



**T.C.  
ESKİŞEHİR OSMANGAZI ÜNİVERSİTESİ  
SAĞLIK BİLİMLERİ ENSTİTÜSÜ  
BİYOİSTATİSTİK ANABİLİM DALI**

**EEG SİNYALLERİNİN WAVELET YÖNTEMİYLE  
DÖNÜŞTÜRÜLEREK YAPAY SİNİR AĞLARI İLE  
SINIFLANDIRILMASI**

**YÜKSEK LİSANS TEZİ**

**EYLEM GÜL**

**DANIŞMAN  
PROF. DR. FEZAN MUTLU**

**2018**





**T.C.  
ESKİŞEHİR OSMANGAZI ÜNİVERSİTESİ  
SAĞLIK BİLİMLERİ ENSTİTÜSÜ  
BİYOİSTATİSTİK ANABİLİM DALI**

**EEG SİNYALLERİNİN WAVELET YÖNTEMİYLE  
DÖNÜŞTÜRÜLEREK YAPAY SİNİR AĞLARI İLE  
SINIFLANDIRILMASI**

**YÜKSEK LİSANS TEZİ**

**EYLEM GÜL**

**DANIŞMAN  
PROF. DR. FEZAN MUTLU**

**2018**

## KABUL VE ONAY SAYFASI

Eylem GÜL'ün Yüksek Lisans Tezi olarak hazırladığı "EEG SINYALLERİNİN WAVELET YÖNTEMİYLE DÖNÜŞTÜRÜLEREK YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI" başlıklı bu çalışma Eskişehir Osmangazi Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddesi uyarınca değerlendirerek "KABUL" edilmiştir.

Tarih 17.12.2018

Üye : Prof. Dr. Fezan MUTLU



Üye : Prof. Dr. Setenay ÖNER



Üye : Doç. Dr Nurhan DOĞAN



Eskişehir Osmangazi Üniversitesi Sağlık Bilimleri Enstitüsü Yönetim Kurulu'nun 26.12.2018 tarih ve 1204./1.598.1 sayılı kararı ile onaylanmıştır.

Prof Dr. Hasan Veysi GÜNEŞ  
Enstitü Müdürü



## ÖZET

Elektroensefalografi (EEG), beyindeki elektriksel aktiviteyi kaydeden bir görüntüleme tekniğidir. EEG sinyalleri gibi durağan olmayan sinyallerin analizinde başarılı olması nedeniyle EEG spektral analizinde genellikle Ayrık Dalgacık Dönüşümü (ADD) kullanılır. ADD ile sinyal alt bantlarına ayrıştırılır ve bu alt bantları temsil eden istatistiksel özellikler elde edilir. Bu tez çalışmasında Akut Lenfoblastik Lösemi (ALL) hastası ve sağlıklı kişilerin EEG sinyalleri Ayrık Dalgacık Dönüşümü ile 5. seviyedeki alt bantlarına ayrılmış ve bu alt bantlarına ait 10 adet istatistiksel özellik elde edilmiştir. Bu özellik vektörleri Yapay Sinir Ağlarına (YSA) giriş olarak verilip ileri beslemeli geri yayımlı YSA modeli ile sınıflandırılmıştır. Aynı işlemler farklı dalgacık aileleri için de tekrar edilmiştir. Böylece her bir dalgacık ailesi için sınıflandırma sonuçları karşılaştırılmıştır. Sınıflandırma sonucunda EEG sinyallerinin sağlıklı veya hasta olduğu hakkında bilgi elde edilmiştir. Sonuçta incelenen ayrışım seviyesi için en düşük sınıflama başarısı Haar ve Coif1 Dalgacıklarına ait olup diğer dalgacıkların sınıflandırma başarılarının ise birbirine yakın ve yüksek olduğu saptanmıştır.

**Anahtar Kelimeler:** Elektroensefalografi (EEG), Sinyal işleme, Dalgacık Dönüşümü, Yapay Sinir Ağı, Akut Lenfoblastik Lösemi

## SUMMARY

Electroencephalography (EEG) is an imaging technique that records the electrical activity in the brain. Discrete Wavelet Transform (DWT) is often used in EEG spectral analysis because it is successful in analyzing non-stationary signals such as EEG signals. Using DWT, it is decomposed into signal subbands and statistical features representing these subbands are obtained. In this thesis study, EEG signals of patients with acute lymphoblastic leukemia (ALL) and healthy individuals were divided into 5 sub-bands by Discrete Wavelet Transform and 10 statistical features of these sub-bands were obtained. These feature vectors are given as input to Artificial Neural Networks (ANN) and classified by the Feed Forward Back Propagation Neural Network (FFNN) model. The same procedure was repeated for different wavelet families. Thus, the classification results for each wavelet family are compared. As a result of classification, information about what is healthy or ill of EEG signals was obtained. Consequently, it is found that the lowest classification success for the analyzed level belongs to Haar and Coif1 Wavelets and the classification results of other wavelets are close to each other and high.

**Keywords:** Electroencephalography (EEG), Signal Processing, Wavelet Transform, Artificial Neural Network, Acute Lymphoblastic Leukemia

# İÇİNDEKİLER

<b>ÖZET</b> .....	v
<b>SUMMARY</b> .....	vi
<b>TABLO DİZİNİ</b> .....	ix
<b>ŞEKİL DİZİNİ</b> .....	x
<b>SİMGE VE KISALTMALAR DİZİNİ</b> .....	xii
1. GİRİŞ VE AMAÇ .....	1
2. GENEL BİLGİLER .....	4
2.1- Sinyal ve Sinyal Analizi.....	4
2.2- Elektroensefalografi (EEG) .....	4
2.2.1- EEG dalgaları .....	5
2.2.2- EEG dalgalarının ölçülmesi.....	6
2.2.3- EEG sinyallerini etkileyen olaylar .....	6
2.3- Dalgacık Dönüşüm Yöntemi .....	7
2.3.1- Sürekli dalgacık dönüşümü .....	10
2.3.2- Ayırık(Kesikli) dalgacık dönüşümü .....	11
2.3.2.1- Ayırık dalgacık dönüşümü kullanılarak özellik çıkarımı .....	13
2.4- Dalgacık Aileleri.....	14
2.4.1- Haar .....	14
2.4.2- Daubechies .....	15
2.4.3- Symlets .....	15
2.4.4- Coiflets .....	16
2.4.5- Biorthogonal.....	16
2.4.6- Morlet.....	17
2.4.7-Mexican Hat .....	17
2.5- Yapay Sinir Ağları .....	18
2.5.1- Giriş .....	18
2.5.2- Yapay sinir ağı kullanım alanları .....	18
2.5.3- Biyolojik sinir ağı.....	19
2.5.4- Yapay sinir ağı mimarisi .....	19
2.5.5- Yapay sinir ağına öğrenme.....	21
2.5.6- Yapay sinir ağlarının sınıflandırılması .....	22

3. GEREÇ VE YÖNTEMLER .....	25
3.1- Gereçler .....	25
3.2- Yöntem .....	27
3.2.1- EEG Portaview .....	27
3.2.2- ADD ile özellik çıkarımı.....	28
3.2.3- Verilere yöntemin uygulanması .....	28
4. BULGULAR .....	33
4.1- Ayrık Dalgacık Dönüşümüne İlişkin Bulgular.....	33
4.2- Yapay Sinir Ağları Sınıflandırmasına İlişkin Bulgular .....	37
5. TARTIŞMA VE SONUÇ .....	40
KAYNAKLAR DİZİNİ.....	43
ÖZGEÇMİŞ.....	48
ETİK KURUL İZİN BELGESİ.....	49



## TABLO DİZİNİ

<b>Tablo 2.1.</b> EEG Ritimleri .....	5
<b>Tablo 2.2.</b> Biyolojik sinir ağı ile YSA'nın karşılaştırılması (Elmas, 2007). 21	
<b>Tablo 3.1.</b> Çalışmaya dahil olma kriterleri. ....	25
<b>Tablo 3.2.</b> Çalışmaya dahil edilmeme kriterleri. ....	26
<b>Tablo 4.1</b> FFNN ağ parametreleri .....	37
<b>Tablo 4.2</b> Farklı dalgacıklar kullanılarak ADD ile 5.seviyeden ayrıştırılan sinyalin YSA performansları.....	39



## ŞEKİL DİZİNİ

<b>Şekil 2.1.</b> 10-20 EEG elektrot konumlandırma sistemi (Malmivuo ve Plonsey, 1995) .....	6
<b>Şekil 2.2. a)</b> Dalga ve <b>b)</b> Dalgacık (Nizam, 2008).....	7
<b>Şekil 2.3.</b> Frekans düzleminin farklı tekniklerle bölünmesi (Gençay, Selçuk, ve Whitcher, 2001) .....	8
<b>Şekil 2.4.</b> ADD ile 3. Seviyeden ayrıştırılan Dalgacık Filtreleme Örneği (Smertneck, 2000). .....	9
<b>Şekil 2.5.</b> Filtrelenmiş bir sinyal örneği (Weeks, 2007) .....	9
<b>Şekil 2.6.</b> Sinyalin ayrışım ve birleşmesi (Yılmaz & Bozkurt, 2013).....	11
<b>Şekil 2.7.</b> 3.seviyeden dalgacık ayrışım algoritması (Miner, 1998).....	12
<b>Şekil 2.8.</b> Haar fonksiyonunun zaman-genlik gösterimi (Misiti, Misiti, Oppenheim, & Poggi, 1996). .....	14
<b>Şekil 2.9.</b> Daubechies fonksiyonunun zaman-genlik gösterimi(Misiti vd., 1996).....	15
<b>Şekil 2.10.</b> Symlets fonksiyonunun zaman-genlik gösterimi (Misiti vd., 1996).....	15
<b>Şekil 2.11.</b> Coiflets fonksiyonunun zaman-genlik gösterimi (Misiti vd., 1996).....	16
<b>Şekil 2.12.</b> Bior1.3 fonksiyonunun zaman-genlik gösterimi (Misiti vd., 1996).....	16
<b>Şekil 2.13.</b> Morlet fonksiyonunun zaman-genlik gösterimi (Misiti vd., 1996).....	17
<b>Şekil 2.14.</b> Mexican hat fonksiyonunun zaman-genlik gösterimi (Misiti vd., 1996). .....	17
<b>Şekil 2.15.</b> Biyolojik sinir ağının yapısı ("Popular Science: Neural Networks. How does it work?," 2016).....	19
<b>Şekil 2.16.</b> Bir dizi girdileri olan bir nöronun mimarisi.....	20
<b>Şekil 2.17.</b> Basit bir yapay sinir ağı modeli(Elmas, 2007).....	22
<b>Şekil 2.18.</b> Geri yayılım algoritması yapısı.....	23
<b>Şekil 3.1.</b> Bir hastaya ait EEG sinyallerinin EEG Portaview uygulamasında görüntülenmesi .....	27
<b>Şekil 3.2.</b> EEG verilerini ASCII formatına dönüştürme.....	29

<b>Şekil 4.1.</b> Sağlıklı bir bireye ait sinyallerin ADD ile 5.seviyeden ayrıştırılmasıyla elde edilen detay alt bandı .....	33
<b>Şekil 4.2.</b> Sağlıklı bir bireye ait sinyallerin ADD ile 5.seviyeden ayrıştırılmasıyla elde edilen yaklaşım alt bandı .....	34
<b>Şekil 4.3.</b> Hasta bir bireye ait sinyallerin ADD ile 5.seviyeden ayrıştırılmasıyla elde edilen detay alt bandı .....	34
<b>Şekil 4.4.</b> Hasta bir bireye ait sinyallerin ADD ile 5.seviyeden ayrıştırılmasıyla elde edilen yaklaşım alt bandı .....	35
<b>Şekil 4.5.</b> Ayrıştırılan sinyal .....	35
<b>Şekil 4.6.</b> Alçak frekans bileşeni .....	36
<b>Şekil 4.7.</b> Yüksek frekans bileşeni .....	36
<b>Şekil 4.8.</b> Oluşturulan ağ mimarisi .....	37
<b>Şekil 4.9.</b> Özelliklerin YSA'da işlenmesi .....	38
<b>Şekil 4.10.</b> Ağın performans eğrileri .....	39

## SİMGE VE KISALTMALAR DİZİNİ

<b>EEG</b>	Elektroensefalografi
<b>EKG</b>	Elektrokardiyografi
<b>DD</b>	Dalgacık Dönüşümü
<b>ADD</b>	Ayrık Dalgacık Dönüşümü
<b>SDD</b>	Sürekli Dalgacık Dönüşümü
<b>Hz</b>	Heartz
<b>A</b>	Dalgacık yaklaşım alt bandı
<b>D</b>	Dalgacık detay alt bandı
<b>h(n)</b>	Alçak geçiren filtre
<b>g(n)</b>	Yüksek geçiren filtre
$\varphi$	Dilatasyon fonksiyonu
$\psi$	Ana dalgacık
<b>db</b>	Daubechies Dalgacık
<b>sym</b>	Symlet Dalgacık
<b>coif</b>	Coiflet Dalgacık
<b>bior</b>	Biorthogonal Dalgacık
<b>YSA</b>	Yapay sinir ağı
<b>NET</b>	Sinir ağı
<b>lr</b>	Öğrenme oranı
<b>mc</b>	Momentum katsayısı
<b>HKO</b>	Hata kareler ortalaması
<b>Feedforward (FFNN)</b>	İleri beslemeli yapay sinir ağı
<b>Feedback</b>	Geri beslemeli yapay sinir ağı
<b>Backpropagation</b>	Geri yayılım algoritması

<b>MLP</b>	Çok katmanlı algılayıcı
<b>SVM</b>	Karar destek makinesi
<b>kNN</b>	k en yakın komşu algoritması
<b>NB</b>	Naive Bayes
<b>ALL</b>	Akut lenfoblastik lösemi



# 1. GİRİŞ VE AMAÇ

Günümüzde sinyal işleme alanında kullanılan ve önemini korumakta olan Wavelet (Dalgacık) Dönüşümü; sinyal analizi, görüntü analizi ve iletişim sistemleri gibi birçok uygulama alanında başarılı olmuştur (Lee ve Yamamoto, 1994). Sinyal işleme alanında yapılan bazı çalışmalarda Fourier dönüşümü kullanılmış olsa da Dalgacık Dönüşümü (DD) Fourier dönüşümünün durağan olmayan sinyallerdeki eksikliğini gidermek amacıyla geliştirilmiştir.

Bugünkü dalgacık teorisinin temellerini atan Joseph Fourier, 1807'de bir analiz fonksiyonuna dayanan bir dizi katsayıyla sinyali açıklamayı hedefleyen yöntem geliştirmiştir. Ancak dalgacık terimi ilk olarak 1909 yılında Alfred Haar'ın doktora tezinde kullanılmıştır. 1930'larda ise Paul Levy, ölçeğe bağlı olarak değişen Haar temel fonksiyonunu Fourier temel fonksiyonlarından üstün bulmuştur. Jean Morlet ve Alex Grossman, bir sinyalin dalgacık katsayılarına ayrıştırılması ve orijinal sinyalin yeniden oluşturulması için 1981'de bir yöntem geliştirmiştir. Stephane Mallat ve Yves Meyer Dalgacık kullanarak 1986'da çok çözünürlüklü bir analiz yöntemi geliştirmiştir. Bu analiz yönteminde ilk kez dalgacıkların ölçekleme işlevinden bahsedilmiştir. Bu alanda çalışan araştırmacılara ve matematikçilere kendi dalgacık ailelerini oluşturmalarına izin verilmiştir. Ingrid Daubechies 1998'de Çok Çözünürlüklü Dalgacık Teorisini kullanarak kendi dalgacık ailesini oluşturmuştur. Dalgacık temel fonksiyonlar seti bugünkü dalgacık uygulamalarının yapı taşı haline gelmiştir (Merry ve Steinbuch, 2005).

Elektroensefalografi (EEG) sinyalleri durağan olmayan sinyaller olduğundan Fourier Dönüşümü kullanılarak gerçekleştirilen EEG analizinde küçük değişiklikler fark edilememektedir. Dalgacık Dönüşümü, sinyalin kesildiği ve sivri bulunduğu fiziksel durumları analiz edebilme yeteneğine sahip olup geleneksel Fourier Dönüşümüne göre çok daha büyük avantajlara sahiptir (Ridha, 2011). Bu dönüşüm yöntemi gürültüye karşı daha az hassasiyet gösterip EEG gibi durağan olmayan sinyallere kolaylıkla uygulanabilmektedir (Palabaş, 2014). Sinyal analizinde temel yaklaşım, en iyi yöntemin kullanılması ile sinyalden doğru bilgiye ulaşmaktır.

Dalgacık Dönüşümü ile sinyalin davranışını karakterize eden, özellik adı verilen sıkıştırılmış parametrelerin hesaplanması ve sinyalin işlemesi gerçekleştirilir (Hazarika, Chen, Tsoi, ve Sergejew, 1997). EEG sinyallerinin daha iyi analiz edilmesi için sinyalin özellikleri çıkarılması ve

bir EEG sinyalinin diğ erinden ayırt edilebilmesi için bu özelliklerin kullanılması gerektiğ i belirtilmiştir (Zhao vd., 2015).

EEG sinyalleri özel bir şek le sahip olmayan, karış ık salınımlardan oluş an biyolojik işaretlerdir. Hekimlerin belki de sayfalarca sü ren bu EEG görüntülerini incelemeleri uzun zaman alıp bazen de bu yoğunlukta bazı önemli noktaların göz den kaçmasına ve yanlış değ erlendirmelere sebep olabilir. Bu yüzden EEG değ erlendirmesini basitleşt irmek amacıyla, EEG çekimi sonrası elde edilen ham verileri azaltan Fourier ve Dalgacık Dönüşümü gibi otomatik sistemler geliştirilmiştir (Sezer, 2008).

Günümüzde Yapay Sinir Ağlarına (YSA) hemen hemen her alanda rastlamak mümkündür. Tıpta ise bilgisayar destekli karar verme uygulamalarına yönelik çalış malarda kullanılmaktadır. Bu çalış mada EEG sinyallerinin sınıflandırılması için DD ve YSA bir arada kullanılarak sınıflandırma başarısının arttırılması amaçlanmıştır.

Akin(2002) çalış masında Fast Fourier Dönüşümü ile Dalgacık Dönüşümünün avantaj ve dezavantajları verilerek karşılaştırılmış tır ve Dalgacık Dönüşümünün Fast Fourier Dönüşümüne göre daha etkili olduğ u sonucuna varılmış tır.

Alp vd.(2008) çalış malarında Fourier Dönüşümü ile Dalgacık Dönüşümü arasında bir kıyaslama yapılmış tır. Dalgacık Dönüşüm tekniğ iyle görüntü işleme, görüntü iyileştirme, gürültü analizi ve sınır saptama konularında başarılı sonuçların elde edildiğ i çeşitli çalış malar yapılmış tır. Yapılan analizlerden elde edilen sonuçlara göre Dalgacık Dönüşümünün Fourier Dönüşümüne göre zaman frekans çözünürlüğ ü daha iyi bulunmuştur.

Shaker(2006) çalış masında Ayrık Dalgacık Dönüşümü ve Fast Fourier Dönüşümü bir arada kullanılmış tır. Sonuçlar değ erlendirildiğ inde, bu çalış ma için hem Dalgacık Dönüşümü hem de Fast Fourier Dönüşümü önerilmektedir.

Coşkun & İstanbullu(2012) anestezi altındaki bir hastadan alınan EEG kayıtlarını Band Geçiren Filtre, Güç Spektral Yoğunluğu, Fast Fourier ve Dalgacık Dönüşümü gibi yöntemlerle incelemiş ve EEG sinyalleri için en başarılı sonuçlara Dalgacık Dönüşüm yöntemi ile ulaşmışlardır.

Yılmaz & Bozkurt(2013) çeşitli aritmi tipleri için Ayrık Dalgacık Dönüşüm yöntemlerinden Daubechies 2 ve Daubachies 10 dalgacık ailelerini EKG öznitelik çıkarımı için kullanarak 4. Seviyeden minimum, maksimum ve varyans özellikleri çıkarımı yapmışlardır.

Erdođmuş & Pekçakar(2009) EKG sinyalleri Daubachies 10 ile dönüştürülmüş ve 4. Seviyeden özellik vektörleri alınıp sınıflandırma için YSA eğitilmiştir. Aynı zamanda EKG verisine Fast Fourier Dönüşümü uygulanıp sınıflandırma başarıları karşılaştırılmıştır. Sonuç olarak EKG verileri için Dalgacık Dönüşüm tekniđi ile ortalama başarı %72 iken Fast Fourier Dönüşümü ile sınıflama başarıları daha yüksek bulunmuştur.

Güler vd. (2009) çalışmalarında travmatik beyin yaralanmalarının şiddetinin belirlenmesi için Yapay Sinir Ağları ile sınıflandırma yapılmıştır. EEG verilerine Ayrık zamanlı Fourier Dönüşümü uygulanmıştır. Sonuç olarak sistem bulguları ile nörolojist bulguları %87 oranında uyuşmuştur.

Ersöz & Özşen(2011) EEG sinyallerini yapay sinir ağları ile sınıflandırılarak uyku evrelemesi yapmışlardır. Elde edilen sonuçlara göre FFT ve Dalgacık Dönüşüm yöntemlerinin bu uygulama için benzer sonuçlar ürettiđi gösterilmiştir.

Bu çalışma, Biyoistatistik, Hematoloji, Pediatrik Nöroloji, Bilgisayar Mühendisliđi gibi birçok disiplini bir araya getiren, literatürde örneđine rastlanmamış, retrospektif olarak lösemi ve kontrol gruplarında EEG dalgalarını karşılaştırmayı ve YSA yöntemiyle de bu dalgaları sınıflandırmayı hedef alan bir çalışmadır. Araştırmanın diđer bir önemi, tedavisi tamamlanmış olan bireylerin hasta ve kontrol grupları arasında EEG dalgalarını karşılaştırarak, hastalık durumlarının elektriksel deşarjlarını nasıl etkilediđi istatistiksel olarak deđerlendirmeyi hedef edinmiş olmasıdır. Hasta ve kontrol grupları arasında herhangi bir nedenle fark çıkması durumunda hasta grubu katılımcılarının EEG'lerini klinik deđerlendirmede daha önemli seviyelere çekmesi beklenmektedir.

Bu çalışmanın amacı, EEG sinyallerinin Lösemili hastalarda ve sağlıklı kişilerde gösterdiđi farklılıkları deđerlendirmek için Ayrık Dalgacık Dönüşümü (ADD) kullanılarak YSA ile sınıflandırma yapmaktır. Çalışma da ikincil bir amaç dalgacık ailelerinin YSA'nın sınıflandırma başarısına olan etkisini saptamaktır. Burada YSA'nın eğitim parametreleri sürekli olarak deđiştirilip en iyi parametre deđerleriyle ağ eğitilip en hızlı ve en başarılı YSA yapısı bulunacaktır.



## **2. GENEL BİLGİLER**

### **2.1- Sinyal ve Sinyal Analizi**

Sinyal temel bir tanımla, genelde elektronik olarak elde edilen bir dizi sayısal ölçümdür. Sinyal işleme; gürültüden arındırma, sıkıştırma, özellik çıkarma ve yeniden yapılandırmayı içerir. Sinyal işlemede sinyalin analiz edilmesi ve kodlanması büyük önem taşır. Buradaki esas amaç, kodlanmış sinyal hedefe gönderildikten sonra minimal kayıpla yeniden oluşturulabilmesidir. Sinyaller genellikle rasgele seslerle birleşerek oluşurlar ve sinyal işlenirken bu gürültü ortadan kaldırılır. Burada önemli olan gözlemlenen gürültülü sinyalden gerçek sinyalin alınmasıdır (Singh, Choudhary, Jayas, ve Paliwal, 2010; Ogden, 2012).

Sinyal işlemede istatistiksel yöntemler, rasgele sinyallerin dağılımının ve sinyallerin yayılma ortamlarının modellenmesini sağlar. İstatistiksel modeller sinyal işlemede ve karar verme sistemlerinde, gürültülü veya eksik olan bir sinyalden bilgi çıkarmak için uygulanır (Vaseghi, 2008).

### **2.2- Elektroensefalografi (EEG)**

Beyindeki elektriksel aktivitelerin varlığı ile ilgili ilk çalışma 1875-1877 yılları arasında Richard Coton tarafından maymun ve tavşan deneylerinde yapılmıştır. Bu çalışmayı takiben Provdich-Neminsky, köpeklerin beyin yüzeylerine elektrotlar yerleştirerek, elektriksel aktiviteyi fotoğrafik olarak kaydettiği elektroensefalogram yöntemini ortaya koymuştur. Birinci Dünya savaşı ile birlikte Alman nöropsikiyatrist Hans Berger, savaşta kafatası yaralanan insanların beyinlerine elektrot yerleştirerek elektroensefalogram yöntemini ilk kez insanlarda uygulamıştır. Zamanla ise bu elektrotlar saçlı deriye yerleştirilerek kayıtlar alınmış olup bu yöntem elektroensefalogram adını almıştır. Berger 1925 yılında elektroensefalogramı ilk kez oğlu Klaus'un üzerinde uygulamıştır. Böylece, Hans Berger insanda EEG çalışmalarının başlamasında en önemli role sahip olmuştur (Collura, 1993).

Elektroensefalografi, beyin nöronlarındaki iyonik akım akışlarından kaynaklanan elektriksel dalgalanmaları ölçen ve kaydeden bir yöntemdir. Bu kayıtlar saçlı deriden elektrotlar yardımıyla yapılır. EEG beyne veya vücudun herhangi bir yerine elektrik iletmediğinden ağrısız ve zararsızdır (Kalaivani, Kalaivani ve Devi, 2014).

EEG sinyalin alındığı yere göre kafa derisi ve intrakraniyal olmak üzere iki çeşittir. Kafa derisi EEG yönteminde elektrotlar sağlıklı deriye temas ettirilerek sinyal alınırken intrakraniyal EEG yönteminde elektrotlar cerrahi bir operasyon ile beyne yerleştirilir (Adeli, Zhou ve Dadmehr, 2003).

### 2.2.1- EEG dalgaları

Sağlıklı bir yetişkinin EEG sinyali, uyku, uyanıklık, gözü açık ve gözü kapalı gibi farklı durumlara kaydedildiğinde genlik ve frekansta değişiklik gösterebilir. Dahası dalga karakteristiği yaşla birlikte değişkenlik gösterir. EEG sinyalleri ritmik ve geçici olarak tarif edilen karışık sinyaller olup bu ritmik aktivite frekanslara göre bantlara ayrılırlar. Bu frekans bantları Delta (0.5-4 Hz), Teta (4-8 Hz), Alfa (8-12 Hz), Beta (12-30 Hz) ve Gamma (30-100 Hz) dalgaları olarak kabul edilmektedir (Sharanreddy ve Kulkarni, 2013).


Tablo 2.1’de EEG ritimleri verilmiştir. Uyanık yetişkinlerde yüksek teta aktivitesinde anormallik veya patolojik bir durum söz konusu olabilir (Subha vd., 2010).

**Tablo 2.1.** EEG Ritimleri

<b>DALGA</b>	<b>FREKANS BANDI</b>	<b>OLUŞUMU</b>
<b>Delta</b>	0.5-4 Hz	Beynin çok düşük aktivite gösterdiği durumlarda ortaya çıkan çok yavaş dalgalarıdır. Çoğunlukla normal bireylerde derin uykuda ve ciddi beyin hastalıklarında görülür.
<b>Teta</b>	4-8 Hz	Düşük aktivite durumlarında ortaya çıkan dalgalarıdır. Uykulu ve uyuşukluk durumlarında görülür.
<b>Alfa</b>	8-12 Hz	Uyanık ama gevşemiş, rahatlamış normal bireylerde görülür.
<b>Beta</b>	12-30 Hz	Yüksek beyin aktivitesi durumlarında ortaya çıkan dalgalarıdır. Korku, heyecan, stres ve endişe durumlarında görülür.
<b>Gama</b>	30-100 Hz	Genellikle klinikte kullanılmayan, EEG kayıtlarında filtrelenen yüksek frekans bantlarıdır.

## 2.2.2- EEG dalgalarının ölçülmesi

Sinyal özellikleri, gözlenen beynin bölgesine ve dolayısıyla izlenen elektrota göre değişir. Elektrotların konumu EEG'nin genliğini, fazını ve frekansını doğrudan etkilemektedir. Elektrotların yerleştirileceği uygun yerler frontal, parietal, temporal, ya da oksipital beyin loblarıdır. En çok kullanılan yerleşim şeması American Electroencephalographic Society tarafından tavsiye edilen 10-20 EEG elektrot konumlandırma sistemi Şekil 2.1'de gösterilmiştir (Malmivuo ve Plonsey, 1995).



Şekil 2.1. 10-20 EEG elektrot konumlandırma sistemi (Malmivuo ve Plonsey, 1995)


## 2.2.3- EEG sinyallerini etkileyen olaylar

EEG sinyalleri uyku, epilepsi, refleksoloji, ilaç ve anestezi, diyabet, meditasyon, müzik ve artefaktlar gibi olaylara göre farklılıklar gösterebilirler. Bu olaylar hekimin seçimine göre değişiklik gösterebilirken beyin dışındaki kaynaklardan gelen istenmeyen elektrik potansiyelleri olan artefaktlar neredeyse her zaman mevcut olup önlenememektedir. Küçük genlikli EEG sinyalleri, artefaktlara oldukça hassas olup EEG sinyallerinin yorumlanmasını iyileştirmek için artefaktlar algılanmalı ve kaldırılmalıdır.

## 2.3- Dalgacık Dönüşüm Yöntemi

Dalgacık, sıfırdan başlayan, artan ve sonra sıfıra doğru azalan genliğe sahip dalga benzeri bir salınımdır. Dalgacık Dönüşümü, veriyi farklı frekans bileşenlerine ayıran ve her bir bileşeni o ölçekteki çözünürlüğüyle inceleyen bir dönüşüm tekniğidir (John, 2016).

Bir sinüs dalgası belirli bir sürede genliği sıfıra inmeyen bir titreşim işaretidir. Dalgacık işareti ise belirli bir sürede genliği sıfıra inen bir salınım işaretidir. Şekil 2.2a'da sürekli, düzenli ve simetrik sinüs dalgası ve Şekil 2.2b'de ise sınırlı, asimetrik ve düzensiz dalgacık gösterilmiştir (Nizam, 2008).



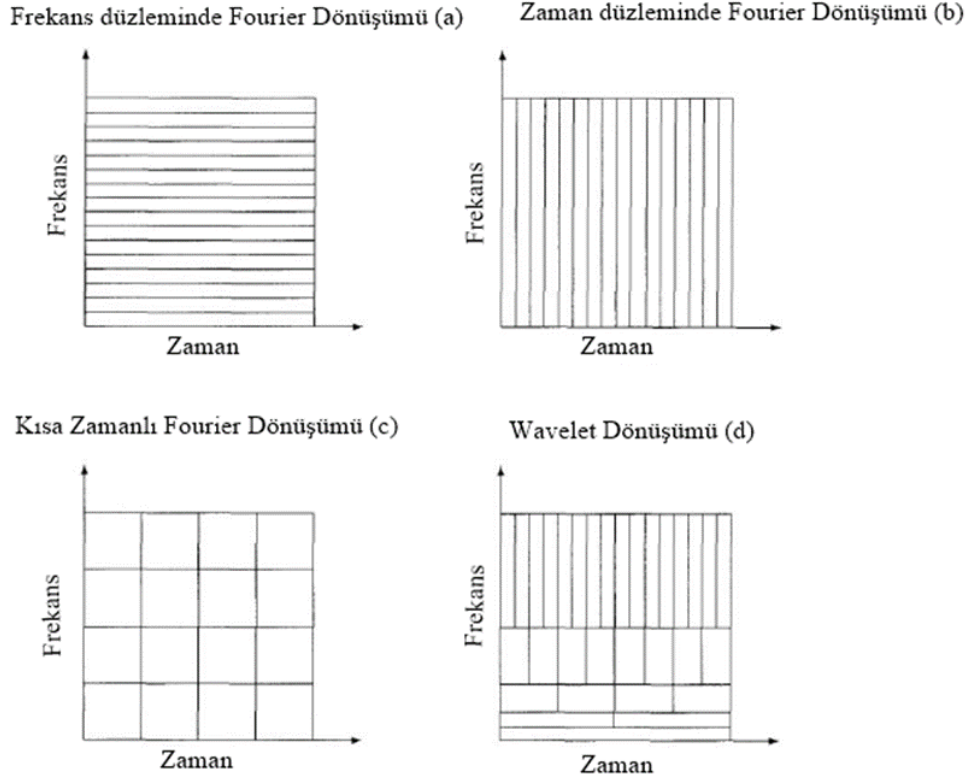
Şekil 2.2. a) Dalga ve b) Dalgacık (Nizam, 2008).

Bir dalgacık sıfır ortalamaya sahip bir fonksiyondur (Omerhodzic, Avdakovic, Nuhanovic ve Dizdarevic, 2013). Bu ifadeye ait matematiksel gösterimi aşağıda verilmiştir.

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (2.1)$$

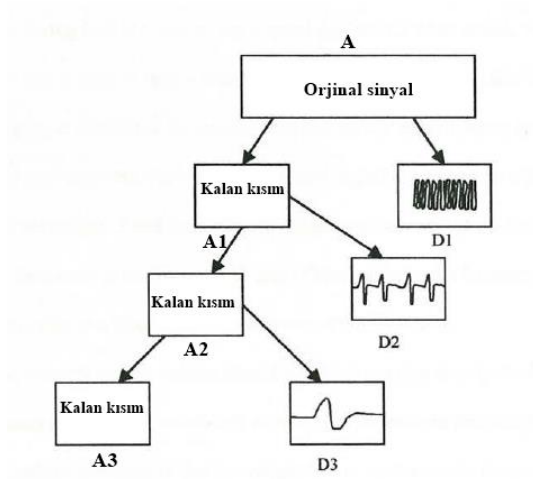
Dalgacık Dönüşümü değişen bir pencere boyutuna sahiptir ve bu pencereler düşük frekanslarda geniş, yüksek frekanslarda dardır. Böylece tüm frekans aralıklarında optimum zaman-frekans çözünürlüğünü sağlar. Ancak bazı çalışmalarda Fourier Dönüşümünün geliştirilmiş şekli olan Kısa Süreli Fourier Dönüşümü kullanılsa da seçilen pencere boyutunun sabit

olmasından dolayı bu yöntem hem zaman hem de frekans düzleminde eşit bir çözünürlük ve iyi bir sonuç vermeyebilir (Tekin, Kaya ve Tağluk, 2011; Übeyli, 2009). Şekil 2.3'te Fourier Dönüşümü, Kısa Süreli Fourier Dönüşümü ve Dalgacık Dönüşümüne ait grafikler verilmiştir.

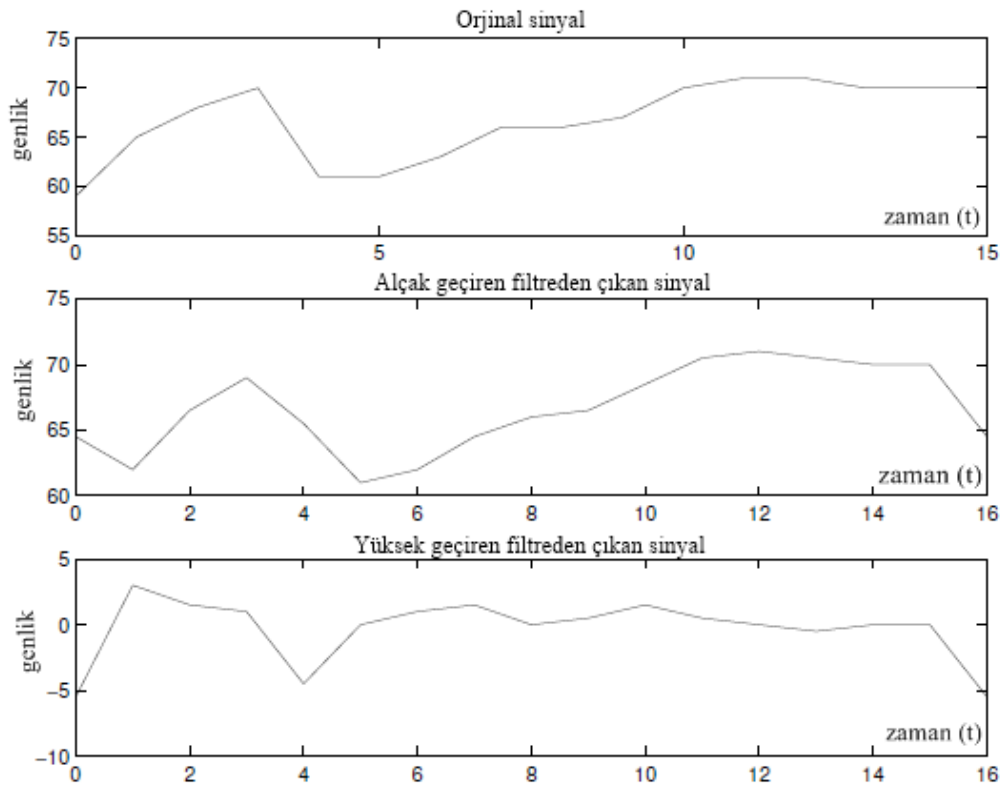


**Şekil 2.3.** Frekans düzleminin farklı tekniklerle bölünmesi (Gençay, Selçuk, ve Whitcher, 2001)

Sinyal işleme genellikle gürültünün ortadan kaldırılmasını gerektirir ve dalgacık filtresi bunu çok etkili bir şekilde yapabilir. Şekil 2.4'te şematik olarak Dalgacık Filtreleme örneği gösterilmiştir. Burada A sinyali yüksek ölçekli-düşük frekanslı bileşenleri ve D sinyali düşük ölçekli-yüksek frekanslı bileşenleri bölmek için filtrelenmiştir. Kalan A1 sinyali daha düşük frekansları kaldırmak için tekrar filtrelenebilir. Bu iterasyonlar sinyalin en düşük frekanslı bileşeni kalana kadar devam eder (Smertneck, 2000). Şekil 2.5'te ise başka bir filtrelenmiş sinyal frekans düzleminde gösterilmiştir.



**Şekil 2.4.** ADD ile 3. Seviyeden ayrıştırılan Dalgacık Filtreleme Örneği (Smertneck, 2000).



**Şekil 2.5.** Filtrelenmiş bir sinyal örneği (Weeks, 2007)

Dalgacık Dönüşümünün 2 temel parametresi vardır:

- **a ölçek (dilatasyon) parametresi:** Bir fonksiyonu sıkıştırır veya yayar. a'nın küçük değerleri yüksek frekanslara, büyük değerleri küçük frekanslara karşılık gelir.
- **b öteleme parametresi:** Zaman (işaretlerde) veya x,y (resimlerde) boyunca dalgacığın ötelenmesini sağlar.

Bu a ve b parametresinin sürekli veya ayırık oluşuna göre Dalgacık Dönüşümü, Sürekli Dalgacık Dönüşümü (SDD) ve Ayırık Dalgacık Dönüşümü (ADD) olarak ikiye ayrılır (Haşiloğlu, 2001).

### 2.3.1- Sürekli dalgacık dönüşümü

Sürekli Dalgacık Dönüşümü ana dalgacığın zaman düzleminde ötelenmiş ve ölçeklenmiş sürümleriyle çarpılan sinyalin tüm zaman boyunca toplamıdır (Öksüz, Altun, Ülgerli, Yücel, ve Özen, 2016). Sürekli Dalgacık Dönüşümü aşağıdaki eşitlikte gösterilmiştir.

$$SDD(a,b) = \int_{-\infty}^{+\infty} x(t) \Psi_{(a,b)}^*(t) dt \quad (2.2)$$

Bu eşitlikte;  $x(t)$ , analiz edilen sinyali,  $a$ , ölçek parametresini ve  $b$ , zamanda kaydırma parametresini ve  $\Psi_{(a,b)}(t)$  ise ana dalgacık fonksiyonunu göstermektedir. Ana dalgacık fonksiyonu  $\Psi$  hem zaman düzlemine hem de frekans düzlemine uygun olarak yerleşir (Cohen ve Kovacevic, 1996). Ana dalgacık fonksiyonu 2.3'de gösterildiği gibi  $a$  ve  $b$  parametrelerine göre elde edilir.

$$\Psi_{(a,b)}(t) = \frac{1}{\sqrt{|a|}} \Psi\left(\frac{t-b}{a}\right) \quad (2.3)$$

Sürekli Dalgacık Dönüşümünde ölçekleme ve öteleme parametreleri ikinin üsleri şeklinde seçilmesi Ayırık Dalgacık Dönüşümünü ortaya

çıkarmıştır. Bu dönüşüm ile çözümlenmeler Sürekli Dalgacık Dönüşümüne göre daha etkili ve doğru sonuç verir (Öksüz vd. 2016).


Sürekli Dalgacık Dönüşümündeki süreklilik kavramı ölçek ve öteleme parametreleri  $a$  ve  $b$ 'nin sürekli olarak değiştiğini gösterir. Bununla birlikte olası her ölçekte dalgacık katsayılarının hesaplanması oldukça güç olabilmektedir ve çok büyük veri yığınlarının oluşmasına neden olur. Bundan dolayı genellikle Ayırık Dalgacık Dönüşümü kullanılır (Übeyli, 2009).

### 2.3.2- Ayırık(Kesikli) dalgacık dönüşümü

Dalgacık Dönüşümünün temel parametrelerinden  $a=2^j$  ve  $b=k2^j$  olarak alınırsa Ayırık Dalgacık Dönüşümü aşağıdaki eşitlikteki gibi olur.

$$\Psi_{j,k}(t) = 2^{-j/2} * \Psi\left(\frac{t-b}{a}\right) \quad (2.4)$$


Ayırık Dalgacık Dönüşümü sinyalin hesaplama süresini azaltarak orijinal sinyalin sentezi ve analizi için yeterli bilgiyi sağlamaktadır. Bu dönüşüm genellikle sıkıştırma ve gürültüden arındırma için kullanılır (Subha, Joseph, Acharya ve Lim, 2010). Ayırık Dalgacık Dönüşümünün hesaplanması, sinyalin bir dizi filtreden geçmesine izin verilerek sağlanır. Burada ana sinyal,  $h(n)$  alçak ve  $g(n)$  yüksek geçiren filtreleri aracılığıyla alt bileşenlerine ayrılır (Sun, 2015). Sinyalin bu filtrelerden geçirilerek ayrıştırılması (analiz) ve birleştirilmesi (sentez) Şekil 2.6'da şematize edilmiştir.



**Şekil 2.6.** Sinyalin ayrışım ve birleşmesi (Yılmaz & Bozkurt, 2013).



Bu ayrışım ile oluşan sinyalin yaklaşım ve detay katsayıları Şekil 2.7’de gösterilmiştir. Buradaki  $A_1$ ,  $A_2$  ve  $A_3$ ; 1,2 ve 3. Seviyedeki yaklaşım katsayılarını yani (alçak frekanslı bileşenlerini),  $D_1$ ,  $D_2$  ve  $D_3$ ; 1,2 ve 3. seviyedeki detay katsayılarını (yüksek frekanslı bileşenlerini) göstermektedir. Burada ana sinyalin yeniden oluşturulması 2.5 eşitliğindeki gibidir.



**Şekil 2.7.** 3.seviyeden dalgacık ayrışım algoritması (Miner, 1998)

$$f(x) = A_1 + D_1 = A_2 + D_2 + D_1 = A_3 + D_3 + D_2 + D_1 \quad (2.5)$$

Sinyal ayrışımında maksimum seviye, sinyaldeki ana frekans bileşenine bağlıdır.  $i$ -inci seviyedeki yaklaşım ( $A_i$ ) ve detay ( $D_i$ ) katsayıları aşağıdaki eşitliklerde gösterilmiştir.

$$A_i = \frac{1}{\sqrt{M}} \sum_n x(n) * \varphi_{j,k}(n) \quad (2.6)$$

$$D_i = \frac{1}{\sqrt{M}} \sum_n x(n) * \psi_{j,k}(n) \quad (2.7)$$

Burada;

$$n=0,1,2,\dots, M-1$$

$$j=0,1,2,\dots, J-1$$

$$k=0,1,2,\dots, 2^j-1$$

$J=\log_2(M)$ ,  $M$  ise sinyalin uzunluğudur.

Buradaki dilatasyon fonksiyonu  $\varphi_{j,k}(n)$  alçak geçiren filtreye, dalgacık fonksiyonu  $\psi_{j,k}(n)$  ise yüksek geçiren filtreye bağlıdır (Gonzalez ve Woods, 2007). Bu fonksiyonlar aşağıda verilmiştir.

$$\varphi_{j,k}(n) = 2^{j/2} * h(2^j n - k) \quad (2.8)$$

$$\psi_{j,k}(n) = 2^{j/2} * g(2^j n - k) \quad (2.9)$$

Eşitlik 2.8 ve 2.9 da verilen yüksek geçiren  $g(k)$  ve alçak geçiren  $h(k)$  filtreleri aşağıdaki eşitliklerde verilmiştir.

$$h_{i+1}(k) = \sum_n h_i[n] * h[2k - n] \quad (2.10)$$

$$g_{i+1}(k) = \sum_n h_i[n] * g[2k - n] \quad (2.11)$$

Böylece her ayrışım seviyesinde yarım band geçiren filtreler aracılığıyla frekans bandının yarısını içeren sinyaller oluşturulur.

### 2.3.2.1- Ayrık dalgacık dönüşümü kullanılarak özellik çıkarımı

EEG kayıtlarından ilgili bilginin çıkarılmasında ana adımlar; önışleme, özellik çıkarımı ve sınıflandırmadır. Özellik çıkarımı EEG veri sınıflamasında büyük önem taşır. Çünkü özellik çıkarma adımı sistemin sınıflandırma başarısında doğrudan etkiye sahiptir. Eğer EEG sinyalinden çıkartılan özellikler mevcut problem için yeterince açıklayıcı değilse sınıflandırıcının performansı da iyi olmayabilir. Aynı şekilde özellik çıkarımı başarılıysa sınıflandırma performansı da o kadar başarılı olur (Amin vd., 2015). Özellik seçimi isteğe bağlıdır. Ancak sınıflama başarısına katkı bakımından en etkili özelliklerin seçilip özellik vektörünün boyutunun azaltılması çalışmanın başarısı için önem teşkil etmektedir (Güler & Übeyli, 2004).


## 2.4- Dalgacık Aileleri

Literatürde Dalgacık Dönüşümü için ana dalgacık olarak kullanılabilen birçok fonksiyon vardır. Ana dalgacık, dönüşümde kullanılan tüm dalgacık fonksiyonlarını kaydırma ve ölçeklendirme yoluyla ürettiğinden Dalgacık Dönüşümünün özelliklerini yine bu ana dalgacık belirler. Bu yüzden bu dönüşümün etkin bir şekilde uygulanmasında ana dalgacığın seçimi büyük önem taşır. Burada seçilen dalgacığın, dönüştürülecek sinyalin şekline benzemesi de önemlidir (Najumnissa, 2010).

Literatür çalışmalarında en sık kullanılan dalgacıklar Haar, Daubechies, Symlets, Coiflets, Biorthogonal, Morlet ve Mexican Hat olup bu dalgacıklar kısaca verilmiştir.

### 2.4.1- Haar


Haar, Alfred Haar tarafından önerilen ilk ve en basit dalgacıdır. Aynı zamanda Daubechies 1 Dalgacı olarak da bilinen bu dalgacık süreksiz olup bir merdiven fonksiyonunu andırır. Sinyali eş uzunluktaki 2 alt sinyale ayırır (Dogra, 2017). Haar fonksiyonunun zaman-genlik gösterimi Şekil 2.8'de verilmiştir.



**Şekil 2.8.** Haar fonksiyonunun zaman-genlik gösterimi (Misiti, Misiti, Oppenheim, & Poggi, 1996).

### 2.4.2- Daubechies


İsmi Ingrid Daubechies'den alan bu dalgacık Ayrık Dalgacık Analizini pratikleştirir. N Daubechies sırası olmak üzere dbN şeklinde gösterilirler. Db1 Haar Dalgacıyla aynı olup bu ailenin en çok kullanılan diğer 9 dalgacı şekil 2.9'da gösterilmiştir (Misiti vd., 1996).



Şekil 2.9. Daubechies fonksiyonunun zaman-genlik gösterimi(Misiti vd., 1996).

### 2.4.3- Symlets

Daubechies ailesinin değiştirilmesiyle oluşturulan Symlets Dalgacık ailesi yaklaşık olarak simetrik bir yapı gösterir. Şekil 2.10'da bu dalgacık ailesine ait zaman-genlik gösterimleri verilmiştir.



Şekil 2.10. Symlets fonksiyonunun zaman-genlik gösterimi (Misiti vd., 1996).

#### 2.4.4- Coiflets


Simetriğe yakın bir yapıya sahip olan Coiflets Dalgacık ailesinin kısa ismi Coif olup bu dalgacıklara ait zaman genlik gösterimleri Şekil 2.11’de gösterilmiştir.



Şekil 2.11. Coiflets fonksiyonunun zaman-genlik gösterimi (Misiti vd., 1996).

#### 2.4.5- Biorthogonal


Simetrik yapıda olan bu dalgacıklar hem ayrık hem de Sürekli Dalgacık Dönüşümünde kullanılabilirler. Kısaca Biort olarak gösterilen bu dalgacık ailesi, tek bir dalgacık kullanmak yerine ayrışma ve yeniden yapılanma için 2 ayrı dalgacık kullanarak özellik çıkarımı yaparlar. Şekil 2.12’de biorthogonal ailesinden bior1.3’ e ait ayrışma ve birleştirme grafikleri verilmiştir (Doğru, 2015).



Şekil 2.12. Bior1.3 fonksiyonunun zaman-genlik gösterimi (Misiti vd., 1996).

#### 2.4.6- Morlet


Simetrik bir yapı gösteren Morlet Dalgacığının ölçeklendirme fonksiyonu bulunmamaktadır. Şekil 2.13'de bu fonksiyonun görünümü verilmiştir (Misiti vd.,1996).



**Şekil 2.13.** Morlet fonksiyonunun zaman-genlik gösterimi (Misiti vd., 1996).

#### 2.4.7-Mexican Hat

Ölçeklendirme fonksiyonu olmayan bu dalgacık fonksiyonu, Gauss olasılık yoğunluk fonksiyonunun 2. dereceden türevi ile orantılı olan bir fonksiyondan üretilmiştir. Simetrik bir yapısı olan bu dalgacığın zaman-genlik gösterimi şekil 2.14'de verilmiştir (Misiti vd.,1996).



**Şekil 2.14.** Mexican hat fonksiyonunun zaman-genlik gösterimi (Misiti vd., 1996).

## **2.5- Yapay Sinir Ağları**

### **2.5.1- Giriş**

İnsan beyninin üstün özellikleri, bilim insanlarının beynin nörofiziksel yapısından esinlenerek bu alanda çalışmalar yapmalarına neden olmuştur. Bu çalışmalar sonrasında beynin matematiksel modellenmesi yapılmıştır. Böylece yapay sinir ağları uygulamalarını da içeren yapay zeka bilim dalı ortaya çıkmıştır.

Yapay sinir ağları, bağımsız değişkenleri olan girişleri, bağımlı kestirilen değişkenler olan çıkışlar ile ilişkilendirerek karmaşık ve doğrusal olmayan modeller oluşturan bir yapay zeka uygulamasıdır (Demirhan, Kılıç, & İnan, 2010).

Geleneksel bilgisayarlara kıyasla yeni bir bilgisayar ve algoritma mimarisine sahip yapay sinir ağları, merkezi sinir sisteminin sinir hücresi ağlarını taklit ederek hesaplama yapmaya çalışır. YSA, kendi kendine öğrenme, ezberleme, tahmin etme ve bilgiler arasında ilişkiler kurma, sınıflandırma ve en iyileştirme (optimizasyon) yeteneklerine sahip bir düzendir (Graupe, 2013).

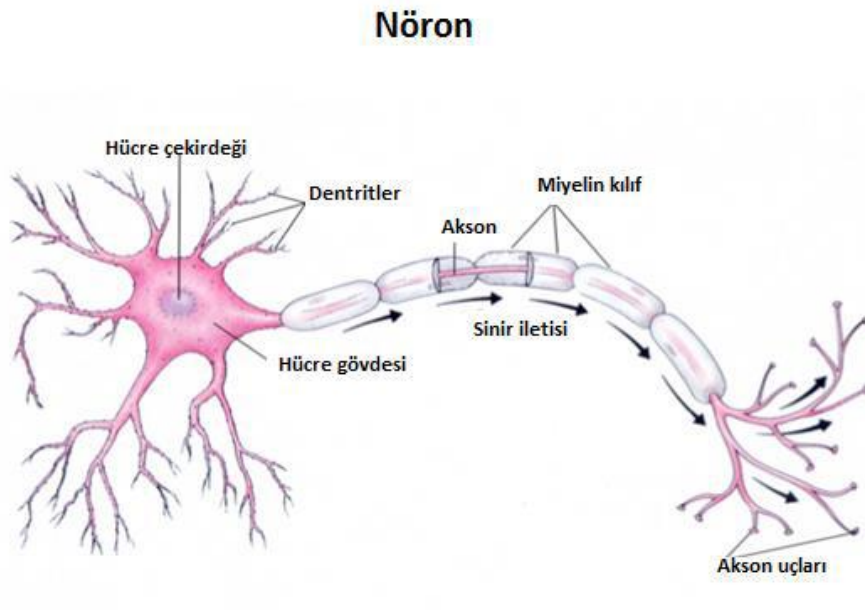
### **2.5.2- Yapay sinir ağı kullanım alanları**

Mevcut yöntemlerle çözülemeyen çok farklı problemlerin çözümünde, belirsiz, gürültülü ve eksik bilgilerin işlenmesinde ve doğrusal olmayan sistemlerde başarıyla uygulanmasından dolayı yaygın olarak kullanılırlar (Elmas, 2007).

Tıp, eğitim, finans, endüstri ve askeriye gibi birçok alanda sınıflandırma, tahmin etme, modelleme, görüntü işleme, örüntü tanıma, ses tanıma, sinyal işleme gibi uygulamalarda kullanılmaktadır. YSA tıp alanında EEG, EKG sinyal analizi, transplantasyon zamanlarının analizi, tıbbi görüntü işleme ve çeşitli hastalıkların teşhisinde başarılı bir şekilde uygulanmaktadır (Ripley, 2007)

### 2.5.3- Biyolojik sinir ağı

Yapay sinir ağı biyolojik sinir sisteminden esinlenerek geliştirilen yöntemlerdir. Biyolojik sinir hücreleri sinapsisler aracılığıyla birbirleriyle iletişim kurarlar. Bu sinir hücreleri edindikleri bilgileri aksonlar yardımıyla diğer sinirlere taşırlar. Benzer şekilde YSA'da dış dünyadan aldığı bilgileri toplama fonksiyonuyla toplayıp aktivasyon fonksiyonundan geçirerek çıktıyı üretir ve bu çıktıyı ağ bağlantıları üzerinden diğer proses elemanlarına gönderir. Şekil 2.15'te biyolojik sinir ağının yapısı gösterilmiştir.



**Şekil 2.15.** Biyolojik sinir ağının yapısı ("Popular Science: Neural Networks. How does it work?," 2016)


### 2.5.4- Yapay sinir ağı mimarisi

Biyolojik bir sinir ağında nöronların yer aldığı gibi bir yapay sinir ağında da yapay nöronlar yer alır. Bu yapay nöronlar bir araya getirilerek bir mimari veya işleme yapısına bağlanır. Bu mimari, her giriş değişkeninin bir veya daha fazla çıkış düğümüne bağlandığı bir ağ oluşturur. Bu ağa yapay sinir ağı denir.

En basit bir yapay sinir hücresi yapısal olarak Girdiler, Ağırlıklar, Toplam fonksiyonu, Aktivasyon fonksiyonu ve Çıktı olmak üzere 5 ana



bileşenden oluşur. Şekil 2.16'da bir yapay sinir ağının mimarisi gösterilmiştir (Nisbet, Miner ve Elder IV, 2009).



**Şekil 2.16.** Bir dizi girdileri olan bir nöronun mimarisi

Burada;

- Girişler: Çevreden aldığı bilgileri sinirlere iletir.
- Ağırlıklar: Yapay sinire verilen girişlerin sinir üzerindeki etkisini belirleyen katsayılardır. Bu katsayının büyük ya da küçük olması o sinirin yapay sinire güçlü ya da zayıf bağlanması anlamına gelmektedir.
- Toplama işlevi (NET): Her bir giriş ile ağırlığın çarpımlarının toplamalarını  $Q_j$  eşik değeri ile toplayan fonksiyondur.

$$NET = a = f(w, x) = f\left(\sum_{i=1}^n w_i x_i\right) \quad (2.10)$$

- Aktivasyon işlevi F(NET): Toplama işlevinin sonucu aktivasyon fonksiyonundan geçerek üretilecek olan çıktı değerini belirler. Literatürde sigmoid, lineer, step, sinüs, hiperbolik tanjant fonksiyonları gibi birçok aktivasyon fonksiyonları var olup literatürde en çok kullanılan çok katmanlı algılayıcı YSA'larda genellikle sigmoid fonksiyon tercih edilir. Aşağıda logsig aktivasyon fonksiyonunu temsil eden F(NET) fonksiyonu verilmiştir.

$$F(NE_T) = \frac{1}{1 + e^{-NE_T}} \quad (2.11)$$

- Çıkış işlevi: Etkinlik işlevinin sonucu çıkışa getirilerek dış dünyaya ya da diğer sinirlere bırakılır. Bir nöronun çıkışı ise aktivasyon fonksiyonu tarafından belirlenen değerdir.

Biyolojik sinir ağı ve yapay sinir ağları yapılarının anlatılmasının ardından Tablo 2.2’de biyolojik sinir ağı ile YSA arasındaki benzerlikler gösterilmiştir (Dandıl & Çevik, 2011; Elmas, 2007).

**Tablo 2.2.** Biyolojik sinir ağı ile YSA’nın karşılaştırılması (Elmas, 2007)


<b>Biyolojik Sinir Ağı</b>	<b>Yapay Sinir Ağı</b>
Nöron	Sinir, işlem elemanı
Sinaps	Sinirler arası bağlantı ağırlıkları
Dendrit	Toplam fonksiyonu
Hücre gövdesi	Aktivasyon fonksiyonu
Akson	Sinir çıkışı

### 2.5.5- Yapay sinir ağında öğrenme

Yapay sinir ağında hücre bağlantılarının ağırlık değerlerinin belirlenmesine ağırlık eğitimi denir. İlk eğitimde bu değerler randomize olarak belirlenirken daha sonraki eğitimler çıktı değerlerine göre tekrar tekrar değiştirilerek gerçekleşir. Buna ağırlık öğrenmesi denir (Dandıl & Çevik, 2011). Bir YSA’ya girdiler verildikten sonra ilk eğitimden sonra ağırlıkların yenilenmesiyle çıktı verileri ile beklenen değerler arasındaki hata kareleri ortalamasının (HKO) en küçük olması istenir. HKO istenilen değerden küçük değilse öğrenme, ağırlıkların yenilenmesiyle olur. Öğrenme ile elde edilen bilgiler bağlantı ağırlıklarında depolanır. Böylece elde edilen bilgi uzun süre saklanabilir ve geri besleme yöntemi ile YSA yeniden eğitilir (Şen, 2004).

## 2.5.6- Yapay sinir ağlarının sınıflandırılması

Ara katmanı olmayan yani sadece giriş ve çıkış katmanından oluşan ağlar karmaşık problemlerin çözümünde yetersiz kalmaktadır. Bu yüzden karmaşık hesaplamalar için oluşturulan bir yapay sinir ağına en az bir ara katman bulunmalıdır. Basit bir yapay sinir ağı 2.17'de gösterilmiştir. Burada giriş katmanından içeri alınan girişler, giriş katmanı ve gizli katman arasındaki ağırlıklar ile çarpılarak gizli katmana ulaşır. Gizli katmandaki sinirlere gelen girişler toplanarak gizli katman ile çıkış katmanı arasındaki bağlantı ağırlıklarıyla çarpılarak çıkış katmanına verilir. Böylece giriş katmanından çıkış katmanına doğru tek yönlü bir iletim gerçekleşir (Elmas, 2007).




**Şekil 2.17.** Basit bir yapay sinir ağı modeli(Elmas, 2007).

YSA mimarileri nöronlar arasındaki iletimin yönüne göre ileri beslemeli (feedforward) ve geri beslemeli (feedback) olarak ikiye ayrılır. İleri beslemeli YSA'da hücreler katmanlar şeklinde düzenlenip giriş katmanı dış dünyadan aldığı bilgileri doğrudan gizli katmana iletir. Bu ağlar çok katmanlı ileri beslemeli ağlar olarak da adlandırılırlar. Geri beslemeli YSA'da ise en az bir hücrenin çıkışı, kendine ya da diğer hücrelere giriş olarak verilir. Geri Beslemeli ağ yapıları genellikle danışmansız öğrenme şeklinde gerçekleşen yapay sinir ağlarında uygulanmaktadır (Gürsoy, 2009).

İleri Beslemeli YSA modeli, YSA uygulamalarının yaklaşık %90'ını oluşturur. Bu YSA modeli için en yaygın olarak kullanılan öğrenim algoritması geri yayılım (backpropagation) öğrenmesidir (Welstead, 1994). Bu öğrenim algoritmasında iki akış vardır. İlk akış katmanlar üzerinden ileriye doğru bilgi akışı şeklinde gerçekleşir. Burada bağlantı katsayıları kullanılarak girişlere karşı çıkışlar elde edilir. İkinci akış ise gerçek çıkışlar ile beklenen çıkış değerleri yardımıyla elde edilen hatanın geriye yayılarak ağırlıklarının değiştirilmesi şeklinde gerçekleşmektedir (Gürsoy, 2009).

Literatürde birçok sinir ağı modeli önerilmiş olmasına rağmen, geriye doğru yayılım öğrenme mekanizmasına sahip çok katmanlı ileri beslemeli ağı, pratik uygulamalar açısından en yaygın kullanılan modeldir (Kantardzic, 2011). Bu yöntemde girdi, gizli ve çıktı birimi olmak üzere 3 farklı birim bulunmaktadır. Hücreler katmanlar şeklinde düzenlenir ve bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir (Murugesan ve Sukanesh, 2009).

Bir yapay sinir ağında istenilen çıktılara ulaşmak için ağı eğitilir. Şekil 2.18'de geri yayılım algoritmasının yapısı gösterilmiştir. Burada ilk hesaplamalardan alınan çıktılar ile beklenen çıktılar karşılaştırılıp birbirlerine göre kabul edilebilir hata sınırları içindeyse YSA eğitime son verilir. Aksi halde eğitime devam edilir.



**Şekil 2.18.** Geri yayılım algoritması yapısı

Yapay sinir ađları, uygulamadaki kolaylıđı, fazla veriye ihtiya duymaması ve veri dađılımlarından etkilenmemesinden dolayı iyi bir yontemdir (Partal, Kahya ve Cıđızođlu, 2011). Sinir ađının istenen haritalamayı retmesi iin, bađlantı ađırlık ve nbilgilerini ayarlaması iin ađ eđitilmelidir. Eđitim ařamasında, zellik vektrleri ađa girdi olarak uygulanır ve ađ, girdi ve ıktılar arasındaki iliřkiyi yakalamak iin deđiřken parametrelerini ve ađırlıklarını ayarlar (Subasi, 2005).



### 3. GEREÇ VE YÖNTEMLER

#### 3.1- Gereçler

Bu çalışmada Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Sağlık Uygulama ve Araştırma Hastanesi Çocuk Sağlığı ve Hastalıkları Anabilim Dalına 2015-2017 yılları arasında başvuran bireyler çalışmaya dahil edilmiştir. Yapılan muayene sonucu Akut Lenfoblastik Lösemi (ALL) tanısı almış olan 2-15 yaş arası 5 bireyin tedavileri tamamlandıktan sonra çekilmiş olan EEG'leri hasta grubunu oluşturmaktadır. Aynı anabilim dalına herhangi bir sağlık problemiyle başvurmuş ve yapılan taramalar sonucunda EEG'sinde herhangi bir bozukluğu bulunmayan 2-15 yaş arası 11 sağlıklı çocuk ise bu çalışmanın sağlıklı grubunu oluşturmaktadır. Kullanılan veri setine ait hasta ve sağlıklı grup için dahil edilme ve dışlama kriterleri Tablo 3.1 ve Tablo 3.2'de gösterilmiştir.

**Tablo 3.1.** Çalışmaya dahil olma kriterleri.

HASTA GRUBU	SAĞLIKLI GRUBU
ALL tanısı almış olmak	EEG'de patolojiye sebep olabilecek herhangi bir rahatsızlığı olmamak
2-15 yaş arası olmak	2-15 yaş arası olmak
Tedavisini tamamlamış olmak	Tedavisini tamamlamış olmak
Santral sinir sistemi tutulumu olmaması	Santral sinir sistemi tutulumu olmaması
Kranyal radyoterapi almamış olması	Kranyal radyoterapi almamış olması
38-42. Hafta gestasyonel yaşta vajinal doğum ile sağlıklı doğmak	38-42. hafta gestasyonel yaşta vajinal doğum ile sağlıklı doğmak
Genetik hastalığı olmamak	Genetik hastalığı olmamak
Sağ el dominant olmak	Sağ el dominant olmak

**Tablo 3.2.** Çalışmaya dahil edilmeme kriterleri.


<b>HASTA VE KONTROL GRUBU İÇİN DAHİL EDİLMEME KRİTERLERİ</b>	
<ul style="list-style-type: none"><li>• EEG’de patolojiye sebep olabilecek lösemi, epilepsi, bilinç bozuklukları, santral sinir sistemi hastalıkları gibi herhangi bir rahatsızlığı olması</li></ul>	<ul style="list-style-type: none"><li>• Annenin yaşam öyküsünde alkol, madde bağımlılığı ve psikiyatrik bir bozukluğunun olması</li></ul>
<ul style="list-style-type: none"><li>• 2 yaşından küçük, 15 yaşından büyük olmak</li></ul>	<ul style="list-style-type: none"><li>• Sezaryen doğum ve doğum distosisi</li></ul>
<ul style="list-style-type: none"><li>• Santral sinir sistemi tutulumu olması</li></ul>	<ul style="list-style-type: none"><li>• Sedatif herhangi bir ilaç kullanıyor olması</li></ul>
<ul style="list-style-type: none"><li>• Tedavisini devam ediyor olması</li></ul>	<ul style="list-style-type: none"><li>• Genetik hastalığı olmak</li></ul>
<ul style="list-style-type: none"><li>• Kranyal radyoterapi almış olması</li></ul>	<ul style="list-style-type: none"><li>• Metabolik / Endokrin hastalığın olması</li></ul>
<ul style="list-style-type: none"><li>• 38-42. hafta gestasyonel yaşta doğmamış olmak</li></ul>	<ul style="list-style-type: none"><li>• Kraniofasiyal anomalisinin olması</li></ul>
<ul style="list-style-type: none"><li>• Sezaryen doğum ile doğmak</li></ul>	<ul style="list-style-type: none"><li>• Hipoksik iskemik ensefalopati bulgularının veya öyküsünün olması</li></ul>
<ul style="list-style-type: none"><li>• Sol el dominant olmak</li></ul>	

Çalışmaya başlanmadan önce Eskişehir Osmangazi Üniversitesi Klinik Araştırmalar Etik kurulundan gerekli izinler alınmış olup çalışmaya dahil edilecek hastalar uzmanlar tarafından belirlenmiştir (30.03.2017 tarihli 80558721/G-103 sayılı etik kurul onay raporu tezin son sayfasında verilmiştir). Hasta ve sağlıklı grubuna ait EEG verileri ise aynı anabilim dalına ait görüntüleme biriminde görevli tekniker tarafından Neurofax 1000 EEG cihazı ile kaydedilmiştir.

## 3.2- Yöntem

### 3.2.1- EEG Portaview

Çalışmaya dahil edilen bireylerin EEG kayıtları Neurofax EEG 1000 cihazı ile kaydedilmiştir. Grafik formunda elde edilen on dokuz kanallı EEG ham verisine istatistiksel analizleri uygulayabilmek için EEG sinyalleri kullanılan EEG cihazına ait EEG Portaview uygulaması ile ASCII formatına dönüştürülmüştür. Şekil 3.1’de bu programa ait ekran görüntüleri verilmiştir.



**Şekil 3.1.** Bir hastaya ait EEG sinyallerinin EEG Portaview uygulamasında görüntülenmesi

EEG kayıtları bireylerin istirahat pozisyonunda ve uykudayken alınmıştır. EEG çekimlerinde elektrotlar bireylerin kafatasına uluslararası 10-20 montaj sistemine göre yerleştirilmiştir. EEG sinyalleri 200 Hz ile örneklendirilmiş ve 30 Hz üstü sinyaller EEG Portaview uygulamasında filtrelenmiştir. Her bir hastanın on dokuz elektrot bölgesi için ayrı veri dosyaları elde edilmiş olup her bir elektrot bölgesi kendi arasında incelenmiştir. Elde edilen sayısal veriler, kayıt alma süresinde oluşan anlık değişimlerin sonucu etkilememesi amacıyla Dalgacık Dönüşümü kullanılarak hastanın elini hareket ettirmesi, gözünü kırpması, dışarıdan gelen gürültüler gibi artefaktlardan arındırılmıştır. Dalgacık Dönüşümünün



uygulamak için ASCII formatındaki sayısal veriler MATLAB R2017a programına aktarılmıştır.

### **3.2.2- ADD ile özellik çıkarımı**

Öncelikle elektrotlardan alınan sinyaller ADD ile 5.seviyeden ayrıştırılıp yaklaşım ve detay alt frekans bantları elde edilmiştir. Her bir yaklaşım katsayısının zaman-frekans dağılımını gösteren istatistiksel özellikleri aşağıda verilmiştir.

1. Her bir alt banddaki katsayıların ortalaması
2. Her bir alt banddaki katsayıların standart sapması
3. Her bir alt banddaki katsayıların maksimum değeri
4. Her bir alt banddaki katsayıların minimum değeri
5. Her bir alt banddaki katsayıların çarpıklık ölçüsü
6. Her bir alt banddaki katsayıların basıklık ölçüsü
7. Her bir alt banddaki katsayıların band gücü
8. Her bir alt banddaki katsayıların ortalama değeri
9. Her bir alt banddaki katsayıların entropi değeri
10. Her bir alt banddaki katsayıların kovaryansı

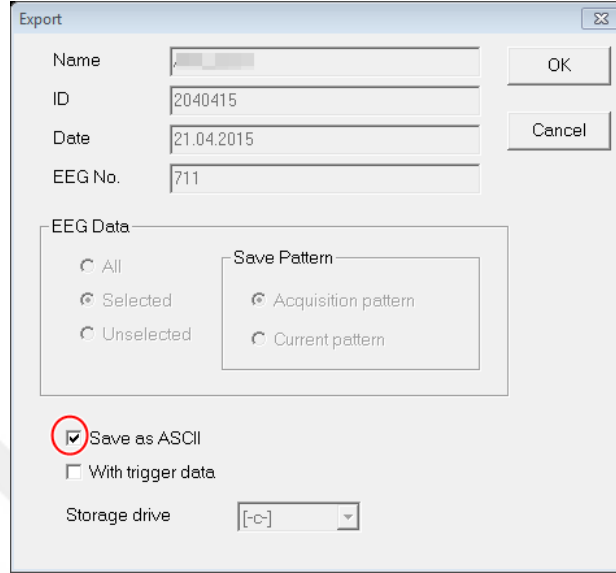
Bu çalışmada literatürde en çok kullanılan ortalama, standart sapma, maksimum ve minimum değerlerine ek olarak farklı özellikler de kullanılmıştır. Yukarıdaki özelliklerden ortalama, standart sapma, maksimum değer, minimum değer, çarpıklık, basıklık, kovaryans gibi özellikler sinyalin zaman alanına ait olup band gücü değeri sinyalin frekans alanına aittir. Buradaki ortalama değer ve entropi değeri sinyalin hem zaman hem de frekans alanına aittir (Altın & Er, 2016).

### **3.2.3- Verilere yöntemin uygulanması**

Ham EEG verilerine aşağıdaki adımlar uygulanarak istenilen sonuçlar elde edilmiştir.

**1.Adım:** Grafik formunda elde edilen ham EEG sinyalleri EEG Portaview programı ile ASCII formatına dönüştürülmüştür. Uygulama arayüzünde

File sekmesinde Export komutu ile "Save as ASCII" seçeneği işaretlenerek bu işlem tamamlanmıştır.



**Şekil 3.2.** EEG verilerini ASCII formatına dönüştürme

**2.Adım:** Aşağıdaki kodlarla ASCII formatlı veriler Matlab R2017a programına aktarılmıştır.

### Veri Setinin MATLAB programına aktarılması

```
names = dir('veri/*.m00') ;           %% dosyaların yolu
names = fullfile('veri', {names.name}) ; %% dosya içindeki verilerin
okunması
for i=1:1:numel(names)
    verilerim=load(names{i});         %% her verinin döngüde tek tek
yüklenmesi
    islem=verilerim(:,1:19);          %% her veri için ilk 19 sinyal
kullanılması
```

**3.Adım:** EEG sinyalleri Matlab'da 'dwt' fonksiyonu yardımıyla Haar, Daubechies, Symlets, Coiflets, Biorthogonal Dalgacıkları kullanılarak 5. seviyeden alt bantlarına ayrıldı. Bu alt bantlara ait grafikler elde edilmiştir.

Ayrıştırılan bantlar için elde edilen yaklaşım (A) ve detay (D) katsayılarından yaklaşım katsayılarına ait özellikler elde edildi. Aşağıda ADD ayrışımı için kodlar verilmiştir. (Çalışma boyunca, bu dalgacıklardan en iyi sonuçları veren ve ham EEG sinyaline en çok benzeyen Sym4 Dalgacığına ait çıktılar verilmiştir.)

### Veri setinin ADD ile ayrıştırılması ve özellik vektörünün elde edilmesi

```
sayi=0;
    for k=1:19

figure, plot(islem(:,k));

        [H,G] = dwt(islem(:,k), 'sym4');
        [H,G] = dwt(L, 'sym4');
        [H,G] = dwt(L, 'sym4');
        [H,G] = dwt(L, 'sym4');
        [H,G] = dwt(L, 'sym4');

figure, plot(H);
figure, plot(G);

        plt=subplot(19,1,k);
        plot(plt,H);

        sayi=sayi+1;
        ozellikler(i,sayi)= mean(H);

        sayi=sayi+1;
        ozellikler(i,sayi)=std(H);

        sayi=sayi+1;
        ozellikler(i,sayi)=max(H);

        sayi=sayi+1;
        ozellikler(i,sayi)=min(H);

        sayi=sayi+1;
        ozellikler(i,sayi)=skewness(H);

        sayi=sayi+1;
        ozellikler(i,sayi)= kurtosis(H);

        sayi=sayi+1;
        ozellikler(i,sayi)= bandpower(H);

        sayi=sayi+1;
        ozellikler(i,sayi)= (1/numel(H))*sum(H.^2);

        sayi=sayi+1;
        ozellikler(i,sayi)= entropy(H);

        sayi=sayi+1;
        ozellikler(i,sayi)=median(H);

end
```

**4.Adım:** Elde edilen bu özellikler 'newff' fonksiyonu yardımıyla feedforward sinir ağı oluşturulmuştur. Öğrenme kuralı olarak traingdx algoritması (gradient descent geri yayılım algoritması- back propagation) kullanılmış ve bu öğrenme kuralındaki parametrelerden öğrenme oranı (lr-learnin rate), maksimum iterasyon sayısı parametreleri için en uygun değerler araştırılmış, deneme yanılma yoluyla değiştirilip en iyi sınıflandırma başarısı elde edilmeye çalışılmıştır. Aşağıda, özelliklerin YSA ile sınıflandırılmasına ilişkin kodlar verilmiştir.

### Özelliklerin YSA ile sınıflandırılması

```
hedef = [0 0 0 0 0 0 0 0 0 0 0 1 1 1 1 1];
ozellikler=ozellikler';
[net]=newff(ozellikler,hedef,[190 100 10 1],
{'logsig','purelin'},'traingdx');
net.trainParam.epoch=1000;
net.trainParam.lr=0.8;
net.trainParam.mc=0.5;
net.trainParam.max_fail=3000;
[net,tr]=train(net,ozellikler,hedef);
[net,tr]=train(net,ozellikler,hedef);
[cikistest]=sim(net,ozellikler);
cikistest=round(cikistest);
H=length(hedef);
hata=0;
for i=1:H
    if cikistest(1,i)~=hedef(1,i)
        hata=hata+1;
    end
end
yuzdehata=hata*100/H;
fprintf('test basarısı=%f\n', 100-yuzdehata);
```

Sınıflama işlemi esnasında toplam veri seti, eğitim ve test verileri olmak üzere ikiye ayrılmıştır. Cross Validation yöntemi ile verilerin %80'i eğitim, %20'si ise test kümesine yerleştirilerek orantılı bir dağılım gerçekleştirilmeye çalışılmıştır. YSA'nın sınıflandırma başarısını değerlendirmek için doğruluk (accuracy) ölçütü kullanılmıştır. Buradaki sınıflama performans ölçütü test verilerinden her yüz veriden kaç tanesinin doğru sınıflandığının bulunması ile kaydedilmiştir.

$$Accuracy = \frac{TP + TN}{TP + TN + FN + FP} \times 100 \quad (3.1)$$

Burada;

TP-True Positive: Doğru sınıflandırılan hastalıklı sinyal

TN-True Negatif: Doğru sınıflandırılan sağlıklı sinyal


FP-False Positive: Hatalı sınıflandırılan sağlıklı sinyal

FN-False Negative: Hatalı sınıflandırılan hastalıklı sinyaldir.


## 4. BULGULAR

### 4.1- Ayrık Dalgacık Dönüşümüne İlişkin Bulgular

Bu çalışmada sinyalin ADD ile 5.dereceden ayrışımında ana dalgacık için 5 ayrı dalgacık ailesi denenmiş olup her bir ayrışım sonuçları YSA'ya giriş olarak verilmiştir. Şekil 4.1 ve Şekil 4.2'de sağlıklı bireye ait 19 kanallı sinyalin Sym4 Dalgacığı kullanılarak 5. seviyeden oluşturulan alt frekans bandları verilmiştir.




**Şekil 4.1.** Sağlıklı bir bireye ait sinyallerin ADD ile 5.seviyeden ayrıştırılmasıyla elde edilen detay alt bandı




**Şekil 4.2.** Sağlıklı bir bireye ait sinyallerin ADD ile 5.seviyeden ayrıştırılmasıyla elde edilen yaklaşım alt bandı

Şekil 4.3 ve Şekil 4.4'de hasta bireye ait 19 kanallı sinyalin Sym4 Dalgacığı kullanılarak 5. seviyeden oluşturulan alt frekans bandları verilmiştir.




**Şekil 4.3.** Hasta bir bireye ait sinyallerin ADD ile 5.seviyeden ayrıştırılmasıyla elde edilen detay alt bandı



**Şekil 4.4.** Hasta bir bireye ait sinyallerin ADD ile 5.seviyeden ayrıştırılmasıyla elde edilen yaklaşım alt bandı


Şekil 4.5'te hasta bir bireye ait 5. Seviyeden ayrıştırılacak bir sinyal verilmiştir. Şekil 4.6'da yüksek ölçekli alçak frekans bileşeni ve Şekil 4.7'de düşük ölçekli yüksek frekans bileşeni verilmiştir.



**Şekil 4.5.** Ayrıştırılan sinyal




Aşağıdaki çıktıda ölçeğin geniş olduğu ve buna karşın dalgaların alçak frekanslarda yoğunlaştığı A5 alt bandına ait grafik verilmiştir. Bu yaklaşım bandının hastalık hakkında bilgi verdiği söylenebilir.



**Şekil 4.6.** Alçak frekans bileşeni


Aşağıdaki çıktıda ölçeğin küçük olduğu ve buna karşın dalgaların yüksek frekanslarda yoğunlaştığı D5 alt bandına ait grafik verilmiştir. Bu detay bandının, sinyal hakkında önemli bilgiler içermediği düşünülen ayrıntı bilgileri verici nitelikte olduğu söylenebilir.



**Şekil 4.7.** Yüksek frekans bileşeni

## 4.2- Yapay Sinir Ağları Sınıflandırmasına İlişkin Bulgular

Bu çalışmada dalgacık ailelerinin sınıflandırma üzerindeki etkisini görebilmek için 7 ayrı dalgacık kullanılmış, Ayrık Dalgacık Dönüşümü ile edilen bu özellik vektörleri Feedforward Back Propagation (FFNN) ağına verilmiştir. Çalışmada toplam 16 birey olup her bir bireye ait toplam 19 adet özellik vektörü olduğundan YSA 190 girişli bir yapıya sahiptir. Ağ çıkışı 1 olarak tasarlanmış olup çıkışın 0 olması sağlıklı, 1 olması ise hasta olduğu anlamına gelmektedir. YSA eğitiminde öğrenme kuralı olarak traingdx algoritması (gradient descent geri yayılım algoritması) kullanılmıştır. Ağın sınıflama performansı doğru sınıflanan birim sayısının toplam birim sayısına oranı olan toplam sınıflama doğruluğu ile belirlenmiştir. Oluşturulan YSA'ya ait ağ parametreleri Tablo 4.1'de ve oluşturulan ağ mimarisi Şekil 4.8'de verilmiştir.



Şekil 4.8. Oluşturulan ağ mimarisi

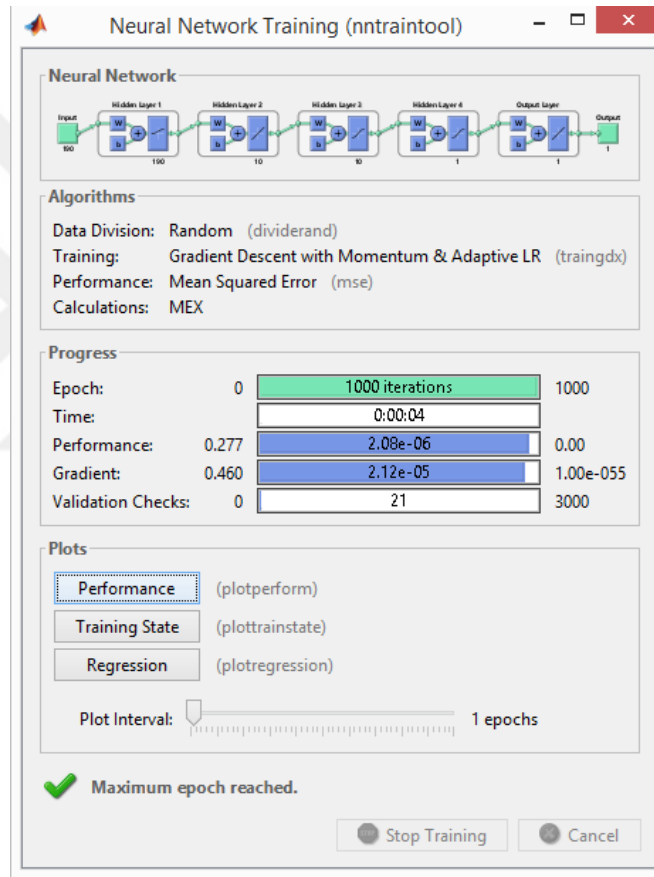
Tablo 4.1 FFNN ağ parametreleri

Eğitim verisi	5 hasta, 11 sağlıklı
Özellik vektör sayısı	190
Aktivasyon fonksiyonu	Logsig, purelin
Öğrenme oranı (lr)	0.8
Momentum katsayısı (mc)	0.5
Öğrenme algoritması	Traingdx
Ağ çıkışı	0: sağlıklı, 1:hasta

Burada özellik vektör sayısı olan 190 ağa verilen giriş sayısıdır. Ağın çıkışı 0: sağlıklı 1: hasta olacak şekilde ayarlanmıştır. Girdi ve çıktı katmanları arasındaki eğrisel eşleşmeyi sağlayan aktivasyon fonksiyonu için Logaritmik Sigmoid ve lineer fonksiyonlar kullanılmıştır. Kurulan Yapay


Sinir Ağında, bağlantılardaki ağırlık değişimini kontrol eden öğrenme katsayısı(n) için 0,8 değeri seçilmiştir ( $0 < n < 1$ ). Ağın öğrenmesi esnasında yerel bir optimum noktaya takılıp kalmaması için ağırlık değişim değerinin belli bir oranda bir sonraki değişime eklenmesini sağlayan momentum katsayısı (mc) ise 0,5 seçilmiştir. Tüm bu parametreler denenerek optimal sonuca ulaşılan parametreler yukarıdaki tabloda verilmiştir.

Sym4 Dalgacıyla dönüştürülen sinyale ait özelliklerin YSA'da işlenmesi ile elde edilen çıktı Şekil 4.9'da verilmiştir.



Şekil 4.9. Özelliklerin YSA'da işlenmesi

Şekil 4.10'da ağın performans eğrileri verilmiştir. Sym4 özellikleriyle oluşturulan YSA 979. denemede en iyi performansa ulaşmıştır.



**Şekil 4.10.** Ağın performans eğrileri

Diğer 4 farklı dalgacık için de aynı işlemler yapılmış olup oluşturulan YSA'nın performansları Tablo 4.4'te verilmiştir. Buna göre Db4, Sym2, Sym4, Bior1.1 dalgacıklarının sınıflandırma performansları eşit olup en yüksek sınıflandırma başarısına sahip olmuşlardır. Yine Daubechies ailesinin dalgacığı olan Db2'de iyi bir sınıflandırma performansı göstermiştir. Coif1 ve en ilkel dalgacık olan Haar dalgacığı ise en düşük sınıflama performansı gösteren dalgacıklar olmuştur.

**Tablo 4.2** Farklı dalgacıklar kullanılarak ADD ile 5.seviyeden ayrıştırılan sinyalin YSA performansları

Dalgacık	Doğruluk(%)
Haar	68.75
Db2	87.5
Db4	93.75
Sym2	93.75
Sym4	93.75
Bior1.1	93.75
Coif1	68.75

## 5. TARTIŞMA VE SONUÇ

Bu tez çalışmasında 5 lösemili ve 11 sağlıklı bireyin EEG kayıtları kullanılıp, birimlere ilişkin hasta ve sağlıklı EEG sinyallerinin ayrıştırılıp sınıflandırılması amaçlanmıştır. EEG gibi durağan olmayan sinyallerin analizinde Dalgacık Dönüşümünün başarısından dolayı bu çalışmada Ayrık Dalgacık Dönüşümü kullanılmıştır. Dalgacık Dönüşümünde dalgacık ailelerinin sınıflandırmaya etkisini karşılaştırmak amacıyla ADD'de dalgacığın ayrışımında Haar, Daubechies, Symlets, Coiflets, Biorthogonal Dalgacıkları kullanılmıştır. EEG sinyali hakkında önemli bilgiler içeren dalgacık katsayılarına ait özellik vektörleri İleri Beslemeli Sinir Ağı ile sınıflandırılmıştır. YSA'nın sınıflandırma başarısı için doğruluk ölçütü kullanılmıştır. Sonuçta, hasta ve sağlıklı bireylere ait EEG sinyallerinin ADD ile 5. seviyeden ayrışımı için en düşük sınıflama başarısı %68.75 ile Haar ve Coif1 Dalgacıklarına ait olup diğer dalgacıkların sınıflandırma başarılarının ise %87.5 ve %93.75 olduğu saptanmıştır.

Sharanreddy ve Kulkarni (2013) çalışmalarında Epilepsi atakları ve beyin tümörü varlığında oluşan EEG sinyallerinin analizi ve sınıflandırılması amaçlanmıştır. Bunun için Çoklu Dalgacık Analizi ve Yapay Sinir Ağlarıyla Sınıflandırma birlikte yapılmıştır. Birlikte kullanılması önerilen bu iki yöntemin sonuçları değerlendirildiğinde sınıflamanın doğruluk başarısı normal hastalar için %98, epilepsi hastaları için %93 ve beyin tümörlü hastalar içinse %87 dir. Aynı zamanda Çoklu Dalgacık Dönüşümünün EEG sinyalleri için özellik çıkarım bakımından en iyi metot olduğu söylenmiştir.

Kalaivani ve arkadaşları (2014) çalışmasında beyin anormalliklerini belirlemek için otomatik bir sistem oluşturulmak istenmiştir. EEG sinyallerini normal ve anormal olarak sınıflandırmak için EEG sinyalleri Ayrık Dalgacık ile dönüştürülmüş ve elde edilen katsayılar k-means kümeleme yöntemi ile sınıflandırılmıştır. En yüksek doğruluğu %74 doğruluk ile alfa band grubu başarmıştır.

Coşkun ve Çömlekçi (2007) çalışmalarında EKG sinyal kaydı alınırken ortamda bulunan cep telefonlarından kaynaklanan artefaktların kaldırılması amacıyla Dalgacık Dönüşümü kullanılmıştır. Dalgacık Dönüşümlerinde Haar, Coiflet, Symlet, Daubechies, Biorthogonal Dalgacık

aileleri kullanılarak EEG sinyalleri ayrıştırılıp oluşan katsayılarla tekrardan sinyal oluşturulmuştur. Sinyalin tekrar oluşturulmasındaki amaç yeni sinyalle orijinal sinyal arasındaki istatistiksel çıkarımlar yapılarak hatanın bulunmasıdır. Burada en düşük hata Bior 2.6 fonksiyonudur.

Palabaş (2014) EEG kayıtlarına ADD yöntemi uygulamış, burada sinyalin analizi için Daubachies 4 filtresi kullanmış ve sonuçta 4. Seviye katsayıları elde edilmiştir. Bu katsayılara ait özellik vektörleri belirlenmiş ve k en yakın komşuluk (kNN) yöntemi ile sınıflandırma yapılmıştır. EEG sinyalleri kNN sınıflandırma algoritması ile %83 doğrulukla sınıflandırılmıştır.

Türk ve Özerdem (2014) çalışmalarında sağlıklı ve epileptik özellikler gösteren farelerin EEG kayıtlarını sınıflandırmaya çalışmıştır. Bu kayıtlara ADD ile 5.seviyeden ayrıştırıp 8 özellik elde edip kNN yöntemi ile sınıflandırmıştır. Her üç dalgacık için de sınıflandırma performansının en az %81.25 olduğu saptanmıştır.

Literatürde EEG sinyallerinin DD ile dönüştürülüp YSA ile sınıflandırıldığı çok fazla çalışma olup bu çalışma da benzer niteliktedir. Ancak yapılan literatür taraması sonucu Lösemili ve sağlıklı bireylerin EEG sinyallerinin Dalgacık Dönüşüm yöntemi ile karşılaştırıldığı bir çalışmaya rastlanmamıştır. Bu çalışmanın diğer bir önemi, tedavisi tamamlanmış olan bireylerin hasta ve kontrol grupları arasında EEG sinyallerini karşılaştırarak, hastalık durumlarının elektriksel deşarjlarını nasıl etkilediği istatistiksel olarak değerlendirmeyi hedef almış olmasıdır.

Lösemi üzerinde yapılacak yeni çalışmalar ışığında EEG patolojisinde önem teşkil eden EEG kanalları belirlenip bu EEG kanalları YSA'ya verildiği takdirde YSA'nın performansı artırılıp işlem süresi azaltılabilir. Sonraki çalışmalarda örneklem sayısının artırılması, YSA'nın sınıflama başarısını arttırabilir. Aynı zamanda YSA'ya ek olarak farklı sınıflandırıcılar da denenip bu sınıflandırıcıların performansı karşılaştırılabilir.

Tedavisi tamamlanmış olan bireylerin hasta ve kontrol grupları arasında EEG dalgalarını karşılaştırarak, hastalık durumlarının elektriksel deşarjlarını nasıl etkilediđi istatistiksel olarak deđerlendirmeyi hedef edinmiş olan bu çalışmada YSA'nın sınıflama başarısı incelendiđinde hasta ve sađlıklı kişilerin EEG sinyalleri arasında fark bulunmuştur. Bu durumda hasta grubu katılımcılarının EEG'lerinin klinik deđerlendirmede daha önemli seviyelere çekmesi beklenmektedir.



## KAYNAKLAR DİZİNİ

- Adeli, H., Zhou, Z., & Dadmehr, N. (2003). Analysis of EEG records in an epileptic patient using wavelet transform. *Journal of Neuroscience Methods*, 123(1), 69-87.
- Akin, M. (2002). Comparison of wavelet transform and FFT methods in the analysis of EEG signals. *Journal of medical systems*, 26(3), 241-247.
- Alp, H., Akıncı, T. Ç., & Albora, M. (2008). Jeofizik Uygulamalarda Fourier ve Dalgacık Dönüşümlerinin Karşılaştırılması. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 14(1), 67-76.
- Altın, C., & Er, O. (2016). Comparison of different time and frequency domain feature extraction methods on elbow gesture's EMG. *European Journal of Interdisciplinary Studies*, 5(1), 35-44.
- Amin, H. U., Malik, A. S., Ahmad, R. F., Badruddin, N., Kamel, N., Hussain, M., & Chooi, W.-T. (2015). Feature extraction and classification for EEG signals using wavelet transform and machine learning techniques. *Australasian Physical & Engineering Sciences in Medicine*, 38(1), 139-149.
- Cohen, A., & Kovacevic, J. (1996). öznits: The mathematical background. *Proceedings of the IEEE*, 84(4), 514-522.
- Collura, T. F. (1993). History and evolution of electroencephalographic instruments and techniques. *Journal of clinical neurophysiology*, 10(4), 476-504.
- Coşkun, M., & İstanbullu, A. (2012). EEG İşaretlerinin FFT ve dalgacık dönüşümü ile analizi. *Akademik Bilişim'12-XIV. Akademik Bilişim Konferansı*, 323-328.
- Coşkun, Ö., & Çömlekçi, S. (2007). Wavelet teorisinin medikal alana uygulanması üzerine bir ön çalışma. *Akademik Bilişim'07-IX. Akademik Bilişim Konferansı*, 31, 317-320.
- Dandıl, E., & Çevik, K. K. (2011). Yapay sinir ağları için. net platformunda görsel bir eğitim yazılımının geliştirilmesi. *Bilişim Teknolojileri Dergisi*, 5(1), 19-28.
- Demirhan, A., Kılıç, Y. A., & İnan, G. (2010). Tıpta yapay zeka uygulamaları. *Yoğun Bakım Dergisi*, 9(1), 31-41.



## KAYNAKLAR DİZİNİ (Devam Ediyor)

- Dogra, A. (2017). Performance comparison of different wavelet families based on bone vessel fusion. Asian Journal of Pharmaceutics (AJP): Free full text articles from Asian J Pharm, 10(04).
- Dođru, F. (2015). Gravite Yönteminde Dalgacık (Wavelet) Dönüşümü Uygulamaları. Dokuz Eylül Üniversitesi, İzmir.
- Elmas, Ç. (2007). Yapay Zeka Uygulamaları, 1. Baskı, Ankara, Seçkin Yayıncılık.
- Erdođmuş, P., & Pekçakar, A. (2009). Dalgacık dönüşümü ile ekg sinyallerinin özellik çıkarımı ve yapay sinir ağları ile sınıflandırılması. Uluslararası İleri Teknolojiler Sempozyumu, 13-15.
- Ersöz, A., & Özşen, S. (2011). Uyku EEG Sinyalinin Yapay Sinir Ağ Modeli İle Sınıflandırılması. Elektrik-Elektronik ve Bilgisayar Sempozyumu.
- Gençay, R., Selçuk, F., & Whitcher, B. J. (2001). An introduction to wavelets and other filtering methods in finance and economics: Academic press.
- Gonzalez, R. C., & Woods, R. E. (2007). Image processing. Digital image processing, 2.
- Graupe, D. (2013). Principles of artificial neural networks (Vol. 7): World Scientific.
- Güler, İ., Gökçil, Z., & Gülbandır, E. (2009). Evaluating of traumatic brain injuries using artificial neural networks. Expert Systems with Applications, 36(7), 10424-10427.
- Güler, İ., & Übeyli, E. (2004). Dalgacık Dönüşümünün Kullanımı ile Teşhis Sistemleri için Öznitelik Çıkarma: İç Karotid Atardamar Doppler İşaretlerinin Durum Analizi. Paper presented at the Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu.
- Gürsoy, U. T. Ş. (2009). Veri madenciliđi ve bilgi keşfi: Pegem Akademi.
- Hazarika, N., Chen, J. Z., Tsoi, A. C., & Sergejew, A. (1997). Classification of EEG signals using the wavelet transform. Signal processing, 59(1), 61-72.
- Haşilođlu, A. (2001). Dalgacık dönüşümü ve yapay sinir ağları ile döndürmeye duyarsız doku analizi ve sınıflandırma. Turkish Journal Of Engineering and Environmental Sciences, 25, 405-413.

## **KAYNAKLAR DİZİNİ (Devam Ediyor)**

- John, S. J. (2016). Handbook of Research on Generalized and Hybrid Set Structures and Applications for Soft Computing: IGI Global.
- Kalaivani, M., Kalaivani, V., & Devi, V. A. (2014). Analysis of EEG Signal for the Detection of Brain Abnormalities. at International Journal of Computer Applications.
- Kantardzic, M. (2011). Data mining: concepts, models, methods, and algorithms: John Wiley & Sons.
- Lee, D. T., & Yamamoto, A. (1994). Wavelet analysis: theory and applications. Hewlett Packard journal, 45, 44-44.
- Malmivuo, J. ve Plonsey, R. 1995. Bioelectromagnetism: principles and applications of bioelectric and biomagnetic fields. Oxford University Press, USA.
- Merry, R., & Steinbuch, M. (2005). Wavelet theory and applications. literature study, Eindhoven university of technology, Department of mechanical engineering, Control systems technology group.
- Miner, N. E. (1998). An introduction to wavelet theory and analysis (No. SAND98-2265). Sandia National Laboratories, Albuquerque, NM, and Livermore, CA.
- Misiti, M., Misiti, Y., Oppenheim, G., & Poggi, J.-M. (1996). Wavelet toolbox. The MathWorks Inc., Natick, MA, 15, 21.
- Murugesan, M., & Sukanesh, R. (2009). Automated detection of brain tumor in EEG signals using artificial neural networks. Paper presented at the Advances in Computing, Control, & Telecommunication Technologies, 2009. ACT'09. International Conference on.
- Najumnissa, D. (2010). Characterisation of epileptic seizure EEG signals using wavelet transform principal component analysis and optimization methods. (pHD), Anna University.
- Nisbet, R., Miner, G., & Elder IV, J. (2009). Handbook of statistical analysis and data mining applications: Academic Press.
- Nizam, A. (2008). Karınca Koloni Optimizasyonuna Dayalı Yeni Bir Aritmi Sınıflama Tekniği, Doktora tezi, İstanbul Teknik Üniversitesi.
- Ogden, T. (2012). Essential wavelets for statistical applications and data analysis: Springer Science & Business Media.

## KAYNAKLAR DİZİNİ (Devam Ediyor)

- Omerhodzic, I., Avdakovic, S., Nuhanovic, A., & Dizdarevic, K. (2013). Energy distribution of EEG signals: EEG signal wavelet-neural network classifier. arXiv preprint arXiv:1307.7897
- Öksüz, E., Altun, A., Ülgerli, B., Yücel, G., & Özen, A. (2016) FFT Tabanlı OFDM ile DWT Tabanlı OFDM Sistemlerinin Karşılaştırmalı Başarım Analizi.
- Palabaş, T. (2014). Ayrık Dalgacık Dönüşümü Bileşenlerine Ait İstatistiksel Veriler ile Epileptik EEG İşaretlerinin Sınıflandırılması. AJIT-e: Online Academic Journal of Information Technology, 5(15).
- Partal, T., Kahya, E., & Cığızoğlu, K. (2011). Yağış verilerinin yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini. İTÜDERGİSİ/d, 7(3).
- Popular Science: Neural Networks. How does it work? (2016). ( <https://steemit.com/popularscience/@puhoshville/popularscience-neural-networks-how-does-it-work-and-my-appeal-to-steemians>, 25.03.2018'de erişildi).
- Ridha, Z. (2011). Wavelet Analysis and Implementation in FPGA. California State University, Northridge.
- Ripley, B. D. (2007). Pattern recognition and neural networks: Cambridge university press.
- Sezer, E. (2008). Epilepsi teşhisi için EEG sinyal analizi. Selçuk Üniversitesi Fen Bilimleri Enstitüsü.
- Shaker, M. M. (2006). EEG waves classifier using wavelet transform and Fourier transform. brain, 2, 3.
- Sharanreddy, M., & Kulkarni, P. (2013). Automated EEG signal analysis for identification of epilepsy seizures and brain tumour. Journal of Medical Engineering & Technology, 37(8), 511-519.
- Singh, C. B., Choudhary, R., Jayas, D. S., & Paliwal, J. (2010). Wavelet analysis of signals in agriculture and food quality inspection. Food and Bioprocess Technology, 3(1), 2.
- Smertneck, J. E. (2000). Wavelet analysis of acoustic signals. (Masters Thesis). Rochester Institute of Technology. Retrieved from <http://scholarworks.rit.edu/theses/8471>

## KAYNAKLAR DİZİNİ (Devam Ediyor)

- Subasi, A. (2005). Epileptic seizure detection using dynamic wavelet network. *Expert Systems with Applications*, 29(2), 343-355.
- Subha, D. P., Joseph, P. K., Acharya, R., & Lim, C. M. (2010). EEG signal analysis: a survey. *Journal of medical systems*, 34(2), 195-212.
- Sun, P. (2015). Comparison of STFT and Wavelet Transform in Time-frequency Analysis.
- Şen, Z. (2004). Yapay sinir ağları ilkeleri. İstanbul: Su Vakfı Yayınları.
- Übeyli, E. D. (2009). Combined neural network model employing wavelet coefficients for EEG signals classification. *Digital Signal Processing*, 19(2), 297-308.
- Tekin, R., Kaya, Y., & Tağluk, M. E. (2011). K-means ve YSA temelli Hibrit Bir Model ile Epileptik EEG İşaretlerinin Sınıflandırılması. *Elektrik Elektronik Bilgisayar Semp. Elazığ*.
- Türk, Ö., & Özerdem, M. S. (2014). EEG İşaretlerinin k-NN ile Sınıflandırılmasında Dalgacıklara İlişkin Performanslarının Karşılaştırılması. Paper presented at the Tıp Teknolojileri Ulusal Kongresi.
- Vaseghi, S. V. (2008). *Advanced digital signal processing and noise reduction*: John Wiley & Sons.
- Weeks, M. (2007). *Digital Signal Processing Using MATLAB and Wavelets*. In: Infinity.
- Welstead, S. T. (1994). *Neural Network and Fuzzy Logic Applications in C-C++*: John Wiley & Sons, Inc.
- Yılmaz, Z., & Bozkurt, M. R. (2013). Ayrık Dalgacık Dönüşümü Kullanarak Aritmilere Ait Özniteliklerin Çıkarılması. *Akademik Bilişim*, 23-25.
- Zhao, H., Guo, X., Wang, M., Li, T., Pang, C., & Georgakopoulos, D. (2015). Analyze EEG signals with extreme learning machine based on PMIS feature selection. *International Journal of Machine Learning and Cybernetics*, 1-7.

# ÖZGEÇMİŞ

## Bireysel Bilgiler

Adı-Soyadı : Eylem GÜL  
Doğum tarihi ve yeri : 05/03/1992, ADANA  
Uyruğu : TC  
Medeni durumu : Bekar  
İletişim adresleri : eylmgul@gmail.com

## Eğitim Durumu

Lise : Dr. M. Feyyaz Etiz Lisesi (2006-2010)  
Lisans : Çukurova Üniversitesi Fen-Edebiyat Fakültesi,  
İstatistik Bölümü (2010-2015, İngilizce Hazırlık)  
Yüksek Lisans : Eskişehir Osmangazi Üniversitesi Sağlık Bilimleri  
Enstitüsü Biyoistatistik A.B.D (2015-2018)

## Yayınlar

:

- **Gül E.**, Mutlu F., "İstatistiklerle Kadın ve İş Hayatı", 1. Uluslararası Kadın Araştırmaları Sempozyumu, ESKİŞEHİR, TÜRKİYE, 13-14 Ekim 2017, cilt.1 no.1, ss.261-262
- Ünal D., Yeldan H., **Gül E.**, Ergüç D., Adıyan M., "Gompertz, logistic and brody functions to model the growth of fish species *Siganus rivulatus*", ACTA BIOLOGICA TURCICA, vol.30, pp.140-145, 2017
- Ünal D., Yeldan H., Şimşek M. , Korkmaz F. , **Gül E.** , Ergüç D., et al., "Gompertz,Richards, Von Bertalanfy ve Lojistik Modellerin Parametre Tahmininine Etkileri", 18. Ulusal Su Ürünleri Sempozyumu, İZMİR, TÜRKİYE, 1-4 Eylül 2015, cilt.1, no.1, ss.405-405
- **Gül E.**, Ergüç D., "Çatalan Baraj Gölü Doluluk Oranları ve Yağış Oranları Arasındaki İlişkinin İncelenmesi" , 11. Uluslararası İstatistik Öğrenci Kolokiyumu, İSTANBUL, TÜRKİYE, 17-18-19 Mayıs 2014

# ETİK KURUL İZİN BELGESİ



## ESKİŞEHİR OSMANGAZİ ÜNİVERSİTESİ GİRİŞİMSSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU BAŞKANLIĞI

Prof. Dr. Ömür ŞAYLIGİL  
(Başkan)  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
Tıp Tarihi ve Etik Anabilim Dalı

Sayı: 80558721/G - 103  
Konu: Karar – Yüksek Lisans Öğr.Eylem GÜL

30 Mart 2017

Doç. Dr. Uğur BİLGE  
(Başkan Yardımcısı)  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
Aile Hekimliği Anabilim Dalı

Doç. Dr. Özlem ÖRSAL  
(Raportör)  
Eskişehir Osmangazi Üniversitesi  
Eskişehir Sağlık Bilimleri Fakültesi  
Halk Sağlığı Hemşireliği Anabilim Dalı

Sayın; Prof.Dr.Fezan MUTLU  
Eskişehir Osmangazi Üniversitesi Tıp Fakültesi  
Biyoistatistik Anabilim Dalı

Prof. Dr. Setenay DİNÇER  
ÖNER  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
Biyoistatistik Anabilim Dalı

Prof. Dr. Hilmi ÖZDEN  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
Anatomi Anabilim Dalı

Sorumlu Araştırmacısı olduğunuz *“Wavelet Dönüşümü ile EEG Sinyallerinin Dönüştürülmesi ve Yapay Sinir Ağları İle Sınıflandırılması: Klinikte Bir Uygulama”* başlıklı çalışma hakkında alınan karar ilişikte gönderilmiştir. Bilgilerinizi ve gereğini saygı ile rica ederim.

Prof. Dr. Varol ŞAHİNTÜRK  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
Histoloji ve Embriyoloji Anabilim Dalı

Prof. Dr. Aydın YENİLMEZ  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
Üroloji Anabilim Dalı

Doç. Dr. Altan EŞSİZÖĞLU  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
Ruh Sağlığı ve Hastalıkları Anabilim Dalı


Doç.Dr.Ömer KILIÇ  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
Çocuk Sağlığı ve Hastalıkları Anabilim Dalı / Çocuk Enfeksiyon Hast. Bilim Dalı

Doç. Dr. Batu Can YAMAN  
Eskişehir Osmangazi Üniversitesi  
Diş Hekimliği Fakültesi  
Restoratif Diş Tedavisi Anabilim Dalı

Prof. Dr. Bekir YAŞAR  
Genel Cerrahi Uzmanı

Av. Önder CAN  
Avukat

Etik Kurul Sekreterliği  
Aysun SERTTAŞ  
Makbule SARIÇİÇEK  
Tel: 0 222 239 29 79 / 4690

  
Doç. Dr. Uğur BİLGE  
Etik Kurul Başkan Yardımcısı  
Eskişehir Osmangazi Üniversitesi  
Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu