

EEG SİNYALLERİNDEN ANOMALİ TESPİTİ

**2014
DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

Musa PEKER

EEG SİNYALLERİNDEN ANOMALİ TESPİTİ

Musa PEKER

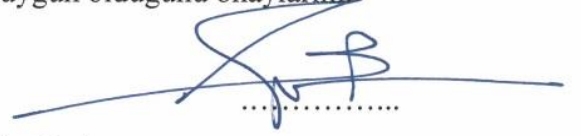
**Karabük Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalında
Doktora Tezi
Olarak Hazırlanmıştır**

**KARABÜK
Şubat 2014**

Musa PEKER tarafından hazırlanan "EEG SİNYALLERİNDEN ANOMALİ TESPİTİ" başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım

Yrd. Doç. Dr. Baha ŞEN

Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

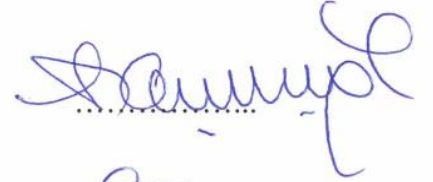


Bu çalışma, jürimiz tarafından oy birliği ile Bilgisayar Mühendisliği Anabilim Dalında Doktora Tezi olarak kabul edilmiştir. .09/01/2014

Unvanı, Adı SOYADI (Kurumu)

İmzası

Başkan: Prof. Dr. Abdullah ÇAVUŞOĞLU (YBÜ)



Üye : Doç. Dr. Haldun GÖKTAŞ (YBÜ)



Üye : Yrd. Doç. Dr. Baha ŞEN (YBÜ)



Üye : Yrd. Doç. Dr. Salih GÖRGÜNOĞLU (KBÜ)



Üye : Yrd. Doç. Dr. İlhami Muharrem ORAK (KBÜ)



Tarih .../.../2014

KBÜ Fen Bilimleri Enstitüsü Yönetim Kurulu, bu tez ile, Doktora derecesini onamıştır.

Prof. Dr. Mustafa BOZ

Fen Bilimleri Enstitüsü Müdürü



“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Musa PEKER

ÖZET

Doktora Tezi

EEG SİNYALLERİNDEN ANOMALİ TESPİTİ

Musa PEKER

Karabük Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Yrd. Doç. Dr. Baha ŞEN

Şubat 2014, 151 sayfa

EEG sinyalleri, beyin hücrelerinin toplu aktivitesini yansıtan sinyallerdir. Genelde EEG dört ana dalga şeklinden oluşmaktadır. Bunlar; alfa dalgası (8-13 Hz), beta dalgası (13-30 Hz), delta dalgası (0-4 Hz) ve teta dalgası (4-7 Hz)'dir. EEG sinyalindeki bu dalgalar, herhangi bir patoloji durumunda değişim gösterirler. Durağan olmayan EEG sinyallerinde patolojik bir durumda, sinyaldeki anlık değişimi gösteren bileşenlerin tanımlanabilmesi güçleşmektedir. Bu nedenle, karmaşık EEG verilerinin yorumlanabilmesi zor bir işlemdir. Son yıllarda, araştırmacılar uzman doktorlara yardımcı olacak sistemler üzerinde yoğunlaşmaktadır. Bu çalışmada EEG sinyallerinden anomali tespitine yönelik olarak başarı ve hız performansına dayalı yeni yöntemler geliştirilmiştir. Önerilen metotlar epilepsi hastalığı, anestezi derinliği ölçümü ve uyku verileri olmak üzere 3 farklı veri grubuna uygulanmıştır.

Birinci aşamada öznitelik seçme tabanlı bir yöntem önerilmiştir. Biyomedikal sinyal işlemede önemli sorunlardan birisi de verileri temsil edecek özniteliklerin tespitidir.

Verileri temsil edecek özniteliklerin tespiti için literatürde ortaya konmuş birçok algoritma vardır. Fakat bu algoritmalarından hangilerinin problem için etkili öznitelikleri belirleyeceği çoğu zaman deneme-yanılma yöntemi ile bulunmaktadır. Bu işlemi otomatik gerçekleştirecek bir sistem araştırmacıların işini büyük bir ölçüde kolaylaştıracaktır. Bunu gerçekleştirmek için bu çalışmada farklı EEG verilerine yönelik olarak bu verilerin en iyi şekilde temsil edileceği bir yöntem önerilmektedir. Sinyalleri temsil edecek özniteliklerin tespitinden sonra etkili özniteliklerin tespiti için öznitelik seçme algoritmaları uygulanmıştır. Son aşamada tespit edilen etkili özniteliklerle beraber yüksek sınıflandırma doğruluğu veren sınıflandırma algoritmasının tespiti gerçekleştirilmiştir.

İkinci aşamada EEG sinyallerinin sınıflandırılması için karmaşık sınıflayıcı tabanlı yeni bir metot sunulmaktadır. Öncelikle farklı seviyelerde ikili ağaç karmaşık dalgacık dönüşümü (IAKDD) ile EEG verilerine ait özellikler çıkartılarak boyut azaltımı yapılmıştır. Sonraki aşamada bu özellik vektörleri kullanılarak istatistik tabanlı beş özellik (maksimum değer, minimum değer, ortalama değer, standart sapma, ortanca değer) elde edilerek kompleks değerli sinir ağına (KDYSA) giriş olarak sunulmuştur. Karmaşık değerli yapay sinir ağında Taguchi yöntemiyle parametre optimizasyonu yapılarak daha kararlı bir modelin oluşturulması hedeflenmiştir.

Üçüncü aşamada EEG verilerinin sınıflandırılmasına yönelik paralel hesaplama tabanlı bir yaklaşım sunulmaktadır. Bunun için paralel programlama ile yüksek performanslı uygulamalar geliştirmeyi sağlayan CUDA kütüphanesinden yararlanılmıştır.

Sonuç olarak hem başarı performansı hem de hız performansı açısından yüksek başarı oranları elde edilmiştir.

Anahtar Sözcükler : EEG, karmaşık sinir ağı, CUDA, öznitelik seçme, sınıflandırma, Taguchi metodu.

Bilim Kodu : 902.1.014

ABSTRACT

Ph. D. Thesis

ANOMALY DETECTION IN EEG SIGNALS

Musa PEKER

Karabük University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering

Thesis Advisor:

Assist. Prof. Dr. Baha ŞEN

February 2014, 151 pages

EEG signals are signals that reflecting collective activity of brain cells. Generally, EEG comprises 4 main wave types. These are alpha waves (8-13 Hz), beta waves (13-30 Hz), delta waves (0-4 Hz), and theta waves (4-7 Hz). In EEG signals, these wave types show changes in pathological situations. It may be difficult to identify the components that show momentary changes in the EEG signal in pathological situations. Therefore, the interpretation of complex EEG data is a difficult process. In recent years, researchers have focused on the systems that will help to doctors. In this study, new methods have been developed based on success and speed performance in order to identify anomalies from EEG signals. Recommended methods applied to 3 different data group including epilepsy, depth of anesthesia measurement and sleep data. In the first phase, a feature selection based method was proposed. One of the most important problems in classifying EEG signals is the identification of the features that will represent the data. Various algorithms used for the identification of features represent data, but most of the time, determining which algorithms

identify the effective features for the specified problem depends on the trial and error method. A system that will automatically generate the identification of effective features will facilitate the works of the researchers to a great extent. A current study seeks to determine a method that will ensure the identification of features that can best represent data. Previous studies in literature were researched with this purpose in mind and 41 features that have previously been used in the classification of sleep stage were extracted. Feature selection algorithms are used to identify the features that provide the highest effect. Identification of the classification algorithm that provided the highest accuracy rates was possible with the features selected in the last stage.

In the second phase, complex classifier based a new method was presented for the classification of EEG signals. To carry out the study, first the features of EEG data are extracted using a dual-tree complex wavelet transformation (DTCWT) at different levels of granularity to obtain size reduction. In subsequent phases, five features (based on statistical measurements-maximum value, minimum value, average value, standard deviation, median value) are obtained by using the feature vectors, and are presented as the input dimension to the complex-valued neural networks (CVANN). Parameter optimization is undertaken in the CVANN using the Taguchi method to ensure a consistent model.

In the third step to accelerate the classification of EEG data, parallel computing based approach is presented. For doing this, parallel programming and CUDA library, which provides high performance applications, were used.

Finally, high success rates were obtained in terms of both success performance and speed performance.

Key Word : EEG, complex-valued neural networks, CUDA, feature selection, classification, Taguchi method.

Science Code : 902.1.014

TEŞEKKÜR

Doktora öğrenimim süresince bana her türlü desteği veren, yorumları ve yönlendirmeleriyle ufkumu açan, pozitif yapısıyla motivasyonumu üst düzeyde tutan, tez danışmanım, değerli hocam Yrd. Doç. Dr. Baha ŞEN'e,

Farklı bakış açıları sunarak hep daha iyiye gitmem için beni teşvik eden, bilgi birikimi ve yardımlarını esirgemeyen değerli hocalarım Prof. Dr. Abdullah ÇAVUŞOĞLU, Prof. Dr. Fatih Vehbi ÇELEBİ, Yrd. Doç. Dr. Salih GÖRGÜNOĞLU ve Doç. Dr. Haldun GÖKTAŞ'a,

Doktora çalışmalarım boyunca burs imkânı sağlayan Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'na (TÜBİTAK),

Ayrıca bu günlere gelmemde çok büyük emekleri olan, bana maddi manevi her türlü desteği sağlayan anne ve babama,

Varlığından ve sevgisinden güç aldığım, her konuda bana destek olan sevgili eşim Nilgün PEKER'e sonsuz teşekkürler.

Bu çalışmamı, biricik kızım Nilüfer PEKER'e atfediyorum.

İÇİNDEKİLER

Sayfa

KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vii
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ	xvii
SİMGELER VE KISALTMALAR DİZİNİ	xix
BÖLÜM 1.	1
GİRİŞ	1
BÖLÜM 2.	6
EEG SİNYALLERİ	6
2.1. EEG BANTLARI.....	7
2.2. EEG VERİLERİNİN ÖLÇÜLMESİ.....	9
2.3. EEG KULLANIM ALANLARI	10
BÖLÜM 3.	11
SINIFLANDIRMA PROBLEMLERİ	11
3.1. EPİLEPSİ HASTALIĞI.....	11
3.2. UYKU DÜZENSİZLİKLERİ	12
3.2.1. Uyku Evreleri.....	13
3.2.2. Hipnogram	14
3.3. ANESTEZİ VE ANESTEZİ DERİNLİĞİ	15
BÖLÜM 4.	17
LİTERATÜR TARAMASI.....	17
4.1. EPİLEPSİ HASTALIĞININ TEŞHİSİ İLE İLGİLİ ÇALIŞMALAR.....	17

	<u>Sayfa</u>
4.2. UYKU EVRELERİNİN TESPİTİ İLE İLGİLİ LİTERATÜR ÇALIŞMASI	19
4.3. ANESTEZİ DERİNLİĞİNİN TESPİTİ İLE İLGİLİ LİTERATÜR ÇALIŞMASI	22
BÖLÜM 5.	25
VERİ SETLERİ	25
5.1. BONN ÜNİVERSİTESİ EPİLEPSİ VERİ SETİ	25
5.2. YILDIRIM BEYAZIT ÜNİVERSİTESİ EPİLEPSİ VERİ SETİ	26
5.3. ST. VINCENT’S UNIVERSITY HOSPITAL AND UNIVERSITY COLLEGE DUBLIN (UCD) UYKU EVRELERİ VERİ SETİ	28
5.4. YILDIRIM BEYAZIT ÜNİVERSİTESİ ANESTEZİ VERİ SETİ	30
BÖLÜM 6.	32
METOT	32
6.1. EEG VERİLERİNİN TEMİZLENMESİ VE FİLTRELEME AŞAMALARI	33
6.2. YÖNTEM 1: ETKİLİ ÖZNETELİK SEÇME VE SINIFLANDIRMA ALGORİTMALARININ TESPİTİ	35
6.2.1. Öznitelik Çıkarma Algoritmaları	35
6.2.1.1. Zaman Tabanlı Öznitelikler	35
6.2.1.2. Lineer Olmayan Öznitelikler	37
6.2.1.3. Frekans Tabanlı Öznitelikler	38
6.2.1.4. Entropi Tabanlı Öznitelikler	40
6.2.2. Öznitelik Seçme Algoritmaları	42
6.2.2.1. Hızlı Korelasyon Tabanlı Filtre	42
6.2.2.2. Minimum Fazlalık Maksimum İlişki	43
6.2.2.3. Fisher Puanlama Algoritması	45
6.2.2.4. T-testi Algoritması	46
6.2.2.5. Relief Algoritması	47
6.2.3. Sınıflandırma Algoritmaları	47
6.2.3.1. Karar Ağaçları	48
6.2.3.2. İleri Beslemeli Yapay Sinir Ağları	48
6.2.3.3. Radyal Tabanlı Yapay Sinir Ağları	49

	<u>Sayfa</u>
6.2.3.4. Destek Vektör Makineleri.....	49
6.2.3.5. Rastgele Orman Algoritması.....	50
6.3. YÖNTEM 2: KARMAŞIK SAYI TABANLI ALGORİTMALAR.....	50
6.3.1. Karmaşık Dalgacık Dönüşümü.....	51
6.3.2. Karmaşık Değerlikli Sinir Ağları	55
6.3.2.1. Matematiksel Model	55
6.3.2.2. Karmaşık Değerlikli Sınıflandırıcıların Avantajları	59
6.3.3. Parametrelerin En İyi Değerlerini Bulma	60
6.3.3.1. Parametreler	60
6.3.3.2. Taguchi Metodu	63
6.4. YÖNTEM 3: CUDA PARALEL İŞLEM MİMARİSİ İLE HIZ OPTİMİZASYONU	63
6.4.1. CUDA Programlama Adımları	64
6.4.2. CUDA Mimarisi ve Programlama	64
BÖLÜM 7.	72
GELİŞTİRİLEN YAZILIMLAR	72
7.1. YÖNTEM 1 AŞAMASINDA GELİŞTİRİLEN YAZILIMLAR	72
7.1.1. Arayüz.....	72
7.1.2. Öznitelik Seçme Aşaması	72
7.1.3. Sınıflandırma Aşaması.....	73
7.1.3.1. İleri Beslemeli Sinir Ağı	73
7.1.3.2. Karar Ağacı Uygulaması.....	76
7.1.3.3. Radyal Temelli Sinir Ağı	79
7.1.3.4. Destek Vektör Makineleri.....	80
7.1.3.5. Rastgele Orman Algoritması.....	82
7.2. YÖNTEM 2 AŞAMASINDA GELİŞTİRİLEN YAZILIM	85
7.3. YÖNTEM 3 AŞAMASINDA GELİŞTİRİLEN YAZILIMLAR	86
BÖLÜM 8.	88
UYGULAMA VE DEĞERLENDİRME	88
8.1. YÖNTEM 1 İLE GERÇEKLEŞTİRİLEN ÇALIŞMALAR	88

	<u>Sayfa</u>
8.1.1. Uygulama 1: Öznitelik Seçme ve Sınıflandırma Algoritmalarını Kullanarak Uyku Evrelerinin Sınıflandırılması Üzerinde Karşılaştırmalı Bir Çalışma.....	88
8.1.2. Uygulama 2: Sınıflandırma Algoritmaları ve FCBF Öznitelik Seçme Algoritmasını Kullanarak Otomatik Epilepsi Teşhisi İçin Yeni Yaklaşımlar	104
8.2. YÖNTEM 2 İLE GERÇEKLEŞTİRİLEN ÇALIŞMALAR	109
8.2.1. Uygulama 1: Karmaşık Değerlikli Sınıflayıcılar ve Taguchi Yöntemini Kullanarak Otomatik Epilepsi Teşhisi İçin Yeni Bir Hibrit Yöntem	109
8.2.2. Uygulama 2: EEG Sinyallerini Kullanarak Otomatik Epilepsi Teşhisi İçin Yeni Bir Karmaşık Değerlikli Akıllı Sistem	122
8.3. YÖNTEM 3 İLE GERÇEKLEŞTİRİLEN ÇALIŞMALAR	126
8.3.1. Uygulama 1: CuEEG: EEG Verilerinin Hızlı İşlenmesi için GPU Tabanlı Bir Yaklaşım	126
8.3.2. Uygulama 2: Anestezi Verileri Üzerinde Hıza Dayalı Performans Uygulamaları.....	135
BÖLÜM 9.	140
SONUÇLAR.....	140
KAYNAKLAR	142
ÖZGEÇMİŞ	151

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1.	İlk kaydedilen EEG işareti	6
Şekil 2.2.	EEG işaretinin farklı durumlarda aldığı şekiller	7
Şekil 2.3.	EEG işaretlerinin klinik ilgi frekans bantlarına ait şekiller.....	8
Şekil 2.4.	Uluslararası 10–20 EEG elektrot yerleştirme sistemi	10
Şekil 3.1.	Normal bir insanın uyku hipnogramı	15
Şekil 5.1.	A,B,C,D ve E kümelerine ait örnek EEG işaretleri.....	26
Şekil 5.2.	Bir epilepsi hastasının atak yokken EEG görüntüsü	27
Şekil 5.3.	Bir epilepsi hastasının atak esnasında alınan EEG görüntüsü.....	27
Şekil 5.4.	Bir epilepsi hastasının atağın hemen arkasından EEG görüntüsü.....	28
Şekil 5.5.	Bir epilepsi hastasının atağın yaklaşık 17 dakika sonrasındaki EEG görüntüsü.....	28
Şekil 5.6.	Uykunun farklı evreleri için EEG sinyalleri	29
Şekil 5.7.	BIS ekranı.....	31
Şekil 6.1.	EEG sinyalinin 0-55 Hz arasında filtreleme ve yumuşatma filtresi aşamalarından geçmesi.....	33
Şekil 6.2.	Filtreleme aşamasından önceki EEG ve filtreleme aşamasından sonraki EEG sinyali.....	34
Şekil 6.3.	Örnek EEG sinyalinin 30 sn' lik epoklara bölünmesi.....	34
Şekil 6.4.	ADD ile alt bantlara ayrışma.....	39
Şekil 6.5.	Değişime karşı duyarsızlık	52
Şekil 6.6.	Bir görüntünün dört seviyeli ayrık dalgacık dönüşümünün seviyeleri ...	53
Şekil 6.7.	Karmaşık dalgacık dönüşümü katsayılarının görüntüleri.....	53
Şekil 6.8.	İki boyutlu standart ADD'nin yönlülük özelliği	54
Şekil 6.9.	İki boyutlu IAKDD'nün yönlülük özelliği.....	54
Şekil 6.10.	Reel ve analitik dalgacığın gösterimi	55
Şekil 6.11.	İkili ağaç karmaşık dalgacık dönüşümü	56
Şekil 6.12.	Giriş, ağırlık, eşik, ve çıkış değerleri kompleks sayılardan oluşan karmaşık değerlikli sinir ağı	57
Şekil 6.13.	Karmaşık değerlikli sinir ağı	57

Sayfa

Şekil 6.14. Reel değerlikli 2 giriş ve 2 ağırlık değerine sahip sinir ağının, karmaşık düzlemde tek bir giriş ve tek bir ağırlık değeri ile temsili	59
Şekil 6.15. GF106 mimarisine ait detaylar	65
Şekil 6.16. Nvidia Quadro 2000 Mimarisi (Akış işlemcisi ve CUDA çekirdeği	67
Şekil 6.17. Warp çizelgeleyici	68
Şekil 6.18. Örnek bir ızgara yapısı	69
Şekil 7.1. Geliştirilen sistemin ekran ara yüzü	72
Şekil 7.2. Öznitelik seçme aşaması	73
Şekil 7.3. Veri seçme ekranı	74
Şekil 7.4. Ayar penceresi	74
Şekil 7.5. Eğitim işlemleri penceresi	75
Şekil 7.6. Sonuç ekranı	75
Şekil 7.7. Hata grafiği	76
Şekil 7.8. Veri giriş ekranı	76
Şekil 7.9. Karar ağacı karar yapısı	77
Şekil 7.10. Performans değerlendirme ekranı	77
Şekil 7.11. Performans değerlendirme ekranı-2	78
Şekil 7.12. Sonuçların grafiksel sunumu	78
Şekil 7.13. RNN algoritması için geliştirilen yazılımın ara yüzü - Veriler ve ayarlar penceresi	79
Şekil 7.14. Sonuç ekranı	79
Şekil 7.15. Veri seçme ekranı	80
Şekil 7.16. Ayarlamaların yapıldığı pencere	81
Şekil 7.17. Çekirdek fonksiyon seçimi	81
Şekil 7.18. Sonuç ekranı	82
Şekil 7.19. Veri giriş ekranı	83
Şekil 7.20 Karar ağacı karar yapısı	83
Şekil 7.21. Performans değerlendirme ekranı	83
Şekil 7.22. Performans değerlendirme ekranı-2	84
Şekil 7.23. Sonuçların grafiksel sunumu	84
Şekil 7.24. Karmaşık sinir ağı yazılımı	85
Şekil 7.25. Aktivasyon fonksiyonları	85
Şekil 7.26. Performans değerlendirme ve grafiksel sonuçlar	86

	<u>Sayfa</u>
Şekil 7.27. GPU platformu	87
Şekil 7.28. CPU platformu	87
Şekil 8.1. Uygulama 1’de önerilen metot.....	89
Şekil 8.2. Deney 1’ in sonucunda seçilen özniteliklerin sayısının artması ile sınıflandırma doğruluğu ve hesaplama zamanındaki değişimler	90
Şekil 8.3. Deney 2’nin sonucunda seçilen özniteliklerin sayısının artması ile sınıflandırma doğruluğu hesaplama zamanındaki değişimler	92
Şekil 8.4. Deney 3’ un sonucunda seçilen özniteliklerin sayısının artması ile sınıflandırma doğruluğu ve hesaplama zamanındaki değişimler	94
Şekil 8.5. Deney 4’ ün sonucunda seçilen özniteliklerin sayısının artması ile sınıflandırma doğruluğu ve hesaplama zamanındaki değişimler	96
Şekil 8.6. Deney 5 sonucunda seçilen öznitelikler ile elde edilen sınıflandırma doğrulukları ve hesaplama zamanları.....	98
Şekil 8.7. Her uyku evresi için performans değerleri.....	100
Şekil 8.8. FCBF algoritmasının ilk aşamasında elde edilen SU değerleri	105
Şekil 8.9. Epileptik atak tespiti için önerilen metot	106
Şekil 8.10. Öznitelik seçmeden önce ve sonraki aşamalarda sınıflandırıcıların performansları	107
Şekil 8.11. Epileptik atak tespiti için uygulanan metodun blok diyagramı.....	110
Şekil 8.12. Parametre etkilerinin grafiksel gösterimi	114
Şekil 8.13. Bulunan en iyi parametre değerleri dikkate alınarak hesaplanan RMSE değerleri.....	116
Şekil 8.14. Epileptik atak tespiti için önerilen yöntem.....	124
Şekil 8.15. Deney 1’ in fold 1 aşamasında elde edilen sonuçlar ve Deney 2’nin fold 10 aşamasında elde edilen sonuçlar	124
Şekil 8.16. Epileptik atak tespiti için önerilen yöntem.....	127
Şekil 8.17. CUDA kullanarak geri yayımlı sinir ağının matris çarpım.....	129
Şekil 8.18. CUDA donanımı üzerinde çalışacak sigmoid fonksiyonu için yazılan kernel fonksiyonu	130
Şekil 8.19. Gizli katman nöron sayısına göre değişen speed-up değerleri.....	132
Şekil 8.20. İterasyon sayısına göre değişen speed-up değerleri	133
Şekil 8.21. İterasyon-MSE grafiği.....	134
Şekil 8.22. 44-10-1 mimarisine sahip yapay sinir ağı	136
Şekil 8.23. 44-10-10-1 mimarisine sahip yapay sinir ağı.....	137

	<u>Sayfa</u>
Şekil 8.24. 44-20-20-1 mimarisine sahip yapay sinir ağı.....	138
Şekil 8.25. 44-50-1 mimarisine sahip yapay sinir ağı	139

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 2.1.	EEG işaretlerinin klinik ilgi frekans bant aralıkları	8
Çizelge 3.1.	EEG özelliklerinin frekans, genlik ve zaman karakteristikleri.....	14
Çizelge 3.2.	Uyku evreleri ve her evrenin genel karakteristiği	14
Çizelge 5.1.	Veri grubunun karakteristikleri	30
Çizelge 5.2.	Anestezi seviyelerinin skorlanması	30
Çizelge 6.1.	Öznitelik tablosu.....	35
Çizelge 6.2.	İstatiksel özniteliklerin kısa açıklamaları	36
Çizelge 6.3.	Hjorth parametreleri	37
Çizelge 6.4.	Bu çalışmada kullanılan ekran kartlarının özellikleri.....	65
Çizelge 8.1.	Bulunan en iyi sonuçlara ait öznitelik sayıları ve doğruluk oranları..	91
Çizelge 8.2.	Bulunan en iyi sonuçlara ait öznitelik sayıları ve doğruluk oranları..	93
Çizelge 8.3.	Bulunan en iyi sonuçlara ait öznitelik sayıları ve doğruluk oranları..	95
Çizelge 8.4.	Bulunan en iyi sonuçlara ait öznitelik sayıları ve doğruluk oranları..	97
Çizelge 8.5.	5 farklı deney sonucunda elde edilen en iyi değerler	99
Çizelge 8.6.	Önerilen metot ile manuel skorlamanın karşılaştırılması.....	100
Çizelge 8.7.	Önerilen metot ile manuel skorlamanın karşılaştırılması.....	101
Çizelge 8.8.	Uyku evrelerinin sınıflandırılması ile ilgili yapılan çalışmalar ve karşılaştırmalı analiz.....	102
Çizelge 8.9.	FCBF ile seçilen öznitelikler	106
Çizelge 8.10.	Epilepsi teşhisi için önerilen metotlar ile literatürdeki diğer çalışmaların karşılaştırmalı analizleri.....	108
Çizelge 8.11.	Faktörlerin alt ve üst seviye değerleri	111
Çizelge 8.12.	Taguchi deneyleri için faktörler ve onların seviye değerleri.....	111
Çizelge 8.13.	Parametre aralık değerlerine bağlı olarak Taguchi metoduyla oluşan parametre değerleri ve deneyler sonucu elde edilen sonuçlar.....	113
Çizelge 8.14.	Taguchi deney tasarımı yönteminde elde edilen Sinyal/Gürültü (S/G) oranları.....	113

Çizelge 8.15. IAKDD-KDYSA-1, IAKDD-KDYSA-2 ve IAKDD-KDYSA-3 modelleri için faktörlerin parametre optimizasyonu sonucunda elde edilen optimal değerleri	115
Çizelge 8.16. Otomatik epilepsi teşhisi için karmaşık değerlikli yöntemler kullanarak (IAKDD+KDYS-1, IAKDD+KDYS-2 ve IAKDD+KDYS-3) elde edilen doğruluk oranı, özgüllük, duyarlılık ve RMSE değerleri.....	116
Çizelge 8.17. Literatürdeki diğer metotlarla karşılaştırmalı analiz	119
Çizelge 8.18. 10-kere çapraz doğrulama sonucu elde edilen istatistikî performans değerleri.....	125
Çizelge 8.19. Epileptik atak tespiti için diğer araştırmacıların elde ettikleri sonuçlarla karşılaştırmalı analiz	125
Çizelge 8.20. Gizli katman nöron sayılarına göre sınıflandırma süreleri(msn)	132
Çizelge 8.21. İterasyon değerlerine göre sınıflandırma süreleri(msn)	133
Çizelge 8.22. Performans değerlendirme kriterlerine göre elde edilen sonuçlar....	134
Çizelge 8.23. Literatürdeki çalışmalar ile doğruluk değerlerinin kıyaslanması	134
Çizelge 8.24. 44-10-1 mimarisine sahip bir ağın performans deneyleri.....	136
Çizelge 8.25. 44-10-10-1 mimarisine sahip bir ağın performans deneyleri	137
Çizelge 8.26. 44-20-20-1 mimarisine sahip bir ağın performans deneyleri	138
Çizelge 8.27. 44-50-1 mimarisine sahip bir ağın performans deneyleri.....	139

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

α	: alfa bandı
β	: beta bandı
θ	: teta bandı
δ	: delta bandı
x_n	: 1,2,3... n bir zaman serisi
N_δ	: sinyal türevlerindeki işaretlerin değişikliklerin sayısı
$WV(t, f)$: sinyalinin t anındaki ve f frekansındaki enerji dağılımıdır.
f^*	: f fonksiyonunun kompleks eşleniğini
ψ	: ana dalgacık fonksiyonu
P_f	: olasılık yoğunluk fonksiyonu
$C_i^k(l)$: korelasyon integrali
$p(\pi)$: ilişkili frekans değeri
$IG(A B)$: A'nın B değerlerine bağlı bilgi kazancı
$H(A)$: A değişkeninin entropisi
$H(B)$: B değişkeninin entropisi
$P(a_i)$: A değişkeninin olasılık değeri
$H(A B)$: A'nın B değerlerine bağlı entropisi
$p(x_i)$: x değişkeninin marjinal olasılık fonksiyonu
$p(y_i)$: y değişkeninin marjinal olasılık fonksiyonu
$p(x_i, y_j)$: bağlantı olasılık dağılımı
$I(x, y)$: x ve y'nin karşılıklı bilgi miktarı
$g[n]$: yüksek geçiren filtre
$f[n]$: alçak geçiren filtre
W_{nm}	: n nöronu ile m nöronu arasındaki karmaşık değerli bağlantı ağırlığıdır.
X_m	: m nöronunun kompleks değerli giriş sinyali

V_n	: n nöronunun kompleks değerli eşik değeri
$f_R(u)$: aktivasyon fonksiyonu
W_{ml}	: giriş katman nöronu l ve gizli katman nöronu m arasındaki ağırlık değeri
V_{nm}	: gizli katman nöronu m ve çıkış katmanı nöronu n arasındaki ağırlık değeri
θ_m	: gizli katman nöronu m için eşik değeri
γ_n	: çıkış katmanı nöronu n için eşik değeri
δ_n	: hedef çıkış ile elde edilen çıkış değeri arasında hata miktarı

KISALTMALAR

REM	: Rapid Eye Movement (hızlı göz hareketleri)
PSG	: Polisomnografik kayıt
EOG	: Elektrokülogram
EMG	: Elektromiyogram
R&K	: Rechtschaffen & Kales
N-REM	: Non-Rapid Eye Movement (hızlı göz hareketleri olmayan uyku)
SWS	: Slow Wave Sleep (yavaş dalgalı uyku)
GPU	: Graphics Processing Unit (grafik işlem birimi)
CUDA	: Compute Unified Device Architecture (birleşik hesap cihazı mimarisi)
ANFIS	: Adaptive Neuro Fuzzy Inference System (adaptif sinir ağına dayalı bulanık çıkarım sistemi)
BIS	: Bispectral Index
SEF	: Spectral Edge Frequency (izgesel köşe frekansı)
SE	: State Entropy (durum entropisi)
RE	: Response Entropy (cevap entropisi)
WAVCNS	: Wavelet Analysis Value for Central Nervous System Monitoring
AO	: Aritmetik Ortalama
MaxV	: Maximum Value (maksimum değer)
MinV	: Minimum Value (minimum değer)
SD	: Standard Deviation (standart sapma)
V	: Varyans (V)

MN	: Medyan (MN)
ZC	: number of Zero Crossing (sıfır geiř sayısı)
SK	: Skewness (arpıklık)
KH	: Kurtosis (basıklık)
PFD	: Petrosian Fractal Dimension (petrosian fraktal uzunluęu)
REn	: Rényi Entropy (renyi entropi)
SpEn	: Spektral Entropy (spektral entropi)
PEn	: Permütasyon Entropi
ApEn	: Approximate Entropy (yaklaşık entropi)
WV-1	: Wigner Ville katsayısı 1
WV-2	: Wigner Ville katsayısı 2
WV-3	: Wigner Ville katsayısı 3
WV-4	: Wigner Ville katsayısı 4
HA	: Hjorth Activity (hjorth aktivitesi)
HM	: Hjorth Mobility (hjorth hareketlilięi)
HC	: Hjorth Complexity (hjorth karmařıklıęı)
MCL	: Mean Curve Length (ortalama eęri uzunluęu)
HE	: Hurst Exponent (hurst üsteli)
ME	: Mean Energy (ortalama enerji)
MTE	: Mean Teager Energy (ortalama teager enerjisi)
DFA	: Detrended Fluctuation Analysis
ADD	: Ayrık Dalgacık Dönüřümü
D3-1	: 3. seviye detay katsayılarının mutlak deęerlerinin ortalaması
D4-1	: 4. seviye detay katsayılarının mutlak deęerlerinin ortalaması
D5-1	: 5. seviye detay katsayılarının mutlak deęerlerinin ortalaması
A5-1	: 5. seviye yaklaşıklık katsayılarının mutlak deęerlerinin ortalaması
D3-2	: 3. seviye detay katsayılarının ortalama gücü
D4-2	: 4. seviye detay katsayılarının ortalama gücü
D5-2	: 5. seviye detay katsayılarının ortalama gücü
A5-2	: 5. seviye yaklaşıklık katsayılarının ortalama gücü
D3-3	: 3. seviye detay katsayılarının standart sapması
D4-3	: 4. seviye detay katsayılarının ortalama gücü
D5-3	: 5. seviye detay katsayılarının ortalama gücü

A5-3	:	5. seviye yaklaşıklık katsayılarının ortalama gücü
D3-4	:	3. seviye detay katsayılarının mutlak ortalama değerlerinin oranı
D4-4	:	4. seviye detay katsayılarının mutlak ortalama değerlerinin oranı
D5-4	:	5. seviye detay katsayılarının mutlak ortalama değerlerinin oranı
A5-4	:	5. seviye yaklaşıklık katsayılarının mutlak ortalama değerlerinin oranı
FCBF	:	Fast Correlation Based Filter (hızlı korelasyon tabanlı filtre)
SU	:	Symmetric Uncertainty (simetrik belirsizlik)
mRMR	:	Minimum Redundancy Maximum Relevance (minimum fazlalık maksimum ilişki)
maxMR	:	Maximum Relevance (maksimum ilişki)
minMV	:	Minimum Redundancy (minimum artıklık)
MID	:	Mutual Information Difference (ortak bilgi farkı)
MIQ	:	Mutual Information Quotient (ortak bilgi oranı)
YSA	:	Yapay Sinir Ağları
RNN	:	Radial Basis Function Neural Network (radyal tabanlı yapay sinir ağı)
SVM	:	Support Vector Machines (destek vektör makineleri)
DT	:	Decision Tree (karar ağacı)
RF	:	Random Forest algorithm (rastgele orman algoritması)
FFNN	:	Feed-Forward Neural Network (ileri beslemeli yapay sinir ağı)
IAKDD	:	İkili Ağaç Karmaşık Dalgacık Dönüşümü
KDYSA	:	Karmaşık Değerlikli Yapay Sinir Ağı
W	:	Wake (uyanık)
AASM	:	American Academy of Sleep Medicine
MT	:	Movement Time
S1	:	AASM standartlarında derin uyku 1 evresi
S2	:	AASM standartlarında derin uyku 2 evresi
S3	:	AASM standartlarında derin uyku 3 evresi
S4	:	AASM standartlarında derin uyku 4 evresi
CV	:	Cross Validation (çapraz doğrulama)
S	:	iterasyon değeri
HN	:	number of Hidden Layer Neuron (gizli katman nöron sayısı)

- L : Learning rate (öğrenme oranı)
- M : Momentum oranı
- HAF : Hidden Layer Activation Function (gizli katman aktivasyon fonksiyonu)
- RMSE : Root Mean Square Error (ortalama karesel hata karekökü)
- CUBLAS : CUDA Basic Linear Algebra Subroutines

BÖLÜM 1

GİRİŞ

Elektroenseleogram (EEG) sinyalleri, beyin hücrelerinin toplu aktivitesini yansıtan sinyallerdir. Bu sinyaller saçlı deri üzerinden elektrotlar vasıtasıyla alınan sinyallerdir. EEG 5 ana dalga şeklinden oluşmaktadır. Bunlar; delta dalgası (0.5~3.5 Hz), teta dalgası (4~7 Hz), alfa dalgası (8~12 Hz), beta dalgası (12~22 Hz) ve gamma dalgası (22~30 Hz)'dir. EEG sinyalindeki bu dalgalar, herhangi bir patoloji durumunda değişim gösterirler. Durağan olmayan EEG sinyallerinde patolojik bir durumda, sinyaldeki anlık değişim gösteren bileşenlerin tanımlanabilmesi güçleşmektedir [1]. Kolb ve Whishaw, bazı epilepsi hastalarının ataklarını tespit etmenin çok zor olduğunu ifade ettiler [2]. Ve hastanın uykuda ve uyanık durumda sürekli gözlem altında tutulması ve EEG kaydına bakılması gerektiğini belirtmişlerdir. Klinik uygulamalarda EEG verileri, uzman doktor tarafından gözle analiz edildiği için, bu işlem göz ve zihin açısından oldukça stresli ve yorucu olmaktadır. Saatlerce hatta günlerce kaydedilmiş EEG verileri 5-10 saniyelik çerçeveler şeklinde bilgisayar ekranından geçerken analiz edilmektedir [3]. Farklı eğitim almış uzmanlar tarafından yorumlanan bu EEG verileri, tutarsız bilgi kayıtlarının oluşmasına sebep olabilmektedir.

Yukarıda belirtilen nedenlerden dolayı, EEG işaretlerinin tutarlı ve uygun bir yöntem ile analiz edilmesi gerekmektedir. Bu çalışmada EEG işaretlerinden yararlanarak 3 farklı probleme yönelik etkili çözümler aranmıştır. Bunlar sırasıyla; epilepsi teşhisi, uyku evrelerinin sınıflandırılması ve anestezi derinliğinin kestirimi konularıdır. 3 farklı problemin seçilmesinin nedeni önerilen metotların farklı durumlarda aynı başarıyı gösterip göstermediğinin tespitidir. Bu sınıflandırma problemleri hakkında kısa bilgiler aşağıda sunulmaktadır.

Epilepsi: Beyin milyonlarca sinir hücresinden oluşmaktadır. Bu nedenle oldukça karmaşık bir yapıya sahiptir. İşlevler beyin hücreleri ile vücudun bütün kısımları arasında akan küçük miktardaki elektrik yükleri vasıtasıyla gerçekleşmektedir [4]. Epilepsi; karmaşık bir yapıya sahip olan beynin normal elektriksel fonksiyonlarında, zaman zaman kısa kesintiler ve düzensizlikler meydana getiren nörolojik bir hastalıktır. Farklı tepkilerde kendisini hissettiren bir hastalıktır. Bu belirtiler; bayılma, morarma, sıçrama, çırpınma, anlamsız bakma ve dalma şeklinde olabilir. Bahsi geçen geçici kesintileri veya istemsiz düzensizlikleri "nöbet" olarak tanımlamak mümkündür. Her nöbet epilepsiye işaret etmez. İnsanlar yaşantılarının herhangi bir döneminde bir nöbete maruz kalabilir. Fakat beyindeki nöronal işlevlerde, beyinden kaynaklanan ve kişide tekrarlama eğilimi gösteren nöbetler varsa "epilepsi" terimini kullanmak doğru olacaktır.

Uyku rahatsızlıkları ve uyku evreleri: Sağlıklı bir uyku günlük hayatı olumlu etkileyen bir faktördür. Uyku insan günlük yaşantısını; çalışma performansı, moral, ruh hali ve diğer bireylerle ilişkiler gibi önemli noktalarda etkilemektedir. Bu sebeple tıp dünyasında uyku ile ilgili problemlerin tespiti için uyku analizi büyük önem taşımaktadır. Uyku analizi değişik psiko-fizyolojik analizlere de önemli bilgiler sunmaktadır. İnsan fizyolojisinde sağlıklı bir derin uyku evresinin, fiziksel iyileşmeyi hızlandırdığı bilinmektedir [5]. Ayrıca hızlı göz hareketleri olarak tanımlanan hızlı göz hareketleri (rapid eye movement, REM) evresinin sağlıklı olmasıyla öğrenme becerisi ve hafıza güçlenmektedir [5]. Uyku sorunlarının teşhisi ile ilgili tüm prosedürlerde uyku skorlama sürecine ihtiyaç duyulmaktadır. Uyku puanlama, uyku esnasında polisomnografik kayıt (PSG) yardımıyla uyku evrelerinin belirlenmesi işlemidir. Uyku ile ilgili sorunların teşhisinde, hastaların EEG, elektrookülogram (EOG) ve elektromiyogram (EMG) verilerini içeren PSG kayıtlarına bakılmaktadır. Bu kayıtlar bir uzman tarafından 1968' de tanımlanan Rechtschaffen & Kales (R&K) kurallarına göre değerlendirilir [6]. Rechtschaffen & Kales (R&K) kurallarına göre uyku verileri; uyanıklık, hızlı göz hareketlerini olmadığı dönem (non-rapid eye movement, N-REM 1, 2, 3) ve hızlı göz hareketleri olduğu dönem (REM) olarak sınıflandırılır. Son zamanlarda 3 ve 4' üncü evreler (N-REM 3 ve 4) birleştirilmiş olup artık bu evreye yavaş dalgalı uyku evresi (slow wave sleep stage, SWS)

denilmektedir. Uyku çalışmalarında, beyin aktivitesini en iyi yansıttığı için fizyolojik sinyaller arasında en sık kullanılanı EEG sinyalleridir.

Anestezi derinliği: Anestezinin hasta üzerindeki etkisi anestezi derinliği olarak ifade edilir. Uygun anestezi derinliği cerrahi operasyonlarda büyük önem taşıyan bir konudur. Anestezinin çok derin uygulanması durumunda hastanın kardiyovasküler sistemi etkilenmektedir [7]. Ayrıca çok derin anestezi hastada kalıcı hasarlara sebep olabilmektedir. Anestetik ilacın az verilmesi durumunda ise hasta ağrıyı hissedebilmektedir. Bu nedenle hasta ani fiziksel tepkilerde bulunabilmektedir [7]. Ayrıca bu durum bazı psikolojik rahatsızlıkları da beraberinde getirecektir. Anestezi derinliğini anlamada kullanılan geleneksel metotlar kalp atım hızı, kan basıncı, göz bebeği büyüklüğü ve terleme gibi ölçümleri içerir. Fakat bu fiziksel belirtiler ameliyatın türüne ve hastaya bağlı olarak değişim göstermektedir. Anestetik maddeler beynin korteksini önemli ölçüde etkilemektedir. Geleneksel anestezi derinliği izleme tekniklerinin yetersiz kaldığı konu; bilinç üzerinde yapılan kortikal etkidir. Bu nedenle anestezi derinliğini ölçmek için büyük ölçüde korteksten kaynaklandığı bilinen EEG kayıtlarını kullanarak beyin aktivitesinin izlenmesi uygun bir yaklaşım olacaktır [8].

Literatürde yapılan çalışmalar incelendiğinde EEG verilerinin sınıflandırılmasına yönelik çalışmaların çoğu iki aşamadan oluşmaktadır: Öznitelik çıkartma ve sınıflandırma. Genellikle öznitelik çıkartma aşaması için istatistiksel parametreler, sınıflandırma için de yapay sinir ağı kullanılmaktadır. Bu çalışmada daha etkili bir sınıflandırma için yeni yaklaşımların sunumu hedeflenmiştir. Önerilen yöntemler ve gerçekleştirilen çalışmanın önemi maddeler halinde listelenmiştir.

1. Etkili Öznitelik Tespiti: Literatürdeki çalışmalar incelendiğinde genellikle birkaç öznitelik tercih edilip, sınıflandırma algoritmalarına giriş olarak verilmektedir. Gerçekleştirilen çalışmada EEG verilerinin sınıflandırılmasında şimdiye kadar kullanılan öznitelikler içerisinde en etkili özniteliklerin tespiti gerçekleştirilmiştir. Bu amaçla yaygın olarak kullanılan öznitelikler içerisinde etkili özniteliklerin tespiti için öznitelik seçme algoritmaları kullanılmıştır. Bu şekilde literatüre önemli bir katkının sağlanacağı öngörülmektedir.

2. Çalışmada karmaşık değerlikli öznitelik çıkartma ve sınıflandırma algoritmalarından da yararlanılmıştır. Karmaşık değerlikli sınıflayıcıların, EEG verilerinin sınıflandırılmasına yönelik olarak herhangi bir uygulamasına yapılan literatür çalışmasında rastlanılmamıştır. Bu kapsamda öznitelik çıkarma aşamasında karmaşık değerlikli dalgacık dönüşümü ve karmaşık değerlikli sinir ağları kullanılmıştır. Karmaşık değerlikli sinir ağları, geleneksel sinir ağlarından farklı olarak karmaşık düzlemde uygulanıyor olması nedeniyle parametre kestirimi konusunda önemli problemler bulunmaktadır. Bu yöntemin uygulandığı çalışmalar incelendiğinde parametre değerlerinin genellikle deneme yanılma yöntemi ile tespit edildiği görülmektedir. Fakat bu yöntem sadece aşırı zaman israfına sebep olmakla kalmayacak, aynı zamanda da olası en iyi performansın elde edilmesinde sıkıntı oluşturabilecektir. Bu tez çalışmasında bu probleme yönelik bir çözüm önerilmektedir. Etkili ve hızlı bir parametre optimizasyonu bu problemin çözülebileceği görülmüştür. Bu amaçla özellikle etkili ve pratik bir metot olan Taguchi yönteminden yararlanılmıştır.

3. EEG verilerinin sınıflandırılması yönelik önerilen metotlar arasında; sınıflandırma aşamasında yeni bir grafik işlem birimi (graphics processing unit, GPU) teknolojisi olan birleşik hesap cihazı mimarisi (compute unified device architecture, CUDA) paralel işlemci mimarisi ile hızlı bir sınıflandırma aşamasının kullanımı yer almaktadır. Bu aşamada EEG verilerinin sınıflandırılmasında yoğunlukla tercih edilen ve paralel işlemeye uygun yapısı nedeniyle ileri beslemeli sinir ağı üzerinde bir çalışma gerçekleştirilmiştir. İleri beslemeli sinir ağı algoritması CUDA teknolojisi ile tekrar kodlanarak işlemlerde paralelleştirilme sağlanmış ve EEG verileri üzerinde performansa dayalı uygulamalar yapılmıştır. Bu aşamada CUDA programlamanın sinyal işlemeye katkıları vurgulanmıştır. Literatürde sadece epilepsi teşhisinde değil, diğer biyomedikal işaretlerin sınıflandırılmasında da böyle bir uygulamaya rastlanılmamıştır.

4. Bu çalışmanın, tıp dünyasının ve biyomedikal mühendisliğin çözüm bekleyen önemli konularından olan epilepsi, uyku bozuklukları ve anestezi derinlik


kestirimi konularını kapsıyor olması, çalışmanın önemini ve değerini arttırmaktadır.

Çalışmanın takibi açısından genel akış şu şekilde özetlenebilir. İkinci bölümde EEG işaretleri hakkında genel bilgilere yer verilmiştir. Üçüncü bölümde bu çalışmada çözüm aranan problemler hakkında bilgiler sunulmuştur. Dördüncü bölümde yapılan literatür çalışmaları hakkında bilgiler verilmiştir. Beşinci bölümde tez çalışmasında üzerinde çalışılan veriler ile ilgili bilgiler sunulmuştur. Altıncı bölümde tez çalışmasında kullanılan yöntemler hakkında bilgiler sunulmuştur. Yedinci bölümde tez süresince geliştirilen yazılımın tanıtımı yapılmıştır. Sekizinci bölümde yapılan uygulamalara ve sonuçlara yer verilmiştir.

BÖLÜM 2

EEG SİNYALLERİ

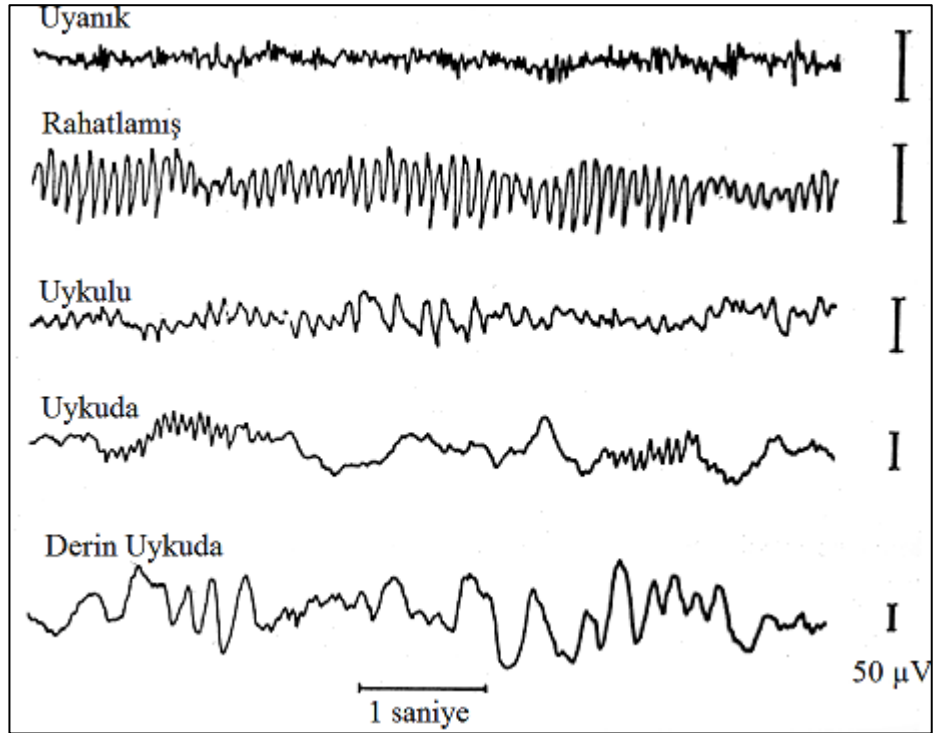
EEG, insan beyninin elektriksel aktivitelerinin meydana getirdiği biyoelektriksel bir işarettir. Bu işaretlerden elde edilen veriler içerisinde beyinin aktivitelerine ait çok fazla miktarda bilgi bulmak mümkündür. Bu işaretlerden elde edilen verilerin işlenmesi işaret işlemenin ilgi konusudur. İnsan beynine ait bu biyoelektriksel işaretler, ilk kez Alman psikiyatrist Hans Berger tarafından 1929 yılında kaydedilmiştir [9]. Berger'in çalışmasında; insan beyninin ürettiği zayıf elektrik akımlarının oluşturduğu grafikler, bir kâğıt üzerine kafatası açılmadan çizdirilmiştir. İlk kaydedilen bu EEG işareti Şekil 2.1'de sunulmaktadır. Berger bu yeni kayıt metodunu EEG olarak isimlendirmiştir. EEG, küçük elektrotların kafatasına jele benzer sabitleyici bir madde aracılığıyla yerleştirilmesi ile alınan ölçümlerdir. Çok düşük genlik değerlerine (μV seviyelerinde) sahip olan bu işaretler EEG cihazı tarafından yükseltilir. Yükseltelen bu EEG işareti bir kâğıda sürekli formda çizdirilir. Kaydedilen bu EEG işaretleri, çok kanallı sismograf kaydına benzemektedir. EEG kayıtlarının değerlendirilmesi, bu konuda uzman olan nörologlar tarafından yapılmaktadır.



Şekil 2.1. İlk kaydedilen EEG işareti [9].

Eğitimli bu uzmanlara nörofizyolojist veya elektroensefalografist denilmektedir. EEG işaretlerinin karmaşık bir değişim şekli vardır.

Bu nedenle EEG işaretlerinin yorumlanması zordur. Kafa üzerinden alınan EEG işaretlerin genliği tepeden tepeye 1–100 μV ve frekans bandı 0.5–100 Hz' dir. EEG işaretleri periyodik değildir, genlik, faz ve frekansları sürekli değişmektedir. Bundan dolayı, EEG işaretlerinin daha iyi incelenebilmesi için uzun süreli kayıtlara ihtiyaç vardır. Şekil 2.2'de EEG sinyallerinin farklı durumlarda aldığı şekiller görülmektedir.



Şekil 2.2. EEG işaretinin farklı durumlarda aldığı şekiller [10].

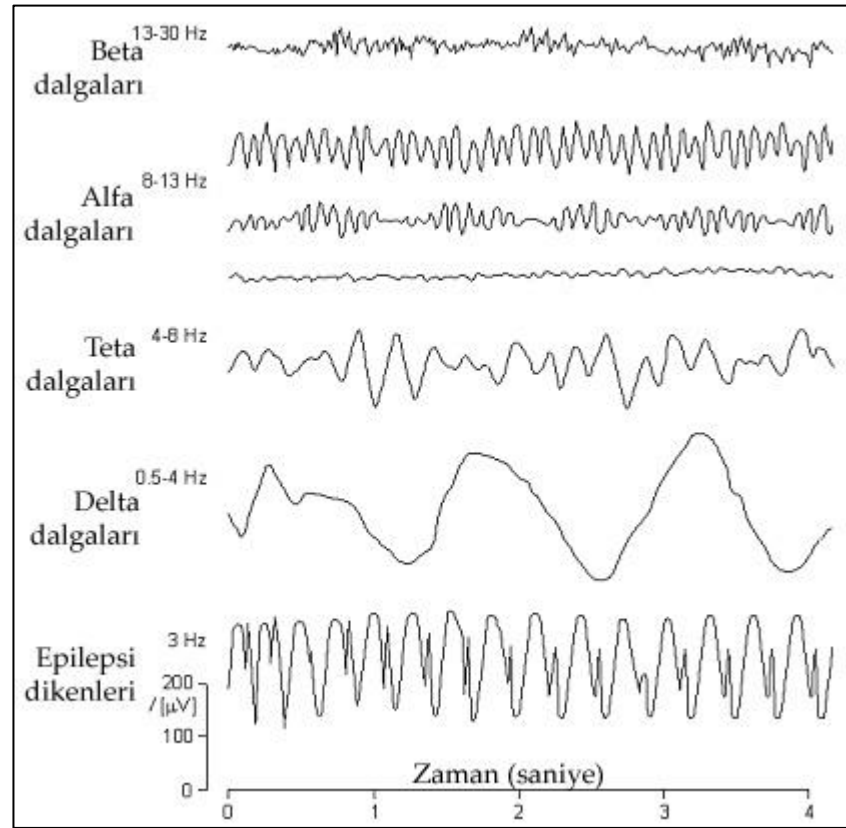
2.1. EEG BANTLARI

EEG işareti geniş bir frekans spektrumuna sahiptir. Bununla beraber, klinik ve fizyolojik ilgi daha çok EEG işaretlerinin anlamlı olduğu 0.5 Hz ile 40 Hz arasındaki banda yoğunlaşmıştır. Bu frekans aralığı Çizelge 2.1'de sunulduğu gibi belli frekans bantlarına ayrılmıştır. Bu yaklaşım EEG spektrumunun temelinde delta, teta, alfa, beta ve gama ile tanımlanan beş banda ayrılmasına sebep olmuştur.

Çizelge 2.1. EEG işaretlerinin klinik ilgi frekans bant aralıkları.

Bant Tanımı	Bant Aralığı (Hz)
Delta (δ)	0.5-3.5
Teta (θ)	4-7
Alfa (α)	8-12
Beta (β)	12-22
Gamma (γ)	22-30

Şekil 2.3'te EEG işaretlerinin yoğunlaştığı bantların işaret şekilleri görülmektedir. Ayrıca en altta epilepsi rahatsızlığı olan bir hastaya ait EEG işareti de verilmiştir.



Şekil 2.3. EEG işaretlerinin klinik ilgi frekans bantlarına ait şekiller.

Alfa Dalgaları: 8-12 Hz arasında frekansa sahip EEG dalgalarıdır. Uyanık, normal ve sakin durumlarda görülür. Yoğun şekilde oksipital bölgede ortaya çıkan bu dalga'nın genlik değeri 5 μ V kadardır. Uyku durumunda kaybolurlar. Uyanıkken dikkat özel bir şeye yönelirse α işaretleri yerini daha yüksek frekanslı, fakat düşük genlikli β işaretlerine bırakır.

Beta Dalgaları: 12-22 Hz arasında frekans değerlerine sahip EEG dalgalarıdır. 22 Hz'e ve nadir hallerde 50 Hz'e kadar uzanırlar. Bu dalgalar, saçlı derinin parietal ve frontal bölgelerinde belirgin olarak kaydedilebilir [11]. Beta-I (BI) ve Beta-II (BII) diye ikiye ayrılırlar. BII işaretlerinin frekans değeri, BI'nın frekans değerlerinin iki katıdır. Bu dalga şekli, zihinsel aktivitenin artması ile beraber ortadan kalkar ve yerlerine düşük genlikli asenkron işaretler oluşur. BII işaretleri, merkezi sinir sisteminin kuvvetli aktivasyonunda veya gerginlik hallerinde ortaya çıkar [11].

Teta Dalgaları: 4-7 Hz arasında frekans değerlerine sahip EEG dalgalarıdır. Özellikle, çocuklarda parietal ve temporal bölgelerde ortaya çıkan bu dalga şekli, yetişkinlerde duygusal gerginlik, düş kırıklığı ve üzüntü gibi durumlarda ortaya çıkmaktadır [11]. Genlikleri 100 μ V'dan küçüktür.


Delta Dalgaları: 0.5-3.5 Hz arasında frekans değerlerine sahip EEG dalgalarıdır. Bebeklerde ve ağır organik beyin hastalıklarında görülebilen bu dalga şeklinin genlik değerleri 100 μ V'dan küçüktür [11].

Gamma Dalgaları: 22-30 Hz arasında frekans değerlerine sahip EEG dalgalarıdır. Genlikleri, 2 μ V'dan daha küçüktür. Kafanın merkezinde, genlikleri daha büyüktür. Uykunun karakteristik belirtisini taşırlar.

2.2. EEG VERİLERİNİN ÖLÇÜLMESİ

EEG işaretlerinin ölçülmesinde beyin-bilgisayar arabirimi kullanılmaktadır. Bu arabirimin ilk kısmı beynin elektriksel aktivitesini kafa yüzeyinden ölçmeye yarayan metal elektrotlardır [12]. Ölçüm elektrotlarının sayısı yapılan çalışmanın içeriğine veya amacına göre değişebilmektedir. Genellikle ölçümler uluslararası 10–20 sistemi denilen bir elektrot yerleştirme düzenine göre yapılmaktadır. Bu sistemin işleyişi şu şekildedir. Baş dört standart nokta ile işaretlenir. Bunlar burun (nasion), başın arka kısmı (inion), sol ve sağ kulak arkalarıdır (preauriculars). Elektrotlar nasion ve inion arasına %10–%20–%20–%20–%20–%10 olacak şekilde bölünerek yerleştirilir. Sistemin 10–20 sistemi olarak adlandırılmasının sebebi de budur. Şekil 2.4'de uluslararası 10–20 elektrot yerleşim sistemi görülmektedir.

EEG işaretlerinin ölçülmesinde kafaya yerleştirilen elektrotlar arasında referans elektrotun seçimi büyük önem taşımaktadır. Uluslararası 10–20 sisteminde yaygın olarak kulağa bağlanılan elektrot referans elektrot olarak kullanılır. Bu hem oluşacak ölçüm hatalarının minimize edilmesinde hem de EEG işaretlerinin dalga şekillerinin çizdirilmesinde büyük önem taşımaktadır.



Şekil 2.4. Uluslararası 10–20 EEG elektrot yerleştirme sistemi [12].

2.3. EEG KULLANIM ALANLARI

EEG sinyallerinin başlıca kullanım alanları aşağıda verilmektedir.

1. Uyanıklılık, koma ve beyin ölümünün belirlenmesi,
2. Beyin kanaması, travma ya da tümörler nedeniyle oluşabilecek hasarlı bölgelerin belirlenmesi,
3. Ameliyatlarda anestezi aşamasının kontrolü ve anestezi derinliği tespiti,
4. Epilepsinin teşhisi ve nöbetlerin başlangıç bölgesinin belirlenmesi,
5. Epilepsi ilaçlarının yan etkilerinin belirlenmesi,
6. Uyku bozuklukları ve uyku psikolojisinin araştırılması,
7. Migren tanısı gibi geniş bir yelpazede EEG sinyallerinden yararlanılmaktadır.

BÖLÜM 3

SINIFLANDIRMA PROBLEMLERİ

3.1. EPİLEPSİ HASTALIĞI

Epileptik nöbet; beyin hücrelerinin normal olmayan şekilde, çok hızlı ve yüksek miktarda elektriksel deşarjlarına maruz kalması neticesinde ortaya çıkan kısa süreli geçici bir durumdur [13]. Halk arasında bu rahatsızlığa sara denilmektedir. Beyin, insan vücudunun en önemli organlarından birisi olmakla beraber insan vücudunun kontrol merkezidir. Beynin işlevlerinin gerçekleştirilmesi, hücreler arasındaki elektriksel işaretler sayesinde gerçekleşir. Beklenmeyen bir elektriksel uyarı ile nöbet oluşabilmektedir.

Epilepsi nöbetini kısaca ifade etmek gerekirse, beynin kısa süreli fonksiyon bozukluğu denilebilir. Dünya genelinde her yüz kişiden birinde görülmektedir [14]. Epileptik nöbetler uluslararası kabul gören iki kategoriye ayrılmaktadır. Birinci kategori kısmi (parsiyal), ikinci kategori ise, genel (jeneralize) nöbet olarak adlandırılmaktadır. Kısmi nöbette, beynin hepsi değil de belirli bir bölümü etkilenmektedir. Etkilenen bu kısmın vücutta kontrol ettiği yerde anormal davranışlar görülür. Genel nöbet ise kısmi nöbetten farklı olarak beynin tamamında görülmektedir. Bu durumda vücudun tamamı etkilenmektedir.

Epilepsi, eski dönemlerden beri bilinen ve tarihi çok eskilere dayanan bir rahatsızlıktır. Sağlıklı görünen bazı kişilerin aniden yere yıkılması ve bilinçsiz bir halde çırpınmaları sebebiyle bu hastalık lanetli bir hastalık olarak tanımlanmıştır. Bu nedenle epilepsi hastalarına tanrılar tarafından cezalandırılan veya içlerine kötü ruhlar girmiş kişiler gözüyle bakılmaktaydı [15]. Epilepsinin bir hastalık olarak değerlendirilip araştırılması ve tedavi süreci 1850 yılından itibaren günümüze kadar sürmüştür.

Epilepsinin net bir tedavi yöntemi olmamakla beraber; uygun anti-epileptik seçimi ve kullanımını yanında hastaların iyi izlenmesiyle tamamen iyileşme veya nöbetlerin 3/4 oranında azalması sağlanabilmektedir. Tedavinin geciktirilmesi ve uygun tedavinin seçilememesi gibi nedenler bu hastalığın kontrol altına alınmasını zorlaştırmaktadır. Bu nedenle epilepsi hastalığının tedavisinde öncelikle hastanın kendisinin ve ailesinin bilgilendirilmesi sağlanmaktadır.

Epilepsi hastalığının teşhis ve tedavisinde beynin elektriksel faaliyetlerini yansıtan EEG sinyallerinden yararlanılmaktadır. Epilepsi nöbetleri arasındaki elektriksel boşalmaların EEG ile belirlenmesi, epilepsi teşhisinde büyük önem taşımaktadır. Bu nedenle nöroloji kliniklerinde EEG cihazı beyin rahatsızlıklarının gözlenmesinde yoğun bir şekilde kullanılmaktadır.

3.2. UYKU DÜZENSİZLİKLERİ

Uyku günlük hayatı ve en önemlisi insan sağlığını farklı şekillerde etkilemektedir. Günümüzde en sık karşılaşılan uyku hastalıkları; uykusuzluk hastalığı, derin uyku hali ve uyku apnesidir [16]. Uykusuzluk hastalığı genellikle uykuya dalamama veya gece uyuduktan sonra sık sık uyanma şeklinde kendini gösterir. Bu durum derin uyku süresini kısaltacağından, uyuyan kişinin dinlenmeden uyanmasına neden olmaktadır. Uyku apnesi uyku sırasındaki solunum duraklamalarından kaynaklanan ve uyku düzeninin bozulmasına sebep olan önemli bir hastalıktır [16]. Uyku apnesi teşhisi için hasta bütün gece uyku laboratuvarında kalarak gözetim altında tutulmaktadır. Hastanın vücudunun çeşitli yerlerine bağlı elektrotlar vasıtasıyla alınan veriler değerlendirilerek bir sonuca erişilmekte ve tedavi için gerekli işlemler yapılmaktadır. Belirtilen rahatsızlıkların dışında uyku düzenliğinden kaynaklanan bazı rahatsızlıklar daha vardır. Depresyon, stres, şizofreni, alzheimer gibi hastalıklar da uyku rahatsızlıkları olarak değerlendirilmektedir.

Uyku düzensizliklerinin tespitinde yararlanılan aşama, uyku evrelerinin belirlenmesi aşamasıdır. Uyku süresince, insan beyni göreceli olarak çeşitli psikofizyolojik seviyelere girmektedir. Uyku esnasında birçok sinir merkezi aktif değildir. Bu

nedenle uykuda beyin daha az karmaşık bir sistem haline gelmektedir. Bu esnada alınan veriler matematiksel modelleme için daha uygundur.

3.2.1. Uyku Evreleri

Uykunun ana evreleri, uyanıklık, REM uykusu ve N-REM uyku evreleridir. N-REM uykusu, en hafif uyku Evre 1 ve en derin uyku Evre 4 olmak üzere 4 seviyeye bölünmüştür. 3. ve 4. uyku evreleri yavaş dalga uykusu (SWS) olarak adlandırılmıştır. NREM ve REM uyku evrelerinin dağılım sıklığı gece boyunca değişmektedir. Uykunun başlangıç saatlerinde SWS uykusu baskındır. REM uykusu, daha çok uykunun ikinci bölümünde baskındır. REM uykusunun dağılımı gece boyunca değişebilmektedir. Bu değişimlerde yaş faktörü de önem taşımaktadır. Örneğin, yeni doğmuş bebeklerde REM uykusunun oranı %50, yetişkinlerde ise %20 civarındadır. Klinik araştırmalarında insan uykusunun incelenmesinde ve araştırılmasında kullanılan temel yöntem polisomnografidir. Bu yöntem, temel olarak EEG, EOG ve EMG değerlerinin ölçülmesinden oluşmaktadır. EEG, beyin aktivitelerini ölçebilen ve elektriksel hareketliliği gözlemleyebilen basit ama etkili bir yöntemdir. EEG'nin ölçüm kalitesi bazı parametrelere bağlıdır. Uykunun evreleri, 1968 yılında A. Rechtschaffen ve A. Kales tarafından yönetilen bir komitenin hazırladığı, "İnsan Uyku Evrelerinin Standart Terminolojisi, Teknikler ve Skorlama Sistemleri El kitabı" isimli araştırma temel alınarak değerlendirilmektedir. Uyku çalışmalarında standart kriterlerin kullanılmasının sebebi, farklı uyku laboratuvarlarında yapılan araştırmaların ve elde edilen sonuçların sağlıklı bir şekilde birbirleriyle karşılaştırılabilmesidir.

Genellikle uyku çalışmalarında iki kanal EEG, iki kanal EOG ve bir kanal EMG kayıtları alınmaktadır [17]. Bu kayıtların dışında solunum, vücut sıcaklığı gibi bilgilerde kayıt altına alınarak, teşhis ve tedavide kullanılabilir. EEG kayıtları, 10-20 elektrot yerleşim sistemine göre daha çok C4/A1 veya C3/A2 elektrotlarından elde edilmektedir. Uykunun evreleri segment-segment yaklaşımı ile yapılır ve her bir segment genellikle 30 sn. sürer.

Çizelge 3.1’de Rechtschaffen ve Kales’in editörlüklerini yaparak belirledikleri uluslararası standartlara göre çıkarılan EEG işaretlerinin frekans ve genlik özellikleri ve genellikle hangi uyku evresinde yaygın olarak görüldükleri ile ilgili özet bir bilgi sunulmuştur. Çizelge 3.2’de ise uyku evreleri ve bu evrelerin genel karakteristik özellikleri özet olarak sunulmuştur.

Çizelge 3.1. EEG özelliklerinin frekans, genlik ve zaman karakteristikleri [16].

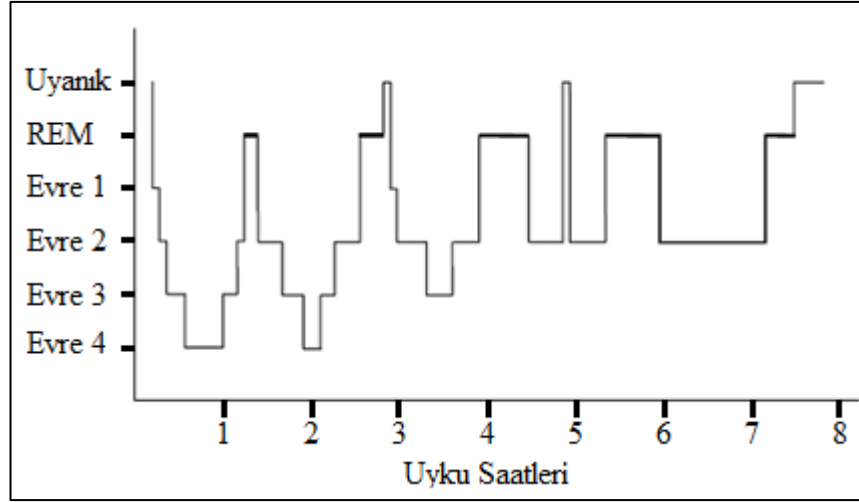
Özellik	Frekans	Genlik	Zaman
Alfa (α)	8-12 Hz	20-60 μ V	Uyanık, Evre I ve REM’ de görülür.
Beta (β)	13+ Hz	2-20 μ V	Uyanıkken baskındır.
Teta (θ)	4-8 Hz	50-75 μ V	Evre I, II, III ve IV’ te görülür.
Delta (δ)	0-4 Hz	75+ μ V	Evre III ve IV’ te görülür.
Uyku içcikleri	12-14 Hz		Evre II (0.5-1.5 s)’ de görülür.
K-kompleksleri	0.4-1.5 Hz		Evre II’ de görülür.

Çizelge 3.2. Uyku evreleri ve her evrenin genel karakteristiği [16].

Uyku evresi	Belirteçler (EEG)
Uyanık (Wake, W)	Gözler kapalı: alfa ritmi (8-13Hz) Gözler açık: düşük genlikli karışık EEG sinyalleri
N-REM Evre 1	Nispeten düşük genlikli karışık frekanslı aktivite Teta aktivitesi Gecenin başlangıcında verteks dalgaları
N-REM Evre 2	Düşük genlikli karışık frekanslı aktivite Uyku içcikleri ve K kompleksleri
N-REM Evre 3	Yüksek (>75 μ V) genlikli, düşük frekanslı (0.5-2 Hz) delta dalgaları
REM	Düşük genlikli karışık frekanslı aktivite 2-6 Hz’lik keskin kenarlı testere dişi dalgaları

3.2.2. Hipnogram

Uyku araştırmalarında sıklıkla kullanılan ve tüm uyku süresi boyunca polisomnogramdan elde edilen uyku evrelerini gösteren histograma hipnogram denilmektedir. Hipnogram uyku ile ilgili hastalıkları tespit etmek için nörologlar tarafından kullanılır. Uyku sorunu olmayan normal yetişkin bir insanın 8 saatlik bir uyku için hipnogram grafiği Şekil 3.1’de sunulmuştur.



Şekil 3.1. Normal bir insanın uyku hipnogramı.

3.3. ANESTEZİ VE ANESTEZİ DERİNLİĞİ

Genel anestezi tam bir bilinç kaybı ve hissizlik olarak bilinmektedir. Anestezi, cerrahi operasyonlarda hem hastaya hem de doktora konforlu bir süreç sağlamaktadır. Anestezi durumu hastaya verilen anestezik ilaçlarla gerçekleştirilmektedir. Anestezik ajan (anesthetic agents), hastaya enjeksiyon veya solunum yoluyla verilebilmektedir [18]. Cerrahi operasyonlarda bu ilaçların daha çok solunum yolundan verilmesi tercih edilmektedir. İnhalasyon (solunum) anestezisi, maske ya da nefes borusuna takılan bir tüp yardımıyla solunum yolundan anestezi uzmanları tarafından gerçekleştirilmektedir.

Cerrahi operasyonlarda, anestetik ilacın kullanımında bir kontrol aracı olarak anestezi derinliğinin güvenilir ve girişimsel olmayan (non-invazif) bir şekilde görüntülenmesi büyük önem taşımaktadır. Uygun anestezi derinliğinden emin olmak için bu işlem önemlidir. Anestezinin, çok derin uygulandığı durumda hastanın kardiyovasküler sistemi etkilenebilmektedir [19]. Bu durumun operasyon sonrasında kalıcı olabilen hasarlara neden olduğu bilinmektedir. Anestetik ilacın az verilmesi durumunda ise, hastanın ağrıyı hissettiği ve ani fiziksel tepkilerde bulunduğu bilinmektedir. Bundan dolayı hastanın en uygun anestezi seviyesinde tutulabilmesi önemli ve zor bir olaydır. Bu problem klinik uygulamalarda hala çözülememiş bir problemdir.

Anestezi derinliđini anlamada kullanılan geleneksel metotlar kalp atım hızı, oksijen doygunluk düzeyi (SpO2), vücut hareketleri, kan basıncı, göz bebeđi büyüklüğü ve terleme gibi ölçümleri içerir. Fakat bu fiziksel belirtiler ameliyatın türüne ve hastaya bađlı olarak deđişim göstermektedir [19]. Sezaryen gibi kısa süreli ameliyatlarda bahsedilen izleme araçları sayesinde anestezi derinliđi uygun bir seviyede tutulabilir. Ancak beyin, kalp, omurga ve ortopedik gibi uzun süreli operasyonlarda geleneksel göstergeler ađrı düzeyini açığa çıkaramayabilir. Ve bu durum uzun süreli operasyonlarda hastanın uyanması ile sonuçlanabilir. Anestetik maddeler beynin korteksini etkilediđinden anestezi derinliđini saptamak için EEG kayıtlarını kullanarak beyin aktivitesinin izlenmesi uygun bir yaklaşımdır.

BÖLÜM 4

LİTERATÜR TARAMASI

4.1. EPİLEPSİ HASTALIĞININ TEŞHİSİ İLE İLGİLİ LİTERATÜR ÇALIŞMASI

Son yıllarda epileptik aktivitelerin tespiti için birçok farklı model önerilmiştir. EEG işaretlerinin analizinde yaygın olarak sinir ağı modelleri ve istatistiksel tanı metotlarından yararlanılmaktadır. Bu bölümde epileptik EEG sınıflandırması ile ilgili diğer araştırmacıların çalışmaları kısaca incelenmektedir. Yüksek doğruluk değerlerinin elde edildiği bazı çalışmalar aşağıda sunulmaktadır.

Pradhan ve arkadaşları epilepsi teşhisine yönelik olarak EEG işaretlerini analiz etmek için iki katmanlı öğrenme vektör nicelendirme ağını kullanmıştır [20]. Petrosian ve arkadaşları epileptik atak tahmini için istatistiksel özelliklerin yerine ham EEG işaretlerini yinelemeli sinir ağına uygulamıştır [21]. Srinivasan ve arkadaşları, EEG sinyallerinden öznitelik tespitinde zaman ve frekans tabanlı 5 öznitelik kullanmıştır [22]. Sınıflandırıcı olarak Elman sinir ağının kullanıldığı çalışmada yüksek doğruluk oranları elde edilmiştir. Nigam ve Graupe iki öznitelik elde etmek için (göreceli doruk genliği ve doruklardaki tekraralama sıklığı) çok aşamalı doğrusal olmayan ön işleme filtresi kullanarak EEG sinyalleri yoluyla epileptik nöbetlerin otomatik teşhisini sağlayan bir metot ortaya koymuştur [23]. Daha sonra araştırmacılar bu öznitelikleri tanısız yapay sinir ağına veri olarak girmişlerdir. Subaşı ve Erçelebi epileptik atak tespiti için ileri beslemeli sinir ağını ve lojistik regresyon modellerini kullanarak EEG işaretlerini analiz etmiştir [24]. Subaşı bir başka çalışmada EEG verilerinin sınıflandırılması için, iki çıkışlı (normal ve epileptik) ileri beslemeli sinir ağını ve dinamik dalgacık ağ modellerini karşılaştırmıştır [25]. Alkan ve arkadaşları sınıflayıcıya giriş olarak; ataksız hastanın

güç spektrumunu kullanarak, çoklu işaret sınıflama, otoregresif ve periyodogram metotlarını ileri beslemeli sinir ağı modeli ile karşılaştırmıştır [26].

Kannathal ve arkadaşları epilepsi teşhisi için farklı entropi değerlerini ve adaptif sinir ağına dayalı bulanık çıkarım sistemi (adaptif sinir ağına dayalı bulanık çıkarım sistemi, ANFIS) algoritmasını kullanarak yaklaşık %92 sınıflandırma doğruluğuna ulaşmışlardır [27]. Forrest Sheng Bao, güç spektrumu, fraktal boyut, Hjorth değişkenleri, ortalama ve standart sapma gibi özniteliklerle eğittikleri olasılık sinir ağları ile %99.5'lük bir doğruluk oranı elde ettiler [28]. Jinfeng Fan, destek vektör makinelerini genetik algoritmalarla birlikte kullanarak %95'lik sınıflandırma doğruluğu elde etmişlerdir [29]. Tzallas, epilepsi teşhisi için zaman-frekans dönüşümü olan Wigner-Ville katsayılarını ve yapay sinir ağlarını kullanmıştır [30]. Polat ve arkadaşları karar ağacı algoritması ve hızlı Fourier dönüşümü tabanlı hibrit bir model önermişlerdir [31].

Işık ve Sezer çalışmasında, epilepsi teşhisi için dalgacık dönüşümünü incelemiştir. EEG verileri dalgacık dönüşüm yöntemi kullanılarak farklı alt bantlara ayrıştırılmış ve bir seri öznitelik vektörü elde edilmiştir. Bu öznitelik vektörlerinin boyutları temel bileşen analizi metoduyla indirgindikten sonra çok katmanlı algılayıcı ve Elman sinir ağları yoluyla epileptik ya da sağlıklı olarak sınıflandırılmıştır [32]. Orhan ve arkadaşları epilepsi teşhisi için ayrıklaştırmaya dayalı olasılık yoğunluğu yaklaşımını kullanmıştır. EEG işaretleri hem zaman hem de zaman-frekans boyutunda üç yöntem kullanılarak ayrıklaştırılmıştır: eşit genişlikli ayrıklaştırma, eşit frekanslı ayrıklaştırma ve k-means. Her ayrık bölgenin yoğunluğu hesaplanmış ve bu yoğunluk çok katmanlı algılayıcı sinir ağı modeline giriş olarak uygulanmıştır. Ayrıca, eşit frekanslı ayrıklaştırma yöntemine dayalı elde edilen yoğunluklara eğri uydurma uygulanarak EEG segmentlerinin olasılık yoğunluk fonksiyonları belirlenmiş ve sinir ağı yerine ortalama karesel hata ölçütü kullanarak epileptik aktiviteler sınıflandırılmıştır. Son olarak, önerilen özellik çıkartma yaklaşımının ve literatürde aynı EEG işaretlerini kullanan bazı çalışmaların başarıları tüm sonuçlar karşılaştırılarak gösterilmiştir [33].

4.2. UYKU EVRELERİNİN TESPİTİ İLE İLGİLİ LİTERATÜR ÇALIŞMASI

Modern seviyede uyku çalışmalarının başlangıcı, 1930'lu yıllarının başlarında EEG'nin icadı ile başlamıştır. Sonraki yıllarda bu konu ile ilgili çok sayıda çalışma yapıldı. Bu bölümdeki literatür araştırması hazırlanırken bazı çalışmalar için [16] numaralı kaynaktan yararlanılmıştır. Loomis, 1937 yılında yaptığı çalışma neticesinde bütün gece süren uykunun homojen olmayan aşamalardan oluştuğunu gözlemledi [34]. Ve EEG yardımıyla uykunun bu safhalarını tanımlamıştır.

Adrian ve Matthews, 1934'te elektrotlar yardımıyla aldıkları EEG işaretlerini kuvvetlendirip kaydetti [35]. Davis, 1939 yılında, uyanık bir insanın EEG'sini incelemiş ve sese karşı uyarılan yanıtların olduğunu saptamıştır [36].

Hu ve Knapp, EEG işaretlerinden uyku evrelerini sınıflandırmak için bulanık mantık tabanlı bir yöntem geliştirdi. EEG işaretinin her epogu için frekans ve genlik değerlerinden oluşan bir öznitelik vektörü elde edilmiştir. Her evrede, her epok içinde üyelik fonksiyonları hesaplanmıştır. Sonraki aşamada her evre maksimum üyelik derecesi ile ölçeklenip sınıflandırılmıştır. Neticede yaklaşık 1101 epogun analizi yapılmıştır. Önerilen metot ve uzman doktor arasında %77' lik bir uyum sağlanmıştır [37].

Merica ve Blois yaptıkları uyku araştırmasında; derin uyku olarak tanımlanan NREM evresindeki farklı frekansların enerjisini, uyku esnasındaki REM evreleriyle ve gece boyunca uyku verileriyle karşılaştırıp, bazı sonuçlar elde ettiler. NREM evrelerinde enerji beta bandı karşılıklı olarak daha yavaş banda (delta, teta) doğru değişim göstermiştir. REM'den önceki son çeyrekte beta dışındaki tüm bantlarda enerji düşüşü gözlenmiş ve beta bandının enerjisinin arttığı sonucu elde edilmiştir. Alfa, teta ve delta enerjileri, REM evresinin ilk %30'luk bölümünde devam etmiş ve sonrasında enerjinin sabitlendiği gözlenmiştir. Beta bandının enerjisi, NREM evresinin sonunda aynı seviyede kalmıştır. Gece boyunca, NREM sürecinde daha yavaş frekans bantlarının (alfa, teta ve delta) enerjisinin azaldığı gözlenmiştir. Delta bandının enerjisi ise dengeleme sürecine göre azalmaktadır [38].

Pacheco ve arkadaşları yaptıkları uyku çalışmasında uyku evrelerini tanımlamak için 3 EEG kanalı, 2 EOG kanalı ve 2 EMG kanalından yararlandılar. Bu kanallardan her bir evre için elde edilen verilerden öznitelikler çıkarılmıştır. Sonraki aşamada bağımsız sınıflandırma ile bu verileri sınıflandırdılar [39].

Oropesa ve arkadaşları uyku evrelerinin sınıflandırılması üzerinde bir çalışma yaptılar. Uyku evrelerini sınıflandırmak için yapay sinir ağı ve dalgacık dönüşüm yöntemlerinden yararlandılar. Sonuç olarak %77.6 sınıflandırma doğruluğu elde ettiler [40].

Flexer ve arkadaşları yaptıkları çalışmada, saklı Markov modeli kullanan sürekli bir uyku evreleme sistemi üzerinde çalıştılar. Önerilen sistem ile, uyanık ve derin uyku evreleri (Evre 3 ve Evre 4) için yaklaşık %80, REM evresi için ise %26'lık bir doğruluk oranı elde ettiler [41].

Kıymık ve arkadaşları, EEG sinyallerinden yararlanarak uyanıklık seviyesi belirlemek üzere yapmış oldukları çalışmada ayırık dalgacık dönüşümü ve yapay sinir ağlarından yararlandılar. Çalışmada uyku, uykuya geçiş evresi ve uyanıklık durumlarının belirlenmesine yönelik olarak deneyler gerçekleştirildi. Ayırık dalgacık dönüşümü ile işaret alt bantlara ayrılmıştır. Sonraki aşamada elde edilen öznitelikler sinir ağına giriş olarak sunulmuştur. Neticede yaklaşık % 90 doğruluk oranı elde edilmiştir [42].

Subaşı, EEG işaretlerinden yararlanarak bir uyku sınıflandırma sistemi üzerinde çalıştı. Öznitelik tespiti için dalgacık dönüşümü, sınıflandırma için ise yapay sinir ağı modelini kullandı. Yapay sinir ağını eğitmek için dalgacık katsayılarını ağa giriş olarak uygulamıştır. Çalışmada uyku, uyanıklık ve uyuklama durumlarının belirlenmesine çalışmıştır. Sonuç olarak %90 civarında bir başarı oranı elde edilmiştir [43].

He ve arkadaşları yaptıkları çalışmada sekiz sağlıklı yetişkinin uyku verileri üzerinde çalıştı. Çalışmada öznitelik elde etme aşamasında spektrum entropisi, yaklaşıklık entropisi ve lempel ziv karmaşıklığı değerlerini öznitelik olarak kullanmış ve

sınıflandırma yapmışlar. Elde ettikleri istatistiksel sonuçlar, bu üç doğrusal olmayan öznitelik değerinin uyku evrelerini başarı ile tanımlayabileceğini göstermiştir. Bahsi geçen öznitelikler arasında yaklaşıklık entropisi, diğer algoritmalarla göre karmaşık olmasına rağmen daha iyi sonuçlar vermiştir [44].

Doroshenkov ve arkadaşları, yaptıkları çalışmada EEG işaretlerinden yararlanarak bir uyku evreleme sistemi üzerinde çalıştılar. Sınıflandırma aşamasında saklı Markov modellerinden yararlandılar. Önerilen metot uykunun ana evrelerini ayırmakta güvenilir bir tanımlama sağlamıştır. Otomatik sınıflandırma sonuçları ile R&K uluslararası sisteme dayalı uzmanların sınıflandırma sonuçları uyumlu olmuştur. Bu çalışmada maksimum doğruluk değeri, derin uykuda elde edilmiştir. Evre 4 için R&K ile karşılaştırıldığında % 92 sınıflandırma başarıları elde edilmiştir. En kötü sınıflandırma doğruluğu % 5'ten daha az bir değer ile Evre 1 olmuştur. Evre 1 çoğunlukla Evre 2 (% 48) veya REM evresi (% 47) olarak sınıflandırılmıştır. Bu çalışmada uyanık evresinin sınıflandırma başarı yüzdesi %74 olmuştur [45].

Agarwal ve Gotman uygulamalarında uyku operatörünün aktif katılımını da içerecek şekilde segmentasyon ve kümeleme stratejileri kullandılar. Önerilen model ile % 80.6 sınıflandırma doğruluğuna eriştiler [46].

Estrada ve arkadaşları uyku araştırmasına yönelik olarak EEG sinyallerinden yararlandılar. Çalışmalarında bağıl spektral bant enerjisi, harmonik parametreler ve itikura mesafesi olarak adlandırılan 3 farklı öz nitelik algoritmasını kullandılar. Yazarlar lineer ölçümler kullanan çalışmalardan farklı olarak EEG sinyallerinin non-lineer analizlerini üzerinde de çalıştılar. Sonuç olarak doğrusal olmayan özniteliklerin de puanlama sürecinde etkin olarak kullanılabilirliği görülmüştür [47].

Becq ve arkadaşları uyku puanlama için hangi sınıflandırma algoritmasının daha etkili olduğunu araştırmıştır. Bunun için belirledikleri 5 sınıflandırma algoritmasını karşılaştırdılar. Bunlar sırasıyla lineer sınıflandırıcı, kuadratik sınıflandırıcı, k en yakın komşu algoritması, parzen çekirdekleri ve yapay sinir ağı algoritmalarıdır. Bulgulara göre en iyi sınıflandırma algoritması %72 oranında doğruluk oranı ile yapay sinir ağları olmuştur [48].

Sinha uyku içcikleri, REM uykusu ve uyanıklık evresi olmak üzere 3 evreyi sınıflandırmıştır. Dalgacık dönüşüm yöntemi ve yapay sinir ağının kullanıldığı çalışmada %95.55 doğruluk oranı elde edilmiştir [49].

Güneş ve arkadaşları, k-ortalamlar adı verilen kümeleme tabanlı öznelik ağırlıklandırma yeni bir veri ön işleme algoritması önermiştir. Uyanık, REM, N-REM evre 1, N-REM evre 2, ve N-REM evre 3 gibi uyku evrelerini sınıflandırmak için C4.5 karar ağacı ile bu yöntemi birleştirmiştir. Karar ağacı, EEG sinyaline ait frekans özellikleri kullanılarak on kat çapraz doğrulama (cross validation, CV) ile uyku evreleri sınıflandırmada % 37.84 sınıflandırma doğruluğu elde etmiştir. Uyku evreleri, karar ağacına dayalı EEG ve EMG sinyallerine ait frekans özellikleri kullanılarak % 41.85 doğruluk ile sınıflandırılmıştır. Bu yöntem ile EEG sinyaline ait ağırlıklı frekans özelliklerinde, karar ağacı kullanılarak uyku evreleri sınıflandırılmasında % 92.40 doğruluk sağlanmıştır [50].

4.3. ANESTEZİ DERİNLİĞİNİN TESPİTİ İLE İLGİLİ LİTERATÜR ÇALIŞMASI

Genel olarak, anestezi derinliğini belirlemek için literatürde çeşitli EEG temelli yaklaşımlar bulunmaktadır. Bunlardan en çok tercih edileni bispektral indeks (BIS) değeridir. BIS değeri ayrı ayrı hesaplanan farklı algoritmalarından oluşur. Algoritmanın içeriği net bilinmemekle beraber, izgesel köşe frekansı (spectral edge frequency, SEF), β -oranı ve ikiz-izgesel gibi parametrelerden oluşan bir değer olduğu tahmin edilmektedir. Elde edilen değerler BIS indeksini oluşturmak için farklı ağırlıklar ile birleştirilir. BIS değeri; ismini, yüksek dereceli izgesel analiz yöntemlerinden biri olan ikiz-izge (Bispectrum) kelimesinden alır [19]. BIS değerini veren BIS cihazı ilk anestezi derinliği izleme cihazı olması yönünden önem taşır. Halen klinik uygulamalarda en çok ilgi gören ürün olan cihazın ürettiği BIS değeri, alın bölgesindeki 4 elektrottan alınan EEG verisinden oluşturulmaktadır. Bu cihaz, 0-100 arasında bir indekslemeye sahiptir ve uyanıklılığı 100 değeri ile temsil etmektedir. BIS indeks değerlerinin genel anestezi sırasında 40-60 arasında tutulmasının, yeterli hipnotik etkiyi sağladığı bildirilmiştir [19].

BIS indeksinin dışında anestezi derinliği tespitine yönelik olarak geliştirilen bazı indeksler mevcuttur [19]. E-entropy, entropy indeksini üreten cihazdır. Cihaz, ismini bilgi kuramındaki entropi kavramından alır. Kullanılan algoritma EEG sinyalindeki bilgi içeriğini, dolayısı ile düzensizliği ve kestirilebilirliği ölçer. Araştırmalar anestezi altında EEG sinyalinin düzensizliğinin azaldığını göstermektedir. Cihaz, zaman alanından ziyade izgesel alandaki düzensizliği (ya da tersi olarak bilgi zenginliğini) gösteren durum entropisi (state entropy, SE) ve cevap entropisi (response entropy, RE) denilen 2 indeks üreterek hastanın durumunu kestirmeye çalışır [19].

Bir başka indeks değeri, Narcotrend indeksi [51]. EEG sinyalinde görsel olarak A ve E arasındaki harflerle sınıflandırılabilen dalga şekillerinden hareketle anestezi safhalarını kestirmektedir. Bu yöntem, EEG şekillerini farklı kategorilerde sınıflandırmak için Kugler sınıflandırma ve denominasyon şemasını kullanır. Narcotrend, artan ya da azalan hipnotik derinlik sırasında kademeli değişimlere sahne olmaktadır. Narcotrend, çok değişkenli algoritmaya dayalı ve aynı zamanda BIS indeksine göre emerjans sırasında daha iyi performans sergilemekte gibi görünmektedir.

Bu belirtilen indeks değerlerinin dışında literatürdeki bazı çalışmalara burada yer verilmiştir.

Traast ve arkadaşları anestezi ilaçları ile EEG sinyalleri arasındaki ilişkiyi incelediler. Sonuç olarak, propofol/sufentanil içeren intravenöz anestezi uyanma esnasında EEG’de çok önemli değişimler olduğunu gözlemlediler [52].

Zikov ve arkadaşları anestezi derinliği tespitine yönelik olarak dalgacık temelli bir anestezi değeri önerdiler. Önerdikleri teknik, tek kanallı EEG sinyalinden yararlanarak dalgacık dönüşümü tabanlı bir analize dayanmaktadır. Bu yöntem merkezi sinir sistemi izlenmesi için dalgacık analizi değeri (wavelet analysis value for central nervous system monitoring, WAVCNS) ismini vermişlerdir. Araştırmacılar bu metodu, referans olması açısından BIS monitörün ürettiği indeks değeri ile karşılaştırmış ve yüksek bir korelasyon değeri ortaya koymuşlardır

($r=0.969$). Ayrıca BIS değerine kıyasla WAVCNS daha hızlı bir algoritmaya sahiptir [53].

Ferenets ve arkadaşları EEG sinyallerinden yararlanarak anestezi derinliğinin ölçümüne yönelik olarak, düzenliliği ve karmaşıklığı temel alan birkaç algoritmanın performansını analiz ettiler. Bu ölçekler spektral entropi, yaklaşıklık entropisi, Higuchi fraktal boyutu ve Lempel-Ziv karmaşıklığıdır. Sonuç olarak anestezi derinliği tahmininde iyi bir performans elde edilmiştir [54].

Lalitha ve arkadaşları anestetik derinlik seviyelerinin tespitinde doğrusal olmayan kaotik özellikler ve sinir ağları sınıflayıcılarından yararlandılar. Kaotik özellikler arasında korelasyon boyutu, Lyapunov üssü ve Hurst üssü öznitelik olarak kullanılmıştır. Sınıflandırma algoritması olarak ileri beslemeli sinir ağı ve Elman geri beslemeli sinir ağı olmak üzere iki algoritma tercih edilmiştir. Deneysel sonuçlar incelendiğinde Lyapunov üssü özniteliği ile Elman geri beslemeli sinir ağının birlikte kullanılması ile %99 doğruluk oranı elde edildiği görülmüştür [55].


BÖLÜM 5

VERİ SETLERİ

Bu bölümde çalışmada kullanılan veriler hakkında genel bilgiler sunulmaktadır.

5.1. BONN ÜNİVERSİTESİ EPİLEPSİ VERİ SETİ


EEG sinyalleri; Bonn üniversitesi Epileptoloji bölümü veri tabanından alınmıştır [56]. Tüm veri, 5 kümeden oluşmaktadır (A-E) ve her küme 23.6 saniye süreli 100 tek kanal EEG segmenti içermektedir. Bu 5 kümeden alınan EEG sinyal örnekleri Şekil 5.1’de görülmektedir. A ve B kümeleri sırasıyla gözler açıkken ve kapalıyken sağlıklı olan 5 gönüllüden elde edilen yüzey EEG kayıtlarını içermektedir. C kümesi, hasta olan gönüllülerden nöbet öncesinde hipokampal oluşumlu karşı yarım küreden ve D kümesi epileptojenik bölgeden elde edilmiştir. E kümesi ise hasta gönüllülerin kriz sırasındaki ölçümleridir. Sinyaller 12 bit analog sayısal dönüştürücü ile dönüştürüldükten sonra bilgisayar ortamına 173.61 Hz örnekleme frekansı ile (toplamda 4097 örnek) aktarılmıştır. Epileptik özellikler kendini 30-40 Hz altındaki frekans bantlarında gösterdiğinden spektral aralığı 0.5-85 Hz olan sinyallere 0.53-40 Hz bant geçiren filtre uygulanmıştır.



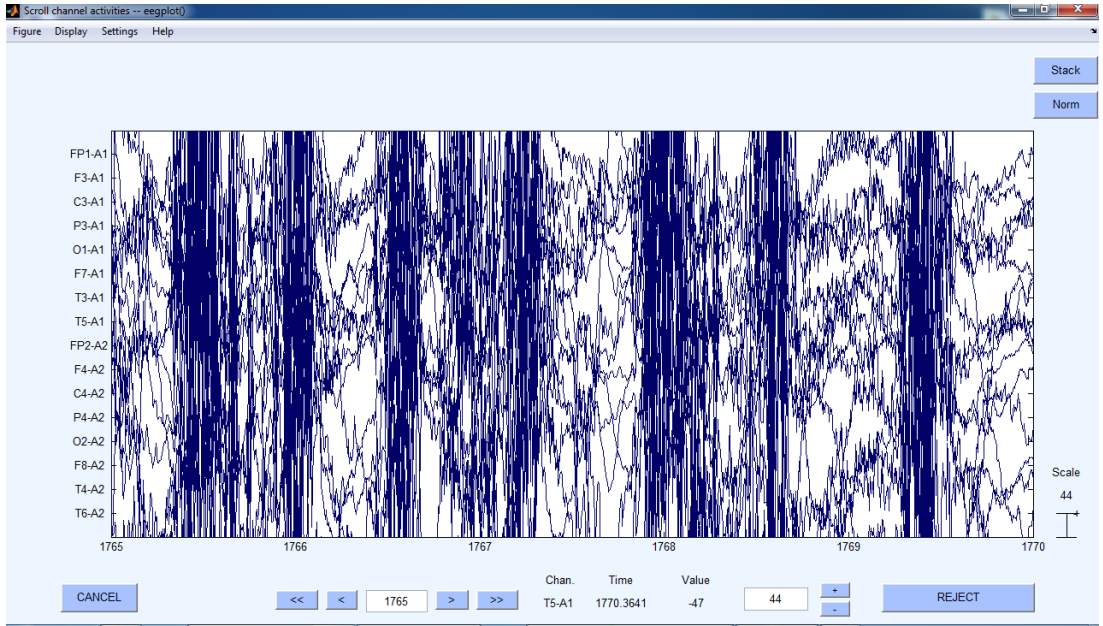
Şekil 5.1. A,B,C,D ve E kümelerine ait örnek EEG işaretleri.

5.2. YILDIRIM BEYAZIT ÜNİVERSİTESİ EPİLEPSİ VERİ SETİ

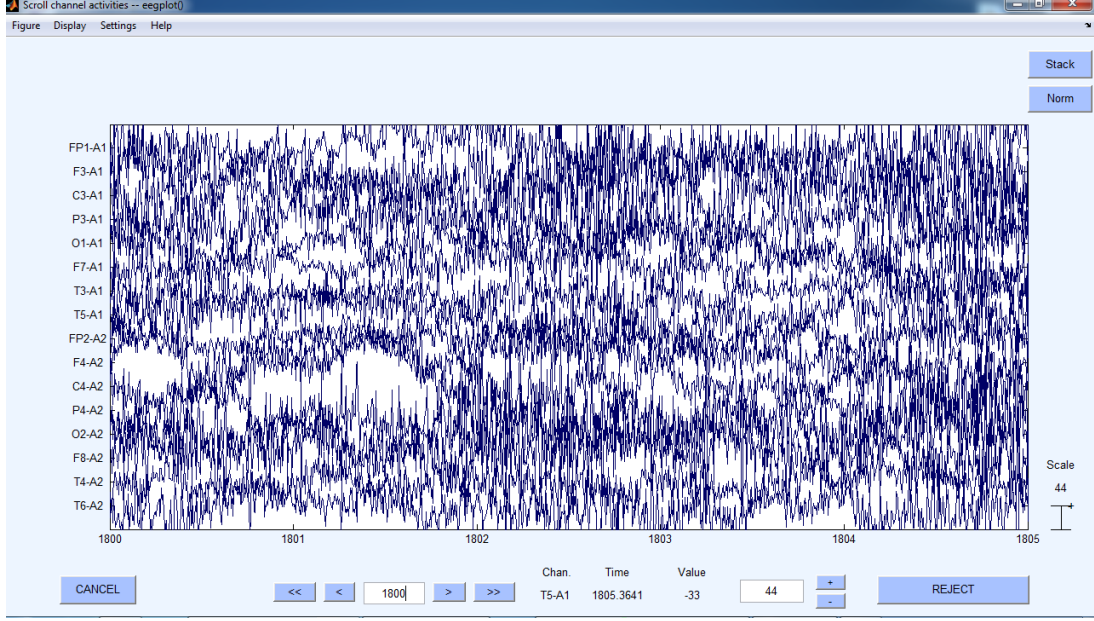
EEG verileri, Yıldırım Beyazıt üniversitesi araştırma ve uygulama hastanesi nöroloji anabilim dalından yaşları 18 ile 45 arasında değişen kişilerden seçilmiştir. Mevcut EEG verileri kişisel bilgisayar ortamında analiz edilmiştir. EEG cihazı olarak, Nihon Kohden firmasının Neurofax EEG 9100 modeli kullanılmıştır. Çekimde standart aktivasyon yöntemleri olan hiperventilasyon ve fotik stimülasyon tüm olgulara uygulandı. Kayıt sırasında genellikle alçak frekans filtresi 0.5-1 Hz, yüksek frekans filtresi 70 Hz olarak kullanıldı. Ancak gerekli görülen durumlarda filtre ayarları değiştirildi. Bütün sinyaller 16 bit çözünürlük, 256 Hz. örnekleme frekansı ile örneklendi. Verilerde hesapladığımız kadarıyla 200 epileptik atak mevcuttur. Bir epilepsi hastasına ait EEG veri örnekleri Şekil 5.2-5.5' de görülmektedir.



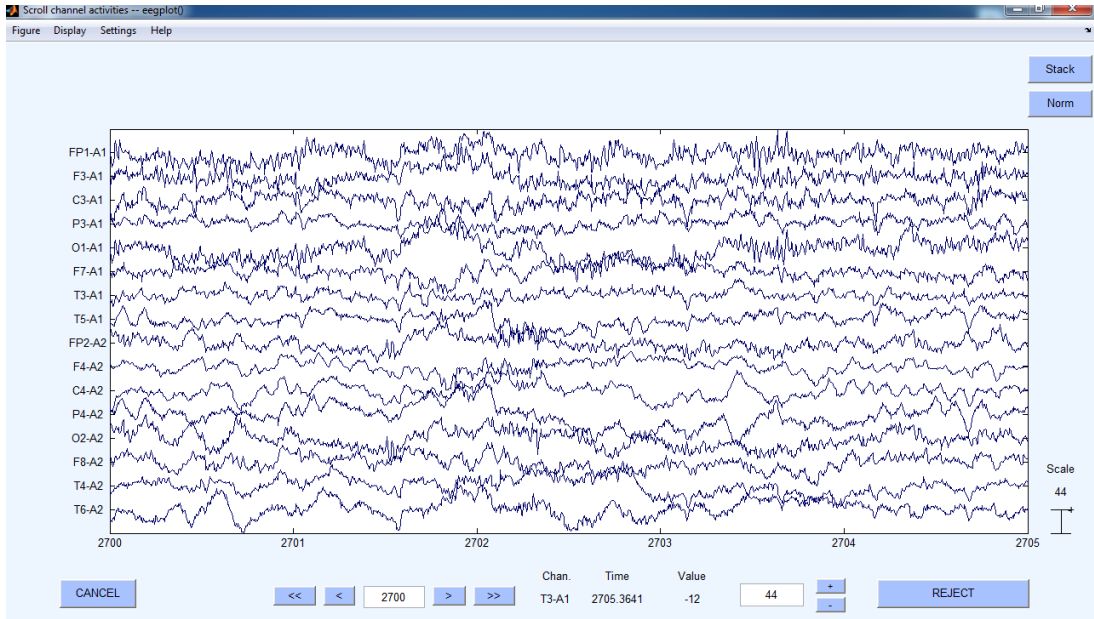
Şekil 5.2. Bir epilepsi hastasının atak yokken EEG görüntüsü.



Şekil 5.3. Bir epilepsi hastasının atak esnasında alınan EEG görüntüsü.



Şekil 5.4. Bir epilepsi hastasının atağın hemen arkasından EEG görüntüsü.

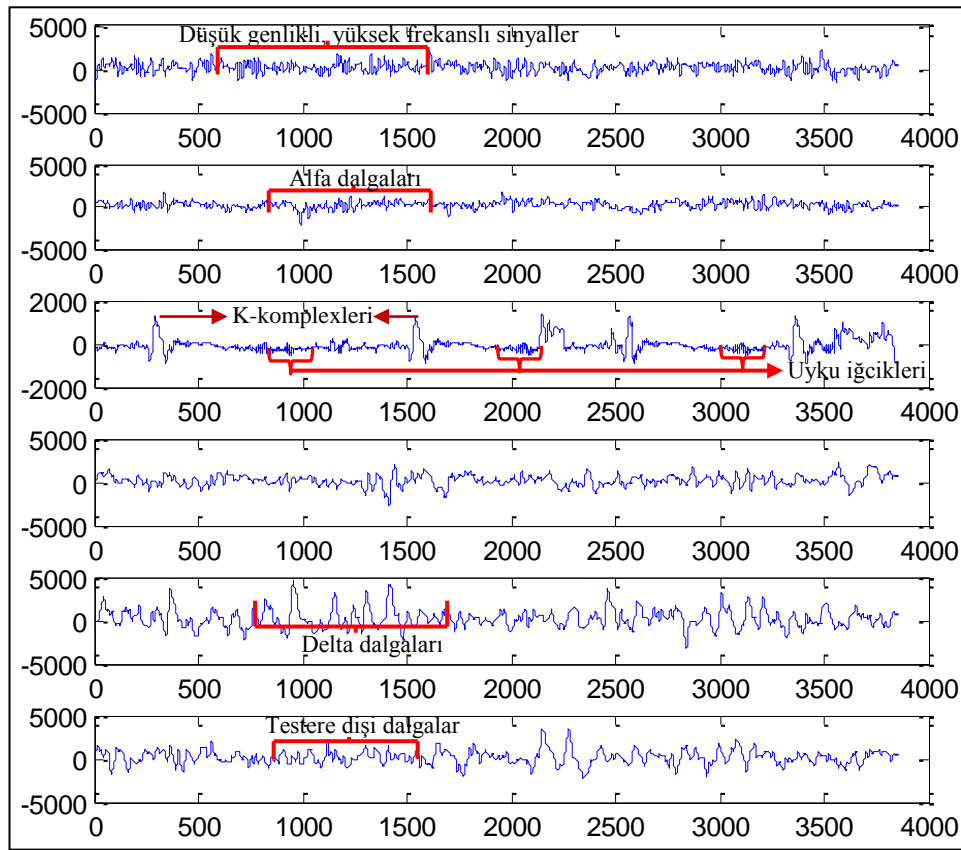


Şekil 5.5. Bir epilepsi hastasının, atağın yaklaşık 17 dakika sonrasındaki EEG görüntüsü.

5.3. ST. VINCENT'S UNIVERSITY HOSPITAL AND UNIVERSITY COLLEGE DUBLIN (UCD) UYKU EVRELERİ VERİ SETİ

Bu çalışmada kullanılan veri seti St. Vincent's üniversitesi hastanesi ve UCD tarafından sağlanmıştır [57]. Veritabanından 25 kişiye ait veriler alındı.

Polisomnogram kayıtları Jaeger-Toennies sistemi kullanılarak elde edildi. 10-20 elektrot sistemi kullanılarak verilerin toplandığı sistemde, veriler 2 EEG kanalından (C3-A2 ve C4-A1), 2 EOG kanalından ve 1 EMG kanalından alınmıştır. Bu çalışmada 1 EEG kanalından (C3-A2) alınan veriler kullanılmıştır. Örnekleme frekansı 128 Hz. seçilmiştir. Önışleme aşamasında EEG sinyallerini yumuşatmak amacıyla hareketli ortalama filtresi kullanılmıştır. EEG sinyallerindeki gürültü ve artifakt etkisini azaltmak amacıyla sinyallere 0.1-60 Hz bant geçiren filtre uygulanmıştır. Ayrıca 50 Hz. şehir şebekesinden kaynaklanan gürültüyü yok etmek için Notch filtre uygulanmıştır. Sonraki aşamada EEG sinyalleri 30 sn'lik epoklara bölündü. Ve her segment Hamming penceresi kullanılarak pencereleme işleminden geçirildi. Farklı uyku evrelerinde elde edilen EEG sinyallerini Şekil 5.6'da görmek mümkündür.



Şekil 5.6. Uykunun farklı evreleri için EEG sinyalleri: Sırasıyla uyanık, N-REM 1, 2, 3 ve REM evreleri.

5.4. YILDIRIM BEYAZIT ÜNİVERSİTESİ ANESTEZİ VERİ SETİ

Bu çalışmada kullanılan veriler Yıldırım Beyazıt üniversitesi tıp fakültesi hastanesinden temin edilmiştir. Bu çalışmaya 20 tane izofluran anestezi ilaç kullanılan vaka dahil edilmiştir. Gerçekleştirilen operasyonlar ve anestezi süreleri farklıdır. Hastaların yaşı 30 ile 60 arasında değişmektedir. Veri grubunun özellikleri Çizelge 5.1’de belirtilmektedir.


Çizelge 5.1. Veri grubunun karakteristikleri.

	Aralık	Ortalama	Standart Sapma
Yaş	30-60	47.5	26.3
Ağırlık	45-88	69.5	13.9

EEG sinyali 10/20 elektrot yerleştirme sistemine uygun olarak 15 kanaldan (Fp1, Fp2, F7, F3, Fz, F4, F8, T7, C3, Cz, C4, T8, P3, Pz, P4) kaydedilmiştir. 0.1 – 60 Hz arasında filtrelenen EEG sinyali 128 Hz örnekleme hızıyla sayısallaştırılmıştır. Anestezi verileri 6 farklı anestezi seviyesine aittir. Dolayısıyla bu çalışmada 6 seviyeli bir anestezi derinliğinin belirlenmesine yönelik uygulamalar yapılmıştır. Kayıtlar sırasında, çıkarılan özniteliklerle kıyaslama yapılabilmesi için anestezi derinliği takip cihazından (BIS™, Aspect Medical Systems) alınan BIS indeksi de kaydedilmiştir. Bu cihaz, 0-100 arasında bir indekslemeye sahiptir ve uyanıklılığı 100 değeri ile temsil etmektedir. Bu çalışmada sınıflandırılan anestezi seviyeleri ve karşılık gelen BIS değerleri Çizelge 5.2’de sunulmaktadır. Şekil 5.7’de BIS cihazı ve özellikleri görülmektedir.

Çizelge 5.2. Anestezi seviyelerinin skorlanması.

Anestezi Derinlik Seviyesi	BIS Aralığı	Seviye
Derin (ing. Deep) Anestezi	BIS indeks: 0-25	6
	BIS indeks: 25-40	5
Orta Seviye (ing. Moderate) Anestezi	BIS indeks: 40-50	4
	BIS indeks: 50-60	3
Hafif (ing. Light) Anestezi	BIS indeks: 60-80	2
Uyanık (ing. Awake)	BIS indeks: 80-100	1



Şekil 5.7. BIS ekranı: a) anlık BIS indeks değeri, b) Geçmiş BIS değerleri, c) Sinyal kalite derecesi, d) EEG sinyali.

BÖLÜM 6

METOT

Biyomedikal teşhis sistemleri genel olarak ön işleme, öz nitelik çıkarma/seçme ve sınıflama aşamalarından oluşmaktadır. Bu aşamalar genel olarak biyomedikal sinyal işleme konuları arasındadır. Öznitelik çıkarma aşamasında ham verilerden, o verileri temsil edecek özniteliklerin elde edilmesi sağlanmaktadır. Öznitelik seçme aşamasında, çeşitli öznitelik seçme algoritmalarını kullanarak mevcut öznitelik kümesinin içinden etkili öznitelik değerlerinin elde edilmesi sağlanmaktadır. Bu şekilde etkili öznitelikler tespit edilmekte ve öznitelik vektörünün boyutu azaltılmaktadır. Teşhis sistemlerinin son aşaması olan sınıflandırma aşamasında ise tespit edilen öznitelikler sınıflandırma algoritmasına giriş olarak sunulur ve algoritmanın yapısına bağlı olarak sınıflandırma işlemi gerçekleştirilir. Bu tez çalışmasında 3 farklı yöntem kullanılarak farklı EEG verilerinin sınıflandırılması gerçekleştirilmiştir. Bütün yöntemlerde ortak olan aşama EEG verilerinin temizlenmesi ve filtreleme aşamalarıdır. Bahsi geçen 3 yöntem sırasıyla aşağıda verilmiştir.

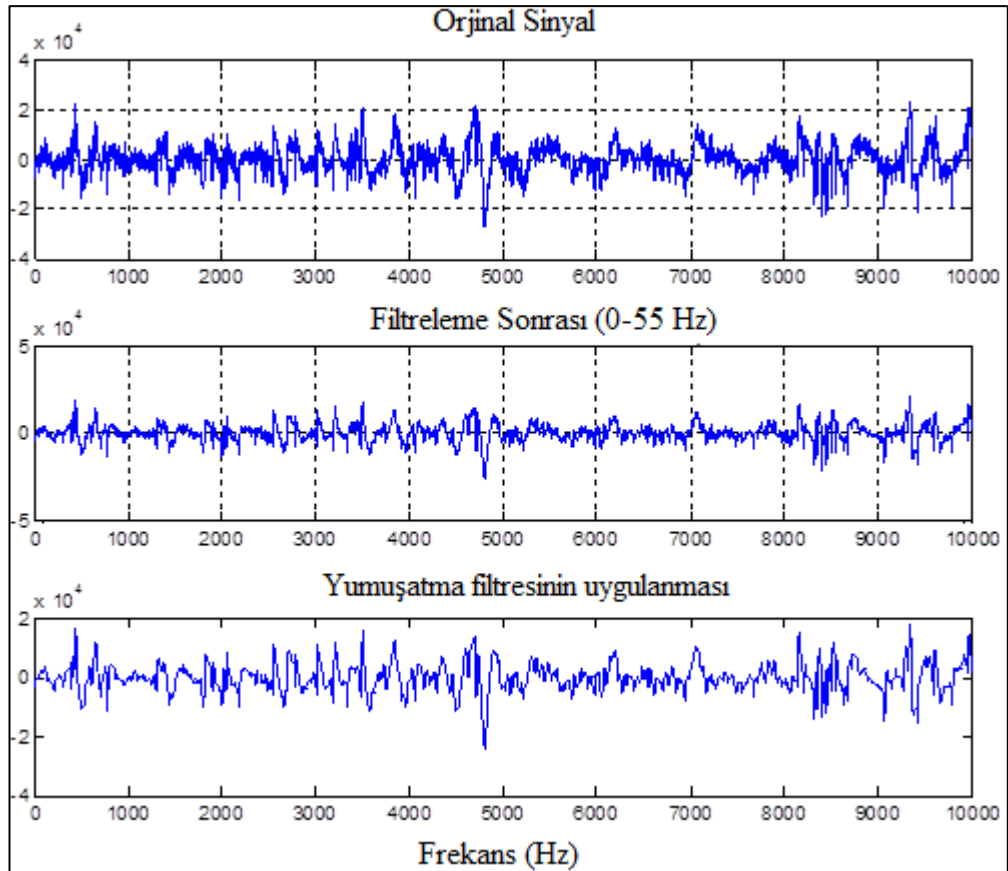
- Yöntem 1 : Etkili öznitelik seçme ve sınıflandırma algoritmasının tespiti
- Yöntem 2 : Karmaşık değer tabanlı algoritmalar
- Yöntem 3 : CUDA paralel işlemci mimarisi ile sınıflandırılma işleminin hızlı bir şekilde gerçekleştirilmesi.

Yapılan deneylerde bu yöntemler farklı EEG verileri üzerinde uygulanarak hız ve başarı performansları elde edilmiştir. Bazı deneylerde bu yöntemlerin birleştirilerek hibrit metotların elde edildiği görülecektir.

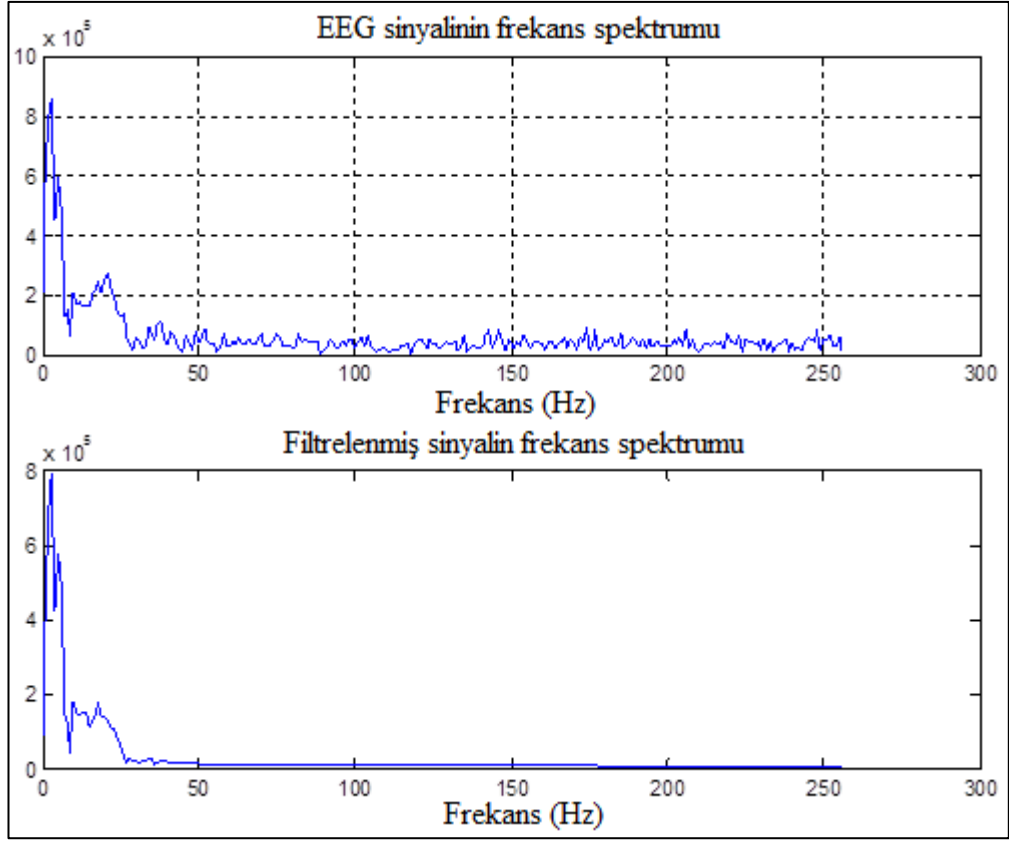
6.1. EEG VERİLERİNİN TEMİZLENMESİ VE FİLTRELEME AŞAMALARI

EEG verilerinin hazırlanması aşamasında MATLAB programı kullanılmıştır. EEG sinyallerindeki gürültü ve artefakt etkisini azaltmak amacıyla sinyallere 0.1-60 Hz bant geçiren filtre uygulanmıştır. Ön işleme aşamasında EEG sinyallerini yumuşatmak amacıyla yumuşatma filtrelerinden, hareketli ortalama filtresi kullanılmıştır. Şekil 6.1’de EEG sinyalinin orijinali ve 0-55 Hz arasında filtreleme ve yumuşatma filtresi aşamalarından geçtikten sonraki görüntüsü görülmektedir. Şekil 6.2’de orijinal ve filtrelenmiş sinyalin frekans spektrumu sunulmuştur.

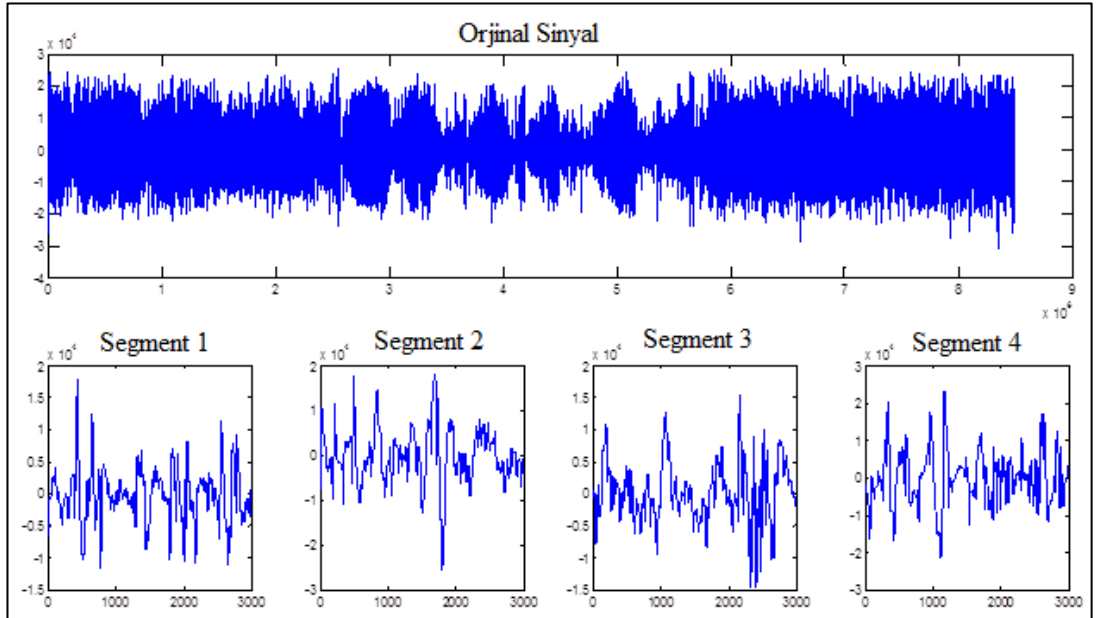
Uzun EEG sinyallerinin daha hızlı işlenmesi için belirli saniyelerde epoklara bölme işlemi gerçekleştirilmiştir. Sinyalin uç bölgelerindeki bilgi kaybını engellemek amacıyla pencereleme fonksiyonlarından yararlanılmıştır. Şekil 6.3’de örnek bir uygulama görülmektedir.



Şekil 6.1. EEG sinyalinin 0-55 Hz arasında filtreleme ve yumuşatma filtresi aşamalarından geçmesi.



Şekil 6.2. Filtreleme aşamasından önceki EEG ve filtreleme aşamasından sonraki EEG sinyali.



Şekil 6.3. Örnek EEG sinyalinin 30 sn'lik epoklara bölünmesi.

6.2. YÖNTEM 1: ETKİLİ ÖZNETELİK SEÇME VE SINIFLANDIRMA ALGORİTMALARININ TESPİTİ

6.2.1. Öznitelik Çıkarma Algoritmaları

Bu tez çalışmasında EEG sinyallerinden anlamlı bilginin tespiti için aşağıda kısa açıklamaları verilen ve Çizelge 6.1’de belirtilen öznitelik değerleri kullanılmıştır. Veri setlerine göre uygun öznitelikler bu tablodan seçilmektedir.

Çizelge 6.1. Öznitelik tablosu.

No	Öznitelik	No	Öznitelik	No	Öznitelik
1	Aritmetik ortalama (AO)	16	Wigner ville katsayısı 2 (WV-2)	31	A5-1*
2	Maksimum değer (MaxV)	17	Wigner ville katsayısı 3 (WV-3)	32	A5-2*
3	Minimum değer (MinV)	18	Wigner ville katsayısı 4 (WV-4)	33	A5-3*
4	Standart Sapma (SD)	19	D3-1*	34	Hjorth aktivitesi (HA)
5	Varyans (V)	20	D3-2*	35	Hjorth hareketliliği(HM)
6	Medyan (MN)	21	D3-3*	36	Hjorth karmaşıklığı (HC)
7	Sıfır geçiş sayısı (ZC)	22	D3-4*	37	Ortalama eğri uzunluğu (MCL)
8	Skewness (SK)	23	D4-1*	38	Hurst üsteli (HE)
9	Kurtosis (KH)	24	D4-2*	39	Ortalama enerji (ME)
10	Petrosian fractal uzunluğu (PFD)	25	D4-3*	40	Ortalama teager enerjisi (MTE)
11	Rényi entropi (REn)	26	D4-4*	41	Beta Ratio
12	Spektral entropi (SpEn)	27	D5-1*	42	Alpha Ratio
13	Permütasyon entropi (PEn)	28	D5-2*	43	SEF
14	Yaklaşık entropi (ApEn)	29	D5-3*	44	Detrended fluctuation analysis (DFA)
15	Wigner ville katsayısı 1 (WV-1)	30	D5-4*		

* işareti ile belirtilen öznitelikler hakkında detaylı bilgi için Bölüm 6.2.1.3’e bakınız.

6.2.1.1. Zaman Tabanlı Öznitelikler

İstatiksel öznitelikler: Bu aşamada EEG işaretlerinin istatistiksel öznitelikleri elde edilmiştir. Bu öznitelikler ve açıklamaları Çizelge 6.2’de sunulmaktadır.

Çizelge 6.2. İstatiksel özniteliklerin kısa açıklamaları.

Öznitelik	Formül	
Minimum Değer (MinV)	: $MinV = \min[x_n]$	(6.1)
Maksimum Değer (MaxV)	: $MaxV = \max[x_n]$	(6.2)
Standart sapma (SD)	: $SD = \sqrt{\frac{\sum_{n=1}^N (x_n - AO)^2}{N - 1}}$	(6.3)
Aritmetik Ortalama (AO)	: $AO = \frac{1}{N} \sum_{n=1}^N x_n$	(6.4)
Varyans (V)	: $V = \frac{\sum_{n=1}^N (x_n - AO)^2}{N - 1}$	(6.5)
Çarpıklık (Skewness, S)	: $S = \frac{\sum_{n=1}^N (x_n - AO)^3}{(N - 1)SD^3}$	(6.6)
Basıklık (Kurtosis, K)	: $K = \frac{\sum_{n=1}^N (x_n - AO)^4}{(N - 1)SD^4}$	(6.7)
Medyan değeri (MN)	$MN = \left(\frac{N + 1}{2}\right)^{th}$	(6.8)
	$MN = \frac{\left(\frac{N}{2}\right)^{th} value + \left(\frac{N}{2} + 1\right)^{th} value}{2}$	(6.9)

- Burada $x_n = 1, 2, 3 \dots n$ bir zaman serisidir. N data sayısı ve AO örneklerin ortalamasıdır.

Sıfır geçiş sayısı (Number of zero crossing, ZC): Sıfır geçiş sayısı; elektronik, matematik, görüntü işleme ve sinyal işleme alanlarında yaygın kullanılan zaman temelli bir özniteliktir [58]. Bir bölüt içerisinde gerçekleşen sıfır geçişlerinin sayısını ifade eder. Sıfır geçişleri örnekler arasında işaret farkı olduğu zaman meydana gelmektedir. Bu öznitelik, işarettaki gürültü oranını ifade eden bir ölçüt olarak kullanılabilir. Araştırmacılar beyin aktiviteleri sırasında ve uykunun farklı evrelerinde EEG sinyallerindeki sıfır geçiş sayısının değiştiği gözlemlemiştir. Sıfır geçiş sayısı şu şekilde hesaplanır: $(x_{n-1} < 0$ ve $x_n > 0)$ veya $(x_{n-1} > 0$ ve $x_n < 0)$ veya $(x_{n-1} \neq 0$ ve $x_n = 0)$.

Hjorth parametreleri: EEG sinyal analizinde sıklıkla kullanılan özniteliklerdir [59]. Aynı zamanda uyku evrelerinin sınıflandırması ile ilgili çalışmalarda kullanılmıştır. Hjorth parametreleri hesaplanırken sinyallerin birinci ve ikinci türevlerinden yararlanılır. Hjorth parametreleri Çizelge 6.3 de görüldüğü gibi hesaplanmaktadır.

Çizelge 6.3. Hjorth parametreleri.

Öznitelik ismi	Hjorth Aktivitesi (HA)	Hjorth Hareketliliği (HM)	Hjorth Karmaşıklığı (HC)
Formül	$HA = \sigma_0^2$	$HM = \sigma_1/\sigma_0$	$HC = \sqrt{(\sigma_2/\sigma_1)^2 - (\sigma_1/\sigma_0)^2}$

6.2.1.2. Lineer Olmayan Öznitelikler

Petrosian fraktal boyutu (Petrosian fractal dimension, PFD): Fraktal Boyut, bir sinyalin karmaşıklığını hesaplayan kaotik bir yöntemdir [60]. PFD, fraktal boyutun hızlı hesaplanmasını sağlamaktadır. Bu işlemi sinyali ikili diziyeye çevirerek gerçekleştirir. Denklem 6.10'da görüldüğü gibi hesaplanmaktadır.

$$PFD = \log_{10} k / (\log_{10} k + \log_{10}(k / (k + 0.4N_\delta))) \quad (6.10)$$

Burada k sinyalin örneklerinin sayısı ve N_δ sinyal türevlerindeki işaretlerin değişikliklerin sayısını ifade etmektedir.

Ortalama eğri uzunluğu (Mean curve length, MCL): MCL [61] Esteller ve arkadaşları tarafından Kat'z fraktal boyutunun bir tahmini için önerilmiştir. EEG sinyallerindeki aktivite tespitinde yaygın olarak kullanılmaktadır. MCL şu şekilde tanımlanabilir;

$$MCL[n] = \frac{1}{N} \sum_{m=k-N+1}^k |x[m] - x[m-1]| \quad (6.11)$$

Burada $x[m]$ bir EEG zaman serisi, N pencere uzunluğu ve k epoktaki en son örnektir.

Ortalama Enerji (Mean energy, ME): Aktivite arttıkça sinyallerin enerji değerlerinde artışlar gerçekleşmektedir. Özellikle farklı uyku evrelerindeki farklı aktiviteler dikkate alındığında ortalama enerjinin iyi bir göstere olacağı düşünülmektedir. Ortalama enerji, işaretteki tüm örneklerin karelerinin ortalaması alınarak hesaplanır. ME denklemdeki gibi hesaplanabilir;

$$ME[n] = \frac{1}{N} \sum_{m=k-N+1}^k x[m]^2 \quad (6.12)$$

Burada $x[m]$ bir EEG zaman serisi, N pencere uzunluğu ve k epoktaki en son örnektir.

Ortalama Teager Enerjisi (Mean Teager Energy MTE): MTE, EEG arařtırmalarında yaygın olarak kullanılan bir öznitelik deęeridir [62]. MTE řu řekilde hesaplanabilir;

$$MTE[k] = \frac{1}{N} \sum_{m=k-N+3}^k (x[m-1]^2 - x[m]x[m-2]) \quad (6.13)$$

Burada $x[m]$ bir EEG zaman serisi, N pencere uzunluğu ve k epoktaki en son örnektir.

6.2.1.3. Frekans Tabanlı Öznitelikler

Wigner-Ville dönüşümü (WV), bir zaman frekans dağılımıdır ve potansiyel olarak zamanla deęişen sinyallerin analizinde kullanışlı bir yöntemdir [63]. WV Denklem 6.14'deki gibi ifade edilir;

$$WV(t, \omega) = \sum_{t=-\infty}^{\infty} f\left(t + \frac{t_0}{2}\right) f^*\left(t - \frac{t_0}{2}\right) e^{-jt_0\omega} d\omega_0 \quad (6.14)$$

Burada; $WV(t, f)$, $f(t)$ sinyalinin t anındaki ve f frekansındaki enerji dağılımıdır. f^*, f 'in kompleks eşleniğini temsil eder. ω frekans deęeridir.

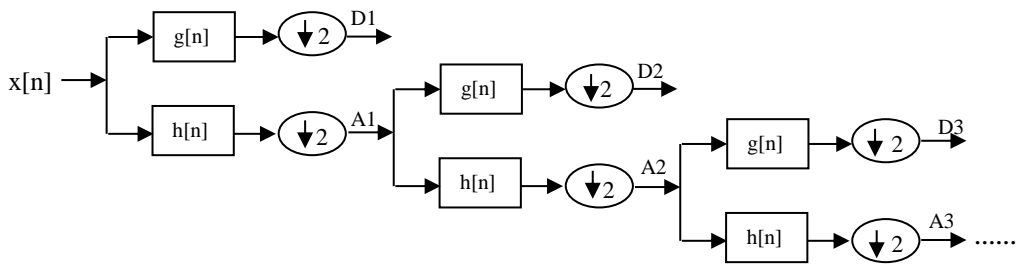
Sinyale WV dönüşümünün uygulanması ile elde edilen zaman-frekans düzleminden öznitelikler elde edilmektedir. Öznitelikler elde edilirken düzlemdeki zaman deęerlerine karşılık gelen en büyük frekans deęerleri kullanılmaktadır. Bu çalışmada bu frekans deęerlerinin oluşturduęu fonksiyon 3. dereceden bir polinomla modellenmiş ve bu polinomun katsayıları öznitelik olarak kullanılmıştır [64]. Sonuç

olarak bu polinomun katsayılarından (WV-1, WV-2, WV-3, WV-4) oluşan 4 tane öznitelik elde edilmiştir.

Dalgacık dönüşümü ve dalgacık katsayıları: Fourier dönüşümünün durağan olmayan sinyaller üzerindeki eksiklerini gidermek için geliştirilmiş bir dönüşüm yöntemidir. Bu yöntem, gürültüye karşı daha az hassasiyet göstermekte ve durağan olmayan sinyallere rahatlıkla uygulanabilmektedir. Sürekli dalgacık dönüşümde hesap yükü çok fazladır. Hesap yükünü azaltmak için ayrık dalgacık dönüşümü (ADD) kullanılmaktadır. Sürekli dalgacık dönüşümü ölçek ve kaydırma parametreleri ($a = 2^j$ ve $b = k.2^j = k.a$) ile ayrık hale getirilir. Bu durumda ADD temel ifadesi aşağıdaki gibi ifade edilebilir:

$$W(j, k) = \sum_j \sum_k x(n) 2^{-j/2} \psi(2^{-j}n - k) \quad (6.15)$$

Burada $x(n)$ işaretin kendisi ve ψ ana dalgacıktır. Alçak geçiren filtre ile işaretin düşük frekansa sahip yaklaşık katsayısı ve yüksek geçiren filtreyle de işaretin yüksek frekansa sahip detay katsayısı elde edilmektedir. İşaretin en uygun yapısını elde etmek için yeterli sayıda katsayı hesaplanmalıdır. Bir $x[n]$ işaretinin ayrıştırma prosedürü Şekil 6.4'de gösterilmektedir.



Şekil 6.4. ADD ile alt bantlara ayrıştırma. $h[n]$ yüksek geçiren filtre, $g[n]$ alçak geçiren filtre.

Şekilde de görüldüğü gibi ayrık $x(n)$ sinyali yüksek-geçiren filtreden geçerek detay katsayıları ($D_i[n]$) ve alçak-geçiren filtreden geçerek yaklaşık katsayıları ($A_i[n]$) elde edilmektedir. Her ayrıştırma seviyesinde yarım-bant filtreler, frekans bandının yarısını içeren sinyallerin oluşmasını sağlar [65].

Bu çalışmada, EEG işaretleri Daubechies dalgacı (db4) kullanılarak 5. seviyeye kadar ayrıştırılmıştır. Bu işlem sonucunda, 5 adet ayrıştırma katsayıları işareti (D1-D5) ve 1 adet yaklaşıklık katsayıları işareti (A5) elde edilmiştir. Çıkarılan öznelik vektörlerinin boyutlarının azaltılabilmesi için dalgacık katsayıları üzerinde istatistiksel özellikler hesaplanmıştır. EEG işaretlerinin zaman-frekans dağılımını göstermekte kullanılan istatistiksel özellikler aşağıda verilmektedir:

1. Her alt bantta dalgacık katsayıların mutlak değerlerinin ortalaması (D3-1, D4-1, D5-1 ve A5-1).
2. Her alt bantta dalgacık katsayıların ortalama gücü (D3-2, D4-2, D5-2 ve A5-2).
3. Her alt bantta dalgacık katsayıların standart sapması (D3-3, D4-3, D5-3 ve A5-3).
4. Komşu alt bantlara ait mutlak ortalama değerlerinin oranı. (D3-4, D4-4, D5-4 ve A5-4).

Özellik 1-2 işaretin frekans dağılımını gösterirken, özellik 3-4 frekans dağılımındaki değişim miktarını göstermektedir. Bu şekilde 16 öznelik parametresi elde edildi.

6.2.1.4. Entropi Tabanlı Öznelikler

Spektral Entropi (SpEn): Kompleks sinyallerdeki düzenlilik derecesinin belirlenmesi sağlayan bir özneliktir [66]. Düzgün bir olasılık dağılımına sahip olan verinin entropisi yüksek olacaktır. Bununla birlikte düzensiz bir olasılık dağılımına sahip olan verinin entropisi ise düşük olacaktır. SpEn, normal entropi hesabından farklı olarak işaretin güç spektrumu bileşenlerinin olasılık değerleri kullanılarak hesaplanır. SpEn denklemde görüldüğü gibi hesaplanır.

$$S = \sum_f P_f \log\left(\frac{1}{P_f}\right) \quad (6.16)$$

SpEn değerinin tespitinde öncelikle, işaretin güç spektral yoğunluğunu bulabilmek amacıyla işaretin Fourier dönüşümü hesaplanır. Buradaki her bir frekans değeri

işaretin toplam güç miktarına bölünerek bir olasılık yoğunluk fonksiyonu elde edilir. Denklem 6.16'daki P_f , bu fonksiyonu göstermektedir.

Renyi Entropi (REn): REn, spektral entropinin özel bir durumudur [67]. Renyi entropi Denklem 6.17'de görüldüğü gibi hesaplanmaktadır. Burada α ($\alpha \geq 1$) entropinin derecesidir.

$$REn(X) = \frac{1}{1-\alpha} \sum_{k=1}^n \log P_k^\alpha \quad (\alpha \neq 1 \text{ and } X = \alpha_i) \quad (6.17)$$

Burada $P_k, \{x_1, x_2, \dots, x_n\}$ değerlerinin olasılığını ifade eder. Bu çalışmada REn, $\alpha = 2$ için hesaplanmıştır.

$$REn(2) = -\log\left(\sum_{k=1} P_k^2\right) \quad (6.18)$$

Yaklaşıklik entropisi (approximate entropy, ApEn) zaman serisinin düzenliliğini anlayabilmemizi sağlayan istatistiksel bir parametredir [68]. ApEn verinin karmaşıklığını ve zaman serisinde bilgi oluşumunu nicelemek için negatif olmayan bir sayı kullanır. Bu değer ne kadar büyük olursa zaman serisindeki veriler de o derece karmaşık ve düzensiz olacaktır.

$$ApEn(k, l, N) = \frac{1}{N-k+1} \sum_{i=1}^{N-k+1} \log C_i^k(l) = -\frac{1}{N-k} \sum_{i=1}^{N-k} \log C_i^k(l) \quad (6.19)$$

Burada: $C_i^k(l) = \frac{1}{N-k+1} \sum_{j=1}^{N-k+1} \theta(l - \|x_i - x_j\|)$ bir korelasyon integralidir. Bu çalışmada $k = 2$ ve l orjinal veri serisinin standart sapmasının 0.15 katı olarak belirlenmiştir.

Permutation entropy (PEn): PEn, Bandt ve Pompe tarafından geliştirilmiştir [69]. PEn komşu değerleri karşılaştırmaya dayalı, zaman serileri için karmaşıklığı ölçmeye dayalı bir değerdir. PEn denklemde görüldüğü gibi hesaplanabilir.

$$H_p(n) = - \sum_{\pi=1}^{n!} p(\pi) \ln p(\pi) \quad (6.20)$$

Burada $p(\pi) = f(\pi)/(T - (n - 1)l)$ ilişkili frekans değeridir. $f(\pi)$ zaman serisindeki frekans değerini, n gömme (ing. embedding) boyutudur.

6.2.2. Öznitelik Seçme Algoritmaları

Sinyal işleme uygulamalarında kullanılacak olan sınıflandırma yöntemine girdi olarak genellikle veri setinden çıkarılmış olan öznitelikler kullanılır. Bazı uygulamalarda öznitelik sayısı birkaç tane ile sınırlı kalırken, bazılarında da çok fazla miktarda olabilir. Her sinyal için çıkarılan öznitelikler bir öznitelik matrisinde saklanır. Dolayısı ile hem sinyal büyüklüğü hem de öznitelik sayısı matrisin boyutunu yani işlem süresini etkileyecektir. Çıkarılmış olan özniteliklerin sinyalleri ve sinyallere karşılık gelen sınıfları ne kadar iyi temsil ettiği önemlidir. Sınıflar arasında daha iyi ayırım yapabilen öznitelikler, yüksek seviyeli öznitelikler olarak adlandırılır ve sınıflandırıcının performansı açısından daha önemlidir. Tüm öznitelikleri kullanmak yerine sadece bazı yüksek seviyeli özniteliklerin kullanılması yapılan işlem sayısını azaltabilir, aynı zamanda gürültülü özniteliklerin temizlenmesi ile performans artışları da sağlanabilir.

6.2.2.1. Hızlı Korelasyon Tabanlı Filtre (Fast Correlation Based Filter, FCBF)

FCBF, öznitelikler arası ilişki ve artıklık kriterlerini temel alarak geliştirilmiştir [70]. FCBF algoritmasında, iki öznitelik arasında ve iki sınıf arasındaki ilişki ve artıklığın değerlendirilmesinde Simetrik belirsizlik (symmetric uncertainty, SU) değeri kullanılır. SU entropi tabanlı doğrusal olmayan bir korelasyon ölçütüdür. X ve Y değişkenleri için SU değeri Denklem 6.21'deki gibi hesaplanır. Burada X ve Y herhangi iki özneliği ya da bir öznitelik ve bir sınıf etiketi çiftini ifade etmektedir.

$$SU(A, B) = 2[IG(A|B)/H(A) + H(B)] \quad (6.21)$$

$$IG(A|B) = H(A) - H(A/B) \quad (6.22) \quad H(A) = - \sum_i P(a_i) \log_2(P(a_i)) \quad (6.23)$$

Burada $IG(A | B)$ A'nın B değerlerine bağlı bilgi kazancını ifade eder. $H(A)$ ve $H(B)$, A ve B değişkenlerinin entropileridir [70]. $P(a_i)$ A değişkeninin olasılık değeridir ve A'nın B değerlerine bağlı entropisi olan $H(A | B)$ denklemde görüldüğü gibi hesaplanır.

$$H(A|B) = - \sum_j P(b_j) \sum_i P(a_i|b_j) \log_2(P(a_i|b_j)) \quad (6.24)$$

FCBF algoritması iki aşamadan oluşmaktadır [64]. İlk olarak her bir öznitelik ile sınıf etiketleri arasındaki korelasyonu ölçmek için SU değerleri hesaplanır. Korelasyon değeri belli bir eşik değerine eşit ya da bu değer altında olan öznitelikler elenmektedir. İkinci aşamada, kalan öznitelikler arasından sınıf etiketleri ile en ilişkili olanlar kullanılarak artık öznitelikler saptanmaya çalışılır. Tespit edilen artık öznitelikler elenir. İki aşama sonucunda kalan öznitelikler, sınıf etiketleri ile en ilişkili, kendi aralarında ise en az artıklığa sahip öznitelik kümesi olarak değerlendirilmektedir [63].

6.2.2.2. Minimum Fazlalık Maksimum İlişki (Minimum Redundancy Maximum Relevance, mRMR)

mRMR algoritması, sınıf etiketleriyle en ilişkili (ing. relevance) öznitelikleri seçmeye çalışırken eş zamanlı olarak seçilen öznitelikler arasındaki artıklığı (ing. redundancy) minimize etmeye çalışan bir filtreleme yöntemidir [71]. Algoritma her bir özniteliği ve sınıf etiketleri vektörünü ayrık bir rastlantı değişkeni olarak görür ve iki öznitelik arasındaki ya da bir öznitelik ile sınıf etiketleri vektörü arasındaki benzerlik seviyesini ölçmek için aralarındaki ortak bilgiyi (ing. mutual information), $I(x, y)$, kullanır.

$$I(X, Y) = \sum_{i,j} p(x_i, y_j) \log \frac{p(x_i, y_j)}{p(x_i)p(y_j)} \quad (6.25)$$

x ve y öznitelikleri için, $p(x_i)$ ve $p(y_j)$ marjinal olasılık fonksiyonu ve $p(x_i, y_j)$ bağlantı olasılık dağılımı olmak üzere $I(x, y)$, x ve y 'nin karşılıklı bilgi miktarıdır (mutual information). Ortak bilgi iki rastlantı değişkeninin tamamıyla bağımsız olduğu durumlarda 0 değerini almaktadır. Bu değer negatif olamaz ve simetriktir ($I(X, Y) \geq 0, I(X, Y) = I(Y, X)$).

Gösterimde kolaylık sağlamak amacıyla, her bir öznitelik f_i , n tane gözlemin bir araya gelerek oluşturduğu bir vektör olarak tanımlanacaktır ($f_i = [f_i^1, f_i^2, f_i^3, \dots, f_i^n]$). Bir öznitelik vektörünün reel değerlerini barındıran f_i vektörü ise F_i ayrık rastlantı değişkeninin bir örneği olarak ele alınacak ve öznitelik i ve j arasındaki ortak bilgi, $I(F_i, F_j)$ bu ayrık rastlantı değişkenleri üzerinden hesaplanacaktır. Burada $i, j = 1, 2, \dots, d$, d ise veri kümesinin boyut sayısını diğer bir deyişle veri kümesindeki öznitelik sayısını göstermektedir. Ortak bilgi kavramı sadece iki öznitelik arasındaki benzerlik seviyesini değil herhangi bir öznitelik i ile sınıf etiketleri vektörü, ($h = [h^1, h^2, h^3, \dots, h^n]$) ve ona denk düşen ayrık rastlantı değişkeni, H , arasındaki benzerliğin, $I(H, F_i)$, ölçülmesinde kullanılmaktadır.

S seçilmek istenen öznitelik kümesi olsun ve $|S|$ bu kümenin eleman sayısını gösterecek. Seçilmek istenen kümenin seçilebilecek en iyi küme olmasını garanti etmek için yukarıda bahsedilen iki koşulun karşılanması gerekir. Bunlardan ilki maksimum ilişki (maximum relevance, maxMR):

$$\max MR, \quad MR = \frac{1}{|S|} \sum_{F_i \in S} I(F_i, H) \quad (6.26)$$

İkincisi ise minimum artıklık (minimum redundancy, minMV):

$$\min MV, \quad MV = \frac{1}{|S|^2} \sum_{F_i, F_j \in S} I(F_i, F_j) \quad (6.27)$$

koşuludur. mRMR algoritması bu iki koşulu iki basit kombinasyon ile birleştirmektedir: $\max(MR - MV)$ ve $\min(MV/MR)$.

İdeal olarak bu iki koşulun karşılanması sonucunda en iyi öznitelik kümesinin elde edilmesi $O(N^{|S|})$ karmaşıklığa sahip bir algoritma gerektirmektedir. Arama uzayının çok büyük olması nedeniyle, mRMR algoritması bu optimizasyon sorununu şu şekilde çözer: Öncelikle ilk öznitelik Eşitlik 6.26'ye göre seçilir. Bu demektir ki seçilen ilk öznitelik sınıf etiketleri ile maksimum seviyede ortak bilgi içeren öznitelik olacaktır. Bundan sonraki her basamakta Eşitlik 6.28 veya 6.29'u sağlayan öznitelik F_i seçilir ve seçilen öznitelikler S kümesinde tutulur. Burada S algoritmanın her basamağında seçilen özniteliklerin tutulduğu kümeyi, Ω tüm öznitelik kümesini, Ω_s ise seçilmiş öznitelikler dışında kalan tüm öznitelikleri ifade etmektedir ($\Omega_s = \Omega - S$).

$$MID(\text{Ortak Bilgi Farkı}) = \max_{F_i \in \Omega_s} \left[I(F_i, H) - \frac{1}{|S|} \sum_{F_j \in S} I(F_i, F_j) \right] \quad (6.28)$$

$$MIQ(\text{Ortak Bilgi Oranı}) = \max_{F_i \in \Omega_s} \left\{ I(F_i, H) / \left[\frac{1}{|S|} \sum_{F_j \in S} I(F_i, F_j) \right] \right\} \quad (6.29)$$

İlk özniteliğin seçilmesinin ardından Eşitlik 6.28 ya da 6.29'u sağlayan öznitelik S kümesine dahil edilir ve istenilen öznitelik sayısına ulaşıldığında algoritma sonlanır. Maksimum ilişki ve minimum artıklık koşullarının bu iki basit kombinasyonu mRMR algoritmasının ayırık veriler üstünde kullanılan iki seçim kriterini ortaya çıkarır. Yukarıda geçen algoritmanın O (Big O) notasyonuna göre karmaşıklığı $O(|S|N)$ 'dir.

6.2.2.3. Fisher Puanlama Algoritması

Fisher puanlama, iki sınıf arasındaki ayırt ediciliği ölçen etkili ve basit bir metottür. Bu metotta veri setindeki her bir özelliğin Fisher puanlama değerleri Denklem 6.30'a göre hesaplanır. Daha sonra veri setinden etkili öznitelikleri seçmek için tüm özelliklerin ortalama Fisher puan değerleri hesaplanarak eşik değeri bulunur. Eğer özniteliğin Fisher puan değeri eşik değerinden fazla ise bu öznitelik veri setinin özellik uzayına eklenir [72].

İki sınıf durumunda her bir t özneliği için;

$$F_t = \frac{(\mu_1 - \mu_2)}{\sigma_1^2 + \sigma_2^2} \quad (6.30)$$

değeri hesaplanır. Burada μ_1 , Sınıf 1'e ait t değerlerinin ortalaması; μ_2 , Sınıf 2'ye ait t değerlerinin ortalaması ve σ_1 ve σ_2 'de sırasıyla Sınıf 1 ve Sınıf 2'nin standart sapmalarıdır. Bunun arkasında yatan fikir; bir öznelik, Sınıf 1 ve Sınıf 2 dağılımlarını ne kadar çok ayırabiliyorsa o kadar iyidir [72]. İki sınıftan daha fazla sınıf varsa Fisher ölçüt skoru,

$$F_t = \frac{(\mu_1 - \sum_{i=2}^M \mu_i)^2 + \dots + (\mu_j - \sum_{i=1}^M \mu_i)^2 + \dots + (\mu_M - \sum_{i=1}^{M-1} \mu_i)^2}{\sum_{i=1}^M \sigma_i^2} \quad (6.31)$$

biçiminde kolayca genelleştirilebilir. Burada M sınıf sayısıdır. Fisher ölçüt skoru aracılığıyla tüm öznelikler için bir sıralama hesaplanır. Metodu karakterize eden şey, öznelikler arasındaki tam bağımsızlık varsayımıdır. Her F_t katsayısı tek bir öznelik hakkındaki bilgiyle hesaplanır ve öznelikler arasındaki karşılıklı bilgiyi hesaba katmaz [72].

6.2.2.4. T-testi Algoritması

T-testi iki grubun ortalamasının birbirinden istatistik olarak farklı olup olmadığını görmek için çok yaygın kullanılan bir metottür. T-test formülü aşağıda gösterilen orantıdır. Orantının üst bölümü iki ortalama ya da averaj arasındaki farktır. Alt bölüm ise değişkenlik ölçüsü ya da puanların dağılımıdır.

$$t = \frac{|\mu_0 - \mu_1|}{\sqrt{\left(\frac{1}{n_0} + \frac{1}{n_1}\right) \frac{(n_0 - 1)\sigma_0^2 + (n_1 - 1)\sigma_1^2}{n_0 + n_1 - 2}}} \quad (6.32)$$

Burada μ_i , σ_i^2 ve n_i sırasıyla i . sınıfın ortalama, varyans ve örnek boyutlarını ifade etmektedir.

6.2.2.5. Relief Algoritması

Kira ve Renden tarafından önerilen Relief algoritmasında öznitelikler, hedef fonksiyona uygunluklarına göre seçilir [73]. Relief algoritmasının ana fikri, k-en yakın komşu algoritmasının temel kuralına benzemektedir [72]. Yani verilen bir mesafeye daha yakın uzaklıkların aynı sınıfa ait olmaları, çok daha olasıdır. Eğer bir öznitelik yararlı ise, aynı sınıfın en yakın mesafeleri o öznitelik boyunca verilen aralığa, diğer tüm sınıfların en yakın mesafelerinden daha yakın olması beklenmektedir [72]. Dolayısıyla, verilen i özneliğinin ağırlığı (önem derecesi) Denklem 6.33'de görüldüğü gibi hesaplanacaktır.

$$(W = W - diff(x_{ij}, near_hit_{ij})^2 + diff(x_{ij}, near_miss_{ij})^2)/m \quad (6.33)$$

Burada m örnek boyutu (eğitim setinden rastgele seçilmiş bir alt küme) ve $diff(x_{ij}, near_hit_{ij})$, rastgele seçilmiş j mesafesi içindeki i özneliğinin değeri ile aynı sınıfa sahip en yakın eğitim örneğindeki özneliğinin ($near_hit_{ij}$) değeri arasındaki farklılıktır. Paralel olarak, $diff(x_{ij}, near_miss_{ij})$ farklı bir sınıfa sahip en yakın eğitim örneğindeki i 'nin değeri olarak tanımlanır. Yararlı öznitelikler için, x_{ij} ve $near_hit_{ij}$ değerlerinin çok yakın olması beklenir. Eğer bir öznitelik yararlı değilse, her iki farklılığın da hemen hemen aynı dağılımı almaları beklenir [72].

6.2.3. Sınıflandırma Algoritmaları

Farklı durumlarda kaydedilen EEG işaretlerini elde edilen öznitelik vektörlerine göre sınıflandırma önemli bir konudur. İşaretin hangi sınıfa ait olduğuna karar verme hem hızlı hem de doğru olmalıdır. Literatürde birçok sınıflandırma yöntemleri mevcuttur. Aynı tür uygulamada değişik sınıflandırma algoritmaları farklı sonuçlar verebilmektedir. Elde edilen öznitelik vektörlerine en uygun sınıflandırıcıyı seçebilmek için sınıflandırma yöntemlerinin özelliklerinin iyi bilinmesi gerekmektedir. Bu çalışmada 5 farklı sınıf algoritması kullanılmıştır. Bu algoritmalar sırasıyla: karar ağaçları (decision tree, DT), ileri beslemeli sinir ağları (feed-forward neural network, FFNN), radyal tabanlı yapay sinir ağları (radial basis function neural

network, RNN), destek vektör makineleri (support vector machine, SVM) ve rastgele orman (random forest, RF) algoritmalarıdır.

6.2.3.1. Karar Ağaçları

Karar ağaçları, yapılandırılması ve anlaşılması diğer algoritmalara kıyasla daha kolay olduğundan, sınıflandırma problemlerinin çözümünde sık kullanılan algoritmalarından biridir. Bu yöntemin yaygın olarak kullanımının en önemli nedeni, ağaç yapılarının oluşturulmasında kullanılan kuralların anlaşılabilir ve sade olmasıdır. Karar ağaçları, sınıflandırma işleminin gerçekleştirilmesinde çok aşamalı veya ardışık bir yaklaşım kullanmaktadır. Sınıflandırmanın ilk aşamasında ağaç oluşturulur. İkinci aşamada ise veriler tek tek ağaca uygulanarak sınıflandırma işlemi gerçekleştirilir. Karar ağaçlarına dayalı olarak geliştirilen birçok algoritma vardır. Literatürde en yaygın olarak bilinen algoritmalar ID3, C4.5 ve C5' dir. Bu çalışmada C4.5 algoritması tercih edilmiştir. Entropi değerine bağlı olarak hesaplanan C4.5 algoritması Quinlan [74] tarafından geliştirilmiştir. C4.5 algoritması ID3 algoritmasını esas alarak, ID3 algoritmasındaki bazı eksiklikleri ve sorunları gidermek amacıyla geliştirilmiştir. ID3 algoritması gibi yukarıdan-aşağıya doğru karar ağacı üretir. ID3 algoritması karar ağacının her düğümü için bilgi kazancı değerlerini hesaplar. C4.5 ise bilgi kazancı ile beraber alt sette yer alan karakteristiklerin bilgi kazanç oranlarını da hesaplar. Bilgi kazanç oranı en yüksek olan karakteristiği düğüm noktası olarak seçer. Karar ağacının her dalı sadece bir tek sınıfa karşılık gelinceye kadar işlemler sürer. Daha sonra karar ağacını kural setine dönüştürür.

6.2.3.2. İleri Beslemeli Yapay Sinir Ağları

Yapay sinir ağları (YSA) ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem biriminden oluşan matematiksel sistemlerdir. Bu işlem birimi, diğer nöronlardan sinyalleri alır; bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkartır. Genelde, işlem birimleri kabaca gerçek nöronlara karşılık gelirler ve bir ağ içinde birbirlerine bağlanırlar; bu yapı da sinir ağlarını oluşturmaktadır. Bu çalışmada sinir ağı modellerinden ileri beslemeli sinir ağı kullanılmıştır. İleri beslemeli yapay sinir ağlarında temel olarak 3 farklı katman bulunur. Bu katmanlar

sırasıyla; yapay sinir ağına giren verileri tutan giriş katmanı, işlemlerin yapıldığı ve istenilen sonuca göre kendisini eğiten gizli katman ya da katmanlar ve son olarak çıkış değerlerini gösteren çıkış katmanıdır.

6.2.3.3. Radyal Tabanlı Yapay Sinir Ağları

Biyolojik sinir hücrelerinde görülen etki-tepki davranışlarından esinlenilerek geliştirilmiştir. RNN modellerinin eğitimi, çok boyutlu uzayda eğri uydurma yaklaşımı olarak görülebilir. Bu nedenle RNN modelinin eğitim performansı, çıktı vektör uzayındaki verilere en uygun yüzeyi bulma ve dolayısıyla bir interpolasyon problemine dönüşmektedir. RNN modelleri genel YSA mimarisine benzer şekilde giriş katmanı, gizli katman ve çıktı katmanı olmak üzere 3 katman halinde tanımlanmaktadır. Ancak, klasik YSA yapılarından farklı olarak RNN' larda, girdi katmanından gizli katmanına geçişte radyal tabanlı aktivasyon fonksiyonları ve doğrusal olmayan bir kümeleme analizi kullanılmaktadır. RNN modellerinde aktivasyon fonksiyonu olarak birçok fonksiyon tipi (Doğrusal, Kübik, Gauss, Multi-Kuadratik, Ters Multi-Kuadratik) kullanılabilir.

6.2.3.4. Destek Vektör Makineleri

İstatistiksel öğrenme teorisine dayalı bir makine öğrenmesi yöntemidir. Destek vektör makineleri temelde sınıflanması zor olan (doğrusal ya da doğrusal olmayan) veri setlerini, kullandığı çekirdek fonksiyonlar yardımıyla kolaylıkla sınıflayabilen bir sınıflama ve regresyon yöntemidir [75]. Yöntemin güçlü bir kuramsal temelinin olması, büyük veri setleri üzerinde çalışabilmesi, kullanılan çekirdek fonksiyonlar ile esnek bir algoritmasının olması ve sonuçlarındaki yüksek doğruluk oranı nedeniyle son yıllarda yaygın olarak kullanılmaya başlanmıştır. Yöntem, doğrusal olarak sınıflanabilen verileri birbirinden ayırt edebilmek için olası pek çok doğrusal fonksiyon içerisinden marjini en büyük olanı belirler. Doğrusal olarak sınıflanamayan verileri de çekirdek fonksiyonları kullanarak daha yüksek boyutlu uzaya aktarır ve marjini en büyük olan çoklu düzlemleri bulur. Kernel fonksiyonu olarak polinom, radyal tabanlı fonksiyon, Pearson VII (PUK) fonksiyonu ve normalleştirilmiş polinom kernelleri kullanılmaktadır.

6.2.3.5. Rastgele Orman Algoritması

Sınıflandırma işlemi sırasında birden fazla karar ağacı kullanılarak sınıflandırma değerinin yükseltilmesi hedeflenir. Breiman tek bir karar ağacı üretmek yerine, her biri farklı eğitim kümeleriyle eğitilen çok sayıda, çok değişkenli ağacın kararlarının birleştirilmesini önermiştir [76]. Farklı eğitim kümeleri önyükleme (ing. bootstrap) ve rasgele özellik seçimi ile orijinal eğitim setinden oluşturulur. Önce her karar ağacı kendi kararını verir ve karar ormanı içerisinde maksimum oyu olan sınıf, son karar olarak kabul edilir ve gelen test verisi o sınıfa dahil edilir.

6.3. YÖNTEM 2: KARMAŞIK SAYI TABANLI ALGORİTMALAR

Bu aşamada EEG verilerinin sınıflandırılmasında karmaşık değerlikli öznitelik çıkarma ve sınıflandırma tabanlı yeni bir yaklaşım sunulmuştur. Önerilen yöntemin özet niteliğinde özellikleri aşağıda sıralanmaktadır.

1. Bu aşamada karmaşık değerli sınıflayıcıların EEG sinyallerini sınıflandırmadaki başarısı incelenmiştir. Özellik çıkartımı için farklı seviyelerde ikili ağaç karmaşık dalgacık dönüşümü (IAKDD) uygulanmış ve elde edilen kompleks değerlikli özellik vektöründen istatistiki özellikler çıkartılmıştır. Her bir EEG verisi için aynı sayıdaki özellik kompleks değerli sinir ağına (KDYSA) giriş olarak sunulmuştur.
2. Karmaşık değerli sinir ağlarının kalitesi, ağ parametrelerinin uygun ayarlanmasına bağlıdır. Problemlerinde KDYSA uygulamak isteyenler için en önemli sorun belirli bir veri seti için parametre değerlerinin nasıl ayarlanacağıdır (iyi bir genelleme performansı sağlamak için). Uzman olmayan kullanıcılar optimum KDYSA yapısı bulmada zorluk çekmekte ve KDYSA meta parametrelerinin nasıl seçileceği konusunda karmaşa yaşamaktadırlar. KDYSA regresyonu konusuyla ilgili mevcut kaynaklar KDYSA parametrelerinin uygun ayarları hakkında bazı önerilerde bulunmakla birlikte, bu kaynaklarda net bir fikir birliği olmayıp birbiriyle çelişen pek çok fikir yer almaktadır. Uzman olmayan bir kullanıcının kendi vakası için en iyi (en

sağlam, doğru ve hızlı) algoritmayı seçmesi zordur. Bu çalışmada bu konu ele alınmakta olup, KDYSA için optimum ağ yapısını bulmada ve ağ parametrelerini ayarlama Taguchi yöntemi tabanlı bir yöntem geliştirilerek uzman olmayan kullanıcıları rahatlatma amaçlanmıştır.


3. Bildiğimiz kadarıyla EEG verilerinin sınıflandırılmasında daha önce karmaşık değerli sınıflayıcılar kullanılmamıştır. Önerilen metot bu yönüyle de önem taşımaktadır.

6.3.1. Karmaşık Dalgacık Dönüşümü

ADD etkili bir algoritma olup; geniş bir uygulama alanına sahiptir. Sinyal ve görüntü işleme, öznitelik elde etme ve gürültü etkisi azaltma gibi birçok alanda yaygın olarak kullanılmaktadır [77]. Bununla beraber ADD'nin bazı önemli eksiklikleri bulunmaktadır. En önemli dezavantaj olarak faz bilgisinin eksikliği belirtilmektedir. ADD algoritmasındaki dezavantajlar yeni algoritma arayışlarına neden olmuştur. Karmaşık dalgacık dönüşümleri bu eksikleri gidermek için geliştirilmiştir. Bu çalışmada karmaşık dalgacık dönüşüm yöntemlerinden ikili ağaç karmaşık dalgacık dönüşüm (IAKDD) yöntemi kullanılmıştır. İkili ağaç karmaşık dalgacık dönüşümü, reel veya kompleks sinyalleri dönüşüm kümesinde gerçek (ing. reel) ve sanal (ing. imajiner) şekilde bölümlere ayırıştırarak kompleks değerli filtreler (analitik filtreler) kullanır. Gerçek ve sanal katsayılar genlik ve faz bilgisini elde etmek amacı ile kullanılmaktadır. Standart ADD ile Karmaşık değerlikli ADD kıyaslanırken dikkate alınması gereken önemli özellikler değişim duyarlılığı, yönlülük ve faz bilgisidir.

Değişime Duyarlılık: Giriş sinyalleri zamanda bir değişime (kayma, sapma) maruz kaldığında dönüşüm katsayılarında beklenmeyen değişiklik gerçekleşiyorsa bu durum değişime duyarlılık olarak ifade edilir [77, 78]. Bu durum istenmeyen bir özelliktir. Dış etkenlerden sinyalin mümkün olduğunca az etkilenmesi önemlidir. ADD dönüşümü bu konuda yetersizdir. Çünkü ADD katsayıları giriş sinyallerindeki değişimi algılamada yetersiz kalmaktadır. Şekil 6.5-b'de bu durum grafiksel olarak gözlenebilmektedir. Şekil 6.5-b'de adım sinyalinin 3 kez kaydırılmış hali ile ADD'nin değişim yapısı incelenmiştir. Şekilde farklı seviyelerdeki detay ve

yaklaşım katsayılarında beklenmeyen değişiklikler gözlenmektedir. IAKDD'ler ise değişime karşı yaklaşık olarak duyarsızdır. Şekil 6.5-a'da bu durumu kanıtlar nitelikte bir şekil sunulmaktadır.




Şekil 6.5. Değişime karşı duyarsızlık, a) Bir boyutlu IAKDD' nin değişime duyarsızlık özelliği, b) Bir boyutlu standart ADD'nin değişime duyarlılığı [79].

Yönlülük: IAKDD yön bilgisi açısından standart ADD'den daha iyi bir seçiciliğe sahiptir. Yön bilgisi alçak geçiren ve yüksek geçiren filtrelerinin mümkün olan kombinasyonunu ifade eder. Şekil 6.6 üzerinden yön bilgisinin ne anlama geldiği açıklanabilir. Yön $\{0, 1, 2, 3\} = \{LH, HH, HL, LL\}$ olarak ifade edilir. Örnek vermek gerekirse; Şekil 6.6'da LH terimi yatay yönde alçak geçiren, dikey yönde de yüksek geçiren filtrelerin uygulandığını ifade etmektedir. l çözünürlük seviyesini, $\theta \in \{0,1,2,3\}$ ise yönü belirtmek üzere I_l^θ altbandı gösterir [80].

I_3^0	I_3^1	I_2^0	I_1^0	I_0^0
I_2^2	I_2^1			
I_1^2		I_1^1	I_0^1	
I_0^2				


Şekil 6.6. Bir görüntünün dört seviyeli ayrık dalgacık dönüşümünün seviyeleri [81].

Ayrık dalgacık dönüşümünde her frekans çözünürlüğünde alçak frekans bileşenleri hariç üç altbant varken, Şekil 6.7’de görüldüğü gibi IAKDD’de her frekans çözünürlüğünde alçak frekans bileşenleri hariç ± 15 , ± 45 ve ± 75 ’den oluşan altı altbant vardır. Bu da yönsel seçicilikte IAKDD’lerin üstünlüğünü ortaya koymaktadır.

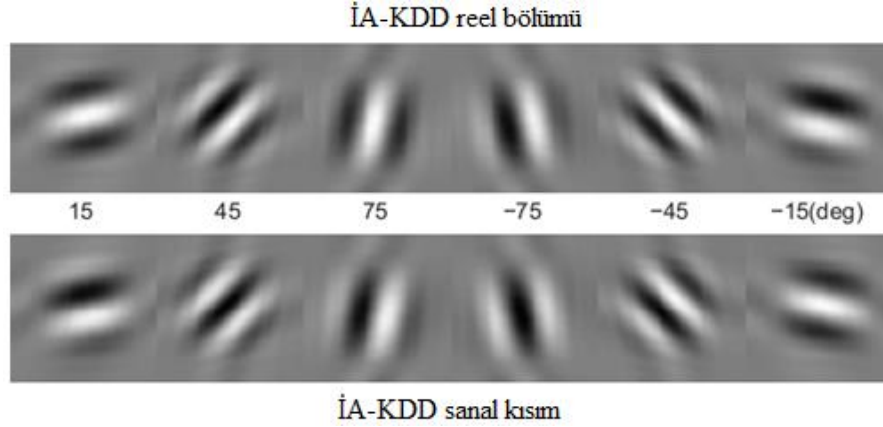


Şekil 6.7. Karmaşık dalgacık dönüşümü katsayılarının görüntüleri. Karşılık gelen filtrelerin yönleri de alt bantların köşesinde belirtilmiştir. LP alçak geçiren IAKDD katsayılarını belirtmektedir [82].

Örnek bir görüntü üzerindeki uygulama Şekil 6.8 ve Şekil 6.9’da sunulmaktadır.



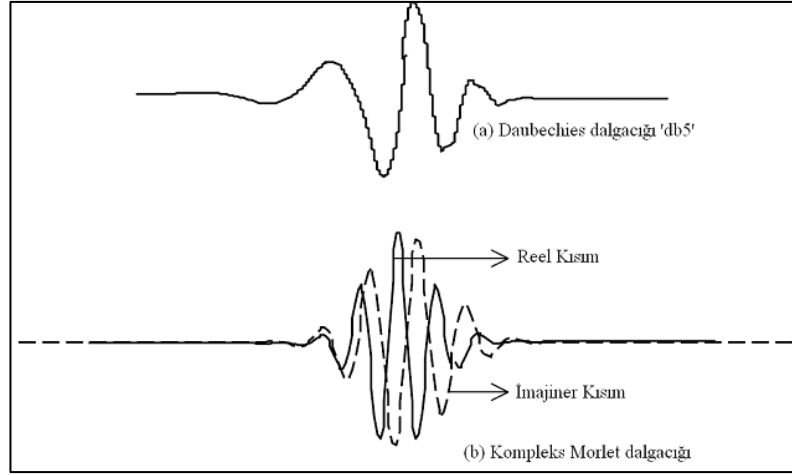
Şekil 6.8. İki boyutlu standart ADD'nin yönlülük özelliği [78].



Şekil 6.9. İki boyutlu İAKDD'nün yönlülük özelliği [78].

Faz Bilgisi eksikliği: Standart ADD'nin önemli eksikliklerinden birisi de faz bilgisindeki eksikliklerdir. Standart ADD'ler yerel faz bilgisinden yoksundur. Bütün doğal sinyaller temel olarak reel değerlidir. Bu yüzden lokal faz bilgisinden faydalanmak için kompleks değerli filtreleme gerekmektedir [77]. Reel ve analitik dalgacıklar arasındaki fark Şekil 6.10'da gösterilmiştir. Analitik dalgacık yapısındaki reel ve sanal kısımlar sayesinde faz bilgisini elde etmek mümkün olmaktadır.

İAKDD, standart ADD'ye göre iki kat daha karmaşık bir yapıya sahiptir ve paralel olarak işleyen iki ADD'den oluşmaktadır. Bu durum Şekil 6.11'de görülmektedir. Ağaçlardan birisi reel ağaç olarak, diğeri ise imajiner ağaç olarak adlandırılmaktadır. İAKDD algoritmasında dalgacık fonksiyonu $\psi(t)$ ve ölçeklendirme fonksiyonu $\varphi(t)$ için bir çift filtre kullanılır. Bu filtreler şunlardır; reel ağaç için sırasıyla alçak geçişli-yüksek geçişli filtre çifti $(h_0(n), h_1(n))$ ve imajiner ağaç için sırasıyla alçak geçişli-yüksek geçişli filtre çifti $(g_0(n), g_1(n))$. Dalgacık fonksiyonu ve ölçeklendirme fonksiyonları Denklem 6.34 ve 6.35 kullanılarak hesaplanmaktadır.



Şekil 6.10. Reel a) ve analitik b) dalgacıđının gösterimi [77].

$$\psi_h(t) = \sqrt{2} \sum_n h_1(n) \varphi_h(2t - n) \quad (6.34)$$

$$\varphi_h(t) = \sqrt{2} \sum_n h_0(n) \varphi_h(2t - n) \quad (6.35)$$

Karmaşık dalgacık fonksiyonu, gerçel ve sanal bileşenlerle beraber, $\psi(t) := \psi_h(t) + j\psi_g(t)$ şeklinde ifade edilebilir. Burada $\psi_h(t)$ ve $\psi_g(t)$ reel değerlikli dalgacıklardır. $\psi_h(t)$ Denklem 6.34'de görüldüğü gibi hesaplanmaktadır. $\psi_g(t)$ ise Denklem 6.36'da görüldüğü gibi $\psi_h(t)$ ' nin yaklaşık olarak Hilbert dönüşümünü verecek şekilde tasarlanmıştır.

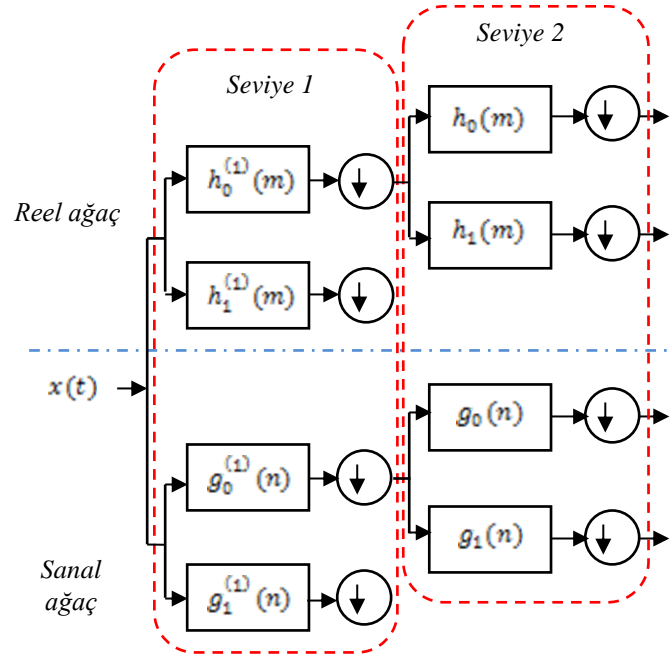
$$\psi_g(t) = H\{\psi_h(t)\} \quad (6.36)$$

6.3.2. Karmaşık Değerlikli Sinir Ağları

Kompleks-değerlikli yapay sinir ağları ağırlık, eşik değeri, giriş ve çıkış gibi parametreleri kompleks sayılardan oluşan bir yapay sinir ağı türüdür. Karmaşık değerlikli sinir ağının yapısı Şekil 6.12 ve 6.13'de görülmektedir.

6.3.2.1. Matematiksel Model

Karmaşık değerli sinir ağlarının matematiksel modeli hakkında kısa bir bilgi aşağıda sunulmaktadır [77, 83]. Nöronun Y_n aktif değeri şu şekilde tanımlanabilir;



Şekil 6.11. İkili ağaç karmaşık dalgacık dönüşümü.

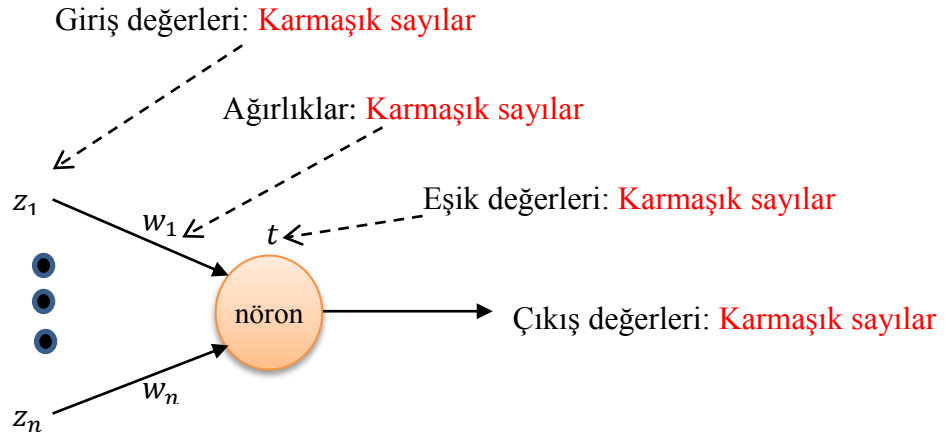
$$Y_n = \sum_m W_{nm} X_m + V_n \quad (6.37)$$

Denklem 6.37’de, W_{nm} , n nöronu ile m nöronu arasındaki karmaşık değerli bağlantı ağırlığıdır. X_m , m nöronunun karmaşık değerli giriş sinyali ve V_n ise n nöronunun karmaşık değerli eşik değeridir. Kompleks değerli çıkış sinyalini elde edebilmek için Y_n aktif değeri, reel ve imajiner kısım olarak aşağıda gösterildiği gibi iki bileşene dönüştürülür;


$$Y_n = x + iy = z \quad (6.38)$$

Burada i , -1 değerini ifade etmektedir. Her bir nöronun çeşitli çıkış fonksiyonları göz önünde bulundurulduğunda, çıkış fonksiyonu aşağıdaki eşitlik kullanılarak tanımlanabilir;

$$f_c(z) = f_R(x) + i \cdot f_R(y) \quad (6.39)$$



Şekil 6.12. Giriş, ağırlık, eşik, ve çıkış değerleri kompleks sayılardan oluşan karmaşık değerlikli sinir ağı.



Şekil 6.13. Karmaşık değerlikli sinir ağı.

Burada $f_R(u)$, aktivasyon fonksiyonudur. Bu çalışmada kullanılan KDYSA üç katmana (giriş, gizli ve çıkış katmanı) sahiptir. Burada W_{ml} , giriş katman nöronu l ve gizli katman nöronu m arasındaki ağırlık, V_{nm} , gizli katman nöronu m ve çıkış katmanı nöronu n arasındaki ağırlık, θ_m gizli katman nöronu m için eşik değeri ve γ_n çıkış katmanı nöronu n için eşik değerini ifade etmektedir. I_l , H_m , O_n sırasıyla giriş katmanı nöronu l , gizli katman nöronu m ve çıkış katmanı nöronu n için çıkış değerini ifade etmektedir. Benzer şekilde U_m ve S_n , sırasıyla, gizli katman nöronu m ve çıkış katmanı nöronu n 'nin aktif değeridir.

$$U_m = \sum_l W_{ml} I_l + \theta_m \quad (6.40) \quad S_n = \sum_m V_{nm} H_m + \gamma_n \quad (6.42)$$

$$H_m = f_c(U_m) \quad (6.41) \quad O_n = f_c(S_n) \quad (6.43)$$

olarak ifade edilmektedir. $\delta^n = T_n - O_n$, n çıkış katmanını nöronunda elde edilen çıkış O_n ve hedef çıkış T_n arasındaki hata ifadesidir. p örüntüsü için karesel hata,

$$E_p = (1/2) \sum_{n=1}^N |T_n - O_n|^2 = (1/2) \sum_{n=1}^N |\delta^n|^2 \quad (6.44)$$

olarak ifade edilmektedir. Burada N çıkış katmanındaki nöronların sayısıdır. Şimdi, kompleks değerlikli geriye yayılım modeli için öğrenme kuralı tanımlanacaktır. Ağırlıkların ve eşik değerlerinin düzenlenmesi aşağıdaki eşitliklere göre yapılmaktadır.

$$\Delta V_{nm} = -\varepsilon \cdot \frac{\partial E_p}{\partial \text{Re}[V_{nm}]} - i \cdot \varepsilon \frac{\partial E_p}{\partial \text{Im}[V_{nm}]} \quad (6.45)$$

$$\Delta \gamma_n = -\varepsilon \cdot \frac{\partial E_p}{\partial \text{Re}[\gamma_n]} - i \cdot \varepsilon \frac{\partial E_p}{\partial \text{Im}[\gamma_n]} \quad (6.46)$$

$$\Delta W_{ml} = -\varepsilon \cdot \frac{\partial E_p}{\partial \text{Re}[W_{ml}]} - i \cdot \varepsilon \frac{\partial E_p}{\partial \text{Im}[W_{ml}]} \quad (6.47)$$

$$\Delta \theta_m = -\varepsilon \cdot \frac{\partial E_p}{\partial \text{Re}[\theta_m]} - i \cdot \varepsilon \frac{\partial E_p}{\partial \text{Im}[\theta_m]} \quad (6.48)$$

Eşitlik (6.45)' den (6.48)' e kadar verilen ifadeler aşağıdaki şekilde yeniden yazılabilir:

$$\Delta V_{nm} = \overline{H_m} \Delta \lambda_n \quad (6.49)$$

$$\Delta \lambda_n = \eta (\text{Re}[\delta^n] (1 - \text{Re}[O_n]) \text{Re}[O_n] + i \cdot \text{Im}[\delta^n] (1 - \text{Im}[O_n]) \text{Im}[O_n]) \quad (6.50)$$

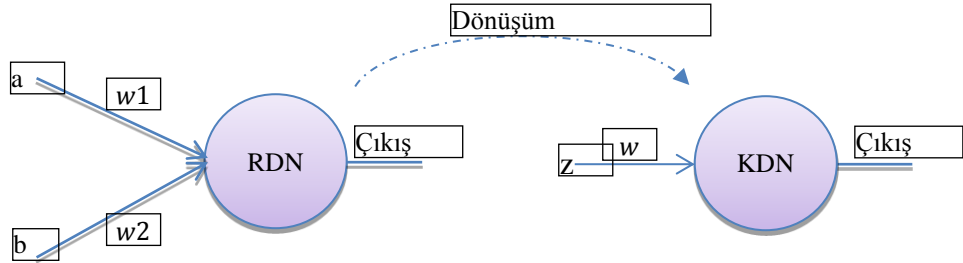
$$\Delta W_{ml} = \overline{I_l} \Delta \theta_m \quad (6.51)$$

$$\Delta\theta_m = \eta \left[x \sum_n \begin{pmatrix} (1 - \text{Re}[H_m])\text{Re}[H_m] \\ \text{Re}[\delta^n](1 - \text{Re}[O_n]) \\ \text{Re}[O_n]\text{Re}[V_{nm}] \\ + \text{Im}[\delta^n](1 - \text{Im}[O_n]) \\ \text{Im}[O_n]\text{Im}[V_{nm}] \end{pmatrix} \right]$$

$$-i\eta \left[x \sum_n \begin{pmatrix} (1 - \text{Im}[H_m])\text{Im}[H_m] \\ \text{Re}[\delta^n](1 - \text{Re}[O_n]) \\ \text{Re}[O_n]\text{Im}[V_{nm}] \\ - \text{Im}[\delta^n](1 - \text{Im}[O_n]) \\ \text{Im}[O_n]\text{Re}[V_{nm}] \end{pmatrix} \right]$$
(6.52)

6.3.2.2. Karmaşık Değerlikli Sınıflandırıcıların Avantajları

Karmaşık değerli girdi/çıkı, ağırlık ve aktivasyon fonksiyonlarının kullanımı tek bir nöronun ve sinir ağının fonksiyonelliğini artırmayı, performanslarını artırmayı ve eğitim süresini azaltmayı mümkün kılmaktadır [84]. Şekil 6.14'de görüldüğü gibi ağırlık küçülmesi eğitim süresini azaltacaktır.



Şekil 6.14. Reel değerlikli 2 giriş ve 2 ağırlık değerine sahip sinir ağının, karmaşık düzlemde tek bir giriş ve tek bir ağırlık değeri ile temsili (RDN: Reel değerlikli nöron, KDN: Karmaşık değerlikli nöron). Burada; $z = a + ib$ ve $w = w1 + iw2$.

Nitta çalışmasında ortogonal karar sınırları ile karmaşık değerlikli sinir ağını kullanarak XOR problemini 2 katmanda çözmüştür [85]. Bu çalışma karmaşık sınıflayıcının yüksek fonksiyonelliğini ispatlamaktadır. Klasik sinir ağı tercih edildiğinde, gerçek düzlemde lineer ayrılmayan XOR probleminin çözümü için daha fazla katmana olan ihtiyaç görülmektedir. Nittanın çalışması tek karmaşık değerli nöronun karar sınırı çaprazlama kesişen iki hiper yüzeyden meydana gelip karar bölgesini 4 eşit bölüme ayırmaktadır [85].

Kompleks değerli sayılar içeren problemlerin çözümünde, bilinen reel değerli yapay sinir ağları kullanıldığında, reel ve imajiner kısımlar için YSA'nın ayrı ayrı uygulanması gerekmektedir. Buna karşılık aynı problem için KDYSA uygulandığında veriler üzerinde doğrudan işlem yapabilme kabiliyeti ile işlem zamanının azaldığı ve doğruluk oranının artırıldığı görülmüştür.

Sinyal işlemenin temelinde karmaşık sayılarının önemli bir yer edindiği bilinmektedir. Bunu Fourier dönüşüm metodundan anlayabiliriz. Fourier dönüşümü çıktı olarak karmaşık değerler üretecektir. Bu dönüşümün çıktılarını gerçek değerlikli bir sınıflayıcı sınıflandırmak istesek, her bir kompleks sayının gerçek ve sanal değerlerini girişe ayrı ayrı sunmamız gerekecektir. Bu da verimin düşmesi ve ekstra yük demektir. Karmaşık değerlikli sınıflandırıcının kullanımı ile 2 boyutlu bilgi, tek boyutta ağa sunulmuş olacaktır.

6.3.3. Parametrelerin En İyi Değerlerini Bulma

Karmaşık değerlikli sinir ağlarının klasik sinir ağlarından farklı olarak karmaşık düzlemde uygulanıyor olması nedeniyle parametre kestirimi konusunda önemli problemler bulunmaktadır. Bu yöntemin uygulandığı çalışmalar incelendiğinde parametre değerlerinin genellikle deneme yanılma yöntemi ile tespit edildiği görülmektedir. Fakat bu yöntem sadece zaman israfına sebep olmakla kalmayacak aynı zamanda da olası en iyi performansı karşılamada sıkıntı oluşturabilecektir. Bu tez çalışmasında bu probleme yönelik bir çözüm hedeflenmektedir. Etkili ve hızlı bir parametre optimizasyonu ile bu problemin çözülebileceği öngörülmektedir.

6.3.3.1. Parametreler

Öğrenme Katsayısı (L) ve Momentum Katsayısı (M): Öğrenme ve momentum katsayılarının uygun biçimde belirlenmesi ağın performansı açısından önemli bir faktördür. Öğrenme katsayısı ağırlıkların değişme miktarını belirlemektedir. Eğer büyük değerler seçilirse yerel çözümler arasında ağın dolaşması ve osilasyon yapması söz konusu olmaktadır [86]. Öğrenme katsayısının düşük seçilmesi ise öğrenme hızının yavaşlamasına neden olmaktadır. Momentum katsayısı da

öğrenmenin performansını etkileyen önemli bir faktördür. Momentum katsayısı, bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesi olarak görülmektedir [86]. Bu, özellikle yerel çözümlerden birine takılan ağların bir sıçrama ile daha iyi sonuçlar bulmasını sağlamak amacı ile kullanılmaktadır. Bu değer küçük olması yerel çözümlerden kurtulmayı zorlaştırabilir. Çok büyük değerler ise tek bir çözüme ulaşmada sorunlar oluşturabilir. Bu nedenle momentum katsayısının belirlenmesi kendi başına önemli bir sorundur.

İterasyon değeri (S): Problemden iyi sonuç veren iterasyon değerinin tespiti genellikle deneme-yanılma metodu ile bulunmaktadır. Etkili iterasyon değerini hızlı bir şekilde tespit etmek çözüm bekleyen önemli bir konudur.

Aktivasyon fonksiyonu (HAF): Geriye yayılım algoritmasının kompleks düzlemde uygulanmasında karşılaşılan güçlüklerden biri, uygun aktivasyon fonksiyonunun seçilmesidir. Literatürde hangi aktivasyon fonksiyonunun kullanılması gerektiği ile ilgili ortak bir görüş mevcut değildir. Kullanılacak aktivasyon fonksiyonu girdi eğitim verisinin türüne ve incelenen duruma göre değişmektedir. Bu çalışmada problemimiz için etkili aktivasyon fonksiyonunun tespiti araştırılacaktır. Etkisi araştırılan aktivasyon fonksiyonları hakkında kısa bilgiler aşağıda sunulmaktadır.

Sigmoid fonksiyonu Leung ve Haykin tarafından KDYSA'lar için kullanılmıştır [87]. Bu çalışmada bu fonksiyon için karmaşık logsig ifadesi kullanılacaktır.

$$f(z) = 1/(1 + e^{-z}) \quad (6.53)$$

Ama bu fonksiyon her bir z 'de $z = (2n + 1)i\pi$, $n \in Z$ tekil noktalara sahiptir. Yazarlar bu sorunu çözmek için girdi verilerini karmaşık düzlemin belli bir bölümüne ölçeklemişlerdir. Daha sonra sigmoid fonksiyonu Birx ve Pipenberg [88]; Benvenuto ve Piazza [89] tarafından KDYSA'lara şu şekilde uyarlanmıştır:

$$f(z) = 1/(1 + e^{-\text{Re}z}) + i/(1 + e^{-\text{Im}z}) \quad (6.54)$$

Bu çalışmada complex logsig aktivasyon fonksiyonu için Denklem 6.54'deki ifade kullanılmıştır. Ayrıca her bir z 'de ($z = (n + 1/2)i\pi$, $n \in Z$) tekil noktalara sahip olan

tanh fonksiyonu da gerçek-imgesel tür aktivasyon fonksiyonu olarak KDYSA'lara uyarlanmıştır.

$$f(z) = \tanh(\text{Rez}) + i \tanh(\text{Im}z) \quad (6.55)$$

sech(.) kullanan gizli nöronun fonksiyonel birimi denklem 6.56'da gösterilen formdur.

$$\text{sech}(z) = 2/(e^z + e^{-z}) \quad (6.56)$$

Sech fonksiyonu bu çalışmada KDYSA'lara aşağıdaki gibi uygulanmıştır.

$$f(z) = \text{sech}(\text{Rez}) + i \text{sech}(\text{Im}z) \quad (6.57)$$

Bildiğimiz kadarıyla geri beslemeli karmaşık sinir ağlarında daha önce aktivasyon fonksiyonu olarak sech fonksiyonunun kullanıldığı bir çalışmaya rastlanılmamıştır.

Bu çalışmada ayrıca karmaşık değerlikli dalgacık sinir ağlarında kullanılan Meksika şapkası ve haar aktivasyon fonksiyonlarının da sonuçlara etkileri araştırılmıştır. Haar dalgacık ve Meksika şapkası dalgacık fonksiyonları aşağıdaki gibi tanımlanmaktadır.

$$\Psi_{\text{Haar}} = (1 - x)e^{-(x/2)} \quad (6.58)$$

$$\Psi_{\text{Mexhat}} = (1 - ax^2)e^{-bx^2} \quad (6.59)$$

Bu çalışmada bu fonksiyonlar karmaşık düzlemde aşağıdaki gibi uygulandı.

$$f(z) = \Psi_{\text{Haar}} = (1 - \text{Rez})e^{-(\text{Rez}/2)} + i(1 - \text{Im}z)e^{-(\text{Im}z/2)} \quad (6.60)$$

$$f(z) = \Psi_{\text{Mexhat}} = (1 - a\text{Rez}^2)e^{-b\text{Rez}^2} + i(1 - a\text{Rez}^2)e^{-b\text{Rez}^2} \quad (6.61)$$

Gizli katman nöron sayısı (HN): Gizli katmanda yer alan nöron sayısının KDYSA performansı üzerinde önemli bir etkisi vardır. Çok az sayıda nöron, veride yer alan ilişkileri anlamada yetersiz kalacaktır. Çok sayıda nöron ise ağ karmaşıklığını ve işlem bitirme süresini artıracaktır. Literatürde gizli katmanda yer alan nöron sayısı

için optimal rakamın genelde deneme yanılma yoluyla elde edildiği görülmektedir. Fakat bu yöntem sadece aşırı zaman israfına sebep olmakla kalmayacak aynı zamanda da olası en iyi performansı karşılamada sıkıntı oluşturabilecektir.

6.3.3.2. Taguchi Metodu

Taguchi yöntemi, optimizasyon ve parametrik analiz çalışmalarında maliyeti düşürmek, sonuçlara daha az sayıda deney yaparak kısa sürede ulaşmak ve parametrelerin hedef sonuç üzerindeki etkilerini belirlemek için tam faktoriyel deney tasarımına alternatif olarak geliştirilmiş güçlü bir yöntemdir [90].

Ortogonal dizinler faktöriyel tasarımdan farklı olarak faktör seviyelerini teker teker değiştirmek yerine eş zamanlı olarak değiştirme yaparak deney sayısını azaltır. Taguchi yönteminin klasik deney tasarımlarından farkı varyansı azaltmasıdır. Amaç, bir yandan hedef kontrol faktörlerinde yapılan ayarlamalar yoluyla gerekli ortalama performans sürdürülürken, diğer yandan varyans kontrol faktörlerinde değişikliğe giderek varyansın azaltılmasıdır.

Diğer önemli bir nokta ise deney tasarımının dengeli olmasıdır, yani faktörlerin birbirinden bağımsız olarak değerlendirebilmesini sağlaması ve bunun için de tasarımda faktörlerin farklı seviyeleri için her test edilen şart altında eşit sayıda örnekleme yapılmasıdır. Taguchi'nin standart tasarımları bu sistem üzerine kurulmuştur. Şekil 8.11'de Taguchi yönteminin aşamaları görülmektedir.

6.4. YÖNTEM 3: CUDA PARALEL İŞLEM MİMARİSİ İLE HIZ OPTİMİZASYONU

Bu aşamada CUDA mantığına uygun sınıflandırma algoritmalarının tespiti yapıp veri setleri üzerinde hız performansına dayalı uygulamalar gerçekleştirildi. CUDA; C, C++ ve Fortran gibi programlama dillerinde yazılan kodların grafik işlemci birimi (Graphics Processing Unit, GPU) üzerinde paralel olarak işlenmesini sağlayan bir GPU mimarisi, yazılımı ve programlama platformudur [91]. C ve C++ diline yapılacak bazı eklemeler sayesinde CUDA programlama gerçekleştirilmektedir.

CUDA'nın önemli avantajlarından biri olarak görülen bu durum, programcının problemleri grafik konseptine dönüştürme zorunluluğunu ortadan kaldırmaktadır. CUDA programlamanın ortaya çıkmasına kadar olan süreçte paralel programlama CPU üzerinden gerçekleştiriliyordu. Fakat CPU'lar aslen seri işlemcilerdir. Bu nedenle birden fazla CPU'nun bir arada kullanılması için kompleks yazılımlar gerekmektedir. CUDA ile beraber paralel işlemler daha kolay geliştirilir oldu. Bunun en önemli sebeplerinden birisi ise CUDA'nın manuel olarak paralellik sağlamasıdır. CUDA'da yazılan program parçasına çekirdek (ing. kernel) denilmektedir. GPU bu çekirdeğin binlerce kopyasını çalıştırır ve onu paralel hale getirir. CUDA'nın C dilinin bir uzantısı olması nedeniyle CPU üzerinden yazılan bir programın CUDA'ya dönüşümü kolay olmaktadır.

6.4.1. CUDA Programlama Adımları

CUDA programlama adımları kısaca; çekirdek fonksiyonunun tanımlanması, GPU'nun bu çekirdek fonksiyonuna göre iş parçacıklarını belirleyip çalıştırması, iş parçacıklarının çözgü (ing. warp) adı verilen 32'lik gruplar halinde paketlenmesi ve bu çözgülerin SM adı verilen yüksek çoklu-iplik (ing. multi-thread) özellikli işlemciler tarafından yürütülmesi şeklindedir [92].

6.4.2. CUDA Mimarisi ve Programlama

Bu çalışmada tercih edilen mimariler GF108 ve GF106 mimarileridir. GF108 mimarisine sahip Nvidia GeForce GT 525M ekran kartı ve GF106 mimarisine sahip Nvidia Quadro 2000 ekran kartı bu çalışmada kullanılmıştır. Bu bölümde GF106 mimarisi üzerinden CUDA platformu açıklanmaya çalışılmıştır. Quadro 2000, Fermi işlemciler grubundandır. GF106 mimarisinde 1.17 milyar transistör ve 192 CUDA çekirdeği bulunmaktadır. GF106 mimarisine ait detaylara Şekil 6.15'den bakılabilir.



Şekil 6.15. GF106 mimarisine ait detaylar.

Çizelge 6.4’de bu çalışmada kullanılan mimarilerin karşılaştırması görülmektedir.

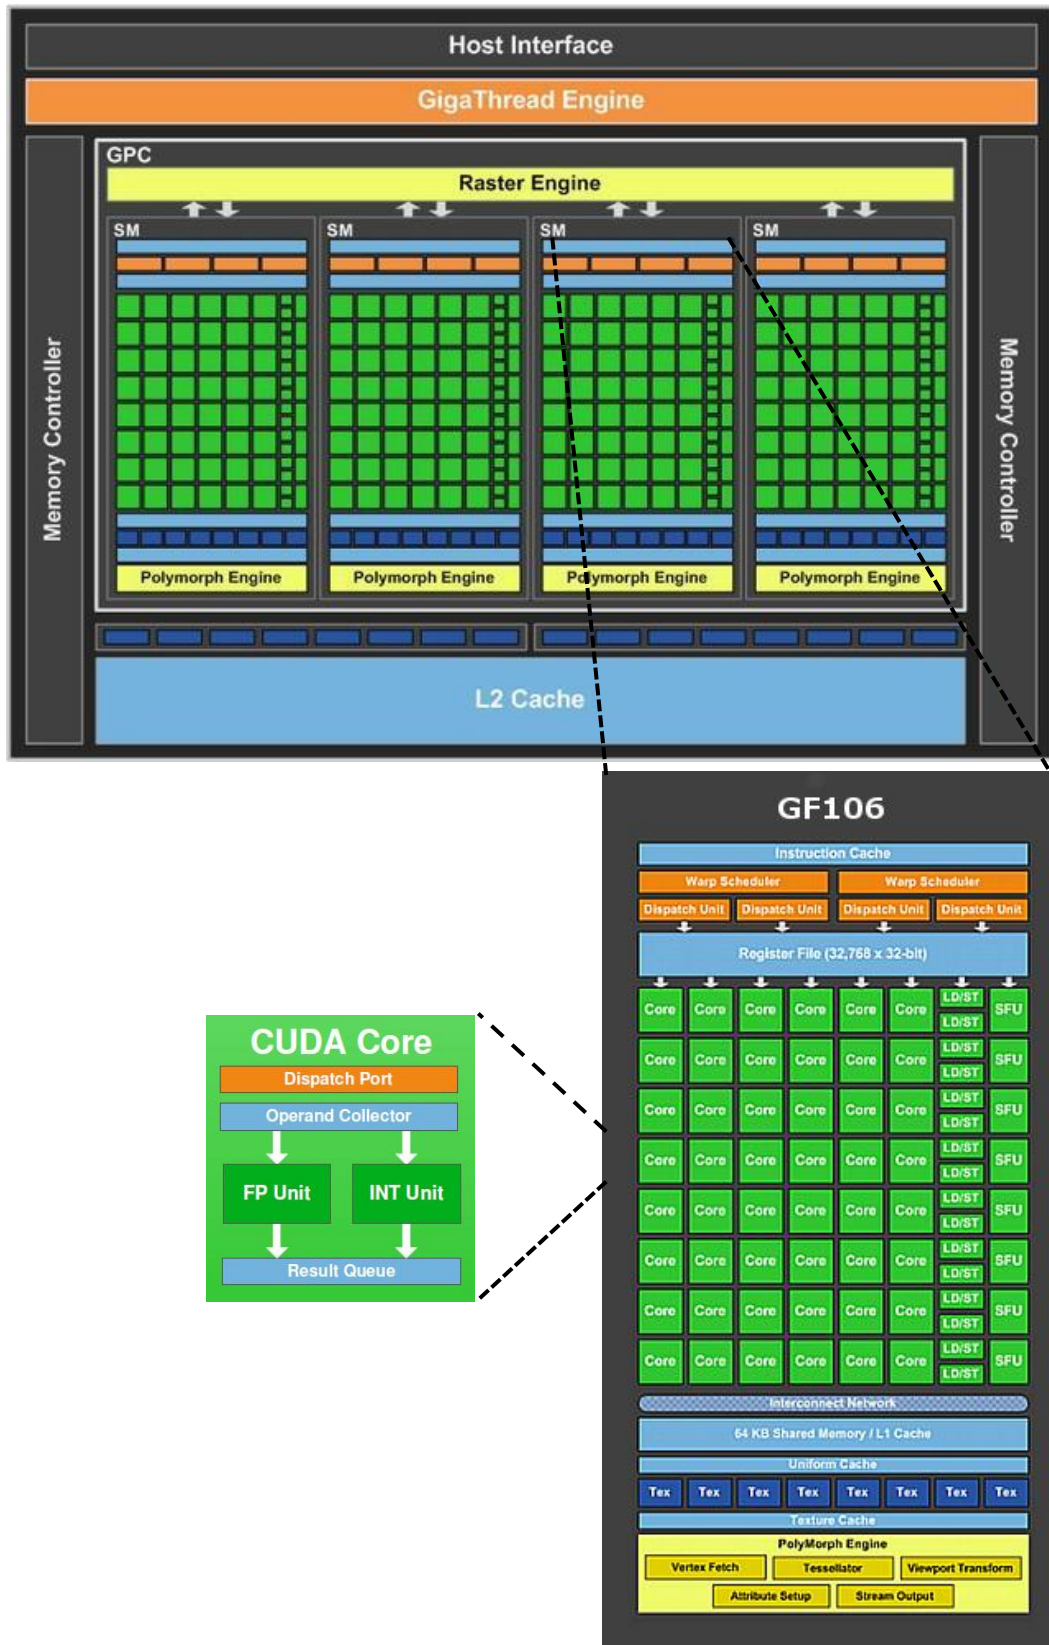
Çizelge 6.4. Bu çalışmada kullanılan ekran kartlarının özellikleri.

Mimari	GF108 (Nvidia GeForce GT 525M)	GF106 (Nvidia Quadro 2000)
Transistör sayısı	585 Milyon	1.17 Milyar
CUDA çekirdeği	96	192


Yukarıda da bahsedildiği gibi NVIDIA Quadro 2000 ekran kartında 192 CUDA çekirdeği bulunmaktadır. Bu çekirdekler her birinde 48’şer tane olmak üzere 4 adet akış işlemcisi içerisinde kümelenmiştir. Ekran kartı, 1 GB’a kadar kullanımlarda bellek desteği vermektedir. 48K paylaşılan hafızayla, bloklar arası bilgi paylaşımına olanak sağlamaktadır [93]. Şekil 6.16’da GF106 mimarisinin detayları görülmektedir. Ayrıca büyütülmüş bir şekilde akış işlemcisi de sunulmaktadır. Her bir akış işlemcisi 48 adet çekirdek barındırmaktadır. Akış işlemcisinin, özel matematiksel işlemleri yapmak üzere kullanılan sekiz adet özel fonksiyon birimi (ing. Special Function Unit, SFU) birimi bulunmaktadır. SFU sinüs, kosinüs, karekök ve interpolasyon gibi işlemleri gerçekleştiren komutları çalıştırır. Her SFU, saat

başına, her iş parçacığı için bir komut çalıştırır. Her bir çekirdekte ise tam sayılı işlemler için tamsayı birimi (ing. Integer Unit, INT), ondalıklı işlemler için kayan nokta birimi (ing. Floating Point Unit, FP) birimleri bulunmaktadır. CUDA programlamadan yararlanılarak geliştirilen bir yazılımda yazılan kodların bir kısmı merkezi işlem birimi üzerinde çalışırken, paralelliğin istendiği yerlerde kodlar grafik işlem birimleri (GIB) üzerinde işlenmektedir. Kodların GIB üzerinde çalışmasını sağlayan kod parçasına çekirdek fonksiyonu denilmektedir. Bu fonksiyon çalıştırılmadan önce belirli parametrelere ait değerlerin belirlenmesi gerekmektedir. Bu parametreler blok sayısı ve iplik (ing. thread) sayısıdır. Ayrıca paylaşımlı bellek kullanılacaksa ne kadarlık bir alanı işgal edeceğinin de belirtilmesi gerekir. Blok ve thradlerden oluşan bu yapı ızgara (ing. grid) mimarisi olarak nitelendirilebilir. Izgara yapısı iş parçacıklarının GPU üzerinde eş zamanlı yürütülmesi noktasında büyük önem taşımaktadır. Quadro mimarisinde her akış işlemcisinde en fazla 8 blok eş zamanlı olarak çalışabilmektedir. Eş zamanlı işlenebilecek en fazla iplik sayısı ise 1536'dır. Bu durumda bir akış işlemcisinde CUDA çekirdeği başına en fazla 48 ipliğin eş zamanlı işlenebileceğini ifade edebiliriz. Her blokta bulunabilecek iplik sayısı ise 1024 ile sınırlanmıştır. Bu durumu bir örnekle izah edersek; bir akış işlemcisinde 768'er iplik içeren 2 blok, 384'er iplik içeren 4 blok ya da 192'şer iplik içeren 8 blok işlenebilir. Ancak 47'er iplik içeren 32 bloklu bir yapı, akış işlemcisindeki en fazla blok sayısı aşıldığı için işlenemez. Aynı zamanda 1536 iplik bulunduran tek bloklu bir yapıda blok başına en fazla iplik sayısı aşıldığı için işlenmeyecektir [94].

Bir ızgara yapısı tanımlandığında ipliklerin çalışma prensibini çözgü çizelgeleyiciler (ing. warp scheduler) belirler. Çözgü çizelgeleyici tarafından bir akış işlemcisindeki iplikler 32'şerli gruplar şeklinde akış işlemcisine gönderilmektedir. Şekil 6.16 incelendiğinde Quadro mimarisinde her akış işlemcisinde ikişer adet çözgü çizelgeleyici olduğu görülmektedir. CUDA programlama stratejilerinde çözgülerin önemine dikkat çekilmekte ve programın etkinliği için çözgü çizelgeleyicilerin çalışma mantığının önemli olduğu bildirilmektedir. Şekil 6.17'de örnek olarak 3 blok ve her blokta 32 iplik içeren bir ızgara yapısında çözgülerin nasıl çalıştığını gösterilmektedir. Çizelgeleyici, iplikleri CUDA çekirdeklerine dağıtmaktadır.



Şekil 6.16. Nvidia Quadro 2000 mimarisi (akış işlemcisi ve CUDA çekirdeği).




Şekil 6.17. Çözgü çizelgeleyici.

Şekil 6.18’de bir çekirdek için örnek bir ızgara yapısı bulunmaktadır. Izgarada x, y ve z eksenlerinde toplam 8 blok bulunmaktadır. Blokların birbirinden ayırt edilebilmesi için renklendirme yapılmıştır. Her blokta toplam 64 iplik bulunmaktadır. Her akış işlemcisinde en fazla 8 blokta toplam 1536 iplik işlenebilmektedir. Şekil 6.18’de verilen örnekte 8 blok ve 512 iplik bulunmaktadır. Akış işlemcisinde en fazla 8 blok kullanıldığından bu örnekte 1 akış işlemcisinin görev alması yeterlidir. 512 iplik bu 8 bloğa paylaşılabilir. Bu durumda her blokta işlenecek iplik sayısı 64 olacaktır. CUDA optimizasyonu için bir blokta işlenecek iplik sayısının 32 ve katları olması tavsiye edilir. Dolayısıyla verilen örnek bu şartı sağlamaktadır. Izgara ve blok boyutları aşağıdaki gibi tanımlanabilir [94].

```
dim3 dimGrid(2,2,2)
dim3 dimBlock(4,4,4)
kernel_name<<<dimGrid,dimBlock>>>(...
```

Grid yapısı, en fazla (65535, 65535, 65535) blok ve en fazla her blok için (1024, 1024, 64) iplik içerecek şekilde tanımlanabilmektedir. GPU mimarisinden bahsederken performansı önemli ölçüde etkileyen bellekleri göz ardı etmemek gerekir.

Genel Bellek (ing. global memory): CPU ile GPU arasındaki temel haberleşme alanıdır. Tüm ipliklerden erişilebilir. Fakat uzun gecikme süresi vardır.



Şekil 6.18. Örnek bir ızgara yapısı.

Paylaşımlı Bellek (ing. shared memory): Her akış işlemcisi, tüm SP'leri tarafından paylaşılan, hızlı, küçük bir miktar paylaşılan bellek içerir. Paylaşılan bellekte tanımlı değişkenlerin ömrü çekirdek fonksiyonunun işlenmesine kadar devam etmektedir [94]. Bu hafıza oldukça hızlıdır. Bu bellek üzerinde tanımlanan değişkenlere tüm bloklar tarafından ulaşılabilmektedir. CUDA optimizasyon araştırmalarında ısrarla altı çizilen bu belleğin kullanımı, performansı önemli ölçüde olumlu etkileyecektir.

Programın bitişi ile başlangıcı arasında değerinin hiç değişmemesi istenilen değişkenlerin sabit bellekte (ing. constant memory) ya da ekran kartının kendi belleğinde tanımlanması, o değişkenin program çalıştığı sürece ömrünü korumasını sağlamaktadır. Sabit bellek sadece okuma amaçlı işlemlerde verimlidir.

GPU mimarisinin daha iyi anlaşılabilmesi için şu şekilde bir benzetmeye değinilebilir [94]. Örneğin, bir fabrikada 16 bölüm, her bölümde 32 makine ve her makinenin birbirine benzer basit işleri eş zamanda çözebilme yeteneğinin olduğunu düşünelim. Bir makineyi bir CUDA çekirdeğine benzetecek olursak, bölüm bir akış işlemcisini fabrika ise mimarının tümünü temsil etmektedir.

6.4.3. CUDA Programlama Stratejileri

CUDA Paralel programlamadan üst seviyede avatanj sağlamak için bazı kurallara dikkat edilmelidir [95, 96].

1. Genel bellek aygıt üzerinde yer alır (DRAM) ve erişim hızı paylaşımlı belleğe göre çok daha yavaştır.
2. Programlamada dikkat edilmesi gereken hususlardan birisi verileri parçalara ayırarak paylaşımlı bellekten faydalanmaktır.
3. Sabit bellek, DRAM üzerinde yer alır. Bu nedenle paylaşımlı belleğe göre yavaştır. Sadece okuma (ing. read-only) amaçlı veriler için avantajlıdır.
4. Veri erişim yapısına bağlı olarak hafıza kullanımı tasarlanmalıdır.
5. Sadece okuma (read/only) işlemlerde sabit bellek (tamponlanmış ise çok hızlı),
6. Okuma-yazma (read/write) işlemlerde blok içerisinde işlem yapılacaksa paylaşımlı bellek,
7. Okuma-yazma (read/write) işlemlerde iplik içerisinde işlem yapılacaksa kaydedici (ing. register) kullanılması avantajlı olacaktır.
8. Okuma-yazma amaçlı giriş ve çıkış işlemlerinde genel bellek kullanılır.
9. Visual Profiler kullanılarak sistem darboğazları analiz edilmelidir.
10. CUDA ile GPU üzerinde en iyi performansı sağlamak için her bir blokta en az 64 izlek yer almalıdır. Bunun nedeni ipliklerin warp denilen 32'lik gruplar halinde koşulmasıdır. Bir warp bir anda bir komut çalıştırır, bu yüzden sadece warp'taki 32 thread'in hepsi aynı çalıştırma yoluna sahipken tam verimliliğe ulaşılabilir. 32 den daha az iplik olduğunda bu durum warp içerisindeki bazı ipliklerin seri çalışmasına neden olacaktır. Bu duruma iplik ayrılması (ing. thread divergence) denilmektedir. Bu durum çözgü içerisinde çalışan komutların toplam işleme zamanını arttıracaktır. Bunun sebebi, bir saat döngüsünde aynı komutun bir çekirdekte 4, dolayısıyla bir çokişlemcilide 32 izlek üzerinde işletilebilmesidir.
11. Farklı algoritmaları gerçeklerken veri alışverişi sadece bu iki algoritma içinde olacak ise, veriyi tekrar CPU üzerine almadan GPU üzerinde diğer algoritmaya aktarmak veri transferindeki darboğazı en aza indirgemektedir.

12. Paralelliğe uygun kod parçalarının CUDA üzerinde, seri olması gereken işlemlerin ise CPU üzerinde çalıştırılmasına dikkat edilmelidir.
13. CUFFT ve CUBLAS gibi optimize edilmiş CUDA kütüphanelerinden yararlanılabilir.

BÖLÜM 7

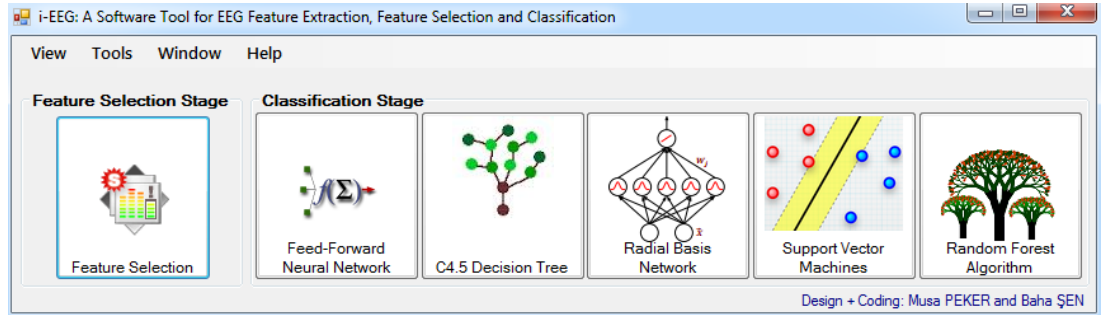
GELİŞTİRİLEN YAZILIMLAR

Bu bölümde tez çalışması süresince geliştirilen ve kullanılan yazılımlar tanıtılmaktadır.

7.1. YÖNTEM 1 AŞAMASINDA GELİŞTİRİLEN YAZILIMLAR

7.1.1. Arayüz

Geliştirilen yazılımın ara yüzü Şekil 7.1'deki gibidir. Programlama dili olarak .Net dillerinden C# programlama dili tercih edilmiştir. Ara yüz kullanıcı dostu olacak şekilde tasarlanmıştır. Bu yazılım sayesinde öznelik seçme ve sınıflandırma aşamaları gerçekleştirilmektedir.

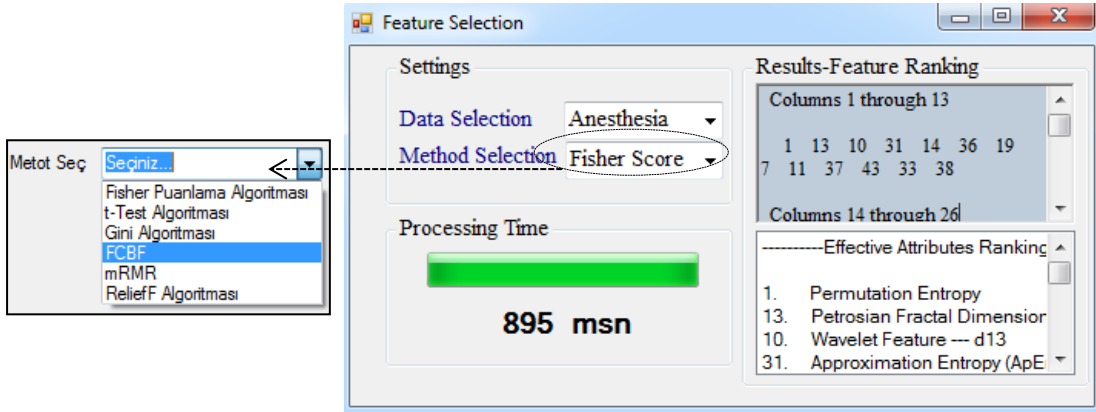


Şekil 7.1. Geliştirilen sistemin ekran ara yüzü.

7.1.2. Öznelik Seçme Aşaması

Öznelik seçme aşaması için geliştirilen yazılım penceresi Şekil 7.2'de görülmektedir. Bu yazılım ile veri türü seçilebilmektedir.

Metot seç bölümünden öznitelik seçme algoritması seçilmektedir. Şekil 7.2’de görüldüğü gibi 6 farklı öznitelik seçme algoritması kullanılmaktadır. Yazılım toplam işlem süresi hakkında bilgi vermektedir. Sonuç ekranından etkili öznitelikleri ve sırasını görmek mümkün olmaktadır.



Şekil 7.2. Öznitelik seçme aşaması.

7.1.3. Sınıflandırma Aşaması

Sınıflandırma aşamasında 5 farklı sınıflandırma algoritması bulunmaktadır. Her algoritma için ayrı bir form tasarımı ve yazılımı geliştirilmiştir. Kullanıcı hangi algoritma ile sınıflandırma işlemini gerçekleştirmek istiyorsa bunu ana sayfadan ilgili butona tıklayarak gerçekleştirebilir.

7.1.3.1. İleri Beslemeli Sinir Ağı

Sinir ağı için geliştirilen yazılım 5 pencereden oluşmaktadır. Veriler, ayarlar, eğitim işlemleri, sonuç ekranı ve grafiksel gösterimler ayrı ayrı pencerelerde sunulmaktadır. Şekil 7.3’de üzerinde çalışılacak veri kümesi seçilmektedir.

Şekil 7.4’ de parametre ayarları yapılmaktadır. 1 no’ lu alanda gizli katman nöron sayıları, gizli katman aktivasyon fonksiyonları seçilmektedir. 2 no’ lu alanda çıkış katmanı aktivasyon fonksiyonları seçilebilmektedir. Giriş katmanı nöron sayısı ve çıkış katmanı nöron sayısı seçilen veri türüne bağlı olarak otomatik seçilmektedir. 3 numaralı alanda eğitim parametreleri belirlenmektedir. Bu alandan iterasyon sayısı,

öğrenme oranı, minimum hata değeri ve momentum katsayısı değerleri girilebilmektedir.

	d15	Activity	Mobility	Complexity
8	57,016	56,293	0,116	0,857
6	52,824	84,808	0,104	0,601
5	94,176	325,07	0,059	0,516
6	52,364	115,67	0,095	0,349
4	66,274	126,63	0,096	0,427
4	23,475	26,425	0,145	0,463
4	23,475	26,425	0,145	0,463
8	26,043	28,499	0,127	0,381
8	26,043	28,499	0,127	0,381
7	214,61	1695,2	0,065	0,242
8	57,016	56,293	0,116	0,857
4	28,679	37,775	0,143	0,394
	36,345	31,243	0,125	0,523
9	30,153	40,033	0,122	0,405

Şekil 7.3. Veri seçme ekranı.

Input Layer
Neuron Value 44

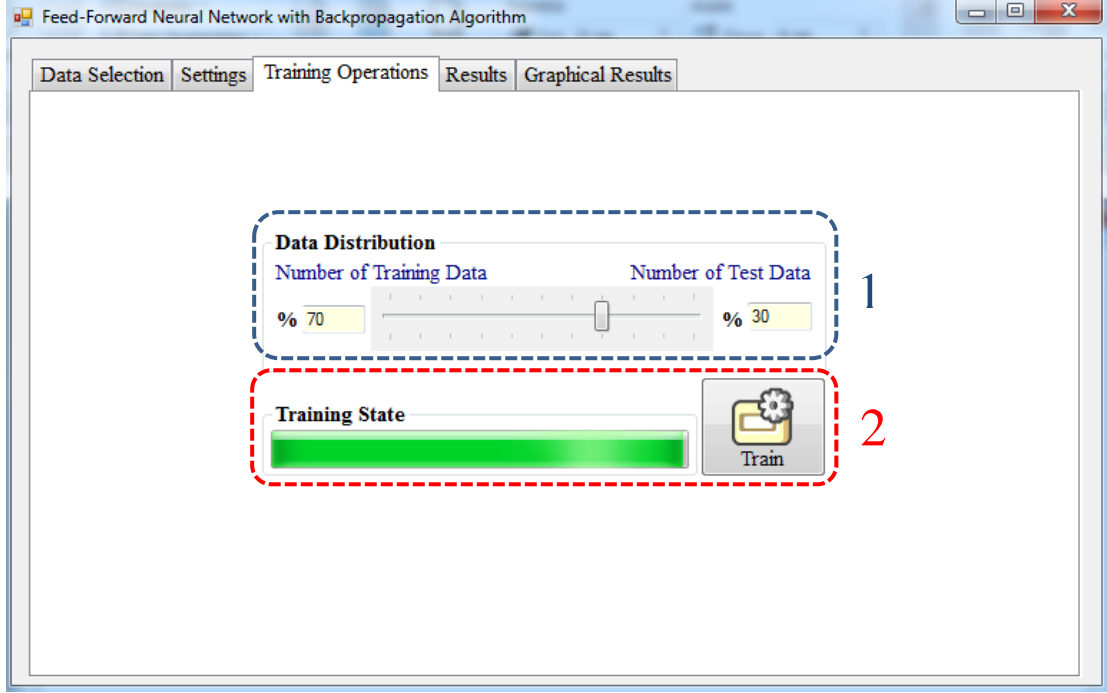
Hidden Layer 2
Activation Function
Sigmoid Layer
Number of neurons 20

Hidden Layer 1
Activation Function
Sigmoid Layer
Number of neurons 30

Output Layer
Activation Function
Sigmoid Layer
Number of neurons 6

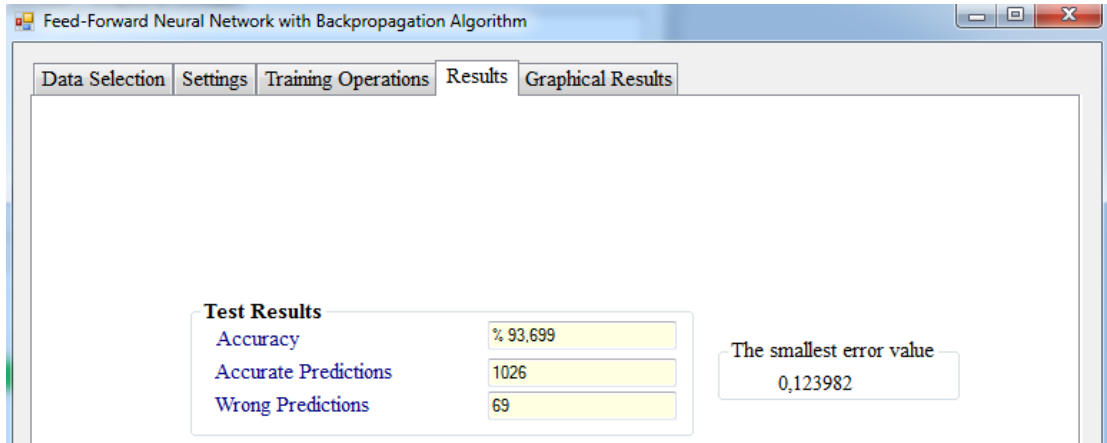
Training Parameters
Iteration Value 1000 Minimum Error 0,01
Learning Rate 0,25 Momentum Rate 0,07

Şekil 7.4. Ayar penceresi.




Şekil 7.5. Eğitim işlemleri penceresi.

Şekil 7.5’ de eğitim işlemleri ve eğitim başlama işlemi gerçekleştirilmektedir. 1 numaralı ekranda eğitim ve test veri sayıları belirlenmektedir. 2 numaralı ekranda “Eğit” butonuna tıklandığında eğitim işlemi başlamaktadır. Ayrıca bu ekrandan işlemin bitme aşaması görülmektedir.



Şekil 7.6. Sonuç ekranı.

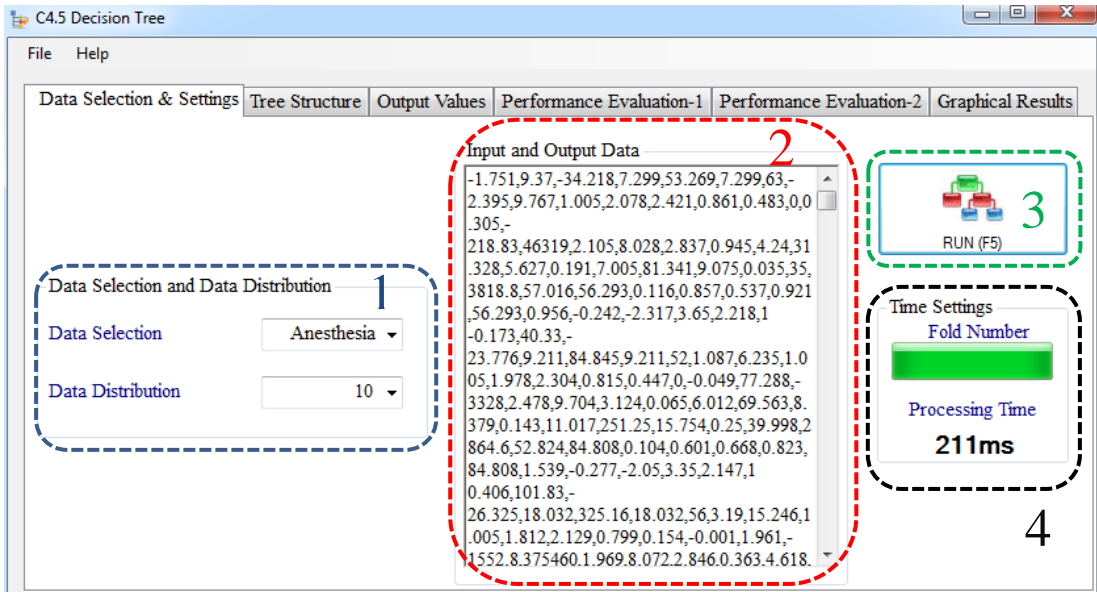
Şekil 7.6’ da sonuçları görmek mümkündür. Bu ekrandan başarı yüzdesi, doğru tahmin edilen kayıt sayısı, hatalı tahmin edilen kayıt sayısı ve en küçük hata değerleri görülebilmektedir. Şekil 7.7’de iterasyon-hata grafiği sunulmaktadır.



Şekil 7.7. Hata grafiği.

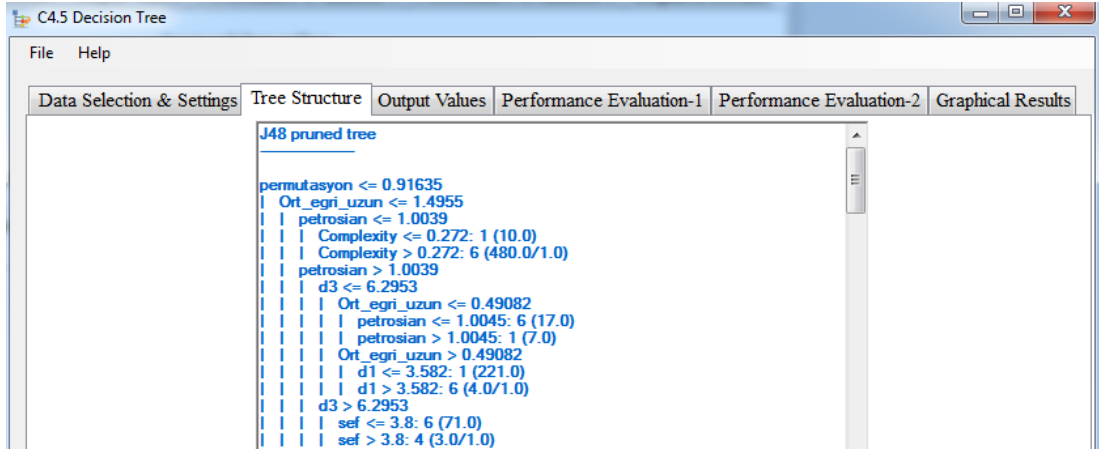
7.1.3.2. Karar Ağacı Uygulaması

Karar ağacı algoritması olarak C4.5 tercih edilmiştir. Karar ağacı için geliştirilen yazılım 5 pencereden oluşmaktadır. Veriler, ayarlar, eğitim işlemleri, sonuç ekranı ve grafiksel gösterimler ayrı ayrı pencerelerde sunulmaktadır.

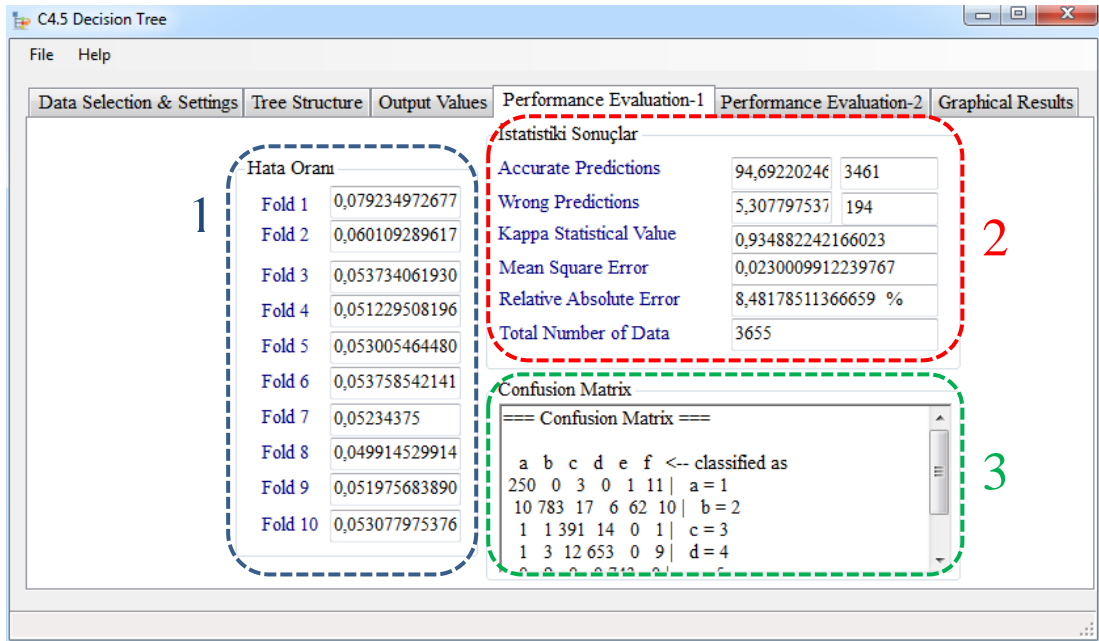


Şekil 7.8. Veri giriş ekranı.

Şekil 7.8’de 4 bölüm bulunmaktadır. 1 numaralı ekranda veri seçme işlemi gerçekleştirilmektedir. Ayrıca bu ekranda veri dağılımının nasıl gerçekleşeceği seçilmektedir. Yazılım kapsamında 3-fold, 5-fold ve 10-fold çapraz doğrulama yöntemleri desteklenmektedir. 2 numaralı ekranda seçilen veri kümesine ait veriler sunulmaktadır. 3 numaralı alandaki buton sayesinde program çalıştırılmaktadır. 4 numaralı alanda işlem zamanına ait bilgiler sunulmaktadır. Şekil 7.9’ da karar ağacı karar yapısı verilmektedir.

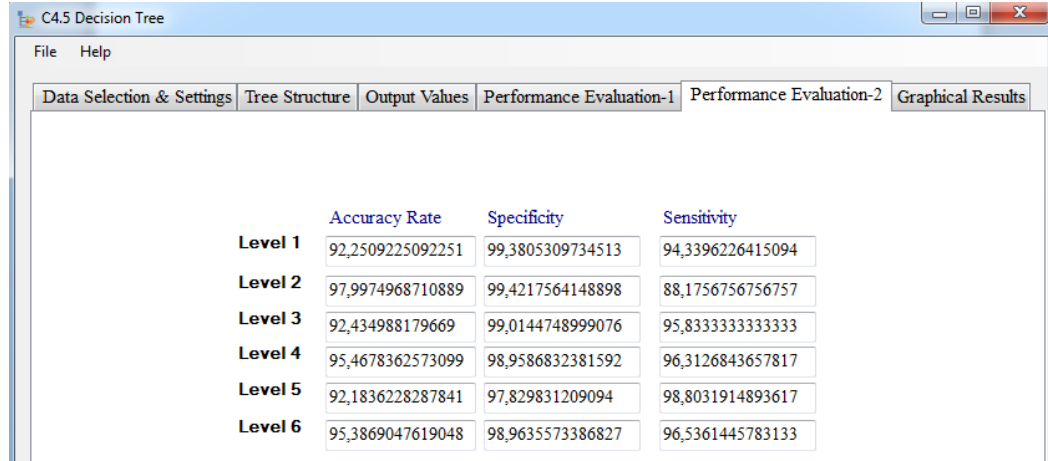


Şekil 7.9. Karar ağacı karar yapısı.



Şekil 7.10. Performans değerlendirme ekranı.

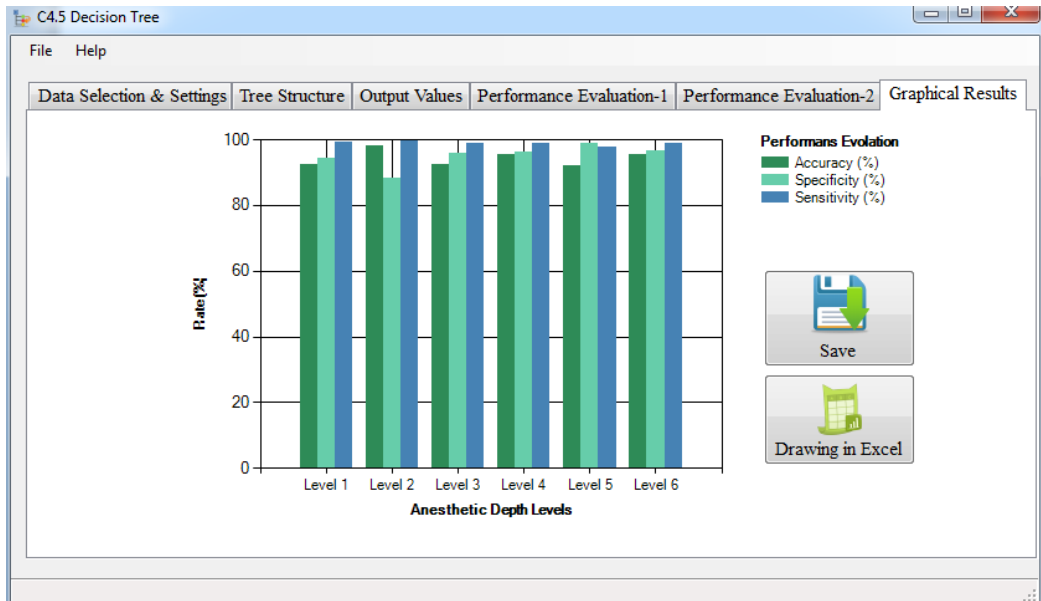
Şekil 7.10'da farklı performans değerlendirme kriterlerine göre elde edilen sonuçlar listelenmektedir. 1 numaralı ekranda her fold sonucunda oluşan hata değerleri listelenmektedir. 2 numaralı ekranda farklı performans değerlendirme kriterlerine göre elde edilen sonuçlar listelenmektedir. 3 numaralı ekranda karışıklık matrisi sunulmaktadır.



	Accuracy Rate	Specificity	Sensitivity
Level 1	92,2509225092251	99,3805309734513	94,3396226415094
Level 2	97,9974968710889	99,4217564148898	88,1756756756757
Level 3	92,434988179669	99,0144748999076	95,8333333333333
Level 4	95,4678362573099	98,9586832381592	96,3126843657817
Level 5	92,1836228287841	97,829831209094	98,8031914893617
Level 6	95,3869047619048	98,9635573386827	96,5361445783133

Şekil 7.11. Performans değerlendirme ekranı-2.

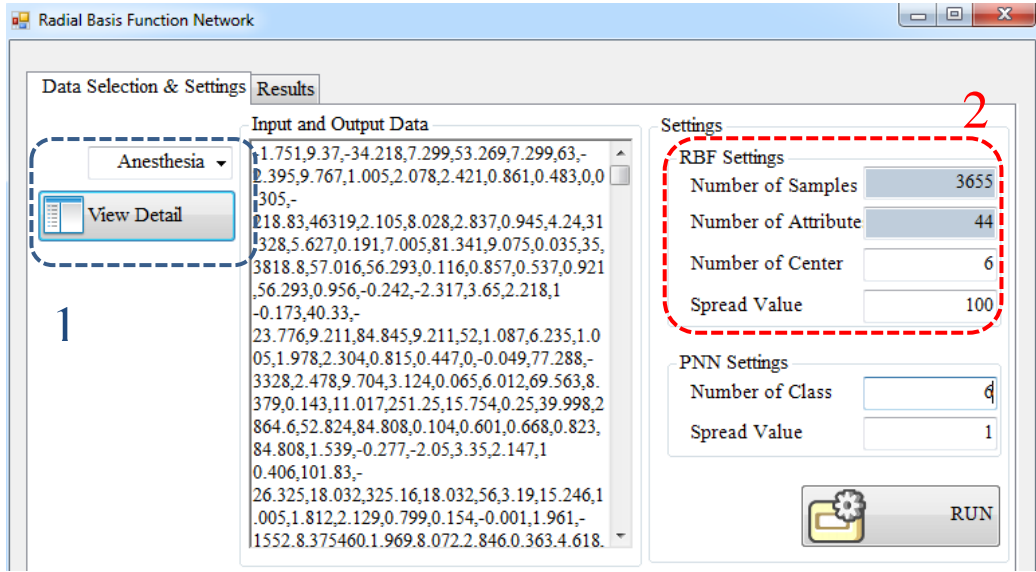
Şekil 7.11'de 3 önemli performans değerlendirme kriterlerine göre sonuçlar listelenmektedir. Son aşamada Şekil 7.12'de görüldüğü gibi her çıkış değeri için doğruluk oranı, özgüllük ve duyarlılık değerleri grafiksel olarak sunulmaktadır.



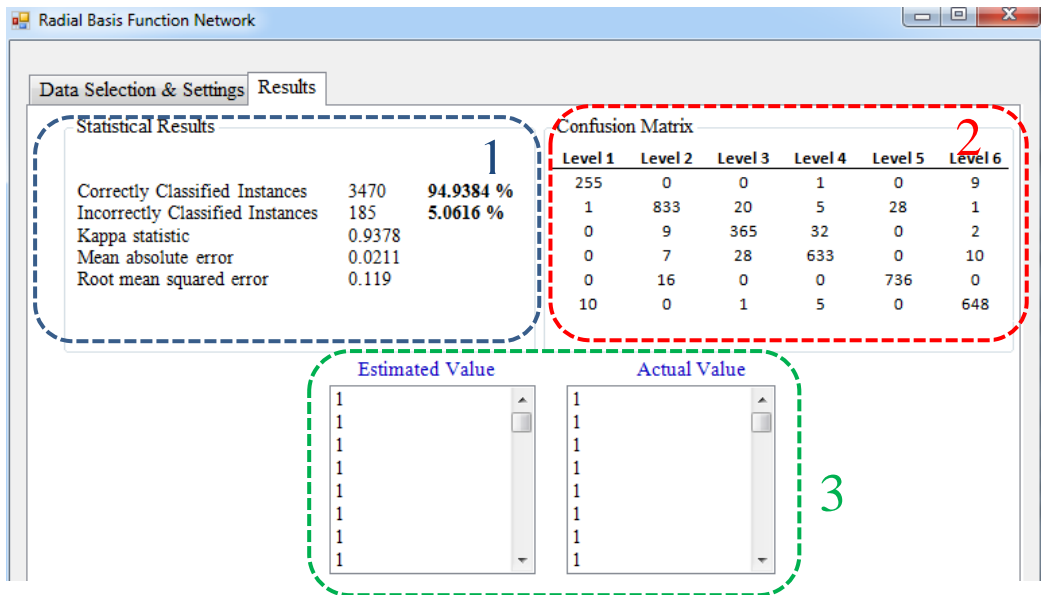
Şekil 7.12. Sonuçların grafiksel sunumu.

7.1.3.3. Radyal Temelli Sinir Ağı

Şekil 7.13'deki ekranlar sayesinde veri seçimi ve ayarlamalar mümkün olmaktadır. 1 numaralı ekran sayesinde farklı veri türleri seçilebilmekte ve bu veriler listelenebilmektedir. 2 numaralı ekrandan RNN algoritmasının parametre girişleri yapılabilmektedir.



Şekil 7.13. RNN algoritması için geliştirilen yazılımın ara yüzü - Veriler ve ayarlar penceresi.

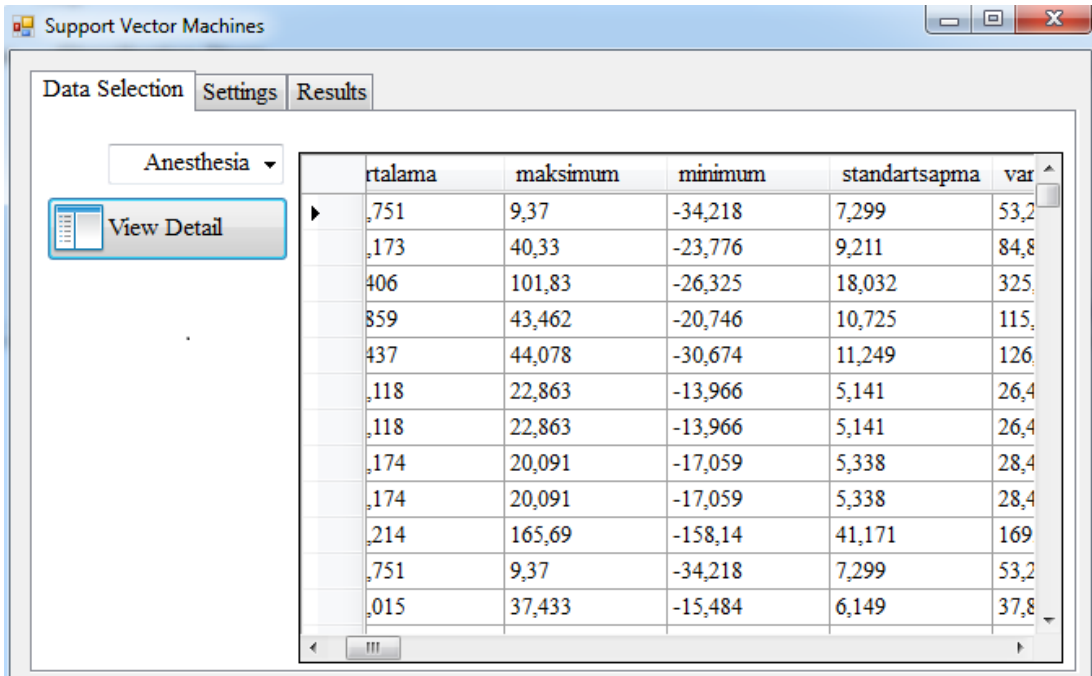


Şekil 7.14. Sonuç ekranı.

Şekil 7.14’de RNN ağına ait istatistiki sonuçlar sunulmaktadır. 1 numaralı ekranda iki algoritmanın çalıştırılması sonucu elde edilen doğruluk değerleri verilmektedir. 2 numaralı ekranda iki algoritmaya ait karışıklık matrisleri sunulmuştur. 3 numaralı ekranda iki algoritmaya ait elde edilen tahmini çıkış değerleri ve elde edilen gerçek çıkış değerleri verilmektedir.

7.1.3.4. Destek Vektör Makineleri

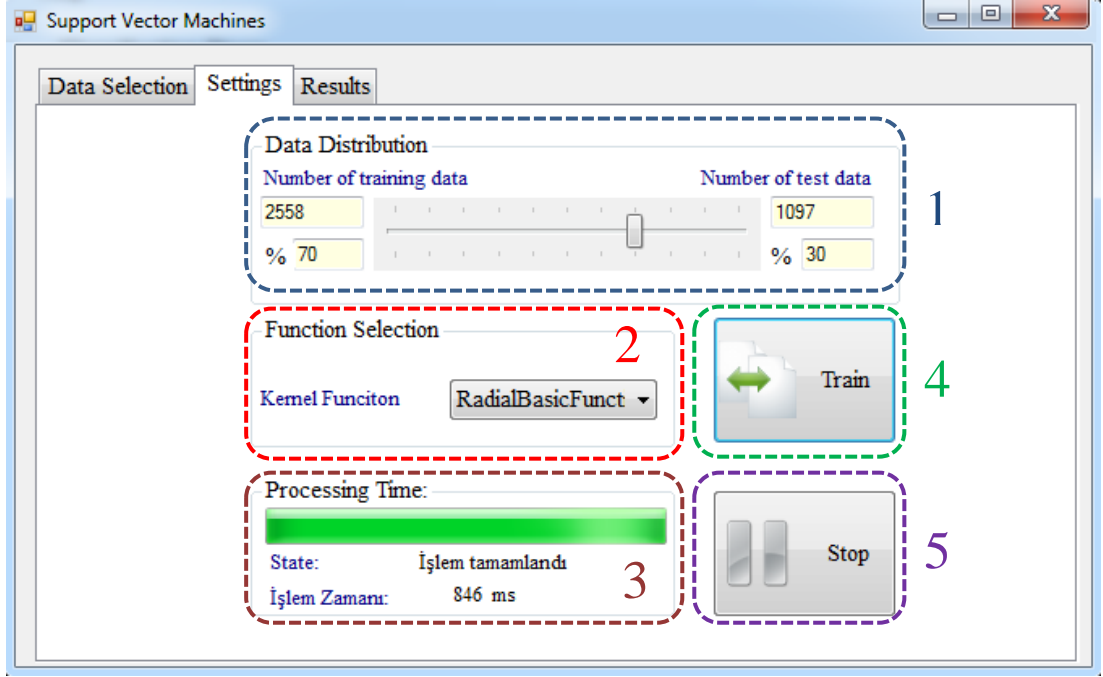
Destek vektör makineleri için geliştirilen yazılım 3 pencereden oluşmaktadır. Veriler, ayarlar ve sonuç ekranı ayrı ayrı pencerelerde sunularak özelleştirilmiştir.



	ortalama	maksimum	minimum	standartsapma	var
751	9,37	-34,218	7,299	53,2	
173	40,33	-23,776	9,211	84,8	
406	101,83	-26,325	18,032	325,	
859	43,462	-20,746	10,725	115,	
437	44,078	-30,674	11,249	126,	
118	22,863	-13,966	5,141	26,4	
118	22,863	-13,966	5,141	26,4	
174	20,091	-17,059	5,338	28,4	
174	20,091	-17,059	5,338	28,4	
214	165,69	-158,14	41,171	169,	
751	9,37	-34,218	7,299	53,2	
015	37,433	-15,484	6,149	37,8	

Şekil 7.15. Veri seçme ekranı.

Şekil 7.16’da destek vektör makinelerine ait ayarlamalar yapılmaktadır. 1 numaralı pencerede veri dağılımı belirlenmektedir. Örnekte verilerin %70’ i eğitim, %30’u test verisi olarak belirlenmiştir. 2 numaralı pencerede çekirdek fonksiyonu gerçekleştirilmektedir. Şekil 7.17’de görüldüğü gibi 5 farklı çekirdek fonksiyonu seçilebilmektedir.



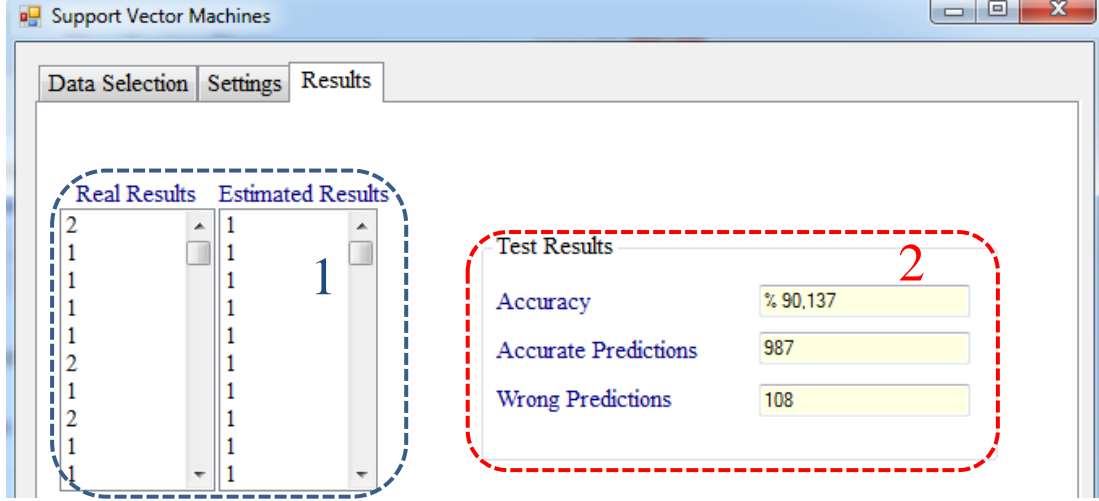
Şekil 7.16. Ayarlamaların yapıldığı pencere.



Şekil 7.17. Çekirdek fonksiyon seçimi.

3 numaralı ekranda işlem zamanı ve işlemin hangi aşamada olduğu hakkında bilgiler verilmektedir. 4 numaralı ekrandaki buton sayesinde algoritma çalışmaya başlamakta, 5 numaralı ekran sayesinde algoritmanın çalışması durdurulabilmektedir.

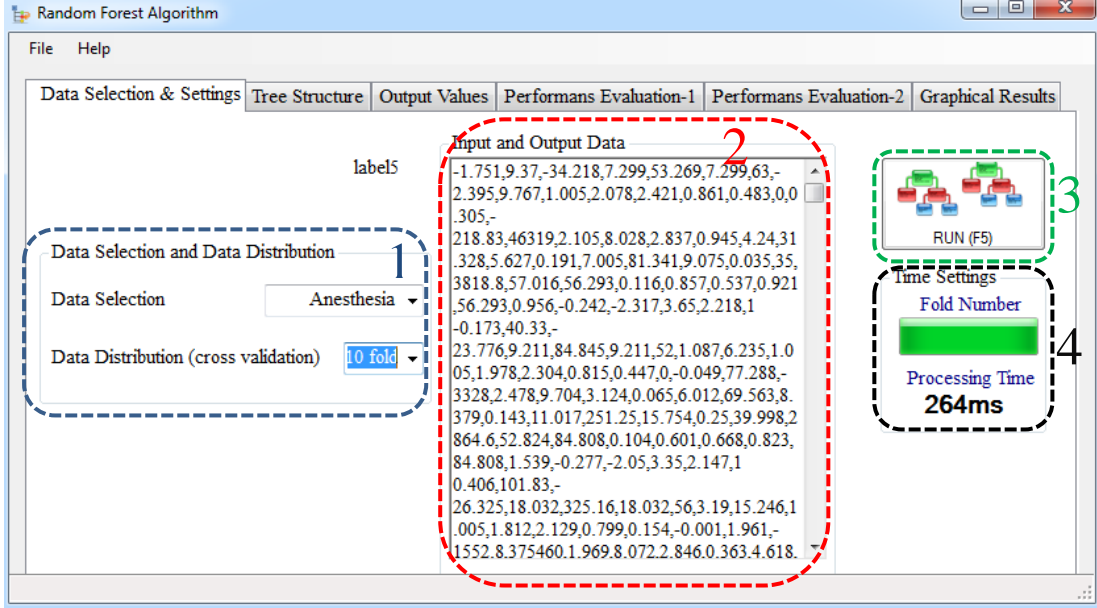
Şekil 7.18'de 1 numaralı ekranda destek vektör makinesi algoritmasına ait elde edilen tahmini çıkış değerleri ve elde edilen gerçek çıkış değerleri verilmektedir. 2 numaralı ekranda algoritmanın çalıştırılması sonucu elde edilen doğruluk değerleri ve başarı oranları verilmektedir.




Şekil 7.18. Sonuç ekranı.

7.1.3.5. Rastgele Orman Algoritması

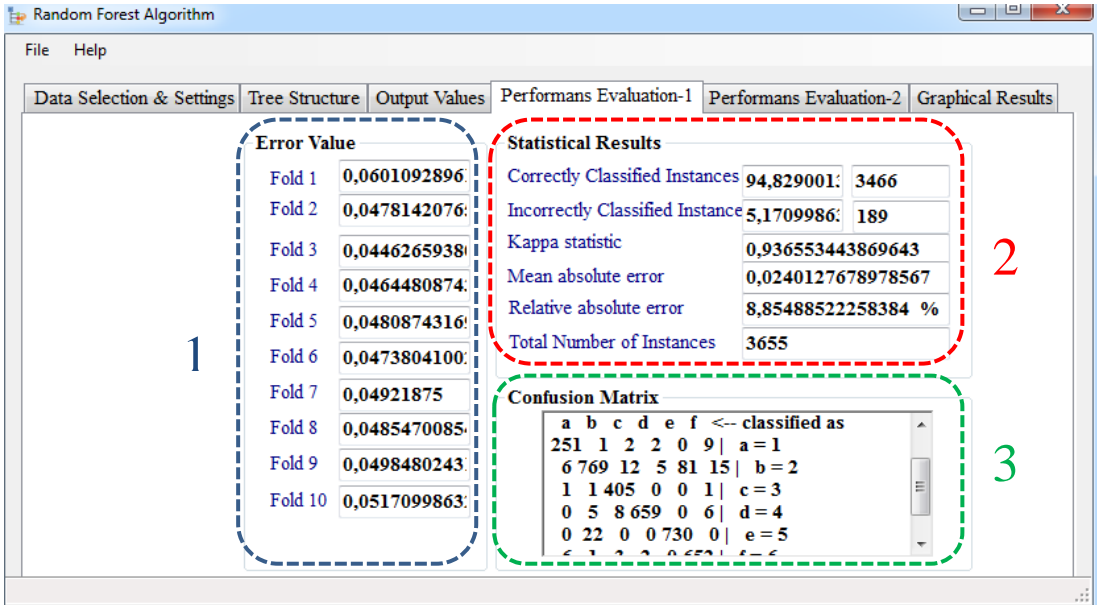
Rastgele orman algoritması için geliştirilen yazılım 5 pencereden oluşmaktadır. Veriler, ayarlar, eğitim işlemleri, sonuç ekranı ve grafiksel gösterimler ayrı ayrı pencerelerde sunularak özelleştirilmiştir. Şekil 7.19'da 4 bölüm bulunmaktadır. 1 numaralı ekranda veri seçme işlemi gerçekleştirilmektedir. Ayrıca bu ekranda veri dağılımının nasıl gerçekleşeceği seçilmektedir. Yazılım kapsamında 3-fold, 5-fold ve 10-fold çapraz doğrulama yöntemleri desteklenmektedir. 2 numaralı ekranda seçilen veri kümesine ait veriler sunulmaktadır. 3 numaralı alandaki buton sayesinde program çalıştırılmaktadır. 4 numaralı alanda işlem zamanına ait bilgiler sunulmaktadır. Şekil 7.20'de karar ağacı karar yapısı verilmektedir. Şekil 7.21'de farklı performans değerlendirme kriterlerine göre elde edilen sonuçlar listelenmektedir. 1 numaralı ekranda her fold sonucunda oluşan hata değerleri listelenmektedir. 2 numaralı ekranda farklı performans değerlendirme kriterlerine göre elde edilen sonuçlar listelenmektedir. 3 numaralı ekranda karışıklık matrisi sunulmaktadır.



Şekil 7.19. Veri giriş ekranı.



Şekil 7.20. Karar ağacı karar yapısı.



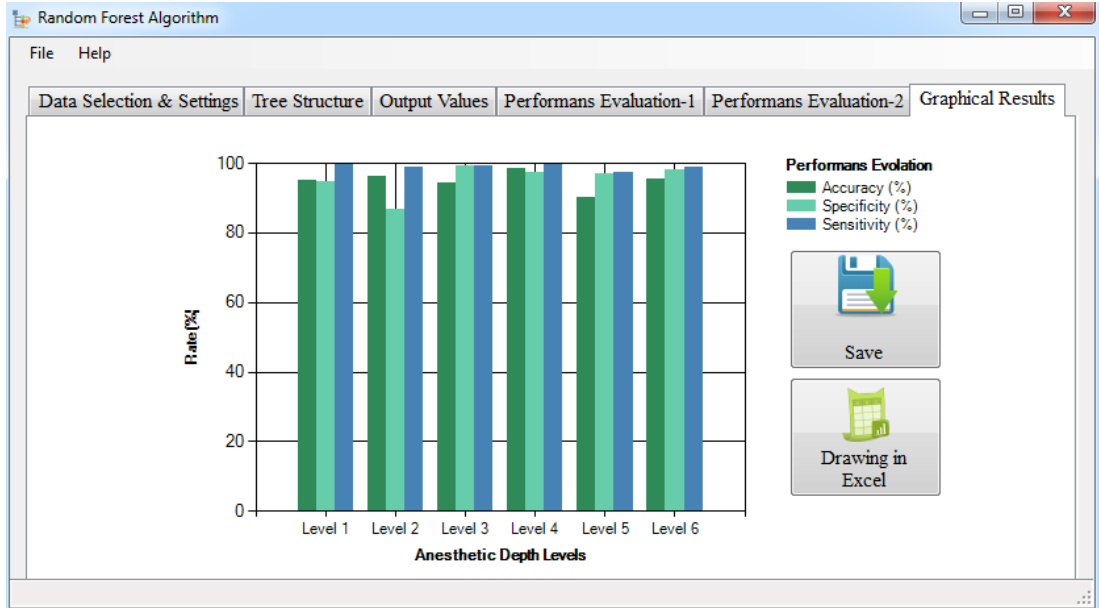
Şekil 7.21. Performans değerlendirme ekranı.

	Accuracy Rate	Specificity	Sensitivity
Level 1	95,0757575757576	99,6165191740413	94,7169811320755
Level 2	96,2453066332916	98,9157932779183	86,5990990990991
Level 3	94,1860465116279	99,2300585155528	99,2647058823529
Level 4	98,6526946107784	99,6976822304333	97,1976401179941
Level 5	90,0123304562269	97,2097829831209	97,0744680851064
Level 6	95,4612005856515	98,9635573386827	98,1927710843374

Şekil 7.22. Performans değerlendirme ekranı-2.

Şekil 7.22’de 3 önemli performans değerlendirme kriterlerine göre sonuçlar listelenmektedir.

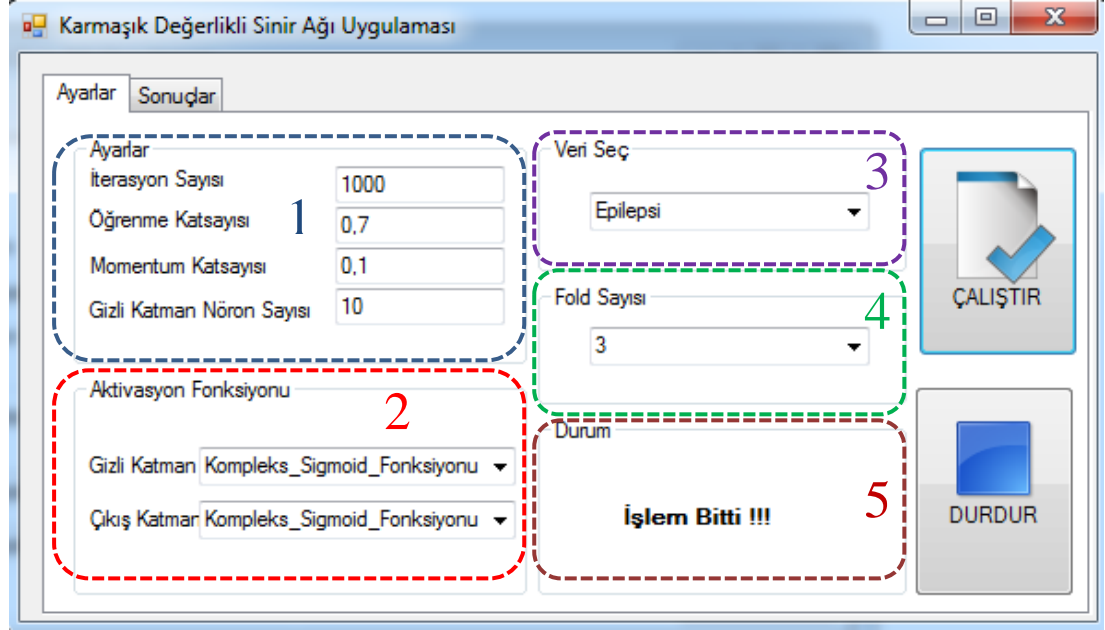
Son aşamada Şekil 7.23’de görüldüğü gibi her çıkış değeri için doğruluk oranı, özgülük ve duyarlılık değerleri grafiksel olarak sunulmaktadır.



Şekil 7.23. Sonuçların grafiksel sunumu.

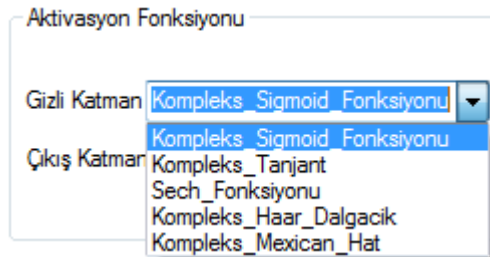
7.2. YÖNTEM 2 AŞAMASINDA GELİŞTİRİLEN YAZILIM

Bu aşamada karmaşık geri yayılım algoritması ile eğitilen karmaşık sinir ağına yönelik bir yazılım geliştirilmiştir.




Şekil 7.24. Karmaşık sinir ağı yazılımı.

Şekil 7.24’de karmaşık sinir ağına ait ara yüz görülmektedir. 1 numaralı ekranda parametre girişleri yapılmaktadır. 2 numaralı ekranda gizli katman ve çıkış katmanı için aktivasyon fonksiyonları seçilmektedir. Bu ekranda 5 farklı aktivasyon fonksiyonu seçilebilmektedir (Bakınız Şekil 7.25). 3 numaralı ekrandan veri seçimi yapılmaktadır. 4 numaralı ekrandan veri dağılımı belirlenmektedir. Bu aşamada sıklıkla kullanılan 3, 5 ve 10 kat çapraz doğrulama seçilebilmektedir. 5 numaralı ekranda işlemin başlayıp başlamadığı, bittiği gibi anlık bilgiler sunulmaktadır.



Şekil 7.25. Aktivasyon fonksiyonları.

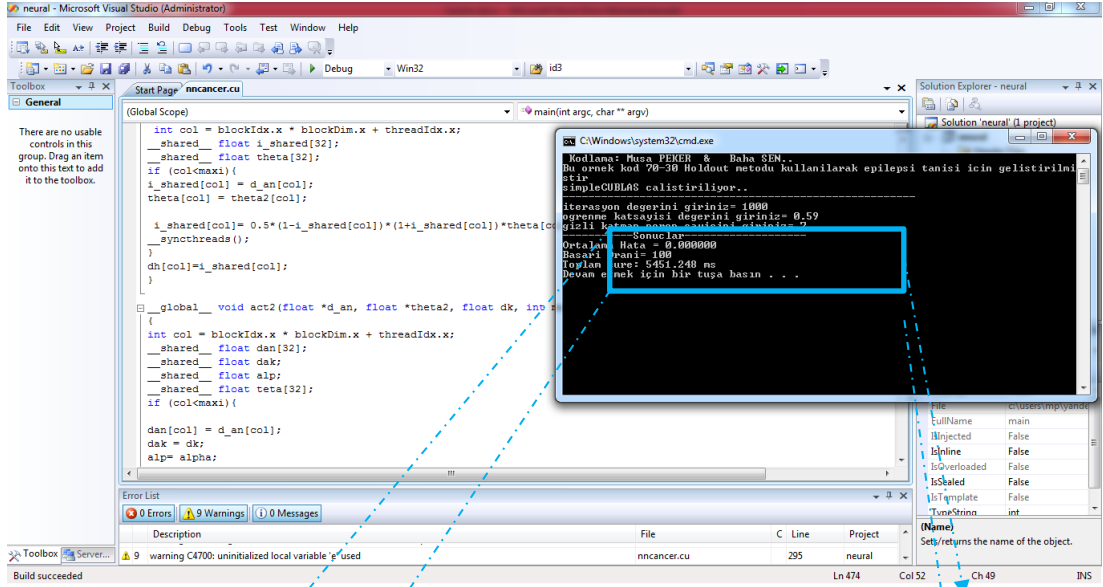
Şekil 7.26'da 1 numaralı ekranda sonuçlara dair istatistiki bazı sonuçlara yer verilmektedir. 2 numaralı grafikte hata grafiği çizdirilmektedir.



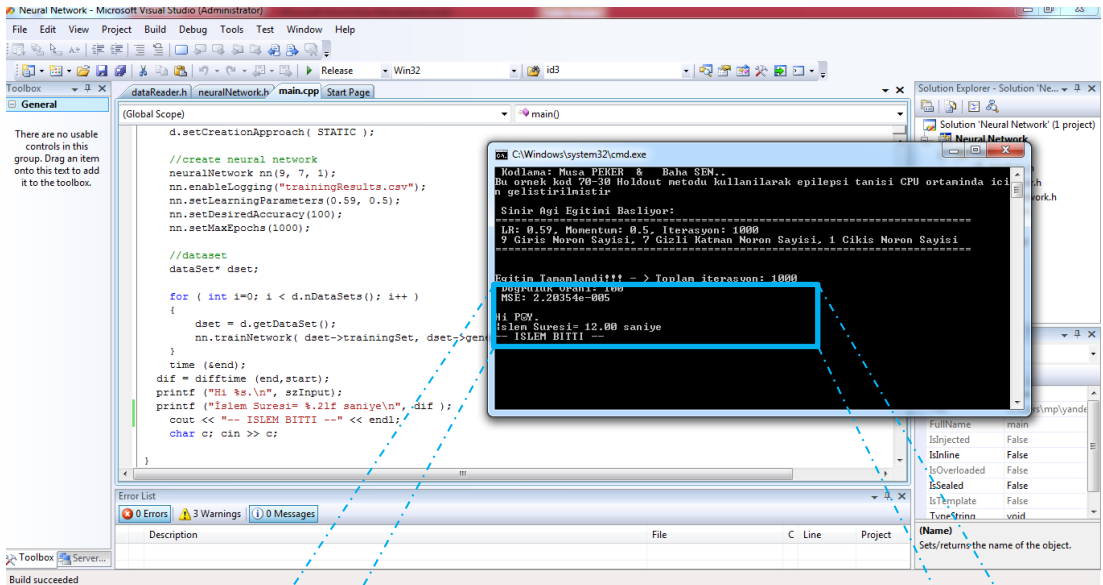
Şekil 7.26. Performans değerlendirme ve grafiksel sonuçlar.

7.3. YÖNTEM 3 AŞAMASINDA GELİŞTİRİLEN YAZILIMLAR

Bu aşamada sınıflandırma işlemi CUDA mimarisi desteğiyle gerçekleştirilmiştir. Amaç gerçek zamanlı bir uygulamada karar verme işleminin hızlı verilmesini sağlayan bir sistemin alt yapısını geliştirmek. Örnek sınıflandırma algoritması olarak karmaşık matematiksel işlemlere sahip geri yayımlı ileri beslemeli sinir ağı seçilmiştir. Algoritma örnek veri seti üzerinde hem CPU hem de GPU üzerinde gerçekleştirilmiştir. İşlem adilliği açısından her iki yazılımda aynı programlama dili üzerinde kodlanmıştır. Programlama dili olarak Visual C++ dili tercih edilmiştir. Kodlamada arayüz hazırlanmamıştır. Hız ön planda olduğu için kodlamalar konsol uygulaması olarak hazırlanmıştır. Şekil 7.27 ve Şekil 7.28'de örnek şekiller görülmektedir.



Şekil 7.27. GPU platformu.



Şekil 7.28. CPU platformu.

BÖLÜM 8

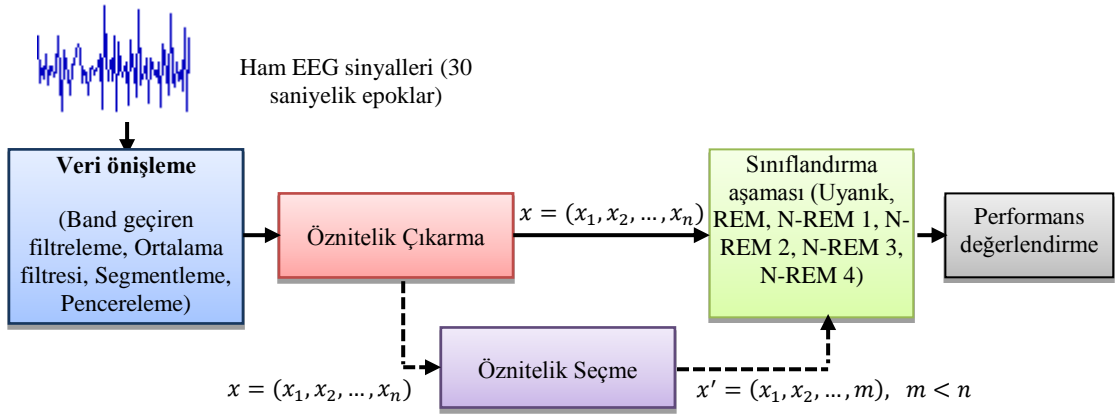
UYGULAMA VE DEĞERLENDİRME

Deneyle epilepsi, uyku ve anestezi verileri üzerinde gerçekleştirilmiştir. Bu bölümde bu deneylelerden elde edilen sonuçlar ve analizlere yer verilmiştir.

8.1. YÖNTEM 1 İLE GERÇEKLEŞTİRİLEN ÇALIŞMALAR

8.1.1. Uygulama 1: Öznitelik Seçme ve Sınıflandırma Algoritmalarını Kullanarak Uyku Evrelerinin Sınıflandırılması ve Karşılaştırmalı Bir Çalışma

Önerilen çalışmanın önceki çalışmalardan farklılıkları: Biyomedikal sinyal işlemede önemli sorunlardan birisi de verileri temsil edecek özniteliklerin tespiti olmaktadır. Verileri temsil edecek özniteliklerin tespiti için literatürde ortaya konmuş birçok algoritma vardır. Fakat bu algoritmalarından hangilerinin problem için etkili öznitelikleri belirleyeceği çoğu zaman deneme-yanılma yöntemi ile bulunmaktadır. Bu işlemi otomatik gerçekleştirecek bir sistem araştırmacıların işini büyük bir ölçüde kolaylaştıracaktır. Bunu gerçekleştirmek için bu çalışmada epilepsi teşhisine yönelik olarak verileri en iyi şekilde temsil edecek bir yöntem önerilmektedir. Öncelikle uyku evrelerinin sınıflandırılmasında literatürde sıklıkla tercih edilen ve Bölüm 6.2’de açıklanan 41 öznitelik parametresi elde edilmiştir. Sonraki aşamada etkili özniteliklerin tespiti için öznitelik seçme algoritmaları uygulanmıştır. Son aşamada tespit edilen etkili özniteliklerle beraber yüksek sınıflandırma doğruluğu veren sınıflandırma algoritmasının tespiti gerçekleştirilmiştir. Önerilen metodun blok diyagramı Şekil 8.1’de görülmektedir.




Şekil 8.1. Uygulama 1’de önerilen metot.

İlk aşamada EEG sinyallerinin önışleme aşaması gerçekleştirilmiştir. Bu aşamada sırasıyla band geçiren filtre, hareketli ortalama filtresi, pencereleme ve bölümlenme işlemleri gerçekleştirilmiştir. Temizleme ve filtreleme aşamalarından sonra verilerin öznitelikleri çıkarılmıştır. 6 uyku evresi için Matlab R2009a’da beş ayrı matris oluşturulmuştur. Bu matrislerin büyüklükleri uyanıklık (Wake, W), NREM-1, NREM2, NREM3, NREM4 ve REM evreleri için sırasıyla 1109x3840, 897x3840, 988x3840, 1078x3840, 764x3840 ve 324x3840’ dır. Buradaki matris boyutları *Epok Sayısı x Her bir epok daki örnek sayısı*’ni ifade etmektedir. Bu matrislerin her bir sütunu için, Bölüm 6.2’de belirtilen 41 ayrı öznitelik parametresi edilmiştir. Sonraki aşamada bu öznitelik kümesinden etkili özniteliklerin tespiti hedeflenmiştir. Öznitelik seçme aşamasında, etkili öznitelik seçme algoritmalarından mRMR, FCBF, reliefF, t-test ve fisher puanlama algoritmaları tercih edilmiştir. Bu şekilde EEG sinyallerini en iyi şekilde temsil edebilecek etkili özniteliklerin tespiti hedeflenmiştir. Elde edilen etkili öznitelik sınıflandırma algoritmaları için giriş parametresi olarak kullanılmıştır. Sınıflandırma aşamasında 5 sınıflandırma algoritması kullanılmıştır. Değerlendirme aşamasında doğruluk oranı, duyarlılık, özgüllük ve karmaşıklık matrisinden yararlanılmıştır. Yapılan deneyler ve elde edilen sonuçların karşılaştırmalı analizleri aşağıda sunulmuştur.

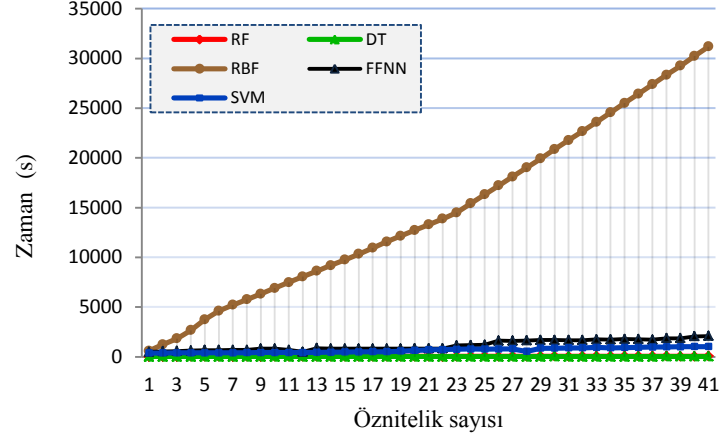
Deney 1: Fisher puanlama algoritması

Deney1 aşamasında öznitelik kümesine, etkili öznitelik seçme algoritmalarından Fisher puanlama algoritması uygulanmıştır. Fisher puanlama algoritmasının uygulanması ile elde edilen etkili özniteliklerin sıralaması sırasıyla şu şekildedir:

D5-1, PEn, D5-3, D3-3, MCL, PFD, D4-3, D5-2, MTE, D4-2, SD, HE, A5-4, A5-1, D4-1, A5-3, D3-2, MaxV, D3-1, MinV, HC, HM, V, ME, HA, ApEn, ZC, A5-2, SpEn, KT, SK, WV-4, D5-4, REn, MN, D4-4, WV-3, D3-4, WV-1, AO ve WV-2. Şekil 8.2’de Fisher puanlama algoritması ile belirlenen öznelik kümelerine ait sınıflandırma doğruluk oranları ve hesaplama zamanları görülmektedir.



a)



b)

Şekil 8.2. Deney 1’ in sonucunda seçilen özneliklerin sayısının artması ile sınıflandırma doğruluğu ve hesaplama zamanındaki değişimler.

Grafik 8.2-a incelendiğinde bazı algoritmalarda tek bir öznelik değeri ile bile yüksek sınıflandırma doğruluklarının elde edildiği görülmektedir. Bu seçilen öznelik kümelerinin etkili olduğu göstermektedir. Grafik incelendiğinde ilk 3 öznelik değerine sahip öznelik kümesinde; RF, DT ve RNN algoritmaları ile %80’nin üzerinde sınıflandırma doğrulukları elde edilmiştir. En iyi sonuçların RF

algoritması ile elde edildiği görülmektedir. Diğer algoritmalar incelendiğinde başarı yönüyle ilk 3 öznitelikte RNN algoritmasının daha etkili olduğu görülmektedir. İlk 3 öznitelik kümesinden sonra üstünlüğü DT algoritması almıştır. İlk 23 öznitelige kadar DT algoritmasının üstünlüğü devam etmiştir. 23 öznitelikten sonra üstünlüğü SVM algoritmasının aldığı görülmektedir. Genel olarak, en düşük başarıyı FFNN algoritması vermiştir.

Çizelge 8.1. Bulunan en iyi sonuçlara ait öznitelik sayıları ve doğruluk oranları.

Metot	Öznitelik sayısı	Sınıflandırma oranı (%)
RF	12	96.39
DT	38	93.30
RNN	20	89.25
FFNN	39	71.53
SVM	34	93.27


%96.39 doğruluk oranı ile belirlenen ilk 12 öznitelik değerine sahip öznitelik kümesinin RF algoritmasıyla kullanımı ile en yüksek doğrulukta sınıflandırma yaptığı belirlenmiştir (Çizelge 8.1). Bu öznitelikler sırasıyla şu şekildedir. D5-1, PEn, D5-3, D3-3, MCL, PFD, D4-3, D5-2, MTE, D4-2, SD ve HE. En iyi skor RF algoritmasından sonra sırasıyla C4.5, RNN, FFNN ve SVM algoritmaları ile elde edilmiştir.

Şekil 8.2-b incelendiğinde öznitelik sayısı arttıkça hesaplama zamanının arttığı görülmektedir. En hızlı çalışan algoritma DT algoritmasıdır. Genel olarak bu algoritmayı sırasıyla RF, SVM, FFNN ve RNN algoritmalarının takip ettiği görülmektedir. Hesaplama zamanı en yüksek olan algoritma RNN algoritmasıdır. Sinir ağı tabanlı algoritmaların yüksek hesaplama zamanlarına sahip olduğu görülmektedir.


Deney 2: mRMR öznitelik seçme algoritması

Deney 2 aşamasında etkili öznitelik seçme algoritmalarından mRMR öznitelik seçme algoritması uygulanmıştır. mRMR algoritmasının uygulanması ile elde edilen etkili özniteliklerin sıralaması sırasıyla şu şekildedir: PFD, 15 PEn, HE, D5-1, WV-1, AO, WV-2, WV-3, WV-4, MaxV, D4-1, D4-3, D5-2, D4-2, D5-4, MN, MinV, D5-3, D3-

3, D3-2, D3-1, MCL, A5-1, HC, SpEn, MTE, ME, HA, A5-2, ZC, V, SK, KT, A5-3, A5-4, SD, D3-4, ApEn, REn, D4-4 ve HM. Şekil 8.3’de mRMR algoritması ile belirlenen öznelik kümelerine ait sınıflandırma doğruluk oranları ve hesaplama zamanları görülmektedir.



a)



b)

Şekil 8.3. Deneysel 2'nin sonucunda seçilen özneliklerin sayısının artması ile sınıflandırma doğruluğu ve hesaplama zamanındaki değişimler.

Şekil 8.3-a incelendiğinde genel olarak ilk 5 öznelik değerine kadar sınıflandırma doğruluğunun düşük olduğu görülürken 5 ve üstü öznelik değerine sahip alt kümelerin bazılarında sınıflandırma doğruluk oranının %80'nin üzerinde olduğu gözlenmiştir. Başarı yönüyle ilk 5 öznelikte SVM algoritmasının daha etkili olduğu görülmektedir. İlk 3 öznelikten sonra üstünlüğü RF algoritması almıştır. Genel olarak, en iyi sonuçların RF algoritması ile elde edildiği görülmektedir. Diğer

algoritmalar incelendiğinde başarı sıralamasında RF algoritmasından sonra üstünlüğü ilk 20 öznitelige kadar DT ve RNN algoritmalarında olduğu görülmektedir. 20 öznitelikten sonra üstünlüğü SVM algoritmasının aldığı görülmektedir. En düşük başarıyı FFNN algoritması vermiştir.

Çizelge 8.2. Bulunan en iyi sonuçlara ait öznitelik sayıları ve doğruluk oranları.

Metot	Öznitelik sayısı	Sınıflandırma oranı (%)
RF	37	96.33
DT	24	92.32
RNN	37	89.36
FFNN	36	71.14
SVM	30	93.26


%96.33 doğruluk oranı ile belirlenen ilk 37 öznitelik değerine sahip öznitelik kümesinin, RF algoritmasıyla kullanımı ile en yüksek doğrulukta sınıflandırma yaptığı belirlenmiştir (Çizelge 8.2). Bu öznitelikler sırasıyla şu şekildedir: PFD, PEn, HE, D5-1, WV-1, AO, WV-2, WV-3, WV-4, MaxV, D4-1, D4-3, D5-2, D4-2, D5-4, MN, MinV, D5-3, D3-3, D3-2, D3-1, MCL, A5-1, HC, SpEn, MTE, ME, HA, A5-2, ZC, V, SK, KT, A5-3, A5-4, SD, D3-4.

Şekil 8.3-b incelendiğinde öznitelik sayısı arttıkça hesaplama zamanının arttığı görülmektedir. En hızlı çalışan algoritma DT algoritmasıdır. Bu algoritmayı sırasıyla RF, SVM, FFNN ve RNN algoritmalarının takip ettiği görülmektedir. Hesaplama zamanı en yüksek olan algoritma RNN algoritmasıdır. Sinir ağı tabanlı algoritmaların yüksek hesaplama zamanlarına sahip olduğu görülmektedir.

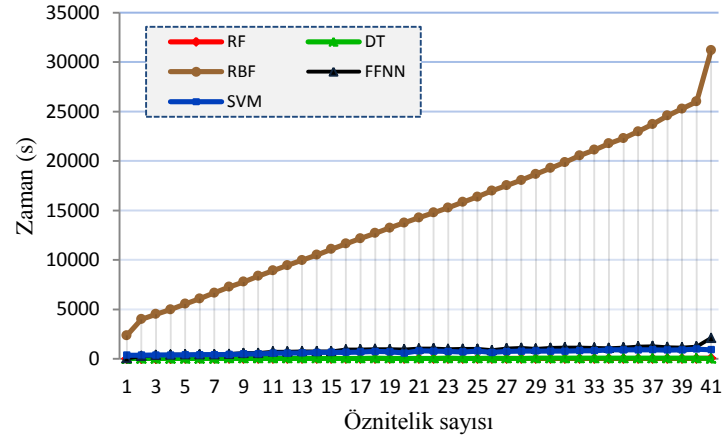
Deney 3: t-Test öznitelik seçme algoritması

Deney 3 aşamasında etkili öznitelik seçme algoritmalarından t-Test öznitelik seçme algoritması uygulanmıştır. T-Test algoritmasının uygulanması ile elde edilen etkili özniteliklerin sıralaması sırasıyla şu şekildedir: PFD, HM, WV-4, A5-4, D5-1, MaxV, HE, ZC, MTE, D4-4, SK, KT, SD, HC, MinV, REn, WV-1, D3-1, WV-3, V, SpEn, D4-1, ME, AO, MN, A5-1, D3-2, WV-2, D5-4, ApEn, A5-2, D3-4, D4-2, D5-2, A5-3, D3-3, D5-3, HA, PEn, D4-3, MCL. Şekil 8.4'de t-Test algoritması ile

belirlenen öznitelik kümelerine ait sınıflandırma doğruluk oranları ve hesaplama zamanları görülmektedir.



a)



b)

Şekil 8.4. Deney 3' un sonucunda seçilen özniteliklerin sayısının artması ile sınıflandırma doğruluğu ve hesaplama zamanındaki değişimler.

Grafik 8.4-a incelendiğinde genel olarak ilk 4 öznitelik değerine kadar sınıflandırma doğruluğunun düşük olduğu görülmektedir. 4 ve üstü öznitelik bilgisine sahip alt kümelerin bazılarında sınıflandırma doğruluk oranının %80'nin üzerine çıktığı görülmektedir. Başarı yönüyle ilk 4 öznitelikte DT algoritmasının daha etkili olduğu görülmektedir. İlk 4 öznitelikten sonra üstünlüğü RF algoritması almıştır. Genel olarak en iyi sonuçların RF algoritması ile elde edildiği görülmektedir. Başarı sıralamasında RF algoritmasından sonra ilk 23 özniteliğe kadar DT algoritmasının

etkili olduğu görülmektedir. 21 öznelikten sonra üstünlüğü SVM algoritmasının aldığı görülmektedir. En düşük başarıyı FFNN algoritması vermiştir.

Çizelge 8.3. Bulunan en iyi sonuçlara ait öznelik sayıları ve doğruluk oranları.



Metot	Öznelik sayısı	Sınıflandırma oranı (%)
RF	31	96.22
DT	39	92.73
RNN	37	89.36
FFNN	36	71.08
SVM	39	92.88

%96.22 doğruluk oranı ile belirlenen ilk 31 öznelik değerine sahip öznelik kümesinin RF algoritmasıyla kullanımı ile en yüksek doğrulukta sınıflandırma yaptığı belirlenmiştir (Çizelge 8.3). Bu öznelikler sırasıyla şu şekildedir: PFD, HM, WV-4, A5-4, D5-1, MaxV, HE, ZC, MTE, D4-4, SK, KH, SD, HC, MinV, REn, WV-1, D3-1, WV-3, V, SpEn, D4-1, ME, AO, MN, A5-1, D3-2, WV-2, D5-4, ApEn, A5-2.

Grafik 8.4-b incelendiğinde öznelik sayısı arttıkça hesaplama zamanının arttığı görülmektedir. En hızlı çalışan algoritmanın DT olduğu görülmektedir. Genel olarak, bu algoritmayı sırasıyla RF, SVM, FFNN ve RNN algoritmalarının takip ettiği görülmektedir. En yüksek hesaplama zamanına sahip algoritma RNN algoritması olmuştur. Sinir ağı tabanlı algoritmaların yüksek hesaplama zamanlarına sahip olduğu görülmektedir.

Deney 4: ReliefF öznelik seçme algoritması

Deney-4 aşamasında etkili öznelik seçme algoritmalarından ReliefF öznelik seçme algoritması uygulanmıştır. ReliefF algoritmasının uygulanması ile elde edilen etkili özneliklerin sıralaması sırasıyla şu şekildedir: PFD, HE, PEn, MaxV, D5-1, ZC, SK, MinV, SpEn, D5-4, D5-3, AO, D4-1, D5-2, MN, HC, KT, D4-3, REn, WV-3, WV-2, D3-1, WV-1, D4-2, D3-3, MCL, ApEn, A5-1, D3-2, MTE, A5-3, WV-4, A5-4, HM, SD, D4-4, A5-2, ME, HA, V, D3-4. Şekil 8.5’de ReliefF algoritması ile belirlenen öznelik kümelerine ait sınıflandırma doğruluk oranları ve hesaplama zamanları görülmektedir.



Şekil 8.5. Deney 4' ün sonucunda seçilen özniteliklerin sayısının artması ile sınıflandırma doğruluğu ve hesaplama zamanındaki değişimler.

Grafik 8.5-a incelendiğinde genel olarak ilk 3 öznitelik değerine kadar sınıflandırma doğruluğunun düşük olduğu görülmektedir. 3 ve üstü öznitelik bilgisine sahip alt kümelerin bazılarında sınıflandırma doğruluk oranının %80'nin üzerine çıktığı görülmektedir. Genel olarak en iyi sonuçların RF algoritması ile elde edildiği görülmektedir. Diğer algoritmalar incelendiğinde başarı yönüyle DT, RNN ve SVM algoritmalarının ön plana çıktığı görülmektedir. Özellikle 15 öznitelikten sonra SVM algoritmasının başarıları yüksek çıkmıştır. En düşük başarıyı FFNN algoritması vermiştir.

Çizelge 8.4. Bulunan en iyi sonuçlara ait öznitelik sayıları ve doğruluk oranları.

Metot	Öznitelik sayısı	Sınıflandırma oranı (%)
RF	32	96.22
DT	36	92.61
RNN	37	89.36
FFNN	38	71.49
SVM	26	93.12

%96.22 doğruluk oranı ile belirlenen ilk 32 öznitelik değerine sahip öznitelik kümesinin, RF algoritmasıyla kullanımı ile en yüksek doğrulukta sınıflandırma oranının elde edildiği görülmektedir (Çizelge 8.4). Bu öznitelikler sırasıyla şu şekildedir: PFD, HE, PEn, MaxV, D5-1, ZC, SK, MinV, SpEn, D5-4, D5-3, AO, D4-1, D5-2, MN, HC, KT, D4-3, REn, WV-3, WV-2, D3-1, WV-1, D4-2, D3-3, MCL, ApEn, A5-1, D3-2, MTE, A5-3, WV-4.

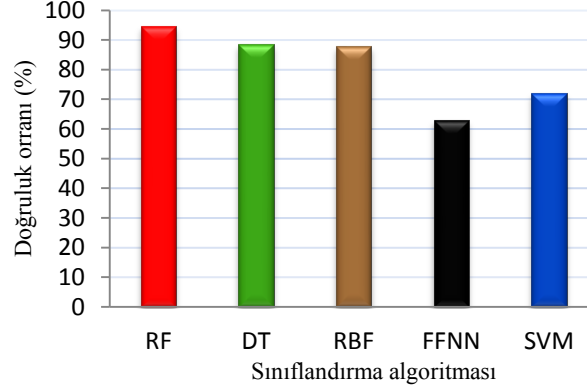
Grafik 8.5-b incelendiğinde en hızlı çalışan algoritmanın DT olduğu görülmektedir. Bu algoritmayı sırasıyla RF, SVM, FFNN ve RNN algoritmasının takip ettiği görülmektedir. En yüksek hesaplama zamanına sahip algoritma RNN algoritması olmuştur. Sinir ağı tabanlı algoritmaların yüksek hesaplama zamanlarına sahip olduğu görülmektedir.

Deney 5: FCBF öznitelik seçme algoritması


Deney-5 aşamasında etkili öznitelik seçme algoritmalarından FCBF öznitelik seçme algoritması uygulanmıştır. Bölüm 6.2.2.1 de bahsedildiği gibi FCBF algoritması eleme usulü çalışmaktadır. Bu nedenle bahsi geçen diğer öznitelik seçme algoritmalarından farklı olarak tek bir öznitelik kümesi elde edilmektedir. Bu algoritmanın uygulanması ile elde edilen etkili özniteliklerin sıralaması sırasıyla şu şekildedir: PFD, PEn, D3, D4, SK. Şekil 8.6'da FCBF algoritması ile belirlenen öznitelik kümesine ait sınıflandırma doğruluk oranları ve hesaplama zamanları görülmektedir.

Grafik incelendiğinde en iyi sonucun RF algoritması ile elde edildiği görülmektedir. %94.65 doğruluk oranı ile belirlenen 5 özniteliğin en yüksek doğrulukta sınıflandırma yaptığı belirlenmiştir. Başarılı sıralamasında RF algoritmasını sırasıyla

DT (%88.5), RNN (%87.92), SVM (%72.07) ve FFNN (%62.94) algoritmaları takip etmektedir.



a)



b)

Şekil 8.6. Deney 5 sonucunda seçilen öznelikler ile elde edilen sınıflandırma doğrulukları ve hesaplama zamanları.

Şekil 8.6-b incelendiğinde en hızlı çalışan algoritmanın DT olduğu görülmektedir. Bu algoritmayı sırasıyla RF, SVM, FFNN ve RNN algoritmasının takip ettiği görülmektedir. En yüksek hesaplama zamanına sahip algoritma RNN algoritması olmuştur. Sinir ağı tabanlı algoritmaların yüksek hesaplama zamanlarına sahip olduğu görülmektedir.

Genel Değerlendirme:


Sonuçlar incelendiğinde başarı sıralamasında en iyi algoritmanın RF algoritması olduğu görülmektedir. RF algoritmasını takiben SVM, DT ve RNN algoritmalarının

farklı öznitelik kümelerinde etkili sonuçlar verdiği görülmektedir. Hesaplama zamanının tespitinde farklı deneylerde birbirine yakın sonuçlara ulaşılmıştır. Hesaplama zamanı en düşük algoritma DT algoritması olmuştur. Genel olarak, bu algoritmayı sırasıyla RF, SVM, FFNN ve RNN algoritmalarının takip ettiği görülmektedir.

Çizelge 8.5. 5 farklı deney sonucunda elde edilen en iyi değerler.

Deney tipi	Öznitelik seçme algoritması	Sınıflandırma algoritması	Öznitelik sayısı	Doğruluk oranı (%)
Deney 1	Fisher puanlama	RF	12	96.39
Deney 2	mRMR	RF	37	96.33
Deney 3	t-test	RF	31	96.22
Deney 4	ReliefF	RF	32	96.22
Deney 5	FCBF	RF	5	94.65

En iyi sonuç Fisher skor algoritması ile elde edilen ilk 12 öznitelik değerinden oluşan öznitelik kümesi ve RF algoritmasının beraber kullanımı ile elde edilmiştir (Çizelge 8.5). Bulunan en iyi yöntemin performans değerlendirme kriterlerine göre başarısı değerlendirilmiştir (Bakınız Şekil 8.7, Çizelge 8.6). En yüksek sınıflandırma doğruluğu uyanıklık aşamasında gerçekleşmiştir. Bunu sırasıyla NREM-3, NREM-1, NREM-4, REM ve NREM-2 takip etmektedir. Diğer istatistiksel parametreler için de etkili sonuçların elde edildiği görülmektedir. Önerilen yöntem hem başarı hem de hız performansı yönüyle etkili sonuçlar vermiştir. Literatürde önemli bir problem olarak görülen NREM-3 ve NREM-4 aşamalarının karışması, önerilen yöntemle önemli ölçüde çözüme kavuşmuştur.



Şekil 8.7. Her uyku evresi için performans değerleri.

Çizelge 8.6. Önerilen metot ile manuel skorlamanın karşılaştırılması

		Uzman doktorun puanlaması						
Önerilen metot	Evreler	W	NREM1	NREM2	NREM3	NREM4	REM	Doğruluk(%)
	W	1109	0	0	0	0	0	100
	NREM1	0	860	24	13	0	0	95.8
	NREM2	0	29	929	25	5	0	94.02
	NREM3	0	10	12	1034	19	3	95.9
	NREM4	0	0	1	20	732	11	95.8
	REM	0	0	1	5	8	310	95.6
Toplam								96.39

Yukarıda belirtilen analizler çalışmanın başında bahsedildiği gibi Rechtschaffen and Kales (R&K) tarafından hazırlanan ölçütler dikkate alınarak oluşturulan sınıflandırma problemi için gerçekleştirilmiştir. Amerikan Uyku Tıbbi Akademisi (American Academy of Sleep Medicine, AASM) standartlarına göre önerilen metodun sınıflandırma başarısı üzerindeki etkisi de incelendi [97]. Dr. Iber Conrad'ın başkanlığında AASM, 2007 yılında uyku evreleri için yeni standartlar belirledi. Bu standartta N-REM 1, N-REM 2, N-REM 3 ve N-REM 4 evreleri sırasıyla S1, S2, S3 ve S4 olarak isimlendirildi. NREM-3 ve NREM-4 evrelerinin özellikleri çok benzer olduğu için, AASM bu aşamaları birleştirmiş ve SWS adıyla anılan yeni bir uyku evresi tanımlamıştır. Uyku evrelerindeki karmaşıklığı gidermek

ve sınıflandırma işlemini basitleştirmek için bu işlemler yapılmıştır. Bu çalışmada AASM standartlarına göre sınıflandırma işlemi tekrar edilmiştir. Bunun için veri seti uzman doktorun katkılarıyla tekrar düzenlenmiştir.

Elde edilen sonuçlara ait karışıklık matrisi tablosu ve her bir evrede elde edilen doğruluk oranları Çizelge 8.7’de görülmektedir.

Çizelge 8.7. Önerilen metot ile manuel skorlamanın karşılaştırılması.

Önerilen metot	Uzman doktorun puanlaması						Doğruluk (%)
	Evreler	W	S1	S2	SWS	REM	
W	1109	0	0	0	0	0	100
S1	0	873	13	11	0	0	97.3
S2	0	37	922	29	0	0	93.3
SWS	0	14	13	1802	13	0	97.8
REM	0	0	0	24	300	0	92.6
Toplam							97.01

Görüldüğü üzere AASM standartları dikkate alındığında % 97.01 doğruluk oranı elde edilmiştir. Bu değer R&K standartları dikkate alınarak elde edilen sonuçtan yüksek çıkmıştır. Bunun en önemli sebebi R&K standartlarındaki NREM seviyelerinin birbirine benzerliğidir. Bu benzerlikten dolayı sınıflandırma başarısı düşük çıkmaktadır. AASM de özellikle de S3 ve S4 evrelerinin birleştirilmesi daha iyi bir sonucun elde edilmesini sağlamıştır.

Çizelge 8.8’de literatürde yayınlanan son çalışmalar ve bu çalışmalarla önerdiğimiz metodun karşılaştırmalı analizi sunulmaktadır.

Çizelge 8.8. Uyku evrelerinin sınıflandırılması ile ilgili yapılan çalışmalar ve karşılaştırmalı analiz.

Yazarlar	Uyku evreleri	Çıkarılan öznelikler	Model	Doğruluk oranı
Šušmáková ve Krakovská [98]	W, S1, S2, SWS, REM	EEG, EMG, EOG ve ECG signalleri: Fraktal üs ve boyut.	Diskriminant Analizi	Hata Oranı: %23
Chapotot ve Becq [99]	W, geçiş uykusu (transitional sleep, N1), derin olmayan uyku (shallow sleep, N2), derin uyku (deep sleep, N3), REM, hareket zamanı (movement time, MT)	EEG signalleri: Shannon entropi, Hjorth aktivitesi, Hjorth hareketliliği, Hjorth karmaşıklığı, Hurst üsteli, izgesel köşe frekansı, ilişkisel güç (ing. relative power): delta, teta, alfa, sigma, beta ve gama, EMG signalleri: Shannon entropi, izgesel köşe frekansı, gama ilişkisel güç.	FFNN (geriye yayılım algoritması ile)	W: %34, N1: %43, N2: %51, N3: %82, REM: %82, MT: %13
Zoubek ve arkadaşları [100]	W, S1, S2, SWS, REM	EEG sinyalleri: Fourier dönüşümü katsayıları, EMG sinyalleri: Entropi, EOG sinyalleri: Entropi, basıklık değeri ve standart sapma.	FFNN (geriye yayılım algoritması ile)	%71 (EEG), %80 (EEG, EOG ve EMG): %84.57: W, %64.56: S1, %85.55: S2, %92.90: SWS, %72.81: REM
Tagluk ve arkadaşları [101]	REM, S1, S2, S3 ve S4	EEG sinyalleri: 0.3-50 Hz frekanslarında 5 sn'lik epoklar, EMG sinyalleri: 40-4000 Hz, LEOG ve REOG sinyalleri: 0.5-100 Hz.	FFNN (geriye yayılım algoritması ile)	%74.7
Sinha [49]	W, Uyku iççikleri, REM	EEG sinyalleri: Dalgacık dönüşüm katsayıları	FFNN (geriye yayılım algoritması ile)	%95.35
Fraiwan ve arkadaşları [102]	W, N-REM 1, N-REM 2, N-REM 3, N-REM 4, REM	EEG sinyalleri: Farklı frekans bantlarında zaman-frekans tabanlı öznelikler	Doğrusal discriminant analizi	%84
Subasi [43]	Uyanık, Uykulu, Uyku	EEG Sinyalleri: Dalgacık dönüşümü	FFNN (Levenberg–Marquardt algoritması ile)	%94.03
Ebrahimi ve arkadaşları [103]	W, S1, S2, SWS, REM	EEG Sinyalleri: Dalgacık dönüşüm katsayıları	FFNN (geriye yayılım algoritması ile)	%93
Doroshenkov ve arkadaşları [45]	W, N-REM 1, N-REM 2, N-REM 3, N-REM 4, REM	EEG Sinyalleri: Fourier dönüşümü	Saklı Markov modelleri	%92
Gunes ve arkadaşları [50]	W, N-REM 1, N-REM 2, N-REM 3, N-REM 4, REM	EEG Sinyalleri: Welch spektral analizi, k-means kümeleme tabanlı öznelik ağırlıklandırma	Karar ağaçları (C4.5)	%92.40
Önerilen metot	W, N-REM 1, N-REM 2, N-REM 3, N-REM 4, REM	EEG Sinyalleri: D5-1, PEn, D5-3, D3-3, MCL, PFD, D4-3, D5-2, MTE, D4-2, SD, HE	Rastgele Orman Algoritması	%96.39
Önerilen metot	W, S1, S2, SWS, REM	EEG Sinyalleri: D5-1, PEn, D5-3, D3-3, MCL, PFD, D4-3, D5-2, MTE, D4-2, SD, HE	Rastgele Orman Algoritması	%97.01

Çizelge 8.8 incelendiğinde 5 uyku evresini de içeren otomatik uyku evresi sınıflandırma uygulamalarının performansının genelde %70-93 aralığında olduğu görülecektir. %90 ve üzerinde uyum oranı elde eden çalışmaların bir çoğu ise evreleri 3-4 evreye genellemiş olan çalışmalardır. Bu durumda önerilen çalışmanın bu alana önemli bir katkısının olacağı öngörülmektedir.

Sonuçlar

Bu çalışmada; nörologlar için; EEG sinyallerini, yüksek doğruluk oranıyla kısa zamanda analiz edip, uyku evrelerinin sınıflandırılmasını otomatik olarak yapabilecekleri yeni hibrit modeller sunulmuştur. Çalışmanın dikkat çeken kısımları aşağıda sıralanmıştır.


1. Öznitelik seçme algoritmaları ile seçilen özniteliklerin performansa etkisi, tüm özniteliklerin kullanımına göre olumlu ve daha fazla olmuştur.
2. Literatürde EEG sınıflandırmaları ile ilgili çalışmalar incelendiğinde çok sayıda öznitelik çıkarma algoritmasının kullanıldığı görülmektedir. Fakat hangi özniteliklerin etkili olduğu önemli bir problem olarak görülmektedir. Çalışma bu yönüyle de büyük önem taşımaktadır. Bu konu üzerinde çalışan araştırmacılar için önemli bir rehber olacaktır. EEG sinyalleri dikkate alınarak yapılan tanılama ve skorlama çalışmaları (epilepsi teşhisi, anestezi derinliğinin tespiti, migren teşhisi v.b.) için de aynı yöntem tercih edilerek etkili öznitelikler saptanabilir.
3. Çalışma hem problemin temsili için kullanılan öznitelikler içerisinde en etkili özniteliklerin tespiti hem de seçilen popüler sınıflandırma algoritmalarından problemin sınıflandırılması için etkili olan algoritmanın tespiti yönüyle de farklı bir analiz sunmaktadır. Etkili özniteliklerin ve etkili sınıflandırma algoritmasının tespiti yüksek sınıflandırma doğruluğunun elde edilmesini sağlamıştır. Diğer biyomedikal işaretler içinde aynı yöntem izlenerek yüksek sınıflandırma doğruluğu elde edilebilir. Bu tarz çalışmalar ile özellikle “verilerimizi en iyi şekilde temsil edecek öznitelikleri elde etmek için hangi öznitelik algoritmasını kullanmalıyız” sorusuna etkili bir çözüm bulunabilir.

4. Bu çalışmada etkili öznitelikler, bahsi geçen 41 öznitelik parametresi içerisinde seçilmiştir. Kuşkusuz EEG verilerinin sınıflandırılmasında farklı özniteliklerden de yararlanılmaktadır. İleriki çalışmalarda öznitelik kümesinin daha da genişletilmesi ile kapsamlı bir çalışma hedeflenmektedir.

8.1.2. Uygulama 2: Sınıflandırma Algoritmaları ve FCBF Öznitelik Seçme Algoritmasını Kullanarak Otomatik Epilepsi Teşhisinin Gerçekleştirilmesi

Bu çalışma sınıflandırma algoritmaları ve FCBF öznitelik seçme algoritmasını kullanarak otomatik epilepsi teşhisi için yeni bir yaklaşım sunmaktadır. Çalışma EEG sinyallerinden öznitelik çıkarma, öznitelik seçme ve sınıflama aşamalarından oluşmaktadır. Öznitelik çıkarma aşamasında 5 kategoride 16 öznitelik algoritması kullanılmış ve bu algoritmalarından 36 adet öznitelik parametresi elde edilmiştir. Bu özniteliklere Çizelge 6.1'den erişilebilir. Öznitelik seçme aşamasında entropi tabanlı FCBF öznitelik seçme algoritması tercih edilmiştir. Bu şekilde EEG sinyallerini temsil edebilecek en iyi öznitelik kümesinin seçilmesi hedeflenmiştir. Elde edilen öznitelikler sınıflandırma algoritmaları için giriş parametresi olarak kullanılmıştır. Sınıflandırma aşamasında problem altı farklı sınıflandırma algoritması ile sınıflandırılmıştır. Bu şekilde farklı sınıflandırma algoritmaları ile elde edilen sonuçların hesaplama sürelerinin ve doğruluk oranlarının karşılaştırılması sağlanmıştır. Önerilen metot ile %100 sınıflandırma doğruluğuna erişilmiştir.

FCBF algoritması iki aşamadan oluşmaktadır. İlk olarak her bir öznitelik ile sınıf etiketleri arasındaki korelasyonu ölçmek için SU değerleri hesaplanır. Korelasyon değeri belli bir eşik değerine eşit ya da bu değerinin altında olan öznitelikler elenmektedir. Hesaplanan doğrusal olmayan korelasyon değerinin her zaman pozitif olması nedeniyle, eşik değerinin 0 olması durumunda, tüm öznitelikler, sınıf etiketleri ile en ilişkiliden en ilişkisize doğru sıralanmış olur. İlk aşamada elde edilen SU değerlerinin sıralanmış hali Şekil 8.8'de görülmektedir.



Şekil 8.8. FCBF algoritmasının ilk aşamasında elde edilen SU değerleri.

Sınıf etiketleri ile düşük korelasyona sahip özniteliklerin elenmesinin ardından, kalan öznitelikler arasından sınıf etiketleri ile en ilişkili olanlar kullanılarak artık öznitelikler saptanmaya çalışılır. Artıklık iki özniteliğin birbiriyle gereğinden fazla ilişkili olması ya da iki öznitelik arasındaki korelasyon değerinin yüksek olması olarak değerlendirilebilir [64]. Algoritmanın artık öznitelikleri eleme aşaması olan ikinci etap şu şekilde çalışmaktadır: Diyelim ki öznitelik 7'nin sınıf etiketleri ile korelasyonu öznitelik 8'den yüksektir. Eğer öznitelik 7 ile öznitelik 8 arasındaki korelasyon değeri, öznitelik 8 ile sınıf etiketleri vektörü arasındaki korelasyon değerinden yüksek ya da bu değere eşit ise öznitelik 8 artık bir öznitelik olarak tanımlanır ve öznitelik 7'nin varlığında öznitelik 8'ye gerek duyulmadığı için öznitelik kümesinden atılır [64]. Bu durum şu şekilde kodlanabilir. Eğer $SU_{i,j} \geq SU_{i,c}$ ise F_i özniteliği elenebilir. (burada $SU_{i,c}$ herhangi bir öznitelik ile sınıf arasındaki korelasyon değerini, $SU_{i,j}$ ise iki öznitelik arasındaki korelasyon değerini ifade etmektedir).

İki aşama sonucunda kalan öznitelikler, sınıf etiketleri ile en ilişkili, kendi aralarında ise en az artıklığa sahip öznitelik kümesi olarak değerlendirilmektedir.

FCBF algoritmasının diğer öznitelik seçme algoritmalarına göre en avantajlı yanlarından biri hızlı çalışmasıdır. Bir filtreleme yöntemi olan FCBF algoritması, öznitelikler ile sınıf etiketleri arasındaki ya da iki öznitelik arasındaki korelasyon değerlerini hesaplayarak bir özniteliğin sınıflandırmadaki değerine sınıflandırıcı

algoritmalarının sonucuna gerek duymadan saptayabilmektedir. Bu yönüyle sarmal öznelik seçme algoritmalarına göre hız açısından büyük avantaj sağlamaktadır [64].

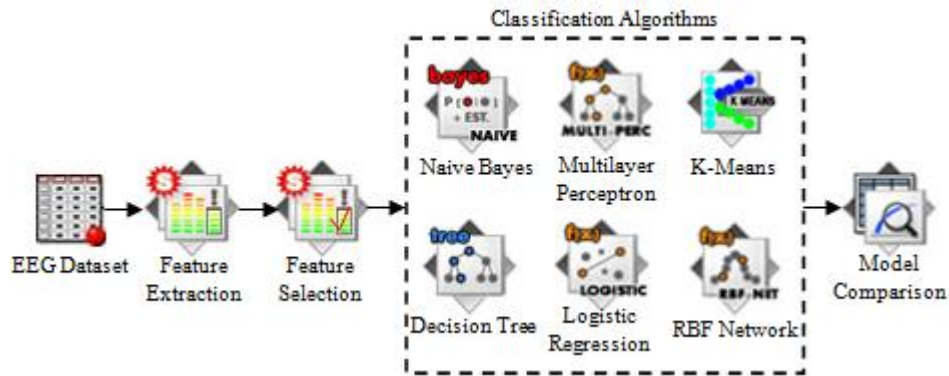
Bu çalışmada FCBF algoritmasının uygulanması ile 35 adet öznelikten en etkili 7 öznelik kümesi elde edilmiştir. Bu öznelikler Çizelge 8.9’da sunulmaktadır.

Çizelge 8.9. FCBF ile seçilen öznelikler.

Öznelik Numarası	Öznelikler
4	Standart sapma
10	Petrosian fraktal boyutu
12	Spektral entropi
21	D3-3
23	D4-1
37	Ortalama eğri uzunluğu
35	Hjorth hareketliliği

Uygulama ve değerlendirme


Bu çalışmada verilerin özneliklerinin çıkarılabilmesi için, Matlab R2009a’da, hem A veri seti (sağlıklı), hem de E veri seti (epileptik aktivite durumu) için 100*4096 boyutunda iki ayrı vektör matris oluşturulmuştur. Bu vektörlerden, 100*4096 boyutundaki A ve E veri setinin her bir sütunu için, Bölüm 6.2’de belirtilen 36 ayrı öznelik parametresi geliştirilen yazılımla elde edilmiştir. Bu öznelik kümesine FCBF öznelik seçme algoritmasını uygulandıktan sonra 36 tane öznelikten 7 tane öznelik kümesi elde edilmiştir. Çizelge 8.9’daki öznelik parametreleri sınıflandırma algoritmaları için giriş parametresi olarak kullanılmıştır. Karşılaştırma amaçlı geliştirilen sistemin mimarisi Şekil 8.9’da sunulmaktadır.



Şekil 8.9. Epileptik atak tespiti için önerilen metod.

Sonuçlar ve değerlendirme

Sağlıklı bireyler ile epilepsi hastalarından (A ve E) alınan EEG işaretlerinin sınıflandırılması 3 aşamada gerçekleştirilmiştir. Bunlar öznelik çıkarma, öznelik seçme ve sınıflandırma aşamalarıdır. Belirlenen performans değerlendirme kriterlerine göre elde edilen sonuçlar Çizelge 8.10'da görülmektedir. En iyi sonuçlar FFNN ve naive bayes algoritmaları ile elde edilmiştir. Sonuçta %100 sınıflandırma doğruluğu elde edilmiştir. Çalışmada ayrıca zaman parametresi de dikkate alınmış ve problemi en kısa zamanda sınıflandıran algoritmanın lojistik regresyon yöntemi olduğu gözlenmiştir. FFNN algoritmasında geri besleme adımlarından dolayı sınıflandırma süresi biraz daha fazla olmaktadır. Performans analizleri iki boyutta gerçekleştirilmiştir. İlk aşamada bütün öznelikler giriş parametresi olarak kullanılmış, ikinci aşamada ise FCBF algoritmasının uygulanması sonucu elde edilen öznelikler giriş parametresi olarak kullanılmıştır. Şekil 8.10 öznelik seçmeden ve seçtikten sonra elde edilen sonuçların karşılaştırmalı analizini sunmaktadır. Öznelik seçme aşamasından sonra elde edilen sonuçların daha iyi sonuçlar verdiği görülmektedir.



Şekil 8.10. Öznelik seçmeden önce ve sonraki aşamalarda sınıflandırıcıların performansları.

Bu çalışmadan elde edilen sonuçlar ile literatürde aynı veritabanı üzerinde yüksek doğruluk değerlerinin elde edildiği çalışmalar karşılaştırıldı. Bu karşılaştırmalı analizler Çizelge 8.10'da görülmektedir. Çizelge 8.10'da Guo ve arkadaşlarının sınıflandırma algoritması olarak FFNN, Polat ve arkadaşlarının ise karar ağacı algoritmalarını kullandıkları görülmektedir. Bizim çalışmamızda da aynı algoritmalar

kullanıldı. Aynı sınıflandırma algoritmalarının uygulanmasına rağmen, bizim çalışmamızdan daha yüksek bir sınıflandırma doğruluğu elde edildi. Bu farklılığın nedeninin, seçilen öznitelik seçme ve çıkarma algoritmalarından kaynaklandığı düşünülmektedir.

Çizelge 8.10. Epilepsi teşhisi için önerilen metotlar ile literatürdeki diğer çalışmaların karşılaştırmalı analizleri.

Yazarlar	Metot	Doğruluk
Fathima ve arkadaşları [104]	İstatiksel öznitelikler ve diskriminant analizi	% 96.90
Subaşı [105]	Ayrık dalgacık dönüşümü ve uzman modeller	% 95.00
Kannathal ve arkadaşları [27]	Entropi değerleri ve ANFIS	% 92.22
Srinivasan ve arkadaşları [22]	Zaman frekans tabanlı öznitelikler ve geri beslemeli sinir ağı	% 99.60
Guo ve arkadaşları [106]	Ayrık dalgacık dönüşümü, ilişkisel dalgacık dönüşümü ve FFNN	% 95.00
Nigam ve arkadaşları [23]	Lineer olmayan ön işleme filtresi ve YSA	% 97.20
Tzallas ve arkadaşları [30]	Zaman-frekans analizi ve YSA	% 100
Polat ve arkadaşları [31]	Hızlı Fourier dönüşümü ve karar ağacı (10 CV)	% 98.72
Kannathal ve arkadaşları [107]	Kaotik ölçütler ve data analizi	% 90.00
Önerilen metot	Çizelge 8.9'daki öznitelikler ve FFNN	% 100
Önerilen metot	Çizelge 8.9'daki öznitelikler ve karar ağacı (C4.5)	% 99.00
Önerilen metot	Çizelge 8.9'daki öznitelikler ve naive bayes	% 100
Önerilen metot	Çizelge 8.9'daki öznitelikler ve k-kümeleme (10 CV)	% 98.5
Önerilen metot	Çizelge 8.9'daki öznitelikler ve RBF	% 99.50
Önerilen metot	Çizelge 8.9'daki öznitelikler ve lojistik regresyon	% 99.00

Çizelge 8.10'da görüldüğü gibi Çizelge 8.9'daki öznitelikler ile FFNN ve Naive Bayes algoritmalarının beraber kullanımının iyi sonuçlar verdiği görülmektedir. Epilepsi teşhisi için önerilen modelin uzmanlara nihai karar açısından yardımcı olacağı öngörülmektedir.

Sonuçlar

Bu çalışmada; nörologlar için; EEG sinyallerini, yüksek doğruluk oranıyla kısa zamanda analiz edip, epileptik aktivite teşhisini otomatik olarak yapabilecekleri yeni hibrit modeller sunulmuştur. Çalışmanın dikkat çeken kısımları aşağıda sıralanmıştır.

1. FCBF algoritması ile seçilen özniteliklerin performansa etkisi, tüm özniteliklerin kullanımına göre olumlu ve daha fazla olmuştur. Bu algoritma

diğer tıbbi işaretlerin sınıflandırılması üzerinde uygulanabilir. Bu şekilde daha iyi performansların elde edilmesinde etkili olacak özniteliklerin seçilmesi gerçekleştirilebilir.

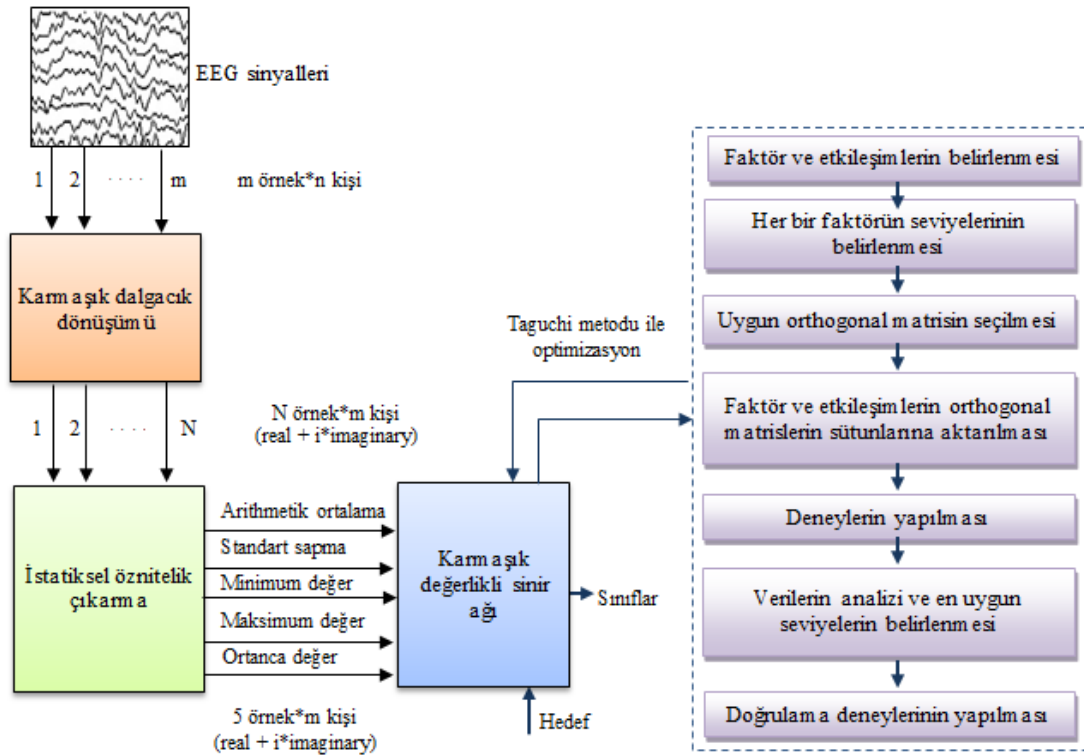
2. Bu uygulamada EEG işaretlerinin sınıflandırılmasında literatürde farklı problemlerin çözümünde kullanılan 6 tane sınıflandırma algoritması kullanılmıştır. Çalışmada sunulan yeni hibrit modellerden bazıları, sonuçları itibarı ile şu ana kadar yapılmış çalışmalara göre en iyi sonucu üretmiştir.
3. Literatürde EEG sınıflandırmaları ile ilgili çalışmalar incelendiğinde çok sayıda öznitelik çıkarma algoritmasının kullanıldığı, fakat hangi özniteliklerin daha etkili olduğuna yönelik bir çalışmanın yapılmadığı gözlenmiştir. Çalışma bu yönü ile de yeni bir algoritmik yaklaşım sunmaktadır.
4. Çalışma hem problemin temsili için kullanılan öznitelikler içerisinde en etkili özniteliklerin tespiti hem de seçilen altı popüler sınıflandırma algoritmalarından problemin sınıflandırılması için en etkili olan algoritmanın tespiti yönüyle de farklı bir analiz sunmaktadır.

8.2. YÖNTEM 2 İLE GERÇEKLEŞTİRİLEN ÇALIŞMALAR

8.2.1. Uygulama 1: Karmaşık Değerlikli Sınıflayıcılar ve Taguchi Yöntemini Kullanarak Otomatik Epilepsi Teşhisi İçin Yeni Bir Hibrit Yöntem

Bu uygulamada, EEG sinyallerinden epilepsi teşhisi için karmaşık sınıflayıcı tabanlı yeni bir metot sunulmaktadır. Öncelikle farklı seviyelerde IAKDD ile EEG verilerine ait özellikler çıkartılarak boyut azaltımı yapılmıştır. Sonraki aşamada bu özellik vektörleri kullanılarak istatistik tabanlı beş özellik (maksimum değer, minimum değer, ortalama değer, standart sapma, ortanca değer) elde edilerek KDYSA'ya giriş olarak sunulmuştur. Karmaşık değerli sinir ağında Taguchi yöntemiyle parametre optimizasyonu yapılarak daha kararlı bir modelin oluşturulması hedeflenmiştir.

Bu uygulama ile ilgili teorik bilgiler Bölüm 6.3’de sunulmuştur. Uygulamada tercih edilen veri seti hakkında bilgiler Bölüm 5.1’de sunulmaktadır. Bu uygulamada, EEG verilerinin sınıflandırılmasında IAKDD ve istatistiksel özellik çıkartma yöntemleri kullanılarak, KDYSA’ların veriminin artırılması amaçlanmıştır. Bu amaçla çalışmada önerilen yapıya ait blok gösterim Şekil 8.11’de verilmektedir. Bu yapıda verilerin özneliklerinin çıkarılabilmesi için, hem A veri seti (sağlıklı), hem de E veri seti (epileptik aktivite durumu) için 100×4096 boyutunda iki ayrı vektör matris oluşturulmuştur. Bu vektörlerden, 100×4096 boyutundaki A ve E veri setinin her bir sütunu için örnek sayıları öncelikle IAKDD’ nin farklı 3 seviyesi kullanılarak azaltılmıştır. Daha sonra, boyutu azaltılmış yeni veri setinin 5 adet istatistiksel özelliği elde edilerek KDYSA ile sınıflandırılmıştır. Uygulama aşamasında yapılan işlemler aşağıda sırasıyla sunulmaktadır.



Şekil 8.11. Epileptik atak tespiti için uygulanan metodun blok diyagramı.

Etkili Parametre Tespiti: Parametrelerin probleme özgü en uygun değerlerini bulmak için Taguchi kalite yöntemi kullanılmıştır. Karmaşık değerlikli sinir ağına etki eden parametrelerinin hangi değer aralıklarında daha etkin olduklarını oldukça az sayıda

deney yaparak belirlemek amacıyla Taguchi deney tasarımından yararlanılmıştır. Etkili değerleri tespit edilecek parametrelerle ilgili bilgiler Bölüm 6.2’de sunulmaktadır.

Çizelge 8.11’de alt ve üst sınır değerleri belirlenen parametreler beşer seviyeye ayrılmıştır. Faktörler için elde edilen seviye değerleri Çizelge 8.12’de sunulmaktadır. Bu çalışmada verilere 3 farklı seviyede (birinci, ikinci ve üçüncü seviye) IAKDD uygulandığı için giriş verileri farklı olan 3 problem karşımıza çıkmaktadır. Kolaylık olması açısından çalışmamızda bu 3 farklı problem için seviye değerleri dikkate alınarak sırasıyla IAKDD-KDYSA-1, IAKDD-KDYSA-2 ve IAKDD-KDYSA-3 denilmiştir.

Çizelge 8.11. Faktörlerin alt ve üst seviye değerleri.

Faktörler	Alt Limit	Üst Limit
<i>S</i>	1000	10000
<i>HN</i>	1	30
<i>L</i>	0.1	0.9
<i>M</i>	0.1	0.9
<i>HAF</i>	1	5

Çizelge 8.12. Taguchi deneyleri için faktörler ve onların seviye değerleri.

Faktörler	Seviye 1	Seviye 2	Seviye 3	Seviye 4	Seviye 5
<i>S</i>	1000	2500	5000	7500	10000
<i>HN</i>	1	5	10	20	30
<i>L</i>	0.1	0.3	0.5	0.7	0.9
<i>M</i>	0.1	0.3	0.5	0.7	0.9
<i>HAF</i>	1 (<i>karmaşık sigmoid</i>)	2 (<i>tanh</i>)	3 (<i>Haar Fonksiyonu</i>)	4 (<i>sech</i>)	5 (<i>Meksika şapkası</i>)

Klasik tam faktöriyel kullanılarak deney yapılması durumunda, 3 gözlem değeri için $3 \times (5^5) = 9375$ adet deneye ihtiyaç duyulurken, seçilen L25 dikey (orthogonal) dizin (beş parametre ve her parametrede beşer seviye) ile $3 \times (5 \times 5) = 75$ adet deney yapılması yeterli olmaktadır. Bu deneyler yukarıda belirttiğimiz 3 probleme uygulanmıştır. Bu durumda istenilen sonuca ulaşmak için uygulanması gereken deney sayısı $9375 \times 3 = 28125$ olurken, Taguchi metodu kullanıldığında bu değer $75 \times 3 = 225$ olacaktır. Bu da uygulanan yöntemin sağladığı katkıyı açıkça göstermektedir.

Dikey dizin ve ilgili parametre ile değer seviyelerinde Minitab programı [108] yardımıyla yapılan deneylerde elde edilen sonuçlar Çizelge 8.13’de sunulmaktadır. Çizelgede L25 ortogonal düzene göre oluşturulan *S*, *HN*, *L*, *M* ve *HAF* değerleri listelenmiştir. Ayrıca bu çizelgede parametrelerin probleme uygulanması sonucu elde edilen hata değerleri de sunulmaktadır. Deneylerin güvenilirliğini artırmak için deneyler üç defa tekrarlanmış ve 3 ayrı gözlem değeri elde edilmiştir. Elde edilen bu gözlem değerlerinin ortalaması kullanılmıştır. Gözlem değeri olarak sinir ağlarında güvenilir bir ölçme parametresi olan ortalama karesel hata karekökü (root mean square error, RMSE) değeri kullanılmıştır. RMSE, ölçüm değerleri ile model tahminleri arasındaki hata oranını belirlemek amacıyla kullanılmaktadır. RMSE değerinin sıfıra yaklaşması modelin tahmin kabiliyetinin artması anlamına gelmektedir. RMSE, Denklem 8.1’de görüldüğü gibi hesaplanmaktadır.

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (u - y)^2} \quad (8.1)$$

Burada *N* kayıt sayısı, *y* değeri *k* zamanında gerçekleşen değeri, *u* değeri *k* zamanı için tahmin edilen değeri ifade etmektedir.

Çizelge 8.13. Parametre aralık değerlerine bağlı olarak Taguchi metoduyla oluşan parametre değerleri ve deneylerden elde edilen sonuçlar.

Sıralama	<i>S</i>	<i>HN</i>	<i>L</i>	<i>M</i>	<i>HAF</i>	Gözlem değerlerinin ortalaması (RMSE değerleri)
1	1000	1	0.1	0.1	1	0.00042356009590937052
2	1000	5	0.3	0.3	2	0.00004106810446919054
.
.
12	5000	5	0.7	0.1	3	0.00002409265970643905
13	5000	10	0.9	0.3	4	0.00000000036883444491
.
.
24	10000	20	0.5	0.3	1	0.00000000000005849969
25	10000	30	0.7	0.5	2	0.00000042845614871178

Bölüm 6.3.3.2’de belirtildiği gibi Taguchi deney tasarımı yönteminde elde edilen deney sonuçları Sinyal/Gürültü (S/G) oranına dönüştürülerek değerlendirmeye alınmaktadır (Bakınız Çizelge 8.14). Bu tablo bize değişkenlerimizin önem sırasını

göstermekte ve en iyi sonuç için değişkenlerimizin hangi seviyelerinin kullanılması gerektiğini göstermektedir. S/G değerleri; KDYSA için RMSE değerinin en küçük olması istendiğinden, “smaller-is-better” formülü kullanılarak hesaplanmıştır. Her bir parametrenin en iyi seviye değeri, en yüksek S/G oranına sahip olan seviye değeridir. Örneğin; IAKDD-KDYSA-1 için yapılan analiz incelendiğinde *S* parametresi için en uygun değer Seviye-5 olduğu görülmektedir. Çizelge 8.12’de *S* parametresi için Seviye 5 değerine karşılık gelen gerçek değer 10000 olduğu görülmektedir. Dolayısıyla bu problem için *S* parametresinin en etkili değerinin 10000 olduğu görülmektedir.


Rank her problem için parametrelerin önem sırasını belirtir ve ana etki değerine bağlı olarak hesaplanır. S/G değerlerine göre her seviyenin etki değerleri Çizelge 8.14’de sunulmaktadır. Bu tabloda her problem için elde edilen rank sıralamalarını da görmek mümkündür. Örneğin; IAKDD-KDYSA-1 için yapılan analiz incelendiğinde en etkili parametrenin rank değeri 1 olan *HAF* olduğu görülmektedir.

Çizelge 8.14. Taguchi deney tasarımı yönteminde elde edilen Sinyal/Gürültü (S/G) oranları.


	Seviye	1	2	3	4	5	Ana Etki Değeri	Rank
IAKDD-KDYSA-1	<i>S</i>	78.54	129.36	131.00	124.55	152.23	73.69	3
	<i>HN</i>	68.61	146.02	135.28	116.25	149.53	80.92	2
	<i>L</i>	126.18	124.58	129.97	111.53	123.42	18.44	5
	<i>M</i>	104.86	129.84	136.22	139.00	105.76	34.14	4
	<i>HAF</i>	207.05	95.64	69.65	186.90	56.45	150.61	1
IAKDD-KDYSA-2	<i>S</i>	48.99	29.32	52.03	72.72	61.49	43.39	3
	<i>HN</i>	61.74	53.80	44.97	63.84	40.19	23.65	5
	<i>L</i>	52.95	56.19	49.84	65.25	40.31	24.94	4
	<i>M</i>	50.42	82.56	49.13	50.08	32.35	50.21	1
	<i>HAF</i>	68.25	35.57	26.53	65.62	68.56	42.02	2
IAKDD-KDYSA-3	<i>S</i>	45.35	37.69	79.88	112.96	107.85	75.27	2
	<i>HN</i>	67.88	81.88	61.39	93.38	79.20	31.99	4
	<i>L</i>	75.44	78.97	88.31	69.82	71.19	18.44	5
	<i>M</i>	65.54	109.53	100.32	70.13	38.22	71.31	3
	<i>HAF</i>	136.47	54.10	26.53	94.60	72.03	109.94	1

Çizelge 8.14’de görüldüğü gibi etkili parametrelerin sırası problemin türüne göre değişmektedir. Genel olarak *HAF*, *S* ve *M* parametrelerinin etkili olduğu

görülmektedir. L parametresinin etkisinin daha az olduğu görülmektedir. Şekil 8.12 incelendiğinde dikkat çeken kısımlardan birisi gizli katman aktivasyon fonksiyonu olarak karmaşık logaritmik sigmoid fonksiyonunun iyi sonuçlar verdiğidir. Ayrıca S/G değerlerine göre sech fonksiyonunun da etkili olduğu görülmektedir. Farklı olarak, IAKDD-KDYSA-2 için en etkili aktivasyon fonksiyonu olarak dalgacık aktivasyon fonksiyonu olan Meksika şapkası dalgacık aktivasyon fonksiyonunun etkili olduğu görülmektedir. Diğer parametrelerin etkileri ise probleme bağlı olarak değişmektedir.




(a)



(b)

Şekil 8.12. Parametre etkilerinin grafiksel gösterimi a) IAKDD-KDYSA-1 için b) IAKDD-KDYSA-2 için c) IAKDD-KDYSA-3 için.



(c)

Şekil 8.12. (devam ediyor).

Ayrıca Şekil 8.13’de, S/G değerleri göre parametrelerin etki değerlerini grafiksel olarak görmek de mümkündür. Çizelge 8.14 ve Şekil 8.12 dikkate alındığında S/G değerlerine göre en iyi parametre seti IAKDD-KDYSA-1 için *S5-HN5-L3-M4-HAF1*, IAKDD-KDYSA-2 için *S4-HN4-L4-M2-HAF5* ve IAKDD-KDYSA-3 için *S4-HN4-L3-M2-HAF1* olarak belirlenmiştir. Bu seviyelerin sahip olduğu gerçek değerler Çizelge 8.15’de sunulmaktadır.

Çizelge 8.15. IAKDD-KDYSA-1, IAKDD-KDYSA-2 ve IAKDD-KDYSA-3 modelleri için faktörlerin parametre optimizasyonu sonucunda elde edilen optimal değerleri.

Parametre	IAKDD- KDYSA-1	IAKDD- KDYSA-2	IAKDD- KDYSA-3
<i>S</i>	10000	7500	7500
<i>HN</i>	30	20	20
<i>L</i>	0.5	0.7	0.5
<i>M</i>	0.7	0.3	0.3
<i>HAF</i>	Karmaşık sigmoid	Meksika şapkası dalgacık fonksiyonu	Karmaşık sigmoid


DeneySEL Sonuçlar

Problemler, Intel(R) Core™ i7-2670QM 2.20 GHz mikro işlemcili ve 8 Gb Ram’li bir bilgisayarda çözülmüştür. KDYSA’nın parametre değerleri için Çizelge 8.15’deki parametre seti dikkate alınmıştır. Öncelikle bulunan en iyi parametre değerleri ile


elde edilen RMSE değerleri hesaplanmıştır. Bu değerler Çizelge 8.16’da sunulmaktadır. Ayrıca iterasyon değerine bağlı olarak değişen RMSE değer grafikleri Şekil 8.13’de sunulmaktadır.

Çizelge 8.16. Otomatik epilepsi teşhisi için karmaşık değerlikli yöntemler kullanarak (IAKDD+KDYSYA-1, IAKDD+KDYSYA-2 ve IAKDD+KDYSYA-3) elde edilen doğruluk oranı, özgüllük, duyarlılık ve RMSE değerleri.

	IAKDD+KDYSYA-1	IAKDD+KDYSYA-2	IAKDD+KDYSYA-3
Fold sayısı	10	10	10
Doğruluk	% 100	% 99.5	% 100
Duyarlık	% 100	% 99	% 100
Özgüllük	% 100	% 100	% 100
Hesaplama zamanı (sn)	45.6 s	40.2 s	30.9 s
RMSE	1.94×10^{-13}	6.19×10^{-4}	3.29×10^{-5}




a) IAKDD-KDYSYA-1



b) IAKDD-KDYSYA-2

Şekil 8.13. Bulunan en iyi parametre değerleri dikkate alınarak hesaplanan RMSE değerleri.



c) IAKDD-KDYSA-3

Şekil 8.13. (devam ediyor).

Çizelge 8.16’da performans değerlendirme kriterlerine göre elde edilen sonuçlar görülmektedir. Ortalama sınıflandırma doğruluk değerlerine göre en iyi sonuçlar IAKDD+KDYSAs-1 ve IAKDD+KDYSAs-3 algoritmaları ile elde edilmiştir. IAKDD+KDYSAs-1 ve IAKDD+KDYSAs-3 aynı doğruluk değerlerini vermelerine rağmen RMSE değerlerinin farklı olduğu görülmektedir. IAKDD+KDYSAs-1 yöntemi ile elde edilen RMSE değeri daha düşük çıkmıştır. Bu da elde edilen çıkış değerleri ile hedef çıktı değerlerinin birbirine daha yakın olmalarını ifade etmektedir. Bu yönüyle en etkili metodun IAKDD+KDYSAs-1 olduğu görülmektedir.

Güvenilir ve adil bir karşılaştırma için aynı veritabanı üzerinde gerçekleştirilen çalışmalar dikkate alınmıştır. Burada sadece Subaşı ve Erçelebi’nin [24] çalışmasında kullandıkları veritabanı farklıdır. Bu çalışmayı karşılaştırma tablosuna eklememizin sebebi önerdiğimiz metodun reel değerlikli versiyonunu kullanmalarındır. Bu şekilde reel değerlikli ve karmaşık değerlikli sınıflandırıcının başarıları kıyaslamak mümkün olmuştur. Literatürdeki çalışmalarla yapılan karşılaştırmalı analiz Çizelge 8.17’ de sunulmaktadır. Sonuçlar incelendiğinde önerilen metodun diğer çalışmalara göre iyi sonuçlar verdiği görülmektedir. %100 doğruluk oranı, bu çalışmada önerilen metod ve Tzallas ve arkadaşlarının önerdiği metod ile elde edilmiştir. Fakat performans kriterleri dikkate alındığında doğruluk oranlarının aynı çıkmasına rağmen iki çalışma arasında belirgin bir farklılık mevcuttur. Bu çalışmada test ve eğitim verilerinin tespitinde 10 farklı deneyin ortalamasını alan çapraz doğrulama yöntemi tercih edilmiştir. Tzallas ve arkadaşlarının çalışmasında ise %50-%50 prensibine dayanan hold-out metodunu

tercih edilmiştir. Yani rastgele olarak verilerin %50 sini eğitim, %50 sini test verisi olarak kullanmışlardır. Ve bu veriler ile elde ettikleri sonuçları rapor etmişlerdir. Hold-out metodu genellikle veri sayısının çok fazla olduğu durumlarda tercih edilmektedir. Bu çalışmada ve diğer biyomedikal alandaki birçok çalışmada veri sayısı genellikle sınırlıdır. Bu nedenle veri sayısının az olduğu çalışmalarda daha güvenilir ve geçerli sonuçlar için çapraz doğrulama metodunun kullanılması tavsiye edilir. Dolayısıyla daha sağlıklı bir karşılaştırma için bu bilginin de dikkate alınması gerekmektedir. Ayrıca duyarlılık ve özgüllük değerleri de incelendiğinde önerilen metodun iyi sonuçlar verdiği görülmektedir.

Subaşı and Erçelebi'nin [24] çalışması bu çalışmada önerilen metodun reel değerlikli versiyonudur. Bu nedenle analize bu çalışma da dahil edilmiştir. Subaşı and Erçelebi'nin çalışmalarında hesaplama zamanı ile ilgili bir bilgi verilmemiştir. Kompleks sınıflayıcıların zaman parametresi üzerinde de önemli etkilerinin olduğundan bahsedilmişti. Aynı veriler üzerinde reel değerlikli sınıflayıcılar ile önerdiğimiz karmaşık değerlikli sınıflayıcıların hesaplama zamanlarını karşılaştırmak için aynı deney tekrarlandı. Ve hesaplama zamanını karşılaştırmak için reel değerlikli dalgacık dönüşümü (ADD) ve YSA ile aynı veriler üzerinde deneyler gerçekleştirildi. Sinir ağı için bu çalışmada, geri yayımlı ileri beslemeli sinir ağı tercih edilmiştir. Dalgacık dönüşümü için birçok model denenmiştir. Bunların içinden en iyi sonuçlar veren 4. dereceden Daubechies dalgacığının kullanıldığı dalgacık dönüşümü olmuştur. Reel değerlikli ADD-YSA yapısının kullanılması durumunda 92.5% sınıflandırılma doğruluğu elde edilmiştir. Bulunan sonuç [24] numaralı çalışmada elde edilen sonuca yakın çıkmıştır. Ve hesaplama zamanı 126.4 sn. olarak belirlenmiştir. Hesaplama zamanı aynı problem için IAKDD+KDYSA-1 modelinin kullanılması durumunda 45.6 sn, IAKDD+KDYSA-2 modelinin kullanılması durumunda 40.2 sn ve IAKDD+KDYSA-3 modelinin kullanılması durumunda ise 30.9 sn olarak belirlenmiştir. Görüldüğü üzere hesaplama zamanı, IAKDD+KDYSA modellerinin kullanılması durumunda reel değerlikli sınıflayıcıya göre önemli ölçüde azalmıştır.

Çizelge 8.17. Literatürdeki diğer metotlarla karşılaştırmalı analiz.

Yazarlar	Metot	Veri Seçimi	Sonuçlar		
			Doğruluk Oranı	Duyarlılık	Özgüllük
Srinivasan ve arkadaşları [22]	Zaman-frekans tabanlı öznelikler ve geri beslemeli yapay sinir ağları	Hold out (%60 eğitim verisi, %40 test verisi)	%99.60	%99.4	%99.8
Subasi ve Ercelebi [24]	ADD ve YSA (geri yayımlı algoritma ile ileri beslemeli sinir ağı)	Hold out (%60 eğitim verisi, %40 test verisi)	%92	%91.6	%91.4
Subasi [25]	ADD ve uzman sistem (ing. mixture of expert model)	Hold out (%60 eğitim verisi, %40 test verisi)	%94.5	%95	%94
Kannathal ve arkadaşları [27]	Entropi ölçümleri ve ANFIS	Hold out (%60 eğitim verisi, %40 test verisi)	%92.22	Açıklanmamış	Açıklanmamış
Kannathal ve arkadaşları [107]	Kaotik ölçümler ve vekil veri analizi (ing. surrogate data analysis)	Açıklanmamış	%90.00	Açıklanmamış	Açıklanmamış
Tzallas ve arkadaşları [30]	Zaman frekans analizi ve YSA	Hold out (%50 eğitim verisi, %50 test verisi)	%100	%100	%100
Polat ve arkadaşları [31]	Hızlı Fourier dönüşümü ve YSA	10 kere çapraz doğrulama	%98.72	%99.4	%99.31
Acharya ve arkadaşları [109]	Dalgacık dönüşümü, temel bileşen analizi ve gauss karışım modeli	10 kere çapraz doğrulama	%99	%99	%99
Guo ve arkadaşları [106]	ADD, ilişkisel dalgacık analizi ve FFNN	Hold out (%50 eğitim verisi, %50 test verisi)	%95.20	%98.17	%92.12
Önerilen Çalışma	IAKDD+KDYSÄ -1	10 kere çapraz doğrulama	%100	%100	%100
Önerilen Çalışma	IAKDD+KDYSÄ -2	10 kere çapraz doğrulama	%99.5	%99	%100
Önerilen Çalışma	IAKDD+KDYSÄ -3	10 kere çapraz doğrulama	%100	%100	%100

IAKDD+KDYSYA-1, IAKDD+KDYSYA-2 ve IAKDD+KDYSYA-3 modellerinin hesaplama zamanları arasındaki farkın sebebi KDYSYA girişine uygulanan giriş örneklerinin sayısındaki değişimlerdir. Daha az girişe sahip IAKDD+KDYSYA-3 modelinin hesaplama zamanı en düşük çıkmıştır.

Bölüm 6.3.1 ve 6.3.2’de IAKDD ve KDYSYA modellerinin avantajlarından ayrı ayrı bahsedilmişti. Bu iki modelin birleşimi ile elde edilen IAKDD-KDYSYA hibrit modelinin sonuçlar itibarı ile hedeflenen başarıyı gösterdiği görülmektedir. EEG verilerinin sınıflandırılmasında ADD-YSA yaklaşımının etkili sonuçlar verdiği bilinmektedir [24]. Fakat çalışmanın başlarında bahsedildiği gibi sinyal işlemenin temelinde kompleks sayıların önemli roller oynadığı bilinmektedir. Bu fikirden hareketle bu çalışmada önerilen metot reel değerlikli ADD-YSA modelinden hem doğruluk oranı hem de hesaplama zamanı olarak daha iyi sonuçlar vermiştir. Ayrıca şunu da belirtmek gerekir ki; bu metodun dışında başka metotlarla da yüksek sınıflandırma doğrulukları elde edilebilir. Mutlaka yüksek doğruluk değerleri elde etmeye çalışan araştırmacılar vardır. Fakat bu çalışmada yüksek doğruluk değerlerinin elde edilmesiyle beraber önemli olan bir noktanın da ilk defa EEG verileri üzerinde tamamen karmaşık değerlikli metotların uygulanması ve başarılı sonuçların elde edilmesidir. Bu yönüyle de bu çalışmanın bu alanda araştırma yapacak olanlar için iyi bir rehber olacağı öngörülmektedir.

Makalede uygulanan bütün yöntemler ve aşamalar detaylı bir şekilde sunulmuştur. Bu, ‘karmaşık ve hesaplama yükü fazla’ olan bir yöntemin uygulandığını düşünebilir. Fakat uygulanan yöntemin Çizelge 8.17’de sunulan yöntemlerden basitlik ve hesapsal yük açısından ciddi bir farkı bulunmamaktadır. Önerilen yöntem Çizelge 8.17’de sunulan çalışmalardaki gibi 2 aşamalıdır. Öznitelik elde etme ve sınıflandırma. Uygulanan parametre optimizasyonu ek bir işlem değildir. Başlangıç aşamasında parametre değerlerini belirlemek amacıyla kullanılmıştır. Önerilen yöntemin diğer çalışmalardan farkı reel değerler yerine karmaşık sayıların kullanılmasıdır. Karmaşık sayılar ise matematiksel bir yük getirmemektedir. Bölüm 6.3.2’de sunulduğu gibi sinyal işlemenin temelinde karmaşık sayıların yattığı bilinmektedir. Dolayısıyla karmaşık sayıların kullanımı sinyal işleme için daha doğal bir çözüm yolu sunmaktadır. Hesaplama zamanı incelendiğinde karmaşık değerlikli

sınıflandırıcının, reel değerlikli sınıflandırıcıya göre daha hızlı bir sınıflandırma yaptığı görülmektedir. Sonuç olarak uygulanan yöntem, hesaplama yükü az ve hızlı bir yöntemdir.

Sonuçlar

Bu çalışmada; nörologlar için; EEG sinyallerini, yüksek doğruluk oranıyla kısa zamanda analiz edip, epileptik aktivite teşhisini otomatik olarak yapabilecekleri yeni hibrit modeller sunulmuştur. Çalışmanın dikkat çeken kısımları aşağıda sıralanmıştır.

EEG verilerinin yüksek doğruluk değerlerinde sınıflandırılmasında karmaşık değerli yöntemlerin etkisi yüksek olmuştur. Farklı biyomedikal sinyal işleme alanlarında aynı yöntemlerle yüksek doğruluk oranları elde edilebilir.

Çalışmanın dikkat çeken kısımlarından biri sistem performansını önemli ölçüde etkileyen parametre optimizasyonu olmuştur. Karmaşık değerli sinir ağlarında parametre optimizasyonu için Taguchi yönteminin kullanıldığı sistemde, daha az deney, zaman ve maliyet tasarrufu sağlanabileceği görülmüştür. Bu yöntemle bahsi geçen 3 farklı problem için tam faktöriyel tasarımı kullanılması durumunda 28125 denemede bulunabilecek en iyi parametre seti 225 deneme ile tespit edilmiştir.

Çalışmada karmaşık değerli dalgacık dönüşümünün farklı seviyelerinin sonuca etkileri araştırılmış ve çok sayıda istatistiksel analiz metodu kullanılarak karşılaştırmalı analizler sunulmuştur.

Değerlendirme sonuçlarını incelendiğinde sonuçların elde edilmesinde gereken süre bilgisi verilmiştir. Algoritmanın hızlı bir sonuçlandırma verdiği görülse de; ileriki çalışmalarda, sistemi grafik işlemciler üzerinde gerçekleştirerek bu süreyi daha da minimize etmek hedeflenmektedir. Bunun için özellikle yeni bir teknoloji olan CUDA paralel işlemci mimarisinden yararlanılacaktır.

İleriki çalışmalarda optimizasyonu yapılan parametrelerin sayısının artırılması hedeflenmektedir. Eklenmesi planlanan parametreler sırasıyla gizli katman sayısı,

hata fonksiyonu ve çıkış katmanı aktivasyon fonksiyonudur. Bu şekilde daha optimize bir çalışma hedeflenmektedir.

Uygulanan yöntemin başarısını tespit etmek amacıyla, önceki çalışmalarda tercih edilen veri seti kullanılmıştır. İleriki çalışmalarda daha büyük ve sürekli verilerden oluşan EEG verilerine, bu yöntemin uygulanması hedeflenmektedir.

8.2.2. Uygulama 2: EEG Sinyallerini Kullanarak Otomatik Epilepsi Teşhisi İçin Yeni Bir Karmaşık Değerlikli Akıllı Sistem

Çalışmanın Özeti

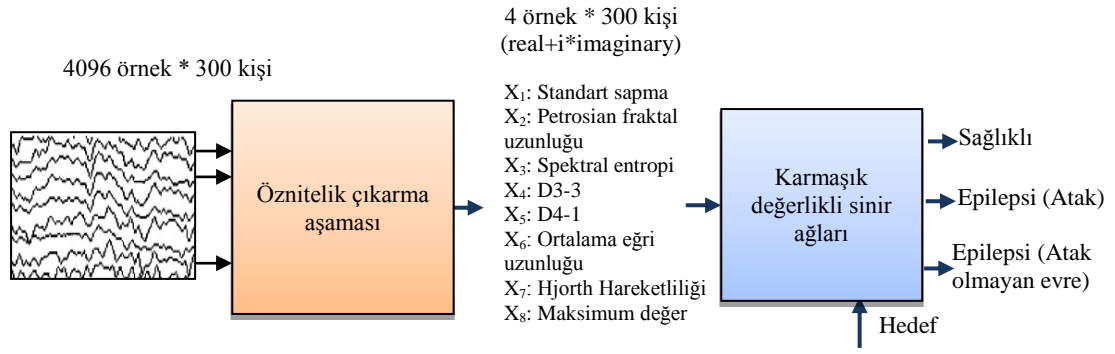
Bu çalışmada karmaşık sınıflandırma metotlarından yararlanılarak EEG sinyallerinden epilepsi tanısı için yeni bir metot önerilmektedir. Öncelikle EEG sinyallerinden anlamlı bilginin tespiti için 8 etkili öznitelik çıkarma algoritması kullanılmıştır. Sonraki aşamada her EEG sinyali için elde edilen 8 öznitelik değeri karmaşık değerlikli sinir ağına giriş olarak sunulmuştur. İki farklı sınıflandırma deneyi geliştirilen model kullanılarak gerçekleştirilmiştir: 1) Bölüm 5.1’de açıklanan A, B ve C sınıfları, 2) Bölüm 5.1’de açıklanan A ve B sınıfları. Önerilen yaklaşım EEG işaretlerini ilk deneyde % 99.60, ikinci deneyde % 100 doğrulukla sınıflandırmıştır. Sonuçlar önerilen metodun, yeni bir akıllı yardımcı tanı sistemi olabileceğini gösteriyor.

Önerilen Yöntem

Biyomedikal sinyal işlemede önemli sorunlardan biri karmaşık ve yoğun miktarda bilgi taşıyan sinyallerden anlamlı ve kısa bilginin tespitini sağlamaktır. Özellikle de durağan olmayan ve gürültülerden dolayı karmaşık bir yapıya sahip olan EEG sinyallerinden anlamlı bilginin tespiti önemli ve zor bir aşamadır. Bu aşamada 3 nolu referansta belirtilen çalışmada önerilen öznitelikler tercih edilmiştir. 3 nolu çalışmada literatürde EEG sinyallerinden öznitelik tespiti amacıyla yaygın kullanılan 36 öznitelik parametresi elde edilmiştir. Bu özniteliklerden etkili olanların tespiti amacıyla öznitelikler arası ilişki ve artıklık değerlerini temel alan etkili bir öznitelik seçme algoritması olan FCBF algoritmasından yararlanılmıştır. Öznitelik seçme aşamasından sonra 7 etkili öznitelik parametresi elde edilmiştir. Araştırmacılar bu


öznitelikleri popüler sınıflandırma algoritmalarına giriş olarak sunmuş ve yüksek sınıflandırma doğrulukları elde etmişlerdir. Bu çalışmada 3 no'lu kaynaktaki çalışmadan farklı olarak deney sayısı arttırılmış ve sınıflandırma aşamasında literatürde EEG sinyallerine yönelik herhangi bir uygulamasına rastlanılmayan KDYSA algoritması kullanılmıştır. KDYSA için girişte 2 gerçek değerden bir karmaşık değer elde edilerek giriş kümesi oluşturulmuştur. Bu durum detaylı bir şekilde Bölüm 6.3.3.2 de sunulmaktadır. 2 gerçek değerden 1 karmaşık giriş vektörü elde edildiği için 7 öznitelik parametresi bu çalışma için yeterli görülmemiştir. 8. öznitelik parametresi olarak etkili bir istatistiksel öznitelik algoritması olan “maksimum değer” tercih edilmiştir. Sonuç olarak bu çalışmada sınıflandırıcının girişine sunulmak üzere 8 etkili öznitelik parametresi kullanılmıştır. Bu parametreler sırasıyla X_1 =Standart Sapma (SD), X_2 =Petrosian fraktal uzunluğu (PFD), X_3 =Spektral entropi (SpEn), X_4 =D3-3, X_5 =D4-1, X_6 =Ortalama eğri uzunluğu (CL), X_7 =Hjorth hareketliliği (HM), X_8 =Maksimum değer parametreleridir. D3-3 ve D4-1 değerleri dalgacık dönüşümü ile ilgilidir. Bu değerler EEG sinyaline 4.dereceden dalgacık dönüşümü uygulanması sonucu elde edilmiştir. D3-3 elde edilen alt bantlardan D3 alt bandındaki katsayı değerlerinin standart sapması, D4-1 ise elde edilen alt bantlardan D4 alt bandındaki katsayı değerlerinin mutlak değerlerinin ortalamasını ifade etmektedir. Bu algoritmalar hakkında kapsamlı bilgilere 3 no' lu kaynaktan ulaşılabilir.

Uygulama ve değerlendirme: Bu çalışmada, EEG verilerinin sınıflandırılmasında etkili öznitelik parametreleri ile KDYSA birlikte kullanılarak yüksek doğruluk değerlerinin elde edilmesi amaçlanmıştır. Bu amaçla çalışmada önerilen yapıya ait blok gösterim Şekil 8.14'de verilmektedir. Bu yapıda verilerin özniteliklerinin çıkarılabilmesi için A, D ve E veri setleri için 100*4096 boyutunda üç ayrı vektör matris oluşturulmuştur. Bu vektör matrislerindeki örnek sayıları, bahsi geçen öznitelikler kullanılarak azaltılmıştır. Daha sonra, bu öznitelikler sınıflayıcı girişine sunularak, sınıflandırma işleminin gerçekleştirilmesi sağlanmıştır.



Şekil 8.14. Epileptik atak tespiti için önerilen yöntem.

Geliştirilen modelde KDYSA'nın parametre değerleri deneme yanılma yöntemi ile belirlenmiştir. Buna göre en iyi sonuçları veren parametre değerleri sırasıyla; iterasyon değeri=7500, gizli katman ve çıkış katmanı aktivasyon fonksiyonu= kompleks sigmoid, öğrenme katsayısı=0.7 ve momentum katsayısı=0.3 olarak belirlenmiştir. Şekil 8.15-a ve 8.15-b'de KDYSA algoritmasının uygulanması sonucu elde edilen çıktı değerlerinin grafiksel sunumu görülmektedir. Şekil 8.15-a'da Deneysel 1'in fold 1 aşamasında elde edilen sonuçlar, Şekil 8.15-b'de ise Deneysel 2'nin fold 10 aşamasında elde edilen sonuçlar görülmektedir. Her sınıftan 10 örnek verilmiştir. Şekil 8.15-a ve Şekil 8.15-b'den de görüldüğü gibi problemin başarılı bir şekilde sınıflandırıldığı görülmektedir. Belirlenen performans değerlendirme kriterlerine göre elde edilen sonuçlar Çizelge 8.18'de görülmektedir. Veri dağılım yöntemi olarak 10-kere çapraz doğrulama yöntemi tercih edilmiştir. Her deney 5 defa tekrar edilmiş ve elde edilen değerlerin ortalaması hesaplanmıştır. Belirlenen performans değerlendirme kriterlerine göre elde edilen sonuçlar Çizelge 8.18'de görülmektedir.



Şekil 8.15. Grafiksel sonuçlar a) Deneysel 1'in fold 1 aşamasında elde edilen sonuçlar (Doğruluk Oranı: 100 %) b) Deneysel 2'nin fold 10 aşamasında elde edilen sonuçlar (Doğruluk Oranı: 100 %).

Çizelge 8.18. 10-kere çapraz doğrulama sonucu elde edilen istatistiki performans değerleri.

Deney	Doğruluk Değeri (%)	Özgüllük (%)	Duyarlılık (%)
A-E	%100	%100	%100
A-D-E	%97.01	%97.0	%96.0 atak yokken epilepsi hastaları için %98.0 atak esnasında epilepsi hastaları için

Aynı veri seti üzerinde daha önce yapılan çalışmalarla bir karşılaştırma yapıldı. Karşılaştırmalı analiz Çizelge 8.19'da görülmektedir. Çizelgeden de görüldüğü gibi önerilen metot iyi sonuçlar vermiştir.

Çizelge 8.19. Epileptik atak tespiti için diğer araştırmacıların elde ettikleri sonuçlarla karşılaştırmalı analiz.

Yazarlar	Metot	Veri Seti	Doğruluk
Subaşı [105]	Dalgacık dönüşümü ve uzman model karışımı	A, E	% 95.00
Orhan ve ark. [33]	Dalgacık dönüşümü ve k-en yakın komşu algoritması	A, E	% 100
Guo ve ark. [106]	Genetik algoritma tabanlı öznitelikler ve k-en yakın komşu algoritması	A, E	% 99.20
Polat ve ark. [31]	Hızlı Fourier dönüşümü ve karar ağacı	A, E	% 98.72
Kannathal ve ark. [107]	Kaotik ölçütler ve vekil veri analizi	A, E	% 90.00
Önerilen metot	Karmaşık değerlikli öznitelikler ve KDYSA	A, E	% 100
Orhan ve ark. [33]	Dalgacık Dönüşümü, k-en yakın komşu algoritması ve ileri beslemeli sinir ağı	A, D, E	% 96.67
Guo ve ark. [106]	Genetik algoritma tabanlı öznitelikler ve k-en yakın komşu algoritması	A, D, E	% 93.5
Önerilen metot	Karmaşık değerlikli öznitelikler ve KDYSA	A, D, E	% 97.01

Sonuçlar

1. EEG verilerinin yüksek doğruluk değerlerinde sınıflandırılmasında karmaşık değerli yöntemlerin etkisi yüksek olmuştur.
2. Literatürde EEG sınıflandırmaları ile ilgili çalışmalar incelendiğinde çok sayıda öznitelik çıkarma algoritmasının kullanıldığı, fakat hangi özniteliklerin daha etkili olduğuna yönelik bir çalışmanın yapılmadığı gözlenmiştir. Bu çalışmada elde edilen sonuçlar 3 nolu çalışmada önerilen yaklaşımı desteklemektedir. Etkili öznitelik tespitine yönelik gerçekleştirilmiş bu çalışma epilepsi teşhisine yönelik araştırmalar için büyük önem taşımaktadır.

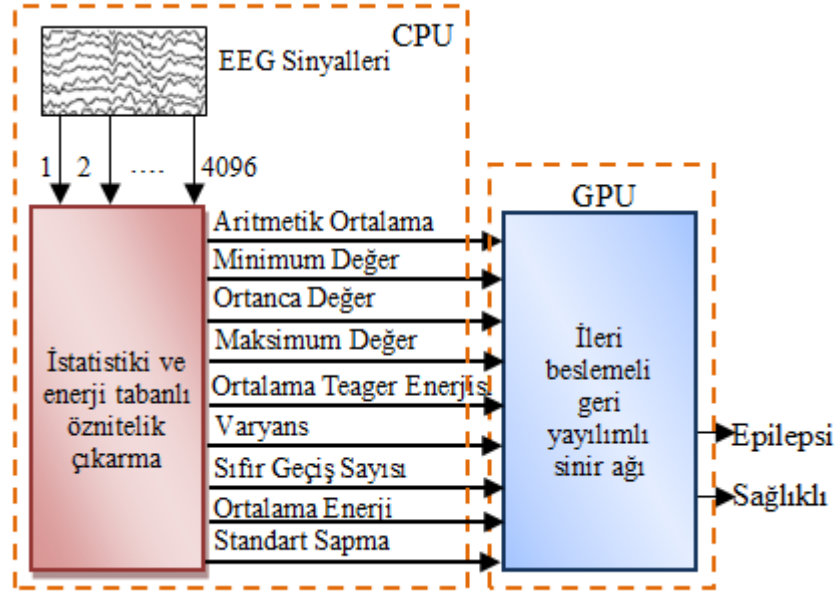
8.3. YÖNTEM 3 İLE GERÇEKLEŞTİRİLEN ÇALIŞMALAR

8.3.1. Uygulama 1: CuEEG: EEG Verilerinin Hızlı İşlenmesi için GPU Tabanlı Bir Yaklaşım

Bu çalışmada EEG verilerinin sınıflandırılmasına yönelik paralel hesaplama tabanlı bir yaklaşım sunulmaktadır. Bu yaklaşımın dikkate aldığı kriter hız parametresidir. Şimdiye dek gerek epilepsi teşhisi gerekse EEG verilerinin sınıflandırılmasına yönelik yapılmış birçok çalışma sınıflandırma doğruluğunu iyileştirmeye yönelik olarak gerçekleştirilmiştir. Bu çalışmada özellikle gerçek zamanlı uygulamalarda bir vazgeçilmez olan hız parametresi dikkate alınmakta ve EEG verilerinin hızlı bir şekilde sınıflandırılması için farklı bir yaklaşım sunulmaktadır. Bunun için özellikle son yıllarda popüleritesi gittikçe artan grafik işlemciler üzerinde programlama yapmamızı sağlayan CUDA programlamadan yararlanılmıştır. Grafik işlemcilerden sınıflandırma aşamasında yararlanılmıştır. Sınıflandırma algoritması olarak EEG verilerinin sınıflandırılmasında yüksek doğruluk oranı veren geri yayımlı sinir ağı tercih edilmiştir. Bu çalışmada epileptik nöbet tespiti için kullanılan bir veri tabanı üzerinde deneyler gerçekleştirilmiştir. Sonuçlar incelendiğinde CUDA programlamanın sonuçlar üzerinde olumlu etkilerinin olduğu görülmüştür. Bu şekilde sadece EEG verilerine yönelik değil diğer biyomedikal işaretlerin sınıflandırılmasında da grafik işlemciler kullanılarak gerçek zamanlı uygulamalara yönelik hızlı bir sistemin altyapısı oluşturulabilir.

Uygulama ve Değerlendirme

Bu uygulamada Bölüm 5.1'de açıklanan EEG veri tabanı kullanılmıştır. Bu uygulamada EEG verilerinin sınıflandırılması için önerilen yapıya ait blok gösterim Şekil 8.16'da verilmektedir. Bu yapıda verilerin özniteliklerinin çıkarılabilmesi için hem A veri seti (sağlıklı), hem de E veri seti (epileptik aktivite durumu) için 100*4096 boyutunda iki ayrı vektör matris oluşturulmuştur. Bu vektörlerden, 100*4096 boyutundaki A ve E veri setinin her bir sütunu için 9 adet öznitelik parametresi elde edilerek geri yayımlı sinir ağı ile sınıflandırılmıştır.



Şekil 8.16. Epileptik atak tespiti için önerilen yöntem.

CUDA Tabanlı Sinir Ağı'nın Gerçekleştirimi: Sinir ağı uygulaması CUDA tarafından uygulanan bir seri matris çarpımı ve aktivasyon fonksiyonu uygulaması olarak gerçekleştirilebilir. CUDA blok başına paylaşılan hafızayı (ing. shared memory) kullanarak matris çarpımını etkin şekilde işleyebilmektedir. Uygulamalarda paylaşımlı bellek verimi önemli oranda artıracaktır. Örnek verilirse; GPU genel işlemlerinde global hafızaya erişim için yaklaşık olarak 400-600 döngü gerekliyse, CUDA'nın hafıza ortamında paylaşılan hafızaya erişimi için sadece 4 döngü yeterli olmaktadır. Bu nedenle CUDA'nın paylaşımlı hafızası işlemlerin etkin yürütülmesi için yardımcı olmaktadır. Ayrıca matrisin eleman sayısına eşit sayıda dizin (ing. thread) sağlayarak ve daha sonra da her bir dizinde işlemleri bağımsız olarak hesaplayarak aktivasyon fonksiyonlar da paralel olarak uygulanabilir.

Şekil 8.17'de CUDA üzerinde gerçekleştirilen sinir ağı'nın ileriye doğru hesaplama adımlarından bir kısmının matris işlemleri sunulmaktadır. Şekil incelendiğinde, sinir ağlarının paralel işlemeye müsait bir yapısının olduğu görülecektir.

Geri yayımlı sinir ağı algoritmasının paralel uygulaması, verilerin GPU' da matris ve vektör işlemlerinin uygulanmasından ibarettir. Bu çalışmada iki tür paralel işlem mevcuttur: matris işlemleri ve aritmetik işlemler. Matris işlemlerine örnek olarak

giriş deęerleri ile giriş ve gizli katman deęerleri arasındaki aęırlık deęerlerinin çarpımı verilebilir. Aritmetik işlemlere de örnek olarak sigmoid fonksiyonu ve aęırlık güncellemeleri verilebilir. Bu çalışmada ilk aşamada yani matris işlemleri için CUDA temel lineer cebir altyordamları (CUDA Basic Linear Algebra Subroutines, CUBLAS) kütüphanesi tercih edilmiştir. CUBLAS optimum paralellığe uygun yapılandırılmış bir seri algoritma sunduğundan, bloklar ve dizinlerin tanımlanması problem teşkil etmemektedir. İkinci aşamada yani aritmetik işlemler için ise çekirdek (ing. kernel) tanımlanarak paralellığın gerçekleştirilmesi sağlanmıştır. Burada kernel, GPU üzerinde çalışan fonksiyona verilen isimdir. Bu iki aşama ile ilgili bazı örnekler aşağıda sunulmaktadır.

Matris çarpım işlemlerinde CUBLAS fonksiyonlarından “cublasSgemm” fonksiyonu kullanılmıştır. Örnek bir kullanım aşağıda sunulmaktadır.

‘cublasSgemm (char transa, char transb, int m, int n,int k, float alpha, const float *A, int lda,const float *B, int ldb, float beta,float *C, int ldc)’

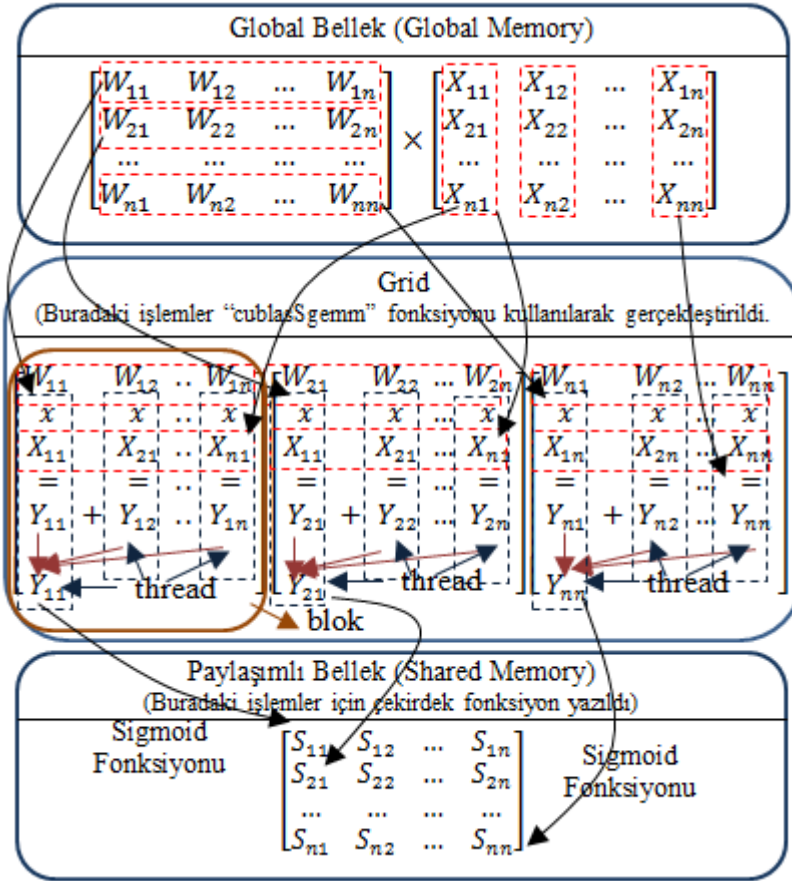
A, B ve C matris deęerleridir. Alpha ve beta ise skaler deęerlerdir.

Bu fonksiyona göre A matrisi $m \times k$, B matrisi $k \times n$ ve C matrisi de $m \times n$ boyutundadır. cublasSgemm fonksiyonu $C = (\alpha \times A \times B) + (\beta \times C)$ matris işlemini hesaplar. Alpha=1 ve beta=0 olarak alındığında işlem $C=A \times B$ ’ ye indirgenir. Lda, ldb ve ldc ise sabit deęerlerdir. Fonksiyondaki trans ifadesi matris transpoze işlemleri için kullanılmaktadır. Genellikle ‘n’ yapısı tercih edilir. Kullanımı aşağıda belirtilmiştir.

‘ Eğer transa=’N’ veya ‘n’, $A=A$.,

Eğer transa=’T’,’t’, ‘C’ or ‘c’ ise $A=A^T$ ’dir.

transb ifadesi ise aynı amaçla B matrisi için kullanılır.’



Şekil 8.17. CUDA kullanarak geri yayımlı sinir ağının matris çarpım işlemleri (ileri hesaplama adımlarından bir kesit).

CUBLAS kullanırken dikkat edilmesi gereken MATLAB'da olduğu gibi matrislerde verinin "column major (veriler sütun öncelikli olarak bellekte tutulmaktadır)" şeklinde işlendiği ve tutulduğu. Belirtilen cublasSgemv fonksiyonunun dışında bu çalışmada GPU bellek ayırımı için cublasAlloc, ayrılan bellek alanını tekrar bırakmak için cublasFree, CPU'dan GPU'ya vektör aktarımı için CublasSetVector, GPU'dan CPU'ya vektör aktarımı için CublasGetVector, CPU'dan GPU'ya matris aktarımı için CublasSetMatrix, GPU'dan CPU'ya matris aktarımı için CublasGetMatrix fonksiyonlarından yararlanılmıştır.

Aritmetik işlemlerin paralelliği için kernel tanımlanmıştır. Aktivasyon fonksiyonu, hata fonksiyonu ve ağırlık güncellemeleri için çekirdek fonksiyonlar geliştirilmiştir. Sigmoid aktivasyon fonksiyonu ile ilgili hesaplamalarda işlemlerin GPU üzerinde gerçekleştirilmesini sağlayan örnek bir kernel Şekil 8.18'de sunulmuştur.

```

__global__ void sigmoid( float *cikis1, int maksimum) {
__shared__ float u_shared[32]; //Paylaşımli bellek ayırma
int sutun = blockIdx.x * blockDim.x + threadIdx.x; //GPU dizininin (thread) işleyeceđi adres bilgisi
if (sutun<maksimum){
u_shared[sutun] = d_an[sutun]; //Paylaşık hafızaya yazma
u_shared[sutun] = (1/(1+__expf(-1*u_shared[sutun]))); //sigmoid fonksiyon deđerinin hesaplanması
__syncthreads(); } // bloktaki tüm threadlerin bu noktaya erişmesini bekletir (Senkronizasyon amaçlı
kullanılır).
d_an[sutun]=u_shared[sutun]; //Global hafızaya yazma }

```

Şekil 8.18. CUDA donanımı üzerinde çalışacak sigmoid fonksiyonu için yazılan kernel fonksiyonu.

Bu çekirdek fonksiyonunun çağırımı aşağıdaki gibi gerçekleştirilmiştir.

```
sigmoid<<< Grid Sayısı, Blok Sayısı >>>(... , ...);
```

GPU üzerinde gerçekleştirilen sinir ağı için çeşitli optimizasyonlar yapılmıştır. Gerçekleştirilen optimizasyon aşamalarından önemli olanlar aşağıda listelenmiştir.

1. Paralel yapılabilen kod parçalarının CUDA üzerinde, seri olması gereken işlemlerin CPU üzerinde çalıştırılmasına dikkat edilmiştir.
2. CUDA ile işlenecek verilerin bir kerede GPU üzerine alınması ve GPU üzerinde tüm işlemler yapıldıktan sonra CPU'ya alınmasına dikkat edilmiştir.
3. Paylaşımli bellek kullanımı, hesaplamalar esnasında bellek erişimini çokça kullanan fonksiyonlarda önemli derecede performans artışı sağlamıştır.

Uygulama Sonuçları

GPU performansı için deneyler NVIDIA GeForce GT 525M grafik kartı üzerinde yapılmıştır. Bu grafik kartında 96 CUDA çekirdeđi mevcuttur. İşlemci hızı 1200 Mhz'dir. CPU performansını tespit etmek için aynı bilgisayarın işlemcisi tercih edilmiştir. Bu işlemci Intel (R) Core™ i7-2670QM CPU @ 2.20 GHz özelliklerine sahiptir. Bilgisayarın belleđi 8 GB kapasiteye sahiptir. Karşılaştırmaların adil olması için yazılımlar aynı programlama dilinde kodlanmıştır. Ayrıca kodlamalarda tek duyarlıklı (ing. single precision) gösterim tercih edilmiştir. Geliştirilen yazılımlar Visual C++ 2010 programlama dili ile hazırlanmıştır. Uygulamada kullanılan veri


seti 2 şekilde kullanılmıştır. İlkinde veri setinin %50 si eğitim için, %50 si test için ayrılmıştır. İkinci şekilde veri setinin %70' i eğitim için, %30'u test için ayrılmıştır. Bu ayırım rastgele bir şekilde yapılmaktadır. Deneysel sonuçlarda kolaylık olması açısından birinci dağılım için Dağılım1, ikinci dağılım içinse Dağılım2 denilecektir.

Hız Performansı

Paralel programlamanın etkisini görmek için 2 aşamada deneyler yapılmıştır. İlk aşamada sonlandırma kriteri olarak eşit iterasyon değeri tercih edilmiştir. Bu aşamada gizli katman nöron sayısının artması durumunda GPU ve CPU'nun sonuca ulaşma zamanları karşılaştırılmıştır. Gizli katman nöron sayısı arttıkça ağırlık matrisleri de büyüyecek ve problem daha karmaşık bir hale gelecektir. İkinci aşamada ise ağ mimarisi sabit tutulup iterasyon değerleri değiştirilmiştir. Ağ mimarisi 9-20-1 olacak şekilde sabitlenmiştir. Burada 9 sayısı giriş katmanındaki elemanların sayısını, 20 gizli katman nöron sayısını ve 1 ise çıkış katmanındaki elemanların sayısını vermektedir.

Algoritmaların çalıştırılmaları sonucu elde edilen sonuçlar Şekil 8.19 ve Şekil 8.20'de görülmektedir. Sonuçlar milisaniye (ms) cinsinden hesaplanmıştır. Hesaplama süreleri CPU ortamında elde edilen 9 öznitelik değerinin GPU'ya taşınması, bellek ayrımı, GPU-CPU arası veri aktarımları ve ileri beslemeli sinir ağının uygulanması sonucunda elde edilen sürelerin toplamından oluşmaktadır. Her deney 10 defa tekrar edilmiş ve bulunan değerlerin ortalaması kullanılmıştır.

Şekil 8.19 ve Şekil 8.20 incelendiğinde CUDA Programlamanın sonuçlara etkisinin yüksek olduğu görülmektedir.



Şekil 8.19. Gizli katman nöron sayısına göre değişen speed-up değerleri.


Şekil 8.19’da Dağılım 1 için ortalama speed-up değerinin 71.21, Dağılım 2 için ortalama speed-up değerinin 70.56 çıktığı görülmektedir. Bu durumda gizli katman nöron sayısının etkisi göz önüne alındığında CUDA programlama ile ortalama 70x civarında bir başarımın sağlandığından bahsedilebilir. Grafikteki bazı değerler aşağıda tablo halinde sunulmuştur.

Çizelge 8.20’de görüldüğü gibi paralel programlamanın etkisiyle yaklaşık 48 saniye süren bir işlemin 0.69 saniyeye düşürüldüğü görülmektedir.

Çizelge 8.20. Gizli katman nöron sayılarına göre sınıflandırma süreleri (msn).

Gizli Katman Nöron Sayısı	Dağılım1		Dağılım2	
	GPU	CPU	GPU	CPU
1	225.1	16034.5	250.1	17529.1
100	335.4	23450.4	342.4	24559.4
300	445.7	31500.7	450.5	32555.3
500	690.1	47900.3	722.4	48895.3

Şekil 8.20’de Dağılım 1 için ortalama speed-up değeri 42.01, Dağılım 2 için ortalama speed-up değeri 44.61 çıkmıştır. Bu durumda iterasyon değerinin etkisi göz önüne alındığında CUDA Programlama ile ortalama 43x civarında bir başarımın sağlandığından bahsedilebilir. Grafikteki bazı değerler aşağıda tablo halinde sunulmuştur. Çizelge 8.21’de görüldüğü gibi paralel programlamanın etkisiyle yaklaşık 395 saniye süren bir işlemin yaklaşık 9 saniyeye indiği görülmektedir.



Şekil 8.20. İterasyon sayısına göre değişen speed-up değerleri.


Çizelge 8.21. İterasyon değerlerine göre sınıflandırma süreleri (msn).

İterasyon Değeri	Dağılım1		Dağılım2	
	GPU	CPU	GPU	CPU
1000	312.4	13338.3	322.6	13500.6
10000	2400.1	106020.4	2600.1	106786.5
20000	4911.8	203008.1	5250.5	225655.4
50000	8807.5	395459.4	11450.08	498788.5

Başarı Performansı

Çalışmada en iyi sonucu veren uygun parametre değerlerinin tespiti deneme-yanılma metodu ile bulunmuştur. Buna göre öğrenme katsayısı 0.6, momentum katsayısı 0.5, gizli katman nöron sayısı 5 olarak belirlenmiştir. İterasyon değeri 5000 olarak sabitlenmiştir. Bu değerler kullanılarak eğitilen ağın iterasyon – ortalama karesel hata (Mean Squared Error, MSE) grafiği Şekil 8.21’de sunulmaktadır. Grafik incelendiğinde veri setinin daha büyük bir oranını eğitim için kullanan Dağılım 2’nin daha başarılı sonuçlar verdiği görülmektedir.

Başarı performansı için ayrıca istatistiki analiz değerleri hesaplanmıştır. Bulunan değerler 10 farklı deneme sonucu elde edilen değerlerin ortalamasıdır. Performans değerlendirme kriterlerine göre elde edilen sonuçlar Çizelge 8.22’de sunulmaktadır.



Şekil 8.21. İterasyon-MSE grafiği.

Çizelge 8.22. Performans değerlendirme kriterlerine göre elde edilen sonuçlar.

Performans Kriteri	Dağılım1	Dağılım2
Doğruluk oranı (DO)	% 96.8	% 98.5
Duyarlılık	% 96.9	% 98.02
Özgünlük	% 96.1	% 98.9
MSE	2.17×10^{-6}	9.49×10^{-7}

Bu çalışmada elde edilen doğruluk oranları ile aynı veri seti üzerinde daha önce yapılmış çalışmalar karşılaştırılmıştır. Doğruluk değerleri dikkate alınarak yapılan karşılaştırmalı analiz Çizelge 8.23’de sunulmaktadır.

Çizelge 8.23. Literatürdeki çalışmalar ile doğruluk değerlerinin kıyaslanması.

Ref. No	Metot	Doğruluk
[106]	Dalgacık dönüşümü, bağıl dalgacık enerjisi ve YSA	%95.0
[23]	Lineer olmayan ön işleme filtreleri ve YSA	%97.2
[104]	İstatiksel öznelilikler ve diskriminant analizi	%96.9
[22]	Zaman-frekans tabanlı öznelilikler ve geri beslemeli sinir ağları	%99.6
[27]	Entropi tabanlı öznelilikler ve uyarlamalı sinirsel bulanık denetim sistemi	%92.2
[31]	Hızlı Fourier dönüşümü ve karar ağaçları	%98.7

Sonuçlar incelendiğinde önerilen metodun EEG verilerini hızlı bir şekilde ve yüksek doğruluk değerlerinde sınıflandırdığı görülmektedir. Önerilen metodun epilepsi

hastalığına yönelik olarak da nihai karar açısından hekimlere faydalı olacağı öngörülmektedir.

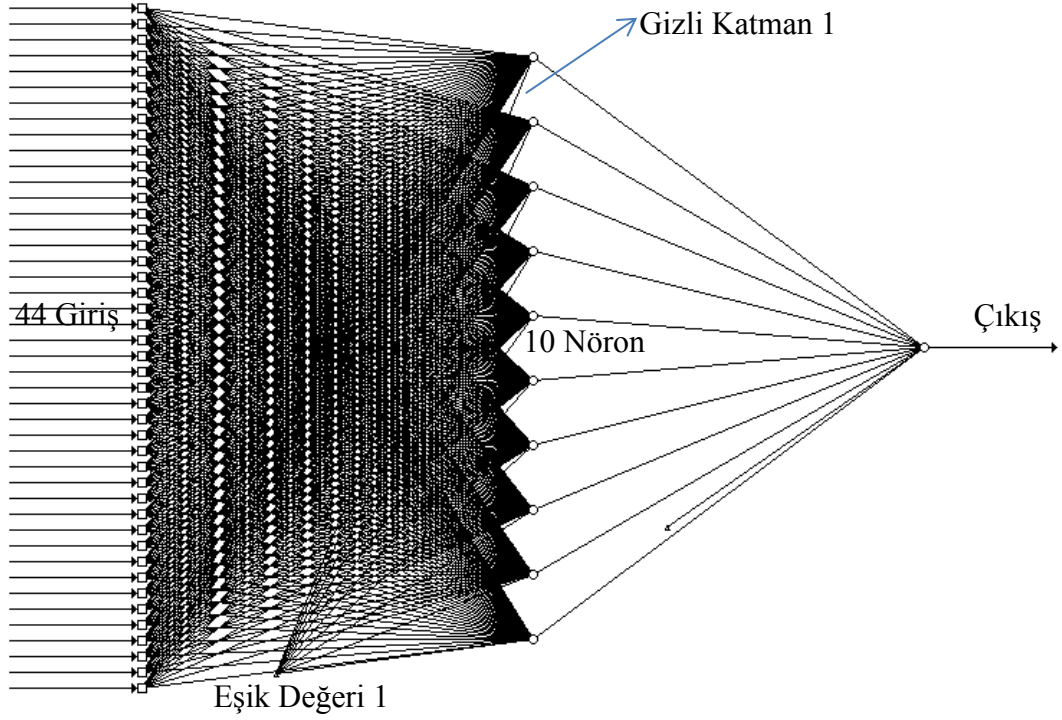
Sonuçlar

Bu çalışma ile CUDA teknolojisi sayesinde EEG sinyallerinin daha kısa zamanda sınıflandırıldığı görülmüştür. Bu çalışmada kullanılan grafik kartı ortalama bir performansa sahiptir. Piyasada daha yüksek çekirdek sayısına sahip grafik kartları da mevcuttur. Yine karşılaştırma amaçlı kullanılan CPU ise şu anda piyasadaki iyi işlemciler arasında gözükmemektedir. Ortalama performansa sahip bir ekran kartı ile çok iyi performansa sahip bir işlemcinin karşılaştırıldığını düşündüğümüzde CUDA programlamanın önemi daha ön plana çıkacaktır. Ayrıca çalışmada önerilen metodun sınıflandırılma doğruluğu ve diğer istatistikî sonuçları da elde edilmiştir. Başarı performansı yönüyle de yüksek doğruluk değerleri elde edilmiştir. Bu yönüyle de önerilen metodun hem hız hem de performans yönüyle etkili bir metot olduğu söylenebilir. İleriki çalışmalarımızda ön işleme aşamasını da GPU üzerinde gerçekleştirerek, tamamen GPU üzerinde çalışan bir sistem hedeflemekteyiz. Bu tarz çalışmalarla sadece biyomedikal sinyal işleme için değil, gerçek zamanlı çalıştırılması hedeflenen birçok çalışmanın hızlı bir şekilde çalıştırılıp, hızlı ve başarılı sonuçların elde edilmesi sağlanabilir.

8.3.2. Uygulama 2: Anestezi Verileri Üzerinde Hıza Dayalı Performans Uygulamaları

Bu aşamada daha karmaşık ve büyük boyuttaki anestezi verileri üzerinde Bölüm 8.3.1’de sunulan yöntem uygulandı. 4 farklı senaryoda yapılan deneylerin sonuçları aşağıda sunulmaktadır.

Senaryo 1: Anestezi derinliğinin sınıflandırılmasına yönelik olarak üzerinde deneyler yapılan mimari; 44 giriş, gizli katman nöron sayısı 10 ve 1 çıkış olacak şekilde tasarlanmıştır. Şekil 8.22’de bu mimarinin şekli sunulmaktadır.



Şekil 8.22. 44-10-1 mimarisine sahip yapay sinir ağı.

Giriş matrisi Denklem 8.2’de belirtilmektedir. Buna anestezi derinliği ölçmeye yönelik olarak hazırlanan veri setinin 44 öznitelik ve 3113 örnekten oluştuğu görülmektedir. Sinir ağına parametre değerleri aşağıda verilmiştir. Deney sonuçları Çizelge 8.24’de sunulmaktadır.

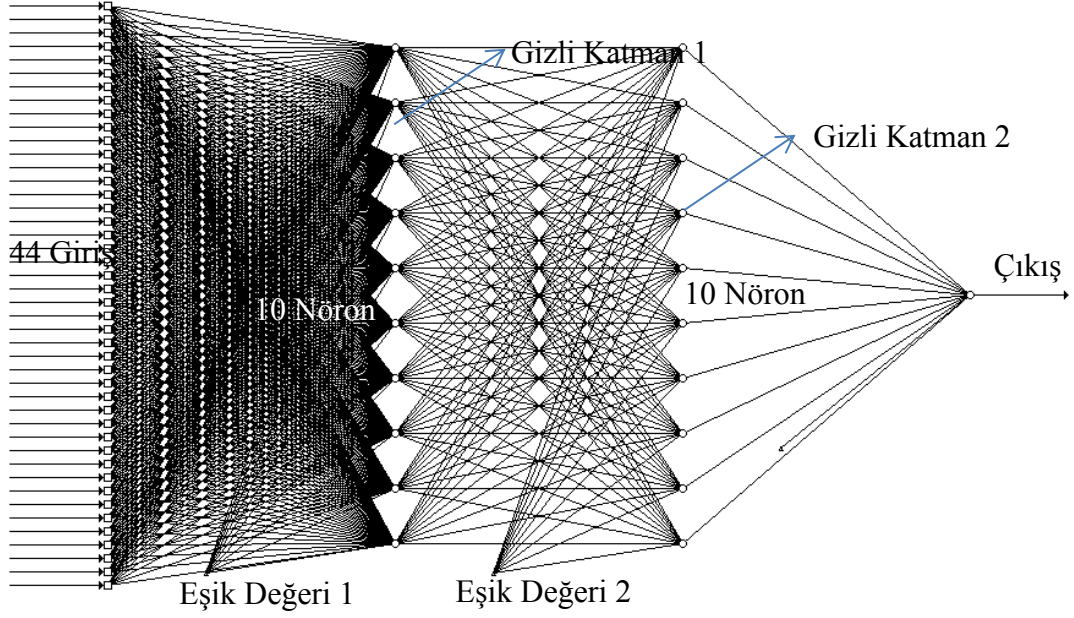
$$\text{Giriş Matrisi } ([44 \times 3113]) = \begin{bmatrix} X_{1,1} & \cdots & X_{1,3113} \\ \vdots & \ddots & \vdots \\ X_{44,1} & \cdots & X_{44,3113} \end{bmatrix} \quad (8.2)$$

Gizli Katman Sayısı : 1
 Gizli Katman 1 Nöron Sayısı : 10
 İterasyon Sayısı : 10000
 Öğrenme Oranı : 0.7
 Momentum Oranı : 0.7

Çizelge 8.24. 44-10-1 mimarisine sahip bir ağına performans deneyleri.

Ekran Kartı	CPU	GT 525 M	Quadro 2000
Zaman	12 dk 19 sn (739 sn)	1 dk 30 sn (90 sn)	38 sn
Başarı		8.21 x	19.44 x

Senaryo 2: Anestezi derinliğinin sınıflandırılmasına yönelik olarak üzerinde deneyler yapılan mimari; 44 giriş, 1. katman nöron sayısı 10, 2. katman nöron sayısı 10 ve 1 çıkış olacak şekilde tasarlanmıştır. Şekil 8.23’de bu mimarinin şekli sunulmaktadır.



Şekil 8.23. 44-10-10-1 mimarisine sahip yapay sinir ağı.

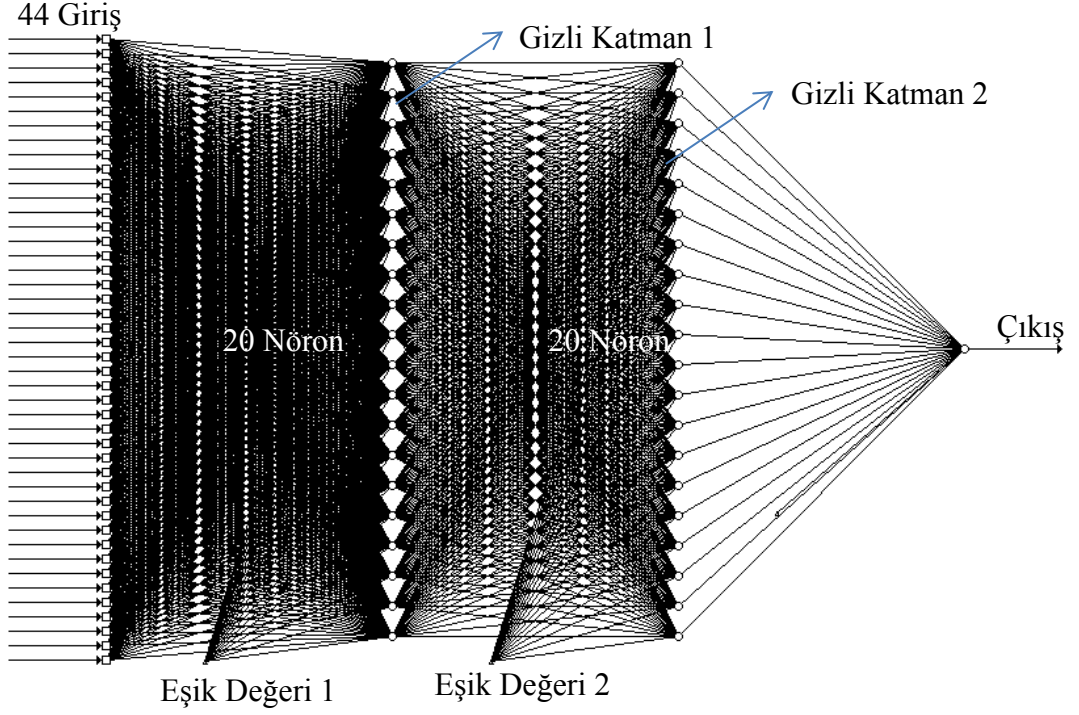
Giriş matrisi Denklem 8.2’de belirtilmektedir. Sinir ağının parametre değerleri aşağıda verilmiştir. Deney sonuçları Çizelge 8.25’de sunulmaktadır.

Gizli Katman Sayısı	: 2
Gizli Katman 1 Nöron Sayısı	: 10
Gizli Katman 2 Nöron Sayısı	: 10
İterasyon Sayısı	: 10000
Öğrenme Oranı	: 0.7
Momentum Oranı	: 0.7

Çizelge 8.25. 44-10-10-1 mimarisine sahip bir yapay sinir ağının performans deneyleri.

Ekran Kartı	CPU	Nvidia GT 525 M	Nvidia Quadro 2000
Zaman (s)	19 dk 48 sn (1188 sn)	120 sn	45 sn
Başarı		9.9 x	26.4 x

Senaryo 3: Anestezi derinliğinin sınıflandırılmasına yönelik olarak üzerinde deneyler yapılan mimari; 44 giriş, 1. katman nöron sayısı 20, 2. katman nöron sayısı 20 ve 1 çıkış olacak şekilde tasarlanmıştır. Şekil 8.24’de bu mimarinin şekli sunulmaktadır.



Şekil 8.24. 44-20-20-1 mimarisine sahip yapay sinir ağı.

Giriş matrisi Denklem 8.2’de belirtilmektedir. Sinir ağının parametre değerleri aşağıda verilmiştir. Deney sonuçları Çizelge 8.26’da sunulmaktadır.


Gizli Katman Sayısı	: 2
Gizli Katman 1 Nöron Sayısı	: 20
Gizli Katman 2 Nöron Sayısı	: 20
İterasyon Sayısı	: 10000
Öğrenme Oranı	: 0.7
Momentum Oranı	: 0.7

Çizelge 8.26. 44-20-20-1 mimarisine sahip bir ağın performans deneyleri.

Ekran Kartı	CPU	GT 525 M	Quadro 2000
Zaman	38 dk. 58 sn. (2338 sn)	390 sn	116 sn
Başarı		6 x	20.1 x

yapılan mimari; 44 giriş, gizli katman nöron sayısı 50 ve 1 çıkış olacak şekilde

tasarlanmıştır. Şekil 8.25’de bu mimarinin şekli sunulmaktadır.



Şekil 8.25. 44-50-1 mimarisine sahip yapay sinir ağı.

Giriş matrisi Denklem 8.2’de belirtilmektedir. Sinir ağının parametre değerleri aşağıda verilmiştir. Deney sonuçları Çizelge 8.27’de sunulmaktadır.

Gizli Katman Sayısı	: 1
Gizli Katman Nöron Sayısı	: 50
İterasyon Sayısı	: 10000
Öğrenme Oranı	: 0.7
Momentum Oranı	: 0.7

Çizelge 8.27. 44-50-1 mimarisine sahip bir ağın performans deneyleri.

Ekran Kartı	CPU	GT 525 M	Quadro 2000
Zaman	1 saat 7 dk 18 sn (4048 sn)	12 dk 15 sn (735 sn)	135 sn
Başarı		5.5 x	29.9 sn

BÖLÜM 9

SONUÇLAR

Bu tez çalışmasında; nörologlar ve anestezi uzmanları için; EEG sinyallerini, yüksek doğruluk oranıyla kısa zamanda analiz edip, sınıflandırma işlemlerini otomatik olarak yapabilecekleri yeni hibrit modeller sunulmuştur. Çalışmada 3 farklı yöntem 3 farklı veri seti üzerinde uygulanmıştır. Bazı deneylerde bu yöntemler bir arada kullanılmıştır. Sonuç itibariyle EEG verileri üzerinde çok boyutlu bir analiz çalışması gerçekleştirilmiştir. Çalışmanın önemli sonuçları aşağıda listelenmiştir.

1. Yöntem 1 aşamasında farklı EEG verilerine yönelik olarak etkili öznitelik ve etkili sınıflandırma algoritmaları araştırılmıştır. Öznitelik seçme algoritmaları ile seçilen özniteliklerin performans etkisi, tüm özniteliklerin kullanımına göre olumlu ve daha fazla olmuştur. Literatürde EEG sınıflandırmaları ile ilgili çalışmalar incelendiğinde çok sayıda öznitelik çıkarma algoritmasının kullanıldığı görülmektedir. Fakat hangi özniteliklerin etkili olduğu önemli bir problem olarak görülmektedir. Çalışma bu yönüyle önem taşımaktadır. Bu çalışmada epilepsi hastalığının teşhisi ve uyku evrelerinin sınıflandırılması konularında etkili öznitelik tespiti gerçekleştirilmiştir. Uygulama bu konu üzerinde çalışan araştırmacılar için önemli bir rehber olacaktır. EEG sinyalleri dikkate alınarak yapılan tanılama ve skorlama çalışmaları (anestezi derinliğinin tespiti, migren teşhisi, beyin bilgisayar arayüzleri v.b.) için de aynı yöntem tercih edilerek etkili öznitelikler saptanabilir. Bu tarz çalışmalar ile özellikle “Verilerimizi en iyi şekilde temsil edecek öznitelikleri elde etmek için hangi öznitelik algoritmasını kullanmalıyız” sorusuna etkili bir çözüm bulunabilir. Önerilen metotlar literatüre bu yönüyle önemli bir katkı sağlayacaktır.

2. Yöntem 2 aşamasında EEG verilerinin sınıflandırılmasında karmaşık değerli yöntemlerin etkisi araştırılmıştır. Yapılan deneyler neticesinde, EEG verilerinin yüksek doğruluk değerlerinde sınıflandırılmasında karmaşık değerli yöntemlerin etkisi yüksek olmuştur. Farklı biyomedikal sinyal işleme alanlarında aynı yöntemlerle yüksek doğruluk oranları elde edilebilir.
3. Yöntem 2 aşamasında dikkat çeken kısımlarından biri sistem performansını önemli ölçüde etkileyen parametre optimizasyonu olmuştur. Karmaşık değerli sinir ağlarında parametre optimizasyonu için Taguchi yönteminin kullanıldığı sistemde, daha az deney, zaman ve maliyet tasarrufu sağlanabileceği görülmüştür. Bu yöntemle epilepsi teşhisine yönelik gerçekleştirilen uygulamada bahsi geçen 3 farklı problem için tam faktöriyel tasarımı kullanılması durumunda 28125 denemede bulunabilecek en iyi parametre seti 225 deneme ile tespit edilmiştir.
4. Yöntem 2 aşamasında karmaşık değerli dalgacık dönüşümünün farklı seviyelerinin sonuca etkileri araştırılmış ve çok sayıda istatistiksel analiz metodu kullanılarak karşılaştırmalı analizler sunulmuştur.
5. Yöntem 3 aşamasında EEG verilerinin sınıflandırılmasında kullanılan sınıflandırma yönteminin hızlandırılması amaçlanmıştır. Bu yönüyle bir hız performans uygulaması gerçekleştirilmiştir. Yöntem, epilepsi ve anestezi verilerine uygulanmıştır. Sonuçlar paralel programlamanın olumlu etkisini açık bir şekilde göstermiştir.

KAYNAKLAR

1. Aydın, S., “Determination of autoregressive model orders for seizure detection”, *Turkish Journal of Electrical Engineering and Computer Science*, 18: 23-30 (2010).
2. Kolb, B. and Whishaw, I. Q., “Fundamentals of Human Neuropsychology 3rd ed.”, *W. H. Freeman and Company*, New York, 697-722 (1990).
3. Sen, B., and Peker, M., “Novel approaches for automated epileptic diagnosis using FCBF feature selection and classification algorithms”, *Turkish Journal of Electrical Engineering & Computer Sciences*. 21: 2092-2109 (2013).
4. Sanei, S. and Chambers, J., “EEG Signal Processing 1st ed.”, *John Wiley & Sons*, England, 24-28 (2007).
5. Pan, S. T., Kuo, C. E., Zeng, J. H. and Liang, S. F., “A transition-constrained discrete hidden Markov model for automatic sleep staging”, *BioMedical Engineering OnLine*, 11: 52-71 (2012).
6. Rechtschaffen, A. and Kales, A., “A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subjects 1st ed.”, *U.S. Public Health Service*, Washington, 15-25 (1968).
7. Gürkan, G., Cebeci, B., Demiralp, T. and Akan, A., “Anestezi altında EEG sinyalinin topografik ve izgesel analizi”, *15. IEEE Biyomedikal Mühendisliği Ulusal Toplantısı*, Antalya, 1-4 (2010).
8. Gürkan, G., Akan, A. and Demiralp, T., “Connectivity analysis of EEG signals under propofol anesthesia with time-varying generalized partial directed coherence”, *Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC 2010)*, Argentina, 3297-3300 (2010).
9. Berger, H., “Über das elektroenkephalogramm des menschen”, *Archiv für Psychiatrie und Nervenkrankheiten*, 87: 527-570 (1929)
10. Penfield W, Erickson T. C. and Thomas C. C., “Epilepsy and cerebral localization: A study of the mechanism, treatment and prevention of epileptic seizures”, *Arch Intern Med (Chic)*, 70 (5): 916-917 (1942).
11. Yazgan, E. ve Korürek, M., “Tıp elektroniği”, *İTÜ Yayınları*, 15741: 386-388 (1996).

12. Webber, W. R. S., Lesser, R. P., Richardson, R. T. and Wilson, K., "An approach to seizure detection using an artificial neural network (ANN)", *Electroencephalography and Clinical Neurophysiology*, 98: 250-272 (1996).
13. Tzallas, A. T., Tsipouras, M. G. and Tsalikakis D. G., "Automated epileptic seizure detection methods: a review study", *Epilepsy-Histological, Electroencephalographic and Psychological Aspects*, 75-98 (2012).
14. İnternet: World Health Organization, "Epilepsy", <http://www.who.int/mediacentre/factsheets/fs999/en/index.html> (2011).
15. Coskun, A., "Beynimizde Çakan Şimşekler: Epilepsi", *Bilim ve Teknik*, 522: 76-80 (2011).
16. Yıldız, M., "Uyku evrelerinin EEG işaretleri kullanılarak sınıflandırılmasında yeni bir yaklaşım", Doktora Tezi, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü*, Sakarya, 10-25 (2009).
17. Devuyt, S., Dutoit, T., Ravet, T., Stenuit, P., Kerkhofs, M. and Stanus, E., "Automatic processing of EEG-EOG-EMG artifacts in sleep stage classification", *13th International Conference on Biomedical Engineering IFMBE Proceedings*, 23: 146-150 (2009).
18. Marshall, B. E. and Lockenferger, D. E., "General anaesthetics, Goodman And Gilman's The Pharmacological Basis Of Therapeutics 8th ed.", *Permagon Pres*, Oxford, 285-311 (1990).
19. Gürkan, G., "EEG sinyallerinin analizi ile anestezi derinliği tespiti", Doktora Tezi, *İstanbul Üniversitesi Biyomedikal Mühendisliği*, İstanbul, 1-10 (2011).
20. Pradhan, N., Sadasivan, P. K. and Arunodaya, G. R., "Detection of seizure activity in EEG by an artificial neural network: A preliminary study", *Computers and Biomedical Research*, 29: 303-313 (1996).
21. Petrosian, A., Prokhorov, D., Homan, R., Dashei, R. and Wunsch, D., "Recurrent neural network based prediction of epileptic seizures in intra and extracranial EEG", *Neurocomputing*, 30: 201-218 (2000).
22. Srinivasan, V., Eswaran, C. and Sriraam, N. "Artificial neural network based epileptic detection using time domain and frequency domain features", *Journal of Medical Systems*, 29 (6): 647-660 (2005).
23. Nigam, V. and Graupe D., "A neural-network-based detection of epilepsy", *Neurological Research*, 26 (1): 55-60 (2004).
24. Subaşı, A. and Erçelebi, E., "Classification of EEG signals using neural network and logistic regression", *Computer Methods and Programs in Biomedicine*, 78: 87-99 (2005).

25. Subaşı, A., “Epileptic seizure detection using dynamic wavelet network”, *Expert Systems with Applications*, 29: 343-355 (2005).
26. Alkan, A., Köklükaya, E. and Subaşı, A., “Automatic seizure detection in EEG using logistic regression and artificial neural network”, *Journal of Neuroscience Methods*, 148: 167-176 (2005).
27. Kannathal, N., Choo, M. L., Acharyab, U. R. and Sadasivana, P. K., “Entropies for detection of epilepsy in EEG”, *Computer Methods and Programs in Biomedicine*, 80: 187-194 (2005).
28. Bao, F. S., Lie, D. Y. C. and Zhang, Y., “A new approach to automated epileptic diagnosis using EEG and probabilistic neural network”, *IEEE International Conference on Artificial Intelligence*, Dayton, 2: 482-486 (2008).
29. Fan, J., Shao, C., Yang, O., Wang, J., Li, S. and Wang, Z., “Automatic seizure detection based on support vector machines with genetic algorithms”, *Simulated Evolution and Learning (SEAL)*, Hefei, 845-852 (2006).
30. Tzallas, A. T., Tsipouras, M. G. and Fotiadis, D. I., “Automatic seizure detection based on time-frequency analysis and artificial neural networks”, *Computational Intelligence and Neuroscience*, 7 (3): 1-13 (2007).
31. Polat, K. and Güneş, S., “Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform”, *Applied Mathematics and Computation*, 187 (2), 1017-1026 (2007).
32. Sezer, E., Işık, H. and Saraçoğlu, E. “Employment and comparison of different artificial neural networks for epilepsy diagnosis from EEG signals”, *Journal of Medical Systems*, 36 (1): 347-362 (2012).
33. Orhan, U., Hekim, M. and Özer, M., “EEG signals classification using the k-means clustering and a multilayer perceptron neural network model”, *Expert Systems with Applications*, 38 (10): 13475-13481 (2011).
34. Loomis, A. L., Harvey, E. N. and Hobart, G. A., “Cerebral states during sleep, as studied by human brain potentials”, *Journal of Experimental Psychology*, 21: 127-144 (1937).
35. Adrian, E. D. and Matthews, B. H. C., “The interpretation of potential waves in the cortex”, *Journal of Physiology*, 81: 440-471 (1934).
36. Davis, P. A., “Effects of acoustic stimuli on the waking human brain”, *Journal of Neurophysiology*, 2: 494-499 (1939).
37. Hu, J. and Knapp, B., “Electroencephalogram pattern recognition using fuzzy logic”, *IEEE Proceedings of the 25th Asilomar Conference on Signals, Systems, and Computers*, Pacific Grove, CA, 2: 805-807 (1991).

38. Merica, H. and Blois, R., "Relationship between the time courses of power in the frequency bands of human sleep EEG", *Clinical Neurophysiology*, 27: 116-128 (1997).
39. Pacheco, O. R. and Vaz, F., "Integrated system for analysis and automatic classification of sleep EEG", *Proceeding of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Hong Kong, 20 (4): 2062-2065 (1998).
40. Oropesa, E., Cycon, H. L. and Jobert, M., "Sleep stage classification using wavelet transform and neural network", *International Computer Science Institute: Technical Reports*, TR-99-008: 1-7 (1999).
41. Flexer, A. and Sykacek, P. et al., "Using hidden Markov models to build an automatic, continuous and probabilistic sleep stager", *In Proceedings of the ICANN*, Como, 3: 627-631 (2000).
42. Kıymık, M. K., Akın, M. and Subaşı, A., "Automatic recognition of alertness level by using wavelet transform and artificial neural network", *Journal of Neuroscience Methods*, 139: 231-240 (2004).
43. Subaşı, A., "Automatic recognition of alertness level from EEG by using neural network and wavelet coefficients", *Expert Systems with Applications*, 28: 701-711 (2005).
44. He, W. X., Yan, X. G., Chen, X. P. and Liu, H., "Nonlinear feature extraction of sleeping EEG signals", *Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*, Shanghai, 1-4 (2005).
45. Doroshenkov, L., Konyshchev, V. and Selishchev, S., "Classification of human sleep stages based on EEG processing using hidden Markov models", *Biomedical Engineering*, 41 (1): 25-28 (2007).
46. Agarwal, R. and Gotman, J., "Computer-assisted sleep staging", *IEEE Transactions on Biomedical Engineering*, 48: 1412-1423 (2001).
47. Estrada, E., Nazeran, H., Nava, P., Behmehani, K., Burk, J. and Lucas, E., "EEG feature extraction for classification of sleep stages", *In: Proceedings of the 26th annual conference of the IEEE EMBS*, San Francisco, 196-199 (2004).
48. Becq, G., Charbonnier, S., Chapotot, F., Buguet, A., Bourdon, L. and Baconnier, P., "Comparison between five classifiers for automatic scoring of human sleep recordings", *Studies in Computational Intelligence*, 4: 113-127 (2005).
49. Sinha, R. K., "Artificial neural network and wavelet based automated detection of sleep spindles, REM sleep and wake states", *Journal of Medical Systems*, 32: 291-299 (2008).

50. Gunes, S., Polat, K., Yosunkaya, S. and Dursun, M., "A novel data pre-processing method on automatic determining of sleep stages: K-means clustering based feature weighting", *Complex Systems and Applications - ICCSA*, Le Havre, 112-117 (2009).
51. Schultz, A., Grouven, U., Beger, F. A. and Schultz, B., "The Narcotrend Index: classification algorithm, correlation with propofol effect-site concentrations, and comparison with spectral parameters", *Biomedizinische Technik (Berl)*, 49 (3): 38-42 (2004).
52. Traast, H. S. and Kalkman, C. J., "Electroencephalographic characteristics of emergence from propofol/sufentanil total intravenous anesthesia", *Anesthesia & Analgesia*, 81: 336-371 (1995).
53. Zikov, T., Bibian, S., Dumont, G. A., Huzmezan, M. and Ries, C. R. "Quantifying cortical activity during general anesthesia using wavelet analysis", *IEEE Transaction on Biomedical Engineering*, 53 (4): 617-632 (2006).
54. Ferenets, R., Lipping, T., Suominen, P., Turunen, J., Puumala, P., Jantti, V., Himanen, S. L. and Huotari, A. M., "Comparison of the properties of EEG spindles in sleep and propofol anesthesia", *IEEE Engineering in Medicine & Biology Society*, New York, 1: 6356-6359 (2006).
55. Lalitha, V. and Eswaran, C., "Automated detection of anesthetic depth levels using chaotic features with artificial neural networks", *Journal of Medical Systems*, 31 (6): 445-452 (2007).
56. Andrzejak, R. G., Widman, G., Lehnertz, K., Rieke, C., David, P. and Elger, C. E., "The epileptic process as nonlinear deterministic dynamics in a stochastic environment: an evaluation on mesial temporal lobe epilepsy", *Epilepsy Research*, 44: 129-140 (2001).
57. Goldberger, A. L., Amaral, L. A. and Glass L. et al. "PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals", *Circulation*, 101 (23): 215-220 (2000).
58. Quyen, M. L. V., Martinerie, J., Baulac, M. and Varela, F., "Anticipating epileptic seizures in real time by a non-linear analysis of similarity between EEG recordings", *Neuroreport*, 10: 2149-215 (1999).
59. Hjorth, B., "Time domain descriptors and their relation to a particular model for generation of EEG activity", *CEAN – Computerized EEG analysis*, Stuttgart, 3-8 (1975).
60. Petrosian, A., "Kolmogorov complexity of finite sequences and recognition of different preictal EEG patterns", *IEEE Symposium on Computer-Based Medical Systems*, Texas, 212-217 (1995).

61. Esteller, R., Echaus, J., Tcheng, T., Litt, B. and Pless, B., “Line length: an efficient feature for seizure onset detection”, *IEEE Engineering in Medicine and Biology Society*, İstanbul, 1707-1710 (2001).
62. Kaiser, J. F., “On a simple algorithm to calculate the ‘energy’ of a signal”, *International Conference on Acoustics, Speech and Signal Processing (ICASSP'90)*, USA, 1: 381-384 (1990).
63. Semmlow, J., “Biosignal and Biomedical Image processing 1st ed.”, *Marcel Decker*, New York, 150-165 (2004).
64. Avşar, E., “Epileptic EEG signal classification using one-class support vector machines”, M.Sc. Thesis, *Istanbul Technical University Graduate School of Science, Engineering and Technology*, İstanbul, 20-35 (2009).
65. Ocak, H., “Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy”, *Expert Systems with Applications*, 36: 2027-2036 (2009).
66. Sabeti, M., Katebi, S. and Boostani, R., “Entropy and complexity measures for EEG signal classification of schizophrenic and control participants”, *Artificial Intelligence in Medicine*, 47: 263-274 (2009).
67. Rényi, A., “On a new axiomatic theory of probability”, *Acta Mathematica Hungarica*, 6: 285-33 (1995).
68. Pincus, S. M., “Approximate entropy as a measure of system complexity”, *Proceedings of the National Academy of Sciences*, 88 (6): 2297-2301 (1991).
69. Bandt, C. and Pompe, B., “Permutation entropy: a natural complexity measure for time series”, *Physical Review Letters*, 88 (17): 1-4 (2002).
70. Yu, L., and Liu, H. “Feature selection for high-dimensional data: A fast correlation-based filter solution”, *Machine Learning, Proceedings of the Twentieth International Conference (ICML'03)*, Washington, 856-863 (2003).
71. Ding, C. and Peng, H. C., “Minimum redundancy feature selection from microarray gene expression data”, *IEEE Computational Systems Bioinformatics Conference*, California, 523-528 (2003).
72. Altun, H., Polat, E., Polat, G. ve Güneş, T., “İnsan bilgisayar etkileşimini geliştirmek için ses ve yüz görüntü işaretlerinden çok kipli biometrik özniteliklerin belirlenmesi ve etkin birleştirilmesi”, *Tübitak Araştırma Projesi Raporu*, 104E179: 42-50 (2007).
73. Kononenko, I., “Estimating attributes: Analysis and extensions of RELIEF”, *European Conference on Machine Learning*, Catania, 171-182 (1994).

74. Quinlan, L., "C4.5: Programs for Machine Learning 1st ed.", *Morgan Kaufmann*, San Francisco, 70-80 (1993).
75. Cortes, C. and Vapnik, V. "Support vector networks", *Machine Learning*, 20 (3): 273-297 (1995).
76. Breiman, L., "Random forests", *Machine Learning*, 45 (1): 5-32 (2001).
77. Ceylan, M., "Bilgisayar tomografili akciğer görüntülerinin değerlendirilmesinde kompleks değerli yeni bir akıllı sistem tasarımı", Doktora Tezi, *Selçuk Üniversitesi Elektrik ve Elektronik Mühendisliği*, Konya, 30-40 (2009).
78. Selesnick, I. W., Baraniuk, R. G. and Kingsbury, N. "The dual-tree complex wavelet transform", *IEEE Signal Processing Magazine*, 22: 123-151 (2005).
79. Ping, Z. and Chun, Z., "Three-channel symmetric tight frame wavelet design method", *Information Technology Journal*, 12: 623-631 (2013).
80. Kazan, S. "Moment tabanlı normalleştirmeye dayalı sayısal görüntü damgalama yöntemleri", Doktora Tezi, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü*, Sakarya, 10-20 (2009).
81. Barni, M., Bartolini, F. and Piva, A., Improved wavelet-based watermarking through pixel-wise masking, *IEEE Transactions on Image Processing*, 10 (5): 783-791 (2001).
82. Zhuang, L. and Jiang, M., "Multipurpose digital watermarking algorithm based on dual-tree CWT intelligent systems design and applications", *IEEE Intelligent Systems Design and Applications (ISDA '06)*, Jinan, 2: 316-320 (2006).
83. Nitta, T. "An extension of the back-propagation algorithm to complex numbers", *Neural Network*, 10: 1391-1415 (1997).
84. Aizenberg, I., Paliy, D. V., Zurada, J. M. and Astola J. T., "Blur identification by multilayer neural network based on multivalued neurons", *IEEE Transactions on Neural Networks*, 19 (5): 883-898 (2008).
85. Nitta, T., "Orthogonality of decision boundaries in complex-valued neural networks", *Neural Computation*, 16 (1): 73-97 (2004).
86. Lahiri, S. K. and Ghanta K. C., "Artificial neural network model with parameter tuning assisted by genetic algorithm technique: study of critical velocity of slurry flow in pipeline", *Asia-Pacific Journal of Chemical Engineering*, 5: 763-777 (2009).
87. Leung, H. and Haykin, S., "The complex back propagation algorithm", *IEEE Transactions on Signal Processing*, 39 (9): 2101-2104 (1991).

88. Birx, D. L. and Pipenberg, S. J., "Chaotic oscillators and complex mapping feed forward networks (CMFFNS) for signal detection in noisy environments", *International Joint Conference on Neural Networks*, Baltimore, 881-888 (1992).
89. N. Benvenuto and F. Piazza, "On the complex back propagation algorithm", *IEEE Transactions on Signal Processing*, 40: 967-969 (1992).
90. Taguchi, G., Elsayed, E. and Hsiang, T. "Quality Engineering in Production Systems 1st ed.", *McGraw-Hill*, New York , 45-55 (1989).
91. İnternet: NVIDIA CUDA, "CUDA Programming Guide 2.3", <http://developer.nvidia.com/cuda> (2009).
92. Che, S., Boyer, M. and Meng, J. Y. et al., "A performance study of general purpose applications on graphics processors using CUDA", *Journal of Parallel and Distributed Computing*, 68 (10): 1370-1380 (2008).
93. İnternet: NVIDIA CUDA, "NVIDIA's Next Generation CUDA Computer Architecture Fermi", http://www.nvidia.com/content/PDF/fermi_white_papers (2011).
94. Özçetin, E., "Karesel atama problemi için grafik işlem birimleri üzerinde paralel bir evrimsel algoritma", Yüksek Lisans Tezi, *Anadolu Üniversitesi Fen Bilimleri Enstitüsü*, Eskişehir, 16-18 (2013).
95. Temizel, A., "Hesaplamalı bilimlerde GPU teknolojileri ve genel amaçlı GPU programlama", *GPU Hesaplama ve Programlama Semineri*, Ankara, 66-69 (2011).
96. Sağel, B., Ceylan, S., Akpulat, M.C., Türken, H. ve Erdoğan, S., "CUDA altyapısı kullanılarak sinyal işleme yazılımı optimizasyonu", *5. Ulusal Yazılım Mühendisliği Sempozyumu*, Ankara, 159-162 (2011).
97. American academy of sleep medicine task force, "Sleep related breathing disorders in adults: recommendations for syndrome definition and measurement techniques in clinical research", *Sleep*, 22: 667-689 (1999).
98. Šušmáková, K. and Krakovská, A. "Discrimination ability of individual measures used in sleep stages classification", *Artificial Intelligence in Medicine*, 44: 261-277 (2008).
99. Chapotot, F. and Becq, G., "Automated sleep-wake staging combining robust feature extraction, artificial neural network classification, and flexible decision rules", *International Journal of Adaptive Control and Signal Processing*, 24: 409-423 (2010).

- 100.Zoubek, L., Charbonnier, S., Lesecq, S., Buguet, A. and Chapotot, F. "Feature selection for sleep/wake stages classification using data driven methods", *Biomedical Signal Processing and Control*, 2: 171-179 (2007).
- 101.Tagluk, M. E., Sezgin, N. and Akin, M., "Estimation of sleep stages by an artificial neural network employing EEG, EMG and EOG", *Journal of Medical Systems*, 34: 717-725 (2010).
- 102.Fraiwan, L., Lweesy, K., Khasawneh, N., Fraiwan, M., Wenz, H., and Dickhaus, H., "Classification of sleep stages using multi-wavelet time frequency entropy and LDA", *Methods of Information in Medicine*, 49 (3): 230-237 (2010).
- 103.Ebrahimi, F., Mikaeili, M., Estrada, E., and Nazeran, H., "Automatic sleep stage classification based on EEG signals using neural networks and wavelet packet coefficients", *Proceeding of IEEE EMBC*, Vancouver, 1151-1154 (2008).
- 104.Fathima, T., Bedeuzzaman, M., Farooq, O. and Yusuf, U. K., "Wavelet based features for epileptic seizure detection", *MES Journal of Technology and Management*, 2 (1): 108-112 (2010).
- 105.Subaşı, A. "EEG signal classification using wavelet feature extraction and a mixture of expert model", *Expert Systems with Applications*, 32: 1084-1093 (2007).
- 106.Guo, L., Rivero, D., Seoane, J. A. and Pazos, A., "Classification of EEG signals using relative wavelet energy and artificial neural networks", *Genetic and Evolutionary Computation Conference*, Shanghai, 12-14 (2009).
- 107.Kannathal, N., Acharya, U. R., Lim, C. M. and Sadasivan, P. K. "Characterization of EEG-a comparative study", *Computer Methods and Programs in Biomedicine*, 80: 17-23 (2005).
- 108.İnternet: Minitab Statistical Analysis Software, "Minitab", <http://www.minitab.com> (2012).
- 109.Acharya, R., Sree, S. V., Ang, P. C. A. and Suri, J. S. "Use of principal component analysis for automatic classification of epileptic EEG activities in wavelet framework", *Expert Systems with Applications*, 39 (10): 9072-9078 (2012).

ÖZGEÇMİŞ

Musa PEKER 1985 yılında Konya’da doğdu; ilk ve orta öğrenimini aynı şehirde tamamladı. 2003 yılında Zonguldak Karaelmas Üniversitesi Karabük Teknik Eğitim Fakültesi Elektronik ve Bilgisayar Eğitimi Bölümü’nde öğrenime başlayıp 2007 yılında iyi derece ile mezun oldu. 2007 yılında Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Bilgisayar Eğitimi Anabilim Dalı’nda başlamış olduğu yüksek lisans programını 2009 yılında tamamladı. 2010 yılında Karabük Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda doktora eğitimine başladı.

2007 yılında Mudurnu Çok Programlı Lisesinde öğretmen olarak göreve başladı. 2008-2010 yılları arasında aynı okulda müdür yardımcısı olarak görev yaptı. 2010 yılında Samandıra Teknik Lise ve Endüstri Meslek Lisesine atandı. Halen aynı okulda bilişim teknolojileri öğretmeni olarak görev yapmaktadır. İlgi alanları biyomedikal sinyal işleme, görüntü işleme, yapay zeka ve paralel programlama konularıdır.

ADRES BİLGİLERİ

Adres : Samandıra Teknik Lise ve EML
Sancaktepe/İSTANBUL
Tel : (506) 908 74 95
E-posta : pekermusa@gmail.com