

T.C.
Selçuk Üniversitesi
Fen Bilimleri Enstitüsü

EEG SİNYALLERİNDE UYKU İÇCİKLERİNİN ZAMAN VE FREKANS
DOMENİ ÖZELLİKLERİ KULLANILARAK ANALİZİ

Mehmet DURSUN

YÜKSEK LİSANS TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

KONYA, 2009

T.C.
Selçuk Üniversitesi
Fen Bilimleri Enstitüsü

EEG SİNYALLERİNDE UYKU İGÇİKLERİNİN ZAMAN VE FREKANS
DOMENİ ÖZELLİKLERİ KULLANILARAK ANALİZİ

Mehmet DURSUN

YÜKSEK LİSANS TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

KONYA, 2009

Bu tez ... / ... / 2009 tarihinde aşağıdaki jüri
tarafından oybirliği / oyçokluğu ile kabul edilmistir.

Yrd.Doç.Dr. Mehmet ÇUNKAŞ
Başkan

Doç.Dr. Salih GÜNEŞ
Üye

Yrd.Doç.Dr. Nihat YILMAZ
Üye

ÖZET

Yüksek Lisans Tezi

EEG SİNYALLERİNDE UYKU İĞCİKLERİNİN ZAMAN VE FREKANS DOMENİ ÖZELLİKLERİ KULLANILARAK ANALİZİ

Mehmet DURSUN

Selçuk Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Salih GÜNEŞ

2009, 86 sayfa

Jüri: Doç. Dr. Salih GÜNEŞ

Yrd. Doç. Dr. Mehmet ÇUNKAŞ

Yrd. Doç. Dr. Nihat YILMAZ

Bu tez çalışmasında, Elektroansefalogram (EEG) kayıtlarının otomatik olarak değerlendirilip, uyku evreleri içinde N-REM (Hızlı Göz Hareketleri Olmayan) Evre 2' nin bulunmasında önemli bir bileşen olan uyku içciklerinin bulunması amaçlanmıştır.

Bu çalışmada, önerilen metot iki adım içermektedir. İlk adımda ham EEG sinyallerinden zaman domeninde altı ve frekans domeninde dört özellik çıkarılmıştır. Ham EEG sinyallerinden Frekans domeni özelliklerinin çıkarılmasında Welch Spectral Analiz yöntemi kullanılmıştır. İkinci adımda ise yapay sinir ağları ile Levenberg-Marquardt algoritması kullanılarak daha önceden uyku uzmanı tarafından elle değerlendirilen uyku içcikleri sınıflandırılmıştır. Uyku içciklerinin sınıflandırılmasında LM-YSA kullanılarak elde edilen sınıflama doğruluğu zaman domeni özellikleri için % 100' dür (Gizli katmandaki düğüm sayısı on için).

Çalışmada kullanılan uyku EEG sinyalleri Selçuk Üniversitesi Meram Tıp Fakültesi Uyku Laboratuvarında yapılan uyku skorlandırma çalışmaları dâhilinde, Yrd. Doç. Dr. Şebnem Yosunkaya ve ekibi tarafından kaydedilmiştir. Çalışma 3 hastada, toplam 712 epok üzerinde test edilmiştir.

Son olarak; elde edilen sonuçlar, önerilen tanıma sisteminin uyku içciklerinin otomatik olarak bulunmasında güvenle kullanılabileceğini göstermiştir. Aynı zamanda bu sistem N-REM evre 2' nin belirlenmesinde çok önemli bir parametredir.

Anahtar Kelimeler – Uyku içciği, Özellik Çıkarımı, İstatiksel Ölçümler, Welch Yöntemi, EEG Veri Kümeleri, Yapay Sinir Ağları.

ABSTRACT

Master Thesis

**ANALYSIS OF SLEEP SPINDLES ON EEG SIGNALS BY USING
TIME AND FREQUENCY DOMAIN FEATURES**

Mehmet DURSUN

Selcuk University

Graduate School of Natural and Applied Sciences

Department of Electrical-Electronics Engineering

Supervisor: Assoc. Prof. Dr. Salih GÜNEŞ

2009, 86 pages

Jury: Assoc. Prof. Dr. Salih GÜNEŞ

Asst. Prof. Dr. Mehmet ÇUNKAŞ

Asst. Prof. Dr. Nihat YILMAZ

In this study, it was aimed that detection of Sleep-Spindles which is the one of important components determining N-REM (Non-Rapid Eye Movement) Stage 2 in the sleep stages, by automatically evaluation of Electroencephalogram (EEG) records.

In this study, the proposed method consists of two steps. In the first step, six time domain features and four frequency domain features have been extracted from raw EEG signals. The extraction of frequency domain features from raw EEG signals, Welch spectral analysis has been used. In the second step, artificial neural network (ANN) with LM (Levenberg-Marquardt) has been used to classify the sleep spindles evaluated before hand by sleep expert physicians. The obtained classification accuracies for time domain features set in the classification of sleep spindles are 100% by using LM-ANN (for ten node in hidden layer).

The sleep EEG signals used in this study are recorded with in support of sleep scoring studies carried out in Selcuk University Meram Faculty of Medicine Department Sleep Laboratory by Asst. Prof. Dr. Şebnem YOSUNKAYA and her team. The study is tested on 3 patients with 712 epochs.

Finally, the obtained results have presented that the proposed recognition system could be confidently used in the automatic classification of sleep spindles. And also, this system is a very important parameter in the determination of N-REM Stage 2.

Keywords – Slip spindles, Feature extraction, Statistical Measurements, Welch Method, EEG Data Set, Artificial Neural Networks.

TEŞEKKÜR

Bu tez çalışmam süresince her konuda, anlayış ve desteğini esirgemeyen, çalışmalarımnda değerli bilgi ve tecrübeleriyle bana yol gösteren danışmanım Sayın Doç. Dr. Salih GÜNEŞ' e, Bölüm Başkanımız Sayın Prof. Dr. Saadetdin HERDEM' e, tez süresince belirttiği görüşler ve önerilerle tezin şekil almasında bana yardımcı olan Sayın Arş.Gör. Dr. Kemal POLAT' a ayrıca Selçuk Üniversitesi Meram Tıp Fakültesi Göğüs Hastalıkları Anabilim Dalı Öğretim Üyesi Sayın Yrd. Doç. Dr. Şebnem YOSUNKAYA ve Sayın Uzman Uyku Teknisyeni Serkan KÜÇÜKTÜRK' e ilgi ve yardımlarından dolayı teşekkürü bir borç bilirim.

Sevgi ve özverileriyle bugünlere gelmemi sağlayan, hoşgörülerini ile her zaman yanımda olan sevgili anneme, babama ve kardeşlerime teşekkürlerimi sunarım.

Mehmet DURSUN
2009, Konya

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
SİMGELER VE KISALTMALAR	viii
ŞEKİLLER LİSTESİ.....	x
TABLolar LİSTESİ.....	xii
1. GİRİŞ	1
2. LİTERATÜR ARAŞTIRMASI	4
3. EEG (ELEKTROENSEFALOGRAF).....	6
3.1. EEG' nin Tarihsel Gelişimi	6
3.2. EEG Nedir ?	7
3.3. EEG Cihazının Temel Çalışma Şekli ve Uygulanması	7
3.4. EEG Değerlendirilmesi	9
3.5. EEG İşaretlerinin Elektriksel Özellikleri	10
3.6. EEG Dalga Şekilleri.....	11
4. UYKU VE UYKU EVRELERİ.....	14
4.1. Uyku	14
4.2. Uyku Evreleri ve Uyku Evreleme	15
4.2.1. Uyku evreleri.....	16
4.2.1.1. Evre W (Uyanıklık evresi)	16
4.2.1.2. NREM Evre I	17
4.2.1.3. NREM Evre II	18
4.2.1.4. NREM Evre III	21
4.2.1.5. REM Evresi.....	22
4.2.2. Yaşa göre uyku evrelerinin dağılımı	24
4.2.3. Örnek bir uyku modeli	24
4.3. Polisomnografi	26
4.4. Uyku Laboratuvarı	27
4.5. Hastanın Hazırlanması	27
4.6. Hastanın İzlenmesi	28
4.6.1. Nörofizyolojik izlem	28
4.6.1.1. EEG kanalları	29
4.6.1.2. EOG kanalları.....	31
4.7. Veri Toplanması.....	32

5. MATERYAL ve METOD.....	34
5.1. Üzerinde Çalışılan Veriye Ait Özellikler.....	34
5.1.1. Spindle bulunan epok.....	34
5.1.2. Spindle bulunmayan epok.....	35
5.2. Önerilen Sistemin Akış Diyagramı.....	36
5.2.1. EEG de C3-A2 kanalındaki sinyalin alınması	37
5.2.2. Filtreleme	40
5.2.2.1. Filtreleme alt programı.....	41
5.2.3. Segmantasyon	41
5.2.3.1. Segmantasyon alt programı.....	41
5.3. Özellik Çıkarımı.....	42
5.3.1. Zaman domenii özellik çıkarımı	42
5.3.2. Frekans domenii özellik çıkarımı.....	43
5.3.2.1. Welch metodu yardımı ile güç spektrum yoğunluğunun hesaplanması	44
5.3.2.1.1. Periodogram metodu	45
5.3.2.1.2. Bartlett metodu.....	46
5.3.2.1.3. Welch metodu	47
5.3.2.1.4. Welch yöntemi ile frekans domenii özelliklerini bulan alt program kodları	49
5.3.2.2. Pencereleme metodu	49
5.3.2.2.1. Pencereleme işlemi	51
5.3.3. Özellik azaltımı	52
5.4. Yapay Sinir Ağları Kullanılarak Uyku İlgiklerinin Sınıflandırılması.....	53
5.4.1. Yapay sinir ağları	53
5.4.1.1. Çok katmanlı algılayıcı yapay sinir ağları	54
5.4.1.2. Levenberg – Marquardt algoritması.....	57
5.4.2. Yapay sinir ağlarının eğitilmesi	60
5.5. Tez Çalışmasında Önerilen YSA Modeli.....	61
6. DENEYSEL SONUÇLAR.....	63
6.1. Performans Kriterleri	64
6.1.1. Sınıflama doğruluğu.....	65
6.1.2. Hassasiyet.....	66
6.1.3. Seçicilik.....	66
6.2. Elde Edilen Test sonuçları	66
7. SONUÇLAR VE ÖNERİLER	78
7.1. Sonuçlar....	78
7.2. Öneriler....	81
8. KAYNAKLAR	82

SİMGELER VE KISALTMALAR

Adaline	: Adaptive linear neuron
AFD	: Ayrık fourier dönüşümü
ANN	: Yapay sinir ağları (Artificial neural network)
AR	: Özbağımlı (Autoregressive)
ATS	: Duyarlılık eşik ölçüsü (Affinity threshold scalar)
BKÖS	: Bilgi kazancına dayanan özellik seçme algoritması
BT	: Bilgisayarlı tomografi
BVAÖ	: Bulanık veri ağırlıklandırma ön-işleme yöntemi
DR	: Dorsal Rabhe
EEG	: Electroencephalography
EKG	: Elektrokardiyografi
EMG	: Elektromiyogram
FFT	: Hızlı fourier dönüşümü (Fast fourier transform)
LAA	: Lineer ayrışım analizi
LM	: Levenberg marquard
LM-YSA	: Levenberg Marquard – Yapay sinir ağları
LVQ	: Öğrenme vektörü inceleme
MLE	: Maksimum olabilirlik kestirimi
MRG	: Manyetik rezonans görüntüleme
MUSIC	: Çoklu sinyal sınıflandırması
NREM	: Hızlı olmayan göz hareketleri
PSG	: Polisomnografi

REM	: Hızlı göz hareketleri
STFT	: Kısa zamanlı fourier dönüşümü
YBS	: Yapay bağışıklık sistemi
YBTS	: Yapay bağışıklık tanıma sistemi
YSA	: Yapay sinir ağları

ŞEKİLLER LİSTESİ

Şekil 3.1 Alfa dalga şekli.....	11
Şekil 3.2 Beta dalga şekli.....	12
Şekil 3.3 Teta dalga şekli.....	12
Şekil 3.4 Delta dalga şekli.....	13
Şekil 4.1 W Evresine ait PSG sinyal kaydı.....	17
Şekil 4.2 NREM Evre I e ait PSG sinyal kaydı	18
Şekil 4.3 K kompleksi ve uyku içiği bulunan bir PSG kaydı.....	20
Şekil 4.4 NREM Evre II' ye ait PSG sinyal kaydı.....	20
Şekil 4.5 NREM Evre III.....	21
Şekil 4.6 REM Evresi ne ait PSG sinyal kaydı.....	23
Şekil 4.7 Sekiz saatlik örnek bir uyku süreci.....	25
Şekil 4.8 Uluslar arası 10-20 sistemi.....	30
Şekil 4.9 EOG elektrotları bağlantı şekli.....	31
Şekil 4.10 Polisomnografi kayıt öncesi hasta bağlantıları.....	32
Şekil 4.11 Bilgisayar destekli polisomnografi cihazının kayıt arayüzü.....	33
Şekil 5.1 Evre 2 ye ait spindle bulunan epok.....	35
Şekil 5.2 Evre 2 ye ait spindle bulunmayan epok.....	35
Şekil 5.3 Önerilen sistemin akış diyagramı.....	37
Şekil 5.4 Dataların .edf dosya formatına dönüşümü.....	38
Şekil 5.5 Dataların .ascii dosya formatına dönüşümü.....	39
Şekil 5.6 Dataların .dat dosya formatına dönüşümü.....	40
Şekil 5.7 128 pencereye ayrılmış Spindle bulunan EEG sinyalinin Welch yöntemi sonucu güç spektrum yoğunluğu.....	52
Şekil 5.8 Zaman domeni için tasarlanan ve en yüksek sınıflama doğruluğu elde edilen YSA Mimarisi.....	62
Şekil 6.1 Spindle bulunan 1 Epokluk (30 saniyelik) EEG işareti.....	63
Şekil 6.2 Spindle bulunmayan 1 Epokluk (30 saniyelik) EEG işareti.....	64
Şekil 6.3. Zaman domeninde lineer dağılımı gösteren grafik.....	76

Şekil 6.4. Frekans domeninde non-lineer dağılımı gösteren grafik.....	77
Şekil 7.1. Zaman domeninde lineer dağılımı gösteren grafik.....	79
Şekil 7.2 Frekans domeninde non-lineer dağılımı gösteren grafik.....	80

TABLÖLAR LİSTESİ

Tablo 3.1 EEG dalga şekilleri.....	10
Tablo 4.1 Yaşa göre uyku evrelerinin dağılımı.....	24
Tablo 4.2 Standart polisomnografi parametreleri	26
Tablo 4.3 EEG dalga şekilleri.....	29
Tablo 4.4 Çeşitli EEG paternleri.....	29
Tablo 5.1 Hastalara ait istatistiksel değerler.....	34
Tablo 5.2 Zaman domenini özellikleri.....	43
Tablo 5.3 Frekans domenini özellikleri.....	44
Tablo 5.4 Pencere tipleri ve eşitlikleri.....	51
Tablo 6.1 Karmaşıklık matrisi.....	65
Tablo 6.2 Zaman domeninde Hasta 1' e ait karmaşıklık matrisi.....	67
Tablo 6.3 Frekans domeninde Hasta 1' e ait karmaşıklık matrisi.....	67
Tablo 6.4 Zaman - Frekans domeninde Hasta 1' e ait karmaşıklık matrisi.....	68
Tablo 6.5 Yapay sinir ağı kullanılarak zaman ve frekans domenlerinde sleep spindlların sınıflandırılması sonucu elde edilen sonuçlar. (Hasta 1).....	69
Tablo 6.6 Zaman domeninde Hasta 2' e ait karmaşıklık matrisi.....	70
Tablo 6.7 Frekans domeninde Hasta 2' e ait karmaşıklık matrisi.....	70
Tablo 6.8 Zaman - Frekans domeninde Hasta 2' e ait karmaşıklık matrisi.....	71
Tablo 6.9 Yapay sinir ağı kullanılarak zaman ve frekans domenlerinde sleep spindlların sınıflandırılması sonucu elde edilen sonuçlar. (Hasta 2).....	72
Tablo 6.10 Zaman domeninde Hasta 3' e ait karmaşıklık matrisi.....	73
Tablo 6.11 Frekans domeninde Hasta 3' e ait karmaşıklık matrisi.....	73
Tablo 6.12 Zaman - Frekans domeninde Hasta 3' e ait karmaşıklık matrisi.....	74
Tablo 6.13 Yapay sinir ağı kullanılarak zaman ve frekans domenlerinde sleep spindlların sınıflandırılması sonucu elde edilen sonuçlar. (Hasta 3).....	75

1. GİRİŞ

Organizmanın çevreyle iletişiminin, değişik şiddette uyaranlarla geri döndürülebilir bir biçimde geçici, kısmi ve periyodik olarak kaybolması durumu olarak tanımlanan uyku, insanoğlunun her zaman çok ilgilendiği konular içerisinde yer almıştır. Bunun nedeni her birimizin günlük işlevselliğimizi sürdürebilmek için uyku uyumaya ihtiyacımızın olmasıdır. Günlük aktivitelerimizi devam ettirebilmek ve gün içerisinde çalışmalarımızda daha verimli olabilmek için her gün belirli bir süre uyumamız gerekmektedir (Dursun 2008).

Bu uyku süreci çeşitli evreler içermekte ve bu evrelerin karakterize edilmesinde sinir hücrelerinin oluşturduğu elektriksel aktivitelerinin yapısal bileşimi rol oynamaktadır.

Sleep Spindle yani uyku içcikleri, uykunun Non-Rem Evre 2 diye tanımlanan bölümünün karakteristik dalga şeklidir (Dursun 2008).

İçciklerin oluşumu ve işlevi hakkında tam bir fikir birliği olmamakla birlikte kabul gören iki varsayım vardır. Birinci varsayıma göre içcikler, motor çıkışın ve algı geçişlerinin bastırılması yoluyla uyku halinin sürdürülmesini sağlayan salınımlardır. İkinci varsayıma göre ise içcikler, talamo-kortikal alanda önceki deneyimlerin bütünleştirilmesi için gereken işlevlerin bir araya getirilmesine yardımcı olur. Hipersomniyak ve insomniyak denekler üzerinde yapılan çalışmalar içcik yoğunluklarının hastalığın türü ile bağlantılı olarak değiştiğini göstermekte ve içciklerin uyku sürecini düzenleyici işlevinin olduğu bulgusunu kuvvetlendirmektedir (Eroğul vd 1999).

Tıp alanında hastalıkların teşhisinde ve bu alanda yapılan araştırmalarda kullanılan EEG (*Elektroensefalogram*) işaretleri beynin sinirsel aktivitesi sonucu elde edilen biyoelektrik tabanlı işaretlerdir. Bu işaretler beynin fonksiyonları ve çalışması ile ilgili çok miktarda bilgi barındırır. Bu bilgilerin kullanılabilir hale gelmesi için sinyal işleme alanındaki uzmanlar çok çeşitli araştırmalar yapmaktadırlar.

EEG sinyallerinin spektral analizlerine ek olarak, sınıflandırma problemlerindeki başarılı uygulama yöntemlerinden dolayı yapay zekâ

uygulamalarının bir çeşidi olan yapay sinir ağları (YSA) biyomedikal sinyal işleme alanında çalışan uzmanların sıklıkla başvurduğu bir sınıflayıcı olmuştur.

YSA'nın öğrenme yeteneği, araştırmacıları cezbeden en önemli özelliklerinden birisidir. Çünkü YSA herhangi bir olay hakkında, doğrusal olsun ya da olmasın, girdiler ve çıktılar arasındaki ilişkiyi eldeki mevcut örneklerden öğrenir ve daha önce hiç karşılaşmamış olayları, önceki örneklerden çağrışımlar yaparak olaya çözümler üretir. İşte bu özellik YSA'daki zeki davranışın da temelini teşkil eder (Polikar 1999).

1987 yılında yapılan ilk yapay sinir ağları sempozyumundan sonra YSA uygulamaları yaygınlaşmıştır. Günümüzde, YSA ile ilgili araştırmalar yapan çok sayıda bilim adamı ve araştırma grupları vardır (Batar 2005).

Uyku içciklerinin sezimi ve incelenmesi konusunda farklı yöntemler önerilmiştir (Eroğul vd 1999). İçcikleri modellemek için Zygierevicz (2000) uyumlu dalgacık yöntemini kullanmıştır. Eroğul vd (1999) dalgacık dönüşümü ile birlikte Teager enerji işlecini içciklerin yerinin belirlenmesi için kullanmıştır. Görür vd (2002) kısa zamanlı Fourier dönüşümünü öznelik bulmak için, içciklerin yerinin belirlenmesi için de Çok Katmanlı Perseptron ve Destek Vektör Makinesi kullanmışlardır. Duman F. ve arkadaşları (2009), çalışmalarında EEG sinyallerinin analizinden sonra karar ağacı algoritmasıyla uyku içciklerinin tesbit edilmesi, yerlerinin kesin olarak bulunmasını sağlamış ve bunun için üç farklı yol kullanmışlardır. Bunlar STFT (Short Time Fourier Transform), MUSIC (Multiple Signal Classification) Algoritması ve TEO (Teager Energy Operator) dur.

Bu tez çalışmasında ise uyku laboratuvarlarında, uyku dönemlerinin belirlenmesi için çalışan uzmanların uyku içciği olarak adlandırdıkları ve özellikle uykunun NREM Evre 2 olarak nitelendirilen dönemlerinde ortaya çıkan EEG dalga şeklinden zaman domen özellikleri ve Welch metodu kullanılarak frekans domeninde özellik çıkartımı yapılarak YSA ile sınıflandırılması ve sonuçta incelenen sinyalde uyku içciği olup olmadığının bulunması amaçlanmaktadır.

Bu tez çalışmasının birinci bölümünde konuya giriş yapılmış yapılan çalışma hakkında tanımlara yer verilmiştir. İkinci bölümde tez konusuyla ilgili yapılan literatür çalışması bulunmaktadır. Üçüncü bölümde EEG hakkında bilgi verilmekte

dördüncü bölümde ise uyku ve uykunun gece boyunca yaşanan evreleri anlatılmaktadır.

Beşinci bölümde çalışmada kullanılan materyalden bahsedilmiş ve önerilen sistemin gerçekleştirilmesinde nasıl bir metod kullanıldığına yer verilmiştir. Altıncı bölümde çalışmada ortaya çıkan deneysel sonuçlar tartışılmıştır. Buradan elde edilen sonuçlar yedinci bölümde değişik açılardan irdelenmiş ve bu alanda çalışma yapmayı düşünenlere önerilerde bulunulmuştur.

Son olarak sekizinci bölümde çalışmada faydalanılan kaynaklar verilmiştir.

2. LİTERATÜR ARAŞTIRMASI

Sweldens (1994), çalışmasında bir fonksiyonun dalgacık sabitlerini bu fonksiyonun örneklerinden hesaplanması üzerine interpolasyon, quadrature eşitlik ve filtreleme metotlarıyla uygulamalar sunmuştur.

Anderson ve ark. (1995), çalışmalarında EEG işaretleri yardımıyla zihinsel durumun tanımlanması amacıyla yapay sinir ağları kullanmışlardır.

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

Kalaycı ve Özdamar (1995), giriş ve çıkış datasının sinyalin karakteristik özelliklerini gösterebilecek şekilde işlenebilmesi durumunda yapay sinir ağlarının daha iyi sonuç verdiğini gösteren bir çalışma yapmışlardır.

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

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

Jung ve ark. (1998), çalışmasında uyku ve uyanıklık durumlarının yapay sinir ağları ile sınıflandırılmasında, ham EEG işaretlerinden ziyade Fourier Dönüşümü alınmış EEG' nin daha uygun sonuçlar verdiğini gözlemlemişlerdir.

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

Torrence ve ark. (1998), çalışmalarında yaygın olarak kullanılan temel dalgacık fonksiyonları sınıflandırılmış, özellikleri verilerek ayrık zaman diziler için sürekli dalgacık dönüşümü yaklaşıklığı verilmiştir. Sonlu uzunlukta zaman serilerine Pencerelemiş Fourier ve Dalgacık dönüşümü uygulayarak istatistik önem ile güvenilirlik aralığı analizleri yapmışlardır.

Önal ve ark. (1998), EEG sinyallerindeki epileptik sürecin Dalgacık Dönüşümü yöntemi ile belirlenmesini amaçlayarak bir çalışma yapmışlar ve bu çalışmada

parsiyel nöbet geçiren 3 yaşındaki bir çocuktan alınan gerçek EEG işareti kullanarak epileptik süreçte özellikle düşük frekans bandı δ 'nın etkinliğini göstermişlerdir.

Güneş ve ark. (1998), EEG işaretlerine Dalgacık Dönüşümü teknikleri uygulayarak, Sürekli ve Ayırık Dalgacık Dönüşümlerinin üstünlüklerini göstermeyi amaçlayan bir çalışma yapmışlardır.

Güneş (1999), EEG işaretlerinin Dalgacık Analizi ve diğer parametrik yöntemlerle karşılaştırılması konulu bir tez çalışması yapmıştır.

Suleesathira ve ark. (2000), deterministik, durağan olmayan sinyallerin gösteriminin ayırık evrimsel dönüşümle yapılabilirliği konusunda çalışmışlardır.

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

Güler İ. (2001), çalışmasında EEG sinyallerini AR (autoregressive method) kullanarak analiz etmiştir. Bu çalışmada parametreler maksimum olabilirlik kestirimi (MLE) yöntemi kullanılarak belirlenmiştir.

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.

Acır N. ve arkadaşları (2004), yapay sinir ağları kullanarak EEG de uyku içciklerini otomatik olarak tanıyan sistemi önermişlerdir.

Álvarez, D., ve arkadaşları (2009), çalışmalarında apne hipapne sendromunda apneik olayların bulunmasına fuzzy logic tabanlı bir çözüm önerisi getirmişlerdir.

Duman F. ve arkadaşları (2009), çalışmalarında EEG sinyallerinin analizinden sonra karar ağacı algoritmasıyla uyku içciklerinin tesbit edilmesi, yerlerinin kesin olarak bulunması sağlanmış ve bunun için üç farklı yol kullanılmıştır. Bunlar STFT (Short Time Fourier Transform), MUSIC (Multiple Signal Classification) Algoritması ve TEO (Teager Energy Operator) dur.

3. EEG

3.1. EEG' nin Tarihsel Gelişimi

Beyinde bir takım elektriksel faaliyetlerin var olduğu 1875 yılında Caton adlı bir bilim adamı tarafından hayvanlar üzerinde yaptığı deneyler sonucunda ortaya atılmıştır. 1929 yılında ise ilk defa insan beyninde elektriksel aktivitenin varlığı Alman Psikiyatrist Hans Berger tarafından kafaya konulan elektrotlar ve bunlara bağlı bir galvanometre düzeneği sayesinde keşfedilmiştir. Dünya bu olayı Berger' in "Beyin tarafından üretilen zayıf elektrik akımlarını grafiksel olarak kağıt üzerinde kaydetmek kafatasını açmadan mümkün olmuştur" şeklinde yaptığı beyan ile öğrenmiştir. Bu gelişme devrimsel bir buluş olmuştur. Aslında Berger, *Klinik Nörofizyoloji* adıyla tamamen yeni ve çok önemli bir tıbbi bilim dalını keşfetmiştir.

Berger, (1930)' da ise *Elektroensefolagram* adı verilen bu dalgaların gözün açılıp kapanmasıyla değiştiğini ortaya koydu.

Fakat Berger' in kullandığı elektrotlar EEG' nin detaylı topografik ölçümü için çok büyüktüler. Bu durum Gray Walter adındaki İngiliz bilim adamınca bertaraf edildi. 1936' da kafatasına çok sayıda küçük elektrod yerleştirilmesi ile beyinde tümör etrafındaki elektriksel aktivitenin belirlendiğini ve içindekinin kaybolduğunu ispatladı.

EEG'nin iki boyutlu haritalarını oluşturma olasılıklarıyla pekişerek Walter 1957'de toposkopu icat etti. Toposkop, her biri kafatasına tutturulmuş bir çift elektroda bağlı 22 katod ışık tüp (TV tüpü benzeri) bulundurur. Toposkopun elektrodları ve ilgili tüpleri iki boyutlu geometrik düzlem üzerinde ayarlandı, tıpkı her tüpün beyinde belirli alanların EEG ölçümlerini oluşturan bir kısım ritimlerin yoğunluğunun betimlemesi gibi. Gray Walter deneklerine birkaç zihinsel görev vererek EEG ritimlerinin farklı yollarla, farklı zamanda ve beynin farklı bölümleriyle değiştiği sonucunu görmüştür. Örneğin, ilk olarak dinlenme halindeki alfa ritminin, dikkat isteyen zihinsel bir etkinlik esnasında neredeyse tüm beyinden kaybolduğunu ve daha hızlı olan beta dalgalarının hakim oldukları gözlemlenmiştir.

Epileptik noktaların tespitinde toposkopun büyük yardımı olabileceği gerçeğinin yanı sıra çok karmaşık ve pahalı olması ticari başarısını ve yaygın kullanımını engellemiştir. Beyin elektriksel etkinliğinin topografik yaklaşımı 80' li yıllarda masaüstü bilgisayarlarıyla birlikte yeniden doğmuştur. EEG beyin topografisi günümüzde renkli beyin haritalaması olarak da anılmaktadır.

3.2. EEG nedir?

Beynin biyoelektrik aktivitesinin incelenmesine ve uygun amplifikasyon ve yazdırma sistemleri kullanılarak kağıt üzerinde işlenmesi yöntemine *elektroensefalografi* denir. EEG yöntemini kullanarak beyinde çeşitli sebeplerden dolayı ortaya çıkan hastalıklar için bazen kesin veriler elde edemezken bazen de hastalığa ait küçük bir veri sonucu teşhis yapılabilmektedir. Bazı değişiklikler hastalığa sebep olan durumun saptanmasını sağlarken bazı değişiklikler de metabolik olayın çeşitleri konusunda bilgi vermektedir.

Bu yöntem beynin yapısal işlevlerinden çok fonksiyonel durumu hakkında bilgi verir. Bu nedenle yapısal görüntüleme yöntemlerinden MRG (Manyetik Rezonans Görüntüleme), BT (Bilgisayarlı Tomografi) gibi gelişmelere rağmen önemini korumaktadır. Bu yöntemler daha çok birbirini tamamlayıcı işlevler olan yapısal ve fonksiyonel inceleme üzerinde etkili olmaktadır. Yapısal inceleme sonucu gözlemlenen patolojik bulguların olmadığı durumlarda EEG önem taşımaktadır.

3.3. EEG Cihazının Temel Çalışma Şekli ve Uygulanması

EEG cihazlarında genel olarak kafatasının çeşitli yerlerinden aynı anda kayıt yapabilen 8, 16 veya daha fazla sayıda ayrı amplifikatörler bulunmaktadır. Amplifikatörler beyinden alınan sinyalleri yükseltirler ve mürekkeple yazan kalemleri hareket ettirerek veya özel bir kağıdı yakma yöntemiyle kayıt alınmasını

sağlarlar. Kalemle saniyede 3cm. hızla ilerleyen kağıda voltaj değişimlerini çizerler. Oluşan dalgaların frekans aralığı 0.5 ile 35 Hz. Arasında değişmektedir. Böylece beyin dalgalarının voltaj zaman grafiği elde edilir. Standart voltaj kalibrasyonu 7 mm. 50 μ V olacak şekildedir.

EEG tamamen ağrısız ve zararsız bir inceleme yöntemidir. Saçlı deriden kayıtlanan potansiyellerin çoğu piramidal hücrelerdeki toplam sinaptik potansiyellerin ekstrasellüler akımlarla ilişkisinin sonucudur. Bu potansiyeller sonucu alınan kayıtlar montaj adı verilen bağlantılarla değerlendirilir. Eskiden kullanılan EEG aletlerinde (yukarda bahsedilen) o andaki kayıt kağıda yapılır ve parametreleri sonradan değiştirilemez. Oysa şimdi kullanılan dijital EEG cihazlarının en önemli avantajı kayıt yapılan montajdan daha sonra diğer montajlara geçilebilmesi, amplitüd ve diğer parametrelerin her olgu için ve her bulgu için yeniden ayarlanarak en sağlıklı bilginin sağlanmasıdır.

Genelde EEG çekimi yaklaşık 30 dakika sürer, çekimden önce elektrotların yerleşimi çok önemli bir hazırlık aşamasıdır. Elektrotlar beynin sağ ve sol lopuna göre simetrik biçimde yerleştirilmelidir. Bu da hemisferler arası kıyaslamının sağlıklı yapılabilmesi için gereklidir. Loplara yerleştirilen elektrotlar lopun adının baş harfine göre solda tek sayı ile sağda çift sayı ile ifade edilir. Örneğin sol arka frontal için F7 sağ ön frontal için F4 kullanılır.

Yerleştirilen elektrot sayısı yaklaşık 20 civarındadır. Genelde elektrotların yerleştirileceği noktalar uluslararası 10 - 20 sistemine göre yapılır. Elektrotlar kafa derisi üzerine uygun yapışkan ve elektriği geçiren bir macunla yapıştırılarak ya da şapka şeklinde kauçuk bantlarla sıkıştırılarak yerleştirilir ve bazı özel pastalar ya da tuzlu su ile iletkenlikleri sağlanır.

EEG çekimi öncesinde hastanın saçlarının temiz olması önem taşır. EEG çekimi süresince hasta sakın bir şekilde gözleri kapalı oturmalıdır. EEG teknisyenin talimatlarınca hasta gözlerini açıp kapayabilir.

Tüm EEG çekimlerinde hiperventilasyon uygulanır. Bunun sebebi bir epileptik odağı aktive etmektir. Ayrıca EEG' de uygulanması gereken önemli bir aktivasyon da aralıklı ışık uyarımıdır.

3.4. EEG Değerlendirilmesi

EEG bulgularının değerlendirilebilmesi için öncelikle normal EEG özelliklerinin çok iyi bilinmesi gereklidir. Her EEG çekiminde önce temel aktivite değerlendirilir. Normal temel aktivite yaşla, uyanıklık durumuyla, açlık gibi bazı fizyolojik durumlarla çok belirgin farklılıklar gösterir. Üç aylık bir bebek için normal sayılan aktivite 3 yaşında bir çocuk için patolojiktir. Ya da derin uykuda olan bir erişkinin EEG aktivitesi aynı kişi uyanırken görüldüğünde ciddi bir patolojik bulgu anlamına gelebilir.

EEG de beynin hemisferleri arasında simetri vardır, bu nedenle iki yarıkürenin kıyaslanması önemlidir. Bunun dışında EEG değerlendirirken en önemli sorun artefaktların ayırt edilebilmesidir. Artefaktlar EEG kaydında yer alan, ancak beyinden kaynaklanmayan (göz hareketleri, hareket ve kas artefaktı, elektrot kayması, terleme gibi) çeşitli mekanik-elektriksel potansiyellerin sonucudur. Deneyimli bir kişinin hemen tanıyabileceği bazı artefaktlar kolayca patolojik beyin aktiviteleri sanılabilir.

EEG çekimi sırasında hastanın kullandığı ilaçlar ve varsa metabolik problemleri mutlaka kaydedilmelidir. Çünkü bazı ilaçların ve metabolik durumların EEG üzerinde etkileri belirgindir. Ayrıca epileptik hastanın nöbeti ile EEG çekimi arasındaki süre, yani EEG'nin postiktal mi yoksa interiktal dönemde mi yapıldığı bazı bulguların yorumu açısından önem taşır.

EEG sonucunda yorum yaparken görülen bulguları tanımlamayı yeğlemek ve EEG bulgusu ile klinik tanı arasında yanlış olabilecek bir yakıştırma yapmamak gerekir. EEG değerlendirmesini bu konuda deneyimli uzmanların yapması ancak her hekimin sonuçları yorumlayabilmesi gereklidir.

3.5. EEG İşaretlerinin Elektriksel Özellikleri

EEG işaretlerinin frekans bileşenleri klinik bakımdan oldukça önemli olduğu gibi, farklı bölgelerden alınan benzer EEG işaretleri arasındaki faz ilişkileri de sayısal anlamda oldukça ilgi çekicidir. Bu türden bilgiler, EEG' nin kaynağının incelenmesinde çok faydalı olup beyin çalışması ile ilgili daha birçok bilginin elde edilmesine olanak sağlar. Kafatasına yerleştirilen elektrotlar yardımıyla alınan EEG sinyallerinin genliği tepeden tepeye 1–100 μ V ve frekans bandı ise 0.5 - 35 Hz aralığındadır. Ölçümler açık beyin ameliyatları gibi durumlarda beyin üzerinden doğrudan alındığı takdirde, genlik değeri 10 kat daha artar. EEG' de oluşan farklı frekansların oluşum mekanizmaları henüz tam olarak açıklanamamıştır.


EEG, EKG ve EMG işaretlerinde olduğu gibi şekil bakımından değil, kapsadığı frekanslara göre değerlendirilmektedir. Çünkü EEG işaretleri periyodik değildir; genlik, faz ve frekansları sürekli olarak zaman içerisinde değişir. Bu sebeple anlamlı bir veri elde edebilmek için ölçümlerin oldukça uzun bir sürede yapılması gerekir. EEG işaretlerinin ana frekansı ile beyin aktivitesi yakından ilişkilidir. Aktivite ile frekans birlikte yükselir. Tablo 3.1, EEG işaretleri, kapsadıkları frekans bantları ve bu bantlara verilen özel isimler ile birlikte aşağıdaki gibi verilmiştir.

Tablo 3.1 EEG dalga şekilleri

Dalga Tipi	Özelliği
Beta	> 13 Hz
Alfa	13-8 Hz
Teta	7-3 Hz
Delta	2-0.5 Hz max.


3.6. EEG Dalga Şekilleri

Alfa Dalgaları: Alfa dalgaları 8–13 Hz arasındaki beyin dalgalarıdır. Uyanık normal ve sakin kimselerde görülür. Yoğun şekilde oksipital bölgede ortaya çıkar, genlikleri 5 μ V kadardır. Uyku durumunda yok olurlar. Uyanık kişi dikkatini özel bir şeye yöneltirse α dalgaları yerine, daha yüksek frekanslı, fakat düşük genlikli EEG işaretleri (β dalgaları) meydana gelir. Şekil 3.1’ de Alfa dalgası görülmektedir (Yazgan ve Korurek 1996).




Şekil 3.1 Alfa dalga şekli

Beta Dalgaları: Beta dalgaları, Frekansları 13 Hz’ in üzerindeki beyin dalgalarıdır. 25 Hz’ e ve nadir hallerde 50 Hz’ e kadar uzanırlar. Saçlı derinin parietal ve frontal bölgelerinde belirgin olarak kaydedilebilir. Beta-I (BI) ve Beta-II (BII) diye ikiye ayrılırlar. BII dalgalarının frekansı, BI’ inkinin iki iki mislidir ve α 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. Şekil 3.2’ de Beta dalgası görülmektedir (Yazgan ve Korurek 1996).




Şekil 3.2 Beta dalga şekli

Teta Dalgaları: Teta dalgaları 3–7 Hz arasındaki dalgalardır. Özellikle, çocuklarda parietal ve temporal bölgelerde ortaya çıkarlar. Yetişkinlerde de duygusal gerginlik, düş kırıklığı durumlarında ortaya çıkarlar. Genlikleri 100 μV (p-p)’ den küçüktür. Şekil 3.3’ de Teta dalgası görülmektedir (Yazgan ve Korurek 1996).



Şekil 3.3 Teta dalga şekli

Delta Dalgaları: Delta dalgaları 2–0,5 Hz’ in altındaki beyin dalgalarıdır. Bazı durumlarda 0,5 Hz’ in altına da düşer. Süt çocuklarında ve ağır organik beyin hastalıklarında görülür. Genlikleri–100 μV (p-p)’ den küçüktür. Şekil 3.4’ de Delta dalgası görülmektedir (Yazgan ve Korurek 1996).



Şekil 3.4 Delta dalga şekli

Gamma Dalgaları: Bazı araştırmacılar tarafından kullanılmaktadır. Bazı araştırmacılar da bu dalgaların yerine, BII dalgalarını kullanmaktadır. Genlikleri, 2 μV (pp)' den daha küçüktür. Kafanın merkezinde, genlikleri daha büyüktür. Uykunun karakteristik belirtisini taşırlar (Yazgan ve Korurek 1996).

4. UYKU ve UYKU EVRELERİ

4.1. Uyku

Uyku insanoğlunun her zaman çok ilgilendiği konular içerisinde yer almıştır. Bunun nedeni her birimizin günlük işlevselliğimizi sürdürebilmek için uyku uyumaya ihtiyacımızın olmasıdır. Günlük aktivitelerimizi devam ettirebilmek için, verimli olabilmek için her gün belirli bir süre uyumamız gerekmektedir.

Her insan, ömrünün üçte birini uyuyarak geçirir. Her gün yaşadığımız ve gerçekte büyük bir mucize olan uyku genellikle bilinenin aksine tüm vücut sistemlerinin pasifleştiği bir dinlenme süresi değildir. Çünkü uyku esnasında vücut aktif bir yenilenme sürecine girer. Tüm bu verilenler ışığında uykunun bir tanımını şöyle yapabiliriz.

Uyku; organizmanın çevreyle iletişiminin, değişik şiddette uyarılarla geri döndürülebilir bir biçimde geçici, kısmi ve periyodik olarak kaybolması durumudur.

Uykunun başlaması, eş zamanlı olarak meydana gelen bir dizi faaliyet sonucu olmaktadır. Retiküler Aktivasyon Sistemi (RAS) ile çevresel sinir sistemi arasındaki pozitif geribildirim döngüsünün engellenmesi (ketlenmesi), uyku merkezlerinin engelleyici etkileri ve uykuyu oluşturan kimyasal ajanların (nörotransmitterlerin) birikmesi uyanıklıktan uykuya geçişe yol açmaktadır. Ayrıca, uykuya geçerken vücut ısısı ve kortizol düzeyi düşmekte, melatonin salgısı artmaktadır. Organizma, “sirkadien ritm” e uygun olarak uykuya girişe hazırlanmakta, sinir sisteminde korteks altı bölgelerde, locus coeruleus’ da (LC) engellenme başlamakta, giderek dorsal raphe çekirdeklerinde (DR) faaliyetin arttığı dikkati çekmektedir. Bunun sonucu, eşzamanlı olarak derin uyku ortaya çıkmakta, uyku derinleştikçe sinir sistemindeki engellenme derinleşmektedir (Uykuder 1. Uyku Bozuklukları Kongre Kitabı, 2008).

Özetle düzenli uyku vücudun performansını artırırken, kronik uykusuzluk işgücünü azaltmakta ve mental yetenekleri kısıtlamaktadır. Uyku döneminde başta merkezi sinir sistemi olmak üzere, solunum, dolaşım ve kas iskelet sistemi gibi, organizmanın büyük bir bölümünün günlük yıpranması tamir edilmektedir. Uykuda

bir bozukluk olduğunda tamir edilemeyen sistemler verimsiz çalışmaya başlamaktadır.

4.2. Uyku Evreleri ve Uyku Evreleme

Uyku bozukluklarının tanısı için “altın standart” yöntem olan polisomnografi; uyku sırasında, nörofizyolojik, kardiyorespiratuar, diğer fizyolojik ve fiziksel parametrelerin belli bir periyod, genellikle gece boyunca, eş zamanlı ve devamlı olarak kaydedilmesi” şeklinde tanımlanabilir. (Uykuder 1. Uyku Bozuklukları Kongre Kitabı, 2008)

1968 yılında Rechtschaffen ve Kales’ in (R&K) editörlüklerini yaptığı 12 araştırmacı, insan uyku evrelerinin standart terminoloji, teknik ve skorum el kitabını hazırlamışlardır. Yakın geçmişe kadar uyku evrelerinin skorum bu grubun belirlediği prensipler esas alınarak yapılmakta ve sağlıklı bir kişide normal uyku; NREM 1, 2, 3, 4 ve REM olmak üzere iki ana bölüm ve 5 evreden oluşmaktaydı.

Amerikan Uyku Tıbbı Akademisi’nin (American Academy of Sleep Medicine-AASM), Dr. Iber Conrad başkanlığında oluşturduğu bir çalışma grubu uzun süren çalışmalar sonunda, uyku ve ilişkili olayların skorumlanması konusunda yeni kuralları belirlemiş ve 2007 yılında bir manüel olarak yayınlanmıştır. Artık günümüzde bu uzlaş raporu kuralları esas alınmaktadır. Buna göre;

A. Uyku evreleri uyanıklık (W), evre I (N 1), evre II (N2), evre III (N3) ve REM (R)’ den oluşmaktadır (Non-REM evre 4 uyku terminolojisinden kaldırılmıştır).

B. Uyku epoklara göre skorumlanır

1. Uyku evrelerinin skorumlanması için 30 saniyelik epoklara ihtiyaç vardır.

2. Her epok bir evre ile isimlendirilir.

3. İki evre aynı epokta yer alıyorsa, epogun yarısından fazlası hangi evre ise o evre olarak adlandırılır.

4.2.1. Uyku evreleri

4.2.1.1. Evre W (uyanıklık evresi)

W evresi, uyanıklık evresidir ve en alert durumdan uykuya dalmak üzere olan duruma kadar değişen bir yelpaze içerir.

W evresinde, gözler kapalıyken genellikle alfa ritmi izlenir. Gözler açıkken alfa'nın ritmisitesi olmaksızın düşük amplitüdlü aktivite içeren EEG paterni izlenir. İnsanların %10'unda gözler kapalı iken alfa dalgaları izlenmez, %10'unda ise çok azdır. Bu kişilerde göz açık ya da kapalı iken EEG paterni aynıdır.

W evresinde, EOG'de 0.5-2 Hz frekansında hızlı göz hareketleri (göz kırpmaları) izlenir. Uykuya dalmak üzereyken göz kırpmaların sıklığı yavaşlar, göz kırpmaların yerini yavaş göz hareketleri alır, bu arada alfa ritmi sebat eder. Eğer gözler açıksa istekli hızlı göz hareketleri ya da okuyan göz hareketleri izlenebilir.

Tanımlar:


Alfa ritmi: 8-13 Hz frekanslardadır. Gözler kapalı iken ve oksipital bölgeden alınır, gözler açılınca zayıflar.

Göz kırpma: 0.5-2 Hz' lik vertikal göz hareketleridir.

Okuyan göz hareketleri: Ters istikametlerde önce yavaş sonra takibinde hızlı faz içeren göz hareketleridir.

Hızlı göz hareketleri: R evresinde geçerli olmakla beraber uyanık, göz açık ve kişi çevreyi gözleri ile tararken de görülür. İrregüler, sert, keskin pikler tarzında dalgalar mevcuttur.

Şekil 4.1' de Uyanıklık (W) evresine ait PSG sinyal kaydı bulunmaktadır.



Şekil 4.1 Uyanıklık (W) Evresine ait PSG sinyal kaydı

4.2.1.2. NREM Evre I

NREM Evre I' de Verteks keskin dalgaları bulunabilir ama NREM Evre I evresini skorlamak için gerekli değildir.

EOG' de, NREM Evre I' de yavaş göz hareketleri izlenir ama NREM Evre I diye skorlamak için bu şart değildir. NREM Evre I boyunca çene EMG aktivitesi değişkendir ama sıklıkla W evresine göre amplitüdü düşüktür. Tıpkı alfa ritimlerinin yavaş göz hareketlerinden önce başlaması gibi uyku latansı alfa ritmi oluşturmamalarına göre daha kısa olabilir. NREM Evre I uyku zamanının %2 - 5' ini içerir. Eğer kişi uykunun bu evresinde uyandırılırsa etrafında olup bitenden tamamen haberdar olmamasına karşın genellikle uyumadığını uyanık olduğunu söyleyecektir.

Tanımlar:


Yavaş göz hareketleri (SEM): En az 0.5 sn' nin üstünde bir defleksiyonla başlayan konjuge, düzenli, sinüzoidal göz hareketleridir.

Düşük amplitüd, karışık frekanslı aktivite: 4-7 Hz' lik aktivite baskın durumdadır.

Verteks keskin dalgaları (V dalgaları): Maksimum 0.5 saniyelik keskin uçlu dalgalarıdır, santral bölgelerden alınır, bazal aktiviteden net olarak ayrılabilir.

Uyku başlangıcı (sleep onset): W dışındaki herhangi bir uyku evresinin ilk görüldüğü epoktur (olguların çoğunda, genellikle NREM Evre I).

Şekil 4.2' de NREM Evre I' e ait PSG sinyal kaydı bulunmaktadır.



Şekil 4.2 NREM Evre I e ait PSG sinyal kaydı

4.2.1.3. NREM Evre II

EOG' de genellikle NREM Evre II' de göz hareketleri aktivitesi yoktur, ama bazen SEM sebat eder. NREM Evre II evresinde, EMG amplitüdü değişkendir, ama genellikle W' den düşük hatta R kadardır. Bu evre total uykunun % 45-55' ini içerir. Uykunun bu evresinde bilinç, kişi uyandırıldığında uykuda olduğunu hatırlayabilmesine yeterli olacak şekilde EEG paternleri görülür.

Tanımlar:

K Kompleksi: İyi ayırt edilen negatif keskin ve onu takip eden pozitif komponenti vardır, toplam süresi 0.5 saniyeden uzundur, maksimum amplitüd frontal

derivasyonlardan sağlanır. Bir arousal' ı K kompleksine eşlik eden arousal kabul etmek için K kompleksinden sonra en fazla 1 saniye içinde gelişmiş olması gerekir.


Uyku iğciği: 12-14 Hz'lik (11-16 da olabilir) frekanstadır, 0.5 saniyeden uzun süren, en yüksek amplitüdün santral derivasyonlardan alındığı peşpeşe küçük dalgalardan oluşur.

Uyku iğcikleri thalamokortikal salınımların güdümüyle kortekste gözlemlenebilen geçici dalga biçimleridir. İğcik aktivitesi uykunun 2. döneminde yoğun olmak üzere diğer NREM uyku evrelerinde nadiren de olsa mevcuttur. Yaşın ilerlemesiyle, yaşam boyu var olan uyku iğciklerinin yoğunluklarında azalma, frekansında artma görülmektedir (A.Nicolas 2001).

İğciklerin oluşumu ve işlevi hakkında tam bir fikir birliği olmamakla birlikte kabul gören iki varsayım vardır. Birinci varsayıma göre iğcikler, motor çıkışın ve algı geçişlerinin bastırılması yoluyla uyku halinin sürdürülmesini sağlayan salınımlardır. İkinci varsayıma göre ise iğcikler, talamo-kortikal alanda önceki deneyimlerin bütünleştirilmesi için gereken işlevlerin bir araya getirilmesine yardımcı olur. Hipersomniyak ve insomniyak denekler üzerinde yapılan çalışmalar iğcik yoğunluklarının hastalığın türü ile bağlantılı olarak değiştiğini göstermekte ve iğciklerin uyku sürecini düzenleyici işlevinin olduğu bulgusunu kuvvetlendirmektedir (Eroğul vd 1999).


İğciklerin geçici rejim özelliklerini ve arka plan EEG (elektroansefalografi) işaretlerine göre daha düşük genliklere sahip olmaları gözle ayırt edilmelerini ve ayrıştırmalarını güçleştirir. İğciklerin otomatik sezimi ve dalga biçimlerinin analizi nesnel olarak değerlendirilebilmeleri için önemlidir (Eroğul vd 1999).

Şekil 4.3' de K kompleksi ve Uyku iğciği bulunan bir PSG sinyal kaydı bulunmaktadır.



Şekil 4.3 K kompleksi ve uyku içiği bulunan bir PSG kaydı

Şekil 4.4' de NREM Evre II' ye ait PSG sinyal kaydı bulunmaktadır.



Şekil 4.4 NREM Evre II' ye ait PSG sinyal kaydı


4.2.1.4. NREM Evre III

NREM evre III' de uyku içcikleri sebat edebilir. NREM evre III' de göz hareketleri tipik değildir ve EMG amplitüdü değişkendir, sıklıkla NREM evre III' dekine göre düşük hatta bazen R' deki kadardır. Bu evre uykunun en derin, en iyileştirici ve en uygun dinlenme noktasıdır. Yavaş dalgalı uyku evresidir. Frekansı 0.5-2 Hz arasındaki sinyaller mevcuttur bu sinyaller *Delta* dalgalarıdır. NREM evre III' tüm gece uykusunun %20-25 ini içerir. Kişiyi uyandırmak daha zordur. Bu esnada derin ve rüyasız bir uyku durumu vardır. Çocuklarda büyüme hormonu özellikle derin uyku döneminde (Evre III) salınır.

Tanımlar:

Yavaş dalga aktivitesi: Delta dalgalarının frekansı 0.5-2 Hz' dir. Frontal bölgeden alınan dalganın amplitüdü >75 mikro voltur.

Şekil 4.5' de NREM Evre III' e ait PSG sinyal kaydı bulunmaktadır.



Şekil 4.5 NREM Evre III

4.2.1.5. REM Evresi

REM evresindeki düşük amplitüd, karışık frekanslı aktivite NREM evre I' e benzer. Bazı kişilerde alfa aktivitesi NREM evre I' den çok R' de izlenir. R' deki alfa aktivitesi W' a göre 1-2 Hz daha yavaştır.

Aşağıdaki fenomenler R evresini, şüpheli durumlarda skorlamaya yardımcı olur.

- a) Testere dişi dalgaları
- b) Geçici kas aktivitesi
- c) Özellikle gecenin ilk R epizotunda, R' de K kompleksi ve uyku iğciği izlenebilir ama hızlı göz hareketleri yok ve sadece düşük EMG söz konusu ise NREM evre II olarak skorlanmalıdır.

Tüm gece uykusunun % 20-25 ini kapsar. EEG' de düşük voltajlı hızlı aktivite gözlenir. Rüyaların % 80' inin REM sırasında görüldüğü bilinmektedir. Bu evrede görülen rüyalar hatırlanır (bu evrede kalıcı bellek kaydı vardır). 90 dakikada bir, 5-30 dakikalık süreçler halinde ortaya çıkar. REM sırasında beyindeki kan akım üzerindeki çalışmalar, kan akımının ve oksijen kullanımının uyanıklığa benzer tarzda artışlar gösterdiğine işaret etmektedir. Tüm vücutta kas tonusu azalır. Kalp atımları, solunum sayısı ve kan basıncı düzensizleşir. Bazı düzensiz kas hareketleri (göz hareketleri gibi) oluşur. Bu evre uykunun diğer evrelerinin arasına serpiştirilmiştir.

Tanımlar:

REM: 0.5 sn' lik defleksiyonla başlayan konjüge, düzensiz, keskin pikli göz hareketleridir.


Düşük EMG tonüsü: EMG aktivitesi diğer herhangi bir evreden daha yüksek değildir, genellikle bütün kaydın en düşük seviyesine sahiptir.

Testere dişi dalgalar: Santral bölgelerden alınan, maksimum 2-6 Hz dalgalı keskin uçlu, üçgenimsi, genellikle REM göz hareketlerine eşlik eden dalgalardır.

Geçici kas aktivitesi: Genellikle 0.25 saniyeden kısa süreli bazaldeki düşük EMG tonüsüne süperpoze kısa, irregüler EMG aktivitesi patlamaları şeklindedir. Çene ve

bacak EMG' sinde olduđu kadar EEG ve EOG' de de izlenebilir. Bu aktivite hızlı göz hareketleri ile beraber maksimumdur.

Şekil 4.6' da REM Evresi' ne ait PSG sinyal kaydı bulunmaktadır.



Şekil 4.6 REM Evresi' ne ait PSG sinyal kaydı

4.2.2. Yaşa göre uyku evrelerinin dağılımı


Uyku evrelerinin dağılımı yaşla değişkenlik gösterir. REM süresinde yaşla değişiklik olmazken, çocuklar erişkinlere kıyasla daha fazla yaşlılar ise daha az yavaş dalga uykusu (NREM Evre 3) uyurlar. Yaşa göre uyku evrelerinin dağılımı Tablo 4.1’ de verilmiştir.

Tablo 4.1 Yaşa göre uyku evrelerinin dağılımı

UYKU EVRELERİ	ÇOCUK	GENÇ ERİŞKİN	YAŞLI
Uyanık	<	5	>
REM	=	20-25	=
NREM-1	<	1-5	>
NREM-2	=	40-50	>
NREM-3	>	20-25	<
TOPLAM saat	10-12	8-10	6-8

4.2.3. Örnek bir uyku modeli

Şekil 4.7’ deki grafikte sarı hat uyanıklık dönemini simgelemektedir. Uyku başlangıcında süratle yüzeysel uykudan derin uykuya geçilir. Genellikle uykuya daldıktan sonra 1 saat içinde NREM döneminin en derin basamağı olan üçüncü basamağa girilir. Daha sonra uykunun derinliği azalır ve ilk REM dönemine geçilir.



Şekil 4.7 Sekiz saatlik örnek bir uyku süreci

Bu ilk REM dönemi 5-10 dakika devam eder. Bundan sonra NREM ve onu izleyen REM' den oluşan ve 80–100 dakika süren periyotlar uyku sırasında peş peşe 4-6 kez meydana gelir. REM' in toplam süresi, uykunun toplam süresinin % 20-25' i kadardır.

Rem döneminde uykunun en hafif dönemine ulaşırız. Bu noktada uyanma ihtimalimiz çok yüksektir veya çevremizdeki sesler, hareketler, içimizdeki ağrılar veya üzüntülerle aniden uyanıp canlanabiliriz. Tekrar uykuya geri dönersek, bütün devreler yeniden başlar.

Uykunun ilk üçte birinde NREM' in derin basamakları egemen durumdadır. Uykunun ortasında ve ikinci yarısında yavaş dalgalı uyku süresi kısalır, REM döneminin süresi ise genellikle uzar.

4.3. Polisomnografi

OSAS tanısı için “altın standart” tanı yöntemi olan “polisomnografi” (PSG) Yunanca ve Romence köklerden oluşmuş bir kelimedir. Bu terim ilk kez 1974 yılında Holland ve arkadaşları tarafından kullanılmıştır.

"Uyku sırasında, norofizyolojik, kardiyorespiratuar, diğer fizyolojik ve fiziksel parametrelerin belli bir periyod, genellikle gece boyunca, eş zamanlı ve devamlı olarak kaydedilmesi" şeklinde tanımlanabilir (Uykuder 1. Uykü Bozuklukları Kongre Kitabı, 2008).

Bu yöntemle uyku evreleri ile birçok fizyolojik parametre ayrıntılı olarak izlenmekte ve çeşitli organ ve sistemlerin fonksiyonu, uyku ve uyanıklık sırasındaki etkileşimleri konusunda bilgi sağlanmaktadır.

Tablo 4.2’ de standart PSG parametreleri görülmektedir.

Tablo 4.2 Standart polisomnografi parametreleri

Standart polisomnografi parametreleri
1. Elektroensefalografi (EEG)
2. Elektraokulografi (EOG)
3. Elektramiyografi (EMG-submentalis)
4. Ora-nasal hava akımı
5. Torako-abdominal hareketler
6. Oksijen saturasyonu
7. Elektrokardiyografi (EKG)
8. Elektromiyografi (EMG-tibialis.)
9. Vücut pozisyonu

EEG, EOG, submental EMG; uyku evrelemesini, yüzeysel uyku (NREM evre 1,2), derin uyku (evre 3) ve REM uykusunun ayrımını ve bu sırada oluşabilecek patolojik bulguların değerlendirilmesini sağlar.

Ora-nasal hava akımı ve solunumsal çabanın değerlendirilmesi (torako-abdominal hareketler) apnenin varlığı, tipini (obstriktif, santral, mikst ayrımı) ve süresini saptamamızı sağlar.

Oksijen satürasyonunun izlenmesi, postapneik ve/veya nonapneik desatürasyonların varlığını, derecesini ve süresini saptar.

Nabız ve EKG kaydı ile kardiyak patolojilerin (ritim bozuklukları, miyokard iskemisi, ventriküler hipertrofisi vs.) ve apneik epizotlarla ilişkisinin saptanması mümkün olur.

EMG tibialis ile, uyku sırasındaki periyodik bacak hareketleri araştırılır.

4.4. Uyku Laboratuvarı

PSG için ilk gereksinim, yalnızca bir hastanım incelenebileceği, yeterli genişlikte, tuvalet, banyosu bulunan bir uyku odasıdır. Çevresel uyaranların uyku üzerine etkisini elimine etmek ve hastanın rahat bir ortamda uyuyabilmesini sağlamak amacıyla PSG, sestem, gürültüden arındırılmış, klimatize edilmiş ve tam karanlık sağlanabilecek bir odada uygulanmalıdır. Rahat bir yatak ve kayıt kalitesinin yüksek olması için yeterli teknik imkanlar bulunmalıdır.

Bir infrared ışık kaynağı ve düşük ışık video kamera, teknisyene uyku laboratuvarındaki hastayı uzaktan görsel ve işitsel izleme olanağı tanır.

4.5. Hastanın Hazırlanması

Genellikle saat 20.00' de hasta uyku laboratuvarına alınır. Hastaya yapılacak işlem hakkında bilgi verilir. Daha önceden broşür, mektup, telefon ve-veya kişisel görüşme ile bilgilendirilmiş hastaların laboratuara uyumu daha iyi olmaktadır.

Çalışma öncesi hastanın uyku özellikleri ile ilgili bir anket uygulanır ve çalışma sonunda hastaya tekrar bir anket uygulanarak gece ki uykusuna yönelik sorgulama yapılır.

Hastanın normal uyku ritminin kaydedilebilmesi için, çalışmadan birkaç gün önce uyku düzenini etkileyen ilaçlar kesilir. Skorlamayı önemli ölçüde etkilemeleri nedeniyle, bu ilaçlar uzun yarılanma ömürleri dikkate alınarak çalışmadan 5-10 gün önce kestirilir.

Çalışma günü ağır fiziksel egzersiz yapmaktan kaçınılır. Hastanın kahve, siyah çay ve alkol alması yasaklanır. Hafif bir akşam yemeğinden sonra uygun bir elbise giyerek ve tuvalet ihtiyacını gidererek çalışma için hazırlanır.

Teknisyen hastanın vücuduna çeşitli sensörler yerleştirir. Bağlantıları kontrol eder, kalibrasyonlarını yapar. Bu işlem 30-60 dakika süre alır. Hasta yatağa alınır ve ışık söndürülerek çalışma başlatılır.

4.6. Hastanın İzlenmesi

Hastanın izlenmesi nörofizyolojik izlem, respiratuar izlem, kardiyovasküler izlem ve diğer parametreler adı altında dört ana bölümden oluşmaktadır. Bu kısımda özellikle bizim için daha fazla önem taşıyan Nörofizyolojik izlem anlatılacak olup diğerlerinden kısaca bahsedilecektir.

4.6.1. Nörofizyolojik izlem

PSG' de temel kanallar EEG, EOG ve EMG' dir. Uyku ve uyanıklığın objektif olarak gösterilmesinin başlıca dayanağı ise beynin elektriksel aktivitesinin kaydedildiği EEG' dir.

4.6.1.1. EEG kanalları

EEG değerlendirilmesi dalgaının amplitüd ve frekansı, bunun yanında bazı spesifik paternler göz önüne alınarak yapılır. EEG aktivitesi alfa, beta, teta ve delta dalgaları olarak tanımlanabilir. Tablo 4.3’ de EEG dalga şekilleri ve hangi evrelerde görüldüğü, Tablo 4.4’ de ise çeşitli spesifik uyku paternleri görülmektedir.

Tablo 4.3 EEG dalga şekilleri

Dalga Tipi	Özelliği	Görüldüğü evre
Beta	> 13 Hz	Uyanık, aktif kişi
Alfa	8-13 Hz	Gözler kapalı, sakin uyanıklık
Teta	3-7 Hz	Hafif uyku
Delta	0.5-2 Hz max.	NREM derin uyku


Tablo 4.4 Çeşitli EEG paternleri

EEG Paterni	Özelliği	Görüldüğü Evre
Uyku içcikleri	12-14 Hz, >0.5 sn	NREM evre 2
K kompleksleri	Keskin negatif, daha yavaş pozitif, >0.5 sn	NREM evre 2
Vertex keskin dalgaları	Keskin negatif defleksiyonlar	Nrem evre 1

Uyku EEG si nörolojide kullanılan klinik EEG’ den önemli farklılıklar gösterir. Başın üzerine çok sayıda elektrot yerleştirilen klinik EEG nin aksine uyku EEG’ sinde başa sadece birkaç elektrot yerleştirilir (En az 1 kanal EEG kaydı gereklidir).

Çoğunlukla da uyku içciklerinin ve K komplekslerinin en iyi kaydedildiği C3 veya C4 bölgeleri kullanılır.

Altın veya gümüş kaplı EEG elektrotları yüzey temizlendikten sonra 10-20 sistemine göre kollodium ile kafa derisine sıkıca yapıştırılır. Şekil 4.8' de bu sistem ayrıntılı olarak gösterilmiştir.



Şekil 4.8 Uluslar arası 10-20 sistemi


REM evresindeki hızlı göz hareketlerinin ve erken NREM Evre-I uykusundaki yavaş dairesel göz hareketlerinin saptanması için sağ ve sol EOG elektrotları her iki göz dış kantusuna biri yukarıda, diğeri aşağıda olacak şekilde yerleştirilir. Bu şekilde vertikal göz hareketleri de kaydedilmiş olur.

4.6.1.2. EOG kanalları

Uyku sırasında göz hareketleri kaydının iki temel nedeni vardır. Bunlar;

- 1- REM döneminin en karakteristik bulgusu olan hızlı göz hareketleri saptanır. Böylece uyku evrelemesi için çok önemli bir kriter kaydedilmiş olur.
- 2- Uykunun başlangıcında görülen yavaş göz hareketleri (SEM) ve NREM Evre 1' e geçişin bulgusudur.

EOG kaydı için en az iki kanal gereklidir. Sağ ve sol EOG elektrotları her iki göz dış kantusunun (üst göz kapağı iç ve dış köşesinde yer alan deri kıvrımları arası) hafif letareline (dışyan), biri 1 cm yukarıda, diğeri ise 1 cm aşağıda olacak şekilde yerleştirilir. Bu sayede hem horizantel hem de vertikal göz hareketleri kaydedilmiş olur. Şekil 4.9' da EOG elektrotları bağlantı şekli görülmektedir.



Şekil 4.9 EOG elektrotları bağlantı şekli

Genel olarak bunların dışında hastaya EMG aktivitelerinin ölçülmesi için çeneye ve bacağına EMG elektrotları, dolaşım sistemi genel bilgisi için EKG elektrotları, ora-nasal hava akımının ölçülmesi için ora-nasal kanül ve termistör, oksijen saturasyonunu ölçmek için pulsoksimetre, torako-abdominal hareketler için göğüs ve karın kemeri, horlama için horlama sensörü, uyku pozisyonunun belirlenmesi için ise pozisyon sensörleri takılır.

Tüm bu elektrotların takılmasından sonra kayıt alma işlemi için hazırlanmış hastanın görüntüsü Şekil 4.10’ da görülmektedir.




Şekil 4.10 Polisomnografi kayıt öncesi hasta bağlantıları

4.7. Veri Toplanması (Kayıt)

Klasik PSG uygulamasında biyolojik sinyaller kağıt üzerine mürekkep ile devamlı olarak kaydedilir. Bu şekilde saniyede 10 mm’ lik hızla her kayıt sayfasında (epok) 30 sn’ lik bir kayıt yapılmış olur. Sekiz saatlik bir kayıt sonrasında ise bu sistemle 432 m uzunluğunda ve yaklaşık 13 kg ağırlığında bir kağıt birikmektedir. Yüksek kağıt maliyeti, kağıt ve kalemler ile ilgili mekanik problemler, kayıt kağıtlarının saklanması gibi güçlükler klasik PSG’ nin majör kısıtlamalarıdır.

Bu nedenle komputeze PSG’ ler geliştirilmiştir. Dijital sistemlerde veriler DAT kasetlere, optik disklere veya CD’ lere kaydedilerek klasik PSG’ lerin maliyet

ve depolama sorunları aşılmıştır. Ancak özellikle klinik çalışmalar için yine de klasik sistemlere ihtiyaç duyulmaktadır. Şekil 4.11’ de bilgisayar destekli polisomnografi cihazının kayıt arayüzü görülmektedir.



Şekil 4.11 Bilgisayar destekli polisomnografi cihazının kayıt arayüzü

PSG için genellikle uygulanan yöntem tüm gece boyunca (full-night) veya en az 6 saatlik kayıt yapılmasıdır. Uykuda solunum bozukluklarının değerlendirilmesi için yarı gece (half-night veya split-night) çalışmalar da uygulanmıştır. “Split-night” çalışmalarda gecenin ilk yarısında tanı, ikinci yarısında ise CPAP titrasyonu yapılır. Ancak bu yöntemle uykuda solunum bozukluğunun ağırlığını saptamada hata yapılabilir. Çünkü apne epizodlarının özellikle sıklaştığı REM dönemine, daha çok gecenin ikinci yarısında girilir. Bu nedenle sağlıklı olanı tüm gece yapılan çalışmalardır.

5. MATERİYAL VE METOD

5.1. Üzerinde Çalışılan Veriye Ait Özellikler

Bu çalışmada kullanılan EEG sinyalleri; Selçuk Üniversitesi Meram Tıp Fakültesi Göğüs Hastalıkları Anabilim Dalı Uyku Laboratuvarına uyku rahatsızlıkları sebebiyle başvuran üç ayrı hastadan alınmıştır. EEG kayıtları ortalama 7–8 saat boyunca kafatası üzerine 10-20 sistemine göre yerleştirilmiş iki elektrot yardımıyla C3-A2 kanalından alınan verilerden oluşmaktadır. Sinyallerin örnekleme frekansı 128 Hz. dir. Hastalar içerisinde Hasta 1 (39 yaşında - kadın)’ den 500 epokluk, toplam 15000 sn’ lik kayıt, Hasta 2 (55 yaşında - kadın)’ den 88 epokluk, toplam 2640 sn’ lik kayıt ve Hasta 3 (33 yaşında - erkek)’ den 124 epokluk, toplam 3720 sn’ lik kayıt olmak üzere genel toplamda 712 epokluk, 21360 sn. lik (5 saat, 56 dakikalık) kayıt alınarak çalışmada kullanılmıştır. Epokların 356’ sının içerisinde en az bir tane spindle vardır. Burada adı geçen epoklar her biri 30 sn. lik sinyal parçalarıdır.


Tablo 5.1’ de çalışmada EEG kayıtları kullanılan hastalara ait istatistiksel veriler bulunmaktadır.

Tablo 5.1 Hastalara ait istatistiksel değerler

ADI SOYADI	CİNSİYET	YAŞ	KİLO	BOY
Hasta 1	Erkek	33	83	177
Hasta 2	Kadın	39	60	158
Hasta 3	Kadın	55	84	160

5.1.1. Spindle bulunan epok


Şekil 5.1’ de Hasta 1’ den alınan evre 2 ye ait spindle bulunan bir EEG kaydı görülmektedir.



Şekil 5.1 Evre 2 ye ait spindle bulunan epok

5.1.2. Spinle bulunmayan epok

Şekil 5.2’ de Hasta 1’ den alınan rem evresine ait spindle bulunmayan bir EEG kaydı görülmektedir.




Şekil 5.2 REM evresine ait spindle bulunmayan epok

5.2. Önerilen Sistemin Akış Diyagramı

Bu tez çalışmasında uyku bozukluklarının tanısı için uyku laboratuvarlarında hastalardan alınan kayıtlardan faydalanılarak, uyku evrelerinin belirlenmesinde özellikle Evre 2 olarak nitelendirilen uyku bölümünün tespit edilmesinde bir işaret olarak gösterilen sleep spindle yani uyku içciklerinin bilgisayar yardımıyla bulunmasına yönelik bir yöntem önerilmiştir.

Daha önceki bölümlerde hastanın test için nasıl hazırlandığı, PSG cihazının yapısı, hastadan hangi parametrelere ait kayıtların hangi elektrotlar yardımıyla alındığı anlatılmıştı.

Bu kısımda PSG cihazından alınan kayıtların işlenebilir kayıtlar haline getirilmesi süreci Şekil 5.3’ de gösterilen sistemin akış diyagramından da faydalanılarak anlatılacaktır. Bu süreç şu şekilde işlemektedir.




Şekil 5.3 Önerilen sistemin akış diyagramı

5.2.1. EEG de C3-A2 kanalındaki sinyalin alınması


PSG cihazı, yaklaşık boyutu 90 MB. olan ham dataları cihazın adını sembolize eden bir dosya formatıyla SD kart üzerine kayıt eder. Bu dosyanın işlenebilir hale getirilebilmesi için bazı programlar vasıtasıyla .edf, .ascii ve son olarak da .dat dosya formatına dönüştürülür.

İlk olarak dosya, cihazın kendi ara yüz programı sayesinde .edf (European Data Format) dosya formatına dönüştürülür. Şekil 5.4' de bu dönüştürme ara yüzü görülmektedir.




Şekil 5.4 Dataların .edf dosya formatına dönüşümü

Buradan elde edilen .edf dosyası daha sonra EDF to ASCII dosya dönüştürme programı ile ASCII dosyasına dönüştürülür. Şekil 5.5’ de bu dönüştürme ara yüzü görülmektedir. Dönüştürme ara yüzünde kaynak dosya, hedef dosya ve dönüştürülecek EEG kanalı seçilerek dönüştürme işi yapılır. Biz EEG kanalını C3-A2 olarak seçtik.



Şekil 5.5 Dataların .ascii dosya formatına dönüşümü

Son olarak elde edilen .ascii uzantılı dosya Edit Plus adlı program yardımıyla açılır ve .dat dosya formatında farklı kaydedilerek sinyal işleme sırasında kullanacağımız dosya formatına ulaşılmış olur. Şekil 5.6' da görüldüğü gibi hastaya ait yaklaşık 8 saatlik veri 4.323.840 adet satır ve bir sütundan oluşan matris formatına dönüştürülmüş olur.



Şekil 5.6 Dataların .dat dosya formatına dönüşümü

5.2.2. Filtreleme

Elimizdeki ham sinyal ilk olarak bir bant geçiren filtreden geçirilir. Sinyalin filtreleneğinde 6. dereceden 0,5 Hz – 35 Hz frekans bandını geçiren Butterworth IIR dijital filtre kullanılmıştır. Burada seçilen aralık daha önceden de anlatıldığı gibi delta, teta, alfa ve beta olarak tanımlanan EEG sinyallerinin bulunduğu frekans bandıdır. 0,5 Hz altındaki ve 35 Hz üstündeki frekansların, rutin saçlı deri kayıtları açısından sınırlı bir klinik yararı vardır. Çünkü çoğunlukla bu aktivitenin serebral

kökenli olup olmadığı açık değildir (Fisch 1997, Tükel 1979). Bu filtre Matlab da aşağıdaki alt program ile tasarlanmıştır.

5.2.2.1. Filtreleme alt programı

```
n =6; Wn = [0.5 35]/128;
ftype = 'bandpass';

[b,a] = butter(n,Wn,ftype);
y=filter(b,a,x);
x=y
```

5.2.3. Segmantasyon

Segmantasyon yaklaşık 8 saatlik verinin 30 sn süreler ile parçalanması sağlayan alt program kümesi tarafından yapılır. Parçalanmış her bir 30 sn lik bölüme bir epok denir. EEG sinyallerinin uyku laboratuvarlarında incelenmesi 30 sn lik bu sinyal parçaları üzerinden yapılır. Matlab da segmantasyon şu alt program marifetiyle yapılır.

5.2.3.1. Segmantasyon Alt Programı

```
k=1;
for i=1:3840:h
for j=0:3839
    x_eeg_epok(j+1,k)=x(j+i);
end
k=k+1;
end
x_eeg_epok=x_eeg_epok';
```

5.3. Özellik Çıkarımı

Bu tez çalışmasında EEG verilerinin işlenmesinde, pencereleme ve Welch metodları, kullanılmıştır. Sinyalleri segmentlere ayırmak için kullanılan pencereleme yöntemi ve sinyalin içerdiği frekans bileşenlerini gösteren, güç spektral yoğunluğunu elde edebilmek için kullanılan Welch metodu aşağıda anlatılmıştır.

5.3.1. Zaman domeni özellik çıkarımı

Bir işaretin, incelenebilecek olan ve işareti karakterize eden birçok zaman domeni ölçümü veya parametresi vardır. Bunların en önemlisi işaretin ortalama ve efektif değerleridir.

EEG işaretlerini analiz etmek ve beynin aktiviteleri hakkında bilgi sahibi olmak için frekans domeninde olduğu kadar zaman domeninde de pek çok parametre kullanılmaktadır.

Bu tez çalışmasında zaman domenine ait 6 özellikli uyku içiği veri kümesini elde etmek için istatistiksel ölçümler kullanılmıştır. PSG cihazından elde edilen EEG sinyallerine ait zaman domeni özellikleri Tablo 5.2' de özetlenmiştir. Kullanılan zaman domeni özellikleri: ortalama değer, standart sapma, maksimum tepe değeri, eğrilik, basıklık ve şekil faktörü özellikleridir.

Tablo 5.2 Zaman domeni özellikleri

1.	Ortalama değer: $X_m = \sum_{n=1}^N x(n)N$
2.	Standart sapma: $X_{std} = \sqrt{\frac{\sum_{n=1}^N (x(n) - x_m)^2}{N - 1}}$
3.	Maksimum tepe değeri: $x_p = \max x(n) $
4.	Eğrilik (Skewness): $X_{ske} = \frac{\sum_{n=1}^N (x(n) - x_m)^3}{(N - 1)x_{std}^3}$
5.	Basıklık (Kurtosis): $X_{ske} = \frac{\sum_{n=1}^N (x(n) - x_m)^4}{(N - 1)x_{std}^4}$
6.	Şekil faktörü (Shape factor): $SF = \frac{X_{rms}}{\frac{1}{N} \sum_{n=1}^N \sqrt{ x(n) }}$

Burada, $x(n)$, $n = 1, 2, \dots, N$ için bir zaman serisidir. N ise, veri noktalarının sayısıdır.

5.3.2. Frekans domeni özellik çıkarımı

EEG sinyallerinden frekans domeninde özellik çıkartımı işleminde, Welch metodu pencereleme işleminde ise hamming pencere modeli kullanılmıştır ve Hamming pencere sayısı 128 olarak seçilmiştir. Eşitlik 5.1' de k frekans domenindeki özellik sayısı olmak üzere;

$$k = \frac{nFFT}{2} + 1 \quad (5.1)$$

olduğu için elde edilen özellik sayısı 65 olarak bulunmuştur.

Frekans domenine ait elde ettiğimiz 65 özellikli uyku içiği veri kümesinin boyutunu azaltmak için istatistiksel ölçümler kullanılarak özellik sayımız 4' e

indirilmiştir. Frekans domeni için özellik azaltımında kullanılan ve Tablo 5.3’ de özetlenen istatistiksel özellikler: ortalama değer, standart sapma, maksimum tepe değeri ve minimum değerdir.

Tablo 5.3 Frekans domeni özellikleri

1. Ortalama değeri: $X_m = \sum_{n=1}^N x(n)N$
2. Standart sapma: $X_{std} = \sqrt{\frac{\sum_{n=1}^N (x(n) - x_m)^2}{N - 1}}$
3. Minimum değeri: $x_p = \min x(n) $
4. Maksimum tepe değeri: $x_p = \max x(n) $

5.3.2.1. Welch metodu yardımı ile güç spektrum yoğunluğunun (Power Spectrum Density-PSD) hesaplanması

Spektral analiz bize bir sinyalin frekans içeriği hakkında bilgi verir. Bazı durumlarda, sinyallerin frekans bilgileri, zaman bölgesi çözümünden daha yararlı açılımlar sağlarlar. EEG, EKG, EMG, EOG gibi pek çok biyolojik sinyal, frekans bölgesinde işlendiği zaman, ihtiyacımız olan tanısal bilgileri bize rahatlıkla sağlar. Bir sinyalin spektrumunun başarısı, sinyalin periyodik, sonlu uzunlukta ve gürültüsüz olmasına bağlıdır. Pek çok biyolojik uygulamada, sinyal ya sonsuz uzunlukta yada analiz için yeterli uzunluktadır. Bu her iki durumda biyolojik sinyallerin analizinde problem olabilmektedir. Bunun yanı sıra, biyolojik sinyaller çoğunlukla gürültü ve artefaktlar ile bozulmuşlardır. Oysa gerçek sinyalin bir kısmı analiz edilebilse ve/veya gürültü sinyal boyunca olsa, bütün spektrum analiz yöntemleri mutlaka gerçek spektruma yaklaşır. Farklı spektrum analiz yaklaşımları özel spektral özelliklerin yaklaşım doğruluğunu artırmak için çalışır (Semmlöv 2004).

Genel olarak spektrum yaklaşım yöntemleri iki grupta incelenmektedir. Welch metodunun da içinde bulunduğu, spektral yaklaşım veya parametrik olmayan yaklaşım olarak adlandırılan ilk kategori, spektrumun tamamının şekli ile ilgilenir.

İkinci kategori olan parametrik yaklaşımda ise spektrumun tamamının yanında yerel özelliklerini de dikkate alır (Semmlow 2004).

Autoregressive Model parametrik spektrum yaklaşımının en popüler yöntemlerinden biridir. Parametrik olmayan yöntemlerin Hızlı Fourier Dönüşümüne (HFD) göre avantajları olmakla birlikte kısa veri uzunluklarında sınırlı frekans çözünürlükleri dezavantajları olarak sayılabilir (Ifeachor ve Jervis 2002).

Sonlu enerjisi olmayan ve dolayısıyla Fourier dönüşümü alınamayan, sinyallerin sonlu ortalama güçleri vardır ve güç spektral yoğunluğu ile karakterize edilirler (Proakis ve ark. 1992). Güç spektrum yoğunluğu (PSD) diğer bir deyişle güç spektrumunun en basit şekli periodogram ile ifade edilir. Welch metodu periodogram metoduna yeni düzenlemeler eklenerek elde edilmiş bir yöntemdir. Bu sebeple Welch metodunun daha iyi anlaşılabilmesi için öncelikle periodogram metodu ve Barlett metodunun anlatılması faydalı olacaktır.

5.3.2.1.1. Periodogram metodu

Güç spektrumu temelde otokorelasyon fonksiyonunun Fourier dönüşümü olarak da tanımlanabilir. Sonlu enerjisi olmayan ve dolayısıyla Fourier dönüşümü alınamayan stabil rasgele sinyaller bir ortalama güce sahiptir ve güç spektral yoğunluğu ile karakterize edilirler (Proakis ve ark. 1992). $x(t)$ durağan rastgele bir sinyali göstermektedir ve Eşitlik 5.2' deki gibi tanımlanabilir.

$$x(t) = [X_K] = [X_0, X_1, \dots, X_{N-1}] \quad (5.2)$$

N örnekli $[X_K]$ verisinin periodogramı $(P_{xx}(f))$, $[X_K]$ verisinin Ayrık Fourier Dönüşümünün $(AFD) (F(jw))$ karesi olarak Eşitlik 5.3' deki gibi tanımlanabilir.

$$P_{xx}(f) = |F(jw)|^2 \quad (5.3)$$

Eğer N veri noktası var ise en az N noktada AFD hesaplanır ve $f_K = k/N$ frekansında Eşitlik 5.4' deki gibi tanımlanır..

$$P_{xx}\left(\frac{k}{N}\right) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n) e^{-j2\pi nk/N} \right|^2 \quad k = 0, 1, \dots, N-1 \quad (5.4)$$

Pratik olarak sık örneklenmeyen spektrumlarda sürekli $P_{xx}(f)$ yaklaşımına göre kayda değer bir sonuç elde edilemez. Bu problemin aşılması $P_{xx}(f)$ 'in ek frekanslarda da hesaplanması yoluyla sağlanabilir. Aynı şekilde, sıfır eklemesi yapılarak dizinin uzunluğu arttırılabilir ve daha sonra $P_{xx}(f)$ daha yoğun frekanslarda hesaplanabilir. Böylece veri dizisinin büyüklüğü L noktaya arttırılarak L noktada AFD alınır. Bir sinyale sıfır eklenmiş ve $L > N$ noktada AFD ' si hesaplanmış olması spektral yaklaşımda frekans çözünürlüğünü iyileştirmemektedir. Bu yalnızca daha yüksek frekansta, ölçülen spektrumun interpolasyonunu sağlar. Spektral yaklaşımda, frekans çözünürlüğü $P_{xx}(f)$ veri kaydının N uzunluğu ile tanımlanır (Proakis ve ark. 1992).

5.3.2.1.2. Bartlett metodu

Periyodogramdaki varyansı indirmek için önerilen Bartlett metodu üç adımdan teşekkül etmiştir. Birinci adımda, N noktalı veri dizisi üst üste binmeyen K tane segmente bölünür. Her bir segmentin uzunluğu M olan K tane veri segmenti için veri yapısı:

$$X_i(n) = X(n + iM) \quad i = 0, 1, \dots, K-1 \quad n = 0, 1, \dots, M-1 \quad (5.5)$$

Eşitlik 5.5' deki gibi tanımlanır ve periodogram hesabı her bir segment için ayrı ayrı yapılır.

$$P_{xx}^i(f) = \frac{1}{M} \left| \sum_{n=0}^{M-1} X_i(n) e^{-j2\pi fn} \right|^2 \quad i = 0, 1, \dots, K-1 \quad (5.6)$$

Bartlett güç spektrumun yaklaşımını hesaplamak için ise K tane segmentin periodogramlarının ortalaması alınır (Proakis ve ark. 1992). Eşitlik 5.7 elde edilir.

$$P_{xx}^B(f) = \frac{1}{K} \sum_{i=0}^{K-1} P_{xx}^i(f) \quad (5.7)$$

5.3.2.1.3. Welch metodu (Modifiye edilmiş periodogramların ortalaması)

Welch metodunda Bartlett metoduna göre iki yeni revizyon yapılmıştır. İlk olarak Welch metodunda veri segmentlerinin üst üste binmesine izin verilmektedir. Bundan başka her segmente pencereleme işlemi uygulanmaktadır (Proakis ve ark. 1992). Welch metodunda veri segmentleri Eşitlik 5.8' deki gibi ifade edilebilir.

$$X_i(n) = X(n + iD) \quad i = 0, 1, \dots, L-1 \quad n = 0, 1, \dots, M-1 \quad (5.8)$$

ifadede iD , i . segment için başlangıç noktası olarak verilmiştir. $D=M$ olması halinde segmentlerde üst üste binme yoktur. $D=M/2$ olması halinde ise ardışık veri segmentleri arasında %50 üst üste binme vardır ve $L=2K$ olarak bulunur (Proakis ve ark. 1992). Eğer üst üste binme %50 - %75 civarında olursa, verinin en çok özelliği muhafaza edilmiş olur (Ifeachor ve Jervis 2002).

Welch metodunda Bartlett metoduna göre yapılan ikinci revizyon ise periodogramın hesaplanması için veri segmentlerinin pencerelenmesidir. Sonuç olarak her segment için düzenlenmiş periodogram, Eşitlik 5.9' daki

$$P_{xx}^i(f) = \frac{1}{MU} \left| \sum_{n=0}^{M-1} x_i(n) w(n) e^{-j2\pi f n} \right|^2 \quad i = 0, 1, \dots, L-1 \quad (5.9)$$

ifadeyle tanımlanır. İfadede $w(n)$ pencere fonksiyonu ve U da pencere fonksiyonundaki güç için normalizasyon faktörüdür.

$$U = \frac{1}{M} \sum_{n=0}^{M-1} w(n)^2 \quad (5.10)$$

Welch güç spektrum yaklaşımı, bu revize edilmiş periodogramların ortalamasıdır (Proakis ve ark. 1992). Eşitlik 5.11' de görülmektedir.

$$P_{xx}^w(f) = \frac{1}{L} \sum_{i=0}^{L-1} P_{xx}^i(f) \quad (5.11)$$

Welch yaklaşımının sonucu olarak ulaşılmak istenen değer,

$$E[P_{xx}^w(f)] = \frac{1}{L} \sum_{i=0}^{L-1} E[P_j(f)] = E[P_j(f)] \quad (5.12)$$

Eşitlik 5.12 yardımıyla bulunur. Burada bulunan değer Bartlett metodu ile bulunan değer ile aynıdır. $N \rightarrow \infty$ ve $M \rightarrow \infty$ olursa, bu değer gerçek güç spektral yoğunluğuna yakınsar. İşte bu sebeple büyük N ve M değerleri için Welch güç spektrum yoğunluğu tarafsızdır. Bu koşullar altında Welch metodunun varyansı sıfıra yakınsar (Ifeachor ve Jervis 2002).

Ayrıca Welch metoduna göre $L=K$ durumunda üst üste binme,

$$\text{var}[P_w] \approx \left(\frac{1}{K}\right) P^2(f) \quad (5.13)$$

Eşitlik 5.13' deki gibi ifade edilir. Bu değer aynı koşullar altındaki Bartlett varyansına eşittir. %50 binme olduğu zaman ise aşağıdaki gösterilir. Bu değer Bartlett varyansından daha azdır ve Eşitlik 5.14' deki gibi ifade edilir. (Ifeachor ve Jervis 2002, Proakis ve ark. 1992)

$$\text{var}[P_w] \approx \left(\frac{9}{8L}\right) P^2(f) \quad (5.14)$$

5.3.2.1.4. Welch yöntemi ile frekans domeni özelliklerini bulan alt program kodları

```

for i=1:r,
    x_eeg_epok_1welch(i,:)=pwelch(x_eeg_epok(i,:),128, 64, 128, 128);
end

x_eeg_epok_1welch=x_eeg_epok_1welch';
[q,k]=size(x_eeg_epok_1welch);

for p=1:k,
    eeg_1_feature_7(:,p)=min(x_eeg_epok_1welch(:,p),[],1);
    eeg_2_feature_8(:,p)=max(x_eeg_epok_1welch(:,p),[],1);
    eeg_3_feature_9(:,p)=std(x_eeg_epok_1welch(:,p),0,1);
    eeg_4_feature_10(:,p)=mean(x_eeg_epok_1welch(:,p),1);
end

eeg_1_feature_7=eeg_1_feature_7';
eeg_2_feature_8=eeg_2_feature_8';
eeg_3_feature_9=eeg_3_feature_9';
eeg_4_feature_10=eeg_4_feature_10';

```

5.3.2.2. Pencereleme metodu

Pencereleme işleminin amacı, spektral sızma ve lekelenmelerin zararlı etkilerini uygun bir pencere yardımıyla en aza indirmektir (Semmlow 2004). Bir sinyal sonsuz uzunlukta bir segment de olsa ya periyodiktir ya da periyodik değildir. Bunun yanı sıra benzer dalga şekillerinin sadece belirli bir bölümü sınırlı belleğe sahip bir bilgisayara sunulabilir ve bu durumda da dalganın nasıl parçalara ayrılacağı önem kazanır (Hayes 1996).

En basit haliyle bir segment basitçe bir dalga şeklinden kesilir ve bu bütün veriye rectangular pencerenin uygulanması ile aynıdır. Analiz sadece dalganın pencerelenmiş bölümü ile sınırlıdır. Rectangular dışındaki pencere şekilleri, istenilen şekille dalganın zaman domeninde çarpılmasıdır (Semmlöv 2004).

Bunun yanında pencereleme, hem zaman domeninde (veri pencereleri) hem de frekans domeninde (frekans pencereleri) yapılabilir. Çünkü zaman domeninde çarpma frekans domeninde konvolüsyon işlemi ile aynıdır. Frekans domeninde pencereleme, frekans domeni penceresi ile sinyal spektrumunun konvolüsyonu şeklinde uygulanır (Ifeachor ve Jervis 2002).

Güç spektrumu yönteminde pencere seçimi etkili bir faktördür. Çünkü bir veri seçildiği zaman pencerenin frekans karakteristiği spektral sonucun bir parçası olur. Bütün pencereler iki tip artefakt üretir: analob (mainlob) ve yanlob (sidelob) (Semmlöv 2004). Pencere tarafından üretilen artefakt pencerenin Fourier dönüşümü alınarak bulunabilir. Gerçek spektrum analob denilen artefakt ile genişletilir ve yan lob adı verilen ek pikler üretilir. Eğer işlem, yakın frekans uzayındaki iki dar bantlı sinyalin çözümünde ise en dar bantlı pencere (rectangular) tercih edilir. Bir güçlü ve bir zayıf sinyal söz konusu ise güçlü sinyallerin yan loblarının zayıf sinyaller tarafından yok edilmesini önlemek için hızla azalan yan lobları olan pencereler tercih edilir. Eğer iki tane orta derecede güçlü sinyal var ise (bunlardan biri zayıf sinyale daha yakın diğeri daha uzak olduğu zaman) orta derecede dar analob ve orta derecede zayıflayan loblar en iyi çözümdür. Genellikle bir sinyale hangi tipte pencere uygulanacağını bulması için farklı tipte pencerelerle denemeler yapılması gerekmektedir (Semmlöv 2004). Tablo 5.4' de en sık kullanılan pencere tipleri ve eşitlikleri verilmiştir (Stearns ve David 1988).

Tablo 5.4 Pencere tipleri ve eşitlikleri


<i>Pencere Tipi</i>	<i>Örnek değerleri</i>	<i>K dizisi</i>
Rectangular	$W_k=1$	$0 \leq k \leq N-1$
triangular	$w_k = 1 - \left 1 - \frac{2k}{N-1} \right $	$0 \leq k \leq N-1$
Hanning	$w_k = \frac{1}{2} \left(1 - \cos \frac{2k\pi}{N-1} \right)$	$0 \leq k \leq N-1$
Hamming	$w_k = 0.54 - 0.46 \cos \frac{2k\pi}{N-1}$	$0 \leq k \leq N-1$
Blackman	$w_k = 0.42 - 0.5 \cos \frac{2k\pi}{N-1} + 0.08 \cos \frac{4k\pi}{N-1}$	$0 \leq k \leq N-1$

5.3.2.2.1. Pencereleme işlemi

Bant geçiren filtre'den geçen EEG sinyallerinin her biri çerçevelere bölünür. Bu çalışmada pencereleme işleminde hamming pencereleme metodu kullanılmıştır. Eşitlik 5.15' de Hamming pencereleme metoduna ait eşitlik verilmiştir.

$$W_n = \begin{cases} 0.54 - 0.46 * \cos(2 * \pi * n / (N - 1)) & 0 \leq n < N \\ 0 & \text{yada} \end{cases} \quad (5.15)$$

Şekil 5.7' de 128 pencereye ayrılmış Spindle bulunan EEG sinyalinin Welch yöntemi sonucu güç spektrum yoğunluğu görülmektedir. Burada bulunan pikler spindle olarak belirtilen frekans aralığında bileşenler olduğunu yani bu epok üzerinde spinle bulunduğunu gösteriyor.



Şekil 5.7 128 pencereye ayrılmış Spindle bulunan EEG sinyalinin Welch yöntemi sonucu güç spektrum yoğunluğu

5.3.3. Özellik azaltımı

YSA için giriş vektörünün seçimi, gerçekten önemli bir konudur. Girişler kötü seçildiğinde kullanılan bu kötü girişlerle, en iyi sınıflandırıcı bile beklenen performansı göstermeyebilir. Bu nedenle sınıflandırılacak veriyi en iyi temsil edecek şekilde YSA' nın giriş vektörlerinin seçimi yapılmalıdır (Güler ve Übeyli 2005).

Özellik seçme ve boyut azaltımı yöntemleri; veri kümesinde bulunan ilgisiz veya gereksiz özellikleri uzaklaştırmak ve veri dağılımını daha uygun ve ayrıştırılabilir bir hale getirmek için uygulanır. Bu sayede, sınıflandırıcının hem hesaplama maliyeti azalmaktadır hem de sınıflama performansı artmaktadır.

Bu çalışmada özellik azaltımı EEG sinyallerinin frekans domeni özellikleri üzerinde istatistiksel ölçümler kullanılarak yapılmıştır.

5.4. Yapay Sinir Ağları Kullanılarak Uyku İğciklerinin Sınıflandırılması

Bu kısımda hastadan alınan ve işlenebilir veriler haline getirilen kayıtların, çeşitli metodlarla işlendikten sonra akış diyagramında son kısım olan sınıflama aşaması anlatılacaktır. Öncelikle sınıflandırmada kullanılan yapay sinir ağları hakkında bilgi verilerek sınıflamanın safhaları anlatılacaktır.

5.4.1. Yapay sinir ağları

Pek çok tanımı bulunan yapay sinir ağları basit olarak, beyindeki sinirlerin çalışmasından esinlenilerek sistemlere öğrenme, hatırlama, bilgiler arasında ilişkiler oluşturma gibi yetenekleri kazandırmayı amaçlayan bilgi işleme algoritmalarıdır.

Yapay sinir ağında hesaplamalar, öğrenme adı verilen süreçle yapılmaktadır. İyi bir başarımlı elde edebilmek için, sinir hücresi, nöron veya işleme birimi adı verilen, basit hesaplama hücreleri arasında uygun bağlantılar kullanılır. Nöronlar, bağlantılar üzerinden işaret göndererek birbirlerini etkiler. Bu bağlantıların herbirinin kendine özgü bir ağırlık katsayısı vardır. Uyarlamalı hesaplanabilen bu ağırlıklar, bilgiyi, doğru olarak bildirir. Genellikle bilgi, ağ boyunca dağıldığı için, bağlantı ağırlıklarını önceden belirlemek mümkün değildir. Bu sebeple, ağırlıkların değiştirileceği bir öğrenme işlemi gereklidir. Haykin (1999) tarafından yapılan tanımda; “ Bir sinir ağı, basit işlem birimlerinden oluşan, deneyimsel bilgileri biriktirmeye yönelik doğal bir eğilimi olan ve bunların kullanılmasını sağlayan yoğun bir şekilde paralel dağıtılmış bir işlemcidir.” denilir.

Bu işlemcinin beyin ile benzerlik gösteren iki özelliği vardır:

1. Bilgi, ağ tarafından bir öğrenme süreciyle çevreden elde edilir.
2. Elde edilen bilgileri biriktirmek için sinaptik ağırlıklar olarak da bilinen nöronlar arası bağlantı güçleri kullanılır (Yurtoğlu, 2005).

Ağın bilgiyi ortamdaki almasını sağlayan öğrenme işlemi, öğrenme algoritması adıyla bilinen, ağın sinaptik ağırlıklarını güncelleyerek istenen modele ulaşılmasını

sağlayan fonksiyonlardır. Öğrenme işlemi üç tiptir: eğitici öğrenme, eğitici öğrenme ve özdenetimli öğrenme. Bu öğrenme şekilleri, ağdaki ağırlıkları eğitmek için hata işareti kullanılarak tanımlanır. Eğitici öğrenmede, ortamın dışından bir eğitici, her çıkış nöronu için hata üretir. Eğitici öğrenmede, hata işareti üretilmez, bunun yerine, ağırlıkları değiştirmek için kullanılmak üzere, nöronlar arasındaki hatalar üretilir. Özdenetimli öğrenmede ise sistem, girişlerin istatistiksel düzenini belirledikten sonra, sınıflamayı başaracak beceriyi oluşturur.

Eğitici öğrenmede, nöronları birleştiren ağırlıklar, eğitici tarafından ayrıntılı hata bilgileri ağı uygulanacak şekilde yerleştirilirler. Pek çok durumda ağ, giriş-çıkış çiftleri kullanılarak eğitilir. Bu öğrenme işleminin performansı, eğitim kümesi kullanılarak istenen sonuca ulaşılabilmesi ve eğitilen ağın genelleştirilebilmesiyle ölçülür.

5.4.1.1. Çok katmanlı algılayıcı yapay sinir ağları

Yapay sinir ağları, hücrelerin birbirleri ile çeşitli şekillerde bağlanmalarından oluşur. Hücre çıkışları, ağırlıklar üzerinden diğer hücrelere ya da kendilerine giriş olarak bağlanabilir ve bağlantılarda gecikme birimi de kullanılabilir. Hücrelerin bağlantı şekillerine, öğrenme kurallarına ve aktivasyon fonksiyonlarına göre çeşitli YSA yapıları geliştirilmiştir .

Geri yayılma ile eğitilen çok katmanlı algılayıcı (Rumelhart ve McClelland, 1986), yapay sinir ağı sınıflandırıcıları içinde en ünlüsü ve en yaygın kullanılanıdır. Lineer olmayan aktivasyon fonksiyonlu ve tek gizli katmanlı ağların en çok kabul gören sınıflandırıcıları olduğu bilinmektedir. Doğru biçimde eğitildiklerinde, herhangi bir örüntüyü belirleyen özellik kümesini giriş vektörü olarak alıp, istenilen sınıflandırmayı yapabilecek güce sahiptirler. Çok Katmanlı Algılayıcı (ÇKA) Sinir Ağları çok çeşitli tanıma ve tahmin görevlerini yerine getirmek için kullanılan parametrik olmayan tekniklerdir (Haykin 1994, Basheer ve Hajmeer, 2000, Chaudhuri ve Bhattacharya, 2000). Öğrenme ve genelleme yeteneği, düşük eğitim gereksinimleri, eğitimden sonra hızlı işlem yapabilme ve kolay gerçekleştirim gibi özelliklere sahiptirler. Bir ÇKA Sinir Ağı, giriş değişkenlerini temsil eden düğümlere

sahip giriş katmanı farklı sınıflara temsil eden çıkış katmanı ve verilerdeki doğrusal dışılığı yakalamak için düğümler içeren bir veya daha fazla gizli katmandan oluşur. Gizli katmandaki her j düğümü, kendilerine gelen her x_i sinyalinin ilgili w_{ji} ağırlığıyla çarptıktan sonra toplayarak çıkış değerini Eşitlik 5.16' daki toplam fonksiyonu ile hesaplar (Sağıroğlu 2003).

$$y_j = f(\sum w_{ji} x_i) \quad (5.16)$$

Yukarıdaki eşitlikde f , düğüme gelen tüm sinyallerin ağırlıklı toplamını bir çıkış değerine dönüştüren aktivasyon fonksiyonudur.

Aktivasyon fonksiyonu olarak kullanılabilecek birkaç seçenek vardır. Bu tez çalışmasında Sigmoid fonksiyon kullanılmıştır. Bu fonksiyon Eşitlik 5.17' de görülüyor.

$$f(net_i) = \frac{1}{1 + e^{\frac{-net_i}{Q_0}}} \quad (5.17)$$

Eşitlik 5.17' de Q_0 terimi, sinir hücresinin sıcaklık değeridir. Sıcaklık ne kadar büyükse, Sigmoid fonksiyonu o kadar yavaş olur. Çok küçük sıcaklıklarda ise bir adım fonksiyonuna dönüşür.

Giriş örüntülerinin uygun sınıflandırılması için gerekli bilgi, ağırlıklar tarafından tutulur. İlk başta, belirli bir problem için ağırlıklar bilinmez. Uygun ağırlıklar bilinmediği sürece ağ hiçbir zaman sorunu çözemez. Uygun ağırlıkları bulma işlemine eğitime denir. Eğitime işlemi, bir grup giriş vektörüne karşılık gelen uygun sınıfların ağa verilmesiyle gerçekleşir. Bu şekilde, her giriş vektörüne karşılık beklenen çıkışların ağa verilmesi işlemine öğretici yardımıyla eğitime denir (Sağıroğlu 2003).

Ağın eğitilmesi işlemi, eğitime setindeki vektörlerin yanlış sınıflandırılması oranı belirli bir sınır değerinin altına ininceye kadar devam eder. Ağ, gerçekte ona öğretildiğinden başka bir problemi çözemez. Eğer eğitime kümesi iyi seçilmişse ve

eğitme algoritması etkinse, ağ eğitme seti dışındaki verilere de belli oranda doğru olarak sınıflandırılabilir. Bu kavram ağın genelleme yeteneği olarak bilinir.

Yapay sinir ağlarının tanıma işleminde kullanılması iki aşamada düşünülebilir. Eğitim aşamasında, ağ ağırlıkları problem kümesinin özelliklerini yansıtacak şekilde adapte edilir. İkinci aşama test aşamasıdır ve ağırlıklar eğitme işleminin sonundaki değerlerini korur. Ağa eğitme setinden farklı test verileri yüklenir ve bir sınıflandırma yapması beklenir.

Bir ağı eğitme işlemi, önceden tespit edilmiş beklenen bir değere ulaşana kadar devam eder. Bu bizi ağın toplam hatası kavramına götürür. Öğretici yardımıyla eğitmede, elimizdeki eğitme seti için beklenen değeri bilmemiz gerekir. Bu yüzden eğitme setinin uygun seçimi, başarılı bir sınıflandırma işlemi için çok önemlidir. Eğitim seti uygun boyda olmalı ve problem uzayını tam olarak yansıtmalıdır (Sağıroğlu 2003).

Geri yayımlı eğitim algoritmasında, ortalama kare hatası (mean squared error) olarak bilinen hata kriteri olabilir (Rumelhart ve McClelland 1986). Aslında bu fonksiyon tek hata kriteri değildir. Sürekli ve diferansiyel başka bir hata fonksiyonu da kullanılabilir. Fakat başka fonksiyon seçerken dikkatli olunmalıdır, çünkü bu yeni fonksiyon işlemlere ek yük getirebilir. Ayrıca seçilen fonksiyon, beklenen ve gerçekte oluşan çıkış değerleri arasında anlamlı bir fark ölçümü sağlamalıdır. Ortalama kare hatası fonksiyonu Eşitlik 5.18' deki gibi tanımlanır.

$$E_p = \frac{1}{2} \sum_{j=1}^N (t_{pj} - O_{pj})^2 \quad (5.18)$$

Burada, E_p , p vektör için hatayı, t_{pj} j sinir hücresi için beklenen değeri (yani eğitim setindeki ilgili çıkış değerini) ve O_{pj} , j çıkış düğümünün gerçek değerini göstermektedir. Hataların karesini almakla, beklenen değerden uzakta olan çıkış değerlerinin toplam hatayı oluşturması sağlanmaktadır. Eğer üssü daha çok büyütürsek, bu etki daha da artacaktır.

5.4.1.2. Levenberg – Marquardt algoritması

Geriye yayılım algoritması, yapay sinir ağlarında en çok kullanılan algoritmadır. Geriye yayılım öğrenmesi sırasında ağ, her giriş örüntüsünü, çıkış nöronlarında sonuç üretmek üzere gizli katmanlardaki nöronlardan geçirir. Daha sonra çıkış katmanındaki hataları bulabilmek için, beklenen sonuçla, elde edilen sonuç karşılaştırılır. Bundan sonra, çıkış hatalarının türevi çıkış katmanından geriye doğru gizli katmanlara geçirilir. Hata değerleri bulunduktan sonra, nöronlar kendi hatalarını azaltmak için ağırlıklarını ayarlar. Ağırlık değiştirme eşitlikleri, ağdaki performans fonksiyonunu en küçük yapacak şekilde düzenlenir.

İleri beslemeli ağlarda kullanılan öğrenme algoritmaları, performans fonksiyonunu en küçük yapacak ağırlıkları ayarlayabilmek için, performans fonksiyonunun gradyenini kullanırlar. Geriye yayılım algoritması da, ağ boyunca gradyen hesaplamalarını geriye doğru yapar. En basit geriye yayılım öğrenme algoritması gradyen azalması algoritmasıdır. Bu algoritmada ağırlıklar, performans fonksiyonunun azalması yönünde ayarlanır. Fakat bu yöntem, pekçok problem için çok yavaş kalmaktadır. Bu algortmadan daha hızlı, daha yüksek performanslı algoritmalar da vardır.

Hızlı algoritmalar genel olarak iki kategoriye ayrılabilir. İlk kategorideki algoritmalar, deneme yanılma tekniklerini kullanarak, standart gradyen azalması (steepest descent) yönteminden daha iyi sonuçlar verebilir. Deneme-yanılma işlemlerini kullanan geriye yayılım algoritmaları; momentum terimli geriye yayılım, öğrenme hızı değişen geriye yayılım ve esnek geriye yayılım algoritmalarıdır. Hızlı algoritmaların ikinci kategorisindeki algoritmalar, standart sayısal optimizasyon yöntemlerini kullanır. Bu algoritmalar; eşlenik gradyen öğrenme algoritması, Newton öğrenme algoritmaları ve Levenberg – Marquardt öğrenme algoritmasıdır.

Öğrenme algoritmaları, kendisinden önce geliştirilen algoritmalara alternatif olarak ortaya çıkmıştır ve önceki algoritmaların iyi yönlerini geliştirip, kötü yönlerini azaltmaya yönelmiştir. Levenberg – Marquardt algoritması da, Newton ve Gradyen Azalması algoritmalarının en iyi özelliklerinden oluşur ve kısıtlamalarını ortadan kaldırır.

Eşlenik gradyen öğrenme algoritmasına alternatif olarak sunulan Newton yöntemlerinde, temel adım Hessian matrisini elde etmektir. Hessian matrisi, performans fonksiyonunun ağırlıklara göre ikinci dereceden türevlerinden oluşan bir matristir. Hessian matrisi, ağırlık uzayının farklı doğrultularındaki gradyen değişimini gösterir.

$$H(n) = \frac{\partial^2 E(n)}{\partial w^2(n-1)} \quad (5.19)$$

Burada H Hessian matrisi, E performans fonksiyonu, w ağın sinaptik ağırlığıdır. Performans fonksiyonu, duruma göre toplam ani hata veya ortalama karesel hata olarak alınabilir.

$$E(n) = E_{ort}(n) = \frac{1}{N} \sum_{n=1}^N \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (5.20)$$

Burada N eğitim kümesindeki toplam örüntü sayısını, e_j hata işaretini, C ağıın çıkış katmanındaki bütün nöronları içeren kümeyi göstermektedir. d_j istenen değer, y_j ağıın çıkışı olmak üzere hata işareti,

$$e(n) = d_j(n) - y_j(n) \quad (5.21)$$

olarak bulunabilir. Hessian matrisi hesaplandıktan sonra, tersi bulunarak ağırlıklar yenilenebilir. Ancak Hessian matrisi çok karmaşık ve ileri beslemeli bir yapay sinir ağı için hesaplanması zor bir matristir. Newton yöntemlerinin içinde, ikinci dereceden türevlerin hesaplanmadan işlem yapılan bir sınıf vardır. Bu sınıftaki yöntemler, Quasi-Newton yöntemleri olarak adlandırılırlar. Quasi-Newton yöntemleri, algortimanın heriterasyonunda, Hessian matrisinin yaklaşık bir şeklini kullanır.

Levenberg-Marquardt algoritması da Quasi-Newton yöntemleri gibi, Hessian matrisinin yaklaşık değerini kullanır. Levenberg-Marquardt algoritması için Hessian matrisinin yaklaşık değeri şu şekilde bulunabilir:

$$H(n) = J^T(n)J(n) + \mu I \quad (5.22)$$

Eşitlik 5.22’ da μ Marquardt parametresi, I ise birim matristir. Burada J matrisi, Jakobien matrisi olarak adlandırılır ve ağ hatalarının ağırlıklara göre birinci türevlerinden oluşur:

$$J(n) = \frac{\partial e(n)}{\partial w(n-1)} \quad (5.23)$$

Eşitlik 5.23’ de e , ağ hataları vektörüdür. Jakobien matrisi, hesaplamada Hessian matrisinden daha kolay olduğu için tercih edilir. Ağın gradyeni,

$$g(n) = J^T(n)e(n) \quad (5.24)$$

olarak hesaplanır ve ağırlıklar Eşitlik 5.24’ e göre değiştirilir:

$$w(n+1) = w(n) - [H(n)]^{-1} g(n) \quad (5.25)$$

Marquardt parametresi, μ , skaler bir sayıdır. Eğer μ sıfırsa, bu yöntem yaklaşık Hessian matrisini kullanan Newton algoritması; eğer μ büyük bir sayı ise, küçük adımlı gradyen azalması yöntemi haline gelir. Newton yöntemleri, en küçük hata yakınlarında daha hızlı ve kesindir. Her başarılı adımdan sonra, yani performans fonksiyonunun azalmasında μ azaltılır ve sadece deneme niteliğindeki bir adım performans fonksiyonunu yükseltecekse μ arttırılır. Bu yöntemle, algoritmanın her iterasyonunda, performans fonksiyonu daima azaltılır.

Genel olarak Levenberg – Marquardt algoritması yavaş yakınsama probleminde etkilenmez. Burada hedef, performans fonksiyonunun en küçük yapacak ağırlık değerini bulmaktır (M. Oğuz 2001, S. H. Ngia 2000).

5.4.2. Yapay sinir ağlarının eğitilmesi

Yapay sinir ağlarında işlemci elemanlar arasındaki bağlantıların ağırlık değerlerinin değiştirilmesi işlemi “*ağın eğitilmesi*” olarak tanımlanır. Başlangıç aşamasında rastgele atanan bu ağırlık değerleri, ağa gösterilen örneklerle değiştirilmektedir. Burada hedeflenen, ağa gösterilen örnekler için doğru çıktıları üretecek ağırlık değerlerinin bulunmasıdır. Yapay sinir ağlarının eğitilmesinde kullanılan girdi ve çıktı çiftlerinden oluşan veri kümesine “*eğitim seti*” denilmektedir (Baş 2006).

Yapay sinir ağlarının eğitimi, belli kurallar dahilinde yapılmaktadır. Bu kurallara öğrenme kuralları adı verilmektedir. Ağırlıklar öğrenme kurallarına göre değiştirilir. Bir yapay sinir ağında ağırlıkların doğru değerlere ulaşması, çözüm aranan problem konusunda ağın genellemeler yapabilme yeteneğini kazanması olarak ifade edilir. Genelleme, yapay sinir ağının eğitiminde kullanılmamış, ancak aynı evrenden gelen girdi-çıkı örneklerini doğru sınıflandırabilme yeteneği olarak tanımlanır. Ağın genelleme kabiliyetini kazanması işlemine “*ağın öğrenmesi*” denir (Baş 2006).

Yapay sinir ağlarında öğrenmenin iki aşaması vardır. Birinci aşamada ağa gösterilen örnek için ağın üreteceği çıktı belirlenir. Bu çıktı değerinin doğruluk derecesine göre, ikinci aşamada ağın bağlantılarının sahip olduğu ağırlıklar değiştirilir. Ağın çıktısının belirlenmesi ve ağırlıkların değiştirilmesi öğrenme kuralına bağlı olarak farklı biçimlerde olmaktadır (Baş 2006).

Bir yapay sinir ağının eğitim aşaması bittikten sonra, ağın öğrenip öğrenmediğini yani ağın performansını ölçmek için denemeler yapılarak ağın test edilmesi gerekmektedir. Bir yapay sinir ağının test edilmesi için ağın eğitimi sırasında görmediği, veri seti içerisinde eğitimden arta kalan diğer bir ifadeyle test amaçlı olarak ayrılan örnekler kullanılır. Test amaçlı olarak ayrılan bu örnekler “*test seti*” adını verilir. Test işleminde ağın ağırlık değerleri değiştirilmemektedir. Örnekler ağa gösterilmekte ve ağ eğitimi sırasında belirlenen ağırlık değerlerini kullanarak daha önce görmediği bu örnekler için çıktılar üretmektedir. Elde edilen çıktıların doğruluk dereceleri ağın öğrenmesi hakkında bilgi vermektedir. Sonuç ne kadar iyi olursa eğitimin performansı da o kadar iyi demektir (Öztemel, 2003).

Eğitim ve test setlerinin oluşturulmasında yeterli eğitim ve test verisi miktarının ne olması gerektiği önemli bir ayrıntıdır. Eğer veri bulma problemi yoksa , yapay sinir ağı mümkün olduğu kadar çok veriyle eğitilmelidir. Eğitim verisinin yeterli olup olmadığı konusunda test etmek için eğitim verisi miktarı artırılarak, bunun ağı performansında bir değişikliğe sebep olup olmadığına bakılır. Ancak bunun mümkün olmadığı durumlarda yapay sinir ağının eğitim ve test verileri üzerindeki performansının yakın olması da verilerin yeterli olduğuna ilişkin bir gösterge olarak kabul edilebilir. Bununla birlikte eğitim setinin içermesi gereken veri miktarı değişik yapay sinir modellerine ve özellikle problemin gösterdiği karmaşıklığa göre farklılık göstermektedir (Baş 2006).


5.5. Tez Çalışmasında Önerilen YSA Modeli

Bu tez çalışmasında; geriye yayılım (back-propagation) algoritmasının bir türü olan Levenberg – Marquardt algoritmasına dayanan ve danışmalı öğrenme metodu kullanılan bir YSA modeli önerilmiştir.

Bu tez çalışmasının yapay sinir ağlarının eğitilmesi aşamasında EEG sinyallerinden elde edilen veri kümeleri, 3 ayrı hastadan alınan spindle bulunan 361 epok, spindle bulunmayan 361 epok olmak üzere toplam 722 epoktan oluşmaktadır. Çalışmada spindle bulunan ve spindle bulunmayan epoklara ait verilerin yarısı eğitime diğer yarısı ise test verisi olarak kullanılmıştır. Sınıflandırma aşamasında gizli katmandaki düğüm sayısı 1, 5, 8, 10, 15, 20 ve 25 olarak ayrı ayrı test edilmiş, bu şekilde eğitilmiş olan sistemin sınıflama doğrulukları, hassasiyet ve seçicilik değerleri ayrı ayrı hesaplanmıştır. Sonuç olarak en yüksek sınıflama doğruluğunun hangi gizli düğüm sayısı ile elde edildiği bulunmuş ve sistem bu model üzerine tasarlanmıştır.

Aşağıda Şekil 5.8’ de zaman domenindeki veriler üzerinde sınıflama yapan ve en yüksek sınıflama doğruluğu elde ettiğimiz 10 tane gizli düğüm sayısına sahip YSA modelinin basit yapısı görülmektedir. Bu modelde zaman domenine ait 6 adet

giriş, gizli katman ve spindle var veya spindle yok olarak sonuç veren 2 adet çıkış bulunmaktadır.




Şekil 5.8 Zaman domeni için tasarlanan ve en yüksek sınıflama doğruluğu elde edilen YSA Mimarisi

6. DENEYSEL SONUÇLAR

Bu tez çalışmasında, Selçuk Üniversitesi Meram Tıp Fakültesi Göğüs Hastalıkları Anabilim Dalı Uyku Laboratuvarı Bölümü' ne uyku rahatsızlıkları sebebiyle başvuran üç ayrı hastadan alınan 361 adet spindle bulunan epok, 361 adet spindle bulunmayan epok olmak üzere toplam 722 epoktan oluşan veri kümesi üzerinde çalışılmıştır.


Çalışmada spindle bulunan ve spindle bulunmayan epoklara ait verilerin yarısı eğitime diğer yarısı ise test verisi olarak kullanılmıştır. Sınıflandırma aşamasında gizli katmandaki düğüm sayısı 1, 5, 8, 10, 15, 20 ve 25 olarak ayrı ayrı test edilmiş, bu şekilde eğitilmiş olan sistemin sınıflama doğrulukları, hassasiyet ve seçicilik değerleri ayrı ayrı hesaplanmıştır. Sonuç olarak en yüksek sınıflama doğruluğunun hangi düğüm sayısı ile elde edildiği bulunmuş ve yapay sinir ağı mimarisi bu şekilde oluşturulmuştur.

Şekil 6.1' de çalışmada kullandığımız spindle bulunan 1 epokluk (30 saniyelik) EEG işareti görülmektedir.



Şekil 6.1 Spindle bulunan 1 Epokluk (30 saniyelik) EEG işareti

Şekil 6.2’ de ise spindle bulunmayan 1 epokluk (30 saniyelik) EEG işareti görülmektedir.



Şekil 6.2 Spindle bulunmayan 1 Epokluk (30 saniyelik) EEG işareti

Zaman ve frekans domeni özellikleri çıkartılarak yapay sinir ağlarıyla yarı eğitim yarı test verisi olarak kullanılmak şartıyla eğitime ve sınıflandırma işlemine tabi tutulan veriler performans kriterleri açısından incelenerek şu sonuçlara varılmıştır.

6.1. Performans Kriterleri

Herhangi bir modelin test performansı sınıflama doğruluğu (CA), belirlilik (specificity-SPE) ve hassasiyet (sensitivity-SEN) ile hesaplanabilmektedir. Bu analizlerin yapılabilmesi için ağın ürettiği çıkış ile uzman görüşüyle belirlenmiş

hedef çıkış değerleri aşağıda verilen kriterlere göre değerlendirilir (Tarrasenko ve ark. 1998, Dirgenali ve Kara 2006).

Karmaşıklık Matrisi: Gerçek değerler ile sistemin ürettiği çıkış değerlerini gösteren bir matristir. Örnek bir karmaşıklık matrisi Tablo 6.1’ de gösterilmektedir.

Tablo 6.1 Karmaşıklık matrisi

<i>Karmaşıklık matrisi</i>	<i>Negatif</i>	<i>Pozitif</i>
<i>Negatif</i>	<i>Doğru Negatif (DN)</i>	<i>Yanlış Pozitif (YP)</i>
<i>Pozitif</i>	<i>Yanlış Negatif (YN)</i>	<i>Doğru Pozitif (DP)</i>

a) Doğru pozitif (DP): Uzman tarafından hastalıklı olarak işaretlenen epok, YSA tarafından da hastalıklı olarak bulunmuştur.

b) Doğru negatif (DN): Uzman tarafından normal olarak işaretlenmiş epok, YSA tarafından da normal olarak bulunmuştur.

c) Yanlış pozitif (YP): Uzman tarafından normal olarak tanımlanmış epok, YSA tarafından hastalıklı olarak bulunmuştur.

d) Yanlış negatif (YN): Uzman tarafından hastalıklı olarak tanımlanmış epok, YSA tarafından normal olarak tespit etmiştir.

Bulunan bu kriterlere bağlı olarak sınıflama doğruluğu (CA), belirlilik (SPE) ve hassasiyet (SEN) Eşitlik 6.1, 6.2 ve 6.3’ e göre hesaplanır

6.1.1. Sınıflama doğruluğu (CA)

Sınıflandırma işleminin tamamlanmasının ardından, sonuç ürünün doğruluğunun belirlenmesi gerekir. Burada sınıflandırma doğruluğu ortaya çıkar.

Sınıflama doğruluğu sınıflandırma sonuçları ile kontrol alanları karşılaştırılarak elde edilir. Eşitlik 6.1 kullanılarak sınıflama doğruluğu bulunur.

$$CA(\%) = \frac{DP + DN}{DP + DN + YP + YN} \quad (6.1)$$

6.1.2. Hassasiyet (SEN)

Sınıflandırıcının hastalıklı veriyi tespit etme yeteneğidir. Hassasiyet Eşitlik 6.2 uyarınca hesaplanır.

$$SEN(\%) = \frac{DP}{(DP + YN)} \times 100 \quad (6.2)$$

6.1.3. Seçicilik (SPE)

Sınıflandırıcının normal veriyi tespit etme yeteneğidir. Seçicilik 6.3 deki eşitlik yardımıyla hesaplanır.

$$SPE(\%) = \frac{DN}{(DP + YP)} \times 100 \quad (6.3)$$

6.2. Elde Edilen Test Sonuçları

Karmaşıklık matrislerine ait veriler ve elde edilen sonuçlar her bir hasta için aşağıdaki gibi bulunmuştur.

Zaman domeninde Hasta 1' e ait karmaşıklık matrisi Tablo 6.2' de verilmiştir.

Tablo 6.2 Zaman domeninde Hasta 1' e ait karmaşıklık matrisi

Gerçek/Tahmin edilen	Spindle	Non-spindle	Gizli katmandaki düğüm sayısı
Spindle	31	0	1
Non-spindle	0	31	
Spindle	18	13	5
Non-spindle	20	11	
Spindle	31	0	8
Non-spindle	0	31	
Spindle	31	0	10
Non-spindle	0	31	
Spindle	31	0	15
Non-spindle	0	31	
Spindle	31	0	20
Non-spindle	0	31	
Spindle	31	0	25
Non-spindle	0	31	

Frekans domeninde Hasta 1' e ait karmaşıklık matrisi Tablo 6.3' de verilmiştir.

Tablo 6.3 Frekans domeninde Hasta 1' e ait karmaşıklık matrisi

Gerçek/Tahmin edilen	Spindle	Non-spindle	Gizli katmandaki düğüm sayısı
Spindle	29	2	1
Non-spindle	18	13	
Spindle	31	0	5
Non-spindle	28	3	
Spindle	31	0	8
Non-spindle	29	2	
Spindle	28	3	10
Non-spindle	11	20	
Spindle	31	0	15
Non-spindle	29	2	
Spindle	30	1	20
Non-spindle	0	31	
Spindle	30	1	25
Non-spindle	21	10	

Zaman ve Frekans domeninde Hasta 1'e ait karmaşıklık matrisi Tablo 6.4' de verilmiştir.

Tablo 6.4 Zaman ve Frekans domeninde Hasta 1' e ait karmaşıklık matrisi

Gerçek/Tahmin edilen	Spindle	Non-spindle	Gizli katmandaki düğüm sayısı
Spindle	27	4	1
Non-spindle	0	31	
Spindle	22	9	5
Non-spindle	29	2	
Spindle	27	4	8
Non-spindle	8	23	
Spindle	28	3	10
Non-spindle	1	30	
Spindle	29	2	15
Non-spindle	1	30	
Spindle	30	1	20
Non-spindle	0	31	
Spindle	31	0	25
Non-spindle	1	30	

Hasta 1' e ait kayıtlarda yapay sinir ağıları kullanılarak zaman ve frekans domenlerinde sleep spindlların sınıflandırılması sonucu elde edilen sonuçlar Tablo 6.5' de verilmiştir.

Tablo 6.5 Yapay sinir ağıları kullanılarak zaman ve frekans domenlerinde sleep spindlların sınıflandırılması sonucu elde edilen sonuçlar (Hasta 1)

Kullanılan Özellik Kümesi	Gizli Katmandaki Düğüm Sayısı	Performans Ölçüm Kriteri		
		Sınıflama Doğruluğu (%)	Hassasiyet (%)	Seçicilik (%)
Zaman domeni özellikleri	1**	100	100	100
	5	46,77	47,36	45,83
	8**	100	100	100
	10**	100	100	100
	15**	100	100	100
	20**	100	100	100
	25**	100	100	100
Frekans domeni özellikleri	1	67,74	61,70	86,67
	5	54,83	52,54	100
	8	53,22	51,66	100
	10	77,41	71,79	86,96
	15	53,22	51,66	100
	20**	98,38	100	96,88
	25	64,51	58,82	90,91
Hem zaman hem frekans domeni özellikleri	1	93,55	100	88,57
	5	38,70	43,13	18,18
	8	80,64	77,14	85,19
	10	93,54	96,55	90,91
	15	95,16	96,67	93,75
	20**	98,38	100	96,88
	25**	98,38	96,88	100

NOT: Test işleminde 31 spindle ve 31 non spindle içeren veri kullanılmış ve en iyi performans ** ile işaretlenmiştir.

Zaman domeninde Hasta 2' ye ait karmaşıklık matrisi Tablo 6.6' da verilmiştir.

Tablo 6.6 Zaman domeninde Hasta 2' ye ait karmaşıklık matrisi

Gerçek/Tahmin edilen	Spindle	Non-spindle	Gizli katmandaki düğüm sayısı
Spindle	125	0	1
Non-spindle	0	125	
Spindle	125	0	5
Non-spindle	0	125	
Spindle	115	10	8
Non-spindle	0	125	
Spindle	125	0	10
Non-spindle	0	125	
Spindle	124	1	15
Non-spindle	0	125	
Spindle	122	3	20
Non-spindle	0	125	
Spindle	118	7	25
Non-spindle	5	120	

Frekans domeninde Hasta 2' ye ait karmaşıklık matrisi Tablo 6.7' de verilmiştir.

Tablo 6.7 Frekans domeninde Hasta 2' ye ait karmaşıklık matrisi

Gerçek/Tahmin edilen	Spindle	Non-spindle	Gizli katmandaki düğüm sayısı
Spindle	125	0	1
Non-spindle	125	0	
Spindle	124	1	5
Non-spindle	125	0	
Spindle	125	0	8
Non-spindle	125	0	
Spindle	125	0	10
Non-spindle	125	0	
Spindle	125	0	15
Non-spindle	125	0	
Spindle	115	10	20
Non-spindle	30	95	
Spindle	125	0	25
Non-spindle	125	0	

Zaman ve Frekans domeninde Hasta 2' ye ait karmaşıklık matrisi Tablo 6.8' de verilmiştir.

Tablo 6.8 Zaman ve Frekans domeninde Hasta 2' ye ait karmaşıklık matrisi

Gerçek/Tahmin edilen	Spindle	Non-spindle	Gizli katmandaki düğüm sayısı
Spindle	125	0	1
Non-spindle	0	125	
Spindle	125	0	5
Non-spindle	0	125	
Spindle	114	11	8
Non-spindle	0	125	
Spindle	96	29	10
Non-spindle	1	124	
Spindle	121	4	15
Non-spindle	1	124	
Spindle	117	8	20
Non-spindle	2	123	
Spindle	84	41	25
Non-spindle	3	122	

Hasta 2' ye ait kayıtlarda yapay sinir ağıları kullanılarak zaman ve frekans domenlerinde sleep spindlların sınıflandırılması sonucu elde edilen sonuçlar Tablo 6.9' da verilmiştir.

Tablo 6.9 Yapay sinir ağıları kullanılarak zaman ve frekans domenlerinde sleep spindlların sınıflandırılması sonucu elde edilen sonuçlar (Hasta 2)

Kullanılan Özellik Kümesi	Gizli Katmandaki Düğüm Sayısı	Performans Ölçüm Kriteri		
		Sınıflama Doğruluğu (%)	Hassasiyet (%)	Seçicilik (%)
Zaman domeni özellikleri	1**	100	100	100
	5**	100	100	100
	8	96	100	92,59
	10**	100	100	100
	15	99,6	100	99,21
	20	98,8	100	97,66
	25	95,2	95,93	94,49
Frekans domeni özellikleri	1	50,00	50,00	0,00
	5	49,6	49,80	0,00
	8	50	50	0,00
	10	50	50	0,00
	15	50	50	0,00
	20**	84	79,31	90,48
	25	50	50,00	0,00
Hem zaman hem frekans domeni özellikleri	1**	100	100	100
	5**	100	100	100
	8	95,6	100	91,91
	10	88	98,97	81,05
	15	98	99,18	96,88
	20	96	98,32	93,89
	25	82,4	96,55	74,85

NOT: Test işleminde 125 spindle ve 125 non spindle içeren veri kullanılmış ve en iyi performans ** ile işaretlenmiştir.

Zaman domeninde Hasta 3' e ait karmaşıklık matrisi Tablo 6.10' da verilmiştir.

Tablo 6.10 Zaman domeninde Hasta 3' e ait karmaşıklık matrisi

Gerçek/Tahmin edilen	Spindle	Non-spindle	Gizli katmandaki düğüm sayısı
Spindle	17	5	1
Non-spindle	0	22	
Spindle	22	0	5
Non-spindle	0	22	
Spindle	18	4	8
Non-spindle	0	22	
Spindle	22	0	10
Non-spindle	0	22	
Spindle	22	0	15
Non-spindle	0	22	
Spindle	20	2	20
Non-spindle	0	22	
Spindle	21	1	25
Non-spindle	0	22	

Frekans domeninde Hasta 3' e ait karmaşıklık matrisi Tablo 6.11' de verilmiştir.

Tablo 6.11 Frekans domeninde Hasta 3' e ait karmaşıklık matrisi

Gerçek/Tahmin edilen	Spindle	Non-spindle	Gizli katmandaki düğüm sayısı
Spindle	22	0	1
Non-spindle	22	0	
Spindle	14	8	5
Non-spindle	18	4	
Spindle	19	3	8
Non-spindle	21	1	
Spindle	19	3	10
Non-spindle	22	0	
Spindle	19	3	15
Non-spindle	22	0	
Spindle	16	6	20
Non-spindle	20	2	
Spindle	21	1	25
Non-spindle	22	0	

Zaman ve Frekans domeninde Hasta 3' e ait karmaşıklık matrisi Tablo 6.12' de verilmiştir.

Tablo 6.12 Zaman ve Frekans domeninde Hasta 3' e ait karmaşıklık matrisi

Gerçek/Tahmin edilen	Spindle	Non-spindle	Gizli katmandaki düğüm sayısı
Spindle	18	4	1
Non-spindle	18	4	
Spindle	2	20	5
Non-spindle	0	22	
Spindle	20	2	8
Non-spindle	0	22	
Spindle	22	0	10
Non-spindle	0	22	
Spindle	19	3	15
Non-spindle	22	0	
Spindle	17	5	20
Non-spindle	22	0	
Spindle	13	9	25
Non-spindle	21	1	

Hasta 3' e ait kayıtlarda yapay sinir ağıları kullanılarak zaman ve frekans domenlerinde sleep spindlların sınıflandırılması sonucu elde edilen sonuçlar Tablo 6.13' de verilmiştir.

Tablo 6.13 Yapay sinir ağıları kullanılarak zaman ve frekans domenlerinde sleep spindlların sınıflandırılması sonucu elde edilen sonuçlar (Hasta 3)


Kullanılan Özellik Kümesi	Gizli Katmandaki Düğüm Sayısı	Performans Ölçüm Kriteri		
		Sınıflama Doğruluğu (%)	Hassasiyet (%)	Seçicilik (%)
Zaman domeni özellikleri	1	88,64	100,00	81,48
	5**	100	100	100
	8	90,90	100	84,62
	10**	100	100	100
	15**	100	100	100
	20	95,45	100	91,67
	25	97,72	100,00	95,65
Frekans domeni özellikleri	1**	50,00	50,00	0,00
	5	40,90	43,75	33,33
	8	45,45	47,5	25,00
	10	43,18	46,34	0,00
	15	43,18	46,34	0,00
	20	40,90	44,44	25,00
	25	47,72	48,84	0,00
Hem zaman hem frekans domeni özellikleri	1	50,00	50	50
	5	54,54	100	52,38
	8	95,45	100	91,67
	10**	100	100	100
	15	43,18	46,34	0,00
	20	38,63	43,59	0,00
	25	31,81	38,24	10,00

NOT: Test işleminde 22 spindle ve 22 non spindle içeren veri kullanılmış ve en iyi performans ** ile işaretlenmiştir.

EEG Sinyallerinden elde edilen zaman domeni özelliklerine göre Spindle ve Non-Spindle verilerinin dağılım grafiği Şekil 6.3' de verilmiştir.

Bu grafikten anlaşıyor ki sadece zaman domeni özellikleri kullanılarak spindle ve non-spindle durumları kolaylıkla ayırt edilebilir. Burada grafik sadece ilk üç özellik kullanılarak çizdirilmiştir. İlk üç özellik kullanılmasına rağmen lineer bir dağılımın elde edilmesi, zaman domeninde spindle bulma işinin sadece üç özellikle bile kolaylıkla yapılabileceğini göstermektedir.

EEG sinyallerinin zaman domeninde ilk üç özelliğe göre spindle olan veya spindle olmayan olarak veri dağılımlarını gösterir grafik




Şekil 6.3 Zaman domeninde lineer dağılımı gösteren grafik

EEG Sinyallerinden elde edilen frekans domeni özelliklerine göre Spindle ve Non-Spindle verilerinin dağılım grafiği Şekil 6.4' de verilmiştir.

Bu grafikten anlaşılıyor ki sadece frekans domeni özellikleri kullanılarak spindle ve non-spindle durumlarını ayırt etmek zordur. Welch yöntemi kullanılarak Frekans domeni özelliklerine göre spindle ve non-spindle veri kümesi lineer olarak ayrılamayan bir veri dağılımına sahiptir. Bu sebeple Welch yöntemi kullanılarak yapılan frekans domeni analizi nadiren yüksek sınıflama doğruluğu verse de spindle bulma adına kullanışlı bir metod değildir.

EEG sinyallerinin frekans domeninde ilk üç özelliğe göre spindle olan veya spindle olmayan olarak veri dağılımlarını gösterir grafik



Şekil 6.4 Frekans Domeninde Non-Lineer dağılımı gösteren grafik

7. SONUÇLAR ve ÖNERİLER

7.1. Sonuçlar

Bu tez çalışmasında uyku laboratuvarlarında, uyku dönemlerinin belirlenmesi için çalışan uzmanların uyku iğciği olarak adlandırdıkları ve özellikle uykunun NREM Evre 2 olarak nitelendirilen dönemlerinde ortaya çıkan EEG dalga şeklinin bilgisayar marifetiyle bulunması amaçlanmıştır.

Bu amaç doğrultusunda hastalardan alınan EEG sinyallerinin zaman domeni özellikleri ve Welch metodu kullanılarak frekans domeninde özellik çıkartımları yapılarak yapay sinir ağları ile sınıflandırılması sonucunda incelenen sinyalde uyku iğciği olup olmadığının bulan bir sistem önerilmiştir.

Özellik çıkarımı sonucunda elde edilen veri setlerinin içerisinde işimize yaramayacak özelliklerin sınıflama performansımızı azaltacağı, ilgisiz verilerle çalışmanın sistemimizde zaman ve emek kaybına sebep olacağı düşünülerek özellikle frekans domeninde elde edilen özellikler istatistiksel ölçümler kullanılarak azaltılmıştır.

Zaman domeninde elde edilen altı ve frekans domeninde, özellik azaltımından sonra elde edilen dört özellikten oluşan veri kümesinin %50 si eğitime, % 50 si test için kullanılmıştır.


Yapay sinir ağlarının eğitilmesinin ardından test veri kümesinin sınıflandırılması yapılmıştır. Sınıflandırma aşamasında gizli katmandaki düğüm sayısı 1, 5, 8, 10, 15, 20 ve 25 olarak ayrı ayrı test edilmiş, bu şekilde eğitilmiş olan sistemin sınıflama doğrulukları, hassasiyet ve seçicilik değerleri ayrı ayrı hesaplanmıştır. Sonuç olarak en yüksek sınıflama doğrulunun hangi düğüm sayısı ile elde edildiği bulunmuş ve sistem bu model üzerine tasarlanmıştır.

Zaman domeninde gizli katmandaki düğüm sayısı 10 olarak tasarlanan YSA mimarisiyle, üzerinde çalışılan tüm hastalarda %100 sınıflama doğruluğu elde edilmiştir.

Buradan EEG sinyalleri içinde sleep spindle bulma işinde sadece zaman domeni üzerinde çalışarak %100 başarı sağlanabileceği sonucuna ulaşılmıştır.

Bu sonucu daha başka bilimsel verilere dayandırarak sonucu desteklemek adına zaman ve frekans özelliklerinin ilk üçü kullanılarak spindle bulunan ve spindle bulunmayan EEG sinyallerinin veri dağılım grafiği matlab programıyla çizdirilmiştir. Elde edilen grafikler bulunan sonucu destekler niteliktedir.

EEG sinyallerinin zaman domeninde ilk üç özelliğe göre spindle olan veya spindle olmayan olarak veri dağılımlarını gösterir grafik




Şekil 7.1 Zaman domeninde lineer dağılımı gösteren grafik

Bu grafikte zaman domenindeki özelliklerin sadece üç tanesi kullanılmasına rağmen spindle ve non-spinle verilerin lineer bir şekilde ayrıştığını yani incelenen epokta spindle olup olmadığının zaman domeninde kolaylıkla bulunabileceği görülmektedir. Bu da bizim bulduğumuz sonucu desteklemektedir.

Frekans domeninde aynı işlemi yaptığımızda ise Şekil 7.2' deki grafiğe göre spindle ve non-spinle verilerin non-lineer olarak yani birbirine karışmış biçimde bir

dağılıma sahip olduğu görülmektedir. Bu sebeple Welch yöntemi kullanılarak yapılan frekans domenini analizi nadiren yüksek sınıflama doğruluğu verse de spindle bulma adına kullanışlı bir metod değildir.

EEG sinyallerinin frekans domeninde ilk üç özelliğe göre spindle olan veya spindle olmayan olarak veri dağılımlarını gösterir grafik



Şekil 7.2 Frekans Domeninde Non-Lineer dağılımı gösteren grafik

7.2. Öneriler

Bu tez çalışmasında üzerinde uyku iğcikleri bulunan ve bulunmayan EEG işaretleri arasındaki farklılıklar değerlendirilmiş ve yapay sinir ağları da kullanılarak bilgisayar destekli bir sistem ortaya çıkarılmıştır.

Tasarlanan bu sistem otomatik uyku evreleme sistemlerinde Evre II' nin bulunması görevini yüksek doğrulukla yerine getirebilir.

Kullanılan YSA modeli yeniden ele alınarak farklı eğitime algoritması kullanan diğer yapay sinir ağı algoritmaları ile de karşılaştırılabilir ve sistemlerin verimlilikleri üzerinde değerlendirmeler yapılabilir.

Bu tez çalışmasında özellik çıkarımında kullanılan Welch metodu ve istatistiki özellikler dışında farklı özellik çıkarma yöntemleri denenerek, YSA veya başka sınıflandırma teknikleri kullanılarak sistemlerin elde ettiği sınıflama doğrulukları arasında karşılaştırmalar yapılabilir.

8. KAYNAKLAR

- A.nicolas, D.Petit, S.Rompre, J. Montplaisir,"Sleepspindle characteristics in healthy subjects of different age groups,"Clinical Neurophysiology, 112:521-527,2001
- Acır, N., Güzeliş, C., 2004. Automatic recognition of sleep spindles in EEG by using artificial neural Networks, Expert Systems with Applications 27 : 451–458
- Álvarez-Estévez, D., Moret-Bonillo, V., (2009) Fuzzy reasoning used to detect apneic events in the Sleep apnea-hypopnea syndrome, Expert Systems with Applications 36: 7778–7785
- Anderson, C.W., Devulapalli, S. V. & STOLZ, E. A., 1995. Determining mental state from EEG signals using neural networks. Scientific Programming, 4: 171–183.
- Baş, N.,2006. "Yapay Sinir Ağları Yaklaşımı ve Bir Uygulama" Yüksek Lisans Tezi M.S.Ü.
- Batar, H., 2005. EEG İşaretlerinin Dalgacık Analiz Yöntemleri Kullanılarak Yapay Sinir Ağları İle Sınıflandırılması K.S.Ü. Yüksek Lisans Tezi, Kahramanmaraş
- Dirgenali F., Kara S. 2006. Recognition of early phase of atherosclerosis using principles component analysis and artificial neural networks from carotid artery Doppler signals. Expert Systems with Applications 31:861-874.

- Duman, F., Erdamar, A., Eroğul, O., Telatar, Z., Yetkin, S., 2009. Efficient Sleep spindle detection algorithm with decision tree. Expert Sysytem with Application 36 : 9980-9985
- Dursun, M., 2008, “ Uyku Evreleri ”Yüksek lisans Semineri, S.Ü.
- Eroğul, O., Güler, E. Ç., Bahadırlar, Y. ve Aydın, H. 1999. Uyku EEG’inde karşılaşılan içciklerin (Spindle) sezimi ve analizi için bir yöntem. Biyomedikal Ulusal Toplantısı – BIYOMUT’99, Kayseri.
- Fisch, B.J. 1997. Spehlmann’ın EEG El kitabı, 6.Baskı Turgut Yayıncılık ve Ticaret A.Ş.
- Görür, D., Halıcı, U., Aydın, H., Ongun, G., Özgen, F. ve Leblebicioğlu, K. 2002. Kısa Zamanlı Fourier Dönüşümü ve Yapay Sinir Ağları Kullanarak Uyku İçciklerinin Sezimi. Siu.
- Grap, A. 1995a. An Introduction To Wavelets. IEEE Computational Sciece And Engineering, 2(2)
- Güler, I., Kıymık, M. K., Akın, M. & Alkan, A., 2001. AR spectral analysis of EEG signals by using maximum likelihood estimation. Computers in Biology and Medicine, 31: 441-450.
- Güler, İ., Übeyli E.D. 2005b. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients”, Journal of Neuroscience Methods 148: 113-121.
- Güneş, M., 1999. EEG işaretlerinin Dalgacık Analizi ve Diğer Yöntemlerle Karşılaştırılması, Yüksek Lisans Tezi KSÜ Fen Bilimleri Enstitüsü.
- Haykin, S., 1994. Neural networks: A comprehensive foundation. New York: Macmillan

- Ifeachor E.C., Jervis B.W., 2002. Digital Signal Processing-A Practical Approach, 2nd ed. Pearson Education Limited USA.
- Jung T.-P., Humphries C., Lee, T.-W., Makeig S., McKeown M.J., Iragui V., Sejnowski T.J., 1998. Removing electroencephalographic artifacts: comparison between ICA and PCA. Neural Networks for Signal Processing VIII, Proceedings of the 1998 IEEE Signal Processing Society Workshop 63 – 72.
- Kalaycı, T. & Özdamar, O., 1995. Wavelet preprocessing for automated neural network detection of EEG spikes. IEEE Engineering in Medicine and Biology Magazine, 16: 0–166.
- Levenberg-Marquardt Algorithm". IEEE Trans. on Signal Process., Vol 48, pp. 1915-1927, 2000.
- M. Oğuz, Yalıtkan Maddelerde Elektriksel Delinme Dayanımının Yapay Sinir Ağları ile Belirlenmesi, Yüksek Lisans Tezi, İTÜ, 2001.
- Miner, N.E., 1998. An Introduction to Wavelet Theory and Analysis. Sandia Report, NM, October:1-25.
- Özbay Y., Ceylan R., Karlık B., 2006. A fuzzy clustering neural network architecture
- Özbay, Y., Kara, S., Latifoğlu, F., Ceylan, R., Ceylan, M., 2007a. “Complex-valued wavelet artificial neural network for Doppler signals classifying”, Artificial Intelligence in Medicine, 40(2): 143-156.
- Özşen, S., Güneş, S., 2008. “Effect of feature-type in selecting distance measure for an artificial immune system as a pattern recognizer”, Digital Signal Processing, 18(4): 635-645.
- Öztemel, E., 2003. Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.

- Palaniappan R., Raveendran P. 2002. Genetic algorithm to Select Features for Fuzzy Artmap Classification of Evoked EEG, , 2002. APCCAS '02 Asia-Pacific Conference on Circuits and Systems 2:53 - 56, 28-31 Oct.
- Pang, C.C.C., Upton, A.R.M., Shine, G., Kamath, M.V. 2003 A comparison of algorithms for detection of spikes in the electroencephalogram IEEE transactions on Biomedical Engineering, 50(4): 521 – 526 April.
- Polikar, R., 1999. The Engineer's Ultimate Guide To Wavelet Analysis The Wavelet Tutorial. [Http://Engineering. Rowan. Edu/~Polikar /Wavelets /Wtpart3.Html](http://Engineering.Rowan.Edu/~Polikar/Wavelets/Wtpart3.Html)
- Polat, K., Güneş, S., 2007. “A hybrid approach to medical decision support systems: Combining feature selection, fuzzy weighted pre-processing and AIRS”, Computer Methods and Programs in Biomedicine, 88(2): 164-174.
- Polat, K., Yosunkaya Ş., Güneş S., 2008. “Comparison of Different Classifier Algorithms on the Automated Detection of Obstructive Sleep Apnea Syndrome”, Journal of Medical Systems, 32(3) 2008, 243-250.
- Pradhan, N., Sadasivan, P. K. & Arunodaya, G. R. (1996). Detection of seizure activity in EEG by an artificial neural network: A preliminary study. Computers and Biomedical Research, 29: 303-313
- Proakis J.G., Manolakis D.G. 1996. Digital Signal Processing: Principles, Algorithms and Applications, 3th ed., Prentice Hall Inc. New Jersey.
- Proakis J.G., Rader C.M., Ling F., Nikias C.L. 1992. Advanced Digital Signal Processing, Macmillian Publishing Company, USA.
- Rechtschaffen, A. and Kales, A. ,1968. A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subject. Washington DC: U.S. Government Printing Office.

- Rumelhart, D. E., Hilton, G. E., & Williams, R. J. 1986, "Learning representations by back-propagating errors", *Nature*, 323, 533–536.
- S. H. Ngia, "Efficient Training of Neural Nets for Nonlinear Adaptive Filtering Using a Recursive
- Sağıroğlu Ş., Beşdok E., Erler M., 2003. Mühendislikte Yapay Zeka Uygulamaları-
- Semmlov, J.L. 2004. Biosignal and Biomedical Image Processing, Marcel Deccer Inc. USA.
- Stearns D.S., David A.R. 1988. Signal Processing Algorithms, Prentice-Hall Inc., Englewood Cliffs, New Jersey.
- Sweldens, W. 1994. Wavelet Sampling Technics.
- Tarassenko L., Khan Y.U., Holt M.R.G. 1998 Identification of Interictal spikes in the EEG using Neural Network Analysis. In Gaven S.,editor IEEE proceedings, Science Measurements and Technology. United Kingdom:IET 270-278.
- Torrence, C., Compo, P.C., 1998. A Practical Guide To Wavelet Analysis. Bulletin Of American Meteorological Society, 79(1):61-78.
- Uykuder 1. Uyku Bozuklukları Kongre Kitabı, 2008
- Yazgan, E. Korurek, M. (1996). Tıp Elektronigi, _TÜ Matbaası, s.220 Semmlov, J.L.
- Yurtoğlu, H., 2005, Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği, Uzmanlık Tezi, Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü, Ankara.
- Zygicrewicz, J., 2000. Analysis of Sleep Spindles and a Model of Their Generation, PhD thesis.Warsaw University.