi aşağıdaki gibidir:

$$U_b\, x = \lambda U_t\, x, \tag{3.12}$$

Denklem (3.12)' ün tüm özdeğerleri $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_N$ ise ve karşılık gelen özvektörler $X_1, \ldots, X_N$ ise DAA genellikle verinin $d - boyutlu$ bir vektöre dönüştürmek için ilk d en büyük özdeğerlere karşılık gelen özvektörleri kullanır. N, örnek vektörün boyutluluğunu temsil eder. Özellik seçimi için kullanılan $X = [x_1, \ldots, x_N]^T$ ve $a = [a_1, \ldots, a_N]^T$ DAA'nın kovaryans matrisinin özvektörünü gösterir. x ile a nın sonucu:

$$z = a^T x = \sum_{i=1}^{N} a_i\, x_i \tag{3.13}$$

Eğitim verileri kullanarak DAA'nın sınıf içi ve toplam dağılım matrisleri hesaplanır. Daha sonra, Denklem (3.12)'deki tüm özvektörleri ve özdeğerleri çözülür.

İlk m en büyük özdeğerlere karşılık gelen özvektörler seçilir ve bu özvektörleri sırasıyla $V_1, \ldots, V_m$ ile gösteririz. $j.$ bileşenin katkısı şu şekildedir:

$$c_j = \sum_{p=1}^{m} \left|V_{pj}\right|, \tag{3.14}$$

V_{pj}, V_p vektörünün $j.$ elemanını belirtir, $j = 1,2, \dots, N,\ \ p = 1,2, \dots, m.\ \ |V_{pj}|\ V_{pj}$'nin mutlak değerini belirtir. Boyut ve zamana göre azalan sırada dizilim yapılarak özellik seçimi yapılır (Song ve diğ., 2010).

3.2.3. İleriye Doğru Seçim (Forward Selection)

Bu yöntem genellikle büyük bir değişken grubu olduğunda aday değişkenlerin ilk taramasını sağlamak için kullanılır. En iyi değişkeni elde etmek için bu ileri seçim prosedürünü kullanıp ardından mümkün olan tüm algoritmayı bu alt kümedeki değişkenlere uygulamak gereklidir.

Veri seti C, seçilmiş özellik seti S ve seçilmeyen özellik seti I gözönüne alındığında İleri Doğru Seçim (Forward Selection) algoritması Chan ve diğ. (2010)'nin öne sürdüğü gibi aşağıdaki şekilde verilebilir:

1. C özelliklerinin tamamı için $S = \emptyset$ yapılır.
2. $z_i \in C$ özelliklerinin her biri için, $\{z_i\} \cup S$ özelliğine sahip veri kümesi kullanılarak sınıflandırıcı eğitilir ve bu sınıflandırıcı için R (en küçük karesel hata) değeri hesaplanır.
3. $z = arg_{z_i \in C} \min R\,, z$ seçilmiş olanların listesi S'ye eklenip genel veri seti C' den çıkarılır.
4. $C \neq \emptyset$ ise ikinci adıma gidilir; aksi halde özellik seçim işlemi sonlandırılır.

3.2.4. Geriye Doğru Seçim (Backward Selection)

Geriye doğru seçim modeli, modeldeki tüm aday değişkenlerle başlar. Her adımda, en az anlamlı olan değişken kaldırılır. Bu işlem, anlamlı olmayan değişkenler kalmayana kadar devam eder. Veri seti C, seçilmiş özellik seti S ve seçilmeyen özellik seti I gözönüne alındığında Geriye Doğru Seçim (Backward Selection) algoritması Chan ve diğ. (2010)'nin öne sürdüğü gibi aşağıdaki şekilde verilebilir:

1. S özelliklerinin tamamı için $I = \emptyset$ yapılır.
2. S özelliğine sahip veri seti kullanılarak sınıflandırıcı eğitilir ve bu sınıflandırıcı için R (en küçük karesel hata) değeri hesaplanır.
3. $z_i \in S$ özelliklerinin her biri için $S - \{z_i\}$ özelliğine sahip veri kümesi kullanılarak sınıflandırıcı eğitilir ve bu sınıflandırıcı için $R(\{z_i\})$ (en küçük karesel hata) değeri hesaplanır.

4. $z = arg_{z_i \in S} \min \text{abs}\left(R - (\{z_i\})\right)$, z seçilmiş olanların listesi I'ye eklenir ve genel veri seti S'den çıkarılır.
5. $S \neq \emptyset$ ise ikinci adıma gidilir; aksi halde özellik seçim işlemi sonlandırılır.

3.3. SINIFLANDIRMA

Teknolojideki değişimle her geçen gün veri miktarının artmasına paralel olarak bu verilerin analizinin klasik istatistiksel yöntemler kullanılarak yapılaması mümkün değildir (Langley ve Simon, 1995). Bu nedenle, büyük verilerin işlenmesi için makine öğrenmesine ihtiyaç duyulur (Duffy, 1997).

Makine öğrenmesi, karar mekanizmaları için programların nasıl yapıldığını öğreten akıllı sistemlerdir. Bu sistemler bilgisayar bilimlerinin dışında birçok alanda dikkat çekmiş ve birçok alanda makine öğrenmesi yöntemleri kullanılmıştır. Bu alanlara hastalık teşhisi, otomotiv, pazarlama, eğlence, ilaç tasarımı, spam filtreleri, kredi puanlama vb. örnek gösterilebilir.

Makine öğrenmesi, insan müdahalesi olmadan çözümler için veri alıp bu veriyi doğru sistemlere tabi tutarak bir tahmin oluşturmaktır. Problemlere çözüm üretmek için sınıflandırma, regresyon, kümeleme ve ilişkilendirme makine öğrenme yöntemleri kullanılır.

Bu çalışmada makine öğrenmesi yöntem sınıflandırma olarak ele alınmıştır. Sisteme gelen EEG ve MRG verilerini seçerek bir karara bağlama sürecinde epilepsi hastası veya sağlıklı veri olduğunun kararını verir.

Makine öğrenme yöntemi, öğreticili (supervised) ve öğreticisiz (unsupervised) olarak ikiye ayrılır. Çalışmada öğreticili yöntem kullanılarak eğitim (train) verilerinin hedef (target) verileri arasında bir ilişkilendirmede bulunup bir sonuç (output) üretmesi sağlanmış olur.

3.3.1. Öğreticili Öğrenme

Öğreticili öğrenme, makine öğrenme yöntemlerinde en çok çalışılan konulardandır. Sistem, eğitim ve test setinden oluşan bir model olarak düzenlenir. Eğitim veri seti oluşturmak için veri setine ait örneklerin özellik vektörleri çıkarılır ve bu özelliklere sınıf bilgisi niteliği de eklenerek hangi sınıfa ait olduğu bilinen bir model oluşturulmuş olur. Bu veri setinde yer almayan örnekler test verisi olarak sisteme verilerek modelin başarısı ölçülmüş olur.

3.3.1.1. Öğreticili Öğrenme Yaklaşımları

Öğreticili öğrenmede birçok yöntem kullanılır (Kotsiantis ve diğ., 2006). Bu yöntemler Karar Ağaçları, Örnek Tabanlı Öğrenme, Öğrenme Regresyonları, Doğrusal Modeller, Çekirdek Yöntemler, Bayes Sınıflandırıcılar ve Yapay Sinir Ağları gibi farklı yaklaşımlara kategorize edilebilir.

Yapay sinir ağları (Ripley, 2007) biyolojik sinir ağlarının fonksiyonel yönlerinin yapısını simule etmeyi denemeye çalışan bir modeldir (Haykin, 2009). Bu ağ yapısında nöronlar ve birbirine bağlı işlemleri aktaran bir grup yapılardan oluşur. Bu yapı bazen tek katmanlı bazen de çok katmanlı olup iletişimler bu katmanlardan geçirilip her katmanda işlem yapılarak sonuç kısmına ulaşılması sağlanır.

En basit yapıda girişlere ait ağırlıklar sonuç kısmına aktarılır. Çok katmanda ise giriş verisi ağırlık değeriyle çarpılarak katmanlar arasındaki işlemleri yaparak bir diğer katmana geçer. Birimlerin arasındaki bağlantı bu ağırlık değeri ile sağlanmış olur.

Tek katmanlı işlem birimine sahip en basit ağ yapısına (Rosenblatt, 1962) algılayıcı (perceptron) denir. Bu algılayıcılar iki sınıfı doğrusal olarak birbirinden ayırabilirler, bunun dışındaki problemlere çözüm üretemezler. Tek katmanlı algılayıcılar doğrusal olarak ayrılmayan problemlerde çözümsüz kalırlar.

Bu sorunu çözmek için Çok Katmanlı Algılayıcılara (MLP) ihtiyaç duyulmuştur (Williams ve Hinton, 1986). MLP'ler doğrusal olmayan fonksiyonlara sahip giriş ve çıkış ağlarının modellenmesi için kullanılır.

Bir ağdaki problemleri çözmek için birçok eğitim yöntemi vardır. Ağırlıkların değerlerini tahmin etmek için yaygın olarak kullanılan öğrenme algoritması (Williams ve Hinton, 1986) geri yayılım algoritmasıdır (back propagation algorithm), eğitimde giriş çıkış parametrelerinin ayarlanmasında gradyan mesafesi (gradient descent) hesaplanır. Yapay sinir ağlarının genellikle diğer yöntemlere göre sınıflandırma doğruluk başarısı daha yüksektir.

3.3.1.2. Doğrulama Tahmini

Sınıflandırma yöntemlerinin performansının ne kadar iyi olduğunu bilmek için bunların değerlendirilmesi gerekir. Sınıflandırma yöntemlerinde algoritma performansları birçok kritere göre test edilir.

Doğrulama tekniği doğru sınıfları tahmin etmek için basit bir işlemdir. Doğru sınıf ve yanlış sınıf kendi benzerlerinin kümesinde toplanır. Öğreticili öğrenmede performans değerlendirilirken hata oranı da bu değerlendirmeyi etkileyen parametrelerdendir.

$$Doğruluk\ (accuracy) = \frac{TP+TN}{TP+TN+FN+FP} \tag{3.15}$$

Ayrıca algoritma performansı değerlendirilirken duyarlılık, kesinlik ve F-skor kullanılır. (Fawcett, 2006).

Duyarlılık, pozitif durumların ne kadar başarılı tahmin edildiğini gösterir:

$$Duyarlılık\ (recall) = \frac{TP}{TP+FN} \tag{3.16}$$

Kesinlik, pozitif olarak tahmin edilen bir durumdaki başarıyı gösterir.

$$Kesinlik\ (precision) = \frac{TP}{TP+FP} \tag{3.17}$$

F-skor, duyarlılık ve kesinlik metriklerinin harmonik ortalamasıdır.

$$F-skor = 2 * \frac{Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık} \tag{3.18}$$

Algoritmada elde edilen maksimum doğruluk değerleridir. K-fold çapraz doğrulama (k- fold cross validation) gibi birçok değerlendirme yöntemi kullanılmıştır (Stone, 1974).

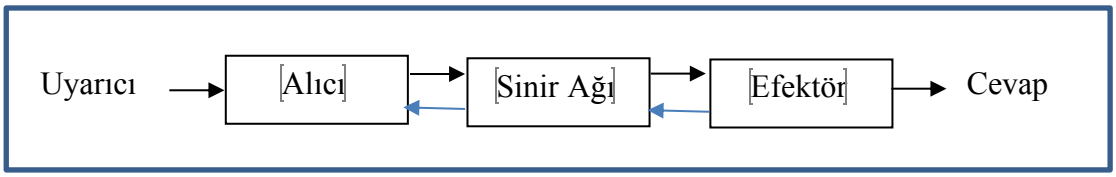
Doğruluğu hesaplamak için kullanılan diğer bir yaygın tekniğe bırakılma yöntemi (leave-one-out) adı verilir (Mosteller ve Tukey, 1968).

3.3.1.3. Yapay Sinir Ağları (YSA)

Bu başlık altında YSA mimarisinin arka planı ve burada ne tür işlemlerin olduğu incelenerek YSA mimarisinin temel yapısı ve detaylı parametreleri açıklanacaktır.

Beynin Biyolojik Yapısı

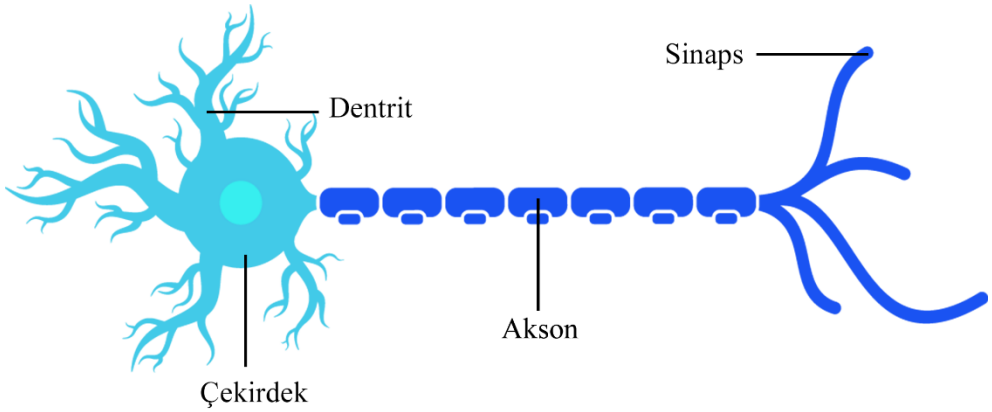
YSA, insan beyninin nörolojik yapısından ilham alınarak modellenmiştir. YSA, biyolojik ağların çalışma yapısını simule etmeye çalışır (Ripley, 2007). İnsan beyninde bulunan hücrelere nöron adı verilir. Bilgi ve sinyaller nöronlar arasında akson bağlantıları sayesinde aktarılır.



Şekil 3.1: Sinir sistemi blok diyagramı.

İnsan beyin yapısı 10 milyon nöron ve 60 trilyon sinaps bağlantısı içerir (Shepherd ve Koch, 1990). Biyolojik beynin işlem gücü çok yüksektir; bu nedenle beynin arızalara karşı hata toleransı çok düşüktür (Carnevale ve Rosenthal, 1992). Beyin enerji kullanımı saniyede işlem başına yaklaşık 10^{-16} jul (J) olduğu düşünülürse, beyin hızı en güçlü bilgisayarın herhangi bir işlemi yerine getirme hızından fazladır. Sinapslar veya sinir uçları, nöronlar arasındaki etkileşimlere aracılık eden temel yapısal ve fonksiyonel birimlerdir. En yaygın tipteki sinaps, Şekil 3.1'de gösterildiği gibi çalışan kimyasal bir sinapstır. Presinaptik bir süreç, sinaptik birleşme boyunca nöronlar arasında yayılan bir verici maddeyi serbest bırakır. Böylece sinaps, presinaptik bir elektrik sinyalini kimyasal bir sinyale ve sonra tekrar bir postsinaptik elektrik sinyaline dönüştürür (Shepherd ve Koch, 1990). Sinapsların alıcı nöronların yanı sıra uyarma ve engelleme sağlayacak bağlantılarının da olduğu varsayılmaktadır.

Daha önceleri (Eggermont, 1990) sinir sisteminin çevreye uyum sağlama özelliğinden bahsedilmiştir (Churchland ve Sejnowski, 1992). Yetişkin beyinlerinde iki türlü mekanizma yer alır: nöronlar arasında yeni sinaps bağlantıları ve mevcut sinapsların modifikasyon sağlanması.



Şekil 3.2: Sinir hücresi yapısı.

Aksonlar, aktarma hatları ve dendritler alıcı bölgeler olarak birbirinden morfolojik yapı olarak ayırt edilir. Akson daha az dallanmaya ve daha uzun bir yapıya sahiptir. Dendrit ise ağaç yapısı gibi daha fazla dallanmaya sahiptir (Freeman, 1975).

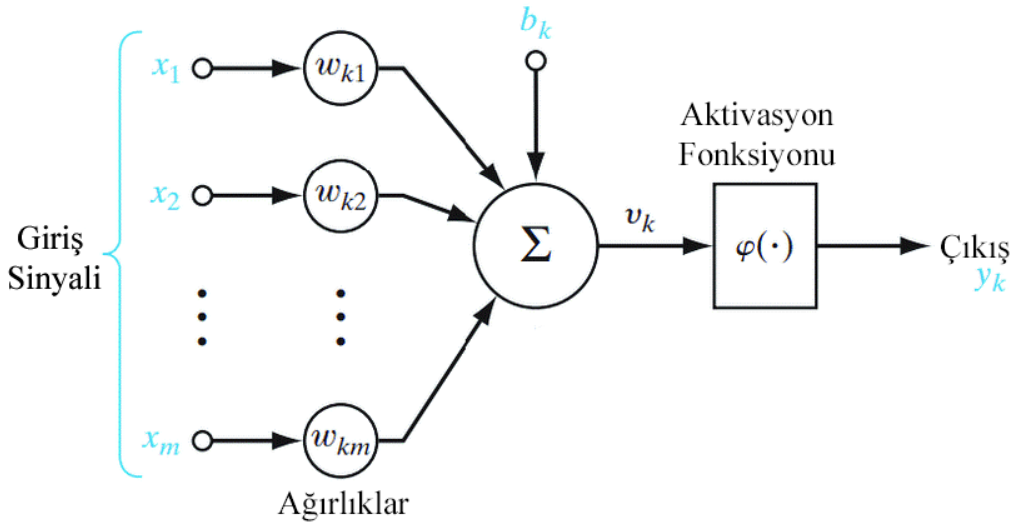
Büyük veri kümelerini YSA'da modellemek kolaydır. YSA kuralları belirsiz ve doğrusal olmayan problemlerle başa çıkmakta çok başarılıdır. Eğitim kısmı kolay fakat ön işlem kısmı önemlidir.

Nöron Modeli

Nöronlar sinir ağının temel işlem birimidir. Nöron modelinin genel yapısının üç temel özelliği incelenmiştir:

i. Giriş Katmanı
ii. Gizli Katman
iii. Çıkış Katmanı

Sinir ağının durumuna göre gizli katman sayısı artabilir.



Şekil 3.3: Nöron modeli (Haykin,2009).

Beyindeki nöronlar bilgileri karmaşık bağlantı kullanıp birbirlerine göndererek iletişim sağlarlar. YSA da aynı yapıyı simüle ederek ağırlık bağlantıları kullanır. Ağırlıklar negatif veya pozitif olabilir. Şekil 3.3'te sinyal girişleri $(x_1, x_2, \ldots, x_m)$ gizli katmana bağlı nöron k ağırlığıdır $(w_{k1}, w_{k2}, \ldots, w_{km})$. Her nöron giriş ve ağırlık katsayılarının çarpılan toplamı alınır

ve eşik değeri b_k ile karşılaştırılır. Bu kısım, ilk çıktı v_k dır. v_k bir aktivasyon fonksiyonuna $\varphi(.)$ aktarılır. Çıkış y_k doğrusal bir değer değildir. Ağ yapısında, geri yayılım algoritmasıyla beraber en sık kullanılan aktivasyon fonksiyonu sigmoiddir.

$$u_k = \sum_{j=1}^{m} W_{kj} X_j \tag{3.19}$$

$$y_k = \varphi(u_k + b_k) \tag{3.20}$$

Eşik değeri yeni sinyal girişi olarak giriş verileri yeniden düzenlenerek eklenebilir. Yeni sinaps ağırlığı $w_{k0} = b_k$ olarak verilebilir (Haykin, 2009).

Geri yayılım algoritmasının amacı, çıkış ile hedef arasındaki hatayı minimum hâle getirmektir. Hata, ağa geri gönderilip hataların büyüklük durumuna göre ağırlıklar tekrar düzenlenir. Bu işlemler belirtilen değerin altına düşüne kadar devam eder.

YSA mimarisini oluşturmak için öncelikle sisteme eğitim seti hazırlanmalıdır. Verilerin doğrulaması yapıldıktan sonra sınıflandırma başarısı test işlemiyle sağlanır.

YSA'ya veri girildiğinde istenen çıktıyı etkileyen optimum ağırlıkları seçmek ve daha sonra doğrulama yapmak ağın başarısını artıracaktır. YSA'nın sınıflandırma başarısını etkileyen faktörler; nöron, gizli katman sayısı ve aktivasyon fonksiyonudur.

YSA sınıflandırmasında meydana gelebilecek problem ise ağın, hatayı minimuma indirmek için fazla eğitilmesi durumunda sistem ezberlenmesinin ortaya çıkmasıdır. Bu da doğrulama ve test sonuçlarının sistem tarafından doğru tahminde bulunulmamasına yol açar. Ağın fazla eğitilmemesi de başka bir sorun çıkarabilir. Sistem yerel minimuma takılıp yine iyi tahminde bulunmayacaktır.

Aktivasyon Fonksiyonu

Doğru sonucu belirlemek için giriş verileri ile ağırlık katsayılarının çarpımının toplamı YSA'nın transfer fonksiyonuna bağlanır. Bu fonksiyonda gizli katmandaki doğrusal olmayan karakteristiklerde etki göstererek çıktıya karar vermeyi sağlar. Temel düzeydeki iki tip aktivasyon fonksiyonu vardır:

a. Treshold Fonksiyonu:

$$\varphi(u) = \begin{cases} 1 \; eğer \; u \geq 0 \\ 0 \; eğer \; u < 0 \end{cases} \tag{3.21}$$

Bu aktivasyon fonksiyonunun, nöron sayısı k'ya göre çıktısı bu şekilde ifade edilir:

$$y_k = \begin{cases} 1 \; eğer \; u_k \geq 0 \\ 0 \; eğer \; u_k < 0 \end{cases} \tag{3.22}$$

$$u_k = \sum_{j=1}^{m} W_{kj} x_j + b_k \tag{3.23}$$

Sinirsel hesaplamada böyle bir nöron modeli McCulloch ve Pitts (1943) modeli olarak adlandırılır. Sinir ağı, nöron çıktısına göre 1 veya 0 değerini alır.

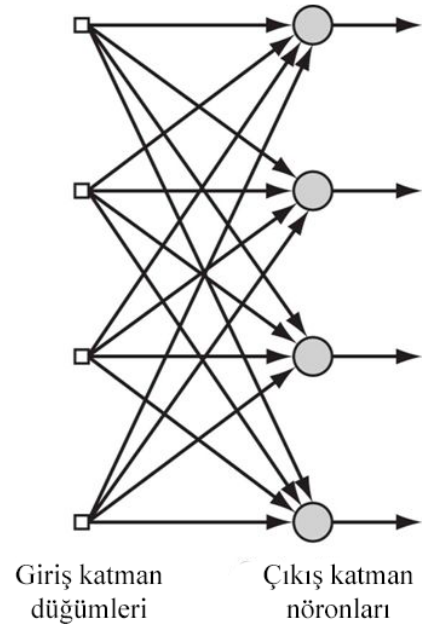
b. Sigmoid Fonksiyonu: Sinir ağları mimarisinde en yaygın kullanılan aktivasyon fonksiyondur. Bu fonksiyon, doğrusal ve doğrusal olmayan sistemler arasında denge sergileyen ve kesinlikle artan bir işlev olarak tanımlanır. Lojistik fonksiyon sigmoid fonksiyonuna örnektir.

$$\varphi(u) = \frac{1}{1+\exp(-au)} \tag{3.24}$$

Sinir Ağı Mimarisi

Mimaride her katman bir diğerine nöronlarla bağlanır. Her nöron bir sonraki katmanın bütün nöronlarına bu nöronu temsil eden ağırlık katsayıları ile bağlanır. Nöronlar giriş sinyalinden bilgiyi alır ve çıkış üretmek için işler. Nöronların giriş, işleme ve bağlantıları arasındaki değişiklikler mimarilerindeki farklılıkları meydana getirir.

a. Tek Katmanlı Ağlar: Perceptron modeli biyolojik nöronun matematiksel ifadesidir. Biyolojik olarak nöronlar komşu nöronlardan gelen sinyalleri dendrit yoluyla alırlar. Perceptron komşu nöronlardan gelen sinyalleri algılayarak her bir nöronun ağırlık değerlerini de alıp çıkış işlemine doğru yol alır. Daha sonra eşik seviyesinden geçerek çıkış hesaplanmış olur. Mimarinin tek katmanlı en basit hâli giriş nöronları ve onlara ait ağırlık katsayılarının çıkış katmanında bir sonuç üretmesidir. Sistem ileri ve tek yönlüdür. Giriş, ara katman ve çıkış katmanından oluşan yapı tek katmanlı sinir ağıdır. Tek katmanlı mimari AND, OR ve NOT gibi ikili mantık fonksiyonlarını çözebilir. Doğrusal problemlere çözüm bulabilirken XOR gibi doğrusal olmayan problemlere çözümsüz kalınmıştır (Minsky ve Paperi, 1969).

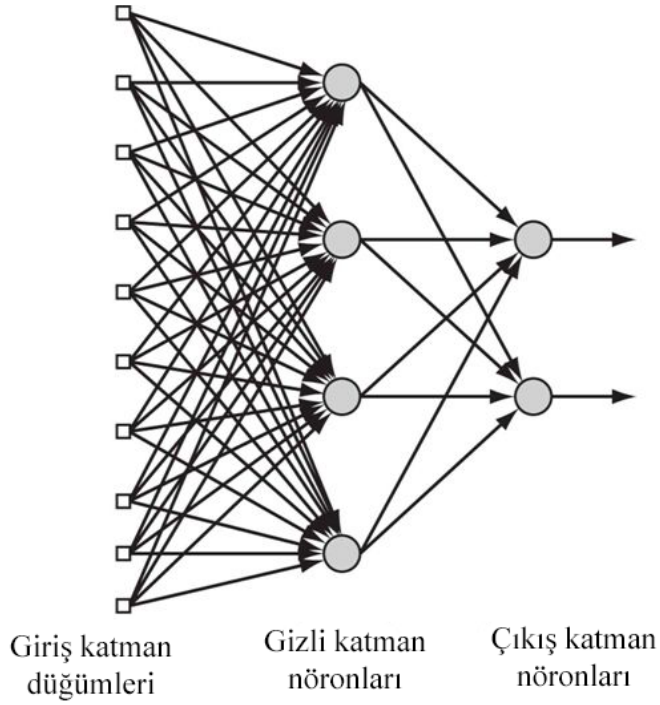


Şekil 3.4: Tek katmanlı ağ yapısı.

b. Çok Katmalı Ağlar: İleri beslemeli sinir ağlarının hesaplama katmanı gizli katman olarak adlandırılır ve giriş katmanı aldığı sinyalleri direk olarak çıkış katmanına ulaştıramaz. Ara katman, yani gizli katmanda, giriş sinyali ve çıkış verisi arasında gerekli işlemler yapılır. Ağ yapısı bazı problem çeşitleri için ara katman seviyesine daha fazla seviye eklemek durumunda kalır. Böylelikle ağ yapısı ekstra nöron ve nöron bağlantılarından oluşan daha uzun bir mimariye sahip olmuş olur (Churchland ve Sejnowski, 1992).

Ağın giriş katmanındaki kaynak düğümleri ikinci katmandaki (ilk gizli katman) nöronlar için aktif hâle gelerek hesaplama düğümleri etkinleştirir. İkinci katmanın çıkış sinyalleri, üçüncü katmanın giriş sinyalleri olarak kullanılır. Bu, bütün mimari için geçerlidir. Bir önceki çıkışlar bir sonraki düğümlere giriş olacak şekilde giriş sinyalinden çıkış katmanına doğru aktif bir düzen sağlanır.

Aşağıda bulunan Şekil 3.5'te çok katmanlı ileriye yönlü tek gizli katmana sahip bir mimari gösterilmektedir. İleri beslemeli mimaride x düğümlü ileri yönlü ağda h1 nöronları ilk gizli katman, h2 nöronları ikinci gizli katman ve y nöronları çıkış katmanı olacak şekilde x – h1 – h2 – y şeklinde adlandırılır. Şekilde ki ağda 10 - 4 - 2 olarak adlandırılır . Açıklaması ise, bunun 10 kaynak düğüme, 4 gizli nörona ve 2 çıkış nöronuna sahip olması demektir.



Şekil 3.5: Çok katmanlı ağ yapısı.

Geri-Beslemeli Sinir Ağı

Öğreticili öğrenmede en yaygın kullanılan algoritmalarından biridir. Giriş verilerine sınıf bilgisi eklenerek tahmin ve sınıflandırma uygulamalarında kullanılmıştır. Giriş katmanı, gizli katman ve çıkış katmanından oluşur. Bağlantı katmanları arasında ağırlık katsayıları bulunur ve her katman birden fazla nöron içerir.

Geri beslemeli sinir ağının arka planda yapısı çıktı hatasını öğrenme sürecinde kademeli olarak azaltmaktır. Öğreticili öğrenmede eğitim aşaması şu şekilde gösterilmektedir:

Giriş katmanına uygulanan uyarıcı $x(n)$, j. nöronun çıkışında üretilen $y_j(n)$' nin çıkış katmanı sinyalidir. Buna bağlı olarak üretilen hata sinyali:

$$e_j(n) = d_j(n) + y_j(n) \tag{3.25}$$

d_j istenen cevap sinyalidir. Hata enerjisinin tanımı:

$$E_j(n) = \frac{1}{2} e_j^2(n) \tag{3.26}$$

Ağın toplam anlık hata enerjisi,

$$E(n) = \sum_{j\epsilon\ C} E_j\ (n) \tag{3.27}$$

$$= \frac{1}{2} \sum_{j\epsilon C} e_j^2(n) \tag{3.28}$$

N örneklerinden oluşan C seti bütün çıkış katmanı nöronlarını içeren ortalama hata enerjisi,

$$E_{av}\ (N) = \frac{1}{N} \sum_{n=1}^{N} E(n) \tag{3.29}$$

$$= \frac{1}{2N} \sum_{n=1}^{N} \sum_{j\epsilon C} e_j^2\ (n) \tag{3.30}$$

Çok katmanlı ağlarda anlık hata enerjisi ve ortalama hata enerjisi sinaptik ağırlık ile ayarlanabilen fonksiyonlardır.

Öğreticili öğrenme eğitimi geri yayılım algoritmasıyla daha da gelişmiştir. j. nörona bağlı ilk aktive değeri u_j(n) aktivasyon fonksiyonunun girişinde üretilen,

$$u_j(n) = \sum_{i=0}^{m} W_{ji}(n), y_i\ (n) \tag{3.31}$$

m nöron j'ye uygulanan toplam girdi sayısıdır. b_j eşik değeri sinaps ağırlığı w_{j0} olarak eklenir. Nöron j'nin çıkış sinyali $y_j(n)$'dir.

$$y_j(n) = \varphi_j(u_j(n)) \tag{3.32}$$

Sinaptik ağırlık $wji(n)$ geri yayılım algoritmasıyla tekrar $\Delta wji(n)$'ler düzeltilir; kısmi türevle $\partial E(n)/\partial w_{ji}(n)$ orantılıdır (Haykin, 2009). Gradyan hesabı şu şekildedir:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial u_j(n)} \frac{\partial u_j(n)}{\partial w_{ji}(n)} \tag{3.33}$$

Kısmi türevde belirleyici olan değer sinaps ağırlığı wji'dir.

Denklemin her iki tarafını ayırt etmek için $e_j(n)$,

$$\frac{\partial E(n)}{\partial e_j(n)} = e_j(n) \tag{3.34}$$

Denklemin her iki tarafını ayırt etmek için $y_j(n)$,

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \tag{3.35}$$

Sonraki ayırt edici değer $u_j(n)$,

$$\frac{\partial y_j(n)}{\partial u_j(n)} = \varphi_j'(u_j(n)) \tag{3.36}$$

Sağ taraf, kullanım açısından farlılık gösteren değerlerdir. Son olarak denklemi farklılaştıran $w_{ji}(n)$,

$$\frac{\partial u_j(n)}{\partial w_{ji}(n)} = y_j(n) \tag{3.37}$$

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n)\varphi_j'(u_j(n))y_j(n) \tag{3.38}$$

$W_{ji}(n)$ değerinin düzeltilerek yeniden $w_{ji}(n)$'e uygulanmasına delta kuralı olarak tanımlanır.

$$\Delta w_{ji}(n) = -\eta\frac{\partial E(n)}{\partial w_{ji}(n)} \tag{3.39}$$

η geri yayılım algoritmasının öğrenme parametresidir. Denklemdeki – işareti ağrılık değerlerinin gradyan değişimini gösterir.

$$\Delta w_{ji}(n) = \eta\delta_j(n)y_j(n) \tag{3.40}$$

Yerel gradyan $\delta_j(n)$ tanımlaması,

$$\delta_j(n) = \frac{\partial E(n)}{\partial u_j(n)} \tag{3.41}$$

$$= \frac{\partial E(n)}{\partial e_j(n)}\frac{\partial e_j(n)}{\partial y_j(n)}\frac{\partial y_j(n)}{\partial u_j(n)} \tag{3.42}$$

$$= e_j(n)\varphi_j'(u_j(n)) \tag{3.43}$$

Yerel gradyan noktası için sinaps ağırlıklarının değişmesi gerekir.

Gizli nöronda hata sinyali olduğunda bu sinyalin alındığı nöronun bağlı olduğu bütün nöronlarda tekrar bir çalışma yapılır, geri yayılım algoritmasının geliştirilmesinin karmaşıklaştığı yer de bu kısımdır. Gizli nöron j için yerel gradyan $\delta_j(n)$ tanımlaması,

$$\delta_j(n) = -\frac{\partial E(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial u_j(n)} \tag{3.44}$$

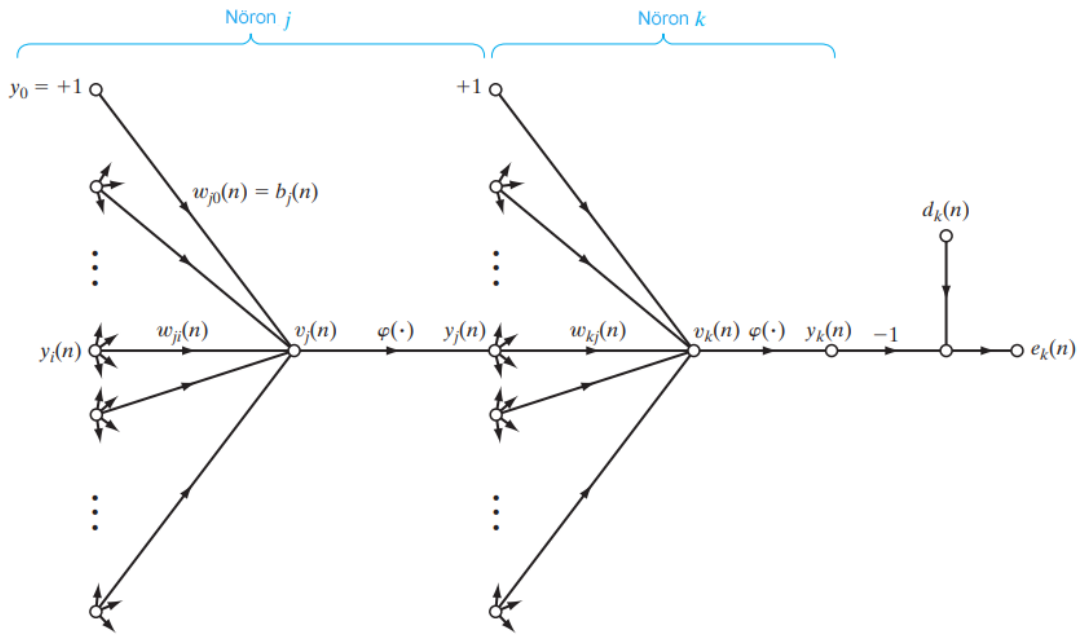
$$= -\frac{\partial E(n)}{\partial y_j(n)} \varphi_j'(u_j(n)) \tag{3.45}$$

Gizli nöron j için $\partial E(n)/\partial y_j(n)$ tekrar hesaplanır,

$$E(n) = \frac{1}{2}\sum_{k\in C} e_k^2(n) \tag{3.46}$$

Çıkış düğümü nöron k için j indeksi yerine k kullanılır; gizli nöronu ifade eden j indeksi kullanımı ile karışmasını önlemek için $y_j(n)$ fonksiyon sinyaline göre,

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_k(n)} \tag{3.47}$$



Şekil 3.6: Çıkış nöron k'nın gizli nöron j'ye doğru sinyal akış grafiği (Haykin,2009).

Daha sonra kısmi türev için $\partial e_k(n)/\partial y_j(n)$ zincir kuralı uygulanır,

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial u_k(n)} \frac{\partial u_k(n)}{\partial y_j(n)} \quad (3.48)$$

Bununla birlikte, şekil 3.6'dan,

$$e_k(n) = d_k(n) - y_k(n)$$

$$= d_k(n) - \varphi_k\big(u_k(n)\big) \text{ , çıkış düğümü nöron k için,}$$

$$\frac{\partial e_k(n)}{\partial u_k(n)} = -\varphi_k'\big(u_k(n)\big) \quad (3.49)$$

Şekil 4.4'te nöron k için yerel alan uyarılması,

$$u_k(n) = \sum_{j=0}^{m} W_{kj}(n), y_j(n) \quad (3.50)$$

m nöron k'ya uygulanan toplam giriş (eşik değeri hariç) sayısıdır. Sinaptik ağırlık $w_{k0}(n)$ eşik değeri $b_k(n)$'e +1 değeri olarak uygulanır. $y_j(n)$,

$$\frac{\partial u_k(n)}{\partial y_j(n)} = W_{kj}(n) \quad (3.51)$$

(3.49), (3.50), (3.51) kullanılarak istenilen kısmi türev elde edilir.

$$\frac{\partial E(n)}{\partial y_j(n)} = -\sum_k e_k(n)\varphi_k'\big(u_k(n)\big)w_{kj}(n) \quad (3.52)$$

$$= -\sum_k \delta_K(n) w_{kj}(n)$$

Sonunda denklem 3.52 kullanarak yerel gradyan $\delta_j(n)$ için geri yayılım algoritması tanımlanabilir,

$$\delta_j(n) = \varphi_j'\left(u_j(n)\right)\sum_k \delta_K(n) w_{kj}(n) \quad (3.53)$$

$$\begin{pmatrix} \Delta w_{ji}(n) \\ \text{Ağırlık} \\ \text{düzeltimi} \end{pmatrix} = \begin{pmatrix} \eta \\ \text{Öğrenme} \\ \text{oranı} \end{pmatrix} x \begin{pmatrix} \delta_j(n) \\ \text{Local} \\ \text{gradyan} \end{pmatrix} x \begin{pmatrix} y_i(n) \\ \text{Nöron j} \\ \text{giriş sinyali} \end{pmatrix}$$

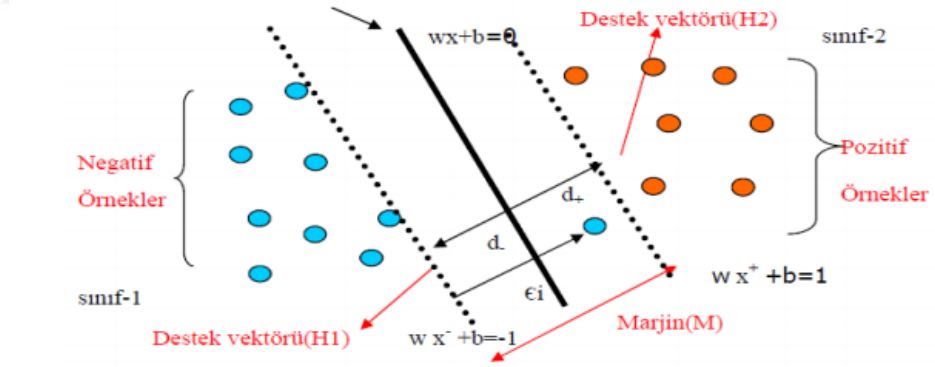
Delta kuralında öğrenme oranı artırılarak momentum (α) katsayısı içeren formülü ile $\Delta w_{ji}(n)$'ler her adımda güncellenir (Haykin, 2009),

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \eta \delta_j(n) y_i(n) \quad (3.54)$$

3.3.1.4. Destek Vektör Makineleri (DVM)

Sinyal işleme, yapay öğrenme ile veri madenciliği alanlarındaki problemlerin çözümünde çekirdek tabanlı doğrusal olmayan sınıflandırıcılar iyi sonuçlar vermektedir (Vapnik, 1999). Bu bu sınıflandırıcılardan biri olan DVM ise iki sınıflı problemlerle ilgilenir. İki sınıfı birbirinden ayırmayı sağlayacak en uygun hyper düzlemi elde etmeye çalışan DVM'de girişte alınan veriler destek vektörler ile tanımlanabilen bir hyper düzlemle Şekil 3.7'de görüleceği üzere ikiye ayrılmaktadır:

Birbirine paralel olarak, her iki sınıfın en uygun hyper düzlemlerine en yakın veri noktalarından geçen hyper düzlemler en uygun olanını seçmek amacıyla çizilir. En uygun hyper düzlem kalitesini bunlar arasındaki uzaklık belirler. Bu iki sınıf arasındaki sınır ayırt etme yüzeyini DVM tayin ederek, eğitim kümesi ile ayırt etme yüzeyine en yakın noktaların arasındaki uzaklığı niceliğin varabileceği en yüksek sınıra getirir. Aşağıda, Şekil 2.4.'te, destek vektörleri, hyper düzlemler ve marjin kavramları görülmektedir:



Şekil 3.7: İki Sınıfı Ayıran Aşırı düzlem ve Sınır (Bayrak,2011)

İki sınıfın örnekleri birbirinden bir hyper düzlem ile ayrılır. Bunun üzerindeki noktalar w.x+b=0 eşitliğini ortaya koyar. Söz konusu eşitlikte w hyper düzleme olan normal; |b|/||w|| hyper düzlemden orijine olan dik uzaklıktır. Destek vektör, hyper düzleme en yakın pozitif ve negatif örnekler arasındaki uzaklığın en fazla olduğu (marjin) bir hyper düzlem bulmaya çalışır. Bu genişlik şu şekildedir: w. x+ + b = +1, w. x- + b = -1

w değeri ne kadar zalırsa marjin genişliği de derece fazlalaşır. Her nokta xi olarak gösterilir. İki sınıfa ait eğitim verisi x = (x1, x2, …,xn) ve sınıf değeri y = (-1, +1) ise en uygun hyper düzlem şu şekilde görünür:

eğer y = +1 ise w . xi + b >= 1 eğer y = -1 ise w . xi + b < 1

Verilen X örneğini sınıflandırmak için öncelikle en uygun hyper düzlem elde edilir. Bu hyper düzlem taraflarından biri negatif, diğeri ise pozitif sınıfı temsil eder (Bayrak, 2011). DVM, Doğrusal Olmayan Sınıflandırıcı kullanma seçeneğine sahiptir. Radyal Temel Fonksiyon Çekirdeği, Polinom çekirdeği gibi farklı türde çekirdekler kullanabilir.

3.3.1.5. K En Yakın Komşuluk Sınıflandırıcısı (KNN)

K en yakın komşuluk algoritması, öğreticili öğrenme yöntemlerinden biridir. Bayes teoremi tabanlı, en yakın komşuluğa göre sınıflandırma tekniği 1967 yılında Cover ve Hart tarafından önerilmiştir. Sınıfları belli olan veri setleri kullanılarak kendisine en yakın k değerine göre çoğunluğun oylamasına bakılarak yapılan sınıflandırma işlemidir. Uzaklık hesaplaması için kullanılan fonksiyonlar Euclidean, Manhattan ve Minkowski'dir. KNN algoritmasının adımları şu şekildedir:

- Bir k parametresi belirlenir. Bu parametre verilen bir noktaya göre en yakın komşuların sayısıdır.
- Sınıfı belirlenmek istenen hedefin mevcut verilere olan uzaklığı tek tek hesaplanır. Ölçüm, uzaklık fonksiyonları ile belirlenir.
- Belirlenen en yakın mesafeye sahip komşu sınıflar seçilir.
- Bu sınıflardan çoğunluğun sınıfına göre yeni değerde etiketlenmiş olur.

3.3.1.6. Rastgele Orman Algoritması (RF)

RF, makine öğrenme algoritmalarından en popüler olanıdır. Rastgele Orman algoritması hem sınıflandırma hem de regresyon türü problemler için kullanılabilir. Bu algoritma, denetimli bir sınıflandırma algoritmasıdır. Adın da anlaşılacağı üzere bir ağaç dizisinden oluşur. Mantıken bir ormanda ne kadar çok ağaç varsa orman o kadar sağlam olur. Rastgele orman sınıflandırıcısında, ormandaki ağaç sayısı arttıkça yüksek doğrulukta sonuçlar elde edilir. Karar ağacı kavramı fazla kural tabanlı sistemdir. Eğitim setinde hedefler ve özellikler göz önüne

alındığında karar ağacı algoritması bazı kurallar dizisi oluşturacaktır. Karar ağacı bazı hedef kuralları ile kök düğümler ve yaprak düğümleri oluşturmaya başlar.

Karar ağacı algoritmasında bu düğümlerin hesaplanması ve kuralların oluşturulması bilgi kazancı ve gini indeksi hesaplamaları kullanılarak gerçekleşecektir. Rastgele orman algoritmasında, kök düğümü hesaplamak için bilgi kazancı veya gini dizini kullanmak yerine, kök düğümü bulma ve özellik düğümlerini bölme işlemi rastgele gerçekleşir.

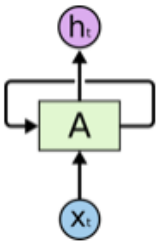
Rastgele orman algoritmasında, oluşan rastgele ağaç yapılarında çoğunluğun oyunu öğrenmeye çalışılır. Algoritmanın avantajı gereksiz ezberlemeye (overfitting) yol açmaz. Rasgele orman algoritması özellik mühendisliği için kullanılabilir. Bu, eğitim veri kümesindeki mevcut özelliklerden en önemli özelliklerinin tanımlanması anlamına gelir. Örneğin tıp alanında, Rastgele orman algoritması, hastanın tıbbi kayıtlarını analiz ederek hastalığın tanımlanmasına da yardımcı olur (Polamuri, 2017).

3.3.1.7. Derin Öğrenme

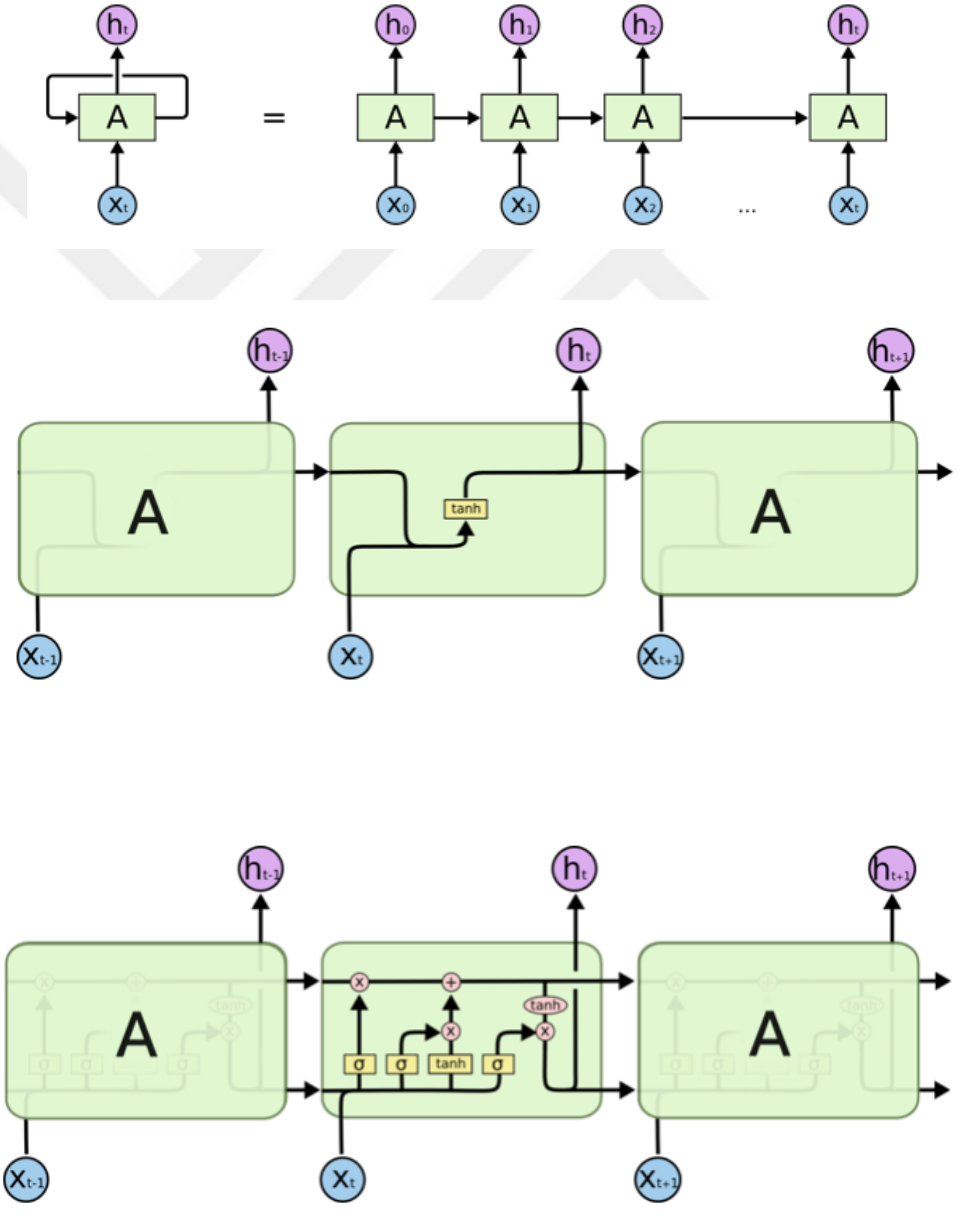
Uzun-Kısa Süreli Bellek (LSTM) Ağ Mimarisi

Hochreiter ve Schmidhuber'in 1997 yılında ileri sürdükleri uzun-kısa süreli bellek modeli (LSTM), tekrarlayan bir RNN sinir ağı olarak tanımlanmaktadır. Bu bellek modeliyle, geleneksel RNN sinir ağlarının eğitilmesinde yaşanan sorunlar tümüyle ortadan kalkmıştır. Uzun-kısa süreli bellek modeli, hafıza geçişli mekanizma ile uzun vadeli bağımlılıkları öğrenebilmesinden dolayı sıralı veya zaman serisi problemlerde bir hayli kullanılmaktadır. Söz konusu modelin ana mimarisi giriş, çıkış, unut kapıları ve hafıza hücrelerinden meydana gelir (Erdoğmuş, 2020).

Klasik yapay sinir ağlarında, bir önceki öğrenmelerde edinilen bilgiler sonraki zaman dilimine ulaştırılamayıp unutularak yeni gelen her bir bilgi önceki öğrenmelerden bağımsız olarak işlenmekte; bu durum doğal olarak dizili işlemlerin önemli olduğu veri türlerinde problemlere yol açmaktadır. Bu sorunları gidermek amacıyla, yapay sinir ağının kopyaları oluşturulmuş şekli gibi düşünebileceğimiz, normal bir sinir ağı görünüşünde olan Recurrent Neural Networks (RNN) kullanılabilmektedir. Çünkü RNN, klasik bir yapay sinir ağının aksine önceki bilgileri hatırlayıp bunları sonra gelen yeni gelen bilgilerle işleyebilir bir niteliktedir. (Can, 2019).



Şekil 3.7: RNN Yapısı (Olah, 2015).



Şekil 3.7: RNN'in açılmış yapısı (Olah, 2015).

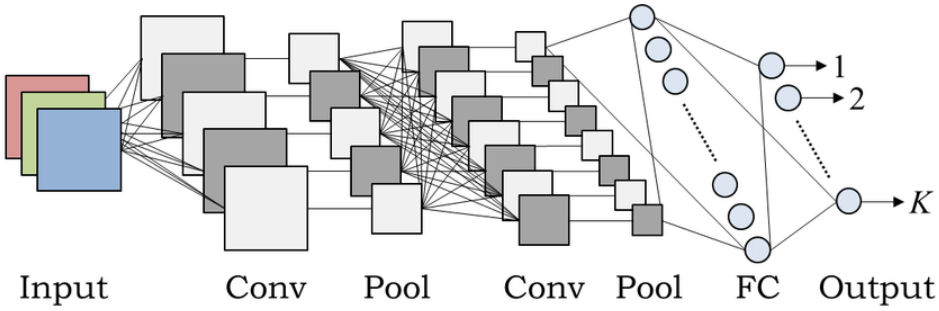
Geriye dönük fazla bilgi uzunluğu arttığı durumlarda sinir ağları işlem yapamaz hâle gelir. Bunun nedeni, ağlarda kullanılan geriye yayılım (backpropagation) algoritmalarında gradyanların son zaman biriminden ilk zaman birimine doğru yapılması, bunlardaki geçmiş bilgilerin artması ve böylelikle gradyanların küçülüp yavaş yavaş kaybolmasıdır.

LSTM, hücre durumu "kapılar denilen yapılarla" bilgi ekleme veya kaldırma yeteneğine sahiptir. Kapılar, isteğe bağlı olarak bilgi vermenin bir yoludur. Bunlar sigmoid sinir ağı Uzun-kısa süreli bellek modeli (LSTM) isteğe bağlı şekilde, "kapı" adı verilen yapılarla bilgi ekleme ve kaldırma yetisine sahiptir. Bunlar sigmoid sinir ağı katmanı ve noktalı çarpma işleminden meydana gelir. Söz konusu katmanda veriler 0 ve 1 çıktı aralığındadır; bu durumda 0 değeri hiçbir şekilde izin vermezken, 1 değeri tümüyle izin anlamındadır (Erdoğmuş, 2020).

Evrişimsel Sinir Ağ (CNN) Mimarisi

Veri setinin özelliklerinden eğitilen klasik yapay sinir ağları yanı sıra özellik çıkarma yöntemi (feature extraction), makine öğrenmesi alanında başlı başına bir araştırma alanıdır. Öğrenme başarısını etkileyen faktörlerin başında ise doğru özelliklerin seçilmesi gelmektedir. Bu seçimin kolaylıkla yapılabilmesi amacıyla özellik çıkarımının ağ içerisinde yapılabileceği bir ağ yapısı teklif edilmiştir. Matematiksel evrişim ve filtreleme işlemleri ile özellik çıkarımı yapılırken, veriden daha derin olmakla birlikte daha düşük boyutlarda özellikler elde edilmesi nedeniyle derin öğrenme olarak adlandırılmış ağ yapıları 2015 yılından itibaren birçok alanda uygulanmaktadır (Erdoğmuş, 2020).

Convolutional Neural Networks (CNN), diğer adıyla evrişimsel sinir ağları kavramına 1990 yılından başlanarak literatürde geniş ölçüde yer verilmiştir. Fakat dönemim yaygın olmayan bilgisayar altyapısı nedeniyle CNN uygulamaları kısıtlı kalmıştır. 1995 yılına gelindiğinde ise Image Processing yani görüntü işleme adı verilen uygulamalarda CNN ilk kez kullanılır (Lawrence ve diğ., 1996). Başarılı sonuçlar veren CNN ağının ana yapısı aşağıdaki gibidir:



Şekil 3.8: CNN ağ yapısı (Hidaka ve Kurita, 2017)

Yukarıdaki şekilde de görüleceği üzere CNN katmanları; giriş (Input), evrişim katmanı (Conv), havuzlama katmanı (Pool) ve sınıflandırma (FC) aşamalarından oluşmaktadır. YSA ile sınıflandırma yapılma aşamasında ise veri özelliklerinin doğru tespit edilip seçilerek sisteme girilmesi gerekir.

Ağ yapısını kolaylaştıcı bir şekilde CNN'de evrişim katmanları özellik çıkarımı ve seçimi otomatik yapılıp veri doğrudan girişe gönderilmektedir. Verilerin gösterildiği katman 'giriş'tir. İkinci aşama olan evrişim katmanında ağa derinlik ismini veren özellik evrişim ağındaki filtre sayısıdır. Bu filtreler farklı özellik çıkarımı için kullanılır. Girişi 227x227x1'lik bir ağda 32'lik filtre kullanılması düşünülüyorsa çıkış derinliği 32'dir. Filtre boyutu ise filtrenin hangi ölçüde bir kernele sahip olduğunu belirtir; burada 3, 5, 7, … gibi tek sayılardan oluşan boyutlar tercih edilir. Bu katmanda çeşitli filtreler ile giriş katmanından veya bir önceki katmandan gelen matris üzerinde evrişim işlemi uygulanarak kenar vb. özellikler çıkarılır (Erdoğmuş, 2020). Aktivasyon katmanı CNN ağlarında, YSA'da olduğu gibi aynı fonksiyona sahiptir. Evrişim katmanındaki ağırlıklar ile çarpımlar toplamı elde edilen sonuçlar bir eşik değere göre çıkış verirler. Formülü F(x)<0 ise 0, F(x)>=0 ise f(x)'te gösterilen Relu katmanı ise sıklıkla tercih edilen bir aktivasyon katmanıdır.

CNN'de "havuzlama" katmanı, seçilen örnek öğeler kümesine dayalı bir ayrıklaştırma prosesidir. Burada hedef, bir giriş gösterimini örneklemektir. Otomatik özellik çıkarımı yapan pooling, yani "havuzlama"nın max pooling, min pooling ve average pooling olarak üç türü vardır. Sonraki katmanlar ise sınıflandırma ve diğer işlemler için gereklidir. Fully-connected layer girişi ağırlık matrisi ile çarparak bias ekler, çok katmanlı ağ yapısındaki katmanlar gibidir. Çıkış sayısını belirleyen katmandır. Softmax katmanı, girişe softmax fonksiyonu uygulayarak çıkışlara ait olasılıkları hesaplar. Softmax N adet girdi değerini alarak herbirine ait olasılıkları

(0- 1) çıkış olarak veren fonksiyondur (Wikipedia, 2020). Sınıflandırma katmanı, çok sınıflı sınıflandırma problemleri için çapraz entropi kaybını hesaplar. Tipik sınıflandırma ağları için sınıflandırma katmanı softmax katmanını izlemelidir.

Derin Öğrenme Algoritmaları

Derin öğrenme yaklaşımlarının gelişmesiyle çok katmanlı yapay sinir ağının nasıl hazırlanacağı, kaç katmandan oluşup kaç nöron içereceği, hangi optimizasyon algoritmasının ya da aktivasyon fonksiyonunun uygulanacağı problem çözümünde daha önemli duruma gelmiştir (Çarkacı, 2018).

Derin öğrenme uygulamalarında, çeşitli optimizasyon yöntemleri kullanılarak öğrenme işleminin sağlıklı bir şekilde sonuçlanması hedeflenir. Bunun için en sık başvurulan yöntemlerden biri "gradyan inişi"dir (Gradient descent) (Ser ve Bati, 2019).

YSA eğitiminde kullanılan geri yayılım algoritması, gradyan iniş algoritmasının diğer bir versiyonu, Batch Gradient Descent (yığın gradyan iniş)'tir. Bu algortimada hata, tüm veri setinin hesaplanmasıyla bulunur. Bazı durumlarda ise hata yüzeyi oldukça karmaşıktır. Bu nedenle tüm veri setiyle hatayı hesaplamak yerine her iterasyon için hata yüzeyi tahmin edilip güncelleme yapılır. Bu algoritma dinamik olarak hata fonksiyonunu değiştirdiği için lokal minimuma takılmayı engeller. Ancak tek örnek üzerinden hesaplanması nedeniyle salınım daha fazladır. Yığın gradyan iniş çok yavaş ama kararlı, stokastik gradyan iniş hızlı ama daha kararsız durumdadır. Bu nedenle her iki algoritma arasında bulunan yeni bir yöntem önerilmiştir. Bu yöntem, mini yığın gradyan iniş algoritması olarak adlandırılır. Eğitim veri setinin küçük bir bölümü ile hata hesaplanıp tüm veri seti tamamlandığında bir epoch adı verilir (Erdoğmuş, 2020).

Adam (Kingma ve Ba, 2014), adaptif öğrenme oranı optimizasyon algoritmasıdır. Söz konusu algoritma derin öğrenme ağlarının eğitimi ve bu eğitimin süresini hızlandırmak için geliştirilmiştir. Fakat ilerleyen yıllarda, bazı durumlarda bu algoritmanın stochastic gradient descent'ten daha kötü sonuçlar verdiği görülmüştür (Bushaev, 2018).

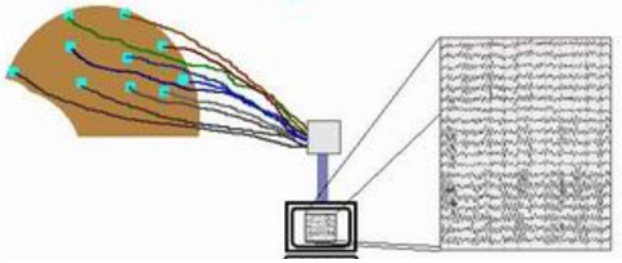
Stochastic gradient descent algoritmasının bir başka versiyonu olan Adam, özellikle derin öğrenme ağ yapılarının eğitiminde kullanılmaktadır. Stochastic gradient descent tüm ağırlıkların güncellenmesi için tek bir öğrenme oranı (alfa) kullanır ve bu durum eğitim boyunca değişmez (Brownlee, 2017).

Derin öğrenmede, oluşturulan ağdaki optimize edilecek ağ ağırlıklarının haricinde kullanılan algoritmaların da çeşitli parametreleri bulunur. Bunlar; sınıf ve örneklem sayısı, filtre sayısı, filtre boyutu, aktivasyon fonksiyonu, en iyileme algoritması, öğrenme katsayısı, yığın boyutu gibi ağı tasarlayan kişilerin tanımladığı bazı paratmerelerdir. Tanımlanan bu parametrelere hiper parametre adı verilir (Kurt, 2018). Bunlar ağ başarısını doğrudan etkilemektedir. Dolayısıyla hiper parametre optimizasyonu da başlı başına bir araştırma alanı olup genetik algoritma, parçacık sürü optimizasyonu gibi birçok sezgisel algoritmadan hiper parametre optimizasyonunda faydalanılmaktadır (Gülcü ve Kuş, 2019).

3.4. EEG ANALİZİ YÖNTEMİ

3.4.1. Malzeme

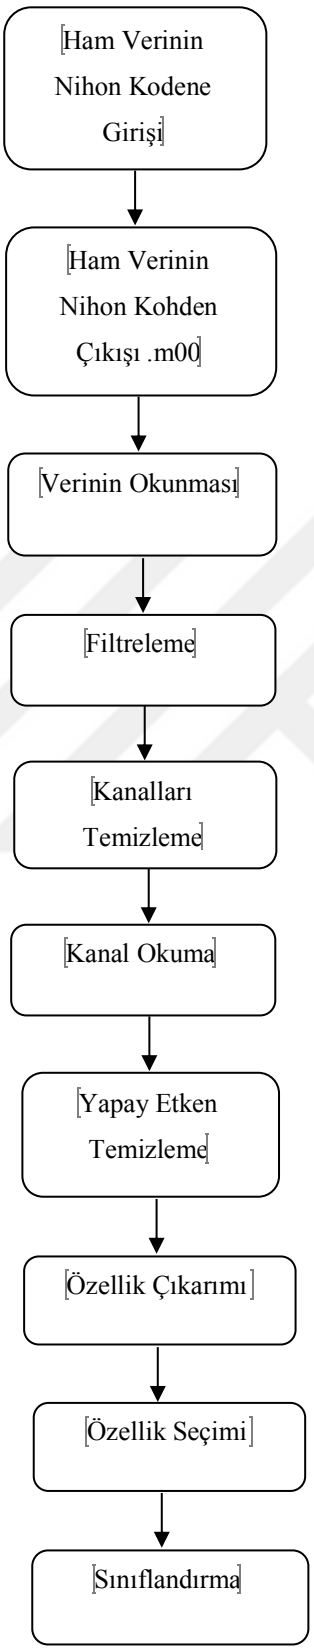
Bolu Abant İzzet Baysal Üniversitesi Nöroloji Bölümü'nde Epilepsi teşhisi konulmuş hastaların ve sağlıklı kişilerin bir listesi çıkarılarak öncelikle Epilepsi hastalarına ait EEG (Elektroensefalografi) işaretleri kaydedildi. Böylelikle, toplamda 103 epilepsi hastasının ve 21 sağlıklı kişinin EEG datası elde edilmiş oldu. Veri okunmasını kolaylaştırabilmek, pratik hâle getirebilmek için bilgisayarda oluşturulan hasta ve sağlıklı klasörüne bu datalar aktarılmıştır.



Şekil 3.7: EEG veri aktarımı.

3.4.2. Yöntem

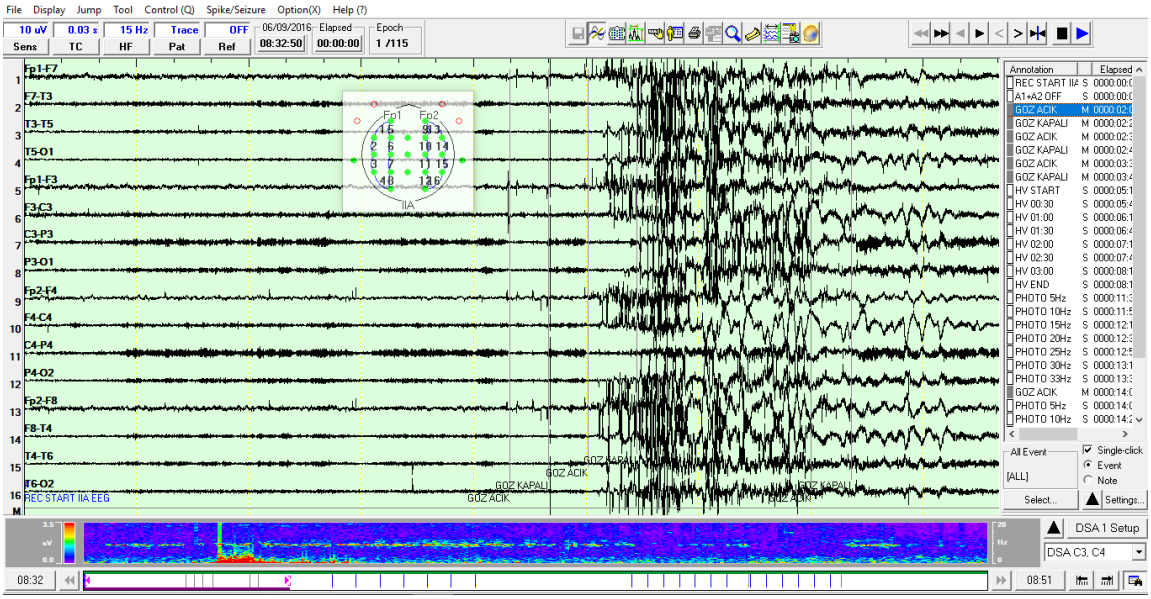
Epilepsi hastasının EEG verileri ile sağlıklı kişinin EEG verilerinin hangi ortamda inceleneceği araştırıldı. Nöroloji Bölümü, EEG çekimlerini yaptıkları cihazdan elde ettikleri sonuçları yine bu cihazın yazılımı olan Nihon Kohden EEG-1000 fax programı ile okumaktadır. Kişilerin çekim verileri, programın .exe ortamına eklenerek çalıştırılır. Şekil 3.8'de, EEG'nin ilk ham veri girişinin incelenmesinden sınıflandırma adımına kadar olan aşamaları gösterilmektedir.



Şekil 3.8: EEG verilerinin akış şeması.

3.4.3. Ham Verinin (Raw Data) Giriş ve Çıkışı

Ham verilerin EEG okuma programı olan Nihon Kohden, EEG-1000 bilgisayar ortamına yüklendikten sonra, işlem sayısı ve çekim esnasında kişide meydana gelen nöbet, kasılma, göz hareketleri, yutkunma, öksürme ve vücut hareketleri gibi etkenler de ham veriye dahil edilmiştir. Şekil 3.9'da verinin ortama aktarılması gösterilmektedir. Bu ortamda okunan veri dışarıda kullanılmak üzere .m00 formatında elde edilmiştir. Veri içeriğinde dışarı aktarılmak istenen bölge önce işaretlenir, daha sonra < aschii > olarak farklı kaydedilir.



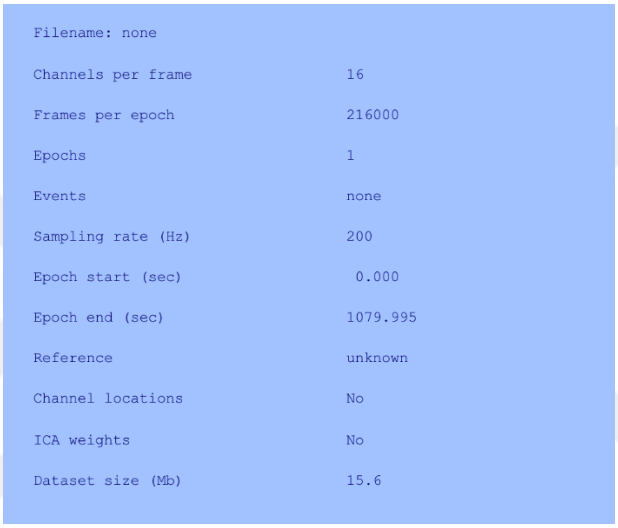
Şekil 3.9: Nihon Kohden ortamı.

3.4.4. EegLab'da Ön İşlemler

EEG verisinin incelenebilmesi, üzerinde ön işlemler yapılabilmesi ve yapay etkiler (artefacts)'den temizlemesi için EegLab14_1_2b programı kullanılmıştır. Program aracılığıyla, EEG verisi Nihon Kohden ortamından Matlab (R_2017b versiyonu) ortamına alınarak veri üzerinde işlem yapılmıştır. Bununla birlikte, Nihon Kohden ortamının veri çıkışları .m00 formatında olduğu ve EegLab'da bu veri okunamadığı için, geliştirilen uygulama üzerinden EegLab'a Nihon Kohdenin plugin 1.1.0 versiyonu eklenerek bu veri okunamama problemi çözülmüştür.

3.4.4.1. Veri Okuma

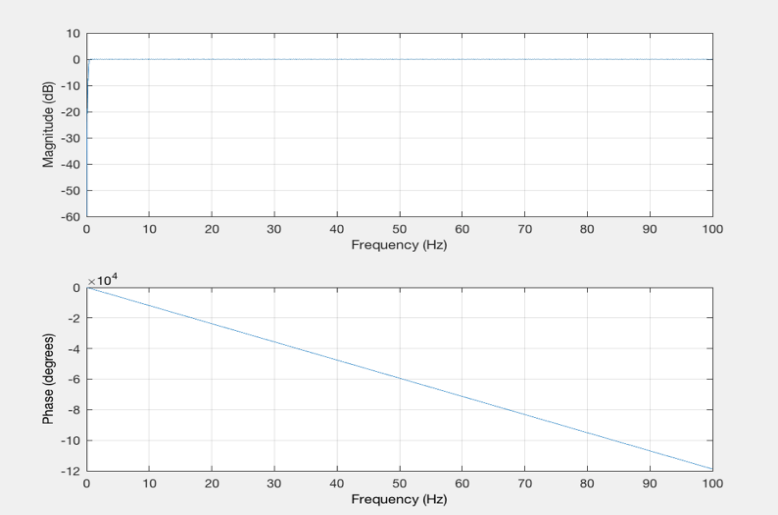
EEG verisi (.m00 formatında) Eeglab'a yüklenen plugin aracılığı ile sisteme aktarılmıştır (Şekil 3.10). Sisteme alınan 16 kanallı EEG işareti 16x21600'lük matris hâlinde aktarım hızı 200 Hz, olmak üzere 1080 saniyede (18 dakika) transfer sonlanmıştır ve veri setinin büyüklüğü 15.6 Mb olarak belirlenmiştir. Şekil 3.10'da, veri yüklenme aşamasında kanal yerlerinin (channel locations) ve Bağımsız Bileşenler Analizi ağırlıklarının (BBA Weights) olmadığı bilgisi görülmektedir.



Şekil 3.10: EegLab'a aktarılmış veri seti.

3.4.4.2. Filtreleme

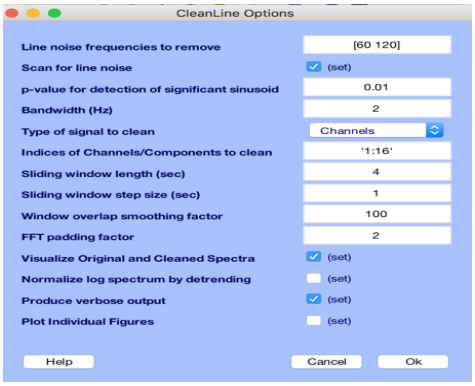
Ham veri okunduğu zaman bu veri içinde bulunan istenmeyen gürültüler yüksek geçirgen filtre aracılığıyla temizlenmiştir (Delorme ve diğ., 2007). Şekil 3.11'de filtrelenmiş verinin genlik ve faz sonuçları gösterilmiştir.

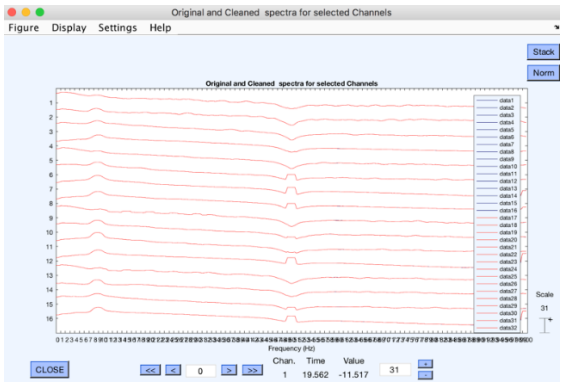


Şekil 3.11: Filtrelenmiş veri.

3.4.4.3. Kanal Temizleme

Filtrelenen veri, her kanal için verilen frekans değerleri arasında sınırlandırıldığı için, sınırlamanın dışında kalan kısımlar veriden çıkarılarak temizlenmiştir. Şekil 3.12 ve Şekil 3.13 sırasıyla Kanal Temizleme (Cleanline) ayarları ve Kanal Temizleme (Cleanline) sonuçlarını göstermektedir.



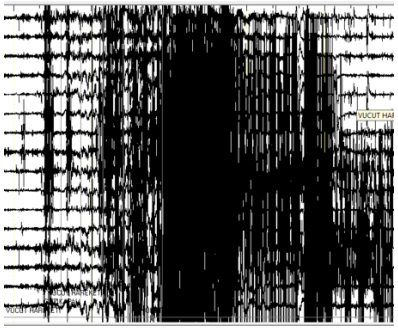


Şekil 3.12: Kanal temizleme ayarları.

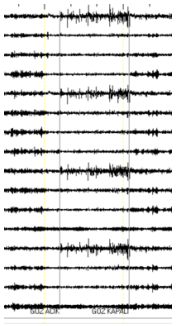
Şekil 3.13: Kanal temizleme sonuçları.

3.4.4.4. Veri Temizleme

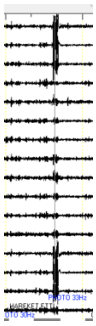
Ham veri okunduğu zaman bu veri içinde istenmeyen yapay etkiler (artefacts) bulunmaktadır. Bu yapay etkiler, göz açıp kapama, göz hareketi, vücut hareketi, yutkunma, öksürme, kasılma, nöbet vb. gibi kimyasal ve fiziksel işlem sırasında kişinin istemsiz olarak gerçekleştirdiği hareketlerdir. Şekil 3.14'te gösterilen bu etkenlerin veriden ayrıştırılması gerekmektedir.



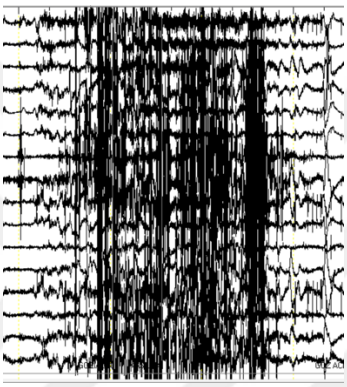
a: Vücut Hareketi



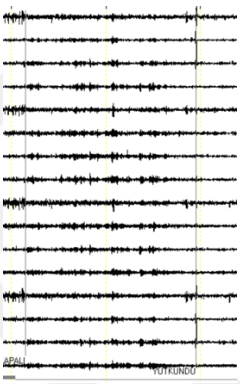
b: Göz Açıp-Kapama



c: Hareket Etme



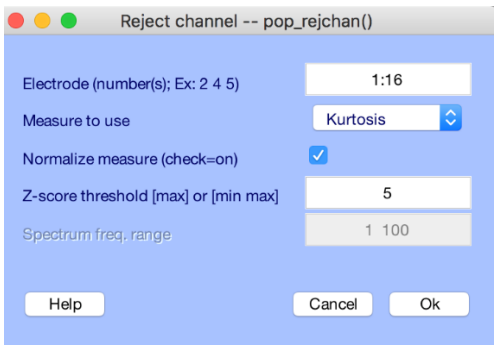
d: Kasılma

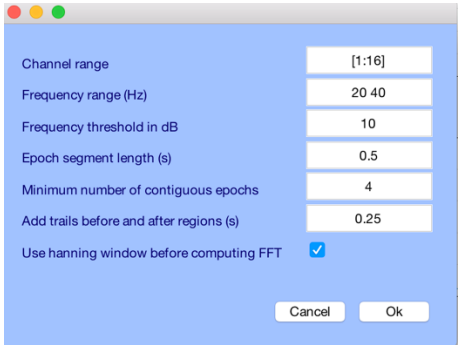


e: Yutkunma

Şekil 3.14: (a,b,c,d,e) veri üzerindeki yapay etkenler.

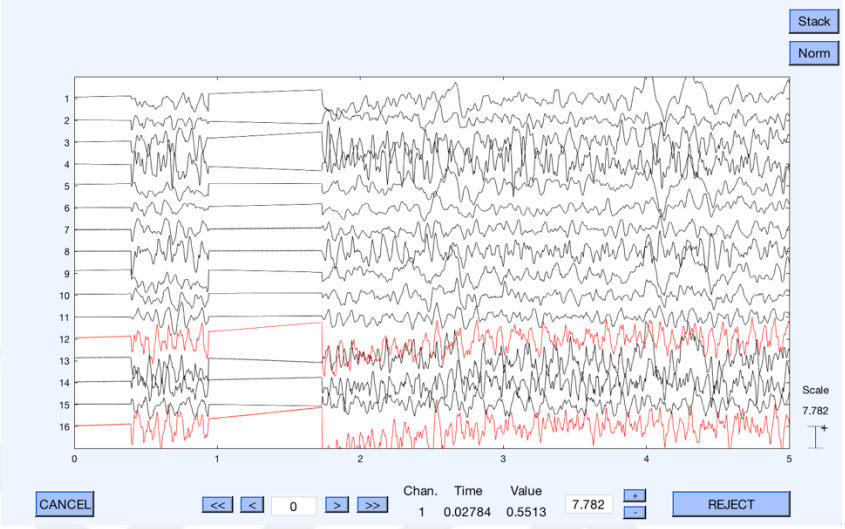
Kanallardaki gürültüyü temizlemek için önce kanal mesafelerinin hesaplanması gereklidir. Eşik değeri 5 verilerek kanalların birbirine olan mesafesi olasılık hesaplaması tabanlı Kurtosis yöntemiyle hesaplanmıştır. Bell ve Sejnowski (1995) çalışmasında, bu yöntem kullanılarak 16 kanal EEG işareti girişi uygulanarak Şekil 3.15'de görülen işlem uzunluğu, frekans değeri ve eşik değeri için kanal mesafeleri hesaplanmıştır.





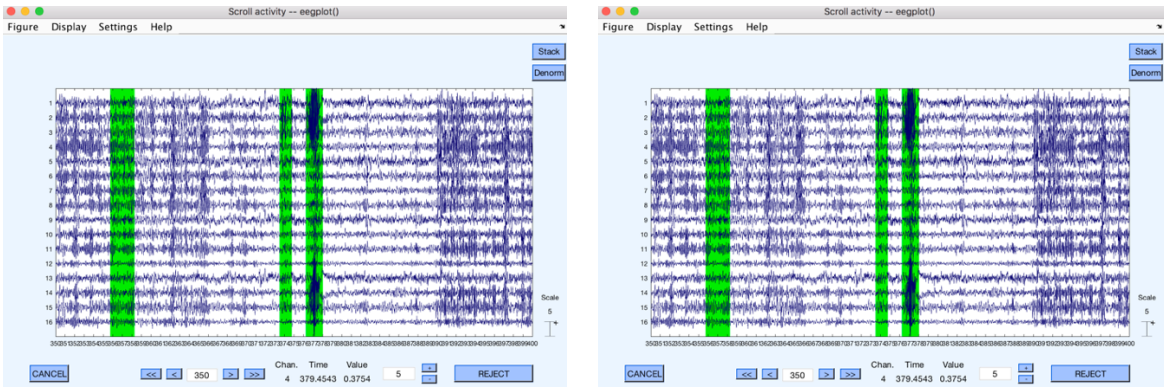
Şekil 3.15: Kanal mesafe ayarları.

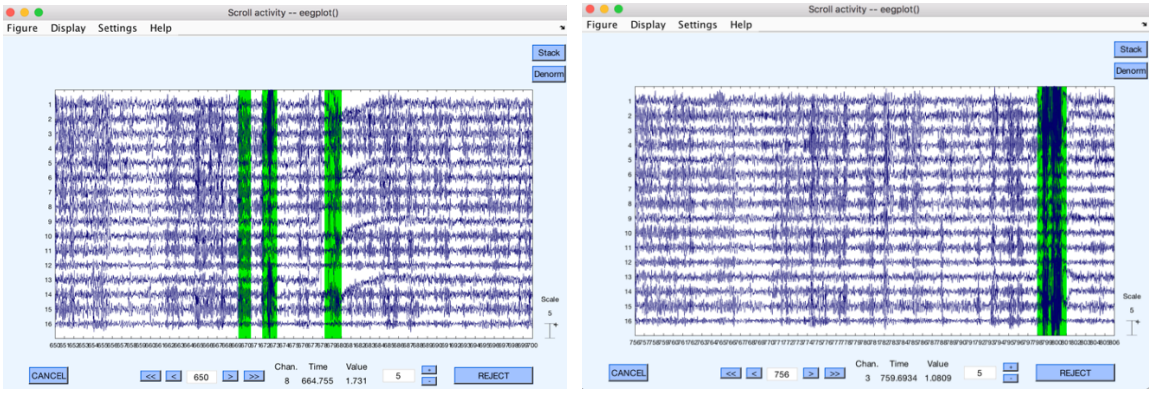
Kanallardaki yapay etkenler kaldırılmadan önce hangi kanalın kötü olduğu Şekil 3.16'da görülmektedir.



Şekil 3.16: Kurtosis yönteminin sonucu.

Bu hesaplama sonucunda kanallar üzerindeki hareket kaynaklı yapay etkenler (artefacts) gözle görülüp elle silinebilir hâle getirilmiştir. Şekil 3.17'de EEG verisindeki yapay etkenler işaretlenmiş olarak gösterilmektedir.





Şekil 3.17: Verideki yapay etkenlerin işaretlenip silinmesi.

Epilepsi hasta verisinin filtre uygulanıp elle silinen küçük yapay etkenlerden temizlendiği örnek veri değerleri Tablo 3.1'de gösterilmiştir.

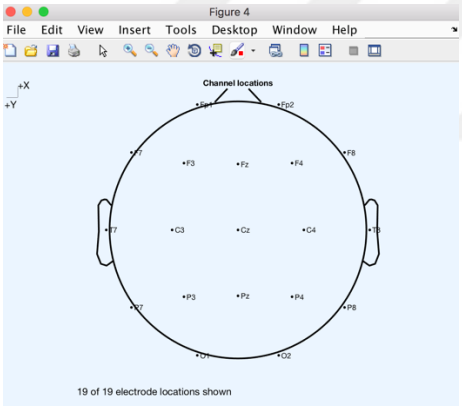
Tablo 3.1: Ham verinin filtrelenmiş ve temizlenmiş sonuçları.

Kanallar	1.sn Sinyal Değeri	2.sn Sinyal Değeri	3.sn Sinyal Değeri	4.sn Sinyal Değeri	5.sn Sinyal Değeri
Kanal-1	0,5231	0,5271	0,5311	0,5351	0,5391
Kanal-2	0,1116	0,1113	0,1109	0,1105	0,1101
Kanal-3	0,0982	0,1008	0,1035	0,1064	0,1092
Kanal-4	0,0148	0,0163	0,0178	0,0195	0,0212
Kanal-5	0,5775	0,5805	0,5834	0,5863	0,5893
Kanal-6	0,0345	0,0353	0,0360	0,0368	0,0377
Kanal-7	0,1077	-0,1287	0,1085	-0,1279	0,1094
Kanal-8	0,0230	0,2110	0,0243	0,2122	0,0255
Kanal-9	1,0146	1,0190	1,0234	1,0277	1,0320
Kanal-10	0,3752	0,3773	0,3794	0,3814	0,3835
Kanal-11	0,0326	0,0331	0,0337	0,0343	0,0349
Kanal-12	0,5732	0,3256	0,5843	0,3367	0,5955

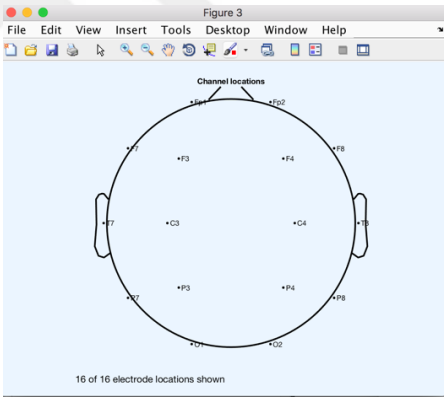
Kanal-13	0,9961	1,1828	1,1489	0,9939	1,1369
Kanal-14	0,3803	0,2497	0,2398	0,3839	0,3089
Kanal-15	0,2155	0,2162	0,2168	0,2174	0,2179
Kanal-16	0,4222	0,1144	0,4328	0,1252	0,4439

3.4.4.5. Kanal Yerlerinin Belirlenmesi

Eeglab'da veri girişine göre 19, 25, 33, 47, 81 şeklinde farklı kanal yerleşim anahtarları vardır. EegLab'da verimize en yakın olan 19 kanal yerleşimi sisteme okutulur (Şekil 3.18). 19 kanallı sistemde Fz, Cz ve Pz kanal verileri kanal koordinatlarına uymadığı için standart kanal yerleşiminden çıkarılarak elde edilen 16 kanal Şekil 3.19'da gösterilmiştir.



Şekil 3.18: 19 kanal yerleşimi.

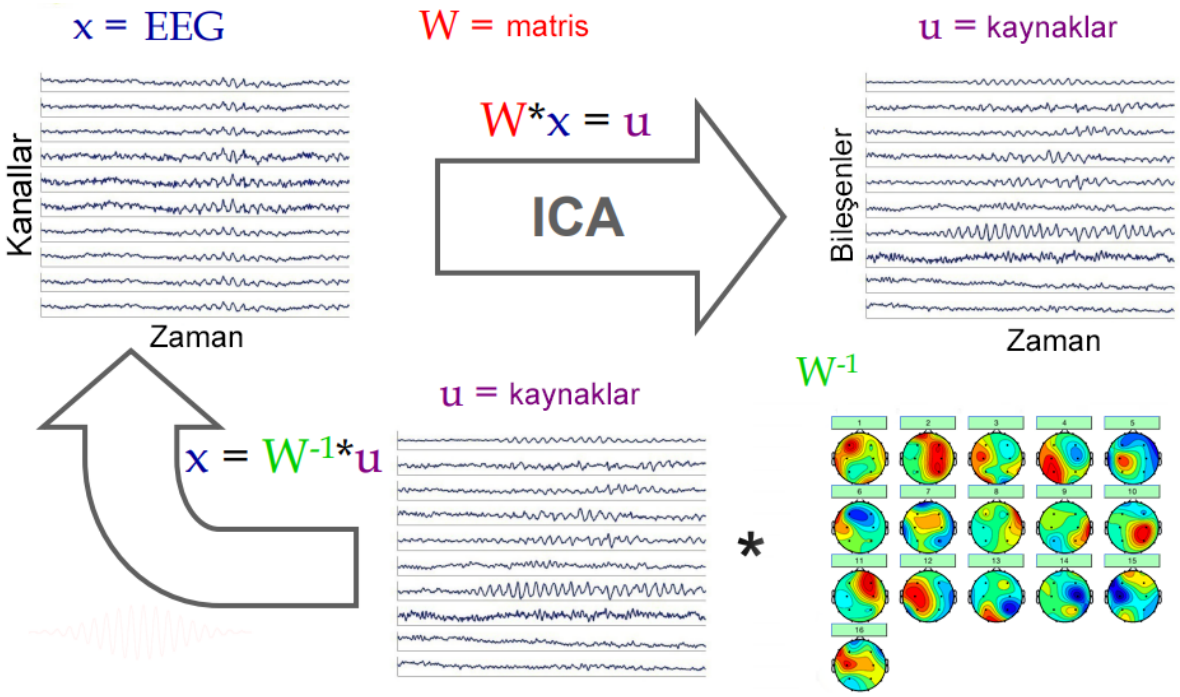


Şekil 3.19: 16 kanal yerleşimi.

3.4.5. Bağımsız Bileşenler Analizi (BBA)

EegLab'da bütün kanalların belli bir bölümündeki (Şekil 3.17'deki gibi) büyük ve küçük yapay etkenlerin tesbit edilmesinden sonra elle veya otomatik olarak bu etkiler kanallardan temizlenmiştir. Tek kanallar üzerinde meydana gelen yapay etkenleri temizlemek için kullanılan en yaygın yöntem Bağımsız Bileşenler Analizi'dir (Independent Component Analysis- ICA). BBA yöntemi ön işlem aşamasında daha etkili olarak yapay etkenlerin tespitini sağlar. Ayrıca BBA yöntemi ayrışmış bileşenlerde kas yapay etkenlerin saptanmasında da etkili olduğu görülmüştür.

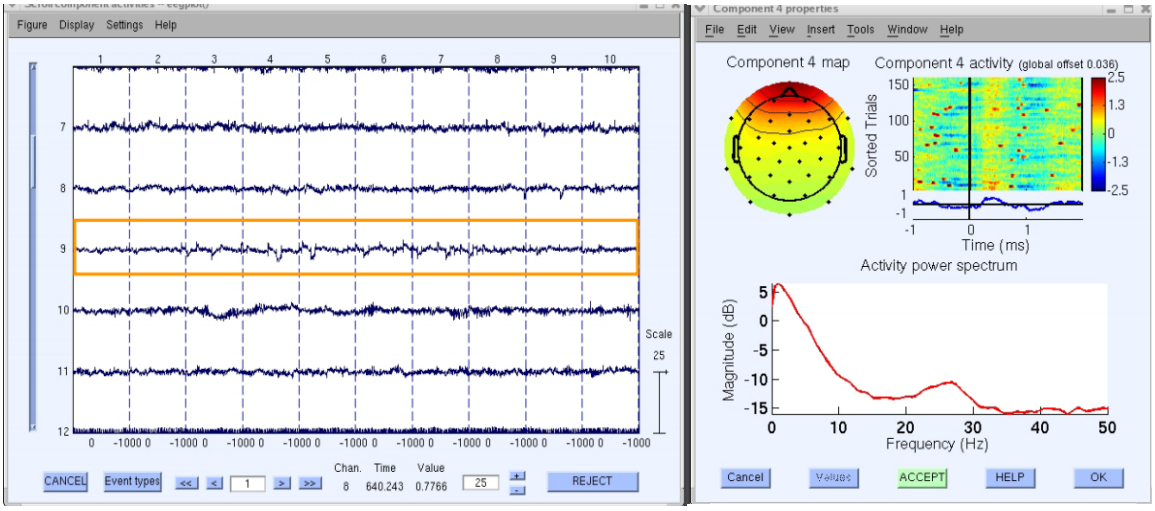
EEG verisinin kanallardaki ayrıştırma işlemi yapıldıktan sonra belirlenmiş olan kanal yerleri ile 2D (2 boyutlu) harita çıkarılmıştır. Kanal üzerindeki mavi dalgalanmalar beyin akımından gelen grafiktir. Kırmızı dalgalanmalar ise gürültü karışmış kanallardır. Burada gereksiz kanallar silinmiş ve en iyi BBA uygulanmış kanal seçilerek öznitelik vektörü uygulanmaya hazır hâle getirilmiştir.



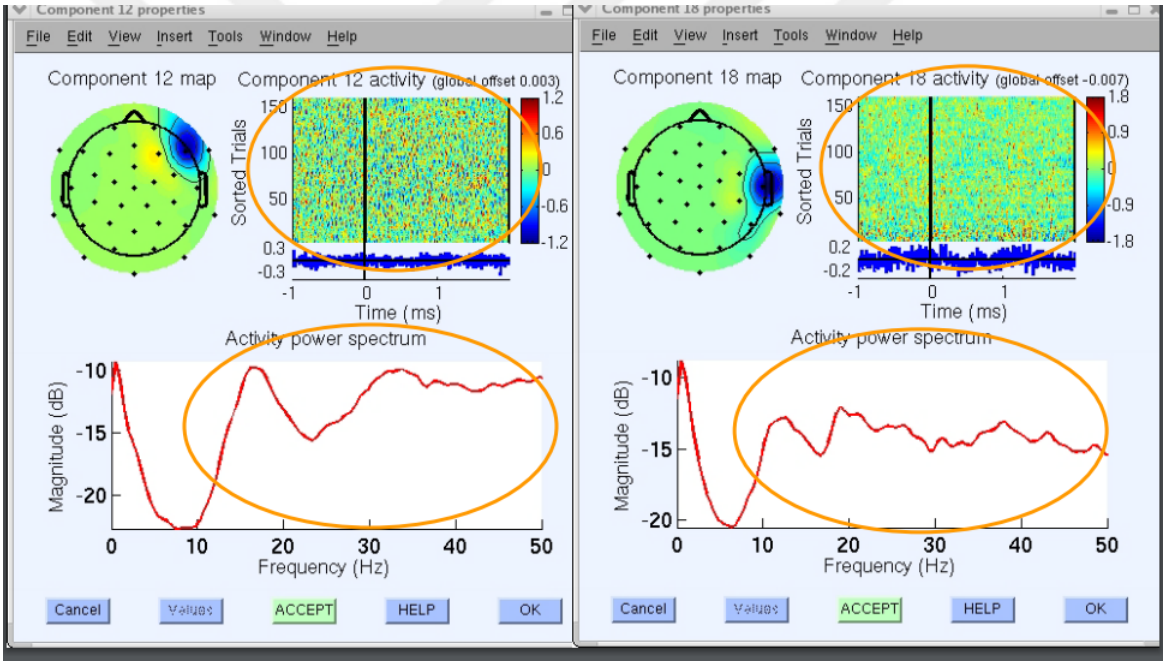
Şekil 3.20: EegLab BBA akış şeması.

16 kanallı EEG verisi (x) ile 16*16 lık BBA ağırlıklarının (W) çarpımı sonucu bağımsız bileşenler (u) elde edilmiştir (Şekil 3.20). EEG verisinin orijinalinin tahmin edilmesi W'nın tersi ile bağımsız bileşenin (u) çarpımından sağlanmıştır.

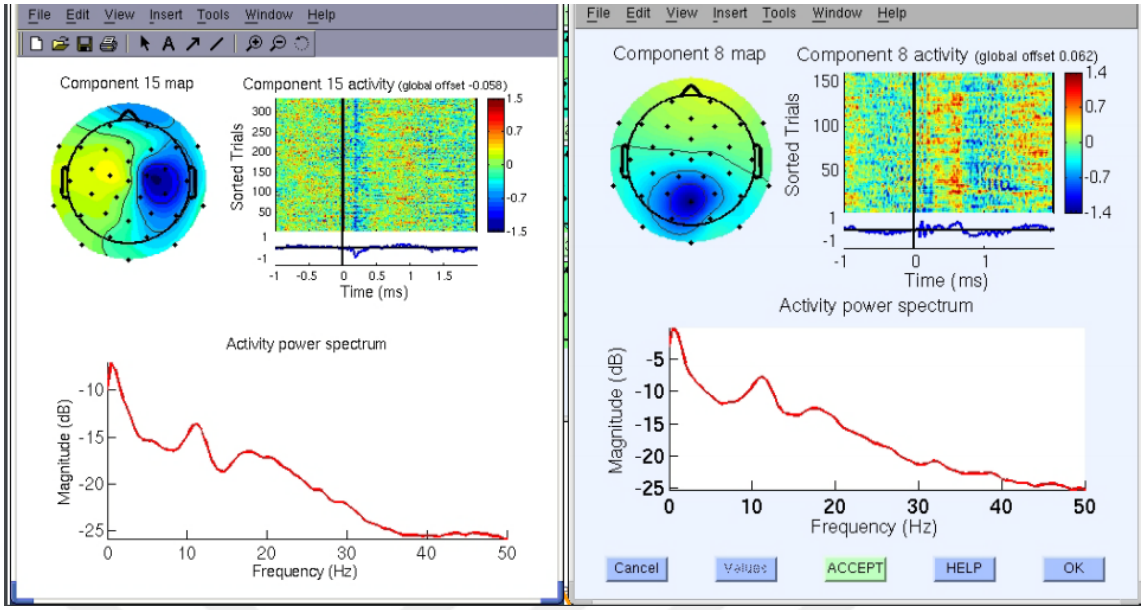
Şekil 3.21: a-d' de, BBA ile ayrıştırma yapılırken yapay etkenlerin durumuna ait örnekler gösterilmiştir. Şekil 3.22'de, bu çalışmada yapılan uygulamaya ilişkin 16 Bileşenin 2 Boyutlu olarak gösterimleri verilmiştir.



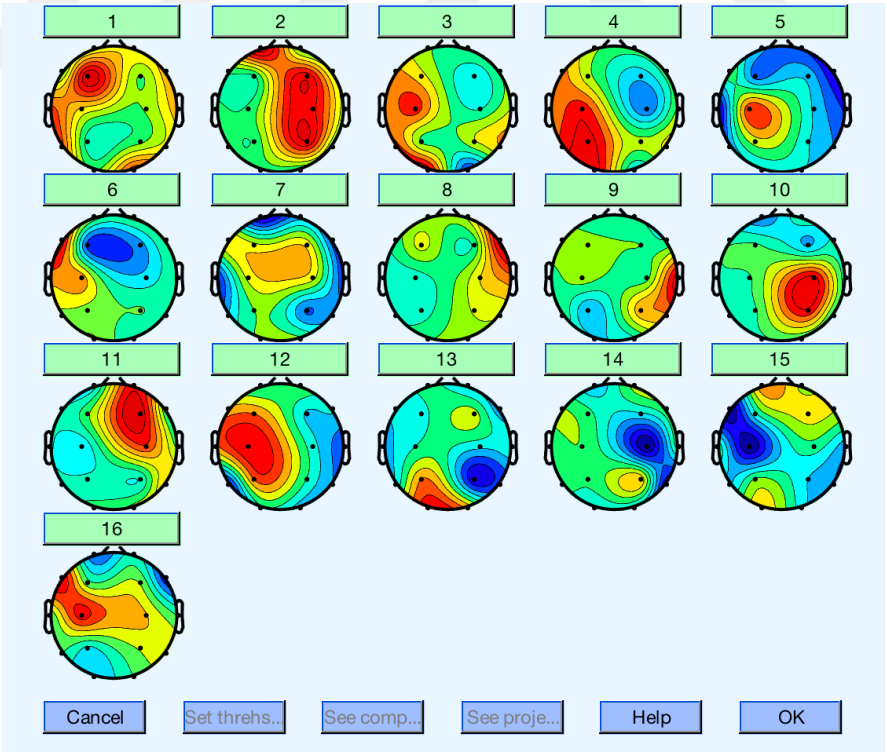
Şekil 3.21 (a): Göz Hareketi. **(b)** Göz Açıp-Kapama.



(c **(c)** Kas yapay etkeni.

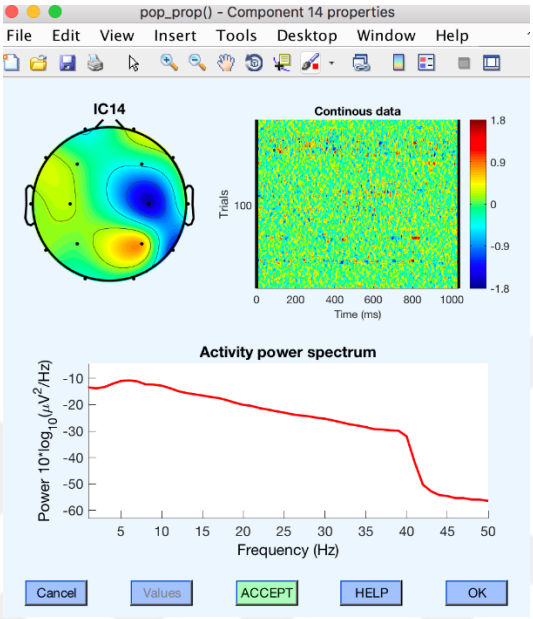


(d) Beyin etkeni.



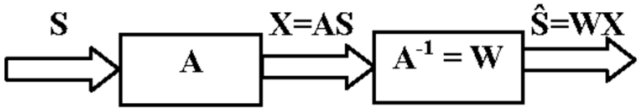
Şekil 3.22: BBA bileşenlerin 2D gösterimi.

Kanal bölgelerindeki kırmızı renkli bölümler yapay etkenli bölümleri göstermektedir. Mavi renkli bölümler ise Beyin aktivitesinden kaynaklanan sinyallerdir. Örneğin, Şekil 3.22'de 14 no'lu bileşeni gürültüden arınmış, yapay etken tespiti yapılıp silinmiş bileşen olarak ele alabiliriz. Bileşenin özellikleri Şekil 3.23'de gösterilmiştir.



Şekil 3.23: 14. bileşenin özellikleri.

Çok kanallı EEG verileri kaydedilirken aynı anda dataya gereksiz birçok bilgi de kaydedilmiş olur. BBA yöntemi ile bu gereksiz bilgilerden ayrıştırma yapılarak veride yapay etkenlerde (artefacts) azaltma sağlanmıştır (Krishnaveni ve diğ., 2005).



Kaynak Sinyaller	Birleşmiş Matris	Sinyal Mesafesi	Birleşmiş Matris Transpozesi	Sinyallerin Ayrışması

Şekil 3.24: Genel BBA akışı.

Denklem 3.55'de, S orijinal istatistiksel kaynak işaretini, A MxM boyutunda birleşmiş matrisi göstermektedir. W sinyallerin ayrışmasını sağlar ve A matrisinin tersi ile hesaplanmıştır.

$$X = AS \rightarrow \hat{S} = WX \tag{3.55}$$

Literatürde, Bağımsız Bileşenler Analizi yöntemi EEG sinyallerinden artefaktleri temizleme amaçlı kullanılmıştır (Delorme ve diğ., 2001; Nicolaou ve Nasuto, 2004).

16 kanallı sinyal verisinde büyük yapay etkenler ayrıştırıldıktan sonra kanallardaki değer değişimlerinin ilk saniyelerdeki hâli Tablo 3.2'de görülmektedir.

Tablo 3.2: BBA uygulandıktan sonra kanal değerleri.

Kanallar	1.sn Sinyal Değeri	2.sn Sinyal Değeri	3.sn Sinyal Değeri
Kanal-1	0,0623	0,0591	0,0618
Kanal-2	0,3431	0,3791	0,3574
Kanal-3	-0,0425	-0,1228	-0,0485
Kanal-4	0,0839	0,1134	0,0898
Kanal-5	0,1425	0,0177	0,1476
Kanal-6	0,0292	0,0372	0,030
Kanal-7	-0,0357	-0,0401	-0,020
Kanal-8	-0,0194	-0,0498	-0,0189
Kanal-9	0,0255	-0,0119	-0,0146
Kanal-10	0,1096	0,1125	0,1214
Kanal-11	0,0316	0,0167	0,0183
Kanal-12	0,0107	0,0087	0,0166
Kanal-13	-0,0634	-0,0330	-0,0634
Kanal-14	0,0147	0,0096	0,0135
Kanal-15	-0,0182	0,0189	-0,0182
Kanal-16	0,0050	0,0024	0,0048

3.4.6. Özellik Çıkarımı

3.4.6.1. 1B Ayrık Kosinüs Dönüşümü

Ham (raw) veriye ön işlemler yapılıp filtre ve kanal temizleme uygulandıktan sonra 16 kanallı beyin siyaline 1B (boyutlu) Ayrık Kosinüs Dönüşümü 3.56 no'lu denklem uygulanarak özellik çıkarımı yapılmıştır.

$$F(u) = C(u) \sum_{x=0}^{N-1} f(x) \cos\left[\frac{\pi(2x+1)u}{2N}\right] \tag{3.56}$$

$$u = 0,1,\dots,N-1 \;\; e\; kadar$$

$$u = 0 \; iken \; C(u) = \sqrt{\frac{1}{N}}$$

$$u \neq 0 \; iken \; C(u) = \sqrt{\frac{2}{N}}$$

Elde edilen vektörün boyutu 16x206900 matristir. Literatürde Ayrık Kosinüs Dönüşümünün sinyalde yaptığı sıkıştırmayı Bağımsız Bileşenler Analizinin yaptığı boyut azaltma sınıfında değerlendirilmiştir (Garg ve Jain, 2017). EEG sinyali ön işlemlerden geçirilmiş, küçük ve büyük yapay etkenlerden arındırılmış hâline 1D (boyutlu) Ayrık Kosinüs Dönüşümü uygulandıktan sonra sinyaldeki değişim sonucu Tablo 3.3'te gösterilmiştir. Yapılan işlemler sinyal değerinin azalmasını (sıkıştırılmasını) sağlamıştır.

Tablo 3.3: AKD sonucu kanal değerleri.

Kanallar	1.sn Sinyal Değeri	2.sn Sinyal Değeri	3.sn Sinyal Değeri	4.sn Sinyal Değeri	5.sn Sinyal Değeri
Kanal-1	1,3677	1,2349	1,3849	1,2352	1,4132
Kanal-2	-0,4244	-0,2868	-0,4248	-0,2796	-0,4457
Kanal-3	-0,0086	-0,1074	-0,0249	-0,0932	-0,0111
Kanal-4	0,3424	0,4518	0,3752	0,4181	0,3733

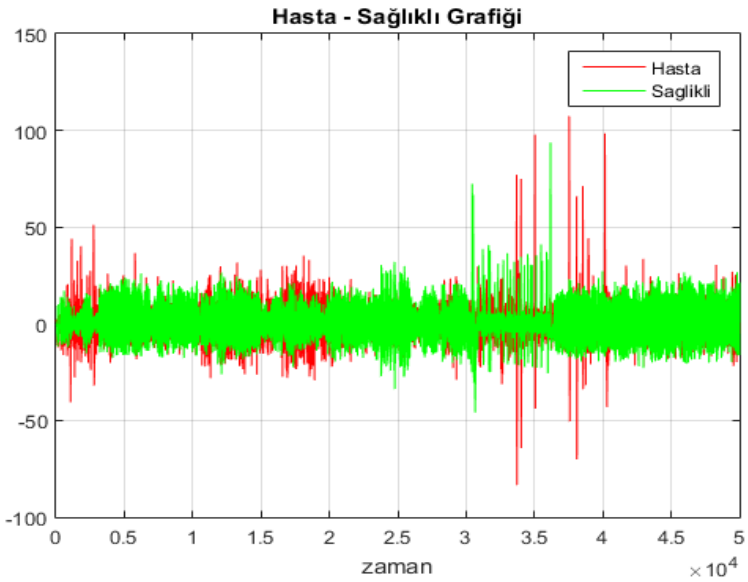
Kanal-5	-0,0128	-0,0444	-0,0393	0,0036	-0,0401
Kanal-6	0,1876	0,2330	0,1978	0,2026	0,2094
Kanal-7	-0,1256	-0,3274	-0,1012	-0,3309	-0,1167
Kanal-8	0,4128	0,5680	0,3586	0,6184	0,3807
Kanal-9	0,6897	0,7372	0,7703	0,6636	0,7572
Kanal-10	-0,5881	-0,5960	-0,6604	-0,5201	-0,6535
Kanal-11	0,01434	-0,0470	0,0471	-0,0956	0,0459
Kanal-12	0,1853	0,0979	0,2063	0,0924	0,1973
Kanal-13	-0,1065	-0,0784	-0,1703	-0,0061	-0,1430
Kanal-14	-0,0199	0,2752	0,0776	0,1696	0,0501
Kanal-15	0,2039	-0,0634	0,1188	0,0508	0,1528
Kanal-16	0,4528	0,4512	0,5122	0,3882	0,4996

Çalışmada bir kanalın sinyal boyunca 1x206900 matrisin t zamanda özellik hesaplanması yerine, zaman t / 4'e ayrılır. t1, t2, t3, t4 ayrı zamanlarda özellik çıkarımları hesaplanır. Her bir kanal için 4 ayrı zamanda hesaplama yapılınca 16 kanal için 64 özellik çıkarımı yapılmış olur.

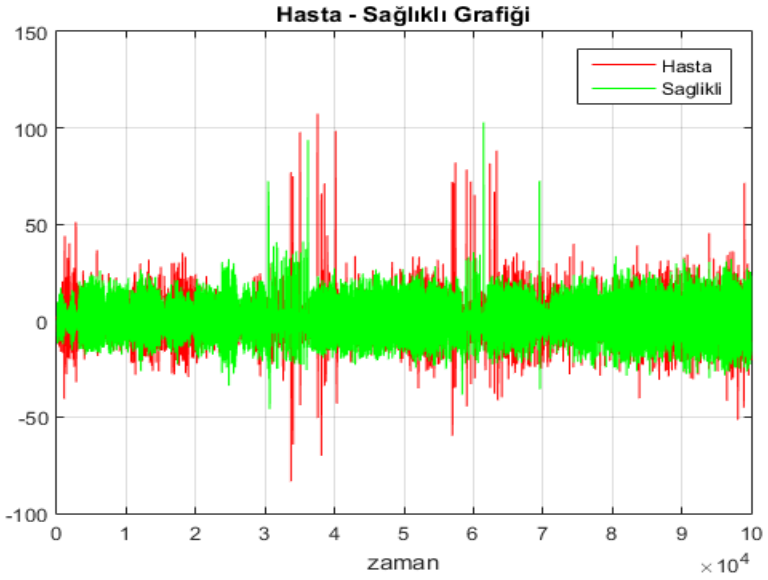
Epilepsi Hastası ve Sağlıklı Kişinin AKD (DCT) Grafiği

Bu bölümde, Hasta ve Sağlıklı bir kişinin AKD (Ayrık Kosinüs Dönüşümü-DCT)'nü farklı kanallar ve farklı matris boyutları için değişim grafikleri elde edilmiştir.

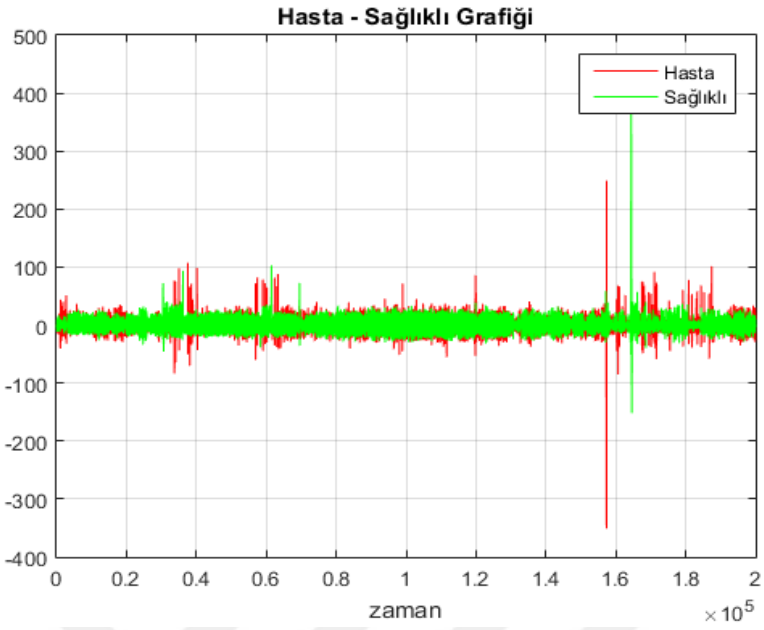
Epilepsi hastası ile Sağlıklı bir kişinin 1x50000 matrisi için 1. kanal görüntüsü, 1x100000 matrisi için 1. kanal görüntüsü, 1x200000 matrisi için 1. kanal görüntüsü sırasıyla Şekil 3.25. a/b/c'de görülmektedir.



Şekil 3.25 (**a**): 1x50000 1. kanal.

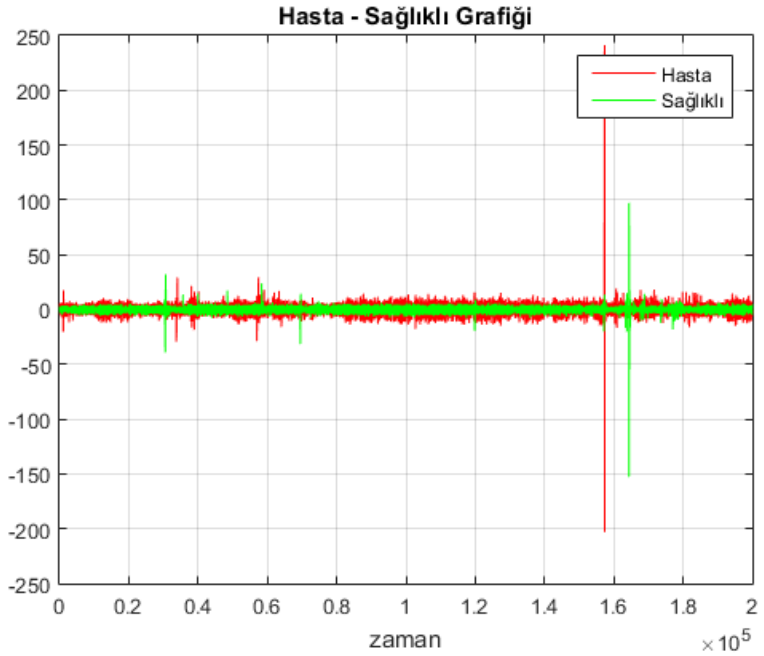


(b) 1x100000 1. kanal.

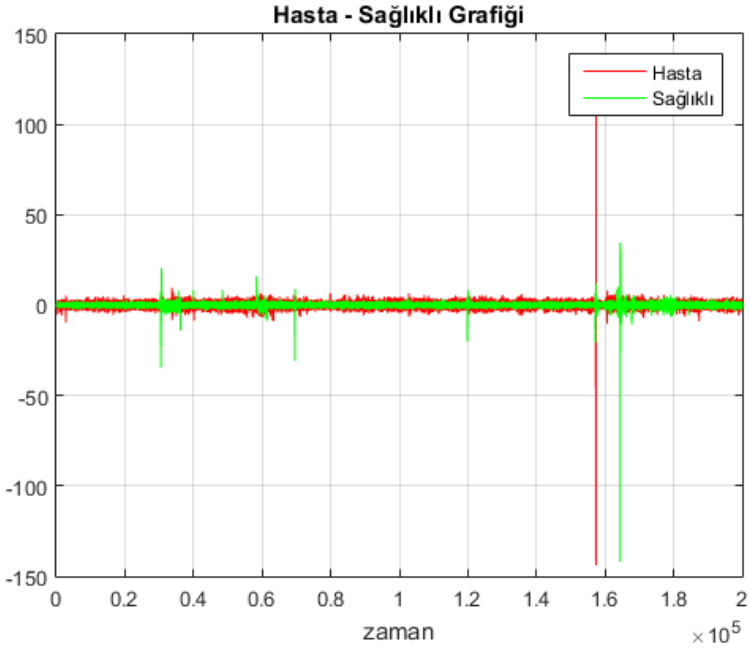


(c) 1x200000 1. kanal.

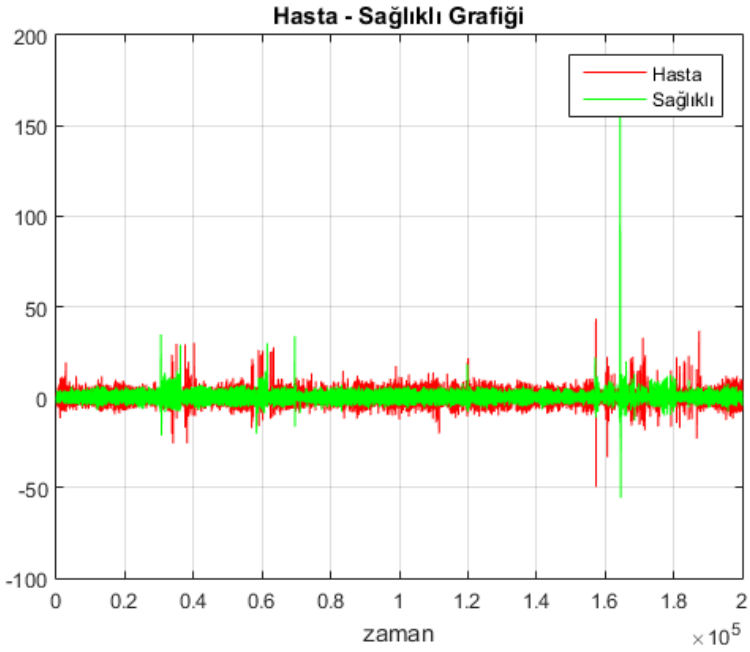
Epilepsi hastası ile Sağlıklı bir kişinin 1x200000 matrisi için 2. kanal, 3. kanal, 4. kanal ve bütün kanalların görüntüleri sırasıyla Şekil 3.26. a/b/c/d' de görülmektedir.



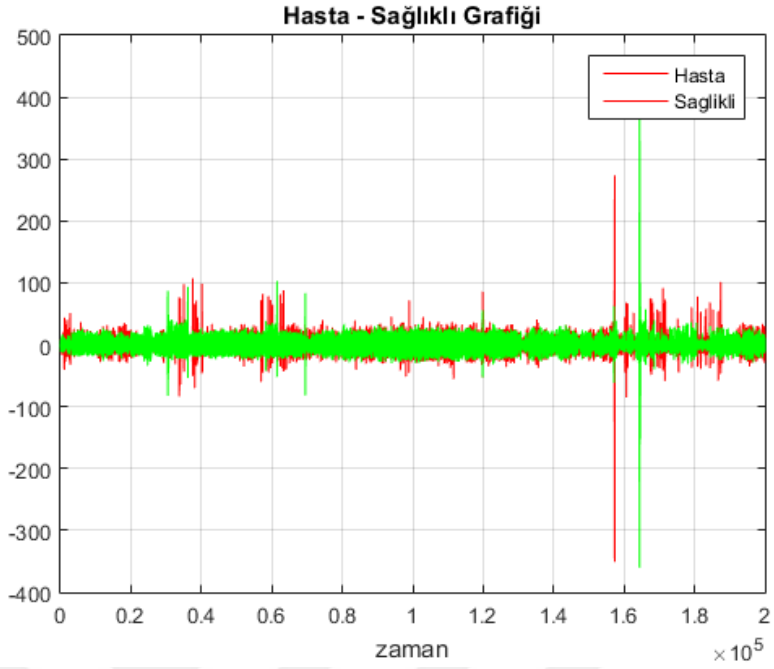
Şekil 3.26 (a): 1x200000 2. kanal.



(b): 1x200000 3. kanal.



(c): 1x200000 4. kanal.



(d): 1x200000 bütün kanallar.

Şekil 3.25 ve Şekil 3.26'da, EEG sinyalleri matris aralıkları daraldıkça sinyalden çok çizgisel hâle dönüşümü; epilepsi hastası ve sağlıklı EEG sinyallerinin kanal kanal karşılaştırılması sonucu aradaki farklar görülmektedir.

3.4.6.2. İstatistiksel Özellik Çıkarımı

Öznitelik çıkarımı için ortalama, varyans, standart sapma, çarpıklık ve basıklık gibi istatistiksel yöntemler kullanılmıştır (Gupta ve Kapoor, 2002). EEG sinyallerine bu yöntemler uygulanarak farklı öznitelik çıkarımları yapılmıştır (Chandaka ve diğ., 2009).

Ortalama (Mean)

Ortalama, bir kanaldaki sinyaller toplamının sinyal sayısına bölünerek elde edilir:

$$\mu = \frac{\sum_{i=1}^{N} x_i}{N} \tag{3.57}$$

Tablo 3.4'te, 16 kanalın 4 farklı (t1, t2, t3, t4) zamandaki ortalama değerleri hesaplanarak toplam 16x4 = 64 özellik bulunmuştur.

Tablo 3.4: Her bir kanalın ortalama özellik değerleri.

Kanallar	t1. Ortalama Değeri	t2. Ortalama Değeri	t3. Ortalama Değeri	t4. Ortalama Değeri

Kanal-1	-0,0042	0,0049	-0,0138	-0,0107
Kanal-2	0,0012	0,0012	-0,0005	0,0045
Kanal-3	0,0013	0,0001	0,0016	0,0055
Kanal-4	-0,0057	-0,0015	-0,0062	-0,0093
Kanal-5	0,0002	-0,0011	0,0011	0,0019
Kanal-6	-0,0052	-0,0014	-0,0070	-0,0091
Kanal-7	-0,0010	-0,0057	-0,0055	0,0073
Kanal-8	-0,0005	0,0008	-0,0068	-0,0154
Kanal-9	-0,0080	-0,0076	-0,0130	-0,0151
Kanal-10	0,0019	-0,0052	0,0009	0,0105
Kanal-11	-0,0030	-0,0087	-0,0072	-0,0122
Kanal-12	-0,0032	-0,0027	-0,0056	0,0028
Kanal-13	0,0022	0,0002	0,0037	-0,0112
Kanal-14	-0,0082	-0,0042	-0,0105	0,0054
Kanal-15	0,0048	0,0006	0,0098	0,0004
Kanal-16	-0,0059	0,0007	-0,0053	-0,0052

Varyans (Variance)

Varyans, sinyallerin ortalamadan ne kadar uzakta olduğunun ölçüsüdür:

$$\sigma^2 = \frac{\sum_{i=1}^{N}(x-\mu)^2}{N} \tag{3.58}$$

Tablo 3.5'de, 16 kanalın 4 farklı (t1, t2, t3, t4) zamandaki varyans değerleri hesaplanarak toplam 16x4 = 64 özellik bulunmuştur.

Tablo 3.5: Her bir kanalın varyans özellik değerleri.

Kanallar	t1. Varyans Değeri	t2. Varyans Değeri	t3. Varyans Değeri	t4. Varyans Değeri
Kanal-1	66,9949	91,8277	88,7976	94,2398
Kanal-2	7,4636	10,8948	13,1516	13,4303
Kanal-3	1,7420	1,87751	1,7916	3,2500
Kanal-4	7,1708	8,5800	7,7574	9,9205
Kanal-5	3,0616	2,5602	2,7469	3,3080
Kanal-6	8,6354	10,0618	9,5552	10,9424
Kanal-7	7,2263	8,0079	8,5141	14,1396
Kanal-8	21,7934	25,3249	24,5627	32,0955
Kanal-9	14,0086	12,9893	11,2375	18,4904
Kanal-10	16,3285	16,1656	13,8155	20,9403
Kanal-11	11,8157	15,1402	16,9232	11,5784
Kanal-12	5,8332	6,7538	6,9894	9,6048
Kanal-13	5,5045	5,1743	5,3607	6,1077
Kanal-14	17,6998	18,3570	18,2192	20,1465
Kanal-15	8,7290	7,50831	6,7359	11,8943
Kanal-16	13,6413	14,1701	10,2688	19,9981

Standart Sapma (Standard Deviation)

Denklem 3.58'deki varyansın karekökü alınarak standart sapma değeri hesaplanmıştır. Tablo 3.6'da, 16 kanalın 4 farklı (t1, t2, t3, t4) zamandaki standart sapma değerleri hesaplanarak toplam 16x4 = 64 özellik bulunmuştur.

Tablo 3.6: Her bir kanalın standart sapma özellik değerleri.

Kanallar	t1. Standart Sapma Değeri	t2. Standart Sapma Değeri	t3. Standart Sapma Değeri	t4. Standart Sapma Değeri
Kanal-1	8,1850	9,5826	9,4232	9,7077
Kanal-2	2,7319	3,3007	3,6265	3,6647
Kanal-3	1,3198	1,3702	1,3385	1,8027
Kanal-4	2,6778	2,9291	2,7852	3,1496
Kanal-5	1,7497	1,6000	1,6574	1,8187
Kanal-6	2,9386	3,1720	3,0911	3,3079
Kanal-7	2,6881	2,8298	2,9178	3,7602
Kanal-8	4,6683	5,0323	4,9560	5,6652
Kanal-9	3,7428	3,6040	3,3522	4,3000
Kanal-10	4,0408	4,0206	3,7169	4,5760
Kanal-11	3,4374	3,8910	4,1137	3,4027
Kanal-12	2,4152	2,5988	2,6437	3,0991
Kanal-13	2,3461	2,2747	2,3153	2,4713
Kanal-14	4,2071	4,2845	4,2683	4,4884
Kanal-15	2,9545	2,7401	2,5953	3,4488
Kanal-16	3,6934	3,7643	3,2044	4,4719

Çarpıklık (Skewness)

Çarpıklık, dağılımın ortalamaya göre gösterdiği asimetrinin bir ölçüsü olarak hesaplanmıştır (3.59).

$$S = \frac{\sum_{i=1}^{N} \frac{(x_i-\mu)^3}{N}}{\left(\sum_{i=1}^{N} \frac{(x_i-\mu)^2}{N}\right)^{3/2}} \tag{3.59}$$

Tablo 3.7'de, 16 kanalın 4 farklı (t1, t2, t3, t4) zamandaki çarpıklık değerleri hesaplanarak toplam 16x4 = 64 özellik bulunmuştur.

Tablo 3.7: Her bir kanalın çarpıklık özellik değerleri.

Kanallar	t1. Çarpıklık Değeri	t2. Çarpıklık Değeri	t3. Çarpıklık Değeri	t4. Çarpıklık Değeri
Kanal-1	1,1156	0,6488	0,1572	0,3482
Kanal-2	0,0241	-0,0980	-0,1331	1,6581
Kanal-3	-0,1529	-0,0380	0,0532	-4,2480
Kanal-4	0,7478	0,7017	0,1192	0,4837
Kanal-5	-0,1159	-0,1759	-0,0945	-0,5935
Kanal-6	0,7252	0,6210	0,1329	0,7556
Kanal-7	-0,0118	0,0372	0,0446	0,4815
Kanal-8	0,8229	0,6874	0,0138	0,8673
Kanal-9	0,6512	0,7551	0,0747	1,3665
Kanal-10	-0,7759	-0,7913	-0,0153	-0,7439
Kanal-11	0,0434	0,0365	-0,0197	0,3462
Kanal-12	-0,0819	-0,0463	-0,0125	-3,8627
Kanal-13	-0,0245	-0,0122	0,0353	-0,6189
Kanal-14	0,1109	0,0556	-0,0138	-0,8297
Kanal-15	-0,1459	-0,0948	-0,0998	-3,4915
Kanal-16	0,9284	1,1137	0,1843	0,9102

Basıklık (Kurtosis)

Basıklık, dağılımın normal bir dağılıma göre dik veya yatay oluşunun bir ölçüsüdür. Yani yüksek basıklık oranına sahip bir dağılım ortalama yakınında sivri bir tepe oluştururken düşük basıklık değerine sahip dağılım ise daha yatay bir tepe meydana getirir:

$$K = \frac{\sum_{i=1}^{N} \frac{(x_i-\mu)^4}{N}}{\left(\sum_{i=1}^{N} \frac{(x_i-\mu)^2}{N}\right)^2} - 3 \tag{3.60}$$

Tablo 3.8'de, 16 kanalın 4 farklı (t1, t2, t3, t4) zamandaki basıklık değerleri hesaplanarak toplam 16x4 = 64 özellik bulunmuştur.

Tablo 3.8: Her bir kanalın basıklık özellik değerleri.

Kanallar	t1. Basıklık Değeri	t2. Basıklık Değeri	t3. Basıklık Değeri	t4. Basıklık Değeri
Kanal-1	20,0529	8,8027	4,5712	65,1958
Kanal-2	8,5481	5,2478	3,1647	689,6521
Kanal-3	4,1783	3,8151	3,2082	1391,9479
Kanal-4	15,2853	8,8501	4,6842	18,3339
Kanal-5	5,0076	5,0305	3,8725	109,8112
Kanal-6	14,2484	9,0613	4,8451	16,3773
Kanal-7	3,9866	3,5492	3,3646	1736,4883
Kanal-8	17,3409	9,7299	3,9985	118,5847
Kanal-9	11,5097	10,3192	3,6647	32,6950
Kanal-10	14,2226	12,2871	3,8740	17,4779
Kanal-11	4,1176	4,0388	3,7407	12,2717
Kanal-12	3,6132	3,4186	3,3864	1622,6179
Kanal-13	3,634	3,6714	3,4743	190,56120

Kanal-14	5,0489	4,9033	4,1374	177,1993
Kanal-15	3,4028	3,3934	3,3994	596,9840
Kanal-16	22,3869	16,3926	6,0195	21,6785

Entropi

Entropi (Denklem 3.61), başta sinyal işlemede olmak üzere birçok alanda kullanılan yaygın bir kavramdır (Phung ve diğ., 2014).

Entropi: E(0) = 0

$$E(s) = \sum_i E(s_i) \tag{3.61}$$

Shannon Entropisi:

$$E1(s_i) = s_i^2 \log(s_i^2) \tag{3.62}$$

$$E1(s) = -\sum_i s_i^2 \log(s_i^2) \tag{3.63}$$

Burada, s sinyali ve (s_i) i. ortonormal bazda s katsayısını göstermektedir.

Enerji

Enerji bağıntısı Denklem 3.64'de verilmiştir.

$$E3(s) = \sum_i \log(s_i^2) \tag{3.64}$$

Burada log(0) = 0 seçilmelidir.

Bu çalışmada Entropi ve Enerji özellik çıkarım yöntemleri, AKD ile BBA yöntemlerinin karşılaştırılmasında kullanılmıştır. Entropi ve Enerjinin kullanımı EEG'de çıkan sorunlar Bölüm 3.4.7'de ayrıntılı olarak açıklanmıştır.

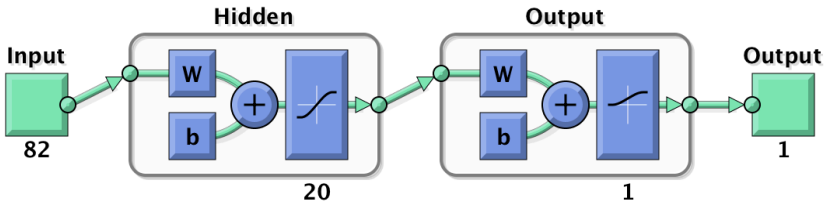
3.4.7. EEG'de Karşılaşılan Sorunlar

EEG analizi yapılırken çalışmanın ilk aşamalarında AKD ile istatistiksel özelliklerin çıkarımı için t zamanda hesaplama yapılmıştır. Ortalama, varyans, standart sapma, basıklık, çarpıklık, entropi ve enerjinin t zamanda hesaplanması verinin sınıflandırma başarımını etkilemiştir. İlk

aşamada kanal mesafe hesabında olasılık (probability) yöntemi kullanılmıştır. Tek bir zamandan hesaplanan AKD 'nin olumsuz yansımasıyla sınıflandırma kısmında iyi bir başarım elde edilmeyişi çalışmanın seyrini değiştirmiştir.

Çalışmanın ilk aşaması olan EEG analizinde BBA ve AKD yöntemleri ile yapılan istatistiksel (ortalama, varyans, standart sapma, basıklık, çarpıklık, entropi ve enerjinin) özellik çıkarım sınıflandırılma başarımları karşılaştırılmıştır. Bu amaçla, 108 örnek set kullanılarak 82 özellikli 2 çıkışlı bir yapay sinir ağı oluşturulmuştur. Toplam 120 veri setinin BAG verilerinin MR görüntülerinde uyuşmazlık olması nedeniyle, içinden seçilen 108 örnek sete düşürülmüştür. Seçilen 108 örneğin %70'i Eğitim (1x76), %15'i Doğrulama (1 x 16), %15'i Test (1x16) olarak bölünmüştür. Ağ yapısı 82 girişli (özellik vektörüne sahip); 2 çıkışlı (Epilepsi- Sağlıklı) olarak tasarlanmıştır. Ağın eğitimi, Neural Network Pattern Recognition Tool (Matlab) kullanılarak gerçekleştirilmiştir.

Şekil 3.27'de görüldüğü gibi, 2 katmanlı ağ sistemi bilgi girişi, gizli (ara) katman, çıktı katmanı ve çıkıştan oluşmaktadır. Gizli katmanda aktivasyon fonksiyonu olarak sigmoid kullanılmıştır. Katmanlar arası ileri ve geri yayılım geçişleri bulunur. İleri yayılım safhasında, ağın çıktısı ve hata değeri hesaplanır. Geri yayılım safhasında ise hesaplanan hata değerinin minimize edilmesi için katmanlar arası bağlantı ağırlık değerleri güncellenir. En küçük kareler algoritmasının genelleştirilmesi olan geri yayılım (back propagation) öğrenme algoritması kullanılır. Ağ yapısında eğitim, doğrulama ve test verileri rasgele seçilmiştir.

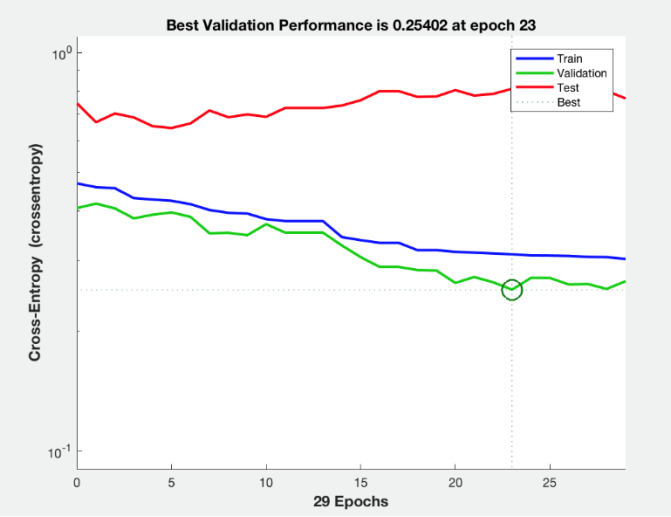


Şekil 3.27: Yapay sinir ağ yapısı.

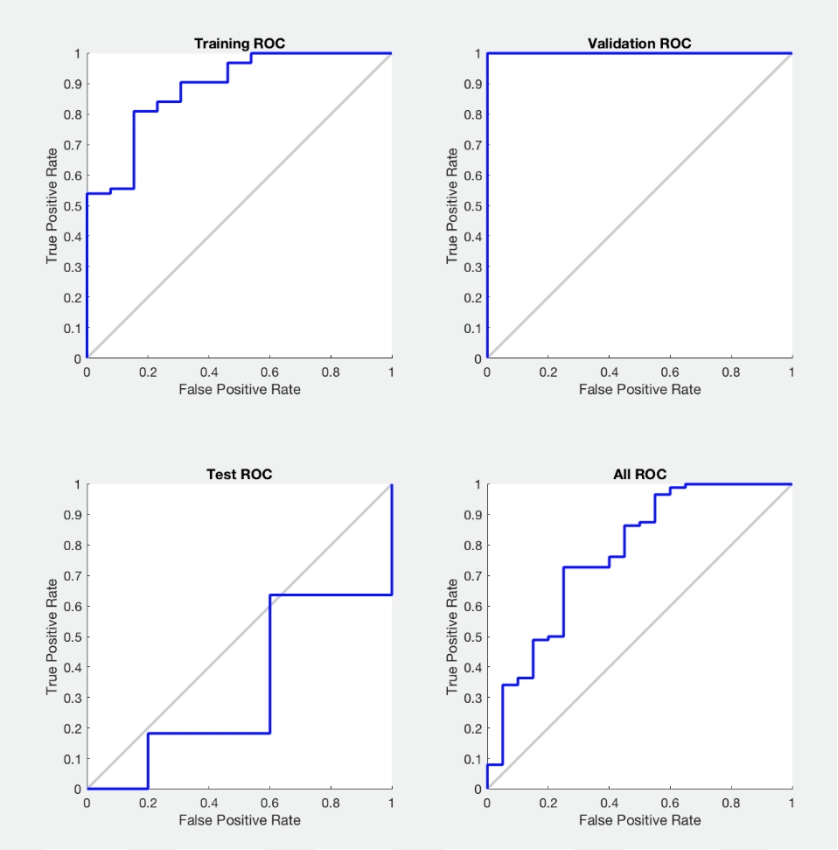
3.4.7.1. Bağımsız Bileşenler Analizi Yapay Sinir Ağ Sonuçları



Şekil 3.28: BBA matris doğruluk oranları.



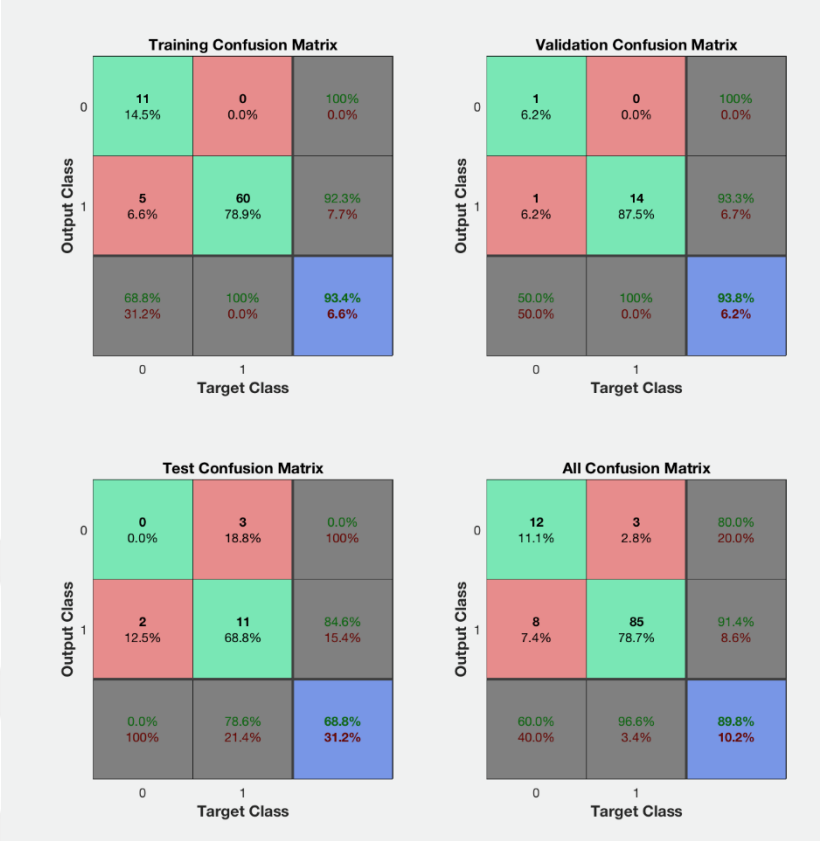
Şekil 3.29: Ağın başarımı.



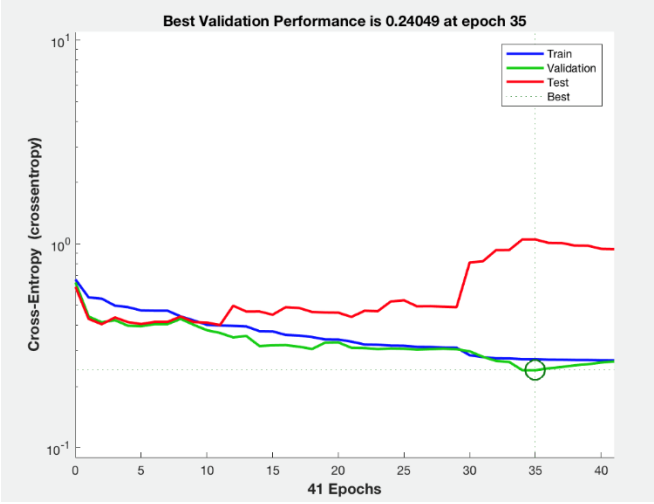
Şekil 3.30: ROC (Receiver Operating Characteristic) eğrileri.

Doğru pozitif oran hassasiyeti, yanlış pozitif oran (1-kesinlik) gösterir. Doğrulama eğrisine bakılarak, bu probleme ait hassasiyet ve kesinliğin oranının yüksek olduğu ve ağın iyi bir performans gösterdiği söylenebilir.

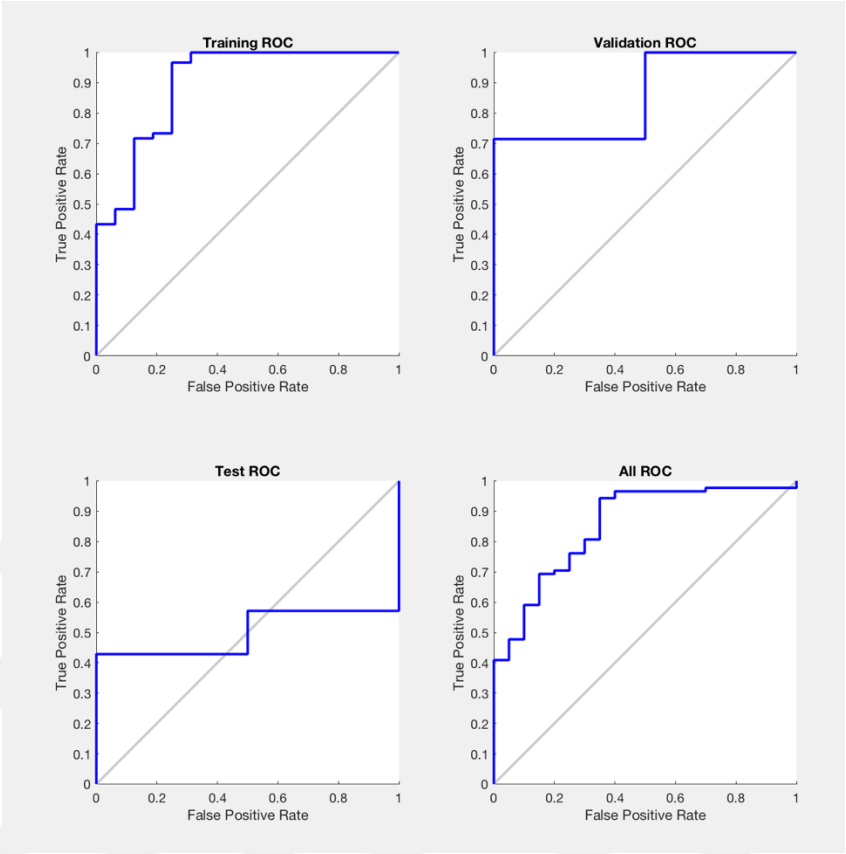
3.4.7.2. Ayrık Kosinüs Dönüşümü Yapay Sinir Ağ Sonuçları



Şekil 3.31: AKD matris doğruluk oranları.



Şekil 3.32: Ağın başarımı.



Şekil 3.33: ROC (Receiver Operating Characteristic) eğrileri.

EEG verisine BBA (Bağımsız Bileşenler Analizi-ICA) ve AKD (Ayrık Cosinüs Dönüşümü) yöntemleri kullanılarak ayrı ayrı Yapay Sinir Ağlarıyla sınıflandırma yapılmıştır. Sınıflandırma sonuçları Tablo 3.9'da gösterilmiştir. Ayrık Kosinüs Dönüşümü eğitim doğruluk oranı ve ağın performansı durumlarında daha başarılı sonuçlar vermiştir.

Tablo 3.9: YSA sınıflandırma performansları.

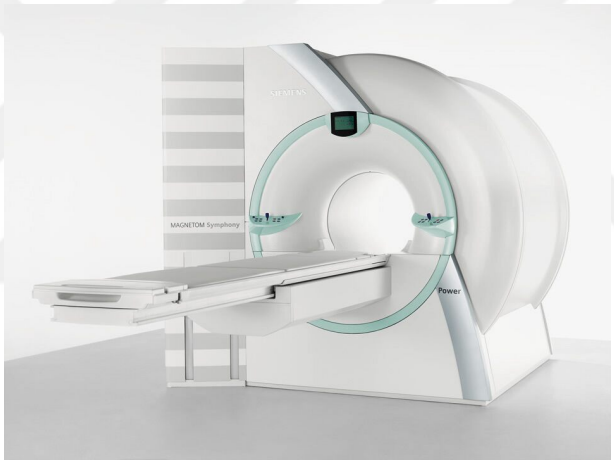
Yöntem	Ağın Performansı	Eğitim Doğruluk Oranı	Doğrulama Doğruluk Oranı	Test Doğruluk Oranı	Genel Doğruluk Oranı	İşlem Sayısı
BBA	0.30	%88.2	%93.8	%68.8	%86.1	29
AKD	**0.26**	**%93.8**	%93.8	%68.8	**%89.8**	41

AKD'nin matris doğruluk başarısının istenilen şekilde olmaması sebebiyle, özellik vektörüne özellik seçim algoritmaları uygulanarak AKD özellik kümesinden sınıflandırma başarımı en yüksek özellikler seçilmiştir.

3.5. MRG ANALİZİ YÖNTEMİ

3.5.1. Malzeme

Bolu Abant İzzet Baysal Üniversitesi Nöroloji Bölümünde Epilepsi teşhisi konmuş hastaların ve sağlıklı kişilerin bir listesi çıkarılarak önce EEG (Elektroensefalografi)'leri kaydedildi. Daha sonra Radyoloji Bölümünde Epilepsi teşhisi konmuş hastaların ve sağlıklı kişilerin 1.5 Tesla Siemens Magnetom Senfoni tarayıcısı (Şekil 3.34) ile çekilmiş olan MRG (Manyetik Rezonans Görüntüleme)'leri ayrı ayrı CD'ye aktarıldı. 103 epilepsi hastasının EEG verisine karşılık MRG verisi olmayan hastaların da bulunması nedeniyle sayıda değişiklik olmuştur. Veri okumayı kolaylaştırıp pratik hâle getirebilmek için bilgisayarda oluşturulan hasta ve sağlıklı klasörüne bu datalar aktarıldı.



Şekil 3.34: 1.5 Tesla Siemens Magnetom Senfoni Tarayıcı (Siemens, 2009).

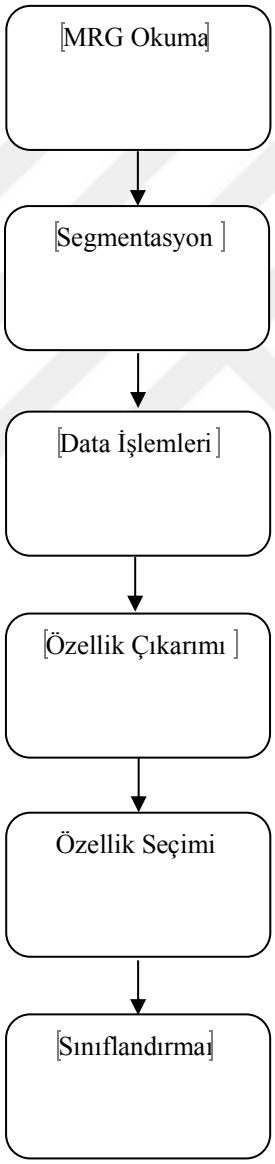
Alınan MRG datalarının formatı DICOM'dur. DICOM (Digital Imaging and Communications in Medicine) medikal görüntüleme cihazlarından alınan 2 ve 3 boyutlu bilimsel verilerin depolanması, görüntülenmesi ve analizinde kullanılmak maksadıyla geliştirilmiş olan digital veri formatı standardına verilen bir addır.

Nöroloji bölümünden edinilen bilgiler doğrultusunda, MRG'da normal ve anormal beyin dokusunun farklı yönlerini vurgulayan birçok nabız dizisi mevcuttur. Anatomik görüntüler, tekrar süresi (TR) ve eko zamanı (TE) gibi dizi parametrelerini değiştirerek farklı veri türleri elde edilmesini sağlar. Elde edilen sıralama türleri: T1, T2 ve PD'dir. Bunlardan T2 türünden epilepsi hastalarının teşhisi konulurken yararlanılmaktadır.

Matlab ortamında dicom formatında okuma işlemi yapılırken bazı kişilerin datasında uygun T2 MRG'ları segmentasyon edilememiş, bu nedenle hasta MRG sayısı 103'ten 88'e düşmüştür.

3.5.2. Yöntem

Şekil 3.35'de, MRG verisinin ilk incelenmeden sınıflandırma adımına kadar olan aşamaları gösterilmektedir.



Şekil 3.35: MRG akış şeması.

3.5.3. Veri Okuma

Matlab'de MRG, dicom formatında MRG klasöründen okunur. Orijinal MRG 384x306'lık bir matristen oluşmaktadır (orijinal MRG Şekil 3.36'da görülmektedir).

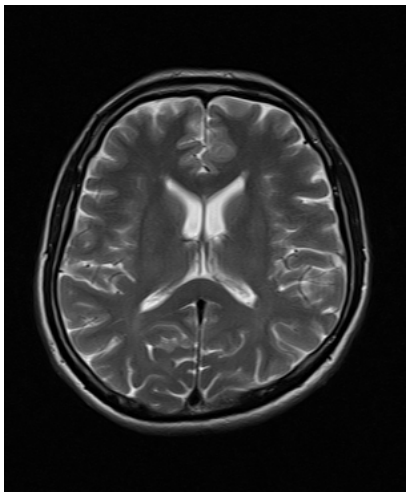
3.5.4. Segmentasyon

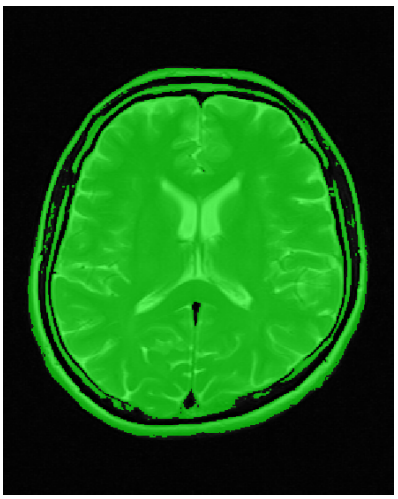
Görüntü segmentasyonunun amacı; pikselleri belirgin görüntü bölgelerine, yani ayrı ayrı yüzeylere, nesnelere veya bölgelere kümelemektir. Literatürde görüntü segmentasyonu bölge (alan) tabanlı, eşikleme, kenar algılama, özellik bazlı model bazlı veya bu tekniklerin herhangi bir kombinasyonu şeklinde olabilir. Çoğu segmentasyon tekniği, alan tabanlı veya kenar tabanlıdır. Bu çalışmada alan tabanlı segmentasyon yöntemi kullanılmıştır.

Alan Tabanlı (Region Based) segmentasyon yöntemi, komşu piksellerinin ortak yoğunluk değerlerine göre kümelenmesi mantığına dayanır. Bu algoritmanın amacı bölgeleri anatomik ve işlevlerine göre gruplamaktadır (Gumaste ve Jadhav, 2015). Chaudhari ve Kulkarni (2013) gri seviye ile birlikte ortaya çıkış matrisine dayalı dokusal özellikler kullanarak MRG görüntülerinin bölümlenmesini önermişlerdir.

Doku, bir görüntüdeki nesneleri veya bölgeyi belirlemede kullanılan en önemli özelliklerden biridir. Doku özellikleri, doku özelliklerini geliştirme adına önemli olan farklılıkları görebilmek için faydalı bilgiler taşır. Görüntüdeki doku bilgisi çeşitli açısal ilişkilerden ve komşu pikseller arası mesafeden hesaplanan gri ton uzamsal matrisi ile belirlenir. Ve bu özellikler, açısal en yakın komşu gri ton uzamsal matrislerinden türetilir. Eş-oluşum matrisi dört parçaya ayrılır ve her bir parçanın arka plan ile ön plan arasındaki eşik değeri hesaplanır. Eşik değerini belirlemek için skalar çizim elde edilir.

Matlab'deki segmentasyon aracı kullanılıp orijinal resim ortama yüklenir ve Region Based yöntemi seçilerek segmentasyon işlemi yapılır. Segmentasyon yapılmış MRG Şekil 3.37'tedir.

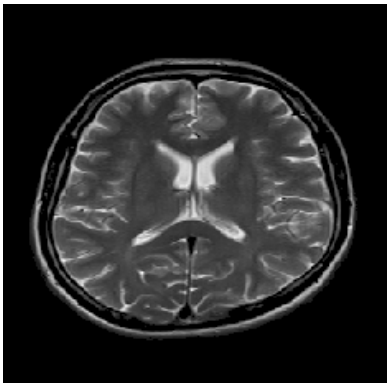


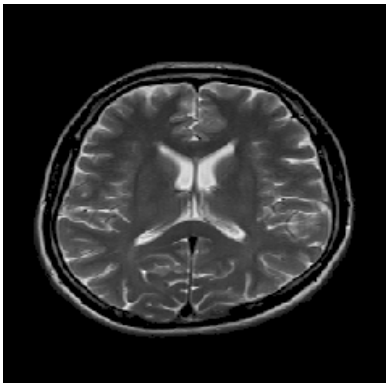


Şekil 3.36: Orijinal MRG. **Şekil 3.37**: Segmentasyon (Demirezen-Yagmur & Sertbas, 2018).

3.5.5. Veri Ön İşlemleri

Segmentasyon sonucunda elde edilen matrisler MaskedImage olarak kaydedilir. MRG verisinin boyutu 384x306'lık matristen 240x240'lık matrise dönüştürülüp yeniden boyutlandırma yapılır (boyutlandırılmış MRG Şekil 3.38'dedir). Boyutlandırılmış MRG matrisleri 0 ile 999 aralığında değerlerdir. Bu değerler 0 ile 1 arasındaki değerlere dönüştürülerek normalizasyon yapılmış olur. Boyutlandırılmış matris (136, 148, 168, ...) bu aralıktan gri seviyeye çevrilerek (0.1401, 0.1524, 0.1730, …) normalizasyon yapılır. Normalizasyon yapılmış MRG Şekil 3.39'dadır.





Şekil 3.38: Boyutlandırma.

Şekil 3.39: Normalizasyon.

3.5.6. Özellik Çıkarımı

Normalizasyon yapılmış MRG'da 240x240'lık matris verisi büyük boyutlu bir bilgi anlamına gelir. Bu nedenle uygun bir özellik çıkarım yöntemi kullanılarak daha düşük boyutlu bir veri

elde edilmesi gereklidir. Literatürde en çok bilinen özellik çıkarımı yöntemlerinden '4. Özellik Çıkarımı' bölümünde detaylı olarak bahsedilmiştir.

Bu yöntemlerden 3.1. nolu başlıkta 'Dönüştürülmüş Yapısal Özellikler' grubunun alt maddelerinden olan iki tanesi kullanılmıştır. Bunlar, 'Ayrık Kosinüs Dönüşümü (Discrete Cosine Transform- AKD)' ve 'Ortalama (Mean)' yöntemleridir. MRG datalarına ayrı ayrı AKD ve Ortalama yöntemi uygulanmış; en yüksek sınıflandırma başarısı iki yöntemin birleştirildiği AKD_Ortalama yönteminde elde edilmiştir. Bu kısımda AKD_Ortalama olarak birleştirilmiş olan yöntem incelenmiş ve bu yöntemlerin karşılaştırılması '3.5.7.MRG'de karşılaşılan sorunlar başlığı altında verilmiştir.

3.5.6.1. 2B Ayrık Kosinüs Dönüşümü

MRG verisine ön işlemler yapılıp segmentasyon ve normalizasyon gerçekleştirildikten sonra 2B (boyutlu) Ayrık Kosinüs Dönüşümü olan 3.65 numaralı denklem uygulanarak özellik çıkarımı yapılmıştır.

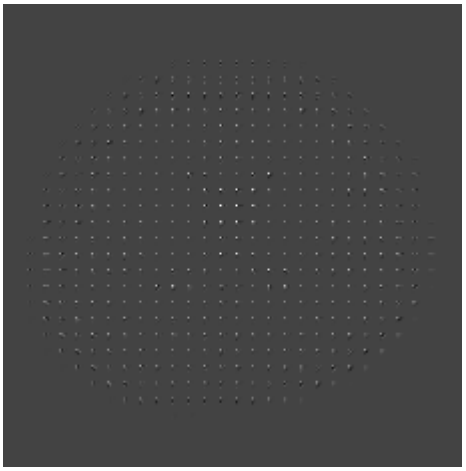
$$F(u,v) = C(u)\,C(v)\sum_{x=0}^{N-1}\sum_{y=0}^{M-1} f(x,y)\,cos\left[\frac{\pi(2x+1)u}{2N}\right]\,cos\left[\frac{\pi(2y+1)v}{2N}\right] \qquad (3.65)$$

$$u = 0,1,\dots N-1\ v = 0,1,\dots M-1\ e\ kadar$$

$$u,v = 0\ iken\ C(u), C(v) = \sqrt{\frac{1}{N}}$$

$$u,v \neq 0\ iken\ C(u), C(v) = \sqrt{\frac{2}{N}}$$

Ayrık Kosinüs Dönüşümü uygulandıktan sonra AKD katsayıları elde edilmiş olur. MRG üzerinde bu katsayıların gösterimi Şekil 3.40'dadır.



Şekil 3.40: AKD katsayıları.

3.5.6.2. Ortalama

Ortalama, serideki tüm eleman sayıların toplamının seriye ait eleman sayısına bölünmesiyle hesaplanır. Aritmetik ortalama "ortalama" olarak anılır (Abramowitz ve Stegun, 1972). Bir dizi değerin aritmetik ortalaması, "ortalama" veya ortalama anlamına gelen miktardır. Bir dizi örnek verildiğinde, aritmetik ortalama şu şekilde olacaktır:

$$\overline{x} = \frac{1}{N} \sum_{i=1}^{N} X_i \tag{3.66}$$

Denklemde, N resimdeki piksel sayısıdır, piksel i değeridir.

3.5.6.3. Ayrık Kosinüs Dönüşümü_Ortalama

AKD katsayılarının boyutu 240x240 pikseldir. Resimler dikey ve yatay olarak sekiz eşit, küçük parçaya bölünür. 64 alt bölüm elde edilir. Alt bölümün her boyutu 30x30 pikseldir. Her alt bölüm için, aritmetik ortalama hesaplanır. Özellik vektörünün boyutu 64'tür (Demirezen-Yagmur & Sertbas, 2018).

3.5.7. MRG'de Karşılaşılan Sorunlar

DICOM formatının NIFTI'ye dönüşümü ve Kullanım Araçları: MRG verilerinin ilk incelenmesinde DICOM formatının NIFTI (Neuroimaging Informatics Technology Initiative) formatına çevrilmesinin gerekliliği, kullanıldığı araçlar (FS, SPM12, Dcm2nii) ve çıkardığı problemler aşağıda açıklanmıştır.

Çalışmanın veri okuma kısmında yaşanan bu sıkıntıdan dolayı datanın orijinal formatına tekrar dönülüp sistem üzerinde çalışmalara DICOM formatıyla devam edilmiştir.

Çalışmada NIFTI formatıyla ilgili edilen tecrübeler şunlardır:

Bu tür MRG'lerin analizinin yapılabilmesi için radiolog ve nörologların birlikte aldıkları kararla datalar NIFTI formatına dönüştürülmüştür. NIFTI'nin birincil amacı, beyin görüntüleme ile ilgili bilişim araçlarının geliştirilmesini hızlandırmak ve bunlardan yararlanılmasını sağlamak için birçok araç geliştirmektir.

NIFTI data formatının özellikleri şunlardır:

- Voksel (3 boyutlu verinin hacim bilgisi) indeksi; (i, j, k) uzamsal konuma (x, y, z) ilişkin koordinat tanımları; 8-128 bit veri türleri, 1-4 boyutlu alanlar üzerinde veri kümelerinin depolanması için standartlaştırılmıştır.
- İkili dosya (.hdr ve .img) veya tek dosya (.nii) depolama alanı sağlamaktadır.

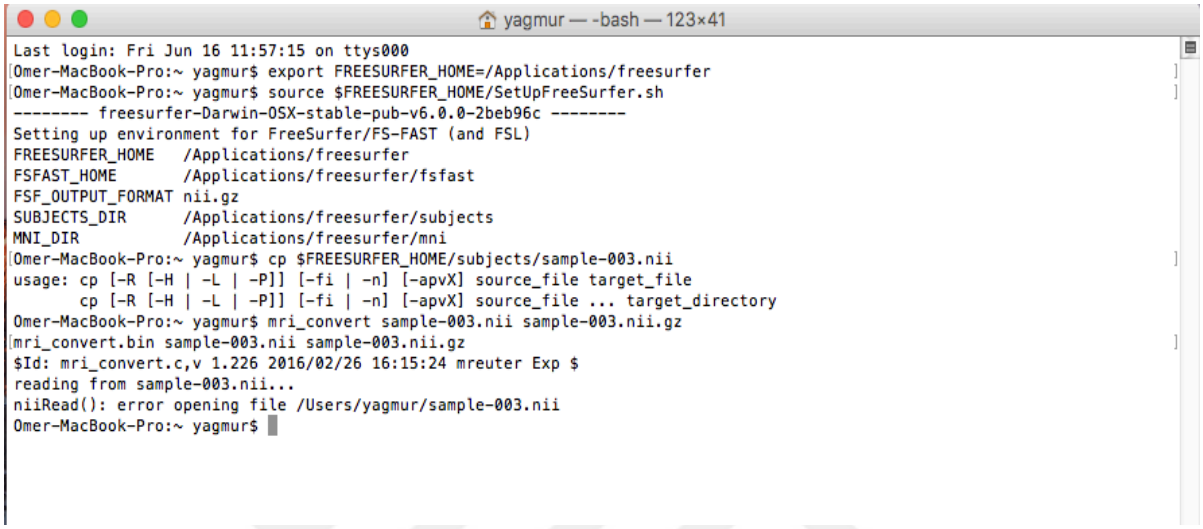
NIFTI data formatının kullanım amacı ise, fMRG veri analiz yazılımı paketleri arasındaki dosya değişim seviyesinde birlikte çalışılabilirliği geliştirmektir. Bu yazılım araçları; FS, SPM, dcm2nii'dir. Bu araçların data giriş çıkışları birbirleri arasında uyumludur.

3.5.7.1. FS (FreeSurfer) Aracı

FS, sanal makine üzerinde çalışabilen fonksiyonel görüntüleme verilerinin analizi için yaygın kullanılan yazılım araçlarından biridir. Hastane datalarını almadan önce bu yazılım aracının hazır datalarından yararlanarak işlemler yapılmıştır. Ortamda ".mgz" formatındaki datayı ".nii.gz" veya ".nii"ye dönüştürerek, MRG işlemlerinin T1 üzerinde detaylı analizinin yapılıp yapılamayacağı araştırılmıştır. FS aracı için terminal ortamında convert fonksiyonları varken DICOM datasını dönüştürme işleminde hata vermektedir. Epilepsi hastalarının teşhisinde özellikle T2 MRG 'lerine bakılıp teşhis konulduğu için datanın okunamaması nedeniyle sonuçlar analiz edilememiştir.

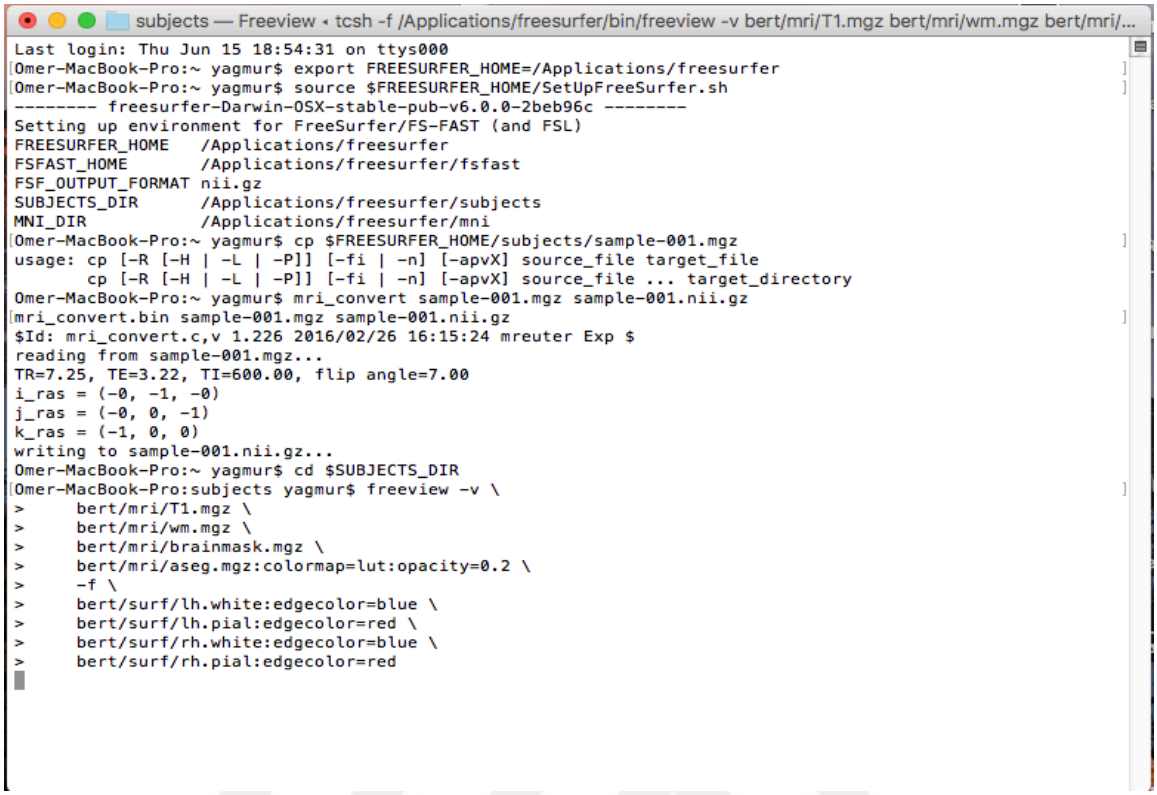
SPM12 aracı ile DICOM datası NIFTI çevrilmiş; sonuç olarak elde edilen NIFTI datasını FS aracında işleme girdirerek iki araç arasında meydana gelen sonuçların karşılaştırılması amaçlanmıştır. Fakat (program) FS içine eklenilen NIFTI datası okumada hata vemiş; bu

nedenle iki araçtaki çıkış dosyaları karşılaştırılamamıştır. Bu durum ise aşağıda Şekil 3.41'de ekran çıktısı olarak gösterilmiştir.



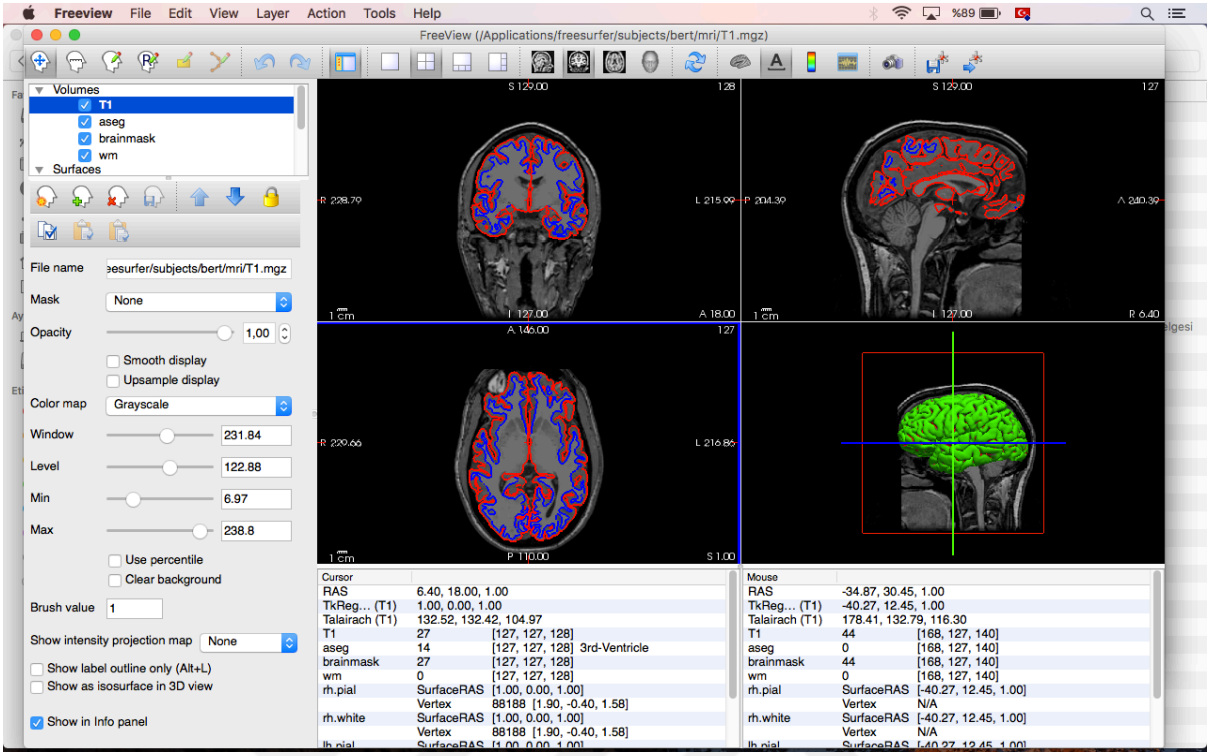
Şekil 3.41: FS-1.

Core i5 2.4 GHz DDR3 SDRAM ortamında esnek çalışma imkanının olmaması ve okunan dataların 10-20 saat arasında dönüşümünü yapabilecek derecede güçlü bir cihazın bulunmaması nedeniyle FS ortamını kullanmaktan vazgeçmek zorunda kalınmıştır. Aşağıda Şekil 3.42'de gösterilen FS aracının kendi klasöründeki örnek datalarıyla okuma ve dönüştürme işlemi yapılmış ekran çıktısıdır.



Şekil 3.42: FS-2.

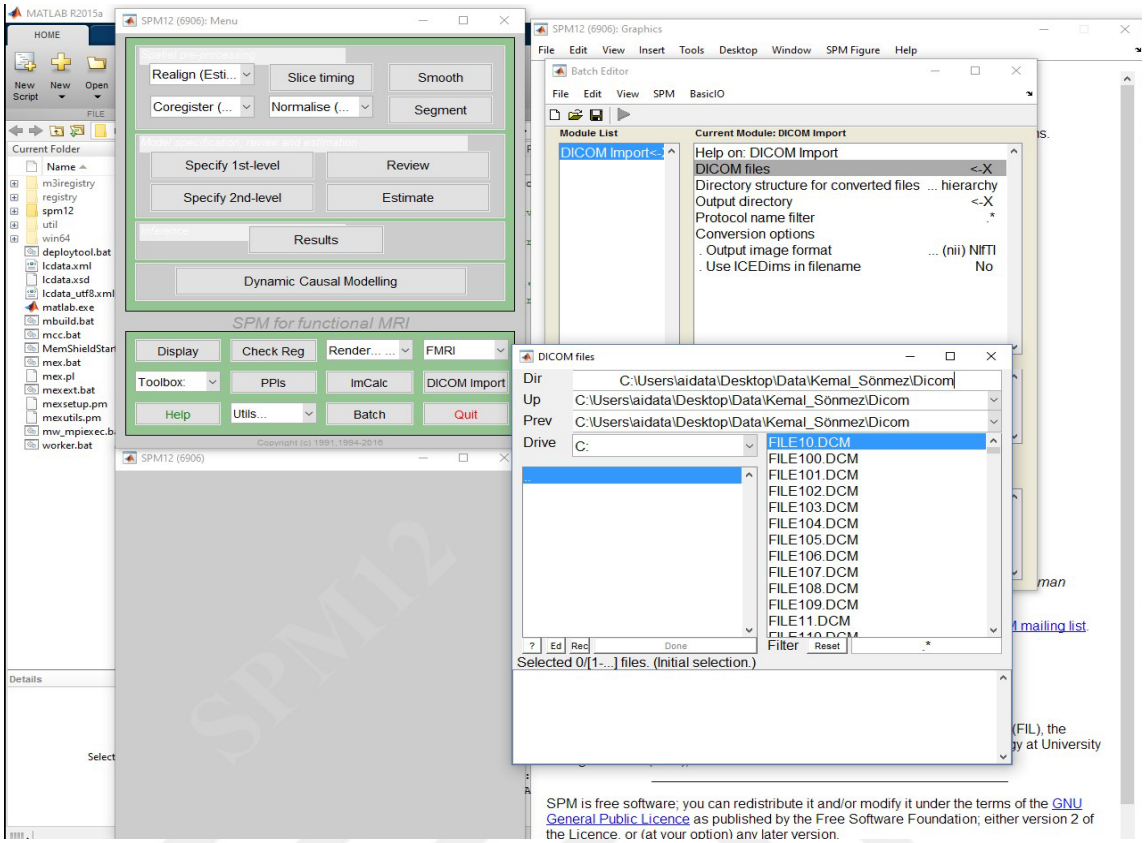
Şekil 3.43'de T1 incelemelerinin yapıldığı ve istenilen bölgenin mouse'la seçiminin yapılıp onun diğer bölgelerdeki 3 boyutlu yeri ile fonksiyonu gösterilmiştir.



Şekil 3.43: FS-3.

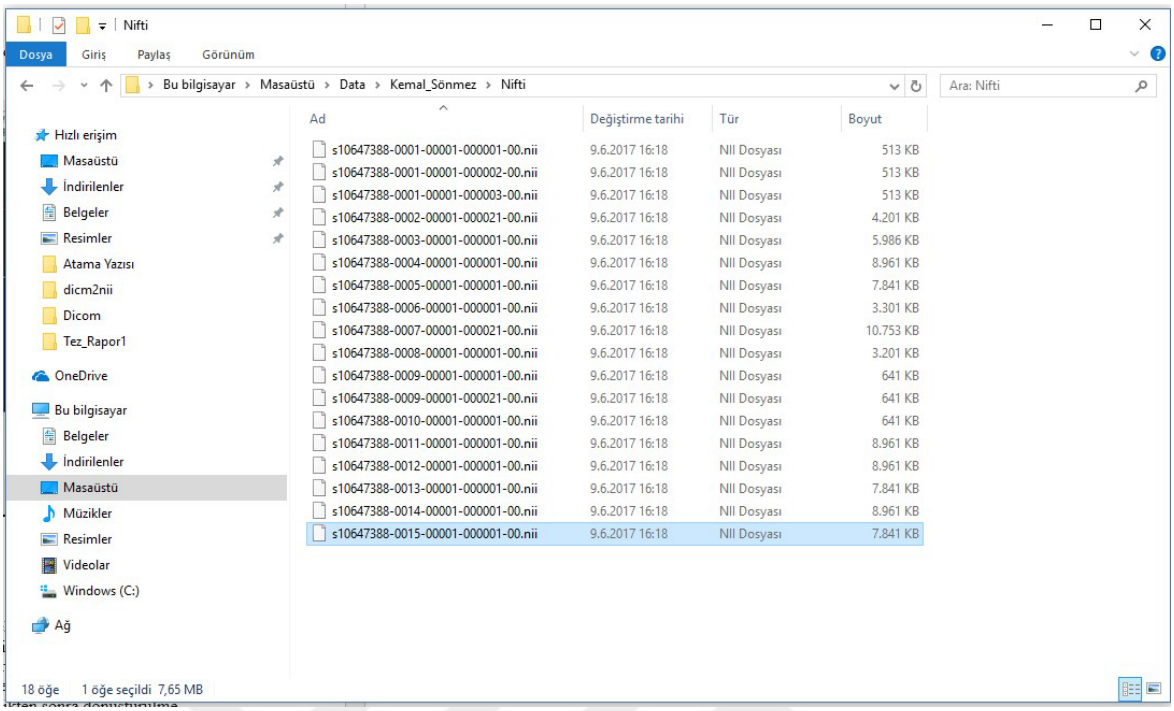
*3.5.7.2. SPM12 (***Statistical Parametric Mapping***) Aracı*

Fonksiyonel görüntüleme verilerinin analizi için istatistiksel, matematiksel ve görüntü işleme bölümlerinden oluşan akademik yazılım aracıdır. FSL ile esnek çalışılma imkanı bulunamayınca Windows tabanlı Matlab üzerinde çalışabilecek bir araç kullanılması gerekmiştir. SPM12 bu konuda kolaylık sağlamış; buraya 305 adet DICOM datası import edildikten sonra NIFTI'in hangi dosya boyutuna çevirileceği ve çıkış dosyasının yeri belirlenip dönüştürülme işlemi başlatılmıştır. Aşağıdaki Şekil 3.44'te SPM aracına DICOM datalarının import edildiği ve dönüştürme işlemlerinin yapıldığı gösterilmektedir.



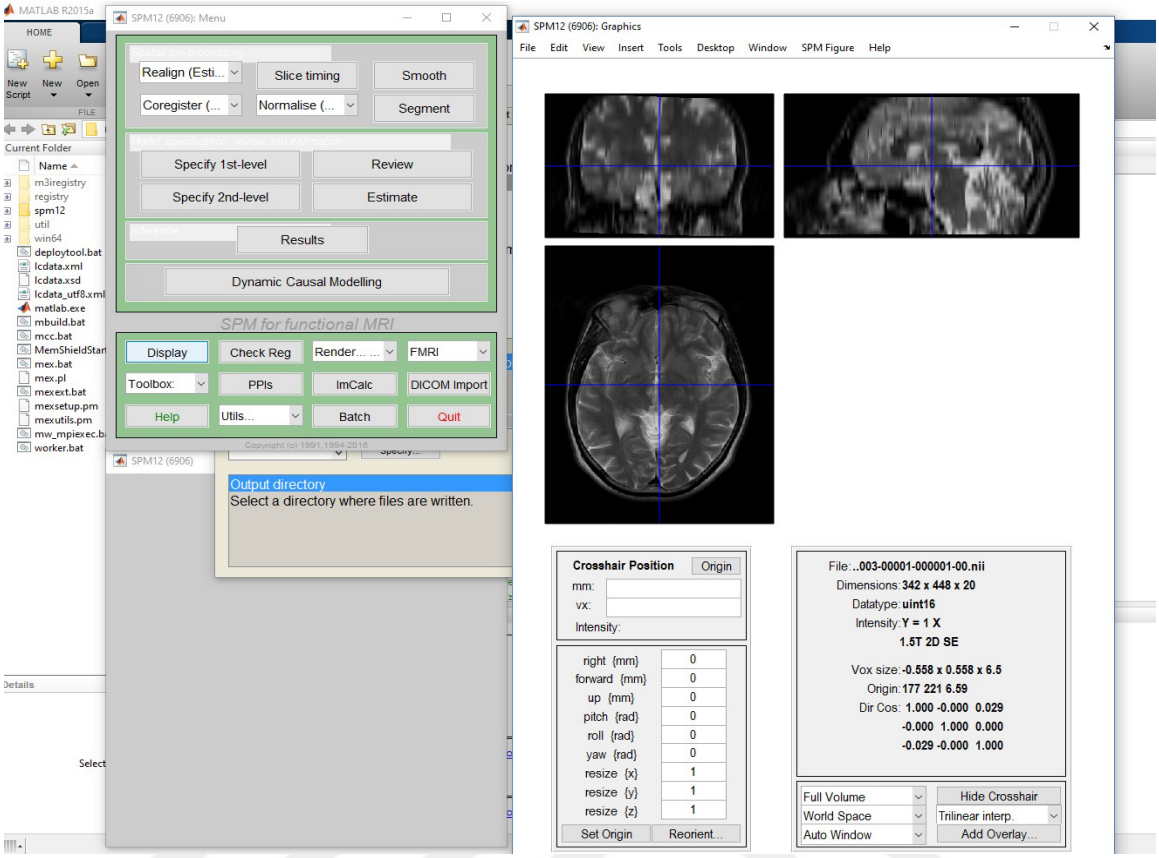
Şekil 3.44: SPM-1.

Böylelikle, Şekil 3.45'te görüldüğü gibi, 18 adet yapısal türde NIFTI datası elde edilmiştir.



Şekil 3.45: SPM-2.

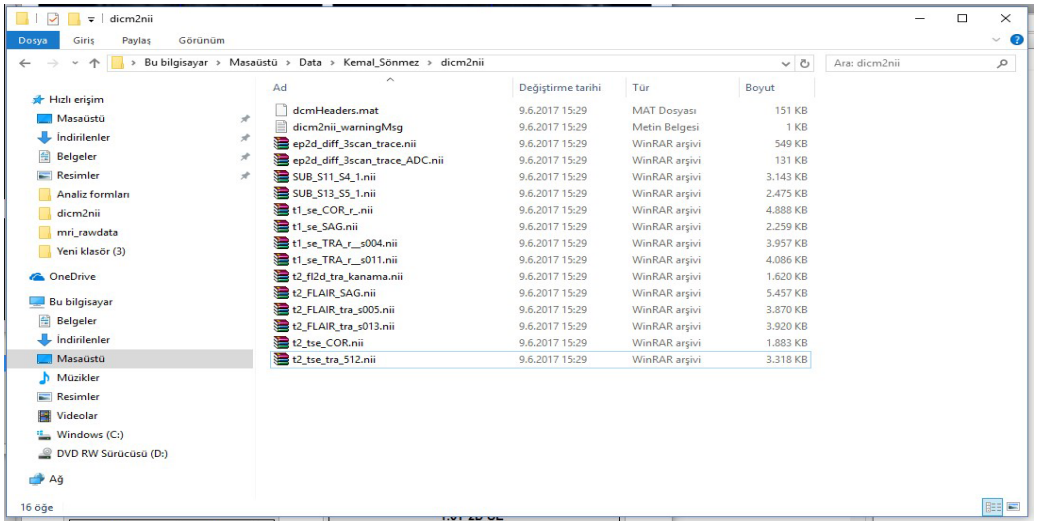
Şekil 3.46'da SPM12'nin Görüntüleme özelliği kullanılarak çevrilmiş olan data sonucu görülür.



Şekil 3.46: SPM-3

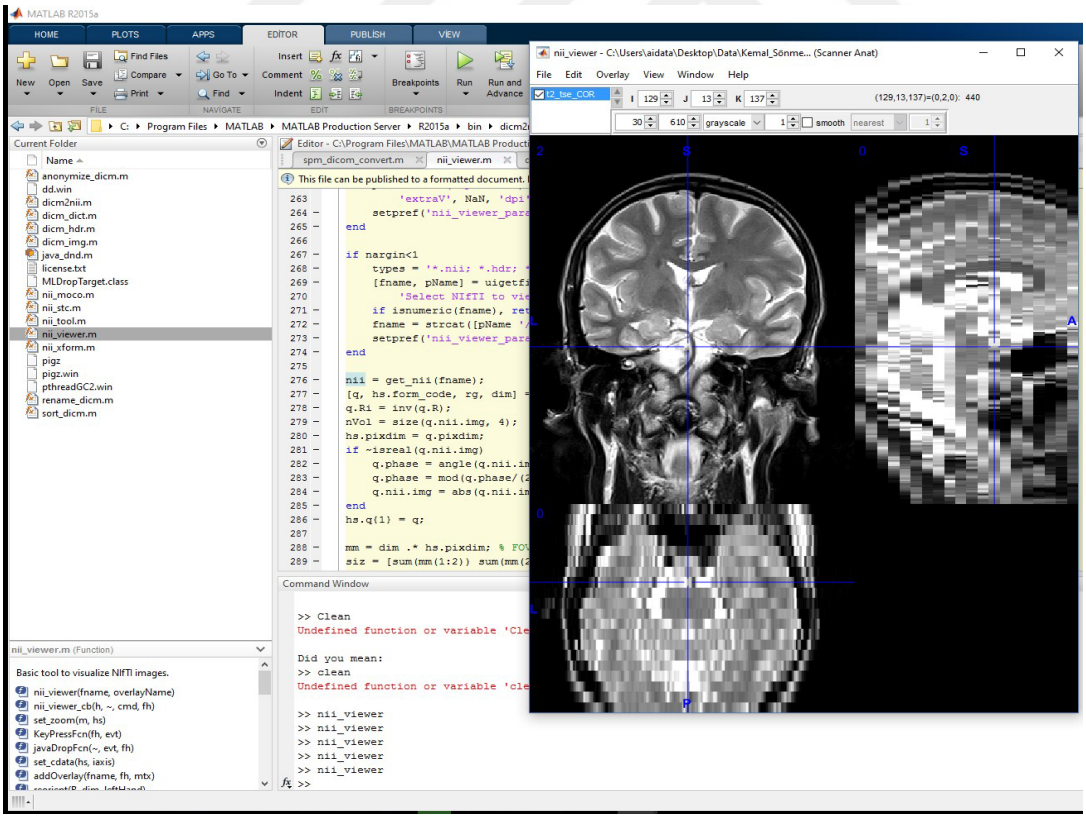
3.5.7.3. Dcm2nii

Diğer yazılım araçlarına göre daha basit foksiyonlarla işlem yapabilen bir araçtır. DICOM dataları import edildikten sonra programın dönüştüreceği dosya türü ve çıkış dosyasının yazılacağı yer belirtildikten sonra işlem başlatılır. Dcm2nii dönüşümde 305 adet DICOM verisi T1, T2 ve PD bölümlerinin başlığı altında NIFTI datasına dönüştürülmüştür. Şekil 3.47'de de görüleceği gibi '.rar' grup hâlinde dönüştürülmüş başlıklar bulunur.



Şekil 3.47: Dcm2nii-1

NIFTI datası görüntülendiğinde kontrastı daha düşük veri elde edildiği Şekil 3.48'de görülmektedir.



Şekil 3.48: Dcm2nii-2

MRG veri formatının NIFTI formatından tekrar DICOM formatına dönülmesine karar verilmiştir. Bu nedenle, NIFTI formatındaki araçların kullanılmasından vazgeçilmek zorunda kalınmıştır.

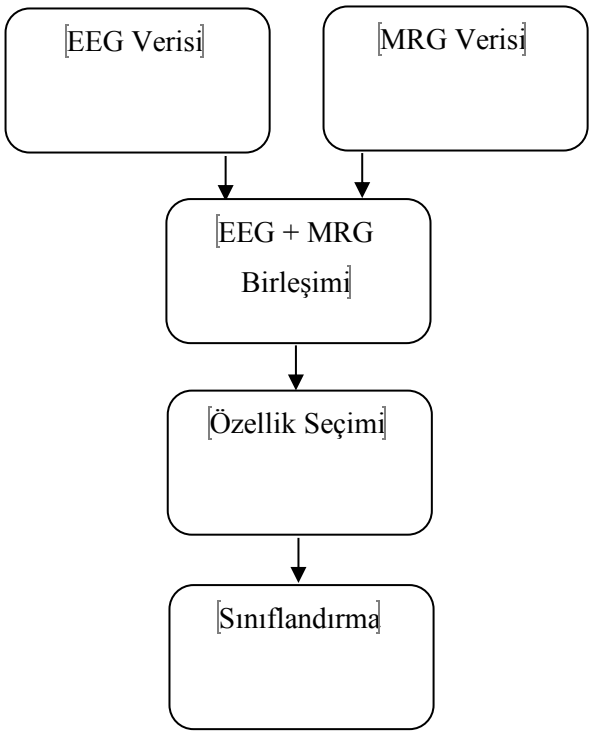
3.6. EEG VE MRG ÖZELLİK BİRLEŞİMİ YÖNTEMİ

3.6.1. Malzeme

EEG verilerine Ayrık Kosinüs Dönüşümü ile birlikte Ortalama yöntemi uygulandıktan sonra 64 özellik elde edilmişti. Aynı şekilde MRG verilerine Ayrık Kosinüs Dönüşümü ile ortalama yöntemi uygulandıktan sonra da 64 özellik elde edilmiştir. Uygulamada 1 boyutlu ve 2 boyutlu farklı boyutlardaki biyomedikal işaretler birleştirilip toplamda 128 özellikli bir veri elde edilir. 1 örneğe ait 128 özellikteki vektör hem EEG hem de MRG özelliği içerir. Çalışmamızda 108 örnekli, 128 özellikli veri seti hazırlanmıştır.

3.6.2. Yöntem

EEG ile MRG verilerinin birleşimi, özellik seçimi ve sınıflandırma akış şeması Şekil 3.49'dadır.



Şekil 3.49: EEG-MRG birleşim akışı.

4. BULGULAR

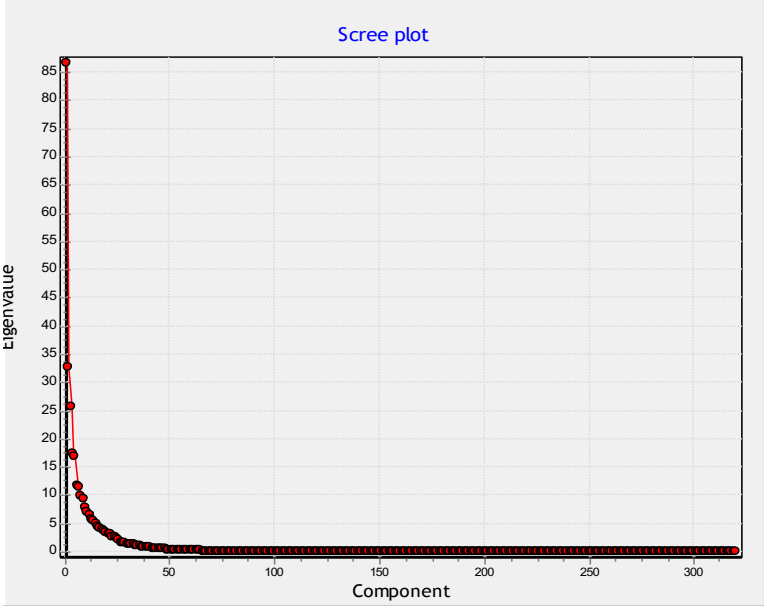
4.1. EEG'NİN DCT (AKD) İLE SINIFLANDIRMA SONUÇLARI

Çalışmamızda, EEG verisine uygulanan t zamanı dört parçaya bölünerek her bölüm için farklı istatiksel hesaplamalar yapılmıştır. Özellik olarak 64 adet ortalama, 64 varyans, 64 standart sapma, 64 adet çarpıklık, 64 adet basıklık değerleri olmak üzere, toplamda bir örneğe ait 320 özellik elde edilmiştir.

Çıkarılan bu özellik vektörlerinin sınıflandırma doğruluk derecesini artırmak için belirli özellik seçimi algoritmaları kullanılmıştır (bkz. Bölüm 3).

4.1.1. AKD'nin Temel Bileşenler Analizi (TBA) İle Sınıflandırma Sonuçları

Tanagra'da öncelikle sisteme ön işlemlerden geçirilmiş EEG verisi alınmıştır. Sonra bu verilerden, TBA yöntemi uygulanarak 320 özellik vektöründen indirgenmiş 107 özellik seçilmiştir. Seçilen özelliklerin öz değerleri (eigenvalue) Şekil 4.1'de gösterilmiştir.



Şekil 4.1: EEG'nin TBA ile seçilen özellikleri.

AKD ile çıkarılan özellikler, TBA yöntemiyle seçilen özellikler farklı yöntemlerle sınıflandırılmıştır. Veriler üzerinde 9-katmanlı çapraz doğrulama yöntemi kullanılmıştır. Tablo 4.1'de farklı sınıflandırma yöntemlerine göre doğrulama sonuçları verilmiştir.

Tablo 4.1: AKD'nin TBA ile özellik seçim yöntemine göre sınıflandırma doğruluk ve hata oranı.

Yöntem	**MLP**	**SVM**	**KNN**	**RF**
Doğruluk	%95	%81	%81	%100
Hata Oranı	0.055	0.138	0.148	0.000

4.1.1.1. YSA Sonucu

Tanagra'da (Rakotomalala, 2008) Öğreticili Öğrenme Yöntemlerinden MLP (Çok Katmanlı Algılayıcı) kullanılarak sınıflandırma yapılmıştır (Bölüm 3). Her bir özellik seçim yönteminin sonucuna göre yapılan sınıflandırma sonuçları karşılaştırılmıştır. MLP mimarisi ara katman kullanılarak tasarlanmıştır. Mimarinin giriş sayısı 320, çıkış sayısı 2, ara katmandaki nöron sayısı 10, öğrenme oranı 0,15, maksimum iterasyon sayısı 100, hata oranı 0,01 olarak ayarlanmıştır. TBA yöntemi kullanılarak seçilmiş olan özelliklerin MLP'de sınıflandırma sonuçları Tablo 4.2'de gösterilmiştir.

Tablo 4.2 (a): EEG'nin TBA-MLP ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	6	14	20
Toplam	94	14	108

b) EEG'nin TBA-MLP ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%100	%94	%96
Normal	%70	%100	%82

4.1.1.2. SVM

Tanagra'da Öğreticili Öğrenme Yöntemlerinden SVM (Destek Vektör Makineleri) kullanılarak sınıflandırma yapılmıştır. EEG sinyalinden AKD yöntemiyle çıkarılan özellikler, TBA yöntemi kullanılarak seçilmiş olan özelliklerin SVM'de sınıflandırma sonuçları Tablo 4.3'de gösterilmiştir.

Tablo 4.3 (a): EEG'nin TBA-SVM ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	15	5	20
Toplam	103	5	108

b) EEG'nin TBA-SVM ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%98	%82	%89
Normal	%5	%50	%9

4.1.1.3. KNN

Tanagra'da Öğreticili Öğrenme Yöntemlerinden KNN (K-en Yakın Komşuluk) kullanılarak sınıflandırma yapılmıştır. EEG sinyalinden AKD yöntemiyle çıkarılan özellikler, TBA yöntemi kullanılarak seçilmiş olan özelliklerin KNN'de sınıflandırma sonuçları Tablo 4.4'de gösterilmiştir.

Tablo 4.4 (a): EEG'nin TBA-KNN ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	16	4	20

Toplam	104	4	108

b) EEG'nin TBA-KNN ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%94	%96
Normal	%20	%100	%33

4.1.1.4. RF

Tanagra'da Öğreticili Öğrenme Yöntemlerinden RF (Birden fazla Karar Ağaçları) kullanılarak sınıflandırma yapılmıştır. EEG sinyalinden AKD yöntemiyle çıkarılan özellikler, TBA yöntemi kullanılarak seçilmiş olan özelliklerin RF'de sınıflandırma sonuçları Tablo 4.5'de gösterilmiştir.

Tablo 4.5 (a): EEG'nin TBA-RF ile elde edilen hata matrisi.

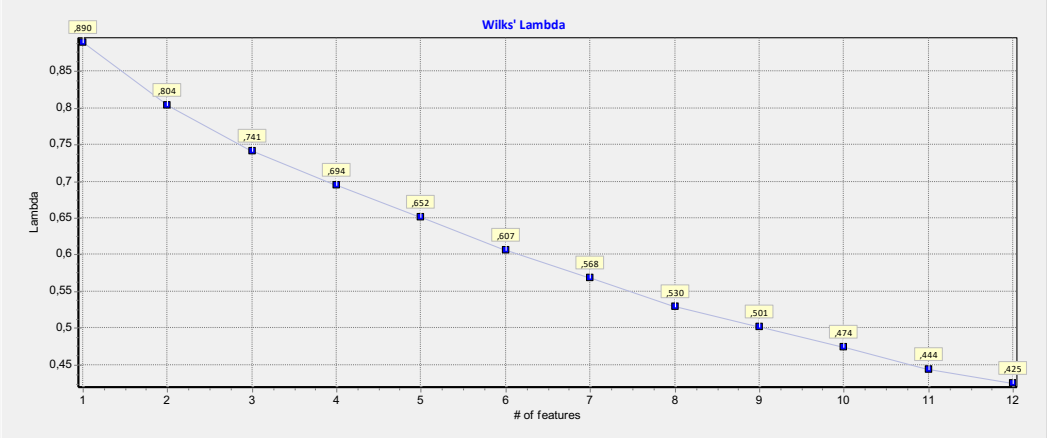
Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88
Normal	0	20	20
Toplam	88	20	108

b) EEG'nin TBA-RF ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%100	%100
Normal	%100	%100	%100

4.1.2. AKD'nin Doğrusal Ayrım Analizi (DAA)

Tanagra sistemine ön işlemlerden geçirilmiş EEG verisi alınmıştır. Ardından, Doğrusal Ayırt Edici (DAA) analizi kullanılarak özellik seçimi yapmak için stepdisc fonksiyonu uygulanmış ve 320 özellik vektöründen 12 özellik seçilmiştir (bkz. Şekil 4.2).



Şekil 4.2: EEG'nin DAA ile seçilen özellikleri.

AKD ile çıkarılan özellikler, DAA yöntemiyle seçilen özellikler farklı yöntemlerle sınıflandırılmıştır. Veriler üzerinde 9-katmanlı çapraz doğrulama yöntemi kullanılmıştır. Tablo 4.6'da farklı sınıflandırma yöntemlerine göre doğrulama sonuçları verilmiştir.

Tablo 4.6: AKD'nin DAA ile özellik seçim yöntemine göre sınıflandırma doğruluk ve hata oranı.

Yöntem	**MLP**	**SVM**	**KNN**	**RF**
Doğruluk	%92	%83	%84	%100
Hata Oranı	0.074	0.166	0.157	0.000

4.1.2.1. YSA Sonucu

Tanagra'da Öğreticili Öğrenme Yöntemlerinden MLP (Çok Katmanlı Algılayıcı) kullanılarak sınıflandırma yapılmıştır (Bölüm 3). DAA yöntemi kullanılarak seçilmiş olan özelliklerin MLP'de sınıflandırma sonuçları Tablo 4.7'de gösterilmiştir.

Tablo 4.7 (a): EEG'nin DAA-MLP ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**

Epilepsi	84	4	88
Normal	4	16	20
Toplam	88	20	108

b) EEG'nin DAA -MLP ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%95	%95	%95
Normal	%80	%80	%80

4.1.2.2. SVM

Tanagra'da Öğreticili Öğrenme Yöntemlerinden SVM (Destek Vektör Makineleri) kullanılarak sınıflandırma yapılmıştır. EEG sinyalinden AKD yöntemiyle çıkarılan özellikler, DAA yöntemi kullanılarak seçilmiş olan özelliklerin SVM'de sınıflandırma sonuçları Tablo 4.8'de gösterilmiştir.

Tablo 4.8 (a): EEG'nin DAA -SVM ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	18	2	20
Toplam	106	2	108

b) EEG'nin DAA -SVM ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%100	%83	%90
Normal	%10	%100	%18

4.1.2.3. KNN

Tanagra'da Öğreticili Öğrenme Yöntemlerinden KNN (K-en Yakın Komşuluk) kullanılarak sınıflandırma yapılmıştır. EEG sinyalinden AKD yöntemiyle çıkarılan özellikler, DAA yöntemi kullanılarak seçilmiş olan özelliklerin KNN'de sınıflandırma sonuçları Tablo 4.9'da gösterilmiştir.

Tablo 4.9 (a): EEG'nin DAA -KNN ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	87	1	88
Normal	16	4	20
Toplam	103	5	108

b) EEG'nin DAA -KNN ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%98	%84	%90
Normal	%20	%80	%32

4.1.2.4. RF

Tanagra'da Öğreticili Öğrenme Yöntemlerinden RF (Birden fazla Karar Ağaçları) kullanılarak sınıflandırma yapılmıştır. EEG sinyalinden AKD yöntemiyle çıkarılan özellikler, DAA yöntemi kullanılarak seçilmiş olan özelliklerin RF'de sınıflandırma sonuçları Tablo 4.10'da gösterilmiştir.

Tablo 4.10 (a): EEG'nin DAA -RF ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	0	20	20
Toplam	88	20	108

b) EEG'nin DAA -RF ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%100	%100
Normal	%100	%100	%100

4.1.3. AKD Çıkarımında İleriye Doğru Seçim

Tanagra'da sisteme ön işlemlerden geçirilmiş EEG verisi alınmıştır ve İleriye Doğru Seçim yöntemi kullanılarak, özellik seçimi yapmak için forward-logit fonksiyonu uygulanmıştır. Böylelikle 320 özellik vektöründen 3 özellik seçilmiştir. AKD ile çıkarılan özellikler, İleriye Doğru Seçim yöntemiyle seçilen özellikler farklı yöntemlerle sınıflandırılmıştır. Veriler üzerinde 9-katmanlı çapraz doğrulama yöntemi kullanılmıştır. Tablo 4.11'de farklı sınıflandırma yöntemlerine göre doğrulama sonuçları verilmiştir.

Tablo 4.11: AKD'nin İleriye Doğru Seçim yöntemine göre sınıflandırma doğruluk ve hata oranı.

Yöntem	MLP	SVM	KNN	RF
Doğruluk	%86	%81	%83	%99
Hata Oranı	0.138	0.185	0.166	0.009

4.1.3.1. YSA Sonucu

Tanagra'da Öğreticili Öğrenme Yöntemlerinden MLP (Çok Katmanlı Algılayıcı) kullanılarak sınıflandırma yapılmıştır (Bölüm 3). İleriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin MLP'de sınıflandırma sonuçları Tablo 4.12'de gösterilmiştir.

Tablo 4.12 (a): EEG'nin İleriye Doğru Seçim -MLP ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	85	3	88

Normal	12	8	20
Toplam	97	11	108

b) EEG'nin İleriye Doğru Seçim -MLP ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%96	%87	%90
Normal	%40	%72	%50

4.1.3.2. SVM

Tanagra'da Öğreticili Öğrenme Yöntemlerinden SVM (Destek Vektör Makineleri) kullanılarak sınıflandırma yapılmıştır. EEG sinyalinden AKD yöntemiyle çıkarılan özellikler, İleriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin SVM'de sınıflandırma sonuçları Tablo 4.13'de gösterilmiştir.

Tablo 4.13 (a): EEG'nin İleriye Doğru Seçim -SVM ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88
Normal	20	0	20
Toplam	108	0	108

b) EEG'nin İleriye Doğru Seçim -SVM ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%81	%89
Normal	%0	%0	%0

4.1.3.3. KNN

Tanagra'da Öğreticili Öğrenme Yöntemlerinden KNN (K-en Yakın Komşuluk) kullanılarak sınıflandırma yapılmıştır. EEG sinyalinden AKD yöntemiyle çıkarılan özellikler, İleriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin KNN'de sınıflandırma sonuçları Tablo 4.14'de gösterilmiştir.

Tablo 4.14 (a): EEG'nin İleriye Doğru Seçim -KNN ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	86	2	88
Normal	16	4	20
Toplam	102	6	108

b) EEG'nin İleriye Doğru Seçim -KNN ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%97	%84	%86
Normal	%20	%66	%30

4.1.3.4. RF

Tanagra'da Öğreticili Öğrenme Yöntemlerinden RF (Birden fazla Karar Ağaçları) kullanılarak sınıflandırma yapılmıştır. EEG sinyalinden AKD yöntemiyle çıkarılan özellikler, İleriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin RF'de sınıflandırma sonuçları Tablo 4.15'da gösterilmiştir.

Tablo 4.15 (a): EEG'nin İleriye Doğru Seçim -RF ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	1	19	20
Toplam	89	19	108

b) EEG'nin İleriye Doğru Seçim -RF ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%99	%99
Normal	%95	%100	%97

4.1.4. AKD Çıkarımında Geriye Doğru Seçim

Tanagra'da sisteme ön işlemlerden geçirilmiş EEG verisi alınmıştır ve Geriye Doğru Seçim yöntemini kullanılarak, özellik seçimi yapmak için backward-logit fonksiyonu uygulanmıştır. Bu durumda 320 özellik vektöründen 46 özellik seçilmiştir. AKD ile çıkarılan özellikler, Geriye Doğru Seçim yöntemiyle seçilen özellikler farklı yöntemlerle sınıflandırılmıştır. Veriler üzerinde 9-katmanlı çapraz doğrulama yöntemi kullanılmıştır. Tablo 4.16'da farklı sınıflandırma yöntemlerine göre doğrulama sonuçları verilmiştir.

Tablo 4.16: AKD'nin Geriye Doğru Seçim yöntemine göre sınıflandırma doğruluk ve hata oranı.

Yöntem	MLP	SVM	KNN	RF
Doğruluk	%91	%81	%82	%100
Hata Oranı	0.083	0.157	0.175	0.000

4.1.4.1. YSA Sonucu

Tanagra'da Öğreticili Öğrenme Yöntemlerinden MLP (Çok Katmanlı Algılayıcı) kullanılarak sınıflandırma yapılmıştır (Bölüm 3). Geriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin MLP'de sınıflandırma sonuçları Tablo 4.17'de gösterilmiştir.

Tablo 4.17 (a): EEG'nin Geriye Doğru Seçim -MLP ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	87	1	88
Normal	8	12	20

Toplam	95	13	108

b) EEG'nin Geriye Doğru Seçim -MLP ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%98	%91	%94
Normal	%60	%92	%72

4.1.4.2. SVM

Tanagra'da Öğreticili Öğrenme Yöntemlerinden SVM (Destek Vektör Makineleri) kullanılarak sınıflandırma yapılmıştır. EEG sinyalinden AKD yöntemiyle çıkarılan özellikler, Geriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin SVM'de sınıflandırma sonuçları Tablo 4.18'de gösterilmiştir.

Tablo 4.18 (a): EEG'nin Geriye Doğru Seçim -SVM ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88
Normal	17	3	20
Toplam	105	3	108

b) EEG'nin Geriye Doğru Seçim -SVM ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%83	%90
Normal	%15	%0	%0

4.1.4.3. KNN

Tanagra'da Öğreticili Öğrenme Yöntemlerinden KNN (K-en Yakın Komşuluk) kullanılarak sınıflandırma yapılmıştır. EEG sinyalinden AKD yöntemiyle çıkarılan özellikler, Geriye Doğru

Seçim yöntemi kullanılarak seçilmiş olan özelliklerin KNN'de sınıflandırma sonuçları Tablo 4.19'de gösterilmiştir.

Tablo 4.19 (a): EEG'nin Geriye Doğru Seçim -KNN ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	86	2	88
Normal	17	2	20
Toplam	102	6	108

b) EEG'nin Geriye Doğru Seçim -KNN ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%97	%83	%88
Normal	%15	%40	%20

4.1.4.4. RF

Tanagra'da Öğreticili Öğrenme Yöntemlerinden RF (Birden fazla Karar Ağaçları) kullanılarak sınıflandırma yapılmıştır. EEG sinyalinden AKD yöntemiyle çıkarılan özellikler, Geriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin RF'de sınıflandırma sonuçları Tablo 4.20'da gösterilmiştir.

Tablo 4.20 (a): EEG'nin Geriye Doğru Seçim -RF ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88
Normal	0	20	20
Toplam	88	20	108

b) EEG'nin Geriye Doğru Seçim -RF ile sınıflandırma sonucu.

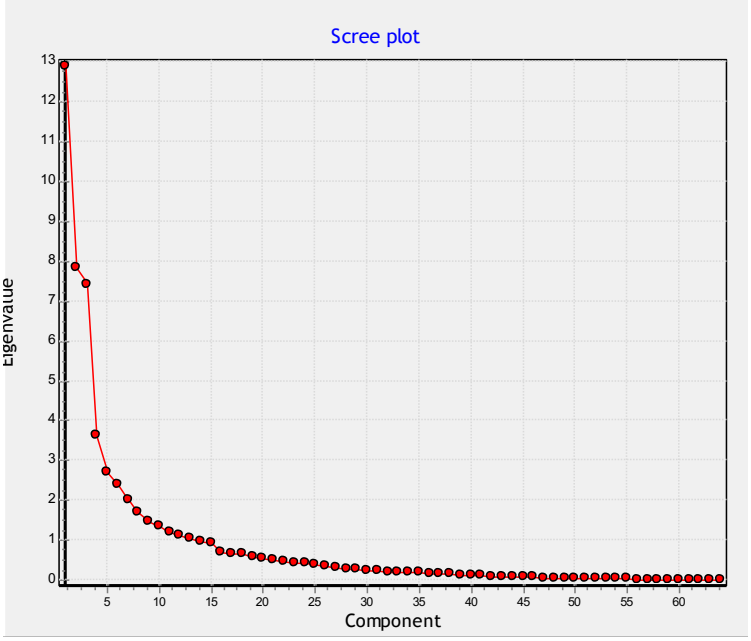
Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%100	%100
Normal	%100	%100	%100

4.2. MRG'NİN DCT (AKD) İLE SINIFLANDIRMA SONUÇLARI

AKD_Ortalama kullanılarak çıkarılan özellik vektörü 64'tür. Çıkarılan bu özellik vektörlerinin sınıflandırmada doğruluk derecesini artırmak için belli özellik seçimi algoritmaları kullanılmıştır. '3.2 Özellik Seçimi' kısmında algoritmaların teorisi detaylı olarak verilmiştir.

4.2.1. AKD'nin Temel Bileşenler Analizi (TBA) İle Sınıflandırma Sonuçları

Tanagra'da öncelikle sisteme ön işlemlerden geçirilmiş MRG verisi alınır. TBA'de sadece giriş verileri ayarlanır; hedef veri girilmez. Bileşenler kısmında faktorial analiz bölümünden TBA seçilerek işleme alınır. 64 özellik vektöründen 56 özellik seçilir. Seçilen özelliklerin öz değerleri (eigenvalue) Şekil 4.3'de gösterilmiştir.



Şekil 4.4: MRG'nin TBA ile seçilen özellikleri.

AKD ile çıkarılan özellikler, TBA yöntemiyle seçilen özellikler farklı yöntemlerle sınıflandırılmıştır. Veriler üzerinde 9-katmanlı çapraz doğrulama yöntemi kullanılmıştır. Tablo 4.21'de farklı sınıflandırma yöntemlerine göre doğrulama sonuçları verilmiştir.

Tablo 4.21: AKD'nin TBA ile özellik seçim yöntemine göre sınıflandırma doğruluk ve hata oranı.

Yöntem	MLP	SVM	KNN	RF
Doğruluk	%90	%81	%81	%100
Hata Oranı	0.092	0.185	0.185	0.000

4.2.1.1. YSA Sonucu

Tanagra'da Öğreticili Öğrenme Yöntemlerinden MLP (Çok Katmanlı Algılayıcı) kullanılarak sınıflandırma yapılmıştır (Bölüm 3). Her bir özellik seçim yönteminin sonucuna göre yapılan sınıflandırma sonuçları karşılaştırılmıştır. MLP mimarisi ara katman kullanılarak tasarlanmıştır. Mimarinin giriş sayısı 56, çıkış sayısı 2, ara katmandaki nöron sayısı 10, öğrenme oranı 0,15, maksimum iterasyon sayısı 100, hata oranı 0,01 olarak ayarlanmıştır. TBA yöntemi kullanılarak seçilmiş olan özelliklerin MLP'de sınıflandırma sonuçları Tablo 4.22'de gösterilmiştir.

Tablo 4.22 (a): MRG'nin TBA-MLP ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	87	1	88
Normal	4	16	20
Toplam	91	17	108

b) MRG'nin TBA-MLP ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%98	%95	%96
Normal	%80	%94	%86

4.2.1.2. SVM

Tanagra'da Öğreticili Öğrenme Yöntemlerinden SVM (Destek Vektör Makineleri) kullanılarak sınıflandırma yapılmıştır. MRG'de AKD yöntemiyle çıkarılan özellikler, TBA yöntemi kullanılarak seçilmiş olan özelliklerin SVM'de sınıflandırma sonuçları Tablo 4.23'de gösterilmiştir.

Tablo 4.23 (a): MRG'nin TBA-SVM ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	20	0	20
Toplam	108	0	108

b) MRG'nin TBA-SVM ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%100	%81	%89
Normal	%0	%0	%0

4.2.1.3. KNN

Tanagra'da Öğreticili Öğrenme Yöntemlerinden KNN (K-en Yakın Komşuluk) kullanılarak sınıflandırma yapılmıştır. MRG'de AKD yöntemiyle çıkarılan özellikler, TBA yöntemi kullanılarak seçilmiş olan özelliklerin KNN'de sınıflandırma sonuçları Tablo 4.24'de gösterilmiştir.

Tablo 4.24 (a): MRG'nin TBA-KNN ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	20	0	20

Toplam	108	0	108

b) MRG'nin TBA-KNN ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%81	%89
Normal	%0	%0	%0

4.2.1.4. RF

Tanagra'da Öğreticili Öğrenme Yöntemlerinden RF (Birden fazla Karar Ağaçları) kullanılarak sınıflandırma yapılmıştır. MRG'de AKD yöntemiyle çıkarılan özellikler, TBA yöntemi kullanılarak seçilmiş olan özelliklerin RF'de sınıflandırma sonuçları Tablo 4.25'de gösterilmiştir.

Tablo 4.45 (a): MRG'nin TBA-RF ile elde edilen hata matrisi.

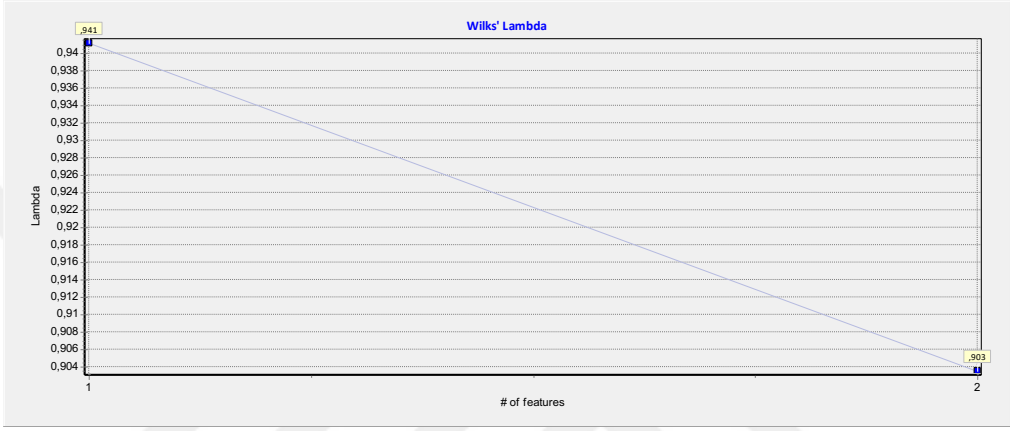
Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88
Normal	0	20	20
Toplam	88	20	108

b) MRG'nin TBA-RF ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%100	%100
Normal	%100	%100	%100

4.2.2. AKD'nin Doğrusal Ayrım Analizi (DAA)

Tanagra'da Doğrusal Ayırt Edici analizi kullanarak özellik seçimi yapmak için stepdisc fonksiyonu uygulanır. Sisteme ön işlemlerden geçirilmiş, MRG verisi alınır. Tanagra ortamında özellik ve hedef verileri ayarlanır. Daha sonra bileşenler kısmında özellik seçimi algoritmalarından stepdisc seçilerek uygulanır. Çalışmada, 64 özellik vektöründen 2 özellik seçilmiştir. Seçilen özelliklerin değerleri Şekil 4.5'de gösterilmiştir.



Şekil 4.5: MRG'nin DAA ile seçilen özellikleri.

AKD ile çıkarılan özellikler, DAA yöntemiyle seçilen özellikler farklı yöntemlerle sınıflandırılmıştır. Veriler üzerinde 9-katmanlı çapraz doğrulama yöntemi kullanılmıştır. Tablo 4.26'de farklı sınıflandırma yöntemlerine göre doğrulama sonuçları verilmiştir.

Tablo 4.26: AKD'nin DAA ile özellik seçim yöntemine göre sınıflandırma doğruluk ve hata oranı.

Yöntem	**MLP**	**SVM**	**KNN**	**RF**
Doğruluk	%81	%81	%82	%100
Hata Oranı	0. 185	0.185	0.175	0.000

4.2.2.1. YSA Sonucu

Tanagra'da Öğreticili Öğrenme Yöntemlerinden MLP (Çok Katmanlı Algılayıcı) kullanılarak sınıflandırma yapılmıştır (Bölüm 3). DAA yöntemi kullanılarak seçilmiş olan özelliklerin MLP'de sınıflandırma sonuçları Tablo 4.27'de gösterilmiştir.

Tablo 4.27 (a): MRG'nin DAA-MLP ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	85	3	88
Normal	17	3	20
Toplam	102	0	108

b) MRG'nin DDA-MLP ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%96	%83	%88
Normal	%15	%50	%22

4.2.2.2. SVM

Tanagra'da Öğreticili Öğrenme Yöntemlerinden SVM (Destek Vektör Makineleri) kullanılarak sınıflandırma yapılmıştır. MRG'de AKD yöntemiyle çıkarılan özellikler, TBA yöntemi kullanılarak seçilmiş olan özelliklerin SVM'de sınıflandırma sonuçları Tablo 4.28'de gösterilmiştir.

Tablo 4.28 (a): MRG'nin DAA-SVM ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	85	3	88
Normal	17	3	20
Toplam	102	0	108

b) MRG'nin DAA-SVM ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%96	%83	%88
Normal	%15	%50	%22

4.2.2.3. KNN

Tanagra'da Öğreticili Öğrenme Yöntemlerinden KNN (K-en Yakın Komşuluk) kullanılarak sınıflandırma yapılmıştır. MRG'de AKD yöntemiyle çıkarılan özellikler, TBA yöntemi kullanılarak seçilmiş olan özelliklerin KNN'de sınıflandırma sonuçları Tablo 4.29'da gösterilmiştir.

Tablo 4.29 (a): MRG'nin DAA-KNN ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	85	3	88
Normal	16	4	20
Toplam	101	7	108

b) MRG'nin DAA-KNN ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F_1-skor**
Epilepsi	%96	%84	%89
Normal	%20	%42	%26

4.2.2.4. RF

Tanagra'da Öğreticili Öğrenme Yöntemlerinden RF (Birden fazla Karar Ağaçları) kullanılarak sınıflandırma yapılmıştır. MRG'de AKD yöntemiyle çıkarılan özellikler, TBA yöntemi kullanılarak seçilmiş olan özelliklerin RF'de sınıflandırma sonuçları Tablo 4.30'da gösterilmiştir.

Tablo 4.30 (a): MRG'nin DAA-RF ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	0	20	20
Toplam	88	20	108

b) MRG'nin DAA-RF ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%100	%100
Normal	%100	%100	%100

4.2.3. AKD Çıkarımında İleriye Doğru Seçim

Tanagra'da İleriye Doğru Seçim yöntemini kullanılarak özellik seçimi yapmak için forward-logit fonksiyonu uygulanır. Sisteme ön işlemlerden geçirilmiş EEG verisi alınır. Tanagra ortamında özellik ve hedef verileri ayarlanır. Daha sonra bileşenler kısmında özellik seçimi algoritmalarından forward-logit seçilerek uygulanır. Çalışmada, 64 özellik vektöründen 1 özellik seçilmiştir. MRG'de AKD ile çıkarılan özellikler, İleriye Doğru Seçim yöntemiyle seçilen özellikler farklı yöntemlerle sınıflandırılmıştır. Veriler üzerinde 9-katmanlı çapraz doğrulama yöntemi kullanılmıştır. Tablo 4.31'de farklı sınıflandırma yöntemlerine göre doğrulama sonuçları verilmiştir.

Tablo 4.31: AKD'nin İleriye Doğru Seçim yöntemine göre sınıflandırma doğruluk ve hata oranı.

Yöntem	MLP	SVM	KNN	RF
Doğruluk	%81	%81	%83	%90
Hata Oranı	0.185	0.185	0.166	0.092

4.2.3.1. YSA Sonucu

Tanagra'da Öğreticili Öğrenme Yöntemlerinden MLP (Çok Katmanlı Algılayıcı) kullanılarak sınıflandırma yapılmıştır (Bölüm 3). İleriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin MLP'de sınıflandırma sonuçları Tablo 4.32'de gösterilmiştir.

Tablo 4.32 (a): MRG'nin İleriye Doğru Seçim -MLP ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88

Normal	20	0	20
Toplam	108	0	108

b) MRG'nin İleriye Doğru Seçim -MLP ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%81	%89
Normal	%0	%0	%0

4.2.3.2. SVM

Tanagra'da Öğreticili Öğrenme Yöntemlerinden SVM (Destek Vektör Makineleri) kullanılarak sınıflandırma yapılmıştır. MRG'de AKD yöntemiyle çıkarılan özellikler, İleriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin SVM'de sınıflandırma sonuçları Tablo 4.33'de gösterilmiştir.

Tablo 4.33 (a): MRG'nin İleriye Doğru Seçim -SVM ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88
Normal	20	0	20
Toplam	108	0	108

b) MRG'nin İleriye Doğru Seçim -SVM ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%81	%89
Normal	%0	%0	%0

4.2.3.3. KNN

Tanagra'da Öğreticili Öğrenme Yöntemlerinden KNN (K-en Yakın Komşuluk) kullanılarak sınıflandırma yapılmıştır. MRG'de AKD yöntemiyle çıkarılan özellikler, İleriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin KNN'de sınıflandırma sonuçları Tablo 4.34'de gösterilmiştir.

Tablo 4.34 (a): MRG'nin İleriye Doğru Seçim -KNN ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88
Normal	18	2	20
Toplam	106	2	108

b) MRG'nin İleriye Doğru Seçim -KNN ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F_1-skor
Epilepsi	%100	%83	%90
Normal	%10	%0	%0

4.2.3.4. RF

Tanagra'da Öğreticili Öğrenme Yöntemlerinden RF (Birden fazla Karar Ağaçları) kullanılarak sınıflandırma yapılmıştır. MRG'de AKD yöntemiyle çıkarılan özellikler, İleriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin RF'de sınıflandırma sonuçları Tablo 4.35'da gösterilmiştir.

Tablo 4.35 (a): MRG'nin İleriye Doğru Seçim -RF ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88
Normal	10	10	20
Toplam	98	10	108

b) MRG'nin İleriye Doğru Seçim -RF ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%89	%94
Normal	%50	%0	%0

4.2.4. AKD Çıkarımında Geriye Doğru Seçim

Tanagra'da Geriye Doğru Seçim yöntemini kullanarak özellik seçimi yapmak için backward-logit fonksiyonu uygulanır. Sisteme ön işlemlerden geçirilmiş MRG verisi alınır. Tanagra ortamında özellik ve hedef verileri ayarlanır. Daha sonra bileşenler kısmında özellik seçimi algoritmalarından backward-logit seçilerek uygulanır. Çalışmada, 64 özellik vektöründen 1 özellik seçilmiştir. AKD ile çıkarılan özellikler, Geriye Doğru Seçim yöntemiyle seçilen özellikler farklı yöntemlerle sınıflandırılmıştır. Veriler üzerinde 9-katmanlı çapraz doğrulama yöntemi kullanılmıştır. Tablo 4.36'da farklı sınıflandırma yöntemlerine göre doğrulama sonuçları verilmiştir.

Tablo 4.36: AKD'nin Geriye Doğru Seçim yöntemine göre sınıflandırma doğruluk ve hata oranı.

Yöntem	MLP	SVM	KNN	RF
Doğruluk	%81	%81	%81	%86
Hata Oranı	0.185	0.185	0.185	0.138

4.2.4.1. YSA Sonucu

Tanagra'da Öğreticili Öğrenme Yöntemlerinden MLP (Çok Katmanlı Algılayıcı) kullanılarak sınıflandırma yapılmıştır (Bölüm 3). Geriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin MLP'de sınıflandırma sonuçları Tablo 4.37'de gösterilmiştir.

Tablo 4.37 (a): MRG'nin Geriye Doğru Seçim -MLP ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam

Epilepsi	88	0	88
Normal	20	0	20
Toplam	108	0	108

b) MRG'nin Geriye Doğru Seçim -MLP ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%100	%81	%89
Normal	%0	%0	%0

4.2.4.2. SVM

Tanagra'da Öğreticili Öğrenme Yöntemlerinden SVM (Destek Vektör Makineleri) kullanılarak sınıflandırma yapılmıştır. MRG'de AKD yöntemiyle çıkarılan özellikler, Geriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin SVM'de sınıflandırma sonuçları Tablo 4.38'de gösterilmiştir.

Tablo 4.38 (a): MRG'nin Geriye Doğru Seçim -SVM ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	20	0	20
Toplam	108	0	108

b) MRG'nin Geriye Doğru Seçim -SVM ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%100	%81	%89
Normal	%0	%0	%0

4.2.4.3. KNN

Tanagra'da Öğreticili Öğrenme Yöntemlerinden KNN (K-en Yakın Komşuluk) kullanılarak sınıflandırma yapılmıştır. MRG'de AKD yöntemiyle çıkarılan özellikler, Geriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin KNN'de sınıflandırma sonuçları Tablo 4.39'da gösterilmiştir.

Tablo 4.39 (a): MRG'nin Geriye Doğru Seçim -KNN ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	20	0	20
Toplam	108	0	108

b) MRG'nin Geriye Doğru Seçim -KNN ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%100	%81	%89
Normal	%0	%0	%0

4.2.4.4. RF

Tanagra'da Öğreticili Öğrenme Yöntemlerinden RF (Rastgele Orman -Birden fazla Karar Ağaçları) kullanılarak sınıflandırma yapılmıştır. MRG'de AKD yöntemiyle çıkarılan özellikler, Geriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin RF'de sınıflandırma sonuçları Tablo 4.40'da gösterilmiştir.

Tablo 4.40 (a): MRG'nin Geriye Doğru Seçim -RF ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	15	5	20
Toplam	103	5	108

b) MRG'nin Geriye Doğru Seçim -RF ile sınıflandırma sonucu.

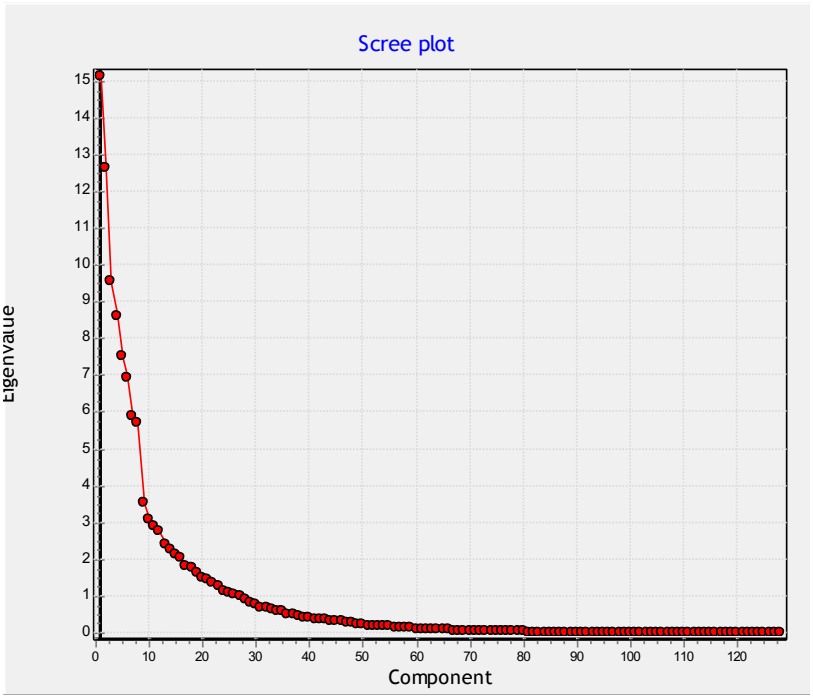
Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%85	%90
Normal	%25	%0	%0

4.3. EEG VE MRG BİRLEŞİMİ AKD (DCT) SONUÇLARI

EEG ile MRG birleşimi kullanılarak oluşturulan özellik vektörü 128'dir. Çıkarılan bu özellik vektörlerinin sınıflandırmada doğruluk derecesini artırmak için belli özellik seçimi algoritmaları kullanılmıştır.

4.3.1. Temel Bileşen Analizi (TBA)

Tanagra sistemine, birleştirilmiş olan EEG_MRG verisi alınır. TBA'da sadece giriş verileri ayarlanır, fakat hedef veri girilmez. Bileşenler kısmında faktorial analiz bölümünden TBA seçilerek işleme alınır. Çalışmamızda 128 özellik vektöründen 100 özellik seçilmiştir. Seçilen özelliklerin öz değerleri (eigenvalue) Şekil 4.8'de gösterilmiştir.



Şekil 4.8: TBA ile seçilen özellikler.

AKD ile çıkarılan özellikler, TBA yöntemiyle seçilen özellikler farklı yöntemlerle sınıflandırılmıştır. Veriler üzerinde 9-katmanlı çapraz doğrulama yöntemi kullanılmıştır. Tablo 4.41'de farklı sınıflandırma yöntemlerine göre doğrulama sonuçları verilmiştir.

Tablo 4.41: AKD'nin TBA ile özellik seçim yöntemine göre sınıflandırma doğruluk ve hata oranı.

Yöntem	MLP	SVM	KNN	RF
Doğruluk	%96	%87	%84	%100
Hata Oranı	0.046	0.125	0.157	0.000

4.3.1.1. YSA Sonucu

Tanagra'da Öğreticili Öğrenme Yöntemlerinden MLP (Çok Katmanlı Algılayıcı) kullanılarak sınıflandırma yapılmıştır (Bölüm 3). Her bir özellik seçim yönteminin sonucuna göre yapılan sınıflandırma sonuçları karşılaştırılmıştır. MLP mimarisi ara katman kullanılarak tasarlanmıştır. Mimarinin giriş sayısı 100, çıkış sayısı 2, ara katmandaki nöron sayısı 10, öğrenme oranı 0,15, maksimum iterasyon sayısı 100, hata oranı 0,01 olarak ayarlanmıştır. EEG_MRG'den TBA yöntemi kullanılarak seçilmiş olan özelliklerin MLP'de sınıflandırma sonuçları Tablo 4.42'de gösterilmiştir.

Tablo 4.42 (a): EEG_MRG'nin TBA-MLP ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	86	2	88
Normal	3	17	20
Toplam	89	19	108

b) EEG_MRG'nin TBA-MLP ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%97	%96	%96

Normal	%85	%89	%86

4.3.1.2. SVM

Tanagra'da Öğreticili Öğrenme Yöntemlerinden SVM (Destek Vektör Makineleri) kullanılarak sınıflandırma yapılmıştır. EEG_MRG'den AKD yöntemiyle çıkarılan özellikler, TBA yöntemi kullanılarak seçilmiş olan özelliklerin SVM'de sınıflandırma sonuçları Tablo 4.43'de gösterilmiştir.

Tablo 4.43 (a): EEG_MRG'nin TBA-SVM ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	87	1	88
Normal	13	7	20
Toplam	100	8	108

b) EEG_MRG'nin TBA-SVM ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%98	%87	%92
Normal	%35	%65	%45

4.3.1.3. KNN

Tanagra'da Öğreticili Öğrenme Yöntemlerinden KNN (K-en Yakın Komşuluk) kullanılarak sınıflandırma yapılmıştır. EEG_MRG'den AKD yöntemiyle çıkarılan özellikler, TBA yöntemi kullanılarak seçilmiş olan özelliklerin KNN'de sınıflandırma sonuçları Tablo 4.44'de gösterilmiştir.

Tablo 4.44 (a): EEG_MRG'nin TBA-KNN ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	87	1	88

Normal	16	4	20
Toplam	103	5	108

b) EEG_MRG'nin TBA-KNN ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%98	%84	%90
Normal	%20	%80	%32

4.3.1.4. RF

Tanagra'da Öğreticili Öğrenme Yöntemlerinden RF (Birden fazla Karar Ağaçları) kullanılarak sınıflandırma yapılmıştır. EEG_MRG'den AKD yöntemiyle çıkarılan özellikler, TBA yöntemi kullanılarak seçilmiş olan özelliklerin RF'de sınıflandırma sonuçları Tablo 4.45'de gösterilmiştir.

Tablo 4.45 (a): EEG_MRG'nin TBA-RF ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88
Normal	0	20	20
Toplam	88	20	108

b) EEG_MRG'nin TBA-RF ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%100	%100
Normal	%100	%100	%100

4.3.2. Doğrusal Ayrım Analizi (DAA)

Tanagra'da Doğrusal Ayırt Edici analizi kullanılarak özellik seçimi yapmak için stepdisc fonksiyonu uygulanır. Sisteme, birleştirilmiş olan EEG_MRG verisi alınır. Tanagra ortamında özellik ve hedef verileri ayarlanır. Daha sonra bileşenler kısmında özellik seçimi algoritmalarından stepdisc seçilerek uygulanır. Çalışmamızda 128 özellik vektöründen 5 özellik seçilmiştir. AKD ile çıkarılan özellikler, DAA yöntemiyle seçilen özellikler farklı yöntemlerle sınıflandırılmıştır. Veriler üzerinde 9-katmanlı çapraz doğrulama yöntemi kullanılmıştır. Tablo 4.46'da farklı sınıflandırma yöntemlerine göre doğrulama sonuçları verilmiştir.

Tablo 4.46: AKD'nin DAA ile özellik seçim yöntemine göre sınıflandırma doğruluk ve hata oranı.

Yöntem	MLP	SVM	KNN	RF
Doğruluk	%100	%81	%84	%100
Hata Oranı	0.000	0.185	0.157	0.000

4.3.2.1. YSA Sonucu

Tanagra'da Öğreticili Öğrenme Yöntemlerinden MLP (Çok Katmanlı Algılayıcı) kullanılarak sınıflandırma yapılmıştır (Bölüm 3). EEG_MRG'den DAA yöntemi kullanılarak seçilmiş olan özelliklerin MLP'de sınıflandırma sonuçları Tablo 4.47'de gösterilmiştir.

Tablo 4.47 (a): EEG_MRG'nin DAA-MLP ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88
Normal	0	20	20
Toplam	88	20	108

b) EEG_MRG'nin DAA -MLP ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor

Epilepsi	%100	%100	%100
Normal	%100	%100	%100

4.3.2.2. SVM

Tanagra'da Öğreticili Öğrenme Yöntemlerinden SVM (Destek Vektör Makineleri) kullanılarak sınıflandırma yapılmıştır. EEG_MRG'den AKD yöntemiyle çıkarılan özellikler, DAA yöntemi kullanılarak seçilmiş olan özelliklerin SVM'de sınıflandırma sonuçları Tablo 4.48'de gösterilmiştir.

Tablo 4.48 (a): EEG_MRG'nin DAA -SVM ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	20	0	20
Toplam	108	0	108

b) EEG_MRG'nin DAA -SVM ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%100	%81	%89
Normal	%0	%0	%0

4.3.2.3. KNN

Tanagra'da Öğreticili Öğrenme Yöntemlerinden KNN (K-en Yakın Komşuluk) kullanılarak sınıflandırma yapılmıştır. EEG_MRG'den AKD yöntemiyle çıkarılan özellikler, DAA yöntemi kullanılarak seçilmiş olan özelliklerin KNN'de sınıflandırma sonuçları Tablo 4.49'da gösterilmiştir.

Tablo 4.49 (a): EEG_MRG'nin DAA -KNN ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**

Epilepsi	87	1	88
Normal	16	4	20
Toplam	103	5	108

b) EEG_MRG'nin DAA -KNN ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%98	%84	%90
Normal	%20	%80	%32

4.3.2.4. RF

Tanagra'da Öğreticili Öğrenme Yöntemlerinden RF (Birden fazla Karar Ağaçları) kullanılarak sınıflandırma yapılmıştır. EEG_MRG'den AKD yöntemiyle çıkarılan özellikler, DAA yöntemi kullanılarak seçilmiş olan özelliklerin RF'de sınıflandırma sonuçları Tablo 4.50'da gösterilmiştir.

Tablo 4.50 (a): EEG_MRG'nin DAA -RF ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	0	20	20
Toplam	88	20	108

b) EEG_MRG'nin DAA -RF ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%100	%100	%100
Normal	%100	%100	%100

4.3.3. İleriye Doğru Seçim (Forward Selection)

Tanagra'da İleriye Doğru Seçim yöntemi kullanılarak özellik seçimi yapmak için forward-logit fonksiyonu uygulanır. Sisteme birleştirilmiş olan EEG_ MRG verisi alınır. Tanagra ortamında özellik ve hedef verileri ayarlanır. Daha sonra bileşenler kısmında özellik seçimi algoritmalarından forward-logit seçilerek uygulanır. Çalışmada, 128 özellik vektöründen 3 özellik seçilmiştir. AKD ile çıkarılan özellikler, İleriye Doğru Seçim yöntemiyle seçilen özellikler farklı yöntemlerle sınıflandırılmıştır. Veriler üzerinde 9-katmanlı çapraz doğrulama yöntemi kullanılmıştır. Tablo 4.91'de farklı sınıflandırma yöntemlerine göre doğrulama sonuçları verilmiştir.

Tablo 4.51: AKD'nin İleriye Doğru Seçim yöntemine göre sınıflandırma doğruluk ve hata oranı.

Yöntem	**MLP**	**SVM**	**KNN**	**RF**
Doğruluk	%99	%83	%85	%100
Hata Oranı	0.009	0.166	0.148	0.000

4.3.3.1. YSA Sonucu

Tanagra'da Öğreticili Öğrenme Yöntemlerinden MLP (Çok Katmanlı Algılayıcı) kullanılarak sınıflandırma yapılmıştır (Bölüm 3). EEG_MRG'den İleriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin MLP'de sınıflandırma sonuçları Tablo 4.52'de gösterilmiştir.

Tablo 4.52 (a): EEG'nin İleriye Doğru Seçim -MLP ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	1	19	20
Toplam	89	19	108

b) EEG'nin İleriye Doğru Seçim -MLP ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**

Epilepsi	%100	%98	%98
Normal	%95	%100	%97

4.3.3.2. SVM

Tanagra'da Öğreticili Öğrenme Yöntemlerinden SVM (Destek Vektör Makineleri) kullanılarak sınıflandırma yapılmıştır. EEG_MRG'den AKD yöntemiyle çıkarılan özellikler, İleriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin SVM'de sınıflandırma sonuçları Tablo 4.53'de gösterilmiştir.

Tablo 4.53 (a): EEG'nin İleriye Doğru Seçim -SVM ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	88	0	88
Normal	18	2	20
Toplam	106	2	108

b) EEG'nin İleriye Doğru Seçim -SVM ile sınıflandırma sonucu.

Tahmin Değerleri	**Duyarlılık**	**Kesinlik**	**F-skor**
Epilepsi	%100	%83	%90
Normal	%10	%100	%18

4.3.3.3. KNN

Tanagra'da Öğreticili Öğrenme Yöntemlerinden KNN (K-en Yakın Komşuluk) kullanılarak sınıflandırma yapılmıştır. EEG_MRG'den AKD yöntemiyle çıkarılan özellikler, İleriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin KNN'de sınıflandırma sonuçları Tablo 4.54'de gösterilmiştir.

Tablo 4.54 (a): EEG'nin İleriye Doğru Seçim -KNN ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**

Epilepsi	88	0	88
Normal	16	4	20
Toplam	104	4	108

b) EEG'nin İleriye Doğru Seçim -KNN ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%84	%90
Normal	%20	%100	%33

4.3.3.4. RF

Tanagra'da Öğreticili Öğrenme Yöntemlerinden RF (Birden fazla Karar Ağaçları) kullanılarak sınıflandırma yapılmıştır. EEG_MRG'den AKD yöntemiyle çıkarılan özellikler, İleriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin RF'de sınıflandırma sonuçları Tablo 4.55'da gösterilmiştir.

Tablo 4.55 (a): EEG'nin İleriye Doğru Seçim -RF ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88
Normal	0	20	20
Toplam	88	20	108

b) EEG'nin İleriye Doğru Seçim -RF ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%100	%100
Normal	%100	%100	%100

4.3.4. Geriye Doğru Seçim (Backward Selection)

Tanagra'da Geriye Doğru Seçim yöntemi kullanılarak özellik seçimi yapmak için backward-logit fonksiyonu uygulanır. Sisteme birleştirilmiş olan EEG_ MRG verisi alınır. Tanagra ortamında özellik ve hedef verileri ayarlanır. Daha sonra bileşenler kısmında özellik seçimi algoritmalarından backward-logit seçilerek uygulanır. Uygulamamızda, 128 özellik vektöründen 119 özellik seçilmiştir. AKD ile çıkarılan özellikler, Geriye Doğru Seçim yöntemiyle seçilen özellikler farklı yöntemlerle sınıflandırılmıştır. Veriler üzerinde 9-katmanlı çapraz doğrulama yöntemi kullanılmıştır. Tablo 4.56'da farklı sınıflandırma yöntemlerine göre doğrulama sonuçları verilmiştir.

Tablo 4.56: AKD'nin Geriye Doğru Seçim yöntemine göre sınıflandırma doğruluk ve hata oranı.

Yöntem	**MLP**	**SVM**	**KNN**	**RF**
Doğruluk	%97	%90	%83	%100
Hata Oranı	0.037	0.092	0.166	0.000

4.3.4.1. YSA Sonucu

Tanagra'da Öğreticili Öğrenme Yöntemlerinden MLP (Çok Katmanlı Algılayıcı) kullanılarak sınıflandırma yapılmıştır (Bölüm 3). EEG_MRG'den Geriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin MLP'de sınıflandırma sonuçları Tablo 4.57'de gösterilmiştir.

Tablo 4.57 (a): EEG'nin Geriye Doğru Seçim -MLP ile elde edilen hata matrisi.

Hata Matrisi	**Epilepsi**	**Normal**	**Toplam**
Epilepsi	87	1	88
Normal	3	17	20
Toplam	90	18	108

b) EEG'nin Geriye Doğru Seçim -MLP ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%98	%96	%96
Normal	%85	%94	%88

4.3.4.2. SVM

Tanagra'da Öğreticili Öğrenme Yöntemlerinden SVM (Destek Vektör Makineleri) kullanılarak sınıflandırma yapılmıştır. EEG_MRG'den AKD yöntemiyle çıkarılan özellikler, Geriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin SVM'de sınıflandırma sonuçları Tablo 4.58'de gösterilmiştir.

Tablo 4.58 (a): EEG'nin Geriye Doğru Seçim -SVM ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88
Normal	10	10	20
Toplam	98	10	108

b) EEG'nin Geriye Doğru Seçim -SVM ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F-skor
Epilepsi	%100	%89	%94
Normal	%50	%100	%66

4.3.4.3. KNN

Tanagra'da Öğreticili Öğrenme Yöntemlerinden KNN (K-en Yakın Komşuluk) kullanılarak sınıflandırma yapılmıştır. EEG_MRG'den AKD yöntemiyle çıkarılan özellikler, Geriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin KNN'de sınıflandırma sonuçları Tablo 4.59'de gösterilmiştir.

Tablo 4.59 (a): EEG'nin Geriye Doğru Seçim -KNN ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	82	6	88
Normal	12	8	20
Toplam	94	14	108

b) EEG'nin Geriye Doğru Seçim -KNN ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F_1-skor
Epilepsi	%93	%87	%88
Normal	%40	%58	%47

4.3.4.4. RF

Tanagra'da Öğreticili Öğrenme Yöntemlerinden RF (Birden fazla Karar Ağaçları) kullanılarak sınıflandırma yapılmıştır. EEG_MRG'den AKD yöntemiyle çıkarılan özellikler, Geriye Doğru Seçim yöntemi kullanılarak seçilmiş olan özelliklerin RF'de sınıflandırma sonuçları Tablo 4.60'da gösterilmiştir.

Tablo 4.60 (a): EEG'nin Geriye Doğru Seçim -RF ile elde edilen hata matrisi.

Hata Matrisi	Epilepsi	Normal	Toplam
Epilepsi	88	0	88
Normal	0	20	20
Toplam	88	20	108

b) EEG'nin Geriye Doğru Seçim -RF ile sınıflandırma sonucu.

Tahmin Değerleri	Duyarlılık	Kesinlik	F_1-skor
Epilepsi	%100	%100	%100
Normal	%100	%100	%100

4.4. EEG'NİN AKD (DCT) VE ADD (DWT) SINIFLANDIRMA SONUÇLARI

EEG'nin AKD özellik çıkarım yöntemine göre özellik çıkarımı ve farklı özellik seçim yöntemlerine göre özellik seçimi yapılmıştır. Seçilen özellikler farklı sınıflandırma algoritmalarıyla sınıflandırılmıştır. Tablo 4.61'de overall accuracy sonuçları gösterilmiştir. Tablo 4.62'de f-skor sonuçları gösterilmiştir.

Tablo 4.61: AKD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (overall accuracy) sonuçları.

Yöntem	YSA	SVM	KNN	RF
TBA	%95	%81	%81	%100
DAA	%92	%83	%84	%100
İleri Seçim	%86	%81	%83	%99
Geri Seçim	%91	%81	%82	%100

Tablo 4.62: AKD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (f-skor) sonuçları.

Yöntem	YSA	SVM	KNN	RF
TBA	%96	%89	%96	%100
DAA	%95	%90	%90	%100
İleri Seçim	%90	%89	%86	%99
Geri Seçim	%94	%90	%88	%100

EEG'nin ADD özellik çıkarım yöntemine göre özellik çıkarımı ve farklı özellik seçim yöntemlerine göre özellik seçimi yapılmıştır. Seçilen özellikler farklı sınıflandırma algoritmalarıyla sınıflandırılmıştır. Sonuçlar Tablo 4.63'de overall accuracy sonuçları gösterilmiştir. Tablo 4.64'de f-skor sonuçları gösterilmiştir.

Tablo 4.63: ADD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (overall accurancy) sonuçları.

Yöntem	YSA	SVM	KNN	RF

TBA	%89	%85	%81	%99
DAA	%90	%83	%84	%100
İleri Seçim	%95	%82	%86	%100
Geri Seçim	%93	%88	%82	%99

Tablo 4.64: ADD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (f-skor) sonuçları.

Yöntem	**YSA**	**SVM**	**KNN**	**RF**
TBA	%93	%90	%88	%99
DAA	%93	%90	%90	%100
İleri Seçim	%96	%90	%90	%100
Geri Seçim	%95	%93	%88	%98

AKD yöntemine Çapraz doğrulama K=9 ile sınıflandırma sonuçları Tablo 4.65'de overall accuracy sonuçları gösterilmiştir. Tablo 4.66'de f-skor sonuçları gösterilmiştir.

Tablo 4.65: AKD'nin özellik seçim yöntemlerine göre çapraz doğrulama sınıflandırma (overall accuracy) sonuçları.

Yöntem	**MLP**	**SVM**	**KNN**	**RF**
TBA	%75	%81	%81	%75
DAA	%77	%81	%77	%77
İleri Seçim	%77	%81	%77	%76
Geri Seçim	%77	%81	%77	%76

Tablo 4.66: AKD'nin özellik seçim yöntemlerine göre çapraz doğrulama (f-skor) sonuçları.

Yöntem	MLP	SVM	KNN	RF
TBA	%84	%88	%88	%86
DAA	%86	%88	%87	%86
İleri Seçim	%86	%88	%87	%86
Geri Seçim	%86	%88	%87	%85

ADD yöntemine Çapraz doğrulama K=9 ile sınıflandırma sonuçları Tablo 4.67'de overall accuracy sonuçları gösterilmiştir. Tablo 4.68'de f-skor sonuçları gösterilmiştir.

Tablo 4.67: ADD'nin özellik seçim yöntemlerine göre çapraz doğrulama sınıflandırma (overall accuracy) sonuçları.

Yöntem	MLP	SVM	KNN	RF
TBA	%66	%82	%79	%76
DAA	%79	%80	%79	%78
İleri Seçim	%77	%81	%81	%81
Geri Seçim	%73	%81	%77	%80

Tablo 4.68: ADD'nin özellik seçim yöntemlerine göre çapraz doğrulama (f-skor) sonuçları.

Yöntem	MLP	SVM	KNN	RF
TBA	%78	%90	%88	%86
DAA	%86	%88	%88	%87
İleri Seçim	%85	%88	%87	%87
Geri Seçim	%83	%89	%86	%88

4.5. MRG'NİN AKD (DCT) VE ADD (DWT) SINIFLANDIRMA SONUÇLARI

MRG'nin AKD özellik çıkarım yöntemine göre özellik çıkarımı ve farklı özellik seçim yöntemlerine göre özellik seçimi yapılmıştır. Seçilen özellikler farklı sınıflandırma algoritmalarıyla sınıflandırılmıştır. Tablo 4.69'da overall accuracy sonuçları gösterilmiştir. Tablo 4.70'de f-skor sonuçları gösterilmiştir.

Tablo 4.69: AKD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (overall accuracy) sonuçları.

Yöntem	MLP	SVM	KNN	RF
TBA	%90	%81	%81	%100
DAA	%81	%81	%82	%100
İleri Seçim	%81	%81	%83	%90
Geri Seçim	%81	%81	%81	%86

Tablo 4.70: AKD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (f-skor) sonuçları.

Yöntem	MLP	SVM	KNN	RF
TBA	%96	%89	%89	%100
DAA	%88	%88	%89	%100
İleri Seçim	%89	%89	%90	%94
Geri Seçim	%89	%89	%89	%90

MRG'nin ADD özellik çıkarım yöntemine göre özellik çıkarımı ve farklı özellik seçim yöntemlerine göre özellik seçimi yapılmıştır. Seçilen özellikler farklı sınıflandırma algoritmalarıyla sınıflandırılmıştır. Sonuçlar Tablo 4.71'de overall accuracy sonuçları gösterilmiştir. Tablo 4.72'de f-skor sonuçları gösterilmiştir.

Tablo 4.71: ADD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (overall accuracy) sonuçları.

Yöntem	MLP	SVM	KNN	RF
TBA	%93	%81	%85	%99
DAA	%82	%81	%81	%99
İleri Seçim	%81	%81	%81	%86
Geri Seçim	%81	%81	%83	%99

Tablo 4.72: ADD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (f-skor) sonuçları.

Yöntem	MLP	SVM	KNN	RF
TBA	%95	%88	%90	%98
DAA	%88	%88	%88	%98
İleri Seçim	%88	%88	%88	%90
Geri Seçim	%88	%88	%89	%98

AKD yöntemine Çapraz doğrulama K=9 ile sınıflandırma sonuçları Tablo 4.73'de overall accuracy sonuçları gösterilmiştir. Tablo 4.74'de f-skor sonuçları gösterilmiştir.

Tablo 4.73: AKD'nin özellik seçim yöntemlerine göre çapraz doğrulama sınıflandırma (overall accuracy) sonuçları.

Yöntem	MLP	SVM	KNN	RF
TBA	%76	%81	%81	%78
DAA	%76	%81	%81	%78
İleri Seçim	%81	%81	%79	%72
Geri Seçim	%81	%81	%81	%76

Tablo 4.74: AKD'nin özellik seçim yöntemlerine göre çapraz doğrulama sınıflandırma (f-skor) sonuçları.

Yöntem	MLP	SVM	KNN	RF
TBA	%83	%88	%88	%86
DAA	%88	%88	%88	%86
İleri Seçim	%88	%88	%88	%83
Geri Seçim	%88	%88	%88	%88

ADD yöntemine Çapraz doğrulama K=9 ile sınıflandırma sonuçları Tablo 4.75'de overall accuracy sonuçları gösterilmiştir. Tablo 4.76'da f-skor sonuçları gösterilmiştir.

Tablo 4.75: ADD'nin özellik seçim yöntemlerine göre çapraz doğrulama sınıflandırma (overall accuracy) sonuçları.

Yöntem	MLP	SVM	KNN	RF
TBA	%79	%81	%79	%75
DAA	%76	%81	%77	%78
İleri Seçim	%81	%81	%81	%79
Geri Seçim	%81	%81	%76	%77

Tablo 4.76: ADD'nin özellik seçim yöntemlerine göre çapraz doğrulama sınıflandırma (f-skor) sonuçları.

Yöntem	MLP	SVM	KNN	RF
TBA	%88	%88	%87	%85
DAA	%87	%88	%86	%85
İleri Seçim	%88	%88	%88	%88
Geri Seçim	%88	%88	%86	%85

4.6. EEG-MRG'NİN AKD (DCT) ÇAPRAZ DOĞRULAMA SONUÇLARI

EEG-MRG'nin AKD özellik çıkarım yöntemine göre özellik çıkarımı ve farklı özellik seçim yöntemlerine göre özellik seçimi yapılmıştır. Seçilen özellikler farklı sınıflandırma algoritmalarıyla sınıflandırılmıştır. Tablo 4.77'de overall accurancy sonuçları overall accuracy sonuçları gösterilmiştir. Tablo 4.78'de f-skor sonuçları gösterilmiştir.

Tablo 4.77: AKD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (overall accuracy) sonuçları.

Yöntem	MLP	SVM	KNN	RF
TBA	%96	%87	%84	%100
DAA	%100	%81	%84	%100
İleri Seçim	%99	%83	%85	%100
Geri Seçim	%97	%90	%83	%100

Tablo 4.78: AKD'nin özellik seçim yöntemlerine göre farklı sınıflandırma algoritma (f-skor) sonuçları.

Yöntem	MLP	SVM	KNN	RF
TBA	%96	%92	%90	%100
DAA	%100	%89	%90	%100
İleri Seçim	%98	%90	%90	%100
Geri Seçim	%96	%94	%88	%100

AKD yöntemine Çapraz doğrulama K=9 ile sınıflandırma sonuçları Tablo 4.79'da overall accuracy sonuçları gösterilmiştir. Tablo 4.80'de f-skor sonuçları gösterilmiştir.

Tablo 4.79: AKD'nin özellik seçim yöntemlerine göre çapraz doğrulama sınıflandırma (overall accuracy) sonuçları.

Yöntem	MLP	SVM	KNN	RF

PCA	%77	%81	%81	%77
LDA	%78	%81	%79	%76
Forward	%79	%81	%78	%75
Backward	%75	%80	%73	%80

Tablo 4.80: AKD'nin özellik seçim yöntemlerine göre çapraz doğrulama (f-skor) sonuçları.

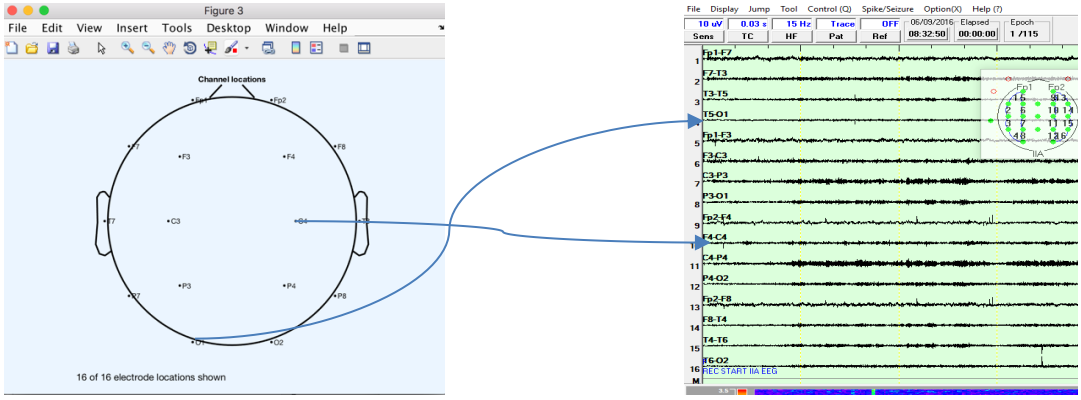
Yöntem	**MLP**	**SVM**	**KNN**	**RF**
PCA	%84	%88	%88	%86
LDA	%86	%88	%87	%84
Forward	%86	%88	%88	%86
Backward	%86	%88	%87	%85

4.7. LSTM SONUÇLARI

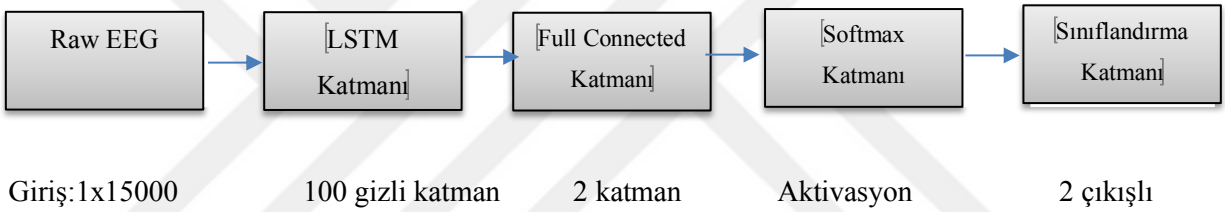
4.7.1. EEG verisinin LSTM Sonuçları

4.7.1.1. Raw EEG Verisi Tek Kanallı

EEG sinyal uygulamalarında ağ girişi sinyal olarak adlandırdığımız bir boyutlu veridir. 16 kanallı EEG datası ortalama 220000 değere sahiptir. 16x220000'lik matrisin LSTM ağına giriş olarak verilmesi matlab da out of memory hatasına yol açmıştır. Literatürde Yıldırım (2018) ve Lopez de Diego (2019) bütün kanalları giriş vermek yerine 4. Kanalın (T5-O1) ilk 60 sn. (15000) lik kısmı giriş olarak verilmiştir. 4. Kanal gösterimi Şekil 4.9' dadır.



Şekil 4.9: EEG verisinde 4. Kanal (T5-O-1) ve 10. Kanal (F4-C4) gösterimi.

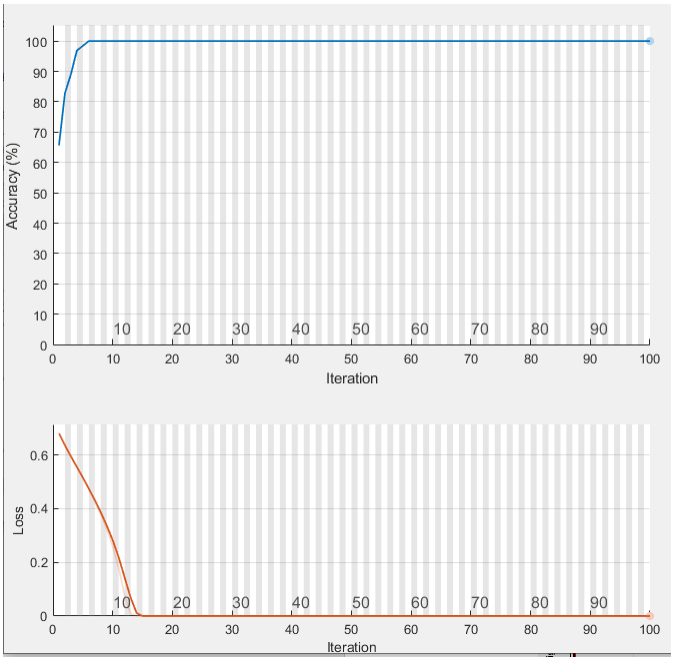


Şekil 4.10: LSTM Akışı

5 katmanlı LSTM ağ yapısında, Raw EEG 1x15000 giriş olarak verilip 2'li çıkış tasarlanmıştır. Ağ yapısı Şekil 4.10'dadır.

Tablo 4.81: Ağdaki Parametreler

Parametre	**Değer**
Layer	5x1
Optimizasyon Algoritması	Adam
Hidden Layer	100
Epoch	100
MiniBatchSize	64
Learning Rate	0,001
Gradient decay factor	$\beta_1 = 0{,}90$
Squared gradient decay factor	$\beta_2 = 0{,}99$
Epsilon	$\varepsilon = 10^{-8}$



Şekil 4.11: LSTM_RawEGG'nin Tek Kanallı Başarı ve Kayıp Grafiği

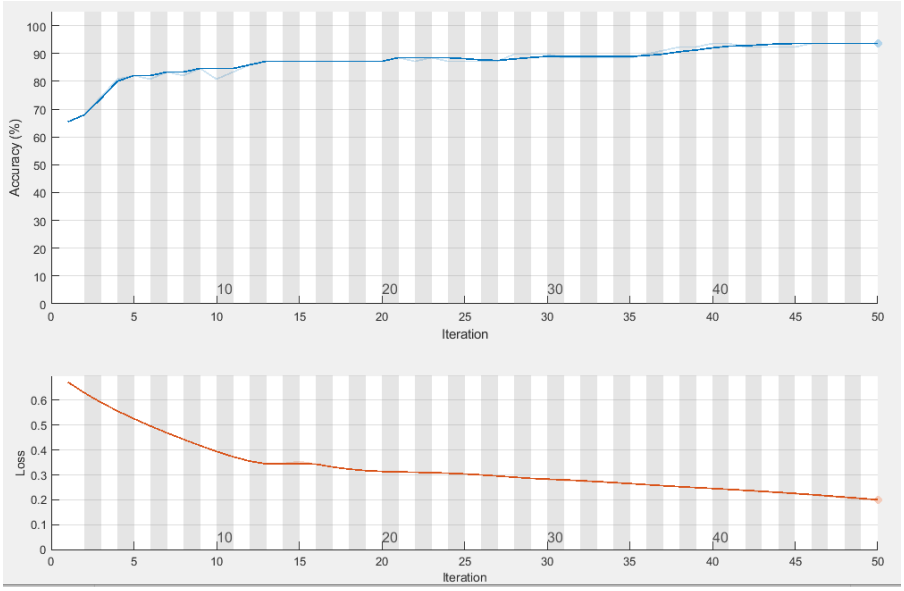
Tablo 4.82: LSTM_EEG ağının Herbir İşlemdeki Sonucu

Epoch	Iteration	Time Elapsed	Mini-batch	Mini-batch	Base Learning
		(hh:mm:ss)	Accuracy	Loss	Rate
1	1	00:02:42	65.63%	0.6801	0.0010
50	50	02:09:22	100.00%	1.6764e-07	0.0010
100	100	04:17:05	100.00%	2.2165e-07	0.0010

Ağda kullanılan parametreler Tablo 4.81'de gösterilmiştir. LSTM ağının başarı ve kayıp grafiği Şekil 4.11'dedir. Ağ da eğitim yapılırken her işlem sonucu Tablo 4.82'de verilmiştir. Ağın Başarısı: %80'dir.

4.7.1.2. Raw EEG Verisi İki Kanallı

Literatürde Yıldırım (2018) bütün kanalları giriş vermek yerine 4. Kanal (T5-O1) ve 10. Kanalın (F4-C4) ilk 60 sn. (15000) lik kısımları giriş olarak verilmiştir. 4. Ve 10. Kanal gösterimi Şekil 4.9' dadır.



Şekil 4.12: LSTM_RawEGG'nin 2 Kanallı Başarı ve Kayıp Grafiği

Tablo 4.83: Ağdaki Parametreler

Parametre	**Değer**
Layer	5x1
Optimizasyon Algoritması	Adam
Hidden Layer	100
Epoch	20
MiniBatchSize	64
Learning Rate	0,001

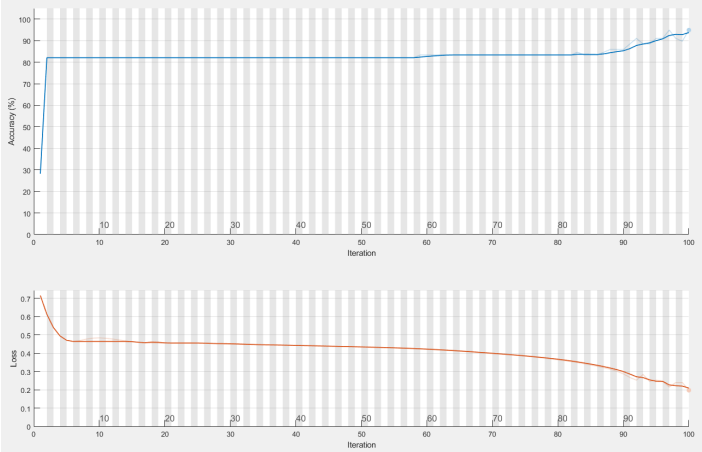
Tablo 4.84: LSTM_EEG ağının Herbir İşlemdeki Sonucu

Epoch	Iteration	Time Elapsed	Mini-batch	Mini-batch	Base Learning
		(hh:mm:ss)	Accuracy	Loss	Rate
1	1	00:04:42	65.63%	0.6801	0.0010
25	25	02:18:22	89.00%	0.3057	0.0010
50	50	04:37:05	93.00%	0.2015	0.0010

Ağda kullanılan parametreler Tablo 4.83'de gösterilmiştir. LSTM ağının başarı ve kayıp grafiği Şekil 4.12'dedir. Ağ da eğitim yapılırken her işlem sonucu Tablo 4.84'de verilmiştir. Ağın Başarısı: %56'dır.

4.7.1.3. AKD EEG Verisi

Literatürde (Michielli N. Ve diğ. 2019), EEG sinyaline ön işlemler uygulanıp, özellik seçimi yapılarak LSTM ağına giriş verilerek çalışma yapılmıştır. Bizim çalışmamızda da AKD yöntemi ve istatistiksel yöntemler kullanılarak elde edilen 320 özellik LSTM ağına verilerek eğitilmiştir. Ağın başarısı ve kaybı aşağıdaki Şekil 4.13'de gösterilmiştir.



Şekil 4.13: LSTM_AKD_EGG'nin Başarı ve Kayıp Grafiği.

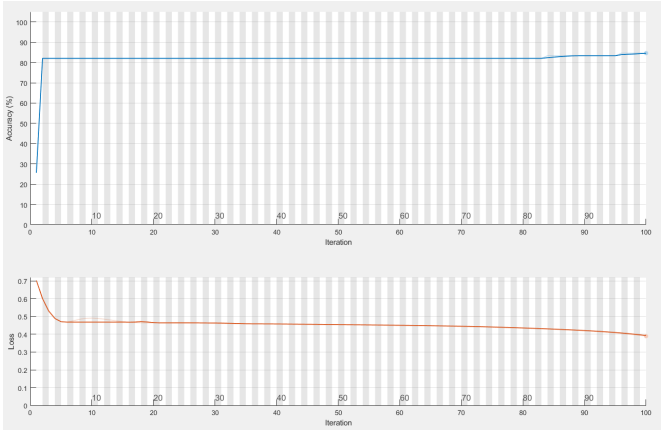
Tablo 4.85: LSTM_AKD_EEG ağının Herbir İşlemdeki Sonucu.

Epoch	Iteration	Time Elapsed	Mini-batch	Mini-batch	Base Learning
		(hh:mm:ss)	Accuracy	Loss	Rate
1	1	00:00:32	28.63%	0.6801	0.0010
50	50	01:05:22	82.00%	0.3753	0.0010
100	100	01:35:05	96.25%	0.2112	0.0010

Ağda kullanılan parametreler Tablo 4.81'de gösterilmiştir. LSTM ağının başarı ve kayıp grafiği Şekil 4.12'dedir. Ağ da eğitim yapılırken her işlem sonucu Tablo 4.85'de verilmiştir. Ağın Başarısı: %90'dır.

4.7.1.4. ADD EEG Verisi

Çalışmamızda ADD yöntemi ve istatistiksel yöntemler kullanılarak elde edilen 320 özellik LSTM ağına verilerek eğitilmiştir. Ağın başarısı ve kaybı aşağıdaki Şekil 4.16'da gösterilmiştir.



Şekil 4.14: LSTM_ADD_EGG'nin Başarı ve Kayıp Grafiği.

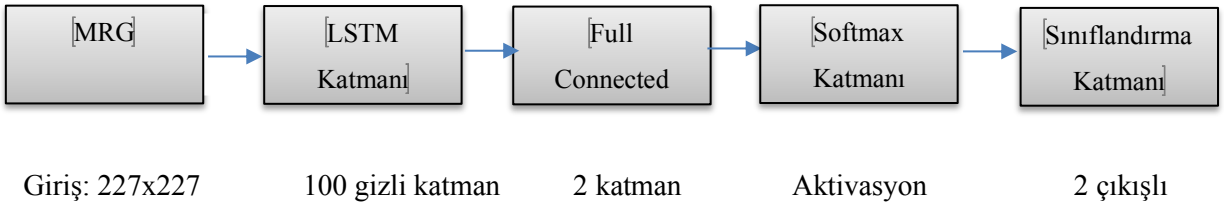
Tablo 4.86: LSTM_ADD_EEG ağının Herbir İşlemdeki Sonucu.

Epoch	Iteration	Time Elapsed	Mini-batch	Mini-batch	Base Learning
		(hh:mm:ss)	Accuracy	Loss	Rate
1	1	00:00:28	26.52%	0.6951	0.0010
50	50	01:00:12	82.00%	0.4753	0.0010
100	100	01:55:05	86.25%	0.3824	0.0010

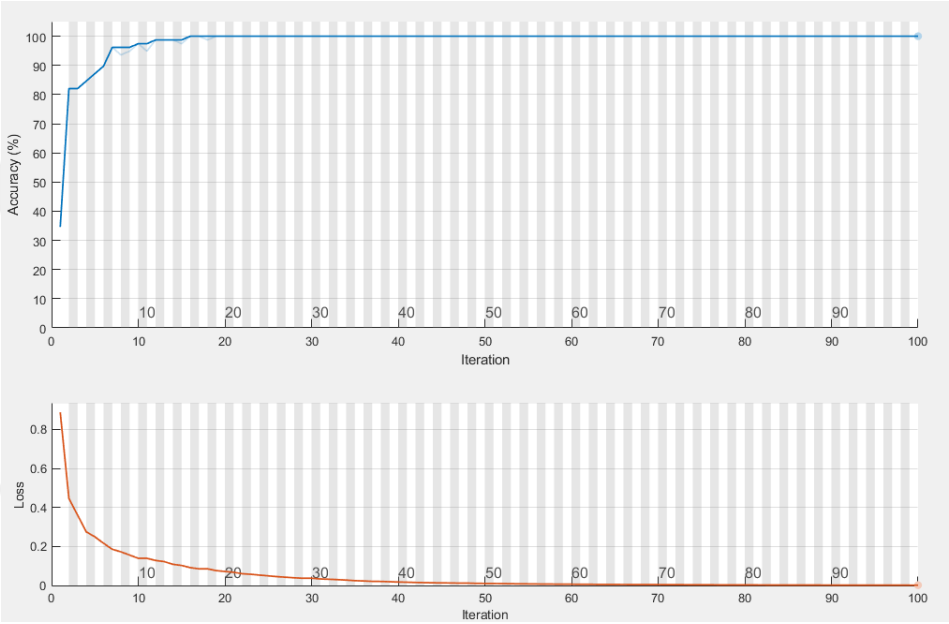
Ağda kullanılan parametreler Tablo 4.81'de gösterilmiştir. LSTM ağının başarı ve kayıp grafiği Şekil 4.14'dedir. Ağ da eğitim yapılırken her işlem sonucu Tablo 4.86'da verilmiştir. Ağın Başarısı: %83'dır.

4.7.2. MRG verisinin LSTM Sonuçları

MRG uygulamalarında ağ girişi resim olarak adlandırdığımız matris olarak verilir. 227x227 lik matris LSTM ağına giriş olarak verilir. Şekil 4.15'de 5 katmanlı LSTM ağının akış şeması verilmiştir.



Şekil 4.15: LSTM-MRG Akışı.



Şekil 4.16: LSTM_MRG'nin Başarı ve Kayıp Grafiği.

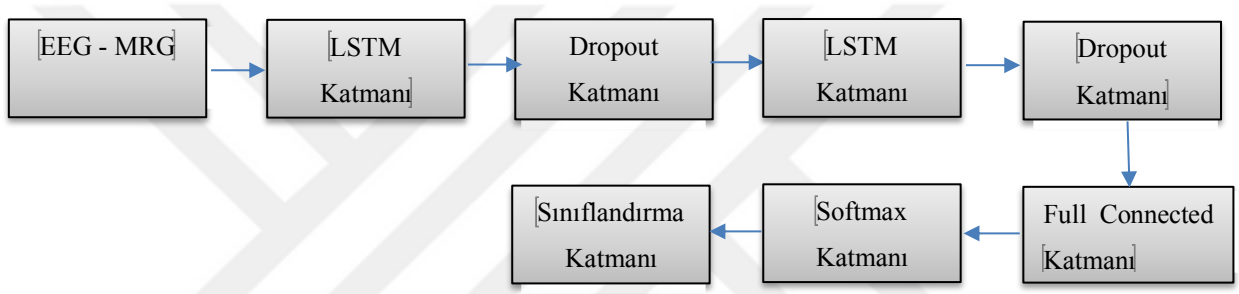
Tablo 4.87: LSTM_MRG ağının Herbir İşlemdeki Sonucu.

Epoch	Iteration	Time Elapsed	Mini-batch	Mini-batch	Base Learning
		(hh:mm:ss)	Accuracy	Loss	Rate
1	1	00:00:03	34.62%	0.8878	0.0010
50	50	00:02:11	100.00%	0.0112	0.0010
100	100	00:04:18	100.00%	0.00022	0.0010

Ağda kullanılan parametreler Tablo 4.81'de gösterilmiştir. LSTM ağının başarı ve kayıp grafiği Şekil 4.16'dadır. Ağ da eğitim yapılırken her işlem sonucu Tablo 4.87'de verilmiştir. Ağın Başarısı: %83'dür.

4.7.3. EEG-MRI verisinin LSTM Sonuçları

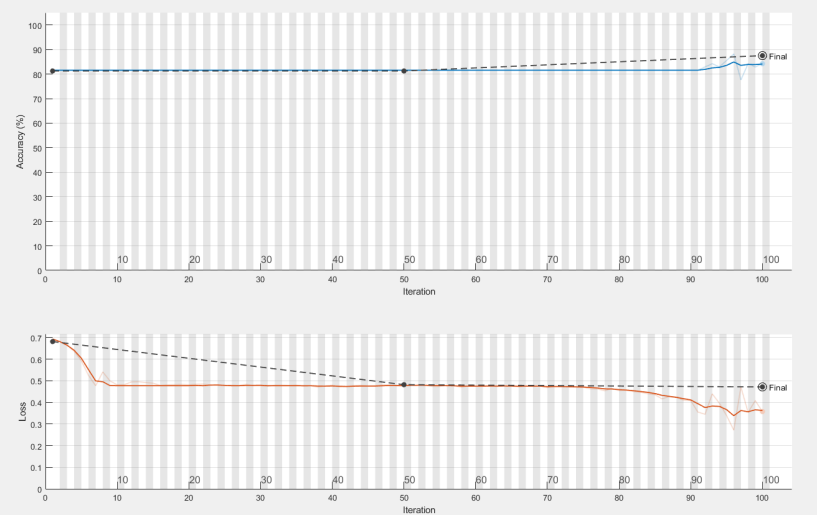
EEG-MRI özellik birleşimlerinin LSTM ağında mimarisi Şekil 4.17'de gösterilmiştir. Eğitim esnasında meyda gelen overfitting'leri önlemek için Dropout Katmanı kullanılmıştır. Ağın eğitiminde de başarılı olunmuştur. Tablo 4.88'de ağın parametreleri verilmiştir.



Şekil 4.17: LSTM EEG-MRI Akışı.

Tablo 4.88: Ağdaki Parametreler

Parametre	**Değer**
Layer	8x1
Giriş	1x376
Optimizasyon Algoritması	Adam
Dropout	0.1
Hidden Layer 1	125
Hidden Layer 2	100
Aktivasyon	Relu
Epoch	100
MiniBatchSize	64
Learning Rate	0,001



Şekil 4.18: LSTM EEG-MRI'nın Başarı ve Kayıp Grafiği.

Tablo 4.89: LSTM EGG-MRI ağının Herbir İşlemdeki Sonucu.

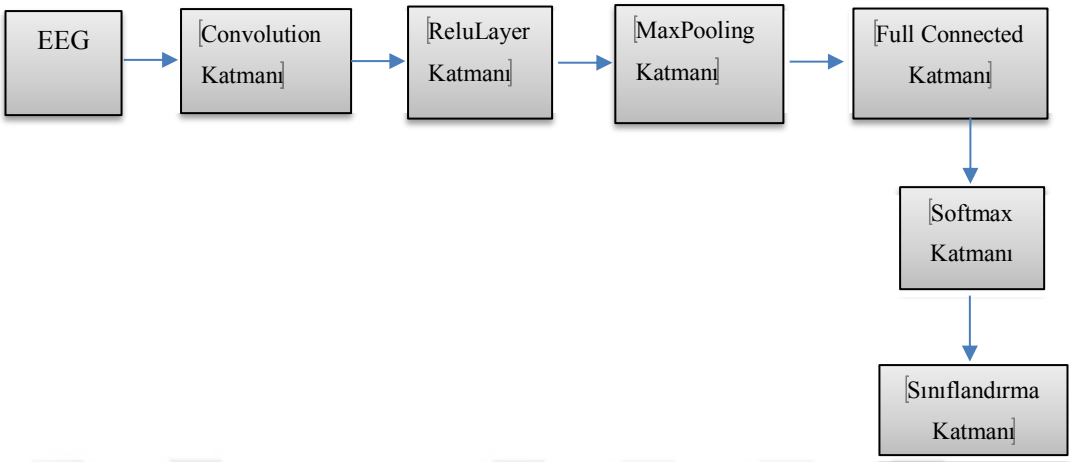
Epoch	Iteration	Time Elapsed	Mini-batch	Validation	Mini-batch	Validation	Base Learning
		(hh:mm:ss)	Accuracy	Accuracy	Loss	Loss	Rate
1	1	00:00:03	81.58%	81.25%	0.7116	0.6930	0.0010
50	50	00:01:12	81.58%	81.25%	1.8340e-08	0.4751	0.0010
100	100	00:02:23	84.21%	87.50%	7.6416e-09	0.3577	0.0010

EEG-MRI'ın LSTM ağında başarı ve kayıp grafiği Şekil 4.18'de gösterilmiştir. Ağ da eğitim yapılırken her işlem sonucu Tablo 4.89'da verilmiştir. Ağın Başarısı: %84'tür.

4.8. CNN SONUÇLARI

4.8.1. EEG CNN Sonuçları

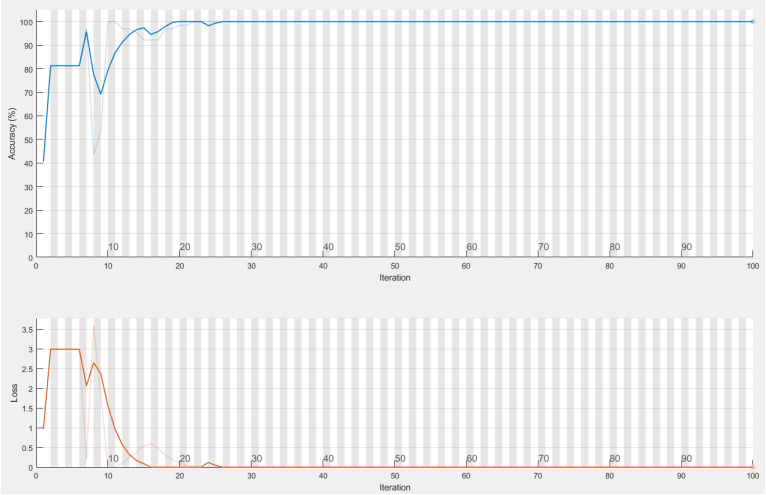
EEG sinyali 16 kanal dan 4. kanalın tek kanallı olarak sisteme 1x15000 olarak verilmiştir. 7 katmanlı CNN yapısı Şekil 4.19'da gösterilmiştir. Evrişim, relu ve havuzlama katmanında giriş verisinden özellik çıkarımı yapılmıştır. Full connected ve softmax kısmında sınıflandırma yapılmıştır. Evrişim katmanında filtre farklı özellikleri çıkarmak için kullanılır. 16'lık kullanılan filtre ağın derinliği olacaktır. Aktivasyon katmanı (Relu) Cnn mimarisinde de aynı işlevi görmektedir. Evrişim katmanındaki ağırlıklar ile çarpımlar toplamı elde edilen sonuçlar bir eşik değere göre çıkış verirler. Havuzlama bir ayrıştırma sürecidir. Maxpooling seçilen bölgeden maksimum değeri almaya dayanır.



Şekil 4.19: CNN-EEG Akışı.

Tablo 4.90: Ağdaki Parametreler

Parametre		**Değer**
Layer		7x1
Giriş		15000x1x1
Optimizasyon Algoritması		Adam
Convolution	Filte sayısı	16
	Filtre boyutu	[5]
	Stride	[1, 1]
Aktivasyon		Relu
Epoch		100
MiniBatchSize		64
Learning Rate		0,001



Şekil 4.20: CNN_EEG'nin Başarı ve Kayıp Grafiği.

Tablo 4.91: CNN_EGG ağının Herbir İşlemdeki Sonucu.

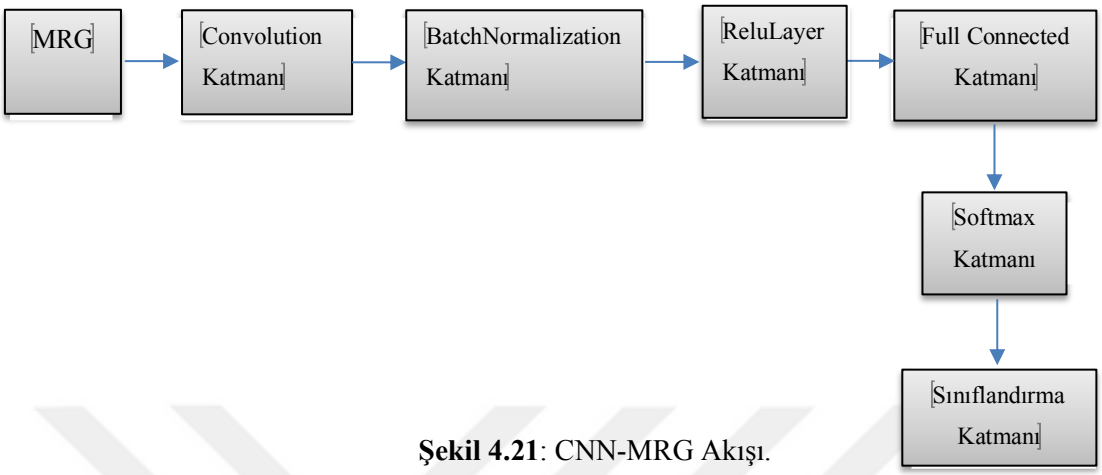
Epoch	Iteration	Time Elapsed	Mini-batch	Mini-batch	Base Learning
		(hh:mm:ss)	Accuracy	Loss	Rate
1	1	00:00:01	50.00%	0.7116	0.001
50	50	00:00:23	100.00%	1.8340e-08	0. 001
100	100	00:00:44	100.00%	7.6416e-09	0. 001

7 katmanlı ağda kullanılan hyperparametreler Tablo 4.90'da gösterilmiştir. EEG'nin CNN ağında başarı ve kayıp grafiği Şekil 4.20'de gösterilmiştir. Ağ da eğitim yapılırken her işlem sonucu Tablo 4.91'de verilmiştir. Ağın Başarısı: %76'dır.

4.8.2. MRG CNN Sonuçları

MRG verileri sisteme 227x227x1 olarak verilir. 7 katmanlı CNN yapısı Şekil 4.21'de gösterilmiştir. Ağda Evrişim, Aktivasyon ve Havuz kısmı giriş verisinde özellik çıkarımı yapılan kısımdır. Full Connected, Softmax katmanı sınıflandırma kısmıdır. Evrişim katmanında ağ filtre sayısı kadar derinleştirilir. Yığın Normalizasyon katmanında giriş kanalları mini yığın boyunca normalleştirme yapılır. Evrişimli sinir ağlarının eğitimini hızlandırmak ve ağın

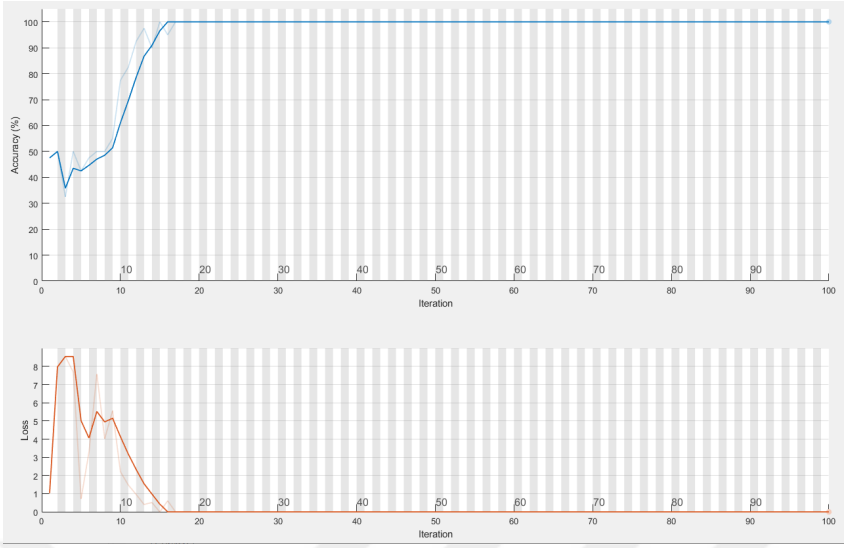
başlatılmasına olan duyarlılığı azaltmak için evrişim katmanı ve relu katmanı arasında kullanılır.



Şekil 4.21: CNN-MRG Akışı.

Tablo 4.92: Ağdaki Parametreler.

Parametre		**Değer**
Layer		7x1
Giriş		227x227x1
Optimizasyon Algoritması		Sgdm
Convolution	Filte sayısı	20
	Filtre boyutu	[5,5]
	Stride	[1,1]
Aktivasyon		Relu
Epoch		100
MiniBatchSize		128
Learning Rate		0,01
Momentum		0,9
L2 Regularization		1.0000e-04



Şekil 4.22: CNN_MRG'nin Başarı ve Kayıp Grafiği.

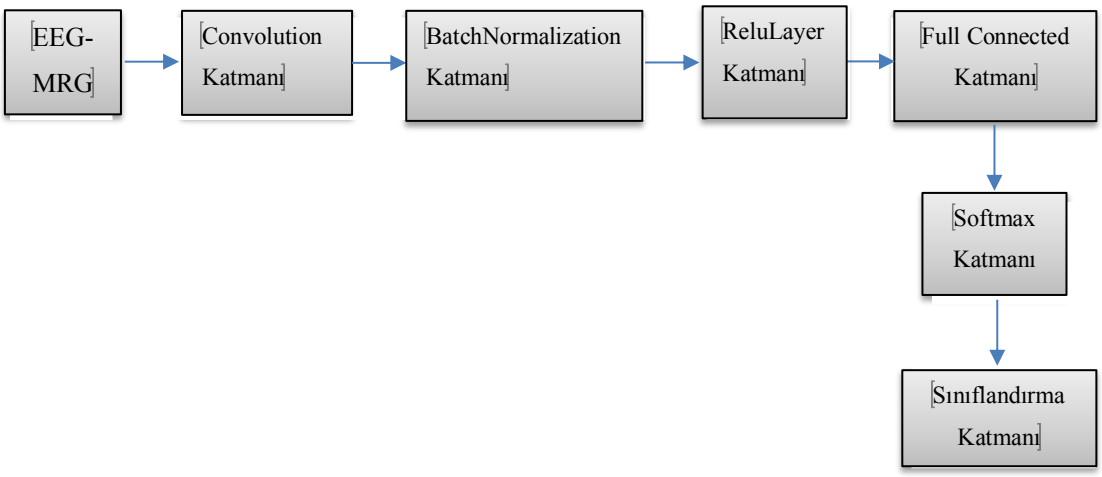
Tablo 4.93: CNN_EGG ağının Herbir İşlemdeki Sonucu.

Epoch	Iteration	Time Elapsed	Mini-batch	Mini-batch	Base Learning
		(hh:mm:ss)	Accuracy	Loss	Rate
1	1	00:00:02	47.50%	1.0377	0.010
50	50	00:00:56	100.00%	7.2037e-06	0.010
100	100	00:01:50	100.00%	2.5630e-07	0.010

7 katmanlı ağda kullanılan parametreler Tablo 4.92'de gösterilmiştir. EEG'nin CNN ağında başarı ve kayıp grafiği Şekil 4.22'de gösterilmiştir. Ağ da eğitim yapılırken her işlem sonucu Tablo 4.93'de verilmiştir. Ağın Başarısı: %92'dir.

4.8.3. EEG-MRG CNN Sonuçları

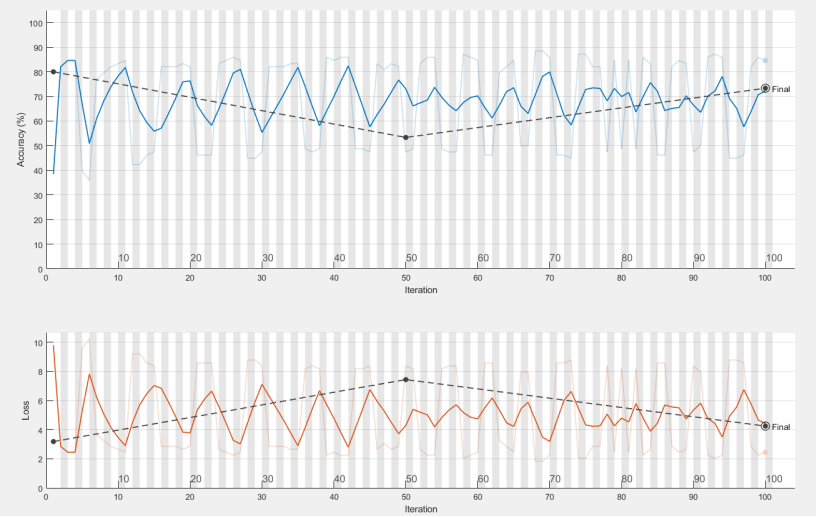
EEG-MRI verilerinin sisteme giriş olarak verilen 7 katmanlı CNN yapısı Şekil 4.23'de gösterilmiştir. 7 katmanlı ağda kullanılan parametreler Tablo 4.94'de gösterilmiştir. EEG-MR'nin CNN ağında başarı ve kayıp grafiği Şekil 4.22'de gösterilmiştir. Ağ da eğitim yapılırken her işlem sonucu Tablo 4.95'de verilmiştir. Ağın Başarısı: %80'dir.



Şekil 4.23: CNN EEG-MRG Akışı.

Tablo 4.94: Ağdaki Parametreler.

Parametre		**Değer**
Layer		7x1
Giriş		376x1x1
Optimizasyon Algoritması		Adam
Convolution	Filte sayısı	16
	Filtre boyutu	[5]
	Stride	[1, 1]
Aktivasyon		Relu
Epoch		100
MiniBatchSize		64
Learning Rate		0,001



Şekil 4.24: CNN EEG-MRG'nin Başarı ve Kayıp Grafiği.

Tablo 4.95: CNN EGG-MRG ağının Herbir İşlemdeki Sonucu.

Epoch	Iteration	Time Elapsed	Mini-batch	Validation	Mini-batch	Validation	Base Learning
		(hh:mm:ss)	Accuracy	Accuracy	Loss	Loss	Rate
1	1	00:00:03	38.46%	80.00%	3.1885	9.8107	0.0010
50	50	00:00:12	47.44%	53.33%	7.4398	8.3800	0.0010
100	100	00:00:40	84.62%	73.33%	4.2513	2.4527	0.0010

5. TARTIŞMA VE SONUÇ

Tezde, AKD (Ayrık Kosinüs Dönüşümü-DCT) özellik çıkarım yöntemine dayanan 1 boyutlu ve 2 boyutlu biyomedikal işaret analizleri yapılarak yüksek doğruluklu epilepsi hastalığı teşhisi gerçeklenmiştir.

Çalışmada, Bolu-Abant İzzet Baysal Üniversitesi Tıp Fakültesi Nöroloji Bölümünden elde edilen EEG verileri üzerinde belirli ön işlemler uygulanarak yapay etkenler giderilmiş, AKD ve ADD özellik çıkarım yöntemleri kullanılmıştır. 1 boyutlu EEG verilerinden çıkarılan bu özellikler TBA, DAA, İleri Seçim ve Geri Seçim yöntemleriyle özellik seçimi uygulanmıştır. Seçilen bu özellikler YSA, SVM, KNN ve RF makine öğrenme algoritmalarıyla sınıflandırılmıştır. Tablo 5.1'de EEG verisinin AKD, ADD yöntemlerine göre farklı sınıflandırma algoritmalarına çapraz doğrulama yapılmadan (overall accuracy) başarı sonuçları verilmiştir. Sonuçlara göre RF algoritmasıyla %100 doğrulama başarısı elde edilmiştir. Bulgular 4.4'de EEG verisinin AKD ve ADD yöntemlerine göre f-skor sonuçları verilmiştir. F-skor sonuçlarının overall accuracy göre daha başarılı olduğu gösterilmiştir.

Tablo 5.1: EEG verisinin doğrulama (overall accuracy) sonuçları.

EEG	Özellik Çıkarımı	YSA	SVM	KNN	RF
TBA	**AKD**	%95	%81	%81	%100
	ADD	%89	%85	%81	%99
DDA	**AKD**	%92	%83	%84	%100
	ADD	%90	%83	%84	%100
İleri Seçim	**AKD**	%86	%81	%83	%99
	ADD	%95	%82	%86	%100
Geri Seçim	**AKD**	%91	%81	%82	%100
	ADD	%93	%88	%82	%99

Tablo 5.2'de EEG verisinin AKD, ADD yöntemlerine göre farklı sınıflandırma algoritmalarına Çapraz doğrulama (ÇD) K= 9 uygulanarak başarı sonuçları verilmiştir. ADD çıkarımı ile SVM yönteminde %82 oranında en yüksek başarı elde edilmiştir.

Tablo 5.2: EEG verisinin çapraz doğrulama (overall accuracy) yapılan sonuçları.

EEG-ÇD	Özellik Çıkarımı	YSA	SVM	KNN	RF
TBA	**AKD**	%75	%81	%81	%75
	ADD	%66	%82	%79	%76
DDA	**AKD**	%77	%81	%77	%77
	ADD	%79	%80	%79	%78
İleri Seçim	**AKD**	%77	%81	%77	%76
	ADD	%77	%81	%81	%81
Geri Seçim	**AKD**	%77	%81	%77	%76
	ADD	%73	%81	%77	%80

Epilepsi teşhisi konulurken ikinci önemli faktör hastaların 2 boyutlu MRG verileridir. Bu veriler beyinde epilepsiye neden olan durumları bulmak için kullanılır. Çalışmamızda, MRG verileri bölütlenerek (segmentation) bunlara belirli ön işlemler uygulanıp Epilepsi/Sağlıklı olarak sınıflandırılmıştır. Tablo 5.3'te MRG verisinin AKD, ADD yöntemlerine göre farklı sınıflandırma algoritmalarına çapraz doğrulama (ÇD) yapılmadan başarı sonuçları verilmiştir. Sonuçlara göre RF algoritmasıyla %100 doğrulama başarısı elde edilmiştir. Bulgular 4.5'de MRG verisinin AKD ve ADD yöntemlerine göre f-skor sonuçları verilmiştir. F-skor sonuçları overall accuracy göre daha başarılıdır.

Tablo 5.3: MRG verisinin doğrulama (overall accuracy) sonuçları.

MRG	Özellik Çıkarımı	YSA	SVM	KNN	RF
TBA	**AKD**	%90	%81	%81	%100
	ADD	%93	%81	%85	%99

DDA	**AKD**	%81	%81	%82	%100
	ADD	%82	%81	%81	%99
İleri Seçim	**AKD**	%81	%81	%83	%90
	ADD	%81	%81	%81	%86
Geri Seçim	**AKD**	%81	%81	%81	%86
	ADD	%81	%81	%83	%99

Tablo 5.4'te EEG verisinin AKD, ADD yöntemlerine göre farklı sınıflandırma algoritmalarına çapraz doğrulama K= 9 uygulanarak başarı sonuçları verilmiştir. AKD, ADD çıkarımı YSA, SVM ve KNN yöntemlerinde %81 oranında en yüksek başarı elde edilmiştir.

Tablo 5.4: MRG verisinin çapraz doğrulama (overall accuracy) yapılan sonuçları.

MRG-ÇD	**Özellik Çıkarımı**	**YSA**	**SVM**	**KNN**	**RF**
TBA	**AKD**	%76	%81	%81	%78
	ADD	%79	%81	%79	%75
DDA	**AKD**	%76	%81	%81	%78
	ADD	%76	%81	%77	%78
İleri Seçim	**AKD**	%81	%81	%79	%72
	ADD	%81	%81	%81	%79
Geri Seçim	**AKD**	%81	%81	%81	%76
	ADD	%81	%81	%76	%77

Çalışmamızda ortaya koyduğumuz tez, EEG ile MRG özellik birleşimlerinin hastalık teşhisinde daha etkili olacağı yönündedir. Yaptığımız uygulama sonuçlarından da anlaşılacağı üzere, EEG-MRG özellik birleşimlerinden elde edilen veri setine DAA (Doğrusal Ayırım Analizi) uygulanarak Tablo 5.5'te %100'lük doğrulama başarısı elde edilmiştir. Bulgular 4.6'da EEG-

MRG verisinin AKD yöntemlerine göre f-skor sonuçları verilmiştir. F-skor sonuçları overall accuracy göre daha başarılıdır.

Tablo 5.5: EEG-MRG verisinin doğrulama (overall accuracy) sonuçları.

Yöntem	YSA	SVM	KNN	RF
TBA	%96	%87	%84	%100
DDA	%100	%81	%84	%100
İleri Seçim	%99	%83	%85	%100
Geri Seçim	%97	%90	%83	%100

EEG-MRG özellik birleşimlerinden elde edilen veri setine çapraz doğrulama K=9 uygulandıktan sonra TBA (Temel Bilişim Analizi) uygulanarak Tablo 5.6'da %83'lük doğrulama başarısı elde edilmiştir. Makine öğrenmesinde özellik çıkarım yöntemlerinin sonuç değerlerinin birbirine yakın olsa da işlem karmaşıklığı ve hesaplama hızı açısından AKD daha başarılıdır.

Tablo 5.6: EEG-MRG verisinin çapraz doğrulama (overall accuracy) yapılan sonuçları.

Yöntem	YSA	SVM	KNN	RF
TBA	%77	%83	%81	%80
DDA	%78	%81	%79	%76
İleri Seçim	%79	%81	%78	%75
Geri Seçim	%75	%80	%73	%80

Derin Öğrenme yaklaşımında LSTM ve CNN ağında ham EEG verisinin sınıflandırma başarısı Şekil 5.7'de verilmiştir. Ham EEG LSTM ağında %80 doğrulama başarısı elde edilmiştir.

Tablo 5.7: Ham EEG LSTM – CNN doğrulama sonucu.

Yöntem	LSTM	CNN

Ham EEG	%80	%76

Derin Öğrenme yönteminde LSTM-CNN ağında MRG verisinin sınıflandırma başarısı Şekil 5.8'de verilmiştir. MRG verisiyle CNN ağında %92'lik doğrulama başarısı elde edilmiştir.

Tablo 5.8: MRG LSTM – CNN doğrulama sonucu.

MRG	**LSTM**	**CNN**
Doğrulama	%83	%92

EEG ve MRI verilerinin ön işlemlerden geçirilmiş özellik çıkarımları birleştirilerek yeni veri seti elde edilmiştir. Derin Öğrenme mimarisinde LSTM-CNN ağında EEG-MRG verilerinin sınıflandırma başarısı Şekil 5.9'da verilmiştir. EEG-MRG verisiyle LSTM ağında %84'lük doğrulama başarısı elde edilmiştir.

Tablo 5.9: EEG-MRG LSTM – CNN doğrulama sonucu.

MRG	**LSTM**	**CNN**
Doğrulama	%84	%80

Bu çalışmanın sonucunda, orijinal EEG ve MRG verilerinin farklı özellik çıkarım yöntemlerinde kullanılmasıyla, yeni veri setleri elde edilerek bunların makine öğrenmesi ve derin öğrenme ağlarında başarılı sonuçlar elde edilmiştir. Derin öğrenme ağına giriş verisi olarak dizi (sequence) verildiği durumlarda LSTM ağının CNN ağına göre daha başarılı olduğu tespit edilmiştir. CNN ağ yapısı ise MRI verilerinde daha başarılıdır.

Sonuç olarak, EEG-MRI özellik birleşimlerinin sınıflandırma başarısı gerek makine öğrenme gerekse derin öğrenmede başarı sağlamıştır. Bu sonuçların da epilepsi teşhisine katkı sağlayabileceğine inanılmaktadır. İlerde LSTM-CNN ağ yapıları birleştirilerek hibrit ağ yapıları denenerek farklı sonuçlar elde edilebilmesi düşünülmektedir.

KAYNAKLAR

Abhinaya, B., and Thanaraj, D. C. K. P., 2016, Feature extraction and selection of a combination of entropy features for real-time epilepsy detection, *International journal of engineering and computer science*, 5(4).

Abramowitz, M., & Stegun, I. A. (1972). *Handbook of Mathematical Functions with Formulas, Graphs, and Mathematical Tables*. (10th ed.). National Bureau of Standarts: Washington DC.

Adam, A., Shapiai, M. I., Tumari, M., Zaidi, M., Mohamad, M. S., and Mubin, M., 2014, Feature selection and classifier parameters estimation for EEG signals peak detection using particle swarm optimization, *The scientific world journal*, 1-13.

Anderson, C.W., & Sijercic, Z. (1996). Classification of EEG Signals from Four Subjects During Five Mental Tasks. Proceedings of the Conference on Engineering Applications in Neural Networks (EANN'96), Finland. Retrieved from http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.51.4092.

Bahadır A., 2005, Manyetik Rezonans Görüntüleme Sistemleri.Yüksek Lisans Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

Bell, A. J., and Sejnowski, T. J., 1995. An information-maximization approach to blind separation and blind deconvolution. *Neural Comput 7*, 1129-1159.

Berg, A. T., Berkovic, S. F., Brodie, M. J., Buchhalter, J., Cross, J. H., Van Emde Boas, W., Engel, J., French, J., Glauser, T. A., Mathern, G. W., Mosh, S. L., Nordli, D., Plouin, P., and Scheffer, I. E., 2010, Revised terminology and concepts for organization of seizures and epilepsies: Report of the ilae commission on classification and terminology, 2005-2009. Epilepsia 51, 4 (2010), 676– 685.

Blume, W., and et. al. ,2001, Glossary of descriptive terminology for ictal semiology: *Report of the ILAE task force on classification and terminology*. Epilepsia 42(9), 1212–8.

Bushaev, V., 2018, *Adam-latest trends in deep learning optimization*, https://towardsdatascience.com/adam-latest-trends-in-deep-learning-optimization-6be9a291375c, [Ziyaret tarihi: 09.06.2020].

Brownlee, J., 2017, *Gentle Introduction to the Adam Optimization Algorithm for Deep Learning*, https://machinelearningmastery.com/adam-optimization-algorithm-for-deep-learning/, [Ziyaret tarihi: 11.06.2020].

Can, B., Temmuz 2019, LSTM Ağları ile Türkçe Kök Bulma, *Bilişim Teknolojileri Dergisi*, Cilt: 12(3).

Chatterjee, C., Roychowdhury, V.P., Chong, E.K.P., 1998, On relative convergence properties of principal component analysis algorithms, *Neural Networks*, IEEE Transactions on, vol. 9, Issue 2, Mar, s:319-329.

Chan, Y.H., Wing, W.Y. NG, Yeung D.S., Chan P.K.,11-17 July 2010, Empirical comparison of forward and backward search strategies ın L-gem based feature selection with RBFNN, *Proceedings of the Ninth International Conference on Machine Learning and Cybernetics,* Qingdao, China, 978-1-4244-6527-9, 1524-1527.

Chandaka, S., Chatterjee, A., & Munshi, S. (2009). Cross-correlation aided support vector machine classifier for classification of EEG signals. *Expert Systems With Applications*, *36*(2P1), 1329-1336. https://doi.org/10.1016/j.eswa.2007.11.017.

Chaudhari, A. K. and Kulkarni, J. V., 2013, Local Entropy based Brain MR Image Segmentation, *2013 3rd IEEE International Advance Computing Conference (IACC)*, pp. 1229 – 1232.

Cheema, A., & Singh, M., 2019, Psychological stress detection using phonocardiography signal: An empirical mode decomposition approach, *Biomedical Signal Processing and Control*, *49*, 493–505. https://doi.org/10.1016/j.bspc.2018.12.028.

Chen, C. Le, Shih, Y. C., Liou, H. H., Hsu, Y. C., Lin, F. H., & Tseng, W. Y. I., 2019, Premature white matter aging in patients with right mesial temporal lobe epilepsy: A machine learning approach based on diffusion MRI data, *NeuroImage: Clinical*. https://doi.org/10.1016/j.nicl.2019.102033

Churchland, P.S., and Sejnowski, T.J., 1992, The Computational Brain, *Cambridge*, MA: MIT Press.

Ciaccio, E., Dunn, S., and M. Akay, 1993, Biosignal pattern recognition and interpretation systems: Part i. IEEE *Eng. in Med. Biol*, 13:89-97.

Çarkacı, N.,2018, *Derin Öğrenme Uygulamalarında En Sık kullanılan Hiper-parametreler*, https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4, [Ziyaret tarihi: 10.06.2020]

Das, A. B., & Bhuiyan, M. I. H.,2016, Discrimination and classification of focal and non-focal EEG signals using entropy-based features in the EMD-DWT domain, *Biomedical Signal Processing and Control*,https://doi.org/10.1016/j.bspc.2016.05.004

Demirezen Yağmur, F. ve Sertbaş, A., 2-5 Mayıs 2018, Diagnosis of Epilepsy in Brain MR Images Using DCT-Means, *26. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU-2018)*, pp. 2439-2443.

Del Gaizo, J., Mofrad, N., Jensen, J. H., Clark, D., Glenn, R., Helpern, J., & Bonilha, L., 2017, Using machine learning to classify temporal lobe epilepsy based on diffusion MRI, *Brain and Behavior*, 7(10). https://doi.org/10.1002/brb3.801

Delorme, A., Sejnowski, T., Makeig, S., 2007, Enhanced detection of artifacts in EEG data using high-order statistics and independent component analysis. *Neuroimage*, 34:1443-1449.

Dhiman, R., and Saini, J. S., 2014, Genetic algorithms tuned expert model for detection of epileptic seizures from EEG signatures, *Applied soft computing*, 19, 8-17.

Diykh, M., Abdulla, S., Saleh, K., & Deo, R. C., 2019, Fractal dimension undirected correlation graph-based support vector machine model for identification of focal and non-focal electroencephalography signals, *Biomedical Signal Processing and Control*. https://doi.org/10.1016/j.bspc.2019.101611

Dohler, F., Chernihovskyi, A., Mormann, F., Elger, C. E., and Lehnertz, K., 2006, Detecting structural alterations in the brain using a cellular neural network based classification of magnetic resonance images. *In cellular neural networks and their applications*, 1-4, IEEE.

Duda, R. O., Hart, P. E., and Stork, D. G., 2001, Pattern Classification. *John Wiley*, New York.

Duffy, A. H. B., 1997, The'what'and'how'of learning in design, invited paper, *IEEE Intelligent Systems*, 12(3), 71-76.

Duque-Muñoz, L., Espinosa-Oviedo, J. J., and Castellanos-Dominguez, C. G., 2014, Identification and monitoring of brain activity based on stochastic relevance analysis of short–time EEG rhythms, *Biomedical engineering*, 13(1), 123.

Erdoğmuş, P., 2020, *Derin Öğrenme: CNN -LSTM Mimarisi*, Basılmamış ders notları.

Eggermont, J.J., 1990. The Correlative Brain: *Theory and Experiment in Neural Interaction*, New York: Springer-Verlag.

Fisher, RS., van Emde Boas, W., Blume, W., et al.,2005, Epileptic seizures and epilepsy: defi nitions proposed by the International League Against Epilepsy (ILAE) and the Internati onal Bureau for Epilepsy (IBE). Epilepsia 2005; 46:470-2

Forsgren, L., Beghi, E., Õun, A., Sillanpää, M., 2005, The epidemiology of epilepsy in Europe a systematic review. Eur J Neurol 12: 245–253.

Freeman, W.J., 1975. Mass Action in the Nervous System, *New York: Academic Press*.

Fu, K., Qu, J., Chai, Y., & Zou, T.,2015, Hilbert marginal spectrum analysis for automatic seizure detection in EEG signals, *Biomedical Signal Processing and Control*, https://doi.org/10.1016/j.bspc.2015.01.002

Gandhi, T. K., Chakraborty, P., Roy, G. G., and Panigrahi, B. K., 2012, Discrete harmony search based expert model for epileptic seizure detection in electroencephalography, *Expert systems with applications,* 39(4), 4055-4062.

Garg, A., Jain, Rachna, 2017, Classification of EEG Signals using various Dimensionality Reduction Techniques, *International Journal of Computational Intelligence Research,* vol. 13, no.14, pp. 2309-2331.

Gotman, J., 1982, Automatic recognition of epileptic seizures in the EEG, *Electroencephalography and Clinical Neurophysiology*, vol. 54, no. 5, pp. 530–540.

Göksu, H., 2018, EEG based epileptiform pattern recognition inside and outside the seizure states, *Biomedical Signal Processing and Control*, https://doi.org/10.1016/j.bspc.2018.03.004

Gumaste P. P., & Jadhav, D. V. (2015). Image Segmentation Techniques for Brain MRI Images: A Survey. *International Journal of Modern Trends in Engineering and Research* (IJMTER) [Special Issue of ICRTET'2015], *2*(7), 1082-1088. Gupta, S.C., and Kapoor, V.K., 2002, Fundamentals of Mathematical Statistics, *Sultan Chand & Sons*, New Delphi, ISBN:81-7014-791-3.

Gupta, V., & Pachori, R. B., 2019, Epileptic seizure identification using entropy of FBSE based EEG rhythms, *Biomedical Signal Processing and Control*, *53*, https://doi.org/10.1016/j.bspc.2019.101569

Gülcü, A., and Kuş Z., Konvolüsyonel Sinir Ağlarında Hiper-Parametre Optimizasyonu Yöntemlerinin İncelenmesi. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji* 7.2 (2019): 503-522.

Haykin, S., 2009, Neural networks and learning machines, *Upper Saddle River*, NJ, USA.

Hidaka, A., and Kurita, T., 2017, Consecutive Dimensionality Reduction by Canonical Correlation Analysis for Visualization of Convolutional Neural Networks. *Proceedings of the ISCIE International Symposium on Stochastic Systems Theory and its Applications*. 2017. 160-167.

Hunyadi, B., 2014, Learning from structured EEG and fMRI data supporting the diagnosis of epilepsy, Faculty of Engineering Science Uitgegeven in eigen beheer, Belgium.

Hochreiter, S., and Schmidhuber, J., 1997, Long short-term memory. *Neural computation*,9.8, 1735-1780.

Kalayci, T., & Ozdamar, O. (1995). Wavelet preprocessing for automated neural network detection of EEG spikes. *IEEE Engineering in Medicine and Biology Magazine*, *14*(2), *160-166*.

Kaleem, M., Guergachi, A., & Krishnan, S., 2018, Patient-specific seizure detection in long-term EEG using wavelet decomposition, *Biomedical Signal Processing and Control*, *46*, 157–165. https://doi.org/10.1016/j.bspc.2018.07.006

Kamath, C., 2013, A new approach to detect epileptic seizures in electroencephalograms using teager energy, *ISRN biomedical engineering*, 2013.

Karabatak, M., M. Cevdet Ince, M.C., Avci, E., 20-22 April 2008, An expert sytem for diagnosis breast cancer based on Principal Component Analysis method, *2008 IEEE 16th Signal Processing Communication and Applications Conference,* Aydin, Turkey, 2165-0608.

Kingma, D. P., Ba, Jimmy, 2014, Adam: A Method for Stochastic Optimization, *the 3rd International Conference for Learning Representations*, San Diego. arXiv:1412.6980v9

Kotsiantis, S. B., Zaharakis, I. D. and Pintelas, P. E., 2006, Machine learning: a review of classification and combining techniques, *Artificial Intelligence Review*, 26(3), 159-190.

Krishnaveni, V, Jayaraman, S., Gunasekaran, A., & Ramadoss, K. (2008). Automatic Removal of Ocular Artifacts using JADE Algorithm and Neural Network. *World Academy of Science, Engineering and Technology International Journal of Computer, Electrical, Automation, Control and Information Engineering, 2*(4), 1330-1341.

Kurt, F., 2018, *Evrişimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi*, Doktora Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara.

Krishnaveni, V., Jayaraman, S., Manoj Kumar, P.M., Shivakumar, K., Ramadoss, K., 2005, Comparison of Independent Component Analysis Algorithms for Removal of Ocular Artifacts from Electroencephalogram. *Measurement Science Review*, 5(2), 67-78.

Lawrence, S., Giles, C. L., Tsoi A. L., 1996, Convolutional neural networks for face recognition*, Proceedings CVPR IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, San Francisco, CA, USA, pp. 217-222.

Langley, P. and Simon, H. A., 1995, Applications of machine learning and rule induction. *Communications of the ACM*, 38(11), 54-64.

Lopez, S., 2017, *Automated identification of abnormal EEGs*. MS thesis, Temple University. Available: http://www.isip.piconepress.com/publications/ms_theses/2017/abnormal

Loyek, C., Woermann, F. G., Nattkemper, T. W., 2008, Detection of Focal Cortical Dysplasia Lesions in MRG using Textural Features, *Bildverarbeitung für die Medizin*, pp. 432- 436.

Li, Y., Wang, X. D., Luo, M. L., Li, K., Yang, X. F., and Guo, Q., 2018, Epileptic seizure classification of EEGs using time–frequency analysis based multiscale radial basis functions, *IEEE journal of biomedical and health informatics*, 22(2), 386-397.

Martinez-del-Rincon, J., Santofimia, M. J., del Toro, X., Barba, J., Romero, F., Navas, P., and Lopez, J. C., 2017, Non-linear classifiers applied to EEG analysis for epilepsy seizure detection, *Expert systems with applications*, 86, 99-112.

Meyer-Bäse, A. (2004). *Pattern Recognition for Medical Imaging*. Elsevier Academic Press: USA, (Chapter 2).

Michielli N., Acharya U.R., Molinari F., 2019, Cascaded LSTM recurrent neural network for automated sleep stage classification using single-channel EEG signals, *Comput. Biol. Med.*, 106, pp. 71-81.

Minsky, M.L., and S.A. Papert, 1969. Perceptrons, *MA: MIT Press*, Cambridge.

Misiti, M., Misiti, Y., 2000, Oppenheim, G., Poggi, J.M., "Wavelet Toolbox for use with Matlab", The User's Guide, The MathWorks Inc.

Mutlu, A. Y., 2018, Detection of epileptic dysfunctions in EEG signals using Hilbert vibration decomposition, *Biomedical Signal Processing and Control*, *40*, 33–40. https://doi.org/10.1016/j.bspc.2017.08.023

Mosteller, F. and Tukey, J. W., 1968, Data analysis, including statistics, *AddisonWesley*, 2.

Nicolaou, N. and Nasuto, S.J., September 2004, Temporal Independent Component Analysis for automaticartefact removal from EEG, *2nd International Conference on Medical Signal and Information Processing*, Malta, 5- 8.

Olah, C., 2015, *Understanding LSTM Networks*, http://colah.github.io/posts/2015-08-Understanding-LSTMs/, [Ziyaret tarihi: 05.06.2020].

Ogulata, S. N., Şahin, C., and Erol, R., 2009, Neural network-based computer-aided diagnosis in classification of primary generalized epilepsy by EEG signals, *Journal of medical systems*, 33(2), 107-112.

Polamuri, S., 2017, *How to Random Forest Algorithm Works in Machine Learning*, https://dataaspirant.com/2017/05/22/random-forest-algorithm-machine-learing/, [Ziyaret Tarihi: 10 Haziran 2020].

Pitts, W., and W.S. McCulloch, 1947. How we know universals: The perception of auditory and visual forms, *Bulletin of Mathematical Biophysics*, vol. 9, pp. 127–147.

Pradhan, N., Sadasıvan, P. K., Arunodaya, G. R., 1996, Detection of seizure activity in EEG by an artificial neural network: A preliminary study, *Computers and Biomedical Research*, 29: 303-313.

Phung, D., Tran, D., Ma, W., Nguyen, P., and Pham, T., 23-25 April 2014, Using Shannon Entropy as EEG Signal Feature for Fast Person Identification, *Computational Intelligence and Machine Learning*. Bruges (Belgium).

Rajaguru, H., and Prabhakar, S. K., 2017, Hilbert transform with elman backpropagation and multilayer perceptrons for epilepsy classification, *In Electronics, Communication and Aerospace Technology (ICECA), 2017 International conference of,* 1, 571-576, IEEE.

Ripley, B. D., 2007, Pattern recognition and neural networks, *Cambridge University Press*, UK.

Rokotomalala, R., 2008, *Tanagra Project*, http://eric.univ-lyon2.fr/~ricco/tanagra/en/tanagra.html, [Ziyaret Tarihi: 10 Nisan 2019].

Rosenblatt, F., 1962, Principles of neurodynamics. Perceptrons and the theory of brain mechanisms, *Spartan Books, Washingotn* D.C., USA.

Rudie, J. D., Colby, J. B., Salamon, N., September 2015, Machine Learning Classification of Mesial Temporal Sclerosis in Epilepsy Patients, *Epilepsy research*,117:63-69, DOI: 10.1016/j.eplepsyres.2015.09.005.

Ser, G., and Bati, C. T., 2019, Derin Sinir Ağları ile En İyi Modelin Belirlenmesi: Mantar Verileri Üzerine Keras Uygulaması, *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi* 29.3: 406-417.

Siemens Medical Solutions USA, 2019, Siemens Healthineers, https://www.siemens-healthineers.com/en-us/refurbished-systems-medical-imaging-and-therapy/ecoline-refurbished-systems/magnetic-resoncance-imaging-ecoline/magnetom-symphony-tim-eco, [Ziyaret tarihi: 13 Kasım 2019].

Sikdar, D., Roy, R., & Mahadevappa, M., 2018, Epilepsy and seizure characterisation by multifractal analysis of EEG subbands, *Biomedical Signal Processing and Control*, *41*, 264–270. https://doi.org/10.1016/j.bspc.2017.12.006

Sharif, B., and Jafari, A. H., 2017, Prediction of epileptic seizures from EEG using analysis of ictal rules on Poincaré plane, *Computer methods and programs in biomedicine*, 145, 11-22.

Song, F., Mei, D., Li, H., 13-14 Oct. 2010, Feature Selection Based on Linear Discriminant Analysis, *2010 International Conference on Intelligent System Design and Engineering Application,* Changsha, China, 978-1-4244-8333-4.

Spyrou, I. M., Frantzidis, C., Bratsas, C., Antoniou, I., & Bamidis, P. D., 2016, Geriatric depression symptoms coexisting with cognitive decline: A comparison of classification methodologies, Biomedical Signal Processing and Control. https://doi.org/10.1016/j.bspc.2015.10.006

Stone, M., 1974, Cross-validatory choice and assessment of statistical predictions, *Journal of the Royal Statistical Society*, 111-147.

Subasi, A., Alkan, A., Koklükaya, E., 2004, EEG İşaretlerinin Dalgacık Dönüşümü İle Sınıflandırılması, *Teknoloji*, Cilt 7, Sayı 1, 71-80.

Subasi A., & Gursoy, M. (2010). EEG signal classification using PCA, ICA, LDA and support vector machines. *Expert Systems with Applications*, *37*(12), 8659-8666.

Subasi, A., Ahmed, A., Aličković, E., & Rashik Hassan, A., 2019, Effect of photic stimulation for migraine detection using random forest and discrete wavelet transform, *Biomedical Signal Processing and Control*. https://doi.org/10.1016/j.bspc.2018.12.011

Tsiouris, K., Markoula, S., Konitsiotis, S., Koutsouris, D. D., & Fotiadis, D. I., 2018, A robust unsupervised epileptic seizure detection methodology to accelerate large EEG database evaluation., *Biomedical Signal Processing and Control*, *40*, 275–285. https://doi.org/10.1016/j.bspc.2017.09.029

Keskin, U.,2018, *Sinir Sistemi*, https://www.universitehazirlik.org/sinir-sistemi-ders-notu-ayt-biyoloji-2019-yks/, [Ziyaret Tarihi: 10 Kasım 2019].

Kumar, T. S., Kanhangad, V., & Pachori, R. B. , 2015, Classification of seizure and seizure-free EEG signals using local binary patterns, *Biomedical Signal Processing and Control*, https://doi.org/10.1016/j.bspc.2014.08.014

Übeyli, E. D., 2008, Support vector machines for detection of electrocardiographic changes in partial epileptic patients, *Engineering applications of artificial intelligence*, 21(8), 1196-1203.

Vapnik, V.N., 1999, An overview of statistical learning theory, *IEEE Transactions on Neural Networks*, Vol. 10, Issue 5, 988-999.

Varsavsky, A., Mareels, I., and Cook, M., 2011, Epileptic Seizures and the EEG: Measurement, Model, Detection and Prediction. CRC Press.

Wang, G., Deng, Z., and Choi, K. S., 2017, Detection of epilepsy with Electroencephalogram using rule-based classifiers, *Neurocomputing*, 228, 283-290.

Wang, L., Long, X., Aarts, R. M., van Dijk, J. P., & Arends, J. B. A. M.,2019, EEG-based seizure detection in patients with intellectual disability: Which EEG and clinical factors are important *Biomedical Signal Processing and Control*, https://doi.org/10.1016/j.bspc.2018.12.003

Wikipedia, 2020, Softmax Fuction, https://en.wikipedia.org/wiki/Softmax_function, [Ziyaret tarihi: 10.06.2020]

Williams, D. R. G. H. R. and Hinton, G. E., 1986, Learning representations by backpropagating errors, *Nature*, 323, 533-536.

Yao, L., Cai, M., Chen, Y., Shen, C., Shi, L., & Guo, Y., 2019, Prediction of antiepileptic drug treatment outcomes of patients with newly diagnosed epilepsy by machine learning. *Epilepsy and Behavior*. https://doi.org/10.1016/j.yebeh.2019.04.006

Yıldırım, Ö., Baloglu, U.B. & Acharya, U.R., 2018, A deep convolutional neural network model for automated identification of abnormal EEG signals. *Neural Comput & Applic*.

Zainuddin, Z., Lai, K. H., and Ong, P., 2013, A hybrid algorithm for the initialization of wavelet neural networks: application in epileptic seizure classification, *International journal of applied physics and mathematics*, 3(5), 352.

Zhang, T., Chen, W., & Li, M., 2019, Classification of inter-ictal and ictal EEGs using multi-basis MODWPT, dimensionality reduction algorithms and LS-SVM: A comparative study, *Biomedical Signal Processing and Control*. https://doi.org/10.1016/j.bspc.2018.08.038

EKLER

EK.1. ETİK KURUL KARARI

ABANT İZZET BAYSAL ÜNİVERSİTESİ KLİNİK ARAŞTIRMALAR ETİK KURULU ONAYI
ABANT IZZET BAYSAL UNIVERSITY CLINICAL RESEARCHES ETHICS COMMITTEE APPROVAL

Sayı : 116 25./5/2017

Konu: Kararlar

BAŞVURU BİLGİLERİ (APPLICATION INFORMATION)	ARAŞTIRMANIN ADI (TITLE OF THE PROJECT)	DCT Tabanlı Farklı Boyutlarda Biyomedikal İşaret Analizi.
	SORUMLU ARAŞTIRMACI (PRINCIPAL INVESTIGATER)	Prof.Dr.Ahmet SERTBAŞ
	DİĞER ARAŞTIRMACILAR (OTHER INVESTIGATERS)	Uzm.Fatma DEMİREZEN YAĞMUR
	ARAŞTIRMA MERKEZİ (RESEARCH CENTER)	AİBÜ

KARAR (DECISION)	**Karar no (Decision No): 2017/45**	**Tarih (Date):27.04.2014**
	Prof.Dr.Ahmet SERTBAŞ'nın sorumluluğunda yapılması tasarlanan ve yukarıda başvuru bilgileri verilen araştırma dosyası ve ilgili belgelerin incelenmesi sonucunda araştırmanın gerçekleştirilmesinde etik yönden sakınca olmadığına mevcudun oy birliği/oy çokluğu ile karar verilmiştir.	

Üyeler	Uzmanlık alanı	Kurumu	İmza
Prof. Dr. Nimet KABAKUŞ (Başkan)	Çocuk Sağlığı ve Hastalıkları AD	Tıp Fakültesi	
Prof. Dr. Safiye GÜREL (Başkan Yrd.)	Radyoloji AD	Tıp Fakültesi	
Prof. Dr .Özge UZUN (Üye)	Farmakoloji AD	Tıp Fakültesi-	
Doç. Dr. Hüsamettin ÇAKICI (Üye)	Ortopedi ve Travmatoloji AD	Tıp Fakültesi	
Yrd. Doç. Dr. Mervan BEKDAŞ (Üye)	Çocuk Sağlığı ve Hastalıkları AD	Tıp Fakültesi	
Yrd. Doç. Dr. Erkan KILINÇ (Üye)	Fizyoloji AD	Tıp Fakültesi	
Yrd. Doç. Dr. İsa YILDIZ (Üye)	Anesteziyoloji ve Reanimasyon AD	Tıp Fakültesi	
Yrd.Doç.Dr.Oya KALAYCIOĞLU (Üye)	Bioistatistik	AİBÜ	
Hatice Selen SÖYLEMEZ (Üye)	Eczacı	Özel	
Av.Huri Hülya GÜNEŞ COŞKUN (Üye)	Hukukçu	Özel Hukuk Bürosu	
Abdurrahman ÇANKALOĞLU (Üye)	Öğretmen	İ.B Halk Eğitim Merkezi	

EK.2. SAĞLIK BAKANLIĞI ONAYI

EK-5

T.C. Sağlık Bakanlığı
Türkiye Kamu Hastaneleri Kurumu

BOLU İLİ KAMU HASTANELERİ BİRLİĞİ
GENEL SEKRETERLİĞİ
GİRİŞİMSEL OLMAYAN BİLİMSEL ARAŞTIRMA TALEPLERİ DEĞERLENDİRME FORMU

ARAŞTIRMA SAHİBİNİN	
Adı Soyadı	Fatma Demirezen Yağmur
Kurumu / Üniversitesi	Abant İzzet Baysal Üniversitesi / İstanbul Üniversitesi
Araştırma Yapılacak İller	Bolu
Araştırma Yapılacak Sağlık Tesisleri	Abant İzzet Baysal Üniversitesi İzzet Baysal Eğitim ve Araştırma Hastanesi
Araştırmanın Konusu	DCT (Ayrık Kosinüs Dönüşümü)Tabanlı Farklı Boyutlardaki Biyomedikal İşaret Analizi Biyomedikal işaret tanımla yöntemleriyle yapılan çalışmalarda data bir boyutlu EEG (Elektriksel Sinyal Grafiği) yada iki boyutlu MRI (Manyetik Rezonans Görüntüleme) ve demografik veriler ile işaretler dikkate alınarak hastaların cinsiyeti, geçmişi gibi analizlerle birlikte daha başka veriler kullanılarak makine öğrenme algoritmalarıyla tanımlama (teşhis) çalışmaları yapılmıştır. Gerçek hayatta ise bir doktor hastalık teşhisinde biyomedikal işaretle birlikte diğer tahlillerin hepsini kullanarak ancak tanıya gider. Burada, hem bir hem iki boyutlu iki farklı verinin birleşiminden oluşmuş ortak (füzyon) yapılı veriye aynı dönüştürme yöntemi Ayrık Kosinüs Dönüşümü (Discrete Cosine Transform) kullanılarak özellik vektörleri çıkarılacaktır. Daha sonra bu özellikler sınıflandırıcıya Yapay Sinir Ağları (Artifical Neural Network), Destekçi Vektör Makinası (Support Vector Machine), K-en Yakın Komşu (K-NearestNeighbor)input verilecek ve ardından Data Mining yöntemleri kullanılarak sınıflandırıcı sonuçlarının yüksek oranda tanınmasıyla teşhise gidilecektir.
Araştırmanın Statüsü	(Aşağıdaki kutucuklardan uygun olanı/olanları işaretleyiniz) ☐ Tezsiz Yüksek Lisans Projesi ☒ Doktora Tezi ☐ Lisans Bitirme Projesi ☐ Uzmanlık Tezi ☐ Yüksek Lisans Tezi ☐ Deneysel Araştırma Projesi ☐ Diğer ise, belirtiniz.
Sağlık Tesisi Ön İzin Formu	(X)Var / ( ) Yok
Başvuru Belgeleri	Dilekçe (X) Var / ( ) Yok Etik Kurul Kararı (X) Var / ( ) Yok Üniversite / Kurum Talebi (X)Var / ( ) Yok Araştırma Yöntemi Örneği ( ) Var / (X) Yok Araştırma Detay Formu (X) Var / ( ) Yok Kurumsal Kimlik Belgesi (X) Var / ( ) Yok Bütçe Formu ( ) Var / (X) Yok
Veri Toplama Araçları	Hastane arşivinden epilepsi teşhisi konmuş hastaların EEG ve MRI larını dijital ortama kaydetmek.
Araştırmanın Yapılacağı Tarih Aralığı	27/12/2016 - 27/12/2018
Görüş İstenilecek Birimler	
KOMİSYON GÖRÜŞÜ	
Komisyon Kararı	Oybirliği / Oyçokluğu ile alınmıştır
Muhalif Üyenin Adı ve Soyadı:	Gerekçesi

27/12/2016

Bolu İli Kamu Hastaneleri Birliği Başkanlığı Uzm.Dr.Abdullah DANIŞ Tıbbi Hizmetler Başkanı — KOMİSYONAN

Bolu İli Kamu Hastaneleri Birliği Genel Sekreterliği Üye

Bolu İli Kamu Hastaneleri Birliği Üye

Bolu İli Kamu Hastaneleri Birliği Üye Uzm. Zeynep BAYSAL

Bolu İli Kamu Hastaneleri Birliği Genel Sekreter

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Fatma DEMİREZEN YAĞMUR
Doğum Yeri	Kayseri
Doğum Tarihi	10.01.1982
Uyruğu	☑ T.C. ❒ Diğer:
Telefon	
E-Posta Adresi	fatmademirezen@ibu.edu.tr
Web Adresi	

Eğitim Bilgileri	
Lisans	
Üniversite	Haliç Üniversitesi
Fakülte	Mühendislik Fakültesi
Bölümü	Bilgisayar Mühendisliği
Mezuniyet Yılı	2006

Yüksek Lisans	
Üniversite	Haliç Üniversitesi
Enstitü Adı	Fen Bilimleri Enstitüsü
Anabilim Dalı	Bilgisayar Mühendisliği Anabilim Dalı
Programı	Bilgisayar Mühendisliği
Doktora	
Üniversite	İstanbul Üniversitesi-Cerrahpaşa
Enstitü Adı	Lisansüstü Eğitim Enstitüsü
Anabilim Dalı	Bilgisayar Mühendisliği Anabilim Dalı
Programı	Bilgisayar Mühendisliği

Makale ve Bildiriler
Demirezen Yağmur, F. ve Sertbaş, A., 2-5 Mayıs 2018, Diagnosis of Epilepsy in Brain MR Images Using DCT-Means, *26. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU-2018)*, pp. 2439-2443. Demirezen Yağmur, F. ve Sertbaş, A., 5-7 Ekim 2020, Automatic Diagnosis of Epilepsy from EEG Signals using Discrete Cosine Transform, *28. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU-2020)*, (Kabul edildi). Demirezen Yağmur, F. ve Sertbaş, A., 2020, A High-Performance Method Based on Features Fusion of EEG Brain Signal and MRI-Imaging Data for Epilepsy Classification, *Expert Systems with Applications*, (Yayım aşamasında).