

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

116 574

**DURAĞAN OLMAYAN İŞARETLER İÇİN ZAMAN – FREKANS
ENTROPİLERİNE DAYALI AKILLI ÖRÜNTÜ TANIMA**

İbrahim TÜRKOĞLU

DOKTORA TEZİ
ELEKTRİK – ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

T.C. YÜKSEKÖĞRETİM KURULU
DOKÜMANTASYON MERKEZİ

116574

Bu tez, 12/06/2022 tarihinde aşağıda belirtilen jüri tarafından oybirliği / ~~oyçokluğu~~ ile başarılı / ~~başarısız~~ olarak değerlendirilmiştir.

Danışman : Doç.Dr. Ahmet ARSLAN

Üye : Doç.Dr. Z.Hakan AKPOLAT

Üye : Doç.Dr. Saadetdin HERDEM

Üye : Doç.Dr. Yakup DEMİR

Üye : Doç.Dr. Erhan AKIN

.....
.....
.....
.....
.....

Bu tezin kabulü, Fen Bilimleri Enstitüsü Yönetim Kurulu'nun/...../..... tarih ve sayılı kararıyla onaylanmıştır.

TEŞEKKÜR

Bu tez çalışmam boyunca, ilgi ve yardımlarını esirgemeyen danışmanım Sayın Doç.Dr.Ahmet ARSLAN 'a, çalışmamın başlangıç aşamasında değerli fikirlerinden faydalandığım Prof.Dr. Cüneyt GÜZELİŞ 'e (Dokuz Eylül Üniversitesi, Elektrik-Elektronik Mühendisliği), uygulama için gerekli ortamın oluşturulmasındaki katkılarından dolayı Doç.Dr. Erdoğan İLKAY 'a (Fırat Tıp Merkezi, Kardiyoloji Anabilim Dalı), tezin düzenlenmesindeki yardımlarından ötürü Arş.Gör. Ahmet ÇINAR, Arş.Gör.Ali KARCI 'ya (Fırat Üniversitesi, Bilgisayar Mühendisliği), teze destek veren Fırat Üniversitesi Bilimsel Araştırma Projeleri Birimine (FÜBAP-527) ve çalışmam boyunca beni sabır ve özveri ile destekleyen aileme, teşekkürlerimi ve şükranlarımı sunarım.

İÇİNDEKİLER

TEŞEKKÜR	
İÇİNDEKİLER	I
ŞEKİLLER LİSTESİ	IV
TABLolar LİSTESİ	VII
EKLER LİSTESİ	VIII
SİMGELER LİSTESİ	IX
KISALTMALAR LİSTESİ	XI
ÖZET	XII
ABSTRACT	XIII
1. GİRİŞ	1
1.1. Amaç	1
1.2. Durağan Olmayan İşaretler	2
1.3. Yönelim Gerekçeleri	3
1.4. Tezin Organizasyonu ve Orijinal Katkıları	6
2. ÖRÜNTÜ TANIMA	8
2.1. Örüntü Tanıma Probleminin Formülasyonu	9
2.2. Örüntü Tanıma Sistemleri	10
2.3. Özellik Çıkarma	15
2.3.1. Zaman – Frekans Gösterimleri	16
2.3.2. Entropi Hesaplama Teknikleri	18
2.4. Sınıflandırma	20
2.4.1. Yapay Sinir Ağı Sınıflandırıcıları	20
3. DALGACIK DÖNÜŞÜM ZAMAN – FREKANS GÖSTERİM ENTROPİLERİ İLE ÖZELLİK ÇIKARMA	26
3.1. Dalgacık Dönüşümü	26
3.2. Dalgacık Dönüşüm Ağacından Entropi Hesaplanması	32
3.3. Dalgacık Paket Dönüşüm Ağacından Entropi Hesaplanması	34
4. PARAMETRİK OLMAYAN ZAMAN – FREKANS GÖSTERİM ENTROPİLERİ İLE ÖZELLİK ÇIKARMA	37
4.1. Kısa Zamanlı Fourier Dönüşümü ile Spektrogram	38
4.1.1. Dalgacık Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması	39

4.1.2. Dalgacık Paket Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması	41
4.2. Güç Spektrum Yoğunluğu	42
4.2.1. Dalgacık Dönüşümü ve Welch Güç Spektrumu ile Entropi Hesaplanması	44
4.2.2. Dalgacık Paket Dönüşümü ve Welch Güç Spektrumu ile Entropi Hesaplanması	46
4.2.3. Dalgacık Dönüşümü ve MUSIC Güç Spektrumu ile Entropi Hesaplanması	47
4.2.4. Dalgacık Paket Dönüşümü ve MUSIC Güç Spektrumu ile Entropi Hesaplanması	51
5. PARAMETRİK ZAMAN – FREKANS GÖSTERİM ENTROPİLERİ İLE ÖZELLİK ÇIKARMA	53
5.1. Model Tabanlı Güç Spektrum Yoğunluğu	54
5.1.1. Dalgacık Dönüşümü ve AR Modeli ile Entropi Hesaplanması	55
5.1.2. Dalgacık Paket Dönüşümü ve AR Modeli ile Entropi Hesaplanması	57
6. GELİŞTİRİLEN DALGACIK SİNİR AĞ MODELLERİ İLE ADAPTİF ÖZELLİK ÇIKARMA VE SINIFLAMA	60
6.1. Dalgacık Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama	61
6.2. Dalgacık Paket Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama	64
7. GELİŞTİRİLEN YÖNTEMLERİN DOPPLER KALP İŞARETLERİNE UYGULANMASI	67
7.1. Doppler Kalp İşaretleri	68
7.2. Veri Alımı	69
7.3. Ön-işlem Süreci	69
7.3.1. Filtreleme	70
7.3.2. Beyaz Gürültü Ayırımı	70
7.3.3. Normalizasyon	71
7.4. Geliştirilen Özellik Çıkarma Algoritmalarının Uygulaması	71
7.4.1. Dalgacık Dönüşüm Ağacından Entropi Hesaplanması	71
7.4.2. Dalgacık Paket Dönüşüm Ağacından Entropi Hesaplanması	73
7.4.3. Dalgacık Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması	75
7.4.4. Dalgacık Paket Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması	76
7.4.5. Dalgacık Dönüşümü ve Welch Güç Spektrumu ile Entropi Hesaplanması	78
7.4.6. Dalgacık Paket Dönüşümü ve Welch Güç Spektrumu ile Entropi Hesaplanması	79
7.4.7. Dalgacık Dönüşümü ve MUSIC Güç Spektrumu ile Entropi Hesaplanması	81
7.4.8. Dalgacık Paket Dönüşümü ve MUSIC Güç Spektrumu ile Entropi Hesaplanması	83
7.4.9. Dalgacık Dönüşümü ve AR Modeli ile Entropi Hesaplanması	85
7.4.10. Dalgacık Paket Dönüşümü ve AR Modeli ile Entropi Hesaplanması	87

7.5. Yapay Sinir Ağı ile Sınıflandırma	88
7.6. Adaptif Örüntü Tanıma Yöntemlerinin Uygulaması	94
7.6.1. Dalgacık Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama ...	94
7.6.2. Dalgacık Paket Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama	95
8. SONUÇ VE DEĞERLENDİRME	97
8.1. Sonuçların İrdelenmesi	97
8.2. Öneriler	99
8.3. Yayınlar	100
KAYNAKLAR	101
ÖZGEÇMİŞ	
EKLER	
EK-1 : Ses kartının teknik özellikleri	
EK-2 : Model 3V2c Doppler ultrason transdüserinin teknik özellikleri	

ŞEKİLLER LİSTESİ

Şekil 1.1. Akıllı örüntü tanıma yaklaşımı	1
Şekil 1.2. İşaret örnekleri : a) Durağan, b) Durağan olmayan işaret	2
Şekil 2.1. Örüntü tanıma kavramı	9
Şekil 2.2. Karar yüzeyinin özellik uzayının haritası olarak gösterimi	10
Şekil 2.3. Örüntü tanıma sistemi	10
Şekil 2.4. Öğrenme süreci	14
Şekil 2.5. Sınıflandırıcının test edilme süreci	14
Şekil 2.6. Çeşitli zaman – frekans gösterim teknikleri.	17
Şekil 2.7. Entropi kavramı : a) Yüksek, b) Düşük	18
Şekil 2.8. Akıllı sınıflama yapısı	20
Şekil 2.9. Bir nöron hücresinin matematiksel modeli	21
Şekil 2.10. Yapay sinir ağ örüntü sınıflandırıcıları	24
Şekil 3.1. Yaygın olarak kullanılan dalgacık örnekleri	27
Şekil 3.2. Daubechies-4 ana dalgacığı ile ölçekleme ve dönüşüm tekniğinin gösterimi	28
Şekil 3.3. a) Doppler İşareti; b) KZFD analizi; c) SDD ayrışımı : ölçek frekansın tersidir	29
Şekil 3.4. a) ADD ayrışım ağacı, b) ADD kullanılarak elde edilen ZFG yapısı	31
Şekil 3.5. DPA ile ADD ayrışımının ağaç yapısı	32
Şekil 3.6. Dalgacık dönüşüm ZFG entropileri ile özellik çıkarımı	32
Şekil 3.7. Dalgacık dönüşüm ağaç yapısı	33
Şekil 3.8. Dalgacık paket dönüşüm ZFG entropileri ile özellik çıkarımı	34
Şekil 3.9. Dalgacık paket dönüşüm ağaç yapısı	35
Şekil 4.1. Doppler işaretinin KZFD spektrogramı	38
Şekil 4.2. Pencere fonksiyonları	39
Şekil 4.3. Dalgacık dönüşümü ve KZFD spektrogramı ZFG entropileri ile özellik çıkarımı ..	39
Şekil 4.4. Dalgacık paket dönüşümü ve KZFD spektrogramı ZFG entropileri ile özellik çıkarımı	41
Şekil 4.5. Güç spektrumu a) Sinüs işareti, b) Durağan olmayan işaret	44
Şekil 4.6. Dalgacık dönüşümü ve Welch güç spektrumu ZFG entropileri ile özellik çıkarımı .	44
Şekil 4.7. Dalgacık dönüşümü ve Welch güç spektrumu ZFG entropileri ile özellik çıkarımı ..	46
Şekil 4.8. Dalgacık dönüşümü ve MUSIC güç spektrumu ZFG entropileri ile özellik çıkarımı	47
Şekil 4.9. Eigen değerlerinin ayrışımı	49
Şekil 4.10. Dalgacık paket dönüşümü ve MUSIC güç spektrumu ZFG entropileri le özellik	

çıkarımı	51
Şekil 5.1. Durağan olmayan işaretleri modelleme	53
Şekil 5.2. Dalgacık dönüşümü ve AR modeli ZFG entropileri ile özellik çıkarımı	55
Şekil 5.3. Dalgacık paket dönüşümü ve AR modeli ZFG entropileri ile özellik çıkarımı	58
Şekil 6.1. Dalgacık sinir ağı yapısı	60
Şekil 6.2. Örüntü tanımak için geliştirilen DSA yapısı	61
Şekil 6.3. DSA eğitim algoritması	63
Şekil 6.4. Örüntü tanımak için geliştirilen DPSA yapısı	64
Şekil 6.5. DPSA eğitim algoritması	66
Şekil 7.1. Geliştirilen yöntemlerin DKS işaretlerine uygulama sistemi	67
Şekil 7.2. DKS işaret örüntüsü	68
Şekil 7.3. Doppler olayı	69
Şekil 7.4. Bir DKS işaretinin dalgacık dönüşüm ağacında bulunan işaretleri	72
Şekil 7.5. DKS işaret örüntüsünün DDA-EH özellik eğrisi	73
Şekil 7.6. Bir DKS işaretinin dalgacık paket dönüşüm ağacının uç yaprak işaretleri	74
Şekil 7.7. DKS işaret örüntüsünün DPDA-EH özellik eğrisi	75
Şekil 7.8. DD-KZFD zaman – frekans gösterimi	76
Şekil 7.9. DKS işaret örüntüsünün DD-KZFD-EH özellik eğrisi	76
Şekil 7.10. DPD-KZFD zaman – frekans gösterimi	77
Şekil 7.11. DKS işaret örüntüsünün DPD-KZFD-EH özellik eğrisi	77
Şekil 7.12. DD-WGS zaman – frekans gösterimi	78
Şekil 7.13. DKS işaret örüntüsünün DD-WGS-EH özellik eğrisi	79
Şekil 7.14. DPD-WGS zaman – frekans gösterimi	80
Şekil 7.15. DKS işaret örüntüsünün DPD-WGS-EH özellik eğrisi	81
Şekil 7.16. DD-MGS zaman – frekans gösterimi	82
Şekil 7.17. DKS işaret örüntüsünün DD-MGS-EH özellik eğrisi	83
Şekil 7.18. DPD-MGS zaman – frekans gösterimi	84
Şekil 7.19. DKS işaret örüntüsünün DPD-MGS-EH özellik eğrisi	85
Şekil 7.20. DD-ARM zaman – frekans gösterimi	86
Şekil 7.21. DKS işaret örüntüsünün DD-ARM-EH özellik eğrisi	86
Şekil 7.22. DPD-ARM zaman – frekans gösterimi	87
Şekil 7.23. DKS işaret örüntüsünün DPD-ARM-EH özellik eğrisi	88
Şekil 7.24. Çok katmanlı ileri beslemeli yapay sinir ağları	89

Şekil 7.25. YSA eğitim başarıml	91
Şekil 7.26. Geliştirilen adaptif yöntemlerin DKS işaretlerine uygulama sistemi	94



TABLÖLAR LİSTESİ

Tablo 7.1. DKS işaretlerinin istatistiksel dağılımı	69
Tablo 7.2. Kullanılan YSA modelinin yapısı ve eğitim parametreleri	91
Tablo 7.3. Geliştirilen özellik çıkarım yöntemlerinin YSA sınıflama başarımlarının karşılaştırılması – I	92
Tablo 7.4. Geliştirilen özellik çıkarım yöntemlerinin YSA sınıflama başarımlarının karşılaştırılması – II	93
Tablo 7.5. DSA modelinin yapısı ve eğitim parametreleri	95
Tablo 7.6. DSA modelinin DKS işaret örüntülerini tanıma başarımları	95
Tablo 7.7. DPSA modelinin yapısı ve eğitim parametreleri	96
Tablo 7.8. DPSA modelinin DKS işaret örüntülerini tanıma başarımları	96



EKLER LİSTESİ

EK-1 : Ses kartının teknik özellikleri

EK-2 : Model 3V2c Doppler ultrason transdüserinin teknik özellikleri



SİMGELER LİSTESİ

x	i) Durağan olmayan işaret, ii) Gerçek giriş uzayındaki gözlemler veya ölçümler
μ_x	İşaretin ortalama değeri
P_x	İşaretin gücü
y	i) Çıkış sınıfları, ii) Karar uzayı
$w^{(k)}$	Karar uzayındaki her bir sınıf
$\underline{D}$	Sınıflandırıcı
F	Giriş ve karar uzayı arasındaki özellik uzayı
(x,y)	Eğitim çifti
$\mathfrak{I}$	Eğitim kümesi
ϕ	Sınıflandırıcının adaptif parametreler kümesi
J	Amaç fonksiyonu
$g(\phi)$	Yan şartlar
$E[.]$	Sınıflandırma hatası
$f(.)$	Yaklaşım fonksiyonu
ξ	Test etme girişleri
ψ	Eğitim girişi
Ω_ψ	İstenen çıkış
$\Delta\phi$	Düzenlenen kurallar
$T[.]$	Eğitimin şartlar kümesi
w_{ij}	Yapay sinir ağı ağırlıkları
$T_x(t,f)$	Zaman – frekans gösterimi
$E(s)$	Entropi ifadesi
ε	i) Entropi eşik değeri, ii) Momentum katsayısı
θ_i	i. işlem elemanının eşik değeri
$a(.)$	Etkinleştirme fonksiyonu
$\psi(t)$	Dalgacık fonksiyonu
m	Dalgacık ayrışım seviyesi
c_A	Dalgacık ayrışımının yaklaşık katsayısı
c_D	Dalgacık ayrışımının detay katsayısı
$h[n]$	Yüksek geçiren filtre

$g[n]$	Düşük geçiren filtre
V	Özellik vektörü
$w[n]$	Pencereleme fonksiyonu
$X(f)$	İşaretin Fourier dönüşümü
$X(k)$	İşaretin kısa zamanlı Fourier dönüşümü
N	Pencere fonksiyonunun nokta sayısı
P_{xx}	Güç spektrumu
U	Pencere fonksiyonunun gücü
K	Güç spektrum yoğunluk fonksiyonlarının sayısı
M	Veri örnek sayısı
S	Ardışık pencerelerinin binişme miktarı
P	MUSIC algoritmasında alt yüzey ayrışım sayısı
R	Oto korelasyon matrisleri
λ_k	Eigen değerleri
V_k	Eigen vektörü
$H(z)$	Transfer fonksiyonu
a_k, b_k	AR model parametreleri
$AR(p)$	p. dereceden AR modeli
σ	Beyaz gürültünün varyansı
$F(.)$	Dalgacık sinir ağı etkinleştirme fonksiyonu
$t_k, 2^k$	Dalgacık fonksiyonunun parametreleri
d	Giriş örüntüsüne karşı istenen çıkış
p	Norm entropi parametresi
sse	Toplam karesel hata
ED	Dalgacık sinir ağının entropi döngüsü
v	Kan akış hızı
f	Transdüser frekans
c	Biyolojik dokudaki işaretin hızı
Δf	Doppler kayması
θ	Transdüser ile kan akışı yönü arasındaki açı
SNR	İşaret gürültü oranı
h_j	Çok katmanlı yapay sinir ağında j. ara katmanın hatası
α	Öğrenme oranı

KISALTMALAR LİSTESİ

ADD	Ayrık Dalgacık Dönüşümü
AR	Otoregresif Model
DD	Dalgacık Dönüşümü
DDA-EH	Dalgacık Dönüşüm Ağacından Entropi Hesaplanması
DD-ARM-EH	Dalgacık Dönüşümü ve AR Modeli ile Entropi Hesaplanması
DD-KZFD-SEH	Dalgacık Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması
DD-MGS-EH	Dalgacık Dönüşümü ve MUSIC Güç Spektrumu ile Entropi Hesaplanması
DD-WGS-EH	Dalgacık Dönüşümü ve Welch Güç Spektrumu ile Entropi Hesaplanması
DDZFGE	Dalgacık Dönüşümü ve Zaman – Frekans Gösterim Entropileri
DKS	Doppler Kalp Ses İşaretleri
DPA	Dalgacık Paket Analizi
DPD	Dalgacık Paket Dönüşümü
DPDA-EH	Dalgacık Paket Dönüşüm Ağacından Entropi Hesaplanması
DPD-ARM-EH	Dalgacık Paket Dönüşümü ve AR Modeli ile Entropi Hesaplanması
DPD-KZFD-SEH	Dalgacık Paket Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması
DPD-MGS-EH	Dalgacık Paket Dönüşümü ve MUSIC Güç Spektrumu ile Entropi Hesaplanması
DPD-WGS-EH	Dalgacık Paket Dönüşümü ve Welch Güç Spektrumu ile Entropi Hesaplanması
DPSA	Dalgacık Paket Sinir Ağı
DSA	Dalgacık Sinir Ağı
EV	Eigen Vektör
FD	Fourier Dönüşümü
GSY	Güç Spektrum Yoğunluğu
HFD	Hızlı Fourier Dönüşümü
KZFD	Kısa Zamanlı Fourier Dönüşümü
MUSIC	Çoklu işaret sınıflama
SDD	Sürekli Dalgacık Dönüşümü
YSA	Yapay Sinir Ağları
ZFG	Zaman Frekans Gösterimi

ÖZET

DOKTORA TEZİ

DURAĞAN OLMAYAN İŞARETLER İÇİN ZAMAN – FREKANS ENTROPİLERİNE DAYALI AKILLI ÖRÜNTÜ TANIMA

İbrahim TÜRKOĞLU

Fırat Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik – Elektronik Mühendisliği Anabilim Dalı

2002, Sayfa: 112

Teknolojinin gelişmesi ile bir çok alanda akıllı tanı sistemleri önem kazanmış ve bu sistemlerin temelini örüntü tanıma oluşturmaktadır. Örüntü tanıma, bilinmeyen örüntü şekillerini belirli bir sınıfa dahil ederek tanımlamak ve bilinen bir sınıfa ait olan örüntüyü teşhis etmektir. Örüntü tanıma, iki önemli aşamadan oluşmaktadır : Özellik çıkarıcı ve sınıflandırıcı. Sınıflandırıcı tasarımında en önemli gösterge doğru özellikleri seçmektir. Başka bir deyişle ileri örüntü tanıma tekniklerinde daha karmaşık sınıflandırıcı tasarlamak yerine, daha iyi özellik çıkarımı ön plandadır. Bu tez çalışmasında da, durağan olmayan işaret örüntüleri için güçlü bir özellik çıkarımı amaçlanmıştır. Bu amaçla, durağan olmayan işaretler için dalgacık dönüşümü, entropi, parametrik ve parametrik olmayan zaman-frekans spektral analiz yöntemlerine dayalı, tümleşik özellik çıkarım metodolojileri geliştirilmiştir. Geliştirilen özellik çıkarım yöntemleri, yapay sinir ağı örüntü sınıflandırıcısının içerisine gömülerek, yeni dalgacık sinir ağ modelleri ile adaptif örüntü tanıma yaklaşımı ortaya konmuştur. Bu yöntemlerin etkinliği ve sağlamlığı, Fırat Tıp Merkezi kardiyoloji kliniğinden temin edilen, Doppler kalp işaretleri üzerinde denenmiştir. Sistemin başarımı, doktor etkenli tanı kararları ile karşılaştırılmış ve yaklaşık olarak %96 doğru tanımlama yüzdesine ulaşılmıştır. Bu yöntem, gerek duyulan biyomedikal, telekomünikasyon ve benzer alanlarda, doğrudan karar verici veya insan faktörünün karar aşamasına yardımcı olacak şekilde, otomatik akıllı tanı sistemlerinin kullanılmasının güvenilirliğini artıracaktır.

Anahtar Kelimeler : Örüntü tanıma, özellik çıkarma, adaptif özellik çıkarma, akıllı tanı sistemi, dalgacık dönüşümü, parametrik modeller, parametrik olmayan modeller, durağan olmayan işaret, Doppler kalp işaretleri, yapay sinir ağları, entropi, dalgacık ağları.

ABSTRACT

PhD Thesis

AN INTELLIGENT PATTERN RECOGNITION FOR NONSTATIONARY SIGNALS BASED ON THE TIME – FREQUENCY ENTROPIES

İbrahim TÜRKOĞLU

Firat University

Graduate School of Natural and Applied Sciences

Department of Electrical - Electronics Engineering

2002, Page: 112


Intelligent recognition systems have gained importance in various areas with the technological developments, and pattern recognition constitutes the bases of this systems. Pattern recognition is to recognize unknown patterns by assigning them into a known class or known patterns belonging to a known class. Pattern recognition includes two steps: Feature extraction and classification. The most important indication is to select the true features. In another word extracting more precise feature is much more important than designing more complex classifier in advanced pattern recognition techniques. In this thesis, a powerful feature extraction was aimed for non-stationary signal patterns. With this aim integrated feature extraction methodologies were developed which depend on wavelet transform, entropy, parametric and non- parametric time-frequency spectral analysis methods for non-stationary signals. By placing the feature extraction methods developed into the artificial neural network pattern classifier, adaptive pattern recognition approach was presented by the new wavelet neural network models. The efficiency and reliability of these methods were examined by using Doppler heart signals from the cardiology clinic of Firat Medicine Center. The success of the system was compared with the doctor-based diagnosis and correct diagnosis about of %96 was achieved. This method will increase the reliability of automatic intelligent diagnosis systems by helping the diagnosis by the practitioner or by directly diagnosing in various fields such as biomedical and telecommunications.

Keywords : Pattern recognition, feature extraction, adaptive feature extraction, intelligent diagnosis system, parametric models, nonparametric models, nonstationary signal, Doppler heart signals, artificial neural networks, entropy, wavelet networks.

BÖLÜM 1

1. GİRİŞ

İnsanların günlük yaşamında, belirli bir sesi veya görüntüyü tanımak için kullandıkları kuralları tanımlamak mümkün değildir. İnsanların pratikte karşılaştıkları bu örüntü tanıma olaylarını, makina tabanlı örüntü tanıma uygulamalarında belirli kriterlere oturtmak mümkündür. Bunun için, örüntülerin bir birinden bağımsız ve belirli karakteristik niteliklerinin elde edilmesi özellik çıkarma süreci ile gerçekleştirilir. Bu özellikler bir sınıflandırıcıya verilerek her bir örüntü belirli sınıflara ayrıştırılıp tanımlama yapılır. Eğer örüntü tanıma sistemi, daha önceden öğrendiklerini tutabilecek bir hafızaya sahip, çıkarım, genelleme ve belirli bir hata toleransı ile karar verebilme yeteneklerini içermekte ise bu sistem akıllı örüntü tanıma sistemi olarak değerlendirilir. Şekil 1.1.de böyle akıllı ve öğrenebilen makinaları gerçekleştirmeye yönelik örüntü tanıma yaklaşımı verilmiştir [1].



Şekil 1.1. Akıllı örüntü tanıma yaklaşımı.


1.1. Amaç

Bu tezin ana amacı, durağan olmayan bir işaretin türleri arasında, akıllı bir örüntü tanıma sistemi ile ayrımı sağlamaya yönelik olarak, zaman – frekans gösterimlerinden kullanılabilir ve etkili özellikler çıkarmak için, dalgacık işaret işleme, çeşitli parametrik ve parametrik olmayan işaret modelleme tekniklerinin üstün taraflarını kullanan ve entropi hesaplama tekniklerine dayalı güçlü ve tümleşik algoritmalar geliştirmektir. Bunun için üç farklı yeni tümleşik özellik çıkarma algoritması önerilmiş ve çıkarılan özelliklerin etkinliği yapay sinir ağ örüntü sınıflandırıcısında test edilmiştir. Tezin ikinci bir amacı da, sınıflayıcının eğitim durumuna göre ayarlanabilir bir özellik çıkarma yapısını sağlamaya yönelik, entropi tabanlı yeni dalgacık sinir ağ modelleri geliştirerek daha etkin, adaptif bir örüntü tanıma sistemi ortaya koymaktır. Ayrıca durağan olmayan işaretler için bir ön işlem yordamı önerilerek işaret, örüntü tanıma sisteminin

girişine verilmeye uygun hale getirmektir. Önerilen bu algoritmalar durağan olmayan gerçek ve bireşimsel Doppler kalp kapak işaretleri üzerinde, deneysel bazda geniş çaplı sınıflama ile değerlendirilmiştir.

1.2. Durağan Olmayan İşaretler

İşaret, fiziksel dünyadan elde edilen büyüklüklerin zamanın bir fonksiyonu olarak tanımlanmasıdır [2]. Eğer bir işaretin genliği zamanla değişmesine rağmen işaretin istatistiksel karakteristikleri (frekans, güç, ortalama değeri, vb.) değişmiyorsa işaret durağandır, aksi durumda durağan değildir. Şekil 1.2. de durağan ve durağan olmayan işaret örnekleri görülmektedir [3].



Şekil 1.2. İşaret örnekleri : a) Durağan, b) Durağan olmayan işaret

Durağan işaretlerin istatistiksel bilgileri zamanın tüm noktalarında aynıdır. Bir başka deyişle $x(t)$ ve $x(t-t_0)$ işaretinin istatistiki özellikleri aynıdır [4]. Durağan olmayan işaretlerde ise bu özellikler zaman ile değişim sergilemektedir [5]. Aşağıdaki örnekte bu durum vurgulanmıştır:

Örnek: $A \sin wt$ durağan bir işaret ve $Ae^{-\alpha t}$ ise durağan olmayan bir işarettir. Her iki işaretin zaman değişimine göre parametrelerine bakılırsa;

Sinüzoidal işaretin ortalama değeri ve gücü:

$$\text{Ortalama}(A \sin wt) = \frac{1}{T} \int_0^T A \sin wt \cdot dt = 0 \quad (1.1)$$

$$\text{Güç}(A \sin wt) = \frac{1}{T} \int_0^T A^2 \cdot \sin^2 wt \cdot dt = \frac{A^2}{2} \quad (1.2)$$

sabittir. Burada T sinüs dalgasının periyodudur. Durağan olmayan işaretin ortalama değeri ve gücü :

$$\text{Ortalama}(Ae^{-\alpha t}) = \frac{1}{T} \int_t^{t+T} A.e^{-\alpha \tau} d\tau = \frac{A}{\alpha T} (1 - e^{-\alpha T}) e^{-\alpha t} \quad (1.3)$$

$$\text{Güç}(Ae^{-\alpha t}) = \frac{1}{T} \int_t^{t+T} A^2 .e^{-2\alpha \tau} d\tau = \frac{A^2}{2\alpha T} (1 - e^{-2\alpha T}) .e^{-2\alpha t} \quad (1.4)$$

zamanla değişir.

Durağan olmayan işaretlere, çok yaygın sahalarda rastlamak mümkündür: Telekomünikasyon, biyomedikal, sistem teorisi, makina kontrol, güç sistemleri, denizbilimi, sismoloji, akustik, vb., [6]. Ayrıca meteoroloji ve finanssal verileri de bu grupta düşünmek mümkündür. Durağan olmayan işaretlere belirli örnekler vermek gerekirse:

Telekomünikasyon sahasında; iletim kanallarının veri trafik yoğunlukları [7], video işareti, ses işareti [3], radar doppler işaretleri [8], çok kanallı iletişim ve modülasyon tertipleri [9] gibi.

Biyomedikal alanda; EEG - Elektroensefalogram [10], ME - Myoelektrik [11], MEG – Magnetoencefalografik [12], VAG – Vibroarthrografik [13], HRV – Kalp atış değişkenliği [14], EGG – Elektrogastrogram [15], Femoral Arter Doppler işaretleri [16], EKG – Elektrokardiyogram [17], EMG – Elektromyogram [18], Doppler kalp işaretleri [19-22] gösterilebilir.

1.3. Yönelim Gerekçeleri

Bu tez çalışmasının hareket noktası günümüzde bir çok mühendislik uygulamasının akıllı sistemlere yönelmesinden gelmektedir. Herhangi bir akıllı örüntü tanıma sisteminin en önemli bileşeni özellik çıkarmadır. Özellik çıkarma, sınıflandırıcının başarımına önemli oranda katkıda bulunur ve örüntü verisinin belirli karakteristik özelliklerini çıkararak boyutunda indirgeme yapar. Çok karmaşık sınıflandırıcı yapısını tasarlamak yerine örüntüler arasındaki ayrımı sağlayacak anahtar özellikleri belirlemek, günümüz örüntü tanıma sistemlerinin odağı haline gelmiştir. Çünkü uygun özellik çıkarımı yapılmadığı takdirde, sınıflandırıcı ne kadar iyi tasarlanırsa tasarlansın başarımı yine çıkarılan özellik uzayına bağlı kalacaktır [23].

Akıllı örüntü tanıma sistemleri öğrenme tabanlı olup, öğrendiklerinden çıkarım yaparak karar verebilmektedirler. Bu özelliklerinden dolayı bir çok alanda potansiyel uygulama alanına adaydırlar. Örneğin; tıbbi teşhis destek ve kontrol sistemleri [24], farklı modülasyon türlerini algılayıp çözebilen ve özellikle askeri alandaki haberleşme güvenliğinde etkin olabilecek akıllı modülasyon tanıma sistemleri [25], çeşitli tanıma uygulamaları [26], güvenlik sistemleri [27]. Bununla birlikte bu alanlarda çalışmalar başlangıç aşamasında olup henüz etkili algoritmalar

geliştirilememiştir. Bu sebeple, tezde önerilen algoritmalar akıllı örüntü tanıma girişimlerine katkıda bulunacaktır.

Örüntü tanıma çalışmalarının bir amacında insan-makina arabirimini iyileştirmeye yöneliktir. Bu amaçla, olayların tanımlanması ve sağlıklı bir biçimde yorumlanabilmesi ana ilgi sahası olmuştur. Ticari dünyadaki bu teknolojinin pratik uygulamaları, bu alandaki araştırmalara destek sağlamaktadır.

Durağan olmayan işaret örüntülerinin özellik çıkarımı, bu alandaki örüntü tanıma sistemlerinin en önemli bileşeni haline gelmiştir. Tez çalışmasının odağı da bu yöndedir. İşaretin betimleyici özellikleri, sadece zaman bölgesindense, zaman ve frekans bölgelerinin ortak gösterimlerinden elde edilmesi daha sağlam yapı sunar [28].

Durağan işaretlerin zamanla istatistiksel özellikleri değişmediğinden (örneğin işaretin taşıyıcı frekans karakteristikleri) analizi için hızlı nümerik metotlar kullanmak mümkündür [9]. Fourier dönüşüm tabanlı olan bu yöntemler temel bir fonksiyon ile işaretin ayrışımı üzerine çalışırlar. Fourier dönüşümü düşük zaman saptamasından dolayı durağan olmayan işaretlerde tercih edilmez. Çünkü işaretin geçici ve uzamsal (şekilsel) değişimlerini saptayamaz [29]. Bunun için durağan olmayan işaretlerin analizine yönelik olarak literatürde sıkça geçen KZFD, AR, MUSIC, Welch gibi spektral analiz yöntemleri kullanılarak durağan olmayan işaret, zaman üzerinde durağan bölümlere ayrılarak spektral karakteristikleri tahmin edilir [30]. Bu klasik ve modern spektral analiz yöntemleri, bir başka deyişle parametrik ve parametrik olmayan metotlar, durağan olmayan işareti durağan kabul edildiği bölümlere ayırarak analiz yaptıklarından bu yaklaşık bir analizdir. Durağan olmayan işaretlerin anlık parametreleri zamanla değişmesine rağmen, durağan kabul edildiği belirli aralıklarda bu parametrelerin sabit olduğu varsayımı yapılmaktadır [6]. Aşağıdaki örnekte bu durum açıklanmıştır :

Örnek : $x(m)$ durağan olmayan bir işaret olup, mevcut yöntemlerle işaret parça parça durağanlaştırılmaktadır. Şöyle ki;

$$y(m) = \overline{s(m)} \cdot x_0(m) + s(m) \cdot x_1(m) \quad (1.5)$$

Burada $s(m)$ ikili bir değişkendir. Yani;

$$y(m) = \begin{cases} x_0(m) & s(m) = 0 \\ x_1(m) & s(m) = 1 \end{cases} \quad (1.6)$$

$x_0(m)$ işaretinin ortalama değeri μ_{x_0} , gücü P_{x_0} ve $x_1(m)$ işaretinin ortalama değeri μ_{x_1} , gücü P_{x_1} ile gösterilirse, bu durumda verilen $s(m)$ göre $y(m)$ 'in beklenen ortalama değeri ve gücü:

$$E[y(m)|s(m)] = \overline{s(m)} \cdot E[x_0(m)] + s(m) \cdot E[x_1(m)] = \overline{s(m)} \cdot \mu_{x_0} + s(m) \cdot \mu_{x_1} \quad (1.7)$$

$$E[y^2(m)|s(m)] = \overline{s(m)} \cdot E[x_0^2(m)] + s(m) \cdot E[x_1^2(m)] = \overline{s(m)} \cdot P_{x_0} + s(m) \cdot P_{x_1} \quad (1.8)$$

şeklinde tahmin edilmektedir. Görüleceği üzere işaret durağan olmamasına rağmen durağanlık kavramı analiz için önemli rol oynamaktadır.

Örüntü tanımada, durağan olmayan işaretlerin bilinmeyen karakteristikleri işaretin doğru bir şekilde ve yüksek başarımla tanınmasında önemli rol oynar [9]. Bu açıdan işaretin hem geçici ve hem de frekans değişim bilgilerini içeren zaman-frekans gösterimleri işaretin tanımlayıcı özellik seçiminde etkilidir [31,32].

Dalgacık dönüşümleri günümüzde bir çok mühendislik uygulamasında durağan ve durağan olmayan süreçlerin zaman-frekans gösterimlerinde en başarılı sonuçları veren kullanışlı ve güçlü bir araçtır [33]. Fourier dönüşümlerinin aksine, işaretin zamana bağımlı frekans değişim karakteristiklerini ölçmede güvenilirlikleri, durağan olmayan işaretlerin yapılarına uygun bir analiz şekli olduklarını göstermektedir [21,22]. Çünkü, dalgacık dönüşümleri işaretin farklı bölümlerini analiz etmek için odağı ayarlanabilir bir matematik mikroskobu gibi davranabilmektedirler. Bu yapısı ile dalgacık dönüşümleri diğer yöntemlere alternatif bir yaklaşım olarak görülmektedir [34,35].

Bu tez çalışmasında da, dalgacık dönüşümleri ile durağan olmayan işaret alt bileşenlerine ayrılarak durağan hale getirilmekte, böylece elde edilen durağan işaret bileşenlerine mevcut spektral analiz metodları uygulanarak sistemdeki iç ve dış dinamiklere karşı daha dayanıklı özellik çıkarılması amaçlanmıştır. Bu önerilen yeni yaklaşım mevcut spektral analiz yöntemlerinin frekans kestirimi ve seçiciliği üstünlüklerini kullandığından [36-38] çalışmalarına göre daha etkin özellik uzayının oluşmasına neden olmuştur. Önerilen özellik çıkarma algoritması, Zaman-Frekans Gösterim (ZFG) 'lerinden elde edilen spektrum özelliklerini daha sağlam yapıya hale getirmek ve özellik uzayının boyutunu indirgemeye yönelik olarak, spektrumun düzensizlik miktarını ölçmek için ideal bir araç olan entropi tabanlı kriterler kullanılarak etkinlikleri artırılmıştır. Böylelikle, geliştirilen tümleşik özellik çıkarma süreci ile elde edilen özelliklerin kararlı yapıları ve boyutunun indirgenmiş olmasından dolayı, sınıflandırıcı aşamasının işini büyük oranda kolay kılmakta ve hızlı karar vermesine yardımcı olmaktadır.

Örüntü tanımanın ikinci aşaması olarak kullanılan yapay sinir ağ örüntü sınıflandırıcıları, insan biyolojik nöron hücresinden esinlenerek ortaya konmuş bir matematiksel modeldir. Bu model paralel işleme yapılarından dolayı hızlı sonuç üretme, öğrenebilme ve öğrendiklerinden genelleme yapabilme yeteneklerine sahiptir. Bu üstünlüklerinden dolayı akıllı örüntü tanıma sistemlerinde başarılı bir şekilde ve yaygın olarak kullanılmaktadırlar. Bu gerekçeden ötürü, tez çalışmasında örüntü sınıflayıcısı olarak tercih edilmiştir.

Adaptif özellik çıkarımı, durağan olmayan işaretlerde olduğu gibi dinamik davranış sergileyen sistemler için, oldukça etkindir. Bu bağlamda yukarıda önerilen özellik çıkarım algoritması, yapay sinir ağının içerisine gömülerek, dalgacık sinir ağ model temelli, yeni adaptif bir örüntü tanıma sistemleri geliştirilmiştir.

1.4. Tezin Organizasyonu ve Orijinal Katkıları

Tezin birinci bölümünde, teze genel bir bakış açısı kazanmaya yönelik olarak temel bilgiler verilmiştir. Diğer bölümlerin organizasyonu ve tezdeki orijinal katkılar ise aşağıda sunulmuştur:

Bölüm 2 de, örüntü tanıma kavramı tanımlanarak, sahip olduğu her bir bileşeni açıklanmıştır. Örüntü tanıma problemi bir matematiksel olay olarak nitelendirilerek yorumlanmıştır. Örüntü tanıma türleri verilerek, özellikle akıllı örüntü tanıma yapısı üzerinde durulmuş ve sahip olması gereken özellikler vurgulanmıştır. Örüntü tanımanın en önemli bileşeni olan ve bu tezde de odaklanılan özellik çıkarımı için önerilen yeni algoritmaların dayalı olduğu teorik alt yapıyı oluşturmaya yönelik zaman-frekans gösterimleri ve türleri, entropi hesaplama teknikleri açıklanmıştır. Örüntü tanımanın ikinci aşaması için kullanılan yapay sinir ağ sınıflandırıcıları sistematik bir gösterimle verilmiştir. Böylece, bu bölümü okuyan kişinin, sonraki bölümlerde geliştirilen algoritmaları daha rahat anlayabilmesi amaçlanmıştır.

Bölüm 3 de, önerilen özellik çıkarma algoritmalarının ilki olan, dalgacık dönüşüm zaman – frekans gösterim entropilerine (DDZFGE) dayalı yöntem açıklanmıştır. Bu yöntem için gerekli olan dalgacık ve dalgacık paket analizi hakkında teorik bilgiler bulunmaktadır. Geliştirilen DDZFGE özellik çıkarma algoritmasının, dalgacık dönüşüm ve dalgacık paket dönüşüm tabanlı olmak üzere iki farklı varyasyonu sunulmuştur.

Bölüm 4 de, dalgacık dönüşüm zaman – frekans gösterimlerinden elde edilen her bir işaret bileşenine parametrik olmayan spektral analiz için KZFD, Welch ve MUSIC analiz yöntemleri uygulanarak, elde edilen işaret sonogramının her bir spektrum bileşeninin entropileri

hesaplanarak özellik çıkarımı yapılmıştır. Böylece farklı varyasyonlarda altı adet yeni özellik çıkarım yöntemi geliştirilmiştir. Bu yöntemler için gerekli olan teorik bilgiyi de içermektedir.

Bölüm 5 de, dalgacık dönüşüm zaman – frekans gösterimlerinden elde edilen her bir işaret bileşenine parametrik spektral analiz için AR analiz yöntemleri uygulanarak, elde edilen işaret sonogramının her bir güç spektrum bileşeninin entropileri hesaplanarak özellik çıkarımı yapılmıştır. Böylece, yine farklı varyasyonlarda iki adet yeni özellik çıkarım yöntemi geliştirilmiştir. Ayrıca bu bölümde, önerilen yöntemler için gerekli olan teorik bilgi de sunulmuştur.

Bölüm 6 de, tezin ikinci amacı olan adaptif özellik çıkarımı için, dalgacık sinir ağı tabanlı yeni bir yöntem verilmiştir. Bu yöntem sınıflandırıcının öğrenebilme yeteneğine bakarak özellik çıkarımını uyarlayabilmektedir. Böylece, örüntü tanımanın özellik çıkarım süreci sınıflandırıcı bileşeninin içerisine gömülmüştür. Geliştirilen yöntemin dalgacık dönüşüm türlerine bağlı olarak iki farklı türü verilmiştir.

Bölüm 7 de, tez çalışmasında geliştirilmiş olan algoritmaların uygulaması, durağan olmayan bir işaret olan, gerçek Doppler kalp işaretleri üzerinde yapılmıştır. Ayrıca gerçek dünyadan alınan bu Doppler kalp işaretlerindeki istenilmeyen bileşenlerin ayıklanması ve örüntü tanıma sisteminin girişine uygun bir veri yapısı şeklinde sunulabilmek için önerilen bir ön işlem sırası ve metodolojisi açıklanmıştır. Akıllı örüntü tanıma sisteminde kullanılan, Yapay Sinir Ağı (YSA) modeli ve bileşenlerinin önemi açıklanmıştır. Geliştirilen algoritmaların uygulama sonuçları toplu olarak değerlendirilmiş ve her bir algoritmanın başarımı karşılaştırmalı olarak verilmiştir.

Bölüm 8 de, tezin sonuçları irdelenmiş ve orijinal katkıları vurgulanmıştır. Ayrıca ileriye dönük uygulama alanları ve öneriler tartışılmıştır.

Bu tez çalışması, Fırat Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından FÜBAP-527 nolu proje ile desteklenmiştir.

BÖLÜM 2

2. ÖRÜNTÜ TANIMA


Örüntü, ilgilenilen varlıklar ile ilgili gözlenebilir veya ölçülebilir bilgilere verilen addır. Gerçek dünyadaki bu örüntüler, genellikle ilgilenilen verilerin nicel tanımlama şekilleridir [39]. Örüntü tanıma, insanların çeşitli ses, görüntü ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel şekillendirir. Aslında, örüntü tanıma bilimin, mühendisliğin ve günlük hayatın geniş bir alanındaki etkinlikleri kapsamaktadır. Örüntü tanıma uygulamalarını insanların yaşantısında da görebiliriz: hava değişimin algılanması, binlerce çiçek, bitki, hayvan türünü tanımlama, kitap okuma, yüz ve ses tanıma gibi bulanık sınırlara sahip bir çok etkinlikte örüntü tanıma kullanılır. İnsan örüntü tanınması, geçmiş tecrübelerle dayalı öğrenme esastır. Böylece, insanlar pratikte karşılaştığı örüntü tanıma olaylarını tecrübeleri ışığında değerlendirebilme yeteneğine sahiptirler. Belirli bir sesi tanımak için kullanılan kuralları tanımlamak mümkün değildir. İnsanlar bu işlemlerin bir çoğunu oldukça iyi yapmalarına rağmen, bu işlemleri daha ucuz, iyi, hızlı ve otomatik olarak makinaların yapmasını arzularlar. Örüntü tanıma, böyle akıllı ve öğrenebilen makinaları gerçekleştirmek için, çok boyutlu bir mühendislik disiplindir [1].

Örüntü tanıma olayını şu şekilde irdeleyebiliriz: Aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen karmaşık işaret örneklerini veya nesneleri bazı tespit edilmiş özellikler veya karakterler vasıtası ile tanımlama veya sınıflandırmadır [40]. Bu bağlamda, örüntü tanımanın en önemli amaçları; bilinmeyen örüntü sınıflarına belirli bir şekil vermek ve bilinen bir sınıfa ait olan örüntüyü teşhis etmektir.

Örüntü tanıma tekniklerinin uygulamaları bir çok mühendislik, tıp, askeri ve bilim alanına açıktır. Bunlardan bazıları; ses tanıma [41], EEG sınıflama [42], DTMF haberleşme işaretlerini tanıma [43] ve radar hedef sınıflama [43], biyomedikal kontrol [45] verilebilir. Örüntü tanıma olarak bilinen bu uygulamalar, makina öğrenmesi, örüntü sınıflandırma, ayırım analizi ve nitelik tahmini gibi isimlerle de anılmaktadır [40]. Örüntü tanıma kavramı, Şekil 2.1. de gösterildiği gibi üç önemli birimden oluşmaktadır [46]:

1. İşaret / Görüntü İşleme : Ön işlem aşamasıdır. İşaret veya görüntünün filtre edildiği, çeşitli dönüşüm ve gösterim teknikleri ile işlendiği, bileşenlerine ayrıldığı veya modellendiği kısımdır.
2. Özellik Çıkarma: İşaret ve görüntünün veri boyutunun indirildiği ve tanımlayıcı anahtar özelliklerinin tespit edildiği ve aynı zamanda normalizasyona tabii tutulduğu aşamadır. Sistemin başarımında en etkili rolü oynar.

3. Sınıflandırma: Çıkarılan özellik kümesinin indirgendliği ve formüle edildiği tanımlayıcı karar aşamasıdır.




Şekil 2.1. Örüntü tanıma kavramı.

2.1. Örüntü Tanıma Probleminin Formülasyonu

Örüntü tanıma probleminin şekilsel amacı, gerçek giriş uzayındaki M adet $\{x_i\}_{i=1}^M$, $x \in X \subset \mathcal{R}^M$ gözlemleri veya ölçümleri, birkaç sınıftan $y \in Y \equiv \{w^{(1)}, w^{(2)}, \dots, w^{(K)}\}$ birine ayırmak suretiyle tanımlayabilmektir. Sınıfsal çıkış, karar uzayındaki her bir $w^{(k)}$ sınıfı temsil etmektedir. $\underline{D}$ operatörü Şekil 2.2. de bir harita olarak gösterilen, her bir ayrıma bir sınıf etiketi atayarak giriş uzayının ayrı bölümlere ayrılmasını sağlayan bir sınıflandırıcıyı veya giriş uzayını birbirini ile kesişmeyen bölümlere ayırarak her bir sınıfa bir etiket atayıcıyı göstermektedir ($\underline{D} : x \rightarrow y$) [28].

İşaret uzaylarını sınıflamada, işaret örüntüsünün boyutunun çok fazla olması ve gürültü gibi birkaç engelleyici unsur vardır. Bu problemlerden kurtulmak için işareten özellik çıkarımı yapılır. Böylece elde edilen özellik uzayı, giriş işaret uzayı ve çıkış karar uzayı arasında $F \subset \mathcal{R}^N$ olarak betimlenir ($N \leq M$). Bir özellik çıkarıcı $f : X \rightarrow F$ olarak tanımlanır ve sınıflandırıcı ise $g : F \rightarrow Y$ şeklinde verilir. Böylelikle sınıflandırma süreci $d = g \circ f$ olarak gösterilebilir [47].



Şekil 2.2. Karar yüzeyinin özellik uzayının haritası olarak gösterimi.


Örüntü tanıma sistemine öğrenme yeteneğinin kazandırılabilmesi için genellikle P adet giriş işareti ve çıkış sınıf etiketi içeren (x,y) eğitim çiftinden oluşan $\mathcal{T}$ eğitim kümesi kullanılır.

$$\mathcal{T} = \left\{ \left(x^{(1)}, y^{(1)} \right), \left(x^{(2)}, y^{(2)} \right), \dots, \left(x^{(P)}, y^{(P)} \right) \right\} \quad (2.1)$$

Burada ⁽ⁱ⁾ ifadesi eğitim kümesi içindeki i . örüntü – sınıf çiftini göstermektedir.

2.2. Örüntü Tanıma Sistemleri

Örüntü tanıma sistemleri gözlenen veya ölçülen verileri tanımlanmasında bir çok uygulamanın merkezinde yer alır. Şekil 2.3 de yaygın olarak kullanılan genel anlamda örüntü tanıma sistemi verilmiştir [40,48]. Algılayıcılar, herhangi bir anda mümkün olan birçok doğal durumlardan biri olabilen bazı fiziksel işlemleri ölçerler. Aşağıdaki blok diyagramın en önemli görevlerinden biride, elde edilen ölçümlerin hepsinden oluşan giriş uzayından daha az boyutta özellik çıkartmaktır. Sonunda, sınıflandırıcının rolü örüntüyü özelliklerine göre kategorize ederek uygun sınıflara kaydetmektir.



Şekil 2.3. Örüntü tanıma sistemi.

Mevcut örüntü tanıma sistemleri üç grupta toplanmaktadır [49] :

1. İstatistiksel örüntü tanıma : İstatistiksel örüntü tanıma yönteminde, sınıflama algoritmaları istatistiksel analiz üzerine kurulmuştur. Aynı sınıfa ait örüntüler, istatistiksel olarak tanımlanan benzer karakteristiklere sahiptirler. Bu yöntemde, özellik olarak nitelendirilen karakteristik ölçümler giriş örüntü örneklerinden çıkarılır. Her örüntü bir özellik vektörü ile tanımlanır. Genelde sınıflandırıcıyı oluşturan karar ve sınıflandırma yöntemleri üzerinde önemle durulur. Sınıflandırıcı tasarımı, ölçümler ve olasılıklar gibi işlenebilir örüntü bilgilerini birleştirmeyi esas alır. Böylece sınıflama, giriş veri uzayının olasılık yoğunluk fonksiyonlarının tahmini üzerine kurulu bir istatistiksel yapıdır [23]. İstatistiksel örüntü tanıma Bayes Karar Teorisi üzerine kurulmuş olup, uzun bir geçmişe sahiptirler. Bu konu hakkında detaylı bilgi [40] da görülebilir.

2.Yapısal örüntü tanıma : Yapısal (geometrik, kural dizilim) örüntü tanıma yaklaşımının da, verilen bir örüntü, şekilsel yapıdan temel karakteristik tanımlanmaya indirgenir. Çoğu zaman, örüntülerden çıkarılan bilgi yalnızca özellikler kümesinin sayısal değerlerinden değildir. Özelliklerin birbirine bağlanması veya aralarındaki karşılıklı ilişki, tanımlamayı ve sınıflandırmayı kolaylaştıran önemli yapısal bilgiye sahiptir. Bir başka deyişle örüntünün işlenmemiş halinden elde edilen tanımlayıcı biçimsel sentaks veya bunların sentezinden çıkarılan gramer ile tanımlama gerçekleşir. Örneğin, örüntünün köşe sayısı, kenar açıları vb. Genel olarak yapısal yöntemde daha basit alt örüntüler karışık örüntülerin hiyerarşik tanımlamalarını formüle eder. Yapısal yöntemde her örüntü, bileşenlerinin bir kompozisyonu olarak ele alınır [50].

Yapısal örüntü tanıma yönteminde çeşitli birimler arasındaki ilişki çok büyük önem taşır ve gerçek tanımda kullanılan bazı şekilsel notasyonlar tarafından belirtilir. Örneğin, ekrandaki bir masayı tanıma, “köşelerinden eşit uzunlukta bacaklar tarafından desteklenen yatay bir dikdörtgen yüzey” gibi yapısal tanımlamayı temel alarak gerçekleştirilebilir. Bu yöntemde, çevre uzunluğu, alan, ağırlık merkezi, eylemsizlik momenti ve Fourier tanımlayıcıları gibi genel özellikleri kullanır. Otoregresif model, poligonlar yaklaşımı ve zincir kodları yapısal örüntü tanıma yöntemine örnek olarak verilebilir [51].

3. Akıllı örüntü tanıma : Akıllı örüntü tanıma yaklaşımları, öğrenme tabanlı olup, karar aşamasında geçmiş tecrübelerinden sonuç üretmektedirler. Günümüzde, öğrenmeli örüntü tanıma algoritmaları yapay sinir ağı merkezli olarak gelişmektedir ve bu doğrultuda çalışmalar yoğunluktadır [41,52,53]. YSA yaklaşımları istatistik yaklaşımına karşı belirleyici olarak ifade edilebilir. Çünkü öğrenme algoritmaları örüntü sınıflarının istatistiksel özellikleri hakkında

hiçbir şey kullanmamaktadır. Bununla birlikte, istatistiksel ve YSA örüntü tanıma yaklaşımları şekil ve amaç olarak çok benzer olup, hatta YSA 'nın geleneksel istatistiksel örüntü tanımının bir uzantısı olarak ifade edilen görüşlerde bulunmaktadır [23].

İstatistiksel, yapısal ve yapay sinir ağları ile örüntü tanıma yaklaşımları arasında kesin bir ayrım yoktur. Bunlar arasındaki sınırlar bulanıklık arz eder. Bu yaklaşımlar, genel ve ortak özellikleri ve amaçları paylaşırlar. Verilen belirli bir örüntü tanıma probleminin çözümünde istatistiksel yaklaşıma göre örüntünün yapısı anlamsız olabilir. Yapı ancak uygun özellik seçimiyle yansıtılabilir. İstatistiksel örüntü tanımada; yapısal bilginin ifade edilmesinde görülen zorluk, yapısal örüntü tanımada kendini yapısal kuralların öğrenilmesinde gösterir. Buna karşın yapay sinir ağı yaklaşımı, istatistiksel ve yapısal yaklaşımlardan türetilmiştir. Açık bir şekilde örüntü hakkındaki yapısal bilgi değerli olduğunda yapısal örüntü tanıma yaklaşımını seçmek daha doğrudur. Yapısal bilgi değersiz ve maksada uygun değilse istatistiksel yöntemi seçmek daha doğrudur. Yapay sinir ağları, istatistiksel ve yapısal yaklaşıma alternatif teknikler sağlayan ve örüntü tanımaya öğrenme boyutu katarak akıllı tanıma niteliği kazandıran bir teknik olarak düşünülebilir [54].

Öğrenmeli örüntü tanıma sistemlerinin başlıca iki amacı vardır:

- Bir sınıflandırılacak verinin bazı yapı ve organizasyonunu birleştirmek.
- Yeni veri için önceden bilinen sonuçlardan eğitilmiş sınıflandırıcıyı kullanmak.

Burada, öğrenme olayı sınıflandırıcıyı (tahmin ediciyi) ilgilendirir. Akıllı örüntü tanıma sistemlerinde, sınıflandırıcının parametreleri bir karar kuralına göre ardışık işlemlerle uyarlanarak öğrenme işlemi gerçekleştirilir. Sınıflandırıcı "*en iyinin ölçüsü*" ile değerlendirilir. Sınıflandırıcının "*en iyinin ölçüsü*" ne uyarlanma işlemlerine, kabul edilebilir sınırlar içinde devam edilebilir. Daha geniş anlamda, sınıflandırıcının öğrenmesi bir çıkış kümesi ile bir giriş kümesinden meydana gelir. Veri kümeleri iki parçaya ayrılır; eğitim verisi ve test etme verisi. Öncelikle öğrenme işlemi gerçekleştirilir sonra sınıflandırıcının bir yetenek göstergesi olarak yeni bilgi ele alınarak test etme sürecine geçilir.

Problemin matematiksel formülasyonu için; bazı değişkenleri tanımlamak gereklidir:

$\phi \in \mathcal{R}^n$ modelin n değişkenli parametreleri veya karakteristikleri

$J(\phi, \psi, \Omega_\psi) \in M$ "*en iyinin ölçüsü*", amaç fonksiyonu veya fonksiyon ölçütü,

M fonksiyonların uzayı $M : \mathcal{R}^n \times \mathcal{R}^{m \times N} \times \mathcal{R}^{s \times N} \rightarrow \mathcal{R}$

$\psi \in \mathcal{R}^{m \times N}$	eğitme verisindeki bağımsız değişken, $\psi = \{\psi_i \in \mathcal{R}^m, i = 1 \dots N\}$
$\Omega_\psi \in \mathcal{R}^{s \times N}$	eğitme verisindeki bağımlı değişken, $\Omega_\psi = \{\omega_{\psi_i} \in \mathcal{R}^s, i = 1 \dots N\}$
N	eğitme verisindeki örneklerin sayısı
$g(\phi)$	m tane yan şart $g(\phi) = \{g_i(\phi) \mathcal{R}^n \rightarrow \mathcal{R}, i = 1 \dots m\}$
$\xi \in \mathcal{R}^{m \times N}$	test verisindeki bağımsız değişken $\xi = \{\xi_i \in \mathcal{R}^m, i = 1 \dots N\}$
$\Omega_\xi \in \mathcal{R}^{s \times N}$	test verisindeki bağımlı değişken $\Omega_\xi = \{\omega_{\xi_i} \in \mathcal{R}^s, i = 1 \dots N\}$
$f(\phi, v \in \mathcal{R}^m)$	sınıflandırıcı eşlemesi $f(\cdot): \mathcal{R}^n \times \mathcal{R}^m \rightarrow \mathcal{R}^s$
$E[\Omega_\xi, f]$	test verisinin sınıflandırılmasındaki hata $E[\cdot]: \mathcal{R}^s \times \mathcal{R}^s \rightarrow \mathcal{R}$

Bir giriş/çıkış eşlemesiyle sınıflandırıcının yorumunda tutarlılık olacak şekilde, bağımsız değişkenler giriş ve bağımlı kopyası ise çıkış olarak genelde adlandırılır. Burada tek gereksinim, $f(\phi, v \in \mathcal{R}^m)$ ile sınıflandırılan, ya bire bir veya birçoğundan birine eşlemektir. Bu nedenle, $f(\phi, v \in \mathcal{R}^m)$ den yaklaştırma fonksiyonu olarak da söz edilir.


Öğrenme süreci, J amaç fonksiyonuna uyan ψ girişlerinden Ω_ψ çıkışlarını elde edebilen, $f(\phi, v \in \mathcal{R}^m)$ en iyi yaklaşım fonksiyonunu elde etmek için, her hangi bir $g(\phi)$ yan şartını sağlayan bir ϕ parametre kümesi bulma çalışmalarını ihtiva eder. Yani:

$$g(\phi) \geq 0 \text{ koşulu ile } J(\phi, \psi, \Omega_\psi) \text{ fonksiyonunu minimize eden } \phi \text{ 'yi bul.}$$


Bu serbest parametrelerin istenilen şekilde ardışık olarak ayarlayıp belirlemek için bir matematiksel optimizasyon algoritması seçmek zorunludur. Ayrıca istenilen $T[\phi, J(\phi, \psi, \Omega_\psi)] < \varepsilon$ biçimi bir veya daha çok bitirme şartıdır. Burada, T birbirini izleyen ardışık değerlendirmelerin tipiksel olarak bir norm ölçüsüdür ve ε ise tavsiye edilen toleranstır.

Eğitme veya öğrenme bittikten sonra, sınıflandırıcı bir veri kümesi (ξ, Ω_ξ) üzerinden test edilir. Seçilen hata ölçüsü $E[\cdot]$ göre, yeni ξ verisi için önceden hesaplanan sonucun $f(\cdot)$ ile sınıflandırılması iyi bir başarıım göstergesidir. $E[\cdot]$ anlamlı bir uzaklık ölçüsü olabilir veya

sınıflandırma senaryosunda karar kuralı ve hata oranını yaklaştırmak için bir sayma işlemi de olabilir. Süreçlerin tanımlanması Şekil 2.4. ve 2.5. 'de özetlenmiştir.



Şekil 2.4 Öğrenme süreci.



Şekil 2.5. Sınıflandırıcının test edilme süreci.

Yukarıda varsayılan formülasyonda veri kümeleri o şekilde tanımlanır ki her bir ψ için Ω_ψ uygunluğu olur. Bu koşullar altındaki öğrenme eğitici öğrenme olarak adlandırılır. Eğitici öğrenme olarak bilinen durumda ise Ω_ψ giriş den bağımsız olarak tanımlanır ve öğrenme süreci daha zordur.

Eğitici öğrenmede, dışarıdan bir eğitici müdahalesi söz konusudur. Eğitici, sisteme ilgili girdi için üretmesi gereken sonucu verir. Yani sınıflandırıcı sisteme girdi/çıkış ikilisinden oluşan örnekler sunulur. Bu ikili, sistemin öğrenmesi gereken özellikleri temsil eder. Eğitici öğrenmede ise, hiç bir eğiticiye ihtiyaç yoktur. Bu nedenle çoğu zaman buna, kendi kendine organize olma da denilmektedir. Tahmin edici, kendine gösterilen örnekleri alır ve belli bir kritere göre sınıflandırır. Bu kriter önceden bilinmeyebilir. Sistem, kendi öğrenme kriterlerini kendisi oluşturmaktadır [55].

Eğitici ve Eğitici olmayan öğrenme türleri bazen birbirini destekleyici olarak kullanılırlar. Eğitici tür ile özellik uzayı kümelendir. Bu kümeler eğitici tür için bilinen yapı olarak eğitim kümesinde kullanılabilir. Böylece özellik uzayının boyutu azaltılır. Fakat bu işlemler zaman aldığından gerçek zaman uygulamaları için zor ve pahalıdır.

2.3. Özellik Çıkarma

Özellik çıkarma örüntü tanımanın en önemli kısmı olup, bir anlamda örüntü tanıma sisteminin başarımında anahtar rolü oynar [1]. Örüntü sınıfları arasında ayrımı gerçekleştirmek için örüntü özelliklerinin çıkarılması gerekir. Günümüzde, çok başarılı sonuçlar veren örüntü sınıflandırıcı türleri mevcut olup, sınıflandırıcının da doğrudan başarımını etkileyen özellik çıkarımı üzerine çalışmalar odaklanmıştır [47]. Özellik çıkarmanın ana sebepleri:

1. Ölçüm veya örüntü uzayından daha küçük boyuta dönüşmeyi sağlamaktır. Bu sınıflandırıcının küçük hatalar ile eğitimi ve karar aşamasının daha kısa sürede gerçekleşmesi demektir.
2. Boyut olarak daha düşük olan özellik uzayını sınıflandırıcının daha az parametre ile öğrenmesini mümkün hale getirecektir. Bunun yararı örüntü uzayı ile karar uzayı arasındaki dönüşüm aşamasının daha kısa sürede gerçekleşmesidir.
3. Durağan olmayan zaman serilerinde olduğu gibi karmaşık örüntülerin tanımlayıcı karakteristiklerini bulabilmek için özellik çıkarımı şarttır. Böylece karar aşamasının güvenilirliği artacaktır.
4. Örüntü sınıflandırma sisteminin, sistem içi veya dışındaki kontrolsüz girişimlerden etkilenmemesini sağlayacak bir özellik çıkarımı kararlı bir yapının oluşmasında etken olacaktır. Bu tür kararlı özellikler, sınıflandırıcının genelleme ve ayrışım yeteneğinin yüksek olmasında önemlidirler.

Örüntü özelliklerini belirlemede ana problem verilen esas örüntüden en iyi özellikleri seçmektir. Bunun için iki yaklaşım vardır : Doğrudan ve dolaylı olarak. Birinci metot güçlü yapısal bağlantılara sahip olan ve basit yapıya belirli örüntü tanıma problemlerine uygulanabilmektedir. Dolaylı metotlarda ise aşağıdaki gibi formüle edilebilen bir dönüşüm veya gösterim tekniği ile daha kullanışlı bir yapıdan özellik çıkarımı yapılmaktadır. Böylece z uzayından, x uzayına bir dönüşüm gerçekleştirilir [50].

$$x = F(z) \quad (2.2)$$

Durağan olmayan işaretlerin özelliklerinin çıkarımı ile ilgilenildiğinde, özellik çıkarımı için genelde zaman ve frekans bölgesi gösterimi ön plandadır. Böylece karmaşık örüntü yapısının hem geçici ve hem de zamana bağlı olarak frekans değişimlerini içeren tanımlayıcı

özellik bilgileri çıkarılabilir. Bu özellikler, işaretin zaman ve frekans bölgelerindeki yerel bilgilerini karakterize eder.

2.3.1. Zaman – Frekans Gösterimleri


İşaret işleme, bilgisayar bilimi ve mühendislik alanındaki gelişim etkinliklerinin ve çağdaş bilimin ana bir parçası haline gelmiştir. İşaret işleme; telekomünikasyonda, teşhis ve tanı sistemlerinde, kontrol uygulamalarında, zaman serilerinin tahmini gibi bilgisayar destekli mühendisliğin çok önemli bir disiplindir. Tüm bu uygulamaların temelinde, bir boyutlu karmaşık işaretlerin (zaman serilerinin) analizi ve değerlendirilmesi yatmaktadır [56].

Zaman – frekans gösterimleri, örüntü tanımının karar sürecini kolaylaştırmaya yönelik olarak veriyi bir başka biçime dönüştürmek amacı ile kullanılan bir işaret işleme tekniğidir. Bu dönüşüm, verinin boyutunu azaltmayı ve içindeki faydalı bilgilerin birçoğunun seçilmesini sağlamayı hedeflemekle birlikte gerçek – zamanlı karar uygulamaları için de son derece önemlidir [57]. Karar aşaması için en iyi sınıflandırıcı yapısı tasarlanırsa bile, eğer veriden çıkarılan özellikler veriyi uygun bir şekilde nitelendirmiyorsa sınıflandırıcının doğru karar verme başarımı düşük olacaktır. Bu açıdan ZFG 'ler durağan olmayan işaret örüntülerinin özelliklerini karakterize etmede uygun bir uzay oluşturmaktadır.

İşaret örüntülerinden özellik çıkarma süreci, bir boyutlu işaret verisini farklı ve daha kullanılabilir bölgelere dönüştürerek işarete ait karakteristik özellikleri elde etme işlemi olarak tanımlanmaktadır [46]. Basit bir örnek vermek gerekirse, sesin merkez frekansını kestirmek için zaman bölgesindeki işaretin Fourier dönüşümü yapılır. Dolayısıyla işaret örüntülerini sınıflama yapısının en önemli kısmı gösterim ve dönüşüm algoritmalarıdır. Burada esas olan işaretin tüm özelliklerini karakterize edebilecek uygun bir gösterim uzayını seçmektir.

ZFG 'ler işaret işleme süreçlerinde, işaret sıkıştırma, kodlama, filtreleme, gürültü bastırma, işaret tahmini, sınıflandırma ve yeniden sentez gibi yaygın uygulama alanı bulmuşlardır [47]. Durağan olmayan işaretlerin frekans içerikleri ile özellik tanımlaması yapılacaksa, özellik çıkarımı genellikle zaman ve frekans bölgelerinin birleşimindeki analiz ile ilgilenilir. Böylece tanımlama için hem geçici ve hem de frekans değişim bilgileri kullanılır.

Zaman bölgesindeki bir boyutlu $x(t)$ işaretlerin zaman–frekans gösterimi zaman ve frekansın iki boyutlu bir fonksiyonudur $T_x(t, f)$. Burada frekans terimi bir çok dönüşüm uzayını betimleyecek geniş bir anlamda kullanılır. Örneğin, hızlı Fourier dönüşümünde spektrum yerlerini, dalgacık dönüşümünde ölçekleri ve çeşitli eşleştirme filtrelerinin çıkışlarını temsil eder. Şekil 2.6. 'da çeşitli zaman–frekans gösterim yöntemleri görülmektedir.



Şekil 2.6. Çeşitli zaman – frekans gösterim teknikleri.


Bu gösterimler genel olarak ikiye bölünebilir: Sıkıştırılmış ve sıkıştırılmamış dönüşümler. Sıkıştırılmamış dönüşümler ayrıca kendi arasında doğrusal ve doğrusal olmayan dönüşümler olarak bölünebilir. Doğrusal dönüşümler süper pozisyon veya doğrusallık prensibini esas alır. Doğrusallık, dönüşüm katsayılarından elde edilen veriler ile zaman bölgesinde yeniden elde edilebilir. Doğrusal ve doğrusal olmayan zaman–frekans dönüşümleri konusunda [58] ve yukarıda belirtilen zaman–frekans gösterimleri için [46,59] iyi birer kaynaktırlar. Sıkıştırılmış dönüşüm yöntemleri ise işaretin her bir çerçevesinin spektral özelliklerini karakterize etmek için

bir takım parametreler kullanır. Bu noktadan hareketle işaretlerin zaman–frekans analizlerini parametrik ve parametrik olmayan yöntemler şeklinde ikiye ayırmakta mümkündür [32,46].

2.3.2. Entropi Hesaplama Teknikleri

Entropi kavramı, bir sistemin düzenliliğini ölçmek amacı ile termodinamik fiziğinde iyi bilinen bir kavramdır. İşaret işlemede, özellikle haberleşme sahasında ilk olarak Shannon kullanmıştır [60]. Entropi tabanlı kriterler verilen bir işaret gösteriminin özellikleri ile ilgili bilgileri tanımlar. Entropi ölçüm metodu durağan olmayan bir işaretin düzensizlik derecesini ölçmek için ideal bir araç olarak görünmektedir [61]. Ayrıca, entropi kavramı bir olayın içerdiği bilginin ortalama miktarını ölçmek amacı ile de kullanılmaktadır [62].

Şekil 2.7. de entropi kavramının anlaşılabilmesine yönelik olarak termodinamik ve işaret işleme alanlarındaki kullanımı karşılaştırmalı olarak verilmiştir. Şekil 2.7.a. da görüleceği gibi gaz molekülleri belirli bir bölgeye sıkıştırılmıştır, Şekil 2.7.b.de ise gaz molekülleri sıkıştırıldığı bölgeden serbest bırakılarak tüm kapalı hacme yayılmışlardır. (a) da gaz molekülleri daha düzenli bir yapıyı sergilediklerinden, düşük entropi değerine sahiptirler, (b) de ise gaz moleküllerinin düzenli yapısı bozulduğundan entropi değeri yüksektir. Termodinamikteki bu durum işaretlerin düzensizlik veya belirsizlik miktarlarını ölçmek içinde iyi bir araçtır. Tekrar Şekil 2.7.de görüleceği üzere, işaret durağan (örneğin sinüzoidal bir işaret) ise frekans bölgesinde dar bir spektrum ile düşük bir entropi değerine sahiptir (a), durağan değilse (doppler ses işareti) frekans spektrumu geniş bir banda yayılarak büyük bir entropi değeri oluşmasına neden olur (b) [64].



Şekil 2.7. Entropi kavramı : a) Yüksek, b) Düşük.

Entropi üzerine ilk çalışmalar 19. yüzyıl da termodinamik üzerine yapılmıştır. 1940 larda Shannon haberleşme kanallarının doluluğunu tahmin etmek ve haberleşme işaretinin içerdiği bilgi miktarını ölçmek için entropi kavramını tatbik etmiştir [60]. Son yıllarda, entropi işaret işleme alanında da yaygın olarak kullanılan bir kavram haline gelmiştir. Bunlardan bazıları; entegre devre teknolojisinde karbon üzerindeki elektron enerji kaybını bulmak [64], JPEG görüntü kodlamada oluşabilecek gürültüyü tespit etmek [65], biyomedikal NMR işaretlerinin dalgacık dönüşüm uzayından istatistiksel bilgilerini elde ederek işaretin gürültüsüz şeklini kestirmek [56], EEG işaretlerinin spektral entropilerini kullanarak anestezi derinliği tahmin etmek [66] ve MEG biyomedikal görüntülerin yeniden yapılandırılmasında Norm entropi metodu kullanarak yüksek kalitede MEG görüntüleri elde etmek [67] gibi.

İşaret işlemede yaygın olarak kullanılan entropi hesaplama türleri : Shannon, Norm, Eşik (Threshold), Logaritmik Enerji ve Sure metotlarıdır [68]. Bunun dışında diğer entropi hesaplama teknikleri de bulunmaktadır. Bunlar hakkında ayrıntılı bilgi [69] da bulunabilir. Aşağıdaki entropi yöntemlerinde, s işareti ve s_i de işaretin i . katsayısını göstermektedir.

1. Shannon entropi :

$$E(s) = -\sum_i s_i^2 \cdot \log_2(s_i^2) \quad \text{ve} \quad \log(0) = 0 \text{ kabul edilerek} \quad (2.3)$$

2. Norm entropi :

$$E(s) = \sum_i |s_i|^p \quad \text{ve} \quad 1 \leq p < 2 \quad (2.4)$$

3. Logaritmik Enerji entropi :

$$E(s) = \sum_i \log_2(s_i^2) \quad \text{ve} \quad \log(0) = 0 \text{ kabul edilerek} \quad (2.5)$$

4. Eşik entropi:

$$\varepsilon \text{ pozitif bir eşik değeri olup } |s_i| > \varepsilon \Rightarrow E(s_i) = 1 \quad \text{ve} \quad |s_i| \leq \varepsilon \Rightarrow E(s_i) = 0$$

tanımlanmak üzere

$$E(s) = \sum_i E(s_i) \quad (2.6)$$

5. Sure entropi :

ε pozitif bir eşik değeri olup

$$|s_i| \leq \varepsilon \Rightarrow E(s) = \sum_i \min(s_i^2, \varepsilon^2) \quad (2.7)$$


Bu entropi hesaplama tekniklerinin, işaret işlemedeki kesin kullanım alanları belirli olmayıp, uygulamalara göre başarımları değişmektedir. Fakat durağan olmayan işaretler için zamana bağımlı entropi hesaplaması daha kullanışlıdır. Bunun için de işaret katsayılarının s_i zamana bağımlı olması gerekir [61].

2.4. Sınıflandırma

Sınıflandırma aşamasının amacı, örüntüleri özellik uzaylarına göre kendilerine en yakın sınıflara minimum hata ile eşlemektir. Sınıflandırıcının başarımında iyi belirlenmiş özellikler kilit rolü oynarlar.

Örüntü sınıflandırıcılarını geleneksel ve akıllı olarak gruplara ayırmak mümkündür. Geleneksel sınıflandırma algoritmaları istatistiksel bir yapı olan Bayes karar teorisi üzerine kuruludur. Bunların dezavantajları, özellik uzayını sınıflandırma uzayını dönüştürürken, bir gürültünün çıkması ve her bir sınıf için hata kriterinin belli olmamasıdır [39]. Geleneksel sınıflandırıcılara; çok değişkenli Gauss modelleri, en yakın komşu, maksimum olabilirlik, ikili ağaç sınıflandırıcıları ve Fisher'in doğrusal sınıflandırıcıları örnek olarak verilebilir [46]. Buna karşın akıllı sınıflandırma yapıları genellikle YSA tabanlı olup, günümüzde en yaygın kullanılan ve başarımını ispatlamış çok güçlü sınıflandırıcı türleridirler. Özellikle de genelleme yetenekleri, örüntü tanıma uygulamalarının çok büyük boyutlu verileri açısından önemlidir. Hoekstra, (1998) çalışması ile geleneksel ve YSA sınıflandırıcılarını kıyaslamış ve YSA sınıflandırıcılarının üstünlüklerinin geleneksel yöntemlere göre tartışılmaz olduğunu göstermiştir.

Şekil 2.8.de akıllı sınıflandırma yapısı gösterilmektedir. Eğitim verisi sınıflandırıcının hafızası içinde şifrelenir. Önceki bölümlerde de belirtildiği gibi, sınıflandırıcı hafızası uyarlanabilen ϕ parametrelerinden oluşmaktadır.



Şekil 2.8. Akıllı sınıflama yapısı.


2.4.1. Yapay Sinir Ağı Sınıflandırıcıları

Yapay sinir ağları biyolojik nöron hücresinin yapısı ve öğrenme karakteristiklerinden esinlenerek geliştirilmiş bir hesaplama sistemi olup, örüntü tanımda çok kuvvetli sınıflandırıcılardır. Yapay sinir ağları, özellikle bilgisayar teknolojisinin gelişmesi ile

mühendislik sahasında çok geniş bir uygulama alanı bulmuştur [71,72]. Yapay sinir ağları aşağıdaki karakteristiklere sahip paralel bilgi işleme yapılarıdır :

- Biyolojik bir nörondan esinlenerek matematiksel modeli ortaya konmuştur.
- Birbirine bağlanan çok fazla sayıdaki işlem elemanlarından oluşur.
- Bağlantı ağırlıkları ile bilgiyi tutar.
- Bir işlem elemanı giriş uyarılarına dinamik olarak tepki verebilir ve tepki tamamen yerel bilgilere bağlıdır (ilgili işlem elemanını etkileyen bağlantılar ve bağlantı ağırlıkları yoluyla gelen giriş sinyali).
- Eğitim verisi ile ayarlanan bağlantı ağırlıkları sayesinde öğrenme, hatırlama ve genelleme yeteneklerine sahiptir.

Bu üstün özellikleri, yapay sinir ağlarının karmaşık problemleri çözebilme yeteneğini gösterir [73]. Şekil 2.9.da biyolojik nörondan esinlenerek ortaya konmuş işlem elemanının basit bir matematiksel modeli gösterilmiştir. Bu modelde, i . işlem elemanının çıkışı Denklem 2.8.de verilmiştir.



Şekil 2.9. Bir nöron hücresinin matematiksel modeli.

$$y_i(t+1) = a \left(\sum_{j=1}^m w_{ij} x_j(t) - \theta_i \right) \quad (2.8)$$

Burada $a(.)$ etkinleştirme fonksiyonu, θ_i ise i . işlem elemanının eşik değeridir. İşlem elemanlarının bilgi işlemleri iki kısımdan oluşur : Giriş ve çıkış. Bir işlem elemanı dışardan almış olduğu x_j giriş bilgilerini bağlı bulundukları w_{ij} ağırlıkları üzerinden birleştirerek bir net değeri üretir. i . işlem elemanının net değeri Denklem 2.9. ile hesaplanır.

$$f_i \triangleq net_i = \sum_{j=1}^m w_{ij} x_j - \theta_i \quad (2.9)$$

Her bir işlem elemanının ikinci süreci, *net* değerini bir $a(.)$ etkinleştirme fonksiyonundan geçirerek çıkış değerini bulmaktır. Etkinleştirme fonksiyonları işlem elemanlarının çok geniş aralıktaki çıkışını belli aralıklara çekmektedir. Böylece her bir işlem elemanının tepkisi yumuşak olmaktadır ve bağlantı ağırlıklarının değişimlerinin de daha küçük değerlerde olması sağlanır. Dolayısıyla yapay sinir ağının eğitiminde, hata değişiminin ıraksaması engellenerek kararlılığa ulaşmasına yardımcı olunur. Çok yaygın olarak kullanılan bazı etkinleştirme fonksiyonları: Birim basamak, signum, rampa, tek ve çift yönlü sigmoid gibi [74,75].

Yapay sinir ağ örüntü sınıflandırıcılarını hem popüler yapan, hem de geleneksel sınıflandırma metotlarından ayıran bir takım temel özellikleri vardır. Bunlar aşağıda sıralanmaktadır :

- 1. Öğrenme :** Yapay sinir ağları, örüntüler hakkındaki ilişkiyi belirli bir algoritmaya dayanarak çözmek yerine o ilişkiyi gösteren örüntü örneklerini incelemek suretiyle çözümler üretirler. Burada, sınıflandırılacak örüntü ile alakalı sinir ağına örneklerden başka hiç bir ön bilginin verilmemiş olması dikkat çekicidir. Ağ, kendisine gösterilen örnekleri tekrar tekrar inceleyerek aradaki ilişkiyi kavramaya çalışır. Her yeni örnek, ağın sahip olduğu bilgiye bir yenisini ekler ve bu işlem tekrar ettikçe ilgili örüntü sınıflandırma problemi hakkında bazı genellemeler yapılır.
- 2. Genelleme :** Alaşılmış bir takım sınıflandırma karakteristiklerinde, istenen çıkışı üretmek için tam olarak doğru girişlere gereksinim duyulmasıdır. Öte yandan yapay sinir ağları, girişlerinde değişimler olsa bile doğru çıkışı üretebilirler. Yani sistem, daha önce o tipten hiç bir şey görmemiş olmasına rağmen, insanlar gibi tamam olmayan veya kısmen hatalı girişlerle bile, doğru tanımlama yapabilmektedir. Buda işaret etmektedir ki, yapay sinir ağları kendilerine gösterilen bir örüntüyü daha önce öğrendikleri ile mukayese ederek ve aradaki benzerlikleri ortaya koyarak, belirli sınıflara ayırma özelliklerine sahiptirler.
- 3. Çıkarım yapma :** Yapay sinir ağları tam doğru olmayan bir eğitim kümesinden, tam doğruyu çıkarabilirler. Ses örüntülerini tanımak için eğitilmiş bir yapay sinir ağına, gürültü tarafından bozulmuş ses verilebilir. Buna rağmen eğitimden sonra, sistem girişi bozuk ses olmasına rağmen, çıkışta ses mükemmel bir şekilde oluşturulabilir. Yani sistem, eğitim kümesinin özünü çıkarıp saklamıştır. Böylece, eksik veya gürültülü girişlere karşı uygun şekilde cevap verebilmektedir.
- 4. Hata toleransı :** Verilerde eğer bir eksiklik söz konusu olursa, geleneksel yöntemler çalışmazlar. Daha önce belirtildiği üzere, iyi eğitilmiş ve genelleme kapasitesi yüksek


bir sinir ağı, kendisine takdim edilen veriler eksik olsa da karar verme işlemine devam eder. Aynı şekilde, yapay sinir ağı üzerinde birtakım problemler ve bozukluklar olabilir. Geleneksel sistemlerin tersine yapay sinir ağları, bu durumda da çalışmalarına devam ederler. Verilerdeki eksiklik veya yapay sinir ağındaki yapısal bozukluk arttıkça yapay sinir ağının performansı yavaş yavaş azalmaya başlar. Fakat sistem fonksiyonunu tamamen durdurmaz ve mutlaka bir sonuç üretilir. Bu özellikler yapay sinir ağının yapısından kaynaklanmaktadır. Çünkü ağın sahip olduğu bilgi, ağ üzerindeki hücrelerin birbirleri ile olan bağlantıları üzerine dağıtılmıştır. Zaten böyle bir durumda tek bir bağlantı ve onun üzerindeki bilgi, başlı başına hiçbir zaman bir mana ifade etmez. Ancak, bir grup halinde ve tam olarak bağlantıların birlikte düşünülmesi sonucu anlamlı bilgiler üretilir. Bundan dolayı birkaç bağlantının etkisiz hale gelmesi, sonucu ya etkilemez veya performansı yavaş yavaş düşürür. Yapay sinir ağı, sahip olduğu diğer bağlantılar nedeniyle işlevine devam eder. Geleneksel sistemlerin ardışıl çalışmalarından dolayı, sistemdeki en küçük bir hatanın veya bozulmanın ulaşabileceği boyutlar düşünülürse, bu özelliğin ne kadar önemli olduğu ortaya çıkar.

5. Hız : Gerçek zaman uygulamalarında bilgi işleme hızı önemli bir yer teşkil eder. Sistemlerin her geçen gün biraz daha karmaşık olduğu, dolayısı ile daha fazla hacimde veriyi daha verimli bir şekilde işleme gerekliliği, yeni yazılım/donanım sistemlerinin zorunluluğunu ortaya çıkarmıştır. Yapay sinir ağlarının da, yine birbirlerine bağlı ve paralel işlem elemanlarından oluştuğundan böyle hızlı işleyebilmeleri, bu ağlara özellikle endüstriyel hayatta çok önemli olan gerçek zamanlı çalışma kabiliyeti kazandırır.

Yaklaşık 60 yıl önce mütevazı çalışmalar ile başlayan YSA çalışmaları, bugün teorik olarak olgunlaşmış ve bir çok uygulamada yeri doldurulamaz bir araç olmuştur. Yapay sinir ağlarının görevlerini gerçekleştirmede, sahip oldukları fiziksel yapının da önemi vardır. Bugün 50 'ye yakın farklı yapılanma, diğer bir deyişle farklı model, görülmekte ve bu sayı her geçen gün artmaktadır [62]. Farklı yapılaşma, işlem elemanlarının birbirleri ile olan bağlantılarından ve uygulanan öğrenme kuralından kaynaklanmaktadır. İşlem elemanları ya tamamen birbirleri ile bağlantılı veya yerel olarak gruplar halinde bağlantılı olabildikleri gibi değişik şekilde de birbirleri ile bağlanabilmektedirler. Bilgi akışı bu bağlantılar üzerinden tek yönlü olduğu gibi, çift yönlü de olabilir. Bir grup işlem elemanı bir araya gelerek bir katman oluştururlar. Genel itibariyle yapay sinir ağlarında 3 tür katman bulunur. Sinir ağının dış dünya ile bağlantısını kuran girdi katmanı, gelen bilgileri işleme kabiliyetine sahip ara katmanlar ve sinir ağının kararlarını dış dünyaya aktaran bir çıktı katmanı. Girdi katmanında çoğu zaman bilgi işleme söz

konusu olmaz. Bu katmandaki işlem elemanları aldıkları bilgiyi herhangi bir değişikliğe uğratmadan ara katmandaki işlem elemanlarına aktarırlar. Burada sözü edilen bilgi, sinir ağının işlem elemanları arasındaki bağlantı hatları üzerinde bulunan ağırlıklarla ifade edilir. Dolayısı ile bilgi, bütün ağı dağıtılmış demektir. Bu bilgiler, yapay sinir ağının belleğidir veya diğer bir deyişle yapay sinir ağları eğitildikten sonra kullanılacağı sistem için bir veri tabanıdır.

Tüm YSA modellerini bir örüntü sınıflandırıcısı olarak kullanmak mümkündür, fakat en yaygın kullanılan ve en güçlü örüntü sınıflandırıcısı çok katmanlı ileri beslemeli ağ olup, tüm yapay sinir ağı uygulamalarının %90 nını kapsamaktadır [70,76,77]. Örüntü sınıflandırıcısı olarak kullanılan YSA türleri hiyerarşik bir biçimde Şekil 2.10. da gösterilmiştir [47].



Şekil 2.10. Yapay sinir ağ örüntü sınıflandırıcıları.

Yaygın olarak kullanılan çok katmanlı ileri beslemeli YSA 'nın eğitiminde çeşitli eğitim algoritmaları kullanılmakla birlikte en başarılı sonuçlar geri yayılım (backpropagation) algoritması ile elde edilmiştir. Bu algoritma, eğim düşme metoduna dayalıdır [76]. Çok katmanlı YSA yapısı ve geri yayılım algoritması tüm YSA çalışmalarında geniş bir yer tutar. Çok katmanlı YSA yapısının kaç katmanlı olacağı ve katmanlarda kaç nöron bulunacağı, etkinleştirme fonksiyon türü seçimi genellikle uygulamalara bağlıdır. Geri yayılım öğrenme algoritmalı çok katmanlı YSA, geniş giriş vektörüne sahip olan örüntü tanıma çalışmalarında en iyi başarımın elde edildiği yapıdır. Çünkü örüntü sınıflandırıcılarından beklen, istenen ayrımı yapabilmeleridir.



BÖLÜM 3

3. DALGACIK DÖNÜŞÜM ZAMAN-FREKANS ENTROPİLERİ İLE ÖZELLİK ÇIKARMA


Dalgacık teorisi farklı alanlarda bir çok köke sahiptir. Fakat sürekli dalgacık dönüşümü Morlet (1982), Grossmann ve Morlet (1984), ve Goupillaud, Grossmann ve Morlet (1984) tarafından ilk olarak jeofizik alanında geliştirildi. Temelleri, Chui (1992) ve Meyer (1993) tarafından sağlamlaştırıldı. Dönüşümün ayrık yorumunu, Mallat (1989) ve Daubechies (1992) geliştirdi. Dalgacık paket dönüşümü, ayrık dalgacık dönüşümünün genelleştirilmiş bir hali olup, Coifman ve Wickerhauser (1992) tarafından önerilmiştir. Bugün dalgacıklar ve dalgacık paketleri işaret işlemenin bir çok alanında kullanılmaktadır.

3.1. Dalgacık Dönüşümü

Dalgacık Dönüşümü (DD) işaretin ölçeklenebilir bir ZFG ile analizini sağlar ve geleneksel işaret işleme teknikleri (HFD, KZFD) tarafından görülmeyen detayları meydana çıkarır. KZFD 'nin sınırlamalarından biri olan, kullanılan pencerenin sabit olması DD de ölçeklenebilir bir pencere ile giderilmiştir. Böylece işaret içindeki düşük frekans eğilimlerini açmak için geniş bir pencere, yüksek frekans detaylarını analiz etmek için sıkıştırılmış bir pencere kullanılır. Bunun için, DD ölçeklenebilir temel bir dalgacık fonksiyonu kullanıp sabit çözünürlük problemine çözüm getirerek, işaretin farklı çözünürlüklerde daha esnek bir zaman bölgesi analizini yapar [21]. Şekil 3.1. de en yaygın olarak kullanılan dalgacıkların bir kısmı verilmiştir. Dalgacık dönüşümü zaman – ölçek metoduna dayalı olduğu için, odağa tam olarak ayarlanarak işaretin farklı kısımlarını gözetleyebilen bir matematik mikroskobu gibi davranır [96]. Dalgacık analiz metotlarının geleneksel metotlara göre üstünlükleri sıralanırsa:

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

Bu özelliklerinden dolayı, dalgacık dönüşümü durağan olmayan işaretlerin daha esnek ZFG 'lerinin elde edilmesinde etkili bir araç olduğu literatürde belirtilmiştir [96-100].



Şekil 3.1. Yaygın olarak kullanılan dalgacık örnekleri


A) Sürekli Dalgacık Dönüşümü

Sürekli Dalgacık Dönüşümü (SDD) sıkıştırma, genişleme ve dönüşümler ile tüm zaman ve ölçeklerdeki işaretler ile ana dalgacık arasında uygunluk sağlar.

$$SDD(a, b) = - \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) dt \quad (3.1)$$


Burada $x(t)$ işaret, $\psi(t)$ dalgacıktır, b dönüşüm etmeni olup, farklı frekans seviyelerinde ayrışım filtreleri tanımlar ve a ise ölçekleme etmeni olup her seviye için ayrışım filtrelerini ölçeklendirir. Şekil 3.2.de bir ana dalgacık ile ölçekleme ve dönüşüm işleminin nasıl yapıldığı

gösterilmiştir. Dönüşüm sonucu, zamanın bir fonksiyonu olarak işaret ve dalgacık arasında nasıl karşılıklı bir ilişki (korelasyon) olduğunu gösterir. İşaret ve dalgacık iyi eşleşmişse işaret ve dalgacık arasındaki korelasyon yüksek olur. Uygulamalara bağlı olarak dalgacık türü seçilir. SDD deki ölçekleme kavramı FD deki frekansın tersine benzerdir. Dalgacık yüksek oranda sıkışık olduğunda işaretin yüksek frekans detaylarını elde eder. Dalgacık tamamen genişse dalgacığın uzunluğu, işaretin uzunluğu ile daha uygun benzerlik sağlar ve böylece işaretin düşük frekans eğilimleri ortaya çıkar.




Şekil 3.2. Daubechies-4 ana dalgacığı ile ölçekleme ve dönüşüm tekniğinin gösterimi.


Şekil 3.3.a' da bir doppler işareti görülmektedir. Şekil 3.3.b,c. de ise sırasıyla işaretin KZFD ve SDD kullanılarak ZFG analizi verilmiştir. Fourier analizinin sonuçları, zaman ve frekans çözünürlükleri arasındaki ilişkiden vazgeçildiğini göstermektedir. SDD 'nin zaman-ölçek şemasında bir salınım görülmektedir. Bu, işaret ile dalgacık arasındaki bağıl faz farkına karşılık gelmektedir. SDD Fourier analizi kadar iyi sinüzoidal bileşenleri çözemez, fakat onun KZFD 'ye alternatif olan ilgi çekici yanı, geçici olayların yerini saptayabilmesidir.



(a) Doppler işareti



(b) KZFD zaman –frekans gösterimi



(c) SDD zaman – frekans gösterimi

Şekil 3.3. a) Doppler İşareti; b) KZFD analizi; c) SDD ayrışımı : ölçek frekansın tersidir.


B) Ayırık Dalgacık Dönüşümü

SDD 'nin hesaplama yükü fazla ve dönüşümü sağlamak için kullandığı bilgi miktarı oldukça büyüktür. Daha etkili bir yol, Ayırık Dalgacık Dönüşümüdür (ADD). ADD, ana dalgacığın sadece belirli genişlemelerinde işarete bakar. Böylece ADD 'nin hız yönünden etkinliği HFD 'den daha iyi olur. ADD 'yi anlamak ve dalgacıkların yerini görmek için filtre bankası kavramını tanıtmak gereklidir. Çünkü filtre bankası dalgacıkların ayırık eşdeğerleridir.


Filtre bankası ve alt bant kodlama : Tek bir filtre belirli bir frekans cevabına sahiptir ve işaret filtreden geçtikten sonra işaretin içindeki bilginin bir kısmı kaybolur. Bu yüzden tek bir filtre, filtrelenmiş işaretten tekrar asıl işareti yeniden elde etmek için kullanılamaz. Çünkü kaybolmuş bilgi tekrar kazanılamaz. İki filtre kullanılırsa, biri düşük frekans bilgisini, diğeri yüksek frekans bilgisini tutar. Bir başka deyişle işaret içindeki bilginin tümü içerilmiş olunur. Böylece bu iki filtrenin çıkışı asıl işareti yeniden elde etmek için birleştirilebilir. Filtre kümesi veya filtre bankası, spektrum bilgisini ayırmak için kullanılarak işareti gittikçe daha ince frekans bantlarına ayırtırmayı mümkün kılar. Filtrelerin çıkışından elde edilen veriyi örneklemek gerekir. Çünkü işaret, filtre bankasının her bir seviyesinden geçirildiğinde verinin miktarı iki katına çıkar. Genellikle ideal olan fikir, işareti daha etkili temsil etmektir. Eğer işaret m tane zaman ile ayrıştırılırsa asıl işaretten 2^m zaman daha fazla veriye sahip olması yararlı değildir. Filtre kümesinin, kusursuz yeniden yapılandırma filtreleri gibi davranabilmesi için özel karakteristiklere sahip olması gerekir. Çünkü gerçek filtreler kusursuz kesim frekanslarına sahip değildir. Böylece bilginin tümünü yeniden elde etmek için bitişik filtreler arasında bazı binişmeler vardır. Bu görevi yerine getirmek için geliştirilen filtreler kuvadratür filtreler olarak bilinir [101]. ADD, bu filtrelerden elde edilir. Şekil 3.4.a. da gösterildiği gibi işaretin ADD 'si, ayrışımının her bir seviyesinde yüksek frekans bileşenleri çıkarılarak, asıl işaretin gittikçe kaba bir yaklaşımının elde edilmesine sebep olacak çok çözünürlüklü bir ayrışım tabanlıdır. Asıl işaret, en yüksek seviyedeki yaklaşık ve daha düşük seviyelerdeki detay işaretleri birleştirilerek yeniden oluşturulabilir. Ayrışımın ZFG yapısı Şekil 3.4.b. de verilmiştir. Görülüyor ki, düşük frekans eğilimlerinde, frekansın yeri iyi saptanır ve yüksek frekans bileşenlerinde ise frekans yerine zaman saptaması daha iyi belirlenir.

C) Dalgacık Paket Analizi

Dalgacık Paket Analizi (DPA) ADD 'ye benzer olup, işaret üzerinde mümkün olan bir çok ayrışimleri üretir ve ADD bunlardan sadece biridir. Filtre bankası her bir zaman için düşük frekans bileşenlerini tam olarak ayırtırmak yerine, yüksek frekans bileşenlerini daha iyi ayırtırmayı mümkün kılar. Böylece tüm zaman-frekans düzlemi Şekil 3.5.de gösterildiği gibi mümkün olan tüm alt bölümlere, farklı zaman-frekans pencereleri ile bölünür [46].




(a)



(b)

Şekil 3.4. a) ADD ayrışım ağacı; b) ADD kullanılarak elde edilen ZFG yapısı.


DPA 'nın avantajı asıl işaretin en uygun ZFG 'sini elde etmek için ayrışımın farklı seviyelerini birleştirmeyi mümkün kılmasıdır.



Şekil 3.5. DPA ile ADD ayrışımının ağaç yapısı.

3.2. Dalgacık Dönüşüm Ağacından Entropi Hesaplanması

Geliştirilen dalgacık dönüşüm ZFG entropilerine dayalı özellik çıkarım tekniğinin blok diyagramı Şekil 3.6.da verilmiştir.



Şekil 3.6. Dalgacık dönüşüm ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı aşağıda açıklanmıştır:

1. Dalgacık dönüşüm ağaç yapısı : Sonlu uzunluktaki işarete uygun olacak şekilde, dalgacık dönüşüm ağacının ayrışım seviyesi aşağıdaki kritere göre seçilmiştir :

$$\frac{n}{2^m} \geq 2N \quad (3.2)$$


Burada;

n : İşaretin uzunluğu

$2N$: Ayrışım filtresinin bant genişliği (N : filtrenin katsayı sayısı)

m : Ayrışım seviyesidir.

Şekil 3.7.de görülen dalgacık ağacının özelliği, yapraklardaki işaret bileşenlerinin toplanarak asıl işareti oluşturabilecek bir yapıya sahip olmasıdır.



Şekil 3.7. Dalgacık dönüşüm ağaç yapısı.

2. Dalgacık dönüşüm ağacının her bir ayrışım seviyesindeki yapraklarda bulunan işaret katsayılarının hesaplanması:

Dalgacık ayrışımı, işaretin farklı ölçek pencerelerine ve seviyelerine göre bileşenlerine ayırmaktır. m seviyede ve t_m konumunda bir dalgacık ayrışımı Denklem 3.3. ile ifade edilebilir:

$$d_m(t_m) = x(t) \cdot \Psi_m\left(\frac{t - t_m}{2^m}\right) \quad (3.3)$$

Burada Ψ_m , m frekans seviyesinde ayrışım filtresi olup, m adet ayrışım seviyesinde 2^m filtre yapısı kullanarak ölçekleme yapmaktır. Bu ayrışımelerde, her bir seviyede yüksek ve düşük frekans bileşenlerini içeren iki yaprak işareti bulunur. Bunlar Denklem 3.4.de belirtildiği üzere, ayrışımı yapılacak olan işaretin düşük frekanslı bileşeni veya yaklaşık katsayısı olarak nitelendirilen cA ile yüksek frekanslı bileşeni veya detay katsayısı olarak isimlendirilen cD katsayılarıdır. Bu zaman-frekans katsayılarının, ağaç yapısında belirtilen sıralamada sentezi yapılarak, bileşenlerine ayrıştırılmış işaret $x[n]$ yeniden oluşturulabilir.

$$cA[n] = x[n] \cdot g[n] \quad (3.4)$$

$$cD[n] = x[n] \cdot h[n]$$

Burada $h[n]$ yüksek geçiren filtre ve $g[n]$ ise düşük geçiren filtre karakteristiği gösterir.

- Her bir yaprak işaret katsayısının entropi değerinin hesaplanması: Dalgacık ayrışım ağacının yapraklarından elde edilen işaret katsayılarının entropi değerleri; Bölüm 2.3.2.de belirtilen entropi yöntemleri kullanılarak hesaplanabilir. Denklem 3.5. ve 3.6. da Shannon entropi hesaplama tekniği kullanılarak entropi çıkarım denklemi verilmiştir.

$$Ed_i = -\sum_n cD_i^2[n].\log_2(cD_i^2[n]) \quad i = 1, 2, \dots, m \quad (3.5)$$

$$Ea_m = -\sum_n cA_m^2[n].\log_2(cA_m^2[n]) \quad (3.6)$$


- Özellik vektörü: Dalgacık dönüşüm ZFG işaret katsayılarının, entropi değerlerinin hesaplanmasından oluşmuş işarete ait betimleyici özellik vektörü:

$$V = [Ed_1, Ed_2, Ed_3, \dots, Ed_m, Ea_m] \quad (3.7)$$

elde edilir.

3.3. Dalgacık Paket Dönüşüm Ağacından Entropi Hesaplanması

Geliştirilen dalgacık paket dönüşüm ZFG entropilerine dayalı özellik çıkarım tekniğinin blok diyagramı Şekil 3.8.de verilmiştir.




Şekil 3.8. Dalgacık paket dönüşüm ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı aşağıda açıklanmıştır:

- Dalgacık paket dönüşüm ağaç yapısı : Sonlu uzunluktaki işarete uygun olacak şekilde, dalgacık dönüşüm ağacının zaman-frekans ayrışım seviyesi, Denklem 3.2. ye göre seçilir.

Şekil 3.9.da görülen ikili dalgacık ağacının işlevi, farklı sıralamalarda yaprak işaret katsayılarının sentezi ile bileşenlerine ayrıştırılmış asıl işareti oluşturabilecek bir yapıyı mümkün kılmasıdır.



Şekil 3.9. Dalgacık paket dönüşüm ağaç yapısı.

2. Dalgacık paket dönüşüm ağacının en son ayrışım seviyesinde bulunan uç yaprak işaretlerinin dalgacık paket dönüşüm katsayılarının hesaplanması:

Dalgacık paket ayrışımı, işaretin mümkün olan tüm farklı ölçek pencerelerine ve seviyelerine göre bileşenlerine ayırmaktır. m seviyede ve t_m konumunda bir dalgacık paket ayrışımı Denklem 3.3. ile ifade edilebilir. Her bir dalgacık paket ayrışım seviyesindeki yaklaşık ve detay işaret katsayıları Denklem 3.4.de tanımlandığı gibi bulunur. Bu zaman – frekans gösterim katsayılarının mümkün olan sentez türleri ile, bileşenlerine ayrıştırılmış işaret $x[n]$ yeniden oluşturulabilir.

3. Dalgacık paket ağacının uç yapraklarında bulunan her bir katsayı işaretinin entropi değerinin hesaplanması: Dalgacık paket ayrışım ağacının en son ayrışım seviyesindeki (m) uç yapraklarından elde edilen işaret katsayılarının entropi değerleri Bölüm 2.3.2. de belirtilen entropi yöntemleri kullanılarak hesaplanabilir. Denklem 3.8. ve 3.9. da Norm entropi hesaplama tekniği kullanılarak entropi çıkarım denkleminin uyarlaması yapılmıştır.

$$Ed_{i,m} = \sum_n |cD_{i,m}[n]|^p \quad (3.8)$$

$$Ea_{i,m} = \sum_n |cA_{i,m}[n]|^p \quad (3.9)$$

Burada $1 \leq p < 2$ ve $\forall i \in m.seviye$ olup $i = 1, 2, \dots, 2^{m-1}$ dir.

4. Özellik vektörü: m. seviye dalgacık paket dönüşüm ZFG işaret katsayılarının entropi değerlerinin hesaplanmasından oluşmuş işarete ait betimleyici özellik vektörü:

$$V = [Ed_{1,m}, Ea_{1,m}, Ed_{2,m}, Ea_{2,m}, \dots, Ed_{2^{m-1},m}, Ea_{2^{m-1},m}] \quad (3.10)$$

elde edilir.

Geliştirilen bu özellik çıkarım algoritmalarının uygulamaları ve başarımları Bölüm 7. de verilmiştir.



BÖLÜM 4


4. PARAMETRİK OLMAYAN ZAMAN-FREKANS GÖSTERİM ENTROPİLERİ İLE ÖZELLİK ÇIKARMA

Parametrik olmayan metotlar, parametrik metotların aksine işaretin istatistiksel olasılık dağılımı hakkında öncesel bir bilgiye ihtiyaç gerektirmediği gibi, işareti karakterize etmek için herhangi bir parametrik modelden de faydalanmaz. Bunlar işaret hakkında birkaç kabul yaparak, zaman bölgesinin geniş aralığındaki işareti ardışıl bir formda işlerler. Bu metotlar işaretin herhangi bir özel karakteristiği ile ilgilenmediklerinden işaret ne olursa olsun uygulanabilirler. Bu metotların dezavantajı, işaret işlemenin farklı karakteristik tekniklerini kullanmadıklarından, tatmin edici performansa sahip değildirler. Parametrik olmayan metotlar, sayısal filtre ve dönüşüm tabanlı işaret işleme gibi metotları (Fourier analizi ve ayrık kosinüs dönüşümü) içerirler [3]. İşaretteki rast gele değişimlerin zaman-frekans ilişkisini belirlemek için parametrik olmayan metotlar ilk kez, Bhattacharya ve Johnson (1968) tarafından önerilmiştir. Onların fikirlerini 1970 ve 1980 'lerde yapılan birkaç çalışma desteklemiştir. 1970 li yılların ortasında, Darkhovsky ve Brodsky bağımlı rast gele değişimlerin sırasını tespit etmek için parametrik olmayan yöntemleri kullanmışlardır [102]. Brodsky ve Darkhovsky tarafından önerilen bu çözüm yaklaşımı, Deshayes ve Picard (1981) tarafından da durağan olmayan işaret değişimlerinin spektrumunu tespit etmek için kullanılmıştır [105]. KZFD, Welch ve MUSIC literatürde sıkça geçen parametrik olmayan işaret işleme teknikleridir.

Parametrik olmayan işaret işleme teknikleri, tüm zaman aralıklarında işaretin var olduğunu kabul eder. Bu durum pratikte gerçekçi bir yaklaşım değildir ve işaretin zamana göre değişimi hakkında bir bilgi vermez [21]. Durağan işaretler için bu yaklaşım bir problem değildir. Çünkü işaretin istatistiki özellikleri zaman ile değişmez. Durağan olmayan işaretlerin analizi için frekans karakteristiklerinin değişim yerini saptamak ve tanımlamak için bu bilgi gereklidir. Bu tez de önerilen yöntemde ise, parametrik olmayan işaret işleme tekniklerinin frekans kestirim üstünlerinden faydalanarak işaret hakkında tanımlayıcı özellikler elde etmek için, durağan olmayan işaretlerin dalgacık dönüşümleri ile elde edilen durağan bileşenlerine tatbik edildi. Böylece, elde edilen ZFG 'nin her bir bileşeninin entropi değeri hesaplanarak, akıllı örüntü tanıma sistemi için farklı nitelikli özellik çıkarım teknikleri gerçekleştirilmiştir.


4.1. Kısa Zamanlı Fourier Dönüşümü ile Spektrogram

Spektrogram, zamana bağımlı Fourier dönüşümünün büyüklüğünün ardışıl olarak ekranda gösterimidir. Zamana bağımlı Fourier dönüşümü, kayan bir pencere kullanan ardışık ayrık Fourier dönüşümüdür. Fourier dönüşümünün bu şekli aynı zamanda Kısa Zamanlı Fourier Dönüşümü (KZFD) olarak da bilinir [106]. Şekil 4.1.de bir Doppler işaretinin spektrogramı verilmiştir. Görüleceği üzere, Doppler işareti durağan olmadığı için, hem zaman ve hem de frekans saptamalarında belirsizlikler oluşmuştur. Bu ZFG ile çıkarılabilecek özelliklerde de belirsizlikler olması muhtemeldir.



Şekil 4.1. Doppler işaretinin KZFD spektrogramı.

Bir $x(t)$ işaretinin Fourier dönüşümü Denklem 4.1. ile hesaplanmaktadır. Zamana bağımlı veya pencereli Fourier dönüşümü olarak bilinen KZFD, durağan olmayan işaretin tümünü küçük veri pencerelerine bölerek analiz etmeye çalışır. Kısaca KZFD, Denklem 4.2. ile verilebilir. Burada $w(n-n_0)$ bir kayan pencere fonksiyonu olup, literatürde kullanılan pencereler: Bartlett, Blackman, Dikdörtgen, Chebyshev, Hanning, Hamming, Kaiser ve Üçgendir [107]. Şekil 4.2. de bu pencere fonksiyonlarından bazıları görülmektedir.



Şekil 4.2. Pencere fonksiyonları.


$$X(f) = \int_{-\infty}^{\infty} x(t) \cdot e^{-j2\pi ft} \cdot dt \quad (4.1)$$

$$X(k) = \sum_{n=0}^N x(n) \cdot w(n - n_0) \cdot e^{-\frac{j2\pi nk}{N}} \quad (4.2)$$

Burada, ZFG arka arkaya KZFD 'lerinin çıkışı ile oluşturulur. Bunun için bir pencere fonksiyonu ile işaret çarpılır, veri penceresinin dışı sıfır olur. Veri penceresi içinde bulunan işaretin frekans spektrumu HFD kullanılarak hesaplanır. Tüm işareti analiz etmek için pencere zaman bölgesinde kaydırılarak işarete tekrar uygulanmaktadır.

4.1.1. Dalgacık Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması

Geliştirilen dalgacık dönüşümü ve KZFD spektrogramı ile oluşturulan ZFG bileşenlerinin entropilerine dayalı özellik çıkarım tekniğinin blok diyagramı Şekil 4.3.de verilmiştir.



Şekil 4.3. Dalgacık dönüşümü ve KZFD spektrogramı ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı aşağıda açıklanmıştır:

1. Uygun dalgacık dönüşüm ağaç yapısı ve bu yapının gerektirdiği dalgacık dönüşüm katsayıları Bölüm 3.2.de belirtildiği üzere elde edilir.
2. Her bir dalgacık dönüşüm katsayı işaretinin KZFD ile spektrogramı Denklem 4.3. ile bulunur.

$$ScD_i(k) = \sum_{n=0}^{N-1} cD_i(n).w(n - n_0).e^{-\frac{j2\pi nk}{N}} \quad (4.3)$$

$$ScA_m(k) = \sum_{n=0}^{N-1} cA_m(n).w(n - n_0).e^{-\frac{j2\pi nk}{N}} \quad (4.4)$$

Burada $i = 1, 2, \dots, m$ dalgacık dönüşüm katsayıları, N pencere fonksiyonunun nokta sayısı, n_0 pencerenin zaman kayması ve k spektrogramı oluşturan ardışıl bileşen sayısını göstermektedir.

3. Spektrogramı ZFG 'sini oluşturan her bir bileşenin entropi değerleri Bölüm 2.3.2.de belirtilen entropi yöntemleri kullanılarak hesaplanabilir. Denklem 4.5. ve 4.6. da Sure entropi hesaplama tekniği kullanılarak entropi çıkarım denkleminin uyarlaması yapılmıştır.

$$|ScD_{i,k}(n)| \leq \varepsilon \Rightarrow Ed_{i,k} = \sum_n \min(ScD_{i,k}^2[n], \varepsilon^2) \quad (4.5)$$

$$|ScA_{i,k}(n)| \leq \varepsilon \Rightarrow Ea_{m,k} = \sum_n \min(ScA_{m,k}^2[n], \varepsilon^2) \quad (4.6)$$

Burada ε pozitif bir eşikleme değeridir.


4. Özellik vektörü: Dalgacık dönüşüm katsayılarının KZFD spektrogram ZFG 'sini oluşturan işaretlerin her birinin entropi değerinin hesaplanmasından oluşmuş işarete ait betimleyici özellik vektörü:

$$V = [Ed_{1,1}, Ed_{1,2}, \dots, Ed_{1,k}, \dots, Ed_{2,1}, \dots, Ed_{m,k}, Ea_{m,1}, \dots, Ed_{m,k}] \quad (4.7)$$

elde edilir.

4.1.2. Dalgacık Paket Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması

Geliştirilen dalgacık paket dönüşümü ve KZFD spektrogramı ile oluşturulan ZFG bileşenlerinin entropilerine dayalı özellik çıkarım tekniğinin blok diyagramı Şekil 4.4.de verilmiştir.



Şekil 4.4. Dalgacık paket dönüşüm ve KZFD spektrogram ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı aşağıda açıklanmıştır:

1. Uygun dalgacık paket dönüşüm ağaç yapısı ve bu yapının en son ayrışım seviyesinde bulunan uç yaprak dalgacık paket dönüşüm katsayı işaretleri Bölüm 3.3.de belirtildiği biçimde elde edilir.
2. En son seviye (m) ayrışımındaki, her bir uç yaprak dalgacık paket dönüşüm katsayı işaretinin KZFD ile spektrogramı Denklem 4.8. ve 4.9. daki gibi bulunur.

$$ScD_{i,m}(k) = \sum_{n=0}^{N-1} cD_{i,m}(n) \cdot w(n - n_0) \cdot e^{-\frac{j2\pi nk}{N}} \quad (4.8)$$

$$ScA_{i,m}(k) = \sum_{n=0}^{N-1} cA_{i,m}(n) \cdot w(n - n_0) \cdot e^{-\frac{j2\pi nk}{N}} \quad (4.9)$$

Burada $i=1,2,...,2^{m-1}$ dalgacık paket dönüşüm katsayıları, N pencere fonksiyonunun nokta sayısını, n_0 pencerenin zaman kayması ve k spektrogramı oluşturan ardışık bileşenleri göstermektedir.

3. Spektrogramı ZFG 'sini oluşturan her bir bileşenin entropi değerleri Bölüm 2.3.2.de belirtilen entropi yöntemleri kullanılarak hesaplanabilir. Denklem 4.10. ve 4.11. de Eşik entropi hesaplama tekniği kullanılarak entropi çıkarım denkleminin uyarlaması yapılmıştır.

Detay katsayıları için:

$$|\text{ScD}_{i,m,k}(n)| > \varepsilon \Rightarrow E(\text{ScD}_{i,m,k}(n)) \approx 1$$

ve

$$|\text{ScD}_{i,m,k}(n)| \leq \varepsilon \Rightarrow E(\text{ScD}_{i,m,k}(n)) \approx 0$$

olmak üzere;

$$E_{d,i,m,k} = \sum_n E(\text{ScD}_{i,m,k}[n]) \quad (4.10)$$

Yaklaşık katsayıları için:

$$|\text{ScA}_{i,m,k}(n)| > \varepsilon \Rightarrow E(\text{ScA}_{i,m,k}(n)) = 1$$

ve

$$|\text{ScA}_{i,m,k}(n)| \leq \varepsilon \Rightarrow E(\text{ScA}_{i,m,k}(n)) = 0$$

olmak üzere;

$$E_{a,i,m,k} = \sum_n E(\text{ScA}_{i,m,k}[n]) \quad (4.11)$$

hesaplanır. Burada $i = 1, 2, 3, \dots, 2^{m-1}$ dalgacık paket dönüşüm katsayılarını ve ε ise pozitif bir eşik değeri göstermektedir.

4. Özellik vektörü: m . seviye dalgacık paket dönüşüm uç yaprak katsayılarının KZFD spektrogramının ZFG 'sini oluşturan işaretlerin her birinin entropi değerinin hesaplanmasından elde edilmiş işarete ait betimleyici özellik vektörü Denklem 4.12. de verilmiştir.

$$V = [E_{d,1,m,1}, E_{a,1,m,1}, \dots, E_{d,1,m,k}, E_{a,1,m,k}, \dots, E_{d,2^{m-1},m,1}, E_{a,2^{m-1},m,1}, \dots, E_{d,2^{m-1},m,k}, E_{a,2^{m-1},m,k}] \quad (4.12)$$

4.2. Güç Spektrum Yoğunluğu

Enerji veya güç spektrum analizi frekans domeninde işaretin gücü veya enerjisinin dağılımı ile ilgilenir. Bu analiz, sonlu uzunluktaki geniş bantlı işaretlerin frekans içerikleri arasında, gücün dağılım şeklini belirlemek için önemlidir. Bir ayrık zamanlı $x[n]$ işaretinin enerji spektrum yoğunluğu, zaman bölgesindeki karesel değerlerin entegrali olarak Denklem 4.13. de tanımlanır:

$$|X(f)|^2 = \left| \sum_{n=-\infty}^{\infty} x(n).e^{-j2\pi fn} \right|^2 \quad (4.13)$$

Durağan olmayan işaretlerde, güç spektrum yoğunluğu (GSY) ile ilgilenilir. N örnekli bir işaretin GSY tahmini için, klasik metot periyodogramdır. Bir işaretin periyodogramı Denklem 4.14. ve 4.15. ile tanımlanmıştır.

$$P_{xx}(f) = \frac{1}{N} \left| \sum_{n=0}^N x(n).e^{-j2\pi fn} \right|^2 \quad (4.14)$$


$$P_{xx}(f) = \frac{1}{N} |X(f)|^2 \quad (4.15)$$

Görüleceği gibi GSY, işaretin enerji spektrumunun ortalamasıdır. GSY veya kısaca güç spektrumu olarak tanımlanan bu denklem, spektral tahminin parametrik olmayan metotlarının temelidir [3].

GSY tahmin etmek için, parametrik ve parametrik olmayan çeşitli metotlar vardır. Parametrik olmayan modern metotlar arasında en popüler olanlar Welch [108] ve çoklu işaret sınıflama (MUSIC-multiple signal classification) yada Eigen Vector (EV) metodu [109] başta gelir.

GSY, veri tahmini, işaret kodlama, işaret tespiti, radar, örüntü tanıma ve karar verici sistemler gibi geniş bir alandaki uygulamalar için önemlidir. Bir işarettaki korelasyon yapısının durumunu ve tekrarlamalı örüntülerin bulunup bulunmadığını tespit etmek şeklindeki karakteristik bilgiler, spektral örüntü tanıma uygulamalarında ilgi çekicidir. Spektral tahmin metotlarının en yaygını HFD tabanlıdır. HFD tabanlı bir çok uygulama yeterince hızlı sonuçlar üretmesine rağmen, spektral tahminin daha avantajlı olan metotları daha iyi frekans çözünürlüğü ve daha küçük değişimleri algılamak için kullanılır.


Şekil 4.5. de durağan bir sinüs ve durağan olmayan bir işaretin Fourier dönüşümü ile GSY tahmini, karşılaştırmalı olarak verilmiştir. Görüleceği üzere durağan sinüs işaretinin gücü tek bir frekans bileşeni etrafında toplanmasına rağmen, durağan olmayan işaretin gücü ise frekans bölgesine yayılmıştır. Böyle bir dağılım, durağan olmayan işaretin yapısı hakkında yeterli karakteristik bilgiyi yansıtmamaktadır. Genellikle, durağan olmayan işaretlerin GSY tahmini için modern yöntemler daha iyi sonuç vermektedir.



Şekil 4.5. Güç spektrumu a) Sinüs işareti, b) Durağan olmayan işaret.

4.2.1. Dalgacık Dönüşümü ve Welch Güç Spektrumu ile Entropi Hesaplanması

Dalgacık dönüşümü ve Welch güç spektrumu ile oluşturulan ZFG bileşenlerinin entropilerine dayalı olarak geliştirilen özellik çıkarım tekniğinin blok diyagramı Şekil 4.6.da verilmiştir.



Şekil 4.6. Dalgacık dönüşümü ve Welch güç spektrumu ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı aşağıda açıklanmıştır:

1. Uygun dalgacık dönüşüm ağaç yapısı ve bu yapının gerektirdiği dalgacık dönüşüm katsayıları Bölüm 3.2.de belirtildiği üzere elde edilir.
2. Her bir dalgacık dönüşüm katsayı işaretinin Welch metodu ile güç spektrumu aşağıda verilen denklemlerle bulunur:

M adet veri örneğinden oluşan her bir dalgacık dönüşüm detay $cD(m)$ ve yaklaşık $cA(m)$ katsayıları N örnek uzunluğunda K adet binişmeli parçalara bölünür. (i) . parça Denklemler 4.16. ile tanımlanır.

$$cD_j^i(m) = cD_j(m + iS), \quad m = 0, 1, \dots, N-1 \quad \text{ve} \quad i = 0, 1, \dots, K-1 \quad (4.16)$$

Burada, S ardışık pencerelerin binişme miktarı olup, $S < N$ olarak seçilip kaydırılmalıdır. Bir $w(m)$ pencere fonksiyon verisi ile pencerelenen i . parçanın periyodogramı Denklem 4.17. de verilmiştir.

$$P_{xx, cD_j}^i(f) = \frac{1}{N.U} \left| \sum_{m=0}^{N-1} w(m).cD_j^i(m).e^{-j2\pi fm} \right|^2 \quad (4.17)$$

Burada U pencere fonksiyonunun gücü olup, Denklem 4.18. de açıklanmıştır.

$$U = \frac{1}{N} \sum_{m=0}^{N-1} w^2(m) \quad (4.18)$$

Pencere fonksiyonunun kenarlarında meydana gelebilecek spektral sızıntıdan dolayı, spektrumun kenarlarındaki spektral güç dağılımında azalma olacaktır. Bu nedenle, Welch güç spektrum yoğunluğu işaretin pencerelenen parçaları ve binişmelerinden elde edilen K adet periyodogramların ortalaması olarak Denklem 4.19. ile tanımlanır.

$$P_{xx, cD_j}(f) = \frac{1}{K} \sum_{i=0}^{K-1} P_{xx, cD_j}^i(f) \quad (4.19)$$

Buna göre, M adet veri örneğinden oluşan dalgacık katsayı işaretlerinin Welch GSY'sini oluşturan parça sayısı veya GSY değerlerinin sayısı:

$$K = \left\lfloor \frac{M - S}{N - S} \right\rfloor \quad (4.20)$$

Benzer şekilde dalgacık dönüşüm yaklaşık cA katsayı işareti içinde Welch GSY değerleri hesaplanır.

3. Dalgacık ağacı üzerinde bulunan katsayı işaretlerinin, Welch güç spektrum ZFG dalga şekillerini oluşturan her bir bileşenin entropi değerleri Bölüm 2.3.2.de belirtilen entropi yöntemleri kullanılarak hesaplanabilir. Denklem 4.21. ve 4.22. de Logaritmik Enerji entropi hesaplama tekniği kullanılarak entropi çıkarım denkleminin uyarlaması gösterilmiştir.

$$Ed_j = \sum_n \log_2(P_{xx, cD_j}^2[n]) \quad (4.21)$$

$$Ea_m = \sum_n \log_2 (P_{xx, cA_m}^2 [n]) \quad (4.22)$$

Burada m dalgacık dönüşüm ağaç seviyesini göstermekte olup, $j = 1, 2, \dots, m$ dir.


- Özellik vektörü: Dalgacık dönüşüm katsayılarının Welch güç spektrum ZFG 'sini oluşturan işaretlerin her birinin entropi değerinin hesaplanmasından oluşmuş işarete ait betimleyici özellik vektörü:

$$V = [Ed_1, Ed_2, \dots, Ed_j, Ea_m] \quad (4.23)$$

elde edilir.

4.2.2. Dalgacık Paket Dönüşümü ve Welch Güç Spektrumu ile Entropi Hesaplanması

Dalgacık paket dönüşümü ve Welch güç spektrumu ile oluşturulan ZFG bileşenlerinin entropilerine dayalı olarak geliştirilen özellik çıkarım tekniğinin blok diyagramı Şekil 4.7.de verilmiştir.



Şekil 4.7. Dalgacık dönüşümü ve Welch güç spektrumu ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı aşağıda açıklanmıştır:

- Uygun dalgacık paket dönüşüm ağaç yapısı ve bu yapının uç yapraklarındaki dalgacık paket dönüşüm katsayıları Bölüm 3.3.de belirtildiği üzere elde edilir.
- Her bir yaprak dalgacık paket dönüşüm katsayı işaretinin Welch metodu ile güç spektrumu Bölüm 4.2.1. deki çözüm ışığında, aşağıda verilen denklemlerle bulunur:

$$P_{xx, cD_{j,m}}(f) = \frac{1}{K} \sum_{i=0}^{K-1} P_{xx, cD_{j,m}}^i(f) \quad (4.24)$$

$$P_{xx, cA_{j,m}}(f) = \frac{1}{K} \sum_{i=0}^{K-1} P_{xx, cA_{j,m}}^i(f) \quad (4.25)$$

Burada $j = 1, 2, \dots, 2^{m-1}$ dalgacık paket dönüşüm katsayı işaretlerini göstermektedir.

3. Dalgacık paket ağacının uç yapraklarında bulunan katsayı işaretlerinin Welch güç spektrum ZFG dalga şekillerinin entropi değerleri Bölüm 2.3.2.de belirtilen entropi yöntemleri kullanılarak hesaplanabilir. Denklem 4.26. ve 4.27. da Logaritmik Enerji entropi hesaplama tekniği kullanılarak entropi çıkarım denkleminin uyarlaması gösterilmiştir.

$$Ed_{j,m} = \sum_n \log_2 (P_{xx,cD_{j,m}}^2[n]) \quad j=1,2,\dots,2^{m-1} \quad (4.26)$$

$$Ea_{j,m} = \sum_n \log_2 (P_{xx,cA_{j,m}}^2[n]) \quad j=1,2,\dots,2^{m-1} \quad (4.27)$$


4. Özellik vektörü: m . seviye dalgacık paket dönüşüm katsayılarının Welch güç spektrum ZFG 'sini oluşturan işaretlerin entropi değerlerinin hesaplanmasından oluşmuş işarete ait betimleyici özellik vektörü:

$$V = [Ed_{1,m}, Ea_{1,m}, \dots, Ed_{2^{m-1},m}, Ea_{2^{m-1},m}] \quad (4.28)$$

elde edilir.

4.2.3.Dalgacık Dönüşümü ve MUSIC Güç Spektrumu ile Entropi Hesaplanması

Dalgacık dönüşümü ve MUSIC güç spektrumu ile oluşturulan ZFG bileşenlerinin entropilerine dayalı olarak geliştirilen özellik çıkarım tekniğinin blok diyagramı Şekil 4.8.de verilmiştir.



Şekil 4.8. Dalgacık dönüşümü ve MUSIC güç spektrumu ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı aşağıda açıklanmıştır:

1. Uygun dalgacık dönüşüm ağaç yapısı ve bu yapının gerektirdiği dalgacık dönüşüm katsayıları Bölüm 3.2.de belirtildiği üzere elde edilir.
2. Her bir dalgacık dönüşüm katsayı işaretinin MUSIC metodu ile güç spektrumu aşağıda verilen denklemlerle bulunur:

MUSIC algoritması, beyaz gürültü içine gömülen durağan olmayan işaretlerin frekanslarını tahmin etmek için EV tabanlı bir alt yüzey ayrışımıdır. Bu metot da, durağan olmayan işaretler durağan sinüzoidallerin toplamı şeklinde modellenerek bir matris problemi olarak formüle edilir. Bu matrisin çözümü ile, Eigen değerleri doğrudan hesaplanır. Buna göre dalgacık dönüşüm katsayı işaretleri $x = [cD, cA]$ beyaz gürültü ile aşağıdaki gibi modellenir.

$$y = x + n = Sa + n \quad (4.29)$$

$$y(m) = \sum_{k=1}^P A_k \cdot e^{-j(2\pi F_k m + \phi_k)} + n(m) \quad (4.30)$$

Burada, gürültü N örnekli bir vektör ile $y = [y(m), \dots, y(m+N-1)]$ gösterilmektedir. Dalgacık dönüşüm katsayı işaret vektörü ise, $x = Sa$ ile Denklem 4.31. de gösterildiği gibi tanımlanmaktadır. P ise alt yüzey ayrışım sayısıdır.

$$\begin{bmatrix} x(m) \\ x(m+1) \\ \vdots \\ x(m+N-1) \end{bmatrix} = \begin{bmatrix} e^{j2\pi F_1 m} & e^{j2\pi F_2 m} & \dots & e^{j2\pi F_P m} \\ e^{j2\pi F_1 (m+1)} & e^{j2\pi F_2 (m+1)} & \dots & e^{j2\pi F_P (m+1)} \\ \vdots & \vdots & \ddots & \vdots \\ e^{j2\pi F_1 (m+N-1)} & e^{j2\pi F_2 (m+N-1)} & \dots & e^{j2\pi F_P (m+N-1)} \end{bmatrix} \begin{bmatrix} A_1 \cdot e^{j2\pi \phi_1} \\ A_2 \cdot e^{j2\pi \phi_2} \\ \vdots \\ A_P \cdot e^{j2\pi \phi_P} \end{bmatrix} \quad (4.31)$$

Denklem 4.29. gürültü işaretinin oto-korelasyon matrisi (y), gürültü (n) ve dalgacık katsayı işaretlerinin oto-korelasyon matrisleri toplamı şeklinde Denklem 4.32.de yazılmıştır.

$$R_{yy} = R_{xx} + R_{nn} \quad (4.32)$$

$$R_{xx} = \sum_{k=1}^P P_k \cdot S_k \cdot S_k^H \quad (4.33)$$

Burada, $P_i = A_i^2$ dalgacık dönüşüm katsayı işaretlerinin gücü, $S_k^H = [1, e^{j2\pi F_k}, \dots, e^{j2\pi (N-1)F_k}]$, dalgacık dönüşüm katsayı işaretlerinin oto-korelasyon matrislerinin Hermitian dönüşümünü (H) göstermektedir. Denklem 4.34. de R_{xx} korelasyon matrisinin Eigen ayrışımı verilmiştir.

$$R_{xx} = \sum_{k=1}^P \lambda_k \cdot V_k \cdot V_k^H \quad (4.34)$$


Burada, λ_k ve V_k gösterilen R_{xx} matrisinin Eigen değerleri ve Eigen vektörüdürler. Gürültü işaretinin oto-korelasyon matrisi ise :

$$R_{nn} = \sigma_n^2 \cdot \sum_{k=1}^N V_k \cdot V_k^H \quad (4.35)$$

$$R_{yy} = \sum_{k=1}^P \lambda_k \cdot V_k \cdot V_k^H + \sigma_n^2 \cdot \sum_{k=1}^N V_k \cdot V_k^H \quad (4.36)$$

$$R_{yy} = \sum_{k=1}^P \lambda_k \cdot V_k \cdot V_k^H + \sigma_n^2 \cdot \sum_{k=1}^N V_k \cdot V_k^H \quad (4.37)$$

Denklem 4.37. den, gürültü işaretinin korelasyon matrisinin Eigen vektörleri ve Eigen değerleri Şekil 4.9. da gösterildiği gibi iki kısma ayrılabilir. Eigen vektörler kümesi $[V_1, V_2, \dots, V_P]$ dalgacık dönüşüm katsayı işaretinin Eigen değerleri olup, ana Eigen vektörleri olarak isimlendirilirler. Dalgacık katsayı işaret vektörü S_i , ana Eigen vektörlerinin doğrusal birleşimi olarak ifade edilebilir. Gürültü işaretine ait $[V_{P+1}, V_{P+2}, \dots, V_N]$ ise, ikinci Eigen vektörler kümesi olup, onun Eigen değerleri olarak σ_n^2 'a sahiptirler.



Şekil 4.9. Eigen değerlerinin ayrışımı.

$$S_i^H(f).V_k = \sum_{m=0}^{N-1} V_k(m).e^{-j2\pi F_i m} = 0 \quad i = 1, \dots, P \quad k = P+1, \dots, N \quad (4.38)$$

Denklem 4.38. çözüldüğünde, dalgacık dönüşüm katsayı işaretinin frekansları Denklem 4.39. da gösterildiği gibi elde edilir.

$$\sum_{k=P+1}^N S^H(f).V_k \quad (4.39)$$

MUSIC algoritmasında güç spektrumu aşağıdaki gibi tanımlanır :

$$P_{xx}(f) = \sum_{k=P+1}^N |S^H(f).V_k|^2 \quad (4.40)$$

Burada, $S_k^H = [1, e^{j2\pi F_k}, \dots, e^{j2\pi(N-1)F_k}]$ dalgacık dönüşüm katsayı işaretinin karmaşık sinüzoidal vektörlerdir ve $[V_{P+1}, \dots, V_N]$ ise gürültü işaretinin Eigen değerleridir.

$$P_{xx}(f_i) = 0, \quad i = 1, \dots, P \quad (4.41)$$

Denklem 4.34. ve 4.41. den dalgacık katsayı işaretlerinin MUSIC güç spektrum yoğunluğu çıkarılır:

$$P_{xx, cD_j}(f) = \frac{1}{\sum_{k=P+1}^N |S^H(f).V_k|^2} = \frac{1}{S^H(f).V(f).V^H(f).S(f)} \quad (4.42)$$

$$P_{xx, cA_m}(f) = \frac{1}{\sum_{k=P+1}^N |S^H(f).V_k|^2} = \frac{1}{S^H(f).V(f).V^H(f).S(f)} \quad (4.43)$$

Burada $j = 1, \dots, m$ dalgacık dönüşüm katsayılarının ayrışım seviyelerini göstermektedir.

3. Dalgacık dönüşüm ağacını oluşturan katsayı işaretlerinin MUSIC güç spektrum ZFG dalga şekillerinin entropi değerleri Bölüm 2.3.2.de belirtilen entropi yöntemleri kullanılarak hesaplanabilir. Denklem 4.44. ve 4.45. de Shannon entropi hesaplama tekniği kullanılarak entropi çıkarım denkleminin uyarlaması yapılmıştır.

$$Ed_j = -\sum_n \left(P_{xx,cD_j}[n] \right)^2 \cdot \log_2 \left(P_{xx,cD_j}[n] \right)^2 \quad j = 1, 2, \dots, m \quad (4.44)$$

$$Ea_m = -\sum_n \left(P_{xx,cA_m}[n] \right)^2 \cdot \log_2 \left(P_{xx,cA_m}[n] \right)^2 \quad (4.45)$$


4. Özellik vektörü: Dalgacık dönüşüm ve MUSIC güç spektrum ZFG işaretlerinin entropi değerlerinin hesaplanmasından oluşmuş işarete ait betimleyici özellik vektörü:

$$V = [Ed_1, Ed_2, Ed_3, \dots, Ed_m, Ea_m] \quad (4.46)$$

elde edilir.

4.2.4. Dalgacık Paket Dönüşüm ve MUSIC Güç Spektrumu ile Entropi Hesaplanması

Dalgacık paket dönüşümü ve MUSIC güç spektrumu ile oluşturulan ZFG bileşenlerinin entropilerine dayalı olarak geliştirilen özellik çıkarım tekniğinin blok diyagramı Şekil 4.10'da verilmiştir.



Şekil 4.10. Dalgacık paket dönüşümü ve MUSIC güç spektrumu ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı aşağıda açıklanmıştır:

1. Uygun dalgacık paket dönüşüm ağaç yapısı ve bu yapının uç yapraklarındaki dalgacık paket dönüşüm katsayıları Bölüm 3.3.de belirtildiği üzere elde edilir.
2. m. seviyedeki her bir yaprak dalgacık paket dönüşüm katsayı işaretinin MUSIC metodu ile güç spektrumu Bölüm 4.2.3. deki çözüm ışığında, aşağıda verilen denklemlerle bulunur:

$$P_{xx,cD_j,m}(f) = \frac{1}{\sum_{k=P+1}^N |S^H(f).V_k|^2} = \frac{1}{S^H(f).V(f).V^H(f).S(f)} \quad (4.47)$$

$$P_{xx,cA_j,m}(f) = \frac{1}{\sum_{k=P+1}^N |S^H(f).V_k|^2} = \frac{1}{S^H(f).V(f).V^H(f).S(f)} \quad (4.48)$$

Burada $j = 1, \dots, 2^{m-1}$ dalgacık paket dönüşüm katsayılarının numaralarını göstermektedir.

3. Dalgacık paket dönüşüm ağacını uç yapraklarında bulunan katsayı işaretlerinin MUSIC güç spektrum ZFG dalga şekillerinin entropi değerleri Bölüm 2.3.2.de belirtilen entropi yöntemleri kullanılarak hesaplanabilir. Denklem 4.49. ve 4.50. de Shannon entropi hesaplama tekniği kullanılarak entropi çıkarım denkleminin uyarlaması yapılmıştır.

$$Ed_{j,m} = -\sum_n \left(P_{xx,cD_{j,m}}[n] \right)^2 \cdot \log_2 \left(P_{xx,cD_{j,m}}[n] \right)^2 \quad j = 1, 2, \dots, 2^{m-1} \quad (4.49)$$

$$Ea_{j,m} = -\sum_n \left(P_{xx,cA_{j,m}}[n] \right)^2 \cdot \log_2 \left(P_{xx,cA_{j,m}}[n] \right)^2 \quad j = 1, 2, \dots, 2^{m-1} \quad (4.50)$$

4. Özellik vektörü: Dalgacık paket dönüşüm ve MUSIC güç spektrum ZFG işaretlerinin, entropi değerlerinin hesaplanmasından oluşmuş işarete ait betimleyici özellik vektörü:

$$V = [Ed_{1,m}, Ea_{1,m}, \dots, Ed_{2^{m-1},m}, Ea_{2^{m-1},m}] \quad (4.51)$$

elde edilir.


Geliştirilen bu özellik çıkarım algoritmalarının uygulamaları ve başarımları Bölüm 7. de verilmiştir.

BÖLÜM 5

5. PARAMETRİK ZAMAN-FREKANS GÖSTERİM ENTROPİLERİ İLE ÖZELLİK ÇIKARMA

Parametrik veya model tabanlı olarak bilinen yöntemler, zaman–frekans gösterimine bir modelleme problemi olarak yaklaşmaktadırlar. Bu yöntemlerde, veri için uygun model ve derecesinin secimi önemli bir konudur [95]. Örneğin, belirli bir aralıktaki işaretlere model uydurmak için sinüzoidallerin toplamı gibi. Uygun olmayan model ve derece seçimi verinin uygun modellenememesine sebep olacaktır ve bu durum ardışık etkileşim ile büyük bir hataya yol açabilir. Böylece elde edilen frekans spektrumunda, bazı piklerin kaybolması ve gerçekte olmayan bazı piklerin de ortaya çıkması görülebilir [110].

Parametrik modellerin hepsi veriyi durağan kabul eder [32]. Böylece durağan olmayan zaman serileri durağan olarak kabul edildiği bölümlere ayrıştırılması gerekmektedir. İşaret işleme teorilerinde durağanlık, dar anlamda durağan ve geniş anlamda durağanlık olmak üzere iki farklı şekilde tanımlanmaktadır. Parametrik yöntemlerle, durağan olmayan işaretlerin analizi yapıldığında, model derecesinin seçiminin oldukça önemli olduğu vurgulanmıştır. Bu bağlamda, durağan olmayan işaretlerin, geniş anlamda durağan işaret türlerinde düşük model derecesi (1 veya 2 gibi) seçimi önerilirken, dar anlamda durağan işaret türleri için daha büyük model derecesi ile spektral tahmin yapılması önerilmektedir [3]. Şekil 5.1. de görüleceği üzere, bu yöntemlerde durağan olmayan işaret, durağan bir işaret ile modellenerek zamanla değişen bir işaret modeli elde edilmektedir.



Şekil 5.1. Durağan olmayan işaretleri modelleme.

Durağan olmayan işaretlerin analizinde, parametrik yöntemler, özellikle yüksek frekans seçiciliklerinden dolayı parametrik olmayan yöntemlere göre daha uygun olarak değerlendirilmektedirler [20,111].

5.1. Model Tabanlı Güç Spektrum Yoğunluğu

Parametrik spektral analizde, fiziksel dünyada karşılaşılan bir çok işaret süreci, sonlu parametrelere sahip bir rasyonel fonksiyon ile modellenenebilir. Bu modellerin parametreleri uygun bir metot kullanılarak hesaplanır. Kullanılan modelin spektral özellikleri bilinme noktasından hareketle, modellenen sürecin spektral özellikleri elde edilmiş olur. Bu yöntemlerde, parametrik spektral analiz, bir modelleme problemine dönüşmüştür. Böylece hesaplanması gereken model parametrelerinin sayısının bilgi örneklerinden daha az olması, hem zaman ve hem de işlem yükü açısından analizde üstünlük sağlar. Ayrıca model tabanlı spektral tahmin ediciler, periyodogramlardan daha iyi çözünürlüğe sahiptirler [3].

Denklem 5.1.de kullanılabilir işaret verisinin rasyonel bir fonksiyonla modeli verilmiştir.

$$x(m) = \sum_{k=1}^P a_k \cdot x(m-k) + \sum_{k=0}^Q b_k \cdot e(m-k) \quad (5.1)$$

Burada, $x(m)$ model çıkışıdır, $e(m)$ giriş, a_k ve b_k model parametreleridir. Denklem 5.1. ARMA (Autoregressive Moving Avarage) modeli olarak bilinir. Bu model sisteminin transfer fonksiyonu $H(z)$, Denklem 5.2. deki gibi verilir.

$$H(z) = \frac{B(z)}{A(z)} = \frac{\sum_{k=0}^Q b_k \cdot z^{-k}}{1 - \sum_{k=0}^P a_k \cdot z^{-k}} \quad (5.2)$$

Burada, $1/A(z)$ ve $B(z)$, ARMA modelinin iki özel durumu olan AR ve MA kısımlarını göstermektedirler. Buna göre $x(m)$ model çıkış işaretinin güç spektrumu, giriş işaretinin güç spektrumu ve modelin frekans cevabından üretilir:

$$P_{xx}(f) = P_{EE}(f) |H(f)|^2 \quad (5.3)$$


Burada, $H(f)$ modelin frekans cevabını ve $P_{EE}(f)$ giriş işaretinin güç spektrumu göstermektedir. Giriş beyaz bir gürültü süreci olarak kabul edildiğinden, güç spektrumu sabittir, yani $P_{EE}(f) = 1$ olur.

$$P_{xx}(f) = |H(f)|^2 \quad (5.4)$$

Sonuç olarak, model çıkışının güç spektrumu, modelin frekans cevabının karesel büyüklüğüdür. Model tabanlı spektrum tahmin edicilerde en önemli gösterge modelin seçimidir. Bu ise modellenmesi istenen işaret ile ilgili bazı ön bilgilerin bilinmesini gerektirir. Örneğin GSY işareti keskin tepeler içeren bir işaret ise, MA (sadece sıfırların dağılımı) tipi model ile modellenemez. Böyle bir işaretin modellenmesi için AR (sadece kutupların dağılımı) tipi modellerin seçilmesi daha uygundur. Eğer işaretin spektral özellikleri ile ilgili ön bilgi yeterince yoksa, bu durumda parametreleri işaretin özelliklerine göre değişebilen zamana bağlı modeller veya GSY 'si hem düzlük ve hem de tepe değerleri içeren işaretleri modelleyebilen ARMA tipi modeller kullanılır [20].

5.1.1. Dalgacık Dönüşümü ve AR Modeli ile Entropi Hesaplanması

Geliştirilen dalgacık dönüşümü ve AR modeli ile oluşturulan ZFG bileşenlerinin entropilerine dayalı özellik çıkarım tekniğinin, blok diyagramı Şekil 5.2.de verilmiştir.



Şekil 5.2. Dalgacık dönüşümü ve AR modeli ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı aşağıda açıklanmıştır:

1. Uygun dalgacık dönüşüm ağaç yapısı ve bu yapının gerektirdiği dalgacık dönüşüm katsayıları Bölüm 3.2.de belirtildiği üzere elde edilir.
2. Her bir dalgacık dönüşüm katsayı işaretinin AR modelinin bulunması: Durağan olmayan işaretlerin modellenmesinde en yaygın kullanıma sahip parametrik model olan AR modeli, her bir dalgacık dönüşüm seviyesi için belirli bir zaman aralıklı işaret veri değerleri, bir beyaz gürültü terimi $w(n)$ ve p ön veri değerleri ile Denklem 5.5. deki gibi tahmin edilir.

$$x[n] = -\sum_{k=1}^p a_k \cdot x[n-k] + w[n] \quad (5.5)$$

Burada $x[n]$ modelin zaman örneklerini, a_k AR model tipinin parametreleri, p model derecesini belirtmekte olup, bu modele de AR(p) ismi verilir. Bu modele ait giriş işareti $w(n)$ ile çıkış işareti $x(n)$ arasındaki transfer fonksiyonunun karesi ile elde edilmiş AR modelinin güç spektrumu Denklem 5.6.da görülmektedir.

$$P_{xx}(f) = \left| H(e^{j2\pi f}) \right|^2 = \frac{\sigma^2}{\left| 1 - \sum_{k=1}^p a_k e^{-j2\pi f k} \right|^2} \quad (5.6)$$

Burada, AR(p) modelinin güç spektrum yoğunluğunu hesaplayabilmek için p adet model parametresi ile beyaz gürültü varyansı σ^2 'nin hesaplanması gerekmektedir. Bu parametrelerin hesaplanması için ya doğrudan veri alanı örnekleri ya da bu veri alanına ait öz ilişki fonksiyon örnekleri kullanılır. Literatürde her iki yönteme de yönelik algoritmalar bulunmakla birlikte, bunların en önemlileri : Yule-Walker, Levinson ve Burg [16,59]. Geliştirilen özellik çıkarımında, Yule – Walker denklem eşitlikleri [112,113] kullanılarak bu parametreler belirlenmiştir. Yule – Walker AR model tahmini için Denklem 5.7. deki eşitlikler kullanılarak model parametreleri bulunmuştur.

$$\begin{bmatrix} r(1) & r(2) & \dots & r(p) \\ r(2) & r(1) & \dots & r(p-1) \\ \vdots & \vdots & \ddots & \vdots \\ r(p) & r(p-1) & \dots & r(1) \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} -r(2) \\ -r(3) \\ \vdots \\ -r(p+1) \end{bmatrix} \quad (5.7)$$

$$r(j) = \sum_{k=1}^p a_k r(j-k) \quad (5.8)$$

$$\sigma^2 = r(0) - \sum_{k=1}^p a_k r(k) \quad (5.9)$$

Burada, $a = [1, a(2), \dots, a(p+1)]$ otoregresif parametre vektörü, $r = [r(1), r(2), \dots, r(p+1)]$ vektör bileşenlerinin korelasyonları ve soldaki otokorelasyon matris ise Hermitian dönüşüm matrisidir. Her bir dalgacık dönüşüm seviyesi için elde edilen işaret katsayılarının Yule-Walker AR model güç spektrum ZFG bileşenleri aşağıdaki denklemlerle elde edilir:

$$P_{xx,cD_i}(f) = \frac{\sigma^2}{\left| 1 - \sum_{k=1}^p a_k \cdot e^{-j2\pi f k} \right|^2} \quad (5.10)$$

$$P_{xx,cA_m}(f) = \frac{\sigma^2}{\left| 1 - \sum_{k=1}^p a_k \cdot e^{-j2\pi f k} \right|^2} \quad (5.11)$$

Burada $i = 1, 2, \dots, m$ dalgacık dönüşüm katsayılarının seviyelerini göstermektedir.

3. ZFG 'yi oluşturan her bir bileşenin entropi değerleri Bölüm 2.3.2.de belirtilen entropi yöntemleri kullanılarak hesaplanabilir. Denklem 5.12. ve 5.13. de Norm entropi hesaplama tekniği kullanılarak entropi çıkarım denkleminin uyarlaması yapılmıştır.

$$Ed_i = \sum_n |P_{xx,cD_i}[n]|^p \quad (5.12)$$

$$Ea_m = \sum_n |P_{xx,cA_m}[n]|^p \quad (5.13)$$

Burada $1 \leq p < 2$ ve $i = 1, 2, \dots, m$ dir.


4. Özellik vektörü: m seviyeli dalgacık dönüşüm işaret katsayılarının Yule-Walker AR model ZFG entropi değerlerinin hesaplanmasından oluşmuş işarete ait betimleyici özellik vektörü:

$$V = [Ed_1, Ed_2, \dots, Ed_m, Ea_m] \quad (5.14)$$

elde edilir.

5.1.2. Dalgacık Paket Dönüşümü ve AR Modeli ile Entropi Hesaplanması

Geliştirilen dalgacık paket dönüşümü ve AR modeli ile oluşturulan ZFG bileşenlerinin entropilerine dayalı özellik çıkarım tekniğinin, blok diyagramı Şekil 5.3.de verilmiştir.



Şekil 5.3. Dalgacık paket dönüşümü ve AR modeli ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı aşağıda açıklanmıştır:

1. Uygun dalgacık paket dönüşüm ağaç yapısı ve bu yapının en son ayrışım seviyesinde bulunan uç yaprak dalgacık paket dönüşüm katsayı işaretleri Bölüm 3.3.de belirtildiği biçimde elde edilir.
2. En son seviye (m) dalgacık paket dönüşüm ayrışımındaki, her bir uç yaprak katsayı işaretinin AR modeli Bölüm 5.1.1. de gösterildiği gibi hesaplanır.

$$P_{xx,cD_{i,m}}(f) = \frac{\sigma^2}{\left| 1 - \sum_{k=1}^p a_k \cdot e^{-j2\pi f k} \right|^2} \quad (5.15)$$

$$P_{xx,cA_{i,m}}(f) = \frac{\sigma^2}{\left| 1 - \sum_{k=1}^p a_k \cdot e^{-j2\pi f k} \right|^2} \quad (5.16)$$

Burada $i = 1, 2, \dots, 2^{m-1}$, m . seviye dalgacık paket dönüşüm uç yaprak katsayı işaretlerini göstermektedir.

3. ZFG 'yi oluşturan her bir bileşenin entropi değerleri Bölüm 2.4.2.de belirtilen entropi yöntemleri kullanılarak hesaplanabilir. Denklem 5.17. ve 5.18. de Sure entropi hesaplama tekniği kullanılarak entropi çıkarım denkleminin uyarlaması yapılmıştır.

$$\left| P_{xx,cD_{i,m}}[n] \right| \leq \epsilon \Rightarrow Ed_{i,m} = \sum_n \min(P_{xx,cD_{i,m}}^2[n], \epsilon^2) \quad (5.17)$$

$$\left| P_{xx,cA_{i,m}}[n] \right| \leq \epsilon \Rightarrow Ea_{i,m} = \sum_n \min(P_{xx,cA_{i,m}}^2[n], \epsilon^2) \quad (5.18)$$

Burada ε pozitif bir eşikleme değeri, $i = 1, 2, \dots, 2^{m-1}$, m . seviye dalgacık paket dönüşüm uç yaprak katsayı işaretlerini göstermektedir.

4. Özellik vektörü: m . seviye dalgacık paket dönüşümünün uç yaprak işaret katsayılarının Yule-Walker AR model ZFG entropi değerlerinin hesaplanmasından oluşmuş işarete ait betimleyici özellik vektörü:

$$V = [Ed_{1,m}, Ea_{1,m}, Ed_{2,m}, Ea_{2,m}, \dots, Ed_{2^{m-1},m}, Ea_{2^{m-1},m}] \quad (5.19)$$

elde edilir.


Geliştirilen bu özellik çıkarım algoritmalarının uygulamaları ve başarımları Bölüm 7. de verilmiştir.

BÖLÜM 6

6. GELİŞTİRİLEN DALGACIK SİNİR AĞ MODELLERİ İLE ADAPTİF ÖZELLİK ÇIKARMA VE SINIFLAMA

Yapay sinir ağları, insan beyninin organizasyonuna benzetilmeye çalışılmış güncel bilgi işleme yapılarıdır. YSA yapılarından ötürü, iyi bir örüntü eşleştiricisi, sınıflandırıcısı ve veri kümeleyicisidirler. Dalgacık sinir ağları (DSA) ise, YSA 'ların karar yapıları ile dalgacık dönüşümünün özellik çıkarma ve seçme yeteneklerini birleştirir [114]. Örüntü sınıflama için, dalgacık dönüşüm temelli olarak yapılandırılan dalgacık sinir ağları, ileri beslemeli YSA 'lara alternatiftirler. DSA, ileri beslemeli YSA nın özel bir türü olarak ta yorumlanmaktadır [115].

Dalgacık dönüşüm temelli olan DSA 'ların yapısı Şekil 6.1. de verilmiştir [116,117]. Bu YSA yapısının çıkış Denklemi 6.1.de tanımlanmıştır.



Şekil 6.1. Dalgacık sinir ağı yapısı.

$$y = F\left(\sum_{k=1}^m w_k \cdot \sum_{t=1}^n x(t) \cdot \psi\left(\frac{t-t_k}{2^k}\right)\right) \quad (6.1)$$


Burada, t_k ve 2^k parametreleri, dalgacık fonksiyonlarının Ψ genişleme ve kayma durumunu, w_k çok katmanlı algılayıcıda bulunan ağırlık değerlerini ve $F(.)$ ise çıkışı belirli aralıklara çekme de kullanılan etkinleştirme fonksiyonunu göstermektedir. DSA 'nın ağırlık parametreleri hata geri

yayınım türü bir algoritma ile ayarlanır [117]. Bu yapının avantajı giriş değerine çok farklı perspektiften bakma imkanı tanınmasıdır. Fakat bunun yanı sıra, aynı giriş verisini birden çok kez kullandığı için YSA 'nın işlem yükü fazladır. DSA nın çeşitli alanlarda uygulamaları bulunmaktadır. Bunlardan bazıları; kroner arter hastalıklarını sınıflama [118], protez kalp kapaklarının karakteristik durumlarını belirleme [119], biyo-işaretleri sınıflama [114], Radar hedef sınıflama [116], zaman serilerinin tahmini [120] gibi.

Tezin bu bölümünde, durağan olmayan işaret örüntülerini tanımak için, dalgacık dönüşüm yapısına entropi kavramı ilave edilerek iki farklı yeni dalgacık sinir ağı modeli geliştirilmiştir. Bu modellerde, örüntü tanımada kilit rolü oynayan özellik çıkarımı, sınıflayıcının başarımına bağlı olarak adaptif bir şekilde ayarlanabilmektedir. Bu adaptif yapı, entropi hesaplama tekniğinin parametrelerine müdahale edilerek sağlanmıştır. Ayrıca geliştirilen yapılarda, özellik çıkarım süreci YSA sınıflayıcısının içerisine gömülmüş ve doğrudan sınıflayıcının eğitim performansını etkilemektedir. Geliştirilen yapılarda, entropiye dayalı özellik çıkarım tekniği ile giriş işaretinin boyutu indirgenerek sınıflayıcının işlem yükü azaltılmış ve gerçek zamanlı çıkış üretme başarımına katkıda bulunulmuştur.

6.1. Dalgacık Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama


Örüntü tanımak için geliştirilen, yeni dalgacık sinir ağı (DSA) modeli Şekil 6.2. de görülmektedir. Bu model, dalgacık dönüşüm, entropi hesaplama ve çok katmanlı algılayıcı tabanlıdır.



Şekil 6.2. Örüntü tanımak için geliştirilen DSA yapısı.

Geliştirilen yeni DSA modelinin eğitim algoritmasının akış şeması Şekil 6.3. de verilmiştir. Bu algoritmanın her bir aşamasının işleyişi aşağıda adımlar halinde sunulmuştur:


1. adım : Tüm ağırlıklar (w), seçilen etkinleştirme fonksiyonları $f(.)$ üzerinden Nguyen-Widrow metoduna [121] göre hesaplanarak öğrenme sürecinin hızlı olmasına katkıda bulunulur.
2. adım : Dalgacık ayrışım seviyesi (m), Denklem 3.2. de belirtilen kritere göre seçilir.
3. adım : Giriş işaretlerine $x_i = (x_1, x_2, \dots, x_n)$ karşın istenen çıkışlar $d_i = (d_1, d_2, \dots, d_m)$ belirlenir.
4. adım : Dalgacık filtreleri ψ , ayrışım seviyelerine göre ayarlanarak dalgacık dönüşüm katsayı işaretleri (cD, cA) elde edilir.
5. adım : Bölüm 2.3.2.de verilen entropi yöntemleri ile dalgacık dönüşüm katsayı işaretlerinin entropi değerleri, entropi parametresine (p) bağlı olarak hesaplanır.
6. adım : Elde edilen entropi değerleri $E = [Ed_1, Ed_2, \dots, Ed_m, Ea_m]$ ile çok katmanlı algılayıcının gerçek çıkışları (y) hesaplanır.
7. adım : Tüm giriş işaret örnekleri için E toplam karesel hata değeri bulunur. Bu değer istenen toplam karesel hatadan (sse) küçük değilse, çok katmanlı algılayıcı kısmında bulunan ağırlıklar hata geri yayılım öğrenme kuralına [122] göre ayarlanır.
8. adım : DSA 'nın eğitim döngüsü, verilen ED döngü değerini aşmış ve E hata değeri sse 'den hala büyükse, entropi parametresi değiştirilip, özellik çıkarım sürecine (5.adım) tekrar dönülerek özellikler uyarlanır.



Şekil 6.3. DSA eğitim algoritması.

6.2. Dalgacık Paket Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama

Örüntü tanımak için ikinci bir model olarak geliştirilen, yeni dalgacık paket sinir ağı (DPSA) yapısı Şekil 6.4.de görülmektedir. Bu yapıda da görüleceği üzere, örüntü tanımadaki anahtar görevi üstlenen özellik çıkarma süreci, sınıflayıcının başarımına bağlı olarak adaptif bir şekilde ayarlanabilmektedir.




Şekil 6.4. Örüntü tanımak için geliştirilen DPSA yapısı.

Geliştirilen yeni DPSA modelinin eğitim algoritmasının akış şeması Şekil 6.5.de verilmiştir. Bu algoritmanın her bir aşamasının işleyişi aşağıda adımlar halinde sunulmuştur:

1. adım : Tüm ağırlıklar (w), seçilen etkinleştirme fonksiyonları $f(.)$ üzerinden Nguyen-Widrow metoduna [121] göre hesaplanarak öğrenme sürecinin hızlı olmasına katkıda bulunulur.
2. adım : Dalgacık paket ayrışım seviyesi (m), Denklem 3.2. de belirtilen kritere göre seçilir.

- 3. adım :** Giriş işaretlerine $x_i = (x_1, x_2, \dots, x_n)$ karşın istenen çıkışlar $d_i = (d_1, d_2, \dots, d_m)$ belirlenir.
- 4. adım :** Dalgacık paket filtreleri ψ , en son ayrışım seviyesine göre ayarlanarak uç yaprak dalgacık paket dönüşüm katsayı işaretleri (cD, cA) elde edilir.
- 5. adım :** Bölüm 2.3.2.de verilen entropi yöntemleri ile dalgacık dönüşüm katsayı işaretlerinin entropi değerleri, entropi parametresine (ϵ) bağlı olarak hesaplanır.
- 6. adım :** Elde edilen entropi değerleri $E = [Ed_1, Ea_1, Ed_2, Ea_2, \dots, Ed_{2^{m-1}}, Ea_{2^{m-1}}]$ ile çok katmanlı algılayıcının gerçek çıkışları (y) hesaplanır.
- 7. adım :** Tüm giriş işaret örnekleri için E toplam karesel hata değeri bulunur. Bu değer istenen toplam karesel hatadan (sse) küçük değilse, çok katmanlı algılayıcı bileşeninde bulunan ağırlıklar hata geri yayılım öğrenme kuralına [122] göre ayarlanır.
- 8. adım :** DPSA 'nın eğitim döngüsü, verilen ED döngü değerini aşmış ve E hata değeri sse 'den hala büyükse, entropi parametresi değiştirilip, özellik çıkarım sürecine (5.adım) tekrar dönülerek özellikler uyarlanır.

Geliştirilen bu yeni dalgacık sinir ağı modellerinin, örüntü tanıma uygulamalarındaki başarımları Bölüm 7. de verilmiştir.




Şekil 6.5. DPSA eğitim algoritması.

BÖLÜM 7

7. GELİŞTİRİLEN YÖNTEMLERİN DOPPLER KALP İŞARETLERİNE UYGULANMASI


Bu bölümde, özellik çıkarımı için geliştirilen yöntemlerin durağan olmayan Doppler işaretlerine uygulaması yapılmıştır. Ayrıca Doppler işaretinin geliştirilen yöntemlere giriş olarak verebilmek için bir ön-işlem süreci geliştirilmiştir. Şekil 7.1. de önerilen akıllı örüntü tanıma sisteminin yapısı sunulmuştur. Alt bölümlerde ise şekilde gösterilen her bir bloğun işlevi verilmiştir.



Şekil 7.1. Geliştirilen yöntemlerin DKS işaretlerine uygulama sistemi.

7.1. Doppler Kalp İşaretleri

Doppler Kalp Ses (DKS) işaretleri, hastanın göğüs kafesi üzerinde doppler transdüserinin uygun yerlere yerleştirilmesi ile elde edilebilir [38]. Şekil 7.2.de kalp mitral kapağından alınan DKS işaretinin örüntüsü görülmektedir. DKS işaretleri, kırmızı kan hücrelerinden (alyuvarlar) saçılan ekolardan üretilen 0.5 – 10 kHz frekans aralığına sahiptirler [123]. DKS işaretlerinin spektral tahmini, kardiyovasküler hastalıkları teşhis etmek için kan akış parametrelerini değerlendirmede yaygın olarak günümüzde kullanılmaktadır. Klinik teşhis yöntemleri, genellikle kan akışını spektral görüntülemenin, çeşitli büyüklüklerinin değerlendirilmesine dayalı olarak ölçülen parametreleri kullanır [124].




Şekil 7.2. DKS işaret örüntüsü.

Şekil 7.3.de gösterilen Doppler olayı, Denklem 7.1. deki eşitlikle ifade edilebilmektedir. Bu denklemden de görüleceği üzere, Doppler işareti ile kandaki alyuvarların akış hızları arasında doğrusal bir ilişki vardır. Kandaki alyuvarların her biri farklı doğrultuda ve farklı hızda hareket ettiğinden, yansıyan saçınımın rast gele karakteristikler içerir. Buna bağlı olarak karmaşık bir yapıya sahip olan Doppler işareti durağan değildir [20,125].

$$\Delta f = \frac{2 v f \cos \theta}{c} \quad (7.1)$$

Burada, v kan akışının hızı, f ultrasonik işaret yayıcı transdüserin frekansı, c dokudaki işaretin hızı (yaklaşık 1540 m/sn), Δf ölçülen Doppler kayma frekansı (yani yayılan ile yansıyan işaretlerin frekansları arasındaki fark) ve θ transdüser ile kan akış yönü arasındaki açı [123].



Şekil 7.3. Doppler olayı.

7.2. Veri Alımı

Orijinal DKS işaretleri, Fırat Tıp Merkezi Kardiyoloji kliniğinde, Acuson Sequoia 512 Model Doppler Ultrason cihazından alınmıştır. $V_{pp} = 1$ voltluk çıkış genliğine sahip, cihazın Doppler ses çıkışından DKS işaretleri MATLAB ortamında (ver. 5.3, The MathWorks Inc.) geliştirdiğimiz bir yazılımla, 5 saniyelik olarak, $SNR = 0$ dB kazançlı ve 20 kHz 'lik örnekleme frekansı ile 16-bitlik A/D çözünürlüğüne sahip olan bir ses kartı (EK-1) üzerinden bilgisayara sayısal biçimde ve hekim gözetiminde alınmıştır. Kullanılan Doppler ultrason transdüsünün (Model 3V2c, EK-2) çalışma modu 2 MHz sürekli dalgadır. Her bir kalp kapağına ait DKS işareti ultrason görüntüsü yardımı ile transdüser hastanın göğsü üzerinde uygun yere yerleştirilerek kayıt alınmıştır. Sayısallaştırılmış veri, 301 adet DKS işaretinin istatistiksel dağılımı Tablo 7.1. de verilmiştir.

Tablo 7.1. DKS işaretlerinin istatistiksel dağılımı.

		Yaş		Cinsiyet		Adet	
		Değişim	Ortalama	Erkek	Bayan	Normal	Normal Olmayan
Kalp Kapakları	Mitral	19 - 78	47.5	58	47	39	66
	Aort	15 - 80	50	74	36	56	54
	Pulmoner	15 - 56	31.7	24	7	17	14
	Triküspit	16 - 80	42.9	26	29	14	41

7.3. Ön-işlem Süreci

Elde edilen orijinal saf DKS işaretlerinin bazı ön işlemlerden geçirilerek, tanılama sisteminin hız ve doğru sınıflama başarımını etkileyecek bazı istenilmeyen ve gereksiz bilgilerden ayıklanması için bir ön-işlem süreci geliştirildi. Önerilen DKS işaret temizleme yordamı aşağıdaki alt bölümlerde sunulmuştur:

7.3.1. Filtreleme

DKS işaretlerinin 0.5-10 kHz aralığında olduğu daha önceden belirtilmişti. 20 kHz de örneklenen saf DKS işaretlerinin içerisinde 0.5-10 kHz dışındaki istenilmeyen frekans bileşenlerini yok etmek için sayısal bir FIR filtre kullanıldı. FIR filtre 500 Hz merkez frekanslı bir yüksek geçiren filtre olup, filtrenin derecesi DKS işaretinin karmaşıklığından dolayı keskin bir filtre karakteristiği için $N = 50$ olarak yüksek seçilmiştir. Böylece şebeke frekansından kaynaklanan gürültüde elimine edilmiş oldu.

Denklem 7.2. de FIR filtrenin transfer fonksiyonu verilmiştir.

$$H(z) = \sum_{n=0}^N h[n].z^{-n} \quad (7.2)$$

İşaret durağan olmadığından, pencereli FIR filtre kullanım gerekliliği ile, $w[n]$ pencere fonksiyonu olup, sayısal FIR filtrenin katsayıları:

$$h[n] = w[n].h[n] \quad (7.3)$$

Burada kullanılan pencere fonksiyonu Hamming olup, aşağıdaki gibi tanımlanmıştır:

$$w[k] = 0.54 - 0.46 \cdot \cos\left(2\pi \frac{k}{n-1}\right), \quad k = 0, \dots, n-1 \quad (7.4)$$

$$w[n] = \begin{cases} w[k] & 0 \leq n \leq N-1 \\ 0 & \text{diğer} \end{cases} \quad (7.5)$$

7.3.2. Beyaz Gürültü Ayrışımı

Beyaz gürültü rast gele bir işaret olup, Fourier dönüşümü düz bir spektrumdur [30]. DKS işaretleri DPA kullanılarak beyaz gürültüden ayrıştırıldılar. Bunun için [126] de önerilen üç adımdan oluşmuş bir yordam tatbik edildi:

1. Dalgacık paket ayrışımı : Daubechies-10 dalgacık filtreleri kullanılarak Bölüm 3.2. de ve Denklem 3.2. de gösterildiği gibi maksimum $m = 12$ seviyede dalgacık dönüşüm ayrışımı yapıldı. Her bir ayrışım seviyesi için detay katsayıları $cd = [cd_1, cd_2, \dots, cd_{12}]$ ve 1 adet son seviye için yaklaşık katsayı ca_{12} elde edildi.
2. Detay katsayılarını eşikleme: Her bir seviyenin sadece detay katsayısı Denklem 7.6. daki eşik değeri ile eşiklendi. Böylece simetrik bir biçimde olmak üzere, eşik değerinin altındaki küçük genlik değerler yok edilerek, her bir katsayıdaki gürültü bileşeni atılmış oldu [127].

$$T = \sqrt{2 \cdot \log(n)} \quad (7.6)$$

$$s[n] = \begin{cases} |s[n]| - T & |s[n]| > T \\ 0 & |s[n]| \leq T \end{cases} \quad (7.7)$$

Burada, T eşikleme değeri, n işaretin uzunluğu, s işaretin kendisidir.

3. İşareti yeniden yapılandırma : Dalgacık ayrışımının detay ve yaklaşık katsayıları Denklem 7.8. deki gibi analitik olarak toplanıp DKS işareti beyaz gürültüden ayrıştırılmış bir biçimde tekrar yeniden elde edilir.

$$DKS = cA_m + \sum_{j=1}^m cd_j \quad (7.8)$$

7.3.3. Normalizasyon

DKS işaretleri Denklem 7.9. kullanılarak normalize edildi. Böylece, işaretin genliğinin hastanın göğüs kafes yapısından etkilenmesi ihmal edilecek seviyeye çekildi.

$$DKS = \frac{DKS}{[(DKS[n])_{\text{maksimum}}]} \quad (7.9)$$

7.4. Geliştirilen Özellik Çıkarma Algoritmalarının Uygulaması

Bölüm 3.,4.,5. de geliştirilen özellik çıkarma yöntemlerinin DKS işaret örüntüleri üzerinde uygulaması aşağıdaki ilgili yöntemlere ait alt bölümlerde verilmiştir.


7.4.1. Dalgacık Dönüşüm Ağacından Entropi Hesaplanması

Bölüm 3.2. de geliştirilen Dalgacık Dönüşüm Ağacından Entropi Hesaplama (DDA-EH) özellik çıkarma yönteminin uygulaması, DKS işaretleri üzerinde yapılmıştır. Şekil 7.4.de kalp mitral kapağına ait bir DKS işaretinin Daubechies – 10 dalgacıkları ile maksimum seviyede $m = 12$ (Denklem 3.2.), dalgacık ayrışımı görülmektedir.


Bu dalgacık katsayı işaretlerinin her birinin Denklem 7.10. da gösterildiği gibi Norm entropi değerleri hesaplanıp 1/1000 ile normalize edilerek, özellik vektörü içeriği grafiksel olarak Şekil 7.5. de verilmiştir.

$$E_i = \sum_n |C_i[n]|^{3/2} \quad (7.10)$$

Burada, E_i Norm entropi değerleri ve C_i katsayı işaretleridir.




Şekil 7.4. Bir DKS işaretinin dalgacık dönüşüm ağacında bulunan işaretleri.




Şekil 7.5. DKS işaret örüntüsünün DDA-EH özellik eğrisi.

7.4.2. Dalgacık Paket Dönüşüm Ağacından Entropi Hesaplanması

Bölüm 3.3. de geliştirilen Dalgacık Paket Dönüşüm Ağacından Entropi Hesaplanma (DPDA-EH) özellik çıkarım yönteminin, DKS işareti üzerine uygulaması yapıldı. Şekil 7.6.da kalp aort kapağına ait bir DKS işaretinin, Daubechies – 10 dalgacık paketi kullanılarak ve $m = 8$ seviyede, dalgacık paket ayrışımının uç yaprak katsayı işaretleri görülmektedir. $2^m = 256$ adet uç katsayı işaretinin Denklem 7.10. da verilen Norm entropi ile entropi değerleri hesaplanıp $1/10$ ile normalize edilerek grafiksel olarak Şekil 7.7. sunulmuştur.



Şekil 7.6. Bir DKS işaretinin dalgacık paket dönüşüm ağacının uç yaprak işaretleri.




Şekil 7.7. DKS işaret örüntüsünün DPDA-EH özellik eğrisi.

7.4.3. Dalgacık Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması


Bölüm 4.1.1. de geliştirilen Dalgacık Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplama (DD-KZFD-EH) özellik çıkarımının DKS işaret uygulamasının $N=25000$ noktalı Hanning pencere fonksiyonu ile elde edilen KZFD spektrogramının ZFG 'si sadece bir katsayı işareti (cD_I) için Şekil 7.8.de görülmektedir. Her bir katsayı işaretinin spektrogramını oluşturan bileşen sayısı (K) Denklem 4.20.den bulunur:

$$K = \left\| \frac{M - S}{N - S} \right\| = \left\| \frac{100000 - 12500}{25000 - 12500} \right\| = 7$$

Burada, M katsayı işaretlerinin uzunluğu, S pencere fonksiyonu ile işaretin binişme bant genişliği olup, $S=N/2$ dir. Bir DKS işaretinin 13 adet katsayı işareti olduğundan, 13 adette yedişer spektrumdan oluşan spektrograma sahip olacaktır. Dolayısıyla özellik çıkarmak için kullanılacak ZFG bileşen sayısı : $13 \times 7 = 91$ olacaktır. ZFG 'nin her bir bileşeninin Denklem 7.10. da verilen Norm entropi hesaplaması yapılarak özellik çıkarım değerleri $1/10000$ normalizasyonla grafiksel olarak Şekil 7.9.da verilmiştir.



Şekil 7.8. DD-KZFD zaman – frekans gösterimi.




Şekil 7.9. DKS işaret örüntüsünün DD-KZFD-EH özellik eğrisi


7.4.4. Dalgacık Paket Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması

Bölüm 4.1.2. de geliştirilen Dalgacık Paket Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplama (DPD-KZFD-EH) özellik çıkarımının, DKS işaret uygulamasının $N=256$ noktalı Hanning pencere fonksiyonu ile elde edilen KZFD spektrogramının ZFG 'si sadece bir uç

yaprak (8. seviye) katsayı işareti ($cD_{1,8}$) için Şekil 7.10.da görülmektedir. Her bir uç yaprak katsayı işaretinin spektrogramını oluşturan bileşen sayısı Denklem 4.20. den $K=2$ bulunur. Burada 8. seviye katsayı işaretlerinin uzunluğu $M=409$ dur. Bir DKS işaretinin 8 seviyeli dalgacık paket ayrışımında, uç yaprak katsayılarının adedi $2^8=256$ dir. Her bir katsayının spektrogram bileşen sayısı dikkate alındığında entropi hesaplaması yapılacak işaret sayısı $256*K=512$ olacaktır. ZFG 'nin her bir bileşeninin Denklem 7.10. da verilen Norm entropi hesaplaması yapılarak özellik çıkarım değerleri $1/10$ normalizasyonla grafiksel olarak Şekil 7.11.de verilmiştir.




Şekil 7.10. DPD-KZFD zaman – frekans gösterimi.



Şekil 7.11. DKS işaret örüntüsünün DPD-KZFD-EH özellik eğrisi.


7.4.5. Dalgacık Dönüşümü ve Welch Güç Spektrumu ile Entropi Hesaplanması

Bölüm 4.2.1. de geliştirilen Dalgacık Dönüşümü ve Welch Güç Spektrumu ile Entropi Hesaplama (DD-WGS-EH) özellik çıkarımının, DKS işaret uygulamasının $N=512$ noktalı Hanning pencere fonksiyonu ile elde edilen Welch güç spektrumlarının ZFG 'si Şekil 7.12.de görülmektedir.



Şekil 7.12. DD-WGS zaman – frekans gösterimi.


ZFG 'nin her bir bileşeninin Denklem 7.10. da verilen Norm entropi hesaplama ile elde edilen özellik çıkarım değerleri, $\times 10^{11}$ ile normalize edilerek grafiksel olarak Şekil 7.13.de verilmiştir.




Şekil 7.13. DKS işaret örüntüsünün DD-WGS-EH özellik eğrisi.

7.4.6. Dalgacık Paket Dönüşümü ve Welch Güç Spektrumu ile Entropi Hesaplanması

Bölüm 4.2.2. de geliştirilen Dalgacık Paket Dönüşümü ve Welch Güç Spektrumu ile Entropi Hesaplama (DPD-WGS-EH) özellik çıkarımının, DKS işaret uygulamasının $N=512$ noktalı Hanning pencere fonksiyonu ile elde edilen Welch güç spektrumlarının ZFG 'si Şekil 7.14.de görülmektedir. ZFG 'nin her bir bileşeninin ($2^8 = 256$) Denklem 7.10. da verilen Norm entropi hesaplama tekniği ile özellik çıkarım değerleri $\times 10^5$ normalizasyonla grafiksel olarak Şekil 7.15.de verilmiştir.




Şekil 7.14. DPD-WGS zaman – frekans gösterimi.




Şekil 7.15. DKS işaret örüntüsünün DPD-WGS-EH özellik eğrisi.

7.4.7. Dalgacık Dönüşümü ve MUSIC Güç Spektrumu ile Entropi Hesaplanması

Bölüm 4.2.3. de geliştirilen Dalgacık Dönüşümü ve MUSIC Güç Spektrumu ile Entropi Hesaplama (DD-MGS-EH) özellik çıkarımının, DKS işaret uygulamasının $N=512$ noktalı Hanning pencere fonksiyonu ve $p = 10$ alt yüzey ayrışım sayısı ile elde edilen MUSIC güç spektrumlarının ZFG 'si Şekil 7.16.da görülmektedir. ZFG 'nin her bir bileşeninin Denklem 7.10. da verilen Norm entropi hesaplama tekniği ile elde edilen özellik çıkarım değerleri $1/10^{12}$ normalizasyonla grafiksel olarak Şekil 7.17.de verilmiştir.




Şekil 7.16. DD-MGS zaman – frekans gösterimi.




Şekil 7.17. DKS işaret örüntüsünün DD-MGS-EH özellik eğrisi

7.4.8. Dalgacık Paket Dönüşümü ve MUSIC Güç Spektrumu ile Entropi Hesaplanması

Bölüm 4.2.4. de geliştirilen Dalgacık Paket Dönüşümü ve MUSIC Güç Spektrumu ile Entropi Hesaplama (DPD-MGS-EH) özellik çıkarımının, DKS işaret uygulamasının $N=512$ noktalı Hanning pencere fonksiyonu ve $p = 10$ alt yüzey ayrışım sayısı ile elde edilen MUSIC güç spektrumlarının ZFG 'si Şekil 7.18.de görülmektedir. ZFG 'nin her bir bileşeninin Denklem 7.10. da verilen Norm entropi hesaplama tekniği ile elde edilen özellik çıkarım değerleri $1/10$ normalizasyonla grafiksel olarak Şekil 7.19.de verilmiştir.




Şekil 7.18. DPD-MGS zaman – frekans gösterimi.




Şekil 7.19. DKS işaret örüntüsünün DPD-MGS-EH özellik eğrisi.

7.4.9. Dalgacık Dönüşümü ve AR Modeli ile Entropi Hesaplanması

Bölüm 5.1.1. de geliştirilen Dalgacık Dönüşümü ve AR Modeli ile Entropi Hesaplanma (DD-ARM-EH) özellik çıkarımının, DKS işaret uygulamasının $N=512$ noktalı Hanning pencere fonksiyonu ve $p = 5$ model derecesi ile elde edilen Yule-Walker $AR(5)$ Modelinin güç spektrumlarının ZFG 'si Şekil 7.20.de görülmektedir. ZFG 'nin her bir bileşeninin Denklem 7.10. da verilen Norm entropi hesaplama tekniği ile elde edilen özellik çıkarım değerleri $\times 10^2$ normalizasyonla grafiksel olarak Şekil 7.21.de verilmiştir.




Şekil 7.20. DD-ARM zaman – frekans gösterimi.




Şekil 7.21. DKS işaret örüntüsünün DD-ARM-EH özellik eğrisi.

7.4.10. Dalgacık Paket Dönüşümü ve AR Modeli ile Entropi Hesaplanması

Bölüm 5.1.2. de geliştirilen Dalgacık Paket Dönüşümü ve AR Modeli ile Entropi Hesaplama (DPD-ARM-EH) özellik çıkarımının, DKS işaret uygulamasının $N=512$ noktalı Hanning pencere fonksiyonu ve $p = 5$ model derecesi ile elde edilen Yule-Walker AR(5) Modelinin güç spektrumlarının ZFG 'i Şekil 7.22.de görülmektedir. ZFG 'nin her bir bileşeninin Denklem 7.10. da verilen Norm entropi hesaplama tekniği ile elde edilen özellik çıkarım değerleri grafiksel olarak Şekil 7.23.de verilmiştir.



Şekil 7.22. DPD-ARM zaman – frekans gösterimi.



Şekil 7.23. DKS işaret örüntüsünün DPD-ARM-EH özellik eğrisi


7.5. Yapay Sinir Ağı ile Sınıflandırma

Sınıflandırmanın amacı, geliştirilen DKS işaretlerinden özellik çıkarma yöntemlerinin etkinliğini ve başarımını göstermektir. Bu amaçla, akıllı örüntü tanıma uygulamalarında güçlü bir sınıflandırıcı olan yapay sinir ağları kullanılmıştır. Kullanılan yapay sinir ağı, tüm yapay sinir ağı çalışmalarının %90 'nın da tercih edilen çok katmanlı ileri beslemeli yapay sinir ağı olup, bu YSA modelinin eğitimi için kullanılan en önemli öğrenme algoritması ise hata geri yayılım algoritmasıdır [23,70,76,77]. Aşağıda bu algoritma kısaca açıklanmıştır:

Geri yayılım YSA : Geriye yayılım ağı, çok katmanlı ileri yön bağlamalı bir ağıdır. Giriş ile çıkış katmanları arasında, birden fazla katmanın kullanıldığı yapay sinir ağı sistemidir. Gizli katman olarak isimlendirilen bu ara katmanlarda, aracısız giriş alamayan ve aracısız çıkış veremeyen işlem elemanları vardır. Şekil 7.24 'de çok katmanlı algılayıcı yapay sinir ağının genel yapısı verilmiştir.

Çok katmanlı ağlarda veriler, giriş katmanı tarafından kabul edilirler. Ağ içindeki işlemler sonucunda çıkış katmanında oluşan cevap ile giriş verisine karşı istenen cevap karşılaştırılır. Hesaplanan cevap ile istenen cevap arasında herhangi bir farklılık varsa, katmanlar arasında bulunan ağırlıklar bu farkı azaltacak şekilde yeniden düzenlenir. Yapay sinir ağının girişindeki veriler, ağırlıklar uygun noktaya ulaşana kadar değişmez. Hesaplanan çıkış cevapları, istenen cevaplarla karşılaştırılarak, sonuçta hata işareti elde edilir. Hata işareti, ara katmanlardan çıkış katmanına olan ağırlıkları değiştirmekte de kullanılır. Çok sayıda ara katmana sahip sistemlerde her katmanın hata işaretleri, bir önceki katmanın düzeltilmiş hata işaretlerinden çıkartılarak

işlem tekrarlanır. Sonuç olarak ağırlık düzeltme işlemi çıkış seviyesine bağlı ağırlıklardan başlar ve işlem ters yönde giriş seviyesine varana kadar devam eder. Sistem, sonuçta yine hatalar yapar, fakat bu hatalardan bir şeyler öğrenip istenen cevabı bulana kadar işlem tekrarlanır. Bu yöntem hata geriy yayılma algoritması denir. Denklem 7.11. de bu algoritmanın öğrenme sürecinde kullanılan matematiksel yapı verilmiştir.



Şekil 7. 24. Çok katmanlı ileri beslemeli yapay sinir ağları.

$$w_{ij}(t+1) = w_{ij}(t) + \varepsilon \cdot h_j \cdot y_i + \alpha (w_{ij}(t) - w_{ij}(t-1)) \quad (7.11)$$

Burada, momentum katsayısı $0 < \alpha < 1$ ve öğrenme oranı $0.001 < \varepsilon < 10$ dir. h_j ise j . katmandaki hata işaretidir. Bu değer ağı verilen giriş için istenen çıkış değerindeki sapmadan kaynaklanmaktadır.

Hata geri yayılım algoritması eğitici bir öğrenmedir. Eğitici öğrenmede, dışardan bir eğiticinin sinir ağına müdahalesi söz konusudur. Eğitici, sinir ağının ilgili girdi için üretmesi gereken sonucu sinir ağı sistemine verir. Yani yapay sinir ağına girdi/çıkı ikilisinden oluşan örnekler sunulur. Bu ikili, ağın öğrenmesi gereken özellikleri temsil eder. Bu algoritmanın detayları [122,128] de bulunabilir. Hata geri yayılım öğrenme algoritmasının başarımını etkileyen önemli birkaç faktör bulunmaktadır. Bunlar:

1. **Başlangıç ağırlıkları :** Çok katmanlı ileri beslemeli ağların başlangıç ağırlıkları, sonuca ulaşmak açısından oldukça kuvvetli bir etkidir. Başlangıç ağırlıklarını küçük rast gele değerler olarak seçmek yerine, etkileştirme fonksiyonları üzerinden hesaplanması öğrenme sürecinin hızlı olmasına katkıda bulunur [121].

2.Öğrenme oranı : Geri yayılım öğrenme algoritmasının yakınsama etkinliği açısından bir diğer önemli parametrede öğrenme oranıdır. Bu oran büyük seçildiğinde ağırlıkların değişimleri büyük salınımlar yapacaktır ve dolayısı ile eğitim sürecinde bir kararsızlık oluşmasına neden olacaktır. Küçük seçildiğinde ise, öğrenme süreci yavaşlayacaktır. Uygun bir öğrenme oranı seçimi için, belirli bir kriter yoktur. Çoğu zaman ilgili sınıflama probleminin bir çok denemesinden sonra en uygun öğrenme oranı belirlenir. Bunun yerine Vogl (1988) ve Jacobs (1988) tarafından önerilen adaptif öğrenme oranı kullanmak daha etkili bir yaklaşımdır. Bu metot da, hatanın değişimine bağlı olarak öğrenme oranı belirli katsayılar ile çarpılarak, artırılacak veya azaltılacak yönde değiştirilir.

3.Momentum katsayısı : Öğrenme oranı çok geniş bir aralıkta değişim sergilemektedir. Bundan dolayı, öğrenme oranının seçiminden kaynaklanan problemlerin etkisini azaltmak için, ağırlıkların düzenlenmesinde ikinci bir parametre olarak momentum katsayısı kullanılır.

4.Gizli katman ve nöron sayısı : Eğitimin verilen hata sınırında hızlı bir şekilde gerçekleşebilmesi için, gizli katman sayısı ve bu katmanlardaki nöron sayıları önem arz eden bir başka unsurdur. Bunların sayısını belirlerken amacımız, verilen girişe karşılık istenen çıkışı elde etmeyi yönelik bir doğrusallaşmayı sağlamaktır. Birden çok gizli katman kullanmak yerine, bir tek gizli katmandaki nöron sayısının denemelerle artırılması, çok katmanlı ağların başarımı açısından daha uygun olacaktır [131].


5.Etkinleştirme fonksiyonları : Etkinleştirme fonksiyonunun seçimi, sınıflandırılacak olan örüntünün yapısına bakarak çıkış katmanında kısmen yapılabilsede genellikle, tecrübeler ve deneysel çalışmalara bağlı olarak bu fonksiyonlar bulunabilmektedirler [132]. Etkinleştirme fonksiyonları YSA 'nın işlem elemanlarının çok geniş aralıktaki çıkışını belli aralıklara çekmektedir. Böylece her bir işlem elemanının tepkisi yumuşak olmaktadır ve bağlantı ağırlıklarının değişimlerinin, daha küçük değerlerde olması sağlanmaktadır. Dolayısıyla yapay sinir ağının eğitimi sırasında, hata değişiminin ıraksaması engellenerek kararlılığa ulaşmasına yardımcı olunur. Adım, rampa, signum, logaritma ve tanjant fonksiyonları yaygın olarak kullanılan bazı etkinleştirme fonksiyonlarıdır.

Uygulama için, MATLAB ortamında programlar geliştirilmiştir. Kullanılan ileri beslemeli çok katmanlı YSA 'nın eğitim parametreleri ve yapısı Tablo 7.2. de gösterilmiştir. Bunlar, bir kaç farklı deneme ile, yani gizli katman nöron sayısı, momentum ve öğrenme oranlarının değerleri ve etkinleştirme fonksiyonlarının türleri, en iyi başarımlar için seçildi. Şekil

7.25. de örnek olarak DD-ARM-EH yöntemine göre elde edilen özellikler ile kullanılan YSA'nın eğitim başarımı görülmektedir.

Tablo 7.2. Kullanılan YSA modelinin yapısı ve eğitim parametreleri.

YSA yapısı	
YSA modeli	Çok katmanlı ileri beslemeli
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş : Özellik vektörünün bileşen sayısı Gizli : Özellik çıkarım yöntemine göre değişken Çıkış : 2
Başlangıç ağırlıkları ve eşik değerleri	Nguyen-Widrow metoduna göre hesaplandı
Etkinleştirme fonksiyonları	Logaritmik sigmoid
YSA eğitim parametreleri	
Öğrenme kuralı	Hata geri yayılım
Adaptif öğrenme oranı	Başlangıç : 0.001 Artış katsayısı : 1.05 Azalış katsayısı : 0.7
Momentum sabiti	0.95
Toplam karesel hata	0.0001



Şekil 7.25. YSA eğitim başarımı.

Tablo 7.3. ve 7.4. de geliştirilen her bir özellik çıkarım yönteminin kullanılan YSA sınıflandırıcı modeli ile başarımları DKS işaret örüntüleri üzerinde, uygulama sonuçları karşılaştırmalı olarak verilmiştir.

Tablo 7. 3. Geliştirilen özelliklik çıkarım yöntemlerinin YSA sınıflama başarımlarının karşılaştırılması – I.


ÖZELLİK ÇIKARIM YÖNTEMLERİ	DDA-EH		DPDA-EH		DD-KZFD-SEH		DPD-KZFD-SEH		DD-WGS-EH		DPD-WGS-EH		DD-MGS-EH		DPD-MGS-EH		DD-ARM-EH		DPD-ARM-EH				
	DKS işaretleri	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral	Mitral			
		105	105	105	105	105	105	105	105	105	105	105	105	105	105	105	105	105	105	105			
		20	20	20	20	20	20	20	20	20	20	20	20	20	20	20	20	20	20	20			
		Eğitim	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33			
YSA	Test	Normal	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19			
		Normal olmayan	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33	33			
		Katmanlardaki nöron sayısı	13 – 5 – 2	256 – 5 – 2	91 – 10 – 2	512 – 4 – 2	13 – 5 – 2	256 – 8 – 2	13 – 5 – 2	256 – 8 – 2	13 – 5 – 2	256 – 8 – 2	13 – 5 – 2	256 – 8 – 2	13 – 5 – 2	256 – 8 – 2	13 – 5 – 2	256 – 8 – 2	13 – 5 – 2	256 – 8 – 2	256 – 8 – 2		
		Eğitim iterasyonu	288	292	263	281	288	3939	257	277	5590	411	100	100	100	100	100	100	100	100	100		
Doğru sınıflama	Hatalı sınıflama	Eğitim başarımları (%)	17	18	19	18	100	100	100	100	100	100	100	100	100	100	100	100	100	100			
		Normal	31	30	30	30	31	18	14	12	17	31	19	21	12	31	17	31	17	17			
		Normal olmayan	2	1	0	1	2	31	19	14	21	31	19	21	12	31	17	31	17	17			
		Normal	2	3	3	3	2	1	5	7	2	2	2	2	2	2	2	2	2	2			
Toplamda tanıma yüzdesi	Toplamda tanıma yüzdesi	En yüksek tanıma yüzdesi	100	99.95	99.96	99.95	100	100	100	100	100	100	100	100	100	100	100	100	100	99.99			
		En düşük tanıma yüzdesi	65	94.84	79.94	85	98.74	64.8	84.71	54.43	84.71	83.41	84.71	54.43	84.71	83.41	84.71	83.41	84.71	83.41			
		Ortalama tanıma yüzdesi	98.54	98.9	98.45	98.5	99.5	89.3	99.66	92.6	99.66	99.56	99.66	92.6	99.66	99.56	99.66	99.56	99.66	99.56			
		Toplamda tanıma yüzdesi	48/52	48/52	49/52	48/52	48/52	33/52	48/52	33/52	48/52	48/52	48/52	33/52	48/52	48/52	48/52	48/52	48/52	48/52	48/52		
			92.3%			%92.3			%94.2			%92.3			%63.4			%92.3			%92.3		

Tablo 7. 4. Geliştirilen özellik çıkarım yöntemlerinin YSA sınıflama başarımlarının karşılaştırılması – II.

ÖZELLİK ÇIKARIM YÖNTEMLERİ		DDA-EH		DPDA-EH		DD-KZFD-SEH		DPD-KZFD-SEH		DD-WGS-EH		DPD-WGS-EH		DD-MGS-EH		DPD-MGS-EH		DD-ARM-EH		DPD-ARM-EH	
		Aort	Aort	Aort	Aort	Aort	Aort	Aort	Aort	Aort	Aort	Aort	Aort	Aort	Aort	Aort	Aort	Aort	Aort	Aort	Aort
DKS işaretleri	Alındığı yer	110	110	110	110	110	110	110	110	110	110	110	110	110	110	110	110	110	110	110	
	Toplam adedi	14	14	14	14	14	14	14	14	14	14	14	14	14	14	14	14	14	14	14	
	Normal	25	25	25	25	25	25	25	25	25	25	25	25	25	25	25	25	25	25	25	
	Normal olmayan	31	31	31	31	31	31	31	31	31	31	31	31	31	31	31	31	31	31	31	
	Test	40	40	40	40	40	40	40	40	40	40	40	40	40	40	40	40	40	40	40	
	Normal olmayan	13 - 5 - 2	256 - 5 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	512 - 4 - 2	
YSA	Katmanlardaki nöron sayısı	5504	269	844	844	844	844	844	844	844	844	844	844	844	844	844	844	844	844	844	
	Eğitim iterasyonu	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	
	Eğitim başarımları (%)	26	27	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	
Doğru sınıflama	Normal olmayan	40	38	38	38	38	38	38	38	38	38	38	38	38	38	38	38	38	38	38	
	Normal	5	4	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	
Hatalı sınıflama	Normal olmayan	0	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	
	En yüksek tanıma yüzdesi	100	100	99.99	99.99	99.99	99.99	99.99	99.99	99.99	99.99	99.99	99.99	99.99	99.99	99.99	99.99	99.99	99.99	99.99	
En düşük tanıma yüzdesi	En düşük tanıma yüzdesi	62.37	77.2	50.89	50.89	50.89	50.89	50.89	50.89	50.89	50.89	50.89	50.89	50.89	50.89	50.89	50.89	50.89	50.89	50.89	
	Ortalama tanıma yüzdesi	99.4	99.01	95.14	95.14	95.14	95.14	95.14	95.14	95.14	95.14	95.14	95.14	95.14	95.14	95.14	95.14	95.14	95.14	95.14	
Toplamda tanıma yüzdesi	Toplamda tanıma yüzdesi	66/71	65/71	66/71	66/71	66/71	66/71	66/71	66/71	66/71	66/71	66/71	66/71	66/71	66/71	66/71	66/71	66/71	66/71	66/71	
		%93	%91.5	%93	%93	%93	%93	%93	%93	%93	%93	%93	%93	%93	%93	%93	%93	%93	%93	%93	

7.6. Adaptif Örüntü Tanıma Yöntemlerinin Uygulaması

Bölüm 6.da, adaptif özellik çıkarma ve sınıflama için geliştirilen yeni dalgacık sinir-ağ modellerinin DKS işaret örüntüleri üzerinde uygulaması yapılmıştır. Şekil 7.26. da akıllı örüntü tanıma sisteminin yapısı bu doğrultuda verilmiştir.



Şekil 7.26. Geliştirilen adaptif yöntemlerin DKS işaretlerine uygulama sistemi.

7.6.1. Dalgacık Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama

Bölüm 6.1. de dalgacık dönüşüm sinir ağı ile adaptif özellik çıkarma ve sınıflama temelli olarak geliştirilen yeni bir DSA modelinin yapısı ve eğitim parametreleri Tablo 7.5. de, ve DKS işaretlerine uygulama sonuçları ise Tablo 7.6. da verilmiştir.

Tablo 7.5. DSA modelinin yapısı ve eğitim parametreleri.

DSA Modelinin Yapısı		
Dalgacık filtre türü		Daubechies – 10
Dalgacık ayrışım seviyesi		12
Entropi	Türü	Norm
	Parametre başlangıç	1.0
	Parametre bitiş	2.0
	Parametre değişim	0.1
Katman sayısı		3
Katmanlardaki nöron sayısı		Giriş : 13 Gizli : 10 Çıkış : 2
Başlangıç ağırlıkları ve eşik değerleri		Nguyen-Widrow metodu ile hesaplandı
Etkinleştirme fonksiyonları		Logaritmik sigmoid
Eğitim Parametreleri		
Öğrenme kuralı		Geri yayılım
Adaptif öğrenme oranı parametreleri		Başlangıç : 0.0001 Artış katsayısı : 1.05 Azalış katsayısı: 0.7
Momentum katsayısı		0.97
Toplam karesel hata (sse)		0.000001

Tablo 7.6. DSA modelinin DKS işaret örüntülerini tanıma başarımı.

		Aort kapak		Mitral kapak	
		Normal	Normal olmayan	Normal	Normal olmayan
DKS işaretleri	Eğitim	14	25	20	33
	Test	31	40	19	33
Eğitim başarımı (%)		100	100	100	100
Doğru sınıflama		26 (%84)	40 (%100)	16 (%84)	30 (%91)
Hatalı sınıflama		5 (%16)	0 (%0)	3 (%16)	3 (%9)
En yüksek tanıma yüzdesi		100	100	100	100
En düşük tanıma yüzdesi		99.98	99.91	99.97	99.98
Ortalama tanıma yüzdesi		99.99	99.99	99.98	99.99
Toplamda tanıma yüzdesi		66/71 = %93		46/52 = %88.5	

7.6.2. Dalgacık Paket Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama

Bölüm 6.2. de dalgacık paket dönüşüm sinir ağı ile adaptif özellik çıkarma ve sınıflama temelli olarak geliştirilen yeni bir DPSA modelinin yapısı ve eğitim parametreleri Tablo 7.7. de, ve DKS işaretlerine uygulama başarımları ise Tablo 7.8.de verilmiştir.

Tablo 7.7. DPSA modelinin yapısı ve eğitim parametreleri.

DPSA Modelinin Yapısı		
Dalgacık paket filtre türü		Daubechies - 10
Dalgacık paket ayrışım seviyesi		8
Entropi	Türü	Norm
	Parametre başlangıç	1.0
	Parametre bitiş	2.0
	Parametre değişim	0.1
Katman sayısı		3
Katmanlardaki nöron sayısı		Giriş : 256 Gizli : 50 Çıkış : 2
Başlangıç ağırlıkları ve eşik değerleri		Nguyen-Widrow metodu ile hesaplandı
Etkinleştirme fonksiyonları		Logaritmik sigmoid
Eğitim Parametreleri		
Öğrenme kuralı		Geri yayılım
Adaptif öğrenme oranı parametreleri		Başlangıç : 0.0001 Artış katsayısı : 1.05 Azalış katsayısı: 0.7
Momentum katsayısı		0.98
Toplam karesel hata (sse)		0.000001

Tablo 7.8. DPSA modelinin DKS işaret örüntülerini tanıma başarımı.

		Aort kapak		Mitral kapak	
		Normal	Normal olmayan	Normal	Normal olmayan
DKS işaretleri	Eğitim	14	25	20	33
	Test	31	40	19	33
Eğitim başarımı (%)		100	100	100	100
Doğru sınıflama		29 (%93.5)	39 (%97.5)	18 (%94.7)	30 (%91)
Hatalı sınıflama		2 (%6.5)	1 (%2.5)	1 (%5.3)	3 (%9)
En yüksek tanıma yüzdesi		100	100	100	100
En düşük tanıma yüzdesi		98.19	89.32	94.32	99.96
Ortalama tanıma yüzdesi		99.8	98.2	98	99.9
Toplamda tanıma yüzdesi		68/71 = %95.7		48/52 = %92.3	

BÖLÜM 8

8. SONUÇ VE DEĞERLENDİRME

Akıllı örüntü tanıma çalışmalarında, en önemli iki sorun: Güçlü ve etkin özellik çıkarımı ve buna bağlı olarak elde edilen sınıflandırma sonuçlarının güvenilirliğidir. Bu tez çalışmasında, durağan olmayan işaretler için üç farklı klasmanda olmak üzere on çeşit özellik çıkarım algoritması işaretin zaman-frekans gösterim entropilerine dayalı olarak tanımlanmıştır. Bu yöntemlerin etkinliği, gerçek zaman uygulamaları ve üstün genelleme yetenekleri ile örüntü sınıflandırıcıları arasında önemli bir yere sahip olan geri yayılım YSA sınıflayıcısı ile değerlendirilmiştir. Ayrıca özellik çıkarım sürecini de içeren ve sınıflayıcının eğitim başarımına göre özellik uzayını uyarlayabilen entropi tabanlı yeni dalgacık sinir ağ modelleri geliştirilmiştir.

8.1. Sonuçların İrdelenmesi

1. Geliştirilen özellik çıkarım algoritmaların da [10,14,17,18,25,36-38,41,43,56,105] çalışmalarının aksine, işaretin doğrudan zaman veya frekans bölgesinin her bir noktasının büyüklüğünü özellik uzayı olarak tanımlamak yerine, daha ayrıntılı ve tutarlı özellikler elde etmek için, dalgacık ayrışımı/dalgacık paket ayrışımı ile durağan olmayan işarete birden çok perspektiften bakılarak elde edilen her bir işaret bileşeninin entropi değerleri hesaplandı. Böylece işaretin özellik uzayı, işaretin farklı bakış açılarından çıkarılan her bir bileşeninin sahip olduğu bir tek entropi değerlerinin oluşturduğu küme ile tanımlanmıştır. Bu durum, doğrudan zaman veya frekans bölgesinden elde edilen özellikler uzayına göre boyut olarak daha azdır. Örneğin; işaretin 1024 noktalı frekans bölgesinden çıkarılan özellik uzayının boyutu 1024 iken, geliştirilen yöntemde bir işarete ait 100000 veri örnekli 13 alt bileşen işaretinden, 13 entropi değeri ile özellik uzayı betimlenmiş ve boyut olarak az olmasına rağmen, tanıma başarımı yüksek çıkmaktadır. Bu ise, özellik çıkarma algoritmasının sağlam temellere dayalı olduğunu göstermektedir. Ayrıca özellik uzayının boyut olarak küçük olması, sınıflayıcının karmaşıklığını (YSA 'da daha az nöron ve ara katman kullanılmasını sağlar; giriş: 13, ara: 5, çıkış: 2 nöron) önlediği için gerçek zaman uygulamalarına daha uygun hale getirmekte ve tasarımı kolaylaştırmaktadır. Ayrıca YSA sınıflayıcının yapısı küçük çapta olduğu için, nöronlar arası bağlantılar üzerinde bulunan ağırlıklar ile nitelendirilen bellek yapısı da

küçük çapta olmakla birlikte bu yüksek başarıyı sağlaması, daha az hafıza boyutuna daha çok bilgiyi depolamanın önemi günümüzde aşıkardır. Buna mukabil, özellik çıkarım sürecindeki karmaşıklık, günümüz bilgisayar teknolojisinin ulaştığı nokta ve sayısal işaret işleme işlemcileri (DSP) ile sorun olmaktan çıkmıştır.

2. Geliştirilen DDA-EH ve DPDA-EH özellik çıkarım yapılarında işaretin doğrudan zaman bölgesi bileşenlerinin örüntülerinden entropi değerleri hesaplanmıştır. Bu yöntemlerin YSA ile DKS işaretlerini sınıflama başarımları, ortalama olarak %92 civarındadır. Diğer özellik çıkarım yöntemlerinde ise, durağan olmayan işaretin ayrışım sonucu elde edilen her bir durağan işaret bileşeninin frekans bölgesi örüntülerinden entropi değerleri hesaplanmıştır. Böylelikle zaman bölgesindeki geçici değişimlerin yanı sıra, frekans bölgesi değişimlerini de içeren daha kararlı ve güçlü özellik çıkarımı amaçlanmıştır. Bu yöntemler arasında DPD-KZFD-SEH, DPD-ARM-EH ve DPD-WGS-EH yöntemleri ile %94 civarında başarımlarına ulaşılmış iken, DPD-MGS-EH ve DD-MGS-EH yöntemleri ile istenen başarıya ulaşılamamıştır. Bunun nedeni MUSIC algoritmasında kullanılan alt yüzey ayrışım seviyesinin (P) küçük seçilmesidir. Bu değerin büyük seçilmesi gerçek zaman uygulamalarında sorun doğurmaktadır.
3. Geliştirilen parametrik olmayan zaman – frekans gösterim yöntemleri ile elde edilen özellik çıkarım algoritmaları arasında, en iyi başarımlar ortalama olarak %93.5 ile KZFD tabanlı özellik çıkarma yöntemleri ile elde edilmiştir.
4. Geliştirilen yöntemlerde, işaretin sadece bir DD veya DPD bileşeninin özellik çıkarmak için kullanılması yerine, işareti yeniden oluşturabilecek katsayı işaret bileşenlerini üzerinde bulunduran bir ağaç yapısı kullanıldığından (13 katsayı işaret bileşenli DD ağacı, 256 katsayı işaret bileşenli DPD ağacı) ve bu kadar çok işaret bileşeni kullanılmasına rağmen entropi kavramı ile her bir işaret bileşeninden bir özellik değeri (KZFD 'de kullanılan pencere fonksiyonunun genişliğine bağlı olarak, her bir işaret bileşeninin spektrogramını oluşturan spektrum sayısı kadar; DD 'de 7, DPD 'de 2) elde edildiğinden, özellik uzayının boyutundaki artıştan da kaçınılarak daha güven verici ve kararlı özellik çıkarımı gerçekleştirilmiştir.
5. YSA sınıflayıcısının, eğitim başarımları geliştirilen özellik çıkarım algoritmaları için (Aort kapak DKS işaret örüntüleri için DPD-MGS-EH yöntemi hariç) %100 gerçekleşmiştir. Buradan, özellik uzayında bir birini kapsayan alt kümelerin oluşmadığı anlaşılır. Bu ise, bir özellik çıkarım algoritmasından beklenen en iyi sonuç

olup, geliştirilen özellik çıkarım yapılarının, sınıflar arasındaki ayrımı ne kadar keskin bir şekilde sağladığını göstermektedir.

6. Adaptif özellik çıkarma ve sınıflama tabanlı akıllı örüntü tanıma için geliştirilen yeni dalgacık sinir ağı modellerinin başarımı ise DPSA modelinde %95.7 olarak en yüksek değerine ulaşmıştır. Geliştirilen bu modellerde, [114-116,118-120] çalışmalarının dezavantajı olarak karşımıza çıkan, giriş değerine çok farklı perspektiften bakılmasından dolayı, aynı giriş verisini birden çok kez kullandığı için DSA 'nın işlem yükü fazla olmasından kaynaklanan dalgacık sinir ağının hızındaki düşme problemine, entropi kavramı DSA yapısının içerisine gömülerek çözülmüştür. Böylelikle DSA 'nın işleyeceği veri boyutu sadece entropi değerlerinin sayısı kadar olacaktır. Ayrıca özellik uzayı, sınıflayıcının eğitim başarımına etkileşimli olarak katkıda bulunmaktadır. Dolayısı ile özellik çıkarımını ayrı, sınıflama sürecini ayrı ayrı değerlendirmek yerine, burada bu her iki süreç bir birini destekleyici rol oynamaktadırlar.
7. Durağan olmayan işaretler için geliştirilen akıllı örüntü tanıma sistemlerinin girişine, işaret örüntülerini doğrudan vermek yerine, önerilen ön işlem süreci ile bu sistemlerin başarımına katkıda bulunulmuştur. DKS işaretlerine uygulaması yapılan, geliştirilen ön işlem sürecinde, gürültüden ayrışım, normalizasyon gibi aşamalar ile durağan olmayan işaret içerisinde bulunan serbest iç ve dış dinamiklere müdahale edilerek, örüntü tanıma sisteminin başarımına olumsuz yönde olan etkileri minimum düzeye çekilmiştir.
8. Entropi kavramının geliştirilen yöntemlerde kullanılması, durağan olmayan işaretlerin karakterizasyonu için çok kullanışlı bir araç olmuştur. Böylece bu yeni tanılama bilgisi elde etme yöntemi, geleneksel genliğe bağlı yöntemlere göre farklı bir yaklaşımdır.

8.2. Öneriler

1. Geliştirilen akıllı örüntü tanıma sisteminin uygulaması sadece DKS işaret örüntüleri üzerine yapılmasına rağmen, Bölüm 1.2. de verilen durağan olmayan işaret örneklerinin her birine uygulanabilir. Örneğin, EEG işaretlerine yapılabilecek uygulaması ile, Epilepsi hastaları için erken uyarı sistemi geliştirilebilir.

2. DKS işaret örüntüleri için yapılan uygulamada, YSA sınıflandırıcısının eğitimi için kullanılan veri örneklerinin sayısı arttırılarak, geliştirilen tıbbi akıllı karar destek sisteminin başarımı daha da yükseltilebileceği gibi hastalık hakkında ayrıntılı bilgilerde (darlık, yetmezlik derecesi, gibi) otomatik olarak çıkartılabilir.
3. MUSIC algoritmasında ortaya çıkan hız problemi, DSP gerçeklemeleri ile giderilebilir.

8.3. Yayınlar

FÜBAP-527 (Fırat Üniversitesi Bilimsel Araştırma Projeleri Birimi) nolu proje ile desteklenen bu tez çalışması, üç adet dergi yayını [133-135] ve iki adet konferans yayını [24,136] ile sonuçlanmıştır.



KAYNAKLAR

1. Rothe, H., 1998, "Approaches to pattern recognition, advanced pattern recognition techniques", NATO-RTO Lecture Series 214, Lisbon Portugal, 1.1 – 1.29.
2. Stein, J.Y., 2000, *Digital Signal Processing: A Computer Science Perspective*. John Wiley & Sons, New York, 870s.
3. Vaseghi, S.V., 2000, *Advanced Digital Signal Processing and Noise Reduction*. John Wiley & Sons, İngiltere, 495s.
4. Meyr, H., Moeneclaey, M. and Fechtel, S.A., 1998, *Digital Communication Receivers: Synchronization, Channel Estimation and Signal Processing*. John Wiley & Sons, New York, 845s.
5. Boashash, B. and Mesbah, M., 2001, "A time – frequency approach for newborn seizure detection," IEEE Engineering in Medicine and Biology Magazine, 20, No. 5, September/October 2001, 54-64.
6. Andria, G., Attivissimo, F. and Lanzolla, A., 1997, "Interpolation techniques for non-stationary signal analysis", Elsevier Measurement, 21, 1-16.
7. Mertins, A., 1999, *Signal Analysis*. John Wiley & Sons, Avustralya, 329s
8. Madrid, J.J.M., Corredera, J.R.C. and Vela, G.M., 1992, "A neural network approach to Doppler-based target classification", Radar 92 International Conference, Helsinki, 450-453.
9. Hopgood, J.R., 2000, "Nonstationary signal processing with application to reverberation cancellation in acoustic environments", Doktora Tezi, Cambridge Üniversitesi, 391s.
10. Arnold, M., Miltner, W.H.R., Witte, H., Bauer, R. and Braun, C., 1998, "Adaptive AR modelling of nonstationary time series by means of kalman filtering", IEEE Transaction Biomedical Engineering, 45, No.5, Mayıs 1998, 553-562.
11. Karlsson, S., Yu, J. and Akay, M., 2000, "Time-Frequency analysis of myoelectric signals during dynamic contractions: A comparative study", IEEE Transaction Biomedical Engineering, 47, No.2, Şubat 2000, 228-238

12. Sekihara, K., Nagarajan, S.S., Poeppel, D., Miyauchi, S., Fujimaki, N., Koizumi, H. and Miyashita, Y., 2000, "Estimating neural sources from each time-frequency component of magnetoencephalographic data", *IEEE Transactions on Biomedical Engineering*, 47, No. 5, Mayıs 2000, 642-653.
13. Krishnan, S., Rangayyan, R.M., Bell, G.D. and Frank, C.B., 2000, "Adaptive time – frequency analysis of knee joint vibroarthrographic signals for noninvasive screening of articular cartilage pathology", *IEEE Transactions on Biomedical Engineering*, 47, No. 6, Haziran 2000, 773-783.
14. Bianchi, A.M., Mainardi, L., Petrucci, E., Signorini, M.G., Mainardi, M. and Cerutti, S., 1993, "Time – variant power spectrum analysis for the detection of transient episodes in HRV signal", *IEEE Transactions on Biomedical Engineering*, 40, No.2, Şubat 1993, 136-144.
15. Lin, Z.Y. and Chen, D.Z., 1994, "Time – frequency representation of the Electrogastrogram – Application of the exponential distribution", *IEEE Transaction Biomedical Engineering*, 41, No.3, Mart 1994, 267-275.
16. Guo, Z., Durand, L.G. and Lee, H.C., 1994, "Comparasion of time – frequency distribution techniques for analysis of simulated Doppler ultrasound signals of the Femoral Artery," *IEEE Transaction Biomedical Engineering*, 41, No. 4, Nisan 1994, 332-342.
17. Kselbrener, L. and Akselrod, S., 1996, "Selective discrete fourier transform algorithm for time – frequency analysis: Method and application on simulated and cardiovascular signals", *IEEE Transaction Biomedical Engineering*, 43, No.8, Ağustos 1996, 789-802.
18. Khalil, M. and Duchene, J., 1999, "Detection and classification of multiple events in piecewise stationary signals: Comparison between autoregressive and multiscale approaches", *Elsevier Signal Processing*, 75, 239-251.
19. Zhang, Y., Wang, Y., Wang, W. And Liu, B., 2001, "Doppler ultrasound signal denoising based on wavelet frames", *IEEE Transactions on Ultrasonics, Ferroelectrics and Frequency Control*, 48, No.3, Mayıs 2001, 709-716.
20. Yüksel, M.E., 1996, "Durağan olmayan ses ötesi Doppler işaretlerinin zamana bağımlı adaptif parametrik modelleri ile modellenmesi", *Doktora Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü*, 83s.

21. Keeton, P.I.J. and Schlindwein, F.S., 1997, "Application of wavelets in doppler ultrasound", *Sensor Review*, MCB University Press, 17, No.1, 38–45.
22. Marple, L., Brotherton, T., Barton, R., Lugo, E. and Jones, D., 1993. "Travels through the time-frequency zone: advanced Doppler ultrasound processing techniques," *The Twenty-Seventh Asilomar Conference on Signals, Systems and Computers*, 2, 1469-1473.
23. Bishop, C.M., 1996, *Neural networks for pattern recognition*. Clarendon Press, Oxford, 482s.
24. Türkoğlu, İ. ve Arslan, A., 2001, "An intelligent pattern recognition system based on neural network and wavelet decomposition for interpretation of heart sounds", 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC2001), 25-28 October 2001, İstanbul, 4.2.4.(f).
25. Nandi, A.K. ve Azzouz, E.E., 1998, "Algorithms for automatic modulation recognition of communication signals," *IEEE Transactions on Communications*, 46, No. 4, 431-436.
26. Wong, K.W., Lam, K.M. ve Siu, W.C., 2001, "An efficient algorithm for human face detection and facial feature extraction under different conditions", *Elsevier Pattern Recognition*, 34(10), 1993-2004.
27. Thomas, F., 1995, "Application of pattern recognition techniques for Early Warning Radar (EWR) discrimination", *NASA Teknik Raporları, Communications and Radar*, No. AD-A298895, USA, 42s.
28. Rutledge, G.A., 2000, "Dictionary Projection Pursuit: A wavelet packet technique for acoustic spectral feature extraction", *Doktora Tezi, Victoria Üniversitesi*, 193s.
29. Burrus, C.S., Gopinath, R.A. and Guo, H., 1998, *Introduction to Wavelet and Wavelet Transforms*. Prentice Hall, New Jersey, 268s.
30. Devasahayam, S.R., 2000, *Signals and Systems in Biomedical Engineering*. Kluwer Academic Publishers, New York, 337s.
31. Cardoso, J.C.S., Ruano, M.G. ve Fish, P.J., 1996, "Nonstationarity broadening reduction in pulsed Doppler spectrum measurements using time – frequency estimators", *IEEE Transaction Biomedical Engineering*, 43, No.12, 1176-1186.

32. Plett, M.I., 2000, "Ultrasonic arterial vibrometry with wavelet based detection and estimation", Doktora Tezi, Washington Üniversitesi, 234s.
33. Liu, P.C., 1999, "A fifteen minutes introduction of wavelet transform and applications," Proceedings, ASCE 1999 International Water Resources Engineering Conference, 7s.
34. Akay, M. ve Mello, C., 1997, "Wavelets for biomedical signal processing", Proceedings 19th International Conference – IEEE/EMBS, 30 Ekim-2 Kasım, Chicago, 2688-2691.
35. Aydın, N., Padayachee, S. and Markus, H.S., 1999, "The use of the wavelet transform to describe embolic signals", Ultrasound Medicine & Biologoy, 25, 953-958.
36. Sternickel, K., 2002, "Automatic pattern recognition in ECG time series", Computer Methods and Programs in Biomedicine, 68, ss.109–115.
37. Pittner, S. ve Kamarthi, S.V., 1999, "Feature extraction from wavelet coefficients for pattern recognition tasks", IEEE Transactions on Pattern Analysis and Machine Intelligence, 21(1), 83 –88.
38. Chan, B.C.B., Chan, F.H.Y., Lam, F.K., Lui, P.W. ve Poon, P.W.F., 1997, "Fast detection of venous air embolism is Doppler heart sound using the wavelet transform", IEEE Transactions on biomedical engineering, 44, No.4, 237-245.
39. Rajan, J.J., 1994, "Time series classification", Doktora Tezi, Cambridge Üniversitesi, 191s.
40. Duda, R.O. and Hart, P.E., 1989, *Pattern Classification and Scene Analysis*. Stanford Research Institute, 483s.
41. Phan, F., Tzanakou, E.M. and Sideman, S., 2000, "Speaker identification using neural networks and wavelets", IEEE Engineering in Medicine and Biology, Ocak/Şubat, 92-101.
42. Akin, M., Arserim, M.A., Kıymık, M.K. and Türkoğlu, İ., 2001, "A new approach for diagnosing epilepsy by using wavelet transform and neural networks", 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC2001), 25-28 October 2001, İstanbul, 4.2.6.(1).
43. Türkoğlu, İ. ve Hanbay, D., 2001, "Yapay sinir ağı ve HFD kullanarak DTMF sinyal örüntülerini tanıma sistemi", Elektrik-Elektronik-Bilgisayar Mühendisliği 9.Ulusal Kongresi, 19-23 Eylül 2001, Kocaeli, 431-434.

44. Sowelam, S.M. ve Tewfik, A.H., 2000, "Waveform selection in radar target classification", IEEE Transactions on Information Theory, 46, 1014 –1029.
45. Chau, T., 1994, "Pattern recognition of processed EMG signals for two-site Myoelectric control", Uygulamalı Master Lisans Tezi, Toronto Üniversitesi, 96s.
46. Kil, D.H. ve Shin, F.B., 1996, *Pattern Recognition and Prediction with Applications to Signal Characterization*. AIP Press, USA, 417s.
47. Englehart, K., 1998, "Signal Representation for Classification of the Transient Myoelectric Signal", Doktora Tezi, New Brunswick Üniversitesi, Kanada, 319s.
48. Young, T.Y. and Fu, K.S., 1986, *Handbook of pattern recognition and image processing*. Academic Press, Inc, 159s.
49. Boller, C., Staszewski, W., Worden, K., Manson, G. and Tomlinson, G., 2000. "Structure integrated sensing and related signal processing for condition-based maintenance", Conference of The Condition-Based Maintenance For Highly Engineered Systems, Eylül 25-27, Pisa Üniversitesi, İtalya, 16s.
50. Banks, S.P., 1990, *Signal Processing, Image Processing and Pattern Recognition*, Prentice-Hall, New York, 409s.
51. Türkoğlu, İ., 1996, "Yapay sinir ağları ile nesne tanıma", Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ, 112 s.
52. Ward, M., 1998, "Detection and classification of transient underwater sounds by a finite impuls response neural network", Yüksek Lisans Tezi, New Brunswick Üniversitesi, Fredericton, Kanada.
53. Kaita, T., Tomita, S. and Yamanaka, J., 2002, "On a higher-order neural network for distortion invariant pattern recognition", Pattern Recognition Letters, 23,8,977-984.
54. Schalkoff, R., 1992, *Pattern Recognition: Statistical, Structural and Neural Approaches*. John Wiley & Sons, 384s.
55. Türkoğlu, İ. ve Arslan, A., 1996, "Eğitici ve eğitici olmayan yapay sinir ağı modellerinin örüntü tanıma başarılarının karşılaştırılması", 4. Bilgisayar – Haberleşme Sempozyumu Bildiriler Kitabı, Bursa, 72-75.

56. Karras, D.A., Karkanis, S.A. and Mertzios, B.G., 1998, "Information systems based on neural network and wavelet methods with application to decision making, modeling and prediction tasks", *Kybernetes, MCB Üniversitesi*, 27, No.3, 224-236.
57. Belouchrani, A. and Amin, M.G., 1998, "Blind source separation based on time-frequency signal representations", *IEEE Transactions on Signal Processing*, 46, No.11, 2888-2897.
58. Hlawatsch, F. and Boudreaux-Bartels, F., 1992, "Linear and quadratic time-frequency signal representations", *IEEE Signal Processing Magazine*, 9, No.2, 21-67.
59. Rorabaugh, C.B., 1999, *DSP Primer*. Mc Graw Hill, 518s.
60. Shannon, C.E., 1948, "A mathematical theory of communication", *Bell System Technology Journal*, 27, 379-423.
61. Tonga, S., Bezerianosa, A., Paula, J., Zhub, Y. and Thakora, N., 2002, "Nonextensive entropy measure of EEG following brainin jury from cardiac arrest", *Elsevier Physica A*, 305, 619 – 628.
62. Principe, J.C., Euliano, N.R. and Lefebvre, W.C., 2000, *Neural and Adaptive Systems*. John Wiley & Sons, 1. Baskı, New York, 656s.
63. Quiroga, R.Q., 1998, "Quantitative analysis of EEG signals: Time-frequency methods and Chaos theory", *Doktora Tezi, Medical Üniversitesi, Lübeck*, 129s.
64. Overwijk, M.H.F. and Reefman, D., 2000, "Maximum-entropy deconvolution applied to electron energy-loss spectroscopy", *Pergamon Micron*, 31, 325-331.
65. Li, X., 2000, "Edge directed statistical inference with applications to image processing", *Doktora Tezi, Princeton Üniversitesi*, 131s.
66. Zhang, X.S. and Roy, R.J., 2001, "Derived fuzzy knowledge model for estimating the depth of anesthesia", *IEEE Transactions on Biomedical Engineering*, 48, No.3, 312-323.
67. Hoang, M., Aaron, R. and Shiffman, C.A., 1997, "Maximum entropy method for Magnetoencephalography", *IEEE Transactions on Biomedical Engineering*, 44,1,98-102.
68. Coifman, R.R. and Wickerhauser, M.V., 1992, "Entropy-based algorithms for best basis selection", *IEEE Transaction on Information Theory*, 38, 2, 713-718.

69. Penny, W.D., 2000, "Signal Processing Course," 28 Nisan 2000, 178s.
70. Hoekstra, A., 1998, "Generalisation in feed forward neural classifiers", Delft Teknik Üniversitesi, Doktora Tezi, Delft, Hollanda, 127s.
71. Rafiq, M.Y., Bugmann, G. and Easterbrook, D.J., 2001, "Neural network design for engineering applications", *Computers & Structures*, 79(17), 1541-1552
72. Pham, D.T. and Pham, P.T.N., 1999, "Artificial intelligence in engineering", *International Journal of Machine Tools and Manufacture*, 39(6), 937-949.
73. Lin, C.T. and Lee C.S.G., 1996, *Neural Fuzzy Systems*. Prentice-Hall, 797s.
74. Türkoğlu, İ. ve Arslan, A., 2002, "Çok katmanlı yapay sinir ağlarında en iyi etkinleştirme fonksiyonu seçimi için çok ölçekli bir yaklaşım", *Anadolu Üniversitesi Bilim ve Teknoloji Dergisi*, 1,1, Eskişehir.
75. Zurada, M.J., 1992, "Introduction to artificial neural systems," West Publishing Company Inc., New York, 715s.
76. Haykin, S., 1994, *Neural networks, A Comprehensive Foundation*. Macmillan College Publishing Company Inc., New York, 417s.
77. Rothe, H., Fecht, A., Kasper, A., and Rinder, T., 1998, "Practical Applications of pattern recognition techniques", *NATO-RTO Lecture Series 214*, Lisbon Portugal, 12-1,12-25.
78. Hush, D.R. and Horne, B.G., 1993, "Progress in supervised neural networks: What's new since Lippmann", *IEEE Signal Processing Magazine*, Temmuz, 8-39.
79. Moody, J. and Darken, C.J., 1989, "Fast learning in networks of locally – tuned processing units", *Neural Computation*, 1, 281-293.
80. Specht, D.F., 1990, "Probabilistic neural networks", *Neural Networks*, 3, 109-118.
81. Kohonen, T., 1988, "An introduction to neural computing", *Neural Networks*, 1(1), 3-16.
82. Waibel, A., Hanazawa, T., Hinton, G., Shikano, K. and Lang, K., 1989, "Phoneme recognition using time-delay neural networks", *IEEE Transactions on Acoustics, Speech and Signal Processing*, 37, No.3, 328-339.

83. Pineda, F.J., 1988, "Dynamics and achitecture for neural computation", *Journal of Complexity*, 4, 216-245.
84. Hopfield, J.J., 1982, "Neural networks and physical systems with emergent collective computational abilities", *Proceedings of the National Academy of Science, USA*, 79, 2554-2558.
85. Carpenter, G.A. and Grossberg, S., 1987, "A massively parallel architecture for a self-organizing neural pattern recognition machine", *Computer Vision, Graphics, and Image Processing*, 37, 54-115.
86. Kohonen, T., 1989, "Self organization and associative memory", Berlin: Springer-Verlag,3.
87. Morlet, J., Arens, G., Fourgean, E. and Giard, D., 1982, "Wave propogation and sampling theory – Part I-II", *Geophysics*, 47(2), 203-236.
88. Grossmann, A. and Morlet, J., 1984, "Decomposition of hardy functions into square integrable wavelets of constant shape", *SIAM Journal of Mathematical Analysis*, 15(4), 723-736.
89. Goupillaud, P., Grossmann, A. and Morlet, J., 1984, "Cycle-octave and related transforms in seismic signal analysis", *Geoexploration*, 23, 85-102.
90. Chui, C.K., 1992, *Wavelets: A tutorial in theory and applications*. Academic Press, New York, 730s.
91. Meyer, Y., 1993, *Wavelets: Algorithms and Applications*. SIAM Press, Philedelphia, 133s.
92. Mallat, S., 1989, "A theory for multiresolution signal decomposition: The wavelet representation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7), 674-693.
93. Daubechies, I., 1992, *Ten Lectures on Wavelets*. Philadelphia: Society of Industrial and Applied Mathematics, Philadelphia, 357s.
94. Coifman, R.R. and Wickerhauser, M.V., 1992, "Wavelets and adapted waveform analysis", *Wavelets: Mathematics and Applications, Studies in Advanced Mathematics*, Florida, 399-423.

95. Karlsson, S., Yu, J., and Akay, M., 1999, "Enhancement of spectral analysis of myoelectric signals during static contractions using wavelet methods", *IEEE Transactions on Biomedical Engineering*, 46, No.6, 670-684.
96. Akay, M., 1994, "Investigating the effects of vasodilator drugs on the turbulent sound caused by femoral artery stenosis using short-term fourier and wavelet transform methods", *IEEE Transaction ob Biomedical Engineering*, 41,921-928.
97. Akay, Y.M., 1994, "Noninvasive detection of coronary artery disease", *IEEE Engineering in Medicine & Biology*, 13, 5, Kasım-Aralık 1994, 761-764.
98. Senhadji, L., 1995, "Comparing wavelet transforms for recognizing cardiac patterns", *IEEE Engineering in Medicine & Biology*, 14, 2 , Mayıs-Nisan 1995, 167-173.
99. Walton, E.K., 1998, "Wavelet techniques and other multiresolution techniques for target phenomenology studies", *NATO-RTO Lecture Series 214*, Lisbon Portugal, 3-1, 3-33.
100. Jing, F., Xuemin, W., Mingshi, W. and Wie, L., 1997, "Noninvasive acoustical analysis system of coronary heart disease", *Biomedical Engineering Conference, Proceedings of the 1997 Sixteenth Southern*, 239 –241.
101. Strang, G. and Nguyen, T., 1996, *Wavelets and Filter Banks*. Wellesley-Cambridge Press, Cambridge, MA, 390s.
102. Bhattacharya, G.K. and Johnson, R., 1968, "Nonparametric tests for shifts at an unknown time point", *Ann Math Statist*, 23, 183–208.
103. Brodsky, B.E. and Darkhovsky, B.S., 1993, *Nonparametric methods in change-point problems*. Kluver Academic Publisher, Dordrecht, 209s.
104. Deshayes, J. and Picard, D., 1981, *Testing for a change-point in a statistical model: rapport technique*. Orsay: Universite de Paris-Sud.
105. Kaplan, A., Röschke, J., Darkhovsky, B. And Fell, J., 2001, "Macrostructural EEG characterization based on nonparametric change point segmentation: application to sleep analysis", *Elsevier Journal of Neuroscience Methods*, 106, 81–90.
106. Rabiner, L.R. and Schafer, R.W., 1978, *Digital Processing of Speech Signals*. Englewood Cliffs, NJ: Prentice Hall.

107. Oppenheim, A.V. and Schafer, R.W., 1989, "Discrete-Time Signal Processing", Englewood Cliffs, NJ: Prentice Hall, 713-718.
108. Welch, P.D., 1967, "The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodograms", IEEE Transaction Audio Electroacoustic, AU-15 Haziran, 70-73.
109. Schmidt, R.O., 1986, "Multiple emitter location and signal parameter estimation", IEEE Transaction Antennas Propagation, AP-34 Mart, 276-280.
110. Kara, S., 1994, "Doppler cihazı ve autoregresif spektral analiz metoduyla mitral ve triküspit kapaklarındaki kan akışının incelenmesi", Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Doktora tezi, 60s.
111. Güler, I. and Kara, S., 1995, "Detection of mitral stenosis by a pulsed Doppler flowmeter and autoregressive spectral analysis method", 14th Conference of the Biomedical Engineering Society of India, IEEE Proceedings, 2/91 -2/92.
112. Proakis, J.G. ve Manolakis, D.G., 1996, *Digital Signal Processing: Principles, Algorithms, and Applications*. Englewood Cliffs, NJ: Prentice Hall.
113. Marple, S.L., 1987, *Digital Spectral Analysis*. Englewood Cliffs, NJ: Prentice Hall.
114. Dickhous, H. and Heinrich, H., 1996, "Classifying Biosignals with Wavelet Networks," IEEE Engineering in Medicine and Biology, Eylül/Ekim, 103-111.
115. Thuillard, M., 2000, "A Review of Wavelet Networks, Wavenets, Fuzzy Wavenets and Their Applications", ESIT'2000, Aachen, Almanya, 14-15 Eylül 2000, 5-16.
116. Zhang, Y. and Jiao, L., 1998, "An Efficient Method of Target Classification," IEEE Proceedings of IGSP'98, 1181-1184.
117. Zhang, Q. and Benveniste, A., 1992, "Wavelet Network", IEEE Transaction on neural networks, 3, No.6, Kasım 1992, 889-898.
118. Tkacz, E.J. and Kostka, P., 2000, "An application of wavelet neural network for classification of patients with coronary artery disease based on HRV analysis", Engineering in Medicine and Biology Society, Proceedings of the 22nd Annual International Conference of the IEEE, 2, 1391-1393.

119. Kostka, P., Tkacz, E.J. and Malota, Z., 2000, "An application of wavelet neural networks (WNN) for heart valve prostheses characteristic", Engineering in Medicine and Biology Society, Proceedings of the 22nd Annual International Conference of the IEEE, 4, 2463-2465.
120. Wang, L., Teo, K.K. and Lin, Z., 2001, "Predicting time series with wavelet packet neural networks", IJCNN '01 International Joint Conference on Neural Networks, Proceedings, 3, 1593 –1597.
121. Nguyen, D. and Widrow, B., 1990, "Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights", Proceedings of the International Joint Conference on Neural Networks, 3, 21-26.
122. Rumelhart, D.E., Hinton, G.E. and Williams, R.J., 1986, "Learning representations by back-propagating errors", Nature, 323, 533–536.
123. Saini, V.D., Nanda, N.C. and Maulik, D., 1993, "Basic Principles of Ultrasound and Doppler Effect", Doppler Echocardiography, Lea & Febiger Philadelphia, London,
124. Madeira, M.M., Tokhi, M.O. and Ruano, M.G., 2000, "Real-time implementation of a Doppler signal spectral estimator using sequential and parallel processing techniques", Elsevier Microprocessors and Microsystems, 24, 153–167.
125. Karabetsos, E., Papaodysseus, C. and Koutsouris, D., 1998, "Design and development of a new ultrasonic doppler technique for estimation of the aggregation of red blood cells", Elsevier Measurement, 24, 207–215.
126. Bakhtazad, A., Palazoglu, A. and Romagnoli, J.A., 1999, "Process data de-noising using wavelet transform", Intelligent Data Analysis, 3, Ekim 1999, 267-285.
127. Donoho, D.L., 1995, "De-noising by soft-thresholding", IEEE Transaction Information Theory, 41, 3, 613–627.
128. Rumelhart, D.E., Hinton, G.E. and Williams, R.J., 1986, *Learning internal representations by error propagation*. Parallel Distributed Processing, 1, 8, Cambridge, MIT Press.
129. Vogl, T.P., Mangis, J.K., Rigler, A.K., Zink, W.T. and Alkon, D.T., 1988, "Accelerating the convergence of the back-propagation method", Biol. Cybern, 59:257-263.

130. Jacobs, R.A., 1988, "Increased rates of convergence through learning rate adaptation", *Neural networks*, 1, 295-307.
131. Freeman, J.A. and Skapura, D.M., 1991, "Neural Networks: Algorithms, Applications, and Programming Techniques", Reading, MA, Addison-Wesley.
132. Narayan, S., 1999, "The Generalized Sigmoid Activation Function Competitive Supervised Learning", *Elsevier Science Inc. Information Sciences*, 69-82.
133. Türkoğlu, İ., Arslan, A., and İlkay E., 2002, "A decision support system for diagnose of the heart valve diseases", *Sakarya Üniversitesi, Fen Bilimleri Enstitüsü Dergisi*, 6, 2, Temmuz 2002, (Basılmak üzere kabul edildi).
134. Türkoğlu, İ., Arslan, A., and İlkay E., 2002, "A pattern recognition system for diagnose of the heart mitral valve diseases based on wavelet packet and neural network", *Fırat Üniversitesi, Fen ve Mühendislik Bilimleri Dergisi*, 14-1, (Basılmak üzere kabul edildi) .
135. Türkoğlu, İ., Arslan, A., ve İlkay E., 2002, "An expert system for diagnose of the heart valve diseases," *Elsevier Science Expert systems with applications*, vol. 23(3), October 2002 (Basılmak üzere kabul edildi).
136. Türkoğlu, İ., Arslan, A., ve İlkay E., 2002, "Kalp Kapak Hastalıklarını Teşhis Etmek İçin Doppler Tekniğine Dayalı Akıllı Bir Karar Destek Sistemi", *Biyomut 2002, Biyomedikal Mühendisliği Ulusal Toplantısı Bildiriler Kitabı*, 30 Mayıs, İstanbul.

ÖZGEÇMİŞ

İbrahim TÜRKOĞLU

Fırat Üniversitesi
Teknik Eğitim Fakültesi
Elektronik ve Bilgisayar Eğitimi Bölümü
23119, Elazığ

Tel : 424 – 2370000 – 6255
E.posta : iturkoglu@firat.edu.tr

- 1973** Elazığ da doğdu.
- 1987 – 1990** Endüstri Meslek Lisesi Elektrik bölümünü tamamladı.
- 1990 – 1994** Fırat Üniversitesi Mühendislik Fakültesi Elektrik – Elektronik bölümünden bölüm ikincisi olarak mezun oldu.
- 1994 – 1996** Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalında “Yapay sinir ağları ile nesne tanıma” konusunda yaptığı tez çalışması ile Yüksek Mühendis derecesini aldı.
- 1995 – ...** Fırat Üniversitesi, Teknik Eğitim Fakültesi Elektronik-Bilgisayar bölümünde öğretim görevlisi olarak çalışmaktadır.
- 1997 – ...** Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik – Elektronik Mühendisliği Anabilim Dalında doktora tez çalışmasına başladı.

EK – 1

Acuson Sequoia 512 Ultrason Sisteminin 3V2c Model Transdüserin Teknik Özellikleri

Çalışma modu : Sürekli Dalga

İndeks Etiketi			MI	TIS/TIB	TIS		TIB	TIC
				Tarama	Tarama yok		Tarama yok	
					$A_{aprt} \leq 1$	$A_{aprt} \geq 1$		
Maksimum İndeks Değeri			1.0	*	*	0.24	1.2	1.1
Akustik Parametreler	Pr.3 [MPa]		1.9					
	W_0 [mW]			*	*		38	54
	Minimum $[W_{.3}(z_1), I_{TA.3}(z_1)]$ [mW]					26		
	Z_1 [cm]					2.9		
	Z_{bp} [cm]					1.8		
	Z_{ap} [cm]		5.0				4.0	
	$d_{ep}(z_{sp})$ [cm]						0.43	
	f_c [MHz]		3.4	*	*	2.0	2.0	2.0
	Boyut	X [cm]		*	*	0.84	0.84	0.82
A_{aprt} Y [cm]			*	*	1.4	1.4	1.4	
Diğer Bilgiler	PD [μsec]		0.65					
	PRF [Hz]		0.0079					
	$Pr@PII_{max}$ [MPa]		3.4					
	$d_{eq}@PII_{max}$ [cm]						0.43	
	Odak uzunluğu [cm]			*	*	4.0		2.6
	$I_{PA.3}@MI$ [W/cm ²]		209					

EK – 2

Ses Kartının Teknik Özellikleri

Modeli : ES1869 Audo Drive ISA Kart
Örnekleme frekansı : 4 – 48 Khz.
Analog giriş kanal sayısı : 2
A/D PCM çözünürlük : 8, 16 bit
Veri transfer modu : DMA



