



**İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS

**META SEZGİSEL ALGORİTMALAR İLE BİYOLOJİK
SİNYALLERİN İŞLENMESİ**

**Elektrik - Elektronik Müh. Gürsel KIZILASLAN
Elektrik - Elektronik Mühendisliği Anabilim Dalı
Elektrik - Elektronik Mühendisliği Programı**

**Danışman
Yrd. Doç. Dr. Niyazi KILIÇ**

İSTANBUL

Bu çalışma 05 /06/ 2012 tarihinde aşağıdaki jüri tarafından Elektrik- Elektronik Mühendisliği
Anabilim Dalı Elektrik- Elektronik programında Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Jürisi



Yrd. Doç. Dr. Niyazi KILIÇ (Danışman)
İstanbul Üniversitesi




Prof. Dr. Aydın AKAN
İstanbul Üniversitesi



Prof. Dr. Osman Nuri UÇAN
İstanbul Aydın Üniversitesi



Doç. Dr. Hakan Doğan
İstanbul Üniversitesi



Doç. Dr. Fırat KAÇAR
İstanbul Üniversitesi

ÖNSÖZ

Lisans ve yüksek lisans öğrenimim sırasında ve tez çalışmalarım boyunca gösterdiği her türlü destek ve yardımdan dolayı çok değerli hocam Yrd. Doç. Dr. Niyazi KILIÇ'a, Doç. Dr. Hakan DOĞAN'a ve Ergün GÜMÜŞ'e en içten dileklerimle teşekkür ederim.

Öğrenim hayatım ve bu çalışma boyunca maddi ve manevi desteklerini hiç bir zaman benden esirgemeyen çok sevgili annem ve babam başta olmak üzere tüm aileme, çalışma arkadaşlarıma ve çalışmamın uygulama kısmını destekleyen İstanbul Üniversitesi'ne teşekkürü borç bilirim.

Haziran, 2012

Gürsel KIZILASLAN

İÇİNDEKİLER

ÖNSÖZ.....	I
İÇİNDEKİLER	II
ŞEKİL LİSTESİ.....	IV
TABLO LİSTESİ.....	VI
SEMBOL LİSTESİ	VII
ÖZET.....	IX
SUMMARY	X
1. GİRİŞ	1
1.1 Tezin Konusu ve Amacı	1
1.2 Literatür Özeti.....	2
2.GENEL KAVRAMLAR.....	5
2.1 BEYİN VE YAPISI.....	5
2.1.1 Beyin Anatomisi.....	5
2.1.2 Sinir Ağı	6
2.2 EPİLEPSİ.....	8
2.2.1 Epilepsi Nedir.....	8
2.2.2 Epilepsi Nöbetleri.....	8
2.2.3 Epilepsi Teşhisi	8
2.2.4 Epilepsi Nedenleri	9
2.2.5 Epilepsi Tedavisi	9
2.3 EEG (Elektroansefalogram).....	10
2.3.1 EEG Nedir?	10
2.3.2 EEG Dalgaları	11
2.3.3 EEG Kullanım Alanları.....	13
3. MALZEME VE YÖNTEM	15
3.1 MALZEME	15

3.1.1 Kullanılan Veri	15
3.2 YÖNTEM	15
3.2.1 Dalgacık Dönüşümü	15
3.2.2 Ön İşleme	32
3.2.3 Öznitelik Çıkarma	32
3.2.4 Öznitelik Seçme	33
3.2.5 Sınıflama	34
3.2.6 k- En Yakın Komşuluk Yöntemi	34
3.2.7 Destek Vektör Makineleri	37
4. BULGULAR	47
4.1 DVM İle Bulunan Sonuçlar	49
4.2. kNN İle Bulunan Sonuçlar :	55
5. TARTIŞMA VE SONUÇ	60
KAYNAKLAR	62
EKLER	65
ÖZGEÇMİŞ	72

ŞEKİL LİSTESİ

Şekil 2.1: Beynin yapısı	15
Şekil 2.2. Nöronun yapısı	17
Şekil 2.3. Sinir sistemi iletişimi	17
Şekil 2.4 İlk kaydedilen EEG sinyali	20
Şekil 2.5 Delta Dalgası	22
Şekil 2.6 Teta Dalgası	22
Şekil 2.7 Alfa Dalgası	22
Şekil 2.8 Beta Dalgası.....	23
Şekil 2.9 Gamma Dalgaları.....	23
Şekil 3.1: Sinyal analiz yöntemleri arasındaki ilişki.....	27
Şekil 3.2: Daubechies dalgacıkları.....	29
Şekil 3.3: Haar dalgacık fonksiyonu.....	29
Şekil 3.4: Meksika şapkası dalgacığı.	30
Şekil 3.5: Meyer dalgacığı	31
Şekil 3.6: Morlet dalgacığı.	31
Şekil 3.7 Symlets dalgacık ailesine ait fonksiyonların zaman-genlik gösterimleri	32
Şekil 3.8: Ölçekleme ve dalgacık fonksiyonlarının spektrumları	37
Şekil 3.9: DWT ile alt bantlarına ayırma; $g[n]$: yüksek, $h[n]$: alçak geçiren filtre	39
Şekil 3.10: Ayrık dalgacık dönüşümü sinyalin ayrıştırılması işlemi	40
Şekil 3.11: Dalgacık paket dönüşümü	41
Şekil 3.12: Yukarı doğru örnekleme	41
Şekil 3.13: Alt bantlara ayırma yöntemine göre analiz ve sentez işlemleri	42
Şekil 3.14 : Örnek kNN sınıflandırma	45
Şekil 3.15: Grafik 2 boyutlu ekseninde yer alan 3 hiperdüzlemi gösterir.....	48
Şekil 3.16: Doğrusal ayrılabilirlik durumunda marjın ve kuramsal hiperdüzlemler.....	50
Şekil 3.17: Lineer ayrılamama durumunda optimum ayırıcı hiperdüzlem	52
Şekil 3.18 Bir doğrusal olmayan Destek Vektör Makinesi.....	54
Şekil 3.19: Giriş uzayını özellik uzayına eşleme	55

Şekil 4.1: Haar dalgacığı 5-kat çapraz doğrulama	61
Şekil 4.2: Haar dalgacığı 10-kat çapraz doğrulama	61
Şekil 4.3: Db4 dalgacığı 5-kat çapraz doğrulama	61
Şekil 4.4: Db4 dalgacığı 10-kat çapraz doğrulama	62
Şekil 4.5: Symlet(sym4) dalgacığı 5-kat çapraz doğrulama	62
Şekil 4.6: Symlet dalgacığı 5-kat çapraz doğrulama	63
Şekil 4.7: Haar dalgacığı 5-kat çapraz doğrulama	67
Şekil 4.8: Haar dalgacığı 10-kat çapraz doğrulama	68
Şekil 4.9: Db4 dalgacığı 5-kat çapraz doğrulama	68
Şekil 4.10: Db4 dalgacığı 10-kat çapraz doğrulama	68
Şekil 4.11: Symlet 5-kat çapraz doğrulama	69
Şekil 4.12: Symlet 10-kat çapraz doğrulama	69

TABLO LİSTESİ

Tablo 2.1: EEG Frekans bandları	21
Tablo 4.1: Sınıflandırma işleminin blok diyagram genel yapısı	57
Tablo 4.2: Haar dalgacığı 5-kat çapraz doğrulama sonuçları.....	59
Tablo 4.3: Haar dalgacığı 10-kat çapraz doğrulama sonuçları.....	59
Tablo 4.4: Db4 dalgacığı 5-kat çapraz doğrulama sonuçları.....	59
Tablo 4.5: Db4 Dalgacığı 10-kat çapraz doğrulama	60
Tablo 4.6: Symlet dalgacığı 5-kat çapraz doğrulama sonuçları	60
Tablo 4.7: Symlet dalgacığı 10-kat çapraz doğrulama sonuçları	60
Tablo 4.8: DVM Doğrusal çekirdek fonksiyon tipi için sınıflandırma sonuçları.....	63
Tablo 4.9: DVM Doğrusal çekirdek fonksiyon için istatiksel sonuçlar	64
Tablo 4.10: DVM Polinom çekirdek fonksiyon için istatiksel sonuçlar	64
Tablo 4.11: Haar, 5-kat çapraz doğrulama, $k=3$, mesafe değişkeni sonuçları.....	65
Tablo 4.12: Haar, 10-kat çapraz doğrulama, $k=3$, mesafe değişkeni sonuçları	65
Tablo 4.13: Db4, 5-kat çapraz doğrulama, $k=3$, mesafe değişkeni sonuçları	66
Tablo 4.14: Db4, 10-kat çapraz doğrulama, $k=3$, mesafe değişkeni sonuçları	66
Tablo 4.15: Symlet, 5-kat çapraz doğrulama, $k=3$, mesafe değişkeni sonuçları.....	66
Tablo 4.16: Symlet,10-kat çapraz doğrulama, $k=3$, sonuç karşılaştırma	67
Tablo 4.17: KNN, Öklid mesafesi duyarlılık, özgüllük ve hassaslık tablosu.....	69

SEMBOL LİSTESİ

- A** : Dalgacık yaklaşım alt bantı
- ADD** : Ayrık Dalgacık Dönüşümü
- C** : Dalgacık Katsayısı
- Coif** : Coiflets dalgacık
- CWT** : (Continuous Wavelet Transform) Sürekli Dalgacık Dönüşüm
- D** : Dalgacık detay alt bantı
- Db** : Daubechies dalgacık
- DFT** : (Discrete Fourier Transform) Ayrık Fourier Dönüşüm
- DTFT** : (Discrete Time Fourier Transform) Ayrık Zamanlı Fourier Dönüşüm
- DVM** : Destek Vektör Makineleri
- DWT** : (Discrete Wavelet Transform) Ayrık Dalgacık Dönüşüm
- EEG** : Elektroensefalogram
- FD** : Fourier Dönüşüm
- FFT** : (Fast Fourier Transform) Hızlı Fourier Dönüşüm
- FN** : False Negative
- FP** : False Positive
- Haar** : Haar Dalgacığı
- kNN** : k En Yakın Komşuluk (k Nearest Neighbourhood)
- MLP** : (Multi Layer Perceptron) Çok Katmanlı Algılayıcı
- MMS** : Merkezi Sinir Sistemi
- RBF** : Radyal Tabanlı Fonksiyon Ağlar (Radial Basis Function)

RTF : Radyal Tabanlı Fonksiyon Ağlar (Radial Basis Function)

SVM : Support Vector Machine (Destek Vektör Makinesi)

SYM : Symlet Dalgacığı

TN : False Negative

TP : False Positive

W : Dalgacık

ψ : Ana dalgacık

ÖZET

Meta Sezgisel Algoritmalar İle Biyolojik Sinyallerin İşlenmesi

Bu çalışmada, EEG sinyallerinin meta sezgisel algoritmalar ile sınıflandırılması gerçekleştirilmiş ve sınıflandırıcıların değişkenleri değiştirilerek Ayrık dalgacık dönüşümünün sınıflandırma üzerindeki etkileri incelenmiştir. İlk olarak ön işleme tabi tutulan EEG sinyallerinden dalgacık dönüşümü yöntemiyle öznitelik vektörleri elde edilmiş, sonrasında ise DVM ve kNN yöntemiyle sınıflandırma gerçekleştirilmiştir. Dalgacık Dönüşümünün sınıflandırma üzerindeki etkileri tablo olarak verilerek sınıflandırma sonucunda EEG sinyallerinin sağlıklı veya epileptik olduğu hakkında bilgi sağlanmıştır. Bu çalışmada 1. seviye Haar, Db4 ve Symlet dalgacıkları ile 5-kat ve 10-kat çapraz doğrulama (k-fold cross validation) kullanılarak sınıflandırma yapılmıştır. Gerçekleştirilen sınıflandırma sonuçları kıyaslandığında SVM yöntemi KNN 'ye göre daha başarılı sonuç vermekte ve dalgacık analizi değişkenleri karşılaştırılmasında SVM için kernel tipi Doğrusal ve Polinom olan ve Symlet dalgacığı kullanıldığında en iyi sonucu verirken; kNN için ise Öklid mesafesi ve dalgacık tipi olarak ise Haar kullanıldığında en iyi sonucu vermektedir. Ayrıca, çapraz doğrulama değeri arttıkça başarımının azaldığı açık bir şekilde görülmektedir.

Anahtar kelimeler: Ayrık Dalgacık Dönüşümü, DVM, EEG, Epilepsi, KNN

SUMMARY

Biological Signal Processing Using Metaheuristic Algorithms

In this thesis, classification of EEG signals by using metaheuristic algorithms is realised and Discrete Wavelet Transform (DWT) and its effect on classification is analyzed by changing variables of classifiers. First, pre-processed EEG signals are obtained, then feature vectors are produced by Discrete Wavelet Transform method after then classification is realized by SVM and k-NN methods. Discrete Wavelet Transform effects on the classification is shown by tables as a result of the classification is epileptic or healthy. In this thesis, 1. level Haar, Db4 and Symlets wavelets with 5-fold and 10-fold Cross Validation are used for classification. When classification results compared, SVM method gives better than kNN method. Comparing the variables; for SVM, linear and polynomial kernel type and using symlet wavelet gives better result. While for the kNN, Euclidean and Cityblock distance and using Haar wavelet gives better result. It is clearly seen that when the k value of k-fold cross validation is increased the result of classification decreased.

Keywords: DWT, EEG, Epilepsy, k-NN, SVM

1. GİRİŞ

1.1 TEZİN KONUSU VE AMACI

Henüz nasıl çalıştığı tam olarak keşfedilememiş olan insan beyni en karmaşık yapıya sahip olan organlardan bir tanesidir. Günlük hayatta okuma-yazmadan hafızaya, nefes almadan yürümeye kadar bütün faaliyetler beynin denetimindedir. Bütün bu faaliyetleri denetleyen beynin, nasıl çalıştığı hala tam olarak keşfedilmemiştir.

Epilepsi aralıklı olarak tekrarlanan krizlerle tanımlanan bir nörolojik rahatsızlıktır ve bu krizler beyindeki anormal sinirsel aktiviteler yüzünden oluşur. Bu aktiviteler EEG işaretlerinde gözlemlenebilirler. Bu nedenle Epilepsi hastalığının teşhis edilmesinde EEG (Elektroensefalografi) yöntemi uygulanmaktadır. EEG kayıtlarının otomatik olarak değerlendirilmesi için bir çok sınıflama yöntemi kullanılmaktadır.

EEG, beyindeki sinir hücreleri tarafından hem uyku, hem de uyanıklık halindeyken üretilen elektriksel faaliyetin beyin dalgaları şeklinde kaydedilmesidir. Beyinde gerçekleşen normal elektriksel faaliyetler başta epilepsi (sara hastalığı) olmak üzere pek çok durumda bozulabilir. EEG'yi oluşturan beyin dalgalarının incelenmesi ile bu bozukluğun yeri ve şekli hakkında bilgi edinilebilir.

EEG cihazları, kafatasının üzerinde belirlenmiş bazı özel noktalara yerleştirilen elektrotlar aracılığıyla beyindeki sinyalleri kaydeder. Kaydedilen bu sinyaller Dalgacık Dönüşümü gibi farklı yöntemler kullanarak analiz edilebilirler. Dalgacık Dönüşümü ile sinyal dalgacık katsayılarına ayrılır ve bu katsayılar sınıflandırıcılara giriş olarak uygulanarak verilerin sadeleştirilip sınıflandırılması sağlanabilir.

Hastalık teşhisi genellikle ön işleme, öznitelik çıkarma/seçme ve sınıflama işlemlerinden oluşmaktadır. İşaret/görüntü elde etme, bozucu etkenlerin yok edilmesi, ortalama alma, eşik değeri belirleme, işaret/görüntü iyileştirme gibi işlemler ön işlemeyi

oluşturmaktadır. Öznitelik çıkarma; şekil tanımlama ve şeklin önemli özniteliklerinin çıkarılıp öznitelik vektörünün elde edilmesi işlemidir. Öznitelik seçme isteğe bağlı olarak yapılan bir işlem olup sınıflama işlemi açısından en belirleyici özniteliklerin seçilmesi ile öznitelik vektörünün boyutunun azaltılmasıdır. Sınıflamada ise kullanılan algoritmaya bağlı olarak giriş öznitelik vektörleri incelenir ve sınıflama sonucu belirlenir böylece teşhis sistemlerinin son aşaması olan sınıflama gerçekleşmiş olur . Sınıflama sonucunu belirlemesi açısından ele alındığında öznitelik çıkarma ve gerekli durumlarda öznitelik seçme, sınıflama sistemlerinin başarısını oldukça etkilemektedir.

Bu çalışmada, EEG işaretlerinin spektral analizi, Ayrık Dalgacık Dönüşümü (ADD) ile gerçekleştirilmiştir ve işaret hakkında önemli bilgi içeren dalgacık katsayıları işareti temsil eden öznitelik vektörleri olarak ele alınmıştır. Dalgacık katsayıları üzerinde istatistiksel işlemler kullanılarak öznitelik vektörlerinin boyutları azaltılmıştır. Elde edilen öznitelik vektörleri, Destek Vektör Makinaları (DVM) ve k En Yakın Komşuluk (kNN) sınıflandırma yöntemlerinin girişlerine uygulanmış ve sınıflandırıcıların parametreleri değiştirilerek Dalgacık Dönüşümünün sınıflandırma üzerindeki etkileri ve sınıflandırma performansları karşılaştırmalı olarak incelenmiştir.

1.2 LİTERATÜR ÖZETİ

EEG işaretlerinin sınıflandırılmasıyla ilgili literatürde birçok çalışma bulunmaktadır. Aşağıda başlıca araştırmacıların çalışmaları özetlenmiştir.

Miner (1998), Dalgacık teorisi, geleneksel Fourier metotları ve Dalgacık analizlerinin gelişimini inceleyerek sinyal işleme alanı temelli çeşitli karşılaştırmalar yapmış, ayrıca sürekli ve ayrık dalgacık analizi algoritmaları vermiştir.

Deon Garrett ve diğerleri (2003) EEG işaretlerini sınıflandırmada doğrusal olmayan sınıflandırma yöntemlerinin, doğrusal olan sınıflandırma yöntemlerine göre çok fazla üstün olmadığını gösteren bir çalışma yapmışlardır. Çalışmalarında yapay sinir ağı, destek vektör makineleri gibi doğrusal olmayan sınıflandırma yöntemi ile doğrusal sınıflandırma biçimi olan lineer ayırtaç analizi (linear discriminant analysis) yöntemini

karşılaştırmıştır. Bunu yaparken 5 ayrı düşünsel durumda kaydedilmiş EEG verilerini kullanmışlardır. Buldukları sonuçlarda destek vektör makineleri ile sınıflandırma ortalama %72, yapay sinir ağına göre %69.4, lineer ayrışım analizine göre %66 oranında başarımla elde etmişler ve doğrusal yöntemin daha hızlı çalıştığını ve doğrusal olmayan yöntemlere göre de çok az hata yaptığını belirtmişlerdir.

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

Übeyli ve Güler (2004), Dalgacık Dönüşümü ile EEG işaretlerinden çıkarılan öznelik vektörleri üzerinde istatistiksel işlemlerin gerçekleştirilmesi ile ilgili bir çalışma yapmışlardır.

Subaşı ve Erçelebi (2005), çalışmalarında EEG sinyallerinin sınıflandırılması için sinyalleri Dalgacık Dönüşümü ile frekans bantlarına ayırmış, yapay sinir ağları ve Logistik Regresyon yöntemiyle sınıflandırma yapmışlardır.

Batar (2005), tez çalışmasında EEG işaretlerini dalgacık analiz yöntemini kullanarak yapay sinir ağlarıyla uyku, yarı uyku ve uyanıklık durumlarına göre sınıflandırma yapmıştır.

Güneş ve ark. (2006), EEG işaretlerinin dalgacık analizini yaparak Kısa Zaman Fourier Dönüşümü ile karşılaştırmışlardır.

Jahankhani ve ark. (2006), Epilepsili ve sağlıklı bireylerden alınan EEG sinyallerinden Ayrık Dalgacık Dönüşümü ile öznelik vektörleri elde etmişler, MLP ve RBF ağlar ile sınıflandırma yapmışlardır. Arka planı gürültülü EEG işaretlerine gömülmüş, sabit olmayan anlamlı EEG işaretlerini elde etmek için etkili bir yöntem olduğunu söylemişlerdir. Ayrıca karar verme zamanını arttırmak için çok kanallı EEG cihazından elde ettikleri işaretlerin boyutlarını temel bileşenler analizi (PCA)

yöntemini kullanarak azaltmışlardır.

Tezel ve Özbay (2007), EEG sinyallerinin sınıflandırılmasında yeni bir yaklaşım denemişler, hatanın geriye yayılmasına dayanan geleneksel YSA ile yeni bir YSA modeli kullanarak epileptik EEG sinyallerinin sınıflandırma doğruluğu ve performans hızını değerlendirmişlerdir.

Toprak (2007) EEG Sinyallerinin Dalgacık Dönüşümü ve Yapay sinir ağları ile analizi, adlı Yüksek Lisans tezi çalışmasında EEG sinyallerinin sınıflandırılması ve daha net veri analizinin yapılabilmesi için DD ve YSA metotları birlikte kullanmıştır. EEG işaretlerinin spektral analizi ADD ile gerçekleştirmiş. Elde edilen öznitelik vektörleri çeşitli ağ yapılarının girişlerine uygulayarak değişik algoritmaların, işareti, epilepsi-normal olarak, sınıflandırma performanslarını incelemiştir.

Sezer (2008) Epilepsi teşhisi için EEG sinyal analizi [EEG signal analysis for epilepsy diagnosis] adlı yüksek lisans tezi çalışmasında değişik YSA yapılarını deneyerek, EEG sinyallerinden epilepsi teşhisi yapmak için en hızlı ve en başarılı olan YSA yapısını belirlemeye çalışmıştır.

Özer (2010) EEG işaretlerinin diskriminant analizi ile sınıflandırılması [Classification of EEG signals by using discriminant analysis] adlı Yüksek lisans tezi çalışmasında EEG işaretlerinin farklı önışlemlerle diskriminant analizi ile karşılaştırmalı olarak sınıflandırmış ve danışmanlı algoritmaların (LDA ve DVM), danışmansız algoritmalarından (K-ortalama ve BCO) daha başarılı sonuçlar verdiği sonucunu gözlemlemiştir.

Yapılan çalışmalarda Dalgacık Dönüşümünün sınıflandırma başarımlarının üzerindeki etkisi üzerine yeterli düzeyde durulmadığı ve geliştirmeye ihtiyaç duyulduğu görülmektedir.


2.GENEL KAVRAMLAR

2.1 BEYİN VE YAPISI

2.1.1 Beyin Anatomisi

Beyin merkezi sinir sisteminin en önemli parçasıdır, kafatası içerisinde yer alır ve beyni içten çevreleyen bir zar tarafından korunur. Yüzeysel olarak beyin ortalama 2000-2100 cm²'dir, kütlesi ise yetişkinlerde ortalama olarak 1300-1400 gramdır. (Jensen, 2006).

Beyin dört ana yapıdan meydana gelir : Beyin, Beyincik, Köprü, Soğancık. Beyin, en büyük alana sahiptir.. Beyin sağ ve sol beyin yarımküresi olmak üzere iki bölümden oluşur. Sağ beyin yarım küresi, vücudun sol tarafını, sol yarımküre ise sağ tarafını kontrol eder. Beyin zarı olarak adlandırılan beynin dıştaki katmanı gri maddeden yapılır. Gri madde sinir hücrelerinden oluşturulur Bu hücreler beyin aktivitelerini kontrol eder. İç kısım beyaz maddedenidir.. Beyaz madde, beyindeki sinir hücreleri ile omurilik arasında bilgi taşıyan aksonlardan oluşturulur. Hemisfer, Şekil 1'de numaranlandırılan frontal (1), parietal (2), temporal (3) , oksipital (4) ve serebellum (5) olarak adlandırılan 5 loba ayrılabilir (Sekil 2.1).



Şekil 2.1: Beynin Yapısı

Frontal lob: Bilinçli düşünmede rol oynar ; zarar görmesi durumunda ruh hali ve hissiyat değişikliği olabilir.

Parietal lob: Çeşitli duyu organlarından gelen bilgileri birleştirmede önemli rol oynar. Ayrıca nesnelerin kullanılması ve bazı mekansal görüş işlemlerinde parietal lobun kimi bölümleri rol alır.


Oksipital lob: Görme duyusuyla ilgili bilgilerin işlendiği lobdur.

Temporal lob: Koku ve sesin algılanması, aynı zamanda da yüzler, mekanlar gibi karmaşık uyarıların işlenmesinde rol oynar

Serebellum: Duyu organlarından gelen bilgilerle hareketi ilişkilendirir ve özellikle dengenin sağlanmasında önemli rol oynar.


2.1.2 Sinir Ağı

Beyin çoğu hareket ve davranışın düzenlenmesi ve denetlenmesinin yanında, kan basıncı, kalp atışı, sıvı dengesi ve beden sıcaklığı gibi beden işlemlerini de düzenler ve denetler. İnsan beyninde yaklaşık 100 milyar nöron bulunur ayrıca beyin bir milimetreküpünde bir milyondan fazla nöron vardır (Jensen, 2006). Merkezi Sinir Sistemini (MSS) oluşturan beyin ve omurilikten kodlanmış sinir darbeleri halindeki komutlar, sinirler yoluyla organlara gönderilerek organların faaliyetlerini düzenler. Her bir sinirin diğer sinirlerle bağlantıya sahip olduğu bu yapı, Sinir Ağı olarak adlandırılmaktadır. Sinir sistemi ve beyin fonksiyonlarının ana unsuru olan nöronlar hücre gövdesi, dendrit ve akson olmak üzere üç temel kısımdan oluşur. Nöronlar, dendrit adı verilen ve hücre gövdesinden çıkan on binlerce kola sahiptir. Dendritler diğer nöronlardan aldığı elektriksel etkiyi akson adı verilen uzun bir lif boyunca diğer nöronlara iletir. Her nöron miyelin kılıfla sarılı bir tane aksone sahiptir (Sousa, 2001). Nöronlar sinaps adı verilen ve akson uçları, dendrit veya hücre gövdesi arasında bulunan birleşme noktaları aracılığıyla iletişim kurarlar.



Şekil 2.2. Nöronun Yapısı (Stevens ve Goldberg, 2001)

Beyindeki iletişim sinir hücreleri arasında elektriksel ve kimyasal sinyaller aracılığıyla oluşur. Sinir hücresi kendi elektrik sinyalini oluşturur ve akson aracılığı ile dendrit'lere gönderir. Dendrit'ler ise bu sinyalleri sinapslere göndererek diğer sinyallerin hücelere gönderilmesini sağlar. Böylece iki hücre arasında bilgi alışverişi sağlanmış olur (Wolfe, 2001). Şekil 2.2'te hücreler arası iletim gösterilmektedir.



Şekil 2.3. Sinir sistemi iletişimi (Sezer'den, 2008)

Hücrelerdeki elektro-kimyasal olayların sonucu oluşan iyonik akımlar elektrotlar yardımıyla alınıp işaret işleme işlemlerinden geçirildikten sonra çeşitli hastalıklara tanı konmasında yararlanır.

2.2 EPİLEPSİ

2.2.1 Epilepsi Nedir

Epilepsi, aralıklı olarak tekrar eden kriz nobetleriyle tanımlanan bir norolojik rahatsızlıktır ve dünya nüfusunun yaklaşık %1'inde görülmektedir. Epilepsinin çok farklı türleri bulunmaktadır, bu nedenle her hastada farklı şekilde görülebilir. Epilepsi nöbeti tüm vücudun kasılması ve çarpınma şeklinde olabildiği gibi, sadece yüz, kol ya da bacakta kasılma, anlamsız konuşma ve davranışlar, titreme ve sabit bakma şeklinde de epilepsi nöbetleri görülebilir. (Gökcil, 2007).

Epilepsiden bahseden ilk kişi M.Ö. 350'lerde Hipokrat'tır. Bu yüzden "Hipokrat hastalığı" olarak da bilinir. Epilepsi ile ilgili ilk fizyopatolojik değerlendirmeler 19. yüzyılda John Hughlings Jackson tarafından, sadece klinik gözlemlere dayanılarak ortaya atılmıştır. Jackson'ın epilepsi alanına yaptığı katkılar modern tıp bilimi tarafından hala kullanılmaktadır.

2.2.2 Epilepsi Nöbetleri

Epilepsi nöbetleri, beyindeki hücrelerin kontrol edilemeyen, ani ve anormal deşarjlarına bağlı olarak ortaya çıkan bir durumdur. Beyin hücreleri arasındaki uyumlu çalışma, elektriksel sinyallerle sağlanır. Nöbetin nedeni, bir tür beklenmeyen elektriksel uyarı olarak düşünülebilir. Kısaca; epileptik nöbet, beynin kuvvetli ve ani elektriksel boşalımı sonucu oluşan kısa süreli ve geçici bir durumdur. Bayılma, morarma, sıçrama, çarpınma, anlamsız bakma, dalma vb. şekilde ortaya çıkan bir rahatsızlıktır. (Gökçil, 2007)

2.2.3 Epilepsi Teşhisi

Epilepsi tanısında en önemli nokta; nöbetler hakkında verilen bilgidir. Genel fizik ve nörolojik muayene yapıldıktan sonra başvurulacak ilk laboratuvar inceleme aracı; elektroensefalografi (EEG) dir. Normal EEG epilepsi olmadığını göstermez ve anormal EEG de her zaman epilepsi demek değildir. EEG tetkiki kısa süreli, dinamik bir tetkik

olduğundan çekim sırasında herhangi bir anormallik ortaya çıkmayabilir. Bu nedenle; tanıya yardımcı olmak amacı ile tekrarlayan ya da uykusuzluk/uyku EEG çekimleri yapılabilir. Epilepsi hastalığı tanısının konulmasında en önemli tetkik EEG'dir. Bilgisayarlı beyin tomografisi (BBT) ve magnetik rezonans incelemesi (MRI) epilepsi nöbetlerine neden olan olayların ortaya konmasında yardımcı olabilir.

2.2.4 Epilepsi Nedenleri

Epilepsi; doğuştan gelen kromozom hastalıkları, bazı enzim eksiklikleri , gebelikte bebeğin beyin gelişimini etkileyen mikrobik hastalıklar, doğum sırasında meydana gelebilecek beyin zedelenmesi ve beynin oksijensiz kalması, doğum sonrası menenjit, beyin iltihabı, beyin zedelenmesi, beyin tümörleri, uzun süren ateşli havaleler ve tiroid hastalıkları sonucunda ortaya çıkabilir (Epilepsie Fonds 2005).

2.2.5 Epilepsi Tedavisi


Epilepsi rahatsızlığı, mutlaka doktora başvurulmasını ve doktorun gerekli gördüğü sürece kontrol altında kalınmasını gerektirir. Basit bir epilepsi nöbeti zararsız olmakla beraber, nöbetlerin tekrarlaması, beynin oksijensiz kalmasına yol açabilir.

Epilepsi ilaçla veya cerrahi olarak tedavi edilebilir. %70-75 oranında tek ilaçla nöbetler kontrol altına alınabilir. Epilepsili hasta ilacını kullanarak aktif ve başarılı bir yaşam sürebilir (Gökçil, 2007). Epilepsinin tedavisi için farklı yöntemlerin bulunmasına rağmen hastaların %25'inde bu nöbetler kontrol altına alınamamaktadır (Gardner et al., 2006). Farklı ilaçlar kullanılarak epilepsi nobetlerinin onune gecilmeye çalışılmasının yanı sıra beynin sorunlu bölgesini elektriksel olarak uyaran cihazlar da geliştirilmeye çalışılmaktadır. Bu tarzdaki çalışmaların etkili bir bicimde uygulanabilmesi için de epilepsi tespiti ve tahmini çok önemlidir.

2.3 EEG (ELEKTROANSEFALOGRAM)

2.3.1 EEG Nedir?

EEG işaretleri, beyin yüzeyinden elektrotlarla algılanan düşük genlikli biyoelektrik işaretlerdir. Kelime anlamı olarak Yunanca'da "Beyin elektriksel resmi" anlamına gelmektedir. Beyinde bir takım elektriksel faaliyetlerin varlığı ilk defa, 1875 yılında Caton tarafından hayvanlar üzerinde yaptığı araştırmalar sonucu ortaya çıkmıştır.. 1929 yılında ise Hans Berger ilk defa, insan beyninde elektriksel aktivitenin varlığını, kafaya yerleştirilen elektrotlar ve bunlara bağlı bir galvanometre yardımıyla ortaya koymuştur. Berger, 1930'da Elektroansefalogram (EEG) adı verilen bu dalgaların gözün açılıp kapanmasıyla değiştiğini göstermiştir.



Şekil 2.4 Hans Berger tarafından kaydedilen ilk EEG sinyali

Elektronikteki gelişmelerle birlikte EEG işaretlerinin varlığı bilimsel bir şekilde ortaya konulmuş ve 1934 yılında Adrian ve Matthews, elektrotlarla alınan EEG işaretlerini kuvvetlendirip kaydedilmesini sağlamışlardır. 1939 yılında P. A. Davis, uyanık bir insanın EEG'sinde, sese karşı uyarılan yanıtların olduğunu bulmuştur. H. A. Davis ve arkadaşları aynı sene, aynı olayın uyuyan insanda da meydana geldiğini göstermişlerdir. İkinci Dünya Savaşı sonrasında, elektronik ve bilgisayar alanında meydana gelen büyük gelişmelerle birlikte ortaya çıkan olumlu sonuçlar, bu alanda da kendisini göstermiş ve EEG'nin klinik uygulamaları geliştirilerek tanımı üzerinde yapılan araştırmalar olumlu sonuçlar vermiştir (Yazgan, 1996). EEG sinyalleri, yaşa, cinsiyete, beynin uyanıklık durumuna, bilişsel uyaranlara, genetik faktörlere ve beyin hastalıklarının var olup olmamasına bağlı olarak değişimler gösterirler. Beyindeki sinir hücreleri tarafından hem uyanıklık, hem de uyku halindeyken üretilen elektriksel

faaliyet kağıt üzerine beyin dalgaları halinde yazdırılır. EEG, insan davranışlarını anlamak ve sonuç çıkarmak için beyindeki işlemlerin temelinde yatanı yansıtmaya yeteneğine sahip fizyolojik bir sinyaldir. Beyin normal elektriksel faaliyetini sürdürürken epilepsi (sara hastalığı) gibi pek çok nedenden dolayı aktivitesi bozulur. EEG ile ölçülen beyin dalgalarının değerlendirilmesi ile bu bozukluk hakkında bilgi edinilir.


2.3.2 EEG Dalgaları

Elektroansefalografi (EEG) işaretleri, EKG ve EMG işaretlerinde olduğu gibi şekil bakımından değil, kapsadığı frekanslara göre değerlendirilmektedir. EEG işaretleri periyodik olmadığından genlik, faz ve frekansları sürekli değişir. Bu nedenle, anlamlı bir veri elde edebilmek için, uzun süreli ölçümler yapılması gerekmektedir. Bir EEG işareti içerisinde, kişinin ruhsal durumuna ve düşündüklerine göre, farklı frekans bandına sahip beş ayrı dalga bulunabilir. EEG işaretlerinin analizinde morfolojik özelliklerinin yanı sıra bu dalgalardan da faydalanılır. Tablo 2.1’de EEG işaretlerinin kapsadıktan frekans bandları ve bu bandlara verilen özel isimler birlikte gösterilmiştir (Yazgan, 1996).

Tablo 2.1. EEG Frekans bandları


BAND İSMİ	SEMBOL	FREKANS ARALIĞI	OLUŞTUĞU BÖLGE
Delta	δ	0,5 – 3,5 Hz	Değişken
Teta	θ	4 – 7 Hz	Değişken
Alfa	α	8 – 12 Hz	Oksipital / Parietal
Beta	β	12 – 22 Hz	Frontal
Gamma	γ	22 – 30 Hz	Değişken

Delta Dalgaları: 0.5 hertz ile 4 hertz frekansları arasındaki spektrum bölümü delta aralığıdır. Bazı durumlarda 1 Hz’in altına da düşer. Genlikleri, 100 μ V (p-p)’den küçüktür. Delta dalgaları süt çocuklarında, genç çocuklarda, derin uyku halinde ve ağır organik beyin hastalıklarında görülür. Yetişkinlerde görülen delta aktivitesi anormal olarak nitelendirilir (Yazgan 1996; Koçal, 2007).




Şekil 2.5 Delta Dalgası

Teta Dalgaları: 4 hertz ile 8 hertz frekansları arasındaki spektrum bölümü teta aralığıdır. Teta aktivitesi genellikle çocuklarda beyinin temporal ve merkezi bölümünde bulunur. Yetişkinlerde duygusal, gerginlik ve düş kırıklığı durumlarında ortaya çıkar. Genlikleri $100 \mu\text{V}$ (p-p)'den küçüktür (Koçal, 2007).



Şekil 2.6 Teta Dalgası


Alfa Dalgaları: 8-12 Hz arasındaki beyin dalgalarıdır ,genlikleri $50 \mu\text{V}$ kadardır. Uyanık normal ve sakin kimselerde görülür. Yoğun şekilde oksipital bölgede ortaya çıkar. Uyku durumunda yok olurlar. Uyanık kişi dikkatini özel bir şeye yöneltirse alfa dalgaları yerine, daha yüksek frekanslı, fakat düşük genlikli EEG işaretleri (beta dalgaları) meydana gelir (Yazgan 1996).



Şekil 2.7 Alfa Dalgası


Beta Dalgaları: 13 hertz ile 23 hertz frekansları arasındaki spektrum bölümü beta aralığıdır. Beta ritimleri genel olarak normal yetişkinlerde ön merkezi beyinden alınır. Saçlı derinin parietal ve frontal bölgelerinde belirgin olarak kaydedilebilir. Beta-I (BI) ve Beta-II (BII) diye ikiye ayrılırlar. BII dalgalarının frekansı, BI'dalga frekansının iki

katıdır ve alfa dalgalarında olduğu gibi zihinsel aktivitenin artması ile ortadan kalkarlar ve yerlerine düşük genlikli asenkron işaretler oluşur. BII dalgaları, merkezi sinir sisteminin kuvvetli aktivasyonunda veya gerginlik hallerinde ortaya çıkar (Yazgan 1996).



Şekil 2.8 Beta Dalgası

Gamma Dalgaları: Bazı araştırmacılar tarafından kullanılmaktadır. Genlikleri, $2 \mu V$ (p- p)'den daha küçüktür. Kafanın merkezinde, genlikleri daha büyüktür. Uykunun karakteristik belirtisini taşırlar (Yazgan, 1996).



Şekil 2.9 Gamma Dalgaları

2.3.3 EEG Kullanım Alanları

Tıp : EEG, Başta epilepsi olmak üzere bir çok beyin rahatsızlıklarının teşhisinde hastaya acı vermeyen ve ucuz bir yöntem olması nedeniyle yaygın olarak kullanılır.

Nöroloji: EMG, Ekokardiogram ve nörolojik kontroller ile birlikte hastanın beyin patolojisinin belirlenmesinde,

Beyin Cerrahisi (Neurosurgery): Beyinden ameliyatla çıkartılacak tümör gibi anormal patolojik dokuların yerinin belirlenmesinde,

Anestezi: Anestezi altındaki hastanın anestezi seviyesinin belirlenmesinde,

Pediyatri: Ortalaması alınmış uyarılmış potansiyeller (Averaged evoked potentials) gibi diğer test yöntemleriyle birlikte, yeni doğmuş çocukların işitme ve görme problemlerinin belirlenmesinde,

Psikiyatri: Zihinsel bir bozukluğun daha kesin bir şekilde belirlenmesi amacıyla, organik bir beyin hastalığının var olup olmadığının belirlenmesinde kullanılmaktadır. EEG işaretlerindeki ana bileşenin frekansı yaşla birlikte artar, genlikleri ise azalır. Bir çocuğun EEG'sinin genliği büyük, frekansı düşüktür. Yetişkinlerde genlik düşer, frekans artar. , EEG üzerinde etkili olan durumlardan biride şuur durumudur. Şuur durumuna bağlı olarak uykudaki yetişkinde EEG'nin genliği artar, frekansı ise azalır.(Yazgan, 1996).

EEG, psikomatik bulguların tanısında yardımcı olmamaktadır .EEG klinikte, beyin iki yarım küresinin elektriksel hareketleri karşılaştırılarak kafa içindeki yabancı yapıların lokalizasyonunda kullanılmaktadır. (Kalaycı, 1996).

EEG, epilepsinin tanınması, izlenmesi ve tedavisinin planlanması aşamalarında klinik açıdan önem taşıyan bir yöntemdir. Epilepsi, bir grup beyin hücresinin aşırı boşalmasına bağlı, mental ve motor fonksiyonların geçici olarak kaybolduğu, epileptik krizler ile kendini gösteren nörolojik bir fonksiyon bozukluğudur. Epilepsi krizleri sırasında EEG’de epileptik aktivitenin saptanması, epilepsinin diğer epilepsi benzeri kriz oluşturan hastalıklar ile ayırıcı tanısının yapılabilmesini sağlar. Epileptik krizler sırasında EEG’de yüksek genlikli, tekrarlayıcı, birbiri ardı sıra gelen dalga şekilleri gözlenir. Krizler arası (interictal) dönemlerde ise diken (spike), diken-dalga kompleksi (spike-and wave), keskin dalga (sharp wave) gibi kısa süreli dalga tipleri kaydedilir (Kalaycı, 1996).

3. MALZEME VE YÖNTEM

3.1 MALZEME

3.1.1 Kullanılan Veri

Bu çalışmada kullanılan EEG sinyalleri; Bonn Üniversitesi Epileptoloji bölümü veri tabanından alınmıştır. Tüm veri, 5 kümeden oluşmaktadır (A,B,C,D,E) ve her küme 100 tek kanal EEG segmenti içermektedir. Her bir segment artefaktların gözle incelenmesinden sonra seçilmiştir. A kümesi, sağlıklı kişilerden, gözler açık biçimde, yüzey elektrotları ile kaydedilmiş EEG verisini içerir. B kümesi, sağlıklı kişilerden, gözler kapalı biçimde, yüzey elektrotları ile kaydedilmiş EEG verisini içerir. C ve D kümeleri, hastalıklı kişilerden, epilepsi krizinin olmadığı anda, girişimsel olarak kaydedilmiş EEG verisini içerir. E kümesi ise hastalıklı kişilerden, epilepsi krizi anında, girişimsel olarak kaydedilmiş EEG verisini içerir. Bu EEG işaretlerinin örnekleme frekansı 173,61 Hz ile sayısallaştırılmıştır ve her bir küme 39.33 dakikalık kayıt içermektedir. Analizlerde, sağlıklı gönüllülerden (Küme A) ve epilepsi hastalarından (Küme E) alınan EEG işaretleri kullanılmıştır. Küme A; kafatası dışından, küme E; kafa boşluğu içinden kaydedilmiştir. Verilerin incelenmesinde MATLAB programından faydalanılmıştır.

3.2 YÖNTEM

3.2.1 Dalgacık Dönüşümü

Dalgacık Dönüşümü son yıllarda kullanımı yaygınlaşan ve işareti alt frekans bandlarına ayırtıran bir sinyal işleme yöntemidir. Dalgacık dönüşümü, zamanla karakteristiği değişen durağan olmayan sinyal işleme için zaman ölçekli inceleme yöntemi olarak ortaya çıkmıştır.

Genel olarak Dalgacık Dönüşümleri herhangi bir sinyali ölçek parametreleriyle etiketlenmiş yerel bileşenlerine ayrıştırmaktadır. Böylelikle sinyallerin zamansal karakteristiklerini spektral bileşenler cinsinden ifade etmek mümkün olmaktadır. Dalgacık Dönüşümlerinin bu özelliği görüntü işleme, konuşma tanıma ve özellikle biyomedikal sinyal işleme gibi alanlarda çok önemli uygulama alanları bulmasına yol açmıştır (Tansel ve ark. 1993). Dalgacık Dönüşümü durağan olmayan sinyaller ve nümerik sinyal işleme üzerine oldukça fazla kullanılmaktadır. Dalgacık Dönüşümünde de Fourier analizinde ki gibi sinyal alt bileşenlerine bölünür. Fourier analizi bir sinyalin analizini yaparken sinyali farklı frekanslardaki sinüs ve kosinüs bileşenlerine böler. Dalgacık Dönüşümü ise sinyali ana dalgacığın ölçeklenmiş ve kaydırılmış alt dalgacıklarına böler. Durağan olmayan türdeki sinyallerin işlenmesinde, sinyalin zaman ve frekans bölgeleri arasında bir ilişki elde etmek çok yararlı olmaktadır. Dalgacık Dönüşümü, farklı frekanslarda durağan olmayan güce sahip zaman serisi sinyallerinin analizinde kullanılabilir. Fourier analizi sinyali sadece frekans bölgesine taşıdığından sinyalin zamandaki bilgileri kaybolmaktadır. Bu nedenle durağan olmayan sinyallerin analizinde Fourier dönüşümü yeterli olmamaktadır.


EEG işaretleri durağan olmayan sinyallerdir ve bu işaretlerde zaman zaman ortaya çıkan kısa süreli dik darbeler ve karmaşık dalgalar teşhis için önemli bilgiler taşımaktadır. Bu durumda bu özel spektral bileşenlerin hangi zaman aralığında meydana geldiği önemli olabilir ve Fourier analizi yetersiz kalır (Yazgan ve Korürek, 1996).

Fourier dönüşümü, sinyali dönüştürürken frekans bölgesine taşır, sinyalin zaman bilgisi kaybolur, durağan kendini sürekli tekrar eden sinyallerde bu sorun teşkil etmez ama durağan olmayan yani EEG gibi sinyallerin analizinde dalgacıkların yapısı itibariyle Dalgacık Dönüşümü kullanılır. Birçok veri sinyali, önemli sayılabilecek durağansızlıklar veya geçici özellikler (eğim, ansızın değişim, kırılma ve olayların başlangıç ve bitişleri) içerebilir. Bu beklenmedik özellikler ve durağansızlıklar, veri sinyalinin en önemli kısımları olabilmektedir (özellikle EEG ve EKG vb.) , bu noktada Dalgacık Dönüşümü kullanımı bir zorunluluk olarak karşımıza çıkmaktadır.

Dalgacıklar sonlu süreli dirler bu yüzden yerel sinyal özelliklerinin analizini mümkün kılarlar. Dalgacık Dönüşümleri tüm sinyal frekans- zaman bilgisini korurlar. Bu

sebeplerden dolayı durağan olmayan gerçek doğal sinyallerin dalgacık temelli metotlarla işlenmesi geleneksel metotlardan daha iyi sonuçlar sağlarlar (Miner 1998). Özellikle durağan olmayan sinyallerde karşılaşılan süreksizliklerin sinyaldeki yerini daha iyi tespit edebilmek amacıyla Dalgacık Dönüşümü kullanılır.

Dalgacık analizinde sinyal, dalgacık ölçekleri ile gösterilir ve Fourier temelli analizde olduğu gibi sinüs temel fonksiyonları değil de dalgacık fonksiyonları kullanıldığından keskin süreksizlikleri içeren veriler için çok uygundur. Dalgacık Dönüşümlerinde zaman tanımlı bölgesinde verilen sinyal, dalgacık fonksiyonu denilen özel bir fonksiyonla çarpılır ve sinyalin her bir kesiti için dönüşüm hesaplanır. Dalgacık Dönüşümlerinde ana hedef bir sinyali ölçek parametreleri ile etiketlenmiş temel fonksiyon kümelerine ayrıştırabilmektir. Bu büyük boyutlu sinyallerin daha küçük yerel bölgelerinde analizine olanak tanır. Diğer bir ifadeyle, düşük frekanslar için geniş, yüksek frekanslar için dar olacak şekilde değişen pencere boyutlarının olmasıyla, bütün frekans aralıklarında optimum zaman- frekans çözünürlüğü sağlanabilmektedir. (Şekil 4.2) Zaman tabanlı (Shannon), frekans tabanlı (Fourier), STFT (gabor) ve Dalgacık Dönüşümlerini göstermektedir (Polikar 2005).



Şekil 3.1: Sinyal analiz yöntemleri arasındaki ilişki

Dalgacık Dönüşümünün taban fonksiyonlarına “dalgacık” denir. Dalgacıklar ortalama değeri sıfır olan ve zamanla sınırlı bir dalga şeklindedir. Zaman ekseninde kaydırma ve ölçekleme parametreleri dalgacıkların temelini oluşturmaktadır. Dalgacık sinyalinin

genleştirildiği bölgelerde sinyaldeki yavaş değişimleri ve/veya düşük frekansları; büzüldüğü bölgelerde ise ani değişimleri ve/veya yüksek frekans bileşenleri görülebilmektedir.

Dalgacık Dönüşümü, veriyi farklı ölçeklerde ve çözünürlükte analiz ettiği için ayrıntılı bir analiz yapmış olur, çünkü ölçek her defasında iki kat artar ve buna göre analiz tekrarlanır, dolayısıyla çözünürlük artmış olur, bu da sinyalin ayrıntılı olarak işlenmesini sağlar. Bu ise tıp elektroniğinde istenilen bir durumdur. Dalgacık analizi bir sinyale ait zaman ve frekans tanımlı bölgelerindeki bilgileri eşzamanlı olarak gösterir. Böylece sinyaldeki yönsemeler, çöküm noktaları ve süreksizliklerin belirlenmesi diğer sinyal analiz metotlarına göre çok daha kolay olmaktadır.


Dalgacık Dönüşümü ile kayda değer bir kötüleşme olmaksızın bir sinyali sıkıştırmak veya gürültüden arındırmak mümkündür. Ayrıca Dalgacık dönüşümü, başka sinyal işleme yöntemlerinin yakalayamadığı eğimleri, bozulma noktalarını, yüksek dereceli türevlerde süreksizlikleri ve benzerlikleri çıkarmada başarılıdır.

Dalgacık Dönüşümü'nün iki tipi vardır: Sürekli Dalgacık Dönüşümü (SDD) ve Ayrık Dalgacık Dönüşümü (ADD) (Adeli vd., 2002). Sürekli Dalgacık Dönüşümünde ölçeklendirme ve dönüşüm parametreleri sürekli değiştiğinden her bir ölçek için dalgacık katsayılarının hesaplanması zor ve zaman alıcıdır. Bu nedenle daha çok ADD kullanılmaktadır (Güler ve Übeyli, 2004).

3.2.1.1. Dalgacık çeşitleri

Dalgacık dönüşümünde birbirinden farklı dalgacık çeşitleri kullanılır. Çok karşılaşılan dalgacık çeşitleri aşağıda verilmiştir. Bu çalışmada Haar ve Daubechies dalgacıkları kullanılmıştır.


Daubechies dalgacığı: Haar dalgacık'a benzemektedir. Db1, Haar dalgacık'ın aynısıdır. Daubechies dalgacığı fonksiyonun formülü denklem 3.1'de verilmiştir. Şekil 3.2'de grafiksel olarak gösterilmiştir.



Şekil 3.2: Daubechies dalgacıkları. (Sezer'den, 2008)

$$c_i = h_0 s_{2i} + h_1 s_{2i+1} + h_2 s_{2i+2} + h_3 s_{2i+3} \quad (3.1)$$

Haar dalgacığı: İlk orthonormal dalgacık fonksiyonları kümesi, 1910 yılında Haar ile ortaya konmuştur. Haar dalgacık en eski ve en basit dalgacık fonksiyonudur. Haar dalgacık fonksiyonun formülleri denklem 3.2, 3.3, 3.4 ile verilmiştir. Grafiksel olarak ise Şekil 3.3'de gösterilmiştir.



Şekil 3.3: Haar dalgacık fonksiyonu.


$$\psi(x) = 1, 0 \leq x < 1/2 \quad (3.2)$$

$$\psi(x) = -1, 1/2 \leq x < 1 \quad (3.3)$$

$$\psi(x) = 0, x \notin [0,1] \quad (3.4)$$

Meksika şapkası dalgacığı:


Meksika şapkası dalgacığı formülü denklem 3.5 ile verilmiştir. Grafiksel olarak ise Şekil 3.4’de gösterilmiştir.



Şekil 3.4: Meksika şapkası dalgacığı. (Sezer’den, 2008)

$$\psi(t) = \frac{2}{\sqrt{3\sigma\pi^{\frac{1}{4}}}} \left(1 - \frac{t^2}{\sigma^2}\right) e^{\frac{-t^2}{2\sigma^2}} \quad (3.5)$$


Meyer dalgacığı: Meyer dalgacığı formülü denklem 3.6 ile verilmiştir. Grafiksel olarak ise Şekil 3.5’de gösterilmiştir.



Şekil 3.5: Meyer dalgacığı (Sezer'den, 2008)

$$\psi(w) = (2\pi)^{-\frac{1}{2}} e^{\frac{iw}{2}} \sin\left(\frac{\pi}{2} v\left(\frac{3}{2\pi}|w| - 1\right)\right) \quad (3.6)$$


Morlet dalgacığı: Bu dalgacık ölçeklendirme fonksiyonuna sahip değildir fakat net şekilde anlaşılırdır. Morlet dalgacığı formülü denklem 3.7 ile verilmiştir. Grafikselle olarak ise Şekil 3.6'de gösterilmiştir.



Şekil 3.6: Morlet dalgacığı. (Sezer'den, 2008)

$$\psi(x) = Ce^{-x^2/2} \cos(5x) \quad (3.7)$$

Symlets dalgacık: Db ailesinin değişmiş hali olarak Daubechies ile desteklenen simetrik dalgacık yaklaşımıdır. Şekil 4.7’ de Symlets dalgacık ailesine ait fonksiyonların zaman-genlik gösterimleri verilmiştir.



Şekil 3.7 Symlets dalgacık ailesine ait fonksiyonların zaman-genlik gösterimleri (Sezer’den, 2008)

3.2.1.2. Sürekli Dalgacık Dönüşümü

Sürekli Dalgacık Dönüşümü (Continious Wavelet Transform) bütün zaman aralığı boyunca dalgacık fonksiyonu ψ ’nin kaydırılmış ve ölçeklenmiş sekliyle sinyalin çarpımından oluşur. SDD’nin sonucunda birçok dalgacık katsayısı elde edilir bunlar ölçek ve pozisyon fonksiyonlarıdır. Dalgacık Dönüşümünün en önemli özelliği her bir spektral bileşeni için dönüşüm hesaplanırken pencere genişliğinin değişmesidir. Bir $X(t)$ işaretinin Sürekli Dalgacık Dönüşümü Denklem 3.8’deki gibi tanımlanabilir:

$$C(a, b) = a^{-\frac{1}{2}} \int_{-\infty}^{+\infty} X(t) \Psi\left(\frac{t-b}{a}\right) dt \quad (3.8)$$

Formül zamana bağlı olarak sinyal fonksiyonu ve dalgacık fonksiyonunun bileşimidir.

Denklem 3.8'deki $C(a, b)$ dalgacık dönüşüm katsayılarını, $\psi(t)$, analizde kullanılan temel fonksiyonu, a ölçek (frekans) parametresi ve b de zaman (konum) parametresini gösterir. Dalgacık Dönüşümünün iki temel parametresi vardır:

a (ölçek): Bir fonksiyonu sıkıştırır veya yayar. a 'nın büyük değerleri küçük frekanslara (kaba ölçek), a 'nın küçük değerleri yüksek frekanslara (ince ölçek) karşılık gelir.

b (öteleme parametresi): dalgacığın zaman (işaret) veya x ; y boyunca (resim) ötelenmesini sağlar. a ; b sürekli veya ayrık olabilir (Haşiloğlu 1999).

Ölçeklendirme parametresi a , haritadaki ölçek de olduğu gibi, detaylı olmayan genel görünüm için yüksek ölçek, detaylı görünüm için ise düşük ölçek uygundur. Ölçeklendirme, bir sinyalinin zaman-genlik gösterimini sıkıştıran veya genişleten bir matematiksel dönüşümdür. Matematiksel ifade ile; $f(t)$ verilen fonksiyon ise $f(st)$ fonksiyonun ölçeklendirilmiş halidir. Ana dalgacık işlemde tüm pencereler için bir prototip olarak kullanılmak üzere seçilir. a değerini büyütüp küçültmekle Ana dalgacık fonksiyonunun genişmesi ve büzülmesi sağlanır. Ana dalgacık seçildiği zaman hesaplama işlemi $a = 1$ ile başlar ve dalgacık dönüşümü tüm a değerleri için hesaplanır. Büyük ölçek değeri sinyali genişletmek için, küçük ölçek değeri sinyali sıkıştırmak için uygundur. Fakat Ana dalgacık fonksiyonu ifadesine dikkat edilirse a skalalandırma parametresi paydada yer almaktadır. Bu durumda a skalalandırma parametresine, $a < 1$ aralığında değerler verildiğinde sinyal genişlemiş olur ve böylece alçak frekans bileşenlerinin analizi için uygun pencere genişliği elde edilir. a parametresine $0 < a < 1$ aralığında değerler verildiğinde ise sinyal zaman ekseninde sıkıştırılmış olur ve böylece yüksek frekans bileşenlerinin analizi için uygun pencere genişliği elde edilir. Tüm a değerleri için hesap işlemleri yapıldıktan sonra işaretin dalgacık dönüşümü hesaplanmış ve ölçek ve pozisyonun bir fonksiyonu olan dalgacık katsayıları üretilmiş olur. Yüksek frekans analizlerinde kısa pencere seçimleri yeterli

olup, alçak frekans analizlerinde ise uzun pencere aralıkları seçilmelidir. Dalgacık dönüşümü sonucunda oluşan; geniş ölçekli ana dalgacık katsayıları sinyalin kaba sinyal özelliklerini, küçük ölçekli ana dalgacık katsayıları ise küçük ayrıntı özelliklerini ortaya çıkarır. Bu da çok karmaşık sinyallerin analizinde üstünlük sağlar ve aranan bir durumdur.

b öteleme parametresi, pencere fonksiyonun sinyal üzerindeki yerini değiştirir. Yani zaman ekseninde sinyal boyunca pencereyi hareket ettirir. Ayrıca bu terim, zaman-frekans grafiğinde zaman bilgisini sağlar (Polikar 2005).

$1/\sqrt{a}$ çarpanı ise, dönüştürülmüş işretin her ölçekte aynı enerjiye sahip olması için yapılan normalizasyon işlemidir. Bu çarpan sayesinde Ana dalgacık fonksiyonundan elde edilen pencere fonksiyonlarının enerjisinin, Ana dalgacık fonksiyonun enerjisi ile aynı olması sağlanır.

Ters Sürekli Dalgacık Dönüşümü ise C_φ ana dalgacığın kabul olunabilirlik sabiti olmak üzere Denklem 10'da olduğu şekilde verilir:

$$F(t) = CWT^{-1}\{f(t), \psi(a, b)\} \quad (3.9)$$

$$F(t) = \frac{1}{C_\varphi} \int \int CWT\{f(t), \psi(a, b)\} \frac{1}{\sqrt{a}} \varphi\left(\frac{t-b}{a}\right) \frac{da db}{a^2} \quad (3.10)$$

Kabul olunabilirlik sabiti C_φ Denklem 3.11' te verilen ifade ile bulunur.

$$C_\varphi = \int \frac{\varphi^*(w)\varphi(w)}{w} dw, C_\varphi < \infty \quad (3.11)$$

Uygulamalarda Denklem 3.11’de verilen Sürekli Dalgacık Dönüşümünün kullanılmamını zorlaştıran dezavantajlar vardır. SDD ile tek boyutlu sinyalin, iki boyutlu zaman-skala birleşik gösterimi elde edilir. Bu gerekenden fazla olan bir lüzumsuz gösterim şeklidir. Çoğu uygulama için bu fazlalığın giderilmesi gerekmektedir. Fazlalığının giderilmesine rağmen, Sürekli Dalgacık Dönüşümünde sonsuz sayıda baz fonksiyonuna gereksinim devam etmektedir. Ayrıca çoğu sinyalin dalgacık dönüşümünün analitik çözümü mümkün değildir sadece nümerik olarak veya görsel analog bilgisayarla hesaplanabilirler.

Ayrıca SDD zaman-band genişliği çarpımı, sinyalin zaman-band genişliği çarpımının karesine eşittir. Mümkün olduğu kadar az bileşenle bir sinyalin analizini yapmaya çalışan çoğu uygulama için bu dezavantajlar, Sürekli Dalgacık Dönüşümü’nü kullanımını kullanışsız hale getirir. Fazla veri hesaplamak zor ve zaman alıcıdır. Bundan dolayı pratikte Sürekli Dalgacık Dönüşüm’ün ayrık versiyonu kullanılır (Tangirala ve ark. 2001).

SDD, bilgisayarda hesaplanırken ayrık olarak işlenir. Ancak, Ayrık Dalgacık Dönüşümünden farkı ölçeğin ve kaymanın sürekli olmasıdır.

3.2.1.3. Ayrık Dalgacık Dönüşümü


Sürekli Dalgacık Dönüşümü ile tek boyutlu sinyalin, iki boyutlu zaman-skala birleşik gösterimi elde edildiğinden işlem ve veri kapasitesi çok büyüktür.

Çoğu uygulama için bu fazlalığın giderilmesi gerekmektedir. Fazlalık giderilmesine rağmen, SDD’ de sonsuz sayıda baz fonksiyonuna gereksinim devam etmektedir. Çoğu sinyalin DD’ sinin analitik çözümü mümkün değildir sadece nümerik olarak veya görsel analog bilgisayarlarla hesaplanabilir. Ayrıca SDD’ nin zaman-band genişliği çarpımı, sinyalin zaman-band genişliği çarpımının karesine eşittir. Mümkün olduğu kadar az bileşenle bir sinyalin analizini yapmaya çalışan çoğu uygulama için bu dezavantajlar, SDD’ nin kullanımını kullanışsız hale getirir. Bundan dolayı pratikte SDD’ nin ayrık versiyonu kullanılır (Gümüş, 2003). işlem verimliliğini arttırmak için konum ve

ölçeklerin ikili kuvvetleri alınmsı işlemine ikili dalgacık (dyadic) dönüşümü denir. Mallat, ikili dalgacık dönüşümünü sayısal süzgeçlerle gerçekleştirmiş ve bu süzgeçler sayesinde dalgacık dönüşümü işlemi hızlandırılmıştır.

Zaman boyutunda sıkıştırma frekans boyutunda yayılma ve yukarı doğru kaymaya denk düşer veya bunun tam tersi de geçerlidir. Zaman domeninde ötelenmiş baz fonksiyonları ile sinyal nasıl tümüyle kaplanıyorsa aynı yolla frekans domeninde sinyalin sonlu uzunluktaki spektrumu genişletilmiş baz fonksiyonlarının spektrumları ile kaplanabilir. Frekans domeninde sinyalin genişletilmiş baz fonksiyonlarının spektrumları ile en iyi şekilde kaplanması, genişletilmiş baz fonksiyonlarının spektrumlarının birbirleriyle kesişecek şekilde baz fonksiyonlarının ayarlanması ile elde edilir (Gümüş, 2003).

Bir dalgacığın değişen ölçekler için frekans tayfları Şekil 3.7’ de gösterilmektedir. Her bir dalgacık bant geçiren süzgeç olarak alınırsa bunun ölçeklenmiş serisi de bant geçiren süzgeç serisi oluşturacaktır. Her bir spektrumun merkez değeri ile bant genişliği oranına bakacak olursak hepsinde bu oranın eşit olduğu görülür. Bu oran “*sadakat faktörü (Q)*” (fidelity factor) olarak adlandırılır. Ve tüm baz fonksiyonları ise “*Sabit Q faktörlü filtre kümesi*” olarak adlandırılır (Valens 1999).



Şekil 3.7: Ölçekleme ve dalgacık fonksiyonlarının spektrumları (Batar’dan, 2005)


Birçok uygulamada zaman-bant genişliği çarpımının farklı frekans ve/veya farklı zamanlarda bölümlenebilmesi istenir. Şekil 3.7’ den de görülebileceği gibi bu amaca dalgacık dönüşümüyle ulaşılır.

Sürekli Dalgacık Dönüşümü’ndeki bu fazla gereksizlik ölçeğin 2’nin katlarıyla değiştiği dyadic dalgacık parametreleriyle ($a=2^i$ ve $b=k2^i$ gibi) ortadan kaldırılır (Fliege 1996). Böylece hem SDD’ nin genel yapısından gelen fazlalıklar azaltılır yani sadece yeterli düzeyde/sayıda öteleme ve ölçekleme yapılır hem de işaret istenilen yeterli

frekans bantlarında incelenebilir. Ölçek ve öteleme parametreleri olan a ve b 'nin bu şekilde *dyatic* seçilmesi temel fonksiyonu seyrekleştirir.

Şekil 3.8'de verildiği gibi sıfıra doğru sinyal spektrumun, 2 çarpanı ile spektrumunu daralan baz fonksiyonlarını kaplanması için bir alçak geçiren filtre spektrumunu yerleştirilebilir.

Bu çözüm ilk defa 1989'da Mallat tarafından ölçeklendirme fonksiyonu ile yapılmıştır. Bu fonksiyonun spektrumunu gerekli olan alçak geçiren filtre spektrumunu karşılar. Ölçeklendirme fonksiyonu, spektrumun alçak geçiren özelliğinden dolayı, ortalama filtresi olarak da adlandırılır. Bir baz fonksiyonu band geçiren filtre ve skalalandırma fonksiyonu da alçak geçiren filtre olarak kabul edilirse, tüm baz fonksiyonları ve skalalandırma fonksiyonu bir filtre kümesi olarak kabul edilir (Gümüş, 2003).



Şekil 3.8: Ölçekleme ve dalgacık fonksiyonlarının spektrumları (Batar'dan, 2005)

Bu yöntemle, alçak frekansları analiz eden geniş pencereler (j 'nin büyük değerlerine karşılık Ana dalgacık fonksiyonundan elde edilen baz fonksiyonları) büyük adımlarla ötelenmiş olur, aynı şekilde yüksek frekansları analiz eden dar pencereler (j 'nin küçük değerlerine karşılık Ana dalgacık Fonksiyonundan elde edilen baz fonksiyonları) sinyaldeki hızlı değişimleri yakalamak amacıyla, küçük adımlarla ötelenmiş olur. (Sezer, 2008)

$a = 2^j$ ve $b = k2^j$ olarak alındığında Ayırık Dalgacık Dönüşümü denklemi 3.12'deki gibi tanımlanır:

$$W(j, k) = 2^{-j/2} \int X(t) \Psi(2^{-j}t - k) dt \quad (3.12)$$


ADD ile yapılan işlem ve elde edilen katsayı miktarı azalmaktadır. Ayrık Dalgacık Dönüşümü’nde esas amaç sayısal süzgeçleri kullanarak ayrık sinyallerin zaman-ölçek gösterimini elde etmektir. Düşük frekanstaki bileşenlerin analizi için sinyal alçak geçiren filtrelerden, yüksek frekans bileşenlerini analiz yapmak için ise yüksek geçiren filtrelerden geçirilir. Bunun sonucunda ADD farklı frekans bantları ve çözünürlükte analiz yaptığı için sinyali yaklaşıklık ve ayrıntı bileşenlerine ayrıştırabilmektedir. Yaklaşıklık sinyalin büyük ölçekli-düşük frekanslı bileşenlerine karşılık gelirken, ayrıntı kısmı ise küçük ölçekli-yüksek frekanslı bileşenlerini oluşturmaktadır (Misiti ve ark. 2000).

DD bir filtre kümesi olarak göz önüne alınırsa, DD işlemini sinyalin bu filtre kümesinden geçirilmesi olarak düşünebiliriz. Her farklı filtrenin çıkışı Dalgacık ve skalalandırma fonksiyonu dönüşüm katsayılarıdır. Bu analiz “*alt band kodlaması*” olarak adlandırılmaktadır (Gümüş, 2003).

Bu analizde, $x(t)$ işareti ayrı ayrı alçak geçiren ve yüksek geçiren filtrelerden geçirilerek iki frekans bandı elde edilir. Filtre çıkışında yeralan işaretteki her iki örnekten biri atılır. Böylece işaretin yaklaşıklık katsayıları ve ayrıntı katsayıları elde edilmiş olur. Yüksek geçiren kısmı genelde istenilen detayları içeren kısımdır. Yaklaşıklık katsayıları bir sonraki ölçeğe ait katsayıları elde etmek için kullanılır (Çetin ve Kucur 2003). Eğer istenilen bilgi elde edilebilirse bu işlem burada sonlandırılır. Fakat hala alçak geçiren kısımda ilgilendiğimiz sinyalin detayları yer almaktadır ve bunların incelenmesi amacıyla alçak geçiren kısmı tekrar alçak ve yüksek geçiren olmak üzere iki parçaya bölünebilir. Birçok işaret için düşük frekans bilgileri işaretin en önemli kısmıdır. Diğer yandan, yüksek frekans kısmı ise ayrıntılardır (detail). Dalgacık analizinde; yüksek ölçek katsayılarına “yaklaşıklık (approximation)”, düşük ölçek katsayılarına da “ayrıntı (detail)” katsayıları denir. Yüksek geçiren süzgecin çıkışı ayrıntı, alçak geçiren süzgecin çıkışı yaklaşıklık katsayılarını verir. Böylece işaret süzgeçlerden geçirilerek alt bantlarına ayrılır ve işaretin boyutunun değişmemesi için süzgeçlerin çıkışlarının örnek sayısı yarıya indirilir. Bu işlem, istenilen bilgilerin elde edilmesine kadar devam edilebilir. Bu yolla iteratif filtre kümesi elde edilmiş olur. Frekans bandlarının sayısı genelde bilgi veya hesaplanabilir güç miktarına göre sınırlıdır. Şekil 3.6’ da verilen

yöntemde iki filtre tasarlanması yeterli olacaktır, fakat sinyal spektrumunun filtrelerin spektrumları ile kaplanma şekli hep sabittir (Gümüş, 2003).

Ayrık Dalgacık Dönüşümü (ADD), pratikte uygulamalarda iki adımlı bir prosedür olarak gerçekleştirilebilen bir ayrık konvolüsyon denklemdir. Prosedürün ilk adımı ayrık sinyalin, sayısal alçak geçiren ve yüksek geçiren filtrelere uygulanmasıdır. İkinci adımda ise konvolüsyon sonunda yani filtrelerin çıkışında elde edilen diziler, seyrek örnekleme (subsampling) ile baştan itibaren her iki dizi elemanın sadece baştaki eleman alınarak, eleman sayıları yarıya düşürülür. Ayrıca bu işleme aşağıya doğru örnekleme (downsampling) de denir. Bu şekilde ayrık sinyalin eleman sayısı toplamı ile konvolüsyon sonucunda elde edilen sinyal dizilerinin eleman sayılarının toplamı aynı olur. Bir $x[n]$ işaretinin Alt bantlarına ayrıştırılma prosedürü blok diyagramı olarak Şekil 3.9'de gösterilmiştir.




Şekil 3.9: DWT ile alt bantlarına ayırma; $g[n]$: yüksek geçiren filtre, $h[n]$: alçak geçiren filtre

Şekil 3.9'daki $h(n)$ alçak geçiren filtrenin, $g(n)$ yüksek geçiren filtrenin dürtü cevabıdır. $d^j(n)$ işaretin ayrıntı katsayılarını, $a^j(n)$ yaklaşık katsayılarını, j dalgacık dönüşümünün seviyesini göstermektedir. Yaklaşık katsayılarını Denklem 3.13 ile, ayrıntı katsayılarını da Denklem 3.14 ile gösterebiliriz ($a^0 = x(n)$).

$$a^{j+1}(n) = \sum_m h(2n - m) a^j(m) \quad (3.13)$$


$$d^{j+1}(n) = \sum_m g(2n - m) a^j(m) \quad (3.14)$$



Şekil 3.10 Ayırık Dalgacık Dönüşümü sinyalin ayrıştırılması işlemi (Burcu'dan, 2007)


Şekil 3.10'da ayrıştırma ile elde edilen sinyalin yaklaşıklığı (i cA), sinyalin alçak frekans bileşenlerini, detaylar (i cD) ise sinyalin yüksek frekans bileşenlerini içerir. cD detay katsayıları küçüktür ve yüksek frekans gürültüsü içerir. cA yaklaşıklık katsayısı orijinal sinyalden çok daha az gürültü içerir (Boztoprak,2005).

Şekil 3.11'de verilen akış şeması, dallanmanın hem alçak hem de yüksek frekans bileşenleri için gerçekleştirilmesi ile edilir ve bu şekilde gerçekleştirilen dalgacık dönüşümü, “*Dalgacık Paket Dönüşümü*” (“*Dalgacık Packet Transform*” (WP)) olarak adlandırılır. Ayrıca Şekil 3.11 'deki akış şeması “Dalgacık Paket Ayrıştırma Ağacı” olarak da bilinir. Dalgacık Paket dönüşümü sayesinde uygulamalarımızda sinyallerin istediğimiz frekans bandlarını analiz edebilme olanağına kavuşuruz.



Şekil 3.11: Dalgacık paket dönüşümü (Burcu'dan, 2007)

Sinyalin, analiz ile elde edilen bileşenlerinden tekrar elde edilmesi işlemine “*Sentez*” veya “*Geriçatılma*” denir. Sentez işleminde, ayrıştırma sonucunda elde edilen dalgacık katsayılarından sinyalin yukarı doğru örnekleme işlemi ile geri çatılması gerçekleştirilir. Şekil 3.12 ‘de gösterildiği gibi yukarı doğru örnekleme işleminde, Dalgacık katsayıları dizilerinde her iki örnek arasına bir “0” genlikli örnek eklenir. Sinyal bu işlem sonunda kayıpsız olarak tekrar elde edilebilir. Aşağıya doğru örnekleme işlemi ile lüzumsuz olarak nitelendirilen bilgilerin arındırılmasının, sinyalin tekrar elde edilmesini engelleyecek veri kaybına yol açmamaktır. Ayrıntı ve yaklaşıklık katsayıları kullanılarak asıl işaret Şekil 3.12’deki gibi tekrar elde edilebilir. İşareti yeniden elde edebilmek için ayrıntı ve yaklaşıklık katsayıları önce 2 ile yukarı örneklenir yani işareti oluşturan her iki örnek arasına sıfır eklenir.




Şekil 3.12. Yukarı doğru örnekleme (Burcu'dan, 2007)

Daha sonra yukarı örneklenmiş işaretler $h'(n)$ ve $g'(n)$ sentez filtrelerinden geçirilerek filtre çıkışlarındaki işaretler toplanır. Sentez filtreleri, $h(n)$ ve $g(n)$ analiz filtrelerinin zaman eksenine göre tersidir ve aşağıdaki denklemlerle ifade edilir.

$$g'(n) = (-1)^n h(n) \quad (3.12)$$

$$h'(n) = (-1)^{n+1} g(n) \quad (3.13)$$



Şekil 3.13: Alt bantlara ayırma yöntemine göre analiz ve sentez işlemleri (Burcu'dan, 2007)

3.2.2 Ön İşleme

Ön işlemlerin amacı verileri standartlaştırarak, özellik çıkarımı için hazır duruma getirmektir. Verilerin ön işlenmesi en zor işlemlerden birisidir. İşaret/görüntü elde etme, bozucu etkenlerin yok edilmesi, ortalama alma, eşik değeri belirleme, işaret/görüntü iyileştirme gibi işlemler ön işlemeyi oluşturmaktadır (Übeyli ve Güler 2004). Mevcut EEG kayıtlarının her biri 4096 örnekten oluşmaktadır.

3.2.3 Öznitelik Çıkarma

Öznitelik çıkarma, farklı düşünce durumunda kaydedilen EEG işaretlerinin önemli özelliklerinin çıkarılıp öznitelik vektörünün elde edilmesi işlemidir.

Öznitelik çıkarma işleminde çok farklı yöntemler kullanılabildiği için EEG işaretini tanımlayan farklı öznitelikler elde edilebilmektedir. Çıkarılan her öznitelik vektörü işareti tanımlayabilir fakat sınıflandırma aşamasında hiç biri yüzde yüz doğruluk vermeyebilir. Bundan dolayı, yüksek sınıflandırma başarımı elde etmek için farklı özniteliklerin birlikte kullanımı gerekli olmuştur. Bu şekilde çok sayıda öznitelik kullanan sınıflandırma işlemleri daha iyi sonuçlar vermektedir.

EEG işaretleri, hastalık teşhisinin doğruluğunu sağlamak için çoğunlukla 8-10 saatlik kayıtlar şeklinde alınmaktadır. EEG kayıtlarının bu şekilde uzun olmasından dolayı, EEG işaretlerinin analizinin bilgisayar ortamında yapılması gerekli olmuştur. Literatürde çok sayıda analiz yöntemi olmakla birlikte bu çalışmada işaretlerin spektral analizi Dalgacık Dönüşümü ile gerçekleştirilmiş ve sınıflama işlemi için kullanılan öznitelik vektörleri elde edilmiştir. Uygun dalgacık seçimi ve ayrışım seviyelerinin sayısının tespiti, işaretlerin Dalgacık Dönüşümü ile analizinde oldukça önemlidir. İşaretin baskın frekans bileşenlerine göre ayrışım seviyelerinin sayısı tespit edilir. Sınıflamanın doğruluğu uygulama için seçilen dalgacık tipine de bağlıdır. Bu çalışmada, EEG işaretleri için ayrışım seviyelerinin sayısı 1 olarak belirlenmiş, dalgacık katsayılarının hesaplanmasında Haar ile 4. dereceden Daubechies dalgacık (db4) kullanımı uygun görülmüştür. Dalgacık Dönüşümü ile sinyal D olarak adlandırılan detay ve A olarak adlandırılan yaklaşım alt-bantlarına ayrılmıştır.

3.2.4 Öznitelik Seçme

Dalgacık katsayıları işaret hakkında önemli bilgi içerdiği için EEG işaretlerinin dalgacık katsayıları işareti temsil eden öznitelik vektörleri olarak ele alındı. Çıkarılan öznitelik vektörlerinin boyutlarının azaltılabilmesi için dalgacık katsayıları üzerinde istatistiksel özellikler kullanıldı. EEG işaretlerinin zaman-frekans dağılımını göstermekte kullanılan istatistiksel özellikler aşağıda verilmektedir:

1. Her bir alt bantdaki katsayıların mutlak değerlerinin ortalaması.
2. Her bir alt bantdaki katsayıların mutlak değerlerinin maksimumu.
3. Her bir alt bantdaki katsayıların kuvvetlerinin ortalaması.

4. Her bir alt bandedeki katsayıların standard sapması.


Özellik 1-3 işaretin frekans dağılımını gösterirken özellik 4 frekans dağılımındaki değişim miktarını göstermektedir (Subaşı, 2005).

3.2.5 Sınıflama

Farklı düşünsel ve görsel durumlarda kaydedilen EEG işaretlerini elde edilen öznitelik vektörlerine göre sınıflandırma önemli bir konudur. İşaretin hangi sınıfa ait olduğuna karar verme hem hızlı hem de doğru olmalıdır. Literatürde birçok sınıflandırma yöntemi mevcuttur. Bunlardan en çok kullanılanları destek vektör makineleri (support vector machines), k en yakın komşuluk (k nearest neighbor), doğrusal ayırtan analizi (linear discriminant analysis), sinir ağları (neural networks), bayes sınıflandırıcısı (bayesian classifier) 'dır. Aynı tür uygulamada değişik sınıflandırma algoritmaları farklı sonuçlar verebilmektedir. Elde edilen öznitelik vektörlerine en uygun sınıflandırıcıyı seçebilmek için sınıflandırma yöntemlerinin özelliklerinin iyi bilinmesi gerekmektedir. Aşağıda sınıflandırmada sıklıkla kullanılan k en yakın komşuluk ve destek vektör makineleri yöntemlerinin özellikleri, üstünlükleri, kritik noktaları üzerinde durulmuş, performans analizleri incelenmiştir.

3.2.6 k- En Yakın Komşuluk Yöntemi

k-en yakın komşuluk algoritması uygulanabilirliği basit, parametrik olmayan öğrenme algoritmalarından biridir. Bir çok değişik uygulama alanında kullanılan bu algoritma, gürültülü eğitim dokümanlarına karşı dirençlidir ve eğitim sayısı arttığında daha etkili olmaktadır. k-en yakın komşuluk uygulaması yeni sorgu örneğini sınıflandırmak için kullanılan bir komşuluk sınıflandırma algoritmasıdır. Eğitim veri kümesine ait örnekler sınıf etiketleriyle birlikte verilmekte ve sınıflandırıcı bu eğitim verileriyle eğitilerek daha önce karşılaşmadığı bir örneğin sınıfını tahmin etmektedir. Bir sorgu örneği verildiği zaman, bu sorgu noktasına en yakın k tane eğitim noktası bulunur. Sınıflandırma ise bu k tane nesnenin en fazla olanı ile yapılır. k-en yakın komşuluk basit ve verimli olduğundan sınıflandırma işlemlerinde sıklıkla kullanılan yöntemlerden biridir.



Şekil 3.14 : Örnek kNN sınıflandırma

Şekil 3.14'deki k-NN sınıflandırma örneğinde; Test örneği (yeşil daire), birinci sınıf (mavi kareler) veya ikinci sınıf (kırmızı üçgen) sınıflandırılması gerekir. Eğer $k=3$ ise ikinci sınıfa atanır çünkü iç daire içinde sadece 2 üçgen ve 1 kare vardır. Eğer $k = 5$ ise, birinci sınıfa atanır çünkü dış daire içinde 3 kareye karşılık 2 üçgen bulunmaktadır.

k-NN İki örnek arasındaki yakınlık veya uzaklıkları ölçen bir uzaklık fonksiyonu esasına dayanmaktadır. x ve y örnekleri arası uzaklık fonksiyonu olarak genellikle standart Euclidean uzaklığı $d(x,y)$ kullanılmaktadır. Genelde ölçüt olarak Euclidean uzaklığının kullanımı yaygın olmakla birlikte probleme göre alternatif diğer ölçütlerin kullanımı ile daha iyi sonuçlar alınabilir.

k-en yakın komşuluk algoritmasının performansı öncelikli olarak uzaklık mesafesine bağlı olmasının yanında k değerinin seçimine de bağlıdır. Genellikle k değerinin yüksek seçilmesi gürültüye karşı daha duyarsız yapmakta ve sınıflar arası sınırları daha yumuşatmaktadır (Rosa,2001).

k-en yakın komşuluk algoritması bir tembel öğrenme örneğidir. Tembel öğrenme basitçe eğitim sırasında eğitim verilerini saklar ve sınıflandırma zamanına kadar öğrenimini geciktirir. Uzaklık bazlı öğrenme algoritması, en iyi sonuçları elde etmek için, hangi uzaklık tipinin ve hangi niteliğin kullanılacağı konusunda açık değildir. Bu çalışmada Öklit (Euclidean), Kosinüs, Cityblock (Manhattan) ve korelasyon uzaklıklarına dayalı en yakın komşuluk yöntemleri karşılaştırmalı olarak uygulanmıştır.

Öklit uzaklığı: $p = p_1, p_2, p_3 \dots p_n$ ve $q = q_1, q_2, q_3 \dots q_n$ n- uzaylı koordinat düzleminde iki nokta olmak üzere, p ve q arasındaki uzaklık denklem 3.14 ile bulunabilir.

$$d(p, q) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (3.14)$$

Cityblock uzaklığı (Manhattan); $p = p_1, p_2, p_3 \dots p_n$ ve $q = q_1, q_2, q_3 \dots q_n$ n- uzaylı koordinat düzleminde iki nokta olmak üzere, p ve q arasındaki uzaklık denklem 3.15 ile bulunabilir.

$$d(p, q) = \|p - q\|_1 = \sum_{i=1}^n |p_i - q_i| \quad (3.15)$$

Kosinüs uzaklığı;

$$\cos(q, r) = d_1 = \frac{\sum_y q(y).r(y)}{\sqrt{\sum_y q(y^2).r(y^2)}} \quad (3.16)$$

Denklem 3.16'da $q(y)$ öznitelik uzayında eğitim noktalarını, $r(y)$ test noktalarını, d_i ($i=1,2,\dots, \infty$) i. denemeye ait uzaklığı belirtir. Test örneği verildiğinde en düşük d_i değerine karşı gelen eğitim örneği bulunur ve sınıfı o test örneği için seçilir.

Korelasyon uzaklığı : Korelasyon katsayısı denklem 3.17 iken

$$\rho_{XY} = \frac{\text{Cov}(X,Y)}{\sqrt{D(X)}\sqrt{D(Y)}} \quad (3.17)$$


Korelasyon uzaklığı denklem 3.18 ile tanımlanır.

$$D_{XY} = 1 - \rho_{XY} \quad (3.18)$$

3.2.7 Destek Vektör Makineleri

Destek Vektör Makineleri (Support Vector Machines (SVM)), sınıflandırma ve regresyon problemlerinin çözümü amacıyla Vapnik tarafından ortaya atılmış istatistiksel öğrenme teorisi ve yapısal riski en aza indirme ilkesine dayanan bir öğrenme algoritmasıdır (Vapnik 1995, 1998). Destek Vektör Makinaları, pozitif ve negatif örnekleri bilinen bir uzayı ikiye bölen en iyi hiper-düzlemi bulmaya çalışan, gözetimli bir öğrenme ve sınıflandırma yöntemidir. DVM, herhangi bir sınıflandırma ya da regresyon problemini, bir karesel programlama problemine dönüştürerek yerel çözümlere takılmadan çözer. Yerel çözümlere takılmama özelliği, DVM'nin diğer tekniklere göre sahip olduğu avantajlardan biridir. Ayrıca DVM, oldukça yüksek genelleme yapabilme yeteneğine sahiptir.

DVM'nin uygulama alanlarına örnek olarak, el yazısı tanıma, yüz tanıma, 3-boyutlu nesne tanıma, ses tanıma, konuşmacı tanıma, metin sınıflandırma verilebilir. DVM sınıflandırıcıları, margin'i (aralığı) maximum yapan bir en uygun (optimal) ayırıcı hiperdüzlemi oluşturmaya çalışır. Burada bahsedilen margin kavramı, ayırıcı hiperdüzlemden, en yakın veri noktasına olan minimum uzaklığı tanımlamaktadır. Şekil 3.15'de verilen iki ayrı kümeyi birbirinden ayırmak için sonsuz sayıda en uygun olmayan hiperdüzlem çizilebilir. Ancak DVM bu iki kümeyi ayırmak için maksimum marjini (en yakın eğitim noktalarının uzaklığı) sağlayan en uygun hiperdüzlemi arar.



Şekil 3.15: Grafik 2 boyutlu eksenlerde yer alan 3 hiperdüzlemi gösterir. H3 sınıflandırma yapmaz iken, H1 küçük marjin ile ve H2 büyük marjin ile sınıflandırma yapar.

DVM sınıflandırıcılarda veriler doğrusal olarak ayrılabilen bir yapıdan ya da doğrusal olarak ayrılamayan bir yapıdan oluşabilir. Ancak, gerçek yaşam problemlerinin büyük çoğunluğu birçok farklı bileşenden oluşan problemlerdir ve doğrusal olarak ayrılmış bir yapı şeklinde olmayabilirler. Doğrusal olarak ayrılabilen veriler arasında maksimum marjin'in bulunması işlemi kolaydır, ancak doğrusal olarak ayrılamayan veriler üzerinde sınıflandırma yaparken, bu veriler öncelikle doğrusal olarak ayrılacakları farklı bir uzaya aktarılmalıdırlar. Ardından veriler bu yeni uzayda sınıflandırılırlar.

DVM sınıflandırıcıları, doğrusal DVM sınıflandırıcıları ve doğrusal olmayan DVM sınıflandırıcıları olmak üzere iki bölümde incelenecektir.

3.2.7.1. Doğrusal Destek Vektör Makinesi sınıflandırıcıları

Doğrusal DVM sınıflandırıcıları doğrusal olarak ayrılabilen ve doğrusal olarak ayrılamayan veriler üzerinde işlem yapan DVM sınıflandırıcıları olarak iki grupta incelenecektir.

Doğrusal olarak ayrılabilme durumu

$(\{x_i, i = 1, 2 \dots l\})$ Eğitim kümesindeki örnekleri, ve $y_i = +1$ ve $y_i = -1$ bu örneklerin sınıf etiketlerini göstermek üzere, pozitif etiketli örnekleri negatif etiketli örneklerden ayırabilen bir hiperdüzlemi ele alalım. Doğrusal ayırma fonksiyonunu denklem 3.19' daki gibi belirtelim.

$$g(x) = w^t \cdot x + b \quad (3.19)$$


Burada w hiperdüzlemin normali ve b eğilim değeri olarak adlandırılır. Ayrıca $\frac{|b|}{\|w\|}$ değeri de hiperdüzlemin merkez noktasına olan dik uzaklığıdır. Bu durumda karar kuralı:

$$w^t \cdot x + b \begin{cases} > 0 \\ < 0 \end{cases} x \in \begin{cases} y_i = +1 \\ y_i = -1 \end{cases} \quad (3.20)$$

$$y_i (w^t \cdot x + b) > 0 \quad (3.21)$$

Böylece tüm eğitim verileri denklem 3.21 koşuluna göre doğru sınıflandırılmış olmaktadır

w ve b sonsuz sayıda değer alabileceğinden birden fazla hiperdüzlem bulunmaktadır. Fakat en büyük marjın bir tanedir ve DVM'nin amacı onu bulmaktır. Marjinin büyüklüğü oranında ayırma hiperdüzlemi ile tanımlanan doğrusal sınıflandırıcının genelleştirme hatasının da o kadar küçük olacağı varsayılmıştır.



Şekil 3.16: Doğrusal ayrılabilme durumunda optimal ayırıcı hiperdüzlem, marjın ve Kuramsal hiperdüzlemler

$H_1 = w^t \cdot x + b = 1$ ve $H_2 = w^t \cdot x + b = -1$, düzlemlerine kuramsal hiper düzlem denmektedir. En büyük marjın $w^t \cdot x + b = 1$ ile $w^t \cdot x + b = -1$ arasındır.

$$\frac{2}{\|w\|} = \frac{2}{\sqrt{w^t \cdot w}} \quad (3.22)$$

$$w^t \cdot x + b \geq +1, y_i = +1 \text{ için} \quad (3.23)$$

$$w^t \cdot x + b \geq -1, y_i = -1 \text{ için} \quad (3.24)$$

Kuramsal hiper düzlemlerin üzerine düşen noktalar destek vektörleri olarak bilinir. Destek vektörleri şekil 3.16'da yuvarlak içerisine alınmışlardır. Marjini maksimize etmek için w minimize yapılır. Bu marjı maksimize yaparken kullanılan w ve b değerleri ve x giriş verisi olmak üzere $w^t \cdot x + b$ denkleminin işareti bulunmaya çalışılır.

Bu bir quadratik programlama problemidir.

Maksimum sınırın bulunması işlemi:

$$\min_{w,b} \frac{1}{2} w^t w \quad (3.25)$$

$$y_i(w^t \cdot x + b) \geq +1, i = 1 \dots l \quad (3.26)$$

ile ifade edilir.

Doğrusal olarak ayrılabilme durumunda, bu iki değerli veriler bir hiperdüzlem ile ayrılacaktır. Bu hiperdüzleme *Ayırıcı Hiperdüzlem* adı verilir. SVM'nin amacı, bu hiperdüzlemin iki örnek grubuna eş uzaklıkta olmasını sağlamaktır. Doğrusal olarak ayrılabilme durumu için, ayırıcı hiperdüzlemi şu şekilde tanımlanabilir (Denklem 3.27):

$$f(x) = \text{sign}(w^t \cdot x + b) \quad (3.27)$$

Burada w bir ağırlık vektörünü (veya hiperdüzlemin normalini), b skaleri de bir sapma değerini ifade etmektedir ve bu parametrelerin alacağı değerler ayırıcı hiperdüzlemin pozisyonunu belirler.

Doğrusal olarak ayrılamama durumu


Bir önceki bölüm'de belirtilen işlemler ancak eğitim örneklerinin tamamen ayrılabilir olması durumunda çalışmaktadır. Eğer ki, örnekler lineer olarak tamamen ayrılabilir

durumda değilse problemin çözümü için pozitif zayıflık değişkenleri $\xi_i, i = 1, 2, \dots, N$ kullanılır (Cortes ve Vapnik, 1995). Denklem (3.27)'deki koşul bu zayıflık değişkenleri ile yeniden tanımlanacak olursa, yeni ifadeler:

$$y_i = +1 \text{ için ; } w^t \cdot x + b \geq +1 - \xi_i \quad (3.28)$$

$$y_i = -1 \text{ için ; } w^t \cdot x + b \geq -1 + \xi_i \quad (3.29)$$

$\xi_i \geq 0, \forall i$, $\xi = 0$ olması durumunda örneği doğru sınıflandırılmış , $\xi < 0$ olması durumunda x örneği doğru sınıflandırılmış ancak, H_1 ve H_2 hiperdüzlemleri arasında yeralıyor $\xi \geq 1$ ise yanlış sınıflandırılmış demektir (Alpaydın, 2004).



Şekil 3.17: Lineer ayırlamama durumunda optimum ayırıcı hiperdüzlem

Şekil 3.17'deki gibi Lineer ayırlamama durumunda optimum ayırıcı hiperdüzlem sistemin ezberlemesi, yani eğitim verisi içinde olası her durum için bir çözüm üretmemesi için sisteme bir C üst sınırı eklenir. Bu üst sınır Lagrange çarpanlarının alabilecekleri maksimum değeri göstermektedir. Bu şekilde Lagrange çarpanlarının $0 <$

$\alpha_i < C$ aralığında kalması sağlanmaktadır. Bu bilgilere göre Lagrange formülasyonu yeniden şu şekilde ifade edilecektir;

$$L_p = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i - \sum_i \alpha_i \{y_i (w^t \cdot x + b) - 1 + \xi_i\} - \sum_i \mu_i \xi_i \quad (3.30)$$

Yukarıdaki formülasyonda ξ_i , μ_i 'nin pozitif olmasını garanti etmek için kullanılmış olan Lagrange parametreleridir. Bu Lagrange formülasyonu da çözülmesi zor olduğundan dolayı lineer ayrılabilir örneklerde olduğu gibi dual problemine dönüştürülmektedir. Bu probleme de Karush-Kuhn-Tucker (KKT) şartları uygulanırsa;

$$\frac{\partial L_p}{\partial w} = w - \sum_i \alpha_i y_i x_i = 0 \quad (3.31)$$

$$\frac{\partial L_p}{\partial b} = - \sum_i \alpha_i y_i = 0 \quad (3.32)$$


$$\frac{\partial L_p}{\partial \xi_i} = C - \alpha_i - \mu_i = 0 \quad (3.33)$$

ifadeleri elde edilir. Bu ifadeler (3.30)'de yerlerine yazılırsa: $0 < \alpha_i < C$, $\forall i$, elde edilir. Bu problemin çözümünde $0 < \alpha_i < C$ aralığında yer alan Lagrange çarpanlarına karşılık gelen x_i değerleri Destek Vektörleridir (Demirci, 2007).

3.2.7.2. Doğrusal olmayan Destek Vektör Makinesi sınıflandırıcıları

Gerçek-dünya problemlerinin büyük çoğunluğu birçok farklı bileşenden oluşan problemlerdir ve bu problemlerde veriler doğrusal olmayan karar yüzeyleri ile


modellenebilir. Doğrusal olmayan problemlerin çözümünü bulmanın yolu, çekirdek fonksiyonları ile örneklerin öncelikle daha yüksek boyutlu ve doğrusal olarak ayrılabilirleri bir uzaya taşınıp, ardından çözümün bu yeni uzayda aranması ile mümkün olmaktadır.(Burges,1998)



Şekil 3.18 Bir doğrusal olmayan Destek Vektör Makinesi

Şekil 3.18’de bir doğrusal olmayan SVM; 3.19’de ise bir giriş uzayını özellik uzayına eşleme yani bir giriş uzayını verilerin doğrusal olarak ayrılabilirliği daha yüksek boyutlu bir özellik uzayına taşıma görülmektedir.

Destek Vektör Makinelerini doğrusal olmayan problemlere uygularken kullanılan yöntemde temel fikir, doğrusal olarak ayrılamayan veriyi doğrusal olarak ayrılabilirliği bir yüksek boyutlu özellik uzayına taşımaktır. Böylece en uygun ayırıcı hiperdüzlem bu özellik uzayında bulunabilir. Giriş uzayındaki eğitim verisi vektörleri çekirdek fonksiyonları kullanılarak özellik uzayına aktarılır.



Şekil 3.19: Giriş uzayını özellik uzayına eşleme

Destek Vektör Makinelerinde kullanılan çeşitli çekirdek (kernel) türleri; Doğrusal (Linear), RBF, Polinom (Polynomial), Quadratic, MLP (Sigmoid)'dir.

Doğrusal çekirdek fonksiyonu:

$$K(x_i x_j) = x_i^t \cdot x_j \quad (3.34)$$

Radyal tabanlı çekirdek fonksiyonu (RBF): RBF, Destek Vektör Makinelerinde kullanılan çekirdek türlerinden en popüler olan seçimdir. Bunun temel nedeni reel x-ekseninin tüm aralıklarında lokalize ve sonlu tepkiler vermesindendir.

$$K(x_i x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (3.35)$$

Polinom çekirdek fonksiyonu:

$$K(x_i x_j) = (x_i^t \cdot x_j)^d \quad (3.36)$$

Quadratic çekirdek fonksiyonu:

$$K(x_i x_j) = \sqrt{\|x_i - x_j\|^2 + c^2} \quad (3.37)$$


MLP (Sigmoid) çekirdek (kernel) fonksiyonu:

$$K(x_i x_j) = \tanh (\alpha x_i^t . x_j + c) \quad (3.38)$$

4. BULGULAR

Sağlıklı bireyler ve epilepsili hastalardan alınan EEG işaretleri 1. Seviye Haar, Db4 ve Symlet (Sym4) dalgacıklarına ayrılarak ayrı ayrı test edilmiş ve öz nitelikleri istatistiksel yöntemler (Minimum, Maksimum, Ortalama, standart sapma) ile çıkarılarak KNN ve DVM sınıflandırıcılarıyla sınıflandırılmıştır. Sınıflandırıcıların değişkenleri değiştirilerek ayrı ayrı test edilmiş ve sınıflandırma sonuçları tablolar ve grafikler halinde verilmiştir. Böylece, Ayrık Dalgacık Dönüşümünün sınıflandırma sonuçları üzerindeki etkisi incelenmiştir. Sistemin başarısını değerlendirmek için tespit duyarlılığı, hasta başına düşen yanlış pozitif (YP) oranı ve doğru pozitif (DP) oranları hesaplanmıştır. Sınıflandırma işleminin genel yapısı aşağıda Tablo 4.1’de verilmektedir:

Tablo 4.1: Sınıflandırma işleminin blok diyagram genel yapısı



Belirli bir sinyalin boyutunun düşürülmesine öznitelik çıkarma işlemi denilmektedir. Öznitelik seçme ise isteğe bağlı olarak yapılan bir işlem olup sınıflama işlemi açısından en belirleyici özniteliklerin seçilmesi ve böylece öznitelik vektörünün boyutunun azaltılmasıdır. Bu tezde, giriş sinyallerinin özniteliklerinin belirlenmesi için dalgacık yöntemi kullanılmıştır.

Ayrık Dalgacık Dönüşümü sonucunda, sinyaller alt bileşenlerine ayrıştırılır. Bu alt bileşenler; asıl işaretin düşük frekans bileşeni olan yaklaşım ve yüksek frekans bileşenleri olan ayrıntı (yatay, dikey ve köşegen) ve bunların birleşim katsayılarından oluşmaktadır. Her bir giriş bileşeni Haar, dB4, ve sym4 tip dalgacık kullanılarak 1. seviye dalgacık katsayıları elde edilmiştir. Öznitelik vektörü ise hesaplanan dalgacık katsayılarının bazı istatistik değerleri alınarak oluşturulmuştur. Öznitelik vektörünün oluşturmak için kullanılan istatistikler ise aşağıda verilmektedir:

- Dalgacık yöntemi ile hesaplanan yaklaşık, yatay, dikey ve köşegen ayrıntı katsayılarının en büyük değerleri,
- Dalgacık yöntemi ile hesaplanan yaklaşık, yatay, dikey ve köşegen ayrıntı katsayılarının en küçük değerleri,
- Dalgacık yöntemi ile hesaplanan yaklaşık, yatay, dikey ve köşegen ayrıntı katsayılarının ortalama değerleri,
- Dalgacık yöntemi ile hesaplanan yaklaşık, yatay, dikey ve köşegen ayrıntı katsayılarının standart sapma değerleri,

Böylece her bir giriş işaretini tanımlayan öznitelik vektörü oluşturulmuştur. Elde edilen öznitelik vektörleri k -katlı çapraz doğrulama yöntemi ile eğitime ve teste tabi tutulmuşlardır. k - katlı çapraz doğrulama (k -fold cross validation), teste tabi tutulacak veriyi, k adet alt veriye ayırır. $k-1$ tane kat, eğitim için, son kat ise test için kullanılır. Çapraz doğrulama işlemi, her bir değerlendirmede kullanılan farklı kat ayrılarak, k defa tekrarlanır. Her veri noktası mutlaka bir kez test dizisinde, $k-1$ kez de eğitim dizisinde yer alır. Böylece sınıflandırılacak verilerin hepsi test edilerek verinin tamamı hakkında sonuç elde edilir. Bu tezde k , 5, 10 ve 20 alınarak k -katlı çapraz doğrulama giriş verisine uygulanmıştır.

4.1 DVM İLE BULUNAN SONUÇLAR

DVM’de çekirdek fonksiyonu olarak doğrusal (Lineer), polinom, Karesel (Quadratic) ve radyal tabanlı fonksiyon (RTF) çekirdekleri kullanılmıştır. C yaptırım parametresi 1000 ve γ parametresi 0.1 seçilmiştir. DVM ile sınıflandırma başarımları aşağıda tablolar halinde verilmiştir.

Tablo 4.2 Haar dalgacığı 5-kat çapraz doğrulama sonuçları

Doğrusal (Lineer)			Karesel (Quadratic)		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
98,25	95,75	98,37	97,37	93,12	97,5
RTF			Polinom (Polynomial)		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
96	96,37	95,87	99,75	97,87	99,87

Tablo 4.3 Haar dalgacığı 10-kat çapraz doğrulama sonuçları

Doğrusal (Lineer)			Karesel (Quadratic)		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
97,38	94,83	97,16	91,5	90,55	91,33
RTF			Polinom (Polynomial)		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
94,72	95,44	94,66	98,44	98,05	98,16

Tablo 4.4 Db4 dalgacığı 5-kat çapraz doğrulama sonuçları

Doğrusal (Lineer)			Karesel (Quadratic)		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
99,12	90,62	99,12	96,75	86,12	97
RTF			Polinom (Polynomial)		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
96,37	89,62	96,37	99,75	89,75	99,75

Tablo 4.5: Db4 Dalgacığı 10-kat apraz doęrulama

Doęrusal (Lineer)			Karesel (Quadratic)		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
96,61	88,5	96,5	97,11	83,11	96,88
RTF			Polinom (Polynomial)		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
94,88	85,77	94,72	95,33	85,94	95,16


Tablo 4.6 Symlet dalgacığı 5-kat apraz doęrulama sonuçları

Doęrusal (Lineer)			Karesel (Quadratic)		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
98,00	89,37	98,25	93,37	85,5	95,5
RTF			Polinom (Polynomial)		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
99,87	88,62	99,87	96	90	95,87


Tablo 4.7 Symlet dalgacığı 10-kat apraz doęrulama sonuçları

Doęrusal (Lineer)			Karesel (Quadratic)		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
96,38	88,5	96,05	94,33	81,55	94,05
RTF			Polinom (Polynomial)		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
91,94	88,55	91,88	98,55	86,5	98,38


Yukarıdaki tabloların grafiksel olarak gösterimi ise aşağıda verilmektedir:




Şekil 4.1: Haar dalgacığı 5-kat çapraz doğrulama




Şekil 4.2: Haar dalgacığı 10-kat çapraz doğrulama




Şekil 4.3: Db4 dalgacığı 5-kat çapraz doğrulama



Şekil 4.4: Db4 dalgacığı 10-kat çapraz doğrulama



Şekil 4.5: Symlet(sym4) dalgacığı 5-kat çapraz doğrulama



Şekil 4.6: Symlet dalgacığı 5-kat çapraz doğrulama

DVM sınıflandırıcısının test performansı istatistiksel parametrelerin hesaplanması ile değerlendirilir. Bu kavramlar aşağıda verilmiştir:

Gerçek Pozitif (GP): Gerçek tanıya (Epilepsili İşaret) uygun olarak sınıflandırıcının da epilepsili dediği olgular,

Gerçek Negatif (GN): Sağlıklı kitleye, sınıflandırıcının da sağlıklı dediği olgular,

Yanlış Pozitif (YP): Sağlıklı olduğu halde sınıflandırıcının epilepsili dediği olgular,

Yanlış Negatif (YN): Epilepsili olduğu halde sınıflandırıcının saptayamadığı olgular,

Yukarıdaki bilgiler ışığında EEG verilerinin DVM ile sınıflandırma sonuçları Tablo 4.8' de verilmiştir.

Tablo 4.8. DVM Doğrusal çekirdek fonksiyon tipi için Sınıflandırma Sonuçları

Dalgacık Tipi	Gerçek Durum	Kestirilen Durum	
		Negatif (sağlıklı)	Pozitif (epilepsili)
Haar	Negatif (sağlıklı)	99	1
	Pozitif (epilepsili)	1	1
Db4	Negatif (sağlıklı)	99	1
	Pozitif (epilepsili)	1	1
Sym4	Negatif (sağlıklı)	99	1
	Pozitif (epilepsili)	1	1

Tablo 4.8’den de görüldüğü gibi doğrusal çekirdek fonksiyonu ile yapılan sınıflandırma ile her 3 dalgacık için de 100 tane sağlıklı işarettten 99 tanesi sağlıklı diye sınıflandırılırken 1 tanesi epilepsili olarak sınıflandırılmıştır.

DVM ile yapılan sınıflandırma işleminin istatistiksel sonuçları ayrıca Tablo 4.9.’da gösterilmiştir.

Tablo 4.9. DVM Doğrusal çekirdek fonksiyon için İstatistiksel Sonuçlar

	Duyarlılık (sensitivity)			Özgüllük (specifity)			Hassaslık (precision)		
	Haar	dB4	Sym4	Haar	dB4	Sym4	Haar	dB4	Sym4
yaklaşım	99	99	99	100	100	100	100	100	100
ayrıntı	96	85	87	99	96	97	98,96	95,5	96,66
birleşik	99	99	99	100	100	100	100	100	100

Tablo 4.10. DVM Polinom çekirdek fonksiyon için İstatistiksel Sonuçlar

	Duyarlılık (sensitivity)			Özgüllük (specifity)			Hassaslık (precision)		
	Haar	dB4	Sym4	Haar	dB4	Sym4	Haar	dB4	Sym4
yaklaşım	100	100	100	100	100	100	100	100	100
ayrıntı	98	85	87	99	94	93	98,98	93,4	92,55
birleşik	100	98	97	100	100	100	100	100	100

DVM sınıflandırıcısının istatistiksel sonuçlarına bakıldığında, en yüksek duyarlılık oranı %100 ile Polinom çekirdek fonksiyonu kullanılarak elde edilmiştir. En yüksek seçicilik oranı ise %90 ile doğrusal çekirdek fonksiyonuna aittir. Toplam sınıflama doğruluğu ise symlet dalgacık kullanıldığında polinom çekirdek fonksiyonu ile en yüksek %99,87 oranına ulaşmıştır.

4.2. KNN İLE BULUNAN SONUÇLAR :

k-en yakın komşuluk algoritmasının performansı öncelikli olarak uzaklık mesafesine bağlı olmasının yanında k değerinin seçimine de bağlıdır. K sayısını belirlemenin en pratik yolu k'yı toplam eğitim örnekleri sayısının karekökünden daha az olarak seçmektir (Rosa,2001). Genellikle k değerinin yüksek seçilmesi gürültüye karşı daha duyarsız yapmakta ve sınıflar arası sınırları daha yumuşatmaktadır. Bu çalışmada k değeri 3 olarak belirlenerek aşağıda sınıflandırma sonuçları tablolar halinde verilmiştir.

Tablo 4.11: Haar dalgacığı 5-kat çapraz doğrulama, k=3, mesafe değişkeni sonuç karşılaştırma

Öklid (Euclidean)			Cityblock		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
99,12	97	99,12	99,12	97,62	99,25
Cosine			Correlation		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
73,62	69,62	68,12	67,62	70,5	64,5

Tablo 4.12: Haar dalgacığı 10-kat çapraz doğrulama, k=3, mesafe değişkeni sonuç karşılaştırma

Öklid (Euclidean)			Cityblock		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
98,5	95,61	98,5	98,66	96,72	98,55
Cosine			Correlation		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
63,61	66,11	58,5	60,27	66,27	56,38

Tablo 4.13: Db4 dalgacığı 5-kat apraz doęrulama, k=3, mesafe deęiřkeni sonu karřılařtırma

Öklid (Euclidean)			Cityblock		
Yaklařım	Ayrıntı	Birleřik	Yaklařım	Ayrıntı	Birleřik
99	85,12	99	98,5	86,37	98,62
Cosine			Correlation		
Yaklařım	Ayrıntı	Birleřik	Yaklařım	Ayrıntı	Birleřik
71,75	65,37	65	67,12	68,75	62,37

Tablo 4.14: Db4 dalgacığı 10-kat apraz doęrulama, k=3, mesafe deęiřkeni sonu karřılařtırma

Öklid (Euclidean)			Cityblock		
yaklařım	ayrıntı	birleřik	yaklařım	ayrıntı	birleřik
97,16	86,33	97,38	98,22	85,38	98,22
cosine			correlation		
yaklařım	ayrıntı	birleřik	yaklařım	ayrıntı	birleřik
64,38	63,83	58,77	63,38	57,11	58


Tablo 4.15: Symlet dalgacığı 5-kat apraz doęrulama, k=3, mesafe deęiřkeni sonu karřılařtırma

Öklid (Euclidean)			Cityblock		
Yaklařım	Ayrıntı	Birleřik	Yaklařım	Ayrıntı	Birleřik
99	89,25	99	98,75	90,12	98,75
Cosine			Correlation		
Yaklařım	Ayrıntı	Birleřik	Yaklařım	Ayrıntı	Birleřik
73,12	71,12	66,75	65,25	70,12	63,75


Tablo 4.16: Symlet dalgacığı 10-kat çapraz doğrulama, $k=3$, mesafe değişkeni sonuç karşılaştırma

Öklid (Euclidean)			Cityblock		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
97,61	89,05	97,55	97,05	89,77	97,16
Cosine			Correlation		
Yaklaşım	Ayrıntı	Birleşik	Yaklaşım	Ayrıntı	Birleşik
66,44	66,11	61,83	62,11	63	58


Tüm dalgacıklar için kNN mesafe değişkenlerinden Öklid ve Cityblock sınıflandırma başarımı açısından daha iyi sonuçlar vermektedir. kNN sınıflandırıcısında mesafe öklid ve cityblock için, Haar dalgacığı ile daha iyi başarımlar elde edilmiştir. Yukarıdaki tabloların grafiksel olarak gösterimi aşağıda verilmektedir;




Şekil 4.7: Haar dalgacığı 5-kat çapraz doğrulama




Şekil 4.8: Haar dalgacığı 10-kat çapraz doğrulama




Şekil 4.9: Db4 dalgacığı 5-kat çapraz doğrulama



Şekil 4.10: Db4 dalgacığı 10-kat çapraz doğrulama



Şekil 4.11: Symlet 5-kat çapraz doğrulama



Şekil 4.12: Symlet 10-kat çapraz doğrulama

Tablo 4.17 kNN, Öklid mesafesi duyarlılık, özgüllük ve hassaslık tablosu

	Duyarlılık (sensitivity)			Özgüllük (specifity)			Hassaslık (precision)		
	Haar	dB4	Sym4	Haar	dB4	Sym4	Haar	dB4	Sym4
yaklaşım	99	99	99	100	100	100	100	100	100
ayrıntı	97	86	88	99	91	90	98,97	90,52	89,79
birleşik	99	99	99	100	100	100	100	100	100

5. TARTIŞMA VE SONUÇ

Bu Çalışmada, Dalgacık Dönüşümünün EEG sınıflandırması üzerindeki etkileri incelenmiştir. EEG sinyallerin ön işleme tabi tutulmuş ve Dalgacık Dönüşümü yöntemiyle öznitelik vektörleri elde edilmiş, sonrasında ise DVM ve kNN yöntemiyle sınıflandırma gerçekleştirilmiştir. Ayrık Dalgacık Dönüşümünün sınıflandırma üzerindeki etkileri tablolar halinde verilerek sınıflandırma sonucunda EEG sinyallerinin sağlıklı veya epileptik olduğu hakkında bilgi sağlanmıştır. Denemelerde 1. Seviye Haar, Db4 ve Symlet (Sym4) dalgacıkları, sadece yaklaşım katsayıları (approach coefficients), sadece ayrıntı katsayıları (detail coefficients) ve birleşik katsayıları (approach + detail coefficients) ile 5-kat ve 10-kat çapraz doğrulama (k-fold cross validation) ayrı ayrı denenmiştir. DVM sınıflandırıcısı çekirdek fonksiyonu polinom olarak belirlendiğinde Sym4 en iyi başarıyı verirken, KNN sınıflandırıcısında mesafe öklid olarak belirlendiğinde en iyi başarıyı Haar dalgacığı vermektedir.

Gerçekleştirilen sınıflandırma sonuçları kıyaslandığında her 3 dalgacık için de SVM yöntemi KNN 'ye göre hem duyarlılık olarak hem de doğruluk olarak daha başarılı sonuç vermekte ve dalgacık analizi değişkenleri değiştirilerek yapılan karşılaştırmalarda, SVM için kernel tipi Doğrusal ve Polinom olan; kNN için ise Öklid ve cityblock mesafesi en iyi sonucu vermekte ve çapraz doğrulama değeri arttıkça başarımının azaldığı görülmektedir. Yaklaşım katsayılarının sınıflandırmada daha çok belirleyici olduğu tablolardan görülmektedir.

Bu tez çalışmasında elde edilen sınıflandırma sonuçları literatür sonuçları ile karşılaştırıldığında gerek başarımlar gerekse duyarlılık ve seçicilik oranları ile başarılı oldukları görülmektedir. Bu çalışma, epilepsi hastalarına ait EEG sinyallerinin daha doğru ve net olarak analiz edilmesini ve epilepsi teşhisinin otomatik olarak yapılmasını sağlayan bir metot önermektedir. İlerde bu konuyla ilgili yapılabilecek çalışmalar;

epilepsili ve sađlıklı bireylerin sınıflandırılması için farklı öznitelik çıkarma ve sınıflandırıcılar uygulanarak daha iyi performans elde edilebilir ve de EEG haricindeki diđer durađan olmayan verilere de uygulanarak Dalgacık Dönüşümünün sınıflandırma doğruluđu üzerindeki etkileri hakkında bir analiz yapılabilir.

KAYNAKLAR

- ADELI, H., ZHOU, Z., DADMEHR, N., 2002, "Analysis of EEG Records in an Epileptic Patient Using Wavelet Transform", Journal of Neuroscience Methods, 123(2003) 69-87.
- ALPAYDIN, E., 2004, Introduction to Machine Learning, MIT Press, Massachusetts.
- BATAR, H., 2005, "EEG İşaretlerinin Dalgacık Analizi Yöntemleri Kullanılarak Yapay sinir Ağları ile Sınıflandırılması" Yüksek Lisans Tezi, Kahramanmaraş sütün İmam Üniversitesi, Kahramanmaraş, 101s.
- BOZTOPRAK, H., 2005, "Wavelet Teorisi ve Uygulamaları", Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, s52, Isparta.
- BURCU, İ., 2007, EEG Sinyallerinin Dalgacık Dönüşümü ve Yapay Sinir Ağları İle Analizi [Analysis of EEG Signals Using The Wavelet Transform And Artificial Neural Networks] Isparta Üniversitesi, Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Yüksek Lisans Tezi, Isparta, 91s.
- BURGES, C. J C., 1998, Tutorial on support Vector Machines for Pattern Recognition, Data Mining Knowledge Discovery, 2(2): 121-167.
- CETIN, U., KUCUR, O., 2003, "Dalgacık Dönüşümü Metodu ile faz geliş zamanlarının tespiti" 5. Ulusal Deprem Mühendisliği Konferansı, İstanbul.
- DEMİRCİ, D. A., 2007, "Destek Makineleri ile Karakter Tanıma", Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, s53, Sakarya.
- GARRETT, D., PETERSON, D. A., ANDERSON, C. W. ve THAUT, M. H., 2003, Comparison of Linear, Nonlinear, and Feature Selection Methods for EEG Signal Classification, IEEE Transactions On Neural Systems And Rehabilitation Engineering, 11, 2 s141-144.
- Epilepsie Fonds, 2005, "Epilepsi (Sara Hastalığı)", National Epilepsie fonds, Hollanda.
- FLIEGE, N. J., 1996, "Multirate digital signal Processing (Multirate Systems – filter banks wavelets)", John Wiley & Sons, Chichester, s251.
- GARDNER, A. B., Krieger A. E. , Vachtsevanos, G., & Litt, B., 2006, One Class Novelty Detection For Seizure Analysis from Intracranial EEG, Journal of Machine Learning Research , vol: 7, pp:1025-1044.

GÖKÇİL, Z., 2007, Epilepsi, <http://www.gata.edu.tr/dahilibilimler/noroloji/epilepsi.htm> Erişim Tarihi 09.08.2011

GÜLER, İ., ÜBEYLİ, E. D., 2004, “Dalgacık Dönüşümünün Kullanımı ile Teşhis Sistemleri için Öznitelik Çıkarma: İç Karotid Atardamar Doppler İşaretlerinin Durum Analizi ”, Akıllı Sistemlerde Yenilikler ve Uygulamalar Sempozyumu ASYU-INISTA.

GÜMÜŞ, İ., 2003, “EKG sinyallerinin Wavelet analizi”, Uludağ Üniversitesi Mühendislik Mimarlık Fakültesi Elektronik Mühendisliği Bölümü Lisans Tezi, s.158, Bursa.

GÜNEŞ, M., KIYMIK, M. K., “EEG İşaretlerinin Dalgacık Analizi ve kısa Zaman Fourier Dönüşümü İle Karşılaştırılması”, Biyomedikal Mühendisliği Ulusal Toplantısı, 2006

HAŞILOĞLU, A., 1999, “Dalgacık analizi ve yapay sinir ağları ile döndürmeye duyarsız doku analizi sınıflandırma” , Tübitak.

JAHANKHANI, P., REVETT K. ve KODOGIANNIS, V., 2007, Data Mining an EEG Dataset With an Emphasis on Dimensionality Reduction, Proceedings of the 2007 IEEE Symposium on Computational Intelligence and Data Mining, s405-412.

JENSEN, E., 2006, Teaching with the brain in mind (Çev. Ahmet Doğanay), Nobel Kitabevi.

KALAYCI, T., 1996, EEG Dikenlerinin Yapay Sinir Ağları ile Tanınması, Ege Üniversitesi, Sağlık Bilimleri Enstitüsü, Doktora Tezi, s. 52, İzmir.

KIYMIK, K., İNAN, G., DİZİBÜYÜK, A., AKIN, M., 2004, “Comparison of STFT and wavelet transform methods in determining epileptic seizure activity in EEG signals for real time application”, Computers in Biology and Medicine, Volume 35, Issue 7, s603-616.

KOÇAL, O., H., 2007 , Biyomedikal Sinyal İşleme Ders Notu, Uludağ Üniversitesi, Mühendislik Mimarlık Fakültesi, s. 93.

MINER, N. E., 1998, “An Introduction to the Wavelet Theory and Analysis” , Sandia Report, NM, October 1-25.

MISITI, M., MISITI, Y., OPPONHEIM, G., POGGI, J. M., 2000, “Wavelet Toolbox for use with Matlab”, The User’s Guide, The Mathworks Inc.

ÖZER, O., 2010, EEG işaretlerinin diskriminant analizi ile sınıflandırılması [Classification of EEG signals by using discriminant analysis], Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans Tezi, Kahramanmaraş, 77s.

POLIKAR, R., 2005, “The Wavelet Tutorial” <http://www.public.iastate.edu/~rpolikar/>

Erişim Tarihi 05.09.2011

ROSA, J. L. A. ve Ebecken N. F. F., 2001, 'Data Mining for Data Classification Based on the KNN-Fuzzy Method Supported by Genetic Algorithm', Lecture Notes In Computer Science, issue: 2565, 2003, pp 126-136. , 2nd edition, Wiley, Newyork.

SEZER, E., 2008, Epilepsi teşhisi için EEG sinyal analizi [EEG signal analysis for epilepsy diagnosis] Selçuk Üniversitesi, Fen Bilimleri Enstitüsü Elektronik ve Bilgisayar Sistemleri Eğitimi Anabilim Dalı Yüksek Lisans Tezi, Konya, 127s.

SOUSA, D, A, 2001, How The Brain Learns: A Classroom Teacher Guide, California: Corwin Press Inc.

SUBAŞI, A., ERÇELEBİ, E., 2005, "Classification of EEG signals Using Neural Network and Logistic Regression", Computer Methods and Programs in Biomedicine, Vol.78, no.2, pp. 87-99.

STEVENS, J. ve GOLDBERG, D. ,2001, For The Learner's Sake: Brain Based Instruction for the 21st Century, ABD: Zephyr.

TANGIRELA A.K., 2001, "Multirate control, Multiscale Monitoring of Chemical Process", University of Alberta, Edmonton, p. 116-146.

TANSEL, I. N., MEKDECİ, C., Rodriguez, O., URAGUN, B., 1993, "Monitoring drill conditions with wavelet based encoding and neural networks", Int. J. Mach. Tools Manufact., 33(4) s. 559-575.

TEZEL, G., ÖZBAY, Y., 2007, "EEG Sinyallerinin Sınıflandırılmasında Yeni Bir Yaklaşım", Signal Processing and Communications Applications, SIU 2007. IEEE 15th- On page :1-4.

TOPRAK, İ. B., 2007, EEG Sinyallerinin Dalgacık Dönüşümü ve Yapay sinir ağları ile analizi, Süleyman Demirel Üniversitesi, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Yüksek Lisans Tezi, Isparta, 79s.

VALENS, 1999, "Really Friendly Guide to Wavelets" <http://perso.orange.fr/polyvalens/clemens>, Erişim Tarihi 10.10.2011.

VAPNIK, V. N.,1995, Nature of Statistical Learning Theory, Springer-Verlag, Newyork.

VAPNIK, V. N.,1998, Statistical Learning Theory, John Wiley & Sons, Newyork.

WOLFE, P., 2001, Brain Matters: Translating Research into Classroom Practice, Virginia, Association for Supervision and Curriculum Development.

YAZGAN, E., KORÜREK, M., 1996, "Tıp Elektroniği", İstanbul Teknik Üniversitesi, Elektroik- Elektronik Fakültesi Ofset Baskı Atolyesi , sayfa 2.1, 2.6 ve 6.1, 6.15 , İstanbul.

EKLER

Ek-1

```

clc
clear all

seviye=1;
%wtipi='db4' sym4;
wtipi='haar';
svmkerneltipi='linear';
xfoldcv=5;
kdegeri=3;
mesafe='euclidean';

dizin=pwd;
hastadosyalaridir([dizin '\S\']);
hastadosyalaridir(1:2,:)=[];
sagliklidostyalaridir([dizin '\Z\']);
sagliklidostyalaridir(1:2,:)=[];

for i=1:size(hastadosyalaridir,1)
    data(i,:)=textread([dizin '\S\' hastadosyalaridir(i,1).name]);
end

for i=1:size(sagliklidostyalaridir,1)
    data2(i,:)=textread([dizin '\Z\' sagliklidostyalaridir(i,1).name]);
end

hastasayisi=size(data,1);
sagliklisayisi=size(data2,1);

[C1,C2]=wavedec(data(1,:),seviye,wtipi); %boyut bulmak için
hasta_appr=zeros(hastasayisi,C2(1,1));
hasta_det=zeros(hastasayisi,C2(1,2));

for i=1:hastasayisi
    [C1,C2]=wavedec(data(i,:),seviye,wtipi);
    appr=appcoef(C1,C2,wtipi,seviye); %son seviyenin yakınlık bileşeni
    temp=detcoef(C1,C2,seviye);
    hasta_appr(i,:)=appr;
    hasta_det(i,:)=temp;
end

[C1,C2]=wavedec(data(1,:),seviye,wtipi); %boyut
saglikli_appr=zeros(sagliklisayisi,C2(1,1));
saglikli_det=zeros(sagliklisayisi,C2(1,2));

for i=1:sagliklisayisi

```

```

[C1,C2]=wavedec(data2(i,:),seviye,wtipi);
appr=appcoef(C1,C2,wtipi,seviye);    %son seviyenin yakınlık
bileşeni
temp=detcoef(C1,C2,seviye);    %tüm seviyelerin detay bileşenlerini
bul

saglikli_appr(i,:)=appr;
saglikli_det(i,:)=temp; %sadece 1 seviye varken
end

set_appr_orj=zeros(hastasayisi+sagliklisayisi,5);
set_det_orj=zeros(hastasayisi+sagliklisayisi,5);
set_birlesik_orj=zeros(hastasayisi+sagliklisayisi,5);

for j=1:hastasayisi
    set_appr_orj(j,1)=min(hasta_appr(j,:));
    set_appr_orj(j,2)=max(hasta_appr(j,:));
    set_appr_orj(j,3)=mean(hasta_appr(j,:));
    set_appr_orj(j,4)=std(hasta_appr(j,:));
    set_appr_orj(j,5)=1;
    set_det_orj(j,1)=min(hasta_det(j,:));
    set_det_orj(j,2)=max(hasta_det(j,:));
    set_det_orj(j,3)=mean(hasta_det(j,:));
    set_det_orj(j,4)=std(hasta_det(j,:));
    set_det_orj(j,5)=1;
    set_birlesik_orj(j,1)=min([hasta_appr(j,:) hasta_det(j,:)]);
    set_birlesik_orj(j,2)=max([hasta_appr(j,:) hasta_det(j,:)]);
    set_birlesik_orj(j,3)=mean([hasta_appr(j,:) hasta_det(j,:)]);
    set_birlesik_orj(j,4)=std([hasta_appr(j,:) hasta_det(j,:)]);
    set_birlesik_orj(j,5)=1;
end

for j=1:sagliklisayisi
    set_appr_orj(j+hastasayisi,1)=min(saglikli_appr(j,:));
    set_appr_orj(j+hastasayisi,2)=max(saglikli_appr(j,:));
    set_appr_orj(j+hastasayisi,3)=mean(saglikli_appr(j,:));
    set_appr_orj(j+hastasayisi,4)=std(saglikli_appr(j,:));
    set_det_orj(j+hastasayisi,1)=min(saglikli_det(j,:));
    set_det_orj(j+hastasayisi,2)=max(saglikli_det(j,:));
    set_det_orj(j+hastasayisi,3)=mean(saglikli_det(j,:));
    set_det_orj(j+hastasayisi,4)=std(saglikli_det(j,:));
    set_birlesik_orj(j+hastasayisi,1)=min([saglikli_appr(j,:)
saglikli_det(j,:)]);
    set_birlesik_orj(j+hastasayisi,2)=max([saglikli_appr(j,:)
saglikli_det(j,:)]);
    set_birlesik_orj(j+hastasayisi,3)=mean([saglikli_appr(j,:)
saglikli_det(j,:)]);
    set_birlesik_orj(j+hastasayisi,4)=std([saglikli_appr(j,:)
saglikli_det(j,:)]);
end

%Approximation için 5x2 cross validation
appr_accuracy=zeros(1,10);
det_accuracy=zeros(1,10);
birlesik_accuracy=zeros(1,10);

```

```
%Approximation için X-fold cross validation
```

```
appr_accuracy=zeros(1,xfoldcv);
det_accuracy=zeros(1,xfoldcv);
birlesik_accuracy=zeros(1,xfoldcv);
appr_knn_accuracy=zeros(1,xfoldcv);
det_knn_accuracy=zeros(1,xfoldcv);
birlesik_knn_accuracy=zeros(1,xfoldcv);
satirsayisi=hastasayisi+sagliklisayisi;
foldsize=satirsayisi/xfoldcv;

mkdir('c:', 'set_appr');
mkdir('c:', 'set_det');
mkdir('c:', 'set_birlesik');

for i=1:xfoldcv
    perm=randperm(hastasayisi+sagliklisayisi);
    set_appr=set_appr_orj(perm,:);
    set_det=set_det_orj(perm,:);
    set_birlesik=set_birlesik_orj(perm,:);
    test=1:satirsayisi;
    train=((i-1)*foldsize+1):(i*foldsize);
    test(train)=[];

    model=svmtrain(set_appr(train,1:end-1),set_appr(train,end),'KERNEL_FUNCTION',svmkernel tipi);
    classes=svmclassify(model,set_appr(test,1:end-1));
    temp=classes-set_appr(test,end);
    temp=find(temp(:,1)~=0);
    temp=size(classes,1)-size(temp,1); %doğru sayısı
    appr_accuracy(1,i)=(100*temp)/size(classes,1);

    appr_knnsonuc=knnclassify(set_appr(test,1:end-1),set_appr(train,1:end-1),set_appr(train,end),kdegeri,mesafe);
    appr_knnsonuc=appr_knnsonuc-set_appr(test,end);
    temp=find(appr_knnsonuc(:,1)==0);
    appr_knn_accuracy(1,i)=(100*size(temp,1))/size(classes,1);

    xlswrite(['c:\set_appr\train' num2str(i)],[set_appr(train,:) 1-set_appr(train,end)]);
    xlswrite(['c:\set_appr\test' num2str(i)],[set_appr(test,:) 1-set_appr(test,end)]);

    model=svmtrain(set_det(train,1:end-1),set_det(train,end),'KERNEL_FUNCTION',svmkernel tipi);
    classes=svmclassify(model,set_det(test,1:end-1));
    temp=classes-set_det(test,end);
    temp=find(temp(:,1)~=0);
    temp=size(classes,1)-size(temp,1); %doğru sayısı
    det_accuracy(1,i)=(100*temp)/size(classes,1);

    det_knnsonuc=knnclassify(set_det(test,1:end-1),set_det(train,1:end-1),set_det(train,end),kdegeri,mesafe);
    det_knnsonuc=det_knnsonuc-set_det(test,end);
    temp=find(det_knnsonuc(:,1)==0);
    det_knn_accuracy(1,i)=(100*size(temp,1))/size(classes,1);
```

```

        xlswrite(['c:\set_det\train' num2str(i)], [set_det(train,:) 1-
set_det(train,end)]);
        xlswrite(['c:\set_det\test' num2str(i)], [set_det(test,:) 1-
set_det(test,end)]);

        model=svmtrain(set_birlesik(train,1:end-
1),set_birlesik(train,end),'KERNEL_FUNCTION',svmkernel tipi);
        classes=svmclassify(model,set_birlesik(test,1:end-1));
        temp=classes-set_birlesik(test,end);
        temp=find(temp(:,1)~=0);
        temp=size(classes,1)-size(temp,1); %doğru sayısı
        birlesik_accuracy(1,i)=(100*temp)/size(classes,1);

        birlesik_knnsonuc=knnclassify(set_birlesik(test,1:end-
1),set_birlesik(train,1:end-
1),set_birlesik(train,end),kdegeri,mesafe);
        birlesik_knnsonuc=birlesik_knnsonuc-set_birlesik(test,end);
        temp=find(birlesik_knnsonuc(:,1)==0);
        birlesik_knn_accuracy(1,i)=(100*size(temp,1))/size(classes,1);

        xlswrite(['c:\set_birlesik\train'
num2str(i)], [set_birlesik(train,:) 1-set_birlesik(train,end)]);
        xlswrite(['c:\set_birlesik\test'
num2str(i)], [set_birlesik(test,:) 1-set_birlesik(test,end)]);
end

appr_son=mean(appr_accuracy);
det_son=mean(det_accuracy);
birlesik_son=mean(birlesik_accuracy);

appr_knn_son=mean(appr_knn_accuracy);
det_knn_son=mean(det_knn_accuracy);
birlesik_knn_son=mean(birlesik_knn_accuracy);

fprintf('\n\n\n%d fold Cross Validation SVM Sonuclari:\n',xfoldcv);
fprintf('Kullanilan wavelet tipi %s, seviye %d\n',wtipi,seviye);
fprintf('Kullanilan SVM Kernel %s\n',svmkernel tipi);
fprintf('Tum Approximationdan min max mean ve std hesaplandiginda
accuracy=%f\n',appr_son);
fprintf('Tum Detailsdan min max mean ve std hesaplandiginda
accuracy=%f\n',det_son);
fprintf('Hem Approximation hem de Detailsdan min max mean ve std
hesaplandiginda accuracy=%f\n',birlesik_son);

fprintf('\n\n\n%d fold Cross Validation KNN Sonuclari:\n',xfoldcv);
fprintf('Kullanilan K %d, mesafe %s\n',kdegeri,mesafe);
fprintf('Tum Approximationdan min max mean ve std hesaplandiginda
accuracy=%f\n',appr_knn_son);
fprintf('Tum Detailsdan min max mean ve std hesaplandiginda
accuracy=%f\n',det_knn_son);
fprintf('Hem Approximation hem de Detailsdan min max mean ve std
hesaplandiginda accuracy=%f\n',birlesik_knn_son);

```

Ek-2

```

clc
clear
dizin=pwd;
filtretileri={'haar','db4','sym4'};
seviye=1;

hastadosyalari=dir([dizin '\S\']);
sagliklidosyalari=dir([dizin '\Z\']);
data=[];

hastasayisi=0;
sagliklisayisi=0;
sayac=1;

for i=1:size(hastadosyalari,1)
    if hastadosyalari(i,1).isdir==0
        temp=textread([dizin '\S\' hastadosyalari(i,1).name]);
        data(sayac,:)=temp;
        sayac=sayac+1;
        hastasayisi=hastasayisi+1;
    end
end

for i=1:size(sagliklidosyalari,1)
    if hastadosyalari(i,1).isdir==0
        temp=textread([dizin '\Z\' sagliklidosyalari(i,1).name]);
        data(sayac,:)=temp;
        sayac=sayac+1;
        sagliklisayisi=sagliklisayisi+1;
    end
end

siniflar=[ones(hastasayisi,1) ; zeros(sagliklisayisi,1)];
%datada ilk 'hastasayisi' kadarı (100) hasta, sonraki 'sagliklisayisi'
kadarı (100) sağlıklı

shuf=randperm(hastasayisi+sagliklisayisi);
data=data(shuf,:);
siniflar=siniflar(shuf);

foldsayisi=10;
knnk=3;

indices=crossvalind('Kfold',1:hastasayisi+sagliklisayisi,foldsayisi);

tp=zeros(3,4,5);    %1. boyut feature grubu, 2. boyut filtretili, 3.
boyut siniflandırıcı
tn=zeros(3,4,5);
fp=zeros(3,4,5);
fn=zeros(3,4,5);

for j=1:size(filtretileri,2)

    waveletdata=[];

```

```

for i=1:size(data,1)
    [C L]=wavedec(data(i,:),seviye,filtretileri{j});
    waveletdata(i,j,1)=min(C(1:L(1)));           %appr
    waveletdata(i,j,2)=max(C(1:L(1)));
    waveletdata(i,j,3)=mean(C(1:L(1)));
    waveletdata(i,j,4)=std(C(1:L(1)));

    waveletdata(i,j,5)=min(C(L(1)+1:L(1)+L(2))); %detail
    waveletdata(i,j,6)=max(C(L(1)+1:L(1)+L(2)));
    waveletdata(i,j,7)=mean(C(L(1)+1:L(1)+L(2)));
    waveletdata(i,j,8)=std(C(L(1)+1:L(1)+L(2)));
end

temp1=waveletdata(:,j,1:4); %sadece appr
temp2=waveletdata(:,j,5:8); %sadece detail
temp3=waveletdata(:,j,:); %hepsi

kerneltipi={'linear','polynomial','rbf','quadratic'};

for y=1:foldsayisi
    testk=(indices==y);
    traink=~testk;

    %knn kısmı

    tahmin=knnclassify(temp1(testk,:),temp1(traink,:),siniflar(traink),knn
k,'euclidean');
    r=(tahmin+siniflar(testk));
    tp(1,j,1)=tp(1,j,1)+length(find(r==2));
    tn(1,j,1)=tn(1,j,1)+length(find(r==0));
    r=(tahmin-siniflar(testk));
    fp(1,j,1)=fp(1,j,1)+length(find(r==1));
    fn(1,j,1)=fn(1,j,1)+length(find(r==-1));

    tahmin=knnclassify(temp2(testk,:),temp2(traink,:),siniflar(traink),knn
k,'euclidean');
    r=(tahmin+siniflar(testk));
    tp(2,j,1)=tp(2,j,1)+length(find(r==2));
    tn(2,j,1)=tn(2,j,1)+length(find(r==0));
    r=(tahmin-siniflar(testk));
    fp(2,j,1)=fp(2,j,1)+length(find(r==1));
    fn(2,j,1)=fn(2,j,1)+length(find(r==-1));

    tahmin=knnclassify(temp3(testk,:),temp3(traink,:),siniflar(traink),knn
k,'euclidean');
    r=(tahmin+siniflar(testk));
    tp(3,j,1)=tp(3,j,1)+length(find(r==2));
    tn(3,j,1)=tn(3,j,1)+length(find(r==0));
    r=(tahmin-siniflar(testk));
    fp(3,j,1)=fp(3,j,1)+length(find(r==1));
    fn(3,j,1)=fn(3,j,1)+length(find(r==-1));

    for ty=1:4 %svm döngüsü

```

```

model=svmtrain(temp1(traink,:),siniflar(traink),'KERNEL_FUNCTION',kern
el tipi{ty});
    tahmin=svmclassify(model,temp1(testk,:));
    r=(tahmin+siniflar(testk));
    tp(1,j,ty+1)=tp(1,j,ty+1)+length(find(r==2));
    tn(1,j,ty+1)=tn(1,j,ty+1)+length(find(r==0));
    r=(tahmin-siniflar(testk));
    fp(1,j,ty+1)=fp(1,j,ty+1)+length(find(r==1));
    fn(1,j,ty+1)=fn(1,j,ty+1)+length(find(r==-1));

model=svmtrain(temp2(traink,:),siniflar(traink),'KERNEL_FUNCTION',kern
el tipi{ty});
    tahmin=svmclassify(model,temp2(testk,:));
    r=(tahmin+siniflar(testk));
    tp(2,j,ty+1)=tp(2,j,ty+1)+length(find(r==2));
    tn(2,j,ty+1)=tn(2,j,ty+1)+length(find(r==0));
    r=(tahmin-siniflar(testk));
    fp(2,j,ty+1)=fp(2,j,ty+1)+length(find(r==1));
    fn(2,j,ty+1)=fn(2,j,ty+1)+length(find(r==-1));

model=svmtrain(temp3(traink,:),siniflar(traink),'KERNEL_FUNCTION',kern
el tipi{ty});
    tahmin=svmclassify(model,temp3(testk,:));
    r=(tahmin+siniflar(testk));
    tp(3,j,ty+1)=tp(3,j,ty+1)+length(find(r==2));
    tn(3,j,ty+1)=tn(3,j,ty+1)+length(find(r==0));
    r=(tahmin-siniflar(testk));
    fp(3,j,ty+1)=fp(3,j,ty+1)+length(find(r==1));
    fn(3,j,ty+1)=fn(3,j,ty+1)+length(find(r==-1));

    end
end
end

accuracy=((tp+tn)/(hastasayisi+sagliklisayisi))*100;
precision=(tp./(tp+fp))*100;
sensitivity=(tp./(tp+fn))*100;
specificity=(tn./(tn+fp))*100;
tss=((tp.*tn)-(fp.*fn))./((tp+fn).*(fp+tn))*100;

save sonuc4

```

ÖZGEÇMİŞ

Gürsel Kızılaslan, 01.01.1983 tarihinde Kadıköy’de doğdu. Liseyi İstanbul Atatürk Fen Lisesi’nde tamamladı. Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü’nünden 2006 yılında mezun oldu. Lisans mezuniyeti sonrası, Emniyet Genel Müdürlüğü Haberleşme Dairesi’nde Elektrik – Elektronik Mühendisi olarak iş hayatına başladı. Sonrasında TEİAŞ İstanbul Grup Başmühendisliği’nde Elektronik Grup Başmühendisi olarak çalıştı. Vatani görevini Genel Kurmay Başkanlığı Elektronik Sistemler Komutanlığında Asteğmen olarak tamamlamasını takiben Ocak 2009’dan beri KOSGEB’de KOBİ Uzman yardımcısı olarak görev almaktadır. 2009 yılı bahar döneminde İstanbul Üniversitesi Elektrik Elektronik Mühendisliği Anabilim Dalı’nda yüksek lisans eğitimine başladı. Rusça ve iyi derece İngilizce bilmektedir.