



**T.C.
MUSTAFA KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**EEG VERİLERİ KULLANILARAK METİNSEL
OKUMA ve MATEMATİKSEL İŞLEMLERİN ANALİZİ**

Server Göksel ERALDEMİR

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**HATAY
HAZİRAN-2014**



**T.C.
MUSTAFA KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**EEG VERİLERİ KULLANILARAK METİNSEL
OKUMA ve MATEMATİKSEL İŞLEMLERİN ANALİZİ**

Server Göksel ERALDEMİR

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**HATAY
HAZİRAN-2014**

T.C.
MUSTAFA KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**EEG VERİLERİ KULLANILARAK METİNSEL OKUMA
ve MATEMATİKSEL İŞLEMLERİN ANALİZİ**

**SERVER GÖKSEL ERALDEMİR
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

Yrd. Doç.Dr. ESEN YILDIRIM danışmanlığında hazırlanan bu tez 17/06/2014 tarihinde aşağıdaki jüri üyeleri tarafından **OYBİRLİĞİ** ile kabul edilmiştir.

Yrd.Doç.Dr.Esen YILDIRIM

BAŞKAN

Yrd.Doç.Dr. Yakup KUTLU
ÜYE

Yrd.Doç.Dr.Merve ERKINAY ÖZDEMİR
ÜYE

Bu tez Enstitümüz Elektrik-Elektronik Mühendisliği Anabilim Dalında hazırlanmıştır.

Kod No: 735

**Prof. Dr. İsmail Hakkı KARAHAN
Enstitü Müdürü**

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

16.07.2014

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını ve tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu beyan ederim.

SERVER GÖKSEL ERALDEMİR

ÖZET

EEG VERİLERİ KULLANILARAK METİNSEL OKUMA ve MATEMATİKSEL İŞLEMLERİN ANALİZİ

Bu çalışmada sayısal ve metinsel işlemler sırasında oluşan EEG işaretlerinin sınıflandırılması hedeflenmiştir. Bu amaçla 18 sağlıklı ve gönüllü denekten uluslararası 10-20 sistemine uygun olarak, EEG verileri kaydedilerek bir veritabanı oluşturulmuştur. Veritabanı, Nihon Kohden 1200 marka 32 kanaldan 1kHz örnekleme ile yüksek kalitede çekim yapabilen, şebeke gürültülerini otomatik temizleyebilen dijital EEG kayıt cihazı ile 22 elektrot kullanılarak 26 kanal üzerinden toplanmıştır. Bu veriler ilk olarak ön işlemden geçirilmiş, daha sonra uzunluğu 1 saniye olan %75 örtüşmeli kayan pencereler kullanılarak Dalgacık Dönüşümü yoluyla öznitelikler çıkartılmış ve BayesNet, kNN ve Karar ağaç yapıları sınıflandırıcıları ile sınıflandırılmış ve sırasıyla ile %88,8, %89,5 ve %90 doğru pozitif oranına ulaşılmıştır.

Bilgisayar beyin arayüz çalışmaları gerçek zamanlı çalışan sistemler olduğundan analiz süreleri büyük önem taşımaktadır. Çok sayıda kanal kullanılan sistemlerde çıkarılacak öznitelik sayısı yüksek olacağından bir pencerenin işlenmesi süresi sorun teşkil edebilmektedir. Kullanılan kanal sayısının doğru pozitif oranını etkilemeyecek şekilde azaltılması analiz süresini azaltacağından sistemin kullanılabilirliğini artıracaktır. Bu nedenle 26 kanaldan elde edilen öznitelikler arasından, Korelasyon Tabanlı Öznitelik Seçimi (KTÖS) kullanılarak, kendi aralarında korelasyonları düşük ve sınıf ile korelasyonu yüksek olan etkin öznitelikler tüm denekler için belirlenmiştir. Bu özniteliklerin ait oldukları kanallar analiz edilerek, en çok seçilenden en az seçilene doğru sıralanmış ve analize teker teker eklenerek sınıflandırma işlemi tekrarlanmıştır. Bu analiz sonucunda doğru pozitif değerini en az etkileyecek şekilde 14 kanal kullanılarak yapılan BayesNet, kNN ve Karar Ağaçları sınıflandırmalarında sırası ile %90,1 %87,7 ve % 90,6 sonuçları elde edilmiştir.

2014, 59 Sayfa

Anahtar Kelimeler: EEG veritabanı, EEG sınıflandırma, kNN, BayesNet, Karar Ağaç Yapıları, Kanal Seçimi.

ABSTRACT

ANAYSIS OF EEG SIGNALS DURING TEXT READING AND MATHEMATICAL PROCESSING

This thesis aims to classify EEG signals during simple math and text processing. For this purpose, EEG recordings were collected from 18 healthy voluntary subjects according to International 10/20 System through 26 channels using the Nihon-Kohden 1200 EEG device with 1kHz sampling rate. After pre-processing, recordings are segmented into 1 second long epochs with 75% overlap for sliding window analysis and features are extracted using Wavelet Transform. Finally BayesNET, kNN and Decision Tree Structure algorithms are employed for classification and 88,8%, 89,5% and 90% true positive rates are obtained respectively.

Brain-Computer Interface studies are real time systems and therefore time of analysis is of great importance. For a system with a high number of channels, number of features might be huge that the time needed to process a window might cause problems. Decreasing the number of channels without affecting the true and false positive rates would increase the effectiveness of the system. For that cause, features that are highly correlated with the class but uncorrelated (or has a low correlation degree) with other features are detected for all subjects using Correlation based Feature Selection (CFS) method. Analyzing the channels detected features belong to, channels are sorted according to the number of times they were selected. Finally, starting from mostly used channel and adding one channel at a time, the whole analysis was repeated. Among 26 channels, 14 channels, through which true positive rate is least affected, were determined and 90,1%, 87,7% and 90,6% true positive rates are obtained for BayesNET, kNN and Decision Tree Structure classifiers respectively.

2014, 59 Pages

Key Words: EEG database, EEG classifications,kNN,BayesNET, Decision Tree Structure,Channel Selection.

TEŐEKKÜR

Yüksek Lisans tez çalışmamda sürekli ve sabırla yardımcı olan danışmanım Sayın Y.Doç.Dr. Esen YILDIRIM'a , desteęini esirgemeyen hocalarım Sayın Y.Doç.Dr. Serdar YILDIRIM'a, Sayın Yrd.DoçDr. Yakup KUTLU'ya, Sayın Yrd.Doç Dr. Z.Merve ERKINAY ÖRDEMİR'e, ve tez sürecinde bana destek olan aileme teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖZET.....	I
ABSTRACT.....	II
TEŞEKKÜR.....	III
İÇİNDEKİLER	IV
ŞEKİLLER DİZİNİ.....	VI
ÇİZELGELER DİZİNİ	1
SİMGELER ve KISALTMALAR DİZİNİ	2
1. GİRİŞ	4
1.1 Beynin Yapısı	6
1.2 EEG (ELEKTROENSEFLOGARFI).....	7
2. ÖCEKİ ÇALIŞMALAR	9
3. MATERYAL VE YÖNTEM	15
3.1. İşaret İşleme Yöntemleri	16
3.1.1. Fourier Dönüşümü	16
3.1.2. Sürekli Dalgacık Dönüşümü	17
3.1.3. Ayrık Dalgacık Dönüşümü	19
3.1.4. Dalgacık Dönüşümünde Kullanılan Dalgacıklar	20
3.1.5. Daubechies Dalgacığı.....	22
3.2. Verilerin Toplanması	23
3.2.1. Elektrotların Bağlantı Şekli.....	24
3.2.2. Slayt Düzeni ve Örnekleri	25
3.2.3. EEG Kaydı Öncesinde ve Kayıt Sırasında Dikkat Edilen Hususlar	28
3.3. Veri Setinin Ayrıştırılması ve Öznitelik Çıkarımı	30
3.3.1. Veri Setinin Ayrıştırılması	30

3.3.2. Özniteliklerin Çıkarılması.....	33
3.4. Sınıflandırma ve Başarım Ölçütü.....	36
3.4.1. Sınıflandırıcılar	36
3.4.1.1. kNN Teoremi	37
3.4.1.2. BayesNet Algoritması (BayesAğ).....	37
3.4.1.3. Karar Ağaç Yapıları Teoremi.....	39
3.4.2. Başarım Ölçümü.....	41
3.5. Kolerasyon Tabanlı Öznitelik Seçimi Yardımıyla Kanal Seçimi	42
3.5.1. Öznitelik Seçimi.....	42
3.5.2. Kanal Seçimi	42
4. ARAŞTIRMA VE BULGULAR	44
4.1. BayesNet Algoritmasına Göre Sınıflandırma Sonuçları	44
4.2. kNN Algoritmasına Göre Sınıflandırma Sonuçları.....	45
4.3. Karar Ağaç Yapıları Algoritmasına Göre Sınıflandırma Sonuçları	46
5. SONUÇ VE ÖNERİLER	54
5.1. Değerlendirme.....	54
5.2. Gelecek Çalışmalar	56
KAYNAKLAR	57
ÖZGEÇMİŞ	62

ŞEKİLLER DİZİNİ

Şekil 1.1. Beyin lobları	7
Şekil 3.1 İşlem basamakları	15
Şekil 3.2 Fourier dönüşümü	16
Şekil 3.3 Kzfd grafiksel görünümü	17
Şekil 3.4 Dalgacık dönüşümü grafiksel gösterimi	18
Şekil 3.5 İki kanallı filtre bankası	19
Şekil 3.6 ADD katsayıları	20
Şekil 3.7 Kullanılan bazı dalgacık türlerinin grafikleri.....	21
Şekil 3.8 Daubechies dalgacıkları	22
Şekil 3.9 Daubechies dalgacıklarından db4 dalgacığı.....	23
Şekil 3.10 Nihon kohden 1200 marka eeg çekim cihazı.....	23
Şekil 3.11 Uluslararası 10-20 sistemi	24
Şekil 3.12 EEG kaydı için elektrotların 10-20 sistemine göre yerleştirilmesi (üstten görünüm).....	25
Şekil 3.13 Deney sırasında elektrotların yerleşiminin görünümü	25
Şekil 3.14 Sayısal slaytlarda toplama işlemi örnek-1	26
Şekil 3.15 Sayısal slaytlarda çıkarma işlemi örnek-2	26
Şekil 3.16 Sayısal slaytlarda çarpma işlemi örnek-3	27
Şekil 3.17 Sayısal slaytlarda bölme işlemi örnek-4	27
Şekil 3.18 Sözel slaytlardan örnek-1.....	28
Şekil 3.19 Sözel slaytlardan örnek-2.....	28
Şekil 3.20 EEG kaydı alınırken oturuş pozisyonu (üstten görünüm)	29
Şekil 3.21 EEG kayıt odası	30
Şekil 3.22 1 slayta ait veri setinin matrisi	31
Şekil 3.23 Sayısal veri seti şeması	32
Şekil 3.24 Sözel veri seti şeması	32
Şekil 3.25 Tüm sayısal ve sözel veri setleri gösterimi	33
Şekil 3.27 EEG işaretinin 7. seviyede ayrıştırılması.....	34
Şekil 3.28 Bir slayta ait öznitelik matrisi.....	35
Şekil 3.29 Bir deneğe ait 27 slaytlık öznitelik matrisleri.....	36

Şekil 3.30 Örnek bayes ağ yapısı	38
Şekil 3.31 Dokuz boyutlu ve iki sınıflı örnek karar ağaç yapısı	40
Şekil 4.1 Sınıflandırıcıların 26 kanala göre sınıflandırma sonuçları grafiği.....	47
Şekil 4.2 Bayesnet kanallara göre doğru pozitif sayıları.....	48
Şekil 4.3 KNN algoritmasının kanallara göre doğru pozitif sayıları	51
Şekil 4.4 Random forest algoritmasının kanallara göre doğru pozitif sayıları	53
Şekil-5.1 Seçilen iki kanalın gösterimi	54
Şekil-5.2 Seçilen dört kanalın gösterimi	55
Şekil-5.3 Seçilen on kanalın gösterimi.....	56

ÇİZELGELER DİZİNİ

Çizelge 3.1 Seçilen özneliklerin sayısının kanallara göre dağılımı.	43
Çizelge 4.1 Bayesnet sınıflandırıcısı sonuçları	44
Çizelge 4.2 1,3,5 Ve 10 k değerlerine göre sınıflandırma sonuçlar	45
Çizelge 4.3 1-Nn Algoritmasına Göre Sınıflandırma Sonuçlar	46
Çizelge 4.4 Karar ağaç yapılarına göre sınıflandırma sonuçlar	47
Çizelge 4.5 Kanalların bayesnet sınıflandırmasına göre analiz sonuçları.....	49
Çizelge 4.6 Seçilen kanallara göre knn sınıflandırma sonuçları	50
Çizelge 4.7 Kanalların random forest algoritmasına göre sonuçları.....	52

SİMGELER DİZİNİ

A	Alfa .
B	Beta
Θ	Teta
Δ	Delta
γ	Gamma
μV	Mikro Volt
T	Zaman
W	Frekans
$wi(t)$	Analitik işaretin anlık frekansı
$\psi(t)$	Temel dalgacık fonksiyonu
$\theta(t)$	Faz fonksiyonu

KISALTMALAR DİZİNİ

ADD	Ayrık Dalgacık Dönüşümü
BT	Bilgisayarlı Tomografi
DD	Dalgacık Dönüşümü
$DTEES$	Doğru tahmin edilmiş etiket sayısı
EEG	Elektroensefalografi
FD	Fourier Transform
$fMRI$	Fonksiyonel manyetik rezonans görüntüleme
Hz	Hertz

<i>kHz</i>	Kilo Hertz
<i>KZFD</i>	Kısa Zamanlı Fourier Dönüşümü
<i>MRG</i>	Manyetik Rezonans Görüntüleme
<i>PET</i>	Pozitron Emisyon Tomografisi
<i>sn</i>	Saniye
<i>TEES</i>	Tahmin Edilmiş Toplam Etiket Sayısı
<i>TES</i>	Toplam etiket sayısı
<i>YS</i>	Yapay Sinir
<i>YSA</i>	Yapay Sinir Ağı
<i>YTEES</i>	Yanlış Tahmin Edilmiş Etiket Sayısı

1. GİRİŞ

Beynin fonksiyonel her aktivitesi, kafatası içinde elektrik akımı meydana getirir. 1929 yılında Berger Elektroensefalografi (EEG) kaydının kafa derisi üzerinden de yapılabileceğini tespit ederek ilk defa kafa derisi üzerinden EEG kaydını gerçekleştirmiştir (Haas,2003). EEG beyin sinir hücreleri olan nöronların uyarılması sonucunda oluşan akımların ölçülerek kayıt edilmesidir. Aktifleşen nöron ile kayıt eden elektrot arasında deri, kafatası ve diğer tabakalar olduğu için kaydedilen işaretin genliği düşük olur, bundan dolayı işaret, şiddeti artırılarak kaydedilir ve sayısallaştırılarak bilgisayarın hafızasında saklanır (Malmivuo ve Plonsey, 1995, İšoğlu Alkaç, 2009).

Normal bireylerde EEG frekanslarının değişim aralığı 1-100 Hz, genlik değer aralığı ise 20-100 μ V'tur (Niedermeyer, 2005). EEG işaretlerinde beyin fonksiyonları ile ilgili çok miktarda bilgi saklıdır. Bu bilgilerin kullanılabilmesi için işaret işleme yöntemleri kullanılarak çeşitli araştırmalar yapılmaktadır. Yapılan deneyler, EEG frekansının kişinin zihinsel aktivitelerine göre çeşitlilik gösterdiğini ortaya koymuştur (Batar,2005,Liu ve Ark., 2011, Chen, 2014).

EEG çeşitli frekans bantlarına ayrılarak isimlendirilmektedir. Bu isimler ve kapsadığı frekans aralıkları delta (Δ) 0.5-3.5 Hz, teta (θ) 4-7Hz, alfa (α) 8-13Hz, beta (β) 14-29Hz ve gamma (γ) 30-80Hz' tir (Niedermeyer,2005, Barışçı ve Müldür, 2003, Hermann ve Demiralp, 2005).

Alfa dalgaları uyanık, sakin ve normal insanlar da görülürken, beta dalgaları zihinsel aktivitenin yoğun olduğu durumlarda görülür. Teta dalgaları çocuklarda ve yetişkin insanlarda düş kırıklığı ve gerginlik anlarında görülürken, delta dalgaları da süt çocuklarında ve ağır beyin hasarı olan yetişkinlerde görülmektedir. Gamma dalgaları ise görsel işlevler sırasında oluşan beyin dalgalarıdır (Yazgan ve Korüerk, 1996, Niedermeyer ,2005).

EEG işaretleri beyin araştırmalarında zamansal çözümleme konusunda, görüntüleme (BT, MRG, fMRI, PET) sistemlerine göre daha avantajlıdır. Görüntüleme sistemlerinde uzaysal çözümleme daha iyi olmasına rağmen, EEG zamana bağlı olayların araştırılmasında diğer yöntemlerden daha etkilidir.

EEG işaretlerinin en belirgin özelliği durağan ve doğrusal olmayan ani değişimler göstermesidir. EEG işaretlerinde, genlik, faz ve frekans değerleri sürekli değişir. Bu özelliğinden dolayı anlamlı bir veri elde edebilmek için, ölçümlerin oldukça

uzun bir süreye yayılarak yapılması gerekir (Yazgan ve Korürek, 1996). Bu işaretlerin işlenmesi ve anlamlı veri elde edilmesi için farklı işaret işleme yöntemleri kullanılmaktadır.

Literatürde bulunan pek çok çalışmada, EEG İşaret analizinde Fourier Dönüşüm (FD) kullanılmıştır (Aljazery ve Ark, 2011). FD ile zaman temelinde bulunan bilgi frekans temeline dönüştürülmektedir. FD, İşaretlerin frekans içerikleri işaret karakteristiği ile ilgili pek çok bilgiyi taşımasından dolayı önemlidir. Ancak, FD işaretlerin periyodik bir yapıya sahip olduğunu ve analiz boyunca karakteristiğinin değişmediğini varsaymaktadır. Bu nedenle durağan işaretler için çok geçerli sonuçlar alınsa da durağan olmayan işaretler için uygun bir analiz yöntemi değildir.

Bu nedenle, EEG işaretlerinin zamana bağlı olarak nasıl değiştiğini analiz ederek anlamlı veri elde edebilmek amacıyla, tüm işaret bileşenlerini inceleyebilecek durağan olmayan işaret işleme yöntemlerine ihtiyaç duyulmaktadır. Biyo işaretlerin incelenmesinde Dalgacık Dönüşümü (DD) FD'nin eksikliklerini gidermek için geliştirilmiş bir yöntemdir. Bu analiz yöntemi gürültüye karşı daha az hassasiyet göstermekte ve durağan olmayan işaretlere rahatlıkla uygulanabilmektedir. Bundan dolayı DD işaret işleme çalışmalarında çok tercih edilen bir yöntem haline gelmiştir.

Dalgacık Dönüşümü, FD'yi temel almasına rağmen, FD' de olduğu gibi sabit fonksiyonları kullanmak yerine, EEG gibi ani değişim gösteren işaretler için zaman-frekans çözünürlüğünü sağlayabilecek, frekansa bağlı büyüklüğü değişebilen ve ayarlanabilen pencere fonksiyonlarını kullanmaktadır.

Bu pencereler düşük frekanslar için geniş, yüksek frekanslar için dar olacak şekilde değişen pencere boyutlarına sahiptir. Böylece, bütün frekans aralıklarında optimum zaman-frekans çözünürlüğünü sağlayabilmektedir (Merry,2005).

Bu çalışmada, sağlıklı deneklerden sayısal işlemler yaparken ve sözel metinler okurken kaydedilen EEG işaretlerinin sınıflandırılması hedeflenmiştir. Bu işlem için gönüllü deneklerden, uluslararası 10-20 sistemine uygun olarak EEG verileri toplanmıştır.

Daha sonra DD yardımıyla elde edilen öznitelikler BayesNet, kNN ve Karar Ağaç Yapıları kullanılarak sınıflandırmaya tabi tutulmuştur. Bu sınıflandırmalar sonucunda sayısal ve sözel işlemler esnasında kaydedilen EEG işaretleri, BayesNet

sınıflandırıcısı ile %88,8, kNN sınıflandırıcısı ile %89,5 ve Karar Ağaç yapıları sınıflandırıcısı ile %90,2 doğru pozitif oranlarıyla ayırt edilmiştir.

Çalışmanın ayrıntılarına değinmeden önce beyin yapısı, EEG işaretleri ve işaret işleme teknikleri hakkında bilgi verilmiştir.

1.1 Beynin Yapısı

Beyin, nöron adı verilen sinir hücrelerinin gövdeleri ve liflerinin kafatası içinde yoğun bir şekilde toplanması ve çevresini saran nöroglia veya glial adı verilen gri bir maddeyle oluşan ve karmaşık işlemleri bir arada yapabilen organdır (Yazgan ve Korüerk,1996). Beyinde bulunan toplam hücre sayısı yaklaşık 100 milyardır. Bu hücrelerin içerisinde, nöronların sayısının 10-15 milyar civarında olduğu bilinmektedir. Geri kalan hücreleri ise glia adı verilen hücreler oluşturmaktadır.

Beyin, kafatası sayesinde dışarıdan gelecek birçok etkiye karşı korunaklıdır. İnsan beyni, beynin alt tarafından yine sinir hücrelerinden oluşan omuriliğe bağlıdır. Yapılan araştırmalarda beynin sağ yarım küresinin vücudun sol tarafını, sol tarafındaki yarım kürenin ise vücudun sağ tarafını kontrol ettiği görülmüştür (Yazgan ve Korüerk,1996).

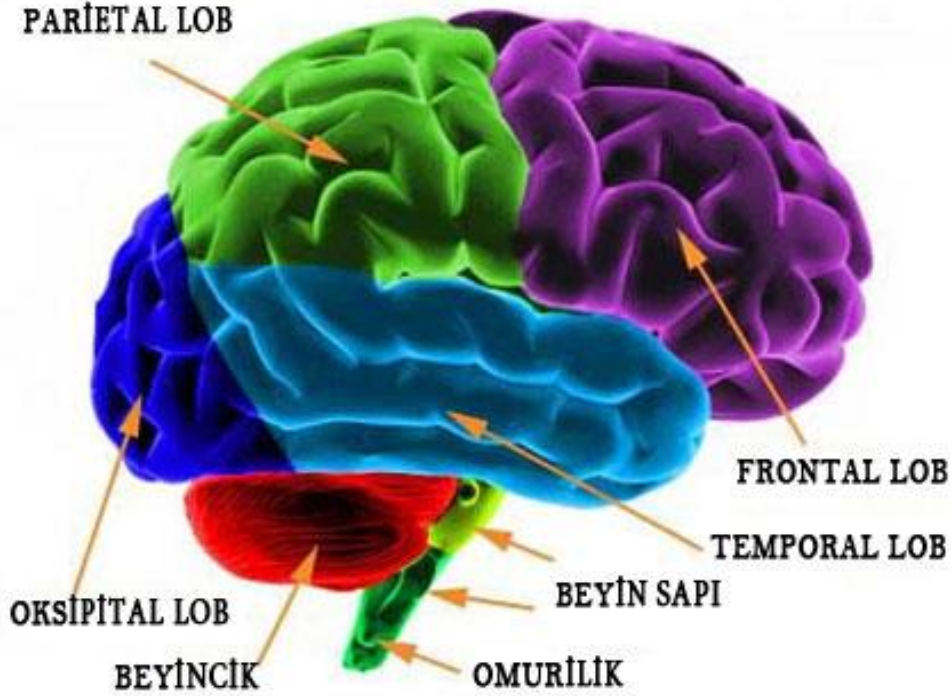
Beynin büyük bir kısmı proteinden oluşur. Beynin çalışması için gerekli olan enerji, glikozun oksijenle yanmasıyla elde edilir. Beyin insan vücudunun sadece % 2'sini oluşturmasına rağmen, vücudun tükettiği oksijenin yaklaşık %25'ini kullanmaktadır.

İnsan beyni yapısal işlevleri açısından 5 ana lob'a ayrılmıştır. Bu loblar Frontal (Ön) Lob, Parietal (Yan) Lob, Temporal (Şakak) Lob, Occipital (Arka) Lob ve Serebellum (beyincik) Lob'dur ve Şekil 1.1'de gösterilmiştir. Aşağıda lobların işlevleri hakkında kısa bilgiler verilmektedir.

1- Frontal Lob: Göz kürelerinin üzerinden başlar ve beynin altında saçlı derinin başladığı yere kadar olan kısmına verilen isimdir. Bu bölgenin en belirgin özelliği insanda akıl özelliklerinin olduğu bölüm olmasıdır. Bu lob sayesinde insan dikkatini toplar, kısa süreli belleği kullanabilir, düşünebilir ve koku alma gibi işlevleri yerine getirebilir. Ayrıca, problem çözme ve hafıza çalışması esnasında da etkilidir.

2- Temporal Lob: Görsel ve işitsel bellek, öğrenme ve konuşma gibi işlemlerin yapılmasından sorumlu olan beyin bölgesidir. Hasar görmesi durumunda konuşma ve işitme problemleri meydana gelmektedir. Ayrıca duygusal denge ve

sosyalleşme konuları da şakak (temporal) lob'un çalışması sonucu ortaya çıkan özelliklerdendir.



Şekil 1.1. Beyin lobları

- 3- **Oksipital Lob:** Kafatasının arka kısmında yer alan bu lob, görme işlemlerinden sorumlu olan beyin bölümüdür. Hasar görmesi durumunda insanda görme bozuklukları meydana gelir.
- 4- **Parietal Lob:** Beynin üst orta kısmında yer alır. Duygusal bilgileri işler, vücuttan gelen dokunma, ağrı, sıcaklık ve basınç duyularını alarak cevap üretir. Ayrıca okuma, matematik gibi işlerde akılda tutmayı sağlar.
- 5- **Beyincik:** Beynin arka kısmında yer alır. Görevi yürüme işlemi sırasında denge ve düzeni sağlamaktır.

1.2 EEG (ELEKTROENSEFLOGRAFİ)

EEG, insan beynini oluşturan sinir hücrelerinin uyarılması sonucu meydana gelen potansiyel farktır. İlk olarak 1875 yılında hayvanlar üzerinde yapılan araştırmalarda varlığı tespit edilen beynin elektriksel faaliyetleri, 1929 yılında Hans Berger tarafından insan beyninde de tespit edilmiştir ve 1930 yılında göz kapaklarının hareketi ile EEG işaretlerinin değiştiği görülmüştür (Yazgan ve Korürek,1996).

EEG işaretleri genellikle kafa derisi üzerinden, elektrotların jel yardımıyla sabitlenmesi sonucu girişimsel olmayan şekilde kayıt edilmektedir. EEG genliği 1-100 μ V arasında genişliğindedir. EEG işaretleri beynin her aktivitesinde oluşmaktadır ve genliği ve frekansı zamana göre ani olarak değişim göstermektedir. Beyin dalgaları bireyin yaşına, çevresindeki duyuşsal uyaranlara, beyindeki hasarlara ve vücudun kimyasal dengesine baęlı olarak deęişebilir. EEG uygulamalarında genelde 0.1 Hz ile 100 Hz frekans aralıęı incelenir ve incelemeler farklı alt frekans bantlarında yapılır. En çok analiz edilen frekans alt bantları ve işlevleri aőaęıda verilmektedir (Malmivuo ve Plonsey, 1995, Yazgan ve Korüerk, 1996).

1.2.1 Delta Dalgaları:

Frekans aralıęı 0.5-3.5 Hz'dir. Genellikle çocuklarda görülür; yetişkinlerde derin uyku halinde, bilincin tam olarak kaybolduęu durumlarda ve ağır beyin hastalıęı olan bireylerde görülür.

1.2.2. Teta Dalgaları:

Frekans aralıęı 4-7 Hz olan bu dalgalar, genellikle uyku öncesi, uykunun ilk evrelerinde bilincin zayıf olduęu durumlarda ve düş kırıklıęı durumlarında meydana gelir. Kafatası bölgelerinden parietal ve temporal bölgelerde ortaya çıkar.

1.2.3. Alfa Dalgaları:

Frekans aralıęı 8-12 Hz'dir. Genellikle uyanık ve sakin bireylerde zihinsel rahatlama anında görülür ve uyku halinde tamamen ortadan kalkar. Kafatasının bölümlerinden oksipital bölgede daha çok görülür.

1.2.4 Beta Dalgaları:

Frekans aralıęı 13-30 Hz'dir. Bu bant genellikle kafatasının frontal ve parietal bölgelerinden kayıt edilmektedir. İnsanların beyinlerini aktif ve yoğun şekilde kullandıkları durumlarda veya stresli ve gergin olduklarında meydana gelir.

1.2.5 Gamma Dalgaları:

Bazı araştırmacılar tarafından kullanılan ve EEG dalgalarının 30 Hz üstü olduęu durumlarda dalgalara verilen isimdir. Özellikle görsel işlevlerde aęıęa çıkan bu dalgalar, genellikle uzun süreli bellek, epilepsi ve uyku karakteristiklerini inceleyen araştırmacılar tarafından kullanılmaktadır. (Keil ve ark., 1999, Brankačk ve ark., 2010).

2. ÖCEKİ ÇALIŞMALAR

Bu bölümde ilk olarak EEG ile ilgili yapılan çalışmalar ve EEG işaretlerinin işlenmesinde dalgacık dönüşümünün kullanıldığı çalışmalar anlatılacaktır.

1875 yılında Richard Caton tavşan, kedi ve maymunlar üzerinde yaptığı deneylerde beyinde elektriksel aktivite olduğunu bulmuştur. Caton deneylerinde elektrotların bağlı olduğu galvanometre kullanmıştır. 1912 yılında Pravdich-Neminsky galvanometreli elektrotlar kullanarak hayvanların beyinde oluşan elektriksel aktiviteleri kayıt etmeyi başarmıştır (Niedermeyer, 2005).

Bu gelişmelerden sonra, insanlar üzerinde ilk çalışmalar başlamıştır. Birinci dünya savaşında kafatası yaralı olan bireylerde kafatası içerisine yerleştirilen elektrotlar ile ilk elektroserebrogram kaydı 1924 yılında gerçekleştirilmiştir (İşoğlu Alkaç, 2009). 1929 yılında ise Hans Berger insan beyinde de aynı aktivitenin olduğunu, oğlunun kafatasına yerleştirdiği elektrotlar yardımıyla tespit ederek bunu kayıt etmeyi başarmıştır (Yazgan ve Korürek,1996, Niedermeyer, 2005). 1930 yılında Berger EEG'nin gözün açılıp kapanması ile değiştiğini tespit etmiştir (Yazgan ve Korürek, 1996).

EEG'nin bilimsel olarak ortaya konması ve incelenmesi elektronik alanındaki gelişmeler sayesinde gerçekleşmiştir. EEG'nin kuvvetlendirilerek kağıt üzerine kayıt edilmesini ilk olarak 1934 yılında Adrian ve Matthews gerçekleştirmiştir. Ayrıca 1936 yılında gözlerin açık olmasına rağmen sesin uyarıcı olarak EEG'nin üzerinde etkili olduğu P.A. Davis tarafından tespit edilmiştir (Yazgan ve Korürek,1996, Niedermeyer, 2005).

Günümüzde EEG kayıtlarının incelenmesi ve anlamlı bir verinin elde edilmesi için çok sayıda çalışma yapılmıştır. Bu çalışmalardan bazıları aşağıda anlatılmaktadır.

Schröder, 1995 yılında yaptığı çalışmada DD' nin işaret işleme alanında en güçlü analiz yöntemi olduğunu ileri sürerek bir küre üzerinde dalgacık fonksiyonu çalışma yapmıştır. Diğer klasik analiz yöntemlerinin sadece basit dikdörtgenel

yapılarda işlem yapabildiğini DD' nin ise küre gibi yapısal olarak karışık olan şekillerde bile analiz yapabileceğini göstermiştir (Schröder and Sweldens, 1995).

Amara Grap, yaptığı çalışmada Fourier Dönüşümü ile Dalgacık Dönüşümü arasındaki farklılıkları araştırmış ve dalgacık dönüşümünün kullanım alanlarından bahsetmiştir (Grap, 1995).

Xizheng ve Arkadaşlarının, dalgacık dönüşümünün zaman-frekans analizi ile işlenmesi üzerine yayınladıkları çalışmada EEG işaretleri üzerindeki gürültülerin DD ile daha iyi temizlendiğini ortaya koyulmuştur (Xizheng ve Ark., 2010).

Amcalar ve Çetin EEG tabanlı beyin-bilgisayar arayüzü ile heceleme problemini araştırdıkları çalışmada, ayarlanabilen görsel uyaran kullanarak EEG'de öngörülmeyen uyarılara tepki sonucu çıkan P300 dalgasının varlığı ve yokluğundaki EEG verilerini kayıt etmişlerdir (Amcalar ve Çetin, 2010). Deneğin yazmaya çalıştığı harfle ilgili EEG işareti Bayes doğrusal ayraç analizine dayalı sınıflandırıcı ile sınıflandırılmıştır. Sonuçta bulunan yöntemin çevrim içi çalışan diğer yöntemlere göre daha iyi sonuçlar verdiği belirtilmiştir.

Bir başka çalışmada Gandhi ve arkadaşları, EEG işaretlerinin analizinde dalgacık dönüşümü dalgalarından hangisinin daha iyi sonuç vereceğini araştırmıştır (Ghandi ve Ark., 2011). Çalışmada Haar, daubechies, coiflets ve biorthogonal dalgacıkları karşılaştırılmıştır. Bu karşılaştırma sonucunda coiflets dalgacığının diğerlerine göre daha iyi sonuç verdiği belirtilmiştir.

İnsan beyni her anında sürekli olarak işaret üreten bir merkezdir. Kişinin uyuması, uyanık olması veya anestezi altında olması beynin işaret üretmesine engel değildir. Coşkun ve İstanbullu yapmış oldukları çalışmada anestezi altındaki hastanın EEG kayıtlarını DD ve FD ile analiz etmişlerdir (Coşkun M. ve İstanbullu A., 2012). Bu analiz sonucunda anestezi altındaki hastaların EEG'lerinin güç yoğunluğu analizlerinde DD' nin FD'ye göre çok daha iyi sonuçlar verdiğini ortaya koymuşlardır.

Geetha ve Geethalakshmi, EEG verilerindeki gürültünün dalgacık dönüşümü ile temizlenebildiğini göstermişlerdir (Geetha and Geethalakshmi, 2012).

EEG çeşitli hastalıkların teşhisleri için önemli verileri içerisinde bulunduran işaretlerdir. Übeyli ve Güler 2004 yılında yaptıkları çalışmada DD' nin EEG gibi durağan olmayan işaretlerin analizinde daha başarılı olduklarını ortaya koymuştur. Ayrıca aynı çalışmada EEG işaretlerinin analizinde kullanılan öznitelik vektörlerinin sayısının azaltılmasında Dalgacık Dönüşümünün etkisi ortaya konmuştur (Übeyli, E.D., ve Güler, İ., 2004).

Ömer Demir, 2008 yılında yapmış olduğu yüksek lisans tezinde hastaların travmalarının derecesini, EEG dalgalarını dalgacık dönüşümü ile analiz ederek bulmuştur. Analiz sonucunda bulunan değer ile hekimlerin hasta için yapmış oldukları travma derecesi %73,96 oranında aynı olmuştur (Demir, 2008).

EEG epilepsi teşhisi, nöbet teşhis ve tahmini çalışmalarında sıklıkla kullanılmıştır. Subaşı ve arkadaşları, epileptik nöbet tahmini için lojistik regresyon ve dalgacık dönüşümüne dayalı olan dalgacık yapay sinir ağlarını kullanmışlardır (Subaşı, A, 2005). Çalışmada hasta olmayan ve epilepsi hastası olan bireylerden alınan EEG verileri kullanılmıştır. Dalgacık yapay sinir ağlarının tahmin sonuçlarının lojistik regresyon tahmin sonuçlarına göre daha başarılı oldukları rapor edilmiştir. Bir başka çalışmada EEG işaretlerinden dalgacık dönüşümü ve yapay sinir ağları kullanılarak yapılan epilepsi teşhisinin, ham EEG verileri ile yapılan teşhislere göre daha iyi sonuç verdiği tespit edilmiştir (Batar, 2005). Subaşı yaptığı çalışmada, EEG işaretlerini ayrık dalgacık dönüşümü ile alt bantlarına ayırarak epileptik nöbet tahminlerinde %94 oranında başarı sağlamıştır (Subaşı, 2007). Toprak 2007 yılında yapmış olduğu yüksek lisans çalışmasında epilepsi teşhisi için EEG verilerini kullanarak dalgacık dönüşümü ile öznitelik çıkarımı yapmış ve bu öznitelikleri yapay sinir ağlarında kullanılan öğrenme algoritmalarından Broyden-Fletcher-Goldfarb-Shanno (BFGS) ile sınıflandırarak %99,81 başarı elde etmiştir (Toprak, 2007). Orhan ve arkadaşları dalgacık dönüşümü katsayılarını kullanarak çok katmanlı algılayıcı yapay sinir ağları ile epilepsi teşhisinde iki farklı deney hazırlamıştır. Bu deneylerden ilk deneyde 50 sağlıklı, 45 atak geçirmeyen epilepsi hastası ve 55 atak geçiren epilepsi hastasından oluşan üç veri kümesi kullanılmış ve sonuçta %99,60 oranında başarı sağlanmıştır, ikinci deneyde ise 202 adet sağlıklı ve atak geçirmeyen epilepsi hastaları ile 48 adet atak geçiren epilepsi hastasından oluşan beş veri kümesi kullanılmış ve sonuçta %100 oranında

başarı sağlamıştır (Orhan ve Ark., 2010). Kaya ve arkadaşları epileptik işaretlerin sınıflandırılması için EEG işaretlerinin dalgacık dönüşümü ile spektral çözümlemesini yaptıktan sonra karar ağaçları ve karar kuralları yöntemlerini kullanarak %96.6 ve %99.70 oranında sınıflandırma başarısı sağlamışlardır (Kaya ve Ark., 2012). Chen, 2014 yılında yaptığı çalışmada epilepsi teşhisi ve nöbet algılamasında FD özelliklerini kullanarak, dual-tree complex wavelet (DTCWT) denilen metot yardımıyla sınıflandırma yapmış ve bornn üniversitesinin veri tabanında %100 sınıflandırma başarısı sağlamıştır (Chen, 2014).

Son yıllarda EEG işaretlerinden duygu tanıma çalışmaları hız kazanmış ve bu konuda pek çok çalışma yapılmıştır. Liu ve arkadaşları tarafından yapılan çalışmada Uluslararası Duyuşsal Sayısallaştırılmış Sesler veri tabanından sesler deneklere dinletilmiş ve bu işlem sırasında EEG verileri kayıt edilmiştir. Gerçek zamanlı algoritma ile korku, sinirli, üzgün, mutlu, keyifli ve memnuniyet duyguları test edilmiştir (Liu ve Ark., 2011). EEG işaretleri üzerine yapılan bir diğer çalışma ise Uzun ve arkadaşlarının duygu tahmini üzerine yaptıkları çalışmadır. Bu çalışmada bireyin duygu durumu, kayıt edilen EEG verilerinin, DD ile analizi sonucu destek vektör regresyon yöntemi kullanılarak tespit edilmeye çalışılmıştır (Uzun ve Ark., 2012)

Culpepper, çalışmasında, zihinsel durumları EEG işaretlerinin güç spektrumlarını kullanarak ayırt etmeyi başarmıştır. Çalışmasında 12 kanal üzerinden veriler toplamış ve bu verileri üç katmanlı ileri beslemeli yapay sinir ağlarını kullanarak eğitmiştir. Çalışması sırasında EEG verilerindeki artefakt etkilerini ayırt etmek için bağımsız bileşen analizi adı verilen (ICA) kullanılmıştır. Çalışma sonucunda iki görev arasındaki farklılıklar %85 oranında doğru şekilde ayırt edilmiştir (Culpepper,1999).

Nelson ve Arkadaşları Bayesian modelini EEG/MEG görüntüleme de oluşan ters problem sorununu gidermek için kullanmışlardır (Nelson ve Ark., 2003).

Aydemir ve Kayıkçıoğlu yaptıkları çalışmada EEG işaretlerinin öznitelik vektörlerini oluşturarak, Bayesian, destek vektör makineleri (DVM), k en yakın komşuluk (kNN), doğrusal ayırt eden analizi ve sinir ağlarını kullanarak sınıflandırmışlardır (Aydemir ve Kayıkçıoğlu, 2009). Bunun sonucunda düşük boyutlu

öznitelikler için kNN, büyük boyutlu öznitelikler için DVM'nin en iyi sonuçları verdiğini ortaya koymuşlardır.

Ersöz ve Özşen, uyku evrelerinin tespiti için uyku halinde kayıt edilen EEG işaretinin dalgacık dönüşümü katsayılarının alınması ve yapay sinir ağları ile sınıflandırılması üzerine yaptıkları çalışmada YSA öğrenme katsayılarını, gizli katman sayılarını ve iterasyon sayılarını değiştirilerek optimum çözümü sağlayan YSA modelini yapmışlardır (Ersöz ve Özşen, 2011)

Aljazery ve arkadaşları EEG işaretlerinin Kuantum sinir ağları ile sınıflandırılması üzerine bir çalışma yapmışlardır (Aljazery ve Ark, 2011). Çalışmada kuantum sinir ağı ile ileri beslemeli sinir ağları karşılaştırılmıştır. EEG verilerinin analizi ve öznitelik çıkarımı için dalgacık dönüşümü, bağımsız bileşen analizi ve fourier dönüşümü kullanılmıştır. Sonuç olarak kuantum sinir ağları yapısının her üç öznitelik çıkarımında da ileri beslemeli sinir ağlarına göre daha iyi sonuçlar verdiğini göstermiştir. Kuantum sinir ağı ile elde edilen sonuçlar, bağımsız bileşen analizi, dalgacık dönüşümü ve fourier dönüşümü için sırasıyla %81,83, %76,67 ve %67,33 olarak rapor edilmiştir.

Araştırmacılar okuma ve problem çözme işlemleri sırasında oluşan sinyallerin farklılıklarının tespiti ve sınıflandırılması için çeşitli çalışmalarda bulunmuşlardır. Oliveria ve arkadaşları okuma ile okumanın olmadığı durumlarda EEG sinyallerini en yakın komşuluk algoritması (kNN, k=5) ile %84,41 doğru pozitif ve %15,59 yanlış pozitif değeri ile sınıflandırmışlardır (Oliveria, 2009)

Mostow ve diğerleri ise yetişkinlerin ve çocukların kolay ve zor metinleri okurken tek kanallı EEG ile kayıtlarını yapmış ve çalışma sonunda EEG işaretlerinden okuyucunun yetişkin veya çocuk olduğunu ve okunmuş olan metnin zorluk derecesini ayırt edebilmişlerdir (Mostow ve Ark., 2011).

Diğer bir çalışmada Federice C.G. ve Carole R.B. 16 öğrenci üzerinde yaptıkları deneylerde öğrencilerin matematik sınav sorusu çözerken çekilen EEG sinyallerinden öğrencinin soruyu doğru ya da yanlış cevapladığını rastgele bir tahminciden daha iyi tahmin edilebilmiştir. Kolay problemlerde %87 başarı sağlanırken zor problemlerde ise %78 tahmin başarısı sağlamıştır (Galán ve Beal, 2012).

Yapılan alıřmada diđer alıřmalardan farklı olarak, sayısal iřlemlerin ve metinlerin yer aldıđı grseller esnasında kaydedilen EEG iřaretlerinin ayırt edilmesi ve bu analiz iin kanalların etkisinin incelenmesi hedeflenmiřtir.

3. MATERYAL VE YÖNTEM

Bu bölümde yapılan işlemler ve kullanılan yöntemler hakkında bilgi verilecektir.

Şekil 3.1’de çalışmanın işlem basamakları verilmiştir.



Şekil 3.1 İşlem Basamakları


3.1. İşaret İşleme Yöntemleri

EEG işaretleri beynin fonksiyonları ile ilgili önemli bilgiler içermektedir. Ancak, ham EEG verilerinden anlamlı bilgiler elde edilebilmesi için çeşitli işaret işleme yöntemleri kullanılmalıdır. Biyomedikal işaretlerin işlenmesinde sıklıkla kullanılan işaret işleme yöntemleri olarak Fourier Dönüşümü, Kısa Zamanlı Fourier Dönüşümü, Dalgacık Dönüşümü ve Hilbert-Huang Dönüşümü sayılabilir (Polikar, 1999, Ghandi ve Ark., 2011, Özdemir ve Ark., 2012, Chen, 2014).

İşaret işlemede boyut değişim işlemi için Kısa Zamanlı Fourier Dönüşümü, Fourier Dönüşümü, Hilbert ve Dalgacık Dönüşümü gibi birçok yöntem kullanılmaktadır (Polikar, 1999).

3.1.1. Fourier Dönüşümü

19. yy'da Fransız bilim adamı Fourier tarafından bulunan bu işaret işleme yöntemi, bir periyodik fonksiyonun sonsuz sayıdaki karmaşık üstel fonksiyonların toplamı ile ifade edilebileceğini belirtmektedir (Batar, 2005, Oppenheim ve Ark., 2014). görüldüğü gibi Fourier Dönüşümü zaman temelinde bulunan işaretin frekans temeline dönüştürülmesidir (Şekil 3.1).



Şekil 3.2 Fourier Dönüşümü

Fourier Dönüşümü'nde (FD) işaretin karakteristiğinin zamanla değişmediği varsayıldığı için işaretin global frekans içeriği elde edilir. Bu da zaman bilgisinin kaybına neden olur. FD'deki bu eksiklik, işaretin pencerelelenerek işleme tabi tutulduğu Kısa Zamanlı Fourier Dönüşümü (KZFD) ile giderilmiştir (Allen, 1977).

KZFD ile orijinal işaret sabit uzunluklu pencerelere bölünür ve bu pencereler kendi içerisinde FD işleminden geçirilir. Bu pencere içerisinde işaret durağan kabul edilir, pencere fonksiyonu işaretin sonuna kadar kaydırılarak dönüşüm tamamlanır.



Şekil 3.3 KZFD grafiksel görünümü

3.1.2. Sürekli Dalgacık Dönüşümü

Biyolojik işaretlerin büyük bir çoğunluğu durağan olmayan yani genlik ve frekans bilgisi zamana bağlı değişen işaretlerden oluşmaktadır. Bu nedenle biyolojik işaretler FD ile eksiksiz olarak analiz edilememektedir. KZFD yöntemi ile işaret pencerelenerek küçük parçalara ayrılmış ve her parçadaki frekans içeriklerinin bulunması ile zamana bağlı değişen spektral analizin yapılabilmesi mümkün olmuştur. Ancak KZFD’de kullanılan pencere boyutunun sabit olması nedeniyle, KZFD işaretin zaman-frekans içeriğini sabit frekans ve zaman çözünürlüğü ile verir. Ancak yüksek frekans içerikleri için zaman çözünürlüğü, düşük frekanslar için olduğundan daha önemlidir.

Sürekli Dalgacık Dönüşümü (SDD), FD ile benzer şekilde, işaretin bir analiz fonksiyonu ile konvolüsyonu olarak hesaplanmaktadır. Ancak FD’deki trigonometrik temel analiz fonksiyonları DD’de dalgacık fonksiyonu ile değiştirilmiştir. Dalgacık fonksiyonu sabit frekans içerikli trigonometrik fonksiyonunun aksine farklı frekans içeriklerine sahip bir fonksiyondur. Zaman bilgisi dalgacık fonksiyonunun işaret boyunca kaydırılması ile elde edilir. Frekans bilgisi ise dalgacıktaki açılma ve daralmalar sayesinde yakalanır.

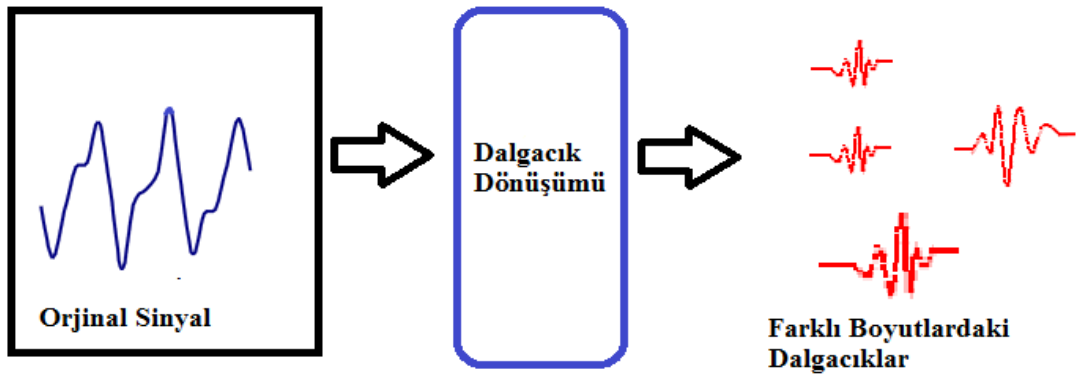
SDD aşağıdaki şekilde tanımlanmıştır (Addison, 2002):

$$SDD_x^\Psi(\tau, s) = W_x(\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} X(t) \cdot \Psi^* \left(\frac{t - \tau}{s} \right) dt \quad (3.1)$$

$SDD_x^\Psi(\tau, s)$ dönüşüm parametresi τ ve ölçek parametresi s 'ye bağlıdır. $\Psi(t)$ dönüşüm fonksiyonudur ve ana dalgacık olarak adlandırılır. Dönüşüm için kullanılan diğer pencere fonksiyonları bu ana dalgacıktan türetilmektedir. İşaretin enerjisi, dalgacık katsayılarının $1/\sqrt{|s|}$ ile bölünmesiyle her ölçekte normalize edilmiştir. Böylelikle her ölçekte aynı enerji elde edilir.

Ana dalgacıkta ölçek parametresi s 'nin değişmesiyle açılır ve daraltılır. Ölçek parametresindeki değişim ile sadece merkez frekansı değil pencere uzunluğunu da değiştirir. Bu nedenle dalgacık analizi sonucunda, frekans yerine ölçek parametresi s kullanılır. Dönüşüm parametresi τ 'nin değişmesiyle dalgacık işaret üzerinde kaydırılır ve dalgacığın zamandaki yeri belirlir.

SDD' de ötelemenin yanı sıra ölçekleme işleminin işaretlerin frekans bantlarında çok daha net çözünürlük vermelerini sağlamaktadır. Yüksek ölçek değerleri düşük frekansa, düşük ölçek değerleri ise yüksek frekans karşılık gelmektedir. Orijinal işaretin tüm zamanlarında ve frekanslarında sabit çözünürlük veren KZFD' nin aksine, SDD yüksek frekanslarda zamanda iyi çözünürlük verirken, düşük frekans bileşenlerinde ölçek ya da frekansta çok iyi çözünürlük sağlamaktadır.



Şekil 3.4 Dalgacık Dönüşümü Grafikselsel Gösterimi

Dalgacık teorisinin işaretlerin analizi ve sentezi için güçlü bir matematiksel araç olduğu kanıtlanmıştır. Fizik, jeofizik, sayısal analiz, işaret işleme, biyomedikal mühendislik ve istatistik gibi disiplinlerin birçoğunda başarılı şekilde uygulamaktadır. Bu dönüşüm özellikle dijital işaret işleme çalışmalarında ani değişimlere verdiği analiz


desteğinden dolayı diğer dönüşümlere göre tercih edilmeye başlanmıştır. Özellikle verilerin sıkıştırılması, gürültünün azaltılması, işaretin güçlendirilmesi ve özellik algılaması gibi alanlarda gerçekleştirilen çalışmalarda kullanılmaktadır (Wei, D., 1998).

Ayrık Dalgacık Dönüşüm (ADD), dalgacık analizi için filtre bankaları kullanır. İşaret, orijinal işaretin yeniden elde edilebileceği şekilde, dalgacık katsayılarına ayrıştırılır. Bu katsayılar işaretin farklı frekans bantlarında temsil edilmiş şeklidir.

3.1.3. Ayrık Dalgacık Dönüşümü

SDD ana dalgacığın açılıp daraltılması ile çok çözünürlük sağlarken, Ayrık Dalgacık Dönüşümünde (ADD) analiz için filtre bankaları kullanır.

Filtre bankası işareti frekans bantlarına ayıran filtrelerden oluşur (Strang and Nguyen., 1997). İki kanallı örnek bir filtre bankası Şekil 3.5’de gösterilmektedir. Ayrık zamanlı bir işaret analiz edildiğinde, işaretin frekans içeriğini eşit parçalara bölen yüksek ve alçak geçiren filtrelerden geçirilirler. Şekilde $H(z)$ yüksek geçiren filtreyi, $L(z)$ ise alçak geçiren filtreyi temsil etmektedir. Filtre bankasının alçak ve yüksek geçiren filtre dalları, $x(k)$ için sırasıyla yaklaşım ve detayları vermektedir.



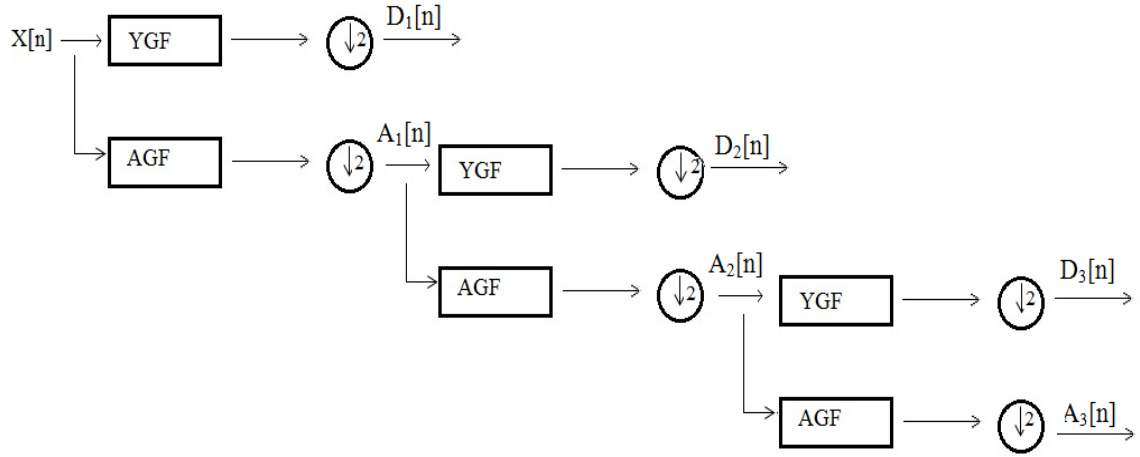
Şekil 3.5 İki kanallı filtre bankası

İşlem sonucunda elde edilen filtre sonuçları, giriş işaretinin frekans içeriklerinin yarısına sahip olmasına rağmen giriş işareti ile aynı sayıda örneğe sahiptir. Bu nedenle alt örnekleme yapılarak çıkışlardaki toplam örnek sayısındaki fazlalık yok edilir.

Filtre bankası istenen çözünürlüğe bağlı olarak istenildiği kadar genişletilebilir. Her seviyede frekans içeriği ikiye bölünür, yüksek geçiren filtre sonucunda elde edilen katsayılar $x(k)$ 'nin frekans içeriğinin üst yarısını simgelerken, alçak geçiren filtre

sonucunda elde edilen katsayılar alt yarısını simgeler. Bu işlem istenilen frekans çözünürlüğü elde edilene kadar tekrarlanabilir.

Şekli 3.6' de görüldüğü gibi orijinal işarete uygulanan alçak ve yüksek geçiren filtre fonksiyonları olan Dubechies, biortogonal, Symlet ve Coiflet dalgacıkları kullanılmıştır.



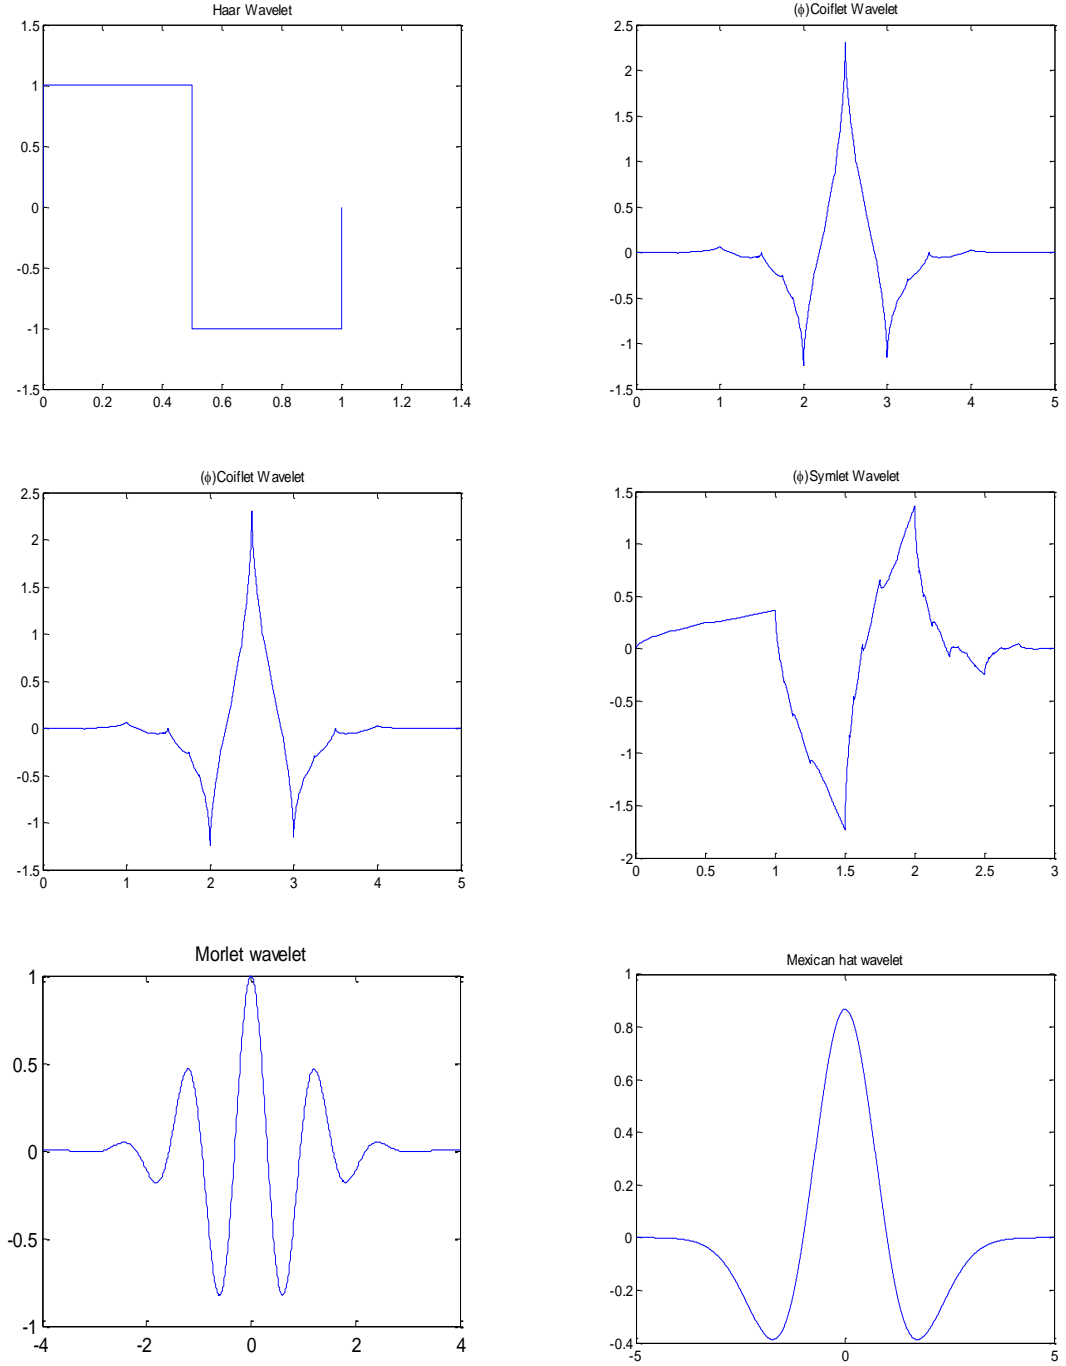
Şekil 3.6 ADD katsayıları

3.1.4. Dalgacık Dönüşümünde Kullanılan Dalgacıklar

Dalgacık Dönüşümü, günümüzde işaret işleme alanında sık kullanılan bir yöntemdir. Dalgacık terimi ilk olarak 1909 yılında Alfred Haar tarafından kullanılmıştır (Haar, 1910). Günümüzde kullanılan dalgacık dönüşümünün temeli 1984'te yapılan çalışmaya dayanmaktadır (Grossmann and Morlet, 1984).

Dalgacık dönüşümü diğer yöntemlere göre nispeten yeni bir işaret işleme yöntemidir. Çoğu araştırmacı modern dalgacık teoremini 1984 yılında yayınlanan çalışmasıyla Fransız fizikçiler Jean Morlet ve Alexander Grossman'dır. Daha sonra 1989 yılında Yves Meyer ve 1992 yılında Stephane Mallat ayrı ayrı yaptıkları çalışmalarda çoklu analiz yöntemlerini dalgacık dönüşümün de geliştirmiştir. Ingrid Daubechies ise 1988-1993 yılları arasında Daubechies dalgacıklarını geliştirerek bir çok çalışma yayınlamıştır (Hubbard, B.B., 1998).


Günümüzde sıklıkla kullanılan dalgacıklardan bazıları; Haar, Coiflets, Daubechies, Biorthogonal, Symlets, Morlet ve Mexican Hat dalgacıklarıdır ve Şekil 3.7’de gösterilmiştir (Misiti ve Ark., 1996).



Şekil 3.7 Kullanılan Bazı Dalgacık Türlerinin Grafikleri

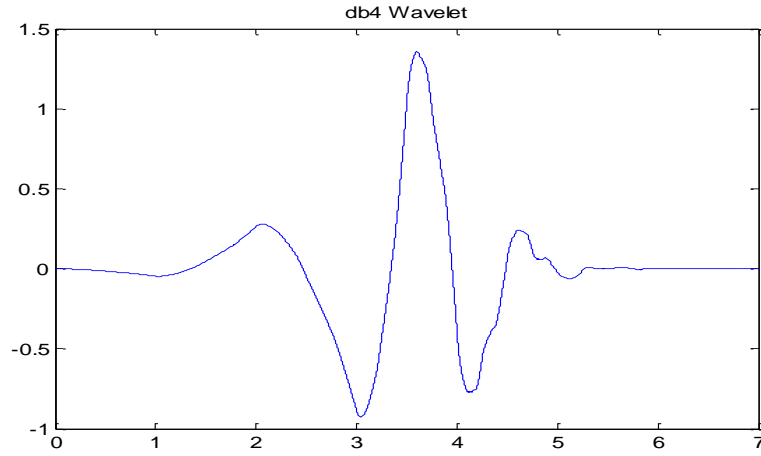
3.1.5. Daubechies Dalgacıđı

Ingrid Daubechis tarafından geliřtirilen bu dalgacık türü günümüzde en çok kullanılan dalgacık türüdür (Daubechies, 1990). Dalgacıkların isimlendirilmesi db1, db2, db3, db4,..... dbN řeklinde olmaktadır. Bu dalgacıklardan ilki olan db1 Haar dalgacıđı ile aynı řekle sahiptir. řekil 3.8’ de diđer daubechies dalgacıklarından bazıları gösterilmiřtir (Misiti, M. Ve Ark., 1996).



řekil 3.8 Daubechies Dalgacıkları


Bu alıřmada řekil 3.9’de gösterilen db4 dalgacıđı kullanılmıřtır.



Şekil 3.9 Daubechies Dalgacıklarından db4 Dalgacıđı

3.2. Verilerin Toplanması

Bu alıřmada 19-24 yař arasında, her hangi bir sađlık problemi bulunmayan, sayısal ve szsel blmlerde eđitim grmekte olan niversite đrencisi deneklerden gnlllk esası ile alınan EEG verileri kullanılmıřtır. Bu EEG verileri Nihon Kohden 1200 marka 32 kanaldan 1kHz rnekleme ile yksek kalitede ekim yapabilen, řebeke grltlerini otomatik temizleyebilen dijital EEG ekim cihazı ile kaydedilerek zgn bir veritabanı elde edilmiřtir. řekil 3.10 cihazın elektrot bađlantı parasını gstermektedir.




Şekil 3.10 Nihon Kohden 1200 Marka EEG ekim Cihazı

3.2.1. Elektrotların Bağlantı Şekli


Bu cihaz 32 kanallı yüksek kalite ve güvenilirlikte EEG çekimi yapan bir cihazdır. Çalışmada deneklerden, Amerikan EEG derneğinin klinik EEG çekimlerinde uyguladığı uluslararası 10-20 standardına uygun olarak, 22 elektrot üzerinden 26 kanallı veri kayıt edilmiştir.

26 kanal referans noktalarına göre oluşmaktadır. Bu kanallar; Fp1-A1, Fp2-A2, F3-A1, F4-A2, C3-A1, C4-A2, P3-A1, P4-A2, O1-A1, O2-A2, F7-A1, F8-A2, T3-A1, T4-A2, T5-A1, T6-A2, Fp2-O2, Fp1-O1, Fp1-Fp2, F7-F8, F3-F4, T3-T4, C3-C4, T5-T6 P3-P4 ve O1-O2'dir.

Elektrotlar kafa derisi üzerine EEG pastası yardımı ile tutturulur, 10-20 sisteminde kafa dört bölüme ayrılır. Bu bölümler burun köprüsü, kafa arkası, sol kulak ve sağ kulak'tır. Şekil 3.11 de uluslararası 10-20 sisteminin bağlanma şekli vardır (American EEG Society., 1991). Elektrotların yerleştirilme şekli Şekil 3.12'de verilmiştir. Şekil 3.13, Şekil 3.20 ve 3.21 de kayıt esnasında çekilen resimlerden örnekler görülmektedir.



Şekil 3.11 Uluslararası 10-20 sistemi



Şekil 3.12 EEG kaydı için elektrotların 10-20 sistemine göre yerleştirilmesi (üstten görünüm)



Şekil 3.13 Deney Sırasında Elektrotların Yerleşiminin Görünümü

3.2.2. Slayt Düzeni ve Örnekleri

Çalışmada deneklere, Türkçe metinler içeren sözel ve dört işlem içeren sayısal slaytlar gösterilmiştir. Slaytların her biri 13,25 saniyelik olup toplam 60 slayttan

oluşmaktadır. Slaytlar arası bekleme süresi verilmemiştir. Slaytlardan ilk 30'u sayısal işlemlerden, sonraki 30'u ise metinlerden oluşmaktadır. Sayısal işlem içeren slaytlarda dört işlemi içeren slaytlar karışık sıra düzeninde gösterilmiştir. Şekil 3.14, şekil 3.15, şekil 3.16, ve şekil 3.17 sayısal işlemler için örnek slaytlardır.

$$\begin{array}{r} 17584 \\ + 9108 \\ \hline \end{array}$$

Şekil 3.14 Sayısal Slaytlarda Toplama İşlemi Örnek-1

$$\begin{array}{r} 7393 \\ - 3450 \\ \hline \end{array}$$

Şekil 3.15 Sayısal Slaytlarda Çıkarma İşlemi Örnek-2

$$\begin{array}{r} 10426 \\ * \quad 3 \\ \hline \end{array}$$

Şekil 3.16 Sayısal Slaytlarda Çarpma İşlemi Örnek-3

$$\begin{array}{r|l} 32211 & 90 \\ \hline \end{array}$$

Şekil 3.17 Sayısal Slaytlarda Bölme İşlemi Örnek-4

Sözel işlem olan slaytlarda ise çeşitli metinler hazırlanmıştır. Metinlerin seçiminde dil kurallarına uygunluk dikkate alınmıştır. Şekli 3.18 ve 3.19 sözel metinlere örnektir.

Çağdaşlaşma denildiğinde, çağımızın özlemleri, gereksinimleri,akımları karşısında duyarlı ve hoşgörülü olmayı anlıyoruz. Çağdaş insan , çevresiyle,ülkesiyle hatta dünya ile birlikte yaşar; çevresinin sorunlarıyla yüklüdür ve huzursuzdur. Bu insanda mutluluk değerleri toplumsal ve evrenseldir.

Şekil 3.18 Sözel Slaytlardan Örnek-1

Dünyada kötülükler olduğu sürece şiddet de olacaktır.Şiddet,şiddetle değil, sevgiyle ortadan kaldırılır. Güzelliklere, güzel duygularla yaklaşmak kolaydır. Önemli olan,insanlık için olumsuzluk olan durumların karşısına güzel duygularla çıkmaktır.

Şekil 3.19 Sözel Slaytlardan Örnek-2

3.2.3. EEG Kaydı Öncesinde ve Kayıt Sırasında Dikkat Edilen Hususlar

Çekimden önce ve çekim sırasında önemli olan hususlar deneklere şu şekilde ifade edilmiştir:

- Denekler saçlarının temiz olması, jöle gibi saç şekillendiricilerinin olmaması ve saçların kısa olması konusunda uyarılmıştır.
- Deneklere çekimden önce herhangi bir ilaç kullanmamaları gerektiği söylenmiştir.
- Deneklerden işlemleri yapmaya çalışmaları istenmiş, heyecan faktörüne karşılık, işlemlerin yetiştirilmesi ve metinlerin tamamının zaman içerisinde okumalarının gerekli olmadığı vurgulanmış ve sadece ekrandaki sayısal işleme veya sözel metine odaklanmaları gerektiği ifade edilmiştir.
- Deneklere çekim sırasında el, kol, kafa, bacak ve göz gibi organlarını oynatmamaları gerektiği söylenmiş ve başlangıçta rahat pozisyonda oturmaları sağlanmıştır.



Şekil 3.20 EEG kaydı Alınırken Oturuş Pozisyonu (üstten görünüm)

Çekimler esnasında ortam gürültüden arındırılmış ve iyi derecede ışıklandırma sağlanmıştır. EEG kaydı ile slayt gösterimi aynı anda başlatılıp bitirilmiştir.



Şekil 3.21 EEG Kayıt Odası

EEG kayıtları 1kHz örnekleme frekansı ile alınmıştır. Kayıt sırasında şebekeden kaynaklanan 50Hz'lik gürültü cihaz tarafından temizlenmiştir. Kayıt edilen veriler kayıt sırasında cihazın otomatik alçak geçiren filtresi ile filtrelenmiş, kesme frekansı olarak 120 Hz ayarlanmıştır.

3.3. Veri Setinin Ayrıştırılması ve Öznitelik Çıkarımı

Çekim sonrası elde edilen EEG işaretlerinin özniteliklerinin çıkarılması için veri setinin parçalara ayrılması gerekmektedir. Bu bölümde veri setinin ayrılması ve özniteliklerinin çıkarılma aşamaları anlatılmaktadır.

3.3.1. Veri Setinin Ayrıştırılması

Çalışmada çekimlerden sonra slâytların süresi olan 13,25 sn dikkate alınarak, kayıt edilen EEG veri seti sayısal ve sözel veri setlerine ayrıştırılmıştır. Bu işlem sırasında senkronizasyondan dolayı oluşabilecek sıkıntıları gidermek için aşağıdaki işlemler yapılmıştır.

1. Slayt gösteriminin bitiminde EEG kaydı sonlandırılmasına rağmen, 1-2 saniyelik senkronizasyon uyumsuzluğu oluşmuştur. Bunun giderilmesi için çekimlerin son bölümü olan sözel slaytların sonuncuları veri setinden çıkarılmıştır.

2. Çekim için kayıt düğmesine basıldığında cihazın özelliğinden dolayı yaklaşık olarak 1,5 sn. sonra kayda başlamaktadır. Bu süreden dolayı meydana gelen uyumsuzluğu gidermek için kayıtların başındaki sayısal veri setinden bir slaytlık bölümler çıkartılmıştır.

Böylelikle veri setimizde her slayt için Şekil 3.22’de görüldüğü gibi 13250x26 boyutunda matris bulunmaktadır. Bu veri setlerinden toplam 29 adet sayısal slayta ait veri seti, 29 adette sözel slayta ait veri seti elde edilmiştir.

Bu veri setini oluşturan matriste örnekleme frekansı 1 kHz, bir slaytın toplam süresi 13,25 sn’dir. Bu nedenle her slayt için toplam 13250 örnek bulunmaktadır. EEG kaydı da 26 kanaldan oluşmaktadır.

		KANALLAR																											
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26		
1 Slaytlık Verinin Uzunluğu	1																												
	2																												
	3																												
	4																												
	5																												
	6																												
	7																												
	8																												
	9																												
	13247																												
	13248																												
	13249																												
	13250																												

Şekil 3.22 1 Slayta Ait Veri Setinin Matrisi

Şekil 3.23’ de verilen 1 slayta ait olan veriler sayısal ve sözel veri setleri olarak yukarıda belirtilen senkronizasyon durumları dikkate alınarak EEG kaydı şekil 3.23’de olduğu gibi sayısal veri setine, Şekil 3.23’de olduğu gibi sözel veri setine ayrıştırılmıştır.



Şekil 3.23 Sayısal Veri Seti Şeması



Şekil 3.24 Sözel Veri Seti Şeması

Her bir denek için, şekil 3.23 ve şekil 3.24 incelendiğinde, her iki veri kümesinde 29 adetlik slayt veri setlerinin sayısal ve sözel olarak ayrılmış halde olduğu görülmektedir.

Şekil 3.25’de görüldüğü gibi EEG veri setlerinden sayısal ile sözel veri setleri ayrıştırılmalarında daha sağlıklı sonuçlar ve senkronizasyondan kaynaklanabilecek sıkıntıları gidermek için, sözel veri seti ile sayısal veri setinin birleştirildiği noktalardaki slaytlar ile her slayt setinin sondan bir önceki slaytları işlem dışında tutulmuştur. Böylelikle ayrıştırılmış veri setleri ile sadece sayısal ve metinsel işlemler içeren verileri elde etmiş olduk.



Şekil 3.25 Tüm Sayısal ve Sözel Veri setleri Gösterimi

3.3.2. Özniteliklerin Çıkarılması

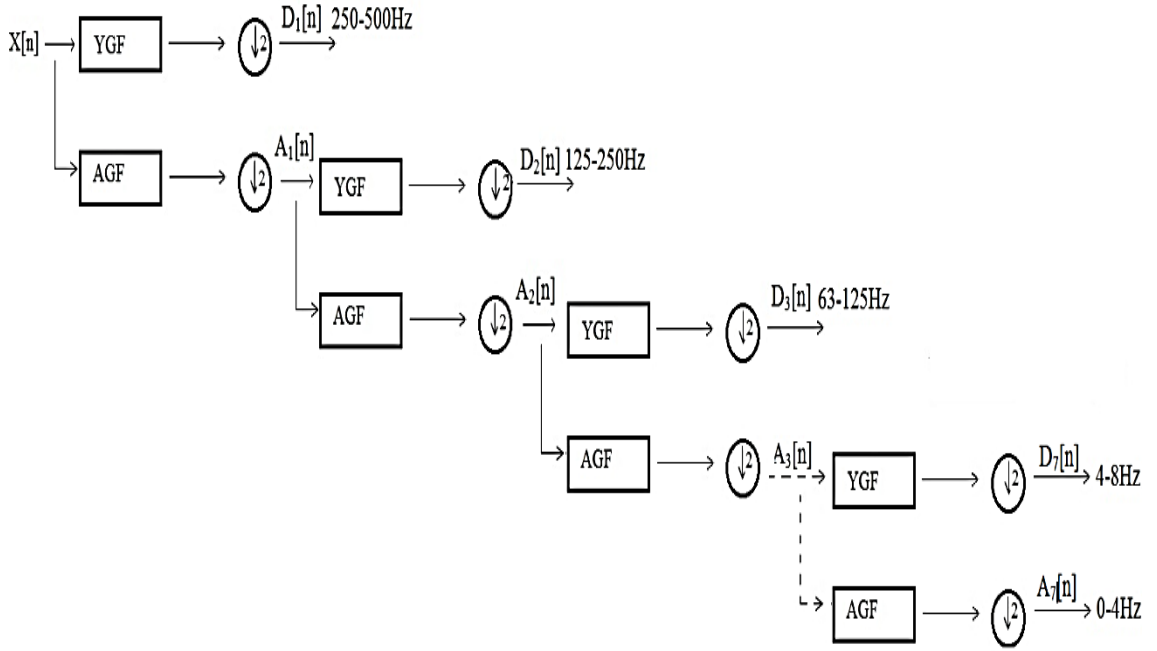
Toplanan EEG verilerinden anlamlı bilgi elde edilmesi ve sınıflandırılmanın başarılı bir şekilde yapılabilmesi için öznitelik vektörlerinin uygun şekilde oluşturulması önemlidir.

Bu çalışmada öznitelik vektörlerinin oluşturulması için EEG işaretleri gibi ani değişen işaretlerin analizinde FD' ye göre daha etkin olan ve birçok çalışmada kullanılan DD kullanılmıştır (Übeyli ve Güler, 2004, Übeyli, 2007, Coşkun ve İstanbullu, 2012). Kullanılan sistem ana hatlarıyla Şekil 3.1'de gösterilmiştir. Elde edilen öznitelikler farklı sınıflandırıcılar kullanılarak sınıflandırılmışlardır.

Dalgacık dönüşümü gelen işareti detay ve yaklaşım katsayılarına ayırarak işleme tabi tutan bir dönüşümdür. İşareti istenilen seviyede ayrıştıma tabi tutarak istediğimiz özelliklerde katsayılara ulaşabiliriz.

Çalışmada öznitelik vektörü oluşturulması için Daubechies dalgacık türünün 4. dalgacığı olan Db4 kullanılmıştır. EEG verileri Db4 dalgacığında 7. seviye dönüşüme tabi tutularak D1, D2, D3, D4, D5, D6, D7 detay katsayıları ve A7 yaklaşım katsayısı elde edilmiştir.

1 kHz'lik örnekleme frekansı göz önüne alındığında, ilk üç detay katsayısı yüksek frekans aralığına sahip olduğundan D1, D2 ve D3 katsayıları kullanılmamıştır. Öznitelik vektörü oluşturulurken D4, D5, D6, D7 detay katsayıları ve A7 yaklaşım katsayısı kullanılmıştır.



Şekil 3.27 EEG işaretinin 7. Seviyede Ayrıştırılması

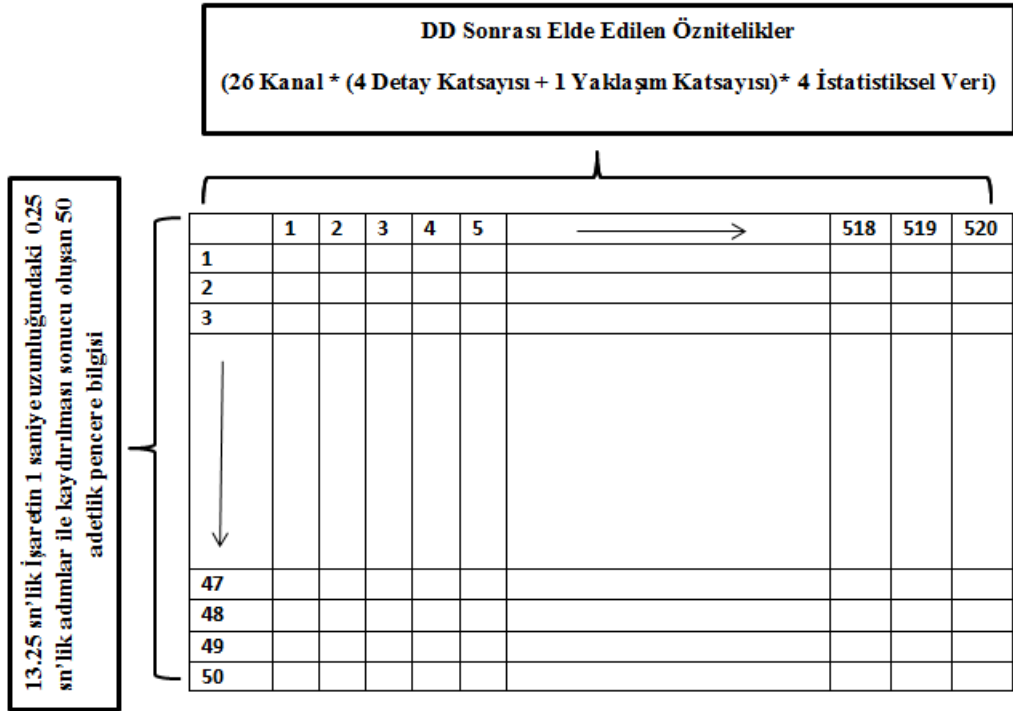
Çalışmada işaretin dalgacık dönüşümü ile işlenmesi sonucunda elde edilen katsayıların, aşağıdaki istatistiksel özelliklerden yararlanarak öznitelik vektörü oluşturulmuştur. (Übeyli ve Güler, 2004).

1. Katsayıların mutlak değerlerinin ortalaması.
2. Katsayıların mutlak değerlerinin maksimumu.
3. Katsayıların mutlak değerlerinin minimumu.
4. Katsayıların standart sapması.

Özniteliklerin elde edilmesi işleminde kayan pencere yöntemi kullanılmıştır. Her slayta ait veriler birer saniye uzunluğunda 0.25 sn'lik kaydırmalar ile oluşan 50 adet pencereye bölünmüş ve her pencere yukarıda belirtilen istatistiksel özellikler kullanılarak öznitelikler elde edilmiştir.

Her pencere için D_4 , D_5 , D_6 , D_7 ve A_7 katsayıları elde edilerek, bu katsayılar için istatistiksel özellikler çıkarılmıştır. Kanal sayısı 26 olduğundan toplamda (26 Kanal * (4 Detay Katsayısı + 1 Yaklaşım Katsayısı) * 4 İstatistiksel Veri) 520 adet öznitelik elde edilerek öznitelik matrisi oluşturulmuştur.

Şekil 3.28’de bir deneğe ait sayısal veya sözel özniteliklerin bir slayta ait matris örneği görülmektedir.



Şekil 3.28 Bir Slayta Ait Öznitelik Matrisi

Her slayt için oluşturulan 50x520’lik matrisler alt alta eklenerek bir deneğe ait sayısal ve sözel öznitelik matrisleri oluşturur. Bir deneğe ait 27 slaytlık öznitelik matrisi örneği Şekil 3.29’ de görülmektedir. Her denek için hazırlanan sayısal ve sözel verilere ait öznitelik matrisleri hazırlanarak eğitim ve test için kullanılmıştır.

DD sonrası elde edilen Öznitelikler
(26 Kanal*(4 Detay Katsayısı+1 Yaklaşım Katsayısı)*4 istatistiksel)

	1	2	3	4	5	→	518	519	520
1									
2									
3									
↓	1. Slayt İçin Olan Öznitelik Vektörleri								
48									
49									
50									
51									
↓	2. Slayt İçin Olan Öznitelik Vektörleri								
98									
99									
100									
1301	27. Slayt İçin Olan Öznitelik Vektörleri								
↓	27. Slayt İçin Olan Öznitelik Vektörleri								
1348									
1349									
1350									

Şekil 3.29 Bir Deneğe Ait 27 Slaytlık Öznitelik Matrisleri

3.4. Sınıflandırma ve Başarım Ölçütü

3.4.1. Sınıflandırıcılar

Verilerin sınıflandırılmasında BayesNet (Deepa ve Thangaraj,2011), kNN (Alzoubi ve Ark., 2008, Murugappan, 2011) ve Karar Ağaç Yapıları (Alzoubi ve Ark., 2008, Kaya ve Ark., 2012) sınıflandırma algoritmaları kullanılmıştır. Çalışmamızda sınıflandırma işlemlerinde açık kaynak kodlu veri madenciliği programı olan WEKA uygulaması kullanılmıştır (Witten ve Frank, 2002, Hall ve Ark., 2009).

3.4.1.1. kNN Teoremi

Bu teorem literatürde bulunan EEG çalışmalarında da çok sık kullanılmaktadır (Qu ve Gotman, 1997, Olivveira ve Ark.,2009, Murugapann, 2011, Pourzare Ark.,2012 ve Özer ve Amasyalı, 2013).

K-En yakın komşu (k-NN) teoremi örnekler arasındaki uzaklık değerine göre çalışan bir teoremdir. Bu teoreme göre veriye en yakın olan k adet nokta seçilir sınıflandırma işlemi bu seçilen k sayısına göre yapılır. K sayısının küçük olması benzerlik oranı en yüksek olan örnekleri bir sınıfta toplamaya yardımcı olurken, k sayısının artışı ile birbirine benzemeyen veriler de aynı sınıfa dahil edilerek yanlış sınıflandırma sonuçları ile karşılaşılabilir (Mitchell, 1997). Bu nedenle k değerinin seçilmesi için yöntemlerden biri de, zaman almasına rağmen, çeşitli k değerleri için sınıflandırma sonuçlarının karşılaştırılmasıdır. Örneğin, Özer ve Amasyalı'nın çalışmasında verilerin sınıflandırılması 1 en yakın komşuya göre yapıldığında ortaya çıkan sınıflandırma başarısı, 3, 5, 7, 9 ve 10 en yakın komşuluk sınıflandırmalarına göre daha iyi sonuç vermiştir (Özer ve Amasyalı, 2013).

Bu metotta veri setinden bir bölüm öğrenme kümesi olarak ayrılır ve eğitim seti olarak kullanılır, bu eğitim seti dışında kalan veri seti ise test için kullanılır. Test için kullanılan verilerin içerisinde bir örnek, eğitim seti içerisinde kendisine en yakın olan k adet örneğin öklid değerine göre en yakın olan eğitim verisini bulur. Bulunan bu veriye göre sınıfı belirlenir, bu işlem test verisindeki tüm verilerin sınıflandırması bitene kadar tekrarlanır (Olivveira ve Ark.,2009, Parvinnia, E., 2014).

3.4.1.2. BayesNet Algoritması (BayesAğ)

Bayesian ağları Bayes teoremine göre çalışmaktadır. Bayes teoremi iki farklı olaya bağlı olarak olasılık hesabına dayanan bir teoremdir.

Birbirinden bağımsız X ve Y olayları için, iki olayın aynı anda oluşma olasılığı iki olayın ayrı ayrı oluşma olasılıkları çarpımına eşittir. Bağımlı olaylarda ise bu olasılık aşağıdaki şekilde elde edilir:

$$P(X\Lambda Y) = P(X) * P(X|Y) \quad (3.2)$$

Bu formül bize X ve Y durumlarının bir arada olma olasılığını vermektedir. Formülde $P(X|Y)$, Y olayının durumunun bilinmesi durumunda X' in meydana gelme olasılığını vermektedir. Bu durumda Bayes teoremi :


$$P(X \wedge Y) = P(X) * P(Y | X) = P(Y) * P(X | Y)$$

$$P(X | Y) = \frac{P(X) * P(Y | X)}{P(Y)} \quad (3.3)$$

Bayes ağ çok terimli verilerin analizinde kullanılan algoritmadır. Bu algoritma zor problemleri verimli ve güvenilir bir şekilde çözmek için var olan yöntemlerin geliştirilmesi ile oluşmuştur. Bayes ağ çok terimli verilerin birbirleri ile olan olasılıklarını hesaplamak için çok güçlü bir algoritmadır. Bayes ağ algoritmasının formülü, formül 3.4'te verilmiştir (Friedman ve Ark., 1997).

$$p(X) = \prod_{i=0}^{n-1} p(X_i | \pi_i) \quad (3.4)$$

Bu formülde $X=(X_0, \dots, X_{n-1})$ değişkenlerin vektörünü, π_i X_i 'lerin ana düğümlerini göstermektedir. Bayes ağ yapılarında olayın etkisi olan çocuk düğümler ve olayın nedeni olan ana düğümler bulunmaktadır (Ben-Gal, 2007).



Şekil 3.30 Örnek Bayes Ağ Yapısı

Şekil 3.30'da C düğümünün ana düğümleri A ve B iken, C düğümü D ve E düğümleri için ana düğümdür. Bu durumların oluşma olasılığı şartlı ve birleşik olasılık

dağılımı ile tanımlanmaktadır ve formül 3.25' de verilen eşitlik ile aralarındaki ilişki tanımlanabilir.

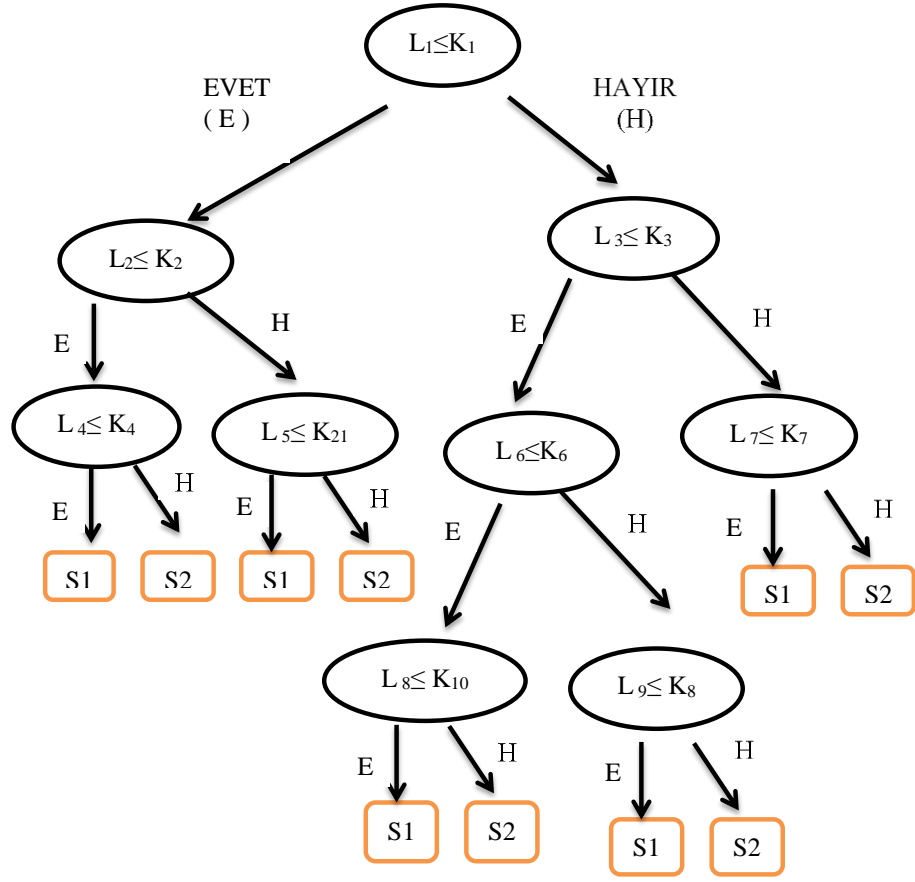
Bayes Ağlarında, her düğümün şartlı olma olasılığının tablosu oluşturulur. Bu tabloda her düğümde bulunan olayın olma olasılığının değerleri bulunur. Genellikle bir adet kök düğüm vardır. Tüm diğer düğümler bu kök düğümün olma olasılığını etkileyebilir. Bayes ağlarda işlem yapılabilmesi için bu tüm olasılıkların değerlerinin tabloya işlenmesi gerekir. Bu işlem sonucunda anlamlı veri elde etmek için tam ya da yarı makine öğrenmesi teknikleri kullanılır (Friedman, 1997).

Bu çalışmada tam öğrenme kullanarak sınıflandırma yapılmıştır.

3.4.1.3. Karar Ağaç Yapıları Teoremi

Karar ağaçları algoritmasının yapısı algoritma akış diyagramlarına benzemektedir. Karar ağaçlarının elemanları dallar, yapraklar ve karar düğümlerinden oluşur. Bu yöntem sınıfları bir ağacın yaprakları şeklinde göstermeye yarayan şekilde dizayn edilir (Bierman, 2001). Karar ağaçları sınıflandırma işlemini oluşturulan kurallardan verilerin test edilmesine dayanır.

Sınıflandırma işlemi için kullanılan karar ağacı örneği Şekil 3.31' de gösterilmiştir. $L_i \leq K_i$ şeklinde karşılaştırmaların bulunduğu elips şeklindeki ilk şekil karar ağaç yapısının kökünü oluştururken diğer şekiller ise karar ağaç yapısının karar düğümlerini oluşturmaktadır. Karar düğümleri L_i değerlerine dayanan K_i eşik değerleri bağlı olarak belirlenir. Şekilde bulunan S1 ve S2 değerlerinin bulunduğu dikdörtgen şeklindeki düğümler karar ağaç yapısının terminal düğümleridir ve karar ağacının sınıf etiketlerini oluştururlar. Sınıf etiketler, test verisindeki değerlerin eğitim sırasında belirlenen eşik değerlerine dayalı olarak karar ağacında EVET (E) veya HAYIR (H) şeklinde dallanmalar ile belirlenir.



Şekil 3.31 Dokuz Boyutlu ve İki Sınıflı Örnek Karar Ağaç Yapısı

Çalışmada, EEG verilerinin sınıflandırmalarında iyi sonuçlar verdiği bir çok çalışmada belirtilen Random Forest (Rastgele Orman: RO) yöntemi kullanılmıştır (Alzoubi ve Ark. 2008, Steyrl ve Ark., 2013). Rastgele Orman yönteminde 10 ağaçtan oluşan algoritma kullanılmıştır.

RO yöntemi 2001 yılında Bierman tarafından geliştirilmiştir. Bierman bu yöntemde, 1996 yılında geliştirmiş olduğu doğru sınıflama oranını arttıran ve varyansı düşüren Bagging yöntemi ile 1998'de Ho'nun geliştirdiği rasgele alt gruplar seçmeye yarayan The Random Subspace tekniklerini birleştirmiştir (Bierman,2001).

RO yöntemi, topluluk öğrenme algoritması olarak bilinmektedir. Bierman bu yöntemde tek bir karar tek ağaç yapısı yerine, çok sayıda farklı eğitim kümeleri ile

eđitilmiş ve çok deęişkenli birbirinden bağımsız karar ağaçlarını kullanarak bir algoritma oluşturmuştur.

Oluşturulan algoritmada bir birinden farklı sınıflama ve regresyon karar ağaçlarından oluşan bir orman kullanıldığından her bir karar ağacına sınıflandırma sonucuna göre oy verilir. Bu işlem tüm karar ormanı içerisinde bulunan ağaçların hepsinin oylanması ile tamamlanır, oylama sonucunda en fazla oyu alan karar ağacı sınıflandırma için seçilir ve seçilen karar ağacına göre sistem sınıflandırmayı gerçekleştirilir (Bierman,2001).

3.4.2. Başarım Ölçümü

Çalışma sonuçlarının değerlendirilmesinde 10 kat çapraz doğrulama kullanılmıştır. 10 kat çapraz doğrulamanın birinci aşamasında veriler rastgele 10 eşit parçaya ayrılır. Veri kümelerinin bir tanesi test için, geri kalan dokuz tanesi ise eğitim için kullanılır. Bu işlem on defa tekrarlanır ve sonuçların ortalaması alınır. Bu işlemde her veri seti bir defa test verisi olarak kullanılmış olur.

Sonuçların değerlendirilmesinde Doğru Pozitif Oranı (True Positive Rate) Formül 3.5’de gösterildiği gibi, her iki sınıfa ait doğru tahmin edilmiş etiket sayısının (DTEES) toplam etiket sayısına (TES) oranı ile bulunur.

$$\text{Doğru Pozitif Oranı} = \frac{DTEES}{\text{Toplam Etiket Sayısı}} \quad (3.5)$$

Yanlış Pozitif Oranı (False Positive Rate) yanlış tahmin edilmiş etiket sayısının (YTEES) toplam etiket sayısına bölünmesiyle bulunur.

$$\text{Yanlış Pozitif Oranı} = \frac{YTEES}{\text{Toplam Etiket Sayısı}} \quad (3.6)$$

Kesinlik (Precision) ise doğru tahmin edilen etiketlerin pozitif olarak tahmin edilmiş toplam etiket sayısına (TEES) oranı olarak bulunur. Ağırlıklı kesinlik ortalaması ise formül 3.7’de gösterildiği gibi, her iki sınıf için elde edilen kesinlik değerlerinin gerçek sınıf etiketleri ile oranlanmış durumu olarak tespit edilir.

$$Kesinlik = \frac{DTEES_X}{TEES_X} * \frac{TES_X}{TES} + \frac{DTEES_Y}{TEES_Y} * \frac{TES_Y}{TES} \quad (3.7)$$

3.5. Kolerasyon Tabanlı Öznitelik Seçimi Yardımıyla Kanal Seçimi

3.5.1. Öznitelik Seçimi

Öznitelik seçimi yöntemleri esasen yüksek sayıdaki özniteliklerden sınıflandırma işlemine katkısı en yüksek olanların seçilmesi amacıyla kullanılmaktadır. Bu işlem sayesinde literatürde boyutun laneti olarak (curse of dimensionality) olarak bilinen sorun da ortadan kaldırılmaktadır (Lee ve Ark., 2013).

Korelasyon Tabanlı Öznitelik Seçimi yöntemi birbirleri ilişkisi az olan fakat sınıfla yüksek ilişkili olan öznitelikleri seçerek bir alt öznitelik kümesi oluşturur. Bu amaçla, öznitelikleri tek tek değerlendirmek yerine alt öznitelik kümelerini puanlanarak en uygun alt küme bulunur.

3.5.2. Kanal Seçimi

Gerçek zamanlı çalışan sistemlerde analiz süreleri büyük önem taşımaktadır. Çok sayıda kanal kullanılan sistemlerde çıkarılacak öznitelik sayısı yüksek olacağından bir pencerenin işlenmesi süresi sorun teşkil edebilmektedir. Kullanılan kanal sayısının doğru pozitif oranını etkilemeyecek şekilde azaltılması analiz süresini azaltacağından sistemin kullanılabilirliğini artıracaktır. Bu nedenle sınıflandırmada en etkili kanalları bulmak önem arz etmektedir. Bu çalışmada sınıflandırma problemine en yüksek katkıyı sağlayan kanalların bulunmasında Korelasyon Tabanlı Öznitelik Seçimi (KTÖS) yönteminden faydalanılmıştır.

KTÖS yöntemi birbirleri ilişkisi az olan fakat sınıfla yüksek ilişkili olan öznitelikleri seçerek bir alt öznitelik kümesi oluşturur. Bu amaçla, öznitelikleri tek tek değerlendirmek yerine alt öznitelik kümelerini puanlanarak en uygun alt küme bulunur (Wang ve Ark., 2005).

Kanal seçimi yapılırken şu işlem sırası kullanılmıştır;

1. KTÖS yardımıyla seçilmiş öznitelikler bulunmuştur.
2. Seçilmiş özniteliklerin hangi kanallarda olduğu tespit edilmiştir.

3. Kanallara ait seçilmiş özniteliklerin sayısının toplamı bulunmuştur.
4. Bu işlem basamakları her denek için tekrarlanarak tüm deneklerde en çok kullanılan öznitelikler bulunmuştur.
5. Tüm deneklerde seçilen öznitelik sayıları dikkate alınarak en yüksek sayıda özniteliğin kullanıldığı kanaldan, en düşük öznitelik sayısına sahip kanala kadar tüm kanallar, birinci kanaldan başlayarak çizelge 3.1'deki sıraya göre yan yana eklenerek kanalların analizi yapılmıştır.

Çizelge 3.1' de kanallar ve öznitelik sayıları verilmiştir. Bu çizelge incelendiğinde en az öznitelik seçimi yapılan kanal 10 öznitelik ile P3-A1 kanalı olurken, en çok öznitelik seçimi yapılan kanal ise 113 öznitelik ile FP1-FP2 kanalı olmuştur.

Çizelge 3.1 Seçilen Özniteliklerin Sayısının Kanallara Göre Dağılımı.

Sıra No	Kanal Numarası	Kanal_adı	Öznitelik Sayısı
1	Kanal19	Fp1-Fp2	113
2	Kanal26	O1-O2	69
3	Kanal24	T5-T6	52
4	Kanal13	T3-A1	51
5	Kanal16	T6-A2	49
6	Kanal1	Fp1-A1	43
7	Kanal14	T4-A2	42
8	Kanal18	Fp1-O1	42
9	Kanal12	F8-A2	40
10	Kanal20	F7-F8	39
11	Kanal25	P3-P4	32
12	Kanal17	Fp2-O2	31
13	Kanal10	O2-A2	30
14	Kanal11	F7-A1	28
15	Kanal15	T5-A1	24
16	Kanal22	T3-T4	24
17	Kanal2	Fp2-A2	22
18	Kanal9	O1-A1	22
19	Kanal23	C3-C4	22
20	Kanal21	F3-F4	21
21	Kanal8	P4-A2	20
22	Kanal4	F4-A2	15
23	Kanal5	C3-A1	13
24	Kanal6	C4-A2	13
25	Kanal3	F3-A1	12
26	Kanal7	P3-A1	10

4. ARAŞTIRMA VE BULGULAR

Bu bölümde 26 kanal üzerinden elde ettiğimiz sonuçlar ile seçilme sayısına göre ksnllsın sırasıyla eklenmesi sonucu elde edilne sonuçlar karşılaştırılmıştır.

4.1. BayesNet Algoritmasına Göre Sınıflandırma Sonuçları

Yapılan çalışmada BayesNet algoritması kullanılarak sayısal ve sözel düşünce birbirinden %88,8 doğru pozitif oranıyla ayırt edilmiştir.

Çizelge 4.1’de deneyin tüm denekler için 26 kanal kullanılarak BayesNet algoritmasının sınıflandırma sonuçları verilmiştir. Yapılan çalışma sonuçları genel olarak incelendiğinde, sayısal ve sözel düşüncenin sınıflandırmasında ortalama %88,8 doğru pozitif oranına ulaşılrken, bireysel doğru pozitif oranlarının %72,3 ile %96,5 arasında değişmekte olduğu görülmektedir. Ayrıca ortalamada yanlış pozitif oranı çok düşük iken, en düşük %3,5 ve en yüksek %27,7 olarak bulunmuştur. Kesinlik değerinde ise ortalama oran %89,2 olurken, en yüksek oran %96,5 ve en düşük oran %73,5’tir.

Çizelge 4.1 BayesNet Sınıflandırıcısı Sonuçları

Denek No	Doğru Pozitif Oranı	Yanlış Pozitif Oranı	Kesinlik
1	0,866	0,134	0,867
2	0,845	0,155	0,853
3	0,723	0,277	0,730
4	0,843	0,157	0,860
5	0,930	0,070	0,930
6	0,877	0,123	0,878
7	0,965	0,035	0,965
8	0,894	0,106	0,899
9	0,921	0,079	0,921
10	0,900	0,100	0,910
11	0,910	0,090	0,910
12	0,839	0,161	0,849
13	0,931	0,069	0,932
14	0,895	0,105	0,906
15	0,927	0,073	0,927
16	0,899	0,101	0,901
17	0,929	0,071	0,933
18	0,888	0,112	0,893
Ortalama	0,888	0,112	0,892

4.2. kNN Algoritmasına Göre Sınıflandırma Sonuçları

kNN algoritması kullanılarak yapılan analizde ortalama %89,5 doğru pozitif oranına ulaşılmıştır.

kNN algoritmasında 1,3,5 ve 10 değerlerine göre sonuçlar incelenmiş ve en iyi sonucun 1 en yakın komşuluk algoritmasında elde edildiği görülmüştür. Çizelge 4.2’de k değerine göre ortalama doğru pozitif, yanlış pozitif ve kesinlik değerleri verilmiştir. Bu sonuçlar ile literatürdeki diğer çalışmalar arasında benzerlik olduğu görülmektedir (Özer ve Amasyalı, 2013).

Çizelge 4.2 1,3,5 ve 10 K değerlerine Göre Sınıflandırma Sonuçları

k Değeri	Doğru Pozitif Oranı	Yanlış Pozitif Oranı	Kesinlik
1	0,895	0,105	0,896
3	0,892	0,108	0,894
5	0,885	0,115	0,889
10	0,874	0,126	0,882

kNN algoritmasında komşuluk sayısı en iyi sonuçları verdiği için k değeri 1 olarak alınmış ve 1 en yakın komşuluk değerine göre ayrıntılı sonuçlar verilmiştir.

1 en yakın komşuya (1-NN) göre yapılan sınıflandırmada elde edilen sonuçlar Çizelge 4.3’de gösterilmektedir. Çizelge incelendiğinde en yüksek sınıflandırma oranı, doğru pozitif ve kesinlik değerlerinde %97,2 olurken, en düşük sınıflandırma oranı doğru pozitif ve kesinlik değerlerinde %70,5’tir. Yanlış pozitif oranlarında ise ortalama %10,5 olurken en düşük oran %2,8 en yüksek oran ise %29,5 olarak gerçekleşmiştir.

Çizelge 4.3 1-NN Algoritmasına Göre Sınıflandırma Sonuçlar

Denek No	Doğru Poz.Oranı	Yanlış Poz.Oranı	Kesinlik
1	0,893	0,107	0,897
2	0,881	0,119	0,884
3	0,705	0,295	0,705
4	0,900	0,100	0,900
5	0,929	0,071	0,929
6	0,757	0,243	0,759
7	0,972	0,028	0,972
8	0,948	0,052	0,948
9	0,918	0,082	0,919
10	0,893	0,107	0,899
11	0,859	0,141	0,864
12	0,917	0,083	0,918
13	0,931	0,069	0,932
14	0,943	0,057	0,944
15	0,931	0,069	0,932
16	0,888	0,112	0,889
17	0,938	0,062	0,939
18	0,906	0,094	0,906
Ortalama	0,895	0,105	0,896

4.3. Karar Ağaç Yapıları Algoritmasına Göre Sınıflandırma Sonuçları

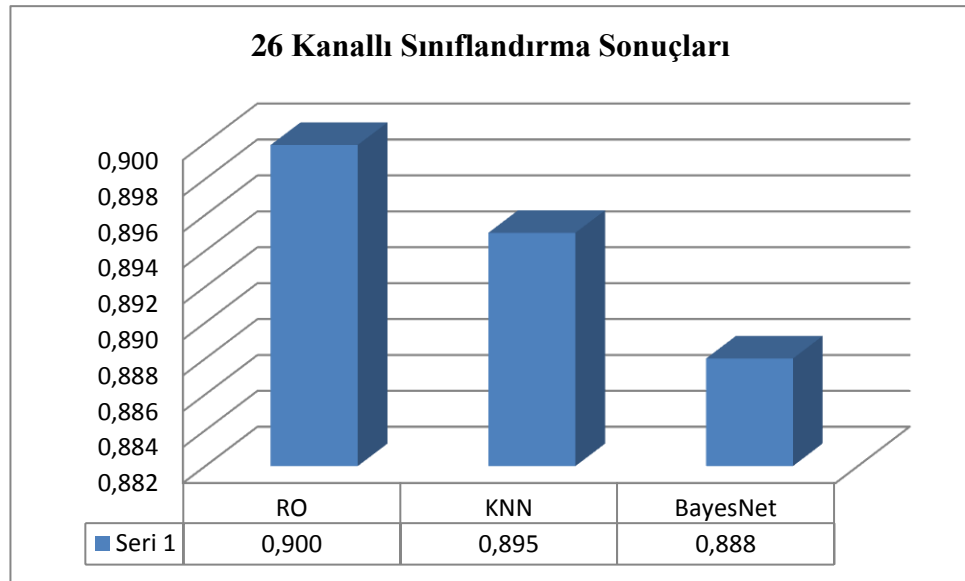
Öznitelikler, bir başka sınıflandırma yöntemi olan karar ağaç yapıları ile sınıflandırıldığında Çizelge 4.4'teki sonuçlar elde edilmiştir.

Karar ağaç yapıları sınıflandırmasında en iyi sonuç %96,5 olurken en düşük sınıflandırma oranı ise %72,6'dır. Sonuçlardan on bir tanesinde %90 üstü başarı elde edilirken, altı tanesinde %89,5 ile %90 arası başarı elde edilmiştir.

Kullanılan tüm sınıflandırıcıların sonuçlarının grafiksel gösterimi Grafik 4.1'de gösterilmektedir. Kullanılan sınıflandırıcıların sonuçları incelendiğinde en iyi sonuçların karar ağaç yapıları ile elde edildiği görülmüştür. BayesNet sınıflandırıcısı ile %88,8 ve kNN sınıflandırıcısı ile %89,5 doğru pozitif oranında ortalama başarı sağlanırken, karar ağaç yapıları ile sınıflandırma sonucunda ortalama başarı oranı doğru pozitifte %90,2, kesinlik değerinde ise %90,4 olarak gerçekleşmiştir.

Çizelge 4.4 Karar Ağaç Yapılarına Göre Sınıflandırma Sonuçları

Denek No	Doğru Poz.Oranı	Yanlış Poz.Oranı	Kesinlik
1	0,866	0,134	0,871
2	0,874	0,126	0,875
3	0,721	0,279	0,726
4	0,952	0,048	0,952
5	0,947	0,053	0,948
6	0,847	0,153	0,852
7	0,963	0,037	0,963
8	0,920	0,080	0,923
9	0,890	0,110	0,894
10	0,910	0,090	0,910
11	0,887	0,113	0,890
12	0,850	0,150	0,850
13	0,917	0,083	0,919
14	0,955	0,045	0,955
15	0,928	0,072	0,928
16	0,900	0,100	0,901
17	0,938	0,062	0,938
18	0,933	0,067	0,933
Ortalama	0,900	0,100	0,902



Şekil 4.1 Sınıflandırıcıların 26 Kanala Göre Sınıflandırma Sonuçları Grafiği

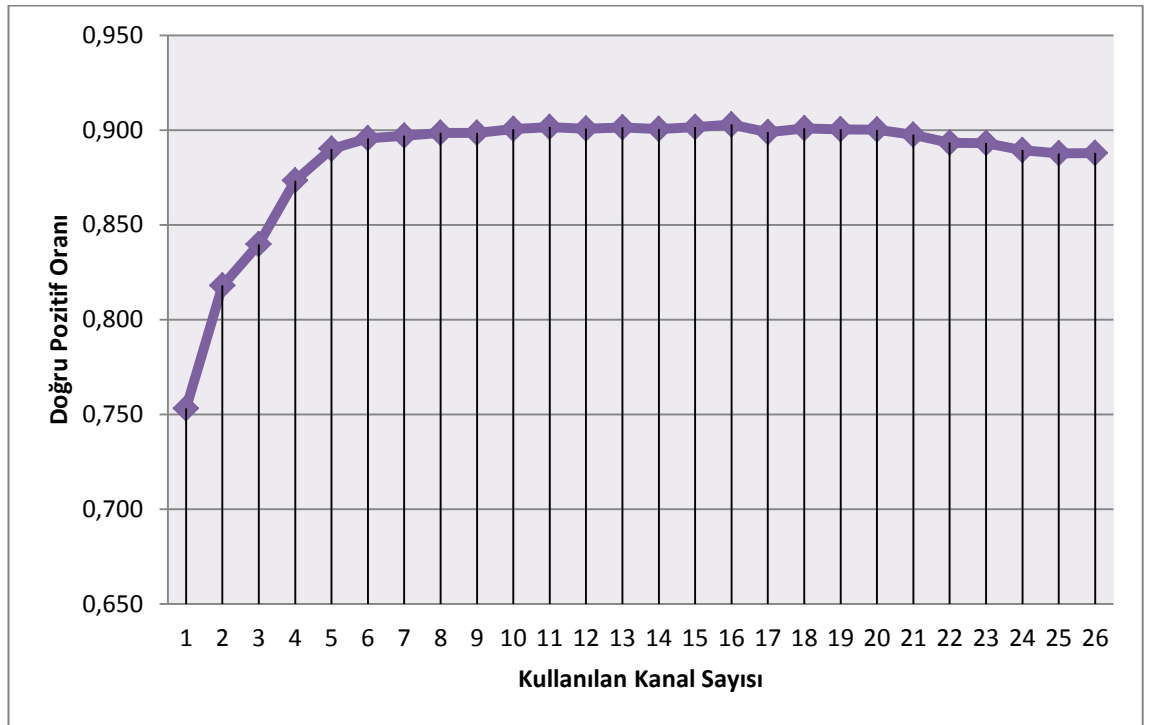
Tüm sınıflandırma sonuçları incelendiğinde, en kötü sonuçların 3 nolu deneye ait olması dikkat çekmektedir. Bu deneye ait sonuçların bütün sınıflandırıcılarda kötü

olmasının nedeni olarak deneğin deney sırasında gerekli özeni göstermediği ve deney öncesi yapılan uyarıları dikkate almadığı düşünülmektedir.

Bu deneğe ait değerler sınıflandırma sonuçlarının dışarısında bırakıldığında BayesNet için ortalama doğru pozitif değeri %88,8 den %89,8'e, kNN algoritmasına göre %89,5'dan %90,6'ya ve Random Forest algoritmasına göre ise %90,2'den %91 değerine çıkmaktadır.

Çizelge 4.5'de ve Şekil 4.2'de kanalların BayesNet sınıflandırmasına göre analiz sonuçları verilmiştir. Bu sonuçlar incelendiğinde daha az kanal kullanılarak daha yüksek doğru pozitif değerine ulaşabileceğimiz görülmektedir.

Sonuçlar incelendiğinde en yüksek sonucun 16 kanal kullanılan analizde alındığı görülmektedir. Ayrıca 26 kanalın kullanımında ulaşılan %88 doğru pozitif değerinin 5 kanal kullanılarak geçildiği %89 oranına ulaşarak geçildiği görülmektedir.



Şekil 4.2 BayesNet Kanallara Göre Doğru Pozitif Sayıları

Kanal sayılarına göre elde edilen doğru pozitif başarı oranları grafik 4.2' de verilmiştir. Şekil incelendiğinde, 10 kanal ile 20 kanal kullanılması arasında %90 üzerinde birbirlerine çok yakın veriler elde edilmektedir.

Çizelge 4.5 Kanalların BayesNet Sınıflandırmasına Göre Analiz Sonuçları

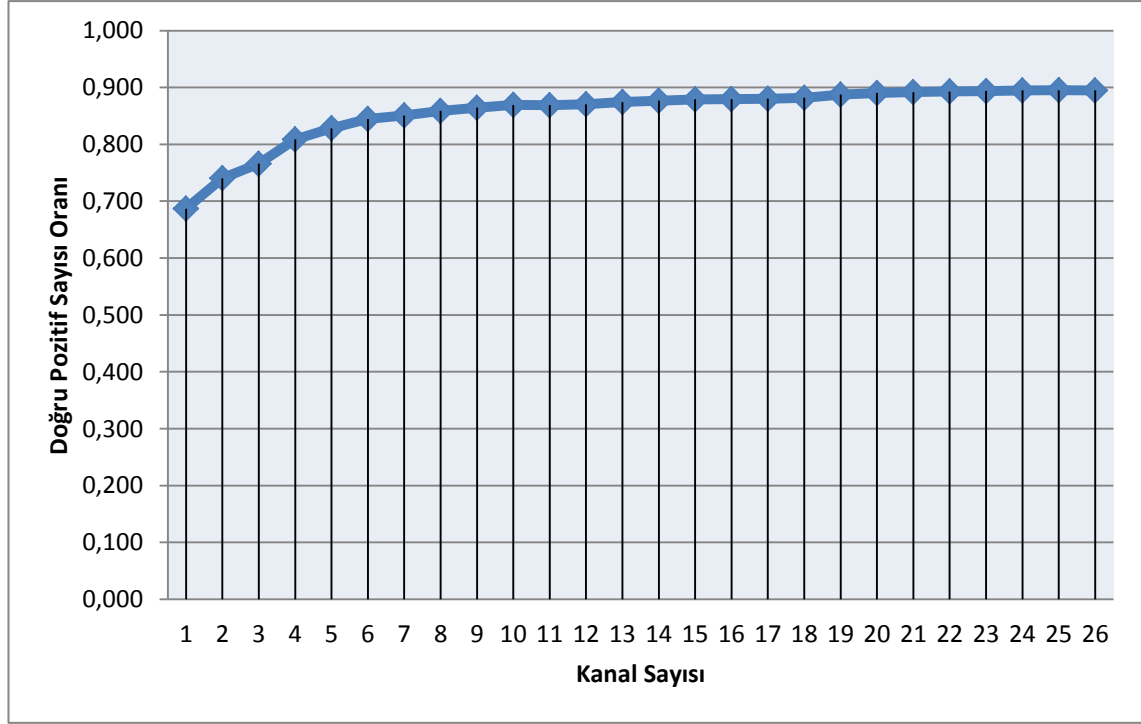
Kanal Sayısı	TPR	Kullanılan Kanallar
1	0,753	Fp1-Fp2
2	0,818	Fp1-Fp2,O1-O2
3	0,840	Fp1-Fp2,O1-O2, T5-T6
4	0,873	Fp1-Fp2,O1-O2, T5-T6, T3-A1
5	0,890	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2
6	0,896	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1
7	0,897	Fp1-Fp2,O1-O2, T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2
8	0,899	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1
9	0,898	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2, Fp1-O1,F8-A2
10	0,900	Fp1-Fp2,O1-O2, T5-T6, T3-A1, T6-A2,Fp1-A1, T4-A2,Fp1-O1, F8-A2, F7-F8
11	0,902	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4
12	0,901	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2
13	0,901	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2
14	0,901	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1
15	0,902	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1
16	0,903	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4
17	0,899	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2
18	0,901	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1
19	0,900	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4
20	0,900	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4
21	0,898	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2
22	0,893	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,
23	0,893	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,C3-A1
24	0,889	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,C3-A1, C4-A2
25	0,888	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,C3-A1, C4-A2, F3-A1
26	0,888	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,C3-A1, C4-A2, F3-A1

Çizelge 4.6 Seçilen Kanallara Göre kNN Sınıflandırma Sonuçları

Kanal Sayısı	TPR	Kullanılan Kanallar
1	0,687	Fp1-Fp2
2	0,740	Fp1-Fp2,O1-O2
3	0,766	Fp1-Fp2,O1-O2, T5-T6
4	0,809	Fp1-Fp2,O1-O2, T5-T6, T3-A1
5	0,828	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2
6	0,845	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1
7	0,851	Fp1-Fp2,O1-O2, T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2
8	0,859	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1
9	0,865	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2, Fp1-O1,F8-A2
10	0,869	Fp1-Fp2,O1-O2, T5-T6, T3-A1, T6-A2,Fp1-A1, T4-A2,Fp1-O1, F8-A2, F7-F8
11	0,869	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4
12	0,871	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2
13	0,874	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2
14	0,877	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1
15	0,879	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1
16	0,879	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4
17	0,880	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2
18	0,882	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1
19	0,888	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4
20	0,890	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4
21	0,892	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2
22	0,893	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,
23	0,894	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,C3-A1
24	0,895	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,C3-A1, C4-A2
25	0,895	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,C3-A1, C4-A2, F3-A1
26	0,895	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,C3-A1, C4-A2, F3-A1

Çizelge 4.6’te 1-NN algoritması kullanılarak elde edilen doğru pozitif oranları verilmiştir.

Çizelge 4.6 incelendiğinde 26 kanal kullanılarak elde edilen %89,5 doğru pozitif oranına yakın sonuçların 20 kanal kullanılarak elde edilebildiği görülmüştür.



Şekil 4.3 kNN Algoritmasının Kanallara Göre Doğru Pozitif Sayıları


Şekil 4.3’de kNN algoritmasına göre kanalların analizleri grafiksel olarak gösterimi verilmiştir. Bu analizler incelendiğinde en yüksek doğru pozitif başarı oranının 26 kanal kullanılarak elde edildiği görülmektedir. Fakat 20 kanallın kullanılması ile %89 başarı elde edilebilmiştir. Ayrıca sadece 4 kanalın kullanılması ile %80 üstünde doğru pozitif oranı elde edilebildiği görülmektedir.

Çizelge 4.7’da ise özniteliklere göre belirlenen kanal sıralaması ile oluşturulan kanal düzeni içerisinde Random Forest algoritması kullanılarak elde edilen doğru pozitif oranları verilmiştir.

Çizelge 4.7 Kanalların Random Forest Algoritmasına Göre Sonuçları

Kanal Sayısı	TPR	Kullanılan Kanallar
1	0,753	Fp1-Fp2
2	0,811	Fp1-Fp2,O1-O2
3	0,836	Fp1-Fp2,O1-O2, T5-T6
4	0,872	Fp1-Fp2,O1-O2, T5-T6, T3-A1
5	0,884	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2
6	0,897	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1
7	0,899	Fp1-Fp2,O1-O2, T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2
8	0,898	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1
9	0,903	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2, Fp1-O1,F8-A2
10	0,901	Fp1-Fp2,O1-O2, T5-T6, T3-A1, T6-A2,Fp1-A1, T4-A2,Fp1-O1, F8-A2, F7-F8
11	0,903	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4
12	0,900	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2
13	0,906	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2
14	0,906	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1
15	0,907	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1
16	0,904	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4
17	0,905	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2
18	0,904	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1
19	0,905	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4
20	0,905	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4
21	0,904	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2
22	0,905	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,
23	0,903	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,C3-A1
24	0,902	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,C3-A1, C4-A2
25	0,900	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,C3-A1, C4-A2, F3-A1
26	0,900	Fp1-Fp2,O1-O2,T5-T6, T3-A1,T6-A2,Fp1-A1, T4-A2,Fp1-O1,F8-A2, F7-F8, P3-P4,Fp2-O2, O2-A2,F7-A1, T5-A1, T3-T4, Fp2-A2,O1-A1,C3-C4, F3-F4, P4-A2,F4-A2,C3-A1, C4-A2, F3-A1

Çizelge 4.7 incelendiğinde 26 kanal kullanılarak elde edilen %90'lık başarının 12 kanal kullanılarak elde edilebilgi görülmektedir. Ayrıca 15 kanal kullanıldığında %90,7 doğru pozitif oranı ile en yüksek sonuca ulaşılabildiği görülmektedir.



Şekil 4.4 Random Forest Algoritmasının Kanallara Göre Doğru Pozitif Sayıları


Şekil 4.4 incelendiğinde 9 kanallı analizden 26 kanallı analize kadar doğru pozitif oranlarında çok fazla sapma meydana gelmemiştir. 9 kanallı analizde %90,3 başarı sağlanırken 26 kanallı analizde %90 başarı sağlanmıştır. Ayrıca iki kanal kullanımı ile %80 üstü sınıflandırma başarısı sağlandığı görülmektedir.

5. SONUÇ VE ÖNERİLER

5.1. Değerlendirme

EEG kayıtlarınının 26 kanlınının kullanılması ile yapılan sınıflandırmada başarı oranı doğru pozitiflerde BayesNet %88,8 1-NN %89,5 ve Random Forest %90 olarak gerçekleşmiştir.


Sadece iki kanal Fp1-Fp2 ve O1-O2 kullanılarak analiz yapıldığında sayısal ve metinsel işlemlerin ayırt edilmesinde BayesNet, kNN ve Random Forest algoritması kullanılarak sırası ile %81,8, %74 ve %81,1 doğru pozitif oranı elde edilebildiği görülmektedir.



Şekil-5.1 Seçilen iki kanalın gösterimi

Bu kanallardan Fp1-Fp2'nin bulunduğu frontal lob problem çözme işlemlerinin yapılmasında kullanılan bölge olarak literatürde bulunmaktadır (Burgess,2000). Bu durum yapılan çalışmanın literatürdeki benzer çalışmalar ile paralel sonuçlar elde edildiğini göstermektedir.


Şekil 5.2'de her üç sınıflandırıcı için yapılan kanal analiz çalışmasında en yüksek öznelik sayısına sahip ilk dört kanal gösterilmektedir. Bu kanallar kullanıldığında ise sayısal ve metinsel işaretlerin analiz edilmesinde %80 üzerinde başarı sağlandığı görülmektedir.



Şekil-5.2 Seçilen dört kanalın gösterimi

Kullanılan ilk dört kanal sırası ile Fp1-Fp2, O1-O2, T5-T6 ve T3-A1'dir. Bu dört kanal üzerinden yapılan sınıflandırmada BayesNet algoritması %87,3, kNN algoritması %80,9 ve Random Forest algoritması ise %87,2 oranında doğru pozitif başarıları sağlamaktadır.

BayesNet ve Random forest algoritmalarında şekil 5-3'de gösterilen, Fp1-Fp2, O1-O2, T5-T6, T3-A1, T6-A2, Fp1-A1, T4-A2, Fp1-O1, F8-A2 ve F7-F8 kanalları kullandığında sırası ile %90 ve %90,1 oranında doğru pozitif sınıflandırma başarıları sağlanmıştır.



Şekil-5.3 Seçilen on kanalın gösterimi

Bu oranlar EEG işaretlerinden matematiksel ve metinsel işlevlerin ayırt edilmesinde, frontal ve oksipital loblar üzerine yerleştirilecek olan elektrotlar kullanılarak %80'nin üstünde sınıflandırma başarısı sağlanabileceğini göstermiştir.

5.2. Gelecek Çalışmalar

Daha sonraki çalışmalarda tarafımızdan toplanan bu veritabanı kullanılarak;

- Farklı öznitelik çıkarma yöntemleri kullanılarak öznitelikler çıkarılması ve farklı sınıflandırıcılar ile sınıflandırmalar yapılması,
- Matematiksel işlemlerde toplama-çıkarma ve çarpma-bölme işlemlerinin gruplandırılarak sınıflandırılması,
- sayısal ve metinsel işlemler sırasında oluşan sinyallerin enerjilerinin incelenmesi ve aralarındaki farkların araştırılması

planlanmaktadır.

KAYNAKLAR

- Acar Şaylan, Ç., 2013. Böbrek Nakli Geçirmiş Hastalarda Akıllı Yöntem Tabanlı Yeni Öznitelik Seçme Algoritması Geliştirilmesi. Kadir Has Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi
- Acar, H., Akın, M., Yıldız, A., Eği, H., Kırbas, G., 2010.TMS320C6713 DSK ve MATLAB Kullanılarak EEG Sinyallerinden Uyanıklık Seviyesini Sınıflandırma. **Ulusal Sinyal İşleme Kurultayı-2010**
- Addison, P.S., 2002.**The Illustrated Wavelet Transform Handbook**. IOP Publishing Ltd, 2002.
- Aljazaery, I. A., Ali, A. A., Abdulridha, H. M., 2011.Classification of Electroencephalograph (EEG) Signals Using Quantum Neural Network. **Signal Processing: An International Journal (SPIJ)**, 4 (6): 329-337
- Allen, J.B. 1977.Short Time Spectral Analysis, Synthesis, and Modification by Discrete Fourier Transform. **IEEE Transactions on Acoustics, Speech, and Signal Processing**. ASSP-25 (3): 235–238.
- Altınbaş, A., 2007. Emg Sinyallerinin Kısa Zamanlı Fourier Dönüşümü Ve Dalgacık Dönüşümü Kullanarak Analiz Edilmesi. Gazi Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi
- AlZoubi, O., Koprinska, I., Calvo, R.A, 2008. Classification of Brain-Computer Interface Data. **The Australasian Data Mining Conference**. 9p
- Amcalar, A. Ve Çetin, M., 2010.Çevrimiçi Heceleme İçin Bir Beyin-Bilgisayar Arayüz Sistemi. **Sinyal İşleme ve Uygulamaları Konferansı 2010** : 196-199p
- American Electroencephalographic Society.,1991. **Guidelines for Standard Electrode Position Nomenclature**. **J Clin Neurophysiol**, 8:200-202p
- Ardıl, E., 2009. Esnek Hesaplama Yaklaşımı İle Yazılım Hata Kestirimi, Fen Bilimleri Enstitüsü, Trakya Üniversitesi Yüksek Lisans Tezi
- Aydemir, Ö. ve Kayıkçıoğlu, T., 2009. EEG Tabanlı Beyin Bilgisayar Arayüzleri. **Akademik Bilişim2009**,7-13s.
- Bahadır, İ., 2008. Bayes Teoremi ve Yapay Sinir Ağları Modelleriyle Borsa Gelecek Değer Tahmini Uygulaması. TOBB Ekonomi Ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi
- Barışçı, N., Müldür, S., 2003. Epileptik EEG Sinyallerin Sinirsel-Bulanık Sistem İle Sınıflandırılması. **Politeknik Dergisi**, 6 (2): 445-449
- Batar, H., 2005. Eeg İşaretlerinin Dalgacık Analiz Yöntemleri Kullanılarak Yapay Sinir Ağları İle Sınıflandırılması. Kahramanmaraş Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi
- Ben-Gal I., Bayesian Networks, in Ruggeri F., Faltin F. & Kenett R., 2007. **Encyclopedia of Statistics in Quality & Reliability**. Wiley & Sons.
- Bentley , P.M., McDonnel, J.T.E., 1994. Wavelet transforms: an introduction. **Electronics Communication Engineering Journal**. August 1994
- Bierman, L. 2001. Random forests. Machine Learning. <http://oz.berkeley.edu/~breiman/randomforest2001.pdf>. Erişim Tarihi 31.05.2014.
- Brankačk, J., Kukushka, V.I., Vyssotski, A.L., Draguhn, A., 2010, Eeg Gamma Frequency And Sleep–Wake Scoring İn Mice: Comparing Two Types Of Supervised Classifiers. **Brain Research** 1322(2010): 59-71.
- Burgess PW,2000. Strategy application disorder: the role of the frontal lobes in human multitasking. **Psychophysiology** 63:279-288p.

- Chen, G., 2014. Automatic Eeg Seizure Detection Using Dual-Tree Complex Wavelet-Fourier Features. **Expert Systems with Applications**, 41 (2014):2391–2394
- Coşkun M. Ve İstanbullu A., 2012. EEG İsaletlerinin FFT ve Dalgacık Donusumu ile Analizi. **Akademik Bilişim 2012**
- Culpepper, J., 1999. Discriminating Mental States Using Eeg Represented By Power Spectral Density. (online: www.cs.hmc.edu/~bjc/eeg/thesis.pdf , Erişim tarihi: 27.05.2014)
- Çorapçioğlu, M.E., 2006. TIPÇIT: Tıbbi Karar destek Sistem Çekirdeği. Başkent Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi
- Daubechies, A. 1990. Different Way to Look at Subband Coding, NJIT Symposium on Multi-Resolution Signal Decomposition Techniques: Wavelets, Subbands and Transforms.
- Deepa, V.B., Thangaraj, P., 2011. Classification of EEG data using FHT and SVM based on Bayesian Network. **International Journal of Computer Science Issues**, Vol. 8, Issue 5, No 2: 239-243p.
- Demir, Ö., 2008. Eeg Dalgalarının Wavelet (dalgacık) Dönüşümü İle Değerlendirilmesi. Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi
- Duda, R. O., and Hart, P. E. 1973. **Pattern classification and scene analysis**. Wiley and Sons, Inc. 472p.
- Ersöz, A., Özşen, S., 2011. Uyku Eeg Sinyalinin Yapay Sinir Ağ Modeli İle Sınıflandırılması. **Elektrik-Elektronik ve Bilgisayar Sempozyumu 2011**
- Federico Cirett Galán, Carole R. Beal. EEG Estimates of Engagement and Cognitive Workload Predict Math Problem Solving Outcomes. User Modeling, Adaptation, and Personalization.2012: 51-62
- Friedman, N., Geiger, D., Goldszmidt, M., 1997. Bayesian Network Classifiers. **Machine Learning** 29(2-3):131–163p.
- Gandhi, T., Panigrahi, K.B., Anand, S., 2011. A comparative study of wavelet families for EEG signal classification. **Neurocomputing**, 74 (2011) 3051–3057p
- Geetha, G., Geethalakshmi, S.N., 2012. Artifact Removal from EEG using Spatially Constrained Independent Component Analysis and Wavelet Denoising with Otsu's Thresholding Technique. **Procedia Engineering** 30 (2012) : 1064 1071p
- Grap, A., 1995. An Introduction to Wavelets. **IEEE Computationscience & Engineering**,: 50-61p
- Grossmann, A. and Morlet, J., 1984. Decomposition of Hardy Functions into Square Integrable Wavelets of Constant Shap. **SIAM J. Math. Anal.**,15(4), 723–736p.
- Haar, A., 1910. Zur Theorie Der Orthogonalen Unktionensysteme. **Mathematische Annalen** 69 (3): 331–371p.
- Haas, L.F., 2003. Hans Berger (1873-1941), Richard Caton (1842-1926), And Electroencephalography. **In Journal of Neurology, Neurosurgery & Psychiatry**, Vol. 74, Issue 1.
- Hall, M., Frank, E., 2009. Geoffrey Holmes, Bernhard Pfahringer, Peter Reutemann, Ian H. Witten, 2009. The WEKA Data Mining Software: An Update. **SIGKDD Explorations**, Volume 11, Issue 1.
- Hermann,C.S., Demiralp, T., 2005. Humman Eeg Gamma Oscillations In Neuropsychiatric Disorders. **Clinical Neurophysiology** Volume 116, Issue 12, 2719-2733p.

- Huang, J.S, 2002. Coiflet Wavelet Transform Applied to Inspect Power System Disturbance-Generated Signals. **Aerospace and Electronic Systems, IEEE Transaction**, 38 (1): 204-210p.
- Hubbard, B.B., 1998. **The World According to Wavelets**. A K Peters, Second Edition, 319p.
- İşoğlu Alkaç, Ü., 2009. Beyin Araştırmaları Tarihinde Bir Gezinti: Elektronörofizyoloji. **Klinik Gelişim**, 22 (3) :14-19p
- Kaur, J., Kaur, R., 2013. Biomedical Images denoising using Symlet Wavelet with Wiener filter. **International Journal of Engineering Research and Applications**, 3, (3): 548-550
- Kaur, S., Kaur, G., Singh D., 2013. Comparative Analysis Of Haar And Coiflet Wavelets Using Discrete Wavelet Transform In Digital Image Compression. **International Journal of Engineering Research and Applications**, 3 (3): 669-673p
- Kaya, Y., Ertuğrul, Ö.F., Tekin, R., 2012. Epileptik EEG İşaretlerinin Sınıflandırılmasında Karar Kuralları ve Karar Ağaçlarının Kullanılması. **Batman University Journal of Life Sciences**, 1,(2) : 403-413
- Kaya,Y., ERTUĞRUL, Ö.F., TEKİN, R., 2012. Epileptik Eeg İşaretlerinin Sınıflandırılmasında Karar Kuralları Ve Karar Ağaçlarının Kullanılması. **Batman University Journal of Life Sciences**, Volume 1, Number 2, (2012), 403-413s
- Keil, A., Muller,M., Ray,W.J., Gruber, T., Elbert, T., 1999, Human Gamma Band Activity and Perception of a Gestalt. **The Journal of Neuroscience**, August 15, 1999, 19(16):7152–7161p
- Lee, B.; Tarng, Y. S. 1999. Application of the discrete wavelet transform to the monitoring of tool failure in end milling using the spindle motor current. **International Journal of advanced Manufacturing Technology** 15 (4): 238–243p
- Lee, T.J., Park, S.M., Sim, K.B., 2013, Electroencephalography Signal Grouping and Feature Classification Using Harmony Search for BCI. **Journal of Applied Mathematics Volume**(2013), Article ID754539, 9p.
- Liu, Y., Sourina, O., Nguyen, K.M., 2011. Real-Time Eeg-Based Emotion Recognition And Its Applications. **Transactions on computational science** 12 : 256-277p
- Malmivuo, J., Plonsey, R., 1995. Bioelectromagnetism Principles and Applications of Bioelectric and Biomagnetic Fields. Oxford University Press, 599P,Oxford.
- Merry, R.J.E, 2005. **Wavelet Theory And Applications: A Literature Study**. Technische Universiteit Eindhoven (Eindhoven), DCT 2005.053:1-41p.
- Misiti, M., Misiti, Y., Oppenheim, G. Poggi, J.-M., 1996. **Wavelet Toolbox for Use With MATLAB**,The MathWorks, 656p, Amerika Birleşik Devletleri
- Mitchell, T., 1997, **Machine Learning**, McGraw Hill, 1997.
- Mostow, J., Chang, K.-M., Nelson, J., Toward Exploiting EEG Input in a Reading Tutor. In: Biswas, G., Bull, S., Kay, J., Mitrovic, A. (eds.) **AIED 2011. LNCS**, vol. 6738, pp. 230–237. Springer, Heidelberg (2011)
- Murugappan, M., 2011. Human emotion classification using wavelet transform and KNN. **Pattern Analysis and Intelligent Robotics (ICPAIR), 2011 International Conference on**, (Volume:1), 28-29 June 2011, 148 – 153p.
- Nelson J. Barreto, T., Va'zquez, E.A.,Sosa, P.A.V., 2003. Bayesian Model Averaging In Eeg/Meg Imaging. **NeuroImage** 21 (2004) 1300– 1319p

- Niedermeyer, E., 2005. **Electroencephalography**. Lippincott Williams & Wilkins, 1039 s, Philadelphia
- Oliveria, I., Grigori, O., Guimaraes, N., 2009. EEG Signal Analysis for Silent Visual Reading Classification. **International Journal Of Circuits, Systems And Signal Processing**, Issue 3, Volume 3, 2009:119-126p.
- Oppenheim, A.V., Willsky, A.S., Nawab, S.H., 2014, Signals and Systems, Pearson Education Limited, 937p, United States of America.
- Orhan, U., Hekim, M., Özer, M., 2010. EEG İşaretlerinin Çok-katmanlı Algılayıcı Yapay Sinir Ağı Modeli ile Sınıflandırılmasında Ayrıklaştırma Yaklaşımı. **IEEE**.
- Ortolani O, Conti A, Di Filippo A, Adembri C, Moraldi E, Evangelisti A, Maggini M, Roberts SJ., 2002. EEG signal processing in anaesthesia. Use of a neural network technique for monitoring depth of anaesthesia. **BJA: British Journal of Anaesthesia**, 88(5):644-652p.
- Özdemir, N., Yıldırım, E., 2012. Hilbert Huang Transform Ve Yapay Sinir Ağları İle Epileptik Nöbet Tahmini. **Sinyal İşleme ve Uygulamaları Konferansı 2012**.
- Özer, Z.B., ve Amasyalı, M.F., 2013, Meta Öğrenme ile KNN Parametre Seçimi., **21. Sinyal İşleme Ve Uygulamaları Konferansı**, 2013.
- Parvinnia, E., Sabeti, M.,Zolghadri Jahromi, M.,Boostani, R., 2014. Classification Of Eeg Signals Using Adaptive Weighted Distance Nearest Neighbor Algorithm. Journal of King Saud University - **Computer and Information Sciences**, Volume 26, Issue 1, January 2014, 1-6p
- POLIKAR, R. 1999. The Engineer's Ultimate Guide To Wavelet Analysis The Wavelet
- Pourzare,S., Aydemir, O., Kayikcioglu, T., 2012. Classification Of Eeg Signals Recorded During İn Facial Movements For Human-Machine Interaction, **Signal Processing and Communications Applications Conference (SIU)**, 2012 20th, 1-4p
- Qu , H. & Gotman, 1997, J. A Patient-Specific Algorithm for the Detection of Seizure Onset in Long-Term EEG Monitoring: Possible Use as a Warning Device. **IEEE Transactions on Biomedical Engineering**, 44, 115-122p.
- Rampil,I.J., 1984. Fast Fourier Transformation of EEG Data. The Journal Of The American Medical Association (JAMA) 1984;251(5):601p
- Robert, C., Gaudy, J.F., Limoge, A., 2002, Electroencephalogram Processing Using Neural Networks, **Clinical Neurophysiology** 113 : 694–701p
- Schröder, P., Sweldens, W., 1995, SphericalWavelets:Efficiently Representing Functions on the Sphere.**Computer Graphics And Interactive Techniques**:161 – 172p
- Steyrl, D., Scherer, R., Müller-Putz, G.R., 2013. Using Random Forests for Classifying Motor Imagery EEG. **TOBI : Tools for Brain-Computer Interaction**.
- Strang, G., Nguyen, T., 1997. Wavelets and Filter Banks. Wellesley-Cambridge Press, Second Edition.
- Subasi, A., Alkan, A., Koklukaya, E., Kiymik, M.K., 2005. Wavelet Neural Network Classification Of Eeg Signals By Using Ar Model With Mle Preprocessing. **Neural Networks** 18 : 985–997p
- Subaşı, A., 2007. Eeg Signal Classification Using Wavelet Feature Extraction And A Mixture Of Expert Model, **Expert Systems with Applications** 32: 1084–1093p

- Toprak, İ.B., 2007.Eeg Sinyallerinin Dalgacık Dönüşümü Ve Yapay Sinir Ağları İle Analizi. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi
- Tutorial.[Http://Engineering.Rowan.Edu/~Polikar/Wavelets/Wtpart3.Html](http://Engineering.Rowan.Edu/~Polikar/Wavelets/Wtpart3.Html) (Erişim Tarihi:03.02.2014)
- UYSAL, İ., BİLEN, M., ULUKUŞ, S., 2014. Twoing Algoritması ile Sınıflandırma Kalp Hastalığı Uygulaması., **Akademik Bilişim Kongresi**.
- Uzun,S.S.,Oflozoğlu,Ç.,Yıldırım,E., Yıldırım, S., 2012. Dalgacık Dönüşümü Analizi İle Eeg İşaretlerinden Duygu Kestirimi. **Signal Processing and Communications Applications Conference**.
- Übeyli, E.D. ve Güler, İ., 2004. Dalgacık Dönüşümü İle EEG İşaretlerinden Çıkarılan Öznitelik Vektörleri Üzerinde İstatistiksel İşlemlerin Gerçekleştirilmesi. **Eleco2004**.
- Übeyli, E.D., 2007. Wavelet/Mixture Of Experts Network Structure For Eeg Signals Classification. **Since Direct**.
- Wang, Y., Tetko, I.V., Hall, M.A.,Frank, E., Facius, A., Mayer, K.F. and Mewes H.W., 2005. Gene Selection From Microarray Data For Cancer Classification--A Machine Learning Approach, **Comput Biol Chem.**, 2005 Feb; 29(1):37-49p.
- Weeks, M., 2011. Digital Signal Processing Using MATLAB & Wavelets, Jones and Barlett Publishers, 489 s, Canada
- Wei, D., 1998. Coiflet-Type Wavelets: Theory, Design, and Applications. Doctor Of Philosophy, Presented to the Faculty of the Graduate School of The University of Texas at Austin.
- Witten, I.H. and Frank, E., 2002. Data mining: practical machine learning tools and techniques with Java implementations. **ACM SIGMOD Record**, vol. 31, no. 1, pp. 76–77p.
- Xizheng, Z.,Ling,Y., Weixiong, W., 2010. Wavelet Time-frequency Analysis of Electro-encephalogram (EEG) Processing. **International Journal of Advanced Computer Science and Applications**, 1 (5)
- Yazgan, E., ve KORÜREK, M., 1996. Tıp Elektroniği. İtü Matbaası, 220 s, İstanbul.

ÖZGEÇMİŞ

Yazar, 1980 yılında İskenderun'da doğdu. İlkokul, Ortaokul ve Endüstri Meslek Lisesi Teknik Lise Bilgisayar Bölümü'nü Hatay'da tamamladı. Ondokuz Mayıs Üniversitesi Eğitim Fakültesi Bilgisayar Öğretim Teknolojileri ve Öğretmenliği Bölümü'nü 1998 yılında kazandı. Üniversiteden 2002 yılında mezun oldu. Aynı yıl Reyhanlı Lisesinde Bilgisayar öğretmeni olarak göreve başladı. 2009 yılında Mustafa Kemal Üniversitesi İskenderun Meslek Yüksekokulunda öğretim görevlisi olarak göreve başlayan Server Göksel ERALDEMİR halen aynı görevi sürdürmektedir.