

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

**GELİŞTİRİLEN ÖNİŞLEMELİ-SİNİR AĞI MODELLERİ
İLE YETİŞKİN İNSANLARDA UYKU APNE
VE ÇEŞİTLERİNİN TEŞHİSİ**

NECMETTİN SEZGİN

**DOKTORA TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**MALATYA
Aralık 2010**

Tez Bařlıđı : Geliřtirilen Öniřlemeli–Sinir Ađı Modelleri ile Yetiřkin
İnsanlarda Uyku Apne ve Çeřitlerinin Teřhisi
Tezi Hazırlayan : Necmettin SEZGİN
Sınav Tarihi : 24 Aralık 2010

Yukarıda adı geçen tez Jürimiz tarafından Elektrik–Elektronik Mühendisliđi Anabilim
Dalında Doktora Tezi olarak kabul edilmiřtir.

Sınav Jürisi Üyeleri

Prof. Dr. M. Salih MAMIŐ
(Jüri Bařkanı)

İnönü Üniversitesi

Yrd. Doç. Dr. M. Emin TAĐLUK
(Danıřman)

İnönü Üniversitesi

Prof. Dr. Ahmet KIZILAY
(Üye)

İnönü Üniversitesi

Prof. Dr. Mehmet AKIN
(Üye)

Dicle Üniversitesi

Yrd. Doç. Dr. Ö. Faruk ÖZGÜVEN
(Üye)

İnönü Üniversitesi

İnönü Üniversitesi Fen Bilimleri Enstitüsü Onayı

Prof. Dr. Asım KÜNKÜL
Enstitü Müdürü

ONUR SÖZÜ

Doktora Tezi olarak sunduđum “**Geliřtirilen Öniřlemeli–Sinir Ađı Modelleri ile Yetiřkin İnsanlarda Uyku Apne ve Çeřitlerinin Teřhisi**” bařlıklı bu çalıřmanın, bilimsel ahlak ve geleneklere aykırı düřecek bir yardıma bařvurmaksızın tarafımdan yazıldıđını ve yararlandıđım bütün kaynakların, hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden olduđunu belirtir, bunu onurumla dođrularım.

Necmettin SEZGİN

ÖZET

Doktora Tezi

GELİŞTİRİLEN ÖNİŞLEMELİ-SİNİR AĞI MODELLERİ İLE YETİŞKİN İNSANLARDA UYKU APNE VE ÇEŞİTLERİNİN TEŞHİSİ

Necmettin SEZGİN

İnönü Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

106+IX sayfa

2010

Danışman: Yrd. Doç. Dr. M. Emin TAĞLUK

Uyku apnesi sendromu (UAS) dünyanın ciddi sağlık problemlerinden biridir. Bu sendromun tedavisinde erken teşhis oldukça önemli bir faktördür.

Bu çalışmada, UAS'nin teşhisi ve sınıflandırılması için farklı yöntemler araştırıldı. Birinci metot, hastanın horlama ses işaretinin, zaman-frekans analizi ile ortaya çıkan apne ile ilintili belirli yapıdaki bileşenlerin enerjisi, tasarlanan YSA'ya verilerek UAS teşhisini ele almıştır. İkinci metot, hastalardan kayıtlanan EEG işaretlerini ele almıştır. EEG işaretinin delta, theta, alfa, beta, ve gamma altbantlarının ikiz-spektrumu ile ortaya çıkan kuadratik faz eşleşmeleri gibi karakteristik özellikler quantifiye edilerek YSA'ya verilmiştir. Üçüncü metot, hastadan alınan karın ve göğüs hareketi işaretlerini ele almıştır. Bu veriler sonra Ayrık Dalgacık Dönüşümü (ADD) kullanarak 7. seviyeye kadar dalgacık katsayılarına ayrıştırılmıştır. UAS sınıflandırması için bir ADD-YSA tasarlanmıştır. Bu dalgacıkların 1. seviyeden 7. seviyeye kadar detay katsayılarının enerjisi ile 7. seviyedeki yaklaşık katsayılarının enerjisi hesaplanarak bu ağa verilmiştir. YSA ile değerlendirilen veriler aynı zamanda Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi (ANFIS) ile de değerlendirildi ve elde edilen sonuçlar karşılaştırıldı.

Önerilen bu metotlar ile UAS'yi teşhis ve sınıflandırmada yüksek başarımlar elde edildi. Bu şekildeki veri analizinin nöroloji ve uyku bozuklukları alanlarında da kullanılması mümkündür. Hem hastaya hem de uzman hekime kolaylık sağlaması için geliştirilen SDD-YSA ve ADD-YSA modelleri PSG cihazına entegre edilebileceği düşünülmektedir.

ANAHTAR KELİMELER: Uyku apne sendromu, yapay sinir ağları, ANFIS, dalgacık dönüşümü, ikiz-spektrum, EEG, karın hareketi işaretleri, göğüs hareketi işaretleri, horlama sesi işaretleri.

ABSTRACT

Ph.D. Thesis

ESTIMATION AND CLASSIFICATION OF SLEEP APNEA IN ADULTS BY DEVELOPED PREPROCESSING–NEURAL NETWORK MODELS

Necmettin SEZGİN

Inonu University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering

106 +IX pages

2010

Supervisor: Assist. Prof. Dr. M. Emin TAGLUK

Sleep Apnea Syndrome (SAS) is one of the serious worldwide health problems. Early diagnosis is an important factor in the treatment of the syndrome.

In this study, various methods for estimating and classifying SAS were investigated. The first method, concerns estimation of SAS by an Artificial Neural Network (ANN) designed to employ the energy of particular scheme emerged through time–frequency analysis of snoring signals that linked to apnea. The second method, concerns the EEG signals taken from patients. The characteristic features, such as the Quadratic Phase Couplings (QPCs), exhibited by bi–spectrum of delta, theta, alfa, beta and gamma sub-bands of EEG were quantified and fed to ANN. The third method, concerns thoracic and abdominal signals taken from patients. These data were then split into wavelet coefficients up to 7th level through Discrete Wavelet Transform (DWT). A particular DWT–NN for classification of SAS was designed. The energies of coefficients of each detail (1–7 level) and the 7th approximation level were fed to the input of the ANN. The data evaluated through ANN were also evaluated through a specifically designed Adaptive Neuro–Fuzzy Inference System (ANFIS) and the obtained results were cross–compared.

With the proposed methods, SAS was estimated and classified with highly significant success rates. Such data analysis may also be used in neurology and sleep disorder fields. The developed Wavelet–NN or DWT–NN model may be considered to integrate into the PSG system to provide ease both to medical specialists and patients.

KEYWORDS: Sleep apnea syndrome, artificial neural networks, ANFIS, wavelet transform, bispectrum, EEG, abdominal effort signal, thoracic effort signal, snoring signal.

TEŐEKKÜR

Öncelikle bu alıőmanın her aőamasında bana her türlü yardım ve desteęi veren ve oldukça yararlandıęım önerileri sunan danıőmanım Sayın Yrd. Do. Dr. M. Emin TAęLUK'a; Yine her türlü yardım ve desteęini esirgemeyen Sayın Prof. Dr. Mehmet AKIN'a; Tez alıőması süresince bana her türlü destek ve önerilerini sunan Tez İzleme Komitesi Üyeleri Sayın Prof. Dr. M. Salih MAMIŐ ve Sayın Yrd. Do. Dr. Ö. Faruk ÖZGÜVEN'e; alıőmada kullandıęımız verilerin alınmasında yardımlarından dolayı Dicle Üniversitesi uyku laboratuvarı sorumlusu Sayın Do. Dr. Gökhan KIRBAŐ'a; Destek ve katkılarından dolayı İnönü Üniversitesi Mühendislik Fakültesi Elektrik ve Elektronik Mühendislięi Bölümü öğretim üyelerine; Tezin dilbilgisi yönünden düzeltilmesinde yardımlarından dolayı deęerli arkadaőım Öğr. Gör. İsmail KAYRI'ye çok teőekkür ederim.

Ayrıca bu alıőma süresince bana destek olan ve alıőmalarımın otürü ihmal ettięim deęerli aileme ve özellikle bugünlere gelmemde büyük emeęi olan sevgili ANNEM'e de őükranlarımı sunarım.

İÇİNDEKİLER

	ÖZET.....	i
	ABSTRACT	ii
	TEŞEKKÜR	iii
	İÇİNDEKİLER	iv
	ŞEKİLLER LİSTESİ	vi
	ÇİZELGELER LİSTESİ	viii
	SİMGELER VE KISALTMALAR.....	ix
1.	GİRİŞ	1
2.	KURAMSAL TEMELLER.....	4
2.1.	UAS ile İlgili Klinik Bilgiler	4
2.2.	Çalışma ile İlgili Yapılmış Bazı Önemli Çalışmalar	6
3.	MATERYAL VE YÖNTEM.....	10
3.1.	Materyel.....	10
3.2.	Yöntem.....	12
3.2.1.	Dalgacık dönüşümü.....	12
3.2.1.1.	Dalgacık taban fonksiyonları.....	13
3.2.1.2.	Dalgacıkların özellikleri.....	16
3.2.2.	Ayrık dalgacık dönüşümü	17
3.2.2.1.	Dönüşüm matrisinin oluşturulması.....	20
3.2.3.	İkiz–spektrum analizi	24
3.2.4.	Yapay sinir ağları.....	31
3.2.4.1.	YSA'nın özellikleri.....	32
3.2.4.2.	YSA'nın uygulama alanları.....	33
3.2.4.3.	Yapay hücre modelleri	34
3.2.4.4.	Etkinleştirme (aktivasyon) fonksiyonu	37
3.2.4.5.	Yapay sinir ağlarında öğrenme	39
3.2.4.6.	Öğrenme algoritmaları	41
3.2.4.7.	Yapay sinir ağlarının avantajları.....	49
3.2.5.	Adaptif ağ yapısına dayalı bulanık çıkarım sistemi.....	50
3.2.5.1.	ANFIS mimarisi.....	51
3.2.5.2.	ANFIS ağında kullanılan hibrit öğrenme algoritması.....	53
4.	ARAŞTIRMA VE BULGULAR.....	55
4.1.	Horlama Verisinden UAS Kestirimi	55
4.1.1.	Horlama sesi verilerinin zaman–frekans analizi.....	55
4.1.2.	Horlama işaretlerinden UAS'nin YSA ile kestirimi	62
4.2.	EEG Verisinden UAS Kestirimi	64
4.2.1.	EEG verilerinin ikiz–spektrum analizi.....	65
4.2.2.	EEG işaretlerinden UAS'nin YSA ile kestirimi	71
4.3.	Karın ve Göğüs Verisinden UAS Sınıflandırması.....	75
4.3.1.	Karın ve göğüs işaretlerinin ADD ile altbantlara ayrıştırılması.....	75
4.3.2.	Karın ve göğüs işaretlerinden UAS'nin YSA ile sınıflandırılması.....	79
4.4.	UAS'nin ANFIS ile Kestirimi ve Sınıflandırılması.....	84
5.	TARTIŞMA.....	88
6.	SONUÇ ve ÖNERİLER.....	92
	KAYNAKLAR	94
	EKLER	100
	EK 1: Horlama sesi işaretlerinin zaman-frekans analizini yapan program.....	100
	EK 2: EEG işaretlerinin ikiz spektrum analizinde kullanılan program	101

EK 3: Karın ve göğüs hareketi işaretlerine uygulanan <i>ADD</i> programı.....	102
EK 4: YSA'ya ait m-file program.....	104
EK 5: ANFIS'e ait m-file program.....	105
ÖZGEÇMİŞ.....	106

ŞEKİLLER LİSTESİ

Şekil 1.1. Geliştirilen modelin blok diyagramı.....	3
Şekil 2.1. Uyku apnesi esnasında hava akımının kapanma durumu [13].....	4
Şekil 2.2. Horlama ve UAS anında gırtlak yapısı [42].....	6
Şekil 3.1. Sinyallerin alındığı uyku laboratuvarı şeması.....	10
Şekil 3.2. Uyku laboratuvarında kullanılan PSG cihazı aparatları	11
Şekil 3.3. 4 seviyelik dalgacık dönüşümünün zaman–frekans yapısı veya şablonu	14
Şekil 3.4. Yaygın olarak kullanılan dalgacık örnekleri.....	15
Şekil 3.5. a) Sentetik işaret, b) İşaretin spektrumu, c) İşaretin <i>SDD</i> 'si.....	16
Şekil 3.6. $x[n]$ işaretinin filtrelerle bir düzeylik katsayılarının elde edilmesi.....	20
Şekil 3.7. Sentetik işaretin 7 seviyeli <i>ADD</i> 'si.....	24
Şekil 3.8. İkiz–spektrumun simetri ve örtüşme bölgeleri.....	27
Şekil 3.9. Birinci konfigürasyon için güç spektrum ve ikiz–spektrum gösterimi.....	28
Şekil 3.10. İkinci konfigürasyon için güç spektrum ve ikiz–spektrum gösterimi	29
Şekil 3.11. Üçüncü konfigürasyon için güç spektrum ve ikiz–spektrum gösterimi.....	30
Şekil 3.12. Dördüncü konfigürasyon için güç spektrum ve ikiz–spektrum gösterimi ...	30
Şekil 3.13. Biyolojik sinir hücresi [75]	35
Şekil 3.14. Statik yapay hücre modeli.....	36
Şekil 3.15. Eğitici öğrenme yöntemi.....	40
Şekil 3.16. Eğitici öğrenme yöntemi.....	40
Şekil 3.17. Takviyeli öğrenme yöntemi	41
Şekil 3.18. İleri beslemeli 3 katmanlı YSA sinyal akış şeması	42
Şekil 3.19. Doğrusal olmayan hücre modeli ve bir problemi öğrenme olayı.....	44
Şekil 3.20. Örnek bir hata yüzeyi.....	48
Şekil 3.21. Birinci dereceden iki girişli ve iki kurallı Sugeno bulanık modeli [84]	50
Şekil 3.22. İki girişli ve iki kurallı Sugeno tip eşdeğer ANFIS mimarisi	51
Şekil 4.1. Horlama işaretlerinin sistematik modeli. a_k , $k = 1, 2, \dots, p$ filtrenin sabit katsayılarıdır	55
Şekil 4.2. Apneik olmayan horlama işareti ve (t, f) gösterimi.....	57
Şekil 4.3. Apneik olmayan horlama işareti ve (t, f) gösterimi.....	57
Şekil 4.4. Apneik olmayan horlama işareti ve (t, f) gösterimi.....	58
Şekil 4.5. Yarı–apneik (hipopne) horlama işareti ve (t, f) gösterimi.....	58
Şekil 4.6. Yarı–apneik (hipopne) horlama işareti ve (t, f) gösterimi.....	59
Şekil 4.7. Apneik horlama işareti ve (t, f) gösterimi	60
Şekil 4.8. Apneik horlama işareti ve (t, f) gösterimi	60
Şekil 4.9. Apneik horlama işareti ve (t, f) gösterimi	61
Şekil 4.10. Apneik horlama işareti ve (t, f) gösterimi	61
Şekil 4.11. Geliştirilen modelin şematik yapısı ve modelde kullanılan YSA'nın eğitim akış şeması.....	63
Şekil 4.12. YSA çıkışının istenen hata değerine yakınsaması ve öğrenme oranının değişimi	64
Şekil 4.13. Normal EEG işareti; (a) EEG işareti, (b) işaretin güç spektrumu, (c) ikiz–spektrum (pozitif frekans için), (d) işaretin ikiz–spektrumu	66
Şekil 4.14. UAS EEG işareti; (a) EEG işareti, (b) işaretin güç spektrumu, (c) ikiz–spektrum (pozitif frekans için), (d) işaretin ikiz–spektrumu	67
Şekil 4.15. UAS öncesi EEG işareti, güç spektrumu, ikiz spektrum ve ikiz spektrumun iki boyutlu gösterimi	69
Şekil 4.16. UAS anında EEG işareti, güç spektrumu, ikiz spektrum ve ikiz spektrumun	

iki boyutlu gösterimi	69
Şekil 4.17. UAS sonrası EEG işareti, güç spektrumu, ikiz spektrum ve ikiz spektrumun iki boyutlu gösterimi	70
Şekil 4.18. Geliştirilen ikiz–spektrum–YSA modelinin şematik yapısı.....	71
Şekil 4.19. Normal EEG işareti ve onun ikiz–spektrumu	73
Şekil 4.20. UAS hastası için EEG işareti ve onun ikiz–spektrumu	73
Şekil 4.21. Eğitilen ağın yakınsaması.	74
Şekil 4.22. Bir S işaretinin 7 seviyelik dalgacık katsayılarını gösteren diyagram.....	76
Şekil 4.23. (a) Karın ve (b) Göğüs hareketi işaretleri	77
Şekil 4.24. Karın hareketi işaretinin 7 seviyeli dalgacık ile ayrıştırılması.....	78
Şekil 4.25. Göğüs hareketi işaretinin 7 seviyeli dalgacık ile ayrıştırılması.....	78
Şekil 4.26. Geliştirilen modelin blok diyagramı	79
Şekil 4.27. Üç çeşit UAS için karın hareketi işaretinin 7 seviyede detay katsayıları	82
Şekil 4.28. Üç çeşit UAS için göğüs hareketi işaretinin 7 seviyede detay katsayıları ...	82
Şekil 4.29. Dalgacık ayrışma seviyesine göre YSA'nın öğrenme süresi ve doğruluğu. 83	
Şekil 4.30. SSE ve öğrenme oranının iterasyona göre değişimi	83
Şekil 4.31. Eğitimde hatanın minimuma yakınsaması	84
Şekil 4.32. Eğitilen verilerin ANFIS çıkışı ile örtüşmesi.....	85
Şekil 4.33. Test işaretlerinin ANFIS çıkışını takip etmesi.	85
Şekil 4.34. UAS'nin kestiriminde ANFIS'in eğitimi sonucu hatanın minimuma yakınsaması	86
Şekil 4.35. UAS'nin sınıflandırılmasında ANFIS'in eğitimi sonucu hatanın minimuma yakınsaması	87

ÇİZELGELER LİSTESİ

Çizelge 3.1.	Çalışmada kullanılan hastalara ait özelliklerin ortalama ve standart sapması	10
Çizelge 3.2.	Etkinleştirme fonksiyonları	37
Çizelge 4.1.	Geliştirilen sinir ağının özellikleri	63
Çizelge 4.2.	YSA'nın test sinyallerinde verdiği sınıflandırma performansı.....	64
Çizelge 4.3.	Normal ve TUAS EEG'lerinde ortalama tepe değerlerinin ortaya çıktığı frekanslar	67
Çizelge 4.4.	3000 EEG epizodu için her altbant için QPC miktarlarının ortalama ve standart sapması.....	68
Çizelge 4.5.	UAS öncesi, UAS anında ve UAS sonrası toplam 4500 EEG epizodu için her altbanda ait QPC miktarlarının ortalama ve standart sapması	71
Çizelge 4.6.	Geliştirilen sinir ağının özellikleri	74
Çizelge 4.7.	YSA'nın test sinyallerinde verdiği sınıflandırma performansı.....	75
Çizelge 4.8.	Farklı momentum katsayılarına göre YSA'nın sınıflandırma performansı ve öğrenme süresi	80
Çizelge 4.9.	Geliştirilen dalgacık-sinir ağının özellikleri	80
Çizelge 4.10.	Dalgacık-sinir ağı modelinin sınıflandırma performansı.....	84
Çizelge 4.11.	ANFIS'in test işaretlerine verdiği sınıflandırma performansı (horlama işareti için)	85
Çizelge 4.12.	ANFIS'in EEG test işaretlerine verdiği sınıflandırma performansı.....	86
Çizelge 4.13.	Karın ve göğüs işaretlerinden UAS'nin sınıflandırılmasında ANFIS ağına ait doğruluk oranları.....	87
Çizelge 4.14.	Çalışmada kullanılan tekniklerin karşılaştırılması.....	91

SİMGELER VE KISALTMALAR

δ	Delta altbandı
δ	Kronoker delta fonksiyonu
θ	Teta altbandı
θ	Faz açısı
α	Alfa altbandı
α	Öğrenme oranı sabiti
β	Beta altbandı
β	Momentum katsayısı
γ	Gamma altbandı
B	İkiz spektrum
C	Kümülant
a_i	Dalgacık dönüşümüne ait yaklaşık katsayılar
d_i	Dalgacık dönüşümüne ait detay katsayılar
φ	Etkileşim fonksiyonu
x	YSA'da hücre girişi
v	Hücrenin net girişi
y	YSA'nın çıkışı
W	Dönüşüm matrisi
W	YSA'da hücreler arası ağırlıklar
YSA	Yapay sinir ağları
UAS	Uyku apne sendromu
TUAS	Tıkayıcı uyku apne sendromu
MUAS	Merkezi uyku apne sendromu
BUAS	Bileşik uyku apne sendromu
PSG	Polisomnografi
CPAP	Sürekli hava akımı basıncı sağlayan cihaz
EEG	Beyin işaretleri
EMG	Kas işaretleri
EKG	Kalp işaretleri
EOG	Göz hareketleri
SaO ₂	Oksijen saturasyonu
AHI	Apne-hipopne indeksi
BKI	Beden-kilo indeksi
ÜHD	Üst hava yolu direnci
RRI	R-R aralığı
QPC	Quadratic phase coupling
SDD	Sürekli dalgacık dönüşümü
ADD	Ayrık dalgacık dönüşümü
ANFIS	Adaptif ağ yapısına dayalı bulanık çıkarım sistemi

1. GİRİŞ

Uyku apnesi sendromu (UAS), günlük yaşam kalitesini ciddi bir şekilde etkileyen ve tedavisi oldukça zor olan kronik bir solunum sistemi hastalığıdır. Yapılan çalışmalarda bu hastalığın kadınlara oranla erkeklerde daha çok görüldüğü raporlanmıştır. Örneğin: Yaşları 30 ile 60 arasında olan kişiler üzerinde yapılan çalışmada, bu türden solunum bozukluğunun yaygınlığı kadınlarda yaklaşık %2 ve erkeklerde %4 olarak tespit edilmiştir [1].

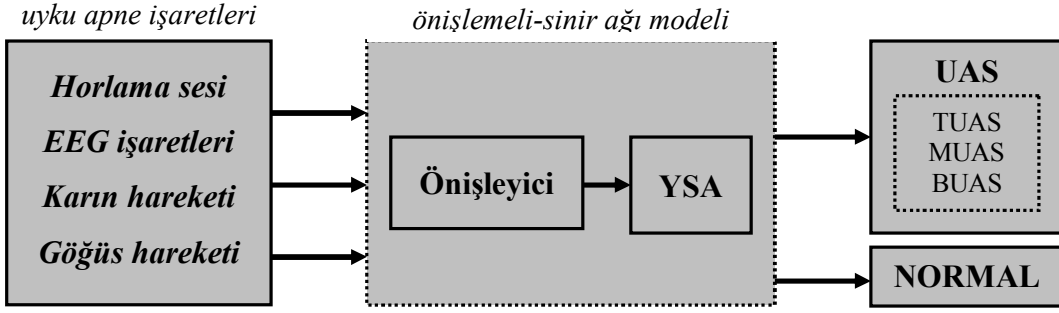
UAS, uykuda iken burun ve/veya ağızdaki hava akımının belirli bir süre durması olarak bilinir. Şiddetine göre alt gruplara da ayrıştırılmış olan UAS'nin, solunum yolu üzerindeki doku ve azaların yapıları ile direkt veya dolaylı olarak bağlantılı olduğu ifade edilmiştir [2]. Apne durumunda kandaki oksijen miktarının azaldığını algılayan beyin, uyku derinliğini azaltır ve kişiyi uyandırarak [3–5] hava yolunun tekrar açılmasını sağlamaya çalışır. Bazı durumlarda ise apne, beyin, solunumu kontrol eden kaslara doğru işaretler göndermemesi sonucunda ortaya çıkar. Bazı durumlarda ise apne daha karmaşık olup, hem beyinden hem de solunum yolu dokularından kaynaklı olabilmektedir.

TUAS tedavisinde başarılı olunabilmesi için erken tanı çok önemlidir. Apne tanı ve sınıflandırmasını yapmak da oldukça zordur. Tanı için UAS hastası, bir sağlık merkezindeki uyku laboratuvarında yatırılır. Gece boyunca hastanın uyku durumunu gözetleyen video kaydı eşliğinde, hastadan polisomnografi (PSG) cihazı ile eş zamanlı olarak beyin işaretleri (EEG), kas işaretleri (EMG), kalp işaretleri (EKG), göz hareketleri (EOG), kan oksijen saturasyonu, solunan hava akımı, horlama sesi, karın ve göğüs hareketleri kayıt edilir [6]. Bu veriler araştırmacılar ve doktorlar tarafından uzun süre görsel olarak değerlendirilir ve gece boyunca hastanın uyku sırasında geçirdiği, saatteki nefes tıkanma sayıları hesaplanır. Bu veri literatürde apne–hipopne endeksi (AHI) olarak tanınmış olup [7] uyku apnesinin derecesini teşhis etmede kullanılmaktadır [8]. Şimdiye kadar yapılan çalışmaların raporlarına göre eğer $AHI < 5$ ise normal, $AHI = 5-15$ ise hafif, $AHI = 15-30$ ise orta ve $AHI > 30$ ise ağır şiddette UAS olarak tanımlanmaktadır [9]. Bunun dışında da UAS tanısı koymak için birçok çalışma yapılmıştır ve yapılmaktadır. Örneğin; Yasuda ve arkadaşları uyku apnesinin karın direnci ve kalp atış hızı değişintisi analizlerinin birleşimi sonucu teşhis edilebildiğini göstermişlerdir [10]. Abeyratne ve arkadaşları uyku apnesinde horlama seslerini karakterize etmek için tepe (pitch) atlama olasılığı ölçümünü önermişlerdir

[11]. Mietus ve arkadaşları uyku apnesi boyunca EKG'nin R–R aralığında ortaya çıkan 0.01–0.04 Hz osilasyonları belirlemek için Hilbert dönüşümünü kullanmışlardır [12]. Onlar çalışmalarında 5 dakikalık kayan pencere kullanarak anlık genlik ve frekansın ortalama ve standart sapmalarını hesaplamışlardır. Daha sonra bir eşik seviyesi belirlediler ve bu seviyeyi apne verilerine uygulayarak apne teşhisini yapmışlardır. Bu teknikte %93.3 doğrulukta apne ve normal durumu ayırt etmişlerdir. Bu çalışmalardan da anlaşılıyor ki, apne teşhisi ve sınıflandırmasını doğru ve kısa bir sürede yapacak bir sisteme hala büyük ihtiyaç vardır. Bu ihtiyaç doğrultusunda bu çalışma tasarlandı.

Bu çalışmada, UAS'yi teşhis etmek ve sınıflandırmak için farklı yöntemlerin araştırılması–geliştirmesi ve bu yöntemlerin apneyi teşhisteki başarımlarının test edilmesi amaç edinilmiştir. Çalışmadaki temel strateji, hastalardan alınan biyolojik işaretlerden, doğrudan teşhis ve sınıflandırılma yerine, bu işaretlerin bir ön işlemden geçirildikten sonra, apne ile ilintilendirilebilecek bazı özelliklerin keşfedilmesi ve sonra da bu özellikleri kullanacak Yapay Sinir Ağı (YSA) gibi bir sistem yardımı ile hastalığı teşhis etmektir. Çalışmada birinci metot olarak, deneklerden alınan horlama işaretlerinin, Sürekli Dalgacık Dönüşümü (*SDD*) yöntemi ile zaman frekans analizi yapılarak, normal bir horlama ile UAS'lı bir horlamayı birbirinden ayırt eden özellikler tespit edilmiştir. Horlama işaretlerinin bu özelliklerinden, UAS tespiti için çok katmanlı bir YSA tasarlanmış ve başarılı bir şekilde bu ağ ile UAS tespiti yapılmıştır. İkinci metot olarak, deneklerden alınan EEG verileri, ikiz spektrum işleminden geçirilerek, bileşenler arasında ortaya çıkan doğrusal olmayan özellikler, literatürde Quadratic Phase Coupling (QPC) olarak ifade edilen faz eşleşmeleri apne ile ilintilendirilmiştir. İkiz spektrumdan elde edilen bu özelliklerin UAS EEG'si ile normal uyku EEG'si arasında belirgin bir farklılık olduğu belirlenmiş ve bu özelliklerden UAS tespiti, yine tasarlanan YSA aracılığı ile yapılmıştır. Üçüncü metotta, deneklerden alınan karın ve göğüs hareket işaretleri, Ayrık Dalgacık Dönüşüm (*ADD*) yöntemiyle altbantlarına ayrıldıktan sonra, her bandın enerjisi hesaplanmış ve YSA ile UAS'nin sınıflandırılması yapılmıştır. Geliştirilen bu önışlemeli YSA modelleri ile ortalama %86.84'e kadar olan bir oranda UAS doğru olarak sınıflandırılmıştır. En son olarak aynı veriler kullanılarak yukarıda değinilen üç metot için YSA yerine, neuro–fuzzy sınıflandırıcılardan olan Sugeno tipi Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi (ANFIS) kullanılarak %83.46 oranında UAS sınıflandırılması doğru yapılmıştır. Elde edilen sonuçlar karşılaştırılarak geliştirilen bu metotlar arasında Dalgacık–sinir ağı

modelinin daha yüksek performans gösterdiği tespit edilmiştir. Geliştirilen bu hibrit modelin blok diyagramı Şekil 1.1’de gösterilmiştir.



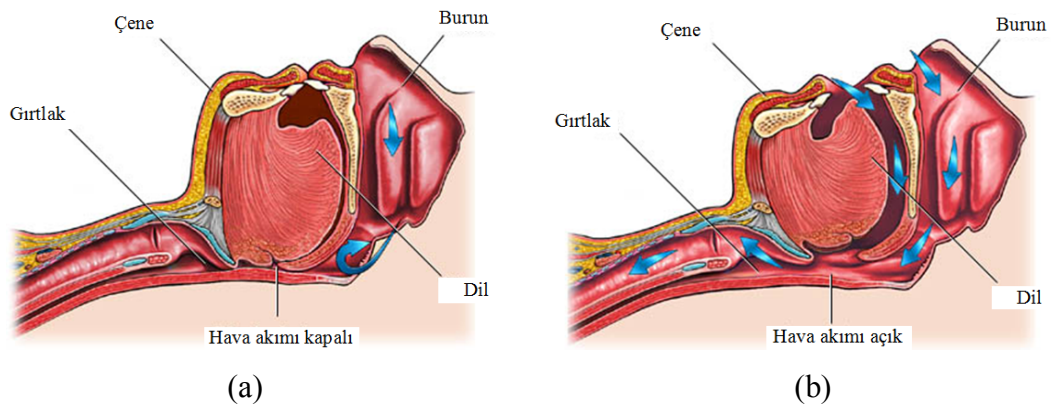
Şekil 1.1. Geliştirilen modelin blok diyagramı

2. KURAMSAL TEMELLER

Bu bölümde, yararlanılan UAS ile ilgili klinik bilgiler ve UAS teşhisi konusunda yapılan önemli çalışmalar özetlenmiştir.

2.1. UAS ile İlgili Klinik Bilgiler

Önceki bölümde uyku apnesi sendromunun (UAS) erkeklerde daha çok görüldüğü, günlük yaşam kalitesini ciddi bir şekilde etkilediği ve tedavisi oldukça zor olan kronik bir solunum sistemi hastalığı olduğu ifade edilmişti. Yetişkinlerde UAS, uykudayken solunum yolunda hava akımının en az 10 saniye süre ile kesilmesi olarak tanımlanmıştır. Literatürde UAS, Tıkayıcı uyku apnesi sendromu (TUAS), Merkezi uyku apnesi sendromu (MUAS) ve Bileşik uyku apnesi sendromu (BUAS) olarak sınıflandırılmıştır. TUAS, Şekil 2.1’de gösterildiği gibi, boğaz çeperinde bulunan yumuşak dokunun, damak, küçük dil, yutak ve dil gibi kasların akciğere havanın geçiş yolunu kapatacağı şekilde gevşemesi olarak ortaya çıkmaktadır. Bu gevşeme sonucunda hava yolu daralır ve bir süre için solunum aktivitesi durur. Bunun sonucunda kandaki oksijen miktarı azalır. Bu azalmayı algılayan beyin, uyku derinliğini azaltarak ya da kişiyi uyandırarak [3–5] solunum yolunun tekrar açılmasını sağlamaya çalışır. MUAS, nadir görülen apne tipi olup beynin, solunumu kontrol eden kaslara doğru işaretler göndermemesi veya işaretlerin iletilmemesi sonucunda ortaya çıkan UAS tipidir. BUAS ise TUAS ile başlayıp MUAS ile devam eden apne durumudur.



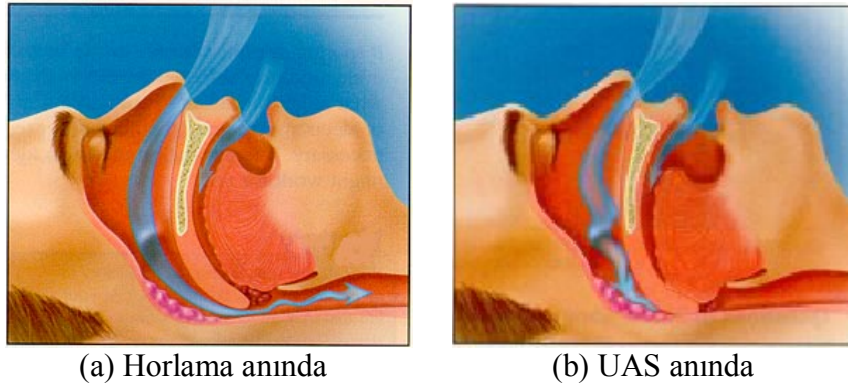
Şekil 2.1. Uyku apnesi esnasında hava akımının kapanma durumu [13]

UAS hastalarının çoğunu, daha yaygın olan TUAS hastaları oluşturmaktadır. Kliniksel olarak yetişkin bir hastanın bir gecelik uykusunda, ortalama, saatte beş defadan fazla tıkaçıcı apne gelişmesi durumunda hastaya TUAS tanısı konur. Günlük hayatta apne hastasının uyanıklık durumunda üst hava yolu açıktır, fakat yutma ve konuşma sırasında anlık olarak kapanabilir [14] ve bu durum TUAS olarak yorumlanmaz. Uyku esnasında ise bazı dönemlerde solunum borusu tıkanarak nefes alış-verişi durur [15] ve bu durum gece boyunca yüzlerce kez tekrar edebilir. Öyle ki, bazı hastalar toplam uyku sürelerinin dörtte üçünü nefes almadan geçirir. Her nefes durmasının ardından hastanın algılayamadığı, saniyeler süren kısa bir uyanıklık dönemi olur. Bu durum uykunun derinleşmesini ve dinlendirici olmasını engeller. Nefes almakta zorlanan hasta, harcadığı çaba nedeniyle çok terler, yatakta sürekli dönerek, yatış pozisyonunu değiştirerek kalitesiz ve yüzeysel bir uykuya sahip olur. Apne hastalarında görülen hava yolunun fiziksel tıkanmasının anatomik etkenleri çeşitlilik göstermektedir [16]. Genetik faktörlerin [17–19] yanı sıra bademciklerin büyümesi [20], küçük dilin büyümesi [21] ve büyük dilin normalden büyük olması [22] gibi faktörlerin UAS’de büyük rol aldığı düşünülmektedir.

Hafif UAS’de saatte 5–15 arası, orta UAS’de saatte 15–30 arası ve ağır UAS’de saatte 30’dan fazla nefes tıkanması olabilmektedir [8] ki bu da düzensiz solunum ve dolayısıyla uyanmalara [3–5] yol açarak hastanın uykusuzluk şikâyetini doğurmaktadır [23]. Ayrıca, yüksek sesle horlama, sabahları dinlenmediğini hissetmek, aşırı yorgunluk [24], günün uygunsuz zamanlarında uykuya dalmak, sabahları baş ağrısı, dikkat süresinin sınırlanması, unutkanlık, kişilik değişimleri ve uyuşukluk gibi durumlar uyku apnesinin diğer belirtileridir [25]. Bu türden hayat kalitesini önemli ölçüde düşüren faktörler kazaların meydana gelme riskini artırmaktadır [26, 27].

Apne hastalarının kendi apne durumlarını hatırlayamadıklarından dolayı, uyku apnesi uzun yıllar teşhis edilememiştir [28, 29]. Apne hastaları çoğu kez, hastanın eşi, oda arkadaşı veya aile fertlerinden birinin apne olayına tanıklık edip fark etmesi üzerine teşhis için kliniğe müracaat etmektedirler [30, 31]. Apnenin klinikte teşhisi oldukça zordur. Teşhis için UAS hastasının bir uyku merkezinde gece boyunca yatması gerekir ve bu sırada polisomnografi (PSG) cihazı ile eş zamanlı olarak beyin işaretleri (EEG), kas işaretleri (EMG), kalp işaretleri (EKG), göz hareketleri (EOG), kan oksijen saturasyonu, solunan hava akımı, horlama sesi, karın ve göğüs hareketleri kayıt edilir [6]. Daha sonra, PSG’den alınan bu veriler ve gece boyunca hastanın uyku sırasında geçirdiği, hesaplanan saatteki tıkanma sayıları birlikte değerlendirilerek hastanın AHI’sı

hesaplanır ve apne derecesi teşhis edilir [7, 8]. Öyle ki, eğer $AHI < 5$ ise normal, $AHI = 5-15$ ise hafif, $AHI = 15-30$ ise orta ve $AHI > 30$ ise ağır şiddette UAS olarak tanımlanır [9]. Uyku apnesinin oluşumunda üst hava yolunun normal olmayışı [16], cinsiyet farklılığı [32-34], alkol kullanımı [35-37], horlama [30], aşırı şişmanlık [38] ve boyun çevresinin kalın olması (erkeklerde 43,18 cm; kadınlarda 40,64 cm'den daha kalın) [39, 40] önemli faktörlerdir. Bu faktörlerden horlamanın uyku apnesi ile çok yakından ilişkili olmasına karşın, horlayan çoğu kişide uyku apnesi bulunmadığına da dikkat edilmelidir [30, 41]. UAS olan hastanın horlaması esnasında boğazın yapısı Şekil 2.2'de gösterilmiştir. UAS'nin derecesi hafif ise hava yolunun genişletilmesine yönelik ameliyatlar yapılır. Bu derece ilerlemiş ise, hastanın, doktor kontrolünde, uyku süresince sürekli pozitif hava basıncı (Continuous Positive Airway Pressure-CPAP) denilen bir çeşit temiz hava kompresörünü kullanması gereklidir. Burun yoluyla devamlı olarak basınçlı hava veren bu cihaz, üst solunum yolunun açık kalmasını sağlar. Genellikle CPAP cihazının uzun süreli kullanımı, kilolu apne hastaların önemli ölçüde kilo vermesini de sağladığı gözlemlenmiştir ve böylece cihaza duyulan ihtiyaç zaman içerisinde ortadan kalkabilmektedir. UAS tedavisinde başarılı olunabilmesi için erken tanı çok önemlidir. Uyku laboratuvarlarının azlığı, kurulumlarının pahalı olması, hastanın teşhis için gece boyunca uyku merkezinde kalmak zorunda bırakılması gibi sebepler, araştırmacıları bu hastalığın teşhisinde farklı yöntemleri keşfetme ve geliştirmeye yöneltmiştir.



Şekil 2.2. Horlama ve UAS anında gırtlak yapısı [42]

2.2. Çalışma ile İlgili Yapılmış Bazı Önemli Çalışmalar

Bu çalışma sırasında önemli ölçüde yararlanılan önemli çalışmalardan bazıları aşağıda özetlenmiştir.

Haja ve arkadaşları [43] yaptıkları çalışmalarda uyku apnesini teşhis edecek ve sınıflandıracak bir metot geliştirmeyi ve bu metodu CPAP cihazı ile entegre etmeyi amaç edinmişlerdir. Bu çalışmada 10 denekten alınan veriler kullanılmıştır. Kayıtlanan hava akımı verilerinin spektral analizi yapılarak verilerin ortalaması, ağırlıklı ortalama frekans ve genlikleri hesaplanmış ve geliştirilen bir bulanık mantık programının girişine uygulanmıştır. Tasarlanan bu program ile normal uyku, tıkayıcı ve merkezi uyku apneleri ayırt edilebilmiştir. Araştırma için 591 normal uyku bölütü ve 306 (165 tıkayıcı ve 140 merkezi) uyku apnesi bölütü kullanılmıştır. Bu bölütlerden 299 normal uyku ve 148 (77 tıkayıcı ve 71 merkezi) uyku apnesi algoritmayı geliştirmek için kullanılmıştır. Geri kalan bölütler ise algoritmayı test için kullanılmıştır. Geliştirilen bu algoritma ile normal uykuyu %99.6, tıkayıcı apneyi %71.9 ve merkezi apneyi %69.6 doğru teşhiste başarımlı sağlanmıştır. Bu algoritmanın apneyi sınıflandırmasından ziyade apnenin olup olmadığını tespit etmede kullanılabileceği görülmektedir.

McNames ve Fraser ise [44] çalışmalarında öncelikle hastanın EKG kayıtlarından seçilen QRS dalgalarını, artifaklardan temizleyerek bir ön işleme yapmışlardır. Daha sonra, bu QRS dalgalarının izge grafiği görsel olarak taranarak tıkayıcı uyku apnesini belirlemeye çalışmışlardır. Görsel analiz için EKG'deki kalp atış sıklığı, S-dalgası ve dalganın enerjisi gibi verilerden faydalanmışlardır. Bu araştırmacılar ilk denemede 17268 dakikalık bir EKG işaretinin 13626 dakikasını ve dördüncü denemede bu işaretin 15994 dakikasını tarayarak tıkayıcı uyku apne durumunu teşhis etmeye çalışmışlardır. İlk denemelerinde 30 hastadan 28 tanesini ve üçüncü denemelerinde ise 30 hastanın 30'unu doğru olarak teşhis edebilmişlerdir.

Mietus ve arkadaşları [12] hastadan alınan EKG işaretlerinin Hilbert transformunu alarak analitik forma dönüştürdükten sonra işaretin üzerine konulan 5 dakikalık kayan bir pencere yardımıyla işaretin yerel genlik ve frekansın ortalama ve standart sapmalarını hesaplamışlar ve hesapladıkları bu değerler için bir eşik değeri aralığı belirlemişlerdir. Geliştirdikleri bu tekniği Computers in Cardiology (CINC) organizasyonunun veri tabanında bulunan uyku apnesi test işaretlerine uygulamışlar ve 30 hastanın 28 tanesini (%93.3) doğru teşhis edebilmişlerdir. Çalışmalarında 17268 dakikalık işaretin 14591 dakikasının (%84.5) tıkayıcı uyku apnesi olup olmadığı şeklinde doğru teşhis etmişlerdir.

Balakrishnan ve arkadaşları [45] çalışmalarında normal uyku ve tıkayıcı uyku apnesine sahip kişileri ayırt etmek için sağlam ve hasta deneklerin uykusu sırasında her uyku evresinde geçen zamanı uykuda geçen toplam zamana oranlayarak bir uyku

kalitesi indeksi geliřtirmişlerdir. Bu çalışmada, 14'ü normal ve 11'i uyku apneli olmak üzere toplam 25 kişiden uyku merkezinde PSG cihazı ile gece boyunca 8 saat kayıtlanan veriler kullanılmıştır. Bu endeks doğal olarak normal uykuya sahip kişiler için yüksek iken apneli uykuya sahip kişiler için düşük çıkmıştır. Bu çalışma ile geliştirilen endeks, uykunun kalitesini ölçmede ve normal ile apne hastasını ayırt etmede kullanılabilirlerdir.

Morsy ve Al-Ashmouny [46] nefes alma işaretlerini kullanarak UAS'yi teşhis ve sınıflandırmak için uyarlamalı bir tanı sistemini öne sürmüşler. Sistem iki tane sınıflayıcı motorun seri bir şekilde kullanılmasıyla oluşturulmuştur. İlk motor bulanık mantık tabanlı olup üç farklı nefes alma (normal, anormal ve kararsız) durumlarından bir tanesini dışarı veren sistemdir. İkinci sınıflandırıcı motor ise ilk motorun çıkışında elde edilen normal ve anormal durumlar ile eğitilerek kararsız olan durumlar sıralanır. Bu sistemin iki seviyeli olmasındaki amaç hatayı minimize ederek doğruluğu artırmaktır. Bu metotla apne teşhisi %96.56 oranında doğruluk ile yapılmıştır.

Tian ve Liu [47], uyku laboratuvarında gece boyunca PSG cihazı ile kayıtlanan hava akımı ve özellikleri çıkarılan SaO₂ işaretlerini zaman gecikmeli bir sinir ağının girişine vererek UAS'yi tespit etmeye çalışmışlardır. İşaretlerin özelliklerini çıkarmak için 1 saniyelik pencerelerle bölütlenmiş hava akımı işaretinin her bölütteki ortalama ve standart sapması hesaplanarak, normalize edilmiş SaO₂ işaretleri ile birlikte ağın girişine verilmiştir. Bu yöntemin 15 sinyal üzerinde test edilmesi sonucunda, yöntemin UAS'yi %90.7 ve yarı UAS'yi %86.4 hassasiyetle kestirdiği görülmüştür.

O. Fontenla-Romero ve arkadaşları ise [48] göğüs işaretlerinin ayrık dalgacık metodu ile ayrıştırılması sonucu elde ettikleri katsayıları ileri yönlü bir sinir ağının girişine vererek apne sınıflandırmasını yapmaya çalışmışlardır. Bu çalışmada 6 hastadan alınan verinin 120 bölütü eğitim ve test için kullanılmıştır. Bu metot, test işaretleri için ortalama %83.78±1.90 hassasiyetle UAS'yi tespit etmede ve %80.90±2.53 TUAS'yi, %80.48±3.65 BUAS'yi ve %89.95±2.71 MUAS'yi sınıflandırmada başarımlarını göstermiştir.

Chao ve arkadaşları [49], çalışmalarında PSG yardımıyla uzun süreli kayıtlanan verilerin işlenmesini yapabilecek bir uyarlanabilir bulanık sınıflandırıcı kullanmışlardır. Bu metot sayesinde uyku ile ilişkili olan teşhislerde arařtırmacılara yardımcı olunması hedeflenmiştir. 8 saat kayıtlanan PSG verileri bölütlenerek dalgacık analizi ile özellikleri çıkarılmış ve apne sınıflandırması için uyarlanabilir bulanık sınıflandırıcının

girişine verilmiştir. Sınıflandırıcı çıkışı da 5 farklı renkte gösterilerek sınıflandırma yapılmıştır.

Campo ve arkadaşları [50] tıkaçıcı uyku apnesinin tanısını koymak için hastadan alınan oksijen saturasyonu işaretlerini, “approximate entropy” (ApEn) denilen yaklaşık düzensizlik yöntemi ile incelemişlerdir. Bu çalışmada 187 apneli hastadan PSG ile alınan oksijen saturasyonu verilerine, geliştirdikleri ApEn tekniğini uygulayarak ApEn seviyesinin TUAS hastalarında yüksek (1.08 – 0.30) ve TUAS olmayanlarda ise düşük olduğunu (0.47 – 0.26) göstermişlerdir. Bu çalışmalarında ayrıca AHI'nın ApEn ile önemli derecede ilişkili olduğunu da ($r = 0.607$; $p < 0.001$) göstermişlerdir. Yaklaşım bölgesi (receiver operating characteristic curve analysis) eğrisinden yararlanarak TUAS'yi %88.3 hassasiyetle teşhis etmeyi başarmışlardır.

Lin ve arkadaşları [51], EEG işaretlerinden yararlanarak uyku apne sendromunu teşhis etmeye çalışmışlardır. Bu çalışmada dalgacık ayrıştırma metodu ile EEG işaretlerini delta, teta, alfa ve beta altbantlarına ayırarak dalgacık katsayılarını çok katmanlı (1 katman giriş, 1 katman gizli ve 1 katman çıkış) sinir ağının girişine vermişlerdir. Bu metotla %69.64 doğruluk oranında apne sendromu tespit edilmiştir.

Son yıllarda yapılan bu ve benzeri çalışmalardan da anlaşıldığı gibi insan hayatını önemli ölçüde etkileyen UAS hastalığının tanı ve tedavisinde kullanılabilecek modern, hızlı, pratik ve maliyeti düşük yöntemlerin geliştirilmesi önem arz etmektedir. Bu tür yöntemleri akıllı sistemlere gömerek geliştirilecek ve insan hizmetine sunulacak her medikal cihaz insanın yaşam standartlarını daha da yükseltecektir. Bu amaçla UAS'yi hızlı ve etkili bir şekilde hem teşhis hem de sınıflandırmak için daha pratik ve etkin çözümlere ihtiyaç olduğu düşünülmektedir.

3. MATERYAL VE YÖNTEM


3.1. Materyal

Bu çalışmada, materyal olarak biyolojik veriler/işaretler ve bu işaretlerin kayıtladığı uyku laboratuvarında bulunan Polisomnografi (PSG) cihazı ve aparatları kullanıldı. Ayrıca verilerin işlenmesi için de Matlab programından yararlanıldı. Biyolojik veriler Dicle Üniversitesi Tıp Fakültesi Uyku Laboratuvarında gece boyunca 64 kanallı E-serisi PSG cihazı ile toplam 22 denekten alındı. Veriler her denekten 7–8 saatlik uykuları boyunca kayıtlanıp dijital ortama aktarıldı. Veriler önce EDF formatında saklandı ve Matlab’da işlenmek üzere *.mat formatına dönüştürüldü.


Bu veriler UAS teşhisinde ve sınıflandırmasında kullanmak üzere hava akış seviyesi, oksijen saturasyonu, karın ve göğüs hareketliliği, horlama sesi, EEG, EMG ve EKG gibi işaretleri içermektedir. Verilerin alındığı deneklere ait yaş, Apne–Hipopne indeksi (AHI) ve Beden–Kilo indeksi (BKİ) ortalamaları Çizelge 3.1’de verilmiştir. Verilerin kayıt edildiği uyku laboratuvarı ve PSG cihazını sembolize eden şematik resim Şekil 3.1’de ve ayrıca PSG cihazı için kullanılan aparatların resimleri Şekil 3.2’de gösterilmiştir.

Çizelge 3.1. Çalışmada kullanılan hastalara ait özelliklerin ortalama ve standart sapması

	UAS	NORMAL
Kişi sayısı	15	7
Yaş	51.25 ± 5.12	48.67±4.33
AHI	37.21±17.11	3.56±1.68
BKI	32.08±2.44	26.58±3.87



Şekil 3.1. Sinyallerin alındığı uyku laboratuvarı şeması



Şekil 3.2. Uyku laboratuvarında kullanılan PSG cihazı aparatları

Şekil 3.2’deki resimler sırasıyla; (a) Polisomnografi cihazı ve kanal seçme paneli (b) Panel–hasta bağlantısında kullanılan elektrotlar (EEG, EMG, EKG, EOG vb. kayıtlar için), (c) Burundan giren ve çıkan hava akımını ölçmek için kullanılan uzantı, (d) Oksijen saturasyonunu (SaO_2) ölçmek için parmak ucuna takılan elektrot, (e) Karın ve göğüs hareketlerini ölçmek için kullanılan kemerler, (f) Tedavide kullanılan CPAP cihazı ve (g) CPAP cihazı ile kullanılan maskeyi göstermektedirler.

PSG’nin en önemli özelliklerden birisi her kanal için ayrı ayrı istenen örnekleme aralığı seçilebilmesi ve bu sayede verilerin sayısallaştırılabilmesidir. PSG cihazı sayesinde alınan veriler ile birçok hastalığın teşhis edilmesi ve buna bağlı olarak tedavi yöntemlerinin geliştirilmesi imkânı doğmuştur. Bu hastalıkların başında, nörolojik hastalıklar, kalp hastalıkları, sinirsel hastalıklar ve uyku bozuklukları gelmektedir. Polisomnografi cihazı özellikle uykuda solunum bozukluklarının teşhisinde ve uyku evrelerinin skorlanmasında kullanılmaktadır. Polisomnografi cihazıyla teşhis edilebilen uyku bozukluklarının başında süreğen uykusuzluk (kronik insomnia), UAS, huzursuz bacak sendromu, uykuda periyodik bacak ve kol hareketleri sendromu ve narkolepsi gelmektedir.

Çalışmamızda kullanılmak üzere uyku laboratuvarlarında kayıt edilen veriler şunlardır:

- iki kanal beyin işareti–EEG (C4–A1 ve C3–A2 noktalarından)
- iki kanal göz hareketi–EOG (sol EOG ve sağ EOG)
- bir kanal kas hareketi–EMG (çene altı)
- bir kanal kalp hareketi–EKG
- bir kanal oksijen saturasyonu
- bir kanal hava akımı
- bir kanal karın hareketi
- bir kanal göğüs hareketi

- bir kanal kan basıncı
- bir kanal mikrofon ile alınan horlama sesi
- bir kanal sol ventrikülün yarattığı arteriyel nabız basınç dalgasının periferik ulaşması sırasında geçen zaman (pulse transition time–PTT)
- iki kanal bacak hareketi (sağ ve sol)

Bu verilerin tamamı uzman hekimler tarafından değerlendirilerek UAS teşhis edilmeye çalışılmıştır. Bu değerlendirmeler, çalışmamızda referans olarak alınmıştır. Çalışmada kullanılan veri setleri horlama sesi, EEG, karın ve göğüs hareketi işaretleri ile sınırlandırılmıştır. Metot olarak, çalışmada UAS teşhis ve sınıflandırması için Dalgacık dönüşümü, İkiz–spektrum analizi, YSA ve ANFIS gibi yöntem ve sistemler kullanıldı. Bu yöntem ve sistemlerin karakteristik yapıları ve modellerin kullandığı algoritmalar aşağıda sırasıyla kısaca açıklanmıştır.

3.2. Yöntem

Çalışmada, UAS’yi teşhis ve sınıflandırmak için birkaç yöntem araştırıldı. Yöntemlerden bazıları (*SDD*, *ADD* ve ikiz–spektrum) biyolojik işaretleri işlemek ve işleme sonucunda UAS ile ilintili bazı özellikler keşfetmek için araştırılmış iken, bazıları (YSA ve ANFIS) da bu özellikleri değerlendirmek suretiyle otomatik olarak UAS’yi teşhis ve sınıflandırmak için araştırılmıştır. Bu yöntemler sırasıyla aşağıdaki gibi özetlenebilir.

3.2.1. Dalgacık dönüşümü

Çalışmada, ilgilenilen biyolojik veri veya işaretler, zamanla değişen, durağan olmayan ve değişik frekanslarda kısa süreli bileşenleri olmalarından dolayı spektral analiz için Fourier dönüşümünün yetersiz kalacağı düşünüldü ve analiz için zaman–frekans yöntemlerinden birisi olan dalgacık dönüşümü kullanıldı [52]. Dalgacık dönüşümü ile yapılan işaret analizinde hem zaman hem de frekans bilgilerinin yanısıra, işaretin süreksizlik ve fiziki yapısından dolayı içerdiği bileşenler arasındaki olası keskin geçişleri de incelemek mümkündür. Dalgacık yöntemleri matematik, quantum fiziği, elektrik mühendisliği ve sismik jeoloji gibi alanlarda birbirinden bağımsız olarak geliştirilmiştir. Bu alanlar arasındaki işbirliği sonucu, özellikle son yıllarda, dalgacık

yöntemi görüntüleme, görüntü sıkıştırma, radar, uzaktan algılama ve deprem tahmini gibi bir çok yeni kullanım alanı bulmuştur.

Bir işaretin dalgacık dönüşümü, o işaretin istenilen dalgacık fonksiyon kümesi ile zaman ortamında konvolusyonu veya frekans ortamında işaretin spektrumu ile dalgacık kümesinin spektrumunun çarpımı ile elde edilir. Dalgacık fonksiyon kümesi, bir taban dalgacıktan türetilmiş aynı form fakat farklı frekansa sahip dalgacıklar kümesidir. Yapılacak çalışmaya yönelik, doğru bir dalgacık taban fonksiyonu seçilmeli ve bu seçim de önemli olduğu için aşağıda bu konuya yer verilmiştir.

3.2.1.1. Dalgacık taban fonksiyonları

Dalgacık taban fonksiyonları, ana dalgacık olarak nitelendirilen bir $\Psi(t)$ temel dalgacığının ölçeklendirilmesi (scaling) ve zaman ekseninde ötelenmesiyle (translation) elde edilen bir dalgacıklar kümesidir. Bir dalgacık kümesi matematiksel olarak:


$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (3.1)$$

şeklinde ifade edilir [53]. Bu bağıntıda a ve b , sırasıyla, ölçekleme ve öteleme değişkenleridir. $a^{-1/2}$ çarpanı değişik ölçeklerdeki dalgacıkları ana dalgacık ile aynı enerji düzeyine getirmek için (dalgacık enerji düzeyi bire eşit olmalıdır ki $x(t)$ 'nin içeriğini etkilemesin) ilave edilen enerji düzgeleme (normalizasyon) katsayısıdır. a ve b 'nin sürekli olması durumunda bu dönüşüm Sürekli dalgacık dönüşümü (*SDD*) adını almaktadır. *SDD* sürekli zaman ortamı süreçlerinde Gaussian pencerelenmiş Fourier dönüşümü gibi bir işlem olarak da düşünülebilir. *SDD*, taban fonksiyonları esas alan bir dönüşüm olduğundan verilen bir $x(t)$ sinyali ile harmanlandığında (convolv edildiğinde) taban fonksiyonlar ile işaret arasındaki benzerliği ölçer. Bir $x(t)$ sinyalinin sürekli dalgacık dönüşümü (*SDD*);

$$\begin{aligned} SDD(a,b) &= \int x(t) \Psi_{a,b}^*(t) dt \quad \text{ve} \\ SDD(a,b) &= \int x(t) \left(\frac{1}{\sqrt{a}} \Psi^*\left(\frac{t-b}{a}\right) \right) dt \end{aligned} \quad (3.2)$$

olarak tanımlanır [53]. Burada *, karmaşık eşleniği ifade eder. Bu bağıntı, $x(t)$ gibi bir işaretin veya sürecin, dalgacık kümesinin taban işlevini temsil eden $\Psi_{a,b}(t)$ aracılığı ile nasıl ayrıştırıldığını ifade etmektedir. Bu bağıntı, verilen $x(t)$ dalga biçiminin, biçimleri sabit ancak farklı süre ve genlikleri olan ve farklı zaman noktalarında merkezlenmiş olan dalgacıkların ağırlıklı bir toplamı olarak sentezlenebileceğini ortaya koymaktadır [53].

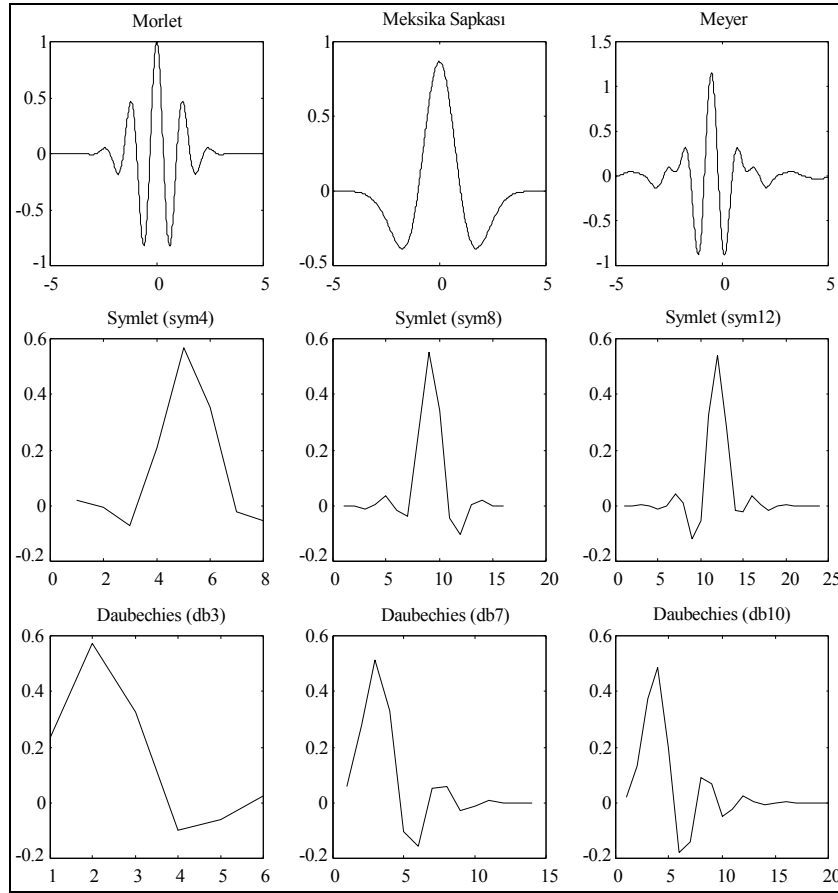
SDD'deki ölçekleme parametresi dalgacığın frekansını artırıp ve azaltmak içindir. Frekansı arttırırken aynı zamanda dalgacığın genliğini arttırarak dalgacığın enerjisinin 1 birim olmasını sağlar. Düşük frekanstaki bir dalgacık daha çok, düşük frekans harmonikleri ile eşleşirken, yüksek frekanstaki bir dalgacık da kendisi gibi yüksek frekansa sahip bir harmonik ile eşleşecektir. Dalgacık dönüşümünde işaret ve dalgacık iyi eşleşmişse aralarındaki ilişki endeksi yüksek olur. Aksi halde endeks düşük olur. Seçilecek dalgacığın türü ve yapısı yapılan uygulamaya göre değişiklik gösterir. Şekil 3.3'te temsili olarak *SDD*'nin zaman–frekans yapısı gösterilmiştir. Şekilde bir işarete ait 4 seviyelik bir ayrışma sonrası işaretin zaman–frekans şeması gösterilmiştir. Görüldüğü gibi dalgacık dönüşümü yüksek frekanslarda, yüksek zaman çözünürlüğü ve buna karşılık düşük frekans çözünürlüğü, düşük frekanslarda ise yüksek frekans çözünürlüğü ve buna karşılık düşük zaman çözünürlüğü sağlar (uncertainty principle).



Şekil 3.3. 4 seviyelik dalgacık dönüşümünün zaman–frekans yapısı veya şablonu

Şekil 3.4'te en yaygın olarak kullanılan dalgacıkların bazıları verilmiştir. Dalgacık analiz metodunun geleneksel metotlara göre üstünlükleri aşağıdaki gibi sıralanabilir:

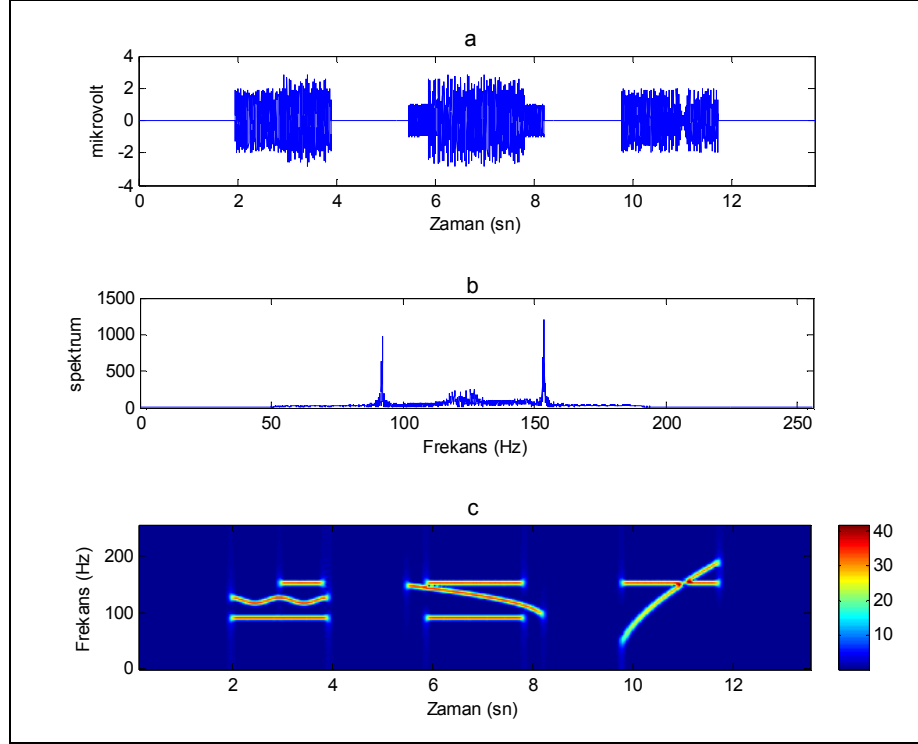
- Frekans spektrumundaki farklı bölgeler için daha kolay farklı frekans çözünürlükleri seçebilir.
- Eğer yapılacak analizde spektrumdaki birkaç frekans bandı kullanılacaksa, tüm spektrumu hesaplamaya gerek yoktur.
- Spektrumun düşük frekans kısımlarında dalgacık dönüşümü oldukça hızlıdır.



Şekil 3.4. Yaygın olarak kullanılan dalgacık örnekleri

SDD'nin durağan olmayan çok bileşenli işaretlerinin yapısını daha iyi ortaya koyduğunu göstermek için aşağıda sentetik üretilmiş bir işarete *SDD* uygulanmış ve çıkan sonuç Şekil 3.5'te verilmiştir. Şekilden de görüldüğü gibi işaretin zaman domeynindeki gösteriminden işaretin bileşenleri hakkında bilgi edinilememektedir. İşaretin spektrumundan da işaret bileşenleri hakkında bilgi alınamamaktadır. Yani Fourier dönüşümü yetersiz kalıyor. İşaretin *SDD* ile elde edilmiş zaman–frekans yapısına bakıldığında sentetik olarak oluşturulan her bir episodun bileşenlerin yapıları

açık ve net bir şekilde görülmektedir. Verilen bu örnekten de anlaşılıyor ki horlama sesi işaretleri gibi komplike ve çok bileşenli işaretlerin analizi için, *SDD*'nin daha iyi sonuç vereceği anlaşılmaktadır.



Şekil 3.5. a) Sentetik işaret, b) İşaretin spektrumu, c) İşaretin *SDD*'si

3.2.1.2. Dalgacıkların özellikleri

İşaret işleme için kullanılan dalgacıkların en önemli özellikleri, kabuledilebilirlik ve düzenlilik koşullarını sağlama oranlarına göre belirlenir ve bu özelliklere göre de dalgacıklar isimlendirilirler.

Kabuledilebilirlik koşulu;

$$\int \frac{|\Psi(w)|}{|w|} dw < +\infty \quad (3.3)$$

şeklinde ifade edilir. Bu özellik, herhangi bir işaretin $\Psi(t)$ taban fonksiyonu ile L^2 uzayında önce analiz edilip ve daha sonra veri kaybı olmadan işaretin geri işlem ile yeniden elde edilmesi (reconstruction) için kullanılır [54]. Denklem 3.3

bağıntısındaki $\Psi(w)$, $\Psi(t)$ 'nin Fourier dönüşümüdür ve bu bağıntı, dalgacıkların zaman ortamındaki ortalama değerinin sıfır olması anlamına gelir. Yani:

$$\int \Psi(t)dt = 0 \quad (3.4)$$

Bu bağıntının sağlanması için $\Psi(t)$ 'nin salınımlı bir fonksiyon olması, başka bir deyişle bir *ac* dalga olması gerekmektedir.

Zaman–band genişliği çarpımı;

Bir dalgacığın zaman–band genişliği çarpımının sabit kalması gerekir, başka bir ifade ile *a* ölçeği azalırken işaretin genliği artacaktır. Düzenlilik koşulu olarak da bilinen bu koşul, dalgacığın hem zaman hem de frekans çözünürlüklerinde bir miktar yumuşama ve konsantrasyon sağlar. Düzenlilik koşulu genelde Denklem 3.5'te verilen kaybolma momenti ile ifade edilir. Bir dalgacık *m*'inci dereceden kaybolma momenti,

$$\int_{-\infty}^{+\infty} t^p \Psi(t)dt \quad p=0,1,\dots,m-1 \quad (3.5)$$

biçiminde ifade edilmiştir [54]. Burada *p*, dalgacık moment derecesini ifade eder.

Tasarım kolaylığından dolayı bir çok uygulamada *SDD* yerine Ayrık dalgacık dönüşümü (*ADD*) kullanılmaktadır. Bu çalışmada da karın ve göğüs hareketi işaretlerinin analizi için *ADD* kullanıldı ve bundan dolayı *ADD* detaylı bir şekilde aşağıda anlatılmıştır.

3.2.2. Ayrık dalgacık dönüşümü

Denklem 3.2 bağıntısındaki olası her *a* ve *b* değeri için dönüşüm katsayılarını hesaplamak, oldukça zaman alan ve çoğu kez gereksiz yere çok sayıda veri elde edilmesine yol açan bir süreç olduğundan, bu dönüşümde olayı pratik boyutlara taşımak için “*Ayrık Dalgacık Dönüşümü*” geliştirilmiştir. Bir *x(t)* işaretinin Ayrık dalgacık dönüşümü bir çok şekilde yapılabileceği gibi, genelde sürekli dalgacık fonksiyonları 2'nin tam kuvvetleri olarak ölçeklenir ve tam sayılarla ötelenerek

ayrık hale getirilirler ki bu şekildeki ayrıklaştırmaya *diyadik ızgara* (dyadic grid) adı verilir [54]. Diyadik bölmelendirme için Denklem 3.1 bağıntısında a ve b yerine, $a = 2^{-s}$ ve $b = k2^{-s}$ yazılır, şöyle ki:

$$\Psi_{s,k}(t) = 2^{s/2} \Psi(2^s t - k) \quad (3.6)$$

Burada sürekli dalgacık dönüşümünde olduğu gibi s ve k tam sayılar olup, s endeksi dalgacığın genişliğini, k ise pozisyonunu belirler. *SDD*, *ADD* parametreleri cinsinden

$$SDD(2^{-s}, k2^{-s}) = 2^{s/2} \int_{-\infty}^{+\infty} x(t) \Psi(2^s t - k) dt \quad (3.7)$$

şeklinde ifade edilebilir ve böylece $x(t)$ işareti de ayrık hale getirilir. Bunun için örnekleme frekansı, örneğin basitçe 1 alınırsa, Denklem 3.7 bağıntısındaki sürekli integral,

$$ADD(2^{-s}, k2^{-s}) = 2^{s/2} \sum_n x(n) \Psi(2^s n - k) \quad (3.8)$$

biçimindeki ayrık forma dönüşür. Böylece bir işaretin *ADD*'sini almak için, işaretin zaman eksenindeki değerlerini bilmemize gerek kalmaz, sadece dalgacıkların sıfır olmadıkları yerlerdeki değerlerinin bilinmesi yeterli olur.

Değişik çözünürlüklerdeki bir veri ortamını taramak için kullanılacak dalgacık kümesi, *ölçekleme bağıntısı* adı verilen temel ayrık dalgacık $\Psi(x)$ cinsinden aşağıdaki gibi ifade edilebilir [54].

$$f(x) = \sum_{k=-1}^{N-2} (-1)^k c_{k+1} \Psi(2x + k) \quad (3.9)$$

Burada c_n , dalgacığın genliğini modüle eden katsayıdır. Dalgacık katsayıları aşağıdaki doğrusal ve kuadratik koşulları sağlamalıdır.


$$\sum_{k=0}^{N-1} c_k = 2, \quad \sum_{k=0}^{N-1} c_k c_{k+2l} = 2\delta_{l,0} \quad (3.10)$$

Bu bağıntıda l pozisyon endeksi ve δ , aşağıdaki gibi tanımlı Kronecker delta fonksiyonudur ve aşağıdaki gibi ifade edilir.

$$\delta_{k,l} = \begin{cases} 1, & k = l \\ 0, & k \neq l \end{cases} \quad (3.11)$$

Denklem 3.9 bağıntısındaki $\{c_0, \dots, c_n\}$ katsayıları bir filtre gibi de düşünülebilir. Filtre katsayıları bir dönüşüm matrisine yerleştirilerek işlenmemiş veri vektörüne uygulanır. Katsayılar dönüşüm matrisine, matrisin bir satırına işarette yumuşatma (alçak geçiren filtre) yapacak şekilde, diğer satırına da işaretin detaylarını yakalayabilecek şekilde (yüksek geçiren filtre) yerleştirilir ve bu iki satırın geri kalan elemanları sıfır yapılır. Daha sonra filtre katsayılarının yerleştirildiği bu iki satır, her seferinde iki sütun kaydırılarak matrisin geri kalan satırları doldurulur. Bu dönüşüm matrisinin veri vektörüne uygulanması sonucu elde edilen vektör düzenlenerek (yaklaşım ve detay bilgileri ayrılarak), vektörün yaklaşım bilgilerini içeren kısmına dönüşüm matrisi tekrar uygulanır ve bu uygulama sonuçta veri vektöründe iki eleman kalıncaya kadar devam eder. Bu şekildeki uygulama algoritması, literatürde “*pyramid algoritması*” olarak isimlendirilmiştir [55].

Yukarıda anlatılan ayrık dalgacık dönüşümü için filtrelerin kullanılmasını ilk olarak 1988’de Mallat [55] gerçekleştirmiştir. Mallat’ın algoritması aslında işaret işleme dilinde “*iki kanal altband kodlayıcı*” olarak bilinen klasik bir yöntemdir. Bu yöntemle göre, eldeki bir $x[n]$ veri vektörüne yukarıda anlatıldığı şekilde dalgacık dönüşüm matrisini uygulamak, bu vektörü yaklaşım ve detay bilgilerine Şekil 3.6’daki gibi filtreleme yöntemi ile ayırma işlemine eşdeğerdir.



Şekil 3.6. $x[n]$ işaretinin filtrelerle bir düzeylik katsayılarının elde edilmesi

$x[n]$ gibi bir ayrık veri vektörünü Şekil 3.6’da d ile gösterilen detay (detail) bilgilerine ve s ile gösterilen yaklaşım (approximation) bilgilerine ayırmak için veri vektörüne şekilde $g[n]$ ile gösterilen bir yüksek geçiren filtreyi ve $h[n]$ ile gösterilen bir alçak geçiren filtreyi uygulayıp ve daha sonra da bu filtre çıkışlarında elde edilen yeni işaret parçaları, $\downarrow 2$ ile gösterilen sistemde olduğu gibi, aşağı örneklenir. Aşağı örnekleme, süzgeçten geçirilmiş işaretin tek ya da çift örneklerini atmak şeklinde yapılır. Burada d ile gösterilen 1. düzey dalgacık katsayılarıdır. Ayrık dalgacık dönüşümünü tamamlamak için, Şekil 3.6’da gösterilen işlemi ardışık olarak sistemin alçak geçiren çıkışına uygulanması gerekir. Bu uygulama, teorik olarak, alçak geçiren filtrenin çıkışında bir veri kalana kadar sürer.

3.2.2.1. Dönüşüm matrisinin oluşturulması

Dönüşüm matrisi W ’nın oluşturulmasına geçmeden önce, bu matrisin oluşturulmasında kullanılan *ADD* bağıntı ve parametrelerinin, hem konu bütünlüğü hem de yapılacak formülasyonun anlaşılması yönünde, tanımlanması daha uygun olacaktır. Önceki bölümlerde ayrık dalgacık dönüşümünde, dalgacık işlevlerinin yanında, ana dalgacığa uygulanan aynı genişleme ve ötelemelerin, ölçekleme işlevine de uygulanmasından ortaya çıkan bir işlevler kümesinden bahsedildi. $\Psi(x)$, ana dalgacık işlevi ve $\phi(x)$, ölçekleme işlevi olmak üzere iki ölçek ilişkisi (two-scale relation) adı verilen bu işlevler kümesi:

$$\begin{aligned}
\Psi(x) &= \sqrt{2} \sum_{n=0}^{2N_m-1} g_n f(2x-n), \\
\phi(x) &= \sqrt{2} \sum_{n=0}^{2N_m-1} h_n f(2x-n) \quad \text{ve} \\
g_n &= (-1)^{1-n} h_{1-n}
\end{aligned} \tag{3.12}$$

bağıntılarıyla tanımlanır [54]. Burada $\{g_n\}$ dizisi, $\Psi(x)$ dalgacık işlevi için süzgeç dizisi ve $\{h_n\}$ dizisi, $\phi(x)$ ölçekleme işlevi için süzgeç dizisini oluşturmaktadır. N_m ise kaybolma momenti sayısını göstermektedir. Dalgacıklar bağlı oldukları dalgacık ailesi içerisinde sahip oldukları kaybolma momenti sayılarına göre de sınıflandırılırlar. Kaybolma momenti tamamen o dalgacık türünün sahip olduğu katsayı miktarıyla ilgili matematiksel bir ilişki olup dalgacığın yaklaştırım derecesini gösteren en önemli özelliklerindedir. Bir fonksiyonun dalgacık olabilmesi için en az bir kaybolma momenti olmalıdır. Bu en basit dalgacık türü olan Haar dalgacıdır ve genellikle eğitim amaçlı kullanılır. İyi bir yaklaştırım için, $\{g_n\}$ süzgeç dizisinin kaybolma momenti sayısının iyi seçilmesi gerekmektedir [56]. Burada N_m ile $\{g_n\}$ arasında,

$$\sum_{n=0}^{2N_m+1} n^j g_n = 0, \quad j=0,1,\dots,N_m-1 \tag{3.13}$$

bağıntısı tanımlanmıştır [56]. N_m sayısının büyük olması matris seyrekliğini azaltmakta fakat sonucun doğruluk derecesini arttırmaktadır. Diğer taraftan, büyük N_m değeri daha yoğun bir W dönüşüm matrisini doğurmakta ve bu da hesaplama maliyetini arttırmaktadır. Bu nedenle, hızlı ve doğru bir çözüm için N_m değerinin optimum bir şekilde seçilmesi gerekmektedir [57].

Bu bağıntı ve parametrelerin ışığında büyüklüğü $N=2^n$ olan s^0 işareti (vektörü) için $N \times N$ 'lik W_n matrisi,

$$W_n = \begin{bmatrix} H_n \\ G_n \end{bmatrix} \tag{3.14}$$

biçiminde oluşturulur [54]. Burada H_n ve G_n dereceleri $2^{N-1} \times 2^N$ olan matrisler

olup sırasıyla alçak geçiren ve yüksek geçiren süzgeçleri ifade ederler. Örnek olarak: $N_m = 2$ için bu matrisler,

$$H_n = \begin{bmatrix} h_1 & h_2 & h_3 & h_4 & 0 & \dots & 0 \\ 0 & 0 & h_1 & h_2 & h_3 & h_4 & \dots & 0 \\ \vdots & \vdots & & & \ddots & & & \\ 0 & \dots & & h_1 & h_2 & h_3 & h_4 \\ h_3 & h_4 & \dots & & & h_1 & h_2 \end{bmatrix} \quad (3.15)$$

$$G_n = \begin{bmatrix} g_1 & g_2 & g_3 & g_4 & 0 & \dots & 0 \\ 0 & 0 & g_1 & g_2 & g_3 & g_4 & \dots & 0 \\ \vdots & \vdots & & & \ddots & & & \\ 0 & \dots & & g_1 & g_2 & g_3 & g_4 \\ g_3 & g_4 & \dots & & & g_1 & g_2 \end{bmatrix} \quad (3.16)$$

şeklinde oluşturulur. $W_n s^0$ çarpımı s^0 vektörünü, s^1 yaklaşım ve d^1 detay parçalarına ayırır. Bu işlem s^0 vektörüne alçak ve yüksek geçiren süzgeç uygulayıp, s^0 vektörünü alçak frekans ve yüksek frekans bileşenlerine ayırmakla aynı anlama gelmektedir. Bu ayrıştırma süreci arka arkaya yaklaşım verisi s^j 'ye tekrar uygulanır ve bu işleme, j düzey endeksi,

$$j = 1, \dots, k \leq n - \log_2 2N_m + 1 \quad (3.17)$$

bağıntısındaki k değerini alıncaya kadar devam edilirse sonuçta s^0 vektörünün ayrık dalgacık dönüşümü alınmış olur. Matris gösterimi ile bu,

$$W_n s^0 = [W_{n-k} \dots W_{n-1} W_n] s^0 = [s^k, d^k, \dots, d^1] \quad (3.18)$$

biçiminde ifade edilir. Burada W_{n-j} blok diyagonal matristir ve

$$W_{n-j} = \begin{bmatrix} \begin{bmatrix} H_n \\ G_n \end{bmatrix} & 0 \\ 0 & I_{N-N/2^j} \end{bmatrix} \quad (3.19)$$

biçimindedir [58]. Denklemdaki $I_{N-N/2}$ birim matristir.

Bundan başka W dalgacık dönüşüm matrisinin herhangi bir matrise uygulanabilmesi için matrisin kare matris ve boyutunun da 2'nin tam kuvveti olması gerekir [58]. 2'nin tam kuvveti olmayan kare matrislerde dönüşümün uygulanabilmesi için, Denklem 3.20'de gösterildiği gibi sıfır ve birim matrisler eklemek suretiyle, matris boyutunun 2'nin tam kuvvetleri olan bir kare matris haline getirilmesi gerekir [58].

$$\begin{pmatrix} Z_{P \times P} & 0 \\ 0 & I \end{pmatrix}_{Q \times Q} \quad (3.20)$$

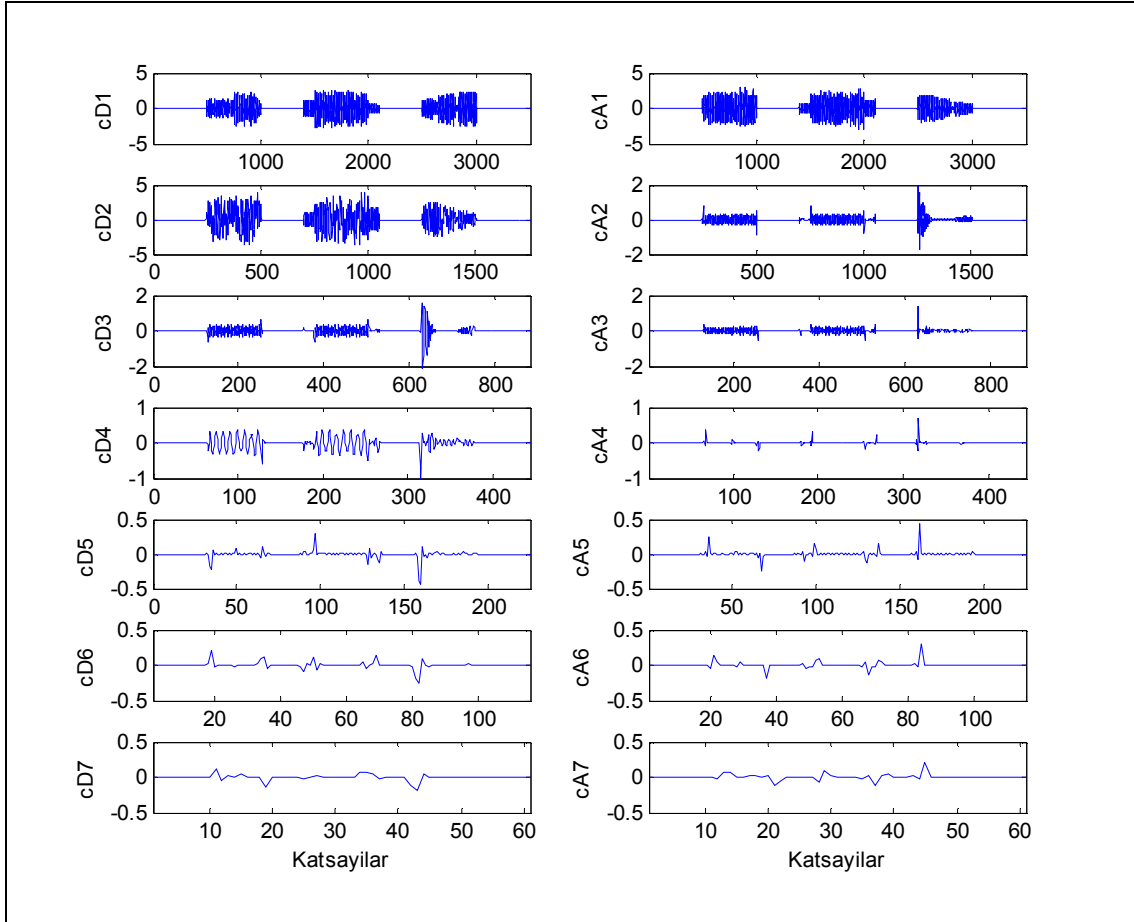
W matrisinin oluşturulması aşamasında [57–60]'ta belirtilen seyreklik, doğruluk derecesi ve işlem zamanı açısından en uygun (optimum) dalgacık olarak Daubechies [61] dalgacı ve optimum kaybolan moment sayısı $N_m = 4$ alınmıştır. Burada seçilen dalgacık türünün Daubechies olmasının başka bir nedeni sinyallerin kondüsyon sayılarıdır. Kondüsyon sayıları iteratif seyrek çözümlerde çözüm zamanını belirleyen önemli bir faktördür. Daubechies türü ortogonal taban (dik taban) işlevleriyle yapılan dönüşümlerde sinyallerin kondüsyon sayıları dönüşümden sonra da korunur. Guan ve arkadaşlarının yaptığı yayında, dalgacık dönüşümünde taban işlevleri olarak Daubechies dalgacıkları kullanmanın sinyalin kondüsyon sayısını değiştirmede gösterilmiştir [62]. Bu nedenle bu çalışmada, dönüşümden sonra sinyalin kondüsyon sayısını değiştirmemeleri, Daubechies dalgacık türünün bir başka tercih edilme sebebidir [63]. Çalışmada kullanılan Db4

dalgacıma ait katsayılar şu şekildedir; $h_1 = \frac{1+\sqrt{3}}{4\sqrt{2}}$, $h_2 = \frac{3+\sqrt{3}}{4\sqrt{2}}$, $h_3 = \frac{3-\sqrt{3}}{4\sqrt{2}}$,

$h_4 = \frac{1-\sqrt{3}}{4\sqrt{2}}$ ve $g_1 = h_4$, $g_2 = -h_3$, $g_3 = h_2$, $g_4 = -h_1$ değerlerini almaktadırlar [61].

Bu bölümde de konunun anlaşılması için SDD için Şekil 3.5'te verilen sentetik işaret ADD ile 7. seviyeye kadar dalgacık detay ve yaklaşık katsayılarına ayrıştırıldı ve bu dalgacıklar Şekil 3.7'de verildi. Şekilde görüldüğü gibi ADD zaman–frekans domeyni yerine belirlenen frekans bantlarındaki herhangi bir harmoniğe yönelmek için daha iyi sonuç verir. SDD ise işaretin tüm bileşenlerinin zaman–frekans domeyninde

nasıl dağıldığını ve nasıl değiştiğini ortaya koymak için iyi sonuç verir. Dolayısıyla yapılan uygulamaya göre *SDD* veya *ADD* seçilmesi yapılır. *SDD*, daha çok işlem gerektiğinden, *ADD*'ye göre daha yavaştır ancak işaretin karakteristiğini daha gerçekçi bir şekilde sergiler.



Şekil 3.7. Sentetik işaretin 7 seviyeli *ADD*'si

3.2.3. İkiz–spektrum analizi

Bir sinyalin farklı frekanslara sahip bileşenleri arasında ister doğrusal olsun ister olmasın herhangi bir fazsal ilinti varsa, ikiz–spektrum bu ilintiyi ortaya çıkarıp sergilemek için geliştirilen istatistiksel bir sinyal işleme yöntemidir [64–66]. İkiz–spektrum, beyin gibi karmaşık, doğrusal olmayan ve çok bileşenli sinyal üreten mekanizmaların ürettiği işaretlerin bileşenleri arasında olası Gauss ve doğrusal olmayan kvadratik faz eşleşme bilgilerini ortaya çıkarmak için kullanılabilir. Bu çalışmada da deneklerden alınan apneik EEG işaretlerin bileşenleri arasındaki fazsal ilişkileri

kullanarak YSA ile UAS teşhisi yapmak için bir ön işleme olarak ikiz–spektrum kullanıldı.

İkiz–spektrum, üçüncü derece kümülantın Fourier dönüşümü olarak tanımlanmıştır [67]. Örneğin, ayrık, durağan ve sıfır ortalamaya sahip rastgele bir $x(k)$ süreci düşünelim. Bu sürecin üçüncü derece kümülantı üçüncü moment serisi cinsinden aşağıdaki gibi ifade edilebilir [66].

$$\begin{aligned}
C_{3x}(n_1, n_2) &= cum \{x(k)x(k+n_1)x(k+n_2)\} \\
&= \langle x(k)x(k+n_1)x(k+n_2) \rangle \\
&\quad - \langle x(k) \rangle \{ \langle x(k)x(k+n_1) \rangle + \langle x(k)x(k+n_2) \rangle \\
&\quad + \langle x(k+n_1)x(k+n_2) \rangle \} + 2 \langle x(k) \rangle^3
\end{aligned} \tag{3.21}$$

Burada $\langle \cdot \rangle$ beklendiği süreci ifade etmektedir.

Herhangi bir $x(k)$ işaretinin r . derece momenti ise,

$$m_{rx}(n_1, n_2, \dots, n_{r-1}) = \langle x(k)x(k+n_1)\dots x(k+n_{r-1}) \rangle \tag{3.22}$$

şeklinde ifade edilir [68, 69]. Buna göre Denklem 3.21 yeniden yazılırsa,

$$C_{3x}(n_1, n_2) = m_{3x}(n_1, n_2) - m_x(m_{2x}(n_1) + m_{2x}(n_2) + m_{2x}(n_2 - n_1)) + 2m_x^3 \tag{3.23}$$

elde edilir. Bu ifade de kısaca

$$C_{3x}(n_1, n_2) = m_{3x}(n_1, n_2) - m_{3x}^G(n_1, n_2) \tag{3.24}$$

şeklinde yazılabilir [70]. Burada $m_{3x}(n_1, n_2)$ terimi $x(k)$ 'nin üçüncü derece momenti ve $m_{3x}^G(n_1, n_2)$ ise $x(k)$ 'nin Gaussal rastgele işleminin üçüncü derece moment fonksiyonu olup, sürecin birinci ve ikinci derece karakteristiği gibi bir davranış sergiler. Eğer $x(k)$ süreci Gaussian bir süreç ise üçüncü derece kümülant fonksiyonu sıfır olur [66, 68] ve dolayısıyla,

$$m_{3x}(n_1, n_2) = m_{3x}^G(n_1, n_2) \quad (3.25)$$

eşitliği elde edilir. Temelde üçüncü derece kümülan özilişki fonksiyonu gibi düşünülse de detayda farklı şeylerdir. Özilişki fonksiyonu, iki büyüklük arasındaki ilişkiyi hesaplarken, üçüncü derece kümülan bir zaman serisi içerisindeki üç büyüklük kombinasyonları arasındaki ilişkiyi hesaplar. Özilişki fonksiyonunda olduğu gibi üçüncü derece kümülan da,

$$C_{3x}(n_1, n_2) = C_{3x}(n_2, n_1) = C_{3x}(-n_1, n_2 - n_1) = C_{3x}(n_1 - n_2, -n_2) \quad (3.26)$$

gibi simetri özelliklerine sahiptir ve bu özellikler aynen ikiz-spektruma da yansımaktadır.

İkiz-spektrum üçüncü derece kümülan fonksiyonun spektrumu olarak,

$$B(\omega_1, \omega_2) = \sum_{n_1=-\infty}^{\infty} \sum_{n_2=-\infty}^{\infty} C_{3x}(n_1, n_2) W(n_1, n_2) e^{-j(\omega_1 n_1 + \omega_2 n_2)}, \quad |\omega_1|, |\omega_2| \leq \pi \quad (3.27)$$

şeklinde ifade edilir [67]. Burada $W(n_1, n_2)$, ikiz-spektrumun değişintisini azaltmak için iki boyutlu pencere fonksiyonudur. Çalışmamızda ikiz-spektrum hesabı için 0.1 saniye aralığında Hanning penceresi kullanıldı. Denklem 3.27, $x(k)$ 'nin Fourier dönüşümü cinsinden aşağıdaki gibi de ifade edilebilir;


$$B(\omega_1, \omega_2) = \langle X(\omega_1) X(\omega_2) X^*(\omega_1 + \omega_2) \rangle. \quad (3.28)$$

Denklemdaki * işareti kompleks eşleniği belirtmektedir. Üçüncü derece kümülan özelliklerine benzer şekilde ikiz-spektrum için de,

$$B(\omega_1, \omega_2) = B(\omega_2, \omega_1) = B^*(-\omega_2, -\omega_1) = B(-\omega_1 - \omega_2, \omega_2) = B(\omega_1, -\omega_1 - \omega_2) \quad (3.29)$$

simetri özellikleri yazılabilir. İkiz-spektrumun bu simetri özelliğinden dolayı üzerinde çalışılan EEG sinyaline ait bütün ikiz-spektrum bilgisi $0 \leq \omega_2 \leq \omega_1$ ve $\omega_1, \omega_2 \leq \pi$ tanımlı üçgensel bölgede yoğunlaşmış olur. İkiz-spektrum, $B(\omega_1, \omega_2)$, içindeki diğer

bölgeler tanımlı üçgenin simetrisi olarak ortaya çıkar. Eğer bu üçgende (ω_1, ω_2) frekansında doğrusal olmayan herhangi bir QPC mevcut ise, bu QPC'ler bu bölgede belirgin bir şekilde ortaya çıkar [69]. Bir sinyalde fazı eşleşen bileşenler bir işlemenin üçüncü derece kümülanına katkı sağlar ve sinyal hakkında ekstra bilgi sunar. Dolayısıyla bu çalışmada, ikiz-spektrumun bu özelliğinden yararlanarak, EEG sinyalin içinde olası QPC'ler değerlendirilerek UAS hastalığının teşhis edilebileceği düşünüldü. Şekil 3.8'de bir ikiz-spektrum ortamı gösterilmiştir. Şekilde de belirtildiği gibi ikiz-spektrumda, karşılıklı simetrik olan 6 bölge ve bu bölgelerden ikisi $f_1=f_2$, diğer ikisi $f_1=2f_2$ ve diğer ikisi de $-2f_1=f_2$ doğrularına göre simetriktir. Her bölgede bu doğrulara göre simetrik bir spektrum meydana gelir. Normal şartlarda şekilde görülen taralı bölgede herhangi bir işaret bilgisi bulunmaz, ancak örtüşme (aliasing) olması durumunda bu alanda da irdelenmesi güç olan bileşenler ortaya çıkabilir. Bu hipotezin geçerliliğini göstermek için de aşağıda sentetik bir örnek verildi.



Şekil 3.8. İkiz-spektrumun simetri ve örtüşme bölgeleri

Örnek:

Verilen bir $x(t)$ süreci,

$$x(t) = \sum_{i=1}^3 \cos(2\pi f_i t + \theta_i) \quad (3.30)$$

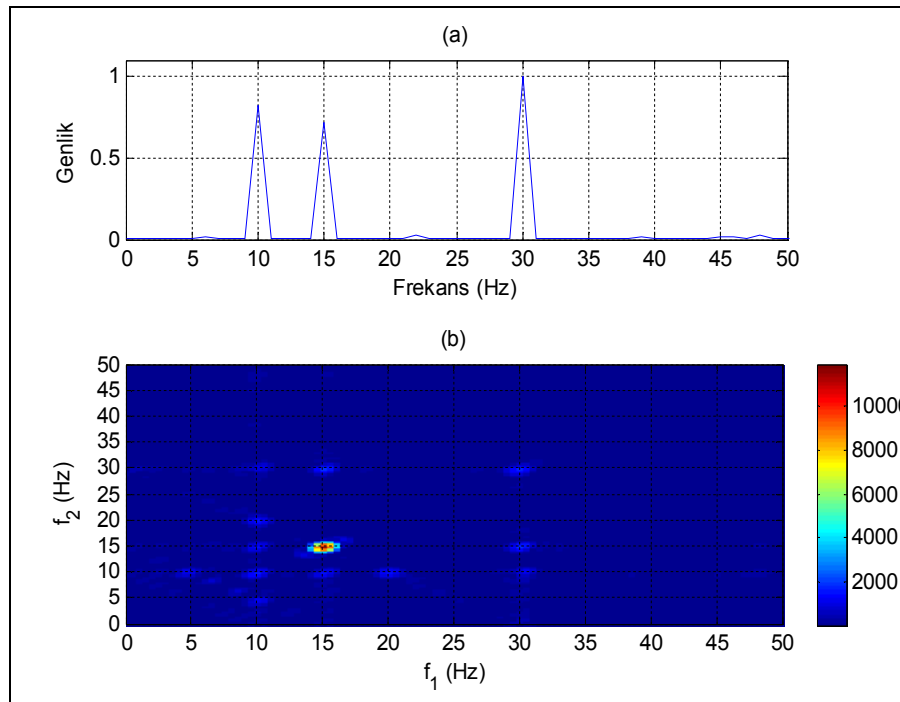
şeklinde 3 sinyalin toplamı olsun. Bu sürecin sürekli zaman domeyninde 3. derece kümülanı,

$$C(n_1, n_2) = \frac{1}{4} \{ \cos(\omega_2 n_1 + \omega_1 n_2) + \cos(\omega_3 n_1 - \omega_1 n_2) + \cos(\omega_1 n_1 + \omega_2 n_2) + \cos(\omega_3 n_1 - \omega_2 n_2) + \cos(\omega_1 n_1 - \omega_3 n_2) + \cos(\omega_2 n_1 - \omega_3 n_2) \} \quad (3.31)$$

şeklinde olur. Bu süreçte her i bileşen farklı bir yapıda olabilir ve bu bileşenler arasında eğer bir ilinti var ise bir şekilde ikiz–spektrumda bu ortaya çıkacaktır. Örneğin; bu süreç için dört farklı konfigürasyon (durum) düşünelim ve sürecin ikiz spektrumunda ortaya çıkacak olası QPC’leri araştıralım.

Konfigürasyon 1:

$f_1 = 15$ Hz,
 $f_2 = 10$ Hz,
 $f_3 = 30$ Hz ($f_3 \neq f_1 + f_2$) ve
 $\theta_1, \theta_2, \theta_3 [0 \ 2\pi]$ arasında rastgele dağılmış



Şekil 3.9. Birinci konfigürasyon için güç spektrum ve ikiz–spektrum gösterimi

Konfigürasyon 2:

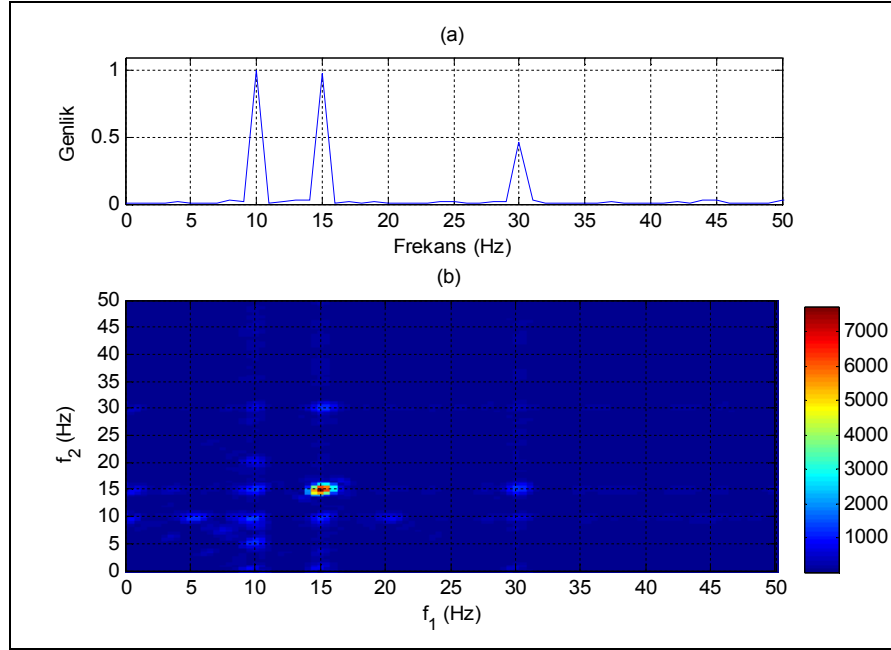
$$f_1 = 15 \text{ Hz,}$$

$$f_2 = 10 \text{ Hz,}$$

$$f_3 = 30 \text{ Hz } (f_3 \neq f_1 + f_2)$$

$\theta_1, \theta_2, [0 2\pi]$ arasında rastgele dağılmış ve

$$\theta_3 = \theta_1 + \theta_2$$



Şekil 3.10. İkinci konfigürasyon için güç spektrum ve ikiz–spektrum gösterimi

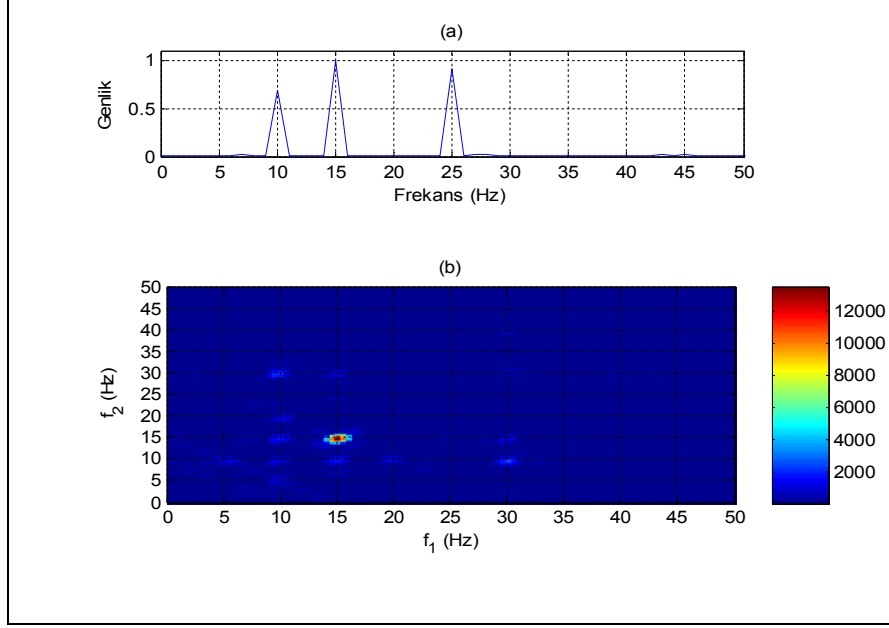
Konfigürasyon 3:

$$f_1 = 15 \text{ Hz,}$$

$$f_2 = 10 \text{ Hz,}$$

$$f_3 = 25 \text{ Hz } (f_3 = f_1 + f_2) \text{ ve}$$

$\theta_1, \theta_2, \theta_3 [0 2\pi]$ arasında rastgele dağılmış



Şekil 3.11. Üçüncü konfigürasyon için güç spektrum ve ikiz–spektrum gösterimi

Konfigürasyon 4:

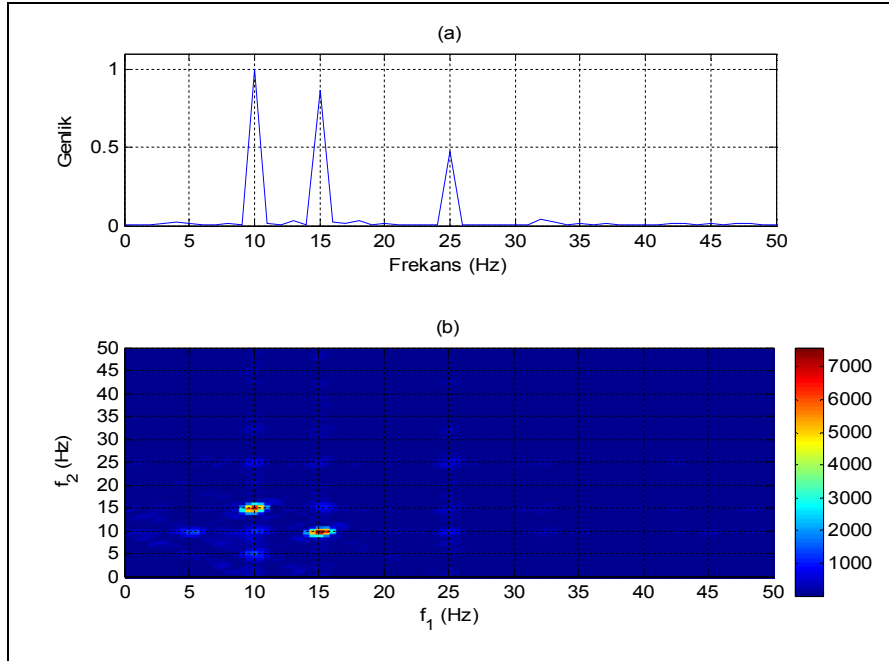
$$f_1 = 15 \text{ Hz,}$$

$$f_2 = 10 \text{ Hz,}$$

$$f_3 = 25 \text{ Hz } (f_3 = f_1 + f_2)$$

θ_1, θ_2 , $[0 \ 2\pi]$ arasında rastgele dağılmış ve

$$\theta_3 = \theta_1 + \theta_2$$



Şekil 3.12. Dördüncü konfigürasyon için güç spektrum ve ikiz–spektrum gösterimi

Verilen örnekten de anlaşıldığı gibi $f_3=f_1+f_2$ şartıyla bileşenlerin faz yapıları için iki durum söz konusudur.

1. Durum: θ_3 $[0, 2\pi]$ aralığında rastgele dağılmıştır. Bu durumda θ_3 , θ_1 ve θ_2 'den bağımsız olup ve $s(t)$ 'nin rastgele birçok fazı Gaussian istatistik olacak. $C(n_1, n_2) = 0$ ve $B(\omega_1, \omega_2) = 0$ olur.
2. Durum: $\theta_3 = \theta_1 + \theta_2$. Bu durumda θ_1 ve θ_2 fazları belli bir frekansla tamamen eşleşmiş (coupled) olacak ki bu yapı $0 \leq \omega_2 \leq \omega_1$ ve $\omega_1, \omega_2 \leq \pi$ bölgesinde f_3 frekansının f_1 ve f_2 bağımlı ve θ_3 ün de θ_1 ve θ_2 ye bağımlı olduğu durumlarda QPC sergilenecektir. Buna göre: 4. Konfigürasyonda olduğu gibi ikiz spektrum, $(f_1, f_2) = (15, 10)$ da bir QPC daha sergilemiştir. Bu çalışmada, farklı bir metot olarak, EEG işaretinde (hasta ve normal) ikiz-spektrumda ortaya çıkabilecek QPC'ler YSA ile değerlendirilip UAS sınıflaması için kullanıldı.

3.2.4. Yapay sinir ağları

Beynin üstün özellikleri, bilim adamlarının dikkatini çekmiş ve dolayısıyla onları beynin nörofiziksel yapısından esinlenerek matematiksel modeller çıkarmaya yöneltmiştir. Beynin mükemmel davranışlarını daha iyi modelleyebilmek için fiziksel bileşenlerinin doğru olarak modellenmesi gerektiği düşüncesi ile çeşitli yapay hücre ve ağ modelleri geliştirilmiştir. Böylece YSA denen yeni ve günümüz bilgisayarlarının algoritmik hesaplama yönteminden farklı bir bilim alanı ortaya çıkmıştır. Genel anlamda YSA, beynin bir işlevi yerine getirme yöntemini modellemek için tasarlanan bir matematiksel sistem olarak tanımlanabilir. YSA, yapısı, bilgi işleme yöntemindeki farklılık ve uygulama alanları nedeniyle çeşitli bilim dallarında kullanılmaktadır [71].

YSA, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmasından oluşur ve genellikle katmanlar şeklinde düzenlenir. Bir sinir ağı giriş, çıkış ve giriş ile çıkış arasında sıralanmış birkaç gizli katman ve her gizli katman da bir dizi sinir hücresi olacak şekilde tasarlanır.

Not: Eğer ağı her gizli katmanında az sayıda hücre seçilirse kompleks yapıları ayırt etme kabiliyetine sahip olamayacak, sadece doğrusal kestirim gereken problemlerde iyi sonuç verebilecektir. Diğer taraftan gizli katmanda gereğinden fazla hücre seçilmesi eğitilmemiş veriler için zayıf bir genelleme olacağından işlenmekte olan verilere gürültü eklenmesine sebep olacaktır. Bir de gizli katman sayısının gereğinden fazla seçilmesi durumunda ağı eğitim süreci daha fazla zaman alacaktır.

YSA, donanımsal olarak elektronik devrelerle ya da yazılımsal olarak bilgisayarlarda gerçekleştirilebilir. Beynin bilgi işleme yöntemine benzeyen YSA, bir öğrenme sürecinden sonra bilgiyi toplama, hücreler arasındaki bağlantı ağırlıkları ile bu bilgiyi saklama ve genelleme yeteneğine sahip paralel dağılmış bir işlemci niteliğindedir. Bu işlemcilerin ilgilenecek problemi öğrenme sürecinde, arzu edilen amaca ulaşmak için YSA ağırlıklarının yenilenmesini sağlayan, öğrenme algoritmalarına ihtiyaç duyulmaktadır. Bu algoritmaları irdelemeye geçmeden önce YSA'nın özelliklerine ve kullanım alanlarına kısaca değinelim.

3.2.4.1. YSA'nın özellikleri

Yukarıda verilen YSA tanımından da anlaşılacağı gibi, YSA paralel dağılmış bir yapıya sahip olup ve bundan dolayı da üstün bir bilgi işleme gücü, öğrenebilme ve genelleme yeteneğine sahiptir. YSA'nın özellikleri kısaca aşağıdaki gibi sıralanabilir.

- **Doğrusal olmama:** YSA'nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlerin çözümünde önemli bir araç olmuştur [72].
- **Öğrenme:** YSA'nın arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu da hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. YSA'nın karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlanmış olarak verilemez ya da tasarlanamaz. Bu nedenle YSA, istenen davranışı gösterecek şekilde ilgilendiği problemten aldığı eğitim örneklerini kullanarak problemi öğrenir [72].
- **Genelleme:** YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter içeren girişler için de doğru karakterleri verebilir. Aynı şekilde bir sistemin eğitilmiş YSA modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterecektir [72].

- **Uyarlanabilirlik:** YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, sinyal işleme, sistem tanımlama ve denetim gibi alanlarda etkin olarak kullanılabilir [72].
- **Hata toleransı:** YSA, çok sayıda seri ve paralel dağılmış hücrenin çeşitli şekillerde kendi aralarında bağlantı oluşturmuş bir yapıda olduğundan ağırlık sahibi olduğu bilgi, ağdaki bütün bağlantılar üzerine dağılmış durumdadır. Eğitim sonucunda bir YSA'nın bazı bağlantılarının, hatta bazı hücrelerinin, etkisiz hale gelmesi, ağırlık doğru bilgi üretmesini önemli ölçüde etkilemez ve bu nedenle geleneksel yöntemlere göre YSA'nın hatayı tolere etme yeteneği son derece yüksektir [72].
- **Donanım ve hız:** YSA, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda kullanılmasını sağlar [73].
- **Analiz ve tasarım kolaylığı:** YSA'nın temel işlem elemanı olan hücrenin yapısı ve modeli bütün YSA yapılarında yaklaşık olarak aynıdır. Dolayısıyla, YSA'nın farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan YSA'lar benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bu özellik, problemlerin YSA ile çözülmesinde önemli bir kolaylık sağlamaktadır [73].

3.2.4.2. YSA'nın uygulama alanları

YSA'lar, özellikle günümüzde, çözümü güç ve karmaşık olan ya da ekonomik olmayan çok farklı alanlardaki problemlerin çözümüne uygulanmış ve başarılı sonuçlar alınabilmiştir. YSA'lar çok farklı alanlara uygulanabildiğinden bütün uygulama alanlarını burada sıralamak zor olmakla birlikte genel bir sınıflandırma ile YSA'nın uygulama alanları aşağıdaki gibi altı grupta toplanabilir.

- **Arıza analizi ve tespiti:** Bir sistemin, cihazın ya da elemanın düzenli (doğru) çalışma şeklini öğrenen bir YSA yardımıyla bu sistemlerde meydana gelebilecek

arızaların tanımlanma olanağı vardır. Bu amaçla YSA, elektrik makinelerinin, uçakların, entegre devrelerin ve böylesi sistemlerin bütün bileşenlerinin arıza analizinde kullanılmaktadır [74].

- **Tip alanında:** EEG ve EKG gibi tıbbi sinyallerin analizi, kanserli hücrelerin analizi, protez tasarımı, transplantasyon zamanlarının optimizasyonu, hastalıkların teşhisi ve hastanelerde giderlerin optimizasyonu v.s. problemlere uygulanmaktadır [74].
- **Savunma sanayi:** Silahların otomasyonu ve hedef izleme, nesnelere/görüntüleri ayırma ve tanıma, yeni algılayıcı tasarımı ve gürültü önleme v.s. problemlere uygulanmaktadır [74].
- **Haberleşme:** Görüntü ve veri sıkıştırma, otomatik bilgi sunma servisleri, konuşmaların gerçek zamanda çevirisi v.s. problemlere uygulanmaktadır [71].
- **Üretim:** Üretime dayalı sistemlerinin optimizasyonu, ürün tasarımı ve analizi, ürünlerin (entegre, kağıt, kaynak v.s.) kalite analizi ve kontrolü, planlama ve yönetim analizi v.s. problemlere uygulanmaktadır [71].
- **Otomasyon ve kontrol:** Uçaklarda otomatik pilot sistemi otomasyonu, ulaşım araçlarında otomatik yol bulma/gösterme, robot sistemlerin kontrolü, doğrusal olmayan sistem modelleme ve kontrolü, elektrikli sürücü sistemlerin kontrolü v.s. problemlere yaygın olarak uygulanmaktadır [71].

3.2.4.3. Yapay hücre modelleri


Biyolojik açıdan bakıldığında, canlıları iç ve dış ortamdaki değişikliklere karşı kendi iç ortamını belirli sınırlar içerisinde koruma ve geliştirme amaçlı kontrol eden sinir sistemidir. Sinir sistemi dış ve iç ortam işaretleri algılama, işleme ve bu işaretleri elektrokimyasal olarak iletme özelliklerine sahip olan sinir hücrelerinden meydana gelmiştir.

Canlı bir sinir sisteminin temelini oluşturan bir sinir hücresi şeması Şekil 3,13'te görülmektedir. Bir sinir hücresi, hücre gövdesi ile dendrit ve akson adı verilen uzantılardan meydana gelir. Dendritler diğer sinir hücrelerinden aldığı işaretleri hücre gövdesine taşır ve hücre gövdesinde toplanan bu işaretler değerlendirilerek bir çıkış işareti üretilir ve bu işaretler akson adı verilen uzantı vasıtasıyla diğer sinir hücresine gönderilir veya iletilir. Bir sinir hücresinde birçok dendrit olmasına karşın tek bir akson

bulunmaktadır. Yani, bir sinir hücresi birçok girişe sahip olmasına rağmen tek bir çıkışa sahiptir.

Sinir hücrelerinin en büyük işlevsel özelliği ise, sinir hücresinin çevreden gelen işaretlere ya cevap vermesi ya da vermemesidir (ya hep ya hiç kuralı). Eğer sinir hücresine gelen işaret, eşik değerini aşarsa hücre tarafından kabul edilir ve cevaplandırılır, eşik değerini aşmıyorsa dendrite gelen bilgileri yok sayarak hiçbir cevap üretilmez.

İki sinir hücresi arasında (birinin dendriti ile diğerinin aksonu arasında) bağlantı/bağlantılar bulunur ve bu bağlantı yerine sinaps adı verilir. Aslında bu bağlantı noktasında veya noktalarında sinirler birbirine bağlı değildir ancak elektriksel darbelerin birinden diğerine iletilmesi (sinaptik iletim) için yeterince yakındırlar.




Şekil 3.13. Biyolojik sinir hücresi [75]

Birinci sinir hücresinin aksonu, sinir hücresinden aldığı işareti sinapslar aracılığı ile ikinci sinir hücresinin dendritlerine ileterek hücre zarının Na^+ ve K^+ iyonları geçirebilme yeteneğini değiştirme yönünde etkiler ve böylece kimyasal reaksiyon başlatır. Bu durumda, hücre zarı iyonların zarı geçmesine izin verir ve zar potansiyelini geçici olarak değiştirir [76].

Biyolojik beynin en önemli özelliklerinden birisi de, öğrenme yeteneğidir. İnsanlar ve hayvanlar, sürekli olarak içerisinde buldukları çevre ile ilişkileri neticesinde bir öğrenme işlemi içerisindeyler. Öğrenilen her yeni bilgi, beynin fonksiyonlarını hemen etkileyerek, yapılan davranışlara yansır.

Benzer şekilde bir yapay sinir hücresi de yukarıda değinilen özellikleri kısmen de olsa taşımalı ve YSA da sinir sistemini modellemelidir. Geliştirilen hücre modellerinde bazı farklılıklar olmakla birlikte genel hücre özelliklerini taşıyan bir yapay hücre modeli, Şekil 3.14'te verilmiştir. Bir yapay sinir hücresi girdiler, ağırlıklar, birleştirme fonksiyonu, etkinleştirme (aktivasyon) fonksiyonu ve çıktı olmak üzere 5 temel bileşenden meydana gelir. Girdiler, dış ortamdan ya da diğer hücrelerin çıkışlarından alınıp ilgili hücreye verilen veriler veya bilgilerdir. Bu bilgiler, bilginin hücre üzerindeki etki oranını belirleyen, bağlantı yolu üzerindeki ağırlıklar ile modüle edilir (ağırlıklandırılır). Modüle edilmiş tüm bireysel bilgiler birleştirme fonksiyonu aracılığı ile birleştirilerek (Birleştirme fonksiyonu, ağ yapısına göre maksimum alan, minimum alan ya da çarpım fonksiyonu gibi olabilir) net bir bilgi halinde hücrenin girişine verilir. Etkinleştirme fonksiyonu ise birleştirme fonksiyonundan elde edilen net bilgi girdisini işlemeye geçirerek hücre çıkışına yansıtır. Etkinleştirme fonksiyonu doğrusal ya da doğrusal olmayabilir. Hücre modellerinde, net girdiyi artıran +1 değerli polarma girişi ya da azaltan -1 değerli eşik girişi bulunabilir ki bu sabit değerli giriş vektörü genellikle x_0 , ve ağırlık vektörü ise W_0 ile gösterilir. Genel olarak yapay bir hücre Şekil 3.14'teki gibi modellenir ancak gerçekleştireceği işleve göre davranışı statik ya da dinamik olabilmektedir [71].

Şekil 3.14'te verilen modelde ağırlıkların sabit oluşu ve hücrede geri besleme ya da geciktirilmiş bir işaretin olmayışına dikkat edilirse bu hücrenin statik bir işlevi gerçekleştireceği kolayca görülür. Dolayısıyla, böylesi bir yapı sergileyen hücre modelleri *statik hücre modeli* olarak adlandırılır.



Şekil 3.14. Statik yapay hücre modeli

Şekil 3.14'ten yararlanarak, x_0 polarma girişinin W_0 ile modüle edilmiş etkisini b ile temsil edildiğini de dikkate alırsak, statik bir hücrenin matematiksel ifadesi:

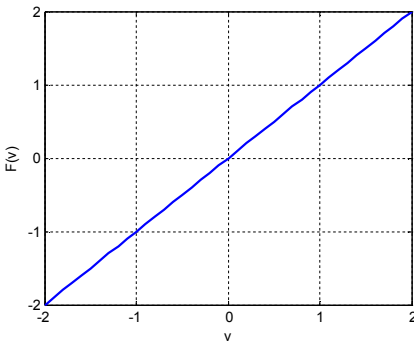
$$v = \sum_{i=0}^n W_i x_i \text{ (polarmasız) ya da } v = \sum_{i=1}^n W_i x_i + b \text{ (polarmalı) ve } y = \varphi(v) \quad (3.32)$$

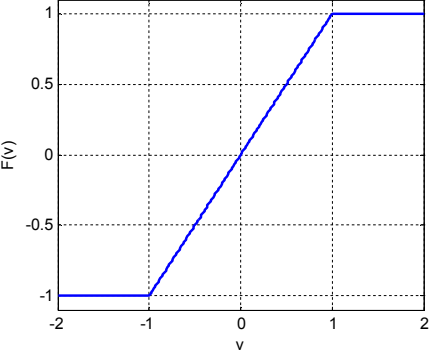
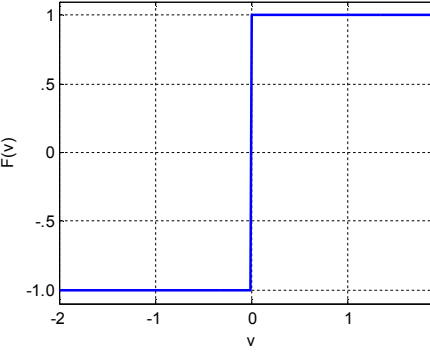
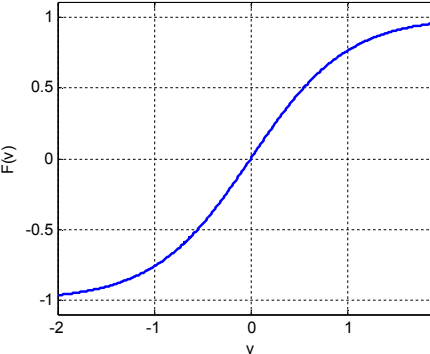
şeklinde yazılabilir. Burada, W hücrenin ağırlıklar matrisini, x hücrenin giriş vektörünü, v hücrenin net girişini, y hücre çıkışını ve $\varphi(\cdot)$ hücrenin etkileşim fonksiyonunu göstermektedir. Bir bilginin hücreden geçişi sırasında karşılaştığı en karakteristik işlem etkinleştirme işlemidir ve bu yüzden etkinleştirme fonksiyonu hakkında detaylı bir bilginin verilmesi yararlı olacaktır.

3.2.4.4. Etkinleştirme (aktivasyon) fonksiyonu

Etkinleştirme fonksiyonu hücrenin davranışını karakterize eder ve dolayısıyla hücrenin gerçekleştireceği işleve göre etkinleştirme fonksiyonun seçimi yapılır. Hücrenin statik veya dinamik yapılandırılmasına göre etkinleştirme fonksiyonu sabit parametrelili ya da uyarlanabilir parametrelili olarak tasarlanabilir. Şimdiye kadar yapılan çalışmalarda yaygın olarak kullanılan etkinleştirme fonksiyon modellerinden en önemlilerini aşağıda verilen tablodaki gibi özetlemek mümkündür.

Çizelge 3.2. Etkinleştirme fonksiyonları

FONKSİYON	İSİM ve GRAFİK	AÇIKLAMA
$F(v) = v$	<p>Doğrusal etkinleştirme fonksiyonu</p> 	<p>Doğrusal hücre ve dolayısıyla doğrusal YSA ile doğrusal bir problemi çözmek amacıyla kullanılır. Genellikle katmanlı bir YSA'nın çıkış katmanında hücrenin net girdisini çıkışa yansıtma amaçlı kullanılır.</p>

$F(v) = \begin{cases} 1 & v > 1 \\ v & -1 < v < 1 \\ -1 & v < -1 \end{cases} \text{ ise}$	<p>Doyumlu–doğrusal etkinleştirme fonk.</p> 	<p>Aktif çalışma bölgesinde doğrusal olup hücrenin net girdisinin değeri belirli bir değerin altında veya üstünde olması durumunda hücre çıkışını doyuma götürür.</p>
$F(v) = \begin{cases} 1 & v \geq 0 \\ -1 & v < 0 \end{cases} \text{ ise}$	<p>Eşik aktivasyon fonksiyonu</p> 	<p>Perceptron (Algılayıcı) sinir hücresi olarak bilinen bir etkinleştirme fonksiyonudur. McCulloch-Pitts modeli olarak da isimlendirilen eşik aktivasyon fonksiyonlu hücreler, mantıksal çıkış verir ve dolayısıyla sınıflandırıcı amaçlı ağlarda tercih edilir [76].</p>
<p>çift taraflı için:</p> $F(v) = a \frac{1 - e^{-bv}}{1 + e^{-bv}}$ <p>tek taraflı için:</p> $F(v) = a \frac{1}{1 + e^{-bv}}$	<p>Sigmoid aktivasyon fonksiyonu</p> 	<p>Sigmoid fonksiyonu , türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyondur. Doğrusal olmayan problemlerin çözümünde kullanılan YSA’da tercih edilir. a ve b katsayıları genellikle birim olarak alınır, ancak YSA’nın eğitiminde öğrenme oranını hızlandırmak için $a=1.716$, $b=2/3$ alınabilir [76]. Bu katsayıların YSA’nın eğitim sürecinde uyarlanmasıyla sabit katsayılı fonksiyona göre daha iyi bir performans elde edilebilir [76].</p>

Bu çalışmada ilgilenilen problemin doğrusal bir problem olmayışından Sigmoid etkinleştirme fonksiyonun yukarıda değinilen diğer fonksiyonlardan daha iyi performans sağlayacağı düşünüldü ve tasarladığımız YSA modelinde bu fonksiyon kullanıldı.

3.2.4.5. Yapay sinir ağlarında öğrenme

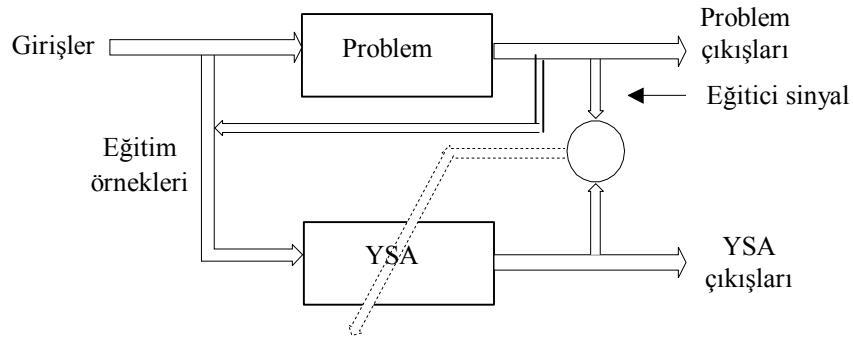
YSA'nın en önemli özelliklerinden biri, ilgilendiği problemde aldığı örneklerle öz yeteneğini bu probleme uyarlayabilmesidir, diğer bir deyişle öğrenmesidir. O halde öğrenme: bir YSA'nın ilgilendiği ortam tarafından belli bir süre uyarılması ile serbest parametrelerinin, arzu edilen öz yeteneği sağlayacak şekilde ayarlanması işlemidir [71]. Öğrenmenin tipi parametre değişikliklerinin yapılaş şekline bağlıdır.

Bu tanıma göre, öğrenme (ya da eğitim) sürecinde ağı uyarılması, bu uyarının sonucu olarak ağı parametrelerinin ayarlanması ve ağı probleme yeni bir tepki vermesi gerekir. Her yeni tepki ağıdaki ağırlıkların yenilemesini ve yeniden işlem yapılmasını gerektirir. Böylece bu yenileşim sürecinde giderek bu tepkinin arzu edilen değere yakınsaması sağlanır. YSA çıkışının yenileşim sürecinde herhangi iki hücre arasındaki bağlantı üzerindeki ağırlığın yenilenmesi,

$$W_{yeni} = W_{eski} \pm \Delta W \quad (3.33)$$

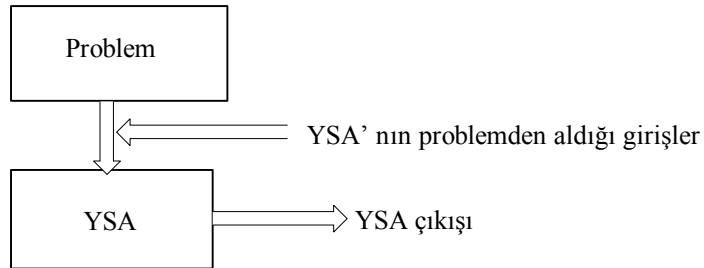
kuralına göre gerçekleşir. Burada ΔW , belirli bir kurala göre hesaplanmış o anki ağırlıklara uygulanacak düzeltme miktarıdır. ΔW 'yi belirlemek için tanımlanmış kurallara öğrenme algoritmaları ya da kuralları denir ve bu kurallar YSA'nın ilgilendiği ortam tarafından uyarılma yöntemine göre de sınıflara ayrılır. Uyarma yöntemlerine göre öğrenmeyi aşağıda verildiği gibi üç temel gruba ayırmak mümkündür

- **Eğiticili öğrenme:** YSA'nın arzu edilen problemi/sistemi öğrenebilmesi için ağı ilgilendiği ortamın (problemin/sistemin) davranışlarını ihtiva eden bir eğitici referans işaret kullanılır ve YSA çıkışında elde edilen tepkinin bu arzu edilen tepkiye yakınsaması istenir. Eğitici sinyalle birlikte problemde alınan ağı girişleri eğitim örneklerini oluşturur. Eğitici problem çıkışı ile gerçek ağı çıkışı arasındaki hata sinyaline göre YSA ağırlıkları ayarlanır. Bu süreç, hata arzu edilen değere ulaşmaya kadar devam eder ve sonuçta eğitici sinyalin temsil ettiği problemin davranışları YSA tarafından öğrenilmiş olur. Eğiticili öğrenme, fonksiyon yaklaştırma, nesne tanıma, sistem modelleme ve uyarlamalı denetim alanlarında kullanılan YSA'lar için etkin bir öğrenme yöntemidir. Bu yöntemin blok şeması Şekil 3.15'te verilmiştir [71].



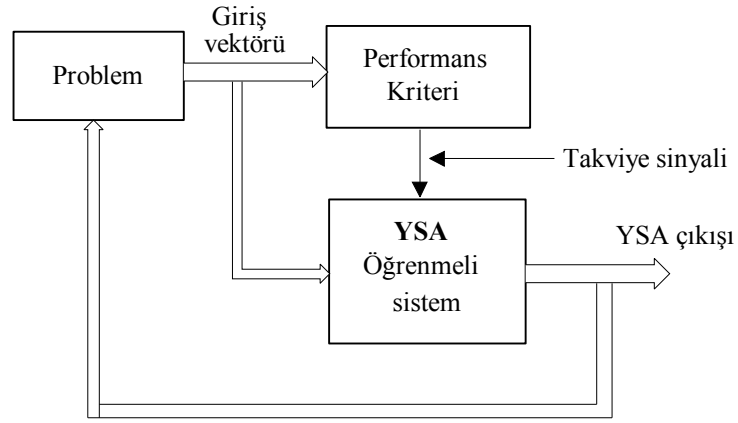
Şekil 3.15. Eğitici öğrenme yöntemi

- **Eğitici öğrenme:** Eğitici ya da kendiliğinden düzenlemeli öğrenme yönteminde ağın öğreneceği belirgin davranış örnekleri, yani eğitici bir sinyal ya da sinyaller yoktur. Ağ girişleri üzerinden gerçekleştirilmek istenen bir amaca göre YSA ağırlıkları ayarlanır. Eğitici öğrenme genellikle, ağ giriş verilerini kümelemek, sürekli zaman ağ girişlerini nitelendirmek, ağ giriş verilerini daha farklı boyutlu uzayda göstermek, ağ giriş sinyalini temsil eden özellikleri belirlemek gibi amaçlar için kullanılır. YSA'nın giriş verilerini kümeleyerek en iyi taban fonksiyonu merkezlerinin belirlenmesi, bir sinyalin öz niteliklerini çıkararak sinyal, nesne ve ses tanıma v.s. gibi uygulamalarda eğitici öğrenme yöntemleri kullanılır. Bu yöntemin blok şeması Şekil 3.16'da verilmiştir [71].



Şekil 3.16. Eğitici öğrenme yöntemi

- **Takviyeli öğrenme:** Takviyeli öğrenme yönteminde, YSA'nın öğrenmesi için bir eğitici sinyal bulunmaz ancak, ağın davranışının uygun olup olmadığını bildiren bir öz yetenek bilgisine göre ağırlıklar ayarlanır. Bu nedenle bu yöntem genellikle gerçek zamanda öğrenme yöntemi olarak bilinir ve deneme yanılma esasına göre YSA öğrenir. Bu yöntemin blok şeması Şekil 3.17'de verilmiştir [71].



Şekil 3.17. Takviyeli öğrenme yöntemi

Yukarıda değinilen öğrenme yöntemleri incelendiğinde biyolojik işaretlerin sınıflandırılması yine bu işaretlerden yararlanarak YSA eğitimi gerektiğinden bu çalışmada eğiticili öğrenme metodu benimsendi. YSA, öğrenme işlemini belli kuralları içeren öğrenme algoritmaları çerçevesinde yapar. Onun için, bu algoritmalara kısaca değinmek ve hangi algoritmanın ilgilenilen probleme (UAS teşhisi ve sınıflandırması için) daha iyi bir sonuç vereceğini belirlemek gerekir.

3.2.4.6. Öğrenme algoritmaları


Yukarıda tanımlanan öğrenme yöntemleri genel bir sınıflandırma olup YSA'nın ağırlıklarının ayarlanabilmesi için gerekli olan ayrıntıları belirlemez. Bu nedenle, herhangi bir problemi çözmek amacıyla kullanılan YSA'nın ağırlıklarının ne gibi işlemlerle yenileceğini tanımlayan çeşitli algoritmalar geliştirilmiştir. Bu algoritmaların bazıları: Algılayıcı (perceptron) Öğrenme, Örneksel ve Toplu Öğrenme ve Geriye Yayılım ile Öğrenme algoritmalarıdır. Algılayıcı algoritma bir eşik değeri ile etkinleştirilen ve çıkışta da “evet”, “hayır” anlamına gelen (0, 1) veya (-1, 1) olarak bir çıkış üreten algılayıcı YSA'ların eğitimi için kullanılır [76]. Bu algoritma genellikle bir veri setini belli bir özelliğine göre iki sınıfa ayırma işlemlerinde tercih edilir. Geriye yayılım algoritması ise bir çoklu geribesleme niteliğinde olup birçok uygulamada üstün başarımlar sağlamaktadır. Özellikle doğrusal olmayan problemlerin çözümünde tercih edilen bu algoritma detaylı bir şekilde aşağıda açıklanmıştır. Ayrıca her bir giriş vektörünü, istenen bir çıkış vektörü ile ilişkilendiren sistemler çağrışımli sistemler, Hebb öğrenme algoritması [77] ve Instar – Kohonen ve outstar öğrenme algoritması [78, 79] gibi algoritmalarla öğrenmeyi gerçekleştirir. Çağrışımli sistemler, verilen bir x_1

giriş vektörü için bir y_1 çıkış vektörü, x_2 giriş vektörü için ise y_2 çıkış vektörü üretilir. Bu sistemler, kodlayıcılar ve kod çözücülerin işlevlerine benzer işlevleri gerçekleştirirler. YSA ile bu şekildeki çağrışımlı sistemler gerçekleştirildiğinde giriş ve çıkış vektörleri arasındaki ilişkiyi belirlemek için YSA ağırlıkları bellek görevini yerine getirirler. Bu çalışmada kullanılan yöntem çağrışımlı olmadığından bu yapıdaki YSA'lara değinilmemiştir.

□ Geriye yayılım öğrenme algoritması

İster doğrusal olsun ister olmasın türevi alınabilir bir etkinleştirme fonksiyona sahip hücrelerin eğitimi genellikle hata düzeltme ya da delta kuralı [76, 77] olarak bilinen eğiticili öğrenme algoritmaları ile sağlanır. Geriye yayılım öğrenme algoritması delta (eğim azalma) algoritmasının bir gelişmiş versiyonu olup özellikle katmanlı YSA'larda çok iyi performans sergilemektedir. Bu yüzden ve ilgilenilen problemin gereği olarak bu çalışmada bu öğrenme algoritması tercih edilmiştir.

Geriye yayılım algoritmasında ağ çıkışındaki hata sinyali, delta kuralında olduğu gibi, katmanlardan geriye doğru yayılır ve bundan dolayı bu algoritmaya geriye yayılım algoritması denmiştir. Bu algoritmanın senaryosunu oluşturmak için Şekil 3.18'de verilen tek çıkışlı olan 3 katmanlı bir ileri beslemeli YSA modelini dikkate alalım. Çok çıkışlı YSA'larda ise her çıkışı, tek çıkışlı YSA'nın bir benzerleri olacağından, her bir çıkış için yapılan işlem tek çıkışlı YSA'nınkine benzerdir. Bu nedenle, Şekilde 3.18'de verilen modeli kurgulayıp analiz etmek bu çalışma için yeterli olacaktır.



Şekil 3.18. İleri beslemeli 3 katmanlı YSA sinyal akış şeması

Şekil 3.18’de verilen şemadan yararlanarak YSA’nın herhangi bir katmanındaki bir j hücrenin giriş sinyalini v_j , çıkış sinyalini o_j ile gösterirsek, bu hücrenin giriş ve çıkış denklemleri,

$$v_j = \sum_{i=0}^n W_{ji} \cdot x_i; \quad \text{ve} \quad o_j = \varphi(v_j) \quad j = 1, 2, \dots, m \quad (3.34)$$


şeklinde ifade edilir [71, 76, 77]. Burada hücrenin v_j net giriş sinyali, n adet sinyalden oluşmuş x_i giriş vektörünü (veya bir önceki katmanda bulunan hücrelerin çıkış vektörü) W_{ji} ağırlık vektörü ile modüle edip (ağırlıklandırıp) toplanarak elde edilmiştir. Hücrenin çıkışı ise, biyolojik hücrede olduğu gibi, v_j giriş sinyalinin belli bir $\varphi(\cdot)$ işleminden geçirilip çıkışa yansıtılması ile elde edilmiştir. Ağın çıkış (en son) hücresi ise bir perceptron hücresi gibi olacağından m adet j hücre çıkışlarının yine bir W_j vektörü ile ağırlıklandırıp toplayarak aşağıdaki gibi çıkışa yansıtacaktır.

$$y = \sum_{j=0}^m W_j \cdot o_j, \quad j = 1, 2, \dots, m \quad (3.35)$$

Bu da ağın çıkış sinyali olup, doğal olarak arzu edilen çıkış arasında bir fark olacaktır ki bu fark, Şekil 3.19’da gösterildiği gibi

$$e(k) = d(k) - y(k) \quad (3.36)$$

şeklinde bir hata sinyali olarak ifade edilmektedir. Bu hatayı aza indirgeyecek şekilde hücre ağırlıklarını belli bir kurala göre (burada delta kuralı) düzeltmek veya yenilemek gerekir. Optimizasyon teorisinde çeşitli hata tanımlama, hata indirgeme ve performans kriterleri önerilmiştir [71] ancak YSA’nın eğitiminde hataların kareleri ile tanımlanan *ortalama – karesel hata* tercih edilmiştir [76].



Şekil 3.19. Doğrusal olmayan hücre modeli ve bir problemi öğrenme olayı

Tek hücreli bir ağıncı çıkışında her k örneđi için $e(k)$ sinyalinin anlık enerjisi veya ortalama karesel hata:

$$E(k) = \frac{1}{2} e^2(k) \quad (3.37)$$

ve N örnek için toplam ortalama enerji veya ortalama karesel hata:

$$J = \frac{1}{N} \sum_{k=1}^N E(k) \quad (3.38)$$

şeklinde hesaplanabilir [76, 77]. Literatürde $E(k)$ *örneksel amaç ölçütü* ve J *toplam amaç ölçütü* olarak da ifade edilmiştir. Bu ölçütlerin bir W_{ji} ağırlığına göre deđişimi (eđimi) ađdaki W_{ji} ağırlıklarının, ΔW_{ji} deđişme miktarı ile orantılı olduđu gösterilmiştir [76, 77]. Eđer tasarlanan algoritmada örneksel amaç ölçütünün eđimine göre, her bir eđitim örneđinin ađa uygulanışında, ağırlıklar yenilenirse ađ örneksel öğrenme kuralı ile öğrenir. Eđer toplam amaç ölçütünün eđimine göre, N adet eđitim örneđinin uygulanışından sonra, ağırlıklar yenilenirse ađ toplu öğrenme kuralı ile öğrenir. Örneksel öğrenme ve toplu öğrenme kuralları (prosedürleri) aşıđıda verilmiştir. Buna göre, bir senaryo kurgulamak için YSA çıkışında kullanılan hücreyi düşünelim. Bu hücrenin her k örneđi için her W_j ağırlığının deđişimine göre $E(k)$ anlık hata sinyali enerjisinin deđişimi, zincir kuralına göre, Denklem 3.39'daki gibi kısmi türevlerle belirlenebilir [78].

$$\frac{\partial E(k)}{\partial W_j(k)} = \frac{\partial E(k)}{\partial e(k)} \cdot \frac{\partial e(k)}{\partial y(k)} \cdot \frac{\partial y(k)}{\partial W_j(k)} \quad (3.39)$$

Ayrıca Denklem 3.39'daki eğimlerin,

$$\delta(k) = \frac{\partial E(k)}{\partial e(k)} \cdot \frac{\partial e(k)}{\partial y(k)} = -e(k); \quad \text{ve} \quad o_j(k) = \frac{\partial y(k)}{\partial W_j(k)} \quad (3.40)$$

şeklinde ifade edilebileceği gösterilmiştir [78, 79]. Burada, δ hücre bazda hata enerjisinin değişimi gibi düşünülebilir. Yani, p . katmandaki q . hücrenin yerel hatası δ_q^p şeklinde gösterilebilir. Buna göre çıkış katmanındaki ağırlıklara uygulanacak düzeltme ve yeni ağırlıklar sırasıyla,

$$\Delta W_j(k) = \alpha \delta^2(k) o_j(k), \quad W_j(k+1) = W_j(k) - \Delta W_j(k) \quad (3.41)$$

elde edilir. Aynı şekilde, bir k örneği için hata enerjisinin ağıdaki herhangi bir j hücrendeki W_{ji} ağırlığa göre eğimi [78, 79],

$$\frac{\partial E(k)}{\partial W_{ji}(k)} = \frac{\partial E(k) \cdot \partial e(k) \cdot \partial y(k) \cdot \partial o_j(k) \cdot \partial v_j(k)}{\partial e(k) \cdot \partial y(k) \cdot \partial o_j(k) \cdot \partial v_j(k) \cdot \partial W_{ji}(k)} \quad (3.42)$$

gibi yazılır. Bu ifadede j hücrendeki δ_j hata enerjisinin değişimi,

$$\delta_j(k) = \frac{\partial E(k)}{\partial e(k)} \cdot \frac{\partial e(k)}{\partial y(k)} \cdot \frac{\partial y(k)}{\partial o_j(k)} \cdot \frac{\partial o_j(k)}{\partial v_j(k)} = -e(k) W_j(k) \varphi'(v(k)); \quad \text{ve} \quad (3.43)$$

$$\frac{\partial v_j(k)}{\partial W_{ji}(k)} = x_i$$

şeklinde olduğu literatürde gösterilmiştir [78, 79].

Böylece ağıdaki herhangi bir katmandaki herhangi bir hücrenin ağırlığındaki değişim miktarı ve hücrenin yeni bir değer alması (düzeltmesi) sırasıyla,

$$\Delta W_{ji}(k) = \alpha \delta_j(k) x_i(k) \quad , \quad W_{ji}(k+1) = W_{ji}(k) - \Delta W_{ji}(k) \quad (3.44)$$

elde edilir. Görüldüğü gibi geriye yayılım algoritmasında ağıdaki herhangi bir ağırlığa uygulanacak düzeltmenin o hücre girişi ve o hücrenin yöresel hatası ile orantılıdır. Toplu amaç ölçütüne göre öğrenmede ise, herhangi bir j hücresi için N örnek kaynaklı toplam hatanın bu hücrenin ağırlıklarına göre değişimi (eğimi) yaklaşık olarak,

$$\frac{\partial J}{\partial W_{ji}} = \frac{1}{N} \sum_{k=1}^N \frac{\partial E(k)}{\partial W_{ji}} \quad (3.45)$$

gibi ifade edilebilir ve bu ifadeyi kullanarak toplu öğrenme metodu ile de geriye yayılım algoritması elde edilir [78, 79].

Örneksel öğrenme, toplu öğrenme algoritmasının bir yaklaşığıdır, ancak gerçek-zamanlı uygulamalarda o anki örnek dikkate alındığından örneksel öğrenme gereklidir. Gerçek-zamanlı olmayan bazı uygulamalarda, alternatif olarak, her bir örnekteki örneksel eğim yerine, geçmişteki $r-1$ adet örneksel eğim değerleri ile o anki örneksel eğim değerinin ortalamasına göre ağırlıklar yenilenebilir. *Yapay-toplu* olarak ifade edilen bu algortmada ağırlıklar her eğitim örneğinde yenilediğinden hatalı duruma düşen geçmişteki $r-1$ adet eğimin etkisini azaltmak için genellikle üstel bir unutma katsayısı, $0 < \zeta < 1$, kullanılır. Yapay-toplu algoritması,

$$\frac{\partial J(k)}{\partial W_j(k)} = \sum_{l=k-r+1}^k \zeta^{l-k} \frac{\partial E(l)}{\partial W_j(l)} \quad (3.46)$$

şeklinde ifade edilir. Çeşitli sistemler üzerinde yapılan çalışmalarda bu şekilde gerçekleştirilen öğrenme algoritmasının, örneksel öğrenmeye göre, yakınsama hızı açısından daha iyi sonuç verdiği belirlenmiştir [71].

Δ Örneksel öğrenme kuralı

- ✓ $k=1$ için $x(1)=[x_1(1) \ x_2(1) \ \dots \ x_n(1)]^T$ örnek giriş vektörü ve $d(1)$ istenen çıkış belirlenir.

- ✓ $x(1)$ giriş vektörü hücre modeline uygulanarak $v(1) = W^T x(1) + b$, ve hücre çıkışı, $y(1) = \varphi\{v(1)\}$ elde edilir.
- ✓ $e(1) = d(1) - y(1)$ örneksel hata hesaplanır.
- ✓ Denklem 3.44'e göre yeni ağırlıklar, $W = W + e(1)x^T(1)$ ve $b = b + e(1)$ şeklinde yenilenir.
- ✓ $k=2,3,\dots, N$ 'e kadar her defasında yenilenen ağırlıklar kullanılmak üzere yukarıdaki işlemler tekrarlanır.
- ✓ N 'inci örnek sonunda da toplam hata sıfır olmamışsa (ya da istenen bir toplam hatanın altına düşmemişse) tekrar $k=1$ 'den başlanarak yukarıdaki işlemler tekrarlanır.
- ✓ Toplam hata istenilen bir değerin altına düşünceye kadar bu süreç devam eder.

Δ Toplu öğrenme kuralı

- ✓ $k=1,2,\dots, N$ için $x(1), x(2),\dots, x(N)$, $d(1),d(2),\dots,d(N)$, $y(1),y(2),\dots,y(N)$ ve $e(1), e(2),\dots,e(N)$ belirlenir.
- ✓ Hücre çıkışı $V = W^T .X + B$, $Y = \varphi(V)$ şeklinde matris formunda bulunur.
- ✓ $E = D - Y$ hata matrisi bulunur
- ✓ Her bir ağırlığa uygulanacak toplam düzeltme miktarları, $W = W + E \times X^T$, ve $b = b + \sum E$ bulunur.
- ✓ Toplam hata sıfır değilse (ya da istenen bir toplam hatanın altına düşmemişse) yukarıdaki işlemler tekrarlanır.
- ✓ Toplam hata istenilen bir değerin altına düşünceye kadar bu iteratif süreç devam eder.

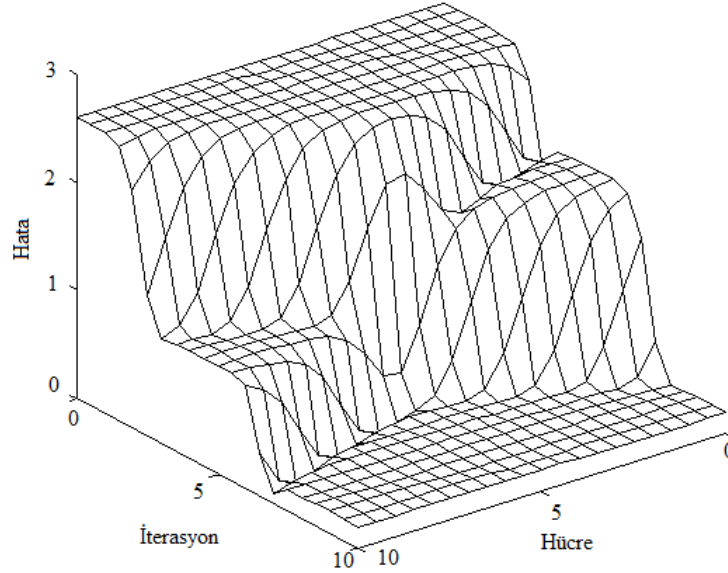
• Geriye yayılım algoritması ile öğrenmenin sakıncaları

Geriye yayılım ile öğrenme, çok boyutlu ağırlık uzayında sistem çıkışında ortaya çıkan hata yüzeyinin eğimine bağlı olarak genel minimum seviyeye birinci dereceden yaklaşmak olarak düşünülebilir. Şekil 3.20'de örnek bir hata yüzeyi verilmiştir. Öğrenim sürecinde, çoğu kez hata yüzeyinin minimumuna doğrusal yönde salınımlarla ulaşılır ve bundan dolayı da öğrenme yavaş olur. Bazen de algoritma hata yüzeyinin genel minimumuna yaklaşım sürecinde iken uğradığı herhangi bir yerel minimumda

takılıp kalır ve bu durumda ağırlıklara uygulanacak düzeltme amaç ölçütünü artırabileceğinden öğrenme gerçekleşmemiş olur, yani sonuçta istenmeyen bir sonuç elde edilir [71].

Geriye yayılım algoritmasının sakıncaları aşağıdaki gibi sıralanabilir.

1. Ağırlık uzayı boyunca hata yüzeyi oldukça düzgün olduğunda, hata yüzeyinin bir ağırlığa göre türevi çok küçük olur ve dolayısıyla ağırlığa uygulanacak düzeltme de çok küçük olacaktır. Bu durumda ağırlık öz yeteneğinin iyileşmesi uzun zaman alacaktır. Diğer taraftan, hata yüzeyi çok girintili-çıkıntılı olduğunda hata yüzeyinin ağırlığa göre türevi büyük olacaktır ki bu durumda da yüzeyin genel minimumundan uzaklaşılabilir.
2. Hatanın ağırlıklara göre negatif eğim vektörü, hata yüzeyinin minimumundan uzaklaşan bir yöne yönelebilir.



Şekil 3.20. Örnek bir hata yüzeyi

Yukarıda ifade edilen bu iki neden öğrenme sürecini ciddi bir şekilde etkilemektedir. Ayrıca algortmadaki öğrenme oranı küçük seçilirse öğrenme yavaşlayacak, büyük seçilirse ağırlık değişimleri salınımlı ve kararsız olacaktır. Bu sakıncaların etkisi, geriye yayılım algortmasında ağırlıklara uygulanacak düzeltme miktarını belirleyen Denklem 3.41 ve 3.44'e momentum (β) terimi eklenerek azaltılabilir [78, 79]. Bu denklemlerdeki ΔW ağırlık değişim miktarına momentum katsayısının eklenmesi ile sistemin istenilen hata değerine yaklaşım hızı arttırılabilir. Yani her bir k örneği için YSA daha az bir s iterasyon sayısı ile ağırlık öğrenme sürecini

tamamlar. Sonuçta, s iterasyon sayısının bir fonksiyonu olarak ağırlık değişim miktarını momentum katsayısını da dikkate alırsak,

$$\begin{aligned}\Delta W_j(s) &= \alpha \delta^2(s) \cdot o_j(s) + \beta \cdot \Delta W_j(s-1) \quad \text{ve} \\ \Delta W_{ji}(s) &= \alpha \cdot \delta_j^1(s) \cdot x_i(s) + \beta \cdot \Delta W_{ji}(s-1)\end{aligned}\tag{3.47}$$

şeklinde elde edilir [78, 79]. Momentum katsayısı $0 < \beta < 1$ aralığında probleme uygun bir değer seçilir. Amaç ölçütünün bir ağırlığa göre eğimi, ardışık iki iterasyonda aynı işaretli ise ağırlıklara uygulanacak düzeltme artar, aksi halde azalır. Uygun momentum katsayısı seçildiğinde YSA'nın öğrenme hızında iyileşme olduğu gibi sistem performansı üzerinde de olumlu etki yapmaktadır. Farklı momentum katsayıları kullanılarak öğrenme hızı ve YSA'nın performansı üzerindeki etkisi Bölüm 4'te gösterilmiştir.

3.2.4.7. Yapay sinir ağlarının avantajları

YSA'ların, sahip oldukları avantajlardan dolayı, mevcut klasik tek işlemlili çözümlerle çalışmanın zor olduğu pek çok konuda, uygulanmakta olduğu ifade edilmiştir. Bu avantajlardan bazıları aşağıda sıralanmıştır.

1. Sinir ağları genelde yüzlerce faktöre sahiptir. Bu faktörlerinin etkisi ile YSA herhangi bir istatistikî modelden çok daha kesin bir sonuçla zor problemlere cevap bulmasını sağlar.
2. İstatistikî modeller, dolaylı yoldan ilişkileri öğrenme yoluna gider. Buna karşın, sinir ağları ile problemi doğrudan modellemek mümkündür.
3. Giriş faktörlerinin çok olmasından ve verideki bozucu etkiden veya donanımın hatasından kaynaklanan sorunlar azdır.
4. Sinir ağ modellerinde bulunan her sinaps kendi işlemine sahiptir. Aynı katmanda bulunanlar arasında zaman bağımlılığı olmayıp, tamamen eş zamanlı olarak çalışırlar.

3.2.5. Adaptif ağ yapısına dayalı bulanık çıkarım sistemi

Adaptif ağ yapısına dayalı bulanık çıkarım sistemi (ANFIS) yapısal olarak Sugeno tipi bulanık sistemini temsil eden sinirsel öğrenme kabiliyetine sahip bir ağ modelidir. Bu ağ, her biri belli bir fonksiyonu gerçekleştirmek üzere, katmanlar halinde yerleştirilmiş düğümlerin birleşiminden oluşur [80, 81]. Buna göre, Şekil 3.21’de gösterildiği gibi birinci dereceden bir Sugeno bulanık çıkarım sistemi, x ve y gibi iki giriş ve f gibi bir çıkışa sahiptir. Sugeno bulanık sisteminin tipik neden–sonuç kural kümesi,


Kural-1: Eger x A_1 ise ve y B_1 ise O Halde $f_1 = p_1x + q_1y + r_1$

Kural-2: Eger x A_2 ise ve y B_2 ise O Halde $f_2 = p_2x + q_2y + r_2$

şeklinde tanımlanmaktadır [81, 82]. A_i ve B_i bulanık kümeleri ve $p_i, q_i, r_i \in R_i$ olmak üzere sonuç değişkenleridir. Bu sistemin f çıkışı ise

$$f = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2} = \overline{w_1} f_1 + \overline{w_2} f_2 \quad (3.48)$$

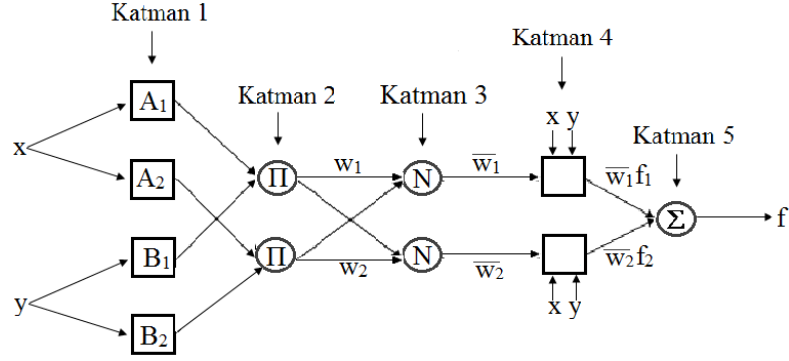
şeklinde tanımlanmıştır [83, 84]. İşte bu modele fonksiyonel olarak benzer tasarlanan ağ modeli ANFIS olarak nitelendirilir.



Şekil 3.21. Birinci dereceden iki girişli ve iki kurallı Sugeno bulanık modeli [84]

3.2.5.1. ANFIS mimarisi

Şekil 3.22’de iki girişli ve iki kurallı Sugeno tipi bulanık çıkarım yöntemine eşdeğer olan ANFIS mimarisi verilmiştir [82]. Mimari içerisindeki her katmana ait bağlantıların ve katmanların işlevleri aşağıda kısaca anlatılmıştır.



Şekil 3.22. İki girişli ve iki kurallı Sugeno tip eşdeğer ANFIS mimarisi

Katman 1:

Bu katmanda yer alan her bir i düğümünün çıkışı,

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x), & i=1,2 & \quad \text{ve} \\ O_{1,i} &= \mu_{B_i}(y), & i=1,2 & \end{aligned} \quad (3.49)$$

şeklinde tanımlanan [84] adaptif bir yapıdadır. Burada x (ya da y) düğümün girişini, A_i (ya da B_i) ise söz konusu düğümüne ait bulanık kümeyi ifade etmektedir [81]. A_i ve B_i için söz konusu üyelik fonksiyonları, uygun bir biçimde parametrelendirilmiş herhangi bir üyelik fonksiyonu olabilir. Örneğin, A_i aşağıda verilen genelleştirilmiş çan eğrisi fonksiyonu ile ifade edilebilir [81, 84].

$$\mu_{A_i}(x) = \frac{1}{1 + \left(\frac{x - c_i}{a_i}\right)^2} \quad \text{veya} \quad \mu_{A_i}(x) = \exp\left[-\left(\frac{x - c_i}{a_i}\right)^2\right] \quad (3.50)$$

Burada yer alan, $\{a_i, c_i\}$ kümesi parametre kümesidir. c_i ve a_i sırasıyla çan eğrisinin merkezini ve standart sapmasını belirlemektedir. Bu katmanın parametreleri, şart ya da giriş parametreleri olarak da ifade edilirler.

Katman 2:

Bu katmandaki her bir düğüm, Π ile etiketlenmiş kendisine gelen bilginin çarpımını çıkışa yansıtan statik bir düğümdür [83]. Her bir düğümün çıkışı, w_i tetikleme kuvveti olarak da adlandırılan,

$$O_{2,i} = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i = 1, 2 \quad (3.51)$$

şeklinde olup her bir kural için gerçekleştirme derecesini oluşturur.

Katman 3:

Bu katmanda yer alan her bir düğüm, N ile etiketlenmiş, statik bir düğümdür. Katmandaki her i . düğüm, i . kuralın gerçekleştirme derecesinin bütün kuralların gerçekleştirme dereceleri toplamına oranını belirler. Diğer bir deyişle, i . kurala ait tetikleme kuvveti Denklem 3.52'deki gibi normalize edilir [81, 83, 84].

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2. \quad (3.52)$$

Dolayısıyla, bu katmanda yer alan düğümlerin çıkışları normalize edilmiş gerçekleştirme dereceleri olarak adlandırılırlar.

Katman 4:

Bu katmana ait her i düğümü, çıkışı

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad i = 1, 2. \quad (3.53)$$

gibi bir düğüm fonksiyonu ile tanımlanan [84] uyarlanır bir düğümdür. Burada \overline{w}_i , 3. katmanın normalize edilmiş çıkışıdır. Bu normalize çıkış $\{p_i, q_i, r_i\}$ parametreleriyle gerekli miktarda ayarlanarak (ağırlıklandırılarak) bir sonraki düğümün net tetikleme seviyesini oluşturur.

Katman 5:

Bu katmanda Σ ile etiketlenmiş kendisine gelen bilginin tümünü toplayarak toplam ağ çıkışını belirleyen statik tek bir düğüm yer alır. Sonuçta ağ çıkışı,

$$O_{5,1} = \text{toplam çıkış} = \sum_i \overline{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (3.54)$$

şeklinde hesaplanır [83, 84]. Böylece Sugeno bulanık çıkarım modeline işlevsel olarak eşdeğer olan, örnek ANFIS ağı modellenmiş olur. Görüldüğü gibi ağın yapısı tamamen statik değildir. Ağın oluşturulmasında yer alan bağlantıların işlevlerini görevlerine göre ayırma, her katmandaki her bir bağlantının sağladıklarına ve modüler işlevselliğine göre keyfi olarak seçilebilmektedir ki bu da ağa bir dinamizm kazandırmıştır.

3.2.5.2. ANFIS ağında kullanılan hibrit öğrenme algoritması

ANFIS ağında öğrenme hibrit öğrenme algoritması ile iki aşamalı olarak gerçekleşir. Şöyle ki: Bilgi akışı ileri yöndeysen ağın giriş parametreleri güncellenir, geri yöndeysen ağın sonuç parametreleri güncellenir. ANFIS ağ yapısına ait parametreler de giriş ve çıkış parametreleri olarak iki kısımda ele alınır ve toplam parametre kümesi $S = S_1 + S_2$ şeklinde ifade edilir. Burada S_1 giriş parametrelerini ve S_2 çıkış parametrelerini ifade eder.

Hibrit öğrenme algoritmasında ileri yön geçişin ve en küçük kareler (LSE) tahmin'in gerçekleştiği kısımda, ağın girişindeki üyelik fonksiyonlarına ait parametreler sabit tutulur. Böylece ağın çıkışı, algoritmada bulunan çıkış parametrelerinin lineer bir kombinasyonu haline gelir. Sisteme ait P tane giriş – çıkış verisi, ya da eğitim verisi ile S_1 giriş parametre kümesinin verilen değerleri kullanılarak ağın çıkışı matrissel formda $A\theta = B$ şeklinde ifade edilebilir [82–84]. Bu eşitlikte yer alan θ vektörü S_2 çıkış

parametrelerinin elemanlarından oluşan bilinmeyen vektördür. θ için en iyi çözüm, $\|A\theta - B\|^2$ 'nin minimum değeri olan, en küçük kareler tahmini $\theta^* = (A^T A)^{-1} A^T B$ 'dir.

Hibrit öğrenme algoritmasının geri yön geçişinde, S_2 çıkış parametreleri sabit tutulur ve ağımlık çıkışındaki hata sinyali geriye doğru yayılarak, eğitim düşümü yöntemiyle giriş parametreleri güncellenir. Geri yön geçişinde giriş parametreleri için güncelleme formülü şu şekildedir [81, 85],

$$\Delta a = -\eta \frac{\partial E}{\partial a} \quad (3.55)$$

Burada a herhangi bir giriş parametresini, η öğrenme oranını ve E ağımlık çıkışındaki hata değerini göstermektedir.

Bu çalışmada YSA'ya benzer şekilde UAS teşhisi ve sınıflandırması için ANFIS de kullanıldı ve elde edilen sonuçlar değerlendirilerek YSA ile elde edilen sonuçlarla karşılaştırıldı.

4. ARAŞTIRMA VE BULGULAR

Bu çalışmada UAS teşhisi için önceki bölümde değinilen metotlar PSG yardımıyla deneklerden (hastalardan) alınan horlama, EEG, göğüs ve karın hareketi işaretlerine uygulandı. Elde edilen sonuçlar değerlendirilerek yöntemler, uygulanabilirlik, kolaylık, analiz süresi ve başarımlarından performansları açısından karşılaştırıldı. Bu açıdan Apne teşhisi için yapılan her bir yaklaşım veya çalışma aşağıda detaylı bir şekilde irdelenmiştir.


4.1. Horlama Verisinden UAS Kestirimi

Bu bölümde apne hastalardan alınan horlama sesleri kullanılarak bir UAS kestirim yöntemi geliştirildi. Burada horlama sesinin zaman–frekans analizinden elde edilen veriler YSA ile değerlendirilerek apne teşhis edilmeye çalışıldı.

4.1.1. Horlama sesi verilerinin zaman–frekans analizi

21 hastadan alınan horlama ses sinyalleri 512 Hz örnekleme frekansı ile örneklenecek şekilde 16 bit çözünürlükte sayısallaştırıldı. Bu sayısal verilerden uzman hekim desteğiyle 1500 normal ve 1500 de UAS'li horlama olmak üzere toplam 3000 horlama epizodu alınarak zaman–frekans analizi için bir veri tabanı oluşturuldu.

Horlama, normal solunum sesine baskın gelen keskin ve karmaşık değişimler (epizodlar) şeklinde sinyal üzerinde geniş bir frekans bandında kendini göstermektedir. Çalışmamızda, literatürde benimsenen horlama epizodunun sistematik modeli benimsendi [86]. Bu model Şekil 4.1'de verildiği gibi p 'nci mertebeden bir rekursif (geri beslemeli) filtreye benzetilmektedir. Bu filtrenin giriş sinyali $u(t)$, kazancı G , ve horlama sesini temsil eden çıkış sinyali $s(t)$ ile ifade edilmiştir.



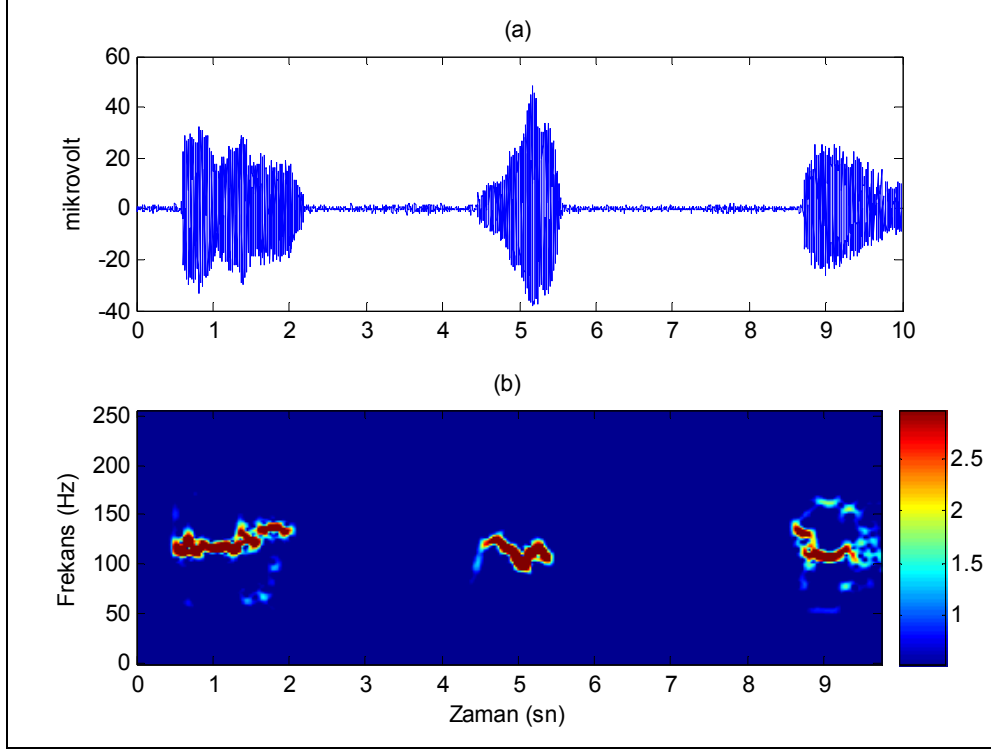
Şekil 4.1. Horlama işaretlerinin sistematik modeli. a_k , $k=1,2,\dots,p$ filtrenin sabit katsayılarıdır

Horlama episodlarının yaklaşık olarak bu modelin çıkışında elde edilen işarete benzeşen, durağan olmayan, bir işaret türü olduğu için zaman–frekans tekniğinin bu işaretin karakteristik yapısı hakkında daha detaylı bilgi sağlayacağı düşünüldü. Zaman–frekans tekniklerinden *SDD* kullanılarak birer frekans ara ile artan bir lineer frekans filtre bankası oluşturuldu. Model dalgacık olarak da kompleks Morlet [87] dalgacık formu seçildi. Morlet dalgacığını seçmemizin nedeni, ortalaması sıfır ve içerdiği enerjinin de 1'e eşit Gaussian bir dağılıma sahip olmasıdır. Böylece seçilen bu formdaki dalgacık, sinyal üzerinde minimum gürültü oluşturacak hem zaman ve frekans parametrelerinin ikisi için de çok iyi bir yerelleştirici hem de genlik ve faz bilgisini sağlayacaktır [88]. Ayrıca bu dalgacık, horlama seslerinin harmonik frekansları arasındaki aynılığı (coherence) yakalamak için de iyi bir araçtır.

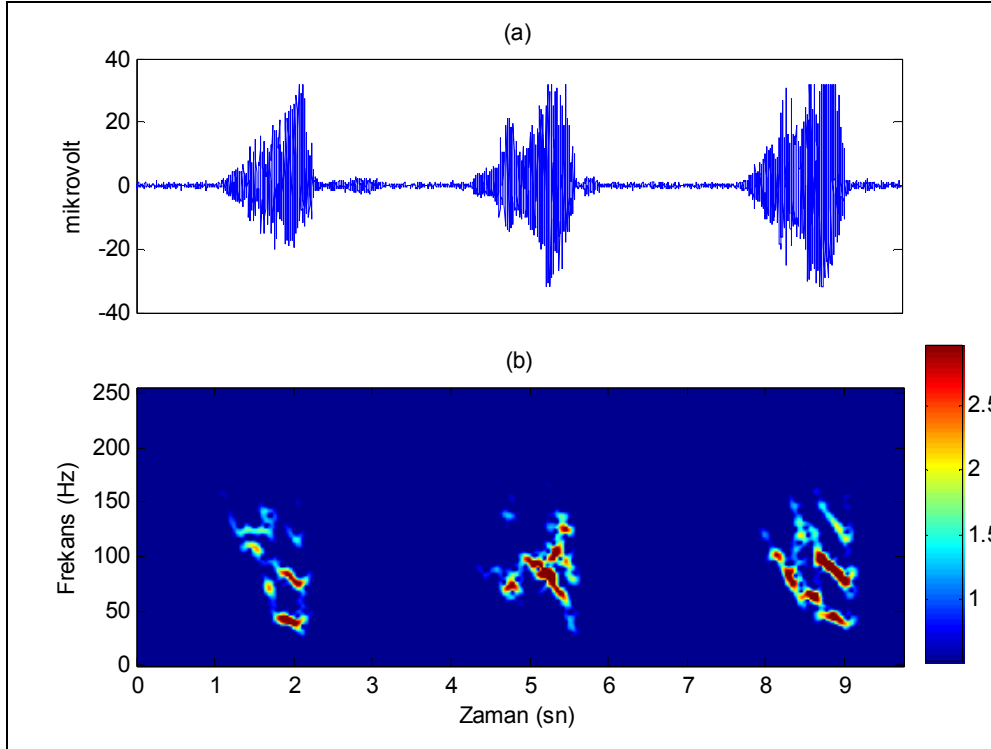
Oluşturulan bu filtre bankası 10 saniye süre ile kayıt yapılmış birkaç episod içeren $s(t)$ horlama işaretlerine uygulandı ve işaretlerin 1–250 Hz bant aralığında zaman frekans enerji dağılım karakteristikleri elde edildi. Elde edilen bu sonuçlardan her bir durum için örnekler Şekil 4.2 – 4.10 arasında gösterildi.

Horlama sesleri zaman ve frekans ortamlarında ayrı ayrı incelendiğinde zaman domeyninde olduğu gibi sinyal genliğinin genellikle apneden önce yüksek ve apneden sonra nispeten azaldığı görülmektedir. Ancak bu standart bir bulgu değildir, hastadan hastaya değişebilmektedir. Doğal olarak her hastanın belli bir frekans bandına sahip kendisine özgü bir horlama tarzı vardır. Bu farklılıklar, horlama sesinin zaman–frekans enerji dağılımında kendini daha da açık bir şekilde göstermektedir.

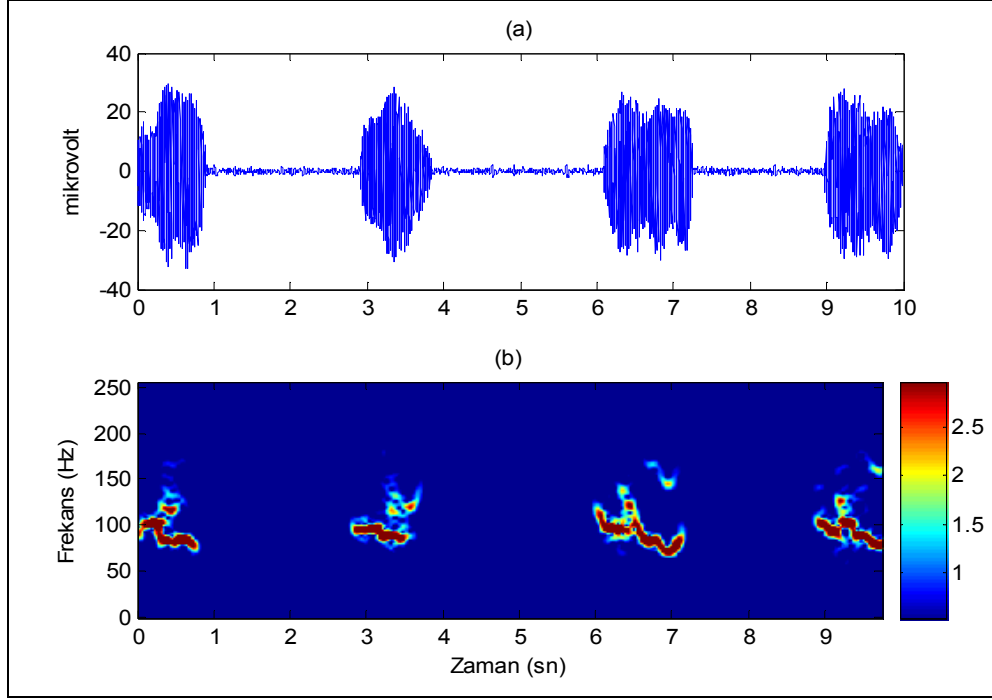
Elde ettiğimiz zaman–frekans karakteristikleri, horlama seslerinin basit birer durağan işaret olmadığını, tam aksine kompleks ve durağan olmayan bir işaret olduğunu göstermektedir. Dolayısıyla basit horlama ile UAS horlama arasındaki detaylı farkın basit tekniklerle anlaşılamayacağı düşünüldü. Şekil 4.2 – 4.4'te basit bir horlama sesinin zaman frekans yapısını ortaya koyan örnekler gösterilmiştir. Şekillerden de görüldüğü gibi horlama episodlarının frekans bandı yaklaşık olarak 75–150 Hz arasında kalmaktadır. Oluşturulan horlama seslerini, veri tabanından alıp incelediğimiz işaretlerde bu episodların genellikle 100 Hz civarında yoğunlaşarak tepe değerine ulaştığı görülmektedir. Bu durumda sinyal episodları daha düzgün ve seyrek olup, maksimum spektral genliğin apne durumuna göre daha düşük olduğu anlaşılmaktadır.



Şekil 4.2. Apneik olmayan horlama işareti ve (t, f) gösterimi

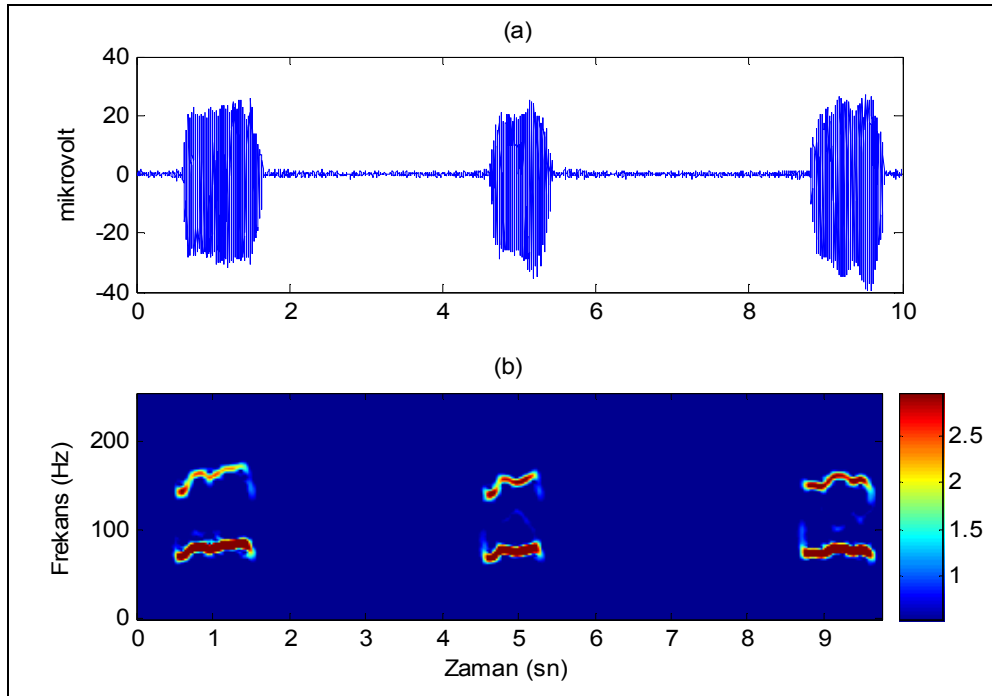


Şekil 4.3. Apneik olmayan horlama işareti ve (t, f) gösterimi

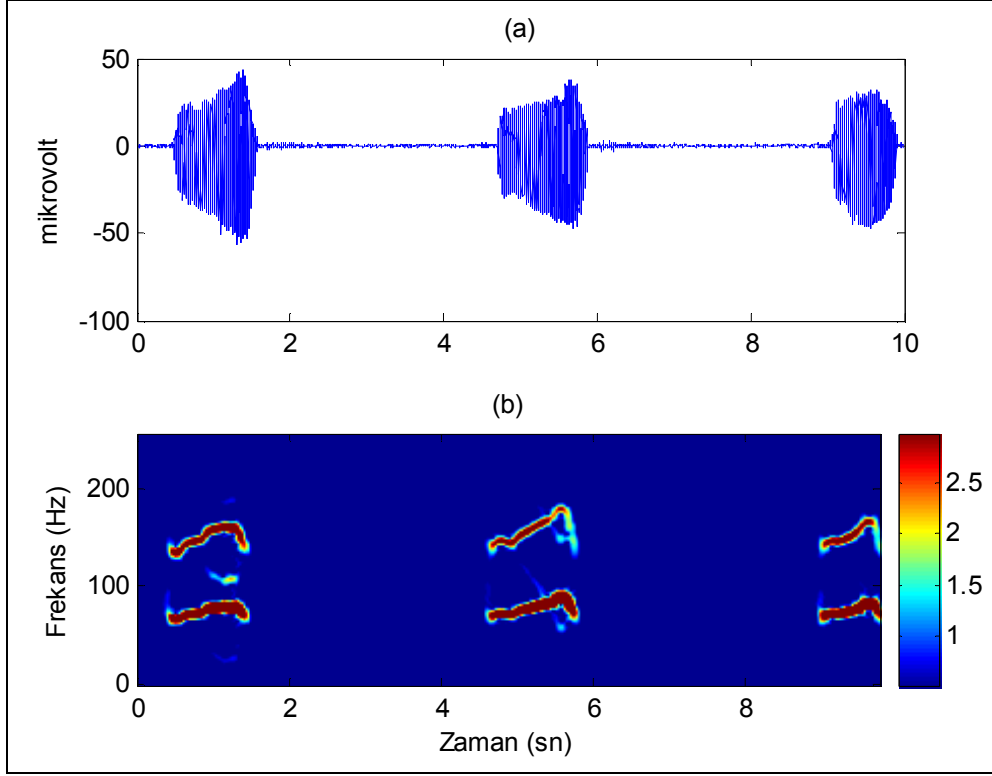


Şekil 4.4. Apneik olmayan horlama işareti ve (t, f) gösterimi

Şekil 4.5 ve 4.6’da ise yarı apne (hipopne) durumunu gösteren örnek işaretlerin zaman–frekans yapısı verilmiştir. Görüldüğü gibi bu durumda horlama episodları basit bir horlamaya göre daha geniş bir banda yayılmıştır ve bu bant içerisinde işaret birkaç tepe yapmıştır veya yapabilmektedir. Ayrıca episodlar arası süreler de daha düzensizdir.

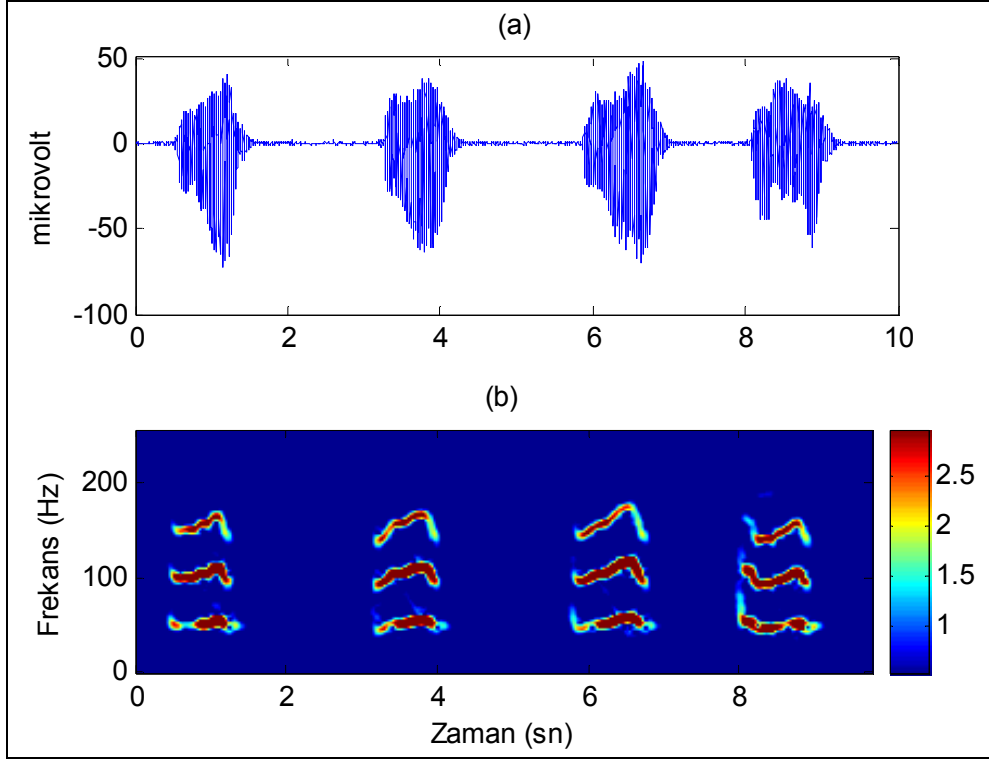


Şekil 4.5. Yarı–apneik (hipopne) horlama işareti ve (t, f) gösterimi

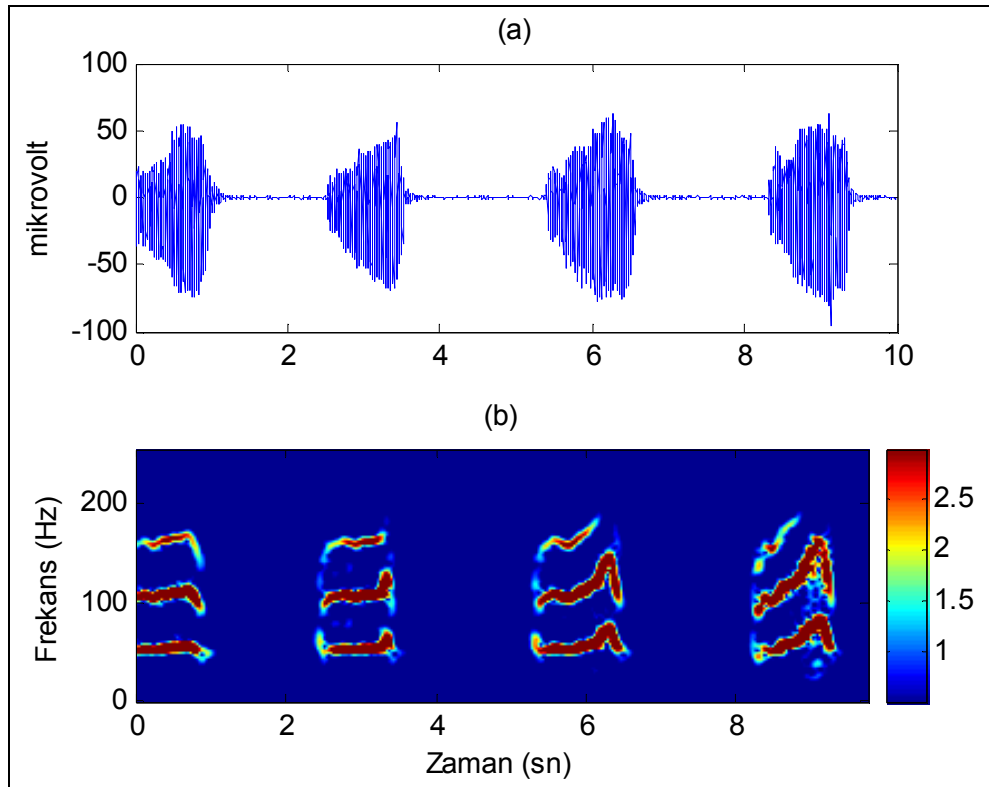


Şekil 4.6. Yarı–apneik (hipopne) horlama işareti ve (t, f) gösterimi

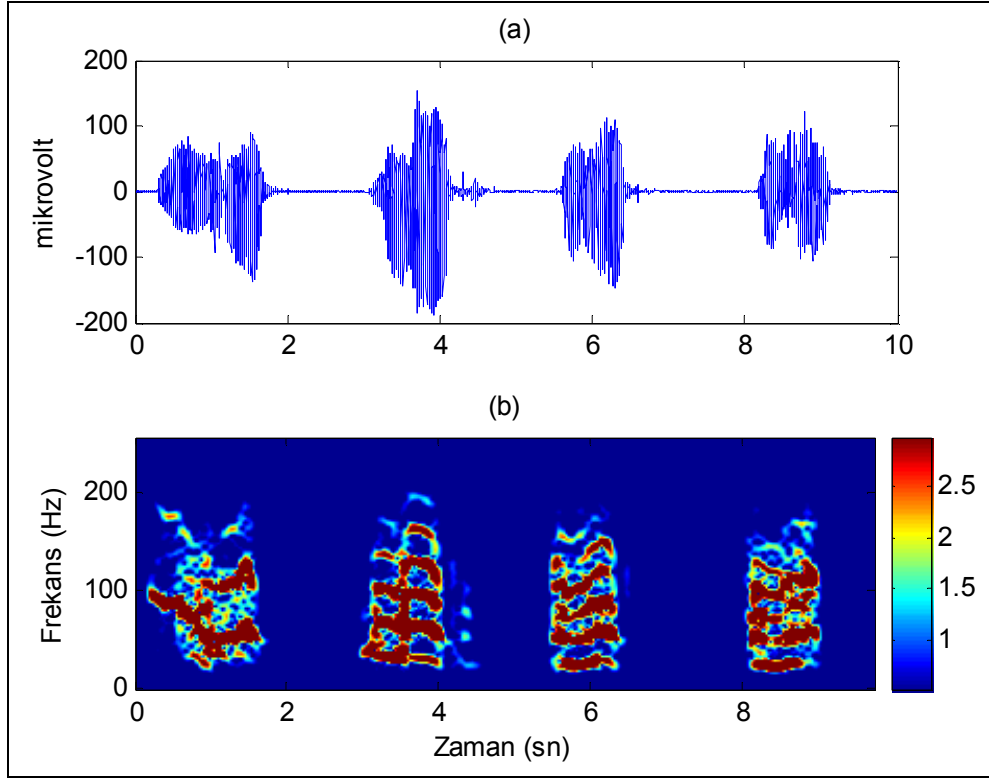
Şekil 4.7–4.10’da ise UAS hastalarının horlama sinyallerine ait dört örnek verilmiştir. Bu işaretlerde episodların frekans bandı yaklaşık olarak 1–200 Hz olduğu görülmektedir. İşaret enerjisi belirli bir dar bantta yoğunlaşma yerine bu geniş bant içerisinde gelişigüzel serpilmiştir. Basit horlamaya göre işaretin episod ve episodlar arası süreleri sık ve düzensiz olup maksimum genlik daha yüksektir. Böylesi geniş bir frekans bandı ve düzensiz bir yapı, UAS hastalarında üst hava yolunda titreşerek horlamaya neden olan dokunun çoklu–segment yapıya sahip olduğunu göstermektedir. Ayrıca UAS’ye ait bu dört işarete olduğu gibi her hastanın kendine özgü bir horlama karakteristiğine sahip oluşu, hastada bulunan nefes yolunun standart olmadığını göstermektedir. Horlamaya neden olan dokunun yeri, şekli ve yapısı tıkama eğiliminin şeklini belirler ki, bu değişiklik genellikle üst hava yolu direnci (ÜHD) olarak ölçeklendirilmektedir. ÜHD, UAS hastalarında basit horlayanlara göre daha düşük olarak çıkmaktadır.



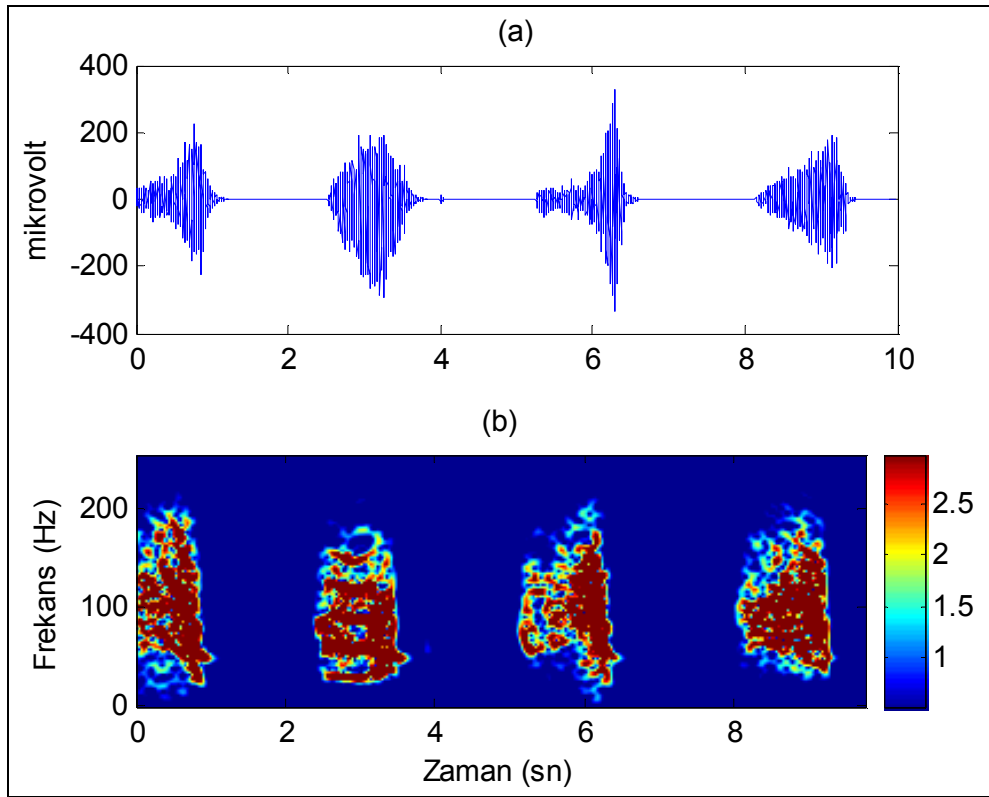
Şekil 4.7. Apneik horlama işareti ve (t, f) gösterimi



Şekil 4.8. Apneik horlama işareti ve (t, f) gösterimi



Şekil 4.9. Apneik horlama işareti ve (t, f) gösterimi



Şekil 4.10. Apneik horlama işareti ve (t, f) gösterimi

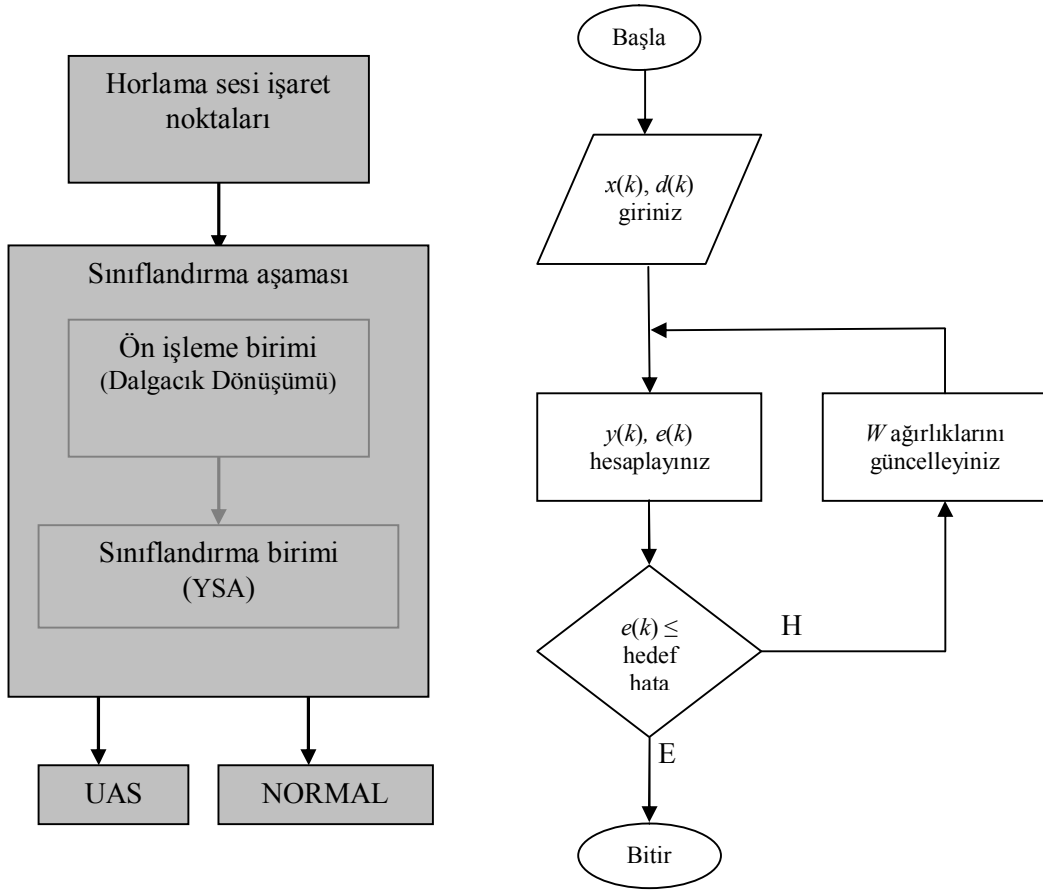
Daha önce yapılan çalışmalarda horlama işaretinin güç spektrumunda çok belirgin olmayan farklı frekans bilgileri olduğu ve bu bilgilerden apne sendromunun kolayca ayırt edilebildiği ifade edilmiştir [89–91]. Örneğin, apne grupları arasındaki fark olarak ölçülen horlama parametrelerinin yerel değişim miktarı AHI ile iyi bir ilintiye (korelasyona) sahip olduğu ifade edilmiştir ($r = 0.71$). Özellikle UAS hastalarında ya sinyal şiddetinde ya da frekans domeyninde ölçülen basit parametrelerde dikkate değer değişkenlik gözlenmiştir [89]. Bu çalışmada, yukarıda değinilen bulguları doğrular nitelikte, apneik horlama ses sinyalinde episod sıklığının değişim bilgisinin yanı sıra, 75–150 Hz spektral bandının ortalama enerjisi 0–75 Hz ile 150–200 Hz arası bantların ortalama enerjisine oranının, apne indeksi ile direkt olarak ilişkili olduğu görüldü ($r > 0.75$).

Apneik horlama seslerinin bu gözlenen özellikleri kolaylıkla bir YSA ile kestirilebileceği düşünüldü ve bunun için aşağıda açıklanan biçimde UAS kestirimi yapıldı.

4.1.2. Horlama işaretlerinden UAS'nin YSA ile kestirimi

Dalgacık dönüşümü metoduyla zaman–frekans spektrumu gösterilen horlama işaretlerinin UAS horlaması olup olmadığına karar verebilecek bir Dalgacık–Sinir ağı modeli oluşturuldu. Bu model Şekil 4.11'de gösterilmiştir. Çalışmanın bu bölümünde YSA'nın hem eğitim, hem de test aşamasında uzman hekimler tarafından yarı apne olarak nitelendirilen veriler de apne olarak dikkate alındı.

Her biri 10 saniyelik toplam 3000 adet horlama episodü (1500 normal ve 1500 UAS) dalgacık dönüşümü ile 0–40 Hz, 40–80 Hz, 80–120 Hz, 120–160 Hz ve 160–200 Hz olmak üzere 5 frekans bandına ayrıştırıldı. Her banda ait spektrumlarının enerjileri hesaplanarak YSA için bir veri tabanı oluşturuldu. Normal ve UAS horlama episodlarından 40'ar adet episod, ağı eğitimi için kullanıldı. Geri kalan 1460'ar adet episod ise test için kullanıldı.




Şekil 4.11. Geliştirilen modelin şematik yapısı ve modelde kullanılan YSA'nın eğitim akış şeması

YSA modelinin oluşturulmasında kullanılan özellikler Çizelge 4.1'de verilmiştir.

Çizelge 4.1. Geliştirilen sinir ağı'nın özellikleri

Katman sayısı	4 (1 giriş, 2 gizli ve 1 çıkış)
Giriş katmanı büyüklüğü	5x80
Gizli katmanların büyüklüğü	10
Çıkış katmanı büyüklüğü	2x1
Öğrenme oranı	0.05
Performans fonksiyonu	SSE(sum-squared error)
Öğrenme hata hedefi	0.001
Momentum katsayısı	0.95
Aktivasyon fonksiyonu	bipolar sigmoid

Oluşturulan sinir ağı eğitilerek test edildi. Ağı eğitimi süresince toplam karesel hatanın minimum hataya yakınsaması ve eğitim boyunca öğrenme oranının değişimi Şekil 4.12'de gösterilmiştir. Şekilden de görüldüğü gibi, sinir ağı 5284 iterasyonda istenen hata değerine ulaşarak eğitimini tamamlamıştır.



Şekil 4.12. YSA çıkışının istenen hata değerine yakınsaması ve öğrenme oranının değişimi

Bütün test verileri eğitilen ağda test edildikten sonra, elde edilen sonuçlar uzman hekimlerin değerlendirmeleri ile karşılaştırıldı. Bütün test sinyallerine karşı ağın gösterdiği performans değerleri Çizelge 4.2’de verilmiştir. Geliştirilen bu model ile ortalamada %97.50’lik bir doğruluk ile sınıflandırıcı sistemin horlama seslerinden apne durumunu teşhis edebildiği görüldü.

Çizelge 4.2. YSA’nın test sinyallerinde verdiği sınıflandırma performansı

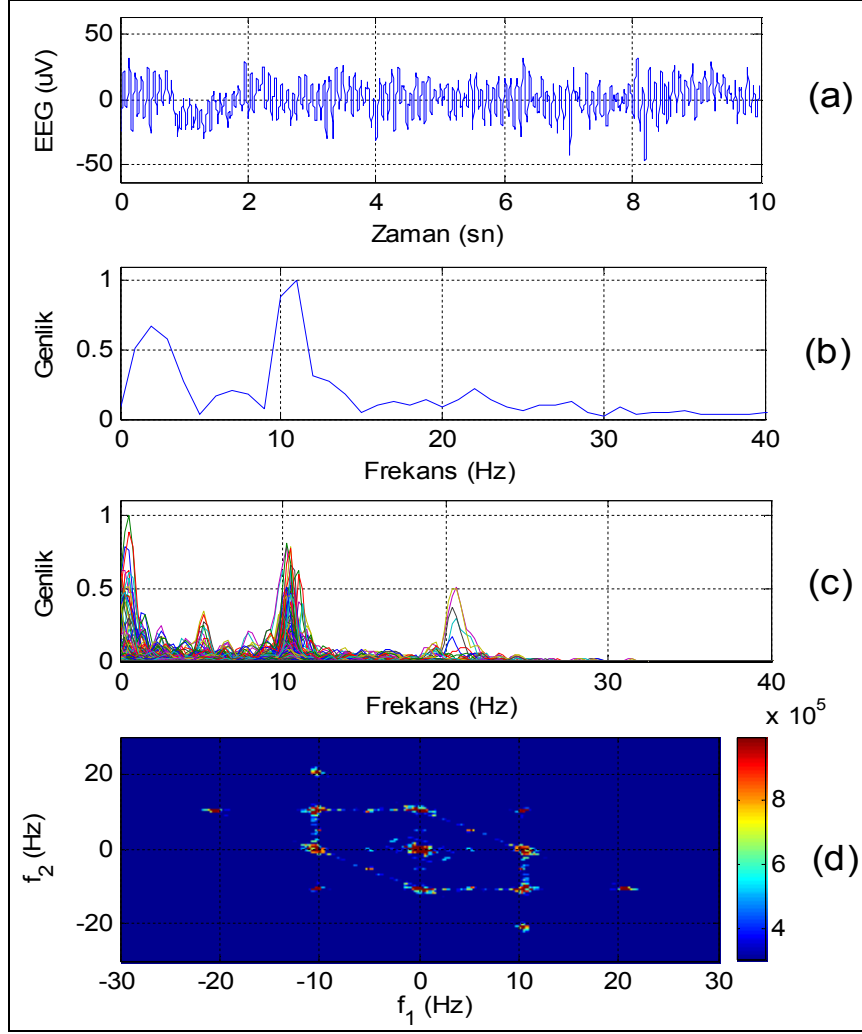
	UAS	NORMAL	Toplam
Doğru Teşhis	1405	1442	2847
Yanlış Teşhis	55	18	73
Doğruluk (%)	96.23	98.77	97.50

4.2. EEG Verisinden UAS Kestirimi

Bu bölümde normal kişi ve apne hastalardan alınan EEG verisi kullanılarak bir UAS kestirim yöntemi geliştirildi. Burada EEG verisinin ikiz–spektrumu alınıp YSA ile apne teşhis edilmeye çalışıldı.

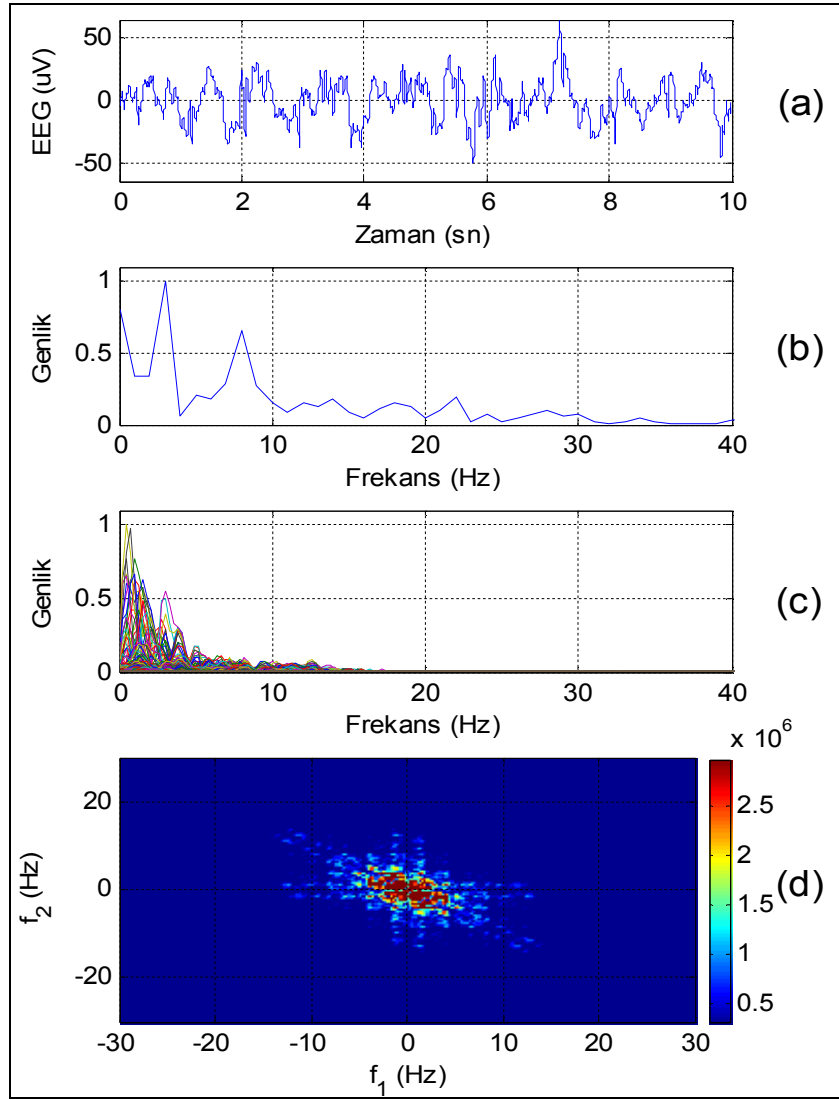
4.2.1. EEG verilerinin ikiz–spektrum analizi

Çalışmada ikinci bir metot olarak PSG yardımıyla alınan EEG işaretinin (EEG'nin doğrusal bir işaret olmadığı düşüncesiyle) bileşenleri arasında olası QPC'leri ortaya çıkarmak için ikiz–spektrum analizi yapıldı. EEG'nin ikiz–spektrum analizi sonucunda ortaya çıkan QPC enerjisi tasarlanan YSA'da değerlendirilerek UAS teşhisinin bu metotla yapılıp yapılamayacağı araştırıldı. Şekil 4.13'te normal bir EEG işareti, ikiz–spektrumu ile bir karşılaştırma ölçütü oluşturmak için güç spektrumu ve ikiz–spektrumun pozitif frekans kısmı gösterilmiştir. Analizin kolay yapılabilmesi için şekillerde güç spektrumu ve ikiz–spektrumun pozitif frekans gösterimlerin genlik değerleri 0–1 aralığına normalize edilmişlerdir. Şekil 4.13b'de verilen işaretin güç spektrumu incelendiğinde işareti oluşturan asıl bileşenlerin 2 Hz ile 11 Hz civarında olduğu görülür. Şekil 4.13c'de ikiz spektrumun pozitif frekansı incelendiğinde güç spektrum ile ortaya konan frekans bileşenleri bilgisine ilave olarak 21 Hz ve 5 Hz civarında kayda değer bileşenlerin de olduğu görülmektedir. Ayrıca 0–2 Hz arası için ikiz–spektrumun genliği (Şekil 4.13c) aynı frekans bölgesi için güç spektrum genliğinden (Şekil 4.13b) daha yüksek olduğu görülmekte ve bunun sebebinin bu frekans aralığında doğrusal olmayan bileşenlerin QPC bileşkesinin katkı yaptığı düşünülmektedir. Şekil 4.13d'de verilen ikiz spektrumda da bu bileşenleri gözlemlemek mümkündür.



Şekil 4.13. Normal EEG işareti; (a) EEG işareti, (b) işaretin güç spektrumu, (c) ikiz–spektrum (pozitif frekans için), (d) işaretin ikiz–spektrumu

Aynı senaryo UAS olan bir EEG işareti için tasarlandı ve sonuçları Şekil 4.14’te verildi. Bu durumda ikiz–spektrumun 5–10 Hz frekans bölgesindeki bileşenleri güç spektrumun aynı frekans bölgesine göre daha düşük genlikte oldukları görülmektedir. Ayrıca UAS’li bir insanın EEG işaretinin sağlıklı bir insanın EEG işaretine göre, daha önce de değinildiği gibi, daha düşük frekanslarda seyrettiği açıkça görülmektedir. Bu iki örnekte ortaya konulan bilgilerin doğru olduğunu ortaya koymak için daha geniş bir örnekleme ile, 1500 normal ve 1500 UAS EEG’sinin ikiz–spektrum analizleri yapıldı. Bu sonuçlardan elde edilen tepe değerleri için ortalama frekansları ve standart sapmaları alınıp quantifiye edilerek Çizelge 4.3’te verildi. Çizelge 4.3’ten de anlaşıldığı gibi apneik hastalara ait EEG işaretlerinin normal EEG işaretlerine göre ortalamada daha düşük frekanslarda yoğunlaştığı anlaşılmaktadır.



Şekil 4.14. UAS EEG işareti; (a) EEG işareti, (b) işaretin güç spektrumu, (c) ikiz–spektrum (pozitif frekans için), (d) işaretin ikiz–spektrumu

Çizelge 4.3. Normal ve UAS EEG’lerinde ortalama tepe değerlerinin ortaya çıktığı frekanslar

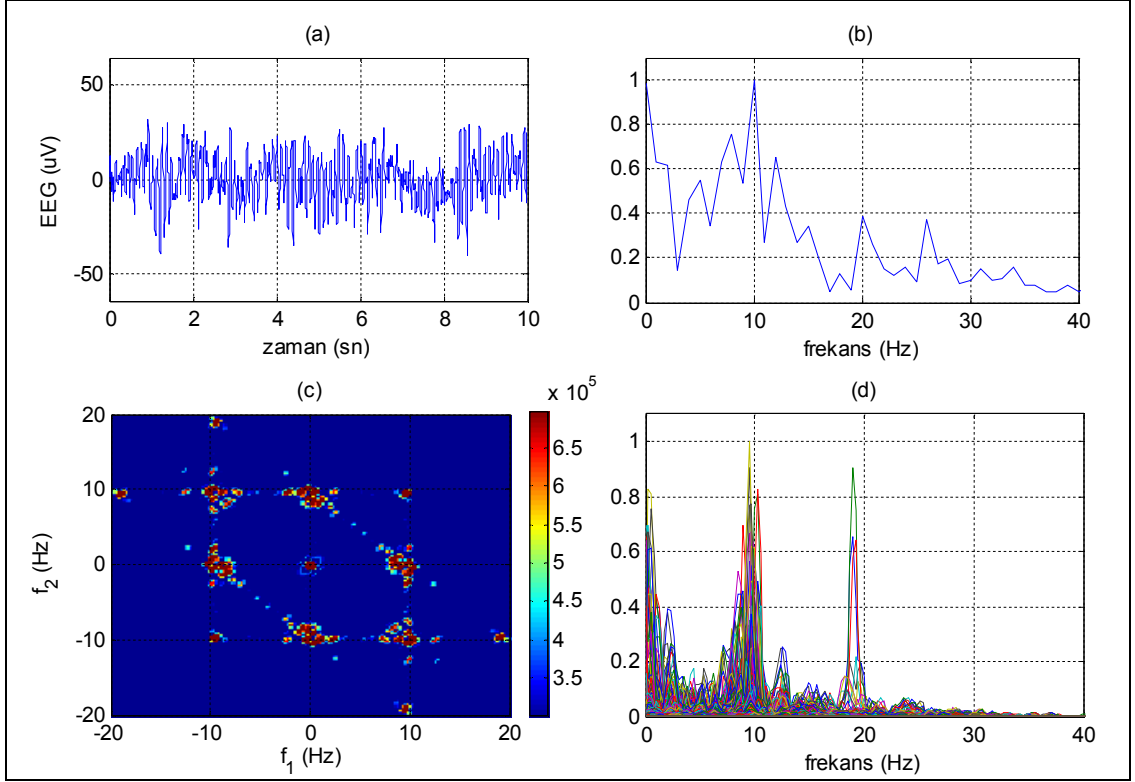
EEG Çeşidi	f_1 (Hz) (ortalama±SD)	f_2 (Hz) (ortalama±SD)
Normal	10.8 ± 5.1	6.4 ± 3.5
UAS	3.5 ± 2.0	3.2 ± 2.1

Yapılan çalışmada ayrıca 1500 normal ve 1500 UAS EEG episodunun Delta, Teta, Alfa, Beta ve Gamma EEG bantlarında ortaya çıkan QPC değerleri de ortalama bazında quantifiye edilerek Çizelge 4.4’te verildi.

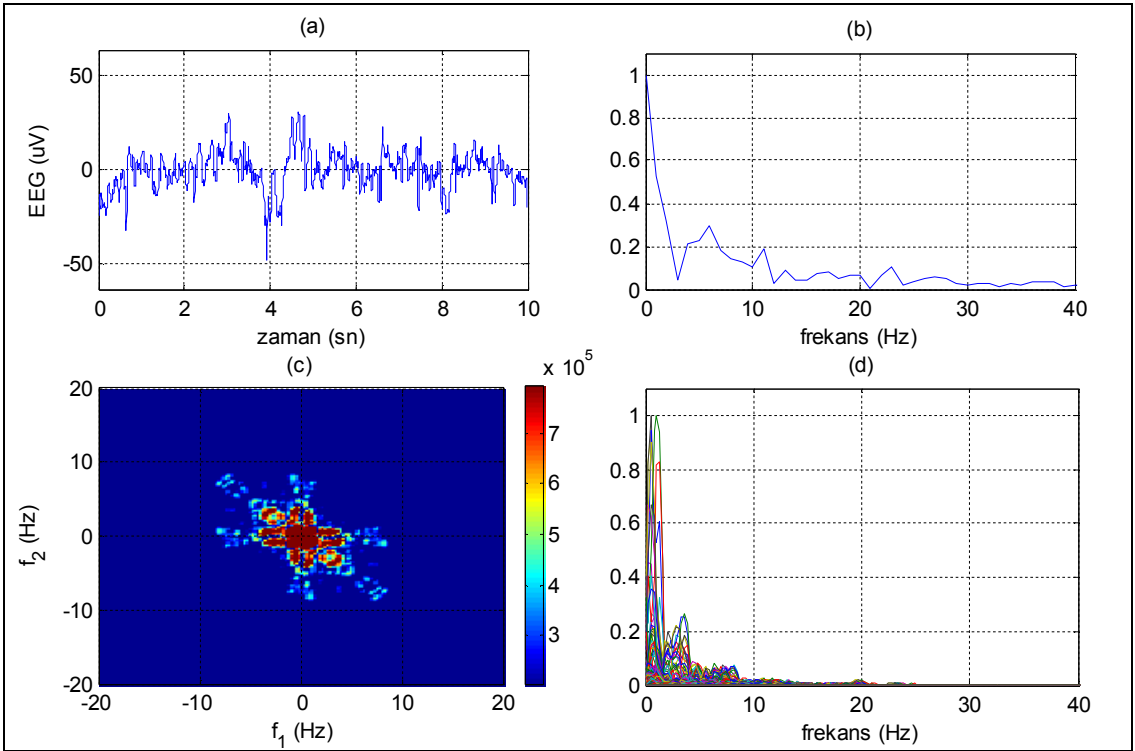
Çizelge 4.4. 3000 EEG episodü için her altbant için QPC miktarlarının ortalama ve standart sapması

EEG bant	UAS EEG (ortalama±SD)	Normal EEG (ortalama±SD)
Delta (0–4 Hz)	250.66 ± 62.34	65.30 ± 17.65
Teta (4–8 Hz)	67.18 ± 16.00	240.77 ± 75.50
Alfa (8–13 Hz)	50.93 ± 13.88	688.73 ± 124.62
Beta (13–32 Hz)	122.74 ± 28.21	213.45 ± 80.45
Gamma (32–64 Hz)	37.21 ± 9.50	43.12 ± 10.45

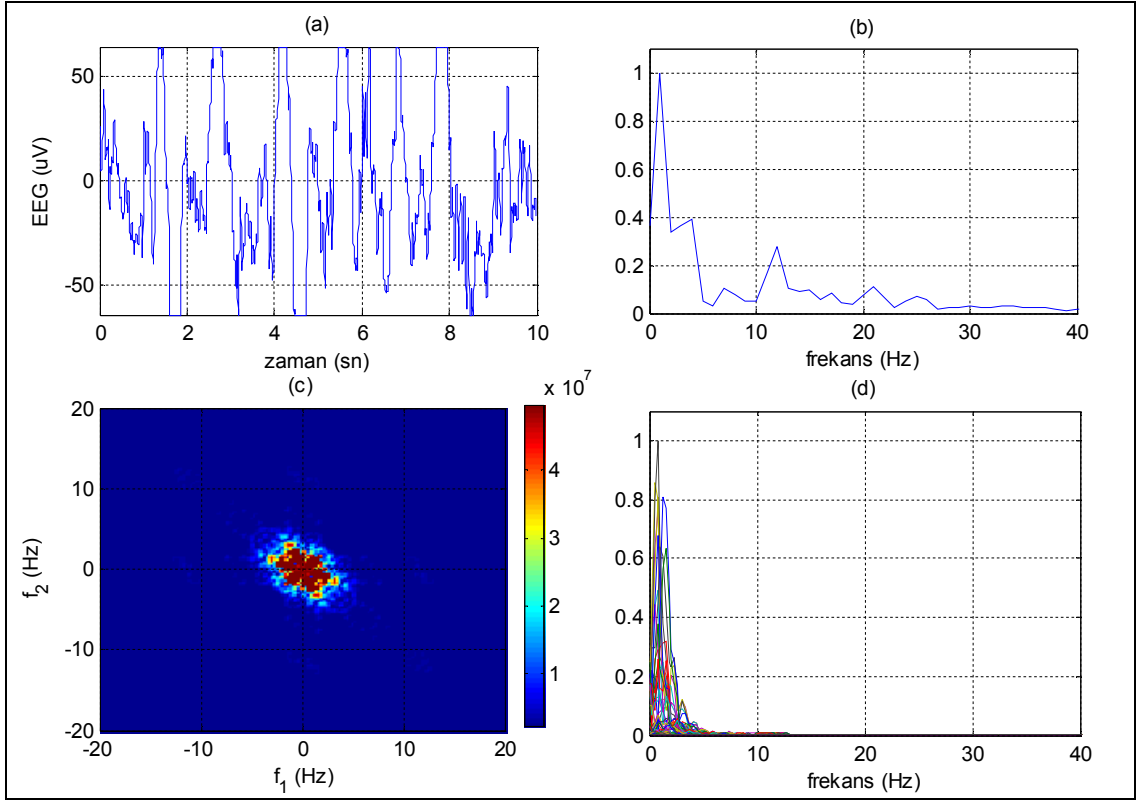
Apneli insanların apne öncesi, apne süresince ve apne sonrası EEG işaretlerinin ikiz–spektrumunun nasıl değiştiğini gözlemek için bu üç durumda işaret parçalarının ikiz–spektrumları ayrı ayrı elde edildi ve güç spektrumları ile birlikte Şekil 4.15, 4.16 ve 4.17’de gösterildi. İkiz spektrumun hesaplaması prosedüründe 0.1 saniye uzunluğunda Hanning penceresi kullanıldı. Bu şekiller apne öncesi, apne anı ve apne sonrası EEG deki değişimi ortaya koymaktadır. Bu şekiller analiz edildiğinde, apne anında özellikle delta ve alfa bandında QPC konsantrasyonunun apne öncesine göre daha fazla olduğu görülmektedir. Apne sonrasında ise bu QPC’lerin daha çok delta bandında yoğunlaştığı açıkça görülmektedir. Buradan da anlaşılıyor ki, QPC’nin yüksek bir tepe değerine veya konsantrasyona sahip olması işaret bileşenlerinin daha fazla birbirleri ile ilintili olduğunu göstermektedir. Güç spektrumu ile ikiz–spektrum karşılaştırıldığında, bazı tepelerin ikiz–spektrumda olduğu fakat güç spektrumunda karşılığı aynen olmadığı veya tersi bir durum olduğu görülmektedir. Örneğin, Şekil 4.15’te $f=19$ Hz frekansı civarında bir yüksek tepe olduğu (Şekil 4.15d) fakat güç spektrumunda (Şekil 4.15b) bu frekansta böyle yüksek bir tepe olmadığı görülmektedir. Diğer taraftan yine Şekil 4.15’te $f=26$ Hz frekansı civarında güç spektrumunda bir tepe olduğu (Şekil 4.15b) fakat aynı frekansta ikiz–spektrum için bu değerde bir tepe olmadığı görülmektedir (Şekil 4.15d). Bu durumdan da ikiz–spektrumda iki bileşen arasındaki ilintinin bazen bir bileşen gibi ortaya çıkabileceği anlaşılmaktadır.



Şekil 4.15. UAS öncesi EEG işareti, güç spektrumu, ikiz spektrum ve ikiz spektrumun iki boyutlu gösterimi



Şekil 4.16. UAS anında EEG işareti, güç spektrumu, ikiz spektrum ve ikiz spektrumun iki boyutlu gösterimi



Şekil 4.17. UAS sonrası EEG işareti, güç spektrumu, ikiz spektrum ve ikiz spektrumun iki boyutlu gösterimi

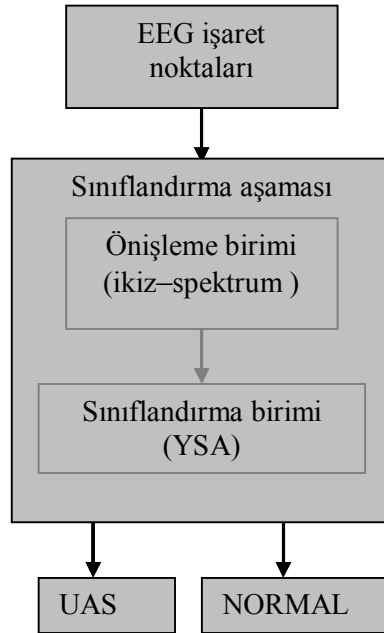
Çizelge 4.5'te 4500 EEG bölütü (1500 UAS öncesi, 1500 UAS anında ve 1500 UAS sonrası bölüt) için 5 altbanda ait UAS öncesi, UAS anında ve UAS sonrası ikiz–spektrumda ortaya çıkan QPC'lerin ortalama ve standart sapma (SS) miktarları gösterilmiştir. Çizelgeden anlaşıldığı gibi hasta apne geçiriyor durumda iken QPC miktarı delta bandı için azalırken teta ve alfa bantları için artmaktadır. UAS sonrası ani bir uyanıklık yaşanacağından (arousal) beyinde dinamiklik artarak çok yüksek bir QPC oluşmasına sebep olmaktadır. UAS sonrası ortalama QPC artışı hemen hemen bütün EEG altbantlarında görülmektedir. Sonuç olarak ikiz–spektrum sonrasında elde edilen apne ile ilintili bu özellikler bir YSA ile değerlendirilip UAS kestirimi yapılabileceği anlaşıldı. Bu görev için aşağıda EEG'nin altbant QPC değerlerine göre sınıflandırma yapan bir YSA tasarlandı.

Çizelge 4.5. UAS öncesi, UAS anında ve UAS sonrası toplam 4500 EEG epİsodu için her altbanda ait QPC miktarlarının ortalama ve standart sapması

EEG bant	UAS öncesi (ortalama±SS)	UAS anında (ortalama ±SS)	UAS sonrası (ortalama ±SS)
Delta (δ)	255.30 ± 85.10	65.30 ± 22.45	2760.00 ± 451.10
Teta (θ)	4.15±1.25	25.20±9.12	33.55 ± 12.34
Alfa (α)	5.90 ± 2.67	27.15 ± 7.54	24.50 ± 11.00
Beta (β)	9.72 ± 5.15	9.65 ± 4.78	43.10 ± 16.90
Gamma (γ)	0.14 ± 0.03	0.12 ± 0.04	1.50 ± 0.06

4.2.2. EEG işaretlerinden UAS'nin YSA ile kestirimi

256 Hz örnekleme frekansı ile deneklerden kayıtlanan EEG işaretleri iki uzman hekim tarafından 2500 UAS ve 2500 normal durum için sınıflandırıldı. Sınıflandırılan bu kayıtlardan rastgele 150 UAS'li ve 150 normal durumlu kayıtlar tasarlanan ikiz–spektrum önişlemeli ağın eğitimi için kullanıldı. Sistemin eğitim sürecini kontrol etmek için eğitim setinden 20 tane bölüt çapraz doğrulama testi için kullanıldı. Daha sonra diğer 2350 UAS ve 2350 normal bölüt verisi sistemi test etmek için kullanıldı. EEG işaretlerinin sınıflandırılması için sunulan metodun gösterimi Şekil 4.18'de verilmiştir.



Şekil 4.18. Geliştirilen ikiz–spektrum–YSA modelinin şematik yapısı

Analiz için kullanılan her bir EEG bölütü UAS için gerekli minimum süre olan 10 saniye uzunluğunda olup, 2560 noktadan oluşmaktadır. Bu denli büyük bir veri setinin sinir ağı girişine direkt olarak verilmesi, sinir ağının hem tasarımını güçleştirecek hem de probleme cevap verme süresini arttıracaktı. Dolayısıyla, bu verileri direkt olarak ağa vermek yerine, işaretin QPC gibi apne ile ilintili özniteliklerini ağa vermekle ağ girişindeki veri setinin boyutu oldukça küçülmüş ve aynı zamanda ağın daha hızlı sonuç vermesi sağlanmıştır. Önceki bölümünde anlatıldığı gibi EEG ikiz–spektrumun $0 \leq \omega_2 \leq \omega_1$ ve $\omega_1, \omega_2 \leq \pi$ şeklinde tanımlı bölgesi aşağıdaki gibi altbantlarına ayrıştırıldı.

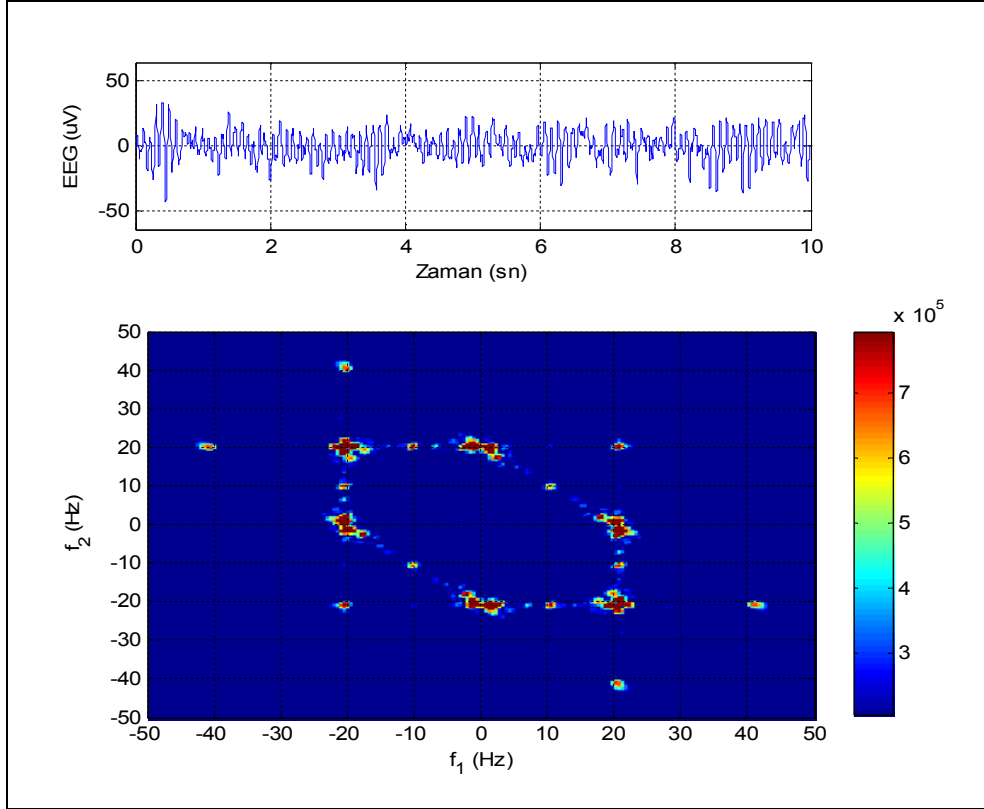
Delta(δ) 0.5–4 Hz,	0.5 Hz < (f_1, f_2) < 4 Hz için,
Teta(θ) 4–8 Hz,	4 Hz < (f_1, f_2) < 8 Hz için,
Alfa(α) 8–13 Hz,	8 Hz < (f_1, f_2) < 13 Hz için,
Beta(β) 13–32 Hz,	13 Hz < (f_1, f_2) < 32 Hz için,
Gamma(γ) 32–64 Hz,	32 Hz < (f_1, f_2) < 64 Hz için.

Her banttaki QPC toplam değerini ölçmek için faz bağlaşımlarıyla direkt ilişkili olan Gauss olmayan rastgele işlemeye sahip verilerin ölçeklendirilmesinde kullanılan [67] Denklem 4.1 kullanıldı.

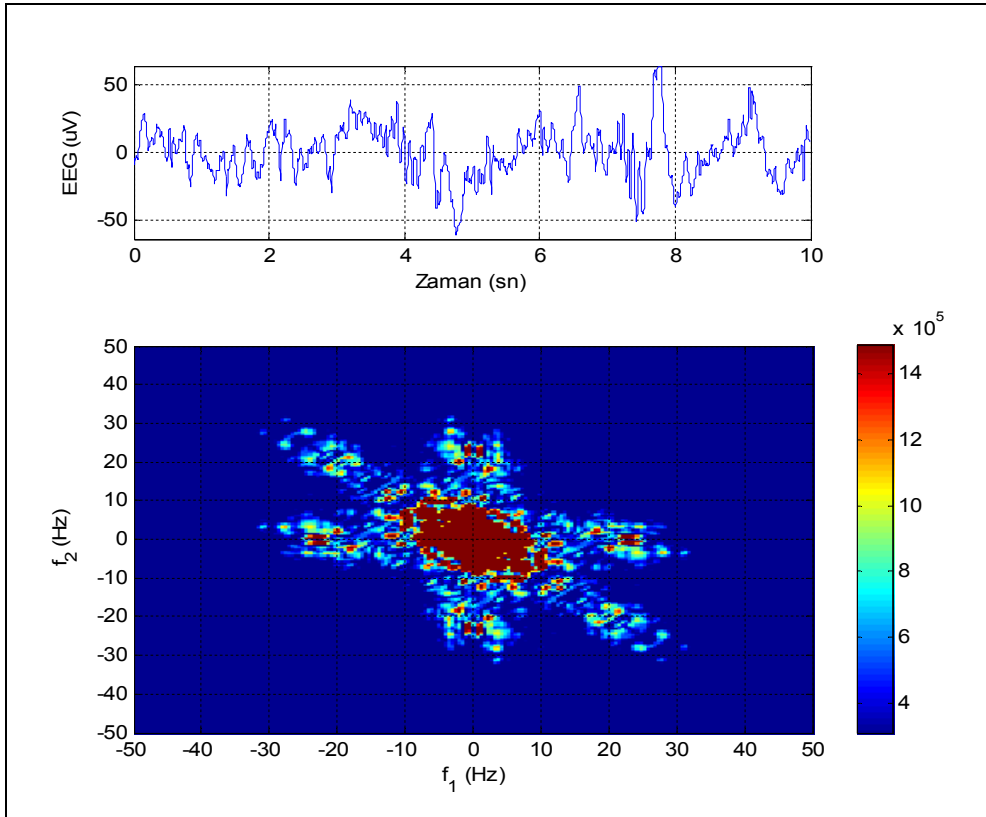
$$D = \sum_{(\omega_1, \omega_2)} |B(\omega_1, \omega_2)| \quad (4.1)$$

Ölçeklendirilen bu veriler daha sonra sınıflandırma birimine giriş olarak verildi.¹

¹ İkiz–spektrum detaylarına bakıldığında ister normal ister UAS hastası olsun her kişinin EEG’sinin ikiz–spektrumu kişiye özgü olduğu anlaşılmaktadır. Yukarıda değinilen her EEG altbandında QPC oluşacak diye bir kavram yoktur. Bazı kişilerde QPC değerleri bir altbantta yoğunlaşırken bir başka kişinin başka bir bantta yoğunlaşabilir. Örneğin bir normal kişi için elde edilen ikiz–spektrum (Şekil 4.13) bir başka normal kişi için Şekil 4.19’daki gibi düşük frekanslarda QPC’si olmayan bir yapı sergileyebilmektedir. Ancak UAS hastasının EEG ikiz–spektrumunda Şekil 4.14 ve yine Şekil 4.20’de görüldüğü gibi QPC konsantrasyonu düşük frekanslarda oluşmaktadır ki bu da apne ile ilintili karakteristik bir yapı olduğu anlaşılmaktadır. Daha önce de belirtildiği gibi bu durum EEG’deki bileşenlerin arasındaki ilintinin artması veya kaotik olmanın azalması olarak nitelendirilebilir.



Şekil 4.19. Normal EEG işareti ve onun ikiz–spektrumu



Şekil 4.20. UAS hastası için EEG işareti ve onun ikiz–spektrumu


Sınıflandırma için geliştirilen çok katmanlı sinir ağına ait karakteristik özellikler Çizelge 4.6’da verilmiştir.

Çizelge 4.6. Geliştirilen sinir ağının özellikleri

Katman sayısı	4 (1 giriş, 2 gizli ve 1 çıkış)
Giriş katmanı büyüklüğü	5x300
Gizli katmanların büyüklüğü	10
Çıkış katmanı büyüklüğü	2x1
Öğrenme oranı	0.05
Performans fonksiyonu	SSE(sum-squared error)
Öğrenme hata hedefi	0.0005
Momentum katsayısı	0.95
Aktivasyon fonksiyonu	bipolar sigmoid

Özellikleri Çizelge 4.6’daki gibi tasarlanan sinir ağı, 7814 iterasyon sonucunda istenen hata düzeyine ($e=0.0005$) ulaşarak başarılı bir şekilde eğitildi. Eğitim sürecinde karesel hatanın iterasyon sayısına göre değişimi Şekil 4.21’de verilmiştir. Bu çalışmada, sistemin ilgilendiği probleme daha hassas bir cevap vermesi için tasarlanan sinir ağının eğitiminde önemli bir çaba harcandı. Şöyle ki: Eğitim safhasında sinir ağının ezberleme durumu göz önünde bulundurularak, uygun katman sayısı ve her katmanda olması gereken hücre sayısını tespit etmek için, ağda yapılan her bir değişim sonrası ağ yeniden eğitildi ve uzun bir süreç gerektiren bu denemeler sonucunda ağda kullanılması gereken katman ve hücre sayısı tespit edildi. Sonra da çapraz doğrulama tekniği ile eğitim safhası kontrol edildi.

YSA’nın tasarımında Çizelge 4.6’daki parametrelerin kullanımı ağın eğitim sürecinde herhangi bir kararsızlık veya başka bir pürüz oluşturmadı ve dolayısıyla bu parametrelerin tutarlı olduğu anlaşılmıştır.



Şekil 4.21. Eğitilen ağın yakınsaması.

Eđitilen YSA bütn test verileri ile test edildikten sonra, elde edilen sonuçlar uzman hekimlerin deęerlendirmeleri ile karřılařtırıldı. Bütn test sinyallerine göre ađın problemi özmedeki performansı izelge 4.7’de verilmiřtir. YSA ile toplamda %96.15’lik bir doęruluk elde edildiđi ve bu sonuca göre ađın bařarılı olduđu anlařılmıřtır.

izelge 4.7. YSA’nın test sinyallerinde verdiđi sınıflandırma performansı

	UAS	NORMAL	Toplam
Doęru Teřhis	2212	2307	4519
Yanlıř Teřhis	138	43	181
Doęruluk (%)	94.13	98.17	96.15

4.3. Karın ve Gęs Verisinden UAS Sınıflandırması

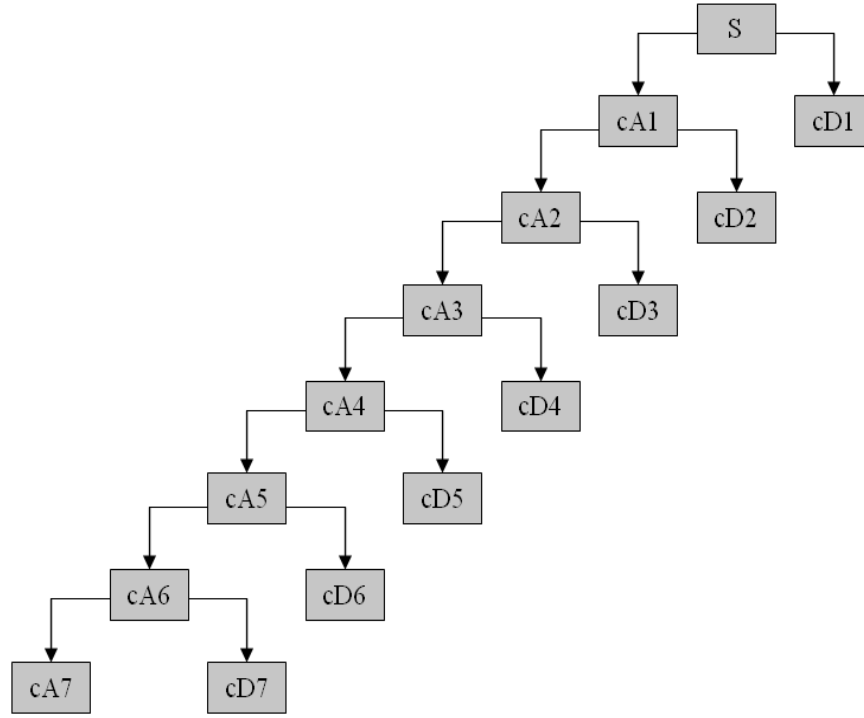
Bu blmde apne hastalardan alınan karın ve gęs verisi kullanılarak bir UAS kestirim yntemi geliřtirildi. Burada hastanın karın ve gęs blgesinden kayıtlanan sinyallerin ADD ile elde edilen zellikler YSA’ya verilerek bir dalgacık–sinir ađı modeli oluřturuldu ve bu ađ ile apne sınıflandırılmaya alıřıldı.

4.3.1. Karın ve gęs iřaretlerinin ADD ile altbantlara ayrıřtırılması

PSG cihazı aracılıđı ile 128 Hz rnekleme frekansıyla rneklenerek deneklerden (hastalardan) alınan karın ve gęs hareketi sinyalleri 10’ar saniyelik (1280 nokta) bltlere blnd ve uzman iki hekim tarafından apne aısından sınıflandırılarak eđitim ve test iin veri kmeleri oluřturuldu. Bu bltlerin (1500 blt) aynı zamanda bu hekimler tarafından hangi eřit apneye ait oldukları da belirlendi ve 500 TUAS, 500 MUAS ve 500 BUAS olacak řekilde veri kmeleri oluřturuldu.

Daha sonra bu sinyal bltleri ADD kullanılarak altbantlarına ayrıřtırıldı. Altbantlara ayrıřtırma iřlemi řekil 4.22’de gsterildiđi gibi iřaret yksek (detay) ve alak (yaklařık) frekans dalgacık katsayılarına ayrıřtırma iřlemi yapıldı. Bu ayrıřtırmayı gerekleřtirmek iin farklı dalgacık fonksiyonları kullanılabilir, ancak deneme yanılma ile bu alıřma iin Daubechies dalgacıđının daha iyi sonu verdiđi anlařıldı ve dolayısıyla bu dalgacık kullanıldı. Bu ayrıřtıma iřlemine 7. seviyeye kadar

devam edildi. Ancak, 7. seviyedeki detay katsayıları, sinyali daha iyi karakterize ederek her UAS çeşidi için farklı özellikler ortaya koyduğu anlaşıldı¹.




Şekil 4.22. Bir S işaretinin 7 seviyelik dalgacık katsayılarını gösteren diyagram

Daha önce yapılan bir çalışmada *ADD* yönteminin UAS'yi belirlemede iyi bir yöntem olduğu ifade edilmiş [51] ve bu çalışmada bu öneri uygun görüldü. Bir sonraki bölümde anlatılacağı üzere, 7. seviyede elde edilen detay (cD1–cD7) ve yaklaşık (cA7) katsayılarının enerjileri sinir ağının girişine verildi ve ağın performansı ölçüldü. Ayrıca önceki çalışmadan farklı olarak 7. seviyeye kadar her seviyede elde edilen detay (cD1–cD7) ve yaklaşık (cA7) katsayılarının enerjileri hesaplanarak bu enerji verileri ağın girişine verilip performans ölçüldü ve daha iyi bir sonuç elde edildi.

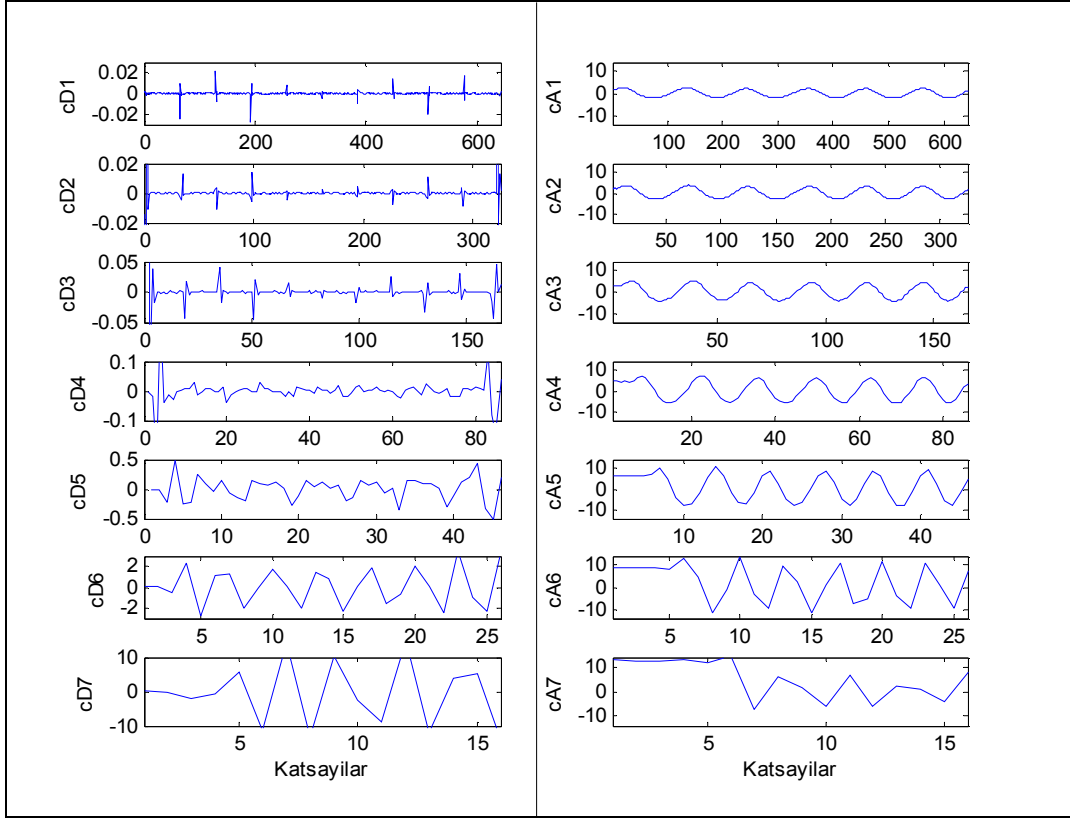
Çalışmanın bu bölümünde ele alınan karın ve göğüs hareketine ilişkin bir örnek işaret Şekil 4.23'te gösterilmiştir. Şekil 4.24 ve 4.25'te da bu işaretlerin 7 seviye sonrası yaklaşık ve detay dalgacık katsayıları gösterilmiştir. Şekillerden de görüldüğü gibi dalgacığın 1. seviyedeki katsayı sayısı 600 den fazla iken 7. seviyedeki dalgacık

¹ Karın ve göğüs verilerini direkt olarak YSA girişine vermek yerine 7 seviyeli dalgacıkların katsayılarının enerjisinin verilmesinin nedeni çalışmamızı yaptığımız diğer metotlarda olduğu gibi bu metotta da YSA girişine verilecek verileri özgünleştirmek, sayısını azaltmak ve ağın daha hızlı cevap vermesini sağlamaktır.


katsayısı sayısı 17 olmuştur ve böylece ağa verilecek veri sayısı azalmıştır. Ağın girişine daha az sayıda verilen ve apneyi daha iyi karakterize eden bu veri YSA'yı hızlandırmasının yanı sıra çıkıştaki doğruluk payını da arttırmıştır.



Şekil 4.23. (a) Karın ve (b) Göğüs hareketi işaretleri



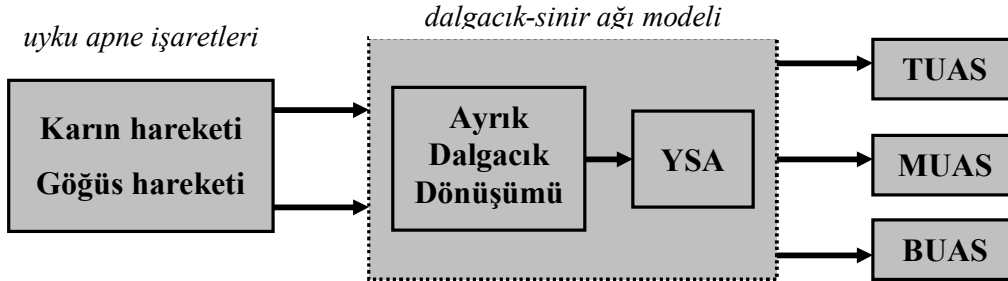
Şekil 4.24. Karın hareketi işaretinin 7 seviyeli dalgacık ile ayrıştırılması



Şekil 4.25. Göğüs hareketi işaretinin 7 seviyeli dalgacık ile ayrıştırılması

4.3.2. Karın ve göğüs işaretlerinden UAS'nin YSA ile sınıflandırılması

Bu bölümde yapılan araştırma için oluşturulan dalgacık–sinir ağı modelinin blok diyagramı Şekil 4.26'da gösterilmiştir.



Şekil 4.26. Geliştirilen modelin blok diyagramı

Daha önce de belirtildiği gibi bir ağın performansını arttırmak için uygun bir model, uygun sayıda gizli katman ve uygun hücre sayısını seçmek gerekir. Bunun yanı sıra da uygun bir eğitim algoritması da ağın performansını arttıracaktır. Bu çalışma için deneme yanılma ile en uygun ağ için iki gizli katman ve her katmanda 15'er hücre olması gerektiği tespit edildi. Yine deneme yanılma yoluyla öğrenme için de geri yayılma algoritmasının daha iyi bir sonuç verdiği anlaşıldı. Geri yayılma algoritmasında hücre etkinleşmesi için bipolar sigmoid aktivasyon fonksiyonu seçildi. YSA'nın öğrenme hızını da arttırmak için uygun momentum teriminin seçilmesi için tasarlanan ağ, eldeki verilerle çeşitli momentum katsayısı için denendi ve sonuçta en uygun momentum katsayısı tespit edildi. Momentum katsayısı tespiti sürecinde 4 farklı momentum katsayısı ve her apne çeşidi için 40'ar adet işaret örneği ağı eğitimi için kullanıldı. Denenen bu momentum katsayıları ve apne sınıflandırması için elde edilen performans değerleri Çizelge 4.8'de verilmiştir. Normalde bir YSA bir problem için eğitildikçe istenilen sonuç ile ağ çıkışı arasındaki hata enerjisinin sıfıra yakınsaması gerekir. Bazen bu yakınsama süreci çok uzun sürer, yani çok fazla sayıda iterasyon kullandığı için öğrenme süreci uzar. Bu olaya ezberleme veya over fitting denir. Dolayısıyla uygun bir iterasyon sayısı ile ağı öğrenmesi önemli bir kriterdir. İterasyon sayısının belirlenmesinde çapraz doğrulama metoduyla hatanın belli bir değerden sonra eğitim sürecini durdurmak gerekir. Buna göre YSA'nın ilgilendiği probleme göre varılacak minimum hata değeri seçilir ve ağ çıkışındaki hata bu değere varır ve sonra da hata artmaya başlarsa eğitim süreci hemen durdurulur. Bu çalışmada çapraz doğrulamadaki hata değeri 0.001 olarak belirlendi ve ağ eğitim sürecinde iyi bir

genelleme ile bu istenen hata değerine ulaştı. Şekil 4.30’da verildiği gibi ağ çıkışındaki SSE eğrisi istenen bu küçük sayıya ulaştığından geliştirilen YSA eğitimin başarılı olduğu anlaşıldı. Deneme yanılma yoluyla elde edilen bu uygun değerler ve ağın diğer parametreleri Çizelge 4.9’da verilmiştir.

Çizelge 4.8. Farklı momentum katsayılarına göre YSA’nın sınıflandırma performansı ve öğrenme süresi

Momentum Katsayısı	YSA Çıkışının Doğruluğu				YSA’nın öğrenme süresi (Bölüt)
	TUAS (%)	MUAS (%)	BUAS (%)	Toplam (%)	
0	78.20	90.05	73.25	80.50	9738
0.5	81.61	93.57	75.60	83.59	6420
0.75	83.67	94.43	76.00	84.70	5645
0.95	85.65	94.74	80.12	86.84	3378

Çizelge 4.9. Geliştirilen dalgacık–sinir ağının özellikleri

Dalgacık birimi	Kullanılan dalgacık	Daubechies
		Dalgacık seviyesi
Sınıflandırma birimi	Katman sayısı	4 (1 giriş, 2 ara ve 1 çıkış)
	Giriş katman büyüklüğü	16x120
	Ara katman büyüklükleri	15
	Çıkış katman büyüklüğü	3x1
	Öğrenme oranı	0.05
	Performans fonksiyonu	SSE(sum–squared error)
	Öğrenme hata hedefi	0.001
	Momentum katsayısı	0.95
	Aktivasyon fonksiyonu	bipolar sigmoid

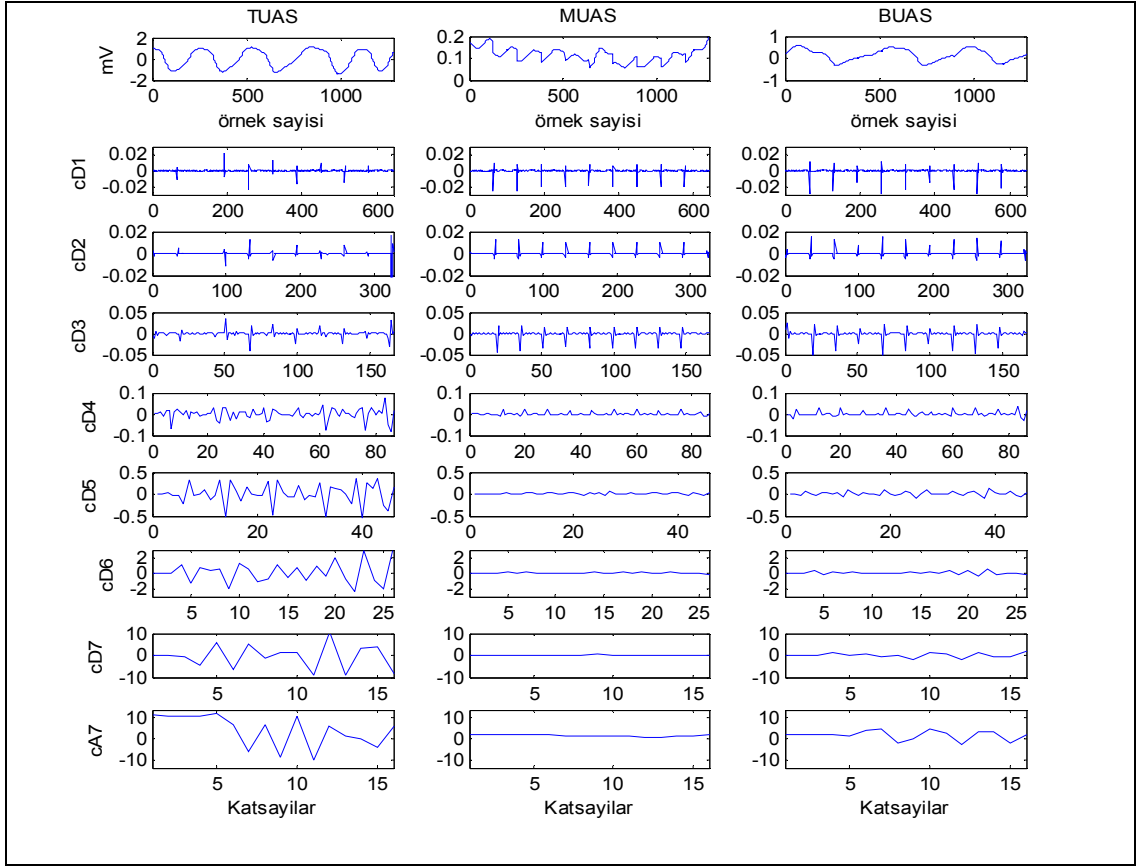
Seçilen bu parametreler ağın eğitim sürecinde herhangi bir kararsızlık oluşturmadığı için bu parametre seçiminin tutarlı olduğu anlaşılmıştır.

UAS’nin her üç sınıfı için karın ve göğüs hareketi işaretleri ile eğitilen ağ, yine karın ve göğüs hareketi işaretleri ile UAS’nin üç sınıfı için test edildi. Burada ağ eğitimi ve testi:


- ADD’den elde edilen 1.–10. seviyeye kadar her dalgacığın detay katsayılarının enerjileri ayrı ayrı ağ girişine verilerek,
1. seviyeden S. seviyeye kadar (S=1,2,3,...10) tüm durumlar için detay altbant dalgacıkların ve sonuncu yaklaşık dalgacığın enerjilerinin ağ girişine verilerek

ayrı ayrı sistemin performansı test edildi. Bu uzun süreçli işlem sonucunda 7. seviyeye kadar olan detay ve 7. seviyedeki yaklaşık dalgacıkları enerjilerinin ağa verilmesiyle elde edilen sonucun en iyi olduđu tespit edildi. Bu süreçte elde edilen her deneme sonucu Şekil 4.29’da gösterilmiştir. Şekilden de görüldüğü gibi, 7 seviyeli bir dalgacık dönüşümünün kullanılması YSA için en iyi doğruluk ve en hızlı eğitim olduđu anlaşılmaktadır. Yapılan bu çalışmaya bir örnek olarak, sırasıyla TUAS, MUAS ve BUAS olan hastalara ait bir karın ve bir de göğüs hareketi işareti 7 seviyeye kadar ki dalgacık detay katsayıları Şekil 4.27 ve 4.28’de gösterilmiştir. Burada UAS sınıflandırması ağın çıkış vektörüne göre şu şekilde yapıldı: H yüksek olasılık ve L düşük olasılığı belirtmek üzere TUAS için [HLL], MUAS için [LHL] ve BUAS için [LLH]. Tasarlanan sistemin 0.95 momentum katsayısı ile 7. seviyedeki dalgacık katsayılarına daha iyi cevap verdiğini tespit ettikten sonra sistem her bir UAS çeşidinden 40’ar adet olmak üzere toplam 120 bölüt kullanarak eğitildi. Test sürecinde ise her bir sınıf için 460 bölüt olmak üzere toplam 1380 bölüt kullanıldı. Elde edilen test sonuçları uzman hekimlerin görüşleri ile karşılaştırıldı. Test sonucunda ağ TUAS için 85.65 ± 2.85 , MUAS için 94.74 ± 1.55 ve BUAS için 80.12 ± 2.94 ve toplamda ortalama 86.84 ± 2.45 olarak doğru kararı verdiği görüldü. Elde edilen dalgacık–sinir ağının bütün test sinyallerine verdiđi sonuçların hekim görüşüne göre doğruluđu Çizelge 4.10’da verilmiştir. Çizelgeden de görüldüğü gibi ana farklılıklar TUAS ile BUAS ve MUAS ile BUAS arasında olduđu anlaşılmaktadır. BUAS, TUAS ve MUAS’nin birleşiminden oluştuđu için ağın BUAS için daha kararsız olması da doğaldır. Bu sonucun diđer çalışmaları ve hekimlerin kişisel sınıflandırmaları ile karşılaştırıldığında iyi bir performans olduđu söylenebilir.


Eđitim sürecinde, YSA 3378 iterasyon sonucunda istenilen hata deđerine ulaşmıştır. Karesel toplam hatanın ve öğrenme oranının iterasyonlara göre deđişimi Şekil 4.30’da gösterilmiştir.



Şekil 4.27. Üç çeşit UAS için karın hareketi işaretinin 7 seviyede detay katsayıları




Şekil 4.28. Üç çeşit UAS için göğüs hareketi işaretinin 7 seviyede detay katsayıları



Şekil 4.29. Dalgacık ayırma seviyesine göre YSA'nın öğrenme süresi ve doğruluğu

Modele ait karesel toplam hatanın ve öğrenme oranının iterasyonlara göre değişimi Şekil 4.30'da gösterilmiştir.



Şekil 4.30. SSE ve öğrenme oranının iterasyona göre değişimi


Çizelge 4.10. Dalgacık–sinir ağı modelinin sınıflandırma performansı

Gerçek	Modelin çıkışı		
	TUAS (%)	MUAS (%)	BUAS (%)
TUAS (%)	85.65±2.85	00.33±0.01	03.85±0.05
MUAS (%)	02.21±0.08	94.74±1.55	05.15±0.15
BUAS (%)	09.65±0.12	15.56±0.28	80.12±2.94

4.4. UAS'nin ANFIS ile Kestirimi ve Sınıflandırılması

Bu bölümde, Bölüm 4.1, 4.2 ve 4.3'te yapılan sınıflandırma işlemi için YSA yerine Sugeno tipi bulanık çıkarım modeli olan ANFIS kullanıldı ve elde edilen sonuçlar YSA ile elde edilen sonuçlarla karşılaştırıldı. Kullanılan ANFIS modeli MATLAB programı kullanılarak tasarlandı. ANFIS modelinde giriş hücre sayısı 5, çıkış hücre sayısı 1, toplam hücre sayısı 524, lineer parametre sayısı 243, lineer olmayan parametre sayısı 30 ve bulanık kural sayısı her hücre için 3 olarak seçildi. ANFIS ağının giriş katmanında üyelik fonksiyon tipi ise Gauss olarak seçildi. Daha önceki bölümlerde kullanılan veriler bu bölümde de aynen kullanıldı.


Bölüm 4.1'de kullanılan horlama sesi işaretlerinden elde edilen 5 frekans bandına ait enerjiler ANFIS ağının girişine verilerek ağ eğitildi ve sonra da YSA modelinde olduğu gibi geriye kalan verilerle de test edildi. Ağın eğitim sürecinde hatanın minimuma yakınsaması Şekil 4.31'de gösterildi. Şekilden de görüldüğü gibi hata 3. iterasyondan sonra neredeyse hedef hataya ulaşmıştır.




Şekil 4.31. Eğitimde hatanın minimuma yakınsaması

Şekil 4.32'de eğitim verilerinin ANFIS çıkışıyla tamamen örtüştüğü ve dolayısıyla verilen eğitimin ağ için yeterli bir eğitim olduğu söylenebilir. Test işaretleri için de

ANFIS'in yine kabul edilebilir bir hatayla iyi bir performans sergilediği Şekil 4.33'ten görülmektedir. Elde edilen sonuçlar Çizelge 4.11'de verilmiştir.



Şekil 4.32. Eğitilen verilerin ANFIS çıkışı ile örtüşmesi.




Şekil 4.33. Test işaretlerinin ANFIS çıkışını takip etmesi.

Çizelge 4.11. ANFIS'in test işaretlerine verdiği sınıflandırma performansı (horlama işareti için)

	UAS	NORMAL	Toplam
Doğru Teşhis	1397	1425	2822
Yanlış Teşhis	63	35	98
Doğruluk (%)	95.68	97.60	96.64

Bölüm 4.2'de kullanılan EEG işaretlerinin ikiz–spektrum analizi sonucunda elde edilen altbantlara ait QPC enerjileri ile ANFIS eğitildi ve sonra da test işaretleri ile sistem test edildi. Test sonucu elde edilen sınıflandırma doğruluk oranları Çizelge 4.12'de verilmiştir. Bölüm 4.2'deki gibi 150 UAS ve 150 normal EEG örneği eğitim

için kullanıldı. Eğitilen ANFIS ağının minimum hataya yakınsamasını gösteren eğri Şekil 4.34'te gösterilmiştir.




Şekil 4.34. UAS'nin kestiriminde ANFIS'in eğitimi sonucu hatanın minimuma yakınsaması

Çizelge 4.12. ANFIS'in EEG test işaretlerine verdiği sınıflandırma performansı

	UAS	NORMAL	Toplam
Doğru Teşhis	2154	2236	4390
Yanlış Teşhis	196	114	310
Doğruluk (%)	91.66	95.15	93.40

Bölüm 4.2'de YSA ile yapılan sınıflandırmada doğruluk oranı toplamda %96.15 iken ANFIS ile yapılan sınıflandırma sonucunda elde edilen toplam doğruluk %93.40 olarak gerçekleşmiştir.

Bölüm 4.3'te Dalgacık–sinir ağı modeli ile yapılan UAS'nin sınıflandırılması burada ANFIS ile gerçekleştirildi. Bölüm 4.3'te hesaplanan 21 hastaya ait karın ve göğüs hareketlerinin dalgacık enerjileri ANFIS girişine verildi. TUAS, MUAS ve BUAS sınıflarına ait 40'ar adet bölüt ANFIS ağının eğitimi için kullanılırken, her bir sınıfa ait 460'ar adet bölüt de ağın testi için kullanıldı. ANFIS ağının eğitim sürecinde ağ çıkışındaki hatanın istenilen hata değerine yakınsama grafiği Şekil 4.35'te gösterilmiştir. ANFIS ağının test işaretlerine verdiği sonuç ise Çizelge 4.13'te verilmiştir. Aynı veriler için çok katmanlı algılayıcı sinir ağı ile yapılan sınıflamada başarı oranı %86.84 (Çizelge 4.10) iken, ANFIS ile yapılan sınıflamanın başarı oranı %83,46 olarak gerçekleşmiştir (Çizelge 4.13).



Şekil 4.35. UAS'nin sınıflandırılmasında ANFIS'in eğitimi sonucu hatanın minimuma yakınsaması

Çizelge 4.13. Karın ve göğüs işaretlerinden UAS'nin sınıflandırılmasında ANFIS ağına ait doğruluk oranları

UAS	ANFIS Çıkışı		
	TUAS (%)	MUAS (%)	BUAS (%)
TUAS (%)	75.20	33.51	26.12
MUAS (%)	0.94	95.01	3.56
BUAS (%)	15.01	31.92	80.18

Adaptif ağ yapısının güncellenmesinde kullanılan iki aşamalı (hibrit) eğitim algoritması sayesinde eğitim hızı YSA'ya göre artırılmıştır. Ağın eğitim süresi YSA'ya göre daha küçük olmasına karşın sınıflama sonuçlarında daha düşük doğrulukta sonuçlar verdiği görülmüştür.

5. TARTIŞMA

Bu çalışma neticesinde UAS hastasını teşhis için çeşitli teknikler geliştirilmiş ve bu tekniklerin performans ölçümleri yapılmıştır. Burada çalışılmış olan teknikler, PSG cihazı ile deneklerden alınan verilerden a- Horlama sesleri, b- EEG işaretleri ve c- Karın ve göğüs hareketi işaretleri kullanarak geliştirilmiştir. Bu teknikler Apne hastalarını hem teşhis hem sınıflandırma için kullanılabileceği gibi muhtemelen hastanın tedavi sürecinde hastaya uygulanacak tedavi türünün belirlenmesinde ve belki de patolojik açıdan horlamaya neden olan dokunun yapısı ve yeri hakkında da yardımcı olabileceği düşünülmektedir.

Yapılan bu çalışma sonucunda, horlama seslerinin zaman–frekans karakteristik bantlarına ayrıştırılması ile ortaya çıkan yapısal özelliklerin, EEG işaretlerinin her standart altbandın ikiz–spektrumundan elde edilen QPC değer ve özelliklerin ve karın ve göğüs hareketleri işaretlerinin *ADD* ile ayrıştırılması sonucu elde edilen (özellikle 7. seviyeye kadar) dalgacık katsayıların apne ile ilintili olduğu görülmüştür. Bu özellikler, YSA veya ANFIS ile değerlendirilerek UAS teşhisi ve hatta sınıflandırması yapılabileceği tespit edilmiştir. Ham veri yerine bu özellikli verilerin kullanılması ile, örneğin, Dalgacık–sinir ağı modeli ile ortalama %97.50 ve aynı verilerle ANFIS ile ortalama %96.64 gibi büyük bir oranda apne teşhisi yapılabildiği gösterilmiştir.

Patolojik olarak apne sonucu ortaya çıkan horlama sesi işaretlerinin zaman–frekans bantlarındaki değişimin dil kökü, gırtlak ve solunum yolundaki diğer doku değişimi ile ilişkili olduğu açıktır. Önceki çalışmalarda da değinildiği gibi solunum yolu doku yapısına bağlı olarak horlama işaretinin güç spektrumunda çok belirgin olmayan AHI ile de ilintili ($r = 0.71$) farklı frekans bilgileri ortaya çıkmakta ve bu karakteristik bilgilerden apne hastası ayırt edilebilmektedir [89–91]. Bu çalışmada da, horlama episodları arasındaki sıklığın ve horlama sesinin 75–150 Hz bandının ortalama enerjisi 0–75 Hz ile 150–200 Hz arası bantların ortalama enerjisine oranı apne indeksi ile direkt olarak ilişkili olduğu net bir şekilde görüldü ($r > 0.75$). UAS'nin artmasıyla spektral değişkenlik, bu çalışmada da görüldüğü gibi, artmaktadır. Daha önce [89] ve [92]'de belirtildiği gibi, UAS arttıkça spektral zarf parametreleri ve standart sapma da artmaktadır.

Benzer şekilde EEG'nin de ikiz–spektrumda ortaya çıkan QPC değerlerinin apne sonucu beyinde meydana gelen sıkıntılı durumdan kurtulma çabaları ile ilişkili olduğu da açıktır. Bu çalışma ile apneik hastalara ait EEG işaretlerinde normal EEG işaretlerine

göre düşük frekanslarda çok daha fazla doğrusal ve Gauss olmayan veri içerdiği ve bu verilerden bazıları işaretin karakteristik QPC değerleri olduğu anlaşılmıştır. Ayrıca Çizelge 4.4'te de verildiği gibi UAS anında yüksek miktarda QPC, delta dalgalarında görünürken normal EEG'de QPC'ler daha çok teta ve alfa dalgalarında artış gösterdiği (UAS'ye göre 4–12 kat) anlaşılmıştır. Ayrıca, EEG işaretlerinin UAS öncesi, UAS anında ve UAS sonrası ikiz–spektrumu ve güç spektrumu karşılaştırıldığında belirgin farklılıklar ortaya çıktığı görülmüştür.

Patolojik durumlarda, genellikle EEG işaretleri oluşan duruma göre karakteristik bir yapı sergiler. Bu patolojik durumlar sinyal işleme teknikleri kullanılarak çıkarılabileceği düşünülmektedir. UAS boyunca EEG işaretleri, UAS öncesi ve normal durumdaki EEG işaretlerine göre daha yüksek ikiz–spektrum tepeleri sergilemektedir. EEG işaretlerinde kullanılan bu metot ile beyin aktiviteleri UAS olmadığı anlarda çok daha kompleks ve kaotik bir işlemeye sahip olduğunu göstermektedir. UAS anında ise EEG işaretleri kaotisitesi düşük farklı frekans bileşenlerine sahip ve dolayısıyla daha yüksek genlikte QPC'lerin olduğu düşünülmektedir. Başka bir ifade ile kişi apne durumuna geçtiğinde beyin içindeki çok yönlü hareketlilik azalarak UAS'den kurtulma yönünde tek amaçlı aktivite artmaktadır.

EEG işaretlerinin ikiz–spektrumu kullanılarak geliştirilen YSA ile %96.15 oranında bir doğruluk ile UAS normal durumdan ayırt edildirmiştir (aynı veriler ile ANFIS ile yapılan sınıflamada doğruluk oranı %93.40 olarak gerçekleşmiştir). UAS kestiriminde Haja ve arkadaşları [43] uyku apnesi ve normal uykuyu hava akışının spektrum analizi ve bulanık mantık metodunu kullanarak birbirinden ayırt etmeye çalışmışlar. Ancak onların çalışmasında hava akımı işaretlerini 6'şar saniyelik bölütler halinde alınıp spektrumları hesaplanmıştır. Bu spektral verileri bulanık mantık programının girişine verip %99.6 gibi yüksek bir doğruluk oranı ile apne durumunu normal durumdan ayırt etmişlerdir. Ancak bu tezde yapılan çalışmada ise bir apneik durumun 6 saniyeden daha uzun sürebileceği düşünülmüş ve literatürde yetişkinler için belirlenen 10 saniye nefesin durması kriteri dikkate alınmış ve her veri için 10 saniyelik episodlar kullanarak apne teşhisi yapılmıştır. Sınıflandırmada kullanılan EEG işaretinin uzunluğu arttıkça apne merkezinin dışındaki sinyale katkı yapan gürültü (apne ile ilintili olmayan işaret bileşenleri gibi) oranı da artacağından daha az doğrulukta bir sonuç elde edilmektedir. Tian ve Liu [47] hava akımı ve SaO_2 işaretlerinin özelliklerini çıkarıp sinir ağının girişine vererek %90.7 hassasiyet ile apne ve %86.4 hassasiyet ile de yarı apne durumunu kestirmişlerdir. Maier ve arkadaşları [93] EKG işaretinin ikinci derece

polinom sınıflandırıcı metodu ile %93 oranında bir doğruluk ile apne kestirimini yapabilmışlardır.

İkiz–spektrum analizi teknik olarak güç spektrum analizine göre oldukça zor ve komplike olduğundan EEG analizinde pek kullanılmamıştır. Bu komplike ve zorluğa rağmen, bu çalışmada, UAS kestirimi için EEG işaretlerinin ikiz–spektrumunun YSA ile başarılı bir şekilde kullanılabilceği gösterilmiştir. İkiz–spektrumun güç spektruma göre daha fazla bilgi içerdiği düşünüldüğünde bu tekniğin kliniklerde daha fazla fayda sağlayacağı düşünülmektedir. Bu çalışma EEG işaretlerinin ikiz–spektrumunu kullanarak UAS teşhisinin yapıldığı ilk çalışma olup daha da geliştirilebileceği düşünülmektedir. Ayrıca bu tekniğin mevcut PSG cihazlarında da kullanılarak otomatik UAS teşhisi özelliği sağlanabilir. Böylece tanı koyma süresi azaltılarak tıbbi servisin etkinliği geliştirilmiş olacaktır.

Şu ana kadar yapılan çalışmalar genellikle UAS'nin teşhisine yönelik olmuştur. Yukarıdaki paragraflarda anlatılanlar dışında, örneğin, Ghunaimi ve arkadaşları [94] R–R aralığı (RRI) işaretlerini kullanarak yeni bir zaman domeyni tekniğini geliştirmişlerdir. Geliştirdikleri teknikte Fourir dönüşümü tabanlı bir teknik yerine spektral analiz için Hilbert dönüşümünü kullanmışlardır. MIT veri tabanından alınan verilere bu metodu uygulayarak ortalama 28/30 oranında bir doğruluk ile TUAS'yi teşhis etmişlerdir. Liu ve arkadaşları [95] EEG işaretlerini sınıflandırarak sinir ağı girişine vermişlerdir ve bu yöntem ile TUAS'yi normal durumdan %91 doğruluk oranı ile ayırt etmişlerdir. Burada yapılan çalışmada ise UAS'nin teşhisinin yanı sıra dalgacık–sinir ağı modelini kullanarak büyük bir doğruluk oranı ile UAS'nin sınıflandırılması da gerçekleştirilmiştir.

Daha önce yapılmış çalışmalardan çok azı apne sınıflandırmasını gerçekleştirmiştir. Sinir ağlarının bu alandaki ilk uygulaması [96, 97] çalışmalarında yapılmıştır. Bu çalışmalarda da geri yayımlı algoritma kullanılmış, fakat sınıflandırmadaki doğruluk oranı %60'ı geçmemiştir. Son zamanlarda Zemen ve arkadaşları [98] radial basis function (BEF) sinir ağı modelini kullanarak yetişkinlerde %64±3.4 ve çocuklarda %62.6±3.4 gibi bir doğruluk oranı ile apne sınıflandırmasını gerçekleştirmişlerdir. Burada yapılan çalışma ile elde edilen sonuçlar daha önce yapılmış bu çalışmaların sonuçları ile karşılaştırıldığında geliştirdiğimiz tekniklerin performansının daha iyi olduğu anlaşılmaktadır.

O. Fontenla-Romero ve arkadaşları [48] apnenin sınıflandırılması için göğüs işaretlerini bir *ADD*'den geçirdikten sonra, sadece 5. dalgacığın katsayılarını dikkate

alıp sinir ağı ile apne sınıflandırması yapan bir sistem önermişler. Çalışmalarında ileri yönlü sinir ağı metodu kullanarak test işaretleri için %83.78±1.90 oranında doğruluk ve her bir sınıf için %80.90±2.53 (TUAS), %80.48±3.65 (BUAS) ve %89.95±2.71 (MUAS) ortalama bir doğruluk payı ile apne sınıflandırmasını başarmışlardır.

O. Fontenla–Romero ve arkadaşlarının çalışmasına yapısal olarak benzer ancak işlemsel olarak farklı bir yaklaşımla bu çalışmada karın ve göğüs hareketi işaretleri eş zamanlı alındı ve ADD kullanılarak işaretlere ait 7 seviyeli yaklaşık ve detay katsayıları hesaplandı. Daha sonra her seviyedeki detay ve son seviyedeki yaklaşık katsayılarının sahip oldukları enerjiler hesaplanarak geliştirilen YSA modelinin girişine verilmiştir. Bu şekilde oluşturulan dalgacık–sinir ağı modeli test sinyallerine daha iyi sonuç verdiği görülmüştür. Dalgacık–sinir ağı modeli ile her bir sınıf için %85.65±2.85 (TUAS), %94.74±1.55 (MUAS) ve %80.12±2.94 (BUAS) ve ortalama %86.84±2.45 oranında bir doğruluk payı ile UAS sınıflandırması gerçekleştirilmiştir. Aynı veriler kullanılarak ANFIS ağıyla apne sınıflandırılması yapıldığında ortalama %83.46 oranında bir doğruluk elde edilmiştir.

Bu çalışmada geliştirilen bu metotları performans açısından değerlendirmek için hem YSA ile hem de ANFIS ağıyla yapılan sınıflandırmaların sonuçları ve karşılaştırmaları Çizelge 4.14’te verilmiştir. Çizelgeden de görüldüğü gibi ANFIS ağının YSA’ya göre daha hızlı eğitilebilmesine rağmen, az da olsa, daha düşük doğruluklarda sınıflandırma yaptığı görülmüştür.

Çizelge 4.14. Çalışmada kullanılan tekniklerin karşılaştırılması

	Kullanılan İşaretler	Özellik Çıkarma Yöntemi	Ağın Çıkışı	Sınıflayıcı	
				YSA	ANFIS
UAS Kestirimi	Horlama sesi İşaretleri	Dalgacık Dönüşümü	Normal	%98.77	%97.60
			UAS	%96.23	%95.68
			Ortalama	%97.50	%96.64
	EEG İşaretleri	İkiz–Spektrum	Normal	%98.17	%95.15
			UAS	%94.13	%91.66
			Ortalama	%96.15	%93.40
UAS Sınıflaması	Karın ve Göğüs hareketi İşaretleri	Dalgacık Dönüşümü	TUAS	%85.65	%75.20
			MUAS	%94.74	%95.01
			BUAS	%80.12	%80.18
			Ortalama	%86.84	%83.46

6. SONUÇ ve ÖNERİLER

UAS teşhisi için sistematik olarak geliştirilen bu tekniklerin her biri farklı bir biyolojik işaret kullanmaktadır ve dolayısıyla farklı avantajlara sahiptirler. Şöyle ki:

- Horlama seslerinin kullanıldığı model ile UAS tespiti basit, ucuz ve dolayısıyla uygulama açısından avantajlıdır. PSG cihazı pahalı ve kompleks bir sistem olup birçok sağlık merkezinde bulunmamaktadır veya bulundurulması mümkün değildir. Veri kaydı için sadece bir ses kayıt cihazı gerekli olan bu sistem kolaylıkla tüm sağlık merkezlerine ve hatta hasta evlerine servis edilebilir. Kayıtlanacak horlama sesleri hekime sağlanan basit bir kişisel bilgisayara bu program yüklenerek UAS tespiti yapılabileceği düşünülmektedir. Veya en azından PSG cihazı için uyku merkezlerine sevk edilip edilmemesi hususunda bir ön eleme için bu teknik kullanılabilir. Ayrıca horlama ses işaretlerinden apneik olmayan horlama problemi ile ilgili alanda da kullanılabilir görülmektedir.
- EEG işaretlerinin kullanıldığı model ile UAS tespiti horlama seslerinin kullanıldığı model kadar basit olmasa bile kompleks bir sistem değildir. Veri kaydı için sadece bir EEG kayıt cihazı gerekli olan bu sistem tüm sağlık merkezlerine sağlanabilir. Bu merkezde kayıtlanacak EEG verileri sistemin programı hekimin bilgisayarına yüklenerek UAS tespiti yapılabileceği veya bu tekniğin daha önce değinildiği gibi bir ön eleme için kullanılabilir düşünülmektedir.
- Karın ve göğüs hareketlerinin kullanıldığı model ile UAS tespiti diğer iki modelden az da olsa daha pahalı ve kompleks olabilmektedir. Bu metot için veriler karın ve göğüs hareketlerini algılayacak algılayıcı ve kayıt cihazı gereklidir. Bu cihaz yine sağlık merkezlerine sağlanabilir ve veriler kayıtlanabilir. Bu merkezde hastalardan alınacak veriler, hekimin bilgisayarına yüklenecek sistemin programı ile UAS tespiti yapılabileceği düşünülmektedir. Bu metot, kullanım açısından diğer metotlar kadar ucuz ve sade olmasa da, UAS sınıflandırması da yaptığından performans açısından daha avantajlı olduğu söylenebilir.

Sonuç olarak, geliştirilen bu metotlarla UAS teşhisi ve sınıflandırılması hekimlerin PSG cihazıyla alınan işaretleri gözlem yoluyla ve daha önce yapılmış çalışmalara göre de daha iyi olduğu söylenebilir. Bu çalışma ile UAS sınıflandırılması kısa sürede yapılabilmektedir.

Gelecekte yapılabilecek çalışmalardan biri, horlama seslerinin *SDD* analizinden horlama derecesini ve belki de solunum yolu üzerindeki doku hakkında bilgi edinmek olabilir. Diğer bir araştırma konusu EEG verisinin *SDD* veya ikiz–spektrumla analizinden çeşitli nörolojik hastalık araştırması yapılabilir. Karın ve göğüs hareketi işaretlerinin *ADD* analizinden apne dışındaki diğer solunum hastalıkları araştırılabilir. Ayrıca, yapılan bu çalışmanın UAS teşhisinde ve sınıflandırılmasında kullanılmak üzere PSG cihazına entegre edilebileceği ve dolayısıyla teşhis sürecini kısaltarak insan sağlığında önemli bir yer tutabileceği düşünülmektedir.

KAYNAKLAR

- [1] T. Young, M. Palta, J. Dempsey, J. Skatrud, S. Weber and S. Badr, *The occurrence of sleep disordered breathing among middle-aged adults*, **N Engl J Med**, 328:17 (1993) 1230–5.
- [2] American Academy of Sleep Medicine Report “*Sleep related breathing disorders in adults: recommendations for syndrome definition and measurement techniques in clinical research*,” **Sleep**, 22:5 (1999) 667–89.
- [3] K. Gleeson, C.W. Zwillich and D.P. White, *The influence of increasing ventilatory effort on arousal from sleep*, **Am Rev Respir Dis**, 142:2 (1990) 295–300.
- [4] E. Benlloch, P. Cordero, P. Morales, J.J. Soler and V. Macian, *Ventilatory pattern at rest and response to hypercapnic stimulation in patients with obstructive sleep apnea syndrome*, **Respiration**, 62:1 (1995) 4–9.
- [5] N.T. Ayas, R. Brown and S.A. Shea, *Hypercapnia can induce arousal from sleep in the absence of altered respiratory mechanoreception*, **Am J Respir Crit Care Med**, 162:3 Pt 1 (2000) 1004–8.
- [6] M.H. Kryger, “Monitoring respiratory and cardiac function”, In: Kryger MH, Roth T, Dement WC, editors. Principles and practice of sleep medicine. Philadelphia, PA: W.B. Saunders, 2000, pp. 1217–30.
- [7] R.D. Chervin, “Use of clinical tools and tests in sleep medicine,” In: Kryger MH, Roth T, Dement WC, editors. Principles and practice of sleep medicine. Philadelphia, PA: W.B. Saunders, 2000, pp. 538.
- [8] M.H. Kryger, “Management of obstructive sleep apnea–hypopnea syndrome: overview,” In: Kryger MH, Roth T, Dement WC, editors. Principles and practice of sleep medicine. Philadelphia, PA: W.B. Saunders, 2000, pp. 940–54.
- [9] The Report of an American Academy of Sleep Medicine Task Force, *Sleep-related breathing disorders in adults: recommendations for syndrome definition and measurement techniques in clinical research*, **Sleep**, 22:5 (1999) 667–89.
- [10] Y. Yasuda, A. Umezu, S. Horihata, K. Yamamoto, R. Miki and S. Koike, *Modified thoracic impedance plethysmography to monitor sleep apnea syndromes*, **Sleep Med** 6:3 (2005) 215–24.
- [11] U.R. Abeyratne, A.S. Wakwella and C. Hukins, *Pitch jump probability measures for the analysis of snoring sounds in apnea*, **Physiol Meas**, 26:5 (2005) 779–98.
- [12] J.E. Mietus, C.K. Peng, P.C. Ivanov and A.L. Goldberger, *Detection of obstructive sleep apnea from cardiac interbeat interval time series*, In: Proceedings of computers in cardiology conference, Cambridge, MA, USA, vol. 27, (2000) pp.753–6.
- [13] http://www.tiredofcpap.com/Sleep_Apnea.html, 2010.
- [14] J.R.L. Shelton and J.F. Bomsa, *Maintenance of the pharyngeal airway*, **J Appl Physiol**, 17 (1962) 209–14.
- [15] J.E. Remmers, W.J. deGroot, E.K. Sauderland and A.M. Anch, *Pathogenesis of upper airway occlusion during sleep*, **J Appl Physiol**, 44 (1978) 931–8.
- [16] R.J. Schwab, M. Pasirstein, R. Pierson, A. Mackley, R. Hachadoorian, R. Arens, G. Maislin and A.I. Pack, *Identification of upper airway anatomic risk factors for obstructive sleep apnea with volumetric magnetic resonance imaging*, **Am J Respir Crit Care Med**, 168 (2003) 522–30.
- [17] C. Guilleminault, M. Partinen, K. Hollman, N. Powell and R. Stoohs, *Familial aggregates in obstructive sleep apnea syndrome*, **Chest**, 107:6 (1995) 1545–51.
- [18] R. Mathur, N.J. Douglas, *Family studies in patients with the sleep apnea–hypopnea syndrome*, **Ann Intern Med**, 122:3 (1995) 174–8.

- [19] S. Redline, P.V. Tishler, T.D. Tosteson, J. Williamson, K. Kump, I. Browner, V. Ferrette and P. Krejci, *The familial aggregation of obstructive sleep apnea*, **Am J Respir Crit Care Med**, 151:3 Pt 1 (1995) 682–7.
- [20] T. Shintani, K. Asakura and A. Kataura, *Adenotonsillar hypertrophy and skeletal morphology of children with obstructive sleep apnea syndrome*, **Acta Otolaryngol Suppl**, 523 (1996) 222–4.
- [21] E.P. Hamans, E.A. Van Marck, W.A. De Backer, W. Creten and P.H. Van de Heyning, *Morphometric analysis of the uvula in patients with sleep-related breathing disorders*, **Eur Arch Otorhinolaryngol**, 257:4 (2000) 232–6.
- [22] K.L. Do, H. Ferreyra, J.F. Heal and T.M. Davidson, *Does tongue size differ between patients with and without sleep-disordered breathing?*, **Laryngoscope**, 110:9 (2000) 1552–5.
- [23] W.C. Dement, M.A. Carskadon and G. Richardson, “Excessive daytime sleepiness in the sleep apnea syndrome”, In: Dement WC, Guilleminault CG, editors. *Sleep apnea syndrome*. New York: Alan R. Liss; 1978.
- [24] A. Kales, R.J. Cadieux, E.O. Bixler, C.R. Soldatos, A. Vela-Bueno, C.A. Misoul and T.W. Locke, *Severe obstructive sleep apnea-I: onset, clinical course, and characteristics*, **J Chronic Dis**, 38:5 (1985) 419–25.
- [25] A.G. Bassiri, C.G. Guilleminault, “Clinical features and evaluation of obstructive sleep apnea–hypopnea syndrome,” In: Kryger MH, Roth T, Dement CG, editors. *Principles and practice of sleep medicine*. Philadelphia, PA: W.B. Saunders, 2000, pp. 870–1.
- [26] C.F. George, P.W. Nickerson, P.J. Hanly, T.W. Millar and M.H. Kryger, *Sleep apnea patients have more automobile accidents*, **Lancet**, 22:2 (1987) 447.
- [27] L.J. Findley, M. Unverzadt, P. Surat, *Automobile accidents in patients with obstructive sleep apnea*, **Am Rev Respir Dis**, 138:2 (1988) 337–40.
- [28] M.H. Kryger, L. Roos, K. Delaive, R. Walld and J. Horrocks, *Utilization of health care services in patients with severe obstructive sleep apnea*, **Sleep**, 19(9 Suppl.) (1996) 111–6.
- [29] E.M. Ball, R.D. Jr Simon, A.A. Tall, M.B. Banks, G. Nino-Murcia and W.C. Dement, *Diagnosis and treatment of sleep apnea within the community*, The Walla Walla Project. **Arch Intern Med**, 157:4 (1997) 419–24.
- [30] V. Hoffstein, “Snoring,” In: Kryger MH, Roth T, Dement WC, editors. *Principles and practice of sleep medicine*. Philadelphia, PA: W.B. Saunders, 2000, pp. 813–26.
- [31] J.R. Stradling, J.H. Crosby, *Relation between systemic hypertension and sleep hypoxemia and snoring: analysis in 748 men drawn from general practice*, **Br Med J**, 300 (1990) 75–8.
- [32] G. Pillar, A. Malhotra, R. Fogel, J. Beauregard, R. Schnall and D.P. White, *Airway mechanics and ventilation in response to resistive loading during sleep: influence of gender*, **Am J Respir Crit Care Med**, 162:5 (2000) 1627–32.
- [33] V. Mohsenin, *Gender differences in the expression of sleepdisordered breathing: role of upper airway dimensions*, **Chest**, 120:5 (2001) 1442–7.
- [34] A. Malhotra, Y. Huang, R.B. Fogel, G. Pillar, J.K. Edwards, R. Kikinis, S.H. Loring and D.P. White, *The male predisposition to pharyngeal collapse: importance of airway length*, **Am J Respir Crit Care Med**, 166:10 (2002) 1388–95.
- [35] F.G. Issa and C.F. Sullivan, *Alcohol, snoring, and sleep apnea*, **J Neurol Neurosurg Psychiatry**, 45 (1982) 353–9.

- [36] L. Scrima, M. Broudy, K. Nay and M.A. Cohn, *Increased severity of obstructive sleep apnea after bedtime alcohol ingestion: diagnostic potential and proposed mechanism of actions*, **Sleep**, 5:4 (1982) 318–28.
- [37] V.C. Taasan, A.J. Block, P.G. Boysen and J.W. Wynne, *Alcohol increases sleep apnea and oxygen desaturation in asymptomatic men*, **Am J Med**, 71:2 (1981) 240–5.
- [38] R.J. Strobel and R.C. Rosen, *Obesity and weight loss in obstructive sleep apnea: a critical review*, **Sleep**, 19:2 (1996) 104–15.
- [39] R.J. Davies, N.J. Ali and J.R. Stradling, *Neck circumference and other clinical features in the diagnosis of the obstructive sleep apnoea syndrome*, **Thorax**, 47:2 (1992) 101–5.
- [40] I.L. Mortimore, I. Marshall, P.K. Wraith, R.J. Sellar, N.J. Douglas, *Neck and total body fat deposition in non-obese and obese patients with sleep apnea compared with that in control subjects*, **Am J Respir Crit Care Med**, 157:1 (1998) 280–3.
- [41] H. Bearpark, L. Elliott, R. Grunstein, S. Cullen, H. Schneider, W. Althaus and C. Sullivan, *Snoring and sleep apnea: a population study in Australian men*, **Am J Respir Crit Care Med**, 151:5 1459–65, 1995.
- [42] http://www.21stcenturydental.com/smith/sleepapena_tappliance.htm, 2010.
- [43] T. Haja, K. Behbehani, F.C. Yen, E.A. Lucas and J.R. Burk, *Sleep Apnea Detection Using Flow Spectral Analysis and Fuzzy Logic*, Proceedings of The First Joint BMES/EMBS Conference Serving Humanity, Advancing Technology, Atlanta, OA, USA, (1999), pp.13-16.
- [44] J.N. McNames and A.M. Fraser, *Obstructive Sleep Apnea Classification Based on Spectrogram Patterns in the Electrocardiogram*, **Computers in Cardiology**, 27 (2000) 749-752.
- [45] G. Balakrishnan, D. Burli, J.R. Burk, E. A. Lucas and K. Behbehani, *Comparison of a Sleep Quality Index between Normal and Obstructive Sleep Apnea Patients*, *Engineering in Medicine and Biology*, Shanghai, China, September, (2005), pp 1154–1157.
- [46] A.A. Morsy and K.M. Al-Ashmouny, *Sleep Apnea Detection Using an Adaptive Fuzzy Logic Based Screening System*, Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference Shanghai, China, September 1-4, (2005), pp. 6124-7.
- [47] J.Y. Tian and J.Q. Liu, *Apnea Detection Based on Time Delay Neural Network*, Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference Shanghai, China, September 1-4, (2005), pp. 2571-4.
- [48] O. Fontenla-Romero, B. Guijarro-Berdinas, A. Alonso-Betanzos and V. Moret-Bonillo, *A new method for sleep apnea classification using wavelets and feedforward neural Networks*, **Artificial Intelligence in Medicine**, 34:1 (2005) 65-76.
- [49] C.F. Chao, J.A. Jiang, M.J. Chiu and R.G. Lee, *Wavelet-Based Processing and Adaptive Fuzzy Clustering For Automated Long-Term Polysomnography Analysis*, **Acoustics, Speech and Signal Processing**, 2 (2006) II-1176- II-1179.
- [50] F. del Campo, R. Hornero, C. Zamarron, D.E. Abasolo and D. Alvarez, *Oxygen saturation regularity analysis in the diagnosis of obstructive sleep apnea*, **Artificial Intelligence in Medicine**, 37:2 (2006) 111—118.
- [51] R. Lin, R.G. Lee, C.L. Tseng, H.K. Zhou, C.F. Chao and J.A. Jiang, *A New Approach For Identifying Sleep Apnea Syndrome Using Wavelet Transform And Neural Networks*, **Biomedical Engineering applications, Basis & Communications**, 18:3 (2006) 138-143.

- [52] M. Akin, *Comparison of Wavelet Transform and FFT in the Analysis of EEG Signals*, **Journal of Medical Systems**, 26:3 (2002) 241-247.
- [53] Y. Istefanopulos, *Biyomedikal sinyal işleme teknikleri: Spektral analiz, sayısal filtreleme, dalgacık dönüşümü*, Tübitak Beyin Dinamiği Multidisipliner Çalışma Gurubu Ders Notları, Bölüm I, Temmuz 1999, sayfa 1-16.
- [54] Y. Sheng, “Wavelet Transforms”, in A.D. Povlarikas (Ed.), *the transforms and applications handbook*, Boca Raton, F1(USA) CRC Press, 1996, p. 747- 827.
- [55] S.G. Mallat, *A theory for multiresolution signal decomposition: The wavelet representation*, **IEEE Trans. on Pattern Analysis on Machine Intelligence**, 11:7 (1989) 674-693.
- [56] R.L. Wagner and W.C. Chew, *A study of wavelets for the solution of electromagnetic integral equations*, **IEEE Trans. on Antennas and Propagation**, 43:8 (1995) 802-810.
- [57] N. Guan, K. Yashiro and S. Ohkawa, *Wavelet transform approach for electromagnetic scattering from an array of metal strips*, **IEICE Trans. on Electron**, E82-C: 7 (1999) 1273-1279.
- [58] T.K. Sarkar, C. Su, *A Tutorial on Wavelets from an Electrical Engineering Perspective, Part I: Discrete Wavelet Techniques*, **IEEE Trans.on Antennas and Propagation Mag.**, 40:5 (1998) 49-69.
- [59] C.F. Wang, *A hybrid wavelet expansion and boundary element analysis of electromagnetic scattering from conducting objects*, **IEEE Trans.on Antennas and Propagation**, 43:2 (1995) 170-178.
- [60] Z.G. Xiang and Y.L. Lu, *An effective wavelet matrix transform approach for efficient solutions of electromagnetic integral equations*, **IEEE Trans.on Antennas and Propagation**, 45:8 (1997) pp. 1205-1213.
- [61] I. Daubechies, *Ten Lectures on wavelets*, Philadelphia, SIAM Publications, 1992.
- [62] N. Guan and K. Yashiro, *On a choice of wavelet basis in the wavelet transform approach*, **IEEE Trans. on Antennas and Propagation**, vol. 48:8 (2000) 1186-1190.
- [63] M.B. Kurt, “*Dalgacık dönüşümünün üç boyutlu EM saçılım problemlerinde kullanılması*”, Doktora tezi, Sakarya Üniversitesi Türkiye, 2002.
- [64] J.C. Sigl and N.G. Chamoun, *An introduction of bispectral analysis for the electroencephalogram*, **Journal of Clinical Monitoring**, 10:6 (1994) 392-404.
- [65] M.J. Hinich and C.S. Clay, *The application of the discrete Fourier transform in the estimation of power spectra, coherence and bispectra of geophysical data*, **Reviews of Geophysics**, 6:3 (1968) 347-363.
- [66] C.L. Nikias and A.P. Petropulu, *Higher order spectral analysis: A nonlinear signal processing framework*, Engle-wood Cliffs, NJ: Prentice-Hall, 1993.
- [67] T. Ning and J.D. Bronzino, *Bispectral analysis of the rat EEG during various vigilance states*, **IEEE Trans Biomed Eng**, 36:4 (1989) 497-499.
- [68] C.L. Nikias and M.R. Raghuveer, *Bispectrum Estimation: A digital signal processing framework*, **Proc. IEEE**, 75:7 (1987) 867-891.
- [69] M.R. Raghuveer and C.L. Nikias, *Bispectrum estimation: A parametric approach*, **IEEE Trans. Acoust., Speech, Signal Processing**, 33:4 (1985) 1113-1230.
- [70] B.T. Gerstein, *Analyzing biological time series with higher order cumulants*, Master of science thesis, Massachusetts institute of technology, 1997.
- [71] M. Gökbulut, *Yapay sinir ağlarına giriş, Yapay sinir ağlarında öğrenme*, ders notları, 2000.
- [72] <http://www.yapay-zeka.org/modules/icontent/index.php?page=47>, 2010.
- [73] <http://batitrakya.dostweb.com/yapaysiniraglari/yapaysiniraglari.htm>, 2003.

- [74] <http://www.yapay-zeka.org/files/tez/tugba-sarac-ysa-seminer.pdf> , 2010.
- [75] <http://www.ahmetkakici.com/yapay-sinir-aglari/yapay-sinir-aglarinin-mimarisi-ve-yapi-elemanlari/>, 2010.
- [76] S. Haykin, *Neural networks: a comprehensive foundation*, Macmillan, New York, 1994.
- [77] I.A. Basheer, M. Hajmeer, *Artificial neural networks: fundamentals, computing, design, and application*, **J Microbiol Methods**, 43:1 (200) 3–31.
- [78] L.V. Fausett, *Fundamentals of Neural Networks architectures, algorithms, and applications*. Prentice-Hall, Englewood Cliffs, 1994.
- [79] C. Eyfe, *Artificial Neural Network*, The University of Paisley, Edition 1.1, 1996.
- [80] L. H. Tsoukalas and R.E. Uhrig, *Fuzzy and Neural Approaches in Engineering*. Jhon Wiley & Sons , Inc, New York, 1996.
- [81] H.R. Özçalık A.F. Uygur, *Dinamik Sistemlerin Uyumlu Sinirsel-Bulanık Ağ Yapısına Dayalı Etkin Modellenmesi*, **KSÜ Fen ve Mühendislik Dergisi**, 6:1 (2003) 36–46.
- [82] J.S.R. Jang, *ANFIS: Adaptive-Network Based Fuzzy Inference Systems*, **IEEE Trans. on Systems, Man, and Cybernetics**, 23:3 (1993) 665-685.
- [83] T. Takagi, M. Sugeno, *Fuzzy identification of systems and its applications to modelling and control*, **IEEE Transactions on Systems, Man, and Cybernetics**, 15:1 (1985) 116-132.
- [84] J. Shing, R. Jang, *ANFIS: Adaptive-Network-Based Fuzzy Inference System*, **IEEE Trans. On Systems, Man, and Cybernetics**, 23:3 (1993) 665-685.
- [85] J. S. R. Jang and C. T. Sun, *Neuro-Fuzzy Modeling and Control*, Proc. Of the IEEE Special Issue on Fuzzy Logic in Engineering Applications, 83:3 (1995) 378–406.
- [86] A.K. Ng, T.S. Koh, E. Baey and K. Puvanendran, *Diagnosis of obstructive sleep apnea using formant features of snore signals*, in Proc. IFBME World Congress Med. Phy. Biomed. Eng., 14:8, 2006, pp. 861-864.
- [87] P.S. Addison, *The Illustrated Wavelet Transform Handbook: Introductory Theory and Applications in Science, Engineering, Medicine and Finance*, Institute of Physics (IOP) te Publishing, Bristol, UK, 2002.
- [88] C. Torrence and G.P. Compo, *A practical guide to wavelet analysis*, **Bull 59 Amer.Meteor.Soc.**, 79 (1998) pp.61-78.
- [89] J. Solà-Soler, R. Jané, J.A. Fiz and J. Morera, *Variability of snore parameters in time and frequency domains in snoring subjects with and without Obstructive Sleep Apnea*, Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference Shanghai, China, September 1-4, 2005, pp. 2583-6.
- [90] D. Matsiki, X. Deligianni, E. Vlachogianni-Daskalopoulou and L.J. Hadjileontiadis, *Wavelet-based Analysis of Nocturnal Snoring in Apneic Patients Undergoing Polysomnography*, Proceedings of the 29th Annual International Conference of the IEEE EMBS Cité Internationale, Lyon, France, August 23-26, 2007, pp. 1912-5.
- [91] Somno medic devices SomnoMedics, Device brochure, available at <http://www.somnomedics.de/>
- [92] J. Solà-Soler, R. Jane, J.A. Fiz, J. Morera, *Spectral envelope analysis in snoring signals from simple snorers and patients with Obstructive Sleep Apnea*, Proceedings of the 25th Ann. Intl. Conf. of the IEEE EMBS, Vol 3, 2003, pp. 2527–30.

- [93] C. Maier, M. Bauch and H. Dickhaus, *Recognition and Quantification of Sleep Apnea by Analysis of Heart Rate Variability Parameters*, **Computers in Cardiology**, 27 (2000) 741-744.
- [94] B.A. Ghunaimi, A. Hossen and M.O. Hassan, *Screening of Obstructive Sleep Apnea based on Statistical Signal Characterization of Hilbert Transform of RRI Data,*” **Technology and Health Care: International Journal of the European Society for Engineering and Medicine**, 12:1 (2004) 67-78.
- [95] D. Liu, Z. Pang and S.R. Lloyd, *A Neural Network Method for Detection of Obstructive Sleep Apnea and Narcolepsy Based on Pupil Size and EEG*, **IEEE transactions on neural Networks**, 19:2 (2008) 308-18.
- [96] M. Clabian, C. Nussbaum and H. Pfützner, *Artificial neural Networks for apnea detection*, Proc EANN, (1996), pp. 601—8.
- [97] M. Clabian and H. Pfützner, *Determination of decisive inputs of a neural network for sleep apnea classification*, Proc EANN, (1997), pp. 171—8.
- [98] T. Zemen, M. Clabian, H. Pfützner, *Classification of sleep apnea events by means of radial basis function Networks*, In: *A new method for sleep apnea classification using wavelets and feedforward neural networks* 75 International ICSC/IFAC Symposium on Neural Computation (NC98), (1998), pp. 351—57.

EKLER

EK 1: Horlama sesi işaretlerinin zaman-frekans analizini yapan program

```
close all
clear all
[x,Fs,Start_date,Start_time,Label,Dimension,Coef,Nmb_chans,N] =
readedf('02.04.2007AO_OSAS.edf',12,3171,3181);

[B,F,T]= spectrogram(x,512,512,128,120); % Display the spectrogram
clims = [.5 3];
t=0:1/512:10;
t=t(1:5120);
subplot 211
plot(t,x)
axis xy
ylabel('mikrovolt')
subplot 212
imagesc(T,F(1:256),1/100.*abs(B),clims)
axis xy
colorbar
colormap jet
xlabel('Zaman (sn)');
ylabel ('Frekans (Hz)')
```


EK 2: EEG işaretlerinin ikiz spektrum analizinde kullanılan program

```
[eeg,Fs,Start_date,Start_time,Label,Dimension,Coef,Nmb_chans,N] = readedf('SY.rec',0,11160,11170);
[bisp,freq,cum,lag]=bisp3cum1(eeg,256,500,'g','b');
close all
figure

subplot 221
t=0:1/256:10;
plot(t(1:2560),eeg);
axis([0 10 -64 64])
seconds='(sn)';
xlabel(['Zaman ' seconds])
ylabel('EEG (uV)')
grid

subplot 222
f=0:127;
ff=fft(eeg,256);
ff=ff(1:128);
ff=abs(ff);
plot(f,ff/max(ff));
axis([0 40 0 1.1])
grid
xlabel('Frekans (Hz)');
ylabel('Genlik')

subplot 223
clims = [300000 600000];
bisp=abs(bisp);
imagesc(freq,freq,bisp,clims)
fontsize='fontsize{10}';
hertz='(Hz)';
fxlabel=[fontsize ' f_{1} ' hertz];
xlabel(fxlabel)
fylabel=[fontsize ' f_{2} ' hertz];
ylabel(fylabel)
axis xy
axis([-20 20 -20 20])
colorbar
colormap jet
grid

subplot 224
plot(freq,bisp/max(max(bisp)))
axis([0 40 0 1.1])
xlabel('Frekans (Hz)');
ylabel('Genlik')
grid
```

EK 3: Karın ve göğüs hareketi işaretlerine uygulanan *ADD* programı

```
close all
clear all
%%%%%%%%%%%%%%
%%ABDOMINAL

[abdo,Fs,Start_date,Start_time,Label,Dimension,Coef,Nmb_chans,N] = readedf('AB.rec',9,4460,4470);

[C,L]=wavedec(abdo,1,'db4');
D1=detcoef(C,L,1);
subplot(721);plot(D1);ylabel('cD1');axis([0 643 -0.03 0.03])
A1=appcoef(C,L,'db4',1);
subplot(7,2,2);plot(A1);ylabel('cA1');axis([1 643 -14 14])

[C,L]=wavedec(abdo,2,'db4');
D2=detcoef(C,L,2);
subplot(723);plot(D2);ylabel('cD2') ;axis([0 325 -0.02 0.02])
A2=appcoef(C,L,'db4',2);
subplot(7,2,4);plot(A2);ylabel('cA2');axis([1 325 -14 14])

[C,L]=wavedec(abdo,3,'db4');
D3=detcoef(C,L,3);
subplot(725);plot(D3);ylabel('cD3');axis([0 166 -0.05 0.05])
A3=appcoef(C,L,'db4',3);
subplot(7,2,6);plot(A3);ylabel('cA3');axis([1 166 -14 14])

[C,L]=wavedec(abdo,4,'db4');
D4=detcoef(C,L,4);
subplot(727);plot(D4);ylabel('cD4');axis([0 86 -0.1 0.1])
A4=appcoef(C,L,'db4',4);
subplot(7,2,8);plot(A4);ylabel('cA4');axis([1 86 -14 14])

[C,L]=wavedec(abdo,5,'db4');
D5=detcoef(C,L,5);
subplot(7,2,9);plot(D5);ylabel('cD5');axis([0 46 -0.5 0.5])
A5=appcoef(C,L,'db4',5);
subplot(7,2,10);plot(A5);ylabel('cA5');axis([1 46 -14 14])

[C,L]=wavedec(abdo,6,'db4');
D6=detcoef(C,L,6);
subplot(7,2,11);plot(D6);ylabel('cD6');axis([1 26 -3 3])
A6=appcoef(C,L,'db4',6);
subplot(7,2,12);plot(A6);ylabel('cA6');axis([1 26 -14 14])

[C,L]=wavedec(abdo,7,'db4');
D7=detcoef(C,L,7);
subplot(7,2,13);plot(D7);ylabel('cD7');axis([1 16 -10 10]); xlabel('Katsayilar')
A7=appcoef(C,L,'db4',7);
subplot(7,2,14);plot(A7);ylabel('cA7');axis([1 16 -14 14])
xlabel('Katsayilar')

%%%%%%%%%%%%%%
%% THORACIC
clear all
figure

[thor,Fs,Start_date,Start_time,Label,Dimension,Coef,Nmb_chans,N] = readedf('AB.rec',8,4460,4470);
```

```

[C,L]=wavedec(thor,1,'db4');
D1=detcoef(C,L,1);
subplot(721);plot(D1);ylabel('cD1');axis([0 643 -0.03 0.03])
A1=appcoef(C,L,'db4',1);
subplot(7,2,2);plot(A1);ylabel('cA1');axis([1 643 -8 8])

[C,L]=wavedec(thor,2,'db4');
D2=detcoef(C,L,2);
subplot(723);plot(D2);ylabel('cD2') ;axis([0 325 -0.02 0.02])
A2=appcoef(C,L,'db4',2);
subplot(7,2,4);plot(A2);ylabel('cA2');axis([1 325 -8 8])

[C,L]=wavedec(thor,3,'db4');
D3=detcoef(C,L,3);
subplot(725);plot(D3);ylabel('cD3');axis([0 166 -0.05 0.05])
A3=appcoef(C,L,'db4',3);
subplot(7,2,6);plot(A3);ylabel('cA3');axis([1 166 -8 8])

[C,L]=wavedec(thor,4,'db4');
D4=detcoef(C,L,4);
subplot(727);plot(D4);ylabel('cD4');axis([0 86 -0.1 0.1])
A4=appcoef(C,L,'db4',4);
subplot(7,2,8);plot(A4);ylabel('cA4');axis([1 86 -8 8])

[C,L]=wavedec(thor,5,'db4');
D5=detcoef(C,L,5);
subplot(7,2,9);plot(D5);ylabel('cD5');axis([0 46 -0.5 0.5])
A5=appcoef(C,L,'db4',5);
subplot(7,2,10);plot(A5);ylabel('cA5');axis([1 46 -8 8])

[C,L]=wavedec(thor,6,'db4');
D6=detcoef(C,L,6);
subplot(7,2,11);plot(D6);ylabel('cD6');axis([1 26 -3 3])
A6=appcoef(C,L,'db4',6);
subplot(7,2,12);plot(A6);ylabel('cA6');axis([1 26 -8 8])

[C,L]=wavedec(thor,7,'db4');
D7=detcoef(C,L,7);
subplot(7,2,13);plot(D7);ylabel('cD7');axis([1 16 -10 10]); xlabel('Katsayilar')
A7=appcoef(C,L,'db4',7);
subplot(7,2,14);plot(A7);ylabel('cA7');axis([1 16 -8 8])
xlabel('Katsayilar')

```


EK 5: ANFIS'e ait m-file program

```
clear all
load abdoenergyOSA;
load abdoenergyCSA;
load abdoenergyMSA;

x=[abdoenergyOSA(:,1:10)';abdoenergyCSA(:,1:10)';abdoenergyMSA(:,1:10)'];
x=log10(x+1);
y1 = [ones(10,1);zeros(10,1);zeros(10,1)];
y2 = [zeros(10,1);ones(10,1);zeros(10,1)];
y3 = [zeros(10,1);zeros(10,1);ones(10,1)];

epoch_n = 20;

in_fis1 = genfis1([x y1]);
out_fis1 = anfis([x y1],in_fis1,epoch_n);
out1=evalfis(x,out_fis1);

in_fis2 = genfis1([x y2]);
out_fis2 = anfis([x y2],in_fis2,epoch_n);
out2=evalfis(x,out_fis2);

in_fis3 = genfis1([x y3]);
out_fis3 = anfis([x y3],in_fis3,epoch_n);
out3=evalfis(x,out_fis3);

%egitim sonrası eğitim sinyal çıkışları

disp(' OSA      CSA      MSA')
disp(' -----      -----      -----')
out=[out1 out2 out3];
disp(out)

%Eğitim sonrası test sinyal çıkışları
xt=[abdoenergyOSA(:,11:40)';abdoenergyCSA(:,11:40)';abdoenergyMSA(:,11:40)'];
xt=log10(xt+1);
out4=evalfis(xt,out_fis1);
out5=evalfis(xt,out_fis2);
out6=evalfis(xt,out_fis3);

disp(' OSA      CSA      MSA')
disp(' -----      -----      -----')
outt=[out4 out5 out6];
disp(outt)

% ortalama test doğruluğu
outt=abs(outt);
osaort=mean(outt(1:30,:));
csaort=mean(outt(31:60,:));
msaort=mean(outt(61:90,:));
ort=[osaort;csaort;msaort];
disp(' OSA      CSA      MSA')
disp(' -----      -----      -----')
disp(ort)
```

ÖZGEÇMİŞ

Yazar, 1975 yılında Siirt ilinin Baykan ilçesinde doğdu. İlkokula 1985 yılında Siirt Marmara yatılı bölge okulunda başlayarak 1990 yılında Kozluk ilçesine bağlı Dolutaş köyü ilkokulunda tamamladı. Ortaokul ve liseyi Batman Fatih Lisesinde 1996 yılında tamamladı. Aynı yıl Hacettepe Üniversitesi Elektrik-Elektronik Mühendisliği bölümünü kazanarak 2001 yılında mezun oldu. 2003 yılında Dicle Üniversitesi Fen Bilimleri Enstitüsü Elektrik ve Elektronik Mühendisliği anabilim dalında yüksek lisansını tamamladı. 2003–2007 yılları arasında Türk Telekom A.Ş. Bilişim Ağları Müdürlüğünde uzman yardımcısı olarak görev yaptı. 2007 yılında Batman Üniversitesinde öğretim görevlisi olarak çalışmaya başladı ve halen bu görevini devam ettirmektedir. Yazar, evli ve üç çocuk babasıdır.