

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKILLI RADAR İLE HEDEF TANIMA SİSTEMİ

Engin AVCI

Tez Yöneticisi

Prof. Dr. Mustafa POYRAZ

Yrd. Doç. Dr. İbrahim TÜRKOĞLU

DOKTORA TEZİ
ELEKTRİK – ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ELAZIĞ, 2005

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKILLI RADAR İLE HEDEF TANIMA SİSTEMİ

Engin AVCI

DOKTORA TEZİ
ELEKTRİK – ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Bu tez, 26.04.2005 tarihinde aşağıda belirtilen jüri tarafından oybirliği / ~~oyçokluğu~~ ile başarılı / ~~başarısız~~ olarak değerlendirilmiştir.

Danışman : Prof. Dr. Mustafa POYRAZ

Üye : Prof. Dr. M. Kemal KIYMIK

Üye : Doç. Dr. Yakup DEMİR

Üye : Doç. Dr. Z. Hakan AKPOLAT

Üye : Yrd. Doç. Dr. Mehmet KAYA

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

Bu tezin kabulü, Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 06/05/05 tarih ve 2005-14/1 sayılı kararıyla onaylanmıştır.

TEŞEKKÜR

Bu tez çalışmam boyunca, ilgi ve yardımlarını esirgemeyen danışmanlarım Sayın Prof. Dr. Mustafa POYRAZ' a ve Sayın Yrd. Doç. Dr. İbrahim TÜRKOĞLU' na, çalışmam boyunca beni sabır ve özveri ile destekleyen anneme, babama, kardeşim Sayın Dr. Esin AVCI' ya, değerli büyüğüm Sayın Dr. Levent AVCI' ya, çalışmamda kullandığım bulanık mantık konusundaki değerli fikirlerinden faydalandığım yüksek lisans tez danışmanım Sayın Doç. Dr. Z. Hakan AKPOLAT' a, tezin düzenlenmesindeki yardımlarından ötürü Sayın Arş. Gör. Resul ÇÖTELİ' ye, Sayın Arş. Gör. Gonca ÖZMEN' e, Sayın Arş. Gör. Davut HANBAY' a, Sayın Arş. Gör. Korhan KAYIŞLI' ya, Sayın Öğr. Gör. Murat KARABATAK' a, Sayın Arş. Gör. Abdulkadir ŞENGÜR' e, Sayın Öğr. Gör. Cafer BAL' a, Sayın Yaşar MUT' a, Sayın Ümit Nuri AYDIN' a ve bu tez çalışmam boyunca benden maddi ve manevi yardımlarını esirgemeyen değerli bölüm hocalarıma ve arkadaşlarıma teşekkürlerimi ve şükranlarımı sunarım.

İÇİNDEKİLER

Sayfa

TEŞEKKÜR

İÇİNDEKİLER	I
ŞEKİLLER LİSTESİ	V
TABLolar LİSTESİ.....	VIII
EKLER LİSTESİ.....	IX
SİMGELER LİSTESİ	X
KISALTMALAR LİSTESİ	XIII
ÖZET.....	XV
ABSTRACT	XVI

1. GİRİŞ	1
1.1. Radar Hedef Tanımanın Tarihçesi.....	1
1.1.1. İlk Radar Hedef Tanıma Çalışmaları.....	2
1.1.2. Radar Hedef Tanıma Çalışmalarının Günümüzdeki Durumu	2
1.2. Radar Hedef Tanıma Konusunda Yapılan Literatür Taraması.....	3
1.2.1. Özellik Çıkarım Yöntemleri Bakımından	3
1.2.2. Sınıflandırıcı Çeşitleri Bakımından.....	8
1.2.3. Radar ve Hedef Tipi Bakımından	8
1.2.4.Yapılan Literatür Tarama Çalışmalarının Genel Değerlendirmesi	9
1.3. Amaç	9
1.4. Radar Hedef Eko İşaretleri.....	10
1.5. Tezin Organizasyonu ve Orijinal Katkıları	12
2. ÖRÜNTÜ TANIMA.....	14
2.1. Örüntü Tanıma Problemi	15
2.2. Özellik Çıkarma Süreci.....	17
2.2.1. Zaman – Frekans Teknikleri ile İşaret İşleme	18
2.2.2. Entropi Kavramı.....	19
2.2.3. Genetik Algoritmalar	20
2.2.3.1. Genetik Algoritma Operatörleri.....	22
2.2.3.2.Kromozomun Şifrelenmesi(Encoding)	22

2.2.3.3. Genetik Algoritmanın Parametreleri	25
2.2.4. Meksika Şapkası Dalgacık Dönüşüm Skalogramı	25
2.2.5. Resim Bölütleme	30
2.2.6. Canny Kenar Çıkarma Yöntemi	30
2.2.7. Merkez Kenar Değişim Yöntemi	32
2.3. Sınıflandırma Süreci	33
2.3.1. Yapay Sinir Ağı Sınıflandırıcıları	34
2.3.1.1. Biyolojik Sinir Ağları ile Yapay Sinir Ağlarının Kıyaslanması	35
2.3.1.2. Yapay Sinir Ağlarının Yapıları	38
2.3.1.3. Yapay Sinir Ağlarında Öğrenme ve Öğrenme Algoritmaları	38
2.3.2. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi Sınıflandırıcıları	41
2.3.2.1. UATBÇS Mimarisi	42
2.3.2.2. UATBÇS İçin Geri Yayımlı Öğrenme Algoritması	44
2.3.3. Bulanık C-Ortalamalar Sınıflandırıcısı	49
2.3.3.1. Matematiksel Temel	49
2.3.3.2. Eğitim	50
2.3.3.3. Test Etme	50
2.3.4. Kohonen Yapay Sinir Ağları Sınıflandırıcısı	52
2.3.4.1. Kohonen Yapay Sinir Ağları Sınıflandırıcısının Yapısı	53
3. ÖZELLİK ÇIKARIMI İÇİN YÖNTEMLER.....	58
3.1. Dalgacık Dönüşüm Zaman-Frekans Gösterim Entropileri ile Özellik Çıkarma Yöntemleri	58
3.1.1. Dalgacık Dönüşümünü	58
3.1.2. Dalgacık Dönüşüm Ağacından Entropi Hesaplanması	62
3.1.3. Dalgacık Paket Dönüşüm Ağacından Entropi Hesaplanması	62
3.2. Çeşitli Zaman-Frekans Gösterim Entropileri ile Özellik Çıkarma Yöntemleri	63
3.2.1. Kısa Zamanlı Fourier Dönüşümü ile Spektrogram	64
3.2.1.1. Dalgacık Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması	66
3.2.1.2. Dalgacık Paket Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması	67

3.2.2. Wigner-Ville Zaman Frekans Gösterimi	67
3.2.3. Born Jordan Zaman Frekans Gösterimi	69
3.2.4. Choi-Williams Zaman Frekans Gösterimi.....	72
3.3. Geliştirilen Optimum Entropi Tabanlı Özellik Çıkarma Yöntemi.....	74
3.3.1. Optimum Entropi Tabanlı Özellik Çıkarımı İçin Kullanılan Genetik Algoritmanın Yapısı ve İşlevi	75
3.4. Geliştirilen Resim Bölütleme Tabanlı Özellik Çıkarma Yöntemi.....	78
4. SINIFLANDIRMA İÇİN KULLANILAN YÖNTEMLER.....	84
4.1. Dalgacık Sinir Ağ Modelleri Kullanılarak Gerçekleştirilen Adaptif Özellik Çıkarma ve Sınıflama.....	84
4.1.1. Dalgacık Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama.....	85
4.1.2. Dalgacık Paket Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama.....	86
4.2. Geliştirilen Dalgacık Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi İle Adaptif Özellik Çıkarma ve Sınıflama	87
4.2.1. Dalgacık Dönüşüm Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi ile Adaptif Özellik Çıkarma ve Sınıflama	89
4.2.2. Dalgacık Paket Dönüşüm Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi ile Adaptif Özellik Çıkarma ve Sınıflama	92
5. KULLANILAN ÖZELLİK ÇIKARIMI VE SINIFLANDIRMA YÖNTEMLERİNİN RADAR EKO İŞARETLERİNE UYGULANMASI	95
5.1. Radar Hedef Eko İşaretleri.....	95
5.2. Veri Alımı	97
5.2.1. İki Kanallı Örnekleyicinin Çalışma Prensipleri	101
5.3. Ön-işlem Süreci	103
5.3.1. Filtreleme	104
5.3.2. Beyaz Gürültü Ayırımı.....	104
5.3.3. Normalizasyon	105
5.4. Kullanılan Özellik Çıkarma Algoritmalarının Uygulanması.....	105
5.4.1. Dalgacık Dönüşüm Ağacından Entropi Hesaplanması	105

5.4.2. Dalgacık Paket Dönüşüm Ağacından Entropi Hesaplanması.....	106
5.4.3. Dalgacık Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması	108
5.4.4. Dalgacık Paket Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması.....	108
5.5. Yapay Sinir Ağlarının Sınıflandırıcı Olarak Kullanımı.....	109
5.5.1. Geriye Yayınım Yapay Sinir Ağları	109
5.6. Adaptif Radar Hedef Tanıma Yöntemlerinin Uygulaması.....	113
5.6.1. Dalgacık Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama	113
5.6.2. Dalgacık Paket Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama.....	114
5.6.3. Dalgacık Dönüşüm Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi İle Adaptif Özellik Çıkarma ve Sınıflama	115
5.6.4. Dalgacık Paket Dönüşüm Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi İle Adaptif Özellik Çıkarma ve Sınıflama	116
5.7. Optimum Entropi Tabanlı Özellik Çıkarımı Yönteminin Uygulaması	117
5.8. Geliştirilen Resim Bölütleme Tabanlı Özellik Çıkarımı Yönteminin Uygulaması.....	118
6. SONUÇ VE DEĞERLENDİRME.....	122
6.1. Sonuçların Değerlendirilmesi.....	121
6.2. Öneriler	124
6.3. Yayınlar	125
KAYNAKLAR	127

ÖZGEÇMİŞ

EKLER

EK-1 : Kullanılan Lab-Volt Radar deney setinin teknik özellikleri

EK-2 : Radar deney seti modülünün kurulumu

EK-3 : Lab-Volt Radar deney setinin kalibrasyonu için kullanılan deney düzenek blok şeması

EK-4 : Ses kartının teknik özellikleri

EK-5 : Kullanılan Lab-Volt Radar Deney Setinin Fotoğrafları -I

EK-6 : Kullanılan Lab-Volt Radar Deney Setinin Fotoğrafları -II

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1.1. Sabit ve hareketli hedefler için eko işaretleri	10
Şekil 1.2. Durağan olmayan bir RHE işareti	11
Şekil 1.3. Küre hedefine ait bir hareketli RHE işareti	11
Şekil 2.1. Örüntü tanıma kavramı	15
Şekil 2.2. Bir örüntü tanıma sistemine ait karar yüzeyi özellik uzayının gösterimi	16
Şekil 2.3. Bir örüntü tanıma sistemi blok diyagramı	17
Şekil 2.4. İkili kodlama için kromozom örneği.....	22
Şekil 2.5. Permutasyon kodlama için kromozom örneği	23
Şekil 2.6. Değer kodlama için kromozom örneği.....	23
Şekil 2.7. Ağaç kodlama için kromozom örneği.....	23
Şekil 2.8. Küçük metal plaka hedefine ait RHE işareti.....	28
Şekil 2.9. Silindirin alttan görünüşü hedefine ait RHE işareti.....	28
Şekil 2.10. Küçük metal plaka hedefinin Meksika şapkası dalgacık dönüşüm skalogramı	29
Şekil 2.11. Silindirin alttan görünüşü hedefinin Meksika şapkası dalgacık dönüşüm skalogramı.....	29
Şekil 2.12. Canny kenar çıkarma uygulaması örneği.....	32
Şekil 2.13. Kare şekli için merkez kenar değişimi yönteminin uygulanması	33
Şekil 2.14. Biyolojik nöronun şematik yapısı.....	35
Şekil 2.15. Bir yapay sinir ağı hücresi modeli.....	36
Şekil 2.16. Yapay sinir ağları için kullanılan eşik fonksiyonları	37
Şekil 2.17. 2 girişli 9 kurallı bir UATBÇS sınıflandırıcı yapısı	43
Şekil 2.18. Bulanık C-Ortalama sınıflandırıcısı.	51
Şekil 2.19. Kohonen ağı.....	52
Şekil 2.20. Kohonen 'in kendi kendini düzenleme haritasının ağ birimleri	54
Şekil 2.21. Kohonen sistem modeli.....	54
Şekil 2.22. Bir işlem elamanının yapısal komşuluğu ($t_1 < t_2 < t_3$)	55
Şekil 2.23. Kohonen yapay sinir ağını eğitmek ve nesne tanımak için kullanılan program akış şeması	57
Şekil 3.1. Yaygın olarak kullanılan dalgacık örnekleri	59
Şekil 3.2. ADD ayrışım ağacı	60
Şekil 3.3. ADD kullanılarak elde edilen ZFG yapısı	61

Şekil 3.4. Dalgacık dönüşüm ZFG entropileri ile özellik çıkarımı.....	62
Şekil 3.5. Dalgacık paket dönüşüm ZFG entropileri ile özellik çıkarımı	62
Şekil 3.6. Radar hedef eko işaretinin KZFD spektrogramı	64
Şekil 3.7. Radar hedef eko işaretinin KZFD spektrogramının üç boyutlu görünümü	65
Şekil 3.8. Pencere fonksiyonları	66
Şekil 3.9. Dalgacık dönüşümü ve KZFD spektrogramı ZFG entropileri ile özellik çıkarımı .	67
Şekil 3.10. Dalgacık paket dönüşüm ve KZFD spektrogram ZFG entropileri ile özellik çıkarımı	67
Şekil 3.11. Radar hedef eko işaretinin Wigner-Ville Zaman Frekans Gösterimi	68
Şekil 3.12. Radar hedef eko işaretinin Wigner-Ville Zaman Frekans Gösteriminin üç boyutlu görünümü	69
Şekil 3.13. Radar hedef eko işaretinin Born Jordan Zaman Frekans Gösterimi	71
Şekil 3.14. Radar hedef eko işaretinin Born Jordan Zaman Frekans Gösteriminin üç boyutlu görünümü	71
Şekil 3.15. Radar hedef eko işaretinin Choi Williams Zaman Frekans Gösterimi	73
Şekil 3.16. Radar hedef eko işaretinin Choi Williams Zaman Frekans Gösteriminin üç boyutlu görünümü	73
Şekil 3.17. KZFD ZFG kullanılarak en iyi entropi değerlerinin bulunması için geliştirilen yöntemin blok diyagramı.....	74
Şekil 3.18. WV ZFG kullanılarak en iyi entropi değerlerinin bulunması için geliştirilen yöntemin blok diyagramı.....	74
Şekil 3.19. BJ ZFG kullanılarak en iyi entropi değerlerinin bulunması için geliştirilen yöntemin blok diyagramı.....	75
Şekil 3.20. CW ZFG kullanılarak en iyi entropi değerlerinin bulunması için geliştirilen yöntemin blok diyagramı.....	75
Şekil 3.21. Rastgele oluşturulmuş birey	76
Şekil 3.22. Kullanılan genetik algoritma akış diyagramı	77
Şekil 3.23. Optimum entropi tabanlı özellik çıkarma yönteminin blok diyagramı	78
Şekil 3.24. Küçük metal plaka hedefine ait 2 seviyeli bölütlenmiş ZFG resmi	79
Şekil 3.25. Silindirin alttan görünüşü hedefine ait 2 seviyeli bölütlenmiş ZFG resmi	79
Şekil 3.26. Küçük metal plaka hedefine ait ZFG resminin belirlenmiş kenarları.....	80
Şekil 3.27. Silindirin alttan görünüşü hedefine ait ZFG resminin belirlenmiş kenarları.....	81
Şekil 3.28. Küçük metal plaka hedefine ait bulunan öklit uzaklık değer vektörü	82

Şekil 3.29. Silindirin alttan görünüşü hedefine ait bulunan öklit uzaklık değeri vektörü	82
Şekil 3.30. Geliştirilen resim bölütleme tabanlı özellik çıkarma yönteminin blok diyagramı ...	83
Şekil 4.1. Dalgacık sinir ağı yapısı.....	85
Şekil 4.2. Örüntü tanımak için kullanılan DSA yapısı.....	86
Şekil 4.3. Örüntü tanımak için kullanılan DPSA yapısı	87
Şekil 4.4. Dalgacık uyarlamalı ağ tabanlı bulanık çıkarım sistemi yapısı.....	88
Şekil 4.5. Örüntü tanımak için geliştirilen DUATBÇS yapısı.....	89
Şekil 4.6. DUATBÇS eğitim algoritması.....	91
Şekil 4.7. Örüntü tanımak için geliştirilen DPUATBÇS yapısı	92
Şekil 4.8. DPUATBÇS eğitim algoritması	94
Şekil 5.1. (a) Bir darbeli radar işareti.....	95
(b) Bir darbeli RHE işaret örneği	96
Şekil 5.2. Kullanılan hedef nesneleri	97
Şekil 5.3. Hareketli büyük metal plaka hedefine ait eko işareti	98
Şekil 5.4. Veri alımında kullanılan radar deney setinin blok diyagramı	99
Şekil 5.5. İki kanallı örnekleyicinin blok diyagramı	103
Şekil 5.6. Bir RHE işaretinin dalgacık dönüşüm ağacında bulunan işaretleri	106
Şekil 5.7. Bir RHE işaretinin dalgacık paket dönüşüm ağacının uç yaprak işaretleri.....	107
Şekil 5.8. Dalgacık dönüşümü ve KZFD spektrogramı ZFG Sure entropileri ile özellik çıkarımı	108
Şekil 5.9. Dalgacık paket dönüşümü ve KZFD spektrogramı ZFG Eşik entropileri ile özellik çıkarımı	108
Şekil 5.10. Çok katmanlı ileri beslemeli yapay sinir ağları	110
Şekil 5.11. DD-KZFD-EH özellik çıkarım yöntemi için kullanılan YSA modelinin eğitim başarımı	111
Şekil 5.12. DPD-KZFD-EH özellik çıkarım yöntemi için kullanılan YSA modelinin eğitim başarımı	112
Şekil 5.13. Kullanılan adaptif yöntemlerin RHE işaretlerine uygulama sistemi	113
Şekil 5.14. Geliştirilen Resim Bölütleme Tabanlı Özellik Çıkarımı ve Sınıflandırma Yönteminin blok diyagramı	119

TABLOLAR LİSTESİ

	<u>Sayfa</u>
Tablo 2.1. İşaret işleme alanında yaygın kullanılan entropi türleri ve bu entropi türlerine ait denklemler	20
Tablo 2.2. Resim piksel matrisi	31
Tablo 2.3. $g_m(m,n)$ katlama maskesi	31
Tablo 2.4. $g_n(m,n)$ katlama maskesi	31
Tablo 5.1. Radar deney setinden alınan sabit RHE işaretlerinin hedeflere göre dağılımı....	100
Tablo 5.2. Radar deney setinden alınan hareketli RHE işaretlerinin hedeflere göre dağılımı	101
Tablo 5.3. Geliştirilen DD-KZFD-EH özellik çıkarım yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri	111
Tablo 5.4. Geliştirilen DPD-KZFD-EH özellik çıkarım yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri	112
Tablo 5.5. DSA modelinin yapısı ve eğitim parametreleri	114
Tablo 5.6. DSA modelinin hareketli RHE işaret örüntülerini tanıma başarımı	114
Tablo 5.7. DPSA modelinin yapısı ve eğitim parametreleri	115
Tablo 5.8. DPSA modelinin hareketli RHE işaret örüntülerini tanıma başarımı	115
Tablo 5.9. DUATBÇS modelinin yapısı ve eğitim parametreleri	116
Tablo 5.10. DUATBÇS modelinin hareketli RHE işaret örüntülerini tanıma başarımı ..	116
Tablo 5.11. DPUATBÇS modelinin yapısı ve eğitim parametreleri	117
Tablo 5.12. DUATBÇS modelinin RHE işaret örüntülerini tanıma başarımı	117
Tablo 5.13. GYSA modelinin yapısı ve eğitim parametreleri	118
Tablo 5.14. GYSA modelinin hareketli RHE işaret örüntülerini tanıma başarımı	118
Tablo 5.15. Geliştirilen RBT özellik çıkarım yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri	120
Tablo 5.16. BCO sınıflandırıcısı kullanılarak gerçekleştirilen RBT özellik çıkarımı ve sınıflandırma modelinin hareketli RHE işaret örüntülerini tanıma başarımı	120
Tablo 5.17. Kohonen YSA sınıflandırıcısı kullanılarak gerçekleştirilen RBT özellik çıkarımı ve sınıflandırma modelinin RHE işaret örüntülerini tanıma başarımı	120
Tablo 5.18. Kullanılan ve geliştirilen özellik çıkarımı-sınıflama yöntemlerinin hedef tanıma bakımından başarımlarının karşılaştırılması	121

EKLER LİSTESİ

EK-1 : Kullanılan Lab-Volt Radar deney setinin teknik özellikleri

EK-2 : Radar deney seti modülünün kurulumu

EK-3 : Lab-Volt Radar deney setinin kalibrasyonu için kullanılan deney düzenek blok

Şeması

EK-4 : Ses kartının teknik özellikleri

EK-5 : Kullanılan Lab-Volt Radar Deney Setinin Fotoğrafları –I

EK-6 : Kullanılan Lab-Volt Radar Deney Setinin Fotoğrafları -II



SİMGELER LİSTESİ

$\Re$	Gerçek giriş uzayı
$v^{(L)}$	Sınıf sayısı
$\underline{D}$	Sınıflandırıcı
$d = g \circ f$	Sınıflandırma süreç fonksiyonu
$\mathcal{T}$	Eğitim kümesi
$x(t)$	İşaret
$\psi(t)$	Dalgacık fonksiyonu
b	Dönüşüm etmeni
a	Ölçekleme etmeni
$\psi_m(t)$	m. seviye frekansındaki ayrışım-filtresi
$g(m,n)$	Resimi oluşturan m ve n boyutlarındaki gri seviye piksel matrisi
$g_m(m,n)$	Resmin düşey eğimi
$g_n(m,n)$	Resmin yatay eğimi
$\theta(m,n)$	Resmin eğimi
M_T	Eşik değeri
T	Piksel değeri
$r(\phi)$	Merkez kenar değişimi fonksiyonu
x_m	Ağırlık merkezi noktasının yatay bileşeni
y_m	Ağırlık merkezi noktasının düşey bileşeni
ϕ	Sınır üzerindeki herhangi bir noktanın yatay konumla yaptığı referans açı
X_i	Yapay sinir ağı girişleri
W_i	Yapay sinir ağı ağırlıkları
F	Eşik fonksiyonu
$\mathcal{C}$	Yapay sinir ağı çıkışları
Sgn	İşaret fonksiyonu
$w_i(t+1)$	Yeni ağırlık değeri
$d_i(t)$	Yapay sinir ağı arzu edilen çıkış değeri
ε	Öğrenme oranı
$\partial E(t)$	Hata değişimi
$\partial w(t)$	Ağırlık değişimi
$\mu(x)$	Üyelik fonksiyonu
w_i	Kuralların kesinlik dereceleri

Δp_i	p parametresi değışimi
Δq_i	q parametresi değışimi
Δr_i	r parametresi değışimi
δ	Hata yansması
$n_i (k + 1)$	Üçgen (delta) kuralı
$f = \sum_i \bar{\mu}_i f_i$	Katman çıkış fonksiyonu
$\bar{\mu}_i$	Normalize edilmiş üyelik fonksiyonu
σ_i	Gauss fonksiyonunun genişliği
m_i	Gauss fonksiyonunun merkezi
$\ \ $	Öklit uzaklığı
N_c	Kategori sayısı
x_k	k. eğitim örneđi
v_i	Küme merkezi
u_{ij}	Üyelik derecesi
v_j^{new}	Yeni küme merkezi
N	Çıkış işlem elemanı
$\alpha(t)$	Öğrenme oranı
$g(v, \tau)$	Kernel olarak adlandırılan iki boyutlu bir fonksiyon
t_k	Dalgacık fonksiyonlarının genişlemesi
2^k	Dalgacık fonksiyonlarının kayma durumu
f_i	Uyarlamalı ağ tabanlı bulanık çıkarım sisteminin Sugeno çıkış fonksiyonları
m	Dalgacık ayrışım seviyesi
p	Entropi parametresi
E	Entropi değeri
ED	Entropi döngü sayısı
D	Eğitim döngüsü
Ed_i	Entropi detay katsayıları
Ea_m	Entropi yaklaşım katsayıları
cD	Uç yaprak dalgacık paket dönüşüm detay katsayı işaretleri
cA	Uç yaprak dalgacık paket dönüşüm yaklaşım katsayı işaretleri
f_p	Darbe tekrarlama frekansı
τ	İşaretin darbe genişliği
$w[n]$	Pencere fonksiyonu

T	Eşikleme değeri
n	İşaretin uzunluğu
SNR	İşaret gürültü oranı
sse	Toplam karesel hata



KISALTMALAR LİSTESİ

OHT	Otomatik Hedef Tanıma
IR	Infrared
FFT	Fast Fourier Transform
STFT	Short Time Fourier Transform
YA	Yapay Açıklıklı
SAR	Syntetic Aperature Radar
TYA	Ters Yapay Açıklıklı
ISAR	Inverse Syntetic Aperture Radar
RCS	Radar Cross Section
PAN	Periodic Attractor Network
SOM	Self Organizing MAP
BM	Bulanık Mantık
BCO	Bulanık C Ortalamalar
UATBÇS	Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
ANFIS	Adaptive Based Fuzzy Inference System
YSA	Yapay Sinir Ağları
HRR	High Range Resolution
MD	Milimetrik Dalga
RADAR	Radio Detection And Ranging
ÇGB	Çok Geniş Bant
UWB	Ultra Wide Band
LRR	Low Range Resolution
ZFG	Zaman Frekans Gösterimi
WV	Wigner Ville
BJ	Born Jordan
CW	Choi Williams
RHE	Radar Hedef Eko İşaretleri
KZFD	Kısa Zamanlı Fourier Dönüşümü
GA	Genetik Algoritmalar
DSA	Dalgacık Sinir Ağı
DPSA	Dalgacık Dönüşüm Paket Sinir Ağı
DUATBÇS	Dalgacık Dönüşüm Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
DPUATBÇS	Dalgacık Paket Dönüşüm Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
DD	Dalgacık Dönüşümü

DPD	Dalgacık Paket Dönüşümü
ADD	Ayrık Dalgacık Dönüşümü
SDD	Sürekli Dalgacık Dönüşümü
DDA-EH	Dalgacık Dönüşüm Ağacından Entropi Hesaplanması
DD-KZFD-EH	Dalgacık Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması
DPD-KZFD-EH	Dalgacık Paket Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması
DDZFGE	Dalgacık Dönüşümü ve Zaman – Frekans Gösterim Entropileri
DPA	Dalgacık Paket Analizi
HFD	Hızlı Fourier Dönüşümü
FD	Fourier dönüşümü
EV	Eigen Vektör
DTF	Darbe Tekrarlama Frekansı
RA-HM	Radar Alıcı Anteni ile Hedef Tablası Arasındaki Mesafe
GYSA	Genetik Yapay Sinir Ağları
RBT	Resim Bölütleme Tabanlı

ÖZET

DOKTORA TEZİ

AKILLI RADAR İLE HEDEF TANIMA SİSTEMİ

Engin AVCI

Fırat Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik – Elektronik Mühendisliği Anabilim Dalı

2005, Sayfa:145

Günümüz teknolojisinde akıllı radar hedef tanıma sistemleri büyük önem kazanmıştır. Bu tez çalışmasında, radar hedeflerini doğru bir şekilde sınıflandırabilmek için güçlü bir özellik çıkarımı amaçlanmıştır. Bu amaç için örüntü tanıma yöntemleri kullanılmıştır. Örüntü tanıma, insanların çeşitli ses, görüntü ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel tanımlamalardır. Örüntü tanıma iki kısımdan oluşmaktadır. Bunlar, özellik çıkarma ve sınıflandırmadır. Sınıflandırıcı tasarımında en önemli belirteç sistemi en iyi şekilde özetleyecek doğru özellikleri seçmektir. Bu çalışmada radar hedef eko işaretleri için dalgacık dönüşümü, entropi ve çeşitli zaman frekans spektral analiz tekniklerine dayalı, tümleşik özellik çıkarım yöntemleri kullanılmıştır. Kullanılan özellik çıkarım yöntemleri yapay sinir ağları ve uyarlamalı ağ tabanlı bulanık çıkarım sistemi içerisinde gömülerek, adaptif örüntü tanıma yaklaşımları sunulmuştur. Ayrıca bu çalışmada, genetik algoritma kullanılarak optimum entropi tabanlı ve çeşitli şekillerde görüntü işleme ve bölütlemeye dayalı özellik çıkarım yöntemleri geliştirilmiştir. Bu yöntemlerin etkinliği ve güvenilirliği, Lab –Volt radar deney setinden elde edilen gerçek darbeleri radar hedef eko işaretleri üzerinde denenmiştir. Sistemin başarımı, hedeflerden alınan gürültülü eko işaretleri ile test edilmiştir. Yaklaşık olarak % 95 doğru tanıma yüzdesine ulaşılmıştır. Bu yöntemler, telekomünikasyon ve biyomedikal gibi benzeri alanlarda, karar verici ve yardımcı olarak, otomatik akıllı tanıma sistemlerinin kullanılmasının güvenilirliğini artıracaktır.

Anahtar Kelimeler: Radar hedef tanıma sistemi, örüntü tanıma, özellik çıkarma, adaptif özellik çıkarım, dalgacık dönüşümü, zaman-frekans gösterimleri, radar hedef eko işaretleri, yapay sinir ağları, uyarlamalı ağ tabanlı bulanık çıkarım sistemi, genetik algoritma, entropi, resim bölütleme.

ABSTRACT

PhD Thesis

A TARGET RECOGNITION SYSTEM BY AN INTELLIGENT RADAR

Engin AVCI

Firat University

Graduate School of Natural and Applied Sciences

Department of Electrical – Electronics Engineering

2005, Page: 145

In today's technology, intelligent radar target recognition systems have gained a great importance in various areas. In this thesis, a powerful feature extraction is aimed in order to classify radar targets correctly. Thus, we have used pattern recognition methods. Pattern recognition is the linguistic definitions which are extracted by the human being from the various sounds, images and likewise patterns. Pattern recognition consists of two stages. These are the feature extraction stage and the classification stage. The most important aspect of the classifier design is the selection of optimum features which will characterize the system. In advanced pattern recognition techniques a better feature extraction becomes a matter of primary importance instead of designing a complex classifier. With this aim integrated feature extraction methodologies were used based on wavelet transform, entropy, and various time-frequency spectral analysis methods for radar target echo signals. By placing the feature extraction methods into the artificial neural network and adaptive network based fuzzy inference system pattern classifiers, adaptive pattern recognition approaches were presented. Besides in this study, feature extraction methods based on optimum entropy approach and various image segmentation were developed by using genetic algorithms. The efficiency and reliability of these methods were examined by using real pulsed radar target echo signals from the Lab – Volt radar experimental set. The success of the system was tested with the noisy echo signals, which were obtained from targets. Correct recognition about 95% was achieved. In various fields such as telecommunication and biomedical, these methods will increase the reliability of automatic intelligent recognition systems by helping the decision maker.

Keywords: Radar target recognition system, Pattern recognition, feature extraction, adaptive feature extraction, wavelet transform, time – frequency representations, radar target echo signals, artificial neural network, adaptive network based fuzzy inference system, entropy, image segmentation.

1. GİRİŞ

Son yıllarda teknoloji hızla ilerlemektedir. Bu ilerlemeye paralel olarak hem askeri hem de sivil uygulamalarda kullanılan radar sistemlerinde hedef tanıma konusunda yapılan çalışmalar da ilgi çekici bir hal almıştır. Radar hedef tanıma çalışmaları aşağıda maddeler halinde sıralanan nedenlerden dolayı yapılmaktadır:

- Sivil havacılıkta hava trafik kontrolünün verimliliğini artırmak için,
- Su, kara ve hava ulaşımının güvenliğini artırmak için,
- Yeryüzündeki nesnelerin tanınmasını sağlamak için,
- Kar ve buz kalınlık durumunu belirleyebilmek için,
- Maden arama için,
- Hava ve meteoroloji tahminleri için,
- Çeşitli kuş türlerinin mevsimlik göçleri ile ilgili çalışmalarda ve hava yolu güvenliğinin sağlanması için kuş türlerinin belirlenmesinde,
- Misillemede, hava savunmasında, yer ve deniz savunmasında, düşman saldırılarında,
- Hedeflerin önemlerinin ve birbirine göre üstün taraflarının belirlenmesinde,
- Bir hedefe saldırı düzenlenirken o hedefin en zayıf noktasının seçilmesinde,
- Yakın düşman füzelerini imha etmede,
- Sanayide makinaların sabit, döner veya hareket eden kısımlarındaki mühendislik teşhisini yapmada,
- Hedefi yok etmeyi kararlaştırmak için kullanılır.

Günümüzde çok çeşitli radar hedef tanıma çalışmaları yapılmaktadır. Bu çalışmalarda kullanılan yöntemler radar tarafından tanınması istenilen hedefin türüne ve radarın bulunduğu ortamdaki hedefin tanınmasını engelleyici faktörlere (hava hedefleri için kuş sürüleri, kara ve deniz hedefleri için olumsuz hava şartları vb.) göre farklılıklar göstermektedir. Ancak bu çalışmalardaki temel amaç hedefin istenilen özelliklerinin radar tarafından bu olumsuzluklara rağmen en iyi, en doğru ve en hızlı bir şekilde tanınmasını sağlayan yöntemleri bulmak ve uygulamaktır.

Radar hedef tanıma kavramını daha iyi anlayabilmek için günümüze kadar bu alanda yapılmış bazı radar hedef tanıma çalışmaları radar hedef tanımanın tarihçesi başlığı altında verilmiştir.

1.1. Radar Hedef Tanımanın Tarihçesi

Radar hedef tanıma çalışmalarının tarihçesini ilk radar hedef tanıma çalışmaları ve radar hedef tanıma çalışmalarının günümüzdeki durumu şeklinde iki başlık altında incelemekte yarar vardır.

1.1.1. İlk Radar Hedef Tanıma Çalışmaları

Hava yolu trafiğinde ilk hedef tanıma çalışma yöntemleri 1934 yılında geliştirilmiştir. Bu yöntem 3 Km'den 7 Km'ye kadar bir mesafede doğrudan yada yansıtılmış işaretlerin çarpışmasıyla operatörün kulaklığında oluşan bir işitsel işaretin analizini içerir. Bu teknik B. K. Shembel adındaki bir bilim adamı tarafından Leningrad Enstitüsü Elektrik Fiziği Bölümü'nde bir sürekli dalga radarı "Rapid" 'nda geliştirilmiştir. Bu işitsel belirti yöntemi aynı zamanda II. Dünya Savaşı sırasında yabancı radarların bir çoğunda kullanılmıştır [1].

Radarların etkinliği, Almanya'da, İngiltere'de ve Amerika Birleşik Devletleri'nde özellikle mesafe çözünürlüğü, darbe sıkıştırmanın ve lineer frekans modülasyonlu radarların ortaya çıkmasıyla önemli bir hal almıştır [1].

1955 yılında hedef tipini tanıma yeteneğinde ilk radar dizayn edilmiştir. Bu SDS radarı Fransız Thomson-CSF şirketinin bir ürünüdür. Bu ürünün değişik versiyonları RATAc ve RASIT isimli radarlardır. Bu radarlar ile hedef tipini tanıma mümkündür (araç, deve, adam vb.). Bu radarlarda hedef tanıma için doppler frekansı ve ses frekansı işaretleri yöntemleri kullanılmıştır [1-2].

Bunlara ilaveten aynı zamanda frekans, genlik, faz, polarizasyon (kutuplaştırma) gibi eko işaretinin özellikleri de radar tanıma sistemlerinde bilgi içeriğini artırmak için kullanılır. Radar tanımada yatay ve dikey kutuplaştırmanın (polarizasyon) eş zamanlı kullanımı, hedefin üç boyutlu (3-D) yapısı hakkında genel bilgi edinmeyi mümkün kılar [1].

1.1.2. Radar Hedef Tanıma Çalışmalarının Günümüzdeki Durumu

Günümüzde bilimin ve bilgisayar teknolojisinin ilerlemesiyle eğitilebilen ve öğrenebilen çeşitli akıllı tanıma yöntemleri ortaya çıkmış ve bu yöntemler radar hedef tanıma çalışmalarında da kullanılmaya başlanmıştır. Bu şekilde akıllı radar hedef tanıma sistemleri ortaya çıkmıştır. Bu radar hedef tanıma yöntemlerine aynı zamanda otomatik hedef tanıma yöntemleri adı verilmektedir. Otomatik hedef tanıma yeteneklerinin şu andaki durumuna bakıldığında bu teknolojinin başta Amerika Birleşik Devletleri olmak üzere birçok gelişmiş ülkede, birçok enstitü ve şirket tarafından geliştirilmeye çalışıldığı görülmektedir.

Örneğin Amerika Birleşik Devletleri'nde otomatik hedef tanıma (OHT) alanında birçok enstitü ve şirket faaliyet göstermektedir. Bunlardan:

Dayton Ohio'daki Wright Patterson Hava Üssü'ndeki Avionics Laboratuvarı'nda bilim adamları radar tanıma sistemleri için (kısmen optik elektronik bulma sistemleri ile ilgili olarak) birçok araştırma yapmaktadırlar. Ayrıca bir savaş halinde radarla hedef tanımanın etkinliğini geliştirmek için toplam ölçüm olarak birçok algılayıcıdan verilerin toplanması (fusion) problemlerine çözüm aranmaktadır. Bu laboratuvar da bir "insan görüş yeteneği tabanlı model" ve "sinir ağı" algoritmaları geliştirilerek kullanılmıştır. Bu laboratuvardaki bilim adamlarının görüşüne göre "insan görüş yeteneği modeli" karmaşık çevresel şartlarda radarla hedef tanıma için en etkili yoldur. Bu yöntemin sonuçları henüz tam olarak tamamlanmamasına rağmen kullanım için en uygun yol olduğu düşünülür.

Amerika Birleşik Devletleri'nde Gelişmiş Savunma Araştırma Projeleri Merkezi (GSAPM) bilgi toplama problemlerinin çözümünü araştırmaktadır. Bu merkezde laboratuvar şartları altında birçok radar hedef tanıma algoritması geliştirilmiştir [1].

Orlando Florida'da bulunan The Martin Marietta Anonim Şirketi'nde güdümlü sistemlerde (akıllı silahlar) hedef tanıma için milimetre dalga-radar tasarımı ve infrared (IR) sensörleri (algılayıcıları) üzerine araştırmalar yapılmaktadır [1].

Texas Dallas'taki The Texas Instruments Şirketi, akıllı silahlara yol göstermede hedef tanınmanın gerçekleştirilebilmesi için laser radarlar ve çeşitli algılayıcılar geliştirmektedir. Bu algılayıcıların bilgisayar benzetimleri tamamen gerçekleştirilmiştir [1].

Amerika Birleşik Devletleri ordusu uzmanları aynı zamanda değişik hedeflerin tanınması için birçok sensörden verilerin toplanması alanında çalışmalar yapmaktadır.

1.2. Radar Hedef Tanıma Konusunda Yapılan Literatür Taraması

Radar hedef tanıma konusunda günümüze kadar yapılan çalışmaları kullanılan özellik çıkarma yöntemlerine, sınıflandırıcı çeşitlerine, kullanılan radar ve hedef tiplerine göre olmak üzere üç ana başlık altında inceleyebiliriz.

1.2.1. Özellik Çıkarım Yöntemleri Bakımından

Hedeften radara doğru geri yansıyan işarete **eko işareti** adı verilmektedir. Eko işareti aynı zamanda hedef mesafe profili olarak da adlandırılır. Bu işaret kullanılarak elde edilen özellikler ile otomatik hedef tanıma çalışması yapılan uygulamalar ve bu uygulamalarda kullanılan özellik çıkarım yöntemleri aşağıda belirtilmiştir:

Birçok otomatik hedef tanıma çalışmasında özellik çıkarımı için eko işaretlerine çeşitli işaret işleme teknikleri kullanılarak özellik çıkarımı yoluna gidilmiştir. Örneğin çeşitli ufuk (azimuth) ve yükselme (elavation) açılarında hedeften radara geri yansıyan eko işaretlerinin genlik ve faz büyüklük değerleri özellik vektöründe özellik olarak kullanılmıştır [3-9].

Bazı otomatik hedef tanıma çalışmalarında ise hedef eko işaretinin frekans domenine çevrilmiş hali olan hedef mesafe profil grafikleri kullanılarak özellik çıkarımı yapılmıştır [10-14]. Örneğin, bu tür otomatik hedef tanıma çalışmalarından birinde ölçülen mesafe profil işaretleri ters Fourier dönüşümü yöntemi ile zaman domenine çevrilmiş ve bulunan bu işaretlerin ilk tepe değerleri ile son tepe değerleri arasındaki mesafeler ölçülerek bu mesafe bilgilerinden özellik vektörü oluşturulmuştur [15]. Mesafe profilleri kullanılarak yapılan bir başka otomatik hedef tanıma çalışmasında ise, hava hedeflerinden elde edilen mesafe profillerinin olasılık yoğunluk fonksiyonlarının tepe genlik ve yerleşme değerleri özellik vektöründe özellik olarak kullanılmıştır [16]. Bu tür çalışmalarda olasılık yoğunluk fonksiyonu olarak genellikle Gaussian olasılık yoğunluk fonksiyonu kullanılmaktadır. Mesafe profillerinin dağılımının bulunması özelliği kullanılarak başka bir otomatik hedef tanıma çalışması daha yapılmıştır [17].

Ayrıca bazı çalışmalarda, eko işaretinin S/N (sinyal/gürültü) oranları, frekans ve darbe genişlik bilgileri de kullanılarak buradan her bir eko işaretinin darbe tekrarlama süresi bulunmuş ve bu değerler özellik vektöründe özellik olarak kullanılmıştır [18].

Bazı uygulamalarda, işaretdaki ilave bozuklukları önleme ve işaretin spektral bileşenlerinin arasındaki gizli bağıntıları ortaya çıkarma gibi avantajları beraberinde getiren bispektrum özelliği eko sinyallerine uygulanarak elde edilen sayısal değerler özellik vektörü olarak kullanılmıştır [19-24].

Bilindiği gibi işaretler zaman domeninde, frekans domeninde ya da zaman-frekans domeninde incelenebilir. Frekans domeninin zaman domenine göre en önemli üstünlüğü işaretlerdeki zamanla değişimin (kayma etkisinin) giderilmesi ya da azaltılabilmesidir. Radar örüntü tanıma sistemlerinde amaç, hedefin değişen özelliklerine göre (radara olan uzaklık, ufuk ve yükselme açısı gibi) elde edilen ve özellik vektöründe kullanılan ayırt edici özelliklerin değişmemesidir. Bu tür değişmez özellikleri elde edebilmek için çok çeşitli yöntemler kullanılır. Bunlardan biride eko işaretlerinin FFT'si (hızlı Fourier dönüşümü) alınarak yani işareti zaman domeninden frekans domenine almaktır. Yapılmış bir çok otomatik hedef tanıma çalışmasında özellik çıkarımı kısmında bu yöntem kullanılarak her bir hedefin eko işaretinin FFT dönüşümlerinin genliği alınarak özellik vektörü oluşturulmuştur [25-27].

Yukarda sunulan FFT özellik çıkarımı yöntemine ilaveten gemi hedeflerinin tanınması için yapılan bir otomatik hedef tanıma çalışmasında ilk önce eko işaretlerinin FFT dönüşümü alınmış daha sonra bu dönüşüm de Mellin dönüşümüne tabi tutulmuş ve en son olarak da her bir hedef için bulunan bu Mellin dönüşümlerinin genlik değerleri ikili kodlar haline getirilerek özellik vektörü oluşturulmuştur [28-31]. Bu çalışmalarda, ayrıca FFT genliğinin çeşitli hedef değişimlerine karşı değişmezlik gösteren bir anahtar özellik olduğu belirtilmiştir.

Bazı otomatik hedef tanıma çalışmalarında, özellik çıkarımı için hedefin polarizasyon ve yayılma matrisi gibi fiziksel özellikleri kullanılmıştır [32-41]. Örneğin yapılan bir otomatik hedef tanıma çalışmasında, pseudoeigen polarizasyon özelliği kullanılarak, eko işaretlerinin polarizasyon matrisi bulunmuştur ve bu polarizasyon matrisi özellik vektörü olarak kullanılmıştır [42].

Bazı otomatik hedef tanıma çalışmalarında ise, hedef eko işaretlerinin çeşitli dalgacık dönüşümleri alınmıştır. Bu dalgacık dönüşüm çeşitlerinden otomatik hedef tanıma çalışmaları için en yaygın kullanılanlar orthogonal dalgacık dönüşümü (Daubechies dalgacık dönüşümü) [43], Haar, Biorthogonal, Coiflet, Symlet dalgacık dönüşümleridir [44-47]. Bu yöntemle ilgili yapılan bir çalışmada, kompleks radar hedef eko işaretlerinin dalgacık dönüşümleri alınmış ve bu bulunan işaretlerin enerji dağılımları (her eko işaretinin uzunluğu 128 örnek datadan oluştuğu için ($2^7 = 128$)) 7 seviyede elde edilmiştir. Bu enerji dağılımlarından en büyük ikisi (her eko işareti için ayrı ayrı) birbirine oranlanmıştır. Standart sapmaları ve ortalamaları alınmıştır. Bulunan bu değerler özellik vektörünü oluşturmuştur.

Hedeften radara geri yansıyan eko işaretlerinin kullanıldığı otomatik hedef tanıma çalışmalarından birinde ise, üç tür uçak hedefi için elde edilen eko işaretlerine özellik çıkarımı için

sırasıyla Fourier-Mellin ve dalgacık dönüşümleri uygulanmıştır. Bunun sonucunda dalgacık dönüşümünün Fourier-Mellin dönüşümüne göre daha iyi sonuçlar ortaya koyduğu görülmüştür [48]. Bu çalışmada dalgacık dönüşümünün Fourier-Mellin dönüşümüne göre avantajlarının bu dönüşümün zaman yerleşmesinin daha iyi olması ve hedefi oluşturan yayılma merkezlerinin özelliklerini (yüksek çözünürlük analizinden dolayı) daha iyi analiz ederek birbirinden rahatlıkla ayırabilmesi olduğu belirtilmiştir.

Bir başka otomatik hedef tanıma çalışmasında ise bir boyutlu mesafe profillerinin MUSIC yöntemine göre zaman-frekans dağılımı bulunmuştur. Bu MUSIC algoritmasının diğer algoritmalara göre üstünlüğü çok iyi bir çözünürlük sağlamasıdır. Daha sonra bu zaman-frekans dağılımının merkez momentleri bulunmuş ve elde edilen değişmez özellikler özellik vektöründe kullanılmıştır [49].

Bazı otomatik hedef tanıma çalışmalarında, her bir hedefin eko işareti alındıktan sonra bu işaretlerin öz değer vektör (eigen vector) değerleri bulunarak bu değerler özellik vektörü olarak kullanılmıştır [50-54].

İlişkisel filtreleme yöntemi kullanılan bazı otomatik hedef tanıma çalışmalarında, her bir hedefin eko işareti alındıktan sonra bu eko işaretlerini oluşturan hedef yayılma merkezlerinin birbirleriyle olan ilişkileri matematiksel olarak belirlenmekte ve bu belirlenen değerler özellik vektörünü oluşturmaktadır [55-58].

Fractal özelliklerin kullanıldığı bir hedef tanıma çalışmasında ise fractal boyutun, kutu hesaplama (box counting) yöntemi kullanılarak veya eko işaretinin spektral güç yoğunluğunun eğiminden yola çıkılarak bulunabileceği belirtilmiştir [59,60].

Birkaç otomatik hedef tanıma çalışmasında ise ilk önce alınan her bir hedef eko işaretinin FFT si alınmış, daha sonra bu işaretlerin çeşitli yöntemlerle spektral güç yoğunlukları bulunmuş ve bu güç yoğunluklarının ikili kodları elde edilerek özellik vektörü olarak kullanılmıştır [61].

Eko işareti kullanılarak yapılan bir başka özellik çıkarım çalışmasında, birden fazla hedefin karışık bir ortamda kompleks eko işaretinin orta seviyedeki (30 MHz) değerleri (bilgileri) alınmış, daha sonra bu eko işaretinin zarfı çıkarılmıştır. Bu zarf işaretinin ilişkisel matrisi bulunmuş ve bu ilişkisel matris karakteristik denklemi hesaplanarak özellik vektörü elde edilmiştir [62].

Bir diğer çalışmada ise, bir Armed helikopterin ana rotoru (pervanesi) ile kuyruk rotorunun etkisiyle meydana gelen modülasyon etkisi kullanılarak hedef tanıma çalışması gerçekleştirilmiştir. Burada bu helikopterlerin ana rotoru ile kuyruk rotorlarının hedeften geri dönen eko işaretine olan etkisini gösteren radar geri dönüt işaretinin modülasyon spektrumu kullanılmıştır [63].

Hedef üzerindeki hareketli kısımlardan dolayı oluşan modülasyon etkisi kullanılarak yapılan bir başka otomatik hedef tanıma çalışmasında ise uçak hedeflerine ait eko işaretlerinin motor modülasyon etkisini görebilmek için optik fourier dönüşümü yöntemi kullanılmıştır. Motor modülasyonunda iki tip modülasyon mevcuttur. Bunlar genlik modülasyonu ve faz modülasyonudur. Motor modülasyonuna uğratılan bu işaretlerin daha sonra genlik spektrumları bulunmuştur. Bu genlik

spektrumundaki tepe deęerleri motor modülasyonunun etkisini göstermektedir. Bu tepe deęerleri özellik vektörü olarak alınmıştır [64].

Eko işaretlerinin zaman-frekans gösterimlerini kullanarak yapılan otomatik hedef tanıma çalışmaları da mevcuttur. Örneğin bir otomatik hedef tanıma çalışmasında, her bir hedef eko işaretinin STFT (Short Time Fourier Transform) zaman-frekans dönüşümleri alınmış ve daha sonra elde edilen işaretlerin genlikleri özellik vektörünü oluşturmuştur [65]. Bir başka otomatik hedef tanıma çalışmasında ise mesafe profillerinin Gabor-Atom modeli zaman-frekans gösterimleri kullanılarak özellik çıkarımı yapılmıştır [66].

Bazı otomatik hedef tanıma çalışmalarında, özellik çıkarımı için hedeflerin iki ve üç boyutlu resimlerinin bölütleme, extra polasyon (yüksek çözünürlük elde etmek için) ve maximum grilik seviyesi gibi resim işleme teknikleri kullanılarak elde edilen özellikleri kullanılmıştır [34], [67-81]. Bu yöntemin kullanıldığı radar çeşitleri genellikle Yapay Açıklıklı (YA) Radar (Syntetic Apature Radar (SAR)) ve Ters Yapay Açıklıklı (TYA) Radar (Inverse Syntetic Aperture Radar (ISAR))'dır. Bu radarların geri dönüt olarak (hedeften radara eko işareti olarak) iki ya da üç boyutlu resim alma özellikleri vardır.

Bir başka YA radarı ile yapılmış olan otomatik hedef tanıma çalışmasında YA radarı ile elde edilen hedef resimleri bir boyutlu hedef mesafe profil grafiklerine çevrilerek bu çalışma için geliştirilmiş özel bir düzenek yardımıyla bu işaretler çeşitli işaret işleme teknikleri kullanılarak işlenmiş ve buradan elde edilen sayısal deęerler özellik vektörünü oluşturmuştur [82].

Bir başka TYA radarı ile yapılan bir otomatik hedef tanıma çalışmasında alınan iki boyutlu resimlere Wigner-Ville, Short Time Fourier ve dalgacık zaman-frekans gösterimleri uygulanarak buradan elde edilen sayısal deęerler özellik vektörü olarak kullanılmıştır [83].

Bazı otomatik hedef tanıma çalışmalarında, E/S darbe teknięi kullanılarak görüş açısından bağımsız bir radar hedef tanıma mekanizması oluşturulmuştur. Bu mekanizma bir radar alıcı-verici antenin dışında ilave elektronik devreleri de içermektedir [84].

Bunların dışında radardan hedefe gönderilen ve hedeften radara geri gönderilen işaretler arasındaki fark olarak tanımlanan doppler işareti kullanılarak hedef tanıma çalışmaları yapılmıştır. Bu yapılan çalışmalarda, doppler işaretinin çeşitli görüş açılarında ve çeşitli dönme hızlarında örnekleri alınarak bu işaretlerden çeşitli işaret işleme teknikleri kullanılarak özellik çıkarımına gidilmiştir [69, 85-87].

Bir dięer otomatik hedef tanıma çalışmasında ise hedefin micro-doppler etkisinden yararlanılarak özellik çıkarılmıştır [88]. Bu micro-doppler etkisi hedefin titreşen veya dönen kısımlarından dolayı oluşan bir etkidir.

Birçok otomatik hedef tanıma çalışmasında ise, hedefin mesafe profilinin yani bütün yayılma merkezlerinin bir yoğunluęunun göstergesi olan ve temelde radar tarafından hedefe gönderilen işaretin hedef yüzeyinde oluşturduęu gücün, radarın verici gücüne oranı şeklinde bulunan Radar Cross Section (RCS) özellięinden yararlanarak özellik çıkarımı yoluna gidilmiştir [89, 90-98]. Bu çalışmalarda her

bir hedefin RCS dağılımını gösteren işareti elde edildikten sonra bu işaret üzerinde çeşitli işaret işleme teknikleri kullanılarak özellik vektörünü oluşturan özellikler elde edilmiştir.

Bir otomatik hedef tanıma çalışmasında hedeflerin RCS değerleri ölçülmüştür ve bu RCS değerlerinin faz ve genlikleri özellik vektörünü oluşturmuştur. Daha sonra bu bulunan RCS'ler çeşitli gürültü değerlerine göre çizdirilmiş ve bu işaretin dalgacık dönüşümü alınarak özellik çıkarımı yapılmıştır [99].

Bir hedef tanıma çalışmasında ise özellik çıkarımı için, yayılma merkezlerinin transfer fonksiyonları bulunmuştur. Bu yöntemin gerçekleştirilebilmesi için yayılma merkezlerinin dürtü cevapları kullanılır. Bu dürtü cevapları hedef RCS bilgileri kullanılarak elde edilebilir [100].

RCS ölçüm özelliğinden yola çıkılarak uygulanan bir hedef tanıma yöntemide hedefin Prony modelinin çıkarılmasıdır. Bu Prony model, hedef geriye yayıcılarını temsil etmek için kullanılır ancak bu yöntemin uygulanabilmesi için hedefin RCS ölçümünün yapılması gerekmektedir [101, 102]. Bu yöntemin kullanıldığı çalışmada bir hedefi oluşturan yayılma merkezlerinin her biri mesafe, genlik ve bir polarizasyon elipsi ile karakterize edilmiştir. Bu yöntem genellikle kompleks hedeflerin tanınması problemini çözmede kullanılır.

RCS ile ilgili yapılan bir başka otomatik hedef tanıma çalışmasında ise, ilk önce hedeflerin RCS bilgileri elde edilmiş ve bu elde edilen işaretlere piramit dalgacık ayrıştırması yöntemi uygulanmıştır. Buradan elde edilen sayısal değerler özellik vektöründe özellik olarak kullanılmıştır [103, 104].

Bazı otomatik hedef tanıma çalışmalarında özellik çıkarımı için PAN (Periodic Attractor Network) isimli bir ağ yapısı geliştirilmiştir. Bu ağ klasik ağ yapılarına (Neural Network gibi) göre daha iyi kavramayı ve karar vermeyi sağlamakla birlikte yavaş olması nedeniyle fazla tercih edilmemektedir [105].

Birkaç otomatik hedef tanıma çalışmasında, hedef tarafından radara gönderilen işaretin darbe uzunluğu ve bant genişliği gibi özellikleri kullanılmıştır [106]. Ancak bu yöntemin dezavantajı, S/N oranı -6 dB'in altına düşürüldüğünde ve hedef hızı 10 m/sn'nin üzerine çıkarıldığında iyi sonuçlar vermemesi olarak gösterilebilir. Bir başka otomatik hedef tanıma çalışmasında ise, bir ortamda bulunan birden fazla radarın bir hedefin türünü belirlemesi için bu her bir radardan o hedef hakkında elde edilen bilgilerin ilişkilendirilmesi çalışması gerçekleştirilmiştir. Bu çalışmada ilk önce, izleme pozisyon vektörlerinin merkez uzaklıkları bulunmuştur. Buradan izleme pozisyonunun ilişki katsayısı bulunmuştur. Daha sonra buradan izleme hız vektörlerinin merkez uzaklığı bulunmuştur. Bulunan bu değerler özellik vektörünü oluşturmuştur [107].

Bir başka otomatik hedef tanıma çalışmasında ise geliştirilen bir yöntemle hedeflerin elektrik alanları ölçülerek hedef tanıma çalışması gerçekleştirilmektedir [108]. Ancak bu çalışmada kullanılan yöntemin getirdiği dezavantaj, hedefin geriye yayılan işaretinden çıkarılabilecek elektrik alan bilgisinin yeterli olmayışıdır.

Bir başka otomatik hedef tanıma çalışmasında ise özellik çıkarımı için, hedef ekolarından elde edilen yayılma merkezlerinin geometrik bilgilerinden yararlanılmıştır [109].

Bunların dışında hedef izleme filtreleri kullanılarak da hedef tanıma çalışmalarına literatürde rastlanmaktadır [110, 111].

1.2.2. Sınıflandırıcı Çeşitleri Bakımından

Otomatik hedef tanıma çalışmalarının bir kısmında sınıflandırıcı olarak çok katmanlı Yapay Sinir Ağları (YSA) kullanılmıştır [3, 10, 12-14, 25-27, 30, 31, 34, 48, 50, 62, 65, 66, 82, 83, 85, 89, 106, 112-114].

Otomatik hedef tanıma çalışmalarının bir bölümünde sınıflandırıcı olarak eğiticiyiz yapay sinir ağları (Kohonen, Self Organizing MAP (SOM)) sınıflandırıcısı kullanılmıştır [40], [85], [89]. Bazı otomatik hedef tanıma çalışmalarında sınıflandırıcı olarak radyal tabanlı fonksiyonel ağ sınıflandırıcısı, yinelemeli (recursive) yapay sinir ağları sınıflandırıcısı gibi yapay sinir ağı sınıflandırıcıları da kullanılmıştır [3, 15, 40, 44, 57, 64, 87, 109, 115].

Birkaç otomatik hedef tanıma çalışmasında ise çeşitli Bulanık Mantık (BM) ve Bulanık C Ortalamalar (BCO) sınıflandırıcıları kullanılmıştır [28, 30, 53, 61, 107].

Bir otomatik hedef tanıma çalışmasında ise Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UATBÇS) (Adaptive Based Fuzzy Inference System (ANFIS)) sınıflandırıcısı kullanılmıştır [116].

Bazı otomatik hedef tanıma çalışmalarında ise Bayes karar kuralı, en yakın komşuluk, maximum benzerlik, K-ortalama gibi sınıflandırıcılar kullanılmıştır [6, 7, 13, 16, 17, 21, 29, 34, 50, 57, 99, 117]. Bazı çalışmalarda ise kaotik sınıflandırıcı kullanılmıştır [118].

Bunlardan başka bir bölüm otomatik hedef tanıma çalışmasında ise dinamik bilgi işleme sistemleri [20], periodic attractor ağı [104], fonksiyonel link ağları [5], uyarlamalı eşleştirme filtresi [56], gizli Markov modeli [102], m-ary binary [11], destek vektör makine [119], Gauss [46] gibi sınıflandırıcılar da kullanılmıştır.

Ancak bu çalışmalarda kullanılan sınıflandırıcılar sınıflandırma performansı bakımından kıyaslandığında UATBÇS, YSA, BM ve BCO sınıflandırıcılarının diğer sınıflandırıcılara göre üstün oldukları görülmektedir.

1.2.3. Radar ve Hedef Tipi Bakımından

Gerçekleştirilen otomatik hedef tanıma çalışmalarında genellikle Yüksek Mesafe Çözünürlüklü (High Range Resolution (HRR)) radarlar kullanılmıştır [5, 7, 11, 16, 19, 20, 22, 27, 30, 45, 55, 57-59, 75, 82, 120-122]. Bu radarların özelliği sahip oldukları yüksek mesafe çözünürlüğünden dolayı hedefi oluşturan yayılma merkezlerini birbirinden ayırt edebilme yetenekleridir. Bundan dolayı bu tip radarlarda hedef eko işareti üzerinde çeşitli özellik çıkarma yöntemleri rahatlıkla kullanılabilmekte ve bu durumda otomatik hedef tanıma çalışmalarını kolaylaştırmaktadır. Bu tür

radarlarla yapılan hedef tanıma çalışmalarında genellikle kara, hava ya da deniz hedeflerinin ya kendilerinden ya da küçültülmüş modellerinden elde edilen veriler kullanılmıştır.

Bunların dışında YA, TYA, SONAR, Lazer tipi radarlarda otomatik hedef tanıma çalışmalarında kullanılmıştır [6, 25, 34, 57, 68-71, 75-77, 79, 83, 123-126].

Bir kısım otomatik hedef tanıma çalışmasında ise Milimetrik Dalga (MD) ve Çok Geniş Bant (ÇGB) (Ultra Wide Band (UWB)) radarları kullanılmıştır [40, 56, 99, 106, 117, 126-130].

Çok az otomatik hedef tanıma çalışmasında ise Düşük Mesafe Çözünürlüklü Radarlar (Low Range Resolution) (LRR) kullanılmıştır [32, 131].

1.2.4. Yapılan Literatür Tarama Çalışmalarının Genel Değerlendirmesi

Yukarıda belirtilen literatür tarama çalışmaları ışığında şu sonuçlar elde edilmiştir:

- Son yapılan Radar Hedef Tanıma çalışmalarında özellik olarak en çok eko işaretinin çeşitli işaret işleme teknikleri kullanılarak (örneğin Fourier, Mellin dönüşümleri v.b.) frekans domenine çevrilmiş hali olan hedef mesafe profillerinden elde edilen özellikler tercih edilmiştir. Ancak elde edilen bu özelliklerde genellikle zamana veya frekansa bağımlı kalınmış ve her ikisinin getirdiği ortak faydalardan yeteri kadar yararlanılamamıştır [3, 10].
- Son yapılan Radar Hedef Tanıma çalışmaları sınıflandırma açısından değerlendirildiğinde bu çalışmalarda genellikle eğitici YSA, Bayes karar kuralı, en yakın komşuluk, maximum benzerlik, K-ortalama gibi sınıflandırıcıların kullanıldığı gözlenmiştir. Eğitici YSA, Bulanık Mantık (BM) ve Bulanık C Ortalamalar (BCO), Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi (UATBÇS) sınıflandırıcılarının ise radar hedef tanıma çalışmalarında diğer sınıflandırıcılara göre daha başarılı sonuçlar vermelerine rağmen henüz yaygın olarak kullanılmamaktadır [3, 10].

1.3. Amaç

Yukarıda sunulan literatür çalışmaları özellik çıkarımı ve sınıflandırma bazında ele alınarak elde edilen sonuçlar değerlendirildiğinde bu tez çalışmasında izlenecek yol ve amaçlar şu şekilde belirlenmiştir:


- Buna göre bu tez çalışmasında birinci amaç, daha önceden yapılmış hedef tanıma uygulamalarında özellik çıkarımı için en çok tercih edilen eko işaretlerinin FFT veya Mellin v.b. dönüşümlerinin alınması yerine, çeşitli zaman-frekans gösterimleri (Dalgacık dönüşümü, Kısa Zamanlı Fourier Dönüşümü, Wigner-Ville Zaman Frekans Gösterimi, Choi Williams Zaman Frekans Gösterimi, Born Jordan Zaman Frekans Gösterimi v.b.) kullanılarak zaman-frekans ortak ekseninde elde edilen etkili özelliklerin otomatik hedef tanıma çalışmasında kullanılmasını gerçekleştirmektir. Bu çalışmada gerçekleştirilen bir hedef tanıma uygulamasında ise yukarıda bahsedilen özellik çıkarım mekanizmasının etkinliğini en yüksek seviyeye çıkarabilmek için ayrıca genetik algoritma yapısı kullanılmıştır. Ayrıca bu tez

alışmasında geliştirilen bir başka hedef tanıma alışmasında ise elde edilen zaman frekans gösterimlerine eşitli resim işleme teknikleri uygulanarak buradan etkili özellik ıkarımına gidilmiştir. Burada yapılan uygulama alışmalarında elde edilen zaman frekans gösterim tekniklerinin etkinliğini artırmak amacıyla bu zaman frekans özelliklerinin eşitli türdeki entropi bilgileri hesaplanarak bu bilgiler eşitli sınıflayıcılara giriş olarak verilmiştir.


- alışmanın yapılmasındaki ikinci amaç, burada gerçekleştirilen uygulamaların özellik ıkarımı safhasında elde edilen etkili özelliklerin Dalgacık Sinir Ağları ve Dalgacık Uyarlamalı Ağ Tabanlı Bulanık ıkarım Sistemi modellerinin girişlerine verilmesi ile bu tekniklerin diğeryaygın tekniklere göre hedef tanıma bakımından üstün taraflarının ortaya konulmasıdır.
- Üçüncü amaç, sınıflayıcının eğitim durumuna göre ayarlanabilir özellik ıkarma yapısını sağlamaya yönelik, entropi tabanlı dalgacık sinir ağ, yeni dalgacık uyarlamalı ağ tabanlı bulanık ıkarım sistemi modellerini kullanarak daha etkin, adaptif bir örüntü tanıma sistemi ortaya konulmaya alışılmıştır. Ayrıca özellik ıkarımında dalgacık dönüşümü kullanılarak, sabit ve hareketli hedeflerin eko işaretlerindeki zaman kayması gibi değışebilecek özelliklerin etkisini azaltmak hedeflenmiştir. Böylelikle hedef tanıma için daha dayanıklı ve değışmez özellikler ıkarılırken, ayrıca entropi kullanılarak özellik vektör boyutu indirgenecektir.

1.4. Radar Hedef Eko İşaretleri


Hedeften radara geri yansıyan işarete eko (yansıma) denir. Aynı zamanda eko işareti hedef mesafe profili olarak da adlandırılır. Şekil 1.1. de sabit hedefler ve hareketli hedefler için eko işaretleri görölmektedir. RHE işaret örnekleri Şekil 1.2. ve Şekil 1.3. de verilmiştir.



Şekil 1.1. Sabit ve hareketli hedefler için eko işaretleri



Şekil 1.2. Bir RHE işareti.



Şekil 1.3. Küre hedefine ait bir hareketli RHE işareti.

1.5. 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, bu tez çalışmasında akıllı radar hedef tanıma için bir araç olarak kullanılan 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 algoritmaların dayalı olduğu teorik alt yapıyı oluşturmaya yönelik zaman-frekans gösterimleri ve türleri, entropi hesaplama teknikleri açıklanmıştır. Ayrıca tezin bu bölümünde geliştirilen optimum entropi tabanlı özellik çıkarımı için kullanılan genetik algoritma ve geliştirilen resim bölütleme tabanlı özellik çıkarımı yapısında kullanılan çeşitli resim işleme teknikleri, bulanık-C ortalamalar ve Kohonen yapay sinir ağları sınıflandırıcıları hakkında da bilgi verilmiştir. Örüntü tanımanın ikinci aşaması için kullanılan yapay sinir ağı ve uyarlamalı ağ tabanlı bulanık çıkarım sistemi sınıflandırıcıları sistematik bir gösterimle verilmiştir. Böylece, bu bölümü okuyan kişinin, sonraki bölümlerde kullanılan ve geliştirilen algoritmaları daha rahat anlayabilmesi amaçlanmıştır.

Bölüm 3 de, [132] çalışmasında geliştirilen özellik çıkarma algoritmalarının RHE işaretleri üzerine uygulanması çalışmalarının 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. Kullanılan DDZFGE özellik çıkarma algoritmasının, dalgacık dönüşüm ve dalgacık paket dönüşüm tabanlı olmak üzere iki farklı varyasyonu sunulmuştur. Dalgacık dönüşüm zaman – frekans gösterimlerinden elde edilen her bir işaret bileşenine KZFD analiz yöntemi uygulanarak, elde edilen işaretin entropileri hesaplanarak özellik çıkarımı yapılmıştır. Ayrıca tezin bu bölümünde geliştirilen optimum entropi tabanlı özellik çıkarımı ve resim bölütleme tabanlı özellik çıkarımı yöntemleri de açıklanmıştır. Bu bölüm, yukarıda belirtilen yöntemler için gerekli olan teorik bilgiyi de içermektedir. Böylece farklı varyasyonlarda altı adet yeni özellik çıkarım yöntemi radar hedef tanıma sistemine için uyarlanmıştır.

Bölüm 4 de, [132] çalışmasında geliştirilen adaptif özellik çıkarımı için, dalgacık sinir ağı tabanlı bir yöntem verilmiştir. Ayrıca bu tez çalışmasında dalgacık uyarlamalı ağ tabanlı bulanık çıkarım sistemi tabanlı yeni bir yöntemde geliştirilmiştir. Bu yöntemler sınıflandırıcının öğrenebilme yeteneğine bakarak özellik çıkarımını uyarlayabilmektedir. Böylece, radar hedef tanımanın özellik çıkarım süreci sınıflandırıcı bileşeninin içerisine gömülmüştür. Kullanılan ve geliştirilen yöntemlerin dalgacık dönüşüm türlerine bağlı olarak dört farklı türü verilmiştir.

Bölüm 5 de, tez çalışmasında geliştirilmiş olan algoritmaların ve [132] çalışmasında geliştirilen algoritmaların gerçek Radar Hedef Eko (RHE) işaretleri üzerinde uygulamaları yapılmıştır. Ayrıca gerçek dünyadan alınan bu RHE işaretlerindeki istenilmeyen bileşenlerin ayıklanması ve örüntü tanıma sisteminin girişine uygun bir veri yapısı şeklinde sunulabilmek için kullanılan bir ön işlem sırası ve metodolojisi açıklanmıştır. Akıllı örüntü tanıma sisteminde kullanılan, özellik çıkarım ve sınıflandırma yöntemlerinin gerçek RHE işaretlerine uygulanmasıyla elde edilen sınıflandırma sonuçları verilmiştir.

Bölüm 6 da, tezin sonuçları irdelenmiş ve orijinal katkıları vurgulanmıştır. Ayrıca ileriye dönük uygulama alanları ve öneriler tartışılmıştır.



2. ÖRÜNTÜ TANIMA


Radar hedef tanıma kavramını iyi bir şekilde açıklayabilmek için ilk önce örüntü tanıma kavramını açıklamak gerekir. Örüntü, varlıklar ile ilgili gözlenebilir veya ölçülebilir bilgilere verilen isimdir. Gerçekte örüntüyü genellikle ilgilenilen verilerin nicel tanımlama şekilleri olarak belirtebiliriz [39]. Örüntü tanıma, insanların çeşitli ses, görüntü ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel şekillendirmedir [132]. Örüntü tanıma bilimde, mühendislikte ve günlük hayatın geniş bir alanında gerçekleştirilen etkinlikleri kapsamaktadır. Örüntü tanıma uygulamalarına yüz ve ses tanıma gibi belirsizliklere sahip bir çok etkinliği örnek olarak verilebilir. İnsanlardaki örüntü tanıma yapısı, insanın geçmiş tecrübelerine dayalı öğrenme esaslıdır. Bundan dolayı, insanlar günlük yaşayışlarında karşılaştıkları örüntü tanıma olaylarını tecrübeleri ışığında değerlendirebilme yeteneğine sahiptirler. Belirli bir sesi tanımak için kullanılan örüntü tanıma kurallarını tam anlamıyla tanımlamak mümkün değildir. İnsanlar bu örüntü tanıma işlemlerinin bir çoğunu oldukça iyi yapmalarına rağmen, bu örüntü tanıma işlemlerinin daha ucuza mal edilmesi, daha iyi olması, hızlı ve otomatik olarak makinaların yapması istenilen özelliklerdir. Örüntü tanıma kavramı, bu şekilde akıllı ve öğrenebilen makinaları gerçekleştirmek için, çok boyutlu bir mühendislik disiplini [136].

Örüntü tanımayı kavram olarak şu şekilde açıklayabiliriz: Aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen karmaşık işaret veya görüntü örneklerini veya nesneleri bazı belirlenmiş özellikler veya karakterler aracılığı ile tanımlama veya sınıflandırmadır [137]. Bu şekilde düşünülürse, örüntü tanımanın yapılmasının en önemli amaçları olarak tanımlanmamış örüntü sınıflarına belirli bir biçim vermek ve tanımlanmış bir sınıfa ait olan örüntüyü belirlemek söylenebilir.

Günümüzde örüntü tanıma uygulamaları bir çok alanda yaygın olarak kullanılmaktadır. Bunlara örnek olarak ses tanıma [138], EEG sınıflama [139], DTMF haberleşme işaretlerini tanıma [140] ve radar hedef sınıflama [141] biyomedikal kontrol [142] verilebilir. Sistem olarak bir örüntü tanıma kavramı, Şekil 2.1. de gösterildiği gibi üç önemli bileşenden oluşmaktadır [143]. Bunlar:

1. Aşama: İşaret / görüntü işleme, örüntü tanıma sisteminin birinci aşaması yani ön işlem aşamasıdır. Bu aşamada, işaret veya görüntü filtrelenir, filtrelenen bu veriler çeşitli dönüşüm ve gösterim teknikleri kullanılarak işlenir, bileşenlerine ayrılır veya modellenir.

2. Aşama: Özellik çıkarma, işaret ve görüntünün veri boyutunun azaltıldığı ve tanımlayıcı anahtar özelliklerinin belirlendiği ve aynı zamanda normalize edildiği örüntü tanıma sistem aşamasıdır. Bu özellik çıkarım aşaması, örüntü tanıma sistemin başarımında en etkili rolü oynayan kısımdır.
3. Aşama: Sınıflandırma, elde edilen özellik vektör boyutunun azaltıldığı ve formüle edildiği belirleyici karar aşamasıdır.




Şekil 2.1. Örüntü tanıma kavramı.

2.1. Örüntü Tanıma Problemi

Burada belirtilen örüntü tanıma probleminin biçimsel amacı, gerçek giriş uzayındaki H adet $\{x_i\}_{i=1}^H$, $x \in X \subset \mathcal{R}^H$ gözlemleri veya ölçümleri, birkaç sınıftan $y \in Y \equiv \{v^{(1)}, v^{(2)}, \dots, v^{(L)}\}$ birine ayırmak suretiyle tanımlayabilmektir. Sınıflandırılmış çıkışı, karar uzayındaki her bir $v^{(L)}$ sınıfı temsil etmektedir. $\underline{D}$ operatörü Şekil 2.2. de bir harita olarak gösterilen, her bir bölgeye bir sınıf türü atayarak giriş uzayının ayrı bölgelere ayrılmasını sağlayan bir sınıflandırıcıyı veya giriş uzayını birbiri ile kesişmeyen bölgelere ayırarak her bir sınıfa bir nitelik atayıcıyı göstermektedir ($\underline{D} : x \rightarrow y$) [144].

Giriş işaret uzaylarını sınıflandırmada, işaret örüntüsünün boyutunun çok fazla olması ve gürültü gibi engelleyici unsurlar mevcuttur. Bu problemlerin üstesinden gelebilmek için

işaretten özellik çıkarımı yapılır. Böylece elde edilen özellik uzayı, giriş işaret uzayı ve çıkış karar uzayı arasında $T \subset \mathcal{R}^G$ olarak betimlenir ($G \leq H$). Bir özellik çıkarıcı $f : X \rightarrow T$ olarak tanımlanır ve sınıflandırıcı ise $g : T \rightarrow Y$ şeklinde verilir. Böylelikle sınıflandırma süreci $d = g \circ f$ olarak gösterilebilir [145].



Şekil 2.2. Bir örüntü tanıma sistemine ait karar yüzeyi özellik uzayının gösterimi.

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

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

Burada $^{(R)}$ ifadesi eğitim kümesi içindeki i . örüntü – sınıf çiftini göstermektedir.

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 [137,146]. 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.

Giriş Uzayı :
Doğal Durumlar



Şekil 2.3. Bir örüntü tanıma sistemi blok diyagramı.

Günümüzde kullanılan örüntü tanıma sistemleri hakkında daha fazla bilgi için kaynak [132]'e bakılabilir.

2.2. Özellik Çıkarma Süreci

Bir örüntü tanıma sisteminde en önemli aşama özellik çıkarmadır. Başka bir deyişle bu aşama, örüntü tanıma sisteminin başarımında anahtar rolü oynar [136]. Giriş örnekleri arasında ayrımı gerçekleştirmek için örüntü özelliklerinin çıkarılması gerekir. Örüntü tanıma üzerine yapılan güncel çalışmalarda çok başarılı sonuçlar veren örüntü sınıflandırıcı türleri kullanılmış olup, ayrıca bu çalışmalarda sınıflandırıcının da doğrudan başarımını etkileyen özellik çıkarmı üzerine yoğunlaşmıştır [145]. Özellik çıkarmasının yapılmasındaki en önemli amaç ölçüm veya örnek uzayından daha küçük boyuta dönüşmeyi sağlamaktır. Bu şekilde sınıflandırıcı daha küçük hatalar ile eğitimi ve karar aşamasının daha kısa sürede gerçekleşmesi demektir [132].

Bir örüntü tanıma işleminde örüntü özellikleri belirlenirken esas problem verilen gerçek örüntüden en iyi özellikleri çıkarmaktır. Bunu sağlayabilmek için iki yaklaşım kullanılır. Bunlar, doğrudan ve dolaylı yaklaşımlardır. İlk yöntem güçlü yapısal bağlantılara sahip olan ve basit yapılı belirli örüntü tanıma problemlerine uygulanabilmektedir. Dolaylı yöntemlerde ise

aşağıdaki gibi formüle edilebilen bir dönüşüm veya gösterim tekniği ile daha kullanışlı bir yapıdan özellik çıkarımı yapılmaktadır. Böylece y uzayından, t uzayına bir dönüşüm gerçekleştirilir [147].

$$t = F(y) \quad (2.2)$$

Örüntü tanıma sistemlerinde işaretlerin özelliklerinin çıkarımı yapılırken, özellik çıkarımı için genellikle zaman ve frekans bölgesi gösterimi kullanılır. Bu şekilde karmaşık bir işaret örüntü yapısının hem geçici ve hem de zamana bağlı olarak frekans değişimlerini içeren belirleyici özellik bilgileri elde edilebilir. Bu elde edilen özellikler, işaretin zaman ve frekans bölgelerindeki yerel bilgilerini temsil eder.

2.2.1. Zaman – Frekans Teknikleri ile İşaret İşleme

İşaret işleme, günümüzde bilgisayar ve mühendislik bilimlerinde, telekomünikasyonda, tıp alanında teşhis sistemlerinde, kontrol uygulamalarında kullanılan yöntemlerin başında gelmektedir. Sayılan bu işaret işleme uygulamalarının esasında, bir boyutlu karmaşık işaretlerin analizi ve değerlendirilmesi yatmaktadır [148].

Örüntü tanımanın karar sürecini kolaylaştırmaya yönelik olarak kullanılan zaman – frekans gösterimleri, en yaygın kullanılan işaret işleme tekniklerindendir. Bu gösterimler, işaret veri boyutunu indirgemeyi ve bu veri içindeki yararlı bilgilerin çoğunun seçilip alınmasını sağlamayı amaçlamakla birlikte gerçek – zamanlı karar uygulamaları için de son derece önemlidir [149]. Bir örüntü tanıma sisteminde en iyi sınıflandırıcı kullanılsa dahi, eğer işareten çıkarılan özellikler işareti uygun bir şekilde temsil etmiyorsa bu kullanılan sınıflandırıcının doğru karar verme başarımı düşük olacaktır. Bu açıdan Zaman – Frekans Gösterimleri (ZFG) işaret örüntülerinin özelliklerini temsil etmede uygun bir uzay oluşturmaktadır.

ZFG' ler işaret işleme süreçlerinde, işaret sıkıştırma, kodlama, filtreleme, gürültü bastırma, işaret tahmini, sınıflandırma ve yeniden sentez gibi yaygın uygulama alanı bulmuşlardır [145]. İşaretlerin frekans içerikleri ile özellik tanımlaması yapılacaksa, özellik çıkarımı için genellikle bu işaretlerin zaman ve frekans bölgelerinin birleşimindeki analiz ile ilgilenilir. Böylece örüntü tanıma için hem geçici ve hem de frekans değişim bilgileri kullanılır. Bu şekilde daha dayanıklı özellik çıkarımı yapılırken, daha üstün başarımı sınıflandırıcılar kullanılarak bu özelliklerin ayırt etme yetenekleri test edilmiş olunur.

Zaman bölgesindeki bir boyutlu $z(t)$ işaretlerin zaman–frekans gösterimi zaman ve frekansın iki boyutlu bir fonksiyonudur $L_z(t, f)$. 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.

2.2.2. Entropi Kavramı

Entropi kavramı, işaret işlemede ve özellikle haberleşme sahasında ilk olarak Shannon tarafından kullanılmıştır [150]. Entropi tabanlı özellikler verilen bir işaret gösteriminin özellikleri ile ilgili bilgileri tanımlar. Entropi kavramı, bir sistemin düzenliliğini ölçmek amacı ile termodinamik fiziğinde iyi bilinen bir kavramdır. Entropi ölçüm yöntemi herhangi bir işaretin düzensizlik derecesini ölçmek için ideal bir araç olarak görünmektedir [151]. Ayrıca, entropi kavramı bir ortamdaki bilginin ortalama miktarını ölçmek amacı ile de kullanılmaktadır [152].

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 [153], JPEG görüntü kodlamada oluşabilecek gürültüyü tespit etmek [154], biyomedikal NMR işaretlerinin dalgacık dönüşüm uzayından istatistiksel bilgilerini elde ederek işaretin gürültüsüz şeklini kestirmek [148], EEG işaretlerinin spektral entropilerini kullanarak anestezi derinliği tahmin etmek [155] ve MEG biyomedikal görüntülerin yeniden yapılandırılmasında Norm entropi metodu kullanarak yüksek kalitede MEG görüntüleri elde etmek [156] gibi.

İşaret işlemede yaygın olarak kullanılan entropi hesaplama türleri : Shannon, Norm, Eşik (Threshold), Logaritmik Enerji ve Sure yöntemleridir [157]. Bunun dışında diğer entropi hesaplama teknikleri de bulunmaktadır. Bunlar hakkında ayrıntılı bilgi [158] da bulunabilir. Aşağıdaki entropi yöntemlerinde, s işareti ve s_i de işaretin i . katsayısını göstermektedir.

İşaret işleme alanında yaygın kullanılan bu entropi türleri ve bu entropi türlerine ait denklemler aşağıda Tablo 2.1. de verilmiştir.

Tablo 2.1. İşaret işleme alanında yaygın kullanılan entropi türleri ve bu entropi türlerine ait denklemler.

Entropi Türü	Entropiye Ait Denklem
1. Shannon Entropisi	$E(s) = -\sum_i s_i^2 \cdot \log_2(s_i^2)$ ve $\log(0) = 0$ kabul edilerek
2. Norm Entropisi	$E(s) = \sum_i s_i ^p$ ve $1 \leq p < 2$
3. Logaritmik Enerji Entropisi	$E(s) = \sum_i \log_2(s_i^2)$ ve $\log(0) = 0$ kabul edilerek
4. Eşik Entropisi	$E(s) = \sum_i E(s_i)$ ϵ pozitif bir eşik değeri olup $ s_i > \epsilon \Rightarrow E(s_i) = 1$ ve $ s_i \leq \epsilon \Rightarrow E(s_i) = 0$
5. Sure Entropisi	$ s_i \leq \epsilon \Rightarrow E(s) = \sum_i \min(s_i^2, \epsilon^2)$ burada ϵ pozitif bir eşik değeri olup

2.2.3. Genetik Algoritmalar

Evrimsel programlamanın (evaluationary computing) bir parçası olan Genetik Algoritmalar (GA) Darwin'in evrim teorisinden esinlenerek ortaya çıkmıştır. Evrimsel programlama, 1960'lı yıllarda I. Rechenberg'in "Evrimsel stratejileri" adlı çalışmasıyla gündeme gelmiştir. Genetik Algoritmaların bugünkü biçimi ilk olarak Michigan Üniversitesi'nden, psikolog ve bilgisayar bilimleri uzmanı J. H. Holland tarafından 1975 yılında ortaya konulmuştur. Genetik Algoritmalar, en iyinin korunumu ve doğal seçim ilkesinin benzetim yoluyla bilgisayarlara uygulanması ile elde edilen bir arama yöntemidir. Standart bir GA'da aday sonuçlar eşit boyutlu vektörler olarak ifade edilir. Başlangıçta, bu vektörlerden bir grup rastlantısal olarak seçilerek belirli büyüklükte bir populasyon (toplum) oluşturulur. Kromozom adı verilen bu vektörler, yeni nesiller (jenerasyon) oluşturarak değişikliklere uğrar. Bir kromozomun üzerindeki genler, n boyutlu vektörlerin bir boyutuna karşılık gelmektedir.

Her yeni nesilde kromozomların iyiliği ölçülür, yani her vektör (kromozom), amaç fonksiyonuna yerleştirilerek vermiş olduğu sonuç hesaplanır. Bir sonraki nesil oluşturulurken, bazı kromozomlar yeniden üretilir, çaprazlanır ve mutasyona uğratılır. Bu işlemler için bazı özel tip operatörler geliştirilmiştir.

Tekrarlama, çaprazlama ve mutasyon gibi operatörlerden geçecek olan kromozomlar, amaç fonksiyonu değerlerine göre rastlantısal olarak seçilir. Örneğin amaç fonksiyonu değeri daha iyi olan kromozomun çaprazlanma ya da tekrar üretilme olasılığı, değeri kötü olana göre daha fazladır. Benzer kromozomlarla çeşitliliği azalan populasyonlarda yine rastlantısal olarak

seilen kromozomlar mutasyona uęratılırlar. Bunun yanı sıra, populasyon içinde iyilięi dūşük olan kromozomların bir sonraki nesilde yer almamaları mümkündür, yani yok olurlar.

Standart bir “Genetik Algoritma Yordamı” aşıęıdaki gibi verilebilir:

1. Olası çözümlerin kodlandığı bir çözüm grubu oluşturulur (çözüm grubu, biyolojideki benzerlięi nedeniyle, toplum (population), çözümlerin kodları da kromozom olarak adlandırılır). Toplumda bulunacak birey sayısı için bir standart yoktur. Genel olarak önerilen 100-300 aralıęında bir büyüklüktür. Büyüklük seiminde yapılan işlemlerin karmaşıklığı ve aramanın derinlięi önemlidir. Toplum bu işlemden sonra rastgele oluşturulur. Birey sayısı belirlendikten sonra probleme baęlı olarak kromozomların kodlanması gerekmektedir. Deęişik kodlama biçimleri vardır.
2. Toplumdaki her kromozomun ne kadar iyi olduęu bulunur. Bu amaçla kullanılan fonksiyona uygunluk fonksiyonu denir. Bu fonksiyon yardımıyla kromozomların uygunluklarının bulunmasına ise evrimleşme (evaluation) adı verilir. Uygunluk fonksiyonu genetik algoritmanın beynini oluşturmaktadır. Genetik algoritmada probleme özel çalışan tek kısım bu fonksiyondur. Uygunluk fonksiyonu, kromozomları problemin parametreleri haline getirerek onların bir bakıma şifresini çözmekte (decoding) ve sonra bu parametrelere göre hesaplamayı yaparak kromozomların uygunluęunu bulmaktadır. Çoęu zaman genetik algoritmanın başarısı bu fonksiyonun verimli ve hassas olmasına baęlıdır.
3. Seilen kromozomları eşleyerek yeniden kopyalama ve deęiştirme operatörleri uygulanır. Sonuçta yeni bir toplum oluşturulur. Bu eşleme kromozomların uygunluk deęerlerine göre yapılır. Bu seimi yapmak için rulet tekerleęi seimi (roulette Wheel selection), turnuva seimi (tournament selection) gibi seme yöntemleri vardır. Yeniden kopyalama (recombination) genlerdeki genetik bilginin birinden dięerine geçmesi işlemine benzedięi için aprazlama (crossover) olarak adlandırılır. Bu işlem, toplumda çeşitlilięi saęlar. Deęiştirmenin (mutation) etkisi, yalnızca bir çözüm üzerinde olmaktadır.
4. Yeni kromozomlara yer açmak için eski kromozomlar ıkartılarak sabit büyüklükte bir toplum saęlanır.
5. Tüm kromozomların uygunlukları tekrar hesaplanır ve yeni toplumun başarısı bulunur.
6. İşlemler tekrarlanarak verilmiş zaman içersinde daha iyi olan yeni nesillerin oluşturulması gerçekleştirilir.
7. Sonuçta toplumların hesaplanması sırasında en iyi bireyler bulunduęunda çözüm elde edilmiş olur.

2.2.3.1. Genetik Algoritma Operatörleri

Çaprazlama ve mutasyon GA'nın en önemli kısımlarıdır. Performans bu iki operatörden etkilenir. Çaprazlama genetik algoritmanın motoru kabul edilir. Basitçe olay, iki ebeveyn kromozomun arasında belirlenen parçaların takasıdır. Gen takası toplumda çeşitliliği yani, iyi özelliklerin bir araya gelmesini kolaylaştırarak en iyiye yaklaşmayı sağlar. Mutasyon kromozomun bir parçasının dışarıdan değiştirilmesi diye tanımlanır. Değiştirme görünüşte genetik algoritmanın dayanak noktasıdır, ancak etkisi tek bir çözüm üzerindedir. Çok düşük bir değiştirme olasılığı toplumda bazı özelliklerin kaybolmasına neden olabilir. Bu da en iyi sonuçların bulunmasını engeller. Ancak yüksek bir değiştirme olasılığı da eldeki çözümleri bozarak sonuca ulaşmayı zorlaştırır. Gen takası ve değiştirmenin olasılıkları için kesin bir sayı yoktur. Değiştirme olasılığı 0.01-0.001, gen takası olasılığı 0.5-1.0 aralığında tavsiye edilir.

2.2.3.2. Kromozomun Şifrelenmesi (Encoding)

Bir problemi GA ile çözmeye başladığımızda karşılaşacağımız problemlerden bir tanesi kromozomların kodlanmasıdır. Kromozomların kodlanması probleme göre değişmektedir. Kullanılan kodlama yöntemleri aşağıda sunulmaktadır.

İkili Kodlama

Bu yöntem ilk GA uygulamalarında kullanıldığı için hala en çok kullanılan yöntemlerdendir. Burada her kromozom, 0 ve 1'lerden oluşan bit dizisidir ve ikili diziyle ifade edilir. Bu dizideki her bit, çözümün bir özelliğini taşır. Dizinin tümü ise bir sayıya karşılık gelir. İkili kodlama için kromozom örneği Şekil 2.4. de verilmiştir.

Kromozom	A	101110010110
Kromozom	B	010110100000

Şekil 2.4. İkili kodlama için kromozom örneği.

İkili kodlama, az eleman sayılı problemlerde bile çok sayıda mümkün kromozom oluşturur. Bu kodlama ile bazı problemlerde çaprazlama ve mutasyon işlemlerinden sonra düzeltmeler yapılmak zorunda kalınabilir.

Permutasyon Kodlama

Bu kodlamada her kromozom bir numaralar dizisidir. Permutasyon kodlama için kromozom örneği Şekil 2.5. de verilmiştir.

Kromozom	A	35127604
Kromozom	B	01562347

Şekil 2.5. Permutasyon kodlama için kromozom örneği.

Burada da çok kolay olan ikili düzende kodlama kullanılabilir. Örneğin, her onluk sayı için ikili düzendeki sayılar yazılabilir.

Değer Kodlama

Bu kodlama, gerçel gibi kompleks sayıların yer aldığı problemlerde kullanılır. Bu tür problemler için ikili kodlama çok zor olur. Burada her kromozom bazı, değerler dizisidir. Bu değerler ise problemle ilişkilidir. Örneğin gerçel sayı, karakter veya bazı kompleks nesneler bile olabilir. Değer kodlama için kromozom örneği Şekil 2.6. da verilmiştir.


Kromozom	A	3.274	6.121	2.456	0.299	2.115
Kromozom	B	ABCJFJKHDERJFDLFFEGHK				
Kromozom	C	(geri),	(sağ),	(ileri),	(geri),	(sol)

Şekil 2.6. Değer kodlama için kromozom örneği.

Bu kodlama bazı özel problemler (örneğin bir yapay sinir ağının ağırlık katsayılarının bulunması) için çok kullanışlıdır.

Ağaç Kodlama

Ağaç kodlama genellikle genetik programlamada programlar ve ifadeler oluşturmak için kullanılır. Ağaç kodlamada her kromozom, adından da anlaşıldığı gibi nesneler ve nesneler arası işlemleri içeren bir ağaç yapısından oluşmaktadır.



Şekil 2.7. Ağaç kodlama için kromozom örneği.

Ağaç kodlama için kromozom örneği Şekil 2.7. de verilmiştir.

Çaprazlama ve Mutasyon

Hangi şifrelemenin kullanılacağına karar verdikten sonra, çaprazlama veya gen takası adımına geçilir. Çaprazlama, genleri ebeveyn kromozomlardan seçer ve yeni bir döl oluşturur. Bu işlem rastgele çaprazlama noktası (veya noktaları) seçer ve bu noktadan (veya noktalardan) itibaren kromatitlerin (alt dizilerin) yerdeğişmesiyle yeni kopyalaların oluşturulmasını sağlar. Kodlama türlerine bağlı olarak çaprazlama ve mutasyon işleminin farklı şekilleri bulunmaktadır.

İkili kodlanmış kromozomlarda dört çeşit çaprazlama gerçekleştirilebilmektedir.

a. Tek noktalı çaprazlama: Bir çaprazlama noktası seçilir. Bu noktaya kadar olan bitler (genler) birinci ebeveynden, geriye kalanlar ise diğerinden alınarak yeni bir kromozom oluşturulur.

Kromozom-1: 1 1 0 1 1 | 0 0 1 0 0 1 1 0 1 1 0

Kromozom-2: 1 1 0 1 1 | 1 1 0 0 0 0 1 1 1 1 0

Döl-1: 1 1 0 1 1 | 1 1 0 0 0 0 1 1 1 1 0

Döl-2: 1 1 0 1 1 | 0 0 1 0 0 1 1 0 1 1 0

b. Çift noktalı çaprazlama: Burada iki kırılma noktası seçilir. İlk noktaya kadar olan bitler birinci ebeveynden iki nokta arasındaki bitler ikinci ebeveynden, kalanlar ise tekrar birinci ebeveynden yeni kromozoma kopyalanır.

$$1 1 0 0 1 0 1 1 + 1 1 0 1 1 1 1 1 = 1 1 0 1 1 1 1 1$$

c. Tek biçimli (uniform) çaprazlama: Bu çaprazlama biçiminde bitler rastgele şekilde her iki ebeveyden yeni kromozoma kopyalanmaktadır.

$$1 1 0 0 1 0 1 1 + 1 1 0 1 1 1 0 1 = 1 1 0 1 1 1 1 1$$

d. Aritmetik çaprazlama: Yeni bir kromozom oluşturmak için değişik aritmetik işlemler uygulanır.

$$11001011 + 11011101 = 11001001 \text{ (AND) VE işlemi}$$

Mutasyon: Mutasyon işlemi, problemin popülasyondaki çözümlerinin yerel optimuma düşmesini engellemek için kullanılır. Mutasyon yeni dölü rastgele değiştirir. İkili şifreleme için, rastgele seçilen birkaç bit 0'dan 1'e veya 1'den 0'a değiştirilebilir, yani seçilen bitler terslenir.

Orjinal döl: 1101111000011110

Mutasyona uğramış döl: 1100111000011110

Mutasyon da çaprazlama gibi şifrelemeye bağlıdır.

2.2.3.3. Genetik Algoritmanın Parametreleri

Genetik algoritmaların iki temel parametresi vardır: çaprazlama olasılığı ve mutasyon olasılığı. Bu parametreler aşağıda kısaca açıklanmaktadır.

- 1.Çaprazlama Olasılığı:** Çaprazlamanın hangi sıklıkla olacağını belirler. Çaprazlama yoksa, döl ebeveynlerin tam bir kopyasıdır. Çaprazlama varsa, döl ebeveynlerin kromozomlarının parçalarından oluşur. Çaprazlama olasılığı %100 ise, bütün dölleri çaprazlama yolu ile oluşur. Çaprazlama olasılığı %0 ise, yeni jenerasyonun tümü, eski popülasyondaki kromozomların kopyasıdır (ama bu yeni jenerasyonun aynı olduğu anlamına gelmez). Çaprazlama işlemi, yeni kromozomların eskilerin kısımlarından oluşması ve yenilerin daha iyi olması umuduyla yapılır. Bunun yanında, popülasyonun belli kısımlarını bırakmak bir sonraki jenerasyon için iyidir.
- 2. Mutasyon Olasılığı:** Mutasyonun hangi sıklıkla olacağını belirler. Mutasyon yoksa döl, çaprazlamadan ya da kopyalamadan sonra hiçbir değişim olmadan alınır; aksi halde kromozomun bir kısmı değişir. Mutasyon olasılığı %100 olduğunda, tüm kromozom değişmektedir. Mutasyon olasılığı %0 ise hiçbir kromozom değişikliğe uğramaz.

2.2.4. Meksika Şapkası Dalgacık Dönüşüm Skalogramı

Dalgacık dönüşümü, günümüzde haberleşme ve radar hedef tanıma gibi işaretlerden özellik çıkarımına gidilen alanlarda bu tür işaretlerin analizinde sağladığı faydalardan dolayı sıkça tercih edilmektedir. Bu dönüşüm, en son yapılan otomatik hedef tanıma çalışmalarında Fourier tabanlı yöntemlere alternatif olarak başarılı bir şekilde kullanılmıştır [45].

Dalgacık dönüşümünün getirdiği en büyük avantaj, bu dönüşümün düşük frekanslı işaretler için geniş, yüksek frekanslı işaretler için ise darlaşabilen değişken bir pencere boyutuna

sahip olmasıdır. Böylece bu dönüşüm bütün frekans aralıklarında çok iyi bir zaman-frekans çözünürlüğü sağlar.

Dalgacık dönüşümü kullanılırken genellikle analiz edilecek işaretin yüksek frekanslı bileşenleri küçük zaman pencereleri ile, düşük frekanslı bileşenleri ise daha geniş zaman pencereleri ile temsil edilir. Bu durum, düşük frekanslı bir bileşenin yüksek frekanslı bir bileşene göre daha uzun bir zamanda bir periyotluk süreyi tamamlamasından ileri gelir. Buna dalgacık ayrışımı adı da verilir. Dalgacık ayrışım fonksiyonu genel olarak m seviyede ve t_m zaman yerleşme değerinde aşağıda Denklem 2.3. deki gibi ifade edilebilir.

$$d_m(t_m) = x(t)\psi_m\left(\frac{t-t_m}{2^m}\right) \quad (2.3)$$

burada $x(t)$ işaretin kendisini ve ψ_m m frekans seviyesindeki ayrışım filtresini temsil eder. Ayrışım filtresinin etkisi, m seviyede 2^m ile skalalanır.

Literatürde, dalgacık dönüşümünün sürekli ve ayrık olmak üzere iki çeşidinden bahsedilir [45]. Bu dalgacık dönüşümleri Bölüm 3.1.1. de ayrıntıları ile verilecektir. Bu bölümde yalnızca Meksika şapkası dalgacık dönüşümü üzerinde durulacaktır. Meksika şapkası dalgacık dönüşümü, sürekli dalgacık dönüşüm çeşitlerinden biridir. Bu dalgacık dönüşümü, Gauss fonksiyonunun ikinci türevi alınarak bulunur [45]. Yapılan çalışmalarda bu dalgacık dönüşümünün zamandan bağımsız olarak işarete ait özellikleri iyi bir şekilde temsil ettiği gösterilmiştir [45]. Ayrıca yapılan dalgacık dönüşüm çalışmalarından en iyi sonucu alabilmek için en uygun dalgacık dönüşüm tipi seçilmelidir [45].

Sürekli Dalgacık Dönüşümü (SDD) sıkıştırıcılar, genişlemeler ve dönüşümler ile tüm zaman ve ölçeklerdeki işaretler ile ana dalgacık arasında uygunluk sağlar. Sürekli dalgacık dönüşümü aşağıda Denklem 2.4. ile verilmiştir.

$$SDD(a, b) = - \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) dt \quad (2.4)$$

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.

Sürekli dalgacık dönüşümlerinin skalogramları işaretin içerdiği bilgiyi doğru bir şekilde verir. Kaynak [45] de, sürekli dalgacık skalogramı kullanılarak bir işaretten dayanıklı işaret özellikleri elde edilebileceği belirtilmiştir. Son yıllarda, sürekli dalgacık skalogram

tekniki, mühendislik ve tıbbi bilimlerde çeşitli işaretlere uygulanarak bu işaretlerden etkili özellik çıkarımı yoluna gidilmiştir [45].


Meksika şapkası dalgacık dönüşümü, genel olarak frekans domenini ve zaman domenini ortak ilişkilidir. Bu da şu anlama gelir ki Meksika şapkası dalgacık dönüşüm skalogramı hem frekans domeninde hemde zaman domeninde işaret için önemli ölçüde çözünürlük sağlar. Sürekli dalgacık dönüşümünün genliği skalogram olarak adlandırılır. Bir sürekli dalgacık dönüşümünün skalogramı üç boyutlu olarak çizdirilir. Buna göre skalogramın yatay eksenini zamanı, dikey eksenini frekansı gösterir. Üçüncü boyut ise genliktir ve büyüklüğe göre değişen bir renk dağılımı ile gösterilir. Meksika şapkası dalgacık dönüşümü, Denklem 2.5. de verilen Gaussian tipinde bir fonksiyonun ikinci türevi kullanılarak bulunur.

$$\psi_m(t) = \left(\frac{2}{\sqrt{3}} \pi^{-1/4} \right) (1 - t^2) e^{-t^2/2} \quad (2.5)$$


burada $\psi_m(t)$ m. seviye frekansındaki ayrışım filtresidir. Buna göre Meksika şapkası dalgacık skalogramı, Meksika şapkası dalgacık dönüşümünün büyüklüğünün karesidir ve aşağıda Denklem 2.6. ile ifade edilmiştir.

$$S = |SDD(a, b)|^2 \quad (2.6)$$


Burada S, skalogramı temsil etmektedir. Sırasıyla küçük metal plaka ve silindirin alttan görünüşü hedeflerinin eko işaretleri Şekil 2.8. ve Şekil 2.9. da verilmiştir. Bu her iki RHE işaretinin Meksika şapkası dalgacık dönüşüm skalogramları ise sırasıyla Şekil 2.10. ve Şekil 2.11. de gösterilmiştir.




Şekil 2.8. Küçük metal plaka hedefine ait RHE işareti.



Şekil 2.9. Silindirin alttan görünüşü hedefine ait RHE işareti.



Şekil 2.10. Küçük metal plaka hedefinin Meksika şapkası dalgacık dönüşüm skalogramı.



Şekil 2.11. Silindirin alttan görünüşü hedefinin Meksika şapkası dalgacık dönüşüm skalogramı.

2.2.5. Resim Bölütleme

Verilen bir resimden nesneleri tanımak için resimleri anlamlı alt bölümlere bölme işlemine resim bölütleme adı verilmektedir. Resim bölütleme işlemi, bir resmi birleştirildiklerinde resmi tamamen yeniden oluşturan parçalara ayırmak olarak yorumlanabilir. Her resim için uygun bir bölütleme tekniği bulmak zordur. Bununla birlikte genel olarak, söylenebilir ki, bölütlenmiş bir resimdeki bölgeler, homojen bir şekilde dağılmalı ve sınırları çok iyi bir şekilde belirlenebilmelidir. Pratikte birçok resim bölütleme teknikleri mevcuttur. Bunlar kenar piksellerini bağlama, kenar piksellerini izleme, eşikleme, v.b. dir. Bunlardan en çok kullanılanı eşikleme yöntemidir. Gri seviye resimlerde eşikleme yönteminde resime ait her piksele bir gri seviye değeri verilir. Daha sonra eğer iki seviyeli eşikleme yapılacaksa belirli yöntemler kullanılarak bir gri seviye eşik değeri seçilir ve gri seviye değerleri bu eşik değerinin altında olan resim pikselleri bir grup, üstünde kalanlar ise diğer bir grup olarak bölütlenir. Eğer ikiden fazla seviye için bölütleme yapılacaksa bu işlemler o kadar eşik değeri için tekrarlanır [159].

2.2.6. Canny Kenar Çıkarma Yöntemi

Canny kenar çıkarma yöntemi, çok adımlı bir kenar çıkarma tekniğidir. Bu yöntemin esas amacı resimdeki nesnelerin kenarlarını iyi bir şekilde ortaya çıkarırken aynı zamanda resimdeki gürültüleride yok etmektir. Canny algoritmasının içeriği aşağıda maddeler halinde sıralanmıştır:

1. Buna göre (m,n) boyutunda bir resim $f(m,n)$, bir Gauss filtresinden geçirilerek yapısındaki gürültüler ve istenmeyen detaylar azaltılır. Bu işlem Denklem 2.7. de ifade edilmiştir.

$$g(m,n) = G_{\sigma}(m,n).f(m,n) \quad (2.7)$$

burada $G_{\sigma} = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{m^2 + n^2}{2\sigma^2}\right)$ şeklinde bir Gauss filtre fonksiyonudur.

2. Burada Canny kenar çıkarma algoritmasını gerçekleştirmek için Sobel kenar belirleyici yöntemi kullanılmıştır. Buna göre ele alınan filtrelenmiş $g(m,n)$ resmini oluşturan gri seviye pikselleri boyutları m ve n olmak üzere iki boyutlu bir matris olarak düşünülür. Bu resim piksel matrisi küçük bir resim için Tablo 2.2. de verilmiştir. Burada m , bu matrisin yataydaki boyutu, n ise düşeydeki boyutudur.

Tablo 2.2. Resim piksel matrisi.

2	4	5	4	2
4	9	12	9	4
5	12	15	12	5
4	9	12	9	4
2	4	5	4	2

Sobel kenar belirleme yönteminde bu resimin düşeydeki eğimi ($g_m(m,n)$) ve yataydaki eğimi ($g_n(m,n)$)'i bulabilmek için biri yatay biride düşey olmak üzere her biri 3 x 3 boyutunda iki adet katlama maskesi kullanılmaktadır. Bu katlama maskeleri Tablo 2.3. ve Tablo 2.4. de verilmiştir.

Tablo 2.3. $g_m(m,n)$ katlama maskesi.

-1	0	+1
-2	0	+2
-1	0	+1

Tablo 2.4. $g_n(m,n)$ katlama maskesi.

+1	+2	+1
0	0	0
-1	-2	-1

Tablo 2.2. deki resim piksel matrisi ayrı ayrı Tablo 2.3. ve Tablo 2.4. deki yatay ve düşey katlama maskeleri ile çarpım işlemine tabi tutulur. Elde edilen değerler yatay ve düşey için ayrı ayrı toplanarak bu eksenlerdeki eğimler olan $g_m(m,n)$ ve $g_n(m,n)$ bulunur.

3. Eğim operatörlerinden Sobel kullanılarak filtrelenmiş resim $g(m,n)$ 'in eğimi aşağıdaki gibi hesaplanır.

$$M(m,n) = \sqrt{g_m^2(m,n) + g_n^2(m,n)} \quad (2.8)$$

ve

$$\theta(m, n) = \tan^{-1}(g_n(m, n)/g_m(m, n)) \quad (2.9)$$


Burada $\theta(m, n)$, resimin eğimidir.

4. Eşik değeri M_T aşağıdaki gibi bulunur.


$$M_T(m, n) = \begin{cases} M(m, n) & M(m, n) > T \text{ ise} \\ 0 & M(m, n) \leq T \text{ ise} \end{cases} \quad (2.10)$$

Burada T değeri, resim gürültüden ve istenmeyen ayrıntılardan temizlendikten sonra resimdeki nesnelerin kenarlarını en iyi şekilde görebilmemizi sağlayacak şekilde seçilen piksel değeridir. Bu şekilde Canny kenar çıkarma algoritması kullanılarak bir resimdeki nesnelerin kenarları elde edilir [160].

Aşağıda Canny kenar çıkarma algoritması kullanılarak yapılan bir kenar çıkarma örneği verilmiştir. Şekil 2.12.(a). da verilen şekle Canny kenar çıkarma algoritması uygulanarak elde edilen nesne kenarları Şekil 2.12.(b). de verilmiştir.



(a)



(b)

Şekil 2.12. Canny kenar çıkarma uygulaması örneği.


2.2.7. Merkez Kenar Değişim Yöntemi

Merkez kenar değişim yöntemi, iki boyutlu bir sınırın bir boyutlu temsidir. Merkez kenar değişimi, $r(\phi)$ fonksiyonunun bir çizimi olarak tanımlanabilir. $r(\phi)$ fonksiyonundaki r , şeklin ağırlık merkezi ile bu şeklin sınırları üzerinde bulunan herhangi bir nokta arasındaki öklit uzaklığını temsil eder. Denklem 2.11. de öklit uzaklığının nasıl hesaplandığı gösterilmiştir.

$$r = \sqrt{(x - x_m)^2 + (y - y_m)^2} \quad (2.11)$$

Burada x sınır üzerindeki noktanın yatay bileşeni, x_m ağırlık merkezi noktasının yatay bileşeni, y sınır üzerindeki noktanın dikey bileşeni ve y_m ise ağırlık merkezi noktasının dikey bileşenidir.

ϕ ise Şekil 2.16. da gösterildiği gibi sınır üzerindeki herhangi bir noktanın yatay konumla yaptığı referans açığı temsil etmektedir. Bu açığa göre şeklin ağırlık merkez noktasıyla bu şeklin sınırları üzerindeki her bir nokta arasındaki öklit uzaklığının çizimi merkez kenar değişimi işaretini verir [161]. Şekil 2.13. den de görüldüğü gibi bu işaret bir kare şekli için belirli peryotlarda tekrarlanan bir dairesel çizimdir.



Şekil 2.13. Kare şekli için merkez kenar değişimi yönteminin uygulanması.

2.3. Sınıflandırma Süreci

Örüntü tanıma işleminde gerçekleştirilen sınıflandırma aşamasının amacı, örüntüleri özellik uzaylarına göre kendilerine en yakın sınıflara minimum hata ile eşlemektir. Burada önemli olan yapılan uygulamaya en uygun sınıflandırıcı türünü seçmektir. Sınıflandırıcının başarımında iyi tanımlanmış özellikler kilit rolü oynarlar.

Örüntü tanımda kullanılan sınıflandırıcıları klasik ve akıllı olarak gruplara ayırabiliriz. Bu sınıflandırıcı türlerini aşağıdaki gibi açıklayabiliriz:

- Klasik sınıflandırma algoritmaları istatistiksel bir yapı olan Bayes karar teorisi üzerine kuruludur. Bunlarda karşılaşılan dezavantajlar, özellik uzayını kullanarak sınıflandırma uzayını oluştururken, istenmeyen etkilerin (gürültü v.b.) meydana gelmesi ve her bir sınıf için hata kriterinin belli olmamasıdır [162]. Klasik sınıflandırıcılara; çok değişkenli Gauss modelleri, en yakın komşu, maksimum olabilirlik, ikili ağaç sınıflandırıcıları ve Fisher'in doğrusal sınıflandırıcıları örnek olarak verilebilir [143].

- Akıllı sınıflandırma yapıları genellikle uyarlamalı ağ tabanlı bulanık çıkarım sistemi, bulanık mantık ve YSA tabanlıdır. Bu akıllı sınıflandırıcılar, son zamanlarda yapılan çalışmalarda kullanılan ve başarımını ispatlamış çok güçlü sınıflandırıcı türleridir. Özellikle de genelleme yetenekleri, örüntü tanıma uygulamalarının çok büyük boyutlu verileri açısından önemlidir. Hoekstra, (1998) çalışması ile klasik ve YSA sınıflandırıcılarını kıyaslamış ve YSA sınıflandırıcılarının üstünlüklerinin klasik sınıflandırıcı yöntemlerine göre tartışılmaz olduğunu göstermiştir.

2.3.1. Yapay Sinir Ağı Sınıflandırıcıları

Yapay sinir ağı sınıflandırıcıları, tanınması istenen nesnenin öznitelik vektörünü giriş olarak alan ve çıkış ünitelerinin birinde bu nesnenin sınıfını belirleyen bir cevap üreten, pek çok doğrusal olmayan hesaplama elemanlarının paralel işleyişinden meydana gelmiş tümleşik bir yapıdır. Yapay sinir ağlarında her çıkış ünitesi gözlenen olayın farklı bir sınıfını belirler. Yapay sinir ağlarının paralel yapıları, bilgisayarları geleneksel yöntemlerden çok daha farklı kullanarak özellikle seri bilgisayarlarda bilinen yöntemlerle yapılması mümkün olmayan ve çok zor olan bir takım işlevleri (ses ve örüntü tanıma gibi) rahatlıkla yapmaları, yapay sinir ağlarını üstün kılmıştır [8], [12, 13].


Yapay sinir ağları genel bir deyişle, insan beyninin çalışma prensibini taklit etme esası üzerine kurulmuş bilgi işleme yöntemleridir. Bu ağlar birbirine paralel olarak bağlanmış işlem elemanlarından (yapay sinir ağı hücresi, nöron, ünite, birim, düğüm) ve onların hiyerarşik bir organizasyonundan oluşurlar. Yapay sinir ağının temel düşüncesiyle insan beyninin fonksiyonları arasında benzerlikler vardır. Yapay sinir ağları, her ne kadar temel yapı itibariyle bir kısım özellikleri insan beyninin fiziki özelliklerinden esinlenerek ortaya atılmış ise de, kesinlikle şu andaki halleri ile insan beyninin ne tam ne de yaklaşık bir modeli olarak değerlendirilemezler [8], [132], [161].

İnsan beyninin ne olduğu ve nasıl çalıştığı henüz kesinlik derecesinde keşfedilmiş sayılmaz. Günümüzde her ne kadar karmaşık matematiksel hesaplamaları ve hafıza işlemlerini eldeki mevcut bilgisayarlarla hızlı ve doğru yapmak mümkün ise de, aynı bilgisayarlarla beynin birçok basit fonksiyonunu (görmek, duymak koklamak, ...vs.) yerine getirmek ya mümkün olmamakta veya oldukça zor olmaktadır. Aynı şekilde biyolojik beyin, tecrübe ile öğrenme ve bilgiyi kendi kendine yorumlama, hatta eksik bilgilerden sonuçlar çıkartma kabiliyetine sahiptir. Bu, daha çok biyolojik sistemlerin, hücreler üzerinde dağıtılmış bilgiyi paralel olarak işleme özelliklerinden kaynaklanır. Hücreler birbirine bağlı ve paralel çalıştıklarından bazılarının işlevini yitirmesi halinde, diğerleri çalıştığı için sinir sistemi, fonksiyonunu tamamen yitirmez.

İşte yapay sinir ağları, bu özellikleri bünyesinde toplayacak şekilde geliştirilmektedir. Yapay sinir ağlarını daha iyi anlamak için, önce biyolojik sinir ağlarına bakmak faydalı olacaktır.

2.3.1.1. Biyolojik Sinir Ağları ile Yapay Sinir Ağlarının Kıyaslanması

Biyolojik sinir ağının en temel elemanı olan sinir hücresi, sinir sistemi içerisindeki fonksiyon ve görevlerine göre değişik şekil ve büyüklükte olabilir (Şekil 2.14.). Bütün hücrelerin ortak bazı özellikleri vardır. Nöronun bir ucunda “dentrit” adı verilen ve hücreye, diğer hücrelerden veya dış dünyadan gelen bilgileri toplayan bağlantı elemanı, diğer ucunda ise tek bir life benzer “akson” adı verilen ve hücreden diğer hücrelere ve dış dünyaya bilgi taşıyan bağlantı elemanı vardır. Akson diğer hücrelerle birleşme esnasında dağınık dallara ayrılmaktadır. Bu iki uçtaki bağlantı noktalarının, elektrofizyolojik olarak hücrelerdeki bilgileri işlemede önemli yeri vardır. Hücrelerin birbiri ile elektrik işaretleri vasıtasıyla irtibat kurduğu belirlenmiştir. İşaretler, bir hücrenin aksonundan, diğerinin dentritine gönderilir. Bir akson birden fazla dentrit ile bağlantı kurabilir. Bu bağlantıların yapıldığı yere “synaps” denir.




Şekil 2.14. Biyolojik nöronun şematik yapısı

Hücreler, elektrik işaretini hücre duvarlarındaki voltajı değiştirerek üretirler. Bu ise, hücrenin içinde ve dışında dağılmış iyonlar vasıtası ile olur. Bu iyonlar sodyum, kalsiyum, potasyum ve klorin gibi iyonlardır. Bir hücre, diğer hücreye elektrik enerjisini bu kimyasal iyonlar vasıtasıyla transfer eder. Bazı iyonlar elektrik ve magnetik kutuplaşmaya sebep olurken, bazıları kutuplaşmadan kurtulup hücre zarını açarak iyonların hücreye geçmesine olanak sağlar. Zaten işaretlerin bir hücreden diğerine akmasını sağlayan da bu kutuplaşmanın azalması olayıdır. İşaretler, hücrenin etkinliğini belirler. Bir hücrenin etkinliği, hücreye gelen synaps sayısı, synapslardaki iyonların konsantrasyonu ve bir de synapsın sahip olduğu güç olmak üzere üç faktöre bağlıdır. Bir hücre sahip olduğu dürtü miktarınca diğer hücreleri etkiler. Bazı

hücreler diğerlerinin dürtülerini pozitif yönde, bazı hücreler de negatif yönde etkiler. İnsan sinir ağı sistemi, bu şekilde çalışan milyonlarca hücrenin bir araya gelmesinden oluşur [132], [152].

Yapay sinir ağları, biyolojik sinir ağlarından esinlenerek modellendirilmiş olup, onlardan çok daha basit bir yapıya sahiptir. Geliştirilen birçok yapay sinir ağı biyolojik sinir ağlarının bilinen birkaç özelliğini (öğrenme kabiliyeti gibi) temsil etmek üzere geliştirilmiştir. Bir takım özellikler ise nörofizyolojik yaklaşımlar yerine mühendislik yaklaşımı ile geliştirilmektedir. Bir yapay sinir ağının yapısını belirleyen bazı faktörler vardır. Yapay sinir hücreleri veya mühendislik tabiriyle işlem elemanları, sinir ağının yapısal modelleri, ağın sahip olduğu kural ve stratejisi bunların başında gelir. Bunlar hakkında detaylı bilgiler ve ilgili formüller [183] bulunmakla beraber burada kısa bilgiler verilmesi yararlı olacaktır.

Yapay sinir ağları, biyolojik sinir ağları gibi yapay sinir hücrelerinin veya işlem elemanlarının bir araya gelmesinden oluşur. Her bir işlem elemanı Şekil 2.15. de görüldüğü gibi beş parçadan oluşur. Bunlar; girişler, ağırlıklar, toplama fonksiyonu, eşik (dürtü veya çıkış) fonksiyonu ve çıkışıdır.



X_i : Giriş
 W_i : Ağırlık
 T : Toplama Fonksiyonu
 F : Eşik Fonksiyonu
 $\checkmark$: Çıkış


Şekil 2.15. Bir yapay sinir ağı hücresi modeli.

Şekil 2.15. de verilmiş olan bir yapay sinir ağı hücresinin matematiksel ifadesi şu şekildedir;

$$Net = \sum_{i=1}^4 w_i \cdot x_i = w_1 \cdot x_1 + w_2 \cdot x_2 + w_3 \cdot x_3 + w_4 \cdot x_4$$

$$\dot{C} = F(\text{Net})$$

Tıpkı biyolojik sinir hücresi gibi, işlem elemanına birden fazla giriş gelmekte ve sadece bir çıkış gitmektedir. Girişler, dentritlere benzer şekilde diğer yapay hücrelerden bağlantılar vasıtasıyla işlem elemanına bilgi gelmesini sağlarlar. Bazı durumlarda bir işlem elemanı kendisine de bilgi geri gönderebilir (geri besleme). Bahsedilen bu bilgiler elemanlar arasında bulunan bağlantı hatları üzerinde depolanır. Her bağlantının bir ağırlığı vardır. Bu ağırlık bir işlem elemanının diğeri üzerindeki etkisini gösterir. Ağırlık büyüdükçe etki de büyür. Ağırlığın sıfır olması hiç bir etkinin olmaması, negatif olması ise etkinin ters yönde olması demektir. Bu ağırlıklar sabit olabildikleri gibi değişken de olabilirler.



Şekil 2.16. Yapay sinir ağları için kullanılan eşik fonksiyonları.

Eşik fonksiyonları, işlem elemanlarının sınırsız sayıdaki girişini önceden belirlenmiş sınırdaki çıkış olarak düzenler. En çok kullanılan dört tane eşik (aktivasyon) fonksiyonu vardır. Bunlar, lineer, rampa, basamak ve sigmoid fonksiyonudur. Şekil 2.16. da bu fonksiyonlar gösterilmiştir.

Toplama fonksiyonu, bir işlem elemanına gelen net girişi hesaplayan bir fonksiyondur. Net giriş genellikle gelen bilgilerin ilgili bağlantıların ağırlıkları ile çarpılıp toplanması ile belirlenir. Bu nedenle adı, toplama fonksiyonu olarak verilmiştir. Eşik fonksiyonu da, toplama fonksiyonu tarafından belirlenen net girişi alarak, işlem elemanının çıkışını belirleyen fonksiyondur. Genel olarak türevi alınabilen bir fonksiyon olması tercih edilir (Şekil 2.16.).

Toplama ve çıkış fonksiyonları, ilgili probleme bağlı olarak farklı şekiller alabilirler. İşlem elemanının çıkış ünitesi ise çıkış fonksiyonunun ürettiği dürtüyü diğer işlem elemanlarına veya dış dünyaya aktarma işlevini yapar. İşlem elemanları ağıın topolojik yapısına bağlı olarak tamamen birbirinden bağımsız ve paralel olarak çalışabilirler.

2.3.1.2. Yapay Sinir Ağlarının Yapıları

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 [8, 12, 13, 183]. 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 giriş katmanı, gelen bilgileri işleme kabiliyetine sahip ara katmanlar ve sinir ağının kararlarını dış dünyaya aktaran bir çıkış katmanı mevcuttur. İşlem elemanları, onların birbirleri ile ilişkileri ve katmanlar arası ilişkiler değişik yapısal modellerin oluşmasına neden olmaktadır.

2.3.1.3. Yapay Sinir Ağlarında Öğrenme ve Öğrenme Algoritmaları

Daha önce belirtildiği gibi bir yapay sinir ağının sahip olduğu bilgi, işlem elemanları arasındaki bağlantı hatları üzerinde saklanır ve ağırlıklar vasıtası ile gösterilir. Ağ, olaylar hakkında giriş ve çıkışlar arasındaki ilişkiyi, elde bulunan mevcut örneklerden genellemeler yaparak öğrenir ve bu genelleme ile yeni oluşan ve ortaya çıkan daha önce hiç görülmemiş olaylar hakkında karar verir. Yani ağa, bir örnek olay gösterildiğinde, giriş katmanından alınıp ara katmanlarda işlenerek, ağın o olay hakkında ürettiği sonuç, çıkış katmanına sunulur. Bu bilgiyi işleme, ağın sahip olduğu tecrübeye göre, bilginin ara katmanlarda çağrıştırılması ile gerçekleştirilir. Bu çağrıştırma olayı modelden modele değişmektedir. Mesela, ara katmanlardaki işlem elemanları sahip oldukları bağlantılar ile kendi kararlarını üretir ve çıkış katmanındaki işlem elemanlarına gönderirler. Çıkış katmanındaki işlem elemanları da, yine ilgili ağırlıkları kullanarak ağın en son kararını oluştururlar. Bu ağırlıklar, tıpkı ilgili olayın belirli özelliklerini hafızada saklayan elemanlar gibi düşünülebilirler. Bilgi işleme ise (örüntü tanıma gibi), bir olay gösterildiğinde hafızadan ilgili özellikleri çağırarak ve bunlar ile ilgili girişleri birlikte analiz ederek karar vermek şeklinde yorumlanabilir [152].

Yapay sinir ağının öğrenme işlemini gerçekleştirebilmesi için, sahip olduğu bütün ağırlıkların, ilgili problemde öğrenilmesi istenen özellikleri genelleştirecek şekilde doğru değerlere sahip olması gerekir. Bu doğruluk ne kadar artarsa ağın sınıflandırma kabiliyeti dolayısı ile öğrenme işlemi o kadar iyi olur. Doğru ağırlık değerleri, bir öğrenme kuralına göre tespit edilirler. Çoğunlukla bağlantılara başlangıç değerleri olarak rastgele ağırlıklar atanır ve bu

ağırlıklar eldeki örnekler incelendikçe bir kurala göre değiştirilerek doğru ağırlık değerleri bulunmaya çalışılır. Öğrenme yöntemleri temelde üç grupta toplanır [8, 152, 183].

- **Eğitici Öğrenme:** Bu yöntemde, dışardan bir eğiticinin sinir ağına müdahalesi söz konusudur. Eğitici, sinir ağının ilgili giriş için üretmesi gereken sonucu sinir ağı sistemine verir. Yani yapay sinir ağına giriş / çıkış ikilisinden oluşan örnekler sunulur. Bu ikili, ağın öğrenmesi gereken özellikleri temsil eder. Ağ giriş kısmını alır ve o anki bağlantı ağırlıklarının temsil ettiği bilgi ile bir çıkış oluşturur. Bu çıkış, olması gereken çıkış ile mukayese edilir ve aradaki hata tekrar ağa aktararak ağırlıklar bu hatayı azaltacak şekilde değiştirilir.
- **Takviyeli Öğrenme:** Bu yöntemde de yine eğiticiye ihtiyaç vardır. Yukarıdaki yöntemden farkı ise, bu durumda eğiticinin, ağın üretmesi gereken sonuç yerine, onun ürettiği sonucun sadece doğru veya yanlış olduğunu söylemesidir. Bu ise ağa bir takviye işaretinin gönderilmesi ile gerçekleştirilir. Bu yöntem, ilgili örnek için beklenen çıkışın oluşturulamadığı durumlarda çok faydalıdır.
- **Eğitici Öğrenme:** Bu durumda hiç bir eğiticiye ihtiyaç yoktur. Bu nedenle çoğu zaman buna kendi kendine organize olma (self-organized learning) da denilmektedir. Ağ, kendine gösterilen örnekleri alır ve belli bir kritere göre sınıflandırır. Bu kriter önceden bilinmeyebilir. Ağ, kendi öğrenme kriterlerini kendisi oluşturmaktadır.

Öğrenme işleminin, başlangıçtaki rastgele seçilmiş ağırlıkların, belirli bir kurala göre değiştirilmesine dayandığı belirtilmişti. Bu öğrenme kurallarının önemli olanlarından bazıları aşağıda yer almaktadır. Bu algoritmalarda, $w_i = [w_{i1} w_{i2} \dots w_{im}]$ vektörü ağıdaki i . hücreye gelen n tane girişin ağırlık katsayılarını, $x = [x_1 x_2 \dots x_n]$ vektörü ağa gelen n tane girişi, y_i ve d_i 'de sırasıyla i . hücrenin hesaplanan ve istenen çıkışını temsil etmektedirler.

- **Hebb Öğrenme Algoritması :**

Hebb öğrenme algoritmasında temel fikir, hücrenin çıkış üretmesine sebep olan bağlantıların ağırlık katsayılarını büyüterek etkilerini arttırmaktır. Buna göre bu değişim aşağıda Denklem 2.13. ve Denklem 2.14.deki gibi tanımlanmıştır.

$$w_i(t+1) = w_i(t) + \epsilon f(w_i(t).x(t)).x(t) \quad (2.13)$$

veya

$$w_i(t+1) = w_i(t) + \epsilon y_i(t).x(t) \quad (2.14)$$

Burada ϵ 'a öğrenme katsayısı veya öğrenme oranı denilmektedir. Dışardan istenilen bir çıkış uygulanmadığından, eğitici bir öğrenme algoritmasıdır.

- **Algılayıcı (Perceptron) Öğrenme Algoritması :**

Rosenblatt tarafından önerilen algılayıcı öğrenme algoritmasında w değişimi, nöron çıkışı ve istenilen çıkışın farkı ile orantılıdır. Dolayısıyla eğitici bir öğrenme algoritmasıdır.

$$w_i(t+1) = w_i(t) + \epsilon [d_i(t) - \text{sgn}(w_i(t).x(t))]x(t) \quad (2.15)$$

Ağın ürettiği çıkış istenen çıkıştan farklı ise, hata azaltılacak yönde hareket edilmektedir. Hata sıfır olduğunda w değişimi durmaktadır.

- **Delta Kuralı (Eğim düşme) Öğrenme Algoritması :**

Eğim düşme (gradient descent) öğrenme algoritması veya “delta kuralı” öğrenme algoritması, sadece türetilebilir fonksiyonlara sahip olan ağlara uygulanabilmektedir. Eğitici bir öğrenme algoritmasıdır. w değişimi, hatanın eğiminin tersi yöndedir. Böylece, hata fonksiyonunun minimum olduğu yere doğru hareket edilmektedir.

$$w_i(t+1) = w_i(t) - \epsilon \frac{\partial E(t)}{\partial w(t)} \quad (2.16)$$

Burada $E(t)$, hata fonksiyonunu temsil etmektedir ve aşağıdaki gibi tanımlanmıştır.

$$E(t) = \frac{1}{2} (d_i(t) - y_i(t))^2 \quad (2.17)$$

$$E(t) = \frac{1}{2} [d_i(t) - f(w_i(t).x(t))]^2 \quad (2.18)$$

$$\frac{\partial E(t)}{\partial w(t)} = -[d_i(t) - f(w_i(t).x(t))] \frac{\partial f(w_i(t).x(t))}{\partial (w_i(t).x(t))} .x(t) \quad (2.19)$$

Bilinen hata geriye yayılması algoritmasının esası da, bu öğrenme kuralına dayanmaktadır.

- **Widrow-Hoff Öğrenme Algoritması :**

Widrow-Hoff öğrenme algoritması, eğitici bir öğrenme algoritmasıdır. w değişimi ağın çıkışından bağımsızdır.

$$w_i(t+1) = w_i(t) + \varepsilon.(d_i(t) - w_i(t).x(t)).x(t) \quad (2.20)$$

- **İlntili Öğrenme Algoritması:**

Hebb öğrenme algoritmasının eğitici uyarlamasıdır. $f(w_i(t).x_i(t))$ yerine $d_i(t)$ istenen çıkış alındığında aşağıdaki denklem elde edilir.

$$w_i(t+1) = w_i(t) + \varepsilon.d_i(t).x(t) \quad (2.21)$$

- **Yarışmacı Öğrenme Algoritması :**

Bu algoritmada esas, giriş işaretine en yakın olan bağlantı ağırlık katsayılarını bulmaktır. Bu, w 'lara ilişkin nöron kazanan nöron olarak adlandırılmaktadır. Sadece kazanan nöron bir çıkış üretmekte ve bu nörona ilişkin w 'lar değişime uğramaktadır. Eğitici öğrenmenin tipik bir örneği olan bu algoritma sonuçta ağa gelen girişleri sınıflandırmaktadır.

$$w(t+1) = w(t) + \varepsilon.(x(t) - w_m(t)) \quad (2.22)$$

Burada w_m kazanan hücrenin bağlantı ağırlık katsayısı olup aşağıdaki gibi tanımlanmıştır.

$$w_m.x = \max(w_i.x) \quad (2.23)$$

ve $i = 1, 2, \dots, p$ dir.

- **Outstar Öğrenme Algoritması:**

Eğitici öğrenme algoritma türü olan bu öğrenme algoritmasında amaç, w 'ları istenen çıkışa benzetmektir.

$$w(t+1) = w(t) + \varepsilon.(d_i(t) - w(t)) \quad (2.24)$$

2.3.2. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi Sınıflandırıcıları

Bulanık çıkarım sistemleri ve çok katmanlı perceptronlar uyarlamalı ağların çok genel hesaplama çalışmalarının özel örnekleridir. Her iki örnekte uyarlamalı ağın geriye yayılma öğrenme yeteneğini almıştır [163]. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi'nin (UATBÇS), işlevsel olarak bulanık çıkarım sistemine eşdeğer olan bir sınıftır. Açık olarak uyarlamalı ağlara dayanan bulanık çıkarım sistemi veya uyarlamalı sinirsel bulanık çıkarım sistemi anlamına gelen UATBÇS ismi, Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi olan özgün adının baş harflerinden oluşmuştur. Aynı zamanda bazı kaynaklarda UATBÇS, TSK bulanık kuralları ile sinirsel bulanık denetleyici olarak geçmektedir. TSK ise Sugeno bulanık

modeli veya Takagi, Sugeno, Kant bulanık mantık modeli anlamında kullanılmaktadır. Aynı şekilde karma sinir ağı olarak da anılmaktadır.


Bulanık çıkarım sistemi çok katmanlı perceptrona göre daha kuvvetlidir. Örnek olarak UATBÇS sınıflandırıcıların bazı üstün özellikleri tanımlanabilir:

1. Öğrenme yeteneği,
2. Paralel işlem,
3. Yapılandırılmış bilgi temsili,
4. Diğer sınıflandırma ve denetim tasarım yöntemleriyle daha iyi bütünleşme.

Çok katmanlı perceptron 1. ve 2. özelliklere sahiptir fakat 3. ve 4. özelliklere sahip değildir.

2.3.2.1. UATBÇS Mimarisi

Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi'nin (UATBÇS) yapısında hem yapay sinir ağı hem de bulanık mantık kullanılır [164]. Yapı bakımından UATBÇS, bulanık çıkarım sistemindeki eğer-ise kuralları ve giriş çıkış bilgi çiftlerinden oluşur. Ancak sistem eğitiminde yapay sinir ağı öğrenme algoritmaları kullanılır. Burada UATBÇS yapısını basit bir şekilde anlatabilmek için örnek olarak iki girişli ve tek çıkışlı bir UATBÇS yapısı verilmiştir. Beş katmandan oluşan bir UATBÇS sınıflandırıcısı Şekil 2.17. de görülmektedir.



Şekil 2.17. 2 girişli 9 kuralı bir UATBÇS sınıflandırıcı yapısı

Bu UATBÇS yapısı aşağıda da görüldüğü gibi 5 katmandan oluşmaktadır. Burada x ve y giriş, z ise çıkış olarak alınırsa temel kural yapısı şu şekilde yazılabilir:

$$\text{Eğer } x \text{ } A_1 \text{ ve } y \text{ } B_1 \text{ ise } f_1 = p_1 x + q_1 y + r_1 \quad (2.25)$$

Burada p, q ve r lineer çıkış parametreleridir. İki girişli ve bir çıkışlı bir UATBÇS' nin temel yapısı Şekil 2.18. de görülmektedir. Bu yapı, 5 katman ve 9 adet eğer-ise kuralı kullanılarak oluşturulmuştur:

1. Katman: Bu katmandaki hücre sayısı, iki giriş ve bu iki girişin her birine üç üyelik fonksiyonu tanımlandığına göre altı adettir ($i=6$ 'dır). Buna göre,

$$O_{1,i} = \mu_{A_i}(x), i=1,2,3 \text{ için } O_{1,i} = \mu_{B_{i-3}}(y), i=4,5,6 \text{ için} \quad (2.26)$$

Burada x ve y girişlerdir. Bu katmanın çıkışı kuralların varsayım (eğer) kısımlarının üyelik fonksiyonlarına olan üyelik dereceleridir. Kullanılan üyelik fonksiyonu Denklem 2.27. de

verilmiştir. Buradan da görüldüğü gibi üyelik fonksiyonu olarak Gauss üyelik fonksiyonu kullanılmıştır.

$$\mu_{A_i}(x), \mu_{B_{i-3}}(y) = \exp((- (x_i - c_i) / (a_i))^2) \quad (2.27)$$

2. *Katman*: Burada kuralların kesinlik dereceleri cebirsel çarpım kullanılarak bulunur (Denklem 2.28).

$$O_{2,i} = w_i = \mu_{A_i}(x) * \mu_{B_i}(y), \quad i=1,2,3,\dots,9 \quad (2.28)$$

3. *Katman*: Burada kuralların normalizasyon işlemi yapılmaktadır (Denklem 2.29).

$$O_{3,i} = \bar{w}_i = w_i / (w_1 + w_2 + \dots + w_9), \quad i=1,2,3,\dots,9 \quad (2.29)$$

4. *Katman*: Bu katmanda normalize edilmiş her bir kural kendine ait çıkış fonksiyonu ile çarpılır (Denklem 2.30).

$$O_{4,i} = \bar{w}_i * f_i = w_i * (p_i x + q_i y + r_i) \quad (2.30)$$

Buradaki p, q ve r lineer parametreleri sonuç parametreleri olarak adlandırılır.

5. *Katman*: 4. Katman çıkışlarının toplanarak UATBÇS çıkışının sayısal değerinin bulunduğu kısımdır.

$$O_{5,i} = \text{toplam çıkış} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (2.31)$$

2.3.2.2. UATBÇS İçin Geri Yayılımlı Öğrenme Algoritması

Geri yayılımlı öğrenme algoritmasında ağırlık çıkışından elde edilen hata değeri giriş katmanına kadar geriye doğru yansıtılarak gerekli ağırlık değişkenlerinin ayarlanması gerçekleştirilir [163]. Amaç E hata ölçütünü öğrenme işlemi sonunda bütün giriş örnekleri için sıfıra götürmektir. Ağırlık çıkışında hata, istenen değer d ile gerçek çıkış f arasındaki farktır ve Denklem 2.32. deki şekilde ifade edilir,

$$e = d - f \quad (2.32)$$

Bu hata değerine en küçük kareler yöntemi uygulanarak hata ölçütü E aşağıda verildiği gibi hesaplanır.

$$E = \frac{1}{2} e^2 \quad (2.33)$$

Hata ölçütü kullanılarak hata geriye doğru katman katman aşağıdaki gibi yansıtılır,

5. Katman: Bu katmanda herhangi bir ağırlık değeri ayarlaması yoktur, sadece çıkıştaki hatanın katman çıkışına yansımaları hesaplanır,

$$\delta^5 = -\frac{\partial E}{\partial f} = -\left[\frac{\partial E}{\partial e} \frac{\partial e}{\partial f} \right] = e \quad (2.34)$$

4. Katman: Bu katmanda p_i , q_i ve r_i sonuç değişkenlerinin ayarlanması için gerekli hesaplamalar gerçekleştirilir.

$$\Delta p_i = -\frac{\partial E}{\partial p_i} = \left[-\frac{\partial E}{\partial f} \right] \left[\frac{\partial f}{\partial p_i} \right] \quad (2.35)$$

$$f = \sum_i \bar{\mu}_i (p_i x + q_i y + r_i) \quad i = 1, 2 \quad (2.36)$$

$$\frac{\partial f}{\partial p_i} = \bar{\mu}_i x \quad (2.37)$$

buradan,

$$\Delta p_i = \delta^5 \bar{\mu}_i x \quad (2.38)$$

Aynı işlemler diğer sonuç değişkenlerine de uygulanarak değişimler hesaplanır. Buna göre,

$$\Delta q_i = \delta^5 \bar{\mu}_i y \quad (2.39)$$

$$\Delta r_i = \delta^5 \bar{\mu}_i \quad (2.40)$$

olur.

Elde edilen bu ifadeler öğrenme oranı eklenerek üçgen (delta) kuralı uygulanır. $n = \{p, q, r\}$ olarak alınırsa bu ifadeler tek bir eşitlik olarak aşağıdaki gibi gösterilir.

$$n_i(k+1) = n_i(k) + \eta_n \Delta n_i(k+1) \quad (2.41)$$

3. Katman: Bu katmanda çıkış katmanından yansıyan hata değeri hesaplanır herhangi bir ağırlık hesaplaması yoktur,

$$\delta_i^3 = -\frac{\partial E}{\partial \bar{\mu}_i} = \left[-\frac{\partial E}{\partial f} \right] \left[\frac{\partial f}{\partial \bar{\mu}_i} \right] \quad i = 1, 2 \quad (2.42)$$

$$f = \sum_i \bar{\mu}_i f_i \quad (2.43)$$

$$\frac{\partial f}{\partial \bar{\mu}_i} = f_i \quad (2.44)$$

$$\delta_i^3 = \delta^4 f_i \quad (2.45)$$

2. Katman: Bu katmanda çıkış katmanından yansıyan hata değeri hesaplanır herhangi bir ağırlık hesaplaması yoktur,

$$\delta_i^2 = -\frac{\partial E}{\partial \bar{\mu}_i} = \left[-\frac{\partial E}{\partial f} \frac{\partial f}{\partial \bar{\mu}_i} \right] \left[\frac{\partial \bar{\mu}_i}{\partial \mu_i} \right] \quad i = 1, 2 \quad (2.46)$$

$$\bar{\mu}_i = \frac{\mu_i}{\sum_i \mu_i}, \text{ bu ifade de } a = \sum_i \mu_i \text{ olarak alınırsa,}$$

$$\frac{\partial \bar{\mu}_i}{\partial \mu_i} = \left[\frac{a - \mu_i}{a^2} \right] \quad (2.47)$$

olarak bulunur. Bu ifade Denklem 2.48. de yerine konularak aşağıdaki son durum elde edilir.

$$\delta_i^2 = \delta_i^3 \left[\frac{a - \mu_i}{a^2} \right] \quad (2.48)$$

1. Katman: Bu katmanda hem hata değeri hem de giriş üyelik işlevlerine ait değişkenlerin ayarlanması gerçekleştirilir.

$$\delta_i^1 = -\frac{\partial E}{\partial \mu_{Ai}} = -\left[\frac{\partial E}{\partial f} \frac{\partial f}{\partial \bar{\mu}_i} \frac{\partial \bar{\mu}_i}{\partial \mu_i} \right] \left[\frac{\partial \mu_i}{\partial \mu_{Ai}} \right] \quad i = 1, 2 \quad (2.49)$$

$$\frac{\partial \mu_i}{\partial \mu_{Ai}} = \mu_{Bi} \quad (2.50)$$

$$\delta_i^1 = \delta_i^2 \mu_{Bi} \quad (2.51)$$

$$\delta_{i+2}^1 = -\frac{\partial E}{\partial \mu_{Bi}} = -\left[\frac{\partial E}{\partial f} \frac{\partial f}{\partial \bar{\mu}_i} \frac{\partial \bar{\mu}_i}{\partial \mu_i} \right] \left[\frac{\partial \mu_i}{\partial \mu_{Bi}} \right] \quad (2.52)$$

$$\frac{\partial \mu_i}{\partial \mu_{Bi}} = \mu_{Ai} \quad (2.53)$$

$$\delta_{i+2}^1 = \delta_i^2 \mu_{Ai} \quad (2.54)$$

$$\mu_{Ai} = \exp \left[-\left(\frac{x - m_i}{\sigma_i} \right)^2 \right] \quad v_i = -\left[\frac{x - m_i}{\sigma_i} \right]^2 \quad \mu_{Ai} = \exp[v_i] \quad (2.55)$$

Çan eğrisi şekilli üyelik işlevlerinin orta noktalarındaki değişim aşağıdaki gibi hesaplanır,

$$\Delta m_i = -\frac{\partial E}{\partial m_i} = -\left[\frac{\partial E}{\partial f} \frac{\partial f}{\partial \bar{\mu}_i} \frac{\partial \bar{\mu}_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \mu_{Ai}} \right] \left[\frac{\partial \mu_{Ai}}{\partial v_i} \frac{\partial v_i}{\partial m_i} \right] \quad i = 1, 2 \quad (2.56)$$

$$\frac{\partial \mu_{Ai}}{\partial v_i} = \exp[v_i] = \mu_{Ai} \quad (2.57)$$

$$\frac{\partial v_i}{\partial m_i} = 2 \left[\frac{x - m_i}{\sigma_i^2} \right] \quad (2.58)$$

$$\Delta m_i = 2 \left[\frac{x - m_i}{\sigma_i^2} \right] \delta_i^1 \mu_{Ai} \quad \delta_i^1 = \delta_i^2 \mu_{Bi} \quad (2.59)$$

$$\Delta m_i = 2 \left[\frac{x - m_i}{\sigma_i^2} \right] \delta_i^2 \mu_{Ai} \mu_{Bi} \quad \mu_i = \mu_{Ai} \mu_{Bi} \quad (2.60)$$

$$\Delta m_i = 2 \left[\frac{x - m_i}{\sigma_i^2} \right] \delta_i^2 \mu_i \quad (2.61)$$

Aynı şekilde Δm_{i+2} aşağıdaki şekilde elde edilir,

$$\Delta m_{i+2} = 2 \left[\frac{y - m_{i+2}}{\sigma_{i+2}^2} \right] \delta_i^2 \mu_i \quad (2.62)$$

Çan eğrisi şekilli üyelik işlevlerinin standart sapmalarındaki değişim aşağıdaki gibi hesaplanır,

$$\Delta \sigma_i = -\frac{\partial E}{\partial \sigma_i} = -\left[\frac{\partial E}{\partial f} \frac{\partial f}{\partial \bar{\mu}_i} \frac{\partial \bar{\mu}_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \mu_{Ai}} \right] \left[\frac{\partial \mu_{Ai}}{\partial v_i} \frac{\partial v_i}{\partial \sigma_i} \right] \quad i = 1, 2 \quad (2.63)$$

$$\frac{\partial v_i}{\partial \sigma_i} = 2 \left[\frac{(x - m_i)^2}{\sigma_i^3} \right] \quad (2.64)$$

$$\Delta \sigma_i = 2 \left[\frac{(x - m_i)^2}{\sigma_i^3} \right] \delta_i^2 \mu_i \quad (2.65)$$

Aynı şekilde $\Delta \sigma_{i+2}$ aşağıdaki şekilde elde edilir,

$$\Delta \sigma_{i+2} = 2 \left[\frac{(y - m_{i+2})^2}{\sigma_{i+2}^3} \right] \delta_i^2 \mu_i \quad (2.66)$$

Elde edilen bu değişimlere üçgen kuralı uygulanarak üyelik işlevine ait değişkenlerin ayarlanması aşağıdaki şekilde gerçekleştirilir.

$$m_i(k+1) = m_i(k) + \eta_m \Delta m_i(k+1) \quad i = 1, 2, 3, 4 \quad (2.67)$$

$$\sigma_i(k+1) = \sigma_i(k) + \eta_m \Delta \sigma_i(k+1) \quad i = 1,2,3,4 \quad (2.68)$$

Burada toplam 8 değişken ayarlanmaktadır.

2.3.3. Bulanık C-Ortalamlar Sınıflandırıcısı

Bulanık C-Ortalamlar (BCO) sınıflandırıcısı, en çok bilinen bulanık sınıflandırıcılarından biridir. Bulanık C-Ortalamlar algoritması, bir bulanık amaç fonksiyonunu optimize etmeyi temel alan ve data noktalarının kümelendirilmesi için en bilinen ve en popüler algoritmadır. Bu sınıflandırıcı aynı zamanda serbest model tahmin edici ve BCO kümelemenin genel kavramı üzerinde esaslanmıştır. Sınıflandırıcı eğitim verisi üzerinde üyelik fonksiyonlarını hesaplar ve kümeleme merkezinin yerini belirler. Yeni verinin sınıflandırılması öğrenilen üyelik fonksiyonları üzerine temellenmiştir. Bu algoritma temel olduğundan aşağıda kısaca verilmiştir [184].

2.3.3.1. Matematiksel temel

Her bir küme veya kategori prototipi veya merkezi, v_i ve bir üyelik fonksiyonu veya U ayrılma (bölünme) matrisi ile karakterize edilir. U'nun bir elemanı olarak, i kategorisindeki k örüntüsünün üyelik derecesi μ_{ik} ifadesi olarak yazılır. Bu üyelik derecesi ifadesi aşağıda verilen Denklem 2.69. ile bulunur.

$$\mu_{ik} = \frac{\left(\frac{1}{\|x_k - v_i\|^2} \right)^{\frac{1}{m-1}}}{\sum_{j=1}^{N_C} \left(\frac{1}{\|x_k - v_j\|^2} \right)^{\frac{1}{m-1}}} \quad (2.69)$$

Burada, N_C kategorilerin sayısıdır, m ; $1 < m < \infty$ arasında bir bulanıklaştırma parametresidir ve x_k k . eğitim örneğidir. Çift çizgi sembolü bir uzaklık ölçüsüdür. Mevcut uygulamalarda, öklit uzaklığı olarak benimsenmektedir. x_k örneği v_i merkezine yakınlığının da üyeliği 1'e yaklaşır, uzağında ise üyeliği 0'a yaklaşır. Yukarıdaki denklemin payı i kümesine uygun olma (dahil olma) miktarı olarak yorumlanabilir ve payda ise kümelerin seçilen gruba uygun olma

seçeneğinin toplam miktarı olarak yorumlanabilir. Bu nedenle, yukarıdaki denklem üyeliğin bir normalizasyonudur (ortalamasıdır). i . küme merkezi şu şekilde verilir:

$$v_i = \frac{1}{\sum_{k=1}^n (\mu_{ik})^m} \sum_{k=1}^n (\mu_{ik})^m x_k \quad (2.70)$$

Burada, n eğitim örneklerinin sayısıdır. Küme merkezi eğitim örneklerinin bir ortalaması olarak düşünülebilir, üyeliklere uygun olarak ağırlıklanır. Aynı zamanda sorgulamadaki kategori ile uygun olarak $\sum_{k=1}^n (\mu_{ik})^m$ örneğinin bulanıklık değeri ile normalize edilir.

2.3.3.2. Eğitim


Eğitim esnasında, aşağıda belirtilen amaç (objektif) fonksiyonu minimize edilir:

$$\sum_{i=1}^{N_C} \sum_{k=1}^n (\mu_{ik})^m \|x_k - v_i\|^2 \quad (2.71)$$

v_i küme merkezleri ve μ_{ik} üyelik fonksiyonları minimizasyon esnasında yararlanılabilir parametrelerdir. Amaç fonksiyonunun eğimi, üyelik fonksiyonları ve küme merkezleri μ_{ik} ve v_i denklemleri ile tanımlanan sistem kazancıdır. Bu sistem denklemleri, bulanık kümeleme algoritması olarak bilinen ardışık bir prosedür tarafından çözülebilir.

2.3.3.3. Test Etme

Yeni veri verildiğinde, çeşitli kümelere üyelikler hesaplanır. Bir kısmi matrisden ziyade bir kısmi vektör, sorguda yalnız bir örnek alınarak hesaplanır. En yüksek üyelik ile kümeleme Şekil 2.18. deki sınıflandırıcı kararı olarak seçilir.



Şekil 2.18. Bulanık C-Ortalama sınıflandırıcısı.

Kümeleme, verilerin benzerlikleri ölçütünde alt kümelere veya sınıflara ayırma işlemi olarak tanımlanır. BCO algoritması iteratif bir yapıda olup, aşağıdaki denklemde verilen J değerinin minimize edilmesi için üyelik derecesi olan u_{ij} ve kümeleme merkezleri olan v_j lerin hesaplanmasına dayanır. Kümelerin başlangıç merkezleri rastgele verilebilir.

$$J = \sum_{i=1}^M \sum_{j=1}^R (u_{ij})^m |x_i - v_j|^2 \quad (2.72)$$

Burada m tasarım parametresi 1'den büyük seçilmelidir. M giriş veri sayısını, R ise küme sayısını göstermektedir. Girişlerin küme merkezlerine göre üyelik dereceleri ise aşağıdaki denklemdeki gibi hesaplanmaktadır. Dikkat edilmesi gereken önemli nokta $\sum_{j=1}^R u_{ij} = 1$ olması gereksinimidir.

$$u_{ij} = \left[\sum_{k=1}^R \left(\frac{|x_i - v_j|^2}{|x_i - v_k|^2} \right)^{\frac{1}{m-1}} \right]^{-1} \quad (2.73)$$


Elde edilen üyelik derecelerinden yeni küme merkezleri aşağıdaki denkleme göre yeniden hesaplanmaktadır.

$$V_j^{new} = \frac{\sum_{i=1}^M x_i (u_{ij})^m}{\sum_{i=1}^M (u_{ij})^m} \quad (2.74)$$

elde edilen yeni küme merkezi ile bir önceki küme merkezi arasındaki fark istenen değerde ise döngü işlemi bitirilir.

2.3.4. Kohonen Yapay Sinir Ağları Sınıflandırıcısı

Kohonen ağı, bir giriş tabakası ve bir de çıkış tabakası olmak üzere iki tabakadan oluşur. Bu ağ Şekil 2.19. da gösterilmiştir. Çıkış tabakasındaki İşlemci Elemanlar (İE) genellikle düzenli iki boyutlu aralıklar olarak düzenlenir. Çıkıştaki her İE, bütün giriş işlemci elemanlarına bağlıdır. Bağlantıların ağırlıkları verilen çıkış işlemci elemanı ile ilgili olan referans vektörünün elemanlarını oluşturur.



Şekil 2.19. Kohonen ağı

Kohonen ağının öğrenme adımları aşağıdaki gibidir.

- i) Çıkış İE'lerin bütün referans vektörleri küçük rastgele değerlere çekilir,
- ii) Bir giriş deseni alınır,
- iii) Kazanan çıkış işlemci elemanı belirlenir (Bu giriş desenine en yakın referans vektörüne sahip işlemci elemanıdır. Referans vektörü ile giriş vektörü arasındaki öklit uzaklığı genellikle uzaklık ölçüsü olarak alınır.),

- iv) Kazanan işlemci elemanı ve onun komşularının referans vektörü güncelleştirilir. Bu referans vektörleri giriş vektörüne yaklaştırılır. Bu yaklaştırma (ayarlar) kazanan işlemci eleman için en fazla ve bu işlemci elemandan uzaklaştıkça daha azdır. Öğrenme ilerledikçe komşuların sayısı azalmakta ve öğrenme sonunda sadece kazanan işlemci elemanın referans vektörü ayarlanmaktadır.

İyi öğrenmiş bir Kohonen ağında birbirine yakın çıkış işlemci elemanlarının referans vektörleri vardır. Öğrenmeden sonra bir etiketleme işlemine başlanır. Bilinen sınıfların giriş desenleri ağına giriş olarak verilir ve bu giriş desenleri tarafından aktif hale gelen çıkış işlemci elemanlarına bu sınıf etiketleri verilir.


Kohonen kuralı, biyolojik sistemlerdeki öğrenmeden esinlenen Kohonen tarafından geliştirilmiştir. Bu kuralda, nöronlar öğrenmek için yarışır, kazanan nöronun ağırlıkları güncellenir. Bu kural “kazanan tamamını alır (winner takes all)” olarak da bilinir. En büyük çıkışa sahip işlemci nöron kazanır, bu nöron komşularını uyarma ve yasaklama kapasitesine sahiptir. Kohonen kuralı hedef çıkışa gereksinim duymadığı için eğitici bir öğrenme yöntemidir [165].

2.3.4.1. Kohonen Yapay Sinir Ağları Sınıflandırıcısının Yapısı


Kendi kendini düzenleyen Kohonen öznelik haritaları, eğitici olmayan durumda giriş işaretlerinin analizi ve kodlanması için otomatik bir yöntemden meydana gelen yapay sinir ağlarıdır. Kendini düzenleme algoritması, beyinde bulunan haritalara benzer. Beyindeki duyu yollarının önemli bir düzenleme prensibi, nöronların yerleşmesinin sıralı olması ve algılanan dış uyarının bazı fiziksel özelliklerini yansıtmalarıdır. Mesela, duyma yolunun her seviyesinde, sinir hücreleri ve fiberler, belli frekanslara en yüksek cevabı veren nöron dikkate alınarak anatomik yapıda düzenlenmiştir. Duyma yolundaki bu düzenleme, beynin duyma kabuğuna kadar gitmektedir. Beyinde alt seviye düzenlemesinin büyük bir kısmı genetik olarak önceden belirlenmiş olmasına rağmen, daha yüksek seviyedeki düzenlemenin bir kısmının kendi kendini düzenlemeyi sağlayan algoritmalar tarafından, öğrenme esnasında meydana geldiği düşünülmektedir. Kohonen, beyine benzer, kendi kendini düzenleme öznelik haritası adını verdiği bir ağ modeli sunmuştur [152].

Kohonen yapay sinir ağının, giriş verisinin bir haritasını gösterdiği söylenebilir. Bu yapay sinir ağında yapısal olarak benzer girişler, yapısal olarak birbirine yakın çıkışlar üretir. Kohonen algoritması, yarışmacı öğrenme (competitive learning) algoritması olarak da adlandırılır. Yarışmacı öğrenme, giriş örüntü setini sınıflandırmak için kullanılabilen belirgin ve genel özellikleri keşfetmek için bir yol sağlar. Yarışmacı kategoriye bağlı öğrenme kurallarının hepsinde ortak özellik, bir yarışma stratejisinin işlem elemanlarının tamamına veya bir kısmına uygulanmasıdır. Bu yarışma sonucu, kazanan işlem elemanının ağırlıkları değiştirilir [166].

Basit işlem elemanlarından oluşan Kohonen yapay sinir ağı, Şekil 2.23. de gösterildiği gibidir. Burada N çıkış işlem elemanı ($z_1, z_2, \dots, z_N$) sayısı, $x_i = (x_1, x_2, \dots, x_n)$ n boyutlu giriş örüntü vektörü, $w_i = (w_{z1}, w_{z2}, \dots, w_{zn})$ her çıkış işlem elemanının ağırlık vektörü olup, w_{ij} ise x_j girişi ile i . işlem elemanı arasındaki ağırlıktır. Ağırlık vektörünün başlangıç değerleri keyfi seçilebildiği gibi, ilk giriş örüntü vektörü ağırlıklar olarak alınabilir. Temelde Kohonen yapay sinir ağı, her çıkış birimine (bu birimlere sınıf da diyebiliriz) giriş vektörünün bir elemanının bağlanması ile meydana gelir. Böylece farklı çıkış birimleri farklı girişlere duyarlı hale gelebilir. Kohonen yapay sinir ağının yapısal sistem modeli Şekil 2.20. de gösterilmiştir. Şekilde de görüleceği üzere Kohonen yapay sinir ağı sadece iki katmana, yani giriş ve çıkış katmanına sahiptir. Ayrıca Şekil 2.21. de ise Kohonen sistem modeli verilmiştir [152].



Şekil 2.20. Kohonen 'in kendi kendini düzenleme haritasının ağ birimleri.



Şekil 2.21. Kohonen sistem modeli.

Giriş işaretleri, doğal nesnelerin gözlenmesinden türetildiği için, giriş örüntü vektörü ayrık zamanda $x = x(t)$ olarak formülize edilir. Buna karşılık $w_i(t)$ ise farklı işlem elemanlarının zamana bağlı değişken ağırlık vektörleridir.

Benzer şekilde Kohonen yapay sinir ağına, gelen giriş örüntü vektörüne cevabı, çıkış katmanındaki herhangi bir işlem elemanı üzerinde yoğunlaşmış olmasına rağmen, fazla sayıda geri besleme bağlantısı sonucu oluşan etkileşimler ile sistemin çıkışı belirlenir. Komşu işlem elemanları arasında yerel bir etkileşim vardır. En yakın komşular birbirini pozitif yönde etkilerken, birbirinden uzak komşuluktaki işlem elemanları birbirini negatif olarak etkilerler. Bu tip etkileşime "meksika şapkası fonksiyonu" denir [161].

Herhangi bir çıkış işlem elamanının, verilen bir dairesel yarıçap ile bütün komşulukları belirlenebilir. Kohonen' in kendi kendini düzenleyen haritaları tarafından incelenen nesneler, x vektörü ile simgelenmektedir. Bu x vektörü, giriş nesnesinin özniteliklerini içeren vektör olup, iki boyutlu düzlemsel çıkış uzayında haritalandırılır. Sonuçta benzer nesneler iki boyutlu düzlemsel çıkış uzayında birbirine yakın yerlere yerleşirler. Böylece yapay sinir ağının öğrenme işlemi, eğiticişiz bir şekilde sağlanmış olur. Öğrenme gerçekleştirildikten sonra benzer giriş nesnelerinin, çıkış düzleminde birbirine yakın haritalandığı gözlenebilir. Buna karşılık birbirine benzemeyen giriş nesneleri birbirinden uzağa haritalanırlar.

1. adım : N tane giriş düğümlerinden M tane çıkış düğümlerine olan ağırlıklar küçük rastgele değerlere ayarlanır ve komşuluğun ilk yarıçap (eşik) değeri belirlenir.

2. adım : Yeni giriş uygulanır.

3. adım : Girişin, tüm çıkış düğümlerine (sınıflara) olan mesafesi Denklem 2.75. deki gibi hesaplanır.

$$d_j = \sum_{i=1}^N (x_i(t) - w_{ij}(t))^2 \quad (2.75)$$

d_j : Giriş ile j. çıkış düğümü arasındaki mesafe,

$x_i(t)$: x giriş vektörünün i. elemanının t anındaki değeri,

$w_{ij}(t)$: i. girişten j. çıkış düğümüne olan ağırlığın t anındaki değerini göstermektedir.

4. adım : Minimum mesafeye sahip çıkış düğümü belirlenir. En küçük d_j mesafesine sahip j. çıkış düğümü seçilir.

5. adım : j. çıkış düğümüne ve komşularına ait ağırlıklar yeniden hesaplanır.

Yeni ağırlıklar;

- yarışmayı kazanan çıkış düğümleri için,

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(t) \cdot (x_i(t) - w_{ij}(t)) \quad \forall i \in N_c(t) \quad (2.76)$$

- yarışmayı kaybeden çıkış düğümleri için,

$$w_{ij}(t+1) = w_{ij}(t) \quad \forall i \notin N_c(t) \quad (2.77)$$


olur.

$\alpha(t)$: zamanla azalan bir kazanç terimi. ($0 < \alpha(t) < 1$)

$N_c(t)$: zamanla değişen komşuluk kümesi.

6. adım : 2. adıma gidilerek işlemler tekrarlanır.

Kohonen yapay sinir ağını eğitmek ve nesne tanımak için aşağıda Şekil 2.24. deki algoritma kullanılır [183].



Şekil 2.23. Kohonen yapay sinir ağı eğitmek ve nesne tanımak için kullanılan program akış şeması

3. ÖZELLİK ÇIKARIMI İÇİN YÖNTEMLER

3.1. Dalgacık Dönüşüm Zaman-Frekans Gösterim Entropileri İle Özellik Çıkarma Yöntemleri

Bu bölümde, [132] çalışmasında geliştirilen dalgacık dönüşüm zaman frekans entropileri ile özellik çıkarma yöntemleri, Radar Hedef Eko (RHE) işaretlerinden özellik çıkarma amacı ile kullanılmıştır.


3.1.1. Dalgacık Dönüşümü

Dalgacık teorisi farklı alanlarda birçok 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.

Dalgacık Dönüşümü (DD) işaretin ölçeklenebilir bir Zaman-Frekans Gösterimi (ZFG) ile analizini sağlar ve geleneksel işaret işleme teknikleri (HFD, KZFD) tarafından görülmeyen detayları meydana çıkarır. Dalgacık dönüşümü zaman – ölçek yöntemine dayalı olduğu için, odağa tam olarak ayarlanarak işaretin farklı kısımlarını gözetleyebilen bir matematik mikroskobu gibi davranır [132]. Şekil 3.1. de en yaygın olarak kullanılan dalgacıkların bir kısmı verilmiştir. Dalgacık analiz yöntemlerinin geleneksel yöntemlere 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 çeşitli işaretlerin daha esnek ZFG'lerinin elde edilmesinde etkili bir araç olduğu literatürde belirtilmiştir [43], [132].



Şekil 3.1. Yaygın olarak kullanılan dalgacık örnekleri.

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 [132].

Dalgacık dönüşümleri, sürekli dalgacık dönüşümleri, ayrık dalgacık dönüşümleri ve dalgacık paket analizi olmak üzere üç farklı kategoride incelenebilir.


1) *Sürekli Dalgacık Dönüşümü*: Sürekli Dalgacık Dönüşümü (SDD) sıkıştırımlar, genişlemeler 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. 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. SDD, Fourier analizi kadar iyi sinüzoidal bileşenleri çözemez, fakat onun KZFD' ye alternatif olan ilgi çekici yanı, geçici olayların yerini saptayabilmesidir.

2) *Ayrık Dalgacık Dönüşümü*: SDD 'nin hesaplama yükü fazla ve dönüşümü sağlamak için kullandığı bilgi miktarı oldukça büyük olduğundan SDD den daha etkili bir yol olarak, Ayrık Dalgacık Dönüşümü (ADD) kullanılmaktadır. 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 ayrık eşdeğerleridir.



Şekil 3.2. ADD ayrışım ağacı.

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 işareten 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

frekans eğilimlerinde, frekansın yeri iyi saptanır ve yüksek frekans bileşenlerinde ise frekans yerine zaman saptaması daha iyi belirlenir.

3) *Dalgacık Paket Analizi*: Dalgacık Paket Analizi (DPA) ADD' ye benzer olup, işaret üzerinde mümkün olan bir çok ayrışmaları üretir ve ADD bunlardan sadece biridir. Filtre bankası her bir zaman için düşük frekans bileşenlerini tam olarak ayrıştırmak yerine, yüksek frekans bileşenlerini daha iyi ayrıştırmayı mümkün kılar. Böylece tüm zaman-frekans düzlemi mümkün olan tüm alt bölümlere, farklı zaman-frekans pencereleri ile bölünür [132].

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

3.1.2. Dalgacık Dönüşüm Ağacından Entropi Hesaplanması

Kaynak [132], çalışmasında geliştirilen dalgacık dönüşüm ZFG entropilerine dayalı özellik çıkarım tekniğinin blok diyagramı Şekil 3.4. de verilmiştir.




Şekil 3.4. Dalgacık dönüşüm ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı söz konusu kaynakta bulunabilir.

3.1.3. Dalgacık Paket Dönüşüm Ağacından Entropi Hesaplanması

Kaynak [132], çalışmasında geliştirilen dalgacık paket dönüşüm ZFG entropilerine dayalı özellik çıkarım tekniğinin blok diyagramı Şekil 3.5. de verilmiştir.



Şekil 3.5. Dalgacık paket dönüşüm ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı söz konusu kaynakta bulunabilir.


3.2. Çeşitli Zaman-Frekans Gösterim Entropileri ile Özellik Çıkarma Yöntemleri

Parametrik olmayan zaman frekans yöntemleri, parametrik yöntemlerin 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 yöntemler, işaretin herhangi bir özel karakteristiği ile ilgilenmediklerinden işaret ne olursa olsun uygulanabilirler. Bu yöntemlerin dezavantajı, işaret işlemenin farklı karakteristik tekniklerini kullanmadıklarından, tatmin edici performansa sahip değildirler. Parametrik olmayan yöntemler, sayısal filtre ve dönüşüm tabanlı işaret işleme gibi yöntemleri (Fourier analizi ve ayırık kosinüs dönüşümü) içerirler [45-47, 132]. İşaretteki rastgele değişimlerin zaman-frekans ilişkisini belirlemek için parametrik olmayan yöntemler 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 rastgele değişimlerin sırasını tespit etmek için parametrik olmayan yöntemleri kullanmışlardır [45-47, 132]. Brodsky ve Darkhovsky tarafından önerilen bu çözüm yaklaşımı, Deshayes ve Picard (1981) tarafından da işarettaki değişimlerin spektrumunu tespit etmek için kullanılmıştır [45-47, 132]. KZFD, Wigner-Ville ZFG, Born-Jordan ZFG, Choi-Williams ZFG 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 [45-47, 132]. Bu tez çalışmasında sırasıyla Kısa Zamanlı Fourier Dönüşümü (KZFD) Zaman Frekans Gösterimi (ZFG), Born-Jordan Zaman Frekans Gösterimi (ZFG), Choi-Williams Zaman Frekans Gösterimi (ZFG), Wigner Ville Zaman Frekans Gösterimi (ZFG) sırasıyla kullanılmıştır. Ayrıca bu yöntemlerin etkinliğini artırmak ve bu yöntemlerden en iyi entropi değerlerini elde etmek amacıyla genetik algoritmada kullanılmıştır. Önerilen bu yöntemde radar eko işaretlerinin yukarıda sayılan ZFG'lerden çıkarılacak en uygun entropi değeri hesaplanması amaçlanmaktadır. Ayrıca bir başka yöntemde ise işaret işleme tekniklerinin frekans kestirim üstünlüklerinden faydalanarak işaret hakkında tanımlayıcı özellikler elde etmek için, radar eko işaretlerinin dalgacık dönüşümleri ile elde edilen bileşenleri hesaplanmıştır. Böylece, elde edilen ZFG 'nin her bir bileşeninin entropi değeri hesaplanarak, radar hedef tanıma sistemi için farklı nitelikli özellik çıkarım teknikleri gerçekleştirilmiştir.

3.2.1. 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 [45-47, 132]. Şekil 3.6. da bir radar hedef eko işaretinin spektrogramı verilmiştir. Şekil 3.7. de ise bir radar hedef eko işareti spektrogramının üç boyutlu görünümü verilmiştir.




Şekil 3.6. Radar hedef eko işaretinin KZFD spektrogramı.



Şekil 3.7. Radar hedef eko işaretinin KZFD spektrogramının üç boyutlu görünümü.

Bir $x(t)$ işaretinin Fourier dönüşümü Denklem 3.11. ile hesaplanmaktadır. Zamana bağımlı veya pencereli Fourier dönüşümü olarak bilinen KZFD, işaretin tümünü küçük veri pencerelerine bölerek analiz etmeye çalışır. Kısaca KZFD, Denklem 3.3. ile verilebilir. Burada $w(n-n_0)$ bir kayan pencere fonksiyonu olup, literatürde kullanılan pencereler: Bartlett, Blackman, Dikdörtgen, Chebyshev, Hanning, Hamming, Kaiser ve Üçgendir [45-47, 132]. Şekil 3.8. de bu pencere fonksiyonlarından bazıları görülmektedir.



Şekil 3.8. Pencere fonksiyonları.


$$X(f) = \int_{-\infty}^{\infty} x(t) \cdot e^{-j2\pi ft} \cdot dt \quad (3.2)$$

$$X(k) = \sum_{n=0}^N x(n) \cdot w(n - n_0) \cdot e^{-\frac{j2\pi nk}{N}} \quad (3.3)$$

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.

3.2.1.1. Dalgacık Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması

Kaynak [132] çalışmasında geliştirilen Dalgacık paket dönüşüm ve KZFD spektrogramı ile oluşturulan ZFG bileşenlerinin entropilerine dayalı özellik çıkarım tekniğinin blok diyagramı Şekil 3.9. da verilmiştir.

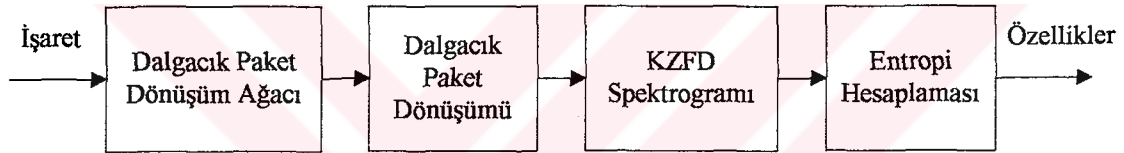


Şekil 3.9. Dalgacık dönüşümü ve KZFD spektrogramı ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı söz konusu kaynakta bulunabilir.

3.2.1.2. Dalgacık Paket Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması

Kaynak [132] çalışmasında geliştirilen Dalgacık paket dönüşüm ve KZFD spektrogramı ile oluşturulan ZFG bileşenlerinin entropilerine dayalı özellik çıkarım tekniğinin blok diyagramı Şekil 3.10. da verilmiştir.



Şekil 3.10. Dalgacık paket dönüşüm ve KZFD spektrogram ZFG entropileri ile özellik çıkarımı.

Blok diyagramdaki her bir aşamanın görevi ve işlev tarzı söz konusu kaynakta bulunabilir.

3.2.2. Wigner-Ville Zaman Frekans Gösterimi

Wigner-Ville (WV) ZFG, bir zaman frekans dağılımıdır ve potansiyel olarak zamanla değişen işaretlerin analizinde çok kullanışlı bir araçtır. Zamanla değişen işaretler ki onların frekans bilgileri, zamanla değişen spektral karakteristiklere sahip tipik bir radar ölçüm alanındaki işaretler gibi zamana bağlıdır.

Bir $s(t)$ işaretinin WV ZFG'si şu şekilde tanımlanır:

$$WV(t, f) = \int_{-\infty}^{\infty} s(t + \tau/2) s^*(t - \tau/2) \exp(-j2\pi f\tau) d\tau \quad (3.4)$$

Burada $WV(t, f)$, $s(t)$ işaretinin “t” anındaki ve “f” frekansındaki enerji dağılımıdır ve $s(t)$ bir analitik işarettir (sürekli işarettir). Bir ayrık zaman işaret için WV aşağıda Denklem 3.5. deki gibi tanımlanır:


$$WV(n, \theta) = 2 \sum_{k=-\infty}^{\infty} s(n+k) \cdot s^*(n-k) \exp(-j2k\theta) \quad (3.5)$$

Burada n işaretin örnek sayısını, k zamanda kaydırmayı temsil eder. Yukarıda verilen iki formül genellikle sonlu işaretler için kullanılır. Sonsuz bir işaret için genellikle WV ZFG dağılımı formülü uygulanmadan önce bir ağırlık fonksiyonu tarafından $s(n)$ işareti pencerelenir yani bölümlendirilir. Bu ağırlık fonksiyonu pencere fonksiyonu olarak adlandırılır ve WV ZFG hesaplanırken n defa zaman eksenini boyunca kayar. Bu pencerelenmiş WV ZFG, Pseudo Wigner-Ville ZFG olarak bilinir ve şu şekilde gösterilir:


$$PWVD(n, m\pi/M) = \sum_{k=-(L-1)}^{L+1} s(n+k) s^*(n-k) w(k) \cdot w^*(-k) \exp(-j2\pi k \frac{m}{M}) \quad (3.6)$$

burada $M=2L$ 'dir. L işaretin uzunluğudur. Pencere fonksiyonu $w(k)$, $2L-1$ uzunluğundadır.

$w(k)=0$ dır (her $|k| \geq L$ olduğu zaman). Şekil 3.11. de RHE işaretinin Wigner-Ville ZFG'si verilmiştir. Şekil 3.12. de ise RHE işaretinin Wigner-Ville ZFG'sinin üç boyutlu görünümü verilmiştir.



Şekil 3.11. Radar hedef eko işaretinin Wigner-Ville Zaman Frekans Gösterimi.



Şekil 3.12. Radar hedef eko işaretinin Wigner-Ville Zaman Frekans Gösteriminin üç boyutlu görünümü.

3.2.3. Born Jordan Zaman Frekans Gösterimi

Kendine has sınırlandırmalar içeren ZFG'ler vardır. Bunlardan biride KZFD ZFG'dir. Bu ZFG'de zaman ve frekans çözünürlükleri birbirlerine bağlıdır. Birinin iyi olması için diğerinin iyiliğinden taviz verilmesi gerekmektedir. Yani kısa zamanlı pencereleme tekniği kullanıldığında, zaman çözünürlüğü geliştirilirken, frekans çözünürlüğü bozulabilir. KZFD ZFG'nin önemli bir dezavantajı ise veri uzunluğu kısa olması durumunda bu ZFG'nin kullanışsız olmasıdır. Kısa uzunluklu işaretler, büyük bant genişliklerine sahiptir ve bu kısa işaretlerin daha küçük bölümlere bölünmesi orjinal işaretin yorumlanmasında anlamsızlıklar meydana getirebilir. KZFD'nin bu dezavantajını gidermenin bir yolu da geliştirilmiş bir ZFG (aynı zamanda Cohen temsili olarak ta bilinir) kullanmaktır. Bu geliştirilmiş ZFG'lerde kernel adı verilen özel pencereleme fonksiyonları kullanılmaktadır. Özellikle Cohen temsili ZFG'ler genel olarak Denklem 3.7. kullanılarak elde edilebilir.

$$C(t, f) = \iiint e^{j2\pi v(u-t)} \cdot g(v, \tau) \cdot s^* \left(u - \frac{1}{2}\tau\right) \cdot s\left(u + \frac{1}{2}\tau\right) \cdot e^{-j2\pi f\tau} dv \cdot du \cdot d\tau \quad (3.7)$$


Burada $g(v, \tau)$, kernel olarak adlandırılan iki boyutlu bir fonksiyondur. $s(u + \frac{1}{2}\tau)$ ve $s^*(u - \frac{1}{2}\tau)$ sırasıyla sinyalin gerçekte ve karmaşık eşleniğini temsil eder. Denklem 3.7. de

verilen genel ZFG ifadesinde $g(v, \tau)$ yerine $\frac{\sin(\frac{v\tau}{2})}{\frac{v\tau}{2}}$ yazılırsa Denklem 3.8. deki Born-


Jordan ZFG ifadesi elde edilir.

$$C(t, f) = \iiint e^{j2\pi v(u-t)} \cdot \frac{\sin(\frac{v\tau}{2})}{\frac{v\tau}{2}} \cdot s^*(u - \frac{1}{2}\tau) \cdot s(u + \frac{1}{2}\tau) \cdot e^{-j2\pi f\tau} dv \cdot du \cdot d\tau \quad (3.8)$$

Bu Born-Jordan ZFG, sinyalin yapay (istenmeyen) frekans etkilerini azaltırken, aynı zamanda KZFD ZFG'den daha yüksek zaman frekans çözünürlüğü sağlar. Şekil 3.13. de RHE işaretinin Born-Jordan ZFG'si verilmiştir. Şekil 3.14. de ise RHE işaretinin Born-Jordan ZFG'sinin üç boyutlu görünümü verilmiştir.



Şekil 3.13. Radar hedef eko işaretinin Born Jordan Zaman Frekans Gösterimi.



Şekil 3.14. Radar hedef eko işaretinin Born Jordan Zaman Frekans Gösteriminin üç boyutlu görünümü.

3.2.4. Choi-Williams Zaman Frekans Gösterimi

KZFD ZFG'nin dezavantajlarını gidermek için kullanılan Cohen sınıfı ZFG'lerden biride Choi-Williams (CW) ZFG'dir. CW ZFG'de pencereleme amaçlı kullanılan kernel aşağıda Denklem 3.9.da verilmiştir.


$$g(v, \tau) = e^{-v^2\tau^2/\sigma} \quad (3.9)$$

Burada σ bir parametredir. Eğer σ çok büyük bir değer olarak alınırsa kernel etkili olur ve Wigner-Ville ZFG elde edilir. σ eğer çok küçük bir değer seçilirse kernel v, τ düzleminde orjine yakın bir yerde bulunur. CW ZFG çoklu frekans içeren sinyallerdeki istenmeyen frekans bileşenlerinin etkisini azaltma özelliğinden dolayı WV ZFG'ye daha üstündür [167]. CW ZFG ifadesi Denklem 3.29.da verilmiştir.


$$C(t, f) = \iint \sqrt{\frac{\pi\sigma}{\tau^2}} e^{-\pi^2\sigma(u-t)^2/\tau^2 - j2\pi f s^*(u - \frac{1}{2}\tau).s(u + \frac{1}{2}\tau)} du.d\tau \quad (3.10)$$

Şekil 3.15. de RHE işaretinin Choi-Williams ZFG'si verilmiştir. Şekil 3.16. da ise RHE işaretinin Choi-Williams ZFG'sinin üç boyutlu görünümü verilmiştir.

Radar Hedef Eko İşaretinin Choi Williams Zaman Frekans Gösterimi



Şekil 3.15. Radar hedef eko işaretinin Choi Williams Zaman Frekans Gösterimi.




Şekil 3.16. Radar hedef eko işaretinin Choi Williams Zaman Frekans Gösteriminin üç boyutlu görünümü.

3.3. Geliştirilen Optimum Entropi Tabanlı Özellik Çıkarma Yöntemi

Bu bölümde, geliştirilen optimum entropi tabanlı özellik çıkarma yöntemi tanıtılmıştır. Bu yöneme göre özellik çıkarımı için dört farklı seçenek vardır. Bu uygulamada, birbirinden farklı özellik çıkarım yöntemlerinden en uygun olanını seçmek için genetik algoritma yapısı kullanılmıştır. Bu dört farklı özellik çıkarım yöntemi aşağıda sıralanmıştır:

Yöntem-1: Kısa Zamanlı Fourier Dönüşümü Zaman Frekans Gösterimi Kullanılarak En İyi Entropi Değerlerinin Bulunması Yöntemi


Bu yöntemde önce işaretin KZFD spektrogramı alınır. Daha sonra sırasıyla bu KZFD spektrogramının Shonnon entropi, norm entropi, logaritmik enerji entropi, sure entropi, eşik entropi değerleri verilen entropi parametre değerlerine göre hesaplanır. Bu yöntem aşağıda Şekil 3.17. de blok diyagram halinde verilmiştir.



Şekil 3.17. KZFD ZFG kullanılarak en iyi entropi değerlerinin bulunması için geliştirilen yöntemin blok diyagramı.

Yöntem-2: Wigner-Ville Zaman Frekans Gösterimi Kullanılarak En İyi Entropi Değerlerinin Bulunması Yöntemi


Bu yöntemde önce işaretin WV ZFG'si alınır. Daha sonra sırasıyla bu WV ZFG'nin Shonnon entropi, norm entropi, logaritmik enerji entropi, sure entropi, eşik entropi değerleri verilen entropi parametre değerlerine göre hesaplanır. Bu yöntem aşağıda Şekil 3.18. de blok diyagram halinde verilmiştir.



Şekil 3.18. WV ZFG kullanılarak en iyi entropi değerlerinin bulunması için geliştirilen yöntemin blok diyagramı.

Yöntem-3: Born Jordan Zaman Frekans Gösterimi Kullanılarak En İyi Entropi Değerlerinin Bulunması Yöntemi


Bu yöntemde önce işaretin BJ ZFG'si alınır. Daha sonra sırasıyla bu BJ ZFG'nin Shonnon entropi, norm entropi, logaritmik enerji entropi, sure entropi, eşik entropi değerleri verilen entropi parametre değerlerine göre hesaplanır. Bu yöntem aşağıda Şekil 3.19. da blok diyagram halinde verilmiştir.



Şekil 3.19. BJ ZFG kullanılarak en iyi entropi değerlerinin bulunması için geliştirilen yöntemin blok diyagramı.

Yöntem-4: Choi-Williams Zaman Frekans Gösterimi Kullanılarak En İyi Entropi Değerlerinin Bulunması Yöntemi

Bu yöntemde önce işaretin CW ZFG'si alınır. Daha sonra sırasıyla bu CW ZFG'nin Shonnon entropi, norm entropi, logaritmik enerji entropi, sure entropi, eşik entropi değerleri verilen entropi parametre değerlerine göre hesaplanır. Bu yöntem aşağıda Şekil 3.20. de blok diyagram halinde verilmiştir.



Şekil 3.20. CW ZFG kullanılarak en iyi entropi değerlerinin bulunması için geliştirilen yöntemin blok diyagramı.

Bu yöntemlerin herbirindeki Shonnon entropi, norm entropi, logaritmik enerji entropi, sure entropi, eşik entropi değerlerinin hesaplanması işlemleri Bölüm 2.2.2.deki entropi hesaplama teknikleri kullanılarak gerçekleştirilir.


3.3.1. Optimum Entropi Tabanlı Özellik Çıkarımı İçin Kullanılan Genetik Algoritmanın

Yapısı ve İşlevi

Bu çalışmada genetik algoritma kullanılmasının nedeni, Bölüm 3.3. de belirtilen dört farklı özellik çıkarım yönteminden en uygun olanını seçmek ve sınıflandırma için kullanılan

YSA'nın giriş katmanındaki başlangıç ağırlıklarını en iyi şekilde ayarlamaktır. Genetik algoritma içerisinde gerçekleştirilen işlemler aşağıda sıralanmıştır:

- 1) **Başlangıç Popülasyonunun Oluşturulması :** Genetik algoritmanın başlangıç popülasyonu için bu uygulamada 20 adet rastgele birey seçilmiştir. Bu bireylerin herbiri 32 bitten oluşmaktadır. Bu 32 bitten ilk iki bit farklı dört özellik çıkarım yöntemini temsil etmektedir. Daha sonraki 30 bit ise 5 adet giriş için başlangıç ağırlıklarını temsil etmektedir. Bu ağırlık değerleri $[-1.50, 1.50]$ aralığında 0.25'lik hassasiyete sahiptir. Her bir ağırlık 6 bitle temsil edildiğinden giriş katmanı başlangıç ağırlıkları için toplam 30 bit kullanılmaktadır. Aşağıda Şekil 3.21. de bu şekilde oluşturulmuş bir adet rastgele birey görülmektedir:



Şekil 3.21. Rastgele oluşturulmuş birey.

- 2) **Özellik Çıkarım Mekanizması :** Popülasyonu oluşturan bireylerin her biri 1. maddede de belirtildiği gibi dört özellik çıkarım yönteminden birini ve 5 adet giriş başlangıç ağırlığının herbiri için bir değeri temsil etmektedir. Rastgele bir birey ele alındığında özellik çıkarımı için o bireyin temsil ettiği özellik çıkarım yöntemine gidilir, burada ilgili bireyin temsil ettiği norm entropi, Shannon entropi, logaritmik enerji entropi, sure entropi ve eşik entropi değerleri hesaplanır. Buradan elde edilen entropi değerleri özellik vektöründe özellik olarak kullanılır.
- 3) **Sınıflandırma Mekanizması :** Sınıflandırma mekanizmasında ise özellik çıkarım mekanizmasında elde edilen özellik vektörü çok katmanlı ileri beslemeli bir YSA sınıflandırıcısının girişlerine verilerek bu özelliklerin sınıflandırılması işlemi gerçekleştirilmiştir. Ancak bu YSA sınıflandırıcısının giriş katmanı başlangıç ağırlıkları rastgele seçilmek yerine ilgili bireyin girişler için temsil ettiği 5 adet ağırlık değeri kullanılmaktadır. Böylelikle daha hızlı ve daha iyi sonuçlar veren bir sınıflandırma mekanizması arzu edilmektedir. Burada kullanılan özelliklerin ait oldukları eko işaretlerini iyi bir şekilde temsil edip etmediklerine uygunluk fonksiyonuna bakılarak karar verilir. Uygunluk fonksiyonu eğer belirli bir değerin üzerindeyse ilgili bireyin temsil ettiği yöntem ve giriş katmanı başlangıç ağırlık


değerleri kaydedilir. Eğer uygunluk fonksiyonu ölçüt alınan değerin altında ise bu birey atılır. Bu şekilde popülasyondaki herbir bireye bakılır.

4) **Çaprazlama Operatörü** : Elde edilen 10 adet iyi bireyin rastgele 6 tanesi kendi aralarında rastgele çaprazlama işlemine tabi tutulur. Kullanılan çaprazlama oranı %60'dır.


5) **Mutasyon Operatörü** : Bu uygulamada mutasyon operatörü olarak bit tersleme yöntemi kullanılmıştır. Geriye kalan 4 bireyin rastgele birer bitine bit tersleme işlemi uygulanarak buradan yeni 4 adet birey elde edilmiştir.

Böylelikle yeni popülasyon için toplam 20 adet yeni birey elde edilmiş olur. Daha sonra yukardaki işlem basamakları tekrarlanır.

Aşağıda Şekil 3.22. de kullanılan genetik algoritma akış diyagramı ve Şekil 3.23. de ise geliştirilen optimum entropi tabanlı özellik çıkarma yönteminin blok diyagramı verilmiştir.



Şekil 3.22. Kullanılan genetik algoritma akış diyagramı.




Şekil 3.23. Optimum entropi tabanlı özellik çıkarma yönteminin blok diyagramı.

3.4. Geliştirilen Resim Bölütleme Tabanlı Özellik Çıkarma Yöntemi

Geliştirilen bu özellik çıkarım yöntemi 5 aşamadan oluşmaktadır. Bu aşamaları şu şekilde maddeler halinde sıralayabiliriz:

1. Birinci aşamada Bölüm 2.2.4. de verilen Meksika şapkası dalgacık dönüşüm spektrogramı yöntemi kullanılarak her bir RHE işaretinin zaman frekans gösterim resimleri elde edilmiştir. Daha sonra bu renkli resimler gri seviye resimlerine dönüştürülmüştür. Bu resimlere örnekler, küçük metal plaka hedefi için Şekil 2.10. da ve silindirin alttan görünüşü hedefi için ise Şekil 2.11. de verilmiştir.
2. İkinci aşamada, Bölüm 2.3.3. de verilen bulanık C-ortalamlar ya da Bölüm 2.3.4. de verilen Kohonen yapay sinir ağları sınıflandırıcılarından biri kullanılarak, bu gri seviye ZFG resimlerinin 2 seviyeli bölütlenmesi yapılmıştır. Bu bölütlenmiş resimlere örnekler, küçük metal plaka hedefi için Şekil 3.24. de ve silindirin alttan görünüşü hedefi için ise Şekil 3.25. de verilmiştir.




Şekil 3.24. Küçük metal plaka hedefine ait 2 seviyeli bölütlenmiş ZFG resmi.



Şekil 3.25. Silindirin alttan görünüşü hedefine ait 2 seviyeli bölütlenmiş ZFG resmi.

3. Üçüncü aşamada, Bölüm 2.2.6. da verilen Canny kenar çıkarma algoritması kullanılarak, bu bölütlenmiş resimlerdeki nesnelerin kenarları belirlenmiştir. Bu belirlenmiş kenarların görüldüğü resimlere örnekler, küçük metal plaka hedefi için Şekil 3.26. da ve silindirin alttan görünüşü hedefi için ise Şekil 3.27. de verilmiştir.




Şekil 3.26. Küçük metal plaka hedefine ait ZFG resiminin belirlenmiş kenarları.




Şekil 3.27. Silindirin alttan görünüşü hedefine ait ZFG resiminin belirlenmiş kenarları.

4. Dördüncü aşamada, Bölüm 2.2.7. de verilen Merkez-Kenar Değişimi yöntemi kullanılarak bu resimlerin merkez piksellerinden, resimdeki nesnelerin kenarları üzerindeki her bir noktaya olan öklit uzaklıkları hesaplanarak, bu uzaklık değerlerinden bir uzaklık vektörü elde edilmiştir. Bu bulunan uzaklık vektörlerine örnekler, küçük metal plaka hedefi için Şekil 3.28. de ve silindirin alttan görünüşü hedefi için ise Şekil 3.29. da verilmiştir.

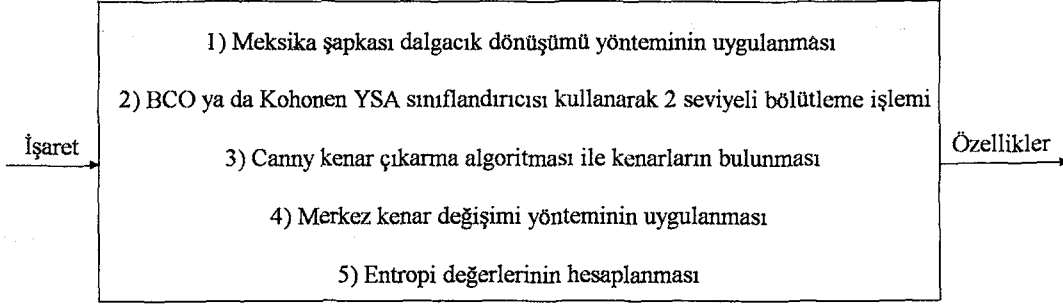


Şekil 3.28. Küçük metal plaka hedefine ait bulunan öklit uzaklık değer vektörü.



Şekil 3.29. Silindirin alttan görünüşü hedefine ait bulunan öklit uzaklık değer vektörü.

5. Beşinci aşamada ise bu uzaklık vektörlerinin her birinin sırasıyla Bölüm 2.2.2. de verilen Norm entropi, Sure entropi, Logaritmik enerji entropi ve Eşik entropi denklemleri kullanılarak, bu entropi değerleri hesaplanmıştır. Her bir ZFG resmi için hesaplanan bu entropi değerlerinin tamamı özellik vektörünü oluşturmaktadır. Bu özellik vektörü, daha sonra yapay sinir ağı sınıflandırıcısına verilerek sınıflandırma işlemi gerçekleştirilmiştir. Aşağıda Şekil 3.30. da bu geliştirilen resim bölütleme tabanlı özellik çıkarma yönteminin blok diyagramı görülmektedir.



Şekil 3.30. Geliştirilen resim bölütleme tabanlı özellik çıkarma yönteminin blok diyagramı.

4. SINIFLANDIRMA İÇİN KULLANILAN YÖNTEMLER


Tezin bu bölümünde, kaynaklar [132, 148, 166] da kullanılmış olan iki dalgacık sinir ağı ve bu tez çalışması kapsamında geliştirilen iki yeni dalgacık uyarlamalı ağ tabanlı bulanık çıkarım sistemi olmak üzere toplam dört farklı model kullanılmıştır. Bu modellerde, örüntü tanıma kilit rolü oynayan özellik çıkarımı, sınıflayıcının başarımına bağlı olarak adaptif bir şekilde ayarlanabilmektedir. Bu adaptif yapı, entropi hesaplama tekniğinin parametrelerine müdahale edilerek sağlanmıştır. Ayrıca kullanılan ve geliştirilen yapılarda, özellik çıkarım süreci YSA ve UATBÇS sınıflayıcılarının içerisine gömülmüştür. Bundan dolayı özellik çıkarım süreci doğrudan bu sınıflayıcıların eğitim performanslarını etkilemektedir. Radar hedef tanıma alanında ilk defa kullanılan ve geliştirilen bu yapılarda, entropiye dayalı özellik çıkarım tekniği ile giriş işaretinin boyutu indirgenerek sınıflayıcının işlem yükü azaltılmış ve gerçek zamanlı çıkış üretme başarımına katkıda bulunulmuştur.

4.1. Dalgacık Sinir Ağ Modelleri Kullanılarak Gerçekleştirilen Adaptif Özellik Çıkarma ve Sınıflama

Dalgacık sinir ağları (DSA), YSA' ların karar yapıları ile dalgacık dönüşümünün özellik çıkarma ve seçme yeteneklerini birleştirir [132, 148, 166]. Örüntü sınıflama için, dalgacık dönüşüm temelli olarak yapılandırılan dalgacık sinir ağları, ileri beslemeli YSA' lara alternatiflerdir. DSA, ileri beslemeli YSA'nın özel bir türü olarak ta yorumlanmaktadır [132].

DSA'nın çeşitli alanlarda uygulamaları bulunmaktadır. Bunlardan bazıları; kronik arter hastalıklarını sınıflama, protez kalp kapaklarının karakteristik durumlarını belirleme, biyo-ışaretleri sınıflama, Radar hedef sınıflama ve zaman serilerinin tahmini [132, 148, 166] gibi.

Dalgacık dönüşüm temelli olan DSA' ların yapısı Şekil 4.1. de verilmiştir [132, 148, 166]. Bu YSA yapısının çıkış Denklemi 4.1.de tanımlanmıştır.




Şekil 4.1. Dalgacık sinir ağı yapısı.

$$y = F\left(\sum_{k=1}^m w_k \cdot \sum_{t=1}^n x(t) \cdot \Psi\left(\frac{t-t_k}{2^k}\right)\right) \quad (4.1)$$

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 yayılım türü bir algoritma ile ayarlanır [132, 148]. 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.

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

Bu bölümde radar hedef tanıma işlemine uygulanan ve kaynak [132, 148] çalışmalarında geliştirilen Dalgacık Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama üzerine kurulu Dalgacık Sinir Ağı (DSA) modeli Şekil 4.2. de görülmektedir.




Şekil 4.2. Örüntü tanımak için kullanılan DSA yapısı.

Bu modelin eğitim algoritması ve işleyişi söz konusu kaynakta bulunabilir.

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

Bu bölümde radar hedef tanıma işlemine uygulanan ve kaynak [132, 166] çalışmalarında geliştirilen Dalgacık Paket Dönüşüm Sinir Ağı ile Adaptif Özellik Çıkarma ve Sınıflama üzerine kurulu Dalgacık Paket Sinir Ağı (DPSA) modeli Şekil 4.3. de görülmektedir.




Şekil 4.3. Örüntü tanımak için kullanılan DPSA yapısı.

Bu modelin eğitim algoritması ve işleyişi söz konusu kaynakta bulunabilir.

Radar hedef tanıma alanında kullanılan bu dalgacık sinir ağı modellerinin, örüntü tanıma uygulamalarındaki başarımları Bölüm 6. da verilmiştir.

4.2. Geliştirilen Dalgacık Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi İle Adaptif Özellik Çıkarma ve Sınıflama

Günümüzde Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri örüntü tanıma ve sınıflama, fonksiyon yaklaştırma, optimizasyon ve veri sınıflandırma problemlerinde oldukça yaygın olarak kullanılmaktadır. Temel yapısı Bölüm 2.4.2’de belirtilen Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UATBÇS)’nin yapısında hem yapay sinir ağları hem de bulanık mantık kullanılmaktadır. Dalgacık Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (DUATBÇS) ise, UATBÇS’lerin karar yapıları ile dalgacık dönüşümünün özellik çıkarma ve seçme yeteneklerini birleştirir [168]. Örüntü sınıflama için, dalgacık dönüşüm temelli olarak yapılandırılan Dalgacık Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri, UATBÇS’lere alternatiftir. DUATBÇS yapısı, UATBÇS’nin özel bir türü olarak ta yorumlanmaktadır [169]. Dalgacık dönüşüm temelli olan UATBÇS’lerin yapısı Şekil 4.4. de verilmiştir. Bu UATBÇS yapısının çıkış Denklemi 4.2.de tanımlanmıştır [170].




Şekil 4.4. Dalgacık uyarlamalı ağ tabanlı bulanık çıkarım sistemi yapısı.

$$y(x) = \frac{\sum_i w_i f_i(\psi[D_i(x - t_i)])}{\sum_i w_i} \quad (4.2)$$

Burada w_i 'ler, DUATBÇS kurallarının kesinlik dereceleri, D_i ölçekleme vektörü, t_i 'ler dönüşüm vektörleri ve f_i 'ler UATBÇS'nin Sugeno çıkış fonksiyonlarıdır. DUATBÇS'nin yapısında giriş ve çıkış parametrelerin ayarlanması için geriye yayılım öğrenme kuralı ve en küçük kareler yöntemlerinin birleşmesinden oluşan bir melez algoritma kullanılmıştır [169]. Literatürde DUATBÇS, tıp alanında hastaların elektro kardiyolojik durum değişikliklerinin belirlenmesinde [171], uydu resimlerinin birleştirilmesinde [172] kullanılmıştır ancak bu zamana kadar DUATBÇS yapısı radar otomatik hedef tanıma alanında kullanılmamıştır.

4.2.1. Dalgacık Dönüşüm Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi ile Adaptif Özellik Çıkarma ve Sınıflama

Örüntü tanımak için geliştirilen, yeni Dalgacık Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (DUATBÇS) modeli Şekil 4.5. de görülmektedir. Bu model, dalgacık dönüşüm, entropi hesaplama ve uyarlamalı ağ tabanlı bulanık çıkarım sistemi tabanlıdır.




Şekil 4.5. Örüntü tanımak için geliştirilen DUATBÇS yapısı.

Geliştirilen yeni DUATBÇS modelinin eğitim algoritmasının akış şeması Şekil 4.6. da verilmiştir. Bu algoritmanın her bir aşamasının işleyişi aşağıda adımlar halinde sunulmuştur:

1. adım : Dalgacık ayrışım seviyesi (m), Denklem 3.2. de belirtilen kritere göre seçilir.
2. 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.
3. adım : Dalgacık filtreleri ψ , ayrışım seviyelerine göre ayarlanarak dalgacık dönüşüm katsayı işaretleri (cD , cA) elde edilir.
4. 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 uyarlamalı ağ tabanlı bulanık çıkarım sisteminin 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, uyarlamalı ağ tabanlı bulanık çıkarım sistemi kısmında bulunan parametreler hata geri yayılım öğrenme kuralına [169] göre ayarlanır.
- 8. adım :** DUATBCS' nin 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 ayarlanır.






Şekil 4. 6. DUATBÇS eğitim algoritması.

4.2.2. Dalgacık Paket Dönüşüm Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi ile Adaptif Özellik Çıkarma ve Sınıflama

Örüntü tanımak için dördüncü bir model olarak geliştirilen, yeni Dalgacık Paket Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (DPUATBÇS) yapısı Şekil 4.7. de görülmektedir. Bu yapıda da görüleceği üzere, örüntü tanımada anahtar görevi üstlenen özellik çıkarım süreci, sınıflayıcının başarımına bağlı olarak adaptif bir şekilde ayarlanabilmektedir.




Şekil 4.7. Örüntü tanımak için geliştirilen DPUATBÇS yapısı.

Geliştirilen yeni DPUATBÇS modelinin eğitim algoritmasının akış şeması Şekil 4.8. de verilmiştir. Bu algoritmanın her bir aşamasının işleyişi aşağıda adımlar halinde sunulmuştur:

1. adım : Dalgacık paket ayrışım seviyesi (m), Denklem 3.2. de belirtilen kritere göre seçilir.
2. 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.
3. adım : Dalgacık paket filtreleri ψ , en son ayrışım seviyesine göre ayarlanarak uç yaprak dalgacık paket dönüşüm katsayı işaretleri (cD, cA) elde edilir.
4. adım : Bölüm 2.3.2.de verilen entropi yöntemleri ile dalgacık dönüşüm katsayı işaretlerinin entropi değerleri, entropi parametresine (ϵ) bağlı olarak hesaplanır.
5. adım : Elde edilen entropi değerleri $E = [Ed_1, Ea_1, Ed_2, Ea_2, \dots, Ed_{2^{m-1}}, Ea_{2^{m-1}}]$ ile uyarlamalı ağ tabanlı bulanık çıkarım sisteminin gerçek çıkışları (y) hesaplanır.
6. adım : Tüm giriş işaret örnekleri için E toplam karesel hata değeri bulunur. Bu değer istenen toplam karesel hatadan (sse) küçük değilse, uyarlamalı ağ tabanlı bulanık çıkarım sistemi bileşeninde bulunan giriş parametreleri hata geri yayılım öğrenme kuralına [169] göre ayarlanır.
7. adım : DPUATBÇS' nin 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 uyarlamalı ağ tabanlı bulanık çıkarım sistemlerinin örüntü tanıma uygulamalarındaki başarımlarını Bölüm 6. da verilmiştir.




Şekil 4.8. DPUATBÇS eğitim algoritması.

5. KULLANILAN ÖZELLİK ÇIKARIMI VE SINIFLANDIRMA YÖNTEMLERİNİN RADAR EKO İŞARETLERİNE UYGULANMASI

Bu bölümde, özellik çıkarımı ve sınıflandırma yöntemlerin Radar Hedef Eko (RHE) işaretlerine uygulanması işlemi gerçekleştirilmiştir. Söz konusu yöntemlerde kullanılan RHE işaretlerine, bir ön-işlem süreci geliştirilmiştir. Bu işlemler alt başlıklar altında bu bölümde sunulmaktadır.

5.1. Radar Hedef Eko İşaretleri


Radar Hedef Eko (RHE) işaretleri hedeften radara geri yansıyan işaretlerdir. RHE işaretlerine aynı zamanda hedef mesafe profili adı da verilmektedir. Literatürde Otomatik Hedef Tanıma (OHT) çalışmalarında RHE işaretlerinin kullanımına sıkça rastlanmaktadır [173]. Radar vericisinden hedefe doğru gönderilen bir darbeli radar işaretinin temsili gösterimi ve bu hedeften geri yansıyan RHE işaret örneği sırasıyla Şekil 5.1.a., Şekil 5.1.b. verilmiştir. Bu RHE işareti bir darbeli radar eko işaretidir.



T : Bir darbenin başlangıcı ile, bir sonraki darbenin başlangıcına kadar geçen süre. Değeri bu uygulama için 1/144 sn'dir.

fp : Darbe tekrarlama frekansıdır. Değeri bu uygulama için 144 Hz'dir.


(a)




(b)

Şekil 5.1.(a). Bir darbeli radar işareti, (b). Bir darbeli RHE işaret örneği.


Burada gerçekleştirilen uygulamalarda deney setinden elde edilen gerçek Radar Hedef Eko (RHE) işaretleri kullanılmıştır. Bu uygulama çalışmalarında, etkili özellik çıkarımı ve sınıflamayı gerçekleştirmek için Şekil 5.2. de verilen sekiz adet gerçek hedef nesnesi (küçük metal plaka, büyük metal plaka, büyük pleksiglas plaka, köşeli yansıtıcı, küre, silindirin yandan görünüşü, silindirin alttan görünüşü ve silindirin dikey görünüşü) kullanılmıştır. Hareketli hedefler için eko işareti örneği Şekil 1.3. de Küre hedefi için verilmiştir.




Küçük metal plaka




Büyük metal plaka




Pleksiglas plaka



Köşeli yansıtıcı



Küre



Silindir

Şekil 5.2. Kullanılan hedef nesneleri.

Deneyisel uygulama çalışmaları bu hedef nesneleri kullanılarak eğitim amaçlı ve çok fonksiyonlu 9620/21 Modelli Lab-Volt Radar Deney Seti üzerinde gerçekleştirilmiştir. RHE işaretleri bilgisayar ortamına 48 KHz'lik örnekleme frekansına sahip bir ses kartı kullanılarak alınmıştır. Alınan RHE işaretlerinden biri Şekil 5.1. de verilmiştir. Kullanılan bu deney setinin fotoğrafları EK-5 ve EK-6' da verilmiştir.


5.2. Veri Alımı

Orijinal RHE işaretleri, Fırat Üniversitesi Teknik Eğitim Fakültesi Elektronik Bilgisayar Eğitimi bünyesinde bulunan radar deney setinden alınmıştır. 5 mWatt'lık çıkış gücüne sahip cihazın darbeli radar hedef eko işaret çıkışından RHE işaretleri MATLAB ortamında (ver. 5.3, The MathWorks Inc.) geliştirdiğimiz bir yazılımla, 750 örnek için, SNR = 0 dB kazançlı ve 48 kHz 'lik örnekleme frekansına sahip olan bir ses kartı (EK-4) üzerinden bilgisayara sayısal biçimde alınmıştır. Kullanılan radar deney setinin (EK-1, EK-2, EK-3) çalışma şekli aşağıdaki biçimde ayarlanmıştır:


- Darbe Genişliği: 2 ns
- RF Osilatör Frekansı: 9.4 GHz
- Darbe Tekrarlama Frekansı (DTF): 144 Hz
- Radar Alıcı Anteni ile Hedef Tablası Arasındaki Mesafe (RA-HM): 135 cm.

Tablo 5.1. ve Tablo 5.2. de sırasıyla radar deney setinden alınan sabit ve hareketli RHE işaretlerinin hedeflere göre dağılımı verilmiştir. Bu deney setinden veri alımı Şekil 5.4. de radar deney seti blok diyagramı üzerinde gösterilmiştir. Buradan da görüldüğü gibi, radar verici anteninden gönderilen radar işaretleri hedef tablası üzerindeki hedefe çarparak geri yansır, bu yansıyan RHE işaretleri radar verici anteni tarafından alınır, radar alıcısı yolu ile I ve Q kanallarından oluşan çift kanallı örnekleyiciye gönderilir. Bu RHE işareti çift kanallı örnekleyici devre içerisinde yapılan işlemlerle daha düşük frekanslı (0.05 - 2.5 kHz) RHE işaretlerine dönüştürülür ve dışarıya verilir. Bu frekans düşürme işlemine zamana yayma adı da verilir.

Bu deneysel çalışmada, her bir hedef nesneye ait hareketli ve sabit RHE işaretleri alınmıştır. Sabit RHE işaretleri, radar alıcı anteni ile hedef tablası arasındaki mesafenin çeşitli değerlerinde (90 cm, 135 cm ve 180 cm), hareketli RHE işaretleri ise sabit (5 ve 10 cm/sn) ve değişken hızlı (5-15 cm/sn) olarak alınmıştır. Ayrıca hedef tanıma işleminin başarımını değerlendirmek amacıyla test aşamasında kullanmak üzere radar deney setinin gürültü oluşturma modülü kullanılarak her bir hedefe ait sırasıyla -2 dB, -3 dB, ve -5 dB'lik RHE işaretleri de yukarıda bahsedilen deney düzeneği kullanılarak alınmıştır. Şekil 5.3. de büyük metal plaka hedefi için 5-15 cm/sn değişken hızı için elde edilen eko işareti verilmiştir.



Şekil 5.3. Hareketli büyük metal plaka hedefine ait eko işareti



Şekil 5.4. Veri alımında kullanılan radar deney setinin blok diyagramı.

Tablo 5.1. Radar deney setinden alınan sabit RHE işaretlerinin hedeflere göre dağılımı.

		Deney Setinden Alınan RHE İşaretlerinin Hedef Türlerine Göre Sayıları					
		Gürültüsüz Durum İçin (İşaret /Gürültü Oranı (İ/G) = 0 dB için)			Gürültülü Durum İçin (İşaret /Gürültü Oranı (İ/G) = -2 dB, -3 dB, ve -5 dB için)		
		RA-HM: 90 cm	RA-HM: 135 cm	RA-HM: 180 cm	RA-HM: 90 cm	RA-HM: 135 cm	RA-HM: 180 cm
Kullanılan Hedef Türleri	Küçük Metal Plaka	1 Adet	1 Adet	1 Adet	3 Adet	3 Adet	3 Adet
	Büyük Metal Plaka	1 Adet	1 Adet	1 Adet	3 Adet	3 Adet	3 Adet
	Pleksiglas Plaka	1 Adet	1 Adet	1 Adet	3 Adet	3 Adet	3 Adet
	Köşeli Yansıtıcı	1 Adet	1 Adet	1 Adet	3 Adet	3 Adet	3 Adet
	Küre	1 Adet	1 Adet	1 Adet	3 Adet	3 Adet	3 Adet
	Silindirin Yandan Görünüşü	1 Adet	1 Adet	1 Adet	3 Adet	3 Adet	3 Adet
	Silindirin Alttan Görünüşü	1 Adet	1 Adet	1 Adet	3 Adet	3 Adet	3 Adet
	Silindirin Dikey Görünüşü	1 Adet	1 Adet	1 Adet	3 Adet	3 Adet	3 Adet

Tablo 5.2. Radar deney setinden alınan hareketli RHE işaretlerinin hedeflere göre dağılımı.

		Deney Setinden Alınan RHE İşaretlerinin Hedef Türlerine Göre Sayıları			
		Gürültüsüz Durum İçin (İşaret /Gürültü Oranı (İ/G) = 0 dB için)		Gürültülü Durum İçin (İşaret /Gürültü Oranı (İ/G) = -2 dB, -3 dB, ve -5 dB için)	
		Sabit Hızlı Hareket	Değişken Hızlı Hareket	Sabit Hızlı Hareket	Değişken Hızlı Hareket
Kullanılan Hedef Türleri	Küçük Metal Plaka	2 Adet	1 Adet	6 Adet	3 Adet
	Büyük Metal Plaka	2 Adet	1 Adet	6 Adet	3 Adet
	Pleksiglas Plaka	2 Adet	1 Adet	6 Adet	3 Adet
	Köşeli Yansıtıcı	2 Adet	1 Adet	6 Adet	3 Adet
	Küre	2 Adet	1 Adet	6 Adet	3 Adet
	Silindirin Yandan Görünüşü	2 Adet	1 Adet	6 Adet	3 Adet
	Silindirin Alttan Görünüşü	2 Adet	1 Adet	6 Adet	3 Adet
	Silindirin Dikey Görünüşü	2 Adet	1 Adet	6 Adet	3 Adet

5.2.1. İki Kanallı Örnekleyicinin Çalışma Prensibi

Darbeli radarlar sabit hızda, kısa patlamalar halinde Radio Frekans (RF) işareti iletirler. Bu patlamaların devam süresi kısaldıkça, darbeli radarın mesafe çözünürlüğü artar. Bu tez

çalışmasında kullanılan radar deney seti en fazla 7.2 m'lik bir mesafe üzerinde çalıştığı için, RF işaret patlamalarının devam süresi, yeterli mesafe çözünürlüğünü elde etmek amacıyla 1 ns düzeyinde olmalıdır.


RF işaret patlamaları anten tarafından alındıktan sonra, alıcıda kalıplarının çıkarılması için demodüle edilir. Sonuç olarak alıcı çıkışında tekrarlanan darbe işareti üretilir. Böyle bir darbe işareti oldukça geniş bant genişliğine sahiptir. Bundan dolayı, darbe işaretinin işlenmesinde görev alan devrenin bant genişliği de oldukça büyük olmalıdır. Bir darbe işaretini işlemek için gerekli yaklaşık bant genişliği B, bu işaretin darbe genişliğinin tersine eşittir. Bu aşağıdaki Denklem 5.1. ile açıklanır.

$$B = \frac{1}{\tau} \quad (5.1)$$

Burada τ , işaretin darbe genişliğidir. Radar alıcısının I ve Q kanallarından gelen darbe işaretlerini işlemek için gereken devrenin bant genişliği, yaklaşık olarak 1 GHz olmalıdır. Böyle bir devre oldukça karmaşık ve pahalıdır. Radar deney setinde, bu problem radar alıcısının I ve Q kanallarından gelen darbe işaretlerini zamanla yayarak (stretching) engellenmiştir. Tekrarlayan darbe işaretleri, birbirini izleyen devirlerin farklı noktalarından örnekler almak ve bu örnek değerleri bir sonraki değer alınana kadar saklamak sureti ile yayılabilir.

Bu şekilde iki kanallı örnekleme devresi içerisinde eko işaretinin frekans değeri küçültülür. Darbeli işaretlerin darbe genişliğinin artırılması ile gerçekleştirilen zamanla yayma işlemi bu işaretin bant genişliğinin azalmasına sebep olur. Bu işlem, örnekleme osilaskoplarında kullanılanların benzeridir ve radar deney setinin iki kanallı örnekleyicisinde kullanılır.

İki kanallı örnekleyicideki zamanla yayma devresinin basitleştirilmiş bir blok diyagramı Şekil 5.5. de gösterilmiştir. Radar alıcısının I ve Q kanallarından darbe işaretleri, I ve Q-kanal Darbe Girişlerine verilir.



Şekil 5.5. İki kanallı örnekleyicinin blok diyagramı.

Rampa işareti üretici, merdiven işareti üretici, karşılaştırıcı ve tetikleyici giriş işaretlerine göre, örneklemenin meydana geleceği anı belirler. O anda, karşılaştırıcı, darbe üreticini tetikler ve bu da her bir kanalın örnekleme kapısının bu ana karşılık gelen darbe giriş işaretinin bir örneğini almasını sağlar.

Örnekleme periyodu, darbe giriş işaretlerinin 1024 eşit aralıklı örneği alınana kadar devam eder. O anda, merdiven işareti üretici, DTF tetikleme girişi ile sıfırlanır. Bu durum, darbe giriş işaret periyodunun uygun noktasında örneklemenin tekrar başlamasını sağlar.

Kısaca burada kullanılan radar deney seti oldukça kısa mesafeler üzerinde çalıştığı için, iletilen RF işaret patlamalarının radara geri dönmesi sadece birkaç nanosaniye alır. İki kanallı örnekleyici, radar alıcısının I ve Q kanallarından gelen darbe işaretlerinin sadece küçük bir bölümünü örnekler. Bu darbeli işaretlerin örneklenen bölümlerinin devam süresi ve pozisyonu, iki kanallı örnekleyicinin sırasıyla Range Span ve Origin kontrolleri kullanılarak ayarlanır.

5.3. Ön-işlem Süreci

Kaynak [132] çalışmasında, geliştirilen ön-işlem süreci kullanılarak saf RHE işaretlerine uygulaması yapılmış, böylece tanılama sisteminin hız ve doğru sınıflama başarımını etkileyecek bazı istenilmeyen ve gereksiz bilgilerin ayıklanması sağlanmıştır. Söz konusu bu ön işlem sürecinin ayrıntıları ilgili kaynakta bulunmakla birlikte RHE işaretleri için uygulama aşamaları aşağıdaki alt bölümlerde sunulmuştur.

5.3.1. Filtreleme

RHE işaretlerinin 0.06-2.5 kHz aralığında olduğu daha önceden belirtilmişti. 6 kHz de örneklenen saf RHE işaretlerinin içerisinde 0.06-2.5 kHz dışındaki istenilmeyen frekans bileşenlerini yok etmek için sayısal bir FIR filtre kullanılmıştır. FIR filtre 0.06 kHz merkez frekanslı bir yüksek geçiren filtre olup, filtrenin derecesi, keskin bir filtre karakteristiği için $N = 30$ olarak seçilmiştir. Böylece şebeke frekansından kaynaklanan gürültüde elimine edilmiştir.

Denklem 5.2. de FIR filtrenin transfer fonksiyonu verilmiştir.

$$H(z) = \sum_{n=0}^N h[n].z^{-n} \quad (5.2)$$

Bu uygulamada pencereci FIR filtre kullanım gerekliliği ile, $w[n]$ pencere fonksiyonu olup, sayısal FIR filtrenin katsayıları:

$$h[n] = w[n].h[n] \quad (5.3)$$

Burada kullanılan pencere fonksiyonu Hamming olup, aşağıdaki gibi tanımlanmıştır:

$$w[k] = 0.54 - 0.46 \cdot \cos\left(2\pi \frac{k}{n-1}\right), \quad k = 0, \dots, n-1 \quad (5.4)$$

$$w[n] = \begin{cases} w[k] & 0 \leq n \leq N-1 \\ 0 & \text{diğer} \end{cases} \quad (5.5)$$

5.3.2. Beyaz Gürültü Ayırışımı

Beyaz gürültü rast gele bir işaret olup, Fourier dönüşümü düz bir spektrumdur [132]. RHE işaretleri DPA kullanılarak beyaz gürültüden ayrıştırılmıştır. Bunun için [132] de önerilen üç adımdan oluşmuş bir yordam tatbik edilmiştir:

1. Dalgacık paket ayrışımı: Daubechies-4 dalgacık filtreleri kullanılarak Bölüm 3.2. de ve Denklem 3.2. de gösterildiği gibi maksimum $m = 5$ seviyede dalgacık dönüşüm ayrışımı yapılmıştır. Her bir ayrışım seviyesi için detay katsayıları $cd = [cd_1, cd_2, \dots, cd_5]$ ve 1 adet son seviye için yaklaşık katsayı cd_5 elde edilmiştir.
2. Detay katsayılarını eşikleme: Her bir seviyenin sadece detay katsayısı Denklem 5.6. daki eşik değeri ile eşiklenmiştir. Böylece simetrik bir biçimde olmak üzere, eşik değerinin altındaki küçük genlik değerler yok edilerek, her bir katsayıdaki gürültü bileşeni atılmıştır [132].

$$T = \sqrt{2 \cdot \log(n)} \quad (5.6)$$

$$s[n] = \begin{cases} |s[n]| - T & |s[n]| > T \\ 0 & |s[n]| \leq T \end{cases} \quad (5.7)$$

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

3. İşareti yeniden yapılandırma: Dalgacık ayrışımının detay ve yaklaşık katsayıları Denklem 5.8. deki gibi analitik olarak toplanıp RHE işareti beyaz gürültüden ayrıştırılmış bir biçimde tekrar yeniden elde edilmiştir.

$$RHE = cA_m + \sum_{j=1}^m cd_j \quad (5.8)$$

5.3.3. Normalizasyon

RHE işaretleri Denklem 5.9. kullanılarak normalize edilmiştir. Böylece, işaretin genliğinin laboratuvar ortamındaki çeşitli gürültülerden etkilenmesi ihmal edilecek seviyeye çekilmiştir.

$$RHE = \frac{RHE}{|(RHE[n])|_{\text{maksimum}}} \quad (5.9)$$

5.4. Kullanılan Özellik Çıkarma Algoritmalarının Uygulaması

Bölüm 3. ve 4. de kullanılan ve geliştirilen özellik çıkarım ve sınıflandırma yöntemlerinin RHE işaret örüntüleri üzerinde uygulaması aşağıdaki ilgili yöntemlere ait alt bölümlerde verilmiştir.


5.4.1. Dalgacık Dönüşüm Ağacından Entropi Hesaplanması

Bölüm 3. de belirtilen ve [132] çalışmasındaki geliştirilen bu yöntemin, burada RHE işaretleri üzerine uygulaması yapılmıştır. Şekil 5.6. da büyük metal plaka radar hedefine ait bir RHE işaretinin Daubechies – 4 dalgacıkları ile maksimum seviyede $m = 5$ (Denklem 3.2.), dalgacık ayrışımı görülmektedir.

Bu dalgacık katsayı işaretlerinin her birinin Denklem 5.10. da gösterildiği gibi Norm entropi değerleri hesaplanıp 1/1000 ile normalize edilmiştir. Bu yöntemden kısaca DD-EH şeklinde söz edilecektir.

$$E_i = \sum_n |C_i[n]|^{3/2} \quad (5.10)$$

Burada, E_i Norm entropi değeri ve C_i katsayı işaretleridir.




Şekil 5.6. Bir RHE işaretinin dalgacık dönüşüm ağacında bulunan işaretleri.

5.4.2. Dalgacık Paket Dönüşüm Ağacından Entropi Hesaplanması

Bölüm 3. de belirtilen ve [132] çalışmasındaki geliştirilen bu yöntemin, burada RHE işaretleri üzerine uygulaması yapılmıştır. Şekil 5.7. de kullanılan pleksiglas plaka hedefine ait bir RHE işaretinin, Daubechies – 4 dalgacık paketi kullanılarak ve $m = 5$ seviyede, dalgacık paket ayrışımının uç yaprak katsayı işaretleri görülmektedir. $2^m = 32$ adet uç katsayı işareti elde edilmiştir. Bu yöntemden kısaca DPD-EH şeklinde söz edilecektir.

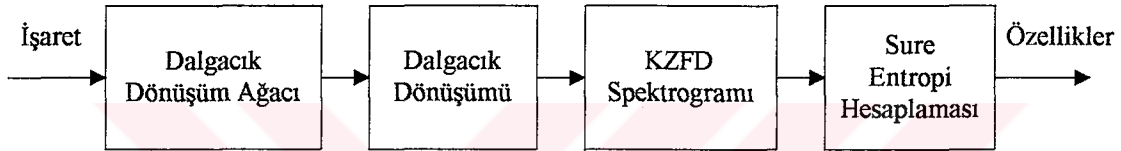
Bu tez çalışmasında dalgacık ve dalgacık paket dönüşümlerinin kullanılmasındaki en önemli nedenler, hareketli ve sabit RHE işaretlerinden daha dayanıklı özellikler çıkarmak ve hareketli hedeflerin RHE işaretlerindeki zaman kayması etkisini azaltmak olarak gösterilebilir. Hareketli hedeflerin tanınması son yıllarda büyük önem kazanan bir konu haline gelmiştir. Bundan dolayı hareketli RHE işaretlerinin zaman kayması problemini çözmek için birçok çalışma yapılmaktadır. Bunlardan biri de [46]'da verilmiştir. Bu kaynaktaki çalışmada yukarda bahsedilen hareketli hedeflerin zaman kayması dezavantajını giderebilmek için RHE işaretleri için dalgacık dönüşümü kullanılarak özellik çıkarımına gidilmiştir. Entropi ise dalgacık özellik çıkarımında özellik vektörünün boyutunu küçültmek için kullanılmıştır.



Şekil 5.7. Bir RHE işaretinin dalgacık paket dönüşüm ağacının uç yaprak işaretleri

5.4.3. Dalgacık Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması


Bölüm 3. de belirtilen ve [132] çalışmasındaki geliştirilen bu yöntemin, burada RHE işaretleri üzerine uygulaması yapılmıştır. Buna göre her bir dalgacık katsayı işaretinin ilk önce KZFD spektrogramı hesaplanmıştır. Daha sonra hesaplanan bu spektrogramların Sure entropi çıkarım denklemi kullanılarak entropi değerleri hesaplanmış ve bu hesaplanan değerler YSA sınıflandırıcısına giriş olarak verilmiştir. Buna göre bir RHE işaretinin 6 adet katsayı işareti olduğundan, 6 adette spektrograma sahiptir. Dolayısıyla özellik çıkarmak için kullanılan ZFG bileşen sayısı 8 adet RHE sinyali için $6 \times 8 = 48$ 'dir. Dolayısıyla özellik çıkarmak için kullanılan ZFG bileşen sayısı : $6 \times 8 = 48$ 'dir. Burada Sure entropi ε eşik parametresi 2 olarak alınmıştır. Ayrıca elde edilen Sure entropi değerleri 1/50 ile normalize edilmiştir. Bu yöntemden ilerdeki bölümlerde kısaca DD-KZFD-EH yöntemi olarak bahsedilecektir.



Şekil 5.8. Dalgacık dönüşümü ve KZFD spektrogramı ZFG Sure entropileri ile özellik çıkarımı.

5.4.4. Dalgacık Paket Dönüşümü ve KZFD Spektrogramı ile Entropi Hesaplanması

Bölüm 3. de belirtilen ve [132] çalışmasındaki geliştirilen bu yöntemin, burada RHE işaretleri üzerine uygulaması yapılmıştır. Buna göre her bir dalgacık paket katsayı işaretinin ilk önce KZFD spektrogramı hesaplanmıştır. Daha sonra hesaplanan bu spektrogramların Eşik entropi çıkarım denklemi kullanılarak entropi değerleri hesaplanmış ve bu hesaplanan değerler YSA sınıflandırıcısına giriş olarak verilmiştir. Buna göre bir RHE işaretinin $2^5 = 32$ adet katsayı işareti olduğundan 32 adette spektrograma sahiptir. Dolayısıyla özellik çıkarmak için kullanılan ZFG bileşen sayısı 8 adet RHE sinyali için $32 \times 8 = 256$ 'dır. Burada Eşik entropi ε eşik parametresi 2 olarak alınmıştır. Ayrıca elde edilen Eşik entropi parametreleri 1/50 ile normalize edilmiştir. Bu yöntemden ilerdeki bölümlerde kısaca DPD-KZFD-EH yöntemi olarak bahsedilecektir.



Şekil 5.9. Dalgacık paket dönüşümü ve KZFD spektrogramı ZFG Eşik entropileri ile özellik çıkarımı


5.5. Yapay Sinir Ağlarının Sınıflandırıcı Olarak Kullanımı

Bölüm 2.3.1. de yapay sinir ağlarının sınıflandırıcı olarak kullanımı hakkında detaylı bilgi verildiği için burada sadece bu tez çalışmasında kullanılan eğitici YSA öğrenme algoritmalarından Geriye Yayınım öğrenme algoritması hakkında bilgi verilecektir.

5.5.1. Geriye Yayınım Yapay Sinir Ağları

Geriye yayınım 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 5.10. da çok katmanlı algılayıcı yapay sinir ağının genel yapısı verilmiştir [152], [161].

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 [8]. Yapay sinir ağının girişindeki veriler, ağırlıklar uygun noktaya ulaşana kadar değişmez. Hesaplanan çıkış cevapları, istenen cevaplarla karşılaştırılarak, sonuçta hata işareti elde edilir [152]. 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 hatanın geriye yayılma algoritması denir. Denklem 5.11. de bu algoritmanın öğrenme sürecinde kullanılan matematiksel yapı verilmiştir.



Şekil 5.10. Çok katmanlı ileri beslemeli yapay sinir ağı.

$$w_{ij}(t+1) = w_{ij}(t) + \varepsilon \cdot h_j \cdot y_i + \alpha (w_{ij}(t) - w_{ij}(t-1)) \quad (5.11)$$


Burada, öğrenme oranı $0 < \alpha < 1$ ve momentum katsayısı $0.001 < \varepsilon < 10$ dur. 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/çıkış ikilisinden oluşan örnekler sunulur. Bu ikili, ağın öğrenmesi gereken özellikleri temsil eder. Bu algoritmanın detayları [132], [152] de bulunabilir.

Uygulama için, MATLAB ortamında programlar geliştirilmiştir. DD-KZFD-EH özellik çıkarım yöntemi için kullanılan ileri beslemeli çok katmanlı YSA'nın eğitim parametreleri ve yapısı Tablo 5.3. 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 5.11. de ise bu yöntem ile elde edilen özellikler ile kullanılan YSA'nın eğitim başarımı görülmektedir.

Tablo 5.3. Geliştirilen DD-KZFD-EH özellik çıkarım yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri.


YSA yapısı	
YSA modeli	Çok katmanlı ileri beslemeli
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş : 6 Gizli : 25 Çıkış : 8
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 : 0.0001 Artış katsayısı : 1.05 Azalış katsayısı : 0.7
Momentum sabiti	0.98
Toplam karesel hata	0.0000001



Şekil 5.11. DD-KZFD-EH özellik çıkarım yöntemi için kullanılan YSA modelinin eğitim başarımı.

Tablo 5.4. Geliştirilen DPD-KZFD-EH özellik çıkarım yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri.


YSA yapısı	
YSA modeli	Çok katmanlı ileri beslemeli
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş : 32 Gizli : 50 Çıkış : 8
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 : 0.0001 Artış katsayısı : 1.05 Azalış katsayısı : 0.7
Momentum sabiti	0.98
Toplam karesel hata	0.00000001



Şekil 5.12. DPD-KZFD-EH özellik çıkarım yöntemi için kullanılan YSA modelinin eğitim başarıımı.

5.6. Adaptif Radar Hedef Tanıma Yöntemlerinin Uygulaması

Bölüm 4. de, adaptif özellik çıkarma ve sınıflama için kullanılan dalgacık sinir ağı ve geliştirilen yeni dalgacık uyarlamalı ağı tabanlı bulanık çıkarım modellerinin RHE işaret örüntüleri üzerinde uygulaması yapılmıştır. Şekil 5.13. de akıllı örüntü tanıma sisteminin yapısı bu doğrultuda verilmiştir.



Şekil 5.13. Kullanılan adaptif yöntemleri RHE işaretlerine uygulama sistemi.

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

Bölüm 4.1.1. de bahsedilen dalgacık dönüşüm sinir ağı ile adaptif özellik çıkarma ve sınıflama temelli DSA modelinin yapısı ve eğitim parametreleri Tablo 5.5. de ve RHE işaretlerine uygulama sonuçları ise Tablo 5.6. da verilmiştir.

Tablo 5.5. DSA modelinin yapısı ve eğitim parametreleri.

DSA Modelinin Yapısı		
Dalgacık filtre türü		Daubechies – 4
Dalgacık ayrışım seviyesi		5
Entropi	Türü	Norm
	Parametre başlangıç	1.0
	Parametre bitiş	2.0
	Parametre değişim	0.1
Katman sayısı		3
Katmanlardaki nöron sayısı		Giriş : 6 Gizli : 15 Çıkış : 8
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)		0.0000001

Tablo 5.6. DSA modelinin hareketli RHE işaret örüntülerini tanıma başarımları.

	Küçük Metal Plaka	Büyük Metal Plaka	Pleksiglas Plaka	Köşeli Yansıtıcı	Küre	Silindirin Yandan Görünüşü	Silindirin Altıtan Görünüşü	Silindirin Dikey Görünüşü
Toplam Örnek Sayısı	9	9	9	9	9	9	9	9
Doğru Sınıflandırma Sayısı	9	9	8	7	9	8	7	8
Yanlış Sınıflandırma Sayısı	-	-	1	2	-	1	2	1
Tanıma Yüzdesi (%)	100	100	88.8	77.7	100	100	77.7	88.8

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

Bölüm 4.1.2. de bahsedilen dalgacık paket dönüşüm sinir ağı ile adaptif özellik çıkarma ve sınıflama temelli DPSA modelinin yapısı ve eğitim parametreleri Tablo 5.7. de ve RHE işaretlerine uygulama sonuçları ise Tablo 5.8. de verilmiştir.

Tablo 5.7. DPSA modelinin yapısı ve eğitim parametreleri.

DPSA Modelinin Yapısı	
Dalgacık paket filtre türü	
Daubechies - 4	
Dalgacık paket ayrışım seviyesi	
5	
Entropi	Türü
	Sure
	Parametre başlangıç
	2
Parametre bitiş	
3	
Parametre değişim	
0.1	
Katman sayısı	
3	
Katmanlardaki nöron sayısı	
Giriş : 32	
Gizli : 50	
Çıkış : 8	
Başlangıç ağırlıkları ve eşik değerleri	
Nguyen-Widrow metodu ile hesaplandı	
Etkinleştirme fonksiyonları	
Logaritmik sigmoid	
Eğitim Parametreleri	
Öğrenme kuralı	
Geri yayılım	
Başlangıç : 0.0001	
Adaptif öğrenme oranı parametreleri	
Artış katsayısı : 1.05	
Azalış katsayısı: 0.7	
Momentum katsayısı	
0.98	
Toplam karesel hata (sse)	
0.000000001	

Tablo 5.8. DPSA modelinin hareketli RHE işaret örüntülerini tanıma başarımı.

	Küçük Metal Plaka	Büyük Metal Plaka	Pleksiglas Plaka	Köşeli Yansıtıcı	Küre	Silindirin Yandan Görünüşü	Silindirin Alttan Görünüşü	Silindirin Dikey Görünüşü
Toplam Örnek Sayısı	9	9	9	9	9	9	9	9
Doğru Sınıflandırma Sayısı	8	9	8	7	9	8	8	9
Yanlış Sınıflandırma Sayısı	1	-	1	2	-	1	1	-
Tanıma Yüzdesi (%)	88.8	100	88.8	77.7	100	100	88.8	100

5.6.3. Dalgacık Dönüşüm Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi İle Adaptif Özellik Çıkarma ve Sınıflama

Bölüm 4.2.1. de bahsedilen dalgacık uyarlamalı ağ tabanlı bulanık çıkarım sistemi ile adaptif özellik çıkarma ve sınıflama temelli olarak geliştirilen yeni DUATBÇS modelinin yapısı ve eğitim parametreleri Tablo 5.9. da ve RHE işaretlerine uygulama sonuçları ise Tablo 5.10. da verilmiştir.

Tablo 5.9. DUATBÇS modelinin yapısı ve eğitim parametreleri.

DUATBÇS Modelinin Yapısı		
Dalgacık paket filtre türü		Daubechies - 4
Dalgacık paket ayrışım seviyesi		5
Entropi	Türü	Norm
	Parametre başlangıç	2
	Parametre bitiş	3
	Parametre değişim	0.1
Katman sayısı		5
Katmanlardaki nöron sayısı		Giriş : 6 Kural sayısı : 64 Çıkış : 8
Başlangıç ağırlıkları ve eşik değerleri		Nguyen-Widrow metodu ile hesaplandı
Etkinleştirme fonksiyonları		Logaritmik sigmoid
Eğitim Parametreleri		
Öğrenme kuralı		Melez Öğrenme Algoritması (Doğrusal olmayan giriş parametreleri için Geri yayılım ve doğrusal çıkış parametreleri için En küçük kareler yöntemlerinin birleşimleri)
Momentum katsayısı		0.98
Toplam karesel hata (sse)		0.000000001

Tablo 5.10. DUATBÇS modelinin hareketli RHE işaret örüntülerini tanıma başarımı.

	Küçük Metal Plaka	Büyük Metal Plaka	Pleksiglas Plaka	Köşeli Yansıtıcı	Küre	Silindirin Yandan Görünüşü	Silindirin Alttan Görünüşü	Silindirin Dikey Görünüşü
Toplam Örnek Sayısı	9	9	9	9	9	9	9	9
Doğru Sınıflandırma Sayısı	9	9	8	7	8	8	7	8
Yanlış Sınıflandırma Sayısı	-	-	1	2	1	1	2	1
Tanıma Yüzdesi (%)	100	100	88.8	77.7	88.8	100	77.7	88.8

5.6.4. Dalgacık Paket Dönüşüm Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi İle Adaptif Özellik Çıkarma ve Sınıflama

Bölüm 4.2.2. de bahsedilen dalgacık paket uyarlamalı ağ tabanlı bulanık çıkarım sistemi ile adaptif özellik çıkarma ve sınıflama temelli olarak geliştirilen yeni DPUATBÇS modelinin yapısı ve eğitim parametreleri Tablo 5.11. de ve RHE işaretlerine uygulama sonuçları ise Tablo 5.12. de verilmiştir.

Tablo 5.11. DPUATBÇS modelinin yapısı ve eğitim parametreleri.

DPUATBÇS Modelinin Yapısı		
Dalgacık paket filtre türü		Daubechies - 4
Dalgacık paket ayrışım seviyesi		5
Entropi	Türü	Sure
	Parametre başlangıç	2
	Parametre bitiş	3
	Parametre değişim	0.1
Katman sayısı		5
Katmanlardaki nöron sayısı		Giriş : 6 Kural sayısı : 64 Çıkış : 8
Başlangıç ağırlıkları ve eşik değerleri		Nguyen-Widrow metodu ile hesaplandı
Etkinleştirme fonksiyonları		Logaritmik sigmoid
Eğitim Parametreleri		
Öğrenme kuralı		Melez Öğrenme Algoritması (Doğrusal olmayan giriş parametreleri için Geri yayılım ve doğrusal çıkış parametreleri için En küçük kareler yöntemlerinin birleşimleri)
Momentum katsayısı		0.98
Toplam karesel hata (sse)		0.000000001

Tablo 5.12. DUATBÇS modelinin hareketli RHE işaret örüntülerini tanıma başarımı.

	Küçük Metal Plaka	Büyük Metal Plaka	Pleksiglas Plaka	Köşeli Yansıtıcı	Küre	Silindirin Yandan Görünüşü	Silindirin Alttan Görünüşü	Silindirin Dikey Görünüşü
Toplam Örnek Sayısı	9	9	9	9	9	9	9	9
Doğru Sınıflandırma Sayısı	9	9	9	8	8	8	7	8
Yanlış Sınıflandırma Sayısı	-	-	-	1	1	1	2	1
Tanıma Yüzdesi (%)	100	100	100	88.8	88.8	88.8	77.7	88.8

5.7. Optimum Entropi Tabanlı Özellik Çıkarımı Yönteminin Uygulaması

Bölüm 3.3 de optimum entropi tabanlı özellik çıkarma ve sınıflama temelli olarak geliştirilen yeni Genetik Yapay Sinir Ağları (GYSA) modelinin yapısı ve eğitim parametreleri Tablo 5.13. de ve RHE işaretlerine uygulama sonuçları ise Tablo 5.14. de verilmiştir.

Tablo 5.13. GYSA modelinin yapısı ve eğitim parametreleri.

Modelinin Yapısı	
Başlangıç popülasyonundaki birey sayısı	20
Popülasyondaki her bir bireyin bit uzunluğu	32
Kullanılan entropi türleri	Shonnon, Norm, Logaritmik Enerji, Sure, Eşik
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş : 5 Kural sayısı : 15 Çıkış : 8
Başlangıç ağırlıkları ve eşik değerleri	Genetik Algoritma ile ayarlandı
Etkinleştirme fonksiyonları	Logaritmik sigmoid
Eğitim Parametreleri	
Öğrenme kuralı	Geri yayılım
Momentum katsayısı	0.98
Toplam karesel hata (sse)	0.0000001


Tablo 5.14. GYSA modelinin hareketli RHE işaret örüntülerini tanıma başarımı.

Nesil sayısı	Seçilen özellik çıkarım yöntemi	Doğru sınıflandırma performansı (%)
1	Yöntem-2	77.7
1	Yöntem-1	88.8
1	Yöntem-4	100
2	Yöntem-1	88.8
4	Yöntem-2	88.8
5	Yöntem-1	88
7	Yöntem-3	66.6
7	Yöntem-1	100
8	Yöntem-1	88.8

5.8. Geliştirilen Resim Bölütleme Tabanlı Özellik Çıkarımı Yönteminin Uygulaması

Bölüm 3.4. de geliştirilen Resim Bölütleme Tabanlı (RBT) özellik çıkarma yöntemi ile elde edilen özellik vektörü örüntü tanıma amacıyla burada Bölüm 5.5. de verilen yapay sinir ağıları sınıflandırıcısına uygulanmıştır. Bu geliştirilen yöntemin özellik çıkarımı safhasında BCO ya da Kohonen YSA sınıflandırıcısı kullanılmasına göre uygulama çalışmaları iki farklı şekilde gerçekleştirilmiştir. Sınıflama modelinin her iki uygulama içinde kullanılan ortak yapısı ve eğitim parametreleri sırasıyla Şekil 5.14. ve Tablo 5.15. de verilmiştir. Yapılan bu uygulamaların birincisinde BCO sınıflandırıcısı kullanılmış ve bu birinci uygulama çalışması sonucunda elde edilen sonuçlar Tablo 5.16. da verilmiştir. İkinci uygulamada ise BCO

sınıflandırıcısı yerine Kohonen YSA sınıflandırıcısı kullanılmış ve elde edilen sonuçlar Tablo 5.17. de verilmiştir.



Şekil 5.14. Geliştirilen Resim Bölütleme Tabanlı Özellik Çıkarımı ve Sınıflandırma Yönteminin blok diyagramı.

Tablo 5.15. Geliştirilen RBT özellik çıkarım yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri.

YSA yapısı	
YSA modeli	Çok katmanlı ileri beslemeli
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş : 6 Gizli : 25 Çıkış : 8
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 : 0.0001 Artış katsayısı : 1.05 Azalış katsayısı : 0.7
Momentum sabiti	0.98
Toplam karesel hata	0.00001

Tablo 5.16. BCO sınıflandırıcısı kullanılarak gerçekleştirilen RBT özellik çıkarımı ve sınıflandırma modelinin hareketli RHE işaret örüntülerini tanıma başarımı.

	Küçük Metal Plaka	Büyük Metal Plaka	Pleksiglas Plaka	Köşeli Yansıtıcı	Küre	Silindirin Yandan Görünüşü	Silindirin Alttan Görünüşü	Silindirin Dikey Görünüşü
Toplam Örnek Sayısı	9	9	9	9	9	9	9	9
Doğru Sınıflandırma Sayısı	8	9	8	7	-	8	7	8
Yanlış Sınıflandırma Sayısı	1	-	1	2	-	1	2	1
Tanıma Yüzdesi (%)	88.8	100	88.8	77.7	100	88.8	77.7	88.8

Tablo 5.17. Kohonen YSA sınıflandırıcısı kullanılarak gerçekleştirilen RBT özellik çıkarımı ve sınıflandırma modelinin hareketli RHE işaret örüntülerini tanıma başarımı.

	Küçük Metal Plaka	Büyük Metal Plaka	Pleksiglas Plaka	Köşeli Yansıtıcı	Küre	Silindirin Yandan Görünüşü	Silindirin Alttan Görünüşü	Silindirin Dikey Görünüşü
Toplam Örnek Sayısı	9	9	9	9	9	9	9	9
Doğru Sınıflandırma Sayısı	8	9	8	8	-	8	8	7
Yanlış Sınıflandırma Sayısı	1	-	1	1	-	1	1	2
Tanıma Yüzdesi (%)	88.8	100	88.8	88.8	100	88.8	88.8	77.7

Yukarıda hareketli RHE işaretlerine uygulanan bütün bu özellik çıkarım ve sınıflama yöntemleri aynı şekilde sabit RHE verilerine de uygulanmış ve ortalama % 97' ye varan bir hedef tanıma başarımına ulaşılmıştır.

Aşağıda Tablo 5.18. de bu tez çalışmasında kullanılan ve geliştirilen özellik çıkarımı-sınıflama yöntemlerinin hedef tanıma bakımından başarımların yüzdeleri karşılaştırılmıştır.

Tablo 5.18. Kullanılan ve geliştirilen özellik çıkarımı- sınıflama yöntemlerinin hedef tanıma bakımından başarımların yüzdelerinin karşılaştırılması.

		Ortalama Hedef Tanıma Başarımları (%)	
		Sabit Hedefler İçin	Hareketli Hedefler İçin
Özellik Çıkarımı- Sınıflama Yöntemleri	DD-EH / YSA	% 90	% 83
	DPD-EH / YSA	% 90	%89
	DD-KZFD-EH / YSA	% 92	% 92
	DPD-KZFD-EH / YSA	% 91	% 89
	DSA Modeli	%93	% 91
	DPSA Modeli	%95	%93
	DUATBÇS Modeli	%97	%90
	DPUATBÇS Modeli	%100	%94
	GYSA Modeli	%92	%87
	RBT Modeli	%90	%88

Buradan elde edilen karşılaştırma sonuçları ayrıntılı bir şekilde Bölüm 6. da irdelenmiştir. Burada elde edilen sonuçlara kısaca değinilirse, Tablo 5.18. den de görüldüğü gibi DD-EH'nin giriş sayısı ve işlem yükü DD-KZFD-EH' e göre daha az olmasına rağmen tanıma başarımı daha düşüktür. Ayrıca DSA ve DPSA yöntemleri incelendiğinde, adaptif özellik çıkarım yöntemlerinin uygulandığı bu her iki yapısında tanıma yüzdelerinin yüksek olduğu söylenebilir. Ancak bu yapılar ile DUATBÇS ve DPUATBÇS yapılarını karşılaştırdığımızda DUATBÇS ve DPUATBÇS yapılarının tanıma başarımının daha yüksek olduğu görülmektedir. İşlem hızı bakımından ise bu dört adaptif yapıdan en hızlı eğitim işlemini gerçekleştiren modelin DUATBÇS ve DPUATBÇS modelleri olduğunu ve bunda da DUATBÇS'nin diğer sınıflama ve tasarım yöntemleriyle daha iyi bütünleşebilmesi özelliğinden kaynaklandığını ifade edebiliriz.

Geliştirilen diğer yöntemler olan GYSA ve RBT modellerine göre adaptif yöntemlerin tanıma yüzdelerinin biraz daha fazla olduğu gözlenmektedir. Bu bulunan sonuçlarda ise kullanılan adaptif dalgacık-entropi yapısının etkin olduğu görülmüştür.

6. SONUÇ VE DEĞERLENDİRME

Akıllı radar hedef tanıma çalışmalarında, en önemli iki sorun: Güçlü ve etkin özellik çıkarımı ve buna bağlı olarak elde edilen sınıflandırma sonuçlarının güvenilirliğidir. Bu tez çalışmasında, RHE işaretleri için dört farklı klasmanda olmak üzere dokuz 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 ve UATBÇS sınıflayıcıları ile değerlendirilmiştir. Ayrıca özellik çıkarım sürecini de içeren ve sınıflayıcının eğitim başarımına göre özellik uzayını uyarlayabilen ve Türkoğlu (2002) tarafından geliştirilen entropi tabanlı dalgacık sinir ağı bu tez çalışmasında da radar hedef tanıma amaçlı olarak kullanılmıştır. Ayrıca aynı amaç için bu tez çalışmasında yeni dalgacık uyarlamalı ağ tabanlı bulanık çıkarım sistem modeli geliştirilmiştir. Optimum özellik çıkarımı için bir genetik yapay sinir ağı modeli geliştirilmiştir. Bunların dışında resim işleme tekniklerini kullanarak otomatik hedef tanıma yapmak için resim bölütleme tabanlı bir özellik çıkarım algoritması da bu tez çalışmaları kapsamında geliştirilmiştir.

6.1. Sonuçların Değerlendirilmesi

- Geliştirilen özellik çıkarım algoritmaların da [132] 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 işarete birden çok perspektiften bakılarak elde edilen her bir işaret bileşeninin entropi değerleri hesaplanmıştır. 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 512 noktalı frekans bölgesinden çıkarılan özellik uzayının boyutu 512 iken, geliştirilen yöntemde bir işarete ait 750 veri örnekli 6 alt bileşen işaretenin, 6 entropi değeri ile özellik uzayı betimlenmiş ve boyut olarak az olmasına rağmen, tanıma başarımı yüksek çıkmıştır. Bu ise, özellik çıkarma algoritmasının sağlam temellere dayalı olduğunu göstermektedir. Ayrıca özellik uzayının boyut olarak küçük olması, sınıflayıcının karmaşıklığını (YSA daha az nöron ve ara katman, UATBÇS' de ise daha

az kural kullanılmasını sağlar; YSA için giriş: 6, ara: 15, çıkış: 8 nöron ve UATBÇS için ise kural sayısı: $2^6 = 64$) önlediği için gerçek zaman uygulamalarına daha uygun hale getirmekte ve tasarımını kolaylaştırmaktadır. Ayrıca YSA ve UATBÇS sınıflayıcılarının 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.

- Kullanılan DDA-EH ve DPDA-EH özellik çıkarım yapılarında işaretin doğrudan zaman bölgesi bileşenlerinin örüntülerinden entropi değerleri hesaplanmıştır. Bu yöntemlerin YSA ve UATBÇS ile RHE işaretlerini sınıflama başarımları, ortalama olarak %93 civarındadır. Diğer özellik çıkarım yöntemlerinde ise, işaretin ayrışımı sonucu elde edilen her bir RHE 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 DD-KZFD-SEH, DPD-KZFD-SEH yöntemleri ile %94 civarında başarımlarına ulaşılmıştır.
- Kullanılan 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 (6 katsayı işaret bileşenli DD ağacı, 32 katsayı işaret bileşenli DPD ağacı) ve bu kadar çok işaret bileşeni kullanılmasına rağmen entropi kavramı ile her bir işaret bileşeninden bir özellik değeri elde edildiğinden, özellik uzayının boyutundaki artıştan da kaçınılarak daha güven verici ve kararlı özellik çıkarımı gerçekleştirilmiştir.
- YSA ve UATBÇS sınıflayıcılarının, eğitim başarımları geliştirilen özellik çıkarım algoritmaları için %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.
- Adaptif özellik çıkarma ve sınıflama tabanlı akıllı radar hedef tanıma için kullanılan dalgacık sinir ağı ve geliştirilen dalgacık uyarlamalı ağ tabanlı bulanık çıkarım sistemi

modellerinin başarımı ise DPSA ve DPUATBÇS modellerinde % 95 olarak en yüksek değerine ulaşmıştır. Kullanılan ve geliştirilen bu modellerde, [132] çalışmalarının dezavantajı olarak karşımıza çıkan, giriş değerine çok farklı perspektiften bakılmasından dolayı, aynı giriş verisini birden çok kez kullandığı için DSA 'nın, DPSA'nın, DUATBÇS'nin ve DPUATBÇS'nin işlem yükü fazla olmasından kaynaklanan dalgacık sinir ağının, dalgacık paket sinir ağının, dalgacık uyarlamalı ağ tabanlı bulanık çıkarım sisteminin ve dalgacık paket uyarlamalı ağ tabanlı bulanık çıkarım sisteminin hızlarındaki düşme problemine, entropi kavramı DSA, DPSA, DUATBÇS ve DPUATBÇS yapılarının içerisine gömülerek çözülmüştür. Böylelikle DSA 'nın, DPSA'nın, DUATBÇS'nin ve DPUATBÇS'nin 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. Bunlara ilaveten bu tez çalışmasında kullanılan [174] DSA ve DPSA modelleri, geliştirilen DUATBÇS ve DPUATBÇS modelleri ile sınıflandırma işlemi için harcanılan zaman bakımından karşılaştırıldıklarında, geliştirilen DUATBÇS ve DPUATBÇS modellerinin kullanılan DSA ve DPSA modellerine göre daha az zamanda başarılı bir şekilde sınıflandırma yaptıkları görülmüştür.

- Bu tez çalışmasında geliştirilen Genetik Yapay Sinir Ağları kullanılarak yapılan optimum entropi tabanlı özellik çıkarımı çalışması ile birden fazla özellik çıkarım yönteminin (KZFD-EH, WV-EH, BJ-EH ve CW-EH) doğru sınıflandırma bakımından performans kıyaslaması yapıldığı gibi aynı zamanda bu yöntemde genetik algoritma kullanılarak YSA'nın başlangıç ağırlıklarının rastgele seçilmesinden dolayı oluşan eğitim zamanındaki artış ve yakınsama problemleri ortadan kaldırılmaya çalışılmış ve bunda da başarılı olunmuştur. Bu yöntemlerden birincisi olan KZFD-EH özellik çıkarım yönteminin diğer yöntemlere göre daha başarılı olduğu gözlenmiştir. Bu yöntem kullanılarak en iyi yöntem ve en iyi entropi değeri bulunmaya çalışılmış ve bunda da başarılı kabul edilebilecek sonuçlar alınmıştır.
- Bu tez çalışmasında çeşitli resim işleme teknikleri kullanılarak geliştirilen Resim Bölütleme Tabanlı özellik çıkarımı ve sınıflandırma yöntemi ile otomatik hedef tanıma alanında daha önceden yapılan çalışmalardan farklı olarak [45-47], işaretlerin zaman frekans gösterimlerinden resim elde etme metodolojisi ortaya atılmıştır. Bu yöntemle

elde edilen özellikler kullanılarak çok katmanlı ileri beslemeli yapay sinir ağıları sınıflandırıcısı ile yapılan sınıflandırma çalışması başarılı kabul edilebilecek sonuçlar vermiştir. Bu çalışmadan elde edilen sonuçların başarı derecesinin yüksek olmasının başlıca nedenlerinden biri bu özellik çıkarımı yöntemi ile elde edilen özelliklerin RHE işaretlerini en iyi şekilde özetleyebilecek nitelikte olması ve entropi değerleri kullanılarak özellik uzayı boyutunun azaltılmasıdır. Ayrıca çok katmanlı ileri beslemeli yapay sinir ağıları sınıflandırıcısı gibi üstün bir sınıflandırıcının kullanımı da alınan bu başarılı sonuçlarda en büyük etkenlerdendir.

- RHE işaretleri için kullanılan akıllı örüntü tanıma sistemlerinin girişine, işaret örüntülerini doğrudan vermek yerine, önerilen [132] ön işlem süreci ile bu sistemlerin başarımına katkıda bulunulmuştur. RHE işaretlerine uygulaması yapılan ön işlem sürecinde, gürültüden ayırışım, normalizasyon gibi aşamalar ile işaret içerisinde bulunan serbest iç ve dış dinamiklere müdahale edilerek, örüntü tanıma sisteminin başarımına olumsuz yönde olan etkileri minimum düzeye çekilmiştir.
- Entropi kavramının önerilen [132] ve geliştirilen yöntemlerde kullanılması, RHE işaretlerin karakterizasyonu için çok kullanışlı bir araç olmuştur. Böylece bu yeni tanılama bilgisi elde etme yöntemi, geleneksel genliğe bağlı yöntemlere göre farklı bir yaklaşımdır.
- Bu tez çalışmasında dalgacık ve dalgacık paket dönüşümleri kullanılarak sabit ve hareketli hedeflere ait RHE işaretlerinden özellik çıkarma yoluna gidilmiştir. Bunun yapılmasındaki en önemli nedenler, hareketli ve sabit RHE işaretlerinden daha dayanıklı özellikler çıkarmak ve hareketli hedeflerin RHE işaretlerindeki zaman kayması etkisini azaltmak olarak gösterilebilir. Çünkü hareketli hedeflerin tanınması son yıllarda büyük önem kazanan bir konu haline gelmiştir. Günümüzde hareketli RHE işaretlerinin zaman kayması problemini çözmek için birçok çalışma yapılmaktadır. Bunlardan bazıları [43, 44] ve [46]'da verilmiştir. Bu kaynaklarda belirtilen hedef tanıma çalışmalarında dalgacık dönüşümü, hedef RHE işaretlerinden dayanıklı özellikler çıkarmada esas alınmıştır. Bu çalışmada ise, kaynak [132]'de geliştirilen DSA ve DPSA dalgacık dönüşüm-adaptif entropi özellik çıkarım ve sınıflama yöntemlerine ilaveten DUATBÇS ve DPUATBÇS dalgacık dönüşüm-adaptif entropi modelleri ile GYSA ve RBT modelleri geliştirilmiştir. Bu kullanılan ve geliştirilen her bir modelin hedef tanıma yüzdeleri daha önceden bu alanda yapılmış hedef tanıma

alışmalarından [43, 44], [46] elde edilen sonuçlarla karşılaştırıldığında iyi kabul edilebilecek sonuçlar verdikleri gözlenmiştir. Ayrıca bu alışmalarda özellik ıkarımı aşamasında entropi değeri kullanarak ıkarılacak özellik boyutu düşürölmüş ve sınıflandırıcıların işlem yükü hafifletilmiştir.

6.2. Öneriler

1. Geliştirilen akıllı radar hedef tanıma sisteminin uygulaması sadece RHE işaret örüntüleri üzerine yapılmasına rağmen, Bölüm 1.5. de verilen çeşitli işaret örneklerinin her birine uygulanabilir. Örneğin, radar Doppler işaretlerine yapılabilecek uygulama ile radar erken uyarı sistemi geliştirilebilir.
2. RHE işaret örüntüleri için yapılan uygulamada, YSA ve UATBÇS sınıflandırıcılarının eğitimi için kullanılan veri örneklerinin sayısı artırılarak, geliştirilen akıllı radar hedef tanıma sisteminin başarımı daha da yükseltilebileceği gibi radar hedefleri hakkında ayrıntılı bilgilerde (hedefin büyüklüğü, konumu, hızı, vb.) otomatik olarak ıkartılabilir.
3. Bu tez alışmasında kullanılan ve geliştirilen algoritmalarda veri alma, özellik ıkarma ve sınıflama işlemlerinin daha hızlı yapılabilmesi problemi ilerde, DSP erçeklemeleri kullanarak giderilebilir.

6.3. Yayınlar

Bu tez alışmasında gerçekleştirilen uygulamalar altı adet dergi yayını [175-180] ve iki adet konferans yayını [181, 182] ile sonuçlandırılmıştır.

KAYNAKLAR

1. Nebabin, V., G., 1995, Methods and Techniques of Radar Recognition, Artech House, Inc., s.s. 239.
2. Ahern, J., Delisle, G., Y., 1989, Radar, Lab-Volt Ltd., 1, Canada, s.s. 501.
3. Ahalt, S., C., Jung, T., Krishnamurthy, A., K., 1990, "A comparison of radar signal classifiers" Systems Engineering, IEEE International Conference on , 9-11 Ağustos 1990, 609 – 612.
4. Mohamed, N., J., 1994, "High-resolution nonsinusoidal radars with three-dimensional target structure", Electromagnetic Compatibility, IEEE Transactions on , 36, No:3 , Ağustos 1994, 229 – 241.
5. Deshuang, H., Erke, M., Yueqiu, H., 1995, "Application of function link net to recognition of radar targets", Acoustics, Speech, and Signal Processing, 1995. ICASSP-95., 1995 International Conferenceon, 5, 9-12 Mayıs 1995, 3487 – 3490.
6. Zyweck, A., Bogner, R., E., 1996, "Radar target classification of commercial aircraft". Aerospace and Electronic Systems, IEEE Transactions on , 32, No:2, Nisan 1996 598 – 606.
7. Robinson, A., D., Inggs, M., R., 1994, "Correlation filters applied to synthetic range profiles of aircraft targets", Communications and Signal Processing, 1994. COMSIG-94., Proceedings of the 1994 IEEE South African Symposiumon, 4 Ekim 1994, 125 – 127.
8. Feixue, W., Wenxian, Y., Guirong, G., 1996, "Recurrent neural network for high-resolution radar ship target recognition", Radar, 1996. Proceedings., CIE International Conference of , 8-10 Ekim 1996, 200 – 203.
9. Jacobs, S., P., O'Sullivan, J., A., 1997, "High resolution radar models for joint tracking and recognition", Radar Conference, 1997., IEEE National , 13-15 Mayıs 1997 99 – 104.
10. Yan, W., Zhu, Z., Hu, R., 1997, "A hybrid genetic/BP algorithm and its application for radar target classification", Aerospace and Electronics Conference. 1997. NAECON 1997.. Proceedings of the IEEE 1997 National , 2, 14-17 Temmuz 1997 981 – 984.

11. Nieuwoudt, C., Botha, E., C., 1998, "Relative performance of correlation-based and feature-based classifiers of aircraft using radar range profiles", Pattern Recognition, 1998. Proceedings. Fourteenth International Conference on, 2, 16-20 Ağustos 1998, 1828 – 1832.
12. Zongquan, Y., 1998, "Two-level classification of target recognition based on neural network", Microwave and Millimeter Wave Technology Proceedings, 1998. ICMMT '98. 1998 International Conference on, 18-20 Ağustos 1998, 460 – 462.
13. Daqing, C., Zheng, B., 1996, "High range resolution radar target identification using multilayer feedforward neural network", Radar, 1996. Proceedings., CIE International Conference of , 8-10 Ekim 1996, 215 – 218.
14. Cheung, J., Baldygo, W., Saito, Y., 1997, "Optimal target identification based upon ultra high resolution radar profiles", Radar Conference, 1997., IEEE National , 13-15 Mayıs 1997 278 – 283.
15. Huaitie, X., Zhaowen, Z., Zhenpin, C., Songhua, H., Biao G., 1997, "Aircraft target recognition using adaptive time-delay neural network", Aerospace and Electronics Conference, 1997. NAECON 1997., Proceedings of the IEEE 1997 National, 2, 14-17 Haziran 1997, 764 – 768.
16. Mitchell, R., A., Westerkamp, J., J., 1998, "Statistical feature based target recognition". Aerospace and Electronics Conference, 1998. NAECON 1998. Proceedings of the IEEE 1998 National, 13-17 Temmuz 1998, 111 – 118.
17. Zhou, D., Wu, L., Liu, G., 1998, "Bayesian classifier based on discretized continuous feature space", Signal Processing Proceedings, 1998. ICSP '98. 1998 Fourth International Conference on, 2, 12-16 Ekim 1998, 1225 – 1228.
18. Mohamed, N., J., 1994, "High-resolution nonsinusoidal radars with three-dimensional target structure", Electromagnetic Compatibility, IEEE Transactions on , 36. No:3 , Ağustos 1994, 229 – 241.
19. Deshuang, H., Erke, M., Yueqiu, H., 1995, "Application of function link net to recognition of radar targets", Acoustics, Speech, and Signal Processing, 1995. ICASSP-95., 1995 International Conference on, 5, 9-12 Mayıs 1995, 3487 – 3490.
20. Zyweck, A., Bogner, R., E., 1996, "Radar target classification of commercial aircraft". Aerospace and Electronic Systems, IEEE Transactions on , 32, No:2, Nisan 1996 598 – 606.

21. Jing, G., Xin, G., Luo, P., 1997, "A new method for automatic target recognition", Aerospace and Electronics Conference, 1997. NAECON 1997., Proceedings of the IEEE 1997 National, 2, 14-17 Temmuz 1997, 1019 – 1024.
22. Liao, X., Bao, 1998, "Circularly integrated bispectra: novel shift invariant features for high-resolution radar target recognition", Electronics Letters , Volume: 34 , Issue: 19 , 17 Eylül 1998, 1879 – 1880.
23. Shi, Y., Zhang, X., 2000, "Local bispectra based high-resolution radar target classification", Signal Processing Proceedings, 2000. WCCC-ICSP 2000. 5th International Conference on, 3, 21-25 Ağustos 2000, 1968 – 1971.
24. Bingnan, P., Zheng B., Mengdao, X., 2001, "Radar target recognition by a logarithm bispectrum-based method", Radar, 2001 CIE International Conference on, Proceedings , 15-18 Ekim 2001, 488 – 492.
25. Robinson, A., D., Inggs, M., R., 1994, "Correlation filters applied to synthetic range profiles of aircraft targets", Communications and Signal Processing, 1994. COMSIG-94., Proceedings of the 1994 IEEE South African Symposiumon, 4 Ekim 1994, 125 – 127.
26. Melendez, G.J., Kesler, S., B., 1995, "Spectrum estimation by neural networks and their use for target classification by radar" Acoustics, Speech, and Signal Processing, 1995. ICASSP-95., 1995 International Conference on, 5, 9-12 Mayıs 1995, 3615 – 3618.
27. Wenfeng, Z., Songhua, H., Guirong, G., 1996, "Approach to reach high range resolution by using neural networks", Aerospace and Electronics Conference, 1996. NAECON 1996., Proceedings of the IEEE 1996 National, 1, 20-23 Mayıs 1996, 188 – 191.
28. Feixue, W., Wenxian, Y., Guirong, G., 1996, "Recurrent neural network for high-resolution radar ship target recognition", Radar, 1996. Proceedings., CIE International Conference of , 8-10 Ekim 1996, 200 – 203.
29. Inggs, M., R., Robinson, A., R., 1995, "Neural approaches to ship target recognition". Radar Conference, 1995., Record of the IEEE 1995 International, 8-11 Mayıs 1995, 386 – 391.
30. Serretta, H., Inggs, M., R., 1998, "Ship target recognition with the Mellin transform aided by neural networks", Communications and Signal Processing, 1998. COMSIG '98. Proceedings of the 1998 South African Symposium on, 7-8 Eylül 1998, 203 – 208.

31. Inggs, M., R., Robinson, A., D., 1999, "Ship target recognition using low resolution radar and neural networks", Aerospace and Electronic Systems, IEEE Transactions on, 35, 2, Nisan 1999, 386 – 393.
32. Huynen, J., R., 1991, "Physical reality and mathematical process in radar polarimetry", Antennas and Propagation, 1991. ICAP 91., Seventh International Conference on (IEE) , 15-18 Nisan 1991, 1, 257 – 261.
33. Ruck, D., W., Rogers, S., K., Kabrisky, M., Mills, J., P., 1989, "Target recognition: Conventional and neural network approaches", Neural Networks, 1989. IJCNN., International Joint Conference on , 18-22 Haziran 1989, 2, 608.
34. Steedly, W., M., Moses, R., L., 1990, "High resolution exponential modeling of fully polarized radar returns", Systems Engineering, 1990., IEEE International Conference on , 9-11 Ağustos 1990, 495 – 498.
35. Xuesong, W., Shunping, X., Zhaowen, Z., Yonghu, Z., Huamin, T., 1996, "Target recognition based on extraction of dynamic polarization structure features", Aerospace and Electronics Conference, 1996. NAECON 1996., Proceedings of the IEEE 1996 National, 1, 20-23 Mayıs 1996, 208 – 212.
36. Shunping, X., Xuesong, W., Zhaowen, Z., Huamin, T., Yonghu, Z., 1996, "Target recognition based on multi-dimensional polarization feature space", Aerospace and Electronics Conference, 1996. NAECON 1996., Proceedings of the IEEE 1996 National, 1, 20-23 Mayıs 1996, 213 – 216.
37. Xuesong, W., Shunping, X., Zhaowen Z., Yonghu Z., Huamin T., 1996, "Target recognition based on polarization frequency stability", Aerospace and Electronics Conference, 1996. NAECON 1996., Proceedings of the IEEE 1996 National, 1, 20-23 Mayıs 1996, 217 – 220.
38. Songhua, H., Hui, Z., Bo H., 1995, "Polarization identification of high resolution range profiles", Aerospace and Electronics Conference, 1995. NAECON 1995., Proceedings of the IEEE 1995 National, 1, 22-26 Mayıs 1995, 53 – 55.
39. Yicheng, J., Yongtan, L., Ping, Y., 1996, "A new radar target classification approach based on polarimetric high range resolution", Radar, 1996. Proceedings.. CIE International Conference of , 8-10 Ekim 1996, 147 – 150.

40. Huamin, T., Jianjun, Y., Chunlei, Z., 1998, "Polarization radar target recognition based on optimal curve fitting", Aerospace and Electronics Conference, 1998. NAECON 1998. Proceedings of the IEEE 1998 National, 13-17 Temmuz 1998, 434 – 437.
41. Huamin, T., Zhiquan, Z., 1998, "Target recognition based on characteristic polarizations, in the optics region", Aerospace and Electronics Conference, 1998. NAECON 1998. Proceedings of the IEEE 1998 National, 13-17 Temmuz 1998, 438 – 440.
42. Shunping, X., Xuesong, W., Yonghu, Z., Huamin, T., Zhaowen, Z., Guirong, G., 1996, "Feature-extracting and recognition based on radar target's dynamic polarization structure", Radar, 1996. Proceedings., CIE International Conference of, 8-10 Ekim 1996 666 – 670.
43. Jun, L., WenXian, Y., GuiRong, G., 1994, "Feature extraction for radar ship target recognition using compactly supported wavelets", Aerospace and Electronics Conference, 1994. NAECON 1994., Proceedings of the IEEE 1994 National, 23-27 Mayıs 1994, 1, 66 – 73.
44. Nelson, D., E., Starzyk, J., A., 1997, "Advanced feature selection methodology for automatic target recognition", System Theory, 1997., Proceedings of the Twenty-Ninth Southeastern Symposium on, 9-11 Mart 1997, 24 – 28.
45. Clark, M., E., 2000, "High range resolution radar techniques and the wavelet transform", Time-scale and Time-Frequency Analysis and Applications (Ref. No. 2000/019), IEE Seminar on, 29 Şubat 2000, 10/1 - 10/7.
46. Huether, B., M., Gustafson, S., C., Broussard, R., P., 2001, "Wavelet preprocessing for high range resolution radar classification", Aerospace and Electronic Systems, IEEE Transactions on, 37, 4, Ekim 2001, 1321 – 1332.
47. Nelson, D., E., Starzyk, J., A., Ensley, D., D., 2003, "Iterated wavelet transformation and signal discrimination for HRR radar target recognition", Systems, Man and Cybernetics, Part A, IEEE Transactions on, 33, 1, Ocak 2003, 52 – 57.
48. Weidong, W., Youan, K., Zhiweeen, L., Guangfei, C., 1996, "Hybrid natural mode and scattering center method for the representation of radar target impulse response", Radar, 1996. Proceedings., CIE International Conference of, 8-10 Ekim 1996, 671 – 673.

49. Kim, K., Seo, D., Kim, H., 2002, "Efficient radar target recognition using the MUSIC algorithm and invariant features", *Antennas and Propagation, IEEE Transactions on*, 50, 3, Mart 2002, 325 – 337.
50. Abbott, D., W., 1994, "Comparison of data analysis and classification algorithms for automatic target recognition", *Systems, Man, and Cybernetics*, 1994. 'Humans, Information and Technology', 1994 IEEE International Conference on , 1, 2-5 Ekim 1994 902 – 907.
51. Xian, M., Zhuang, Z., Chen, Z., Guo, G., 1996, "The fractal characteristic of radar target based on polarimetry", *Aerospace and Electronics Conference*, 1996. NAECON 1996., *Proceedings of the IEEE 1996 National*, 1, 20-23 Mayıs 1996, 339 – 344.
52. Bhatnagar, V., Shaw, A., K., Williams, R., W., 1998, "Improved automatic target recognition using singular value decomposition", *Acoustics, Speech, and Signal Processing*, 1998. ICASSP '98. *Proceedings of the 1998 IEEE International Conference on*, 5, 12-15 Mayıs 1998, 2717 – 2720.
53. Jing, J., Shouyong, W., Lan, Y., Delin, Z., Zhaoming, Y., Changwen, T., "Radar target recognition based on fuzzy clustering", *Signal Processing Proceedings*, 1998. ICSP '98. *1998 Fourth International Conference on*, 2, 12-16 Ekim 1998, 1532 – 1535.
54. Shouyong, W., Jing, J., Lan, Y., Zhaoming, Y., Delin, Z., Changwen, T., 1998, "Multiple target recognition by eigenvalue estimation", *Signal Processing Proceedings*, 1998. ICSP '98. *1998 Fourth International Conference on*, 2, 12-16 Ekim 1998, 1536 – 1539.
55. Nieuwoudt, C., Botha, E., C., 1994, "Using correlation filters to classify aircraft down-range radar profiles", *Communications and Signal Processing*, 1994. COMSIG-94., *Proceedings of the 1994 IEEE South African Symposium on*, 4 Ekim 1994, 132 – 137.
56. Songhua, H., Wenfeng, Z., Guirong, G., 1996, "High range resolution MMW radar target recognition approaches with application", *Aerospace and Electronics Conference*. 1996. NAECON 1996., *Proceedings of the IEEE 1996 National*. 1, 20-23 Mayıs 1996 192 – 195.
57. Jinsong, T., Zhaoda, Z., 1996, "Comparison study on high resolution radar target recognition", *Aerospace and Electronics Conference*, 1996. NAECON 1996., *Proceedings of the IEEE 1996 National*, 1, 20-23 Mayıs 1996, 250 – 253.

58. Lingen, L., 1996, "Target detection with high-range-resolution (HRR) radar", Radar, 1996, Proceedings., CIE International Conference of, 8-10 Ekim 1996, 715 – 718.
59. Wenfeng, Z., Songhua, H., Guirong, G., 1996, "High-resolution polarimetric radar targets recognition based on the fractal characterization", Aerospace and Electronics Conference, 1996. NAECON 1996., Proceedings of the IEEE 1996 National, 1, 20-23 Mayıs 1996, 184 – 187.
60. Xian, M., Zhuang, Z., Chen, Z., Guo, G., 1996, "The fractal characteristic of radar target based on polarimetry", Aerospace and Electronics Conference, 1996. NAECON 1996., Proceedings of the IEEE 1996 National, 1, 20-23 Mayıs 1996, 339 – 344.
61. Xiang, L., Zhaowen, Z., Guirong, G., 1996, "Algorithm for target recognition based on fractal Brownian motion model", Signal Processing, 1996., 3rd International Conference on, 2, 14-18 Ekim 1996, 1366 – 1369.
62. Wenfeng, Z., Songhua, H., Guirong, G., 1996, "Approach to the fractal features of high-resolution polarimetric radar targets", Radar, 1996. Proceedings., CIE International Conference of, 8-10 Ekim 1996, 230 – 233.
63. Weidong, H., Wenxian, Y., Aimin, L., 1995, "Fractal detection of radar weak targets", Aerospace and Electronics Conference, 1995. NAECON 1995., Proceedings of the IEEE 1995 National, 1, 22-26 Mayıs 1995, 140 – 144.
64. Jianjun, H., Jingxiong, H., Weixin, X., 1996, "Target classification by conventional radar", Radar, 1996. Proceedings., CIE International Conference of, 8-10 Ekim 1996, 204 – 207.
65. Xiaojian, X., A., G., 1996, "Constantinides, Aircraft identification using a multi-stage fuzzy neural network", Radar, 1996. Proceedings., CIE International Conference of, 8-10 Oct. 1996, 151 – 155.
66. Shi, Y., Zhang, X., 2001, "A Gabor atom network for signal classification with application in radar target recognition", Signal Processing, IEEE Transactions on [see also Acoustics, Speech, and Signal Processing, IEEE Transactions on], 49, 12, Aralık 2001, 2994 – 3004.
67. Furong, Z., Yihe Y., Jianyong X., Weizhen Z., 1991, "Hardware implementation method for air target recognition and location", Circuits and Systems, 1991. Conference Proceedings. China., 1991 International Conference on, 16-17 Haziran 1991, 1, 456 – 459.

68. Dudgeon, D., E., Verly, J., G., Delanoy, R., L., 1990, "An experimental target recognition system for airborne laser radar imagery", Systems Engineering, 1990., IEEE International Conference, 9-11 August 1990, 478 – 481.
69. Delanoy, R., L., Troxel, S., W., 1993, "Automated gust front detection using knowledge-based signal processing", Radar Conference, 1993., Record of the 1993 IEEE National , 20-22 Nisan 1993, 150 – 155.
70. Fister, T., Garber, F., Sawtelle, S., Withman, R., 1993, "Match hypothesis evaluation for synthetic aperture radar targets", Aerospace and Electronics Conference, 1993. NAECON 1993., Proceedings of the IEEE 1993 National , 24-28 Mayıs 1993, 269 – 274.
71. Fister, T., 1994, "Symbolic match hypothesis evaluation for UHRR radar targets", Aerospace and Electronics Conference, 1994. NAECON 1994., Proceedings of the IEEE 1994 National, 23-27 Mayıs 1994, 2, 696 – 700.
72. Grabisch, M., Murofushi, T., Sugeno, M., 1999, Fuzzy Measures and Integrals Theory and Applications, Physica-Verlag, Leiden, The Netherlands, s.s. 477.
73. Ranganath, H., S., Kerstetter, D., 1995, "Self partitioning backpropagation network for target recognition", Southeastcon '95. 'Visualize the Future', Proceedings., IEEE , 26-29 Mart 1995 30 – 36.
74. Nichols, S., A., Naylor, R., B., 1995, "Reliable motion detection of small targets in video with low signal-to-clutter ratios", Security Technology, 1995. Proceedings. Institute of Electrical and Electronics Engineers 29th Annual 1995 International Carnahan Conference on , 18-20 Ekim 1995, 447 – 456.
75. Irwin, J., D., 2000, Supervised and Unsupervised Pattern Recognition Feature Extraction and Computational, CRC Pres LLC., Florida, s.s. 446.
76. Ulug, B., Ahalt, S., C., Mitchell, R., A., 1997, "Efficient ATR using compression", Aerospace and Electronic Systems, IEEE Transactions on, 33, 4, Ekim 1997, 1199 – 1211.
77. Bahram, J., 2002, Image Recognition and Classification: Algorithms, Systems, and Applications, Marcel Dekker Incorporated, s.s. 519.

78. Çetin, M., Karl, W., C., Castanon, D., A., 2003, "Feature Enhancement and ATR Performance Using Nonquadratic Optimization-Based SAR Imaging", *IEEE Transactions on Aerospace and Electronic Systems*, 39, 4, Ekim 2003, 1375-1395.
79. Fisher, J., W., Willsky, A., S., 1999, "Information theoretic feature extraction for ATR", *Signals, Systems, and Computers*, 1999. Conference Record of the Thirty-Third Asilomar Conference on, 2, 24-27 Ekim 1999, 1245 – 1249.
80. Kim, H., Hero, A., O., 2000, "When is a maximal invariant hypothesis test better than the GLRT?", *Signals, Systems and Computers*, 2000. Conference Record of the Thirty-Fourth Asilomar Conference on, 1, 29 Ekim-1 Kasım 2000, 401 – 405.
81. Kim, H., S., Hero, A., O., 2001, "Comparison of GLR and maximal invariant detectors under structured clutter covariance", *Acoustics, Speech, and Signal Processing*, 2001. Proceedings. (ICASSP '01). 2001 IEEE International Conference on, 5, 7-11 Mayıs 2001, 2869 – 2872.
82. Gross, D., 1999, "A neural network ATR for high range resolution radar signature recognition of moving ground targets", *Signals, Systems, and Computers*, 1999. Conference Record of the Thirty-Third Asilomar Conference on, 2, 24-27 Ekim 1999, 1235 – 1239.
83. Kim, K., Choi, I., Kim, H., 2000, "Efficient radar target classification using adaptive joint time-frequency processing", *Antennas and Propagation*, *IEEE Transactions on*, 48, 12, Aralık 2000, 1789 – 1801.
84. Chen, K., M., Nyquist, D., P., Rothwell, E., J., Sun, W., M., 1992, "New progress on E/S pulse techniques for noncooperative target recognition", *Antennas and Propagation*, *IEEE Transactions on*, 40, No:7, Temmuz 1992, 829 – 833.
85. Nandagopal, D., Martin, N., M., Johnson, R., P., Lozo, P., Palaniswami, M., 1994, "Performance of radar target recognition schemes using neural networks-a comparative study", *Acoustics, Speech, and Signal Processing*, 1994. ICASSP-94., 1994 IEEE International Conference on, 2, 19-22 Nisan 1994, II/641 - II/644.
86. Songhua, H., Liang, Z., Wenfeng, Z., 1995, "Doppler Compensation of Range Profiles And Moving Target Discrimination In FMCW Radar", *Aerospace and Electronics Conference*, 1995. NAECON 1995., Proceedings of the IEEE 1995 National ,1 , 22-26 Mayıs 1995, 49.
87. Guosui, L., Yunhong, W., Chunling, Y., Dequan, Z., 1996, "Radar target classification based on radial basis function and modified radial basis function networks",

- Radar, 1996. Proceedings., CIE International Conference of , 8-10 Ekim 1996, 208 – 211.
88. Chen, V., C., Analysis of radar micro-Doppler with time-frequency transform”, Statistical Signal and Array Processing, 2000. Proceedings of the Tenth IEEE Workshop on , 14-16 Ağustos 2000, 463 – 466.
89. Kanal, L., Raghavan, S., 1992, “Hybrid systems-a key to intelligent pattern recognition”, Neural Networks, 1992. IJCNN., International Joint Conference on , 4, 7-11 Haziran 1992, 177 – 183.
90. Spoelstra, J., Botha, E., C., 1992, “Radar target recognition using multiple bounce scattering terms”, Communications and Signal Processing, 1992. COMSIG '92., Proceedings of the 1992 South African Symposiumon, 11 Eylül 1992, 17 – 21.
91. Schukantz, J., H., Jr., Tam, D., W., S., McGee, J., B., Koyama, L., B., Rockway, J., W., Li. S. T., 1995, “Transient scattering response of an airborne target”, Electromagnetic Compatibility, 1995. Symposium Record. 1995 IEEE International Symposium on , 14-18 Ağustos, 1995, 620 – 623.
92. Kashyap, S., Stanier, J., Painchaud, G., Louie, A., 1995, “Radar response of missile-shaped targets”, Antennas and Propagation Society International Symposium, 1995. AP-S. Digest, 4 , 18-23 Haziran 1995, 1910 – 1913.
93. Peikang, H., Wei, T., Xiaojian, X., Zhenxun, F., 1996, “Radar target full-scale measurement and data processing”, Radar, 1996. Proceedings., CIE International Conference of , 8-10 Ekim 1996, 119 – 123.
94. Preiss, B., Tollefson, M., Howard, R., 1997, “A 3D perspective for radar cross section visualization Aerospace Conference, 1997. Proceedings., IEEE. 2. 1-8 Şubat 1997 95 – 112.
95. Moruzzis, M., Colin, N., 1998, “Radar target recognition by Fuzzy Logic”, Aerospace and Electronic Systems Magazine, IEEE, 13, 7, Temmuz 1998, 13 – 20.
96. Colin, N., Moruzzis, M., 1997, “Radar target recognition by fuzzy logic”. Radar Conference, 1997, IEEE National, 13-15 Mayıs 1997, 257 – 262.

97. Herman, S., Moulin, P., 2002, "A particle filtering approach to FM-band passive radar tracking and automatic target recognition", Aerospace Conference Proceedings, 2002. IEEE, 4, 9-16 Mart 2002, 4-1789 - 4-1808.
98. Shalinie, S., M., 2002, "Neuro-fuzzy pattern classification model with rule extraction based on supervised learning", Neural Information Processing, 2002. ICONIP '02. Proceedings of the 9th International Conference on, 4, 18-22 Kasim 2002, 1862 – 1866.
99. Jouny, I., Kanapathipillai, M., 1994, "Neural network adaptive wavelet classification of radar targets", Geoscience and Remote Sensing Symposium, 1994. IGARSS '94. 'Surface and Atmospheric Remote Sensing: Technologies, Data Analysis and Interpretation'. International , 4, 8-12 Ağustos 1994, 1889 – 1891.
100. Li, Q., Rothwell, E., J., Chen, K., M., Nyquist, D., P., Ross, J., Bebermeyer, R., 1994, "Determination of radar target scattering center transfer functions from measured data", Antennas and Propagation Society International Symposium, 1994. AP-S. Digest ,3 , 20-24 Haziran 1994, 2006 – 2009.
101. Ping, D., L., 1996, "High resolution radar target structure description using modified Prony model", Aerospace and Electronics Conference, 1996. NAECON 1996., Proceedings of the IEEE 1996 National, 1, 20-23 Mayıs 1996, 231 – 238.
102. Zhenpin, C., Wei, W., Guirong, G., Zhaowen, Z., 1996, "Recognition and analysis of aircraft targets by fully polarized radar using structural features", Radar, 1996. Proceedings., CIE International Conference of, 8-10 Ekim 1996, 653 – 656.
103. Charrier, C.; Delisle, G., Y., 1999, "Radar targets characterization using wavelets pyramidal decomposition", Computational Electromagnetics and Its Applications, 1999. Proceedings. (ICCEA'99) 1999 International Conference on, 1999, 467 – 470.
104. Arnaud, D., Brousseau, C., Bourdillon, A., "Study of flight route effects on aircraft RCS signature at VHF frequencies by means of wire grid models", Radar Conference, 2000. The Record of the IEEE 2000 International , 7-12 Mayıs 2000 231 – 235.

105. Farhat, N., H., Babri, H., 1992, "Cognitive networks for automated target recognition and autonomous system applications", Neural Networks, 1992. IJCNN., International Joint Conference on , 1, 7-11 Haziran 1992, 535 – 540.
106. Pigeon, E., Grenier, D., 1994, "Identification of high speed targets facing the radar according to their length and signature", Electrical and Computer Engineering, 1994. Conference Proceedings. 1994 Canadian Conference on, 25-28 Eylül 1994 2, 417 – 420.
107. Mohandes, M., Bogner, R., E., Bouzerdoum, A., Pope, K., J., 1996, "A neural network approach towards multiradar track fusion Neural Networks, 1996., IEEE International Conference on, 3 , 3-6 Haziran 1996, 1616 – 1621.
108. Weidong, W., Youan, K., Zhiween, L., Guangfei, C., 1996, "Hybrid natural mode and scattering center method for the representation of radar target impulse response" Radar, 1996. Proceedings., CIE International Conference of , 8-10 Ekim 1996, 671 – 673.
109. Xun, Z., Zhaowen, Z., Guirong, G., 1997, "HRR target recognition using the geometry information of scattering centers Aerospace and Electronics Conference, 1997. NAECON 1997., Proceedings of the IEEE 1997 National. 2, 14-17 Temmuz 1997, 936 – 940.
110. Huizing, A., G., Theil, A., Groen, F., C., A., 1997, "A comparison of a possibilistic and a probabilistic classifier in a multitarget tracking environment", Radar 97 (Conf. Publ. No. 449) , 14-16 Ekim 1997, 614 – 619.
111. Becker, J., C., 1999, "Fusion of data from the object-detecting sensors of an autonomous vehicle", Intelligent Transportation Systems, 1999. Proceedings. 1999 IEEE/IEEJ/JSAI International Conference on, 5-8 Ekim 1999, 362 – 367.
112. Nandagopal, D., Johnson, R., P., Martin, N., M., Wright. A., C., 1992, "Radar target recognition using multilayer backpropagation neural network (MLBPN)", Radar 92. International Conference, 12-13 Ekim 1992, 422 – 425.
113. Przytula, K., W., Thompson, D., 1997, "Evaluation of neural networks for automatic target recognition", Aerospace Conference, 1997. Proceedings.. IEEE .3 , 1-8 Şubat 1997, 423 – 439.

114. Jun, W., 2002, "Radar targets identification based on perfect parametric modeling using artificial neural Networks", TENCON '02. Proceedings. 2002 IEEE Region 10 Conference on Computers, Communications, Control and Power Engineering, 3, 28-31 Ekim 2002, 1302 – 1305.
115. Kerstetter, T., Massey, S., Roberts, J., 1999, "Recursively partitioning neural networks for radar target recognition", Neural Networks, 1999. IJCNN '99. International Joint Conference on, 5, 10-16 Temmuz 1999, 3208 – 3212.
116. Xiaojian, X., A., G., 1996, "Constantinides.:Aircraft identification using a multi-stage fuzzy neural network", Radar, 1996. Proceedings., CIE International Conference of , 8-10 Ekim 1996, 151 – 155.
117. Van Kempen, L., Sahli, H., Nyssen, E., Cornelis, J., 1998, "Signal processing and pattern recognition methods for radar AP mine detection and identification", Detection of Abandoned Land Mines, 1998. Second International Conference on the (IEE Conf.Publ.No.458), 12-14 Ekim 1998, 81 – 85.
118. Leung, H., 1995, "An intelligent radar recognition system for surveillance", Systems, Man and Cybernetics, 1995. 'Intelligent Systems for the 21st Century', IEEE International Conference on, 3, 22-25 Ekim 1995, 2280 – 2285.
119. Ulug, B., Ahalt, S., C., Mitchell, R., A., 1997, "Efficient ATR using compression", Aerospace and Electronic Systems, IEEE Transactions on, 33, 4, Ekim 1997, 1199 – 1211.
120. Jacobs, S., P., O'Sullivan, J., A., 1997, "High resolution radar models for joint tracking and recognition", Radar Conference, 1997., IEEE National , 13-15 Mayıs 1997, 99 – 104.
121. Quincy, E., A., Stafford, R., B., Holloway, C., L., Cotton, M., G., Ali, A., S., 1997, "Distortion measures for wavelet compression of SAR images in ATR", Communications, Computers and Signal Processing, 1997. '10 Years PACRIM 1987-1997 - Networking the Pacific Rim'. 1997 IEEE Pacific Rim Conference on, 1, 20-22 Ağustos 1997, 310 – 317.
122. Le-Tien, T., Nguyen, T., D., 1997, "A transformed image processing approach based on the continuous wavelet transform for non-dispersive scattering extraction TENCON '97. IEEE

Region 10 Annual Conference. Speech and Image Technologies for Computing and Telecommunications', Proceedings of IEEE, 1, 2-4 Aralık 1997, 311 – 314.

123. Mullen, L., Yost, T., Herczfeld, P., R., Allocca, D., Contarino, V., M., 1995, "Hybrid lidar-radar system for ocean experimentation", OCEANS '95. MTS/IEEE. 'Challenges of Our Changing Global Environment'. Conference Proceedings., 1, 9-12 Ekim 1995, 305 – 308.
124. Drumheller, D., M., Glasser, M., L., 1997, "Detection of chi-square fluctuating targets in arbitrary clutter", Aerospace and Electronic Systems, IEEE Transactions on, 33, 3, Temmuz 1997, 784 – 794.
125. Chant, I., J., Rye, A., R., 1996, "Overview of current radar land mine detection research at the Defence Science and Technology Organisation", Salisbury, South Australia The Detection of Abandoned Land Mines: A Humanitarian Imperative Seeking a Technical Solution, EUREL International Conference (Conf. Publ. No. 431), 7-9 Ekim 1996.
126. Benitz, G., R., 1997, "High-definition vector imaging for synthetic aperture radar", Signals, Systems & Computers, 1997. Conference Record of the Thirty-First Asilomar Conference on, 2, 2-5 Kasım 1997, 1204 – 1209.
127. Parnell, W., C., Copeland, F., 1995, "A unique government capability for supporting ITS technology development", Intelligent Vehicles '95 Symposium., Proceedings of the, 25-26 Eylül 1995, 394 – 399.
128. Xiaojian, X., A., G., 1996, "Constantinides, Aircraft identification using a multi-stage fuzzy neural network", Radar, 1996. Proceedings., CIE International Conference of , 8-10 Ekim 1996, 151 – 155.
129. Skolnik, M., 1997, "Spaceborne radar for the global surveillance of ships over the ocean", Radar Conference, 1997., IEEE National , 13-15 Mayıs 1997, 120 – 125.
130. Ciboci, J., W., 1998, "Over-the-horizon radar surveillance of airfields for counterdrug applications", Aerospace and Electronic Systems Magazine, IEEE, 13, 1, Ocak 1998, 31 – 34.
131. Mengdao, X., Zheng B., 2000, "One dimensional cross-range imaging and methods to improve the resolution of low resolution radar targets", National Aerospace and Electronics

Conference, 2000. NAECON 2000. Proceedings of the IEEE 2000 , 10-12 Ekim 2000, 645 – 652.

132. Türkoğlu, İ., 2002, “Durağan Olmayan İşaretler İçin Zaman-Frekans Entropilerine Dayalı Akıllı Örüntü Tanıma”, Fırat Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, s.s. 112.
133. Mertins, A., 1999, *Signal Analysis*. John Wiley & Sons, Avustralya, 329s.
134. Vaseghi, S.V., 2000, *Advanced Digital Signal Processing and Noise Reduction*. John Wiley & Sons, İngiltere, 495s.
135. Hopgood, J.R., 2000, “Nonstationary signal processing with application to reverberation cancellation in acoustic environments”, Doktora Tezi, Cambridge Üniversitesi, 391s.
136. Rothe, H., 1998, “Approaches to pattern recognition, advanced pattern recognition techniques”. NATO-RTO Lecture Series 214, Lisbon Portugal, 1.1 – 1.29.
137. Duda, R.O. and Hart, P.E., 1989, *Pattern Classification and Scene Analysis*. Stanford Research Institute, 483s.
138. 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.
139. 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).
140. 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.
141. Sowelam, S.M. ve Tewfik, A.H., 2000, “Waveform selection in radar target classification”, IEEE Transactions on Information Theory, 46, 1014 –1029.
142. Chau, T., 1994, “Pattern recognition of processed EMG signals for two-site Myoelectric control”, Uygulamalı Master Lisans Tezi, Toronto Üniversitesi, 96s.

143. Kil, D.H. ve Shin, F.B., 1996, *Pattern Recognition and Prediction with Applications to Signal Characterization*. AIP Press, USA, 417s.
144. Rutledge, G.A., 2000, "Dictionary Projection Pursuit: A wavelet packet technique for acoustic spectral feature extraction", Doktora Tezi, Victoria Üniversitesi, 193s.
145. Englehart, K., 1998, "Signal Representation for Classification of the Transient Myoelectric Signal", Doktora Tezi, New Brunswick Üniversitesi, Kanada, 319s.
146. Young, T.Y. and Fu, K.S., 1986, *Handbook of pattern recognition and image processing*. Academic Press, Inc, 159s.
147. Banks, S.P., 1990, *Signal Processing, Image Processing and Pattern Recognition*, Prentice-Hall, New York, 409s.
148. 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.
149. 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.
150. Shannon, C.E., 1948, "A mathematical theory of communication", *Bell System Technology Journal*, 27, 379-423.
151. Tonga, S., Bezerianosa, A., Paula, J., Zhub, Y. and Thakora, N., 2002, "Nonextensive entropy measure of EEG following brain injury from cardiac arrest", *Elsevier Physica A*, 305, 619 – 628.
152. Principe, J.C., Euliano, N.R. and Lefebvre, W.C., 2000, *Neural and Adaptive Systems*. John Wiley & Sons, 1. Baskı, New York, 656s.
153. Overwijk, M.H.F. and Reefman, D., 2000, "Maximum-entropy deconvolution applied to electron energy-loss spectroscopy", *Pergamon Micron*, 31, 325-331.

154. Li, X., 2000, "Edge directed statistical inference with applications to image processing", Doktora Tezi, Princeton Üniversitesi, 131s.
155. 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.
156. Hoang, M., Aaron, R. and Shiffman, C.A., 1997, "Maximum entropy method for Magnetoencephalography", IEEE Transactions on Biomedical Engineering, 44,1,98-102.
157. Coifman, R.R. and Wickerhauser, M.V., 1992, "Entropy-based algorithms for best basis selection", IEEE Transaction on Information Theory, 38, 2, 713-718.
158. Penny, W.D., 2000, "Signal Processing Course," 28 Nisan 2000, 178s.
159. Cheng, H., D., Chen, J., Li, J., 1998, "Threshold Selection Based on Fuzzy c-Partition Entropy Approach", Pattern Recognition, Elsevier Science Ltd, 31, 7, s.s.857-870.
160. http://www.pages.drexel.edu/~weg22/can_tut.html
161. Kulkarni, A., D., 2001, Computer Vision and Fuzzy – Neural Systems, Prentice Hall PTR, USA, s.s. 509.
162. Rajan, J.J., 1994, "Time series classification", Doktora Tezi, Cambridge Üniversitesi, 191s.
163. Elmas, Ç., 2003, Bulanık Mantık Denetleyiciler, Seçkin Yayınları, Ankara, s.s. 230.
164. Jang, J. S. R., Sun, C. T., "Neuro-Fuzzy Modeling and Control", proceedings of the IEEE. vol. 83, No. 3, 1995.
165. Sağiroğlu, Ş., Beşdok, E., Erler, M., 2003, Mühendislikte Yapay Zeka Uygulamaları-I Yapay Sinir Ağları, Ufuk Kırtasiye – Yayıncılık Tic. Ltd. Şti. s.s. 254.
166. Turkoglu, I., Arslan, A., Ilkay, E., 2003, "An Intelligent system for diagnosis of the heart valve diseases with wavelet packet neaural networks", Computer in Biology and Medicine 33, s.s. 319-331.

167. Boashash, B., 1992, Time-Frequency Signal Analysis Methods And Applications, Longman Cheshire, Wiley Halsted Press, Hong Kong, s.s. 544.
168. Jang, J. S. R., 1993, "ANFIS: Adaptive network-based fuzzy inference systems", IEEE, Trans. Syst., Man. and Cybern., 23, s.s. 665-685.
169. Avci, E., Turkoglu, I., 2003, "Modeling of Tunnel Diode by Adaptive-Network-Based Fuzzy Inference System", International Journal of Computational Intelligence , ISSN 1304-2386, 1, 1, s.s. 231-233.
170. Ho, D.W.C., Zhang, P., Xu, J., 2001, Fuzzy wavelet networks for function learning, Fuzzy Systems, IEEE Transactions on , 9, 1, Şubat 2001, 200 -211.
171. Guler, I., Ubeyli, E., D., 2004, "Application of adaptive neuro-fuzzy inference system for detection of electrocardiographic changes in patients with partial epilepsy using feature extraction", Expert Systems with Applications, 27, 3, s.s. 323-330.
172. Ersahin, K., Yazgan, B., 2001, "Satellite Image Fusion With Wavelet Decomposition", Eleco 2001 International Symposium Bursa, Turkey.
173. Famili, A., Wei-Min, S., Weber, R., Simoudis, E. 1997, "Data preprocessing and intelligent data analysis," *Intell. Data Anal.*, 1.
174. Türkoğlu, İ., Arslan, A., İlkay, E., 2003, "A Computer Aided Method for Diagnose of The Heart Mitral Valve Diseases", International Journal for Engineering Modelling . Haziran, 15 1-4 , 1-9.
175. Avcı, E., Türkoğlu, İ., Poyraz, M., 2005, "Intelligent Target Recognition on Based Wavelet Packet Neural Network", Elsevier Expert Systems with Applications , 29(1) , (baskıda).
176. Avcı, E., Türkoğlu, İ., Poyraz, M., 2005, "Intelligent Target Recognition on Based Wavelet Adaptive Network Based Fuzzy Inference System", 2nd Iberian Conference on Pattern Recognition and Image Analysis, Portekiz 7-9 Haziran. (Kabul edilmiştir.)
177. Avcı, E., Türkoğlu, İ., Poyraz, M., 2005, "A New Approach Based On Scalogram For Automatic Target Recognition With X-Band HRR Doppler Radar", Asian Journal of Information Technology, 4, 1, s.s. 133-140.

178. Avcı, E., Türkoğlu, İ., Poyraz, M., 2004, “Darbeli Radar Sistemlerinde Bayes Karar Kuralı İle Hedef Sınıflama Uygulaması”, Doğu Anadolu Bölgesi Araştırmaları Dergisi (DAUM), Şubat, 2, 2, s.s. 25-29.
179. Avcı, E., Türkoğlu, İ., Poyraz, M., 2005, “Kalman Filtresinin Radar Hedef İzlemedeki Performans Analizi”, Fırat Üniversitesi Fen Bilimleri Dergisi, 16(4), s.s. 679-686.
180. Avcı, E., Türkoğlu, İ., Poyraz, M., 2005, “Darbeli Radar Sistemlerinde Geliştirilen Periodogram Çıkarımlı Akıllı Hedef Tanıma”, Gazi Üniversitesi Fen Bilimleri Dergisi (Kabul edilmiştir.)
181. Avcı, E., Türkoğlu, İ., Poyraz, M., 2004, “A New Approach For Automatic Target Recognition With X-Band Doppler Radar”, Creating Future 3rd FAE International Symposium, European University of Lefke, TRNC, 25-26 Kasım, s.s. 359-364.
182. Avcı, E., Türkoğlu, İ., Poyraz, M., 2005, “Wigner-Ville Zaman- Frekans Dağılımı Kullanılarak Geliştirilen Bir Akıllı Hedef Tanıma Yöntemi, IEEE 13. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU 2005), Kayseri.
183. Türkoğlu, İ., 1996, “Yapay sinir ağları ile nesne tanıma”, Yüksek Lisan tezi, Fırat Üniversitesi, Elazığ.
184. Türkoğlu, İ., 1999, “Örüntü Tanıma Yöntemlerinin İncelenmesi”, Doktora Semineri, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.

EK – 1

Kullanılan Lab-Volt Radar Deney Setinin Teknik Özellikleri

Çalışma modları : Darbeli Dalga Modu (Palslı Mod), Sürekli Dalga Modu (CW Mod), Frekans Modülasyonlu Sürekli Dalga Modu (FM-CW Mod)

Radar Setinin Teknik Özellikleri:

- Deney setinin çıkış gücü : 5 mW.
- Darbe tekrarlama hızları : 12 Hz, 18 Hz, 144 Hz, 216 Hz, 288 Hz.
- RF Osilatör Frekansı : 8-10 GHz arasında değişken mod, 9.4 GHz. De ise sabit mod.
- Eko çıkış kanal sayısı : I ve Q kanalları olmak üzere iki kanal.
- Darbe üretici darbe genişlik seçenekleri : 1 ns, 2 ns, 5ns sabit, 1-5 ns değişken.
- Hedef mesafe ayarı : 1.8 m, 3.6 m, 7.2 m.

Radar Vericisi, Model 9620 Teknik Özellikleri:


Test Noktası	Açıklama
TP1	İzolatör Çıkışı
TP2	Yöneltmeli Bağlayıcı Girişi
TP3	CW/FM-CW RF Çıkışı
TP4	RF Osilatör Çıkışı

Radar Alıcısı, Model 9621 Teknik Özellikleri:

Test Noktası	Açıklama
TP1	RF Girişi
TP2	Lokal Osilatör Girişi
TP3	1 KHz Alt Geçirim Filtre Girişi
TP4	CW Doppler Çıkışı
TP5	1 KHz Üst Geçirim Filtre Girişi
TP6	FM-CW Çıkışı


EK – 2

Radar Deney Seti Modülünün Kurulumu



EK – 3

Lab-Volt Radar Deney Setinin Kalibrasyonu İçin Kullanılan Deney Düzenek Blok Şeması



EK-4



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




EK-5

Kullanılan Lab-Volt Radar Deney Setinin Fotoğrafları -I



EK-6

Kullanılan Lab-Volt Radar Deney Setinin Fotoğrafları –II



ÖZGEÇMİŞ

Engin AVCI

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

Tel: 424 – 2370000 – 6558
E.posta: enginavci@firat.edu.tr

- 1978** Elazığ ‘da doğdu.
- 1992 – 1995** Elazığ Mehmet Akif Ersoy Lisesini tamamladı.
- 1996 – 2000** Fırat Üniversitesi Teknik Eğitim Fakültesi Elektronik – Bilgisayar Eğitimi Elektronik Öğretmenliği Bölümünden mezun oldu.
- 2000 – 2002** Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik – Bilgisayar Eğitimi Anabilim Dalında “Anestezi Alanında Bulanık Mantık Uygulamaları” konusunda yaptığı tez çalışması ile Yüksek Lisans derecesini aldı.
- 2000 – 2005** Fırat Üniversitesi, Teknik Eğitim Fakültesi Elektronik-Bilgisayar bölümünde araştırma görevlisi olarak çalıştı.
- 2005 –** Fırat Üniversitesi, Teknik Eğitim Fakültesi Elektronik-Bilgisayar bölümünde öğretim görevlisi olarak çalışmaktadır.
- 2003 –** Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik – Elektronik Mühendisliği Anabilim Dalında doktora tez çalışmasına başladı.