

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**EEG SİNYALLERİNDEKİ EPİLEPTİFORM
AKTİVİTENİN VERİ MADENCİLİĞİ
SÜRECİ İLE TESPİTİ**

DOKTORA TEZİ

Mehmet ALBAYRAK

Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK MÜH.

Enstitü Bilim Dalı : ELEKTRONİK MÜH.

Tez Danışmanı : Prof. Dr. Etem KÖKLÜKAYA

Haziran 2008

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**EEG SİNYALLERİNDEKİ EPİLEPTİFORM
AKTİVİTENİN VERİ MADENCİLİĞİ
SÜRECİ İLE TESPİTİ**

DOKTORA TEZİ

Mehmet ALBAYRAK


Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK MÜH.

Enstitü Bilim Dalı : ELEKTRONİK MÜH.

Bu tez .. / 09 /2008 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

 Yard.Doç.Dr. Cemil ÖZ Prof.Dr. Etem KÖKLÜKAYA  Yard.Doç.Dr. A. Fuat BOZ
Jüri Başkanı Üye Üye

 Yard.Doç.Dr. M. Reşit USAL
Üye

 Yard.Doç.Dr. Okan BİNGÖL
Üye

TEŞEKKÜR

Bu çalışmanın hazırlanma sürecinde desteklerini esirgemeyen danışmanım Prof.Dr. Etem KÖKLÜKAYA'ya, çalışmanın nöroloji ile ilgili bölümlerinde ve bu bölümlerin redaksiyonundaki katkılarından dolayı SDÜ Tıp Fakültesi Nöroloji ABD öğretim üyesi Doç.Dr. Serpil DEMİRCİ'ye, veri madenciliği ve analiz kısmındaki katkılarından dolayı mesai arkadaşım SDÜ Teknik Eğitim Fakültesi öğretim üyesi Yard.Doç.Dr. Ecir Uğur KÜÇÜKSİLLE'ye, tüm bölümlerin redaksiyonuna katkılarından ve tezin bölümlerinin organizasyonuna katkılarından dolayı SDÜ Eğirdir Meslek Yüksekokulu öğretim üyesi Yard.Doç.Dr. Murat ÇUHADAR'a teşekkürü bir borç bilirim.

Ayrıca tezin oluşturulma sürecinde desteklerini hep yanımda hissettiğim SDÜ Dış İlişkiler Koordinatörü Doç.Dr. Hüseyin GÜL'e, SDÜ Teknik Eğitim Fakültesi öğretim üyesi Yard.Doç.Dr. Mustafa Reşit USAL'a, SAÜ Enformatik Bölümü öğretim görevlisi M. Cemil KARACADAĞ'a, tezin yazım ve düzenlemesinde benimle defalarca sabahlayan bilgisayar sistemleri öğretmeni Harun ÇAKIR'a, zamanlarından çalarak çalıştığım eşim, çocuklarım ve aileme sonsuz sevgi ve saygılarımı sunarım.

Mehmet ALBAYRAK

Isparta, 2008.

İÇİNDEKİLER

TEŞEKKÜR.....	ii
İÇİNDEKİLER	iii
SİMGELER VE KISALTMALAR LİSTESİ	vii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	x
ÖZET.....	xi
SUMMARY	xii
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
EPİLEPSİ (SARA HASTALIĞI).....	9
2.1. Epilepsi'ye Neden Olan Etkiler	10
2.1.1. Epilepsiyi tetikleyici etkenler.....	11
2.1.2. Kalıtsal (genetik) faktörler	12
2.2. Nöbet Türleri.....	13
2.2.1. Parsiyel nöbetler	13
2.2.1.1. Basit parsiyel nöbetler.....	13
2.2.1.2. Kompleks parsiyel nöbetler	14
2.2.2. Absans nöbeti	15
2.2.3. Miyoklonik nöbetler	15
2.2.4. Tonik-klonik (grand mal) nöbetler	16
2.2.4.1. Tonik safha.....	16
2.2.4.2. Klonik safha	17
2.2.4.3. Gevşeme safhası.....	17
2.2.4.4. Nöbet sonrası	17

BÖLÜM 3.

EEG SİNYALLERİNİN ÖZELLİKLERİ.....	18
3.1. EEG Aktivitesini Tanımlayan Nitelikler	21
3.1.1. Yineleme	24
3.1.2. Frekans	24
3.1.3. Genlik (Amplitüd).....	25
3.1.4. Dağılım.....	26
3.1.5. Faz İlişkisi	27
3.1.6. Zamanlama	28
3.1.7. Israrlılık	29
3.1.8. Reaktivite	29
3.2. Normal EEG'nin Tanımlanması	30
3.2.1. Alfa ritmi	31
3.2.2. Beta ritimleri	34
3.2.3. MU ritmi.....	36
3.2.4. Lambda dalgaları.....	37
3.2.5. V dalgaları	37
3.2.6. Kappa ritmi.....	38
3.2.7. Normal posterior teta ritimleri.....	38
3.2.8. Düşük voltajlı EEG	38
3.2.9. Majör anormallikler.....	39
3.3. Anormal EEG'nin Tanımlanması.....	40
3.4. EEG Paternleri ile Nörolojik Hastalıklar Arasındaki Bağını.....	41
3.5. EEG'nin Tanı Değeri.....	42

BÖLÜM 4.

EEG SİNYAL ANALİZİ VE MODELLEME METODLARI	44
4.1. Sinyal Analiz Metotlarının Gelişimi.....	45
4.2. Klasik Spektral Analiz Metodları	47
4.2.1. Akan fourier dönüşümü.....	48
4.2.2. Kısa zaman fourier dönüşümü	48
4.2.3. Ayrık fourier dönüşümü	49
4.2.4. Hızlı fourier dönüşümü	49

4.2.5. Zak dönüşümü	50
4.2.6. Periodogram yöntemi	50
4.3. Modern Spektral Analiz Yöntemleri.....	51
4.4. Altuzay Yöntemleri.....	52
4.5. Dalgacık Dönüşümü (Wavelet) ile Sinyal Analizi	52

BÖLÜM 5.

VERİ MADENCİLİĞİ METODOLOJİSİ.....	56
5.1. Veri Madenciliğinin Gelişimini Etkileyen Faktörler	59
5.2. Veri Madenciliği İle Yapılabilecekler	60
5.3. Veri Madenciliğinin Gereksinimleri	62
5.4. Veri Madenciliği Uygulamalarında Karşılaşılan Problemler	63
5.5. Veri Madenciliği Yazılımları.....	64
5.6. Veri Madenciliği Süreci.....	64
5.6.1. Problemin tanımlanması.....	65
5.6.2. Verilerin hazırlanması	66
5.6.3. Modelin kurulması ve değerlendirilmesi.....	67
5.6.4. Modelin kullanılması.....	67
5.6.5. Modelin izlenmesi	68
5.7. Veri Madenciliği ve Makine Öğrenmesi Kuramı	68
5.8. Veri Madenciliğinde Kullanılan Yöntemler	70
5.8.1. Sınıflama ve regresyon modelleri	71
5.8.1.1. Diskriminant analizi.....	71
5.8.1.2. Naive bayes	72
5.8.1.3. Karar ağaçları.....	72
5.8.1.4. Yapay sinir ağları	73
5.8.1.5. Kaba kümeler	74
5.8.1.6. Genetik algoritma.....	74
5.8.1.7. Bellek temelli nedenleme.....	75
5.8.1.8. Regresyon analizi.....	76
5.8.2. Kümeleme modelleri	77
5.8.3. Birliktelik kuralları ve ardışık örüntüler.....	79
5.9. Tıbbi Verilerle Veri Madenciliği	80

5.9.1. Tıbbi verilerle veri ambarının oluşturulması.....	81
5.9.2. Tıbbi verilerin özellikleri	82
BÖLÜM 6.	
GERÇEKLEŞTİRİLEN ÇALIŞMA	84
6.1. Literatür Taraması.....	84
6.2. Çalışmada Kullanılan Veriler ve Özniteliklerinin Çıkartılması.....	91
6.3. Verilerin Analizi	98
BÖLÜM 7.	
SONUÇ VE ÖNERİLER	100
KAYNAKLAR	103
EKLER.....	112
ÖZGEÇMİŞ	130

SİMGELER VE KISALTMALAR LİSTESİ

ADD	: Ayrık Dalgacık Dönüşümü
AFD	: Ayrık Fourier Dönüşümü
AR	: Otoregresif (Auto Regressive)
ARMA	: Otoregresif Hareketli Ortalama (Auto Regressive Moving Average)
BT	: Bilgisayarlı Tomografi
C&RT	: Classification and Regresion Trees
CHAID	: Chi-squared Automatic Interaction Detector
ÇKA	: Çok Katmanlı Ağ
DD	: Dalgacık Dönüşümü
dEEG	: Dijital Elektroensefalogram
EEG	: Elektroensefalogram
EKG	: Elektrokardiyogram
EMG	: Elektromiyogram
EV	: Özvektör (Eigenvector)
FD	: Fourier Dönüşümü
GA	: Genetik Algoritma
GID3	: Generalized Iterative Dichotomiser 3
GSY	: Güç Spektral Yoğunluğu
HFD	: Hızlı Fourier Dönüşümü
Hz	: Hertz
ID3	: Iterative Dichotomiser 3
KZFD	: Kısa Zamanlı Fourier Dönüşümü
MA	: Hareketli Ortalama (Moving Average)
MRG	: Magnetik Rezonans Görüntüleme
MUSIC	: Çoklu Sinyal Sınıflama (Multiple Signal Classification)
p-p	: Tepeden Tepeye (Peak to Peak)
RTFA	: Radyal Tabanlı Fonksiyon Ağı

WEKA	: Waikato Environment for Knowledge Analysis
WNN	: Dalgacık Sinir Ađı (Wavelet Neural Network)
YSA	: Yapay Sinir Ađı
α	: Alfa
β	: Beta
γ	: Gamma
δ	: Delta
θ	: Teta

ŞEKİLLER LİSTESİ

Şekil	3.1.EEG kaydı blok şeması.....	19
Şekil	3.2.EEG dalga formları.....	22
Şekil	3.3.Örnek bir EEG kaydı.....	23
Şekil	3.4.EEG frekans ölçüm cetveli.....	25
Şekil	4.1.Epileptik EEG işareti ve periodigram spektrumu.....	50
Şekil	4.2.Daubechies dalgacığı.....	54
Şekil	5.1.Veri madenciliği aşamaları.....	58
Şekil	5.2.Veri madenciliği süreci.....	65
Şekil	6.1.10-20 sistemine göre EEG elektrot yerleşim düzeni.....	93
Şekil	6.2.10-20 sistemine göre elektrotların yan ve üst görünümü.....	93
Şekil	6.3.Veritabanında bulunan veri setlerine ait grafik örnekleri.....	94
Şekil	6.4.A veri setine ait genlik ($\square V$) ve örnekleme değişim örneği.....	94
Şekil	6.5.B veri setine ait genlik ($\square V$) ve örnekleme değişim örneği.....	95
Şekil	6.6.C veri setine ait genlik ($\square V$) ve örnekleme değişim örneği.....	95
Şekil	6.7.D veri setine ait genlik ($\square V$) ve örnekleme değişim örneği.....	95
Şekil	6.8.E veri setine ait genlik ($\square V$) ve örnekleme değişim örneği.....	96
Şekil	8.1.M5P algoritmasına ait karar ağacı.....	119
Şekil	8.2.REPTree algoritmasına ait karar ağacı.....	120

TABLULAR LİSTESİ

Tablo 5.1.	Veri madenciliğinin uygulandığı alanlar	62
Tablo 5.2.	Veri madenciliği yazılımları ve çalıştıkları platformlar	64
Tablo 7.1.	Kullanılan veri madenciliği algoritmaları ve sonuçları	101

ÖZET

Anahtar kelimeler: Veri madenciliği, epileptiform aktivite, EEG

Türkiye’de ve dünyada; biyomedikal ve sinyal işleme konularındaki çalışmalara bakıldığında; elektronik sistem tasarımları, matematiksel modeller, istatistik metotlarla yapılmış çalışmalar, yapay zekâ tabanlı (bulanık mantık, yapay sinir ağları ve genetik algoritmalar içeren) çalışmalar ve tıbbi yazılımlar (genel olarak mobil uygulamalar ve cihaz otomasyonları) olarak gruplandırılabilir. Bu alandaki çalışmaların özellikle 2000 yılından sonraki artışı dikkat çekicidir. Türkiye’de ve dünyada veri madenciliği alanında çalışmaların çok yeni ve az oluşunun yanı sıra, tıbbi veriler üzerindeki veri madenciliği çalışmalarının yok denecek kadar az olması konunun önemini ortaya koymaktadır. Veri madenciliği süreçlerinin tıbbi veriler üzerinde uygulanması sonucunda analiz süresinin kısaldığı ve yüksek doğruluk oranı içeren sonuçlar elde edildiği görülmektedir. Çalışma bu bakımdan ele alındığında, güncel bir uygulama olarak önem taşımaktadır.

Bu çalışmada; elektroensefolagram (EEG) verileri üzerinde, epileptik aktivitelerin olup olmadığının belirlenmesi ve daha sonraki aşamalarda geliştirilecek ilave yazılımlarla otomatik teşhis koymaya yardımcı bir araç geliştirilmesi amaçlanmıştır. Verilerin veri madenciliği süreçleri kapsamında sınıflama ve kümeleme algoritmaları kullanarak tespit edilebilmesi için öncelikli olarak sekiz adet öznitelik parametresi seçilmiş ve belirlenen öznitelik değerleri hesaplanmıştır. Belirlenen öznitelikler için elde edilen sonuçlar, onbir ayrı veri madenciliği algoritmasına tabi tutulmuş ve seçilen bazı algoritmaların yüksek doğruluk oranı ile epileptik aktiviteyi tespit ettiği görülmüştür. Böylelikle farklı veri madenciliği algoritmaları ile elde edilen sonuçların hesaplama sürelerinin ve doğruluk oranlarının kıyaslanması sağlanmıştır. En yüksek doğruluk oranını verdiği tespit edilen algoritmalar yardımı ile bu alanda çalışan uzmanların epileptik aktivite teşhisi koymalarına zemin oluşturmak, ilgililerin teşhis sürecinde karar vermelerini kolaylaştırmak ve konulan teşhislerde doğruluk oranını yükselterek, Türkiye’de nöroloji ve bilgisayar bilimleri literatürüne katkı sağlanması hedeflenmiştir.

THE DETECTION OF AN EPILEPTIFORM ACTIVITY ON EEG SIGNALS BY USING DATA MINING PROCESS

SUMMARY

Key Words: Data mining, epileptiform activity, EEG

The studies generally include electronic system designs, mathematical models, statistical analysis, fuzzy logic, neural network and genetic algorithm based models, mobile medical applications and related software designs and intelligent equipment automations. A very limited and insufficient number of studies on data mining in the world and Turkey clearly show the need for such studies.. Such findings indicate that this study has high implementation value and an up-to-date subject.

In this study; the goal is to develop a tool and additional software that would help diagnose whether or not there are epileptic activities based on electroencephalograph (EEG) data. Firstly, eight attribute parameters are selected in order to be able to gather data by using grouping and classification algorithm in the process of data mining. Then, the values of selected attribute parameters are determined. Thirdly, the values of selected attribute parameters are analyzed by eleven different data mining algorithms and it is observed that some selected algorithms help detect epileptic activity with high accuracy levels. Accordingly, it is found that different data mining algorithms allow for a comparison of calculation time and accuracy levels of the results. Through the algorithms that give the highest accuracy level, the findings of the study provide health care professionals with the data to diagnose epileptic activity, to ease the decision making process in the process of diagnosis, and to contribute to neurological studies and computer science literature in Turkey by increasing the level of accuracy in diagnosis.

BÖLÜM 1. GİRİŞ

Tıp; yüzyıllarca ustadan çırağa geçen, her kuşağın deneyimlerini yeni kuşaklara aktarımı ile ilerleyen bir bilim olarak yürümektedir. Son yüzyılda teknolojiye görülen ilerlemelere bağlı daha nesnel ve bilimsel bir nitelik kazanmıştır. Teknolojinin hızla ilerlemesi, tıp bilimine giderek daha fazla tanı koymaya yardımcı araçlar ve teknikler sağlamıştır. Örneğin; röntgen ışınları ile görüntüleme gibi basit bir teknik, yeni teknolojiler sayesinde bilgisayarlı tomografi gibi daha karmaşık ve tanıya yardımcı bir yönteme dönüşmüştür. İleri teknoloji, önceleri daha çok yeni tanı metotları geliştirilmesinde rol oynamasına rağmen daha sonra cihazlarda elde edilen sonuçların daha kolay ve otomatik olarak yorumlanması için de kullanılmıştır [1].

Canlıların vücudunda, hücrelerde oluşan biyolojik kaynaklı elektriksel aktivitenin sonucu olarak, pek çok elektriksel sinyal oluşmaktadır. Bu sinyallerden biri de beyinde oluşan elektriksel aktivitenin ölçümü olan elektroensefolagram (EEG) sinyalleridir. EEG; beyindeki sinir hücreleri tarafından hem uyanık, hem de uyku halindeyken oluşan beyin dalgalarındaki elektriksel faaliyetlerin kâğıt üzerine grafik halinde yazdırılmasıdır [2].

EEG sinyalleri serebral kortekste bulunan nöronlar tarafından üretilmektedir. Bu sinyaller birçok uyarana verilen yanıtlardır. Beynin derinliklerinde bulunan, ritim düzenleyen (pacemaker) merkezlerin oluşturduğu ritimler de EEG sinyallerini oluşturmaktadır [3].

Caton 1875 yılında hayvanlar üzerinde yaptığı deneyler sonucunda ilk defa, beyinde bir takım elektriksel faaliyetlerin varlığını keşfetmiştir. 1929 yılında ilk defa, Hans Berger, kafaya yerleştirilen elektrotlar ve bunlara bağlı bir galvanometre yardımıyla insan beyinde elektriksel aktivitenin varlığını ortaya koymuştur. Berger, 1930'da

Elektroensefolagram adı verilen bu dalgaların gözün açılıp kapanmasıyla değiştiğini ortaya koymuştur [4].

Elektronikteki gelişmelerle birlikte EEG işaretlerinin varlığı bilimsel bir şekilde ortaya konulmuştur. 1934'de Adrian ve Matthews, elektrotlarla alınan EEG işaretlerini kuvvetlendirip kaydedilmesini sağlamışlardır. 1939'da P. A. Davis, uyanık bir insanın EEG'sinde, sese karşı uyarılan yanıtların olduğunu bulmuştur. H. A. Davis ve arkadaşları aynı yıl, aynı olayın uyuyan insanda da meydana geldiğini göstermişlerdir. İkinci dünya savaşından sonra, elektronik ve bilgisayar alanlarında meydana gelen büyük gelişmelerin olumlu sonuçları, bu alanda da kendisini göstermiş ve EEG'nin klinik uygulamaları geliştirilerek tanımı üzerinde yapılan araştırmalar olumlu sonuçlar vermiştir [4].

EEG'nin çok karmaşık bir değişim şekli vardır ve yorumlanması güçtür. Yüzeiden ölçülen EEG potansiyelleri, alttaki birçok noktadan ve serebral korteksin oldukça geniş bir bölgesinden gelen potansiyellerin toplamından oluşmaktadır. Deneyler, EEG frekansının kişinin zihin faaliyeti ile değiştiğini göstermektedir [4].

Son yıllarda geliştirilen yöntemlerin bazıları işaretlerin istatistiksel analizinin yapılmasında, diğerleri ise özel dalga şekillerinin belirlenip, ayrıştırılıp incelenmesinde kullanılmaktadır [5]. EEG işareti geniş bir frekans bandına sahip olmakla birlikte, klinik ve fizyolojik ilgi 0.5 ile 30 Hz arasına yoğunlaşmıştır. Bu frekans aralığı belli frekans bantlarına ayrılmıştır. Bu yaklaşım EEG spektrumunun temelde delta (0.5-4 Hz), teta (4-8 Hz), alfa (8-13 Hz) ve beta (13-30 Hz) şeklinde dört frekans bandı içerdiği gözlemlerine dayanmaktadır [6].

Kişi uyanır uyanmaz veya düşünmeye başlarken alfa ritmi kaybolur ve yerine senkronize olmayan biçimde, genellikle beta bandında bir ritim oluşmaktadır. Günümüzde, beyinde oluşan spektral bantlardaki değişimin ve bu işlemi yapan mekanizmanın bulunması üzerine pek çok araştırma yapılmaktadır.

EEG işaretlerinin frekans bileşenleri oldukça önemli olduğu gibi, farklı bölgelerden alınan benzer EEG işaretleri arasındaki faz ilişkileri oldukça ilgi çekmektedir. Bu tip

bilgiler, EEG'nin kaynağının incelenmesinde çok faydalı olup beyin çalışması ile ilgili ilave bilgiler elde edilmesini sağlamaktadır. Kafa üzerinden algılanan EEG'lerin genliği tepeden tepeye 1-100 μ V ve frekans bandı ise 0.5-100 Hz'dir. Ölçümler beyin üzerinden doğrudan alındığı takdirde, genlik 10 kat daha artmaktadır. EEG'de oluşan farklı frekansların oluşum mekanizmaları henüz tam olarak anlaşılamamıştır [4].

Elektroensefalogram (EEG) sinyali, elektrokardiogram (EKG) ve elektromiyogram (EMG) işaretlerinde olduğu gibi şekil bakımından değil, kapsadığı frekanslara göre değerlendirilmektedir. EEG işaretleri periyodik değildir; genlik, faz ve frekansları sürekli değişmektedir. Bu nedenle anlamlı bir veri elde etmek için ölçümlerin oldukça uzun bir sürede yapılması gerekmektedir. EEG işaretlerinin ana frekansı ile beyin aktivitesi yakından ilişkilidir. Buna bağlı olarak aktivite ile frekans birlikte yükselir ya da değişim göstermektedir [4].

EEG özellikle beynin fonksiyonel ve mental aktivitesi incelenirken bulguların netleştirilmesine yardımcı olmaktadır. EEG işaretleri, beynin fiziksel ve zihinsel aktivitesine göre dört ana frekans bandına sahip spektral bileşenler (α , β , δ , θ dalgaları) içermektedir. EEG sinyallerinin bilgisayar ortamında analiz edilebilmesi için; öncelikli olarak analiz edilecek sinyaller sayısallaştırılarak kaydedilmelidir [3]. Sayısallaştırılan EEG sinyalleri kullanılan cihazın özelliğine göre, belli frekanslarda örneklenmektedir. Sayısallaştırılıp örneklenmiş olarak kaydedilen EEG işaretleri, modern işaret işleme teknikleri ile analiz edilerek, hastalık tespitinde yol gösterici olmaktadır.

Beynin normal elektriksel faaliyeti, beyin kaynaklı pek çok hastalık ve ani şoklar durumunda bozulabilmektedir. EEG'yi oluşturan beyin dalgalarının değerlendirilmesi ile bu bozulmanın gerçekleştiği bölge ve bozulma durumundaki sinyal şekli hakkında bilgi edinilebilmektedir. Özellikle epilepsi hastalığının teşhisinde ve tiplerinin belirlenmesinde tedaviye karar verecek olan inceleme yöntemi EEG'dir. Ancak kısa süren epileptik dalga şekillerinin gözle tanınması zor ve zaman alıcı bir işlemdir [2]. EEG kaydını değerlendiren uzman, değerlendirme sürecinde epileptik dalga şekillerinin genel tanımlarından yararlandığı gibi, tüm

kanalların etkileşimleri, önceki ve sonraki dalga şekilleri gibi sübjektif bilgilerden de yararlanılmaktadır. Bu yüzden EEG kayıtlarının yorumlanmasında bu alanda eğitilmiş, deneyimli bir uzman gerekmektedir. Böyle bir EEG uzmanının da EEG kaydı yapılan her yerde bulunması pratik olmadığı gibi ekonomikte değildir [7].

Modern tıbbın gelişimi ile özellikle nörolojik kökenli rahatsızlıkların tanı ve tedavisinin izlenmesinde kullanılan EEG teknikleri de benzer bir gelişim göstermiştir. İlk EEG kayıtlarının gerçekleşmesinden bir süre sonra, bu kayıtların otomatik olarak değerlendirilmesi gündeme gelmiştir. Geçmişten günümüze bu amaçla birçok yöntem geliştirilmiş ve uygulanmıştır [1].

Klinik bağlamda ele alındığında, nöbetler birçok tıbbi hastalık sırasında ortaya çıkabilmektedir. Bu serebral korteksin hastalık tarafından primer veya sekonder olarak etkilendiğini göstermektedir. Konvülfif nöbetler doğaları gereği, status epileptikus da olduğu gibi dakikalar içerisinde tekrarlırsa yaşamı tehlikeye sokabilmektedir. Aynı şekilde önemli olan bir nokta da, bir nöbetin veya nöbet serisinin, özel tanı ve tedavi uygulamaları gerektiren beyin tümörü örneğinde olduğu gibi, devam edegelen bir nörolojik hastalığın bulgusu olabileceğidir [8].

Epilepsi nöbet halinde kendini belirten bir hastalıktır. Nöbetler, beyindeki elektriksel dengenin aniden geçici olarak bozulmasıyla meydana gelmektedir. Nöbetlerin şekli kişiden kişiye değişmektedir. Bazıları yere düşüp kollarıyla ve bacaklarıyla çırpınarak bunu belli ederken, bazıları vücutlarında tuhaf karıncalanmalar hisseder, garip sesler duyar veya kısa bir süre için etraflarına dik dik bakarlar. Bu durum epilepsinin çeşitli nedenlerden ortaya çıkmasından kaynaklanmaktadır. Epilepsinin bazı türleri de yaşa bağlıdır. Bu, nöbetlerin belli bir yaş döneminde olduğunu ve yaşlandıkça kaybolabilecekleri anlamına gelmektedir. Birçok epilepsi türü ise, buna karşı bir eğilim, beyin hastalığı veya beyin hasarından meydana gelmektedir. Bu nöbetler çok ender olarak kendiliğinden kaybolur. Epilepsiden ancak, bir yıl içinde birden fazla epileptik nöbet geçirildikten sonra bahsedilebilmektedir. Sadece bir tek nöbet geçirilmesi halinde, epilepsi var anlamı çıkarılmamalıdır. Bu nöbet bazı özel durumlara bağlı ortaya çıkmış olabilir. Bu durumda bir sonraki nöbetin gelme ihtimali nispeten daha azdır. Belki de bu durum başka bir hastalığın sonucu olabilir.

Tedaviye ancak, hastaya kesin 'epilepsi' teşhisi konulduktan sonra geçilebilir. Epilepsiyi tedavi etmenin en doğru yöntemi ilaçlarla olmaktadır [9]. İlaç tedavisi ile çözümlenemeyen durumlarda cerrahi müdahale gerekmekte, fakat bu durum yüksek risk taşımaktadır.

Daha sık rastlanan ve nispeten daha az kötü bir durum ise, bu nöbetin uzun bir süre içinde tekrarlayan çok sayıda nöbetlerden biri olmasıdır ki burada nöbetlerin çoğu birbirine az çok benzer özellik göstermektedir. Bu durumda, bunlar geçmişte oluşmuş ve sönerak skara dönüşmüş bir lezyon sonucu olabilirler. Orijinal hastalık farkedilmeden geçmiş olabilir. Rahatsızlık doğumda, çocukluk dönemlerinde ya da beynin muayene edilemeyen bölgelerinde oluşmuş olabilir. Olgunlaşmış beyinde çok küçük veya sessiz bir bölgeyi etkilemiş olabilir. Literatürde patolojik temeli bulunamamış olan ve olası genetik bir neden dışında asıl nedeni gösterilememiş başka epilepsi tiplerinin de mevcut olduğu görülmektedir. Bunlardan primer olarak bahsedilir. Bu kategoride örneğin bazı jeneralize tonik-klonik (grand mal) ve absans nöbetleri yer almaktadır. Nöbetler birçok şekilde gruplanır. Bunlar; nedene göre idyopatik (primer) veya semptomatik (sekonder); kaynaklandıkları yere göre; klinik şekillerine göre (jeneralize veya fokal); sıklıklarına göre (izole, sıklık veya tekrarlayıcı veya status epileptikustaki gibi yakın zaman ilişkisi içinde) veya elektrofizyolojik karşılıklarına göre sınıflandırılabilir [8].

Epilepsinin ne olduğu, bir nöbet sırasında neler yaşandığı, kalıtsal yönleri ve oluşum sebepleri oldukça bilindik olmasına rağmen, yine de bazı belirsizlikler devam etmektedir. Bilim adamları, beyindeki sinyallerin dönüşümünün nasıl gerçekleştiğini genellikle bilmekle birlikte, halen bu konuda birçok soru cevapsızdır. Epilepsi hakkında araştırmalar aralıksız devam etmektedir. Epilepsi teşhisi konulurken, analize yardımcı başka araçlar veya yazılımlar kullanılmadığı durumlarda, doğruluk oranının yüksek olması, öncelikle doktorun tecrübesi ile doğru orantılıdır. Hatalı konulan veya konulamayan teşhisler, insanların yaşamını doğrudan etkilemektedir. Bunlar dikkate alındığında, öncelikli olarak teşhisin konulması ve konulan teşhisin doğruluk oranı önem taşımaktadır.

Herhangi bir analiz yöntemine tabi tutulacak EEG kaydında, önce uygun bölümler görsel olarak incelenir ve seçilir. Bu işlem sırasında özellikle gürültü ve bozucu işaretlerin bulunduğu bölümler atılarak, uygulanacak analiz yöntemine uygun özellik gösteren bölümler ayrıştırılır. Epilepsi analizinde; diken ve keskin dalga gibi özel dalga şekillerinin bulunduğu bölümler seçilmektedir. Ardından EEG işaretinin bölümleri sınıflandırılır ve ilgili analiz yöntemine tabi tutularak gerekli bilgiler elde edilir [10].

Rutin klinik teşhislerde EEG işaretlerinin analizine duyulan ihtiyaç, otomasyon ve bilgisayar tekniklerinin kullanımını zorunlu kılmıştır. Bu nedenle objektif bir değerlendirme yapabilmek için EEG işaretlerinin farklı yöntemlerle analiz edilmesi yoluna gidilmiştir. Son yıllarda geliştirilen bu yöntemlerin bazıları işaretlerin istatistiksel analizinin yapılmasında, diğerleri ise özel dalga şekillerinin belirlenip, ayrıştırılıp incelenmesinde kullanılmaktadır. Bu yöntemlere örnek olarak; frekans analizi, özilişki ve çapraz ilişki analizi, otoregresif (autoregressive - AR) modelleme yöntemi ve dalga şekillerinin ayrıştırılması ve sınıflandırılması sayılabilir [5, 10]. Spektral analiz yöntemleri; klasik (parametrik olmayan), modern (parametrik) ve alt uzay yöntemleri olmak üzere üç gruba ayrılmaktadır [10]. Özellikle son beş yılda yapılmış çalışmalar incelendiğinde kullanılan analiz yöntemlerine ek olarak özellikle yapay sinir ağları ve dalgacık (Wavelet) dönüşümü kullanılan çalışmalar göze çarpmaktadır.

Türkiye’de ve dünyada; biyomedikal ve sinyal işleme konularındaki çalışmalara bakıldığında, hem teorik hem de uygulamalı olarak çok sayıda çalışmanın bulunduğu göze çarpmaktadır. Bu çalışmalar genel olarak; elektronik sistem tasarımları, matematiksel modeller, istatistik metotlarla yapılmış çalışmalar, yapay zekâ tabanlı çalışmalar (bulanık mantık, yapay sinir ağları ve genetik algoritmalar içeren) ve tıbbi yazılımlar (genel olarak mobil uygulamalar ve cihaz otomasyonları) olarak gruplandırılabilir. Bu alandaki çalışmalar ve özellikle yayınların son beş yıldaki artışı ise dikkat çekicidir.

Bu konunun doktora tez konusu olarak seçilmesinin en önemli nedeni; Türkiye’de ve dünyada veri madenciliği alanında çalışmaların çok yeni ve çok az oluşunun yanı

sıra, tıbbi veriler üzerindeki veri madenciliği çalışmalarının yok denecek kadar az olmasıdır. Veri madenciliği süreçlerinin tıbbi veriler üzerinde yüksek doğruluk oranı içeren sonuçlar elde etmesi ve analiz sürecini kısaltması dikkate alındığında, güncel ve çarpıcı bir uygulama olması önem taşımaktadır.

Veri madenciliği alanında devam eden bir uluslararası proje de IBM firmasının salgın hastalıkların yayılmasını önlemek amacıyla, Dünya Sağlık Örgütü (WHO) ve küresel çapta faaliyet gösteren diğer toplum sağlığı kuruluşlarıyla işbirliği yapması gösterilebilir. IBM, Global Salgın Hastalıklar Girişimi (Global Pandemic Initiative) grubuna sunduğu BT altyapısıyla, dünyanın değişik bölgelerindeki sağlık örgütlerinin salgın hastalıklar konusundaki bilgilerini aynı anda paylaşmalarını sağlamayı planlamaktadır. IBM, sahip olduğu süper bilgisayar Blue Gene ve ileri yazılım teknolojilerini kullanarak, salgın hastalıkların yayılma profillerini ve bunları önlemenin yöntemlerini belirlemeye çalışmaktadır. Proje kapsamında IBM, sağlık örgütlerinin birbirleriyle hızlı ve gerçek zamanlı bilgi paylaşımını sağlamak amacıyla araştırma laboratuvarını önde gelen sağlık kurumlarının kullanmasına açacaktır. IBM, Çin, Hindistan, İsrail, Japonya, İsviçre ve ABD'deki 8 araştırma laboratuvarında projeye ilgili iletişim merkezleri oluşturarak dünyanın birçok noktasındaki sağlık örgütü arasında ortak bir iletişim ağı kuracaktır. Hızlı iletişim sayesinde toplanan güncel bilgi yine IBM'in geliştirdiği veri madenciliği süreçleri içeren yazılımlarla veriler işlenerek, araştırmacıların salgın hastalıklar hakkında çok yönlü bilgi elde edebilmeleri planlanmaktadır. IBM, iletişim ağı aracılığı ile toplanan bilgilerde veri madenciliği yaparak yol haritaları, kuşların göç yolları ve seyahat eğilimleri gibi verileri, sağlık kuruluşlarının salgın hastalıklarla ilgili verileriyle eşleştirecek ve salgınların coğrafi yayılışını saptama imkânını sağlayacaktır. IBM ayrıca virüslerin zaman içinde nasıl bir evrim geçirdiği hakkındaki bilgileri sağlık kurumlarına ulaştırarak, ilaç üreticileri arasındaki bilgi transferini de gerçekleştirecektir. Böylelikle ilaç üreticilerinin daha etkili aşular geliştirebilmesi ve bu aşuların potansiyel salgın bölgelerine zamanından önce gönderilebilmesi sağlanacaktır [11].

Türkiye'de yapılan lisansüstü tez çalışmaları Haziran 2008 itibariyle incelendiğinde, veri madenciliği ile ilgili toplam 133 adet çalışma bulunduğu göze çarpmaktadır. Bu çalışmaların büyük bir bölümü işletme, ekonomi, istatistik, bilgisayar bilimleri

anabilim dallarında ilgili olduğu görülmektedir. Tıbbi veriler kullanılarak yapılmış veri madenciliği süreci içeren sadece bir adet bulunmakta çalışma ve yüksek lisans tez çalışması olarak karşımıza çıkmaktadır. Söz konusu çalışma “Osteoporoz hastalığının tanısı için veri madenciliği kullanımı” konusunda Fırat Üniversitesi Fen Bilimleri Enstitüsünde Süleyman Gökalp Öger tarafından yapılan yüksek lisans tezidir. Veri madenciliği süreçleri kullanılarak yapılan analizlerde elde edilen sonuçların doğruluk oranı, doğru modeller kullanıldığında, diğer analiz yöntemlerine göre genellikle daha yüksek olduğu görülmektedir. Bunun sebebinin veri madenciliğinin diğer yapay zekâ tekniklerini de kullanan bir süreç olduğu söylenebilir. Çalışmada veri madenciliği tekniklerinin kullanılması bu sebeple tercih edilmiştir.

Bu çalışmanın amacı; elektroensefolagram verileri üzerinde, epileptik aktivitelerinin olup olmadığının, veri madenciliği süreçleri kapsamında sınıflama ve kümeleme algoritmaları kullanarak tespit edilmesi, bu algoritmalarından elde edilen sonuçlarının mukayese edilmesi ve en yüksek doğruluğu sağlayan algoritmaların bulunmasıdır. En yüksek doğruluk oranını verdiği tespit edilen algoritmalar yardımı ile bu alanda çalışan uzmanların epileptik aktivite teşhisi koymalarına bir zemin oluşturmak, ilgililerin teşhis sürecinde karar vermelerini kolaylaştırmak ve konulan teşhislerde doğruluk oranını yükselterek, Türkiye’de nöroloji ve bilgisayar bilimleri literatürüne katkı sağlanması çalışmanın amaçları arasında yer almaktadır.

Veri madenciliği süreçleri ile yapılan çalışmalarda elde edilen sonuçların doğruluk oranları diğer yöntemlere göre daha yüksek olduğunun görülmüştür. Veri madenciliği tekniklerinin çok sayıda sınıflama ve kümeleme algoritmalarında elde edilen sonuçların mukayese edilerek en uygun modellerin seçilmesi ve Türkiye’de tıbbi veriler ile yapılan veri madenciliği çalışmalarının sınırlı olması gibi faktörler göz önünde bulundurulduğunda, tez çalışmasında epileptik aktivite tespitinde veri madenciliği süreçlerinin kullanılması tercih edilmiştir.

BÖLÜM 2. EPİLEPSİ (SARA HASTALIĞI)

Epilepsi; halk arasında “sara veya tutarık” olarak bilinen beyin odaklı bir hastalıktır. Toplum genelinde; bu hastalıkla ilgili olarak pek çok gerçek bilinmemektedir. İnsanların bazıları, belki de birinin grand mal nöbeti geçirdiğini tesadüfen görmüş olabilirler. Araştırmalara göre epilepsi hastası oranı, ülkelere göre değişiklik göstermekle beraber, 1/150 civarındadır. Nöbet; epilepsi hastalığının dış dünyada fark edilmesinin sadece bir şeklidir. Bunun yanı sıra, nöbet şekilleri de çok farklıdır. Epilepsi ile bilinen gerçekler şunlardır:

1. Herkes her yaşta epilepsi hastası olabilmektedir.
2. Epilepsi tamamen atlatılmaz. Ancak epilepsi hastası çoğu kişi, aldığı doğru ilaçlarla nöbet geçirmeden de hayatını sürdürebilir. Bu nedenle çevre, o kişinin epilepsi hastası olduğunu çoğunlukla anlayamayabilir.
3. Çok istisnai durumlarda beyindeki epileptik merkez ya ameliyatla aldırılır ya da devre dışı bırakılabilir.
4. Epilepsi ile zihinsel özür arasında herhangi bir bağlantı tespit edilememiştir.
5. Ancak, zihinsel özürlü kişilerin diğer kişilere oranla daha fazla epilepsi hastası oldukları da doğrudur. Epilepsi hastalığının nedeni, genellikle zihinsel özre neden olan beyin hasarından kaynaklanmaktadır.
6. Epilepsi kesinlikle bulaşıcı bir hastalık değildir [9].

Epilepsi nöbet halinde kendini belirten bir hastalıktır. Nöbetler, beyindeki elektriksel dengenin aniden geçici olarak bozulmasıyla meydana gelmektedir. Nöbetlerin şekli kişiden kişiye değişir. Bazıları yere düşüp kollarıyla ve bacaklarıyla çırpınarak bunu belli ederler. Bazıları ise, vücutlarında tuhaf karıncalanmalar hisseder, garip sesler duyar veya kısa bir süre için etraflarına dik dik bakarlar. Bu da, epilepsinin çeşitli nedenlerden dolayı ortaya çıkmasından ileri gelir. Bu nedenler; nöbetlerin türü ve miktarını belirlemektedir. Prognoz da kişiden kişiye değişir. Epilepsinin bazı türleri

de yaşa bağlıdır. Yani bu durum nöbetlerin belli bir yaş döneminde olduğunu ve yaşlandıkça kaybolabilecekleri anlamına gelmektedir. Birçok epilepsi türü ise, buna karşı bir eğilim, beyin hastalığı veya beyin hasarından oluşmaktadır. Bu nöbetler çok ender olarak kendiliğinden kaybolabilir. Epilepsiden ancak, bir yıl içinde birden fazla epileptik nöbet geçirildikten sonra bahsedilmesi mümkündür. Sadece bir tek nöbet geçirilmiş ise epilepsi var anlamına gelmemektedir. Nöbet, bazı durumlar sonucu ortaya çıkmış olabilir. Bu durumda bir sonraki nöbetin gelme ihtimali nispeten daha az olmaktadır. Belki de bu durum başka bir hastalığın sonucu ortaya çıkmış olabilir. Tedaviye ancak, hastaya kesin “epilepsi” teşhisi konulduktan sonra geçilmesi uygundur. Epilepsiyi tedavi etmenin en doğru yöntemi, ilaçlarla olmaktadır [9].

2.1. Epilepsi’ye Neden Olan Etkiler

Epilepsi, çok sayıdaki çeşitli rahatsızlıklardan oluşabilir. Vakaların yarısından daha fazlasında halen bir neden bulunamamaktadır. Yapılan araştırmalar sonucu bir beyin hasarı bulunduğu ortaya çıksa bile, bunun nasıl meydana gelmiş olduğu genellikle bilinmemektedir. Bazen, hastada kendiliğinden var olan eğilim de buna neden olabilmektedir. Kalıtım epilepside önemli bir rol oynamaktadır. Epilepsinin nedeni genellikle birçok etkene bağlıdır. Bir bölümü, oluşan beyin rahatsızlıklarından, bir bölümü genetik, başka bir bölümü ise aniden meydana gelen dış (tetikleyici) etkenlerden oluşabilmektedir [9].

Epilepsi, doğumdan önce veya doğum sırasında oluşabilir. Hamilelik sırasındaki bir enfeksiyon veya hastalık; doğuştan olan bir beyin bozukluğu veya doğum esnasında oksijen eksikliği ileride epilepsi sonucu doğabilir. Nokta kadar küçük bir beyin hasarı bile, belli bir eğilimle birlikte, sonradan epilepsiye dönüşmek için yeterli olabilmektedir [9].

Menenjit gibi ciddi bir hastalık veya bir kazadan sonra meydana gelen beyin hasarı da epilepsinin nedeni olabilir. Ancak bu durum, bir hastalıktan sonra veya beyin hasarından dolayı herkeste epilepsi olabileceği anlamına da gelmemektedir. Kronik derecede aşırı alkol veya uyuşturucu kullanımı da beyine hasar verebilir ve bu durumda nöbetlere yol açabilmektedir [9].

Bazen de iyi veya kötü huylu bir beyin tümörü de nöbete neden olabilmektedir. Yaşlı insanlarda bir beyin kanaması veya enfarktüsü (Serebral Vasküler Atak) epilepsinin sıkça rastlanan nedenleri arasında sayılmaktadır [9].

Enfeksiyon, apse, oksijensizlik veya bir ameliyattan sonra olduğu gibi beyin rahatsızlığından dolayı ortaya çıkan yara izi dokusu, epileptik nöbetlerden sıklıkla sorumludur. Bu yara izinin kenarında çoğunlukla normal dışı işlev yapan beyin hücreleri bulunmaktadır [9].

Artan genetik eğilimin de, epilepsiye neden olması mümkündür. Bu durumda nöbet geçirme riski daha düşüktür. Bir veya birden fazla nedenle epilepsi hastası olma ihtimali, genetik yatkınlığı olmayan kişilere göre daha fazladır [9].

2.1.1. Epilepsiyi tetikleyici etkenler

Epilepsi hastası bir kişinin belli bir anda nöbet geçirmesinin nedeni genellikle pek açık değildir. Bazı durumlarda ise nedenleri açıktır. Epilepsiyi ortaya çıkartan nedenlere tetik(leyici) adı verilir. Bazı kişilerin aşağıdaki durumlarda nöbet geçirdiği gözlemlenmiştir:

1. Aşırı alkol kullanımından sonra,
2. Bir iş için büyük gayret sarf etmeden önce veya sonra,
3. Eğlence ve sonraki uykusuzluğun ardından,
4. Kadınlarda hormonal değişiklikler sırasında,
5. Bilgisayar oyunları veya disko ışıklandırması gibi güçlü ışık etkenleri sebebiyle,
6. Yüksek ateş halinde olduğu gibi, vücut ısısında büyük değişikliklerden sonra ortaya çıkabilmektedir [9].

2.1.2. Kalıtsal (genetik) faktörler

Epilepside kalıtımın bir rol oynayabileceği açık olmasına rağmen; yine de bu konuda birçok çok soru işaretleri ve belirsizlikler bulunmaktadır. Bir çiftin epilepsi hastası çocukları olma ihtimali, bilimsel araştırmalar esasen değil, ancak deneyim bilgilerine dayanarak tahmin edilebilir. Ancak epilepsinin bazı türlerinin diğerlerine nazaran kalıtsal yönden daha fazla belirgin oldukları da bilinmektedir. Epilepsi hastası olan bir kişinin, çocuk sahibi olmaktan çekinmemesi gerekir. Epilepsi hastası bir çocuk sahibi olma ihtimali zaten her çift için farklıdır. Çeşitli türleri olmasından dolayı, ebeveynlerinden biri epilepsi hastası olduğunda çocuğun da epilepsi hastası olma ihtimali yüzde 0 ile 50 arasındadır. Normalde bu risk ortalama yüzde 2 ile 8 oranındadır. Erkeğin veya kadının epilepsi hastası olup olmaması hiç fark etmez. Ancak, bir ailede birden fazla kişide epilepsi varsa, hasta çocuk olma ihtimali daha da büyük olur. Bu durum ebeveynlerin her ikisinde de söz konusu olduğunda, bu ihtimal daha da büyümektedir. Epilepsi, başka (kalıtsal) bir hastalık görünümüne de ait olabilir. Bundan dolayı risk daha da büyür ve bazen yüzde 25–50'ye kadar çıkabilmektedir [9].

Epilepsinin ne olduğu, bir nöbet sırasında neler yaşandığını ve kalıtsal yönlerinin kısmen nasıl olduğu bilinmesine rağmen, yine de bazı belirsizlikler devam etmektedir. Bilim adamları, beyindeki sinyallerin dönüşümünün nasıl geliştiğini genellikle bilmekle birlikte, birçok soru hala cevapsızdır. Bu nedenle, epilepsi hakkında araştırmalar durmadan devam etmektedir. Epilepsinin teşhisi için yapılan araştırmalar devam etmekte ve bunların en önemlisi EEG üzerinde yapılan araştırmalar olduğu görülmektedir [9].

Epileptik nöbet sırasında beyindeki elektrik sinyallerinin iletilmesinde bozukluk yaşanmaktadır. Bu durum EEG kaydında da görülebilmektedir. Nöbet arasındaki EEG görüntüsü, epilepsi söz konusu olduğunda normalinden farklı olabilir. Ancak, EEG'de her zaman bir değişiklik görülmeyebilir. Bu durum, EEG araştırmasının bir anlık kaydının olmasından kaynaklanmaktadır. Ölçüm yapıldığı anda beyinde epileptik aktivitenin görülmesi durumuna pek sık rastlanmamaktadır. Bu durumda birden fazla EEG kaydı gerekebilir. Epilepsinin nedenini bulmak için sıklıkla

tamamlayıcı arařtırmalar da yapılmaktadır. BT veya MRG taraması gibi görüntüleme cihazlarıyla yapılan arařtırmalarda, beyindeki bozukluklarda çok daha net olarak teřhis edilebilir. Yapılan arařtırmalardan herhangi bir sonuç çıkmaması da mümkün olabilmektedir. Bu durumda hastaya sadece hastalık geçmiři ve nöbet tanımıyla epilepsi teřhisi konulması gerekebilir [9].

Epilepsi hastası olan kiřilerin çoęu ilaçlarla tedavi edilmektedir. İlaçların amacı; nöbetlerin önlenmesidir. Ancak ilaçlar epilepsiyi tamamen iyileřtiremezler. Epilepsi hastası kiřilerin yüzde yetmişinde, doęru ilaç dozajına ulařıncaya kadar bir süre geçse bile, ilaçlar yine de nöbetlerin önlenmesine yardımcı olmaktadır. İlaçlarla %70 kontrol saęlanabilmektedir. Hastaların yüzde otuzunda ilaçlara dirençli nöbetler izlenebilir. Bazı olgularda ilaç yetersiz kalmakta ve cerrahi tedavi gerekmektedir [9].

2.2. Nöbet Türleri

Epilepsi nöbetleri genel olarak parsiyel ve jeneralize olmak üzere iki gruba ayrılmaktadır. İlk türde beynin bir kısmında, ikinci türde ise beynin her iki yarım küresinde aynı zamanda bozulma olduęu görülmektedir [9].

2.2.1. Parsiyel nöbetler

Epilepsiye neden olan bozulma, beynin belli bir kısmında (dilimde) ortaya çıkmaktadır. Bütün nöbet belirtileri çok çeřitli olup, bozulmanın oraya çıktığı beyin kısmına baęlıdır. Bazı nöbetlerde insanın řuuru açık kalmakta, bazılarında ise kaybolmaktadır. Parsiyel nöbetler, basit, kompleks ve sekonder jeneralize nöbetler olarak üç kısma ayrılmaktadır. Sayılanlar arasındaki son nöbet türü, bir parsiyel nöbetin jeneralize nöbete geçebilmesi anlamına gelmektedir [9].

2.2.1.1. Basit parsiyel nöbetler

Bu tür nöbetlerde řuur açık kalır. Kiři nöbet geçirdięinin tamamen bilincinde olur ve nöbet sırasında neler yařadıklarını da anlatabilmektedir. Ancak nöbeti istese de durduramazlar. Nöbetin süresi çok farklı olabilir. Bu süre, saniye ile dakikalar

arasında deęişebilir. Bazen nöbetler o kadar hafif olur ki etraftaki kişiler bunların çoęu zaman farkına bile varamaz. Nöbet ařaęıda belirtilenler ile kendini gösterebilir:

1. Bir kol veya bacaęın ansızın kontrolsüz hareketleri,
2. Hoř olmayan bir koku veya aęızda garip bir tat duyulması,
3. El, kol, bacak veya ayakta karıncalanma ve/veya ięnelenme,
4. Aęzın etrafında kasılmalar,
5. Bařkalarının göremedięi, duymadıęı şeyleri kısa süre iřitme veya görme [9].

2.1.1.2. Kompleks parsiyel nöbetler

Bu tip nöbetlerde, her zaman bilinç düzeyi deęişiklikleri görölmektedir. Parsiyel nöbetlere kompleks sözcüęünün eklenmesi, bilincin tamamen veya kısmen kaybolması anlamına gelmektedir. Belirtileri ise çok farklıdır. Beyindeki deřarj yerine baęlı olarak, çeřitli tür kompleks parsiyel nöbetler ortaya çıkabilir. Bunlardan en bilinenleri, beynin temporal lobundan çıkan temporal nöbetlerdir. Bu nöbetlerden önce sık sık tonik-klonik (büyük) nöbetlerde olduęu gibi- aura (nöbet arazı) ortaya çıkmaktadır.

Aura (aslında parsiyel küçük nöbet) ancak bir kaç saniye sürer ve mide bölgesi ile birlikte, yemek borusundan yukarıya doęru çıkan garip belirsiz bir histen oluşur. Bazen de kiři aęzında hoř olmayan bir tad duyar veya burnuna garip bir koku gelir. Bazen kiři kendini gerçek dıřı hissedebilir, bazen sadece bu belirtiler ile bunlarla kalır, bazen nöbet devam eder ve bilinç düzeyinde deęişiklik meydana gelir. Bilincin kısmen kaybolması nedeniyle kiři artık neler olup bittięini bilemez. Hiç bir şeye, aęrı etkenlerine bile, tepki gösteremez. Bu nöbet sırasında sıcak nesnelere dokunursa, bunu hissetmez ve bundan dolayı ciddi şekilde yaralanabilir. Kendisine hitap edildięinde tepki gösteremez veya yanlış bir cevap verir. Çevredeki kişileri tanıyamaz. Bakıřları dik dik ve sanki karřındakileri görmüyormuş gibi olur. Bu nöbetler sırasında kiřinin rengi solar veya kızarır. Gözbebekleri büyür ve sık sık aęzından biraz da salya gelir. Bazı kişiler nöbet sırasında garip davranıřlar sergilerler. Parmakları oynar, bir şeyleri çekerler, ayaklarını yerde sürükleyerek yürürler, gezinirler veya örneęin; dolap ve kapıları açarlar. Ayrıca yüzlerini

buruřtururlar, ağızlarıyla ıslık hareketleri ıkarırlar, yalanmak, yutkunmak ve dudaklarını řapırdatmak gibi garip hareketler de yapabilirler [9].

2.2.2. Absans nbeti

Absans szcg, dalgınlık anlamına gelmektedir. Genellikle ok kısa sren bilin kaybıyla hafif geen bir nbettir. Bu nbetler genellikle ocukluk aęında grlmektedir.

řuur kaybı, genellikle etraftakiler bunun farkına bile varmadan, bir anda bařlar ve biter. Nbet sırasında ilgili kiři dik dik bakar ve evresine tepki gstermez. Gzleri biraz kayar veya onları kırpıřtırır. Bazen ellerinde kk kasılmalar olur, bař ne dřebilir veya tam tersine arkaya eęilebilir. Bu durum, kiřinin durumunu bilmeyen birisine, karřısındaki kiři sanki hayal kuruyormuř gibi gelebilir. Nbetten sonra insanlar genellikle meřgul oldukları iřlerine aynen devam ederler. Bu nbetler gnde birkaç kez, bazen ok sık meydana gelebilir. Absans geiren kiřiler bunu o anda anlayamazlar. nk absans aniden bařladıęı gibi aniden de bitebilir. Kiřinin yz rengine deęiřiklik olmaz ve salyası da akmaz. Dalgınlık o kadar kısa olabilir ki, hemen hemen hissedilemez. Ancak, nbet geirildięi yine de konsantrasyon bozukluklarından anlařılabilmektedir. Bu durum ocuk hastalar iin okulda sorun yaratmaktadır [9].

2.2.3. Miyoklonik nbetler

Miyoklonik nbetlerde kol ve/veya bacak kasları ani kasılmalar gstermektedir. Kasılma bazen bir tek, bazen de bir dizi řeklinde olmaktadır. Ender olarak tm vcut kasılmaktadır. Kasılmalar o kadar kısa srmektedir ki, řuurun biran kaybolduęu anlařılmamaktadır. Kas kasılmaları ok řiddetli olduęunda, kiři yere dřebilmektedir. Miyoklonik nbetler ise kısa srmekte ve kiři nbetten sonra kısa bir sre iinde yine iyileřebilmektedir [9].

2.2.4. Tonik-klonik (grand mal) nöbetler

Tonik-klonik sözcüğün anlamı 'kramplaşma ve kasılma' anlamına gelmektedir. Bu isim, nöbet sırasında olanları belirtir. Bu nöbet, en çok bilinen nöbet olmakla birlikte, en çok görünen nöbet türü değildir. Tonik-klonik nöbette, başka bir deyişle 'grand mal' da kişi şuurunu tamamen kaybeder. Birçok tonik-klonik nöbetler, küçük parsiyel nöbet, yani aura olarak başlar. Aura oluşmadığı hallerde, kişi aniden şuurunu kaybetmektedir.

Bir grand mal nöbeti sırasında üç safha ortaya çıkmaktadır. Bunlar:

1. Tonik safha
2. Klonik safha
3. Gevşeme safhası [9].

2.2.4.1. Tonik safha

Nöbetin bu ilk safhası yaklaşık yarım dakika sürmektedir. Beyin hücrelerinin toplu deşarjı nedeniyle vücudun tüm kasları kasılır ve tüm vücut kaskatı kesilir. Göğüs kasların gerilmesiyle, akciğerlerden dışarıya hava itilmesi sağlanır. Bu da bir nevi bağırtıya neden olabilir. Bu bağırtı korku veya ağrı belirtisi değildir. Çünkü hasta o anda baygındır ve bir şey hissetmemektedir. Göğüs kasılması sırasında ve yoğun şekilde kas gerilmesinden ve aynı zamanda çok enerji sarf edilmesinden dolayı solunum bozular. Kişinin yüzü morarabilir. Geçici olarak yutkunmak mümkün olmadığından dolayı, boğazda tükürük birikir. Çene kaslarının aniden kasılmasından dolayı dil hastanın dişlerinin arasına sıkışabilir. Bu da dilin ısırılması sonucu, dilde veya yanakta bir yaraya neden olabilir. Bundan dolayı da ağızdan kan gelebilir. Ancak bu durum görüldüğü kadar ciddi değildir. Hastanın kalp atışları bazen biraz düzensiz atmakta fakat daha sonra ise normalinden daha hızlanmaktadır [9].

2.2.4.2. Klonik safha

İkinci safha, genellikle yarım veya bir buçuk dakika sürmektedir. Beyindeki deşarjlar, vücut kısa bir süre için gevşedikten sonra kasların yeniden kasılmasıyla bir koruma mekanizması ortaya çıkartır. Sırayla oluşan bu gevşeme ve kasılmalar, kol, bacak ve yüzde çirpınmalara neden olmaktadır. Klonik safhada solunum duraksayarak yine devam etmektedir. Ağızda toplanan tükürük (bazen kanla karışık) köpük olarak dışarıya üflenmektedir [9].

2.2.4.3. Gevşeme safhası

Bir ile birkaç dakika arasında sürebilen üçüncü safhada, sarsılmalar gittikçe azalmakta ve gevşeme süreleri artmaktadır. Bütün vücut gevşeyene kadar bu durum böylece devam etmektedir. Hastanın yüzü solmakta, derinden ve hırıldayarak nefes alabilmektedir. Bazen de idrarını kaçırmakta veya kusmaktadır [9].

2.2.4.4. Nöbet sonrası

Sarsılmalar durduğunda, nöbet geçmiş olmaktadır. Kişi, beyninin bitkinliğinden dolayı kısa bir süre daha baygın kalabilir. Uyandığında ise, genellikle şaşkındır ve başına neler geldiğini bilemez. Bunun yanı sıra sık sık baş ağrısı ortaya çıkar ve çoğunlukla uyumak istemektedir. Bazen de baygınlık durumu hemen uykuya dönüşmektedir. Nöbetten sonraki dönemde kas ağrısı da çekilebilmektedir. İyileşme safhasının süreci çeşitli şekillerde geçebilir. Bazı kişiler birkaç dakika sonra yine işlerine devam ederler. Bazıları ise bir tam gün veya daha uzun bir süre dinlenmeleri gerekmektedir [9].

BÖLÜM 3. EEG SİNYALLERİNİN ÖZELLİKLERİ

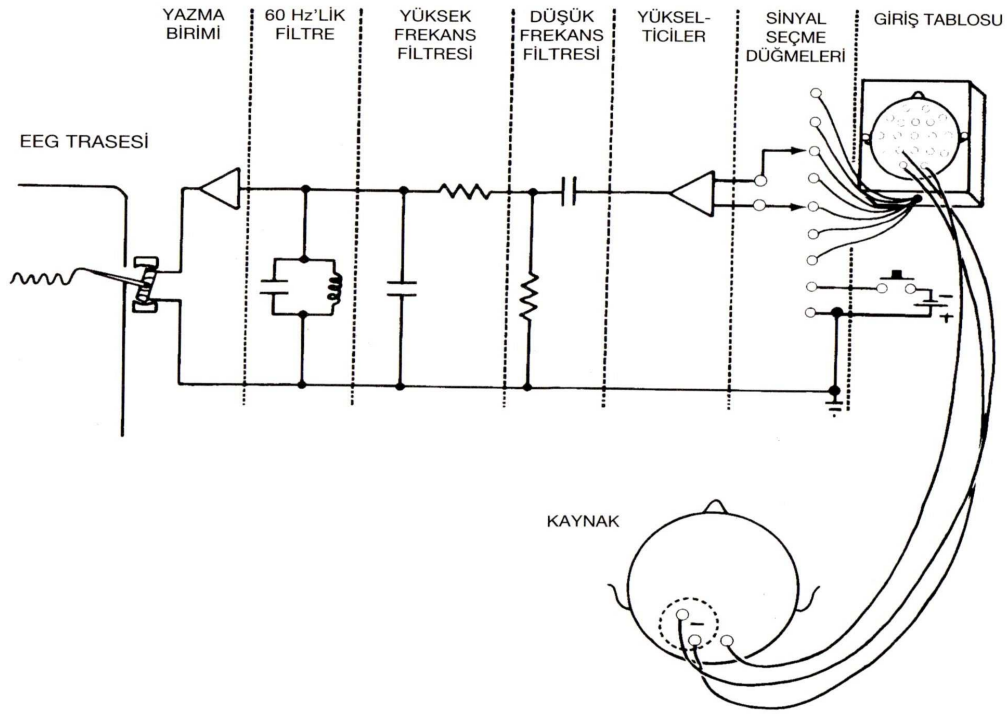
Uzun yıllar boyunca EEG sinyalleri üzerinde yapılan incelemeler, tüm serebrovasküler hastalıklarla ilgili çalışmalara yol gösterici laboratuvar metodu olarak kullanılmıştır. EEG, nöbetleri geçiren ve nöbet geçirdiğinden şüphe edilen hastalarda incelemenin temel çalışmasıdır. EEG, birçok sistematik metabolik hastalığın serebral etkilerinin incelenmesinde, uyku çalışmalarında ve ameliyathanede anestezi altındaki hastalarda serebral aktivitenin izlenmesinde kullanılmaktadır [8].

EEG, serebral korteks kaynaklı anlık elektriksel aktiviteyi kaydetmektedir. EEG kaydı yapılırken çapları 0,5 mm olan lehim veya gümüş-gümüş klorid disklerden imal edilmiş elektrotlar, kolloid ve yapıştırıcı pasta benzeri bir materyal ile saçlı deriye tutturulmaktadır.

EEG'de saçlı derideki birçok bölgeden aynı anda kayıt yapabilen 8–24 veya daha fazla yükseltici ünite bulunmaktadır. Yükseltici ünite aracılığı ile yükseltilecek beyin ritimleri, yazıcı ünitesi olarak çalışan bir kalemi hareket ettirebilecek güçtedir. Akışının standart hızı 3 cm/sn'dir. Kağıt üzerinde, frekans aralığı 0,5–30 Hz olan beyin aktivitesi dalgaları çizilir. Bu dalgalar genellikle dijital olarak işlenir ve bir bilgisayar ekranına aktarılmaktadır. Çizilen EEG sinyali, aslında voltaja karşı zaman grafiğidir. Alınan veriler çok sayıda paralel dalgalı çizgi (kanal) olarak kaydedilmektedir.

Her kanal iki elektrot arasındaki elektriksel potansiyeli temsil etmektedir. Ortak elektrot veya toprak elektrotu tek bir kayıt noktası olarak kullanılabilir. Kanallar genellikle serebral korteksin bir alanından karşı hemisferin aynı alanından gelen aktiviteyi karşılaştıran standart montajlar halinde görülecek şekilde düzenlenmektedir. Geleneksel kalemli EEG grafiği yerini giderek dijital EEG cihazlarına bırakılmaktadır. Dijital EEG'de (dEEG) sayısallaştırılmış dalga formları

bilgisayar ekranında görüntülenebilmektedir. Dijital EEG’de kanal sayısının çokluğu sonuçların yorumlanmasını kolaylaştırmaktadır. Dijital EEG ayrıca depolama ve yeniden incelemeye imkân sağlar [8]. EEG kaydına ilişkin blok şema Şekil 3.1.’de verildiği gibidir.



Şekil 3.1. EEG kaydı blok şeması [3]

Hastalar, genellikle gözleri kapalı olarak ve rahat bir koltukta/yatakta dinlenir durumda iken EEG kaydı yapılmaktadır. İstirahat kaydının yanında, birkaç aktivasyon işlemi de genellikle kullanılmaktadır. Bu işlemler beynin aktive edilmesi için gerçekleştirilmektedir.

1. Hastaya 3 dakika boyunca dakikada 20 kez derin soluk alıp-vermesi söylenmektedir. Hiperventilasyon, hala açıklanamamış bir mekanizma ile karakteristik nöbet şekillerini veya diğer bozuklukları aktive edebilmektedir.
2. Hastadan 35 cm uzağa yerleştirilmiş olan güçlü bir ışık kaynağından, hastanın gözleri açık ve kapalı iken 1–20/sn frekansında flaşlar uygulanmaktadır. EEG kayıtlarında her ışık çakması (fotik uyaran) ile dalgalardaki değişimler veya anormal deşarjlar kaydedilebilmektedir.

3. EEG, hasta doğal yollardan uykusuzken veya ağızdan/damar yoluyla sedatif ilaç verilmesinden sonrada çekilebilmektedir. Uyku, bazı epilepsi türlerini ortaya çıkarmak için yardımcı olabilmektedir [8].

Standart EEG, her biri 10 sn olan 150–300 veya daha fazla sayıda kayıttan oluşmaktadır. EEG kaydı sırasında hastada oluşan hareket veya diğer nedenlere bağlı artefaktları (bozucu sinyalleri/etkileri) önlemek amacıyla bazı tedbirler alınır. Ayrıca EEG kayıtlarının doğru olması için hasta sedatif ilaç almaması ve uzun süreli aç olmaması gerekmektedir [8].

Parlak ışıkta gözleri açma ve sonra kapatma durumu EEG işaretlerinde değişim göstermektedir [12]. Aşırı sinirlilik veya uyuklama hali de normal alfa ritmini baskılamakta ve kas kaynaklı artefaktları artırmaktadır. EEG'nin doğru yorumlanması için karakteristik normal ve anormal ritimler ile temel ritimlerin (hastanın yaşı ile ilişkili olarak) tanınması, ritimdeki asimetri ve periyodik değişikliklerin ortaya konmasının yanı sıra, en önemli faktörde gerçek bozukluklardan artefaktların ayrımının yapılmasıdır [8].

EEG sinyalleri pek çok alanda kullanılmaktadır. EEG kaydının başlıca kullanım alanları aşağıdaki gibi sayılabilir.

1. Nöroloji: Elektroensefolagram (EEG), Ekokardiogram (EKG) ve nörolojik kontroller ile birlikte hastanın beyin patolojisinin belirlenmesinde,
2. Beyin Cerrahisi: Beyinden ameliyatla çıkartılacak tümör ve benzeri anormal patolojik dokuların yerlerinin belirlenmesinde,
3. Anestezi: Anestezi altındaki hastanın anestezi seviyesinin belirlenmesinde,
4. Pediatri: Ortalaması alınmış uyarılmış potansiyeller gibi diğer test yöntemleriyle birlikte, yeni doğmuş çocukların duyma ve görme problemlerinin belirlenmesinde,
5. Psikiyatri: Zihinsel bozuklukların daha kesin şekilde belirlenmesi amacıyla, organik beyin hastalığının belirlenmesinde kullanılmaktadır [12].


3.1. EEG Aktivitesini Tanımlayan Nitelikler

Dalga formu veya biçimi, bir dalganın görünüşünü veya morfolojisini tanımlamak için kullanılan terimlerdir. Dalga formuna bakılmaksızın, iki kayıt elektrotu arasındaki herhangi bir elektriksel potansiyel değişikliğine dalga denilmektedir. Her dalga veya dalga dizisi aktivite olarak adlandırılır. Birçok dalga formunun düzenli bir yapıda olduğu bilinmektedir. Yani simetrik yükselme ve alçalma fazı nedeniyle oldukça değişken bir yapıya sahiptir. Bazı düzenli dalgalar sinüs dalgalarına benzemektedir. Bu nedenle, sinüsoidal olarak tanımlanabilirler. Diğer düzenli dalga formları yay şeklinde veya testere dişi şeklinde olabilirler. Düzensiz dalgaların şekilleri ve süreleri eşit olmamaktadır. Dalgalar; monofazik, difazik, trifazik ve polifazik olarak da sınıflandırılabilirler. Monofazik dalgalar; izoelektrik çizgiden yukarı veya aşağı yönde tek bir defleksiyon gösteren dalgalar olarak bilinmektedir. Difazik dalganın zıt yönlerde iki bileşeni, trifazik dalganın ise izoelektrik çizgi etrafında değişen üç bileşeni bulunmaktadır. Polifazik dalganın ise, değişik yönlerde iki veya daha fazla bileşeni olduğu görülmektedir [3].

Transient, zemin aktivitesinden belirgin olarak ayrılan bir olay olarak bilinmektedir. Tek bir dalgayı içerebileceği gibi karmaşık da olabilirler. Yani ayırt edici bir formu olan ya da oldukça tutarlı biçimiyle yineleyen iki veya daha fazla dalga dizisinden oluşabilmektedir. Keskin transient ise, alışılmış EEG kayıt hızlarında keskin bir pike sahip, herhangi bir süredeki dalgadır. Anormal epileptiform tarzında olmayan keskin konturlu dalga formları sıklıkla keskin transientler olarak kabul edilmektedir [3].

Epileptiform; özellikle nöbet ya da epilepsi ile bağlantılı olanlarla özdeş EEG paternlerini tanımlamak için kullanılmaktadır. Epileptiform paternler genellikle diken veya keskin dalga olarak kabul edilen dalga formlarıdır. Diken (spike), 20-70 msn'lik keskin konturlu dalga formudur. Keskin dalgalar (sharp wave), 70-200 msn süreli olmakta ve diken kadar keskin konturlu olmayabilmektedir. Diken dalgalar bazen yavaş bir dalga tarafından izlenebilmektedir. Bunun sonucu olarak, düzenli aralıklarla yineleyebilen diken ve dalga kompleksi oluşmaktadır. 3 Hz'den düşük hızlarda yineleyen diken-dalga kompleksleri, yavaş diken ve dalga kompleksleri olarak isimlendirilmektedir. Bir keskin dalgayı yavaş bir dalga izlerse, bu dalgalar


keskin ve yavaş dalga kompleksini oluşturmaktadır. Bu tür kompleksler genellikle saniyenin 1/3'ünden daha uzun sürmemektedir. Bu nedenle de 3 Hz'lik bir hızın üzerinde yinelememektedir. Bazı durumlarda iki ya da çok diken ardı sıra ortaya çıkıp, polispike kompleksi olarak da isimlendirilen, multiple diken kompleksini (multiple spike complexes) oluşturmaktadır. Bu kompleksler yavaş bir dalga tarafından izlenebilmekte ve böylece çoklu diken-yavaş dalga kompleksini ya da polispike ve yavaş dalga kompleksinin bir parçasını oluşturmaktadırlar. EEG'de kaydedilebilen bu dikenler, sadece 1 msn kadar süren ve beyne yerleştirilen mikro elektrotlarla kaydedilen, tek nöronun aksiyon potansiyeli ile karıştırılmamalıdır. Bunlar da sıklıkla diken olarak isimlendirilmekte ancak hiçbir zaman yüzey EEG'sinde gözlenememektedirler [3].



Şekil 3.2. EEG dalga formları [3]

Şekil 3.2.'de görüldüğü üzere sıklıkla karşılaşılabilen EEG dalga formu 10 tip olarak özetlenebilir. Birkaç saniyeden kısa süren, diken ve keskin dalga içeren kompleksler ile tek diken ve keskin dalgalar, interiktal epileptiform aktivite olarak isimlendirilmektedir. Bu aktivitelerin ve bazı diğer tiplerin birkaç saniyeden daha uzun sürmesi durumunda bunlar, nöbet paterni ya da iktal patern olarak değerlendirilmektedir. Nöbet paternleri çoğunlukla klinik nöbet tablosu ile ilişkili olmaktadır. Ancak, bu tür bir ilişki olmadan da ortaya çıkabilmekte ve o zaman

subklinik nöbet paterni olarak isimlendirilmektedir [3]. Şekil 3.3.'de farklı hemisferlere ait EEG kayıt örnekleri görülmektedir.



Şekil 3.3. Örnek bir EEG kaydı [3]

Paroksizm ya da paroksimal deşarj terimi, ani başlayan, maksimum amplitüde (genliğe) hızla ulaşan ve aniden kaybolan bir veya daha fazla sayıdaki dalga için kullanılmaktadır. Bu tür dalgalar, zeminden belirgin bir biçimde ayrılabilirler. Genellikle anormal bir yapıya sahip olup, sıklıkla epileptiform paternler içinde görülmektedir. Paroksizmler; sıklıkla kompleksleri içermektedir. Ancak, tüm kompleksler aniden başlayıp bitmeyebilirler. Tüm paroksizmler benzer biçimlerde yinelemeyebilirler [3].

Diken(ler), keskin dalga(lar), paroksizm ve paroksimal deşarj terimleri genellikle epileptiform paternleri tanımlamak için kullanılmakla birlikte, bu terimlerin epileptiform aktivite ile eşanlamlı olmadığını belirtmekte yarar görülmektedir. Bu nedenle, eğer epileptiform aktivitenin varlığı söz konusu olduğunda, kullanılan diğer tanımlayıcı terimlerin hepsine epileptiform terimi eklenmelidir [3].

3.1.1. Yineleme

Dalgaların yinelemesi ritmik veya aritmik olabilmektedir. Ritmik yinelemeli dalgalarda, tek tek dalgalar arasında benzer aralıklar bulunmaktadır. Genellikle düzenli ve sıklıkla da sinüzoidal şeklinde olmaktadır. Uyku içcikleri (spindles) amplitüd olarak yavaş yavaş yükselen ve daha sonra alçalan ritmik yinelemeli dalga gruplarıdır. Aritmik yinelemeli dalgalar, tek tek dalgalar arasında değişken, düzensiz aralıklarla tanımlanmaktadır. Bunlar değişik frekanslardaki dalga dizileri olarak kabul edilebilir. Genelde düzensiz bir biçime sahiptirler [3].

3.1.2. Frekans

Frekans; yinelemeli bir dalganın bir saniye içinde kaç kez yinlendiğini göstermektedir. Bir saniyede 3 çevrimi tamamlayan bir dalgaya 3 Hz'lik ya da saniyede 3 kez yineleyen dalga adı verilmektedir. Bir dalganın ya da yinelemeli dalganın frekansı, tek bir dalganın süresi ve dalga boyu ölçülerek ve evrik değeri hesaplanarak belirlenmektedir. Örneğin, yinelesin ya da yinelemesin, 250 msn ya da 1/4 saniye süren bir dalganın frekansı, 4 Hz olarak hesaplanır. Tek dalgalar ve kompleksler, dalga boylarından daha uzun aralıklarla yineleyebilir. Bu durumda periyodik diye isimlendirilirler ve dalgalar arasındaki zaman aralığına da periyot denilmektedir [3].

EEG dalgalarının frekansı genellikle dört alt frekans bandına ya da gruba ayrılmaktadır. Bu alt bantlar:

- | | | |
|----------|----------|------------------------------|
| 1. Delta | δ | 0,5 – 3,5 Hz |
| 2. Teta | θ | 4 – 7 Hz |
| 3. Alfa | α | 8 – 12 Hz |
| 4. Beta | β | 12 – 22 Hz |
| 5. Gamma | γ | 22 – 30 Hz şeklindedir [12]. |



Şekil 3.4. EEG frekans ölçüm cetveli [3].

Nörologlar EEG kaydı üzerinden yapılan hastalık teşhisleri için Şekil 3.4.'de görülen frekans ölçüm cetvelini sıklıkla kullanmaktadırlar.

EEG alt frekans bantlarına ait ayrımlar gerçekte biraz keyfi yapılmaktadır. Çoğu EEG'de, bantların sınırları dışına yayılan dalga frekansları bulunmaktadır. Örneğin 3-5 Hz'lik dalgalar buna örnek verilebilir. Ayrım farklılık gösterebilse bile frekans bantları, EEG'deki normal ve anormal dalgaları ayırmada en önemli yardımcıdır. Frekans, klinik EEG'de anormalliklerin belirlenmesinde en önemli ölçütlerden biri olarak kabul edilmektedir. 8 Hz'in altındaki dalgalar genellikle yavaş dalgalar ve 13 Hz üzerindeki de hızlı dalgalar olarak isimlendirilse de, aktivitenin frekansını belirtmek ya da bulunduğu frekans bandına göre tanımlamak (örn. delta ve teta aktivite) daha doğru olmaktadır. $\frac{1}{2}$ Hz altındaki ve 20 Hz üstündeki frekansların, rutin saçlı deri kayıtları açısından sınırlı bir klinik yararı bulunmaktadır. Bunun sebebi olarak, çoğunlukla bu aktivitenin serebral kökenli olup olmadığının açık olmaması gösterilmektedir [3].

3.1.3. Genlik (Amplitüd)

EEG dalgalarının genliği, mikrovolt (μV) düzeyinde ölçülmektedir. Bir dalganın toplam dikey (vertikal) uzunluğunun, aynı kazanç (gain) ve filtre ayarlarında kaydedilmiş kalibrasyon sinyali yüksekliğiyle kıyaslanması ve ölçülmesiyle belirlenmektedir. Örneğin; bir EEG dalgasının yüksekliği 14mm ve 50 μV 'lik kalibrasyon sinyali 7 mm olarak ölçülmüşse, dalganın genliği 100 μV 'dir. Eğer bir yükseltecin duyarlılığı 7 $\mu V/mm$ olarak biliniyorsa, doğrudan bir kıyaslama yapmadan kalibrasyon uyarısıyla (pulse) 7 mm'lik bir dalganın 50 μV 'lik bir genliği olduğu söylenebilir [3].

Saçlı deri üzerinden algılanan EEG sinyallerinin genliği tepeden tepeye 1–100 μV ve frekans bandı 0,5–100 Hz arasında değişmektedir. Saçlı deri üzerinden değil de farklı kafa içine yerleştirilen elektrotlarla yapılan ölçümlerde, genlik değerleri 1000 μV değerine kadar çıkabilmektedir. EEG işaretleri periyodik olmadığından, genlik, faz ve frekansları sürekli değişim göstermektedir. Voltaj değeri olarak genlik; Delta ve Teta sinyalleri için 100 μV (p-p), Alfa sinyalleri için 50 μV (p-p), Gamma sinyalleri için ise 2 μV (p-p)'den küçük olarak karşımıza çıkmaktadır [3].

Genlik; hiçbir zaman kalem sapmasının boyuna dayanarak belirtilmemelidir. Çünkü sapma, cihazın ayarlanmasına bağlı olarak değişmektedir. Klinik EEG'de genlik çoğu zaman mikrovolt olarak değil, kabaca düşük (20 μV altı), orta veya ılımlı (20-50 μV arası) ya da yüksek (50 μV üstü) olarak adlandırılmaktadır. Ne var ki bu terimler sıklıkla, aynı kayıt içindeki diğer dalgaların genliğine göre belli dalgaların genliğini tanımlamak için kullanılmaktadır. Örneğin 40-50 μV 'lik bir zeminde ortaya çıkan 60 μV 'lik bir dalganın yüksek genliği olduğu söylenememektedir [3].

Önemli bir anormallik, başın karşılıklı iki yanında eşzamanlı olarak kaydedilen aktivitenin genliğindeki asimetri olarak bilinmektedir. Eğer asimetri sürekli ise, genlikteki en ufak değişiklik bile klinik önem taşımaktadır. Özellikle erişkin EEG'si açısından -alfa ritmi dışında- geçerli olmaktadır [3].

Genlikteki değişimler bazen beyin dışı etmenler, özellikle empedans farkı olan ve eşit mesafelerde yerleştirilmeyen elektrotlar nedeniyle oluşabilmektedir. Bu nedenle anormal genliğin gerçek olduğunu kabul etmeden önce teknisyen, elektrotların doğru yerleştirildiğini ve empedansı denetlemelidir [3].

3.1.4. Dağılım

Dağılım başın farklı bölgeleri üzerine yerleştirilen elektrotlarla kaydedilen elektriksel aktivitenin oluşumunu anlatmaktadır. EEG paternleri başın her iki tarafında geniş alanlarda olabileceği gibi tek hemisferde de bulunabilmekte ya da küçük bir alanda sınırlı kalabilmektedir [3].

Yaygın, difüz veya jeneralize dağılım, başın tümünde veya tümüne yakın kısmında aynı zamanda görülen aktiviteyi ifade etmektedir. Jeneralize aktivitenin, dağılım alanı içinde açıkça maksimum bir amplitüdü olabilmekte ve bulunduğu alanda yapılan bipolar kayıtlarda faz karşılaşması ve referans montajda çok yüksek amplitüdle tanınmaktadır [3].

Lateralize dağılım, sadece ya da çoğunlukla başın tek yanında görülen aktiviteyi ifade etmektedir. Lateralize aktivite anormaldir; ya anormal aktivitenin bulunduğu tarafta ya da normal aktivitenin bulunmadığı tarafta serebral bir anormalliği düşündürmektedir. Bazı normal paternler başın bir tarafında bir süre görüldükten birkaç saniye ya da dakika sonra diğer alanda oluşabilmektedir [3].

Fokal aktivite, bir alan üzerindeki bir veya birkaç elektrotla sınırlı olarak saptanabilen aktivitedir. Bazı komşu elektrotlar, bu aktiviteyi daha düşük amplitüdü olarak alabilmektedirler. Bu sınırlı dağılım, bir bölgede maksimum amplitüdü olabilecek, geniş ya da jeneralize bir dağılımdan ayırt edilmesi gerekmektedir. Bu ayırım özellikle anormal yavaş ve keskin dalga söz konusu olduğunda önemli taşımaktadır. Bu ayırımın yapılmasında kimi zaman yararı olan ölçüt, jeneralize yavaş dalgaların tersine, fokal yavaş dalgaların maksimum amplitüdün olduğu alanda sıklıkla daha düşük bir frekansa sahip olmasıdır. Yayılma eğilimi olan fokal keskin dalgalar, lokal maksimum amplitüdü jeneralize keskin dalgalardan odakta kalmaktaki daha büyük ısrarıyla ayrılabilirler [3].

Tek bir ünilateral odaktan kaynaklanan aktivite her zaman anormal kabul edilmektedir. Orta hat bir odaktan ya da iki hemisferde simetrik olarak bulunan iki odaktan kaynaklanan aktiviteler normal bir paternin parçası olabilmektedirler [3].

3.1.5. Faz ilişkisi

Faz; bir veya birkaç kanaldaki dalga bileşenlerinin zamanlama ve polaritesini ifade etmektedir. Değişik frekanstaki dalgalar değişik kanallarda ortaya çıkabilmektedir. Böylece aynı anda pikler ve çukurlar oluşmaktadır. Bu dalgaların faz birlikteliği (inphase) içinde olduğu söylenebilmektedir. Eğer frekanstaki

dalgalar bu tarzda bir araya gelmemişlerse o zaman faz ayrılığı (out of phase) vardır denilmektedir. Faz farklılıkları, faz açılarına dayanarak ifade edilebilmektedir. Örneğin, zıt yöndeki pik noktaları 180° faz ayrılığı göstermektedir. Böylesi bir “faz karşılaşması”, bipolar kayıtlarda EEG potansiyellerinin kaynağının en büyük göstergesi durumundadır. Faz, tek bir kanalda, bir ritmin değişik bileşenleri arasındaki zaman ilişkisini göstermektedir. Örneğin, sinüsoidal bir dalganın pik noktası ile sıfır noktası arasında 90° , bir sonraki pik ile 360° bulunmaktadır [3].

3.1.6. Zamanlama

Başın değişik alanlarındaki dalgaların zamanlaması aynı veya farklı olabilmektedir. Simültane (eşzamanlı) ve senkron terimleri iki olayın aynı zamanda oluştuğunu ifade etmektedir. Bu terimler genellikle aynı anlamda kullanılmaktadır. Ancak “senkron” terimi bazen tam bir aynı anda oluşumu vurgulamak için kullanılırken, “simültane” daha geniş olarak, EEG'nin görece daha yavaş kayıt hızı sınırları içinde, sadece kesin olmayan bir tarzda görülebilen, aynı anda oluşumu belirtmek için kullanılabilir. Komşu kanallarda olsa bile, iki dalga üzerindeki karşılıklı noktalar arasındaki 1mm'den az yatay farklılık çıplak gözle zorlukla ayırt edilebilmektedir. Alışılmış EEG kayıt hızında sadece 1mm'lik yatay uzaklık, 33 ms'nlik bir zaman farkına karşılık gelmektedir. Eğer yazıcı birimler tam olarak sıraya konulmamışsa ve daha uzak kanallar kıyaslanıyorsa, zaman ilişkilerinin çözülümü bozulmaktadır. Kalemlerin dairesel hareketi nedeniyle farklı amplitüdlerin senkronize hareketi farklı zamanlarda oluşmuş gibi görünebilmektedir [3].

Başın her iki tarafında aynı zamanda oluşan dalgalar için bilateral senkron veya bisenkron terimleri kullanılmaktadır. Bu terimler esas olarak her iki hemisfer arasındaki ilişkiyi dikkate almaktadır. Aynı hemisferdekiler için böyle bir zorunluluk bulunmamaktadır. Bu nedenle bilateral senkron dalgalar aynı hemisfer içinde faz ayrılığı gösterebilmektedir. Bazı durumlarda, başın önünden arkasına doğru yerleştirilen elektrotlar aracılığıyla aktiviteleri kaydedilen dalgalar, önden arkaya doğru yayıldıkları izlenimi yaratarak, ardışık kanallarda eşit süreyle

gecikebilmektedir. Örneğin bu tip bir gecikme metabolik ensefalopatilerin trifazik dalgalarında görülebilmektedir. Değişik kanallarda oluşan ve aralarında sabit zaman ilişkisi olmayan dalgalara asenkron dalgalar denilmektedir. Bu genellikle, aynı frekansta olmasalar ya da aynı fazda birleşmeseler bile, değişik alanlarda aynı zamanda ortaya çıkan dalgaları göstermektedir. Eğer dalgalar bir an bir alanda, başka bir zaman da başka bir alanda oluşuyorsa, bunlara bağımsız dalgalar denilmektedir [3].

3.1.7. Israrlılık

Israrlılık (persistans); bir kayıt esnasında bir dalga veya paternin hangi sıklıkla oluştuğunu tanımlanmaktadır. Bazı dalgalar, tek bir dalga formunda ya da dalga silsilesi biçiminde, çok seyrek ya da aralıklı olarak oluşmaktadır. Diğer dalgalar tüm kayıt süresince ya da büyük bir kısmında görülebilmektedir. Bir dalga formunun ısrarlılığı o dalganın toplam tekrar süresinin tüm traseye oranı ile tahmin edilebilmektedir. Buna indeks denilmektedir. Örneğin delta indeksi %20 denildiğinde, delta aktivitesinin bir kaydın 5'te 1'i süresince görüldüğü anlaşılmaktadır.

EEG paternlerinin klinik öneminin sıklıkla, sadece ısrarlılıklarına değil, aynı zamanda amplitüdlere de bağlı olması nedeniyle, ısrarlılık ve amplitüd, genellikle kantite, miktar veya belirginlikle (quantity, amount, prominence) tanımlanmaktadır. Tek tek dalgalar ve kompleksler yüksek, orta ve düşük ısrarlılıkla oluşabilmektedir. Bunların ısrarlılığı en iyi, bir saniye veya bir dakika içindeki ortalama sayıları ile ifade edilmektedir. Belirli aralıklarla ya da düzensiz aralarla oluşabilmektedir. Düzensiz ve seyrek oluşum bazen sporadik olarak da adlandırılmaktadır [3].

3.1.8. Reaktivite

Reaktivite, çeşitli manevralarla bazı normal ve anormal paternlerde ortaya çıkabilen değişiklikleri anlatmaktadır. Bazı paternler, gözlerin açılıp kapatılması, hiperventilasyon, fotik ya da duyuşsal uyarılar, uyanıklık düzeyinde değişiklikler,

hareket veya diğer manevralar ile kışkırtılabilir ya da artırılabilir, azaltılabilir ya da engellenebilmektedir. Toksik ve metabolik ensefalopatilerde anormal yavaş dalgalar genellikle hastanın uyarılmasıyla azalmaktadır. Hiperventilasyon ve uyuklamayla artarken, yapısal lezyon vakalarında görülen anormal yavaş dalgalar uyarıcı manevralar sırasında genellikle daha az azalabilmekte ya da engellenebilmektedir [3].

EEG üzerinde uyandırmanın etkilerini göstermek için en azından basit uyarıcı manevralar yapmadan, kayıt tamamlanmış olarak kabul edilmemektedir. Bu manevralar göz açıp kapatma (sözel komutlara yanıt veremeyen kişilerde ve çocuklarda pasif olarak yapılabilmektedir) ve hafızayı ölçen sorular ve basit hesaplamaları içermelidir. Eğer hasta sözel komutlara yanıt veremiyorsa, o zaman işitme ve dokunma ile ilgili etkin uyaranlar uygulanmaktadır. Bu manevralar, gerçekten bir zemin yavaşlığı mı olduğunu ya da kayıt sırasında hastanın sadece fazlasıyla mı uyuklu olduğunu belirlemeye de yardımcı olmaktadır [3].

3.2. Normal EEG'nin Tanımlanması

Normal EEG paternleri aynı yaşlardaki kişilerde değişiklik gösterebilmektedir. Farklı yaş gruplarında ise normal EEG paternleri çok daha büyük çeşitlilikler gösterebilmektedir. Uyanık durumda çekilen EEG kayıtları, uyku durumundakilere göre daha fazla değişkenlik göstermektedir. Bu nedenle tüm normal paternlerini ve varyasyonlarını sıralayarak normal EEG'yi tanımlamak uygun ve pratik olmamaktadır. Normal EEG'nin tanımlanması sorununa farklı yollarda yaklaşmak gerekmektedir. EEG'de normal örneklerin büyük çeşitliliğinin tersine, dikenler ve keskin dalgalar, bazı yavaş dalgalar ve amplitüd değişiklikleri gibi her yaşta anormal sayılan örnekler oldukça az olmaktadır. Dolayısı ile normal EEG, normal paternlerin varlığı ile değil, anormal örneklerin yokluğu ile daha doğru bir biçimde tanımlanabilmektedir. Buna karşılık, normal örnekler içermediğine bakılmaksızın, anormal örnekler içeren her EEG 'de anormal olarak kabul edilmektedir [3].

Normal EEG, erken prematüre dönemden 19 yaşa kadar çok büyük değişiklikler gösterebilmektedir. Bu dönemde normal kabul edilen çeşitli paternler, erişkinlik

çağındakilere göre çok daha fazla olmaktadır. Dikenler ve yavaş dalgalar gibi anormal bulguların bile erişkinlerdeki benzer örneklerinden farklı bir klinik anlamı bulunmaktadır. Bu yaş grubu sayılan özellikler dikkate alınarak incelenmelidir [3].

20 ile 60 yaşları arasında normal EEG'de çok az klinik önem taşıyan birkaç değişim görülmektedir. Daha genç yaştakilere göre bu yaş grubunda normal ve anormal paternler arasındaki sınırlar daha iyi belirlenmektedir. Çoğunlukla anormal paternler temel beyin lezyonları ile ilişkili olmaktadır. 60 yaşın üzerinde normal EEG daha genç yetişkinlerinkine benzemektedir [3].

Pek çok anormal EEG paterni, anormal beyin işlevinin göstergesi durumundadır. Ne var ki, anormal paternler çok ender olarak beyin hastalığı olmayan kişilerde de görülebilmektedir. 20 yaşını geçmiş normal kişilerin %5–15'inde, yavaş dalgaların belli bir türünde önemsiz bir fazlalık ve olağan dışı düşük bir amplitüdü gösteren durum görülebilmektedir. Bu tür sinyaller en azından bazı kişilerde hafif beyin anormalliklerinin varlığını gösterebilmektedir. Böyle beyin anormallikleri olasılığını gözden kaçırmamak için bu paternlerin en hafif formunu bile EEG anormalliği olarak sınıflandırmak gerekmektedir [3].

EEG sinyalleri üzerinde çalışırken, alt frekans bantlarını oluşturan bileşen sinyalleri hakkında da bilgi sahibi olmak gerekmektedir. Bu frekans bileşenleri izleyen bölümlerde açıklanmıştır.

3.2.1. Alfa ritmi

Alfa ritmi, frekansı, dağılımı ve reaktivitesi ile tanımlanmaktadır. Bu nedenle alfa ritmi ve alfa frekansı veya aktivitesi eşanlamlı değildir. Dalga formu düzenli ve her zaman olmasa bile sıklıkla sinüzoidaldir. Alfa dalgalarının tepede veya tabanda keskin noktaları olabilmektedir. Keskin tepeleri olan tekli alfa dalgaları, aynı kayıttaki yineleyici alfa dalgalarına olan benzerliğiyle anormal keskin dalgalardan ayırt edilebilmektedir [3].

Alfa frekansı farklı kişilerde 8 Hz'den 13 Hz'e kadar değişebilmektedir. Frekans genelde sabittir ancak, uyuklama ile 1 Hz kadar azalabilmektedir. Gözün kapanması ile anlık bir artış olabilmektedir. Gözün kapatılmasından hemen sonra frekanstaki bu kısa artış bazen kaçış fenomeni olarak isimlendirilebilmektedir. Frekansın sabit oluşu yüzünden normal frekans alanı içindeki alfa ritmi dahi, aynı kişinin diğer kayıtlarıyla karşılaştırıldığında anormal düzeyde yavaş ya da hızlı bulunabilmektedir [3].

Alfa ritminin frekansı, her iki hemisferde de her an eşit olmalıdır. Hafif bir fark bile ısrarlı olması halinde bir anormallikten kuşulanılmasını gerektirir ve herhangi bir anda 1 Hz'yi aşan bir fark kesinlikle anormal kabul edilmektedir. Daha düşük frekanslı hemisfer anormal olarak görülmektedir [3].

Beynin değişik kısımlarındaki alfa ritminin faz ilişkisi değişkenlik gösterebilmektedir. Alfa ritminin normal olarak her iki hemisferde eşzamanlı olarak başlayıp kaybolmasına karşın, tek tek alfa dalgaları normal bir EEG'nin değişik alanlarında sıklıkla aynı fazda olmamaktadır [3].

Alfa ritminin dağılımı posterior olmaktadır. En çok oksipital ve parietal alanlarda ısrarlı ve en büyük amplitüde sahip durumdadır. Özellikle gençlerde sıklıkla temporal ve bazen santral alanlara yayılım göstermektedir. Kulakta, mastoid veya diğer posterior yerleşimli referans elektroda bağlanan bir frontal elektrottan yapılan kayıta alfa ritmi görülebilmektedir. Çünkü bu referans elektrotlar posterior yerleşimli alfa ritmini alabilmektedir. Erişkinlerde sadece ya da esas olarak frontal bölgelerde görülen alfa ritmi anormaldir. Uyuklamanın erken evrelerinde, boyun/göğüs, averaj ya da kulak referansları kullanarak kayıt yapılırken, alfa frekans alanındaki aktivite frontosantral bölgelerde daha belirgin bir hal aldığı görülmektedir. Uyuklama sırasında, alfa aktivitesi topografyasındaki bu değişim, sıklıkla yaşlı kişilerde olduğu bilinmektedir [3].

Alfa ritminin amplitüdü sık sık artıp azalabilmektedir. Değişik anlarda her iki tarafta amplitüd farkı olabilirken, alfa ritminin yaklaşık bir ortalaması, iki tarafta da simetri gösterebilmektedir. Ancak alfa ritminin ısrarlı asimetrisi bile her zaman

anormal kabul edilmektedir. Sağ hemisferde alfa ritminin daha yüksek amplitüdü olması oldukça sık görülmektedir. Ancak sol taraftaki amplitüd, sağ taraftakinin %50'sinden az olmamalıdır. Bazı normal kişilerde sol tarafta hafifçe daha yüksek bir alfa ritmi olabilmektedir. Alfa ritminin normal asimetrisi, büyük olasılıkla oksipital kemik kalınlığının asimetrisi nedeniyle olmaktadır. Kişinin sağ veya sol elini kullanmasına bağlı değilmiş gibi görülmektedir. Anormal asimetriler pek çok durumda görülebilmektedir [3].

Alfa ritminin amplitüdü ve ısrarlılığı çocukluk çağında maksimum iken, yaşla birlikte azalmaktadır. Normal erişkinler alfa ritminin geniş varyasyon göstermesi nedeniyle, düşük amplitüdü olması, seyrek oluşması veya hatta tamamen kaybolması, erişkinler açısından anormal sayılmamaktadır. Bu nedenle dominant ve seyrek alfa ritimleri arasında ya da ısrarlı (P tipi) ve “plus”; reaktif (R tipi) ve “minus” veya minimal (M tipi) alfa ritimleri arasında yapılan ayrımların hiçbir klinik önemi bulunmamaktadır. Ancak, alfa ritmi aynı kişinin ardışık kayıtları arasında önemli bir değişiklik gösterirse, bir anormalliğin gelişiminden kuşkulandırılabilir [3].

Alfa ritminin reaksiyonu değişik manevralarla test edilebilmektedir. Alfa ritmi göz açmakla, ani uyandırma ile görsel veya diğer uyaranlara dikkat yöneltmekle ve zihinsel yoğunlaşma ile bloke olabilmektedir. Reaksiyon derecesi değişik kişilerde veya aynı kişide değişik zamanlarda farklılık göstermektedir. Alfa ritmi saniyelerce bloke olabileceği gibi, amplitüdü kısa süre için azalabilmektedir. Ancak, herhangi bir azalmanın hiç olmaması bir anormalliği düşündürmektedir. Alfa ritminin tek taraflı bloke olması, her zaman, reaksiyon göstermeyen tarafta bir anormalliğin varlığını göstermektedir [3].

Alfa ritmi, uyanık olma durumu uyuklama düzeyine indikçe de zayıflamaktadır. Sıklıkla yavaş yavaş ve aralıklarla oluşan bu zayıflama, frekansın azalması ile birlikte olabilmektedir. Uyuklama ayrıca, kısmi uyarma sonucu gözün açılması üzerine beliren ve paradoksal alfa ritmi denilen, alfanın blokajının normal bir varyasyonunu da oluşturabilmektedir. Uyuklamaya yeniden dönülürse, gözün

kapatılması ile birlikte alfa ritmi kaybolabilmektedir. Paradoksal alfa ritmi gösteren çoğu kişide normal bir alfa ritmi de saptanabilmektedir [3].

Alfa varyantları normal ritimlerdir. Reaktivite ve dağılım olarak alfa ritmine benzer, ancak daha yavaş ya da daha hızlı frekansta olmaları ile alfa ritminden ayrılmaktadır. Yavaş alfa varyantları, 3,5 – 6,5 Hz'lik ritimlerdir. Bu ritimler aynı kayıt içinde, başka yerde görülen alfa ritminin yarı frekansındadır. Posterior bölgelerde olağan frekanstaki alfa ritmi ile genellikle yer değiştirmekte ve alfa ritmi gibi bloke olmaktadır. Yavaş alfa varyantları seyrekir ancak normaldir. Çocuklarda ve erişkinlerde görülen aralıklı oksipital yavaş dalgalarla karıştırılmamalıdır [3].

Hızlı alfa varyantları beta ritimleri içinde tanımlanmıştır. Alfa ritminin fizyolojik önemi bilinmemektedir. Posterior dağılımı, göz açmakla bloke olması ve diğer ayırt edici özellikleri, alfa ritminin görsel sistem işleviyle bütünlendiğini ve büyük olasılıkla, bu sistemde özgül enerji yokluğunda ortaya çıkan aktiviteyi ifade ettiğini göstermektedir. Diğer kortikal ritmik aktivitelerde olduğu gibi, talamik ve kortikal etkileşimlerle ayarlanmaktadır [3].

3.2.2. Beta ritimleri

Alfa ritimden farklı olarak beta ritimleri, dağılım ve reaktiviteye göre daha alt gruplara bölünebilseler de, sadece frekansla tanımlanmaktadır. Beta ritminin frekansı 13 Hz'in üzerindedir. Bu frekansın üzerindeki her ritmik aktivite beta ritmi olarak anılsa da, 30Hz'in üzerindeki beta ritmi genellikle çok düşük amplitüde sahiptir. Geleneksel EEG teknikleri ile kaydedilmesi zor olmaktadır. Beta ritimlerinin dağılım ve reaktivitesi değişkendir. Üç tipi ayırt edilebilmektedir. Tümü uyku veya uyuklama durumunda kaybolur, ancak ilk ikisi uyuklama sırasında alfa ritmine göre genellikle daha uzun süre kalıcı olduğu görülmektedir [3].

Frontal beta ritmi en sık rastlanan tip olarak bilinmektedir. Sıklıkla santral bölgelere doğru yayılmaktadır. Bazı durumlarda bu tip bir beta ritmi hareketle, hareket etme

niyeti ile veya taktik uyarım ile bloke olduğu bilinmektedir. Blok etkisi, hareket eden ya da uyarılan tarafın karşısındaki hemisferde daha büyük olmaktadır. Yaygın beta ritmi genellikle aynı zamanda başın pek çok bölgesinde kaydedilebilmektedir. Hiçbir uyarım ile bloke olmamaktadır. Posterior beta ritmi veya hızlı alfa varyantının frekansı, alfa ritminin iki katı kadar olmaktadır (genellikle 16–20 Hz). Beta ritmi, alfa ritmi ile karışık ya da alternan olmakta veya onun yerine geçmektedir. Bu beta ritmi, alfa ritmini bloke eden manevralarla bloke edilebilmektedir. Beta aktivitesinin amplitüdü aynı kayıttaki alfa aktivitesinin amplitüdünden genellikle daha düşük olmaktadır. Ancak beta ritminin amplitüdü ve ısrarlılığı anormal ölçüde yüksek olabilmektedir. Tüm normal beta ritimlerinin amplitüd ve dağılımı simetrik olabilmektedir. Homolog beyin bölgelerinde amplitüd %35'den fazla fark olmamalıdır. Anlamli (>%35) bir asimetri veya beta ritimde ünilateral veya fokal görünüm anormal olabilmektedir [3].

Bireylerin EEG'lerindeki beta ritminin ısrarlılığı ve toplum genelinde beta ritmi insidansı yaşla birlikte artmaktadır. Alfa aktivitesi, erişkin yaş sırasında azalma eğiliminde olduğundan, betanın alfa aktivitesine oranı da yaşla birlikte artmaktadır. Ancak, bu yaşa bağlı değişimlerin tek bir kişi açısından belirli bir klinik anlamı bulunmamaktadır. Sadece genel bir biçimde, yaşlı kişilerde beta aktivitesinin varlığı, yokluğuna göre daha iyi bir serebral işlev belirtisi durumundadır [3].

Aşırı belirgin bir beta aktivitesi genellikle, benzodiazepin veya barbitüratların meydana getirdiği medikasyon etkisinin bir sonucu olmaktadır. Bunun dışında aşırı yaygın beta aktivitesinin tanı açısından çok az önemi bulunduğu görülmektedir. Beta ritminin fizyolojik önemi açık değildir. Frontal beta ritminin bloke oluş mekanizması, altta yatan korteksin sensorimotor işlevleri ile bu tip beta ritmi arasında yakın bir ilişki olduğunu düşündürmektedir. Benzer bir ilişki mu ritmi için de kabul edilebilmektedir. Posterior beta ritmi genellikle alfa ritmi ile aynı öneme sahiptir. Klinik bir önem taşımamaktadır [3].

3.2.3. MU ritmi

Mu ritmi; en yaygın olarak genç erişkinlerde olmak üzere, EEG'lerin %10'undan azında görülmektedir. Santral veya santro-pariyetal bölgelerde genellikle birkaç saniye süren, 7-11 Hz'lik diziler halinde ortaya çıkan yay biçimli dalgalardan oluşmaktadır. Bu diziler genellikle başın her iki tarafında değişik zamanlarda ortaya çıkmaktadır. Referans kayıttan çok, bipolar kayıta daha iyi görülmektedir. Mu dalgaları, beta aktivitesi ile karışabilir veya alternan olabilir ve bu durumda sıklıkla beta dalgalarının yarı frekansındadır. Mu ritmi, alfa ritmiyle benzer bir frekansa sahip olmaktadır. Bu nedenle genellikle gözün açılmasıyla alfa ritminin bloke olması sırasında daha iyi tanınmaktadırlar. Hastanın gözleri ile bir cismi izlemesi sırasında mu ritminin daha kolay ortaya çıktığı söylenmektedir. Frontal beta ritmi gibi mu ritmi de sıklıkla, hareket etme niyeti ya da taktıl uyaranla, istemli, refleks veya pasif hareketle bloke olmaktadır. Hareketin ya da uyarının olduğu tarafın karşısındaki hemisferde bu etki çok büyük olmaktadır. Mu reaktivitesi test edilirken alfa ritmi ortaya çıkarsa, testin hastayı uyandırması halinde mu ritmi yanında alfa ritmi de bloke olabilmektedir. Paradoksal mu ritmi; uykulu kişilerde mu ritminin kaybolmasından sonra karşı hemisferdeki bir hareket ya da dokunma ile ortaya çıkartılan mu ritmidir. Paradoksal bir mu ritmine yol açan olay hastayı da uyandırabilir ve aynı anda paradoksal bir alfa ritmi ortaya çıkabilmektedir [3].

Mu ritmi normal olarak aralıklı ve asenkron olduğundan, bir tarafta sadece birkaç mu ritmi dizisinin görüldüğü ya da iki taraftaki mu ritmi insidansında az bir farklılığın olduğu bir EEG anormal değildir. Ancak, sadece tek yanda sık sık mu ritmi dizilerinin görülmesi veya mu ritminin frekans ve amplitüdündeki değişmeyen asimetri, düşük amplitüd veya frekanslı tarafta bir anormallik olduğunu düşündürmektedir. Mu ritminin fizyolojik önemi, hareketle ilişkili somatosensoriyal bir süreçle bağıntılı olabilmektedir. Mu ritminin dağılımı, duyuşsal uyaran ve pasif hareketin bloke edici etkisi, gerçek ve niyet edilen hareketten önce mu blokajının başlaması durumudur. Mu ritmi, alfa ritminde olduğu gibi talamik çekirdekten gelen özgül enerjinin alınmadığı bir duyuşsal sistem tembelliğini gösterebilmektedir [3].

3.2.4. Lambda dalgaları

Bazı kişiler görsel detayların olduğu bir şekle bakarken, oksipital bölgelerde testere dişi görünümünde ve pozitif polariteye sahip keskin transientler oluşabilmektedir. Bu nedenle rutin klinik EEG'lerde lambda dalgalarına seyrek rastlanmaktadır. Varlıkları veya yoklukları anormal değildir ancak belirgin bir asimetri, düşük amplitüdü tarafta bir anormalliği düşündürmektedir. Lambda dalgaları, dağılım, dalga formu, görsel uyaran değişikliği ile dalga piki arasındaki latansı da içeren pek çok açıdan, aralıklı flaş uyaran ile açığa çıkartılan görsel olarak uyarılmış potansiyellere benzemektedir. Her lambda dalgası öncesinde, bazen frontal derivasyondaki bir göz artefaktıyla tanınabilen arayıcı bir göz hareketi bulunmaktadır. Bu nedenle, genellikle lambda dalgaları kısmen görsel olarak uyarılmış potansiyelleri ifade etmektedir. Ancak, karanlıkta göz hareketlerinden sonra bir süre devam etmektedir ve genellikle göz hareketleri ya da bakışın değişmesi sırasında görsel girdinin kesilmesiyle bağıntılı olan olayları da yansıtmaktadır [3].

3.2.5. V dalgaları

Verteksteki negatif polariteye sahip keskin transientler normal uyku aktivitesinin yaygın bir unsuru olmaktadır. V dalgaları (verteks keskin transientler); uyanık durumdaki erişkinlerde nadiren ani bir yüksek ses veya beklenmedik başka bir uyarımı izleyerek oluşmaktadır. Ancak çocuklarda, (örneğin ayak ya da ellerin çarpılmasıyla) daha kolayca ortaya çıkmaktadır.

Uyanıklık sırasında V dalgalarının amplitüdü uyku sırasında oluşana göre genellikle çok daha düşük olmaktadır. V dalgaları, şaşırtıcı bir uyarana karşı oluşan jeneralize bir yanıtın parçası olabilmektedir. Böyle bir yanıt göz kırpması ve saçlı deri hareketlerini de içerebilmektedir [3].

V dalgaları genellikle, uyarılmış potansiyellerin geç bir bileşenini simgelemektedir. Bu bileşen duysal uyarının şekline bağlı olmamaktadır. Küçük bir duysal korteks alanından çok, daha geniş kortikal alanlardan

kaynaklanmaktadır. Uyarılmış verteks dalgalarının yaygın dağılımı nedeniyle, EEG'de kaydedilmesi daha kolay olmaktadır. Özgül duysal yollardan ve kortikal algı alanlarından kaynaklanan duysal yanıtların erken bileşenlerinin açıkça görülebilmesi ise, bilgisayar averajlamasıyla artırmayı gerektirmektedir [3].

3.2.6. Kappa ritmi

Bu ritim; çok düşük amplitüdü alfa veya teta frekansında boşalmalar içermektedir. Zihinsel aktivite içindeki bir kişinin temporal bölgelerinde birkaç kez kaydedilmiş ve rutin klinik kayıtlarda nadiren görülmektedir. Bu dalgaların, zihinsel çabadan doğan temporal loblardaki elektroserebral aktiviteyi mi gösterdiği yoksa göz kapağının kımıldamasının eşlik ettiği hassas ritmik göz hareketlerine mi bağlı olduğu açık değildir [3].

3.2.7. Normal posterior teta ritimleri

Bazı normal EEG'lerde ritmik teta aktivitesinin çok nadir iki örneği ayırt edilebilmektedir. Dağılım ve reaktiviteleri alfa ritmininkileri andırmaktadır. Uyanık, istirahat halindeki erişkinlerin EEG'sinde anormal kabul edilen senkron ve yineleyici teta dalgalarının tek istisnasıdır. Yavaş alfa varyantı yukarıda tanımlanmaktadır. 5 Hz'lik ritmik yavaş dalgalar normal erişkinlerin belki de %1'inden azında, aralıklı bir biçimde oksipital ve temporal alanlarda ortaya çıkmaktadır. Bu ritimlerin dağılımı alfa dalgalarından çok az farklı da olsa da göz açıp kapama ve uyandırma ile bloke olabilmektedir. Uyuklama ve uykuda kaybolmaktadır. Bu paternin insidansı erişkin yaşlarda azalmaktadır [3].

3.2.8. Düşük voltajlı EEG

Bazı EEG'ler başın herhangi bir noktasından alınan kayıtlarda 20 μ V üzerinde hiçbir aktivite göstermezler. Yüksek bir kazançta (gain), beta, teta ve bazı delta dalgaları ve bazen posterior alfa dalgaları da olmak üzere, geniş bir frekans bandı ayırt edilebilmektedir. Bu nedenle, bazen bu paternin tanımlanmasında kullanılan

"düşük voltajlı hızlı EEG" deyimini uygun olmamaktadır. Daha yüksek amplitüdü dalgalar bazen hiperventilasyon, fotik uyarım ve uyku ile indüklenebilir [3].

Düşük voltajlı EEG'ler normal çocuklarda görülmez, ancak ilerleyen yaşla birlikte daha yaygınlaşabilmektedir. Bunlar bazen, rahat haldeyken normal amplitüde sahip olan, gergin kişilerde görülebilmektedir. Ne var ki, düşük voltajlı EEG bilateral azalan bir amplitüdü yansıtıyorsa anormal olabilmektedirler. Bu da sadece, aynı kişinin daha önce alınan kaydı normal amplitüd gösteriyorsa belirlenebilmektedir. Çok düşük voltaj, örneğin 10 μ V üzerinde aktivite olmayışı anormal kabul edilmektedir. Düşük voltajlı EEG'ler elektroserebral aktivite yokluğu gösteren kayıtlardan, yani 2 μ V üzerinde serebral aktivitenin olmamasından, açıkça ayırt edilmelidir [3].

3.2.9. Majör anormallikler

Dikenler ve keskin dalgalar bazı istisnalar dışında anormaldir. Bunlar;

1. Verteks keskin transientleri,
2. Şekilleri ve dağılımları ve özgül açığa çıkartıcı mekanizmaları ile kolayca tanınabilen lambda dalgaları,
3. En çok da 6 Hz'lik diken ve yavaş dalga kompleksleri ve diğer normal varyantlardır [3].

EEG'de 8Hz altındaki yavaş dalgalar bulunmamalı ya da çok seyrek olmalıdır. Ancak tekli, teta frekansında; fokal, bölgesel veya hemisfer hâkimiyeti olmayan asenkron, bir zeminden çok yüksek amplitüdü olmayan yavaş dalgalar normal olarak kabul edilebilmektedir. Sık ve yineleyici delta frekansında ise, fokal, bölgesel veya lateral dağılımı varsa, bilateral senkron veya amplitüdü açıkça zeminden daha yüksek ise yavaş dalgalar anormal kabul edilmektedir. Seyrek görülen bir istisna, erişkinlerin çok azında görülen posterior bölgelerdeki bilateral senkron teta ritmidir [3].

Düşük amplitüd tanısı genel olarak, aynı kişinin önce ve sonra alınan EEG kayıtları kıyaslandığında amplitüdün düştüğü gösterilebiliyorsa, anormal olarak kabul edilmektedir. Tek bir kayıta orta düzeyde bir düşük amplitüd kesinlikle anormal bir EEG özelliği olsa da, çoğu zaman klinik bir anormallikle ilişkili olmamaktadır. Ancak, çok düşük amplitüdün tek bir kaydı dahi sıklıkla bir anormalliği göstermektedir. Alfa ritminin frekans ya da reaktivitesindeki değişiklik olması halinde ve komada veya nöbetlerde alfa frekansı patenlerinin oluşması gibi normal paternlerden sapmalar durumu, önemli anormalliklerin göstergesi olabilmektedir [3].

3.3. Anormal EEG'nin Tanımlanması

Bir EEG eğer; A. epileptiform aktivite, B. yavaş dalgalar, C. amplitüd anormallikleri ya da D. normal aktiviteyi andıran ancak; frekans, reaktivite, dağılım ve diğer özelliklerinde sapma gösteren belirli paternleri kapsıyorsa anormal diye nitelendirilmektedir. En önemli EEG anormallikleri aşağıdaki temel anormal EEG paternlerine ayrılabilir:

A. Epileptiform aktivite

1. Lokalize epileptiform aktivite
2. Jeneralize epileptiform aktivite
3. Özel epileptiform paternler

B. Yavaş dalgalar

1. Lokalize yavaş dalgalar
2. Jeneralize asenkron yavaş dalgalar
3. İki yanlı senkron yavaş dalgalar

C. Amplitüd anormallikleri

1. Lokalize amplitüd değişiklikleri: Asimetriyer
2. Jeneralize amplitüd değişiklikleri

D. Normal paternlerden sapmalar [3].

3.4. EEG Paternleri ile Nörolojik Hastalıklar Arasındaki Bağntı

Yukarıda sayılan temel anormal EEG paternlerinin her biri, bir veya birkaç tip serebral anormallik nedeniyle oluşabilmektedir. Anormallikler iritatif veya destruktif özellikleri ve kortikal, subkortikal ve epikortikal yerleşimleri ile ayırt edilebilmektedir [3].

Lokal epileptiform aktivite genellikle serebral korteksin fokal iritatif lezyonuna bağlı olmaktadır. Bebekler de böyle bir aktivite yaygın bir lezyon ya da toksik, metabolik veya elektrolit anormalliği sonucu olabilmektedir. Bazı çocuklarda ise saptanabilen bir serebral lezyon olmaksızın lokal dikenler bulunabilmektedir. Jeneralize epileptiform aktivite gösterilebilir lezyonlarla ilişkili olmadan ya da subkortikal merkezlerin, serebral korteksin geniş bir kısmının ya da her ikisinin de uyarılma eşiğini artıran çeşitli durumlarla ilişkili olabilmektedir. Özel epileptiform paternlerin geniş bir patolojik bağntı çeşitliliği bulunmaktadır [3].

Lokal yavaş dalgalar sıklıkla kortikal tutulumun eşlik ettiği ya da etmediği sınırlı bir beyaz madde hasarından kaynaklanabilmektedir. Jeneralize asenkron yavaş dalgalar, yaygın bir serebral işlev bozukluğunu düşündürür ve sıklıkla serebral korteksten çok, subkortikal beyaz maddenin daha fazla tutulumuna bağlıdır. Bisenkron yavaş dalgalar sıklıkla yaygın subkortikal ve kortikal gri madde tutulumu veya derin orta hat yapılarının lokal tutulumu nedeniyle ortaya çıkmaktadır. Bu durum yapısal hasar ya da metabolik, toksik veya endokrin bozukluklardan kaynaklanıyor olabilmektedir [3].

Amplitüdde lokal azalmalar sıklıkla kortikal elektriksel potansiyelleri düşüren yüzeysel lezyonlara ya da korteks ve kayıt elektrotlarının arasına giren ve kortikal potansiyellerin elektrotlarla elektriksel iletimini bozan maddelere bağlıdır. Amplitüdde lokal bir artış sıklıkla kafatası defektlerinin sonucudur. Amplitüdde genel bir azalma, elektrokortikal potansiyel üretiminde yaygın bir düşüşe ya da korteks ile kayıt elektrotları arasındaki iletken ortamda artışa bağlıdır [3].

Normal EEG paterninden sapmalar, normal paternleri andırır ancak, örneğin frekans, reaktivite veya dağılım gibi özgül noktalarda bunlardan ayrılmaktadır. Bazıları belirli serebral anormalliklerle bağıntılı olmaktadır [3].

3.5. EEG'nin Tam Değeri

Her serebral lezyon birçok değişik nörolojik hastalık tarafından oluşturulabilir. Herhangi bir EEG paterninin herhangi bir hastalığa özgü olmadığı açıktır; her patern birkaç hastalık nedeni ile ortaya çıkabilmektedir. Paternler ve hastalıklar arasındaki bağıntı da ayrıca birkaç nedenden ötürü zayıflayabilir:

1. Birçok hastalık birden çok serebral lezyon tipine ve dolayısıyla birden çok paterne yol açmaktadır.
2. Nörolojik hastalıkların tümü EEG bozukluğu yaratmaz; özellikle serebral lezyon küçükse, kronik ya da derinse EEG normal olabilmektedir. Aralıklı ve çok seyrek olarak EEG anormalliği yaratan bir hastalıkta rutin kayıtlarda bir bulgu görülmeyebilir.
3. Bazı kişilerde bir hastalıkla ilgili başka bir kanıt bulunmasa da EEG anormal olabilir; örneğin EEG anormalliği, hastalığın diğer bulgularının önüne geçebilir ya da ondan sonra da devam edebilmektedir [3].

Her anormal EEG paterninin birden fazla hastalıktan kaynaklanması ve bazı hastalıkların birden fazla anormal EEG paterni yaratması nedeniyle, EEG tek başına özgül bir klinik tanı için kullanılamamaktadır. Ancak, sadece bir dizi olası tanıyı düşündürebilir. Buna rağmen EEG, bir olgunun özgül klinik tablosunda kullanıldığında güçlü bir tanı aracı olabilmektedir. Diğer laboratuvar testlerinde olduğu gibi EEG de ayırıcı tanıyı sınırlar ve böylece doğru tanının seçilmesine yardım edebilmektedir [3].

Genelde EEG, serebral işlev değişikliklerini yapısal lezyonlardan daha güvenilir olarak yansıtmaktadır. Özellikle yapısal lezyonların sınırları belirli ve hemisfer yüzeyine yakın bir yerde değilse bu durum daha doğru olmaktadır. Sonuç olarak, EEG bazı hastalıkların ayırıcı tanısında diğerlerine göre daha yararlı

bulunmaktadır. Bu nedenle; EEG istemek için gerekli koşullar, her vakada göz önüne alınacak tanılara bağlıdır. EEG'nin tanı değeri; hemisferlerin, diensefalik orta hat ve mezensefalik yapıların ani ve hızla ilerleyici bozukluklarında yüksek olmaktadır. Örneğin; konvülsif bozukluklar, toksik-metabolik ensefalopatiler, nedeni belirlenemeyen komalar, beyin ölümü kuşkusu, karotis endarterektomisi sırasında serebral kan akışında azalma, ensefalitler, Jakob-Creutzfeldt hastalığı, Huntington koresi, hemisferlerin ya da orta hat diensefalik veya mezensefalik yapıların, yakın zamanda gelişmiş ya da ilerleyici fokal kitle lezyonlarında orta düzeyde olmaktadır. Bu lezyonlar genellikle MR veya BT ile daha kesin olarak belirleniyorsa da, bazı vakalarda daha erken olarak ya da sadece EEG ile görülebilmektedir. Örneğin; beyin tümörü, inmeler, kafa travması, kronik subdural hematoma, serebral apseler verilebilir [3].

Orta hat diensefalik ve mezensefalik yapıları tutmayan hemisferlerin derinliklerindeki lezyonlarda ve hemisferin hafif, eski ve değişmeyen ya da yavaş ilerleyici jeneralize bozukluklarında düşük olmaktadır. Yani; serebellar hastalıklar ve lezyonlar, retiküler sistemi tutmayan, kraniyal sinirleri ve uzun traktları tutan beyin sapı lezyonları, psikiyatrik hastalıklar, Alzheimer, Parkinson, Wilson hastalıkları, spino-serebellar dejenerasyonlar, nedeni belirsiz kronik baş ağrıları gösterilebilir [3].

Belirli hastalıklarda EEG'nin tanı değerinin genellikle düşük olmasına karşın, EEG bu hastalıklarda diğer tanı olasılıklarını dışlamakta yararlı olabilmektedir. Örneğin, Alzheimer hastalığında EEG sadece hafif jeneralize yavaş dalgaları göstermekle birlikte, bu yavaş dalga bulgusu frontal tümör veya hipotiroidi ensefalopatisi gibi diğer olası demans nedenlerinin dışlanmasına yardım edebilmektedir. EEG sıklıkla bir hastalığın ilerlemesinin veya tedavinin etkisinin izlenmesinde de yararlı olmaktadır. Bu, akut ve subakut serebral yapı ve işlev bozukluklarının geniş bir kısmı için doğrudur. Örneğin; EEG, postanoksik koma, intoksikasyon, metabolik ensefalopati veya status epileptikustan sonraki iyileşmenin gösterilmesine yardım edebilmektedir. Bu bozuklukların erken evresinde ve herhangi bir tedavi başlamadan önce bir başlangıç kaydı alınması son derece önemlidir [3].

BÖLÜM 4. EEG SINYAL ANALİZİ VE MODELLEME METODLARI

EEG sinyalleri, beyin fonksiyonlarıyla ilgili çok miktarda bilgi içermektedir. Bu bilgilerin tıbbi arařtırmalarda ve hastalık teřhisinde kullanılabilmesi için, modern parametrik yöntemler kullanılarak gerçek zamanda spektral analizinin gerçekleştirilmesi ve yazılım alanında gelişen yeni teknolojilerinde desteęiyle, veri analizlerinin doğruluk oranının artırılması ve daha az iş yükü harcanarak otomatikleştirilmesi önemli bir gelişmedir. Bu bağlamda, son yıllarda kullanılan yapay zekâ aęırlıklı yöntemler ile hastalık teřhisi giderek daha yüksek doğruluk oranı ile tanımlanabilir duruma gelmiştir. Girişlerin belirsiz olması ve deęişkenlik göstermesi durumunda yapay sinir aęları (YSA) veri sınıflamada başarılı olmaktadır. Tıbbi alandaki uygulamalar da, YSA'nın hastalık teřhisini içeren şekil (veri) sınıflama için uygun model olduğunu göstermektedir [13, 14].

EEG sinyalleri üzerinde yapılan analiz çalışmalarında gelinen son aşama; istatistik temelli ve spektral analiz yöntemleriyle tespiti çok güç olan parametre ilişkilerinin, yapay zeka algoritmaları, kaos teorisi ve veri madencilięi kullanılarak ortaya çıkarılmasıdır.

Sinyallerin analiz edilmesi direk sinyalin kendisi veya sinyalin gösteriminin başka boyutlara (zaman, frekans, zaman-ölçek, vb) taşınarak gerçekleştirilmesiyle yapılmaktadır. Amaç; sinyalin bilgi kaybına uğratılmadan, bu boyutlardan birisine dönüşümü yapılarak, işlenmemiş haldeki verilerden sağlıklı seçilemeyen anlamlı detay bilgilerine ulaşmaktır. Öncelikle dönüşüm işlemine ihtiyaç duyulur. Her hangi bir sinyalden daha fazla bilgi almak için matematiksel dönüşüm işlemi uygulanır. Mevcut birçok dönüşüm teknięi farklı tip sinyaller ve amaçlar için kullanılmaktadır. Hilbert, kısa zaman hızlı Fourier dönüşümü (KZFD), Zak Fourier, akan Fourier dönüşümü, Wigner, Radon ve Wavelet dönüşümü gibi. Her bir dönüşüm teknięinin avantajları ve dezavantajları vardır [4].

Bütün analiz yöntemlerinde olduğu gibi spektral analiz yöntemlerinde de ihtiyaç duyulan bilgilerin en doğru ve en detaylı şekilde sunulması gerekmektedir. Bu nedenle kullanılan alana göre çeşitli spektral analiz yöntemleri kıyaslanarak en uygun yöntem belirlenmelidir [10].

Çoğu sinyaller zaman alanında gösterilir. Zaman alanında bir sinyalin çizilmesi zaman-genlik gösterimi ile ifade edilir. Bu gösterim genellikle sinyal işlemede iyi bir gösterim olmamaktadır. Sinyallerin yapılarına bağlı olmakla birlikte çoğu kez ayırt edilebilir önemli bilgiler frekans bileşenlerinde gizli tutulurlar. Fourier dönüşümü sinyalin de mevcut olan frekans bileşenlerini bize verir. Fakat bu tip bir dönüşüm frekansların hangi zaman aralığında var olduğunu gösteremez. Bu bilgiler sinyal şayet durağan ise gerekli değildir. Çünkü durağan sinyallerde zamana göre frekans değişmez. Şayet sinyalin zamana göre frekansı değişiyorsa bunlara “durağan olmayan sinyaller” denir. Fourier dönüşümünü durağan olmayan sinyallerde ne tür bir spektral bileşen olduğunu öğrenmek için kullanılabilir, fakat nerede oluştuğunu söyleyemez [15].

4.1. Sinyal Analiz Metotlarının Gelişimi

19. yüzyılda Fourier, herhangi bir periyodik fonksiyonun sonsuz sayıdaki karmaşık üstel fonksiyonların toplamıyla ifade edilebileceğini söylemiştir. Fourier temelli dönüşüm teknikleri; ayrık Fourier dönüşümü (Discrete Fourier Transform) ve hızlı Fourier dönüşümü (Fast Fourier Transform) algoritmalarının geliştirilmesiyle bilgisayarlarda veri işleme için önemli bir basamak oluşturmuştur [4].

Denis Gabor 1946 yılında Gabor dönüşümü olarak bilinen Fourier temelli analiz yöntemini sunmuştur. Bu metot da pencereleme yöntemini kullanarak ki pencere fonksiyonu Gauss Hata fonksiyonudur, işaretin küçük bir parçasını zaman tanım aralığında ele alınmış, işaret zaman ve frekansın fonksiyonu olarak iki boyutta ifade edilmiştir. Böylece durağan olmayan sinyallerin işlenmesi daha sağlıklı hale gelmiştir. Gabor dönüşümü bugün kısa zaman hızlı Fourier dönüşümü (KZFD) olarak yöntemin kaynağı olarak görülmektedir [16].

Fourier serisi yaklaşımıyla başlayan sinyal frekans analizi kavramı günümüze değin ölçek analizi kavramına ve bununla sıkı sıkıya bağlı dalgacık dönüşümüne kadar gelişmiştir. Ölçek analizi, basitçe bir $f(x)$ fonksiyonunun ölçeği değişen matematiksel yapılar oluşturarak analiz edilmesidir. Önce basit bir temel fonksiyon tasarlanır, sonra bir miktar ötelenir ve ölçeği değiştirilir. Bu yapı her hangi bir fonksiyonun yaklaşımında kullanılır ve aynı işlemler tekrar edilir böylelikle yeni yaklaşımlar aynı basit yapısal temel fonksiyondan türetilerek elde edilir. Bu ölçek analizi dizisi, sinyalin farklı ölçeğe sahip ortalama dalgalanmalarını ölçtüğünden gürültüye de en az duyarlıdır. Konuyla ilgili ilk açıklama 1909 yılında A. Haar tarafından sunulmuştur. 1930'larda fonksiyonların değişken ölçekli temel fonksiyonlar kullanılarak gösterilmesi ile ilgili bağımsız çalımsalar yapılmıştır. Temel fonksiyonlar ve değişken ölçekli temel fonksiyonlar kavramlarının anlaşılması dalgacıkların anlaşılmasına anahtar oluştururlar [4].

Aynı yıllarda Paul Levy, Haar temel fonksiyonu olarak adlandırılan değişken ölçekli temel fonksiyonunu kullanarak rastgele bir sinyal tipi olan Brownian hareketi araştırmıştır. Bu çalışmada Brownian hareketin küçük karmaşık detaylarının incelenmesinde Haar temel fonksiyonların Fourier temel fonksiyonlarına göre oldukça üstün olduğu sonucu çıkmıştır [4]. 1960-1980 yıllarında matematikçiler Guido Weiss ve Ronald R. Coifman "atoms" adı verilen bir fonksiyon uzayının en küçük elemanı üzerinde çalışmışlardır. Amaç sıradan bir fonksiyon için bu atomların bulunması ve bu atomlar kullanılarak fonksiyon uzayının tüm elemanlarını tekrar meydana getirecek birleştirme kuralını bulmaktır. 1980'lerde fizikçiler Morlet ve Grossman dalgacıklara quantum fiziğinde geniş yer vermişlerdir [4]. Alex Grossman ve Jean Morlet bu fonksiyon yapı blokları için ilk defa "Wavelet" yani dalgacık adını önermişlerdir ve o zamana kadar Littlewood-Paley teorisi olarak belirtilen teori "Wavelet" dalgacık teorisi olarak adlandırılı gelmiştir [17].

1985'de Stephane Mallat dalgacıkları bu alanda yeni bir sıçrama tahtası oluşturan sayısal sinyal işleme çalışmalarında kullanmış ve Quadrature Mirror Filtre, piramit algoritmaları ve normal-dikey (Orthonormal) dalgacık temeller ve daha bir çokları arasındaki ilişkileri keşfetmiştir [4]. Y. Meyer ilk önemli dalgacığı kurmuştur. Bu Haar dalgacığının tersine sürekli türevleşebilir özellikteydi fakat tam dayanaklı

(Compact Support) değillerdi. Birkaç yıl sonra Ingrid Daubechies Mallat'ın çalışmaları ışığında normal-dikey temel dalgacık fonksiyonlarını inşa etti ki bunlar belki en seçkin ve günümüzdeki dalgacık uygulamalarına köşe taşı teşkil edecek olanlardır [18].

Spektral analiz yöntemleri klasik (parametrik olmayan), modern (parametrik) spektral analiz yöntemleri ve alt uzay yöntemleri olmak üzere üç başlık altında sınıflandırılabilir. Modern spektral analiz yöntemleri ise performans açısından avantajlı olmalarına karşın işlem yükleri fazla olduğundan zaman açısından problem oluşturmaktadır. Klasik yöntemlerden hızlı Fourier dönüşümü yöntemi, modern yöntemlerden ise AR modelleme yaygın kullanıma sahiptir [10].

4.2. Klasik Spektral Analiz Metodları

Klasik yöntemler genelde Fourier dönüşümüne dayalıdır. Bu yöntemler modern yöntemlere göre işlem yükü açısından daha avantajlı olmalarına rağmen, oluşan kaçaklardan dolayı spektrum bozulmakta ve zayıf sinyaller maskelenmektedir. Fourier dönüşümünün yapısı gereği kısa gözlem süreli işaretlerde frekans çözünürlüğü iyi olmamaktadır.

19.Yüzyılda Fourier herhangi bir periyodik fonksiyonun sonsuz sayıdaki kompleks üstel fonksiyonların toplamıyla ifade edilebileceğini söylemiştir. Fourier dönüşümü sonuçları frekans bileşenlerinin yerel zaman, başlangıç veya bitiş bilgileri hakkında kesin veriler sağlamaz çünkü bu bilgi Fourier spektrumu boyunca yayılmıştır yani Fourier dönüşümü ancak genel bir bakış sağlar. Bunun sebebi Fourier temel fonksiyonlarının (sinüs ve kosinüs) tam dayanaklı olmamalarıdır. Bundan dolayı durağan sinyallere uygulanmalarında en iyi sonuç verir. Denklem 4.1 ve 4.2'de görüldüğü gibi herhangi bir t_1 veya t_2 anı entegrale aynı etkide bulunacaktır [4, 16].

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt \quad (4.1)$$

$$x(t) = \int_{-\infty}^{\infty} X(f)e^{j\omega t} df \quad (4.2)$$

4.2.1. Akan Fourier dönüşümü

Bir $f(t)$ sinyalinin Akan Fourier Dönüşümü (Running Fourier Transform) ifadesi; c verilen bir sabit olmak üzere, denklem 4.3'de verildiği gibi ifade edilir. $F(t, \omega)$, $f(t)$ sinyalinin τ dilimine karşılık gelen $f(t+\tau)$ sinyalinin Fourier dönüşümüdür. Böylelikle durağan olmayan sinyaller için spektrumun değişimi sinyalin durağan kabul edildiği τ dilimleri ile belirlenebilmektedir.

$$F(t, \omega) = \int_{-c}^c f(t + \tau) e^{-j\omega\tau} d\tau = e^{j\omega t} \int_{t-c}^{t+c} f(\alpha) e^{-j\omega\alpha} d\alpha \quad (4.3)$$

$F(t, \omega)$ 'nin ters dönüşüm ifadesi de $\omega_0 = \pi / c$ olmak üzere;

$$f(t) = \frac{1}{2c} \sum_{m=-\infty}^{\infty} F(t, m\omega_0) \quad (4.4)$$

eşitliği ile verilir [4, 19].

4.2.2. Kısa zaman Fourier dönüşümü

Fourier dönüşümünün durağan olmayan sinyaller için elverişli olmadığı ifade edilmişti. Denis Gabor, 1946 yılında pencereleme yöntemini kullanarak, işaretin küçük bir parçasını zaman tanım aralığında ele almış, işareti zaman ve frekansın fonksiyonu olarak iki boyutta ifade etmiş ve haritalamıştır. Bu dönüşüm yönteminde işaretin belirli bir kesiminin durağan olduğu kabul edilebilecek bir pencereden geçirilir. Yerel bir frekans parametresiyle FD işlemi gerçekleştirilir. Kısa zamanlı Fourier dönüşümü (KZFD) ile FD arasında çok az bir fark bulunur. KZFD'de sinyal küçük çerçeveler bölünür ve bu çerçeve anlarında sinyalin durağan olduğu kabul edilir. Durağanlığın geçerli olduğu bu çerçeveler sinyalin bir pencere fonksiyonu ile çarpılmasıyla elde edilir. FD'in yerelleştirilmesi fikrine dayanan bu teknik ilgilenilen yerde uygun bir pencere seçilerek dönüşüm işlemi gerçekleştirilir. Durağan olmayan sinyallerin spektral analizi çok iyi zaman ve frekans çözünürlüğü sunması gereken yetenekli işlemlere ihtiyaç duyar [4, 15, 20, 21, 22].

4.2.3. Ayrık Fourier dönüşümü

Bütün frekans boyutunun analog olarak gösterimi sonsuz sayıda örneklenmiş işareti gerektirmektedir bu ise uygulamada mümkün değildir. Sayısal işaretler için Fourier dönüşümünün hesaplanması belirli sınırlamalar içindeki yaklaşıklıklarla bulunabilir. Bir $f[k]$ ayrık dizisinin N örneği için tanımlanan bu yeni dönüşüm Ayrık Fourier dönüşümü (AFD) olarak adlandırılır.

Tersi de alınabilen bu dönüşümün önemli özellikleri vardır. Ayrık Fourier Temelli dönüşümler dizinin periyodik olduğunu kabul ederler. Dolayısıyla bir ayrık zaman sinyali periyodik ise bunun yaklaşık Fourier dönüşümü AFD'dir.

AFD, $f(k)$, $k = 0, 1, \dots, N-1$, gibi bir sonlu diziyi, $F(n)$, $n = 0, 1, \dots, N-1$, gibi diğer bir sonlu diziyeye eşleyen önemli bir operatördür. Normalize edilmiş örnekleme frekansı 2 olmak üzere;

$$F[n] = \text{AFD}\{f[k]\} = \sum_{k=0}^{N-1} f[k]e^{-j2\pi kn/N} \quad (4.5)$$

şeklinde ifade edilir [16].

4.2.4. Hızlı Fourier dönüşümü

Ayrık Fourier dönüşümünün hızlı bir biçimde hesaplanmasına olanak tanıyan yöntemler hızlı Fourier dönüşümü olarak adlandırılmaktadır. Yukarıdaki formül dikkate alındığında N noktalı bir AFD için bu işlem miktarı N^2 ile orantılı bir hesap yükü anlamına gelmektedir. Bu hesap yükünden HFD kullanılarak aşılmaktadır [4].

$$F[n] = \text{AFD}\{f[k]\} = \sum_{k=0}^{N-1} f[k]w[k]e^{-j2\pi kn/N} \quad (4.6)$$


4.2.5. Zak dönüşümü

Bir fonksiyonun Zak dönüşümü aşağıdaki gibi tanımlanır [4, 23].

$$Zf(x, \omega) = \sum_l f(x+l)e^{-i\omega l} \quad (4.7)$$

4.2.6. Periodogram yöntemi

Periodogram yöntemi de hızlı Fourier dönüşümü gibi klasik yani parametrik olmayan yöntemlerden olup, bir işaretteki frekans bileşenlerinin güç yoğunluğunu belirlemek için kullanılır. Bu klasik yöntem Sir Arthur Schuster tarafından geliştirilmiştir. Temel olarak hızlı Fourier dönüşümüne dayanan bu yöntemle güç spektral yoğunluğunu (GSY) elde etmek için, EEG işaretleri 64, 128, 256 gibi ikinin katları olacak şekilde pencereleir [10]. Şekil 4.1.'de epileptik EEG işareti ve periodogram spektrumu gösterilmektedir.



Şekil 4.1. Epileptik EEG işareti ve periodogram spektrumu [10].

4.3. Modern Spektral Analiz Yöntemleri

Parametrik olmayan güç spektrumu tahmin yöntemleri parametrik yöntemlere göre anlaşılması ve HFD kullanılarak hesaplanması daha kolaydır. Ama bu yöntemler uygun frekans çözünürlüğü için uzun veri kayıtlarına ihtiyaç gösterirler [10].

Modern spektral analiz yöntemlerinde güç spektrumu, tepe frekansı, band genişliği veya güç içeriği gibi bir dizi parametre ile özetlenebildiğinden, bu yöntemlere parametrik analiz yöntemleri de denmektedir. Parametrik (model tabanlı) güç spektrum tahmin yöntemleri spektral kaçak problemlerini ortadan kaldırarak daha iyi frekans çözünürlüğü verir. Yine AR yöntemi ile elde edilen tahminlerin orijinal spektruma daha yakın olması ve spektrum hesaplamaları için HFD 'ne göre daha kısa örnekleme süresi gerektirmesi de bu yöntemin avantajları arasında sayılabilir [10].

Bir işareti uygun bir şekilde modellemek için işaretin özelliklerinin dikkate alınması gerekmektedir. Mesela AR modeli frekans spektrumunda ani pikleri bulunan işaretler için uygundur. Hareketli ortalama (Moving Average - MA), bunun tam tersine keskin pikleri olmayan işaretler için kullanılır. Otoregresif hareketli ortalama (Autoregressive Moving Average - ARMA) ise her iki işaret türü için kullanılabilir. EEG işaretlerinin yapısında belirli frekans aralıklarında pikler bulunduğu için AR veya ARMA tercih edilir. AR yöntemi ARMA'ya göre işlem yükü açısından daha avantajlıdır. AR yöntemiyle spektral analiz yapılmasında, Burg yöntemi ve Yule-Walker eşitliklerinden faydalanılarak oluşturulan Levinson - Durbin yöntemi kullanılmaktadır [10].

Modern spektral analiz yöntemleri kapsamında altta verilen yöntemler sayılabilir:

1. Otoregresif (Özbağlanımlı) Parametre Tahmini
2. Otoregresif (Özbağlanımlı) Parametre Tahmini İçin Burg Yöntemi
3. Yule-Walker AR Yöntemi
4. Kovaryans Yöntemi
5. İyileştirilmiş Kovaryans Yöntemi [10].

4.4. Altuzay Yöntemleri

Altuzay yöntemleri aynı zamanda yüksek çözünürlük yöntemleri olarak da bilinmektedirler. Bu yöntemde bir işaretin korelasyon matrisinin özvektör analizi temelli frekans bileşeni tahminleri yapılır. Katlı işaret sınıflandırma (MUSIC) ve Özvektör (eigenvektör, EV) yöntemleri bu kategoride yer alan yöntemlerdendir. Bu yöntemler özellikle sinüzoidal işaretlerin spektrumlarının oluşturulmasına uygundur ve özellikle düşük işaret gürültü oranlı, gürültüye gömülmüş sinüzoidlerin belirlenmesinde etkili olmaktadır [10].

Alt uzay yöntemleri kapsamında altta verilen yöntemler sayılabilir:

1. Çoklu Sinyal Sınıflama Yöntemi (Multiple Signal Classification - MUSIC)
2. Özvektör Analiz Yöntemi (Eigenvector - EV) [10].

4.5. Dalgacık Dönüşümü (Wavelet) ile Sinyal Analizi

Fourier dönüşümü temel fonksiyon kullanarak bir fonksiyonun analizini ve tekrar elde edilmesini gerçekleştirmektedir. Dalgacıklar ise durağan olmayan sürekli sinyallerin genişletilebilmesi ve ayrıştırılabilmesi için uygunlaştırılmış fonksiyonlardır. Yani zaman boyutundan zaman-frekans boyutuna eşleşmeye olanak tanır [4, 24].

Sinyal işlemede kullanılan Fourier temelli sinyal analizi; bir sinyali zaman alanından frekans alanına dönüştüren ve frekans bileşenlerinin önemli olduğu zaman sıkça başvurulan bir tekniktir. Fourier analizinde frekans alanına geçildiğinde zaman alanı yok olur. Durağan sinyallerde Fourier analizi iyi bir yöntem olmaktadır. Fakat çoğu sinyaller durağan olmayan yapıya sahiptirler. Dalgacık analizi farklı frekanslarda durağan olmayan güce sahip zaman serisi sinyalleri analizinde kullanılabilir [10].

Dalgacık analizi KZFD'nin bir alternatifi olarak, çözünürlük probleminin üstesinden gelmek için ortaya çıkmıştır. KZFD'de zaman-frekans alanında elde edilen bilgiler sınırlı bir hassasiyette elde edilebilmektedir. Bu hassasiyet pencerenin büyüklüğüne

bağlıdır. Çoğu sinyaller daha hassas yaklaşıma ihtiyaç duyar ve bu pencerenin büyüklüğünün sürekli değişmesi gerekmektedir. KZFD’de zaman penceresi bütün frekanslarda değişmeyen büyüklüktedir [4].

Dalgacık analizi ise KZFD’den ileri bir yöntem olup, pencereleme tekniği büyüklüğü değiştirilebilir. Dalgacıklar; durağan veya durağan olmayan sinyallerin zaman-ölçek analizi için olanak sağlar. Dalgacıklar sonlu süreli dirler. Bu yüzden yerel sinyal özelliklerinin analizini mümkün kılarlar. Dalgacık dönüşümleri tüm sinyalin frekans-zaman bilgisini korurlar. Bu sebeplerden dolayı durağan olmayan, gerçek doğal sinyallerin dalgacık temelli metotlarla işlenmesi, geleneksel metotlardan daha iyi sonuçlar sağlarlar. Dalgacığın en önemli avantajlarından birisi, büyük işaretlerin yöresel analizine olanak tanınmasıdır [4, 21].


Fourier analizi sayesinde bir sinyalin sinüzoidal birçok frekanstan oluştuğu bilinmektedir. Dalgacık ise bir sinyalin, orijinal dalgacığın kaydırılmış ve ölçeklendirilmiş formundan oluşturulur. Sürekli Dalgacık Dönüşümü (SDD) bütün zaman aralığı boyunca dalgacık fonksiyonunun ölçeklenmiş ve kaydırılmış sekliyle sinyalin çarpımından oluşur. Sürekli dalgacık dönüşümünün sonucunda birçok dalgacık katsayısı elde edilir. Bunlar ölçek ve pozisyon fonksiyonlarıdır [4].

Gözle fark edilemeyecek kadar küçük süreksizliği olan işaretlerle gerçek hayatta sürekli karşılaşırız. Süreksiz sinüzoidal bir işareti ele alacak olursak, işaretin FD’de sadece işaretin uç noktalarında pik değerleri oluşurken, dalgacık dönüşümü ile süreksizlik civarındaki değişimi de gerçek zamanlı olarak gözlemlenebilir. Süreksizlik gösteren ve keskin sıçramalar içeren sinyallerin analizinde dalgacık dönüşümünün Fourier dönüşümüne göre avantajları vardır. Dalgacık analizi, başka analiz yöntemlerinin yakalayamadığı eğilimleri, bozulma noktalarını, yüksek dereceli türevlerde süreksizlikleri ve benzerlikleri çıkarmada başarılıdır [4, 25].

Dalgacık analizinin altında yatan temel düşünce, sinyali ölçeğe göre analiz etmektir. Fourier temelli analizde olduğu gibi sinüs temel fonksiyonları değil de dalgacık fonksiyonları kullanıldığından keskin süreksizlikleri içeren veri yaklaşıklıkları için

çok uygundur. Dalgacık dönüşümleri ile analiz sonuçları teorik olarak sonsuz sayıda kümeden oluşur.

Farklı dalgacık ailelerinin aralarında dayanaklı temel fonksiyon olmaları, uzayda nasıl yer aldıkları ve düzgünlük dereceleri açısından farklılık gösterirler. Böylece yapılacak analiz niteliğine göre seçilebilirler.



Şekil 4.2. Daubechies dalgacığı [4, 18].

Bazı temel dalgacık fonksiyonlar fraktal yapıya sahiptirler. Şekil 4.2'de bir örneği verilen Daubechies dalgacık ailesi bu konuya iyi bir örnektir [4, 18]. Daubechies dalgacık fonksiyonu görüldüğü gibi düz ve yumuşak değildir. Esasında fraktal bir yapıya ve her yerde türevlenemez özelliğe sahiptir [4, 25].

Dalgacık dönüşümü ile gürültüden arındırma işlemi önemlidir ve dört adımda gerçekleştirilir:

1. Dalgacık temel fonksiyonu ile sinyal ayrıştırma: Dalgacık detay sabitlerinin (veya ölçek yaklaşıklık) sabitlerinin bulunması.
2. Her ayrıştırma derecesi için gürültü eşiğinin seçimi.
3. Detay sabitlerinin eşik süzgeçlenmesi
4. Sinyalin son güncellenmiş detay sabitleri kullanılarak yeniden oluşturulması yani ters dalgacık dönüşümünün uygulanması [4].

Genel olarak dalgacığın ve ayrıştırma derinliğinin seçimi kesinlikle sinyal özelliklerine bağlıdır. Bu durumda yumuşak (smooth) dalgacıklar sinyalin daha yumuşak yaklaşımını oluşturur tersi ise yani kısa dalgacıklar sıçramaları daha iyi takip ederler [4].

BÖLÜM 5. VERİ MADENCİLİĞİ METODOLOJİSİ

Bilgi çağında, her türlü karar biriminin en önemli girdisi bilgidir. Ekonomik birim olarak firma açısından rekabet avantajı sayılabilecek bilgiyi incelemek, modellemek ve karar destek sistemlerinde kullanabilmek için güçlü araçlara ihtiyaç vardır. Kuramsal tabana oturtulmuş bilgi destek sistemleri, bilişim teknolojilerinde, özellikle son yıl ardaki hem yazılım hem de donanım açısından gelişmelere paralel olarak, büyük miktardaki verileri işleme ve çıktı olarak elde edilen bilgiyi karar destek sistemlerinde kullanabilme olanağına kavuşmuştur [26].

Bilgisayarların ucuzlaması ile sayısal teknoloji daha yaygın olarak kullanılmaktadır. Veriler doğrudan sayısal olarak toplanmakta ve saklanmaktadır. Bunun sonucu olarak ayrıntılı ve doğru bilgiye ulaşabilmektedir [27].

Örneğin eskiden süper marketteki kasa basit bir toplama makinesinden ibaretti. Müşterinin o anda satın almış olduğu malların toplamını hesaplamak için kullanılmaktaydı. Günümüzde ise kasa yerine kullanılan satış noktası terminalleri sayesinde bu hareketin bütün detayları saklanabilmektedir. Saklanan bu binlerce malın ve binlerce müşterinin hareket bilgileri sayesinde her malın zaman içindeki hareketlerine ve eğer müşteriler bir müşteri numarası ile kodlanmışsa bir müşterinin zaman içindeki verilerine ulaşmak ve analiz etmek mümkün olabilmektedir. Bütün bunlar marketlerde kullanılan barkot, bilgisayar destekli veri toplama ve işleme cihazları sayesinde mümkün olmaktadır [28].

Verilen market örneğinde olduğu gibi ticari, tıp, askeri, iletişim, vb. birçok alanda benzer teknolojilerin kullanılması ile veri hacminin yaklaşık olarak her yirmi ayda iki katına çıktığı tahmin edilmektedir [29,30].

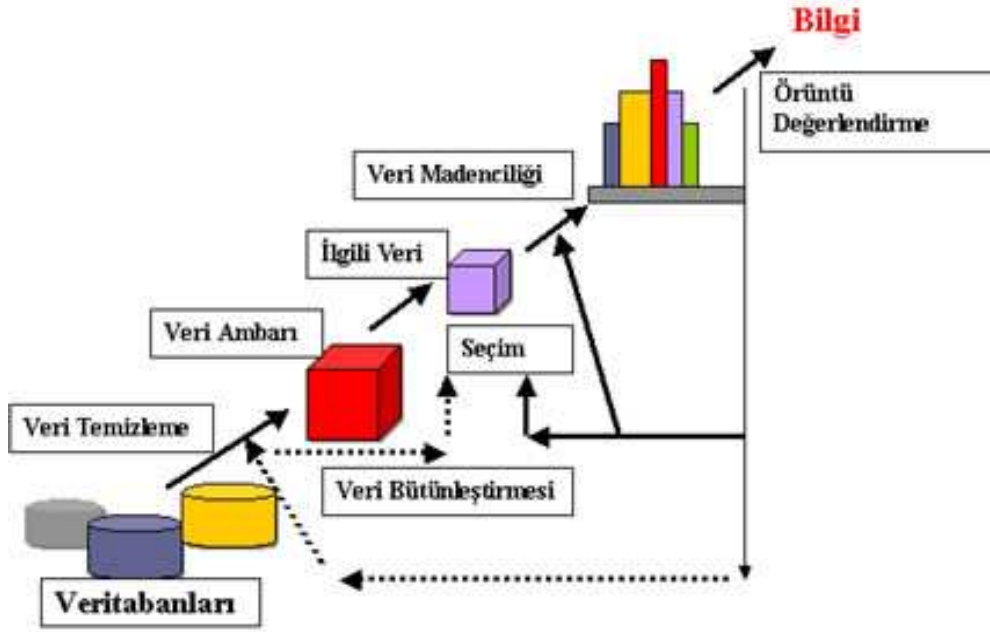
Veri madenciliği; verideki trendleri, ilişkileri ve profilleri belirlemek için veriyi sınıflandıran bir analitik araç ve bilgisayar yazılım paketidir. Spesifik veri madenciliği yazılımları; kümeleme, doğrusal regresyon, sinir ağları, Bayes ağları, görselleştirme ve ağaç tabanlı modeller gibi pek çok modeli içermektedir.

Veri madenciliği uygulamalarında yıllar boyu istatistiksel yöntemler kullanılmıştır. Bununla birlikte, bugünün veri madenciliği teknolojisinde eski yöntemlerin tersine büyük veri kümelerindeki trend ve ilişkileri kısa zamanda saptayabilmek için yüksek hızlı bilgisayarlar kullanılmaktadır. Böylece veri madenciliği, gizli trendleri minimum çaba ve emekle ortaya çıkarmaktadır [31].

Literatürde veri madenciliği ile ilgili olarak aşağıda yer alan farklı tanımlar ile karşılaşılmaktadır:

1. Jacobs (1999), veri madenciliğini, ham verinin tek başına sunamadığı bilgiyi çıkaran veri analizi süreci olarak tanımlamıştır [32].
2. David (1999), veri madenciliğinin büyük hacimli verilerdeki örüntüleri araştıran matematiksel algoritmaları kullandığını söylemiştir. David'e göre veri madenciliği hipotezleri keşfeder, sonuçları birleştirmek için insan yeteneğini kullanır. Veri madenciliğinin bir bilim olmadığı, aynı zamanda bir sanat olduğu da söylenebilir [33].
3. DuMouchel (1999), veri madenciliğinin geniş veritabanlarındaki birliktelikleri araştırdığını belirtmiştir [34].
4. Hand (1998), veri madenciliğini istatistik, veritabanı teknolojisi, örüntü tanıma, makine öğrenme ile etkileşimli yeni bir disiplin ve geniş veritabanlarında önceden tahmin edilemeyen ilişkilerin ikincil analizi olarak tanımlamıştır [35].
5. Kitle ve Wang (1998), veri madenciliğini oldukça tahminci anahtar değişkenlerin binlerce potansiyel değişkenden izole edilmesini sağlama yeteneği olarak tanımlamışlardır [36].
6. Bransten (1999), veri madenciliğinin insanın asla bulmayı hayal bile edemeyeceği trendlerin keşfedilmesini sağladığını belirtmiştir [37].

Sonuç olarak veri madenciliği, önceden bilinmeyen ilişki ve trendlerin bulunması için bugünün endüstrisinde yaratılan büyük miktarlardaki veriyi analiz eden bir yoldur. Yüksek güçlü bilgisayarlara ve gereken yazılımlara kolay ve düşük fiyatlarla ulaşılabilmesi bu teknolojinin işlemlerini olanaklı kılmıştır. İnternet ise birçok noktadaki verinin toplanmasını sağlamaktadır. Bilgisayar üzerinde çalışma aynı zamanda emek ve zaman tasarrufunu sağlamıştır [31].



Şekil 5.1. Veri madenciliği aşamaları [38].

Şekil 5.1.'de veri madenciliğine ait aşamalar verilmiştir. Süreç bu aşamalara uygun olarak sürdürülmelidir. Veri ambarı, organizasyonun ihtiyaçları ile uyumlu büyük miktarlardaki verinin kolay erişilebilir bir yapıda tutulmasını sağlayan bilgisayar tabanlı depolama sistemleridir [39]. Veri ambarları organizasyonel veriye kolay bir şekilde ulaşılmasını sağlayan yapılardır. Veri ambarları 1990'lı yıllarda ortaya çıkmıştır. Veri ambarları veriyi kullanılabilir trend, ilişki ve profillerde sınıflandırmazlar, sadece potansiyel bilgiye sahip veritabanlarıdır. Veride saklı bilgiyi keşfetmeyi sağlayan ise veri madenciliği gibi tekniklerdir. Veri ambarından veriyi çekebilmek için hangi verinin gerekli olduğunu ve bu verinin nerede olduğunu tespit etmek önemlidir. Çoğunlukla gerekli veri, farklı sistemler üzerinde olup, farklı formatlardadır. Bu nedenle, ilk aşamada veri temizleme ve düzenleme işlemi gerçekleştirilmelidir. Veri ambarının

yaratıcısı W.H. Immon'a göre veri ambarı verinin temizlendiği, birleştirildiği ve yeniden düzenlendiği merkezi ve entegre bir depodur [31,40].

5.1. Veri Madenciliğinin Gelişimini Etkileyen Faktörler

Temel olarak veri madenciliği ve gelişimini beş ana faktör etkilemektedir. Bunlar [41]:

1. Veri: Veri madenciliğinin gelişmesindeki en önemli faktördür. Son yirmi yılda sayısal verinin hızla artması, veri madenciliğindeki gelişmeleri hızlandırmıştır. Verilerin bu üstel artışına karşın, verilerle uğraşan bilim adamları, mühendisler ve istatistikçilerin sayısı aynı oranda artmamıştır. Problemin çözümü, verileri analiz etme yöntemlerinin ve tekniklerinin geliştirilmesidir.
2. Donanım: Veri madenciliği, sayısal ve istatistiksel olarak büyük veri kümeleri üzerinde yoğun işlemler yapmak için planlanmıştır. Gelişen bellek kapasiteleri ve artan işlemci hızları sayesinde, son birkaç yıla kadar madencilik yapılamayacak kadar büyük veri ambarları üzerinde çalışmaya olanak sağlamıştır.
3. Bilgisayar ağları: Yeni nesil Internet teknolojileri, çok yüksek hızlarda veri transferine izin vermektedir. Bilgisayar ağları aracılığıyla, dağıtık veri tabanlarına ulaşmak, verileri analiz etmek ve farklı algoritmaları kullanmak mümkün olmaktadır. 2000'li yılların başlarında hayal olarak görünen kavramlar günümüzde kullanılabilen teknolojilerdir.
4. Bilimsel hesaplamalar: Günümüz bilim adamları ve mühendisleri, simülasyonu bilimin üçüncü yolu olarak görmekteler. Veri madenciliği ve bilgi keşfi, teori, deney ve simülasyonu birbirine bağlamada önemli bir rol almaktadır.
5. Ticari eğilimler: Günümüzde, işletmeler rekabet ortamında varlıklarını koruyabilmek için daha hızlı hareket etmeli, daha yüksek kalitede hizmet sunmalı, bütün bunları yaparken de minimum maliyeti ve en az insan gücünü göz önünde bulundurmalıdır. Veri madenciliği sayesinde müşterilerin ve müşteri faaliyetlerinin yarattığı fırsatlar daha kolay tespit edilebilmekte ve riskler daha açık görülebilmektedir.

5.2. Veri Madenciliği İle Yapılabilecekler

Günümüzde veri madenciliğinin kullanım alanları aşağıdakiler gibi sayılabilir [41].

Pazarlama alanında; müşteri sınıflandırmada, müşterilerin demografik özellikleri arasındaki bağlantıların kurulmasında, çeşitli pazarlama kampanyalarında, mevcut müşterilerin elde tutulması için geliştirilecek pazarlama stratejilerinin oluşturulmasında, pazar sepeti analizinde, çapraz satış analizleri, müşteri değerlendirme, müşteri ilişkileri yönetiminde, çeşitli müşteri analizlerinde, satış tahminlerinde kullanılmaktadır.

Bankacılık alanında; farklı finansal göstergeler arasındaki gizli ilişkilerin bulunmasında, kredi kartı dolandırıcılıklarının tespitinde, müşteri sınıflandırmada, kredi taleplerinin değerlendirilmesinde, usulsüzlük tespiti, risk analizleri, risk yönetiminde kullanılmaktadır.

1. Sigortacılık alanında; yeni poliçe talep edecek müşterilerin tahmin edilmesinde, sigorta dolandırıcılıklarının tespitinde, riskli müşteri tipinin belirlenmesinde kullanılmaktadır.
2. Perakendecilik alanında; satış noktası veri analizleri, alış-veriş sepeti analizleri, tedarik ve mağaza yerleşiminin en uygun yerleşime sokulmasında kullanılmaktadır.
3. Borsa alanında; hisse senedi fiyat tahmini, genel piyasa analizleri, alım-satım stratejilerinin en uygun şekilde sokulmasında kullanılmaktadır.
4. Telekomünikasyon alanında; kalite ve iyileştirme analizlerinde, hisse tespitlerinde, hatların yoğunluk tahminlerinde kullanılmaktadır.
5. Tıp ve medikal alanında; test sonuçlarının tahmini, ürün geliştirme, tıbbi teşhis, tedavi sürecinin belirlenmesinde kullanılmaktadır.
6. Endüstri alanında; kalite kontrol analizlerinde, lojistik, üretim süreçlerinin en uygun şekilde sokulmasında kullanılmaktadır.
7. Bilim ve mühendislik alanında; ampirik veriler üzerinde modeller kurarak bilimsel ve teknik problemlerin çözümlenmesinde kullanılmaktadır.

Veri madenciliğinin asıl amacı veri yığınlarından anlamlı bilgiler elde etmek ve bunu eyleme dönüştürecek kararlar için kullanmak olduğu dikkate alınarak kullanım alanları daha özelleştirildiğinde [41];

Bir işletme kendi müşterisiyken rakibine giden müşterilerle ilgili analizler yaparak rakiplerini tercih eden müşterilerinin özelliklerini elde edebilir ve bundan yola çıkarak gelecek dönemlerde kaybetme olasılığı olan müşterilerin kimler olabileceği yolunda tahminlerde bulunarak onları kaybetmemek, kaybettiklerini geri kazanmak için strateji geliştirebilir.

1. Ürün veya hizmette hangi özelliklerin ne derecede müşteri memnuniyetini etkilediği, hangi özelliklerinden dolayı müşterini bunları tercih ettiği ortaya çıkarılabilir.
2. Ürün talebi bazında müşteri profillerini belirleyerek, müşteri segmentasyonuna gitmek ve çapraz satış olanakları yaratmakta kullanılabilir.
3. Piyasada oluşabilecek değişikliklere mevcut müşteri portföyünün vereceği tepkinin firma üzerinde yaratabileceği etkinin tespitinde kullanılabilir.
4. Bir ürün veya hizmetle ilgili bir kampanya programı oluşturmak için hedef kitlenin seçiminden başlayarak bunun hedef kitleye hangi kanallardan sunulacağı kararına kadar olan süreçte veri madenciliği kullanılabilir.
5. Operasyonel süreçte oluşabilecek olası kayıpların veya suiistimallerin tespitinde kullanılabilir.
6. Kurum teknik kaynaklarının en uygun şekilde kullanılmasını sağlamakta kullanılabilir.
7. Firmanın finansal yapısının, makro ekonomik değişimler karşısındaki duyarlılığı ve oluşabilecek risklerin tespitinde kullanılabilir.
8. Geçmiş ve mevcut yapı analiz edilerek geleceğe yönelik tahminlerde bulunulabilir. Özellikle ciro, karlılık, Pazar payı, gibi analizlerde veri madenciliği çok rahat kullanılabilir.
9. Tıbbi veriler değerlendirilerek teşhis koymada ve koyulan teşhis neticesinde hastanın verilerine uygun izlenilecek tedavinin seçilmesinde kullanılabilir [41].

Tablo 5.1’de 2003 yılında veri madenciliğinin sektörler bazında kullanımına ilişkin bir araştırmanın sonuçları yer almaktadır [42]. Bu çizelgede araştırmaya katılan toplam 421 şirketin 51 adedinin bankacılık alanında veri madenciliğinin kullandığı görülmektedir.

Tablo 5.1 Veri madenciliğinin uygulandığı alanlar [31].

Son 3 yıl içinde veri madenciliğinin uygulandığı alanlar	
Bankacılık (51)	12%
Biyoteknoloji/ Genetik (11)	3%
Kredi skorlama (35)	8%
CRM(52)	12%
Doğrudan pazarlama (34)	8%
e-Ticaret (11)	3%
Eğlence/ Müzik (4)	1%
Sahtekarlık tespiti (31)	7%
Şans oyunu (2)	0,01 %
Kamu uygulamaları (12)	3%
Sigortacılık (24)	6%
Yatırım/ Hisse senedi (5)	1%
Junk email / Anti-spam (5)	1%
Sağlık/ İK(15)	4%
İmalat (19)	5%
Tıp/ Farmakoloji (12)	3%
Perakende (25)	6%
Bilim (17)	4%
Güvenlik / Anti-terörizm(5)	1%
Telekomünikasyon (23)	5%
Seyahat (8)	2%
Web (9)	2%
Diğer (11)	3%

5.3. Veri Madenciliğinin Gereksinimleri

Veri madenciliği sürecinin gereksinimleri aşağıdaki belirtilebilir [31]:

1. Erişilebilir veri,
2. Etkin erişim yöntemleri,
3. Açık problem tanımı,

4. Etkin algoritmalar,
5. Yüksek performanslı uygulama sunucusu,
6. Sonuç oluşturmada esnekliktir.

Veri madenciliğinin diğer bir gereksinimi temizlenmiş veridir. Veri madenciliğinde kullanılacak veri yanlış sonuçlar üretmeye yol açabilecek aykırı değerler veriden temizlenmelidir [32]. Doğru veri mevcut değilse ve verinin limitleri bilinmiyorsa; kullanılan yazılımın yanlış sonuçlar üretmesi kaçınılmazdır [31].

5.4. Veri Madenciliği Uygulamalarında Karşılaşılan Problemler

Veri madenciliği girdi olarak kullanılacak ham veriyi veritabanlarından alır. Bu da veritabanlarının dinamik, eksiksiz, geniş ve net veri içermemesi durumunda sorunlar doğurur [28]. Diğer sorunlar da verinin konu ile uyumsuzluğundan doğabilir. Sınıflandırmak gerekirse başlıca sorunlar aşağıdadır [31]:

1. Sınırlı bilgi: Veritabanları genel olarak veri madenciliği dışındaki amaçlar için tasarlanmışlardır. Öğrenme görevini kolaylaştıracak bazı özellikler bulunmayabilir.
2. Gürültü ve kayıp değerler: Veri özellikleri ya da sınıflarındaki hatalara gürültü adı verilir. Veri tabanlarındaki eksik bilgi ve bu yanlışlardan dolayı veri madenciliği amacına tam olarak ulaşmayabilir. Bu bilgi yanlışlığı, ölçüm hatalarından, ya da öznel yaklaşımdan olabilir.
3. Belirsizlik: Yanlışlıkların şiddeti ve verideki gürültünün derecesi ile ilgilidir. Veri tahmini bir keşif sisteminde önemli bir husustur.
4. Ebat, güncellemeler ve konu dışı sahalara: Veri tabanlarındaki bilgiler, veri eklendikçe ya da silindikçe değişebilir. Veri madenciliği perspektifinden bakıldığında, kuralların hala aynı kalıp kalmadığı ve istikrarlılığı problemi ortaya çıkar. Öğrenme sistemi, kimi verilerin zamanla değişmesine ve keşif sisteminin verinin zamansızlığına karşı zaman duyarlı olmalıdır.

5.5. Veri Madenciliği Yazılımları

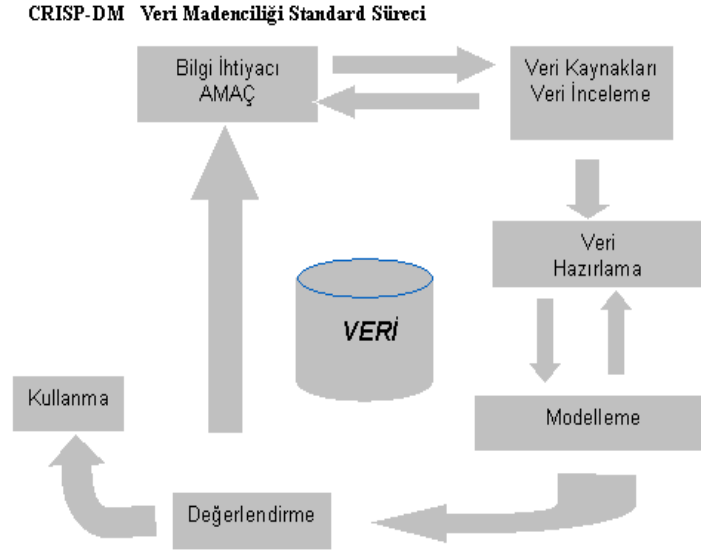
Farklı algoritmaları bünyesinde bulunduran ve farklı işletim sistemleri üzerinde çalışabilen birçok veri madenciliği yazılımı bulunmaktadır.

Tablo 5.2. Veri madenciliği yazılımları ve çalıştıkları platformlar [31]

Ürün Adı	IBM Intelligent Miner	Oracle Darwin	SAS Enterprise Miner	Angoss Knowledge Seeker	NCR Teraminer Stats	WEKA
Platform	AIX 4.1, NVS, AS/400, Windows	Windows	Masintosh, Windows, Unix	Windows, Unix	Windows, Unix	Masintosh Windows Unix
Karar Ağacı	X	X	X	X		X
Sinir Ağları	X	X	X		X	
Zaman Serileri	X		X			
Tahmin	X	X	X	X		X
Kümeleme	X		X			X
Birliktelik	X		X			X
Görselleştirme	X	X	X	X	X	X

5.6. Veri Madenciliği Süreci

Ne kadar etkin olursa olsun hiç bir veri madenciliği algoritmasının üzerinde inceleme yapılan işin ve verilerin özelliklerinin bilinmemesi durumunda fayda sağlaması mümkün değildir. Bu nedenle tüm aşamalardan önce iş ve veri özelliklerinin anlaşılması gereklidir.



Şekil 5.2. Veri madenciliği süreci [40].

Veri madenciliğinin beş ana sürece ayrıldığı görülmektedir. Bunlar [40]:

1. Problemin Tanımlanması,
2. Verilerin Hazırlanması,
3. Modelin Kurulması ve Değerlendirilmesi,
4. Modelin Kullanılması,
5. Modelin İzlenmesi.

5.6.1. Problemin tanımlanması

Veri madenciliği çalışmalarında başarılı olmanın en önemli şartı, projenin hangi işletme amacı için yapılacağına açık bir şekilde tanımlanmasıdır. İlgili işletme amacı işletme problemi üzerine odaklanmış ve açık bir dille ifade edilmiş olmalı, elde edilecek sonuçların başarı düzeylerinin nasıl ölçüleceği tanımlanmalıdır. Ayrıca yanlış tahminlerde katlanılacak olan maliyetlere ve doğru tahminlerde kazanılacak faydalara ilişkin tahminlere de bu aşamada yer verilmelidir [34].

Bu aşamada mevcut iş probleminin nasıl bir sonuç üretilmesi durumunda çözüleceğinin, üretilecek olan sonucun fayda - maliyet analizinin başka bir değişle

üretilebilen bilginin işletme için değeri doğru analiz edilmesi gerekmektedir. Analistin işletmede üretilen sayısal verilerin boyutlarını, proje için yeterlilik düzeyinin iyi analiz edilmesi gerekmektedir. Ayrıca analistin işletme konusu hakkındaki iş süreçlerinin de iyi analiz edilmesi gerekmektedir [34].

5.6.2. Verilerin hazırlanması

Veri madenciliğinin en önemli aşamalarından bir tanesi olan verinin hazırlanması (veri ambarının oluşturulması) aşaması analistin toplam zaman ve enerjisinin %50 - %75 ini harcamasına neden olmaktadır. Bu aşamada firmanın mevcut bilgi sistemleri üzerinde ürettiği sayısal bilginin iyi analiz edilmesi, veriler ile mevcut iş problemi arasında ilişki olması gerektiği unutulmamalıdır. Proje kapsamında kullanılacak sayısal verilerin, hangi iş süreçleri ile yaratıldığı da bu veriler kullanılmadan analiz edilmelidir, bu sayede analist veri kalitesi hakkında fikir sahibi olabilir. Verilerin hazırlanması aşaması kendi içerisinde toplama, birleştirme ve temizleme, dönüştürme adımlarından meydana gelmektedir [34].

Veri toplama; tanımlanan problem için gerekli olduğu düşünülen verilerin ve bu verilerin toplanacağı veri kaynaklarının belirlenmesi adıımıdır. Verilerin toplanmasında kuruluşun kendi veri kaynaklarının dışında, nüfus sayımı, hava durumu, merkez bankası kara listesi gibi veri tabanlarından veya veri pazarlayan kuruluşların veri tabanlarından faydalanılabilir [34].

Veri birleştirme ve temizleme; bu adımda toplanan verilerde bulunan farklılıklar giderilmeye çalışılır. Hatalı veya analizin yanlış yönleneğine sebep olabilecek verilerin temizlenmesine çalışılır. Genellikle yanlış veri girişinden veya bir kereye özgü bir olayın gerçekleşmesinden kaynaklanan verilerin, önemli bir uyarıcı enformasyon içerip içermediği kontrol edildikten sonra veri kümesinden atılması tercih edilir Ancak basit yöntemlerle ve baştan savma olarak yapılacak sorun giderme işlemlerinin, ileriki aşamalarda daha büyük sorunların kaynağı olacağı unutulmamalıdır [34].

Veri dönüştürme; kullanılacak model ve algoritma çerçevesinde verilerin tanımlama veya gösterim şeklinin de değiştirilmesi gerekebilir. Örneğin; kredi riski uygulamasında iş tiplerinin, gelir seviyesi ve yaş gibi değişkenlerin kodlanarak gruplanmasının gerekliliği söz konusudur [34].

5.6.3. Modelin kurulması ve değerlendirilmesi

Tanımlanan problem için en uygun modelin bulunabilmesi, olabildiğince çok sayıda modelin kurularak denenmesi ile mümkündür. Bu nedenle veri hazırlama ve model kurma aşamaları, en iyi olduğu düşünülen modele varılıncaya kadar yinelenen bir süreçtir [34].

Bir modelin doğruluğunun test edilmesinde kullanılan en basit yöntem basit geçerlilik (simple validation) testidir. Bu yöntemde tipik olarak verilerin % 5 ile % 33 arasındaki bir kısmı test verileri olarak ayrılır ve kalan kısım üzerinde modelin öğrenimi gerçekleştirildikten sonra, bu veriler üzerinde test işlemi yapılır. Bir sınıflama modelinde yanlış olarak sınıflanan olay sayısının, tüm olay sayısına bölünmesi ile hata oranı, doğru olarak sınıflanan olay sayısının tüm olay sayısına bölünmesi ile ise doğruluk oranı hesaplanır. (Doğruluk Oranı = 1 - Hata Oranı) [34].

Önemli diğer bir değerlendirme ölçüt modelin anlaşılabilirliğidir. Bazı uygulamalarda doğruluk oranlarındaki küçük artışlar çok önemli olsa da, birçok işletme uygulamasında ilgili kararın niçin verildiğinin yorumlanabilmesi çok daha büyük önem taşıyabilir. Çok ender olarak yorumlanamayacak kadar karmaşıklaşsalar da, genel olarak karar ağacı ve kural temelli sistemler model tahmininin altında yatan nedenleri çok iyi ortaya koyabilmektedir [34].

5.6.4 Modelin kullanılması

Kurulan ve geçerliliği kabul edilen model doğrudan bir uygulama olabileceği gibi, bir başka uygulamanın alt parçası olarak kullanılabilir. Kurulan modeller risk analizi, kredi değerlendirme, dolandırıcılık tespiti gibi işletme uygulamalarında doğrudan

kullanılabileceği gibi, promosyon planlaması simülasyonuna entegre edilebilir veya tahmin edilen envanter düzeyleri yeniden sipariş noktasının altına düştüğünde, otomatik olarak sipariş verilmesini sağlayacak bir uygulamanın içine gömülebilir [34].

5.6.5. Modelin izlenmesi

Zaman içerisinde bütün sistemlerin özelliklerinde ve dolayısıyla ürettikleri verilerde ortaya çıkan değişiklikler, kurulan modellerin sürekli olarak izlenmesini ve gerekiyorsa yeniden düzenlenmesini gerektirecektir. Tahmin edilen ve gözlenen değişkenler arasındaki farklılığı gösteren grafikler model sonuçlarının izlenmesinde kullanılan yararlı bir yöntemdir [34].

5.7. Veri Madenciliği ve Makine Öğrenmesi Kuramı

Bilgi çağında, her türlü karar biriminin en önemli girdisi bilgidir. Ekonomik birim olarak firma açısından rekabet avantajı sayılabilecek bilgiyi incelemek, modellemek ve karar destek sistemlerinde kullanabilmek için güçlü araçlara ihtiyaç vardır [26].

Kuramsal tabana oturtulmuş bilgi destek sistemleri, bilişim teknolojilerinde, özellikle son yıl ardaki hem yazılım hem de donanım açısından gelişmelere paralel olarak, büyük miktardaki verileri işleme ve çıktı olarak elde edilen bilgiyi karar destek sistemlerinde kullanabilme olanağına kavuşmuştur [26].

İnsan ve makine uzman, veri madenciliğinin birbirini tamamlayan en önemli bileşenleridir. İnsan uzman, veri tabanının hazırlanması, problemin tanımlanması ve hedeflerin belirlenmesinde aktif olan etkidir. Makine uzman ise verileri, hedeflerle uyuşan örüntüleri saptamak amacıyla taramak ve bu örüntülere uygun kuralları öğrenmekten sorumludur [26].

Veri madenciliğinde veri elektronik ortamda saklanmakta, verideki örüntüler otomatik olarak aranmakta, doğrulanmakta ve tahmin veya sınıflandırma amacıyla kullanılmak üzere kurallar öğrenilmektedir. İnsan uzmanın bilgi çıkarma sürecindeki diğer bir

sorumluluğuyorsa, makine uzmanın öğrendiği bilginin incelenmesi, sorgulanması, sınanması ve tutarsız ve anlamsız bilgilerin ayıklanması, sorgulama ve sınama sonucunda veri tabanının düzenlenmesi, hatalı bilgi ve verilerin düzeltilmesidir. Bununla birlikte, veri madenciliğinin asıl amacı olarak düşünüldüğünde, insan uzmanı, makine uzmanın bilgi işleme yeteneği ve kapasitesine dayanarak sürece olabildiğince az dâhil etmek ve değerli bir kaynak olarak zamanın daha önemli alanlarda kullanılabilmesini sağlamaktır [44].

Makine öğrenmesi, yapay zekânın veri madenciliği ve istatistikle ilintili bir dalıdır. Veri madenciliğinde olduğu gibi, makine öğrenmesinde de, analize konu olan alana ait veriler, örnekler, daha açık bir ifadeyle, örneklere ait özellikleri tanımlayan öznelik değerleri olarak sisteme iletilir ve makine uzman ya da programın bu verilere ait örüntüyü ya da yapıyı öğrenmesi istenir. Öğrenme sürecinin en önemli özelliği, veri setine eklenen her yeni bilgi için, makine uzmanın önceki veri yapılarını öğrenmiş olarak, örüntüdeki değişmelerin ayırımına varması ve bu değişimlerin getirdiği bilginin kural setine eklemesinin varsayılmış olmasıdır. Böylece, makine uzmanın yeni durumlarla karşılaştığında, en azından potansiyel performansının artırılması amaçlanmaktadır. Makine öğrenmesi yöntemleri, büyük veri setlerinde rahatlıkla kullanılabilen ve daha çok bilgiyi kolaylıkla işlemeye yatkın güçlü yöntemlerdir. Bu buluşsal tahmin yöntemleri, istatistiksel yöntemlerden farklı olarak, sıklıkla güçlü ampirik sonuçlar üretebilmektedir [26,45].

Öğrenme yöntemlerinin çoğunda, “öğrenilen problemin” yapısal tanımları araştırılır [46]. Bu tanımlar, genellikle oldukça karmaşık ve karar ağaçlarının öğrendiğine benzer kural setleri biçiminde ifade edilmektedir. Diğer taraftan, örneğin yapay sinir ağları gibi yöntemler, böyle tanımlar yapmazlar. Makine öğrenmesi uygulamalarında tanımlar, genellikle algoritmanın yeni örnekleri sınıflandırma performansından daha önemlidir; tanımların kuramsal anlamlılık koşulu sağlandığında, yüksek sınıflandırma performansı algoritmanın tercih edilmesinde ikinci düzeyde aranacak ölçüttür [26, 47].

Veri madenciliği ve makine öğrenmesi yöntemlerinin temel özellikleri şöyle özetlenebilir [26]:

1. Her iki yöntem de kuramsal olmaktan çok ampirik öğrenme/sınıflandırma problemleriyle ilgilendir.
2. Verideki yapısal örüntüleri bulmak ve tanımlamak, bu veriyi açıklayacak aracı, yani algoritmayı ve ilintili kural kümesini (kümelerini) bulmak ve bu bilgiyi tahmin veya sınıflandırma amacıyla kullanmak makine öğrenmesinin asıl amacıdır.
3. Veri seti örneklerden oluşmaktadır. Her iki yöntemin çıktısı, yeni örnekler üzerinde yapılan tahmin/sınıflandırma ya da öğrenilen kurallardır.
4. Elde edilen bilginin, tanım alanı bağlamında kuramsallaştırılması önemli bir hedefdir.
5. Makine öğrenmesi ve veri madenciliği yöntemlerinde, veriden bilgi çıkarma yarım ya da tam otomatik süreçlerdir.
6. Karar destek sistemleri açısından, her iki yöntemde de, makine uzmanının bilgi işleme kapasitesine dayanılarak, insan uzmanının bu alandaki eksiklikleri giderilmek ve rekabet avantajı sağlamak amaçlanmaktadır.

5.8. Veri Madenciliğinde Kullanılan Yöntemler

Veri madenciliği tekniklerini işlevlerine göre aşağıdaki gibi 3 temel grupta sıralamak da uygun olacaktır [31].

1. Sınıflama (Classification),
2. Kümeleme (Clustering),
3. Birliktelik kuralları ve sıralı örüntüler (Association rules and sequential patterns).

Gerek tanımlayıcı gerekse tahmin edici modellerde yoğun olarak kullanılan belli başlı istatistikî yöntemler; sınıflama (classification) ve regresyon (regression), kümeleme (clustering), birliktelik kuralları (association rules) ve ardışık zamanlı örüntüler (sequential patterns), bellek tabanlı yöntemler, yapay sinir ağları ve karar ağaçları olarak sayılabilir. Sınıflama ve regresyon modelleri tahmin edici, kümeleme, birliktelik kuralları ve ardışık zamanlı örüntü modelleri tanımlayıcı modellerdir [34].

5.8.1. Sınıflama ve regresyon modelleri

Sınıflama, verinin önceden belirlenen çıktılarına uygun olarak ayrıştırılmasını sağlayan bir tekniktir. Çıktılar, önceden bilindiği için sınıflama, veri kümesini denetimli (supervised) olarak öğrenir [48]. Mevcut verilerden hareket ederek geleceğin tahmin edilmesinde faydalanılan ve veri madenciliği teknikleri içerisinde en yaygın kullanıma sahip olan sınıflama ve regresyon modelleri arasındaki temel fark, tahmin edilen bağımlı değişkenin kategorik veya süreklilik gösteren bir değere sahip olmasıdır. Ancak çok terimli lojistik regresyon (multinomial logistic regression) gibi kategorik değerlerin de tahmin edilmesine olanak sağlayan tekniklerle, her iki model giderek birbirine yaklaşmakta ve bunun bir sonucu olarak aynı tekniklerden yararlanılması mümkün olmaktadır. Sınıflama ve regresyon modellerinde kullanılan başlıca teknikler aşağıdaki gibi sıralanabilir [41];

1. Diskriminant analizi (Discriminant Analysis),
2. Naïve-Bayes,
3. Karar Ağaçları (Decision Trees),
4. Yapay Sinir Ağları (Artificial Neural Networks),
5. Kaba kümeler,
6. Genetik Algoritmalar (Genetic Algorithms),
7. Bellek Temelli Nedenleme (Memory Based Reasoning),
8. Regresyon analizi (Regression Analysis).

5.8.1.1. Diskriminant analizi

Diskriminant analizi, bir dizi gözlemi önceden tanımlanmış sınıflara atayan bir tekniktir. Model, ait oldukları sınıf bilinen gözlem kümesi üzerine kurulur. Bu küme, öğrenme kümesi olarak da adlandırılır. Öğrenme kümesine dayalı olarak, diskriminant fonksiyonu olarak bilinen doğrusal fonksiyonların bir kümesi oluşturulur. Diskriminant fonksiyonu, yeni gözlemlerin ait olduğu sınıfı belirlemek için kullanılır. Yeni bir gözlem söz konusu olduğunda için tüm diskriminant fonksiyonları hesaplanır ve yeni gözlem diskriminant fonksiyonunun değerinin en yüksek olduğu sınıfa atanır.

5.8.1.2. Naive bayes

Naive Bayes, hedef deęişkenle bağımsız deęişkenler arasındaki ilişkiyi analiz eden tahmine yönelik ve tanımlayıcı bir sınıflama algoritmasıdır [31, 49].

Naive Bayes, sürekli veri ile çalışmaz. Bu nedenle sürekli deęerleri içeren bağımlı ya da bağımsız deęişkenler kategorik hale getirilmelidir. Örneęin; bağımsız deęişkenlerden biri yaş ise, sürekli deęerler “<20” “21-30”, “31-40” gibi yaş aralıklarına dönüştürülmelidir.

Naive Bayes, modelin öğrenilmesi esnasında, her çıktının öğrenme kümesinde kaç kere meydana geldiğini hesaplar. Bulunan bu deęer, öncelikli olasılık olarak adlandırılır. Örneęin; bir banka kredi kartı başvurularını “iyi” ve “kötü” risk sınıflarında gruplandırmak istemektedir. İyi risk çıktısı toplam 5 vaka içinde 2 kere meydana geldiyse iyi risk için öncelikli olasılık 0,4’tür. Bu durum, “Kredi kartı için başvuran biri hakkında hiçbir şey bilinmiyorsa, bu kişi 0,4 olasılıkla iyi risk grubundadır” olarak yorumlanır Naive Bayes aynı zamanda her bağımsız deęişken / bağımlı deęişken kombinasyonunun meydana gelme sıklığını bulur. Bu sıklıklar öncelikli olasılıklarla birleştirilmek suretiyle tahminde kullanılır [31].

5.8.1.3. Karar ağaçları

Karar ağaçları, yaygın olarak kullanılan sınıflama algoritmalarından biridir. Karar ağacı yapılarında, her düęüm bir nitelik üzerinde gerçekleştirilen testi, her dal bu testin çıktısını, her yaprak düęüm ise sınıfları temsil eder. En üstteki düęüm kök düęüm olarak adlandırılır. Karar ağaçları, kök düęümünden yaprak düęüme doğru çalışır [50].

En yaygın kullanılan karar ağacı algoritmaları [51];

1. A limited search induction tree algorithm [52],
2. ID3-IV [53],
3. GID3 [54],

4. ASSISTANT 86 [55],
5. CHAID [56],
6. C&RT (Classification and Regression Trees) [31],
7. Improved CHAID (Tschuprow Goodness of Split) [57],
8. C4.5 [58, 59]
9. Improved C4.5 [60, 61, 62]
10. Cost sensitive C4.5 [63, 64, 65]

5.8.1.4. Yapay sinir ağıları

Yapay sinir ağıları; insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir. Bu yetenekleri geleneksel programlama yöntemleri ile gerçekleştirmek oldukça zor veya mümkün değildir. Bu nedenle yapay sinir ağlarının, programlanması çok zor veya mümkün olmayan olaylar için geliştirilmiş adaptif bilgi işleme ile ilgilenen bir bilgisayar bilim dalı olduğu söylenebilir [66].

Diğer bir tanıma göre yapay sinir ağıları; insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapıları; bir başka deyişle, biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır [67].

Yapılan tanımların bazı ortak noktaları bulunmaktadır. Bunların en başında yapay sinir ağlarının birbirine hiyerarşik olarak bağlı ve paralel çalışabilen yapay sinir hücrelerinden oluşmaları gelmektedir. Proses elemanları da denilen bu hücrelerin birbirlerine bağlandıkları ve her bağlantının bir değerinin olduğu kabul edilmektedir. Bilginin öğrenme yolu ile elde edildiği ve proses elemanlarının bağlantı değerlerinde saklandığı, dolayısıyla dağıtık bir hafızanın söz konusu olduğu da ortak noktalardan birisini oluşturmaktadır. Proses elemanlarının birbirleri ile bağlanmaları sonucunda oluşan ağa yapay sinir ağı adı verilmektedir [68]. Bu teknik, veritabanındaki örüntüleri,

sınıflandırma ve tahminde kullanılmak üzere genelleştirmektedir. Yapay sinir ağıları algoritmaları, sayısal veriler üzerinde çalışırlar [31].

5.8.1.5. Kaba kümeler

Kaba küme teorisi 1970’li yıllarda Pawlak tarafından geliştirilmiştir. Kaba küme teorisinde bir yaklaştırma uzayı ve bir kümenin alt ve üst yaklaşırmaları vardır. Yaklaştırma uzayı, ilgilenilen alanı ayrı kategorilerde sınıflandırır. Alt yakınlaştırma belirli bir altkümeyle ait olduğu kesin olarak bilinen nesnelere tanımıdır. Üst yakınlaştırma ise alt kümeyle ait olması olası nesnelere tanımıdır. Alt ve üst sınırlar arasında tanımlanan herhangi bir nesne ise “kaba küme” olarak adlandırılır [69].

5.8.1.6. Genetik algoritma

Genetik algoritma (GA), rassal arama tekniklerini kullanarak çözüm bulmaya çalışan, parametre kodlama esasına dayalı bir arama tekniğidir [70]. Genetik algoritma, pek çok problem türü için uygun parametrelerle çalışıldığı takdirde optimuma yakın çözümler verir. GA’nın çalışma yöntemi Darwin’in Doğal Seçim prensibine dayanır. GA’da amaç doğal sistemlerin uyum sağlama özelliğini dikkate alarak yapay sistemleri tasarlamaktır [71,72].

Algoritma ilk olarak popülasyon adı verilen bir çözüm kümesi (öğrenme veri kümesi) ile başlatılmaktadır. Bir popülasyondan alınan sonuçlar bir öncekinden daha iyi olacağı beklenen yeni bir popülasyon oluşturmak için kullanılmaktadır. Evrim süreci tamamlandığında bağımlılık kuralları veya sınıf modelleri ortaya konmuş olma anlamındadır [73].

Bir problemin GA ile çözümünde takip edilecek işlem adımları aşağıda verilmiştir [71].

1. Arama uzayındaki bütün muhtemel çözümler, dizi olarak kodlanır. Her bir dizi, arama uzayında belirli bir bölgeye tekabül eder.

2. Genellikle rassal bir çözüm seti seçilir ve başlangıç popülasyonu olarak kabul edilir.
3. Her bir dizi için bir uygunluk değeri hesaplanır; bulunan uygunluk değerleri dizilerin çözüm kalitesini gösterir.
4. Bir grup dizi (kromozom) belirli bir olasılık değerine göre rassal olarak seçilip üreme işlemi gerçekleştirilir.
5. Üreme işleminde çeşitli genetik operatörler kullanılabilir.

5.8.1.7. Bellek temelli nedenleme

Bellek tabanlı (memory based reasoning) veya örnek tabanlı bu yöntemler istatistikte 1950’li yıllarda önerilmiş olmasına rağmen o yıllarda gerektirdiği hesaplama ve bellek yüzünden kullanılamamış ama günümüzde bilgisayarların ucuzlaması ve kapasitelerinin artmasıyla, özellikle de çok işlemcili sistemlerin yaygınlaşmasıyla, kullanılabilir olmuştur [74].

Bu yönteme en iyi örnek en yakın k komşu algoritmasıdır. En yakın komşu yaklaşımı, x noktasının sınıfını, x noktasına en yakın olan noktanın sınıfı olarak belirleme yaklaşımıdır. Sınıfı belirlenen nokta ile komşu nokta aynı sınıfa ait değiller ise hata söz konusudur. Bu yaklaşım sadece en yakın komşu ile sınıflandırma yapar, önceden sınıflandırılmış diğer noktaları önemsemez [74].

Temel yaklaşımı, sınıflandırılmak istenen örneğe en yakın örnekleri bulmak olarak özetlenebilir [43].

1. Bütün örnekler n -boyutlu uzayda bir noktaya karşı düşürülür.
2. Nesnelere arasındaki uzaklık (Öklid uzaklığı) belirlenir.
3. Öğrenilen fonksiyon ayrık değerli veya gerçel değerli olabilir.
4. Ayrık değerli fonksiyonlarda k komşu algoritması X_q örneğine en yakın k öğrenme örneğinde en çok görülen sınıf değerini verir.
5. Sürekli değerli fonksiyonlarda en yakın k öğrenme örneğinin ortalaması alınmaktadır.

5.8.1.8. Regresyon analizi

Regresyon analizi (regression analysis), herhangi bir deęişkenin (baęımlı deęişken) bir veya birden fazla deęişkenle (baęımsız veya açıklayıcı deęişken) arasındaki ilişkinin matematik bir fonksiyon şeklinde yazılmasıdır. Bu fonksiyona regresyon denklemi adı verilmektedir. Regresyon denklemi yardımıyla baęımlı deęişken ile baęımsız deęişken(ler) arasındaki ilişkiyi kuran parametrelerin deęerleri tahmin edilir [68,74]. Regresyon analizi, kullanılan baęımsız deęişken sayısına göre;

1. Basit regresyon analizi (Tek baęımsız deęişken),
2. Çoklu Regresyon analizi (Birden çok baęımsız deęişken),

Fonksiyon tipine göre;

1. Doğrusal regresyon analizi,
2. Doğrusal olmayan (eęrisel) regresyon analizi,

Verilerin kaynağına göre;

1. Ana kütle verileriyle regresyon analizi,
2. Örnek verileriyle regresyon analizi olmak üzere üç grupta toplanabilir.

Ana kütle (evren) için basit doğrusal regresyon denklemi aşağıdaki gibi yazılır;

$$Y = \beta_0 + \beta_1 x + \varepsilon \quad (5.1)$$

Bu denklemde β_0 , $x = 0$ olduğunda regresyon doğrusunun dikey eksenini kestięi noktayı göstermektedir. β_1 Doğrusal fonksiyonun eğimi, yani baęımsız deęişken x 'deki bir birimlik deęişmenin baęımlı deęişken Y 'de (Y cinsinden) ne kadarlık bir deęişme meydana getirdiğini gösteren regresyon katsayısıdır. ε ise, rassal (tesadüfi) hata terimidir. Artık veya kalıntı (residual) adı da verilmektedir. $\varepsilon = Y - \hat{Y}$ 'dir. \hat{Y} , tahmini baęımlı deęişkenin deęerini göstermektedir. Gerçek hayat uygulamalarında β_0 ve β_1

değerleri bilinmiyorsa, ana kütlede örnekler alınarak bunların tahminçileri olan b_0 ve b_1 kullanılarak (5.1) nolu denklem,

$$y = b_0 + b_1x + e \quad (5.2)$$

olarak yazılır. Ana kütle ve örnek için çoklu doğrusal regresyon denklemleri ise sırasıyla,

$$Y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_nx_n + \varepsilon \quad (5.3)$$

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n + e \quad (5.4)$$

şeklinde ifade edilmektedir [75].

5.8.2. Kümeleme modelleri

Kümeleme, veriyi sınıflara veya kümelere ayırma işlemidir. Aynı kümedeki elemanlar birbirleriyle benzerlik gösterirlerken, başka kümelerin elemanlarından farklıdır. Kümeleme veri madenciliği, istatistik, biyoloji ve makine öğrenimi gibi pek çok alanda kullanılır. Kümeleme modelinde, sınıflama modelinde olan veri sınıfları yoktur. Verilerin herhangi bir sınıfı bulunmamaktadır. Sınıflama modelinde, verilerin sınıfları bilinmekte ve yeni bir veri geldiğinde bu verinin hangi sınıftan olabileceği tahmin edilmektedir. Oysa kümeleme modelinde, sınıfları bulunmayan veriler gruplar halinde kümelere ayrılırlar. Bazı uygulamalarda kümeleme modeli, sınıflama modelinin bir önişlemi gibi görev alabilmektedir [76, 77].

Marketlerde farklı müşteri gruplarının keşfedilmesi ve bu grupların alışveriş örüntülerinin ortaya konması, biyolojide bitki ve hayvan sınıflandırmaları ve işlevlerine göre benzer genlerin sınıflandırılması, şehir planlanmasında evlerin tiplerine, değerlerine ve coğrafik konumlarına göre gruplara ayrılması gibi uygulamalar tipik kümeleme uygulamalarıdır. Kümeleme aynı zamanda Web üzerinde bilgi keşfi için dokümanların sınıflanması amacıyla da kullanılabilir [78]. Veri kümeleme güçlü bir gelişme göstermektedir. Veri tabanlarında toplanan veri miktarının artmasıyla orantılı

olarak, kümeleme analizi son zamanlarda veri madenciliği arařtırmalarında aktif bir konu haline gelmiřtir [76].

Literatürde pek çok kümeleme algoritması bulunmaktadır. Kullanılacak olan kümeleme algoritmasının seçimi, veri tipine ve amaca baėlıdır. Genel olarak başlıca kümeleme yöntemleri su řekilde sınıflandırılabilir [76, 79]:

1. Bölme yöntemleri (Partitioning methods)
2. Hiyerarşik yöntemler (Hierarchical methods)
3. Yoğunluk tabanlı yöntemler (Density-based methods)
4. Izgara tabanlı yöntemler (Grid-based methods)
5. Model tabanlı yöntemler (Model-based methods)

Bölme yöntemlerinde, n veri tabanındaki nesne sayısı ve k oluşturulacak küme sayısı olarak kabul edilirler. Bölme algoritması n adet nesneyi, k adet kümeye böler ($k \leq n$). Kümeler tarafsız bölme kriteri olarak nitelendirilen bir kriterine uygun oluşturulduğundan aynı kümedeki nesnelere birbirlerine benzerken, farklı kümedeki nesnelere daha farklıdır [79].

En iyi bilinen ve en çok kullanılan bölme yöntemleri k -means yöntemi, k -medoids yöntemi ve bunların varyasyonlarıdır [80]. k -means yöntemi, ilk önce n adet nesneden rastgele k adet nesne seçer ve bu nesnelerin her biri, bir kümenin merkezini veya orta noktasını temsil eder. Geriye kalan nesnelere her biri kendisine en yakın olan küme merkezine göre kümelere dağılırlar. Yani bir nesne hangi kümenin merkezine daha yakın ise o kümeye yerleşir. Ardından her küme için ortalama hesaplanır ve hesaplanan bu değer o kümenin yeni merkezi olur. Bu işlem tüm nesnelere kümelere yerleşinceye kadar devam eder [79].

k -means yöntemi, sadece kümenin ortalaması tanımlanabildiği durumlarda kullanılabilir [81]. Kullanıcıların k değerini, yani oluşacak küme sayısını belirtme gerekliliği bir dezavantaj olarak görülebilir. Esas önemli olan dezavantaj ise dışarıda kalanlar (outliers) olarak adlandırılan nesnelere karşı olan duyarlılıktır [79]. Değeri çok büyük

olan bir nesne, dâhil olacağı kümenin ortalamasını ve merkez noktasını büyük bir derecede değiştirebilir. Bu değişiklik kümenin hassasiyetini bozabilir. Bu sorunu gidermek için kümedeki nesnelerin ortalamasını almak yerine, kümede ortaya en yakın noktada konumlanmış olan nesne anlamındaki medoid kullanılabilir. Bu işlem k-medoids yöntemi ile gerçekleştirilir.

k-medoids kümeleme yönteminin temel stratejisi ilk olarak n adet nesnede, merkezi temsili bir medoid olan k adet küme bulmaktır. Geriye kalan nesnelere, kendilerine en yakın olan medoide göre k adet kümeye yerleşirler. Bu bölünmelerin ardından kümenin ortasına en yakın olan nesneyi bulmak için medoid, medoid olmayan her nesne ile yer değiştirir. Bu işlem en verimli medoid bulunana kadar devam eder [79].

Kümeleme modellerinde amaç üyelerinin birbirlerine çok benzediği, ancak özellikleri birbirlerinden çok farklı olan kümelerin bulunması ve veri tabanındaki kayıtların bu farklı kümelere bölünmesidir. Kümeleme analizinde; veri tabanındaki kayıtların hangi kümelere ayrılacağı veya kümelemenin hangi değişken özelliklerine göre yapılacağı konunun uzmanı olan bir kişi tarafından belirtilebileceği gibi veri tabanındaki kayıtların hangi kümelere ayrılacağını geliştirilen bilgisayar programları da yapabilmektedir [41].

5.8.3. Birliktelik kuralları ve ardışık örüntüler

Birliktelik kuralları, büyük veri kümeleri arasında birliktelik ilişkileri bulurlar [82]. Toplanan ve depolanan verinin her geçen gün gittikçe büyümesi yüzünden, şirketler veritabanlarındaki birliktelik kurallarını ortaya çıkarmak istemektedirler. Büyük miktardaki mesleki işlem kayıtlarından ilginç birliktelik ilişkilerini keşfetmek, şirketlerin karar alma işlemlerini daha verimli hale getirmektedir. Birliktelik kurallarının kullanıldığı en tipik örnek market sepeti uygulamasıdır. Bu işlem, müşterilerin yaptıkları alışverişlerdeki ürünler arasındaki birliktelikleri bularak müşterilerin satın alma alışkanlıklarını analiz eder. Bu tip birlikteliklerin keşfedilmesi, müşterilerin hangi ürünleri bir arada aldıkları bilgisini ortaya çıkarır ve market yöneticileri de bu bilgi ışığında daha etki satış stratejileri geliştirebilirler. Örneğin bir müşteri süt satın alıyorsa, aynı alışverişte sütün yanında ekmek alma olasılığı nedir? Bu tip bir bilgi ışığında

rafları düzenleyen market yöneticileri ürünlerindeki satış oranını arttırabilirler. Örneğin bir marketin müşterilerinin süt ile birlikte ekmek satın alan oranı yüksekse, market yöneticileri süt ile ekmek raflarını yan yana koyarak ekmek satışlarını arttırabilirler. Örneğin bir A ürününü satın alan müşteriler aynı zamanda B ürününü de satın alıyorsa, bu durum (2.1)'deki Birliktelik Kuralı ile gösterilir [76, 83]:

$$A \Rightarrow B \text{ [destek} = \%2, \text{güven} = \%60] \quad (5.5)$$

Buradaki destek ve güven ifadeleri, kuralın ilginçlik ölçüleridir. Sırasıyla, keşfedilen kuralın kullanışlılığını ve doğruluğunu gösterirler. (2. 1)'deki Birliktelik Kuralı için %2 oranındaki bir destek değeri, analiz edilen tüm alışverişlerden %2'sinde A ile B ürünlerinin birlikte satıldığını belirtir. %60 oranındaki güven değeri ise A ürününü satın alan müşterilerinin %60'ının aynı alışverişte B ürününü de satın aldığını ortaya koyar. Kullanıcı tarafından minimum destek esik değeri ve minimum güven esik değeri belirlenir ve bu değerleri asan birliktelik kuralları dikkate alınır. Büyük veri tabanlarında birliktelik kuralları bulunurken, şu iki işlem basamağı takip edilir [83]:

1. Sık tekrarlanan öğeler bulunur: Bu öğelerin her biri en az, önceden belirlenen minimum destek sayısı kadar sık tekrarlanırlar.
2. Sık tekrarlanan öğelerden güçlü birliktelik kuralları oluşturulur: Bu kurallar minimum destek ve minimum güven değerlerini karşılamalıdır. Sık tekrarlanan öğeleri bulmak için kullanılan en temel yöntem Apriori Algoritmasıdır [76].

Birliktelik analizi, bir veri kümesindeki kayıtlar arasındaki bağlantıları arayan denetimsiz (unsupervised) veri madenciliği şeklidir. Birliktelik analizi çoğu zaman perakende sektöründe süpermarket müşterilerinin satın alma davranışlarını ortaya koymak için kullanıldığından “pazar sepeti analizi” olarak da adlandırılır [76].

5.9. Tıbbi Verilerle Veri Madenciliği

Tıp alanında bilginin kullanım şeklinde meydana gelen değişiklikler sağlık bakım hizmetini verenleri etkilemiştir, sağlık bakım hizmetinin verilmesinde bilgisayar

kullanımı, bilginin paylaşım-ekip yaklaşımını, veri ve bilgi temelli uygulama gibi kavramlar yaygınlaşmaya başlamıştır. Bilgisayarlar hasta bakım hizmetlerinin destekleme, sağlık bakım hizmetlerinin kalitesinin değerlendirilmesi gibi doğrudan sağlık bakım hizmetlerinin sunulmasında kullanılmasının yanı sıra, teşhis koyma, tedavi süreçleri, yönetim, planlama ve tıbbi araştırmalar gibi yönetsel ve akademik fonksiyonların yerine getirilmesinde daha fazla kullanılmaya başlanılmıştır [84].

Tıp alanında bulunan mevcut veri oldukça fazla ve hayati öneme sahiptir. Hastane bilgi sistemleri sayesinde bu veriler düzenli olarak tutulmaktadır. Hayati öneme sahip olan bu verilerden daha fazla yararlanmak mümkündür. Hastane Bilgi sistemlerinden veya diğer tıbbi veri toplayan sistemlerden alınan veriler üzerinde yapılan veri madenciliği çalışmaları hem uzmanlar için hem hastane yönetimi için hem de hastaların daha kaliteli bir hizmet almalarında etkin rol oynamaktadır [84].

5.9.1. Tıbbi verilerle veri ambarının oluşturulması

Tıbbi veriler üzerinde çalışma yapmak bu verileri iyi tanımakla mümkündür. Tıbbi verilerin yorumlanmasında uzmanların önemli bir rolü vardır. Bu nedenle uzman görüşleri ile işlemler arasındaki bağlantı iyi kurulmalıdır. Tıp alanında belirli bir standardın olmayışı ve var olan standartlar arasında tam bir uyumun olmaması nedeniyle, bu alanda bir veri ambarının oluşturulması oldukça zor bir işlemdir. çeşitli standartlar arasında farklı kodlama sistemleri mevcut durumdadır. Bu nedenle veri ambarı oluştururken farklı kaynaklardan toplanan veriler arasındaki standart uyumu da göz önüne alınmalıdır [84].

Bunu yanı sıra tıp alanındaki terimlerin hem karışık hem de birbirine yaklaşık olması da veri ambarı oluşumunu negatif yönde etkilemektedir. Tıp alanındaki veri genellikle farklı kaynaklarda toplanmaktadır. Örneğin hastanın laboratuvar ile ilgili verileri ile hastanın teşhis bilgileri farklı kaynaklarda ve farklı şekillerde tutulmaktadır [84].

5.9.2. Tıbbi verilerin özellikleri

Tıbbi verilerin veri madenciliğinde etkin olarak kullanılabilmesi için bu verilerin özelliklerinin çok iyi bilinmesi ve yapılan işlemlerin bu özellikleri dikkate alınarak yapılması gerekmektedir. Bunlar [38, 94]:

1. Çok sayıda yordam, görüntülemeyi bir tanı aracı olarak kullanmaktadır. Bu nedenle, görüntülerden oluşan veritabanlarında etkin bir veri madenciliği gerçekleştirebilmek için yöntemler geliştirmek gerekmektedir. Bu da sayısal veritabanlarındaki veri madenciliğinden hem daha farklı, hem de daha zordur.
2. Tıbbi veritabanları, her zaman heterojendir. Örneğin, bir organa ait görüntü, her zaman, hekimin yorumu (klinik izlenim, tanı) gibi, başka klinik bilgilerle bir aradadır. Bu ise, bu tür verilerin çözümü için yeni araçlar ve yüksek kapasiteli veri depolama aygıtları gerektirir.
3. Hekimler, görüntüler, sinyaller ya da diğer klinik bilgilerle ilgili yorumlarını, standartlaştırılması çok güç olan serbest metinler olarak yazmaktadır. Örneğin aynı hastalık açıklanırken bile farklı adlar kullanılmaktadır. Tıbbi kavramlar arasındaki ilişkileri açıklamak için de farklı dilbilgisi yapıları kullanılmaktadır.
4. Verinin sahibi kimdir? Her yıl milyarlarca baytlık tıbbi veri üretilmekte, bu veriler, heterojen veritabanlarında saklanmakta ve sağlık kurumları tarafından ortak bir biçim ya da ilkeye göre düzenlenmeden yayılmaktadır. Hastaya ait bilgilerin sahibinin kim olduğu sorusu hâlâ yanıtlanmamıştır. Hastalar mı, hekimler mi, sigorta kurumları mı?
5. Hekimlere ya da sağlık hizmeti veren diğer kişilere yönelik davalardır. Örneğin, hekimler gereksiz testler yüzünden dava konusu olabilmektedir. Böyle bir ortamda da hekimler ya da sağlık hizmeti veren diğer kişiler, verilerini bu veriler üzerinde çalışacak olan kişi ya da kurumlara aktarmakta gönülsüz davranmaktadır.
6. Gizlilik, güvenlik ve hasta mahremiyetiyle ilgili vb konular. Veri Internet üzerinden elektronik olarak aktarıldığından, güvenli değildir. Bu nedenle veri bir kurum içinde bir birimden diğerine aktarılacak olsa da dikkatli bir biçimde şifrelenmelidir.

7. Tıptaki temel veri yapıları, fiziksel bilimlerin birçok alanıyla karşılaştırıldığında, matematiksel olarak karakterize edilmeye pek uygun değildir. Veri madencisinin bilgiyi düzenleyebileceği, kümeleme, gerileme modelleri ya da dizi çözümlenmeleri gibi karşılaştırılabilir yapılar yoktur.
8. Tıp öncelikle insan sağlığıyla ilgili bir etkinlik, ikincil olarak bir araştırma kaynağıdır. Genel olarak tıp alanında bilgi toplama ya da bazı bilgilerin toplanmasını reddetme, hasta yararı içindir.

BÖLÜM 6. EPİLEPTİFORM AKTİVİTENİN BELİRLENMESİNE YÖNELİK UYGULAMA

6.1. Literatür Taraması

Bu bölümünde EEG sinyalleri kullanılarak, epileptiform aktivitenin veri madenciliği süreci ile tespit edilmesine yönelik bir uygulama gerçekleştirilmiştir. Uygulama öncesi konu ile ilgili yapılmış çalışmaların kısa bir özeti aşağıda verilmiştir.

EEG dalgalarına ilk spektral analizi, Hızlı Fourier Dönüşümünü kullanarak, 1936 yılında Grass uygulamıştır. Bu uygulamadan sonra 1969 yılında Walter'ın ve 1971'de Joy'un genel amaçlı bir bilgisayar kullanarak spektral analiz yöntemiyle EEG dalgalarını incelediği bilinmektedir [87, 88].

1967'de Fenwick vd., 1969'da Zxetterberg, 1979'da Gersch ve Kleiner modern spektral analiz yöntemlerinden biri olan AR yöntemini EEG'ye uygulamışlardır [87].

1981'de Isakson vd., orijinal EEG işaretini 200 Hz'le örnekleyip spektral analiz yöntemlerine tabi tutmuşlardır. Bu çalışmada AR modelinin işlem yükü açısından daha avantajlı olduğu belirlenmiştir [87, 88].

Jansen vd. 1981 yılında yaptıkları çalışmada, kısa süreli EEG kayıtlarında, FFT veya parametrik yöntemlerin kullanılabileceği, fakat ani değişikliklerin ortaya çıkma ihtimalinin olduğu işaretlerde Burg yönteminin tercih edilmesi gerektiği sonucuna varmışlardır [87, 88].

1988'de Birch vd., sağlıklı insanlardan alınan EEG'leri 1 sn'lik bölümlere ayırarak FFT, AR ve önbeyazlamalı AR yöntemleri ile incelemişlerdir [87].

1992’de Gath vd., epileptik nöbetler sırasında kaydedilen EEG’lerin spektral analizinde FFT ve AR yöntemlerini kullanarak karşılaştırma yapmışlardır [87, 88].

Tseng vd. 1993 yılında EEG işaretlerinin formunun tespit edilmesi üzerine yaptıkları bir çalışmada sinir ağlarını kullanmışlardır. Uzman gözlemcilerin elde ettiği veriler ile sistemden elde edilen veriler karşılaştırıldığında %88,7 başarı sağlandığı görülmüştür [87, 88].

1994’de Pradhan ve Dutt, çok kanallı EEG cihazı ile kaydedilen EEG işaretlerini standart Fourier yöntemlerinden olan CSA ve AR modeli ile incelemişler, işlem yükü, depolama kapasitesi ve EEG bilgilerinin transferi açısından AR modelinin daha avantajlı olduğunu gözlemlemişlerdir [87, 88].

Sweldens (1994), çalışmasında bir fonksiyonun dalgacık sabitlerini bu fonksiyonun örneklerinden hesaplanması üzerine interpolasyon, quadrature formül ve filtreleme metotlarıyla uygulamalar sunmuştur [4, 89].

Schiff, EEG verilerinde epileptik dalgaları tespit etmek ve rahatsızlık bölgelerini belirlemek için 1994’de yaptığı çalışmada DD’yi kullanarak büyük oranda sonuca ulaşmıştır [87].

Anderson vd. (1995), çalışmasında EEG işaretleri yardımıyla zihinsel durumun tanımlanması amacıyla Yapay Sinir Ağları kullanmışlardır [4, 90].

Grap (1995), makalesinde geleneksel Fourier metotları, Dalgacık teorisi ve analizlerinin gelişimini inceleyerek sinyal işleme alanı temelli çeşitli karşılaştırmalar yapmış, ayrıca dalgacık analizinin uygulama alanlarından bahsetmiştir [4, 18].

Kalaycı ve Özdamar (1995), giriş ve çıkış sinyalinin karakteristik özelliklerini gösterebilecek şekilde işlenebilmesi durumunda Yapay Sinir Ağlarının daha iyi sonuç verdiğini gösteren bir çalışma yapmışlardır [4, 91].

Prodhan vd. (1996), LVQ (Learning Vector Quantization) temelli bir Yapay Sinir Ağı kullanarak nöbet aktivitesinin sınıflandırılması için çalışma yapmışlardır [92].

Kalaycı (1996), EEG Dikenlerinin Yapay Sinir Ağları ile Tanınması isimli doktora tezinde DDK, EMG ve Zemin-EEG tipi EEG olaylarının tanınmasında 3 katmanlı, tam bağlanmış, ileri beslemeli, geriye dağılma tipinde YSA kullanmıştır. Beş hastadan kaydedilen EEG sinyalleri sayısallaştırıldıktan sonra özel olarak geliştirilen bir yazılım kullanılarak, YSA için eğitim ve test verileri oluşturulmuştur. Bu veriler kullanılarak, çok sayıda ağ; giriş verisi sayısının, gizli katman nöron sayısının ve eğitim döngüsü sayısının tanıma performansı üzerindeki etkilerini belirlemek amacıyla eğitilmiş ve test edilmiştir [1].

Dograhmi ve ark. (1997), çalışmasında EEG kayıtlarının spektral analiz temelli sınıflandırılmasını amaçlayarak elektrot sayısı ve uygulanan spektral analiz yöntemi özelliklerinin bir sınıflandırıcı gibi kullanılması konusunu incelemişlerdir [4].

Mckeown vd. (1997), EEG işaretlerinin analizi ve uyarı değişikliklerinin bulunması amacıyla istatistiksel yöntemler kullanarak bir çalışma yapmışlardır [4].

Jung vd. (1997) çalışmasında uyku ve uyanıklık durumlarının Yapay Sinir Ağları ile sınıflandırılmasında, ham EEG işaretlerinden ziyade Fourier Dönüşümü alınmış EEG'nin daha uygun sonuçlar verdiğini gözlemlemişlerdir [4].

Wu ve Gotman (1998), EEG sinyallerinden belirledikleri öznelikleri çıkararak, sınıflama ve kümeleme algoritmaları ile epileptik aktiviteyi belirlemeye çalışmışlardır [93].

Miner (1998), bu raporda geleneksel Fourier metotları, Dalgacık teorisi ve analizlerinin gelişimini inceleyerek sinyal işleme alanı temelli çeşitli karşılaştırmalar yapılmış, ayrıca sürekli ve ayrık dalgacık analizi algoritmaları verilmiştir [21].

Torrence vd. (1998), çalışmalarında yaygın olarak kullanılan temel dalgacık fonksiyonları sınıflandırılmış, özellikleri verilerek ayrık zaman diziler için sürekli

dalgacık dönüşümü yaklaşıklığı verilmiştir. Sonlu uzunlukta zaman serilerine pencerelemiş Fourier ve dalgacık dönüşümü uygulayarak istatistik önem ile güvenilirlik aralığı analizleri yapmışlardır [4, 98].

Önal vd. (1998), EEG sinyallerindeki epileptik sürecin Dalgacık Dönüşümü yöntemi ile belirlenmesini amaçlayarak bir çalışma yapmışlar ve bu çalışmada parsiyel nöbet geçiren 3 yaşındaki bir çocuktan alınan gerçek EEG işareti kullanarak epileptik süreçte özellikle düşük frekans bandının etkinliğini göstermişlerdir [87].

1998 yılında Önal tarafından hazırlanan EEG İşaretlerindeki Epileptik Sürecin Dalgacık Dönüşüm Yöntemi İle Belirlenmesi adlı Yüksek Lisans Tezinde; DD, frekans içeriği bilinen simüle işarete ve üç yaşında epilepsi nöbeti geçiren bir çocuktan alınmış gerçek işarete uygulanmıştır. Epileptik nöbet aktivitesinin tespit edilmesi ve görüntülenmesi için DD'nin kullanışlı olacağı gösterilmiştir [87].

Güneş 1999 yılında hazırladığı Yüksek Lisans tezinde EEG işaretlerine DD ve diğer analiz tekniklerini uygulayarak karşılaştırma yapmıştır [95].

Suleesathira vd. (2000), deterministik durağan olmayan sinyallerin gösteriminin ayrık evrimsel dönüşümle yapılabilirliği konusunda çalışmışlardır [4].

Girault vd. (2000), çalışmalarında durağan olmayan benzetim ve gerçek sinyaller üzerinde FFT, AR, zamanla değişen parametrik model yaklaşımı metotlarını kullanmışlar, frekans kestirimi için de karşılaştırma maksadıyla spektral ağırlık merkezi hesabıyla değerlendirmelerde bulunmuşlardır [4].

Andrzejak vd. (2001), çalışmalarında beyinin farklı bölgelerinden ve farklı hastalar üzerinden alınan verilerle beyin elektriksel aktivitesini kıyaslamışlardır. Çalışmada zaman serisi ve öznitelik çıkararak, sağlıklı ve hasta bireylerdeki durumları analiz etmişlerdir [96].

Akın vd. (2001), çalışmalarında epilepsi krizini teşhis etmek ve EEG sinyallerini sınıflamak için DD'yi ve YSA'yı kullanmışlardır [97].

Hazarika vd. çalışmalarında Normal, Şizofren ve Obsesif Kompulsif Bozukluğu olan kişilerden aldıkları 3 tip EEG sinyalini kullanmışlardır. Sınıflama için 3 katmanlı yanlış öğrenme algoritmasının geri yayılımını sağlayan ağ yapısını tercih etmişlerdir. Şizofrenilerin sınıflamasında %71, normalde %66'nın üzerinde doğruluk sağlamışlardır. DD'nin, sınıflamadan önce EEG sinyallerinin ön işlemleri için güçlü bir teknik olduğu gösterilmiştir [88,98].

Nuh vd. 2002 yılında yaptıkları çalışmada epileptik ani voltaj yükselmelerinin otomatik algılanması için Dalgacık Sinir Ağı (WNN) tabanlı yeni bir metot önermişlerdir. Sonuçlar, Dalgacık skalasının uygun seçiminin WNN performansını düşürmeden eğitim süresini azaltabileceğini göstermiştir [2].

Szilagyi vd. (2002), EEG sinyal işlemeyi iki adımda gerçekleştirmişlerdir. Birinci aşamada EEG sinyali, Çoklu çözünürlük dalgacık ayrışımı ile farklı spektral bileşenlerine ayrılmıştır. İkinci adımda bu bileşenler yapay sinir ağının girişi olarak kullanılmıştır. Ağın bütün test sinyallerini tanıma oranı %95'in üzerinde elde edilmiştir [88, 99].

Zarjam vd. (2003) çalışmalarında; yeni doğanlardaki EEG verilerinden kriz olaylarını seçmek için otomatik bir metot önermişlerdir. Eğitim ve test setleri; 2 günden 2 haftalığa kadar değişen yaş aralığında 5 yeni doğandan alınan EEG verilerinden elde edilmiştir. Üç katlı ileri beslemeli ağ kullanılmıştır. Eşleştirmeli eğitim öğrenme algoritması tercih edilerek bütün kriz verilerine '1' hedef değeri ve kriz olmayan verilere '-1' hedef değeri verilmiştir [88, 100].

Latka ve Was. (2003) çalışmalarında epileptik dikenlerin dalgacık dönüşümü ile analizini yapmışlardır. Beyin iki ayrı yarım küresinden sinyalleri inceleyerek, sinyallerin uyumunu dalgacık dönüşümü kullanarak incelemişlerdir [101].

Adeli vd. (2002) çalışmalarında, Epilepsi hastalarına ait EEG kayıtlarının analizinde Ayrik Daubechies ve harmonik Dalgacıkları kullanmışlardır [6].

Kıymık vd. (2004), gerçek zamanlı uygulamalar için EEG sinyallerindeki epileptik sürecin belirlenmesinde KZFD (Short Time Fourier Transform) ve Dalgacık Analiz yöntemlerini kapsayan bir çalışma yapmışlar ve bu çalışmada Dalgacık Dönüşümü'nün diğer spektral analiz yöntemi olan KZFD'ye oranla daha başarılı sonuçlar verdiğini göstermişlerdir [4].

Subaşı (2005) çalışmasında, bir deneğin uyanıklık seviyesini ayırt etmek için hata geri yayımlı ağ yapısını kullanmıştır. Ağ, Uyanık, Uykulu ve Uyumakta olmak üzere 3 çıkışa sahiptir. YSA'nın girişleri EEG kayıtlarına DD uygulanarak elde edilmiştir. YSA'nın doğruluk oranı %95 uyanık, %93 uykulu ve %92 uyumakta olarak bulunmuştur [87, 102].

Güler vd. (2005), 3 tip EEG sinyalini modüler sinir ağı yapısı ile %93,7 doğrulukla sınıflandırma elde etmişlerdir. İşaretleri spektral bileşenlerine ayırmada ADD kullanmışlardır [103].

Batar (2005) tez çalışmasında EEG işaretlerinin uyanıklık, uyuklama ve uyku hallerinde gösterdiği farklılıkları değerlendirip yapay sinir ağlarını kullanarak otomatik sınıflandırma yapmıştır [4].

Güler ve Übeyli (2005), EEG sinyallerinin özniteliklerinin elde edilmesi için DD'yi, sınıflandırılması için bulanık mantık sistemine dayalı uyarlanırlı ağ yöntemini (ANFIS) kullanmışlardır [104].

Srinivasan vd. (2005), çalışmalarında zaman-domain ve frekans-domain özniteliklerinden yola çıkarak, yapay sinir ağı tabanlı epilepsi teşhisi için bir model kullanmışlardır. Çalışma sonucunda %99,6 doğruluk oranı elde etmişlerdir [105].

Alkan (2005), çalışmasında EEG işaretlerinin klasik ve modern yöntemlerle ön işlenmesi için yapay sinir ağları ile model geliştirmiştir [10].

Subaşı (2007), EEG sinyallerinin sınıflandırılarak Epilepsi teşhisinin yapılabilmesi için modüler sinir ağı mimarisini kullanmıştır [106].

Toprak (2007) gerçekleştirdiği çalışmada EEG sinyallerinin dalgacık dönüşümü ile özniteliklerinin çıkararak yapay sinir ağları ile analizini yapmıştır. Farklı dalgacıkların, değişik öğrenme algoritmalarıyla eğitilen farklı mimarideki Çok Katmanlı Algılayıcı yapay sinir ağları ve Radyal Tabanlı Fonksiyon Ağları (RTFA) üzerindeki etkisi incelenerek, yüksek sınıflama doğruluğu elde edilmiştir [87].

Tıp alanında veri madenciliği uygulamaları çeşitli konularda yapılmıştır. Bunlardan bir kaçını aşağıda özetlediği gibidir. Kusiak ve arkadaşları tarafından akciğerdeki tümörün iyi huylu olup olmadığına dair, karar destek amaçlı bir çalışma yapılmıştır. İstatistiklere göre Amerika da 160.000 den fazla akciğer kanseri vakasının olduğu ve bunların %90'ının öldüğü belirlenmiştir. Bu bağlamda bu tümörün erken ve doğru olarak teşhisi önem kazanmaktadır. Noninvaziv testler ile elde edilen bilgi sayesinde %40–60 oranında doğru teşhis konabilmektedir. İnsanlar kanser olup olmadıklarından emin olmak için biyopsi yaptırmayı tercih etmektedirler. Biyopsi gibi invaziv testler hem maliyeti yüksek hem çeşitli riskler taşımaktadır. Farklı yerlerde ve farklı zamanlarda kliniklerde toplanan invaziv test verileri arasında yapılan veri madenciliği çalışmaları teşhiste %100 oranında doğruluk sağlamıştır [84, 85].

Başka bir çalışma ise Kore Tıbbi Sigorta Kurumu (The Korea Medical Insurance Corporation) tarafından hazırlanan bir veri tabanı üzerinde yapılan yüksek tansiyon ile ilgili bir çalışmadır. Bu çalışma 1998 yılına ait 127,886 kayıt üzerinde yapılmıştır. İlk aşamada yüksek tansiyona sahip 9,103 kayıt üzerinde, daha sonra aynı sayıda yüksek tansiyonu olmayan kayıtlar üzerinde çalışılmıştır. Bu örnek 13,689 kayıttan oluşan öğrenme ve 4,588 kayıttan oluşan test setine bölünerek modelin eğitimi yapılmıştır. Öğrenim algoritmasında karar ağaçları algoritmalarından CHAD, C4.5, C5.0 kullanılmıştır. Bu çalışmalar sonucunda yüksek tansiyon tahmininde etkili değerler BMI, idrar proteini (urinary protein), kan glikozu, kolesterol değerleridir. Yaşam koşullarının (diyet, alınan tuz miktarı, alkol, tütün gibi) hiçbirinin tahminde etkili olmadığı ayrıca grafiksel değerlerde de yalnızca yaşın etkili olduğu saptanmıştır [84, 86].

6.2. Çalışmada Kullanılan Veriler ve Özniteliklerinin Çıkarılması

EEG kayıtları pek çok farklı yöntem ve pek çok farklı cihazla yapılabilmektedir. Bu farklılıkların yanında verilerin analizinde hekimlerin kullandığı yöntemler ise birbirine benzerlik göstermektedir. Analiz başlangıcında dikkate alınması gereken temel faktörler daha önceki bölümlerde ele alınmıştır. Bu aşamada dikkate alınması gereken pek çok faktör bulunmaktadır. Bunlardan bazıları; hastanın hastalık geçmişinden başlayarak (çocukluktan başlayarak geçirdiği hastalıklar, hastalığın doğuştan mı yoksa sonradan mı oluştuğu, bir olaydan sonra mı başladığı veya sıklaştığı, genetik faktörler vb.), dış ortamdaki gelen uyarıcılara (parlak ışık, yüksek ses vb.) verdiği tepkilerdir. Ayrıca hastalığın analizinde hastanın yaşı, başka bir beyin hastalığı sebebi ile mi epilepsi krizlerinin oluştuğu, krizin gelme sıklığı da önem taşımaktadır.


EEG sinyalleri beyin aktivitesinin analizinde ve hastalık teşhisinde önemli bir yer tutmaktadır. Alınan EEG kayıtları uyanık, uykulu / dinlenme (rahatlama) ve uyur halde iken incelenmektedir. EEG verileri, epilepsinin analizinin yanı sıra başka beyin kaynaklı hastalıklarda da (Alzheimer, Parkinson, Creutzfeldt-Jakob, Depression, Schizophrenia vb.) hekimlere yardımcı olmaktadır [96]. Hastalık teşhisi konmasında, EEG verisi alınan kişiler sağlıklı kişilerin verileri ile kıyaslama sıklıkla kullanılan bir yöntemdir. Bu kıyaslama işlemi sırasında aynı yaş grubunda ve aynı cinsiyete sahip bir kişinin sahip olması gereken değerler ilgili kaynaklarda belirtilmekte ve hekiminde tecrübesi eklenerek teşhiste doğruluk oranı artırılmaya çalışılmaktadır. Genellikle uyanık halde iken oluşan beyin aktivitesi pek çok analiz yönteminde yeterli olmakta ve dış uyaranlar aracılığı ile bu durumdaki bireye uyarıcılar uygulanabildiği için uyanıklık halindeki analizler genellikle yüksek doğruluk oranında sonuç vermektedir [107, 108].

Teşhis işlemine yardımcı olan bir önemli faktör de EEG sinyalini alt frekans bantlarına veya özniteliklerine göre ayırarak analiz etmektir. Bu analizi bazı EEG cihazlarının üzerindeki yazılımlar yapmakla birlikte bazen bu sinyal EEG cihazından alınarak farklı bilgisayarda da yapılabilmektedir. Analiz yazılımları aynı sistemle çalışarak artifaktları ayırmakta, çeşitli filtrelerden geçirebilmekte ve alt frekans bantlarına ayırabilmektedir. Bu analiz yazılımları farklı formatta veri üreten cihazlara ait çok çeşitli veri formatlarını okuyabilmektedir.


Çalışmada kullanılan veriler; beyin sinyalleri konusunda dünyadaki sayılı bilimsel çalışma merkezlerinden biri olan Bonn Üniversitesi Epileptoloji Bölümü (Freiburg Veri Analizi ve Modelleme Merkezi) veritabanından alınmıştır. Veritabanındaki veriler 5 ayrı setten oluşmaktadır. Verilerin örnekleme frekansı 173,61 Hz ve artifaktların temizlenmesi amacıyla 0,5 Hz ile 85 Hz'lik bant geçiren filtreye tabi tutulmuştur. Ayrıca bu işlemten sonra verilere 0,53 ile 40 Hz'lik alçak geçiren filtre uygulanmıştır. Veriler veritabanına aktarılırken ayrıca nöroloji uzmanlarının göz ile kontrollerinde de geçirilmiştir [96].

Veritabanı içindeki 5 set farklı verilerden oluşmaktadır. Bu setlerden her biri içinde 100 adet tek kanal 23,6 saniyelik EEG veri segmentlerinden oluşmaktadır. Bu segmentlerden her biri çok kanallı EEG sinyallerinden göz ve vücut (kas) hareketleri de dikkate alınarak seçilmiştir. Bu beş adet veri setinden A ve B veri setleri gönüllü ve sağlıklı seçilmiş kişilerden, 10-20 standart elektrot yerleşim düzenine göre Şekil 6-1'de görüldüğü üzere yerleştirilerek çekilmiş EEG sinyallerinden oluşmaktadır. EEG kaydı sırasında kafa derisine yapıştırılan standart elektrotlar kullanılmıştır [96].

Veritabanına EEG kaydı alınan gönüllüler rahat ve uyanık durumdadırlar. Veritabanında bulunan beş ayrı veri setinden A veri seti gözleri açık ve B veri seti ise gözleri kapalı durumdaki sağlıklı bireylere aittir. Veritabanında bulunan C, D ve E veri setleri epilepsi teşhisi daha önceden konulmuş ve bir ön operasyonla kafatasına derin elektrot yerleştirilmiş bireylere aittir. C veri seti beyin karşı yarım küresindeki hippocampal yapıdan alınan, D veri seti ise epileptogenic bölgeden alınmış EEG kayıtlarından oluşmaktadır. E veri seti hastalık teşhisi konan bireylerin epileptik aktivite geçirmesi sırasında kaydedilmiş verileridir. EEG verilerinin tümü 128 kanallı EEG cihazından ve aynı yükselteç sistemi kullanılarak alınmıştır. 128 kanallı EEG sisteminden alınan bu veriler 12 bitlik analog - digital dönüşümden geçirilmiştir [96].




Şekil 6.1. 10-20 sistemine göre EEG elektrot yerleşim düzeni [96].




Şekil 6.2. 10-20 sistemine göre elektrotların yan ve üst görünümü [4].

Saçlı deri üzerinden yapılan ölçümlerde EEG sinyallerinin genliği μV cinsindedir. Fakat hastalarda kriz sırasında 100 veya 1000 μV türünden değerler elde edilebilmektedir. 100 adet veri bloğu içeren her bir veri seti 4096 örneklemeden oluşmaktadır [96]. Veri alınan veritabanında bulunan C ve D veri setleri beynin hippocampus bölgesi orta ve alt bölümüne simetrik olarak yerleştirilen derin elektrotlar (strip türünde) yardımı ile elde edilmiştir. Verilerin genliği kriz öncesi (normalde) 100 μV , kriz esnasında ise 1000 μV gibi değerlere ulaşması bu sebeptir. E veri setinde ise yerleştirilen strip türü bu elektrotların tümünden elde edilen veriler bulunmaktadır. Veri setlerine ait örnek grafikler Şekil 6.3.'de görülmektedir. Bu grafiklerden her biri 23,6 saniyelik dilimlerde elde edilmiş ve 4096 veri örneği içermektedir.




Şekil 6.3. Veritabanında bulunan veri setlerine ait grafik örnekleri [96]


Analizlerde, gözleri açık sağlıklı gönüllülerden alınan sinyaller (A veri seti) ve epilepsi hastalarından epilepsi krizi esnasında (E veri seti) alınan EEG sinyalleri kullanılmıştır. Şekil 6.4. – 6.7.’de veri setlerine ait μV türünden değerler (genlik) ile örnekleme sayısını gösteren grafikler yer almaktadır. Orijinal veriler veritabanında *.txt dosyalar halinde bulunmaktadır.




Şekil 6.4. A veri setine ait genlik (μV) ve örnekleme değişim örneği




Şekil 6.5. B veri setine ait genlik (μV) ve örnekleme deęişim örneęi



Şekil 6.6. C veri setine ait genlik (μV) ve örnekleme deęişim örneęi



Şekil 6.7. D veri setine ait genlik (μV) ve örnekleme deęişim örneęi



Şekil 6.8. E veri setine ait genlik (μV) ve örnekleme değişim örneği

Hastalık teşhisleri, veri sınıflama işlemi olarak incelenebilmektedir. Girişlerin belirsiz olması ve değişkenlik göstermesi durumunda YSA veri sınıflamada başarılı olmaktadır. Tıbbi alandaki uygulamalar da, YSA'nın hastalık teşhisini içeren şekil (veri) sınıflama için uygun olduğunu göstermektedir [103, 104, 108].

Teşhis sistemleri genellikle şu işlemlerden oluşmaktadır: ön işleme, öz nitelik çıkarma / seçme ve sınıflama. Öznitelik çıkarma, şekil tanımlama ve şeklin önemli özniteliklerinin çıkarılıp öznitelik vektörünün elde edilmesi işlemidir. Öznitelik seçme isteğe bağlı olarak yapılan bir işlem olup sınıflama işlemi açısından en belirleyici özniteliklerin seçilmesi ile öznitelik vektörünün boyutunun azaltılmasıdır. Teşhis sistemlerinin son aşaması olan sınıflamada, kullanılan algoritmaya bağlı olarak giriş öznitelik vektörleri incelenir ve sınıflama sonucu belirlenir. Sınıflama sonucunu belirlemesi açısından ele alındığında öznitelik çıkarma ve gerekli durumlarda öznitelik seçme, YSA gibi sınıflama sistemlerinin başarısını oldukça etkilemektedir [108].

Literatürde kurulan ve daha çok parametre ile yapılan analizlerin doğruluk oranı %90 ve üzerinde olmaktadır. Bu analizler yine yapay sinir ağı temelli olmakla beraber zaman-domain, frekans-domain özelliklerini de hastalık analizinde kullanmaktadır [104]. Srinivasan ve arkadaşlarının 2005 yılında yaptığı çalışmada analizin yapılırken beş ayrı parametre göz önünde tutulmuştur. Bunlar; baskın frekansın (dominant frequency) belirlenmesi, ana enerji bölgesinde ortalama gücün hesaplanması (average power in the main energy zone), normalize edilmiş spectral entropi (normalized spectral entropy), diken ritmi (spike rhythmicity) ve bağlı diken genliği (relative spike amplitude) 'dir. Bu

özellikler normal ve epileptik EEG sinyalleri üzerinden hesaplama ile çıkarılmış ve yapay sinir ağına eğitim ve test değişkenleri olarak giriş yapılmıştır [105].

Yukarıda sayılan parametreler farklı çalışmalarda farklı bilim adamları tarafından da kullanılmıştır. Bu parametrelerin nasıl hesaplanacağı Gotman ve Nigam vd. yaptığı çalışmalarda belirtilmiştir [93, 109, 110]. Srinivasan ve arkadaşlarının 2005 yılında yaptığı Elman ağı temelli bu çalışmada elde ettikleri %99,6 doğruluk oranını literatürde bulunan en yüksek doğruluk oranına sahip çalışmalardan biridir [105].

Yüksek doğruluk oranı bulunan başka bir çalışmada, Toprak'a ait yüksek lisans tezinde, %99,81 ile karşımıza çıkmaktadır. İlgili çalışmada, Kuasi - Newton yöntemlerinden en başarılı bulunan, Broyden-Fletcher-Goldfarb-Shanno (BFGS) yöntemi kullanarak elde edildiği belirtilmektedir [87]. Analiz parametreleri olarak Güler ve Übeyli'nin de kullandığı alttaki öznitelik parametrelerini kullanmıştır [87, 103, 104]. Bunlar:

1. Her bir alt banttaki katsayıların maksimumu,
2. Her bir alt banttaki katsayıların minimumu,
3. Her bir alt banttaki katsayıların standart sapması,
4. Her bir alt banttaki katsayıların ortalamasıdır.

Bu çalışmada verilerin özniteliklerinin çıkarılabilmesi için, Matlab R2007a'da, hem A veri seti (sağlıklı), E veri seti (epileptik aktivite durumu) için iki ayrı 100*4096 boyutunda iki ayrı vektör (matris) oluşturulmuştur. Bu vektörlerden, 100*4096 boyutundaki A ve E veri setinin her bir sütunu için, altta verilen 8 ayrı öznitelik parametresi EK-1'de verilen Matlab kodundan elde edilmiştir. Bu kod sonucunda elde edilen öznitelik parametreleri:

1. Ortalama,
2. Karesel ortalama,
3. Maksimum değer,
4. Minimum değer,
5. Standart sapma,
6. Varyans,

7. Medyan,
8. Sıfırdan geçiş sayısıdır.

6.3. Verilerin Analizi

Çalışmada kullanılan veri setlerinin yukarıda sayılan sekiz ayrı öznitelik parametresi çıkarıldıktan sonra, veri madenciliği süreci ile analizlerine ve farklı algoritmalar ile yapılmış analizlerin karşılaştırılması yapılmıştır.

Verilerin analizinde WEKA (Waikato Environment for Knowledge Analysis) veri madenciliği platformu kullanılmıştır. WEKA platformu Java tabanlı bir makine öğrenmesi paketi olup, Yeni Zelanda Waikato Üniversitesi'nde geliştirilmiştir. WEKA platformu'nun en önemli özelliklerinden birisi açık kaynak kodlu olmasıdır. Bunun yanında, WEKA'nın bugüne kadar geliştirilmiş tüm sürümleri ve yardımcı araçlar WEKA'nın sitesinden ücretsiz olarak edinilebilmektedir [111]. WEKA ticari olarak geliştirilen diğer birçok platformdan daha fazla öğrenme algoritmasını bünyesinde barındırmaktadır. WEKA platformunun çalışmamızdaki analizlerde kullanılmak üzere seçilme nedenlerinden biri de bilgi işlem maliyetinin yanında bu platformun diğer ticari yapay zekâ platformlarına göre gelişim açısından daha dinamik bir yapı sergilemesi de önemli bir etken olmuştur. WEKA'nın en güçlü özelliklerinden biri de birçok sınıflandırma tekniğini içermesidir. Diğer bir özelliği de uygulamaların komut girilerek gerçekleştirilmesine imkân tanmasıdır.

WEKA'da; ön işleme (preprocess), sınıflama (classify), kümeleme (cluster), birliktelik kuralları (associate), nitelik seçme (select attribute) ve görselleştirme (visualize) panelleri bulunmaktadır. Ön işleme paneli; bilgi keşfinin başlangıç noktasıdır. Veri dosyaları bu panelden yüklenir. WEKA'ya Excel ve Access ortamından ve Internet ortamından dosya yüklemek mümkündür. Sınıflandırma paneli; veri kümesi üzerinde WEKA'nın sınıflandırma algoritmalarının çalıştırıldığı paneldir. Sınıflandırma paneli, karar ağaçlarından kurallara; fonksiyonlardan Bayes ağlarına birçok sınıflandırma algoritmasını içermektedir [29].

Çalışmada; Matlab’da yapılan ön işlem sonucu elde edilen öznitelik parametreleri aşağıda belirtilen veri madenciliği süreçlerine tabi tutulmuştur.

1. Doğrusal Regresyon Modeli (Linear Regression Model)
2. Çok Katmanlı Geri Yayılma Algoritması (MultiLayer Perceptron)
3. Sıralı Regresyon Modeli (Pace Regression Model)
4. Radyal Tabanlı Fonksiyon Ağı (Radial Basis Function Network, Linear Reg. Applied to k-Means Clusters as Basis Functions)
5. SMO Regresyon (SMOreg)
6. KStar Algoritması (K-Star Beta)
7. Eklemeli Regresyon (Additive Regression, ZeroR Model)
8. Karar Ağacı (Decision Stump)
9. M5 Doğrusal Karar Ağacı (M5 Pruned Model Tree, Using Smoothed Linear Models)
10. Karar Tablosu (Decision Table: M5 Pruned Model Rules, Using Smoothed Linear Models)
11. İndirgenmiş Hata Karar Modeli (REPTree)

Veri madenciliği süreçleri sonucunda analizde kullanılan algoritmalar ve elde edilen sonuçlar aşağıda verilmiştir. Elde edilen öznitelik değerlerine ait sonuçlar EK-2’de verilmiştir. Analiz sırasında kullanılacak her bir model için öznitelik parametreleri sistem tarafından otomatik olarak seçilmektedir. WEKA platformunda işlenen verilere ait sonuçlar EK-3’de verilmiştir.

BÖLÜM 7. SONUÇ VE ÖNERİLER

Çalışmada kullanılan veriler; beyin sinyalleri konusunda dünyadaki sayılı bilimsel çalışma merkezlerinden biri olan Bonn Üniversitesi Epileptoloji Bölümü (Freiburg Veri Analizi ve Modelleme Merkezi) veritabanından alınmıştır. Bu veritabanının oluşturulması ve verilerin paylaşılması ile birlikte, 1992 yılından bu yana, pek çok bilimsel dergi de aynı veritabanını kullanarak yayınların yapıldığı görülmektedir. Bu yayınların pek çoğunda epileptiform aktivite ve epilepsi hastalığı analizi için çeşitli modeller geliştirilmiştir. Özellikle 2005 yılından bu yana yapılan çalışmalarda güncel yöntemler (yapay zekâ içeren algoritmalar) kullanılarak yapılan çalışmalarda %90'ın üzerinde doğruluk oranı elde edildiği görülmektedir. Bunlardan; Subaşı (2005), Güler vd. (2005), Batar (2005), Güler ve Übeyli (2005), Srinivasan vd. (2005), Alkan (2005), Subaşı (2007), Toprak (2007) çalışmalarında yapay sinir ağı temelli modelleri kullanarak %90 ve üzerinde doğruluk oranlarına ulaşmışlardır. Yapay sinir ağı kullanılan bu çalışmalar incelendiğinde farklı öznitelik parametrelerinin de kullanıldığı göze çarpmaktadır. Çalışmalar incelendiğinde veri madenciliği süreçlerinin kullanılmamış oluşu, tıbbi veriler üzerinde veri madenciliği algoritmaları kullanımının diğer yöntemlere göre yüksek doğruluk oranı ile sonuçlar ortaya koyması bu çalışmanın önemini arttırmıştır.

Çalışmada elektroensefolagram verileri üzerinde, epileptik aktivitenin, veri madenciliği süreçleri kapsamında, sınıflama ve kümeleme algoritmaları kullanarak belirlenmesi, bu algoritmalarından elde edilen sonuçlarının karşılaştırılması yapılarak en yüksek doğruluk oranını sağlayan algoritmaların tespiti yapılmıştır. Veri madenciliği sürecinde kullanılmak üzere 8 ayrı öznitelik parametresi elde edilmiş ve öznitelik parametreleri kullanılarak 11 ayrı veri madenciliği algoritması ile veriler işlenmiştir. Veri madenciliği sürecinde elde edilen sonuçlara bakıldığında bazı algoritmaların %100 doğruluk oranı ile sonuçlar verdiği görülmektedir. Bunun yanı sıra seçilen bazı algoritmaların düşük doğruluk oranı ile sonuç verdiği ortaya

çıkıştır. Doğruluk oranı düşük çıkan sonuçlar, kullanılacak verinin türüne göre uygun algoritma seçiminin önemini de ortaya koymuştur.

En yüksek doğruluk oranını verdiği tespit edilen algoritmalar yardımı ile bu alanda çalışan uzmanların epileptik aktivite teşhisi koymalarına bir zemin oluşturmak, ilgililerin teşhis sürecinde karar vermelerini kolaylaştırmak ve konulan teşhislerde doğruluk oranını yükselterek, Türkiye’de nöroloji ve bilgisayar bilimleri literatürüne katkı sağlanması çalışmanın bir diğer sonucu olarak görülebilir.

Elde edilen doğruluk oranlarının; Güler vd. (2005), Subaşı (2007), Toprak (2007), Srinivasan (2005) çalışmalarında belirtilen YSA ile yapılmış ÇKA sınıflandırma performansı değerlerinden daha yüksek olduğu görülmüştür.

Tablo 7.1. Kullanılan veri madenciliği algoritmaları ve sonuçları

No	Model	Korelasyon Katsayısı	Ortalama Bağlı Hata	Ortalama Karesel Hata	Bağlı Mutlak Hata (%)	Bağlı Karesel Hata (%)	Modelin Oluşturulma Süresi
1	Linear Regression Model	0,834	0,217	0,277	43,449	55,286	0,050
2	MultiLayer Perceptron	0,999	0,011	0,020	2,243	4,059	0,470
3	Pace Regression Model	0,952	0,128	0,159	25,572	31,828	0,050
4	Radial basis function network	0,700	0,269	0,358	53,728	71,485	0,110
5	SMOreg	0,930	0,120	0,192	23,927	38,310	0,170
6	KStar Beta	1,000	0,000	0,000	0,000	0,000	0,000
7	Additive Regression	1,000	0,000	0,000	0,000	0,000	0,020
8	Decision Table	1,000	0,000	0,000	0,000	0,000	0,030
9	M5 pruned model tree 1	0,998	0,038	0,045	7,628	8,985	0,030
10	M5 pruned model tree 2	1,000	0,015	0,022	2,986	4,376	0,050
11	REPTree	1,000	0,000	0,000	0,000	0,000	0,000

Veri madenciliği süreçleri ile yapılan bu çalışmada elde edilen doğruluk oranlarının diğer yöntemlere göre daha yüksek olduğu görülmektedir. Veri madenciliği tekniklerinin içerdiği çok sayıda sınıflama ve kümeleme algoritmalarıyla elde edilen sonuçların mukayese edilerek uygun modellerin seçilmesi ve Türkiye’de tıbbi veriler ile yapılan veri madenciliği çalışmalarının sınırlı olması gibi faktörler göz önünde

bulundurulduğunda, çalışmada epileptik aktivite tespitinde veri madenciliği süreçlerinin kullanılması önem taşımaktadır.

Veritabanında yer alan veri setlerine farklı veri madenciliği algoritmaları uygulandığında bazı algoritmalarından elde edilen sonuçların %100 doğruluk oranı verdiği Tablo 7.1.'de görülmektedir. Ayrıca modellerin hesaplama sürelerinin de farklılığı göze çarpmaktadır. KStar, Additive Regression, Decision Table, REPTree algoritmalarının %100 doğruluk oranı ile sonuç verdiği görülmektedir. Ayrıca bu algoritmalar içinden KStar ve REPTree algoritmalarının çok kısa sürede sonuç verdiği görülmektedir. Bu sonuçlar değerlendirildiğinde karesel ortalama kullanan algoritmalarda %100 doğruluk oranı ile sonuçlara ulaşıldığı dikkat çekmektedir.

Bu çalışmanın ayrıca önemli bir katkısı nörologlar için; EEG sinyallerinin istenen özelliklerinin kullanılarak yüksek doğruluk oranı ile kısa zamanda analiz edilmesi ve epileptik aktivite teşhisinin otomatik olarak yapabileceği bir yöntem için yardımcı bir bilgi tabanı oluşturmasıdır. İleriye dönük çalışma geliştirilerek bağımsız bir programlama dili ile ara yüz oluşturulabilir. Geliştirilecek kullanıcı ara yüzü ve model nörologların veya bu konu ile ilgili çalışan diğer araştırmacıların yararlanabilecekleri bilgi tabanı oluşturarak kullanımlarına sunulabilir.

KAYNAKLAR

- [1] KALAYCI, T., EEG Dikenlerinin Yapay Sinir Ağları İle Tanınması, Doktora Tezi, Ege Ün., Sağlık Bil. Ens., 1996.
- [2] MOHAMMAD, N., ACHMAD, J., MOHAMAD, A.M., Automatic Detection of Epileptic Spikes Based On Wavelet Neural Network, IEEE APCCAS Asia-Pacific Conference on Circuits and Systems, Vol. 2, pp. 483–486, 2002.
- [3] FISCH, B.J., Spehlmann'ın EEG El Kitabı, Elsevier Science, Türkçe 6. Baskı, Turgut Yayıncılık, İstanbul, 1998.
- [4] BATAR, H., EEG İşaretlerinin Dalgacık Analiz Yöntemleri Kullanılarak Yapay Sinir Ağları İle Sınıflandırılması, Yüksek Lisans Tezi, Sütçü İmam Ün., Fen Bil. Ens., Kahramanmaraş, 2005.
- [5] GÜLER, I., KIYMIK, M.K., AKIN, M., ALKAN, A., AR Spectral Analysis of EEG Signals By Using Maximum Likelihood Estimation, Comp. in Biology and Medicine, Vol. 31, pp. 441-450, 2001.
- [6] ADELI, H.Z., DADMEHR, Z.N., Analysis of EEG Records in An Epileptic Patient Using Wavelet Transform, Journal of Neuroscience Methods, Vol. 123, pp. 69-87, 2003.
- [7] WAN, B., DHAKAL, B., QI, H., ZHU, X., Multi-method Synthesizing to Detect and Classify Epileptic Waves in EEG, IEEE Proceedings of the Fourth International Conference on Computer and Information Technology, 2004.
- [8] ROPPER, A.H., BROWN, R.H., Adams and Victor's Principles of Neurology, (Türkçe Baskı: Güneş Kitabevi), İstanbul, 2006,
- [9] Epilepsi (Sara) Hastalığı, Nationaal Epilepsie Fonds, Erişim Tarihi: 25.06.2006.
<http://www.epilepsie.nl/attachments/epilepsieinhetkortturks.pdf>
- [10] ALKAN, A., EEG İşaretlerinin Klasik ve Modern Yöntemlerle Önişlenmesi ve Sınıflandırılması, Doktora Tezi, Sakarya Ün., Fen Bil. Ens., Sakarya, 2005.
- [11] IBM Haber Bülteni, Erişim Tarihi: 25.06.2006.
<http://www.ibm.com/news/tr/tr/2006/05/who.html>
- [12] YAZGAN, E., KORUREK, M., Tıp Elektroniği. İTÜ, Yayın No:15741, İstanbul, 1996.

- [13] GÜLER, I., ÜBEYLİ, E.D., Dalgacık Dönüşümünün Kullanımı ile Teşhis Sistemleri için Öznitelik Çıkarma: İç Karotid Atardamar Doppler İşaretlerinin Durum analizi, Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu, ASYU-INISTA, 2004.
- [14] GÜLER, I., ÜBEYLİ, E.D., Çok Katmanlı Perseptron Sinir Ağları ile Diyabet Hastalığının Teşhisi, Gazi Ün. Mühendislik Mimarlık Fak. Dergisi, 21(2), 319–326, 2006.
- [15] POLIKAR, R., The Engineer's Ultimate Guide To Wavelet Analysis The Wavelet Tutorial, Erişim Tarihi: 25.06.2007.
<http://engineering.rowan.edu/~polikar/wavelets/wtpart3.html>
- [16] ROBERT, R.A., MULL, S.C.T., Digital Signal Processing. Addison-Wesley Publishing Company, USA, 1987.
- [17] JAWERT, B., SWELDENS, W., An Overview Of Wavelet Based Multiresolution Analysis, Erişim Tarihi: 25.06.2007.
<http://cm.bell-labs.com/who/wim/papers/overview.pdf>
- [18] GRAP, A., An Introduction To Wavelets, IEEE Computational Science And Engineering, Vol. 2(2), 1995.
- [19] PAPOULIS, A., Signal Analysis, Mcgraw-Hill International Editions, New York, 1984.
- [20] ARSERİM, M.A., Beyin Sinyallerinin Modern Spektral Analiz Yöntemleri ile Kestirimi, Yüksek Lisans Tezi, Dicle Ün., Fen Bil. Ens., Diyarbakır, 2001.
- [21] MINER, N.E., An Introduction to Wavelet Theory and Analysis, Sandia Report, NM, October:1-25, 1998.
- [22] KEETON, P.I.J., SCHLINDWEIN, F.S., Spectral Broadening of Clinical Doppler Signals Using FFT and Autoregressive Modelling, European Journal of Ultrasound (ISSN: 0929-8266), Vol. 7, No. 3, pp.209-218, August, 1998.
- [23] SWELDENS, W., Wavelet Sampling Technics, Erişim Tarihi: 25.08.2006.
<http://w3.nai.net/~alokaeng/wavelet/sampling.pdf>
- [24] FLIEGE, N.J., Multirate Digital Signal Processing (Multirate Systems-Filter Banks-Wavelets), John Wiley & Sons, Chichester, 1996.
- [25] FOMITCHEV, M., An Introduction To Wavelets And Wavelets Transforms, Systems And Programming Inc., Tulsa, 1994.
- [26] ÇAKIR, M., Firma Başarısızlığının Dinamiklerinin Belirlenmesinde Makina Öğrenmesi Teknikleri: Ampirik Uygulamalar ve Karşılaştırmalı Analiz, Uzmanlık Yeterlilik Tezi, Türkiye Cumhuriyet Merkez Bankası, İstatistik Genel Müdürlüğü, Ankara, 2005.

- [27] ALPAYDIN, E., Zeki Veri Madenciliği: Ham Veriden Altın Bilgiye Ulaşma Yöntemleri, Erişim Tarihi: 11.05.2007.
www.cmpe.boun.edu.tr/~ethem/files/papers/verimaden_2k- notlar.doc
- [28] AYDOĞAN, F., e-Ticarette Veri Madenciliği Yaklaşımlarıyla Müşteriye Hizmet Sunan Akıllı Modüllerin Tasarımı ve Gerçekleştirimi, Yüksek Lisans Tezi, Hacettepe Ün., Fen Bil. Ens., Ankara, 2003.
- [29] KAYAALP, K., Asenkron Motorlarda Veri Madenciliği İle Hata Tespiti, Yüksek Lisans Tezi, Süleyman Demirel Ün., Fen Bil. Ens., Isparta, 2007.
- [30] FRAWLEY, W.J., PIATETSKY-SHAPIRO, G., MATHEUS, C.J., Knowledge Discovery Databases: An Overview, in Knowledge Discovery in Databases, Cambridge, MA: AAAI/MIT, 1-27, 1991.
- [31] AKBULUT, S., Veri Madenciliği Teknikleri ile Bir Kozmetik Markanın Ayrılan Müşteri Analizi ve Müşteri Segmentasyonu, Yüksek Lisans Tezi, Gazi Ün., Fen Bil. Ens., Ankara, 2006.
- [32] JACOBS, P., Data Mining: What General Managers Need To Know, Harvard Management Update, 4 (10): 8, 1999.
- [33] DAVIS, B., Data Mining Transformed, Information Week, 751: 86, 1999.
- [34] DUMOUCHEL, W., Bayesian Data Mining in Large Frequency Tables, With An Application To The FDA Spontaneous, American Statistician, 53 (3): 177, 1999.
- [35] HAND, D.J., Data Mining: Statistics and More?, The American Statistician, 52:112-118, 1998.
- [36] KITLER, R., WANG, W., The Emerging Role of Data Mining, Solid State Technology, 42 (11): 45, 1998.
- [37] BRANSTEN, L., Technology – Power Tools – Looking For Patterns: Data Mining Enables Companies To Better Manage The Ream of Statistics They Collect; The Goal: Spot The Unexpected, Wall Street Journal, 27 (12): 16- 20, 1999.
- [38] BAYKAL., N., Tıp Bilişimi Güz Okulu, Erişim Tarihi: 11.06.2006.
www.metutech.metu.edu.tr/download/File/TR/3-SUNU-Nazife_Baykal.pdf
- [39] BAYRAM, E., Customer Segmentation and Churn Modeling in Wireless Communication, Yüksek Lisans Tezi, Boğaziçi Ün. Fen Bil. Ens., İstanbul, 2001.
- [40] RESTIVO, K., The Drill on Data Mining, Computer Dealer News, 15 (14): 29-30, 1999.
- [41] AKPINAR, H., Veri Tabanlarında Bilgi Keşfi ve Veri Madenciliği, Erişim Tarihi: 20.04.2007.
http://www.isletme.istanbul.edu.tr/surekli_yayinlar/dergiler/nisan2000/1.htm

- [42] Internet: Current Data Mining Applications / Percentage in Different Industries, Erişim Tarihi: 16.05.2007.
http://www.kdnuggets.com/polls/2003/data_mining_applications_industries.html
- [43] OGDURUCU, S. G., Veri Madenciliği, Erişim Tarihi: 16.05.2007.
www.cs.itu.edu.tr/~gunduz/courses/verimaden/
- [44] WEISS, S.M., INDURKHAYA, N., Predictive Data Mining, Morgan Kaufman Publishers, Inc., San Fransisco, CA., 1998.
- [45] FRANK, E., WITTEN, I.H., Generating Accurate Rule Sets Without Global Optimization, Proceedings Fifteenth International Conference on Machine Learning, Madison, WISF: Morgan Kaufmann, 1998.
- [46] İKİZLER, N., Benefit Maximizing Classification Using Feature Intervals, BU-CE-0208, Bilkent Un. Technical Report, 2002.
- [47] WITTEN, I.H., FRANK, E., Data Mining, Practical Machine Learning Tools and Techniques with Java Implementations, Morgan Kaufman Publishers, Inc., San Fransisco, CA., 2000.
- [48] GIUDICI, P., Applied Data Mining: Statistical Methods for Business and Industry, John Wiley & Sons Inc., Chichester, 85-100, 2003.
- [49] HUDAIRY, H., Data Mining and Decision Making Support in The Governmental Sector, Master Thesis, Faculty of Graduate School of The University of Louisville, Kentucky, 2004.
- [50] WEI, C., CHIU, T., Turning Telecommunications Call Details to Churn Prediction: A Data Mining Approach,”, Expert Systems with Applications, 23: 103-102, 2002.
- [51] Karar Ağaçları Algoritmaları, Erişim Tarihi: 16.05.2007.
http://eric.univ-lyon2.fr/~ricco/sipina_learning_algorithms.html
- [52] CATLETT, J., Megainduction : Machine Learning on Very Large Databases, PhD Thesis, School of Computer Science, University of Technology, Sydney, Australia, 1991.
- [53] QUINLAN, J., Induction of Decision Trees in Machine Learning, Erişim Tarihi: 16.10.2007.
<http://www.springerlink.com/content/ku63wm5513224245/>
- [54] CHENG, J.U., FAYYAD, K., QIAN, I.Z., Improved Decision Trees: A Generalized Version of ID3, Proc. of 5th International Conference on Machine Learning, pp.100-108, 1988.
- [55] CESTNIK, B., KONONENKO, I., BRATKO, I., ASSISTANT 86: A Knowledge Elicitation Tool for Sophistical Users, Proc. of the 2nd European Working Session on Learning, pp.31-45, 1987.

- [56] KASS, G., An Exploratory Technique for Investigating Large Quantities of Categorical Data, *Applied Statistics*, 29(2), pp. 119-127, 1980.
- [57] RAKOTOMALALA, R., Arbres de décision, in *Revue Modulad*, no:33, 2005.
- [58] QUINLAN, R., *C4.5: Programs for Machine Learning*, Morgan Kaufman Publishers, 1993.
- [59] KOHAVI, R., QUINLAN, R., Decision Tree Discovery, *Handbook of Data Mining and Knowledge Discovery*, Klossgen & Zytkow Editors, Chapter 16.1.3, pp.267-276, Oxford University Press, 2002.
- [60] RAKOTOMALALA, R., LALLICH, S., Handling Noise with Generalized Entropy of Type Beta in Induction Graphs Algorithm, *Proc. Int. Conf. on Computer Science and Informatics*, pp. 25-27, 1998.
- [61] RAKOTOMALALA, R., LALLICH, S., DI PALMA, S., Studying The Behavior of Generalized Entropy in Induction Trees Using A M-of-N Concept, *Proc. of 3rd European Conf. on KDD*, pp. 510-517, 1999.
- [62] TANEJA, I., Generalized Information Measures and Their Applications; Chapter 3, Entropy-type Measures - Entropy of Degree s and Degrass (r,s), *Departemento de Matematica, UFSC, Brazil*, 2001.
- [63] CHAUCHAT, J.H., RAKOTOMALALA, R., CARLOZ, M., PELLETIER, C., Targeting Customer Groups Using Gain and Cost Matrix : A Marketing Application, *Proc. of Data Mining for Marketing Applications Workshop, PKDD'2001*, pp. 1-13, 2001.
- [64] BRADFORD, J., KUNZ, C., KOHAVI, R, BRUNK, C., BRODLEY, C., Pruning Decision Trees with Misclassification Costs, *Proc. of 10th ECML*, pp. 131-136, 1998.
- [65] DRUMMOND, C., HOLTE, R., Exploiting The Cost of (in)Sensitivity of Decision Tree Splitting Criteria, *Proc. of ICML*, pp.239-246, 2000.
- [66] ÖZTEMEL, E., *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul, 2003.
- [67] ELMAS, Ç., *Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)*, Seçkin Yayıncılık, Ankara, 2003.
- [68] ÇUHADAR, M., *Turizm Sektöründe Talep Tahmini İçin Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi (Antalya İlinin Dış Turizm Talebinde Uygulama)*, Doktora Tezi, Süleyman Demirel Ün., Sosyal Bil. Ens., Isparta, 2006.
- [69] PAWLAK Z., Rough Sets, Decision Algorithms And Bayes Theorem, *European Journal of Operation Research*, 136: 181-189, 2002.

- [70] GOLDBERG, D.E., Genetic Algorithms in Search Optimization and Machine Learning, Addison Wesley Publishing Company, USA, 1989.
- [71] CROCE, F.D., TADEI, R., VOLTA, G., A Genetic Algorithm for The Job Shop Problem, Computers and Operations Research, Vol.22, No.1, 1995.
- [72] ENGİN, O., FIĞLALI, A., Akış Tipi Çizelgeleme Problemlerinin Genetik Algoritma Yardımı ile Çözümünde Uygun Çaprazlama Operatörünün Belirlenmesi, Doğuş Ün. Dergisi, Sayı 6, 27-35, 2002.
- [73] SHAH, S., KURSAK, A., Data Mining and Genetic Algorithms Based Gene / SNP Selection, Artificial Intelligence in Medicine, 31: 183 -196, 2004.
- [73] Veri Madenciliği Nedir? Erişim Tarihi: 16.05.2007.
<http://yunus.hacettepe.edu.tr/~hcingi/ist376a/6Bolum.doc>
- [74] ORHUNBİLGE, N., Uygulamalı Regresyon ve Korelasyon Analizi, İstanbul Ün. İşletme Fak. Yayını, No: 281, İstanbul, 2002.
- [75] KALAYCI, Ş., SPSS Uygulamalı Çok Değişkenli İstatistik Teknikleri, Asil Yayın Dağıtım A.Ş., Ankara, 2003.
- [76] ÖZEKES, S., Veri Madenciliği Modelleri ve Uygulama Alanları, Erişim Tarihi: 16.05.2007.
<http://www.iticu.edu.tr/kutuphane/dergi/d3/M00041.pdf>
- [77] RAMKUMAR, G.D., SWAMI, A., Clustering Data Without Distance Functions, IEEE Bulletin of The Technical Committee on Data Engineering, Vol.21, No.1, 9-14, March 1998.
- [78] SEIDMAN, C., Data Mining with Microsoft SQL Server 2000, Microsoft Press, 1 st Ed.; Washington, USA, 2001.
- [79] HAN, J., KAMBER, M., , Data Mining Concepts and Techniques, Morgan Kaufmann Publishers, 1st Ed., San Francisco, USA, 2000.
- [80] FAYYAD, U., Mining Databases: Towards Algorithms for Knowledge Discovery, IEEE Bulletin of the Technical Committee on Data Engineering, Vol.21 No.1, 41-48, March 1998.
- [81] HAN, J., Cluster Analysis, Erişim Tarihi: 26.08.2007.
<http://www-sal.es.uiuc.edu/~hanj/bk/8clst.ppt>
- [82] HAN, J., FU, Y., Mining Multiple-Level Association Rules in Large Databases, IEEE Transactions on Knowledge and Data Engineering, Vol. 11, no.5, 1999.
- [83] ZAKI, M.J., Parallel and Distributed Association Mining: A Survey, IEEE Concurrency, Special Issue on Parallel Mechanisms for Data Mining, Vol. 7, No. 5, 14-25, December 1999.

- [84] KAYA, E., BULUN, M., ARSLAN, A., Tıpta Veri Ambarları Oluşturma ve Veri Madenciliği Uygulamaları, Akademik Bilişim, Erişim Tarihi: 16.05.2007.
<http://ab.org.tr/ab03/abstracts/96.html>
- [85] KUSIAK, A., KERNSTINE, K.H., KERN, J.A., MCLAUGHLIN, K.A., TSENG, T.L., Data Mining: Medical and Engineering Case Studies, Erişim Tarihi: 16.05.2007.
<http://www.icaen.uiowa.edu/~ankusiak/Res-in-Prog/IIE-0.pdf>
- [86] CHAE, Y.M., HO, S.H., CHO, K.W., LEE, D. H., JI, S.H., Data Minig Approach to Policy Analysis in A Healt Insurance Domain, International Journal of Medical Informatics, 62(2-3):103-11, July 2001.
- [87] ÖNAL, B., EEG İşaretlerindeki Epileptik Sürecin Dalgacık Dönüşüm Yöntemi ile Belirlenmesi, Yüksek Lisans Tezi, KSÜ Fen Bil. Ens., Kahramanmaraş, 1998.
- [88] TOPRAK, B., EEG Sinyallerinin Dalgacık Dönüşümü ve Yapay Sinir Ağları İle Analizi, Yüksek Lisans Tezi, Süleyman Demirel Ün., Fen Bil. Ens., Isparta, 2007.
- [89] SWELDENS, W., Wavelet Sampling Technics, Erişim Tarihi: 16.05.2007.
<http://w3.nai.net/~alokaeng/wavelet/sampling.pdf>
- [90] ANDERSON, C.W., DEVULAPALL, S.V., STOLZ, E.A., Determining Mental State From EEG Signals Using Neural Networks, Scientific Programming, 4: 171–183, 1995.
- [91] KALAYCI, T., ÖZDAMAR, O., Wavelet Preprocessing For Automated Neural Network Detection of EEG Spikes, IEEE Engineering in Medicine and Biology Magazine, Vol.16, 1995.
- [92] PRADHAN, N., SADASIVAN, P.K., ARUNODAYA, G.R., Detection of Seizure Activity in EEG by An Artificial Neural Network: A Preliminary Study, Computers and Biomedical Research, Vol.29: 303-313, 1996.
- [93] GOTMAN, J., WU, L., Segmentation and Classification of EEG During Epileptic Seizures, Electroencephalography and Clinical Neurophysiology, Vol.106, 344–356, 1998.
- [94] TORRENCE, C., COMPO, P.C., A Practical Guide To Wavelet Analysis, Bulletin of American Meteorological Society, Vol.79(1):61-78, 1998.
- [95] GÜNEŞ, M., EEG İşaretlerinin Dalgacık Analizi ve Diğer Yöntemlerle Karşılaştırılması, Yüksek Lisans Tezi, KSÜ Fen Bil. Ens., Kahramanmaraş, 1999.
- [96] ANDRZEJAK, R.G., LEHNRET, K., MORMANN, F., RIEKE, C., DAVID, P., ELGER, C.E., Indications of Nonlinear Deterministic and Finite-Dimensional Structures in Time Series of Brain Electrical Activity: Dependence on Recording Region and Brain State, Physical Review E, Vol.64:061907, 2001.

- [97] AKIN, M., ARSERİM, M.A., KIYMIK, M.K., TÜRKÖĞLU, I., A New Approach for Diagnosis Epilepsy by Using Wavelet Transform and Neural Networks, Proc. of the 23rd Annual EMBS International Conference, 1596–1599, 2001.
- [98] HAZARIKA, N., CHEN, J.Z., TSOI, A.C., SERGEJEW, A., Classification of EEG Signals Using The Wavelet Transform, IEEE Proc. of 13th International Conference on Digital Signal Processing, 89–92, 1997.
- [99] SZILAGYI, L., BENYO, Z., SZILAGYI, S.M., A New Method for Epileptic Waveform Recognition using Wavelet Decomposition and Artificial Neural Networks. Proc. of the Second Joint EMBS/BMES Conference, 3, 2025–2026, 2002.
- [100] ZARJAM, P., MESBAH, M., BOASHASH, B., Detection of Newborn EEG Seizure using Optimal Features Based on Discrete Wavelet Transform, IEEE, 265–268, 2003.
- [101] LATKA, M., WAS, Z., KOZIK, A., WEST, B.J., Wavelet Analysis of Epileptic Spikes, Physical Review E. 67, 052902, 2003.
- [102] SUBAŞI, A., Automatic Recognition of Alertness Level from EEG by using Neural Network and Wavelet Coefficients, Expert System with Applications, Vol.28, pp.701–711, 2005.
- [103] GÜLER, İ., ÜBEYLİ, E.D., GÜLER, E., A Mixture of Experts Network Structure for EEG Signals Classification, Proc. of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference, pp.2707–2710, 2005.
- [104] GÜLER, İ., ÜBEYLİ, E.D., Adaptive Neuro Fuzzy Inference Sysytem for Classification of EEG Signals using Wavelet Coefficients, Journal of Neuroscience Methods, Vol. 148, 113–121, 2005.
- [105] SRINIVASAN, V., ESWARAN, C., SRIRAAM, N., Artificial Neural Network Based Epileptic Detection using Time-Domain and Frequency-Domain Features, Journal of Medical Systems, Vol. 29, No. 6, 2005.
- [106] SUBAŞI, A., EEG Signal Classification using Wavelet Feature Extraction and a Mixture of Expert Model. Expert Systems with Applications, 32, 1084–1093, 2007.
- [107] TOPRAK, B., ÇAĞLAR, M.F., MERDAN, M., Dalgacık Dönüşümü ve Bulanık Mantık Sistemine Dayalı Uyarlanıır Ağ ile Epilepsi Hastalığı Teşhisi, SDÜ 15. Yıl Mühendislik Mimarlık Sempozyumu, sf. 9-17, Isparta, 14-16 Kasım 2007.
- [108] GÜLER, İ., ÜBEYLİ, E.D., Dalgacık Dönüşümünün Kullanımı ile Teşhis Sistemleri için Öznitelik Çıkarma: İç Karotid Atardamar Doppler İşaretlerinin Durum Analizi, Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu, ASYU-INISTA, 2004.
- [109] QU, H., GOTMAN, J., A Patient-Specific Algorithm for the Dedection of Seizure Onset in Long-term EEG Monitoring: Possible Use a Warning Device. IEEE Trans., Biomed. Eng., Vol.44(2), p:115-122, 1997.

[110] NIGAM, V.P., GRAUPE, D., A Neural-Network-Based Detection of Epilepsy, Neurol. Res., Vol.26, p:55-60, 2004.

[111] WEKA Web Sitesi, Erişim Tarihi: 20.05.2008.
www.cs.waikato.ac.nz/~ml/weka/

EKLER

EK-1: Öznitelik Parametrelerinin Çıkarılması İçin Kullanılan Program Kodları

```
for i=1:100
    %Sütun Ortalaması
    %sütünortalamasi(i,1)=mean(deger(:,i));
    s(i,1)=mean(deger(:,i));

    % Karesel Ortalama
    toplamkareler=0;
    for k=1:4096
        toplamkareler=toplamkareler+((deger(k,i))^2);
    end
    %ortakare(i,2)=sqrt(toplamkareler/1024);
    s(i,2)=sqrt(toplamkareler/1024); % karesel ortalama

    %max ve min
    %maks(i,3)=max(deger(:,i));
    %mnmum(i,4)=min(deger(:,i));
    s(i,3)=max(deger(:,i));
    s(i,4)=min(deger(:,i));

    % standart sapma
    %standartsapma(i,5)=std(deger(:,i));
    s(i,5)=std(deger(:,i));

    % varyansı
    % varyans(i,6)=var(deger(:,i));
    s(i,6)=var(deger(:,i));

    %medyan
    %medyan(i)=median(deger(:,i));
    s(i,7)=median(deger(:,i));
end

sifirgecis=zeros(100,1); % 1 x 100 lük sıfır geçiş
for i=1:100
    if(deger(1,i)<0)
        ekside=true;% eksi bölge
```

```
else
    ekside=false;
end

for k=1:1024
    if (ekside==true) % sayılar bölgesi
        if(deger(k,i)>0) % artı sayılara geçiş testi
            sifirgecis(i,1)=sifirgecis(i,1)+1; % eksi sayıdan artı sayıya 1 arttır
            ekside=false; % artık artı bölgesini tarama.
        end
    else
        if(deger(k,i)<0)
            sifirgecis(i,1)=sifirgecis(i,1)+1;
            ekside=true;
        end
    end
end
end
end
```

EK-2: Ön İşleme Tutulan Verilerden Elde Edilen Öznitelik Parametreleri

ortalama	karesel ort	max	min	std	varyans	medyan	sifirgecis	durum
67.993	862.425	185	-190	42.587	18.136.525	7	106	1
-524.375	1.432.862	169	-254	488.224	23.836.269	-51	58	1
126.882	976.318	184	-146	471.439	22.225.438	13	103	1
-40.015	944.885	162	-181	470.803	22.165.509	-4	168	1
-179.995	967.775	152	-188	449.219	2.017.979	-18	94	1
-278.315	1.058.648	123	-180	450.304	20.277.386	-28.5	86	1
-133.289	962.908	147	-177	462.692	21.408.435	-13	124	1
-56.553	656.732	129	-124	323.499	10.465.161	-5	108	1
82.012	650.655	117	-93	314.859	9.913.637	9	80	1
-27.376	1.031.399	122	-190	43.709	19.104.803	-29	84	1
-136.086	81.513	136	-163	384.221	14.762.593	-13.5	88	1
-144.167	842.755	115	-162	395.996	15.681.284	-14	76	1
74.194	668.794	123	-95	326.102	10.634.235	8	90	1
61.133	857.338	155	-156	424.339	18.006.387	5	85	1
-53.245	559.561	87	-117	274.701	7.546.061	-4	136	1
49.917	947.471	183	-185	471.156	22.198.773	5	113	1
8.658	621.334	117	-93	298.395	890.398	9	96	1
126.235	1.103.134	204	-187	536.993	28.836.131	11	120	1
7.657	642.877	109	-99	312.223	9.748.349	8	84	1
-20.715	532.266	93	-89	265.358	7.041.495	-2	145	1
-59.023	593.367	109	-115	290.788	8.455.792	-6	94	1
-53.584	597.724	99	-110	294.055	8.646.837	-6	91	1
50.439	1.009.003	158	-223	502.035	25.203.922	6	157	1
16.812	731.435	117	-147	365.376	13.349.933	1	193	1
55.996	1.025.713	152	-167	509.853	25.994.978	6	112	1
150.056	1.153.926	220	-286	557.176	31.044.515	13	144	1
81.621	794.658	129	-132	388.903	15.124.543	8	159	1
-490.525	1.191.898	67	-168	33.848	11.456.869	-49	30	1
22.913	852.159	168	-202	425.515	1.810.628	1	191	1
567.393	1.545.256	294	-142	524.488	27.508.722	57	120	1
80.256	602.705	129	-92	290.504	8.439.273	8	110	1
-24.839	535.266	91	-91	26.651	7.102.776	-3	141	1
575.459	1.451.472	254	-90	442.253	19.558.753	56	61	1
-280.574	1.027.758	137	-166	430.576	18.539.549	-29	116	1
30.862	1.116.522	205	-180	557.476	31.077.901	1	90	1
53.491	980.779	175	-196	487.523	2.376.788	7	106	1
50.496	91.814	138	-166	45.634	20.824.632	6	126	1
-750.994	1.571.527	3	-152	231.184	5.344.602	-75	4	1
12.642	1.117.999	196	-224	558.925	31.239.663	3	92	1
563.201	1.314.755	177	-85	339.085	11.497.835	56	40	1
34.709	944.941	167	-150	471.251	22.207.791	4	97	1

-753.669	1.581.211	14	-157	238.859	5.705.352	-76	0	1
27.393	631.005	123	-115	314.349	9.881.547	2	149	1
35.596	887.883	156	-169	442.566	19.586.475	4	141	1
2.907	815.637	166	-156	406.831	1.655.111	3	137	1
-187.974	878.327	149	-163	39.695	15.756.918	-19	94	1
-505.129	1.324.011	92	-222	427.949	1.831.404	-50	57	1
4.678	878.489	140	-200	436.799	19.079.375	7	116	1
566.404	1.302.482	178	-55	321.445	10.332.706	56	30	1
38.171	100.074	163	-206	498.973	24.897.397	4	125	1
34.482	798.401	161	-143	397.757	15.821.062	2	140	1
79.983	793.712	184	-132	38.876	15.113.443	8	158	1
55.737	625.412	115	-105	307.736	9.470.153	6	86	1
-182.112	1.121.343	144	-233	530.336	28.125.676	-18	83	1
-141.716	945.675	174	-159	451.156	20.354.164	-13	126	1
49.497	986.858	169	-162	49.1	24.108.092	6	114	1
16.213	99.658	169	-184	498.087	24.809.069	1.5	88	1
10.071	798.062	126	-157	398.953	15.916.315	1	181	1
-62.185	750.287	135	-142	369.999	13.689.899	-6	73	1
-523.918	1.239.599	69	-156	331.191	10.968.752	-53	30	1
-75.509	1.576.425	-3	-154	22.612	5.113.005	-75	0	1
81.619	1.055.389	244	-214	521.408	27.186.632	8	112	1
-14.374	734.048	105	-123	337.747	11.407.333	-15	101	1
-284.744	1.054.072	121	-199	443.549	19.673.595	-28	116	1
85.637	757.071	153	-149	368.766	13.598.841	9	174	1
-3.668	495.427	67	-99	245.013	6.003.132	-3	111	1
-177.871	100.267	132	-189	468.777	21.975.219	-17	113	1
1.832	828.956	146	-168	414.123	17.149.818	3	122	1
51.316	1.001.552	165	-151	49.82	24.820.366	5	98	1
41.921	922.085	170	-150	459.189	21.085.421	6	97	1
-184.685	1.125.264	159	-205	531.522	28.251.521	-18	77	1
64.746	913.192	168	-139	452.037	20.433.752	6	149	1
-522.588	1.161.074	35	-151	252.865	639.406	-53	14	1
87.483	833.346	165	-106	407.435	16.600.365	9	110	1
106.316	89.051	168	-140	432.429	1.869.947	9	101	1
-19.641	701.961	109	-176	350.473	12.283.145	-1	115	1
3.834	1.023.478	165	-230	510.363	26.047.041	4	103	1
81.274	779.895	151	-171	38.143	14.548.917	8	184	1
25.127	759.184	132	-121	378.806	1.434.939	2	113	1
-522.551	1.137.666	17	-124	224.775	5.052.377	-52	4	1
60.488	804.023	142	-131	397.483	15.799.297	6	114	1
85.657	976.652	188	-202	480.813	23.118.155	9	148	1
-512.427	1.187.163	37	-182	299.633	8.977.975	-51	22	1
-24.646	768.948	114	-135	38.373	14.724.896	-2	121	1
39.338	904.936	165	-161	450.809	20.322.918	2	117	1

-513.564	1.305.529	71	-206	40.298	16.239.276	-51	44	1
22.795	757.039	139	-139	377.879	14.279.226	1	130	1
16.995	855.822	154	-139	427.625	18.286.357	2	124	1
-287.817	922.038	102	-161	360.182	12.973.135	-29	75	1
85.557	968.629	178	-208	476.756	2.272.963	8	146	1
-282.371	1.055.479	106	-183	445.897	19.882.454	-28	99	1
-41.228	812.427	141	-146	404.165	16.334.963	-4	111	1
-46.724	882.407	153	-166	438.776	1.925.245	-5	168	1
-20.657	1.041.835	192	-200	520.571	27.099.437	-1	122	1
56.501	911.948	176	-183	452.515	20.476.981	5	129	1
-513.413	1.349.753	147	-288	438.078	19.191.206	-51	60	1
-3.145	826.688	138	-161	412.196	16.990.574	-2	116	1
-185.449	923.178	113	-196	422.749	17.871.643	-18	113	1
-149.141	948.528	142	-183	450.259	20.273.289	-15	141	1
-283.699	1.014.716	138	-164	420.678	17.697.037	-30	105	1
469.988	9.616.039	1027	-1765	4.785.577	2.290.175.197	187	90	0
375.332	10.130.181	1364	-1816	5.051.782	2.552.049.962	116	116	0
302.788	7.501.888	1435	-1283	3.739.159	1.398.131.315	83	119	0
71.406	3.199.507	467	-399	1.598.354	255.473.643	10	87	0
128.206	6.654.556	727	-1026	3.325.213	1.105.704.081	82.5	66	0
-58.489	252.667	352	-451	1.262.134	159.298.299	-16.5	86	0
95.876	4.970.822	1129	-1430	2.483.864	616.958.282	39	59	0
-503.257	816.107	820	-885	4.049.877	1.640.150.285	-85	78	0
-334.116	6.679.123	1219	-800	3.323.211	1.104.373.338	-112	91	0
-176.204	10.953.763	1565	-1885	5.474.715	2.997.250.238	57.5	140	0
-77.859	7.242.201	1793	-895	3.620.705	1.310.950.718	-89.5	94	0
37.144	9.619.005	1381	-912	4.809.947	2.313.558.534	-185	79	0
-215.588	10.814.827	1405	-1523	5.403.774	292.007.724	-114	81	0
-594.258	304.7	351	-696	1.402.993	196.839.051	-38	56	0
-56.106	427.206	591	-590	2.135.554	456.059.033	-22	75	0
-113.843	2.116.961	462	-248	1.052.469	110.769.092	-34	39	0
286.511	11.844.335	1308	-1853	5.915.955	3.499.852.612	124.5	112	0
-56.802	2.958.202	640	-385	1.478.191	218.504.716	5	78	0
62.297	9.061.013	1445	-1227	4.530.631	205.266.196	-100	62	0
-149.333	3.874.333	555	-429	1.931.638	373.122.517	-30	115	0
-43.535	2.479.026	430	-254	1.238.899	15.348.718	-37	73	0
-407.886	3.912.962	607	-773	1.913.725	366.234.156	11	89	0
-153.589	4.298.336	639	-840	2.143.935	459.645.613	45	82	0
-331.484	5.906.478	1018	-951	2.934.934	861.384.038	-28.5	103	0
-23.186	7.264.002	642	-1453	3.632.371	1.319.411.632	51.5	54	0
26.877	4.453.197	613	-572	2.226.708	49582.29	-13	84	0
-111.895	10.719.053	1420	-1868	5.359.013	2.871.901.717	95	132	0
133.921	9.548.717	1629	-1032	4.773.063	2.278.212.577	-82	58	0
-624.387	3.857.326	741	-750	1.825.019	333.069.457	-65	69	0

286.653	9.361.036	1460	-1542	4.672.302	2.183.040.894	18	109	0
-543.445	5.729.922	584	-525	281.329	79.146.009	-160	79	0
-534.568	2.381.852	398	-273	106.434	113.281.862	-65	60	0
-186.201	702.976	570	-1135	3.510.373	1.232.271.924	88.5	66	0
70.493	758.208	1624	-854	3.790.847	1.437.052.225	-56.5	125	0
36.854	10.558.686	1408	-1664	5.267.107	2.774.241.364	110	147	0
104.272	3.774.345	632	-494	188.452	355.141.446	26	71	0
-52.183	11.817.642	1346	-1872	5.909.312	349.199.653	176	98	0
23.997	3.376.922	776	-527	1.688.497	285.102.161	-8	60	0
-79.075	2.129.119	253	-239	1.061.748	112.730.901	-29	83	0
-151.284	4.012.126	584	-516	2.000.595	400.237.945	-38	69	0
-59.873	8.678.725	1158	-1529	4.339.479	1.883.108.116	103.5	76	0
-43.767	6.574.345	683	-843	3.287.282	1.080.622.446	78	84	0
-130.029	2.209.097	362	-389	1.097.002	120.341.382	-8	85	0
561.775	7.779.581	1367	-890	384.948	1.481.849.582	-11	75	0
205.955	3.879.919	730	-519	1.929.231	372.193.403	-26	44	0
-363.093	5.632.733	919	-849	2.793.204	780.198.816	-98	55	0
-92.297	11.864.135	1469	-1872	5.932.073	3.518.949.457	140.5	115	0
-39.741	4.942.159	860	-580	2.471.062	610.614.499	-63	65	0
-163.835	9.904.073	1482	-1863	494.993	245.018.047	31	117	0
-311.108	5.434.122	769	-645	2.699.521	728.741.108	-108	76	0
-34.429	2.606.476	314	-724	1.302.942	169.765.809	13	76	0
-2.853	5.023.176	1088	-1061	2.511.732	630.879.989	4.5	138	0
-94.351	4.620.758	980	-1066	2.308.734	533.025.096	-2.5	49	0
203.887	5.043.982	622	-609	2.514.043	632.041.234	49	148	0
66.487	2.890.946	439	-461	144.412	208.548.155	19	85	0
-54.065	320.558	873	-298	1.602.073	256.663.898	-39	69	0
-36.084	5.423.753	506	-733	2.711.967	735.476.723	84	83	0
161.995	6.219.808	1236	-717	3.106.061	964.761.543	-67	73	0
35.227	1.225.129	2047	-1649	6.126.292	3.753.145.045	-116	64	0
-80.151	9.873.248	950	-1869	4.936.576	2.436.978.225	153	48	0
-379.856	5.073.632	721	-658	2.508.522	629.268.132	-69	153	0
-151.489	5.863.659	967	-1057	2.928.271	857.476.941	-69	73	0
-285.654	2.573.727	524	-423	1.254.912	157.480.392	-16	93	0
357.393	2.756.962	370	-579	1.331.508	17729.13	51	61	0
-111.702	7.554.877	2047	-738	3.776.248	1.426.004.743	-130	63	0
-106.113	5.680.807	734	-906	2.838.767	805.859.954	23	79	0
427.942	9.817.957	1068	-1829	4.890.887	2.392.077.454	141	75	0
-97.048	11.125.739	1556	-1867	5.562.702	3.094.365.309	84	109	0
-218.452	4.683.245	1023	-899	2.331.695	543.680.263	-23	49	0
-67.427	398.448	524	-531	1.874.897	35.152.379	-98	74	0
216.423	3.038.098	586	-395	1.503.736	226.122.278	15	78	0
-0.4517	5.067.239	683	-609	2.533.925	642.077.598	-60	79	0
573.394	6.576.964	1349	-837	3.238.502	1.048.789.398	-5	87	0

-484.487	2.397.332	287	-384	1.096.524	120.236.545	-31	68	0
-330.337	4.026.817	486	-583	1.986.367	394.565.425	-11	74	0
-140.046	9.859.999	1762	-1867	4.928.612	2.429.121.345	96	108	0
-339.272	2.369.788	243	-599	1.135.422	128.918.223	-21	66	0
-186.619	2.595.753	399	-455	1.284.547	165.006.033	4	88	0
0.8333	10.256.615	1502	-1428	5.128.927	2.630.589.028	-85	65	0
-14.959	10.384.265	1050	-1107	5.190.611	269424.39	78	78	0
449.736	9.103.902	1088	-1841	4.530.232	2.052.300.496	153	85	0
-37.759	796.961	1214	-1117	3.985.113	1.588.112.191	-57	83	0
-526.882	2.181.683	253	-454	955.276	91.255.309	-36	126	0
-107.634	2.805.015	513	-461	1.398.542	19.559.198	27	52	0
446.682	8.980.436	1000	-1740	446.849	1.996.740.572	175	102	0
-56.304	354.805	624	-589	1.773.348	314.476.294	-11	121	0
254.644	7.510.388	648	-1248	3.747.008	1.404.006.576	140	62	0
-162.314	371.423	420	-520	1.850.234	342.336.612	21	74	0
476.243	3.893.702	784	-565	1.887.933	356.429.262	40	59	0
-397.651	5.517.223	1033	-1102	2.730.134	745.362.921	-37	143	0
-121.653	831.267	1565	-1524	4.155.062	1.726.453.707	42	79	0
-226.694	530.881	951	-824	264.503	69.961.837	-61	91	0
434.917	9.919.535	1059	-1839	4.941.265	2.441.610.339	210	66	0
-79.438	5.987.102	595	-792	2.992.862	895.722.493	79	82	0
256.958	4.542.065	585	-538	2.256.724	50.928.054	29	132	0
-445.752	2.346.498	348	-441	1.085.406	117.810.552	-47	80	0
-64.502	11.055.415	999	-1341	5.528.006	3.055.885.304	115.5	79	0
20.496	5.870.213	568	-735	2.935.393	861.653.482	70	82	0
220.398	7.617.212	1555	-838	3.802.688	1.446.043.293	-94	104	0
33.369	5.185.714	1058	-833	2.592.959	672.343.656	-21	84	0

EK-3: WEKA Platformundan Elde Edilen Sonuçlar

1. Linear Regression Model

```

sonuc =
0.0013 * ortalama +
-0.0007 * max +
0.0007 * min +
0      * varyans +
0.0019 * sifirgecis +
0.878

```

Time taken to build model: 0.05 seconds

==== Evaluation on test split ====

==== Summary ====

Correlation coefficient	0.834
Mean absolute error	0.2174
Root mean squared error	0.2766
Relative absolute error	43.4489 %
Root relative squared error	55.2857 %
Total Number of Instances	40

2. MultiLayer Perceptron

Time taken to build model: 0.47 seconds

==== Evaluation on test split ====

==== Summary ====

Correlation coefficient	0.9993
Mean absolute error	0.0112
Root mean squared error	0.0203
Relative absolute error	2.2433 %
Root relative squared error	4.0588 %
Total Number of Instances	40

3. Pace Regression Model

```

sonuc =
1.0369 +
0.0017 * ortalama +
0.0022 * karort +
-0.0001 * max +
-0.0114 * std +
0      * varyans +
-0.0004 * medyan +
0.0016 * sifirgecis

```

Time taken to build model: 0.05 seconds

==== Evaluation on test split ====

==== Summary ====

Correlation coefficient	0.952
Mean absolute error	0.1279
Root mean squared error	0.1592
Relative absolute error	25.5724 %
Root relative squared error	31.8275 %
Total Number of Instances	40

4. Radial basis function network (Linear regression applied to K-means clusters as basis functions):

Linear Regression Model

```
sonuc =  
-0.3709 * pCluster_0_0 +  
0.3709 * pCluster_0_1 +  
0.3658
```

Time taken to build model: 0.11 seconds

==== Evaluation on test split ====

==== Summary ====

Correlation coefficient	0.6999
Mean absolute error	0.2688
Root mean squared error	0.3577
Relative absolute error	53.7279 %
Root relative squared error	71.4853 %
Total Number of Instances	40

5. SMOreg

Kernel used :

Linear Kernel : $K(x,y) = \langle x,y \rangle$

Machine Linear: showing attribute weights, not support vectors.

(normalized) sonuc =

0.1893 * (normalized) ortalama
 + -1.2101 * (normalized) karort
 + -0.4399 * (normalized) max
 + 0.0459 * (normalized) min
 + -1.8795 * (normalized) std
 + 2.5034 * (normalized) varyans
 + -0.1351 * (normalized) medyan
 + 0.0473 * (normalized) sifirgecis
 + 0.9964

Number of kernel evaluations: 20100 (100 % cached)

Time taken to build model: 0.17 seconds

==== Evaluation on test split ====

==== Summary ====

Correlation coefficient	0.9299
Mean absolute error	0.1197
Root mean squared error	0.1917
Relative absolute error	23.9272 %
Root relative squared error	38.3099 %
Total Number of Instances	40

6. KStar Beta Version (0.1b).

Copyright (c) 1995-97 by Len Trigg (trigg@cs.waikato.ac.nz).

Java port to Weka by Abdelaziz Mahoui (am14@cs.waikato.ac.nz).

KStar options : -B 20 -M a

Time taken to build model: 0 seconds

==== Evaluation on test split ====

==== Summary ====

Correlation coefficient	1	
Mean absolute error	0	
Root mean squared error	0	
Relative absolute error	0	%
Root relative squared error	0	%
Total Number of Instances	40	

7. Additive Regression (ZeroR model)

ZeroR predicts class value: 0.5

Base classifier weka.classifiers.trees.DecisionStump

2 models generated.

Model number 0

Decision Stump

Classifications

karort <= 184.9086 : 0.5

karort > 184.9086 : -0.5

karort is missing : 0.0

Model number 1

Decision Stump

Classifications

ortalama <= -75.43795 : 0.0

ortalama > -75.43795 : 0.0

ortalama is missing : 0.0

Time taken to build model: 0.02 seconds

==== Evaluation on test split ====

==== Summary ====

Correlation coefficient	1	
Mean absolute error	0	
Root mean squared error	0	
Relative absolute error	0	%
Root relative squared error	0	%
Total Number of Instances	40	

8. Decision Table:

Number of training instances: 200

Number of Rules : 10

Non matches covered by Majority class.

Best first search for feature set,
terminated after 5 non improving subsets.

Evaluation (for feature selection): CV (leave one out)

Feature set: 2,9

Time taken to build model: 0.03 seconds

==== Evaluation on test split ====

==== Summary ====

Correlation coefficient	1
Mean absolute error	0
Root mean squared error	0
Relative absolute error	0 %
Root relative squared error	0 %
Total Number of Instances	40

9. M5 pruned model tree: (using smoothed linear models)

karort \leq 184.909 : LM1 (100/0%)

karort $>$ 184.909 : LM2 (100/0%)

LM num: 1

sonuc =
-0.0002 * karort
+ 0.9893

LM num: 2

sonuc =
-0.0002 * karort
+ 0.1197

Number of Rules : 2

Time taken to build model: 0.03 seconds

==== Evaluation on test split ====

==== Summary ====

Correlation coefficient	0.9978
Mean absolute error	0.0382
Root mean squared error	0.045
Relative absolute error	7.6282 %
Root relative squared error	8.9854 %
Total Number of Instances	40

10. M5 pruned model rules (using smoothed linear models) :

Number of Rules : 2

Rule: 1

IF

karort \leq 184.909

THEN

sonuc =

-0.0002 * karort

+ 0.9893 [100/0%]

Rule: 2

sonuc =


+ 0 [100]

Time taken to build model: 0.05 seconds

==== Evaluation on test split ====

==== Summary ====

Correlation coefficient	1
Mean absolute error	0.0149
Root mean squared error	0.0219
Relative absolute error	2.9864 %
Root relative squared error	4.3758 %
Total Number of Instances	40



Şekil 8.1. M5P algoritmasına ait karar ağacı

11. REPTree

karort < 185.52 : 1 (70/0) [30/0]

karort >= 185.52 : 0 (63/0) [37/0]

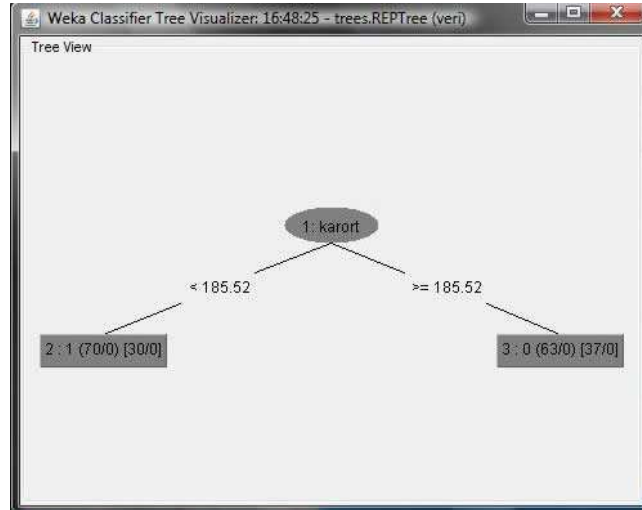
Size of the tree : 3

Time taken to build model: 0 seconds

==== Evaluation on test split ====

==== Summary ====

Correlation coefficient	1
Mean absolute error	0
Root mean squared error	0
Relative absolute error	0 %
Root relative squared error	0 %
Total Number of Instances	40



Şekil 8.2. REPTree algoritmasına ait karar ağacı

ÖZGEÇMİŞ

Mehmet Albayrak, 07.06.1974 tarihinde İzmir’de doğdu. İlk, orta ve lise eğitimini Isparta’da sırasıyla; Alaybeyoğlu İlkokulu, Gülkent Ortaokulu, Isparta Teknik ve Endüstri Meslek Lisesi Elektrik ve Elektronik bölümlerinde tamamladı. 1990 yılında Gazi Üniversitesi Teknik Eğitim Fakültesi, Elektrik-Elektronik Bölümüne girdi. 1994 yılında Elektrik bölümünden mezun olarak aynı yıl Eylül ayında Gazi Üniversitesi Fen Bilimleri Enstitüsü Elektrik Bölümünde yüksek lisans öğrenimine başladı. Mart 1998’de Doç.Dr. Osman Gürdal yönetiminde "Üç Boyutlu Uzayda Hareket Edebilen Bir Robot Kolun, Bilgisayar Destekli Kontrolü, Tasarımı, Simülasyonu ve Uygulaması" konulu tezi hazırlayarak yüksek lisansını tamamladı. Lisans mezuniyetinden bu yana pek çok kamu kurumun ve özel kuruluşta farklı kademelerde görev yaptı. 1994-1995 yıllarında MEB Kayseri Seyyid Burhaneddin Endüstri Meslek Lisesinde Teknik Öğretmen olarak görev aldı. 1995-1998 yılları arası Süleyman Demirel Üniversitesi (SDÜ) Teknik Eğitim Fakültesi araştırma görevlisi ve öğretim görevlisi olarak çalıştı. 1999-2000 yıllarında İstanbul Sabiha Gökçen Uluslararası Havaalanı Network Yöneticisi, 2001-2005 yılları arasında SDÜ Senirkent Meslek Yüksek Okulu Bilgisayar Bölümü Öğretim Görevlisi, SDÜ Bilgisayar Bilimleri Araştırma ve Uygulama Merkezi Müdür Yardımcısı olarak çalıştı. 2005-2007 yılları arası bu yana SDÜ Sürekli Eğitim Merkezi Müdür Yardımcısı ve SDÜ Teknik Eğitim Fakültesi Elektronik – Bilgisayar Eğitimi Bölümü öğretim görevlisi olarak görev aldı. Halen SDÜ Teknik Eğitim Fakültesi Elektronik – Bilgisayar Eğitimi Bölümü Öğretim Görevlisi ve SDÜ Uzaktan Eğitim Meslek Yüksek Okulu Teknik Programlar Bölüm Başkanı olarak görevini sürdürmektedir.

Mehmet Albayrak evli olup, Ege Onur ve Eylül Begüm isimlerinde iki çocuk babasıdır.