

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ENDOSKOPIK GÖRÜNTÜLERİN
DEĞERLENDİRİLMESİNDE GÖRÜNTÜ İŞLEME
TEMELLİ AKILLI KARAR DESTEK SİSTEMİ**

Abdulkadir ŞENGÜR

Tez Yöneticisi
Yrd. Doç. Dr. Melih C. İNCE
Yrd. Doç. Dr. İbrahim TÜRKOĞLU

DOKTORA TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ELAZIĞ, 2006

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ENDOSKOPIK GÖRÜNTÜLERİN
DEĞERLENDİRİLMESİNDE GÖRÜNTÜ İŞLEME
TEMELLİ AKILLI KARAR DESTEK SİSTEMİ**

Abdulkadir ŞENGÜR

Doktora Tezi
Elektrik-Elektronik Mühendisliği Anabilim Dalı

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

Danışman: Yrd. Doç. Dr. Melih C. İNCE

Üye:

Üye:

Üye:

Üye:

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

İÇİNDEKİLER

Sayfa

TEŞEKKÜR

İÇİNDEKİLER	I
ŞEKİLLER LİSTESİ.....	IV
TABLolar LİSTESİ.....	VII
EKLER LİSTESİ.....	VIII
KISALTMALAR LİSTESİ.....	IX
SİMGELER LİSTESİ.....	XI
ÖZET	XIII
ABSTRACT	XV

1. GİRİŞ	1
1.1. Amaç	1
1.2. Literatür Taraması ve Değerlendirilmesi	2
1.3. Tezin Organizasyonu ve Orijinal Katkıları	6
2. GÖRÜNTÜ BÖLÜTLEME.....	8
2.1. Görüntü Bölütleme Yöntemlerinin Sınıflandırılması	8
2.1.1. Problem Yönelimli Yöntemler	8
2.1.2. Bilgi Tabanlı Yöntemler	9
2.1.3. Model Tabanlı Yöntemler	10
2.1.4. Genel Yöntemler	10
2.1.5. Bölge Temelli Yöntemler.....	11
2.1.6. Sınır Temelli Yöntemler	12
2.1.7. Ölçüm Uzayı Temelli Yöntemler	12
2.1.8. Hibrit Yöntemler	14
3. ÖRÜNTÜ TANIMA.....	15
3.1. Özellik Çıkarma	16
3.1.1. Dalgacık Dönüşümü	17
3.1.2. Sürekli Dalgacık Dönüşümü	18
3.1.3. Entropi Hesaplama Teknikleri	19
3.1.4. Enerji Hesaplama Teknikleri.....	21

3.1.5. Eş-Oluşum Matrisi	22
3.2. Sınıflandırma.....	25
3.2.1. Yapay Sinir Ağı Sınıflandırıcıları	26
3.3. Eğitici-siz Sınıflandırıcılar	31
3.3.1. Klasik C-Ortalama	31
3.3.2. Bulanık C-Ortalama	33
3.3.3. Geçerlilik Ölçütü.....	34
3.3.4. Kohonen Ağları	37
3.3.5. Ortalama Kaydırma Kümeleme Algoritması	40
 4. POISSON MARKOV RASSAL ALANLARI İLE EĞİTİCİ-SİZ	
GÖRÜNTÜ BÖLÜTLEME.....	42
4.1. Görüntü Bölütleme Modeli	44
4.2. İteratif Şartlı Kipler	46
4.3. Beklentilerin Maksimizasyonu İle Parametre Tahmini.....	46
4.4. Uygulama Sonuçları ve Değerlendirme Kriteri	48
 5. DALGACIK DÖNÜŞÜMÜ EŞ-OLUŞUM MATRİSLERİNİN İSTATİSTİKSEL	
ÖZNETELİKLERİ ve OSİLATÖR SINIR AĞI İLE GÖRÜNTÜ BÖLÜTLEME.....	59
5.1. Teorik Bilgiler.....	62
5.1.1. Dalgacık Dönüşümü.....	62
5.1.2. Doku Öznetelik Çıkarımı.....	65
5.1.3. Osilatör Sinir Ağı.....	66
5.2. Önerilen Yöntem.....	68
5.3. Uygulamalar ve Sonuçları.....	70
 6. DALGACIK PAKET SINIR AĞI İLE GÖRÜNTÜ SINIFLANDIRMA.....	76
6.1. Matematiksel Temeller.....	77
6.1.1. Dalgacık Paket Ayrışımı	77
6.1.2. Dalgacık Paket Sinir Ağları	78
6.2. Metodoloji.....	79
6.3. Uygulamalar ve Sonuçları	83
 7. GELİŞTİRİLEN YÖNTEMLERİN ENDOSKOPIK GÖRÜNTÜLERE	
UYGULANMASI.....	86

7.1. Gastrointestinal Sistem Endoskopisi	87
7.1.1. Üst GİS Endoskopisi İncelenmesi	87
7.1.2. Alt GİS Endoskopik İncelenmesi	87
7.1.3. Rektosigmoidoskopi	87
7.1.4. Kolonoskopi	88
7.2. Endoskopik Görüntüleme	88
7.3. Veri Alımı	89
7.4. Ön İşlem Süreci	89
7.5. Bölütleme Algoritmalarının Uygulanması	91
7.5.1. Görüntünün Dalgacık Paket Dönüşüm Ağacından Entropi ve Enerji Hesaplanması	91
7.5.2. Görüntünün Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Özniteliklerin Hesaplanması	93
7.5.3. Yapay Sinir Ağı ile Bölütleme	94
7.6. Değerlendirme Kriteri	107
7.7. Uygulama Sonuçlarının Değerlendirilmesi	113
8. SONUÇ VE DEĞERLENDİRME	118
8.1. Sonuçların Değerlendirilmesi	118
8.2. Öneriler	121
8.3. Yayınlar	122
KAYNAKLAR	123

ÖZGEÇMİŞ

EKLER

ŞEKİLLER LİSTESİ

Şekil 2.1. Gri seviyesi histogramı (a) Tek eşik değeri (b) Çok seviyeli eşik değeri	13
Şekil 3.1. Örüntü tanıma kavramı	16
Şekil 3.2. Yaygın olarak kullanılan dalgacık örnekleri	18
Şekil 3.3. Entropi kavramı : a) Yüksek, b) Düşük	20
Şekil 3.4. Seçilen benek etrafında çeşitli açılar için yönlerin gösterilmesi	23
Şekil 3.5. Akıllı sınıflama yapısı	25
Şekil 3.6. Bir nöron hücresinin matematiksel modeli	27
Şekil 3.7. Yapay sinir ağı örüntü sınıflandırıcıları	30
Şekil 3.8. Kohonen 'in kendi kendini düzenleme haritasının ağı birimleri	38
Şekil 3.9. Kohonen sistem modeli	38
Şekil 3.10. Meksika şapkası fonksiyonu	39
Şekil 3.11. Bir işlem elemanının yapısal komşuluğu ($t_1 < t_2 < t_3$)	39
Şekil 4. 1. Piksel komşulukları	
a-) Matris formatında gösterim b-) Vektör formatında gösterim	44
Şekil 4. 2. Mevcut yöntemle önerilen yöntemin karşılaştırmalı blok diyagramı	49
Şekil 4. 3. (a) Orijinal üç-sınıflı yapay görüntü (b) Histogramı	
(c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu	50
Şekil 4. 4. (a) Orijinal dört-sınıflı yapay görüntü (b) Histogramı	
(c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu	51
Şekil 4. 5. (a) Orijinal görüntü (b) Histogramı	
(c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu	52
Şekil 4. 6. (a) Orijinal ev görüntüsü (b) Histogramı	
(c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu	53
Şekil 4. 7. (a) Gerçek kadın görüntüsü (b) Histogramı	
(c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu	54
Şekil 4. 8. (a) Gerçek el görüntüsü (b) Histogramı	
(c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu	55
Şekil 4. 9. (a) Orijinal hücre görüntüsü (b) Histogramı	
(c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu	56
Şekil 4. 10. (a) SNR = 20 dB gerçek gürültülü görüntü (b) Histogramı	
(c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu	57

Şekil 4. 11. (a) SNR = 10 dB Orijinal gürültülü görüntü (b) Histogramı	
(c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu	58
Şekil 5.1. Önerilen yöntemin blok gösterimi	61
Şekil 5.2. Tek seviyeli dalgacık analiz filtre bankası.....	64
Şekil 5.3. DD ayrışımı (a) Tek seviyeli ayrışım (b) İki seviyeli ayrışım	65
Şekil 5. 4. (a) x-sıfır eğrisi ve y-sıfır eğrisi, (b) 3x 3'lük LEGION yapısı	68
Şekil 5. 5. Orijinal görüntü (b) Yatay Detay (c) Dikey Detay (d) Diyagonal Detay	
(e) Bölütlenmiş mozaik doku 1.....	72
Şekil 5. 6. Özniteliklerin görüntüye dönüştürülmüş durumları.....	72
Şekli 5. 7. Bölütleme sonuçları	75
Şekil 6.1. DPA ile DD ayrışımının ağaç yapısı	78
Şekil 6.2. Dalgacık sinir ağı yapısı	79
Şekil 6.3. Örnek doku görüntüsü (Tuğla duvar)	80
Şekil 6.4. DPSA blok diyagramı.....	81
Şekil 6.5. Orijinal doku görüntüsünün 2 seviyeli dalgacık paket	
ayrışımı ile elde edilen görüntüleri	81
Şekli 6. 6. DPSA eğitim başarımı	83
Şekil 6.7. Kullanılan Brodatz doku örnekleri	85
Şekil 7.1. Geliştirilen yöntemlerin Endoskopik görüntülere uygulama sistemi.....	86
Şekil 7.2. Olympus CV-260 Endoskopi cihazı	90
Şekil 7.3. Kolonoskopik görüntü	90
Şekil 7.4. Ön İşlem Süreci	91
Şekil 7.5. Kırpılmış görüntü	91
Şekil 7.6. Endoskopik bir görüntünün dalgacık paket dönüşüm ile elde edilen alt bantları ...	92
Şekil 7.7. Çok katmanlı ileri beslemeli yapay sinir ağları.....	95
Şekil 7. 8. YSA modelinin eğitim başarımı	97
Şekil 7.9. DPA ağacından entropi ve enerji öznitelikleri ve YSA sınıflandırıcısı	
ile elde edilen uygulama sonuçları (1/3)	98
Şekil 7.9. DPA ağacından entropi ve enerji öznitelikleri ve YSA sınıflandırıcısı	
ile elde edilen uygulama sonuçları (2/3)	99
Şekil 7.9. DPA ağacından entropi ve enerji öznitelikleri ve YSA sınıflandırıcısı	
ile elde edilen uygulama sonuçları (3/3)	100
Şekil 7.10. Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Öznitelikleri ve YSA	
sınıflandırıcısı ile elde edilen uygulama sonuçları (1/6)	101

Şekil 7.10. Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (2/6)	102
Şekil 7.10. Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (3/6)	103
Şekil 7.10. Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (4/6)	104
Şekil 7.10. Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (5/6)	105
Şekil 7.10. Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (6/6)	106
Şekil 7.11. İdeal (a) ve kötü (b) performans göstergesi olan ROC eğrileri	110
Şekil 7.12. Normal dağılım eğrileri, girişim bölgesi ve pozitiflik eşiği seçenekleri.....	111
Şekil 7.13. Örnek kolonoskopik görüntü ve değerlendirme analizi için elde oluşturulan altın standart görüntü (1/2).....	113
Şekil 7.13. Örnek kolonoskopik görüntü ve değerlendirme analizi için elde oluşturulan altın standart görüntü (2/2).....	114
Şekil 7.14 (a) Orijinal görüntü (b) DPA ağacından entropi ve enerji öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonucu (c) Altın Standart görüntü.....	115
Şekil 7.15. Örnek görüntü için DPA entropi ve enerji öznitelikleri kullanılarak yapılan tanı testi sonucu elde edilen duyarlılık ve özgüllük grafiği	116
Şekil 7.16. (a) Orijinal görüntü (b) DD Eş-oluşum matrislerinin istatistiksel öznitelikleri ve YSA sınıflandırıcısı kullanılarak gerçekleştirilen tanı testi sonucu (c) Altın standart görüntü	116
Şekil 7.17. Örnek görüntü için DD Eş-oluşum matrislerinin istatistiksel öznitelikleri ve YSA sınıflandırıcısı kullanılarak yapılan tanı testi sonucu elde edilen duyarlılık ve özgüllük grafiği	117

TABLÖLAR LİSTESİ

Tablo 4. 1. Bölütleme yöntemlerinin başarımı	49
Tablo 6.1. ÇKA'nın yapısal ve eğitim parametreleri	83
Tablo 6.2. Uygulama sonuçları	85
Tablo 7.1. Kullanılan YSA modelinin yapısı ve eğitim parametreleri	97
Tablo 7.2. Karşılaştırma matrisi	107
Tablo 7.3. A tanısı değerlendirme matrisi	109
Tablo 7.4. Örnek görüntü için DP entropi ve enerji öznitelikleri kullanılarak yapılan tanı testi sonucu elde edilen karşılaştırma matrisi	115
Tablo 7.5. Örnek görüntü için DD eş oluşum matrisi öznitelikleri kullanılarak yapılan tanı testi sonucu elde edilen karşılaştırma matrisi	117

EKLER LİSTESİ

EK-1 : Evis Lucera Olympus CV-260 Endoskop

SİMGELER LİSTESİ

x	i) Durağan olmayan işaret, ii) Gerçek giriş uzayındaki gözlemler veya ölçümler
y	i) Çıkış sınıfları, ii) Karar uzayı
$w^{(k)}$	Karar uzayındaki her bir sınıf
F	Giriş ve karar uzayı arasındaki özellik uzayı
(x,y)	Eğitim çifti
$\mathfrak{I}$	Eğitim kümesi
ϕ	Sınıflandırıcının adaptif parametreler kümesi
J	Amaç fonksiyonu
$E[.]$	Sınıflandırma hatası
$f(.)$	Yaklaşım fonksiyonu
ξ	Test etme girişleri
Ψ	Eğitim girişi
Ω_{Ψ}	İstenen çıkış
$\Delta\phi$	Düzenlenen kurallar
$T[.]$	Eğitimin şartlar kümesi
w_{ij}	Yapay sinir ağı ağırlıkları
$T_x(t,f)$	Zaman – frekans gösterimi
$E(s)$	Entropi ifadesi
ε	i) Entropi eşik değeri, ii) Momentum katsayısı
θ_i	i. işlem elemanının eşik değeri
$a(.)$	Etkinleştirme fonksiyonu
$\psi(t)$	Dalgacık fonksiyonu
m	Dalgacık ayrışım seviyesi
A	Dalgacık ayrışımının yaklaşık katsayısı
H	Dalgacık ayrışımının detay katsayısı (Horizontal)
D	Dalgacık ayrışımının detay katsayısı (Diagonal)
V	Dalgacık ayrışımının detay katsayısı (Vertical)
$h[n]$	Yüksek geçiren filtre
$g[n]$	Alçak geçiren filtre
$X(f)$	İşaretin Fourier dönüşümü
$F(.)$	Dalgacık sinir ağı etkinleştirme fonksiyonu
$t_k, 2^k$	Dalgacık fonksiyonunun parametreleri

d	Giriş örüntüsüne karşı istenen çıkış
p	Norm entropi parametresi
sse	Toplam karesel hata
ED	Dalgacık sinir ağının entropi döngüsü
SNR	İşaret gürültü oranı
h_j	Çok katmanlı yapay sinir ağında j. ara katmanın hatası
α	Öğrenme oranı

KISALTMALAR LİSTESİ

ADD	Ayrık Dalgacık Dönüşümü
CE	Classification Entropy (Sınıflandırma Entropisi)
ÇKA	Çok Katmanlı Algılayıcı
DD	Dalgacık Dönüşümü
DPA	Dalgacık Paket Analizi
DPD	Dalgacık Paket Dönüşümü
DPSA	Dalgacık Paket Sinir Ağı
DSA	Dalgacık Sinir Ağı
DSP	Digital Signal Processing (Sayısal İşaret İşleme)
DVM	Destek Vektör makinesi
EM	Expectation Maximization (Beklentilerin Maksimizasyonu)
FCM	Fuzzy C- Means (Bulanık C- Ortalamalar)
GA	Genetik Algoritma
GİS	Gastrointestinal Sistem
GMRA	Gauss Markov Rassal Alanları
GN	Gerçek Negatifler
GP	Gerçek Pozitifler
HFD	Hızlı Fourier Dönüşümü
ICM	Iterated Conditional Modes (İteratif Şartlı Kipler)
LDA	Linear Discriminate Analysis (Doğrusal Ayrışım Analizi)
LEGION	Locally Excitatory Globally Inhibitory Oscillator Networks
YUKİOSA	Yerel Uyartımlı Küresel İnhibitörlü Osilatör Sinir Ağı
KZFD	Kısa Zamanlı Fourier Dönüşümü
MRA	Markov Rassal Alanları
MRF	Markov Random Fields
MR	Manyetik Rezonans
PMRA	Poisson Markov Rassal Alanları
PE	Proportion Exponent (Orantı Üssül)
PC	Partition Coefficient (Bölüm Katsayısı)
PCA	Principle Component Analysis (Temel Bileşen Analizi)
ROC	Receiver Operating Curve (Alıcı İşletme Eğrileri)
SDD	Sürekli Dalgacık Dönüşümü
SOM	Self Organizing Maps (Kendinden Organize Haritalar)

YP	Yanlış Pozitifler
YN	Yanlış Negatifler
ZFG	Zaman Frekans Gösterimi

ÖZET

DOKTORA TEZİ

ENDOSKOPIK GÖRÜNTÜLERİN DEĞERLENDİRİLMESİNDE GÖRÜNTÜ İŞLEME TEMELLİ AKILLI KARAR DESTEK SİSTEMİ

Abdulkadir ŞENGÜR

Fırat Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik – Elektronik Mühendisliği Anabilim Dalı

2006, Sayfa: 133

Teknolojinin gelişmesi ile bir çok alanda akıllı tanı sistemleri önem kazanmış ve bu sistemlerin temelini örüntü tanıma oluşturmaktadır. Örüntü tanıma, bilinmeyen örüntü şekillerini belirli bir sınıfa dahil ederek tanımlamak ve bilinen bir sınıfa ait olan örüntüyü teşhis etmektir. Örüntü tanıma; iki önemli aşamadan oluşmaktadır. Bunlar; öznitelik çıkarıcı ve sınıflandırıcıdır. Görüntü bölütleme, bir örüntü tanıma sisteminin öznitelik çıkarımı aşamasına dahildir. Görüntü bölütleme, örüntü tanıma sistemleri için oldukça önemlidir. Çünkü sınıflandırıcının başarısı doğrudan bölütlemenin başarımına bağlıdır.

Bu tez çalışmasında, gri seviyesi ve renkli görüntülerin bölütlenmesinde üç farklı yöntem önerilmiştir;

1. Gri seviyesi görüntülerin bölütlenmesi için Poisson olasılık yoğunluk fonksiyonu kullanan bir MRA (Markov Rassal Alanları) yapısı önerilmiştir.
2. Özellik çıkarım sürecini de içeren ve sınıflayıcının eğitim başarımına göre özellik uzayını uyarlayabilen entropi tabanlı dalgacık sinir ağı yapısı, görüntülere de uygulanabilmesi için yeniden düzenlenmiştir. Entropi özniteliklerinin yanı sıra enerji öznitelikleri de sisteme eklenerek daha dayanıklı ve etkili bir sistem geliştirilmiştir.
3. Dalgacık ayrışımı ve osilator sinir ağı yapısını kullanarak eğitici olarak görüntü bölütlenmesini sağlayan yeni bir sistem önerilmiştir. Sistemin en büyük avantajı eğitici örüntülü tanıma sistemlerindeki gibi eğitim verisine ihtiyaç duymaksızın istenilen bölütlemeyi doğru olarak gerçekleştirebilmesidir.

Önerilen öznitelik çıkarım yöntemleri ile eğitici YSA yapısı kolonoskopik video görüntülerden normal ve ab-normal (polip) dokuların teşhisi üzerine uygulaması yapılmıştır.

Dalgacık paket entropi ve enerji öznitelikleri ile yapay sinir ağı sınıflandırıcısı kullanılarak gerçekleştirilen uygulamalar da ortalama % 86.2 duyarlılık ve % 85.7 kesinlik değerleri elde edilirken, dalgacık dönüşümü eş oluşum matrislerinin istatistiksel öznitelikleri ile yapay sinir ağı sınıflandırıcısı kullanılarak gerçekleştirilen uygulamalar da ise ortalama % 90.2 duyarlılık ve % 88.7 kesinlik değerleri elde edilmiştir.

Anahtar Kelimeler : Örüntü tanıma, özellik çıkarma, akıllı tanı sistemi, dalgacık dönüşümü, görüntü bölütleme teknikleri, endoskopik görüntüler, yapay sinir ağları, osilatör sinir ağı, dalgacık sinir ağı.

ABSTRACT

PhD Thesis

AN INTELLIGENT DECISION SUPPORT SYSTEM BASED ON IMAGE PROCESSING FOR EVALUATING OF THE ENDOSCOPIC IMAGES

Abdulkadir ŞENGÜR

Firat University

Graduate School of Natural and Applied Sciences

Department of Electrical - Electronics Engineering

2006, Page: 133

Intelligent recognition systems have gained importance in various areas with the technological developments, and pattern recognition constitutes the bases of these systems. Pattern recognition is to recognize unknown patterns by assigning them into a known class or known patterns belonging to a known class. Pattern recognition includes two steps: Feature extraction and classification. Image segmentation is considered at the feature extraction stage of a pattern recognition system. Thus, image segmentation is important for subsequent pattern recognition processes. Its performance directly affects the performance of the subsequent classification procedure.

In this thesis, three various techniques were proposed for gray and color image segmentation.

1. A MRF (Markov Random Fields) model which uses Poisson probability density function for gray level image segmentation, is proposed.
2. Entropy based wavelet packet neural networks architecture which contain feature extraction period and update the features according to the performance of the classifier was modified as it can be used on images. Beside entropy features, energy feature were embedded for robust and efficient system development.
3. A new unsupervised system was proposed which uses wavelet transform and oscillator neural networks architecture. The most important advantage of the proposed system is that it achieves the desired segmentation process without any training samples as needed in the supervised pattern recognition systems.

The proposed feature extraction mechanisms and the supervised neural networks architecture were used for detection of normal and abnormal (polyp) formations at the endoscopic video frames. 86.2 % sensitivity and 85.7 % specificity values were obtained when wavelet packet entropy and energy features with the supervised neural networks were used. We also obtained 90.2 % sensitivity and 88.7 % specificity values by using statistical features of the wavelet transform co occurrence matrices and neural networks.

Keywords : Pattern recognition, feature extraction, intelligent diagnosis system, wavelet transform, image segmentation techniques, endoscopic images, artificial neural networks, oscillator neural networks, wavelet neural networks.

1. GİRİŞ

Görüntü bölütleme, görüntüyü birbiriyle örtüşmeyen fakat görüntünün tamamını içerecek homojen alt bölgelerine veya nesnelere ayırma işlemidir. Bu ayırma işlemi, görüntünün belirli bir veya birden fazla özelliği dikkate alınarak gerçekleştirilebilmektedir. Bu özellik veya özelliklerin seçimi, yapılacak uygulamaya ve kullanılan görüntülere bağlı olarak değişiklikler gösterebilir. Bu özelliklerden en önemlisi, gri seviyesi görüntüler için parlaklık, renkli görüntüler için ise renk bileşenleridir (Kırmızı, Yeşil ve Mavi). Ayrıca görüntülerdeki doku (texture) özelliği de bölütleme açısından oldukça yararlı bilgiler içermektedir.

Literatürde, görüntü bölütleme ile ilgili birçok yöntem mevcuttur. Bölütleme ile ilgili standart bir yöntem bulunmamakla birlikte, sezgisel ya da uygulamaya özgü temel yöntemler ile bölütleme işlemi gerçekleştirilmektedir. Bunlardan farklı olarak, görüntü bölütlemeyi matematiksel bir modele uyarlamayı amaçlayan çalışmalarda bulunmaktadır. Bölütleme işlemi sonucunda elde edilen bölütlerin gerçek görüntüdeki belirgin nesnelere karşı düşmesi gerekmektedir. İyi bölütlenmiş bir görüntünün özellikleri Haralick ve Shapiro tarafından şöyle sıralanmıştır [1];

- Bölütlenmiş görüntüdeki her bir bölüt homojen özellik göstermeli ve herhangi iki bölüt birbiri ile kesinlikle örtüşmemelidir.
- Bölütler küçük delikler içermemelidir.
- Bölüt sınırları basit olmalı, girinti çıkıntı olmamalı ve bölüt sınırları uzamsal (spatial) olarak doğru konumda bulunmalıdır.

1.1. Amaç

Bu tezin temel amacı, gri seviyesi, renkli ve dokulu görüntüler için bölütleme yapmaya yönelik güçlü ve tümleşik akıllı bir görüntü tanıma sistemi geliştirmektir. Bunun için iki farklı öznetelik çıkarım algoritması önerilmiş ve çıkarılan özneteliklerin etkinliği yapay sinir ağı ve osilatör sinir ağı görüntü sınıflandırıcıları kullanılarak test edilmiştir. Ayrıca, gri seviyesi görüntülerin bölütlenmesi için literatürde sıkça kullanılan Gauss olasılık yoğunluk fonksiyonu kullanan MRA yapısına alternatif, Poisson olasılık yoğunluk fonksiyonu kullanan bir MRA yapısı oluşturmaktır. Önerilen PMRA yapısının etkinliği, gerçek ve yapay görüntüler üzerinde gerçekleştirilen uygulamalar ile değerlendirilecektir. Ayrıca, önerilen her iki öznetelik çıkarma algoritmaları ve yapay sinir ağı görüntü sınıflandırıcısı, endoskopik video görüntülerinde ab-

normal dokuların tespiti için doktora yardımcı akıllı bir karar destek sisteminin tasarlanması amaçlanmaktadır.

1.2. Literatür Taraması ve Değerlendirilmesi

Literatürde en sık rastlanılan bölütleme yöntemlerinden biri görüntünün sadece parlaklık bilgisini göz önüne alarak bölütlemeyi gerçekleştiren, eşikleme işlemidir. Eşikleme, incelenen görüntüye bağlı olarak görüntünün iki (ikili eşikleme) ya da daha fazla (çoklu eşikleme) gri-seviye grubuna ayrıştırılmasıdır. Diğer bir tanımlama ile eşikleme işlemi, görüntünün gri-seviye ya da renkli olmasına bağlı olarak parlaklık ya da renk bileşenlerindeki değişime bağlı olarak bölütleme işleminin gerçekleştirildiği bir yöntemdir. Eşikleme işleminin başarımı daha sonraki görüntü işleme yöntemlerinin başarımını doğrudan etkilediği için eşik değeri seçimini otomatik olarak gerçekleştiren yöntemler literatürde önerilmiştir;

Otsu-1979'da görüntü bölütleme probleminin çözümü için bir ayırt etme kriteri (discriminant criterion) önermiştir [2]. Önerdiği bu yöntemi orijinal görüntü ile bölütlenmiş görüntü (ikilik görüntü) arasındaki toplam karesel hatanın minimizasyonu olarak adlandırmıştır. Kittler ve Illingworth, 1985'de önerdikleri yöntemde, görüntü histogramını, görüntüdeki nesne ve arka plan öğelerinin olasılık yoğunluk fonksiyonlarının tespitinde kullanmışlar ve uygun eşik değeri seçimini bu olasılık yoğunluk fonksiyonlarını kullanarak gerçekleştirmişlerdir [3]. Önerilen bu yöntem, aynı zamanda çoklu eşik değeri seçimi içinde kullanılmaktadır. 2 ve 3 kaynak numaralı çalışmalar aynı zamanda histogram kümelemesine dayalı yöntemler olarak da adlandırılırlar. Cho 1988'de, Kittler ve Illingworth tarafından önerilen minimum hata eşikleme yöntemini daha da geliştirmiştir [4]. Kurita ve diğ., 1992, de maksimum olabilirlik eşikleme yöntemi önermiştir [5]. Ayrıca makalede önerilen yöntem, Otsu'nun önerdiği yöntem ve Kittler ve Illingworth'un önerdiği yöntem ile uygulama sonuçları açısından karşılaştırılmıştır. Bongiovanni ve diğ., 1993'de piramit algoritması ile görüntüdeki piksel popülasyonunun iki modlu olup olmadığını incelemişlerdir [6]. Sekita ve diğ. (1994), Kittler ve Illingworth'un önerdiği yöntemde, σ değeri 0 olduğu durumda J_{Kit} değerinin sonsuz olması problemini, önerdikleri farklı bir yöntem ile giderilmiştir [7]. Bu yöntem daha sonra el yazısı karakterlerinin bölütlenmesi için kullanılmıştır. Huang ve diğ. 1995'de herhangi bir giriş görüntüsünün bulanıklık ölçüsünün minimizasyonunu kullanarak eşikleme işlemini gerçekleştiren yeni bir yöntem önermiştir [8]. Li ve diğ. 1997'de iki boyutlu görüntü histogramının, Fisher linear discriminant ile tek boyuta indirgenmesine ve böylece hesaplama yükünün azaltılarak otomatik görüntü eşiklemeyi gerçekleştirmişlerdir [9]. Friel ve diğ. 1999'de rasgele küme teorisini görüntü eşikleme problemine uyarlamışlardır [10]. Bunların dışında, bulanık küme teorisinin

görüntü eşikleme problemine uyarlanması ile ilgili çalışmalara literatürde sıkça rastlanılmaktadır [11–19]. Eğer görüntü histogramı herhangi bir vadi içermiyorsa bu durumda entropi tabanlı yöntemler önerilmiştir [20–40]. Entropi tabanlı çalışmaların bir bölümünde bulanık mantık teorisine dayalı entropi yapısı önerilirken, diğer bir grup çalışma da ise görüntülerin iki boyutlu entropilerine dayalı eşikleme yöntemleri önerilmiştir. Literatürde bulunan bütün görüntü eşikleme tekniklerine genel bir bakış ve değerlendirme (survey) 2004’de Sezgin ve diğ. tarafından gerçekleştirilmiştir [41]. Yine benzer genel bir inceleme Fu ve Mui – 1980, Zhang–1996 ve Pal ve Pal–1993 tarafından gerçekleştirilmiştir [42–44].

Markov rasgele alanlarının görüntü bölütlemeye kullanımı bir hayli ilgi çekmiştir. MRF, hem gri-seviyesi görüntülerin bölütlenmesinde hem de renkli görüntülerin bölütlenmesinde kullanılmıştır [45–50]. Özellikle dokulu (texture) görüntülerin bölütlenmesi için kullanılan model tabanlı yaklaşımlar, MRF modellerini kullanmaya yönelmişlerdir [51–53]. Dokulu görüntülerin bölütlenmesi öznitelik çıkarımını gerektirdiğinden, MRF modellerinin kullanımı büyük avantajlar sağlamaktadır. MRF parametrelerinin tahmini birçok uygulama için hesaplama yükünü artırmaktadır. Yu ve diğ. [54], MRF parametrelerinin tahmini ve bu tahminin daha hızlı yapılması için yeni bir yöntem önermiştir.

Doku, biyomedikal görüntüler, uydu fotoğrafları ve doğa görüntüleri için önemli bir karakteristiktir ve bu görüntülerdeki nesnelerin belirlenmesinde önemli rol oynar [55]. Dokunun görüntüdeki nesnelerin ayrıştırılmasında kullanılan görsel bir öznitelik olduğu bilinmekle birlikte doku, verilen bir komşuluktaki gri seviyesi piksellerin uzamsal dağılımı ile karakterize edilir. Bu nedenle doku noktasal bir olgudan çok bölgesel bir olgudur ve bu özelliği ile görüntü bölütleme için oldukça önemlidir. Doku, farklı örüntülerin ayırt edilmesinde önemli özelliktir. Doku, benzer yapısal özelliklere sahip bölgeleri tanımlamakta kullanılmaktadır. Bu özellikler az yada çok değişim gösteren tekrarlanan bir takım örüntülerdir. Çeşmeli ve diğ., Gauss Markov rasgele alanları ve Gabor filtrelerini kullanarak doku görüntülerinin bölütlenmesini gerçekleştirmişlerdir [56, 57]. Bu çalışmaların her ikisinde de sınıflandırıcı olarak osilator network yapısı kullanılmıştır [58]. Dalgacık dönüşümü kullanılarak gerçekleştirilen doku bölütleme uygulamaları da literatürde mevcuttur [59–63]. Filtreleme yöntemlerin, doku sınıflandırma performansları açısından karşılaştırılması, Chen ve diğ. tarafından gerçekleştirilmiştir [64]. Ayrıca spektral histogram kullanılarak doku sınıflandırma uygulaması da bulunmaktadır [65].

Literatürde yapay sinir ağları (YSA) kullanılarak gerçekleştirilen görüntü bölütleme uygulamaları mevcuttur. Blanz ve Gish [66], görüntü bölütleme için çok katmanlı sinirsel ağlar kullanmıştır. Burada giriş katmanındaki sinir hücresi sayısı, her piksel için giriş özelliği sayısına bağlıdır ve çıkış katmanındaki sinir hücresi sayısı küme sayısına eşittir. Babaguchi [67] eşik

değerli bir görüntü için geriye yayılım ile eğitilmiş çok katmanlı ağları kullanmıştır. Ghosh [68, 69] ise gürültülü bir ortamdan nesne çıkarımı için yoğun etkileşimli bir sinir ağını kullanmıştır. Diğer gürültülü ortamlarda nesne çıkarmayla ilgili etkin algoritma, Hopfield tipi sinirsel ağlardır [70]. Sinir ağının enerji fonksiyonu, gürültülü ortamdan özlü alan çıkarmada ağın kararlı durumunu göz önüne alır. Ong [71], iki adımda kendinden organize ağ (self organizing network-SOM) yapısı kullanarak renkli görüntülerin bölütlemesini gerçekleştirmiştir. Bu çalışmada hem tek boyutlu hem de iki boyutlu Kohonen ağı kullanılmıştır. Bağlaşım (connectionist) yaklaşımı kullanarak görüntü eşikleyen, sinir ağı yapısı ise Chang ve Vinod [72] tarafından önerilmiştir. Terman ve Wang 1995’de nörol osilator network yapısını önermiş ve önerilen bu yöntemin farklı versiyonları farklı görüntülere uygulanarak görüntü bölütleme gerçekleştirilmiştir [73-76].

Renkli görüntülerin bölütlenmesi için Comaniciu ve diğ. [77-80] ortalama kaydırma yöntemi önermişlerdir. Bu yapı eğiticişiz bir kümeleme yapısı olup, uzamsal düzlemde renklerin yoğunluk ve gradientlerine bağlı olarak dayanaklı bir renk sınıflandırıcı yapısı göstermektedir. Önerilen yöntemde L^*a^*b renk uzayı kullanılmıştır.

Rushing ve diğ., birliktelik kurallarını (association rules), doku görüntülerinin bölütlenmesinde kullanmışlardır [81, 82]. Manjunanth ve Ma [83], Gabor filtre bankası kullanarak doku görüntülerinin bölütlenmesini sağlamışlardır.

Genetik Algoritmalar (GA), en iyinin korunumu ve doğal seçilim ilkesinin benzetim yoluyla bilgisayarlara uygulanması ile elde edilen bir arama yöntemidir. Bhandarkar ve diğ. [84], GA ile kenar çıkarma algoritması önermiştir. Chun ve diğ. [85], bulanık ölçüm ve GA kullanarak dayanıklı bir görüntü bölütleme algoritması kullanmıştır. Yoshimura ve diğ. [86], doku görüntülerinin bölütlenmesi için GA tabanlı bir optimizasyon gerçekleştirmişlerdir. Gerçekleştirilen bu çalışmada üç farklı yöntem değerlendirilmiştir. Bunlar; sadece GA yapısı, GA+SOM yapısı ve GA+SOM ve optimum bölüt sayısını da kullanan bir yapıdır.

Görüntü bölütleme yöntemlerinin en çok uygulama bulduğu alanlardan biride tıp alanıdır. Sammouda ve diğ. [87], renkli patolojik akciğer görüntülerinden kanserli hücre çekirdeklerinin belirlenmesi üzerine bir çalışma gerçekleştirmişlerdir. Bölütleme için Hopfield ağı kullanılmıştır. Ringo ve diğ. [88], gastro-intestinal görüntülerin analizi için doku bölütleme tabanlı yöntemleri önermişlerdir. Her bir görüntü önce belirli bir alt görüntü gurubuna ayrıştırılmış daha sonra Gabor filtreleri ve istatistiksel yaklaşımlar kullanılarak öznelik çıkarımı sağlanmıştır. Esgiar ve diğ. [89], kalınbağırsak kanserinin analizi ve teşhisi için yine görüntü bölütleme tekniklerinden faydalanmışlardır. Kanserli ve normal görüntülerin birbirinden ayırt edilmesi için fraktal boyut analizi kullanılmıştır. Krishnan ve diğ. [90], endoskopik görüntülerdeki anormalliklerin tespitinde görüntü bölütleme tekniklerinden

faaydalanmışlardır. Asari [91], yine endoskopik görüntülerin bölütlenmesi için yeni bir bölge genişletme algoritması önermiştir.

Literatürde bulunan görüntü bölütleme yöntemlerinin büyük çoğunluğu gri seviyesi görüntüler için gerçekleştirilmiştir. Önerilen yöntemler bazı değişikliklerle renkli görüntüleri de uygulanabilir hale getirilmiştir. Mena ve diğ. [92], renkli görüntülerin bölütlenmesi için farklı derecelerden istatistik kullanan, eğitici bir bölütleme yöntemi önermişlerdir. Zhang ve diğ. [93], görüntüdeki piksellerin parlaklık değerlerini ve Hue renk bileşenini kullanan bir bölütleme yöntemi önermişlerdir. Bu yöntem, uzamsal düzlemde Hue bileşeni ve parlaklık bilgisinin toplanmasına (clustering) dayanır. Bergman ve diğ. [94]. Görüntü bölütlemenin renkli basım kalitesine etkisini incelemişlerdir. Burada, görüntü bölütleme iki aşamada gerçekleştirilmiştir. Birinci aşamada, görüntü piksellerin kaba bir sınıflandırılması sağlanırken, daha sonra kullanılan bulanık-Kohonen toplama yöntemi ile görüntü bölütleme tamamlanmıştır. Chen ve Lu [95], renk uzayında renk toplayan bir renkli görüntü bölütleme sistemi önermişlerdir. Renk kümeleme işlemi, bulanık üyelik fonksiyonu ve bir amaç fonksiyonu kullanılarak gerçekleştirilmiştir. Renkli görüntülerin bölütlenmesi ile ilgili literatür de var olan tüm yöntemlerin incelenmesi ve değerlendirilmesini içeren bir çalışma Cheng ve diğ. [96] tarafından yapılmıştır. Litertür tarama çalışmaları ışığında şu sonuçlar elde edilmiştir:

- Görüntü bölütleme ile ilgili yapılan ilk çalışmalar çoğunlukla gri seviyesi görüntülerin bölütlenmesine yönelik önerilen yöntemler ve algoritmalarıdır. Bu dönemde en çok kullanılan yöntem eşikleme yöntemidir. Daha sonraları, görüntülerin renk bilgisine dayalı bölütlenmesini amaçlayan bir çok çalışma ortaya konmuştur. Çünkü renk, görüntüleri oluşturan bölgelerin ayırt edilmesinde kullanılan önemli bir bilgidir. Diğer taraftan parlaklık ve renk bilgisine dayalı görüntü bölütlemekten farklı olarak dokulu görüntülerin bölütlenmesi için öznelilik çıkarım yöntemleri önerilmiştir. Dokulu görüntülerden çoklu çözünürlüklü yöntemlerle öznelilik çıkarımı en çok kullanılan yöntemler olarak göze çarpmaktadır. Son zamanlarda ise renk ve doku bilgisini kullanarak bölütleme yapabilen yöntemler en çok dikkat çeken yöntemler olmuşlardır. Önerilen görüntü bölütleme yöntemleri günlük hayatta bir çok alanda uygulama imkanı bulmuştur. Özellikle tıp alanındaki uygulamalarına sıkça rastlanılmaktadır.
- Son yapılan görüntü bölütleme çalışmaları sınıflandırma açısından değerlendirildiğinde bu çalışmalarda genellikle eğitici YSA, olasılıksal sınıflandırıcılar, MRA modelleri mesafe sınıflandırıcıları, en yakın komşuluk ve maksimum olabilirlik yöntemlerinin

kullanıldığı görülmüştür. Eğitici-siz YSA, kümeleme algoritmaları, bulanık kohonen ağı gibi yapıların kullanıldığı çalışmalarda mevcuttur.

1.3. 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, görüntü bölütleme kavramı tanımlanarak, sahip olduğu her bir bileşen açıklanmıştır. Görüntü bölütleme problemlerinin çözümüne yönelik literatürde önerilen yöntemler sınıflandırılmıştır.

Bölüm 3 de, örüntü tanıma kavramı tanımlanarak, sahip olduğu her bir bileşen 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 ikinci aşaması için kullanılan yapay sinir ağı sınıflandırıcıları sistematik bir gösterimle verilmiştir.

Bölüm 4 de, gri seviyesi görüntülerin bölütlenmesi için literatürde sıkça kullanılan Gauss olasılık yoğunluk fonksiyonu kullanan MRA yapısı yerine, Poisson olasılık yoğunluk fonksiyonu kullanan MRA yapısı sunulmuştur. Sunulan yöntemin etkinliği, gerçek ve yapay görüntüler üzerinde gerçekleştirilen uygulamalar ile gösterilmiştir.

Bölüm 5 de, dalgacık dönüşümü ve osilator sinir ağı yapısını kullanarak dokulu görüntülerin eğitici-siz olarak bölütlenmesini sağlayan yeni bir sistem sunulmuştur. Sistemin avantaj ve dezavantajları ve uygulama sonuçları ayrıntılı olarak sunulmuştur.

Bölüm 6 da, öznelilik çıkarım sürecini de içeren ve sınıflayıcının eğitim başarımına göre özellik uzayını uyarlayabilen ve daha önceden kalp Doppler işaretlerinden özellik çıkarımı için geliştirilen entropi tabanlı dalgacık sinir ağı yapısı iki boyutlu görüntüler için yeniden uyarlanmış ve dokulu görüntülerin sınıflandırılmasında kullanılması gösterilmiştir. Önerilen yöntemdeki entropi özneliliklerinin yanı sıra enerji öznelilikleri de eklenerek daha dayanıklı ve etkili öznelilik vektörü oluşturulmuştur. İlgili uygulama sonuçları bu bölümde görülebilir.

Bölüm 7 de, endoskopik video görüntülerinde ab-normal dokuların tespitinde doktora yardımcı akıllı bir karar destek sistemi sunulmuştur. Geliştirilen karar destek sistemi bölüm 5 ve bölüm 6 da verilen öznitelik vektörlerini ve yapay sinir ağı sınıflandırıcısını kullanmaktadır. Sistemin başarımlı değerlendirilmesi ROC (Receiver Operating Curve-Alıcı İşletme Eğrileri) kriteri ile gerçekleştirilmiştir.

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

2. GÖRÜNTÜ BÖLÜTLEME

Görüntü bölütleme, homojen bir küme içerisinde görüntüyü parçalara ayırmadır. Bölütleme sonucu ortaya çıkan bölgeler bölüt olarak adlandırılırlar. Bölütleme sonucunda oluşan bölütler birbirinden bağımsız ve homojendirler. Diğer bir ifade ile bölütleme, birbiriyle örtüşmeyen ve komşu iki bölgenin birleşiminin homojen olmadığı bir işlemdir [97]. Mantıksal olarak bu işlem şöyle tanımlanır;

$$\bigcup_{i=1}^n S_i = F \quad (2.1)$$

$$S_i \cap S_j \neq \emptyset, i \neq j \quad (2.2)$$

$$F = (S_1, S_2, \dots, S_n) \quad (2.3)$$

Burada F ; görüntüyü, S ise homojen bölgeleri göstermektedir. Bölütleme ile ilgili yapılan çalışmaların sınıflandırılması bir alt başlıkta verilmiştir.

2.1. Görüntü Bölütleme Yöntemlerinin Sınıflandırılması

Görüntü bölütleme yöntemleri kabaca problem yönelimli yöntemler ve genel yöntemler olmak üzere iki sınıfa ayrılabilir. Problem yönelimli yöntemler, verilen bir probleme bağlı olarak geliştirilirler. Bu yöntemleri kendi içlerinde iki ana kategoriye ayırmak mümkündür. Bunlar bilgi temelli yöntemler ve model temelli yöntemlerdir. Genel yöntemler ise bölütleme işlemini herhangi bir ön bilgi olmaksızın gerçekleştirirler. Genel yöntemlerde kendi içlerinde dört ana sınıfa ayrılırlar. Bunlar; bölge tabanlı yöntemler, sınır tabanlı yöntemler, ölçüm uzayına bağlı yöntemler ve hibrit yöntemlerdir.

2.1.1. Problem Yönelimli Yöntemler

Problem yönelimli bölütleme yöntemleri, bölütleme işlemini verilen probleme özgü bazı parametreler ve problemle ilgili bilinen ön bilgiler ışığında gerçekleştirirler. Örneğin MR görüntüleri hastadan hastaya çok değişmeyen bir yapıda olup beyin ile ilgili biyolojik bilgiler ve diğer uzman görüşleri bölütleme işleminde kullanılabilir. Problem yönelimli yöntemlerde kendi içinde iki sınıfa ayrılırlar. Bunlar; bilgi tabanlı yöntemler ve model tabanlı yöntemlerdir.

2.1.2.Bilgi Tabanlı Yöntemler

Bu yöntemler daha önceden bilinen ve verilen probleme özgü bazı parametreleri kullanarak bölütleme işlemini gerçekleştirirler. Bölütlemeye kullanılan bu ön bilgiler daha çok insanların verilen probleme ilişkin tecrübelerinden oluşmaktadır. Böylece uzman bir insan tarafından yapılacak bölütlemenin sınırları belirlenebilir. Nazif ve Levine, bu yönteme dayalı bir yaklaşım önermiştir [98]. Önerilen yöntem kural tabanlı bir yöntemdir ve altı ana işlemten oluşmuştur. Bunlar, başlama, çizgi analizi, bölge analizi, alan analizi, yoğunlaşma ve programlamadır. Sistemde iki ayrı hafızadan yararlanılmaktadır. Bunlar kısa dönemli hafıza ve uzun dönemli hafızadır. Kısa dönemli hafıza, giriş görüntüsünü depolarken, uzun dönemli hafıza bölütlemeye kullanılacak kuralları ve genel kontrol parametrelerini saklar. Uzun dönemli hafızada bulunan parametreler ve kurallar üç seviyeden oluşmaktadır. Bunlar; bilgi kuralları, kontrol kuralları ve strateji kurallarıdır. Bilgi kuralları, çizgi, bölge ve alanlar ile ilgilenir. Bu kurallar ayrıca bölge birleştirme, bölge parçalama, çizgi birleştirme ve çizgi genişletme gibi işlemleri de yerine getirirler. Bu işlemler, uzman tarafından sisteme verilen bilgi sayesinde gerçekleştirilir. Örneğin bölge parçalama tekniği ile yapılacak bir bölütleme uygulaması için şu kurallar üretilmiştir.

- EĞER: 1. Parçalanacak bölgenin boyutu küçük değilse,
2. Parçalanacak bölgenin gradienti büyükse,
3. Parçalanacak bölgenin histogramı iki modeli ise
İSE: Verilen bölgeyi histograma uygun olarak bölütle

Burada verilen kurallar dizisi farklı uygulamalar için ayrıca uyarlanabilir. Raya (1990), MR görüntülerinin bölütlenmesi için Nazif ve Levine'nin önerdiği kurallar dizisine benzer kurallar önermiştir [99]. Benzer olarak Darwish ve Jain (1998), baskı devrelerin incelenmesi için bir dizi kural önermiştir [100]. Bu yöntemler morfolojik teknikleri içermelerine rağmen, sistem için gerekli olan kurallar Nazif ve Levine'nin önerdiği yöntemi temel almaktadır.

Bazı akıllı sistemler görüntü işlemede uzman olan kişilerin bilgilerinden doğrudan faydalanarak bölütleme işlemini gerçekleştirirler. Bu sistemler, uygulamaya bağlı olarak uzman görüşü doğrultusunda en uygun görüntü işleme rutinini seçerek istenilen işlemleri gerçekleştirirler.

2.1.3. Model Tabanlı Yöntemler

Diğer problem yönelimli yöntemler ise model tabanlı yöntemlerdir. Bu yöntemler nesnelerin modellerini önceden verilmiş görüntülerin eğitiminden sonra elde ederler. Görüntü modelleme ile verilen bir görüntünün nasıl oluşturulduğunun anlaşılması ve buna bağlı olarak görüntünün birkaç parametre ile karakterize edilmesi sağlanır [101] (Dubes ve Jain, 1989). Bölütlemeye kullanılan modeller ikiye ayrılabilir; bunlar fizik temelli modeller ve stokastik modellerdir.

Fizik temelli modeller, gölge, ışık, yansıma ve doku gibi fiziksel etkilerin modellenmesini kapsar. Bu etkilerin modellenmesi için önceden incelenecek görüntü ile ilgili önceden bilinen bazı parametrelere ve eğitim verilerine ihtiyaç duyulur. Örneğin Healey (1992), metal yüzeyler için di-kromatik yansıma modeli türetmiştir [102]. Önerilen bölütleme yöntemi, metal yüzeydeki oryantasyon değişimlerini ve renkli metal yüzey görüntüsündeki ışık olaylarını göz önüne almaktadır.

Stokastik modeller ise görüntüyü oluşturan bölgelerin piksellerinin veya özniteliklerinin belirli bir olasılık yoğunluk dağılımına sahip olduğu düşüncesini kabul eder ve buradan yola çıkarak bölütleme işlemini gerçekleştirmeyi amaçlar [103]. Gibbs ve Markov rassal alanları bu sınıfa dahil edilirler ve bu yöntemlerin bölütleme işlemine piksellerin uzamsal ilişkilerini dahil etmeleri bu yöntemlerin en önemli avantajlarıdır. Ayrıca Bayes karar teorisi de rassal alan modelleri içersine alınabilir. Bu modellerin tamamında ilkönce bir modelin seçilmesi gerekir. Daha sonra uygulamaya bağlı olarak kullanılacak olasılık dağılım fonksiyonu belirlenmelidir. İkinci olarak, seçilen modele ve olasılık dağılım fonksiyonuna bağlı olarak örnek veriler modelde yerine konarak, rassal alanların gerçekleştirilmesi sağlanmaktadır. Model parametreleri ya eğitim verilerinden tahmin edilebilir yada kullanıcı tarafından girilebilir. Son olarak da girilen verilerin modele uygun olarak ilgili sınıflara atanması gerçekleştirilir. Bu genellikle sonrasal bir olasılık fonksiyonun maksimizasyonu ile sağlanmaktadır.

2.1.4. Genel Yöntemler

Genel yöntemler önceki başlıklarda anlatılan yöntemlerin aksine uygulamaya özel parametreler kullanmazlar. Genel yöntemler bölütlemeyi, bölge tekdüzeliği, kenar süreksizliği vb. sezgisel (heuristic) ve daha çok kabullere dayanan yaklaşımlarla gerçekleştirirler. Bundan dolayı bu yöntemler çoğunlukla önceki bölümde bahsedilen problem yönelimli yöntemlerden bölütleme başarımı açısından daha başarılı sonuçlar üretemezler. Genel yöntemleri dört kategoride incelenir, bu kategoriler şunlardır; bölge temelli, sınır temelli, ölçüm uzayı temelli ve

hibrit yöntemlerdir. Bölge temelli yöntemler, bölütlemeyi, bölütlenecek bölge ile ilgili özellikleri hesaba katarak gerçekleştirmektedirler. Bu yöntemlerde görüntüde bölütlenecek bölgenin ki, bu çoğunlukla görüntüdeki bir nesnedir, homojen ve tekdüze bir yapıda olduğu varsayılır ve piksellerin benzerlikleri kullanılır. Sınır temelli yöntemler, bölge temelli yöntemlerin tersine bölgeler arasındaki süreksizliği kullanırlar. Bir görüntüdeki süreksizlik, görüntüdeki farklı nesnelere veya bölgelere işaret eder. Bu süreksizlik noktaları takip edilerek bölge sınırları belirlenebilir. Ölçüm uzayı temelli bölütleme yöntemleri ise bölütlemeyi görüntünün uzamsal ilişkilerinden çok ölçülen niteliklere bağlı olarak gerçekleştirirler. Piksel özniteliklerinin kümeleme algoritmaları ile sınıflandırılması en yaygın örneklerdir. Hibrit yöntemler, daha önce bahsi geçen yöntemlerin birbiri ile bağlantılı olarak kullanıldığı yöntemlerdir.

2.1.5. Bölge Temelli Yöntemler

Bölge temelli yöntemler, uzamsal domende işleyen ve pikseller arasındaki benzerlikleri göz önüne alan yöntemlerdir. Piksellerin benzerliklerini ifade edebilecek dayanıklı ve yeterli bir kriterin belirlenmesi bu yöntemlerin en önemli adımıdır. Bu kriter çoğunlukla ön bir bilgi olarak tanımlanır ve doğrudan bölütleme yapılacak görüntüye bağlı değildir. Bölge temelli yöntemler arasında en çok bilineni bölge büyütme yaklaşımıdır. Bölge büyütme yaklaşımı, verilen bir kural ve/veya kurallar dizisi dahilinde piksellerin benzerliklerine bağlı olarak gruplandırılması ilkesine dayanır. Bölge büyütme algoritmalarının çoğunluğunda bölge büyütmeye başlamak için başlangıç noktaları seçilir. Bu noktalara tohum pikseller denir ve bu noktalara komşu diğer pikseller, benzerlik kriterine bağlı olarak ya bu bölgeye dahil edilir yada farklı bir bölgeye ait olacak şekilde işaretlenir. Çok basit bir yaklaşım olmasına rağmen, algoritmanın uygulanmasında bazı sıkıntılar ile karşılaşılır. Bunlardan ilki piksel benzerlikleri test eden eşik değeri seçiminin zorluğudur. Bu değeri büyük seçildiği takdirde homojen bölgeler parçalanır ve aşırı bölütleme denilen durum meydana gelir. Bunun tersi durumda ise homojen bölgelere eklenmesi gereken pikseller eklenmez ve homojen bölgeler olması gerekenden daha küçük kalırlar. Diğer bir problem ise bölgeler arasındaki bağlantıların zayıflığıdır. Eğer iki homojen bölge arasındaki sınırda benzerlik kriterini her iki bölge içinde sağlayan bir piksel varsa, bu piksel farklıda olsalar bu iki bölgeyi birleştirir. Böylece farklı olmasına rağmen benzermiş gibi görünen bölgeler oluşur. Bu problemlerin çözümüne katkıda bulunacak yeni yaklaşımlar önerilse de başlangıç tohumlarının belirlenmesi de ayrı bir sıkıntı olarak görülmektedir. Çünkü yapılan bölge büyütme bu noktalardan başlamakta ve farklı tohum noktalarının seçimi farklı bölütlemelere yol açmaktadır. Bu tohum noktaları manuel olarak belirlenebilir fakat çok

kullanılmayan bir yöntemdir. Adams ve Bischof (1994), göğüs röntgen görüntülerinin bölütlenmesi için otomatik tohum noktası belirleyen, yakınsak kareler algoritmasını önermiştir [104]. Tohumları otomatik seçen algoritma kural tabanlı bir yöntemdir. Bölge temelli yöntemlerin farklı bir varyasyonu böl ve birleştir (split and merge) yöntemleridir. Bu yöntem görüntünün tamamından başlar ve görüntüyü verilen tekdüzelik tanımlamasına bağlı olarak sırayla küçük parçalar ayırır. Daha sonra bitişik küçük bölgeler yine tekdüzelik kriterince birleştirilir. Yine bu yöntemin uygulama açısından bazı problemleri mevcuttur. Diğer bir bölge temelli yöntem ise Watershed dönüşümüdür. Watershed algoritması adından anlaşılacağı gibi bölgeleri yakalama havuzlarına bölütler. Algoritmada görüntüye topografik bir yüzeymiş gibi davranılır. Bu yüzey daha sonra dereceli olarak su baskınına maruz bırakılır. Farklı havuzlardaki suların birbirine karışması engellenir ve böylece iki havuz arasındaki sınırlar belirlenmiş olur. Böylece verilen görüntü, havuzlar ve Watershed çizgileri olmak üzere iki sınıfa ayrılmaktadır. Burada havuzlar homojen bölgeleri, çizgiler ise kenarları göstermektedir. Bu yöntemin dezavantajı görüntüler bölütlenirken aşırı bölütlemenin fazlaca oluşmasıdır. Bu sorunun giderilmesi için hiyerarşik Watershed yaklaşımı kullanılmaktadır.

2.1.6. Sınır Temelli Yöntemler


Bölge temelli yöntemlerin tersine, sınır temelli yöntemler görüntüdeki süreksizlikleri göz önüne alarak bölütleme işlemini gerçekleştirirler. Görüntülerdeki süreksizlikler, yansıma, ışık ve gürültü gibi nedenlerden meydana gelebilir. Ayrıca görüntülerdeki homojen bölgelerin birbiri ile kesiştikleri noktalarda yine süreksizliklerin olduğu noktalardır ve buralar bölgelerin kenarları olarak adlandırılırlar. Kenarlar, gradient ve Laplas temelli kenar detektörleri ile bulunabilir. Bu detektörler piksellerin gri seviyelerinin çabuk değiştiği noktalarda yüksek değer üreten yerel türev operatörleri kullanırlar. Sobel, Prewitt, Roberts, Frei-Chen, Canny ve Deriche en çok bilinen kenar çıkarma algoritmalarıdır. Daha sonra bulunan kenarlardan nesnelerin sınırları enerji minimizasyon kriterlerine bağlı olarak bulunabilir.

2.1.7. Ölçüm Uzayı Temelli Yöntemler

Ölçüm uzayına bağlı olarak bölütleme yapan yöntemler, piksellerin gri seviyesi değerlerini, renk bilgilerini, doku parametrelerini, yerel ortalama değerleri ve yerel varyans değerleri gibi sadece ölçümlerden elde edilen nitelikleri kullanırlar. Bu algoritmalar piksellerin görüntüdeki konumları ile ilgilenmezler. Bölütleme bu öz niteliklerin gruplandırılması veya

verilen sınıflara atanması ile gerçekleştirilir. Ölçüm uzayı temelli yöntemler iki ana gruba ayrılabilir. Bunlar; çoklu-eşikleme ve kümeleme (clustering) yöntemleridir.

Sezgisel özellikleri ve kolayca uygulanabilir oluşu, görüntü eşiklemeyi, görüntü bölütleme uygulamaları içinde merkezi bir konuma koymuştur [2]. Şekil 2.1-(a)'daki gri seviyesi histogramının, karanlık bir arka plana ve daha aydınlık bir nesneye sahip olan $f(x,y)$ görüntüsüne ait olduğunu varsayarsak, bu durumda arka planın ve nesnenin piksellerinin gri seviyesi değerlerinin iki baskın bölgede guruplaştığı görülmektedir. Nesnenin, arka plandan ayrıştırılmasının en basit yolu, bu iki gurubu birbirinden ayırabilecek bir T eşik değerinin seçilmesidir. Herhangi bir (x,y) noktası ki, $f(x,y) > T$ ise nokta nesneye aittir, aksi durumda nokta arka plan ögesidir denilir. Şekil 2.1-(b)' de bu yaklaşımın en genel hali görülmektedir. Burada çok seviyeli eşikleme ile bir (x,y) noktası, eğer $T_1 < f(x,y) < T_2$ ise birinci nesneye, $f(x,y) > T_2$ ise ikinci nesneye ve $f(x,y) < T_1$ ise arka plan olarak sınıflandırılır.



Şekil 2.1. Gri seviyesi histogramı **(a)** Tek eşik değer **(b)** Çok seviyeli eşik değer

Eşikleme, ayrıca bir $T=T[x,y, p(x,y), f(x,y)]$ işlevi olarak gösterilebilir. Bu durumda $f(x,y)$, (x,y) noktasının gri-seviyesi değerini, $p(x,y)$ ise o noktasının yerel bir özelliğini gösterir. Örneğin $p(x,y)$, merkezi (x,y) olan piksele komşu piksellerin parlaklıklarının ortalamasını gösterebilir. Böylece eşiklenmiş bir görüntü şöyle tanımlanır;

$$g(x,y) = \begin{cases} 1 & f(x,y) > T \\ 0 & f(x,y) \leq T \end{cases} \quad (2.4)$$

Böylece 1 olarak etiketlenen pikseller nesneyi gösterirken, 0 ile etiketlenen pikseller arka planı gösterecektir. T değeri sadece $f(x,y)$ değerine bağlı ise buna global eşikleme denir. Diğer taraftan T hem $f(x,y)$ hem de $p(x,y)$ değerlerine bağlı ise bu da yerel eşikleme olarak adlandırılır. Ayrıca eğer T , x ve y uzamsal koordinatlarına bağlı ise bu tür eşikleme dinamik veya uyarlamalı olarak adlandırılır.

Eğer pikseller arasındaki uzamsal ilişkiler göz önüne alınmayacaksa, bölütleme, bir tür kümeleme problemi olarak görülebilir. Kümeleme teorisinin temeli, benzer özniteliklere sahip piksellerin gruplanması veya daha önceden verilen sınıflara atanması olarak görülebilir. Bazı kümeleme algoritmalarının kullanıldığı çalışmalar şöyle özetlenebilir;

Haralick ve diğ. (1969), uydu fotoğraflarından tarım alanlarına benzer alanların çıkarılması için kümeleme yöntemi kullanmışlardır [105]. Bu amaçla piksellerden öznitelik vektörü elde edilmiştir. Bu öznitelikler yerel ortalama, yerel varyans ve renk bilgisidir. Eğer seçilen öznitelikler etkili ise aynı bölge için elde edilen öznitelikler benzer olacaktır.

Coleman ve Andrews (1979) başka bir kümeleme algoritmasına dayalı bölütleme yöntemi önermiştir [106]. Önerilen bölütleme sisteminin ilk adımını öznitelik vektörlerinin elde edilmesi oluşturmaktadır. 1, 3, 5 ve 15 boyutlarındaki pencereler ile toplam 12 adet öznitelik hesaplanmaktadır. Daha sonra en uygun sınıf sayısı belirlenmekte ve oluşturulan kümelerin geçerlilikleri analiz edilmektedir.

Diğer taraftan literatürde bölütleme için birçok kümeleme algoritması mevcuttur. Bunlardan en önemlileri parametrik sınıflandırıcılar, yapay sinir ağları tabanlı sınıflandırıcılar ve bulanık sınıflandırıcılarıdır. Kümeleme algoritmalarının tek dezavantajı piksellerin uzamsal ilişkilerini kullanmamalarından kaynaklanan sorunların meydana gelmesidir. Bu problemin giderilmesi için Pappas (1992), uyarlamalı kümeleme algoritması önermiştir [107]. Bu yaklaşımda k-ortalamalar algoritması ile bölütlenen görüntü daha sonra Markov rassal alanları ile piksellerin uzamsal ilişkileri de kümeleme algoritmasına entegre edilerek dayanaklı bir yapı sunulmuştur.

2.1.8. Hibrit Yöntemler

Bölütleme başarımının artırılması için iki veya daha fazla yöntemin birbirine bağlanarak yeni yöntemlerin oluşturulması, hibrit yöntemler olarak adlandırılır. Örneğin Pavlidis ve Liow (1990), böl ve parçala (split and merge) yaklaşımı ile kenar çıkarma algoritmalarını birlikte kullanılarak görüntü bölütlemeyi önermişlerdir [108]. Şöyle ki; görüntü ilk önce parçala ve böl tekniği ile bölütlenir ve daha sonra bölütlenmiş görüntü yatay ve dikey taranarak bölütleme ile oluşan yapay kenarlar silinir. Daha sonra yeni bir kenar düzgünleştirme algoritması ile gerçek sınırlar belirlenir. Ölçüm uzayına bağlı bir yöntem ile sınır temelli başka bir yöntemin birleştirildiği farklı bir çalışma Qian ve Zhao (1997) tarafından gerçekleştirilmiştir [109]. Önerilen yöntem iki aşamalıdır. Görüntü ilk olarak iki farklı yöntemle bölütlenmekte ardından yeni bir bulanık c-ortalamalar kümeleme yaklaşımı ile bölütleme tamamlanmaktadır.


3. ÖRÜNTÜ TANIMA

Örüntü, ilgilenilen varlıklar ile ilgili gözlenebilir veya ölçülebilir bilgilere verilen addır. Gerçek dünyadaki bu örüntüler, genellikle ilgilenilen verilerin nicel tanımlama şekilleridir. Örüntü tanıma, insanların çeşitli ses, görüntü ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel şekillendirir. Aslında, örüntü tanıma bilimin, mühendisliğin ve günlük hayatın geniş bir alanındaki etkinlikleri kapsamaktadır. Örüntü tanıma uygulamalarını insanların yaşantısında da görebiliriz: hava değişimin algılanması, binlerce çiçek, bitki, hayvan türünü tanımlama, kitap okuma, yüz ve ses tanıma gibi bulanık sınırlara sahip birçok etkinlikte örüntü tanıma kullanılır. İnsan örüntü tanınması, geçmiş tecrübelerle dayalı öğrenme esaslıdır. Böylece, insanlar pratikte karşılaştığı örüntü tanıma olaylarını tecrübeleri ışığında değerlendirebilme yeteneğine sahiptirler. Belirli bir sesi tanımak için kullanılan kuralları tanımlamak mümkün değildir. İnsanlar bu işlemlerin birçoğunu oldukça iyi yapmalarına rağmen, bu işlemleri daha ucuz, iyi, hızlı ve otomatik olarak makinelerin yapmasını arzularlar. Örüntü tanıma, böyle akıllı ve öğrenebilen makineleri gerçekleştirmek için, çok boyutlu bir mühendislik disiplini [110].

Örüntü tanıma olayını şu şekilde irdeleyebiliriz: Aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen karmaşık işaret örneklerini veya nesneleri bazı tespit edilmiş özellikler veya karakterler vasıtası ile tanımlama veya sınıflandırmadır. Bu bağlamda, örüntü tanımının en önemli amaçları; bilinmeyen örüntü sınıflarına belirli bir şekil vermek ve bilinen bir sınıfa ait olan örüntüyü teşhis etmektir [110].

Örüntü tanıma tekniklerinin uygulamaları birçok mühendislik, tıp, askeri ve bilim alanına açıktır. Bunlardan bazıları; Doppler kalp işaretlerini tanıma [111], EEG sınıflama [112], haberleşme işaretlerini tanıma [113] ve radar hedef sınıflama [114], biyomedikal kontrol [115] verilebilir. Örüntü tanıma olarak bilinen bu uygulamalar, makine öğrenmesi, örüntü sınıflandırma, ayırım analizi ve nitelik tahmini gibi isimlerle de anılmaktadır. Örüntü tanıma kavramı, Şekil 3.1. de gösterildiği gibi üç önemli birimden oluşmaktadır [110]:

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



Şekil 3.1. Örüntü tanıma kavramı.

Öğrenmeli örüntü tanıma sistemlerinin başlıca iki amacı vardır:

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

3.1. Özellik Çıkarma

Özellik çıkarma örüntü tanımanın en önemli kısmı olup, bir anlamda örüntü tanıma sisteminin başarımında anahtar rolü oynar. Örüntü sınıfları arasında ayrımı gerçekleştirmek için örüntü özelliklerinin çıkarılması gerekir. Günümüzde, çok başarılı sonuçlar veren örüntü sınıflandırıcı türleri mevcut olup, sınıflandırıcının da doğrudan başarımını etkileyen özellik çıkarımı üzerine çalışmalar odaklanmıştır [110]. Özellik çıkarmanın ana sebepleri:

1. Ölçüm veya örüntü uzayından daha küçük boyuta dönüşmeyi sağlamaktır. Bu sınıflandırıcının küçük hatalar ile eğitimi ve karar aşamasının daha kısa sürede gerçekleşmesi demektir.
2. Boyut olarak daha düşük olan özellik uzayını sınıflandırıcının daha az parametre ile öğrenmesini mümkün hale getirecektir. Bunun yararı örüntü uzayı ile karar uzayı arasındaki dönüşüm aşamasının daha kısa sürede gerçekleşmesidir.

3. Durağan olmayan zaman serilerinde olduğu gibi karmaşık örüntülerin tanımlayıcı karakteristiklerini bulabilmek için özellik çıkarımı şarttır. Böylece karar aşamasının güvenilirliği artacaktır.

4. Örüntü sınıflandırma sisteminin, sistem içi veya dışındaki kontrolsüz girişimlerden etkilenmemesini sağlayacak bir özellik çıkarımı kararlı bir yapının oluşmasında etken olacaktır. Bu tür kararlı özellikler, sınıflandırıcının genelleme ve ayrışım yeteneğinin yüksek olmasında önemlidirler.

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


$$x = F(z) \quad (3.1)$$

3.1.1. Dalgacık Dönüşümü

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. 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 [110]. Şekil 3.2'de en yaygın olarak kullanılan dalgacıkların bir kısmı verilmiştir. Dalgacık dönüşümü zaman – ölçek metoduna dayalı olduğu için, odağa tam olarak ayarlanarak işaretin farklı kısımlarını gözetleyebilen bir matematik mikroskobu gibi davranır[115]. Dalgacık analiz metotlarının geleneksel metotlara göre üstünlükleri sıralanırsa [110]:

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

Bu özelliklerinden dolayı, dalgacık dönüşümü durağan olmayan işaretlerin daha esnek ZFG 'lerinin elde edilmesinde etkili bir araç olduğu literatürde belirtilmiştir [116].



Şekil 3.2. Yaygın olarak kullanılan dalgacık örnekleri

3.1.2. Sürekli Dalgacık Dönüşümü

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


$$SDD(a, b) = - \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) dt \quad (3.2)$$

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 Fourier Dönüşümündeki 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 [110].

3.1.3. Entropi Hesaplama Teknikleri

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

Şekil 3.3. de entropi kavramının anlaşılabilmesine yönelik olarak termodinamik ve işaret işleme alanlarındaki kullanımı karşılaştırmalı olarak verilmiştir. Şekil 3.3.a. da görüleceği gibi gaz molekülleri belirli bir bölgeye sıkıştırılmıştır, Şekil 3.3.b.de ise gaz molekülleri sıkıştırıldığı bölgeden serbest bırakılarak tüm kapalı hacme yayılmışlardır. (a) da gaz molekülleri daha düzenli bir yapıyı sergilediklerinden, düşük entropi değerine sahiptirler, (b) de ise gaz moleküllerinin düzenli yapısı bozulduğundan entropi değeri yüksektir. Termodinamikteki bu durum işaretlerin düzensizlik veya belirsizlik miktarlarını ölçmek içinde iyi bir araçtır. Tekrar Şekil 3.3.de görüleceği üzere, işaret durağan (örneğin sinüzoidal bir işaret) ise frekans bölgesinde dar bir spektrum ile düşük bir entropi değerine sahiptir (a), durağan değilse (doppler ses işareti) frekans spektrumu geniş bir banda yayılarak büyük bir entropi değeri oluşmasına neden olur (b) [110].



Şekil 3.3. Entropi kavramı: a) Yüksek, b) Düşük.

Entropi üzerine ilk çalışmalar 19. yüzyıl da termodinamik üzerine yapılmıştır. 1940 larda Shannon haberleşme kanallarının doluluğunu tahmin etmek ve haberleşme işaretinin içerdiği bilgi miktarını ölçmek için entropi kavramını tatbik etmiştir [117]. 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 [118], JPEG görüntü kodlamada oluşabilecek gürültüyü tespit etmek [119], biyomedikal NMR işaretlerinin dalgacık dönüşüm uzayından istatistiksel bilgilerini elde ederek işaretin gürültüsüz şeklini kestirmek [120], EEG işaretlerinin spektral entropilerini kullanarak anestezi derinliği tahmin etmek [121] ve MEG biyomedikal görüntülerin yeniden yapılandırılmasında Norm entropi metodu kullanarak yüksek kalitede MEG görüntüleri elde etmek [122] gibi.

İşaret işlemede yaygın olarak kullanılan entropi hesaplama türleri: Shannon, Norm, Eşik (Threshold), Logaritmik Enerji ve Sure metotlarıdır [123]. Bunun dışında diğer entropi hesaplama teknikleri de bulunmaktadır. Bunlar hakkında ayrıntılı bilgi [124] da bulunabilir. Aşağıdaki entropi yöntemlerinde, s işareti ve s_i de işaretin i . katsayısını göstermektedir.

1. Shannon entropi :

$$E(s) = -\sum_i s_i^2 \cdot \log_2(s_i^2) \quad \text{ve} \quad \log(0) = 0 \text{ kabul edilerek} \quad (3.3)$$

2. Norm entropi :

$$E(s) = \sum_i |s_i|^p \quad \text{ve} \quad 1 \leq p < 2 \quad (3.4)$$

3. Logaritmik Enerji entropi :

$$E(s) = \sum_i \log_2(s_i^2) \quad \text{ve} \quad \log(0) = 0 \quad \text{kabul edilerek} \quad (3.5)$$

4. Eşik entropi:

ε pozitif bir eşik değeri olup $|s_i| > \varepsilon \Rightarrow E(s_i) = 1$ ve $|s_i| \leq \varepsilon \Rightarrow E(s_i) = 0$ tanımlanmak üzere

$$E(s) = \sum_i E(s_i) \quad (3.6)$$

5. Sure entropi :

ε pozitif bir eşik değeri olup

$$|s_i| \leq \varepsilon \Rightarrow E(s) = \sum_i \min(s_i^2, \varepsilon^2) \quad (3.7)$$

Bu entropi hesaplama tekniklerinin, işaret işlemedeki kesin kullanım alanları belirli olmayıp, uygulamalara göre başarımları değişmektedir. Fakat durağan olmayan işaretler için zamana bağımlı entropi hesaplaması daha kullanışlıdır. Bunun için de işaret katsayılarının s_i zamana bağımlı olması gerekir [110].

3.1.4. Enerji Hesaplama Teknikleri

Enerji özellikle dokulu görüntüleri karakterize etmekte kullanılan önemli bir özneliktir. $M \times N$ boyutundaki bir görüntü için l_1 normu ve l_2 normu enerji denklemleri denklem (3.8) ve (3.9)'da sırası ile verilmiştir [125].

$$En_1 = \frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N |f(x,y)| \quad (3.8)$$

$$En_2 = \frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N f(x,y)^2 \quad (3.9)$$

Burada $f(x,y)$ görüntüdeki her bir pikselin parlaklık değerini göstermektedir.

3.1.5. Eş-Oluşum Matrisi

Dikdörtgensel bir görüntünün analiz edildiğini, yatay ve düşey yönlerde sırasıyla N_x ve N_y adet pikselden oluşan bir alt pencerenin var olduğunu düşünelim. Her bir alt pencere içindeki piksellerin G seviye ile nicemlendiğini varsayalım. $L_x = \{1, 2, \dots, N_x\}$ yatay uzaysal domeni, $L_y = \{1, 2, \dots, N_y\}$ düşey uzaysal domeni, $\{0, 1, 2, \dots, G-1\}$ G adet nicemlenmiş gri-tonu temsil etsin. $L_y \times L_x$ kümesi, görüntüde satır-sütun düzeninde sıralanmış alt pencereye ait piksellerin kümesidir.

Bir I görüntüsünün doku-içerik bilgisi, P_{ij} bağıl frekanslar matrisi tarafından belirlenmektedir. Bu matriste aralarında d mesafesi bulunan iki pikselden biri i , öteki de j gri tonuna sahiptir. Açık ve sıklık bilgisi taşıyan matrise literatürde *eş-oluş matrisi* ('co-occurrence matrix') ismi verilir. Bu matris, alt pencere içindeki pikseller arasındaki açısal ilişkinin ve mesafenin fonksiyonudur. 45°'lik aralıklarla nicemlenmiş açılar için normalize edilmemiş sıklık değerleri aşağıdaki şekilde tanımlanmıştır.

$$P(i, j, d, 0^\circ) = \# \left\{ \begin{array}{l} ((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x) \\ |k - m| = 0, \quad |l - n| = d, \quad I(k, l) = i, \quad I(m, n) = j \end{array} \right. \quad (3.10)$$

$$P(i, j, d, 45^\circ) = \# \left\{ \begin{array}{l} ((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x) \\ |(k - m = d, \quad l - n = -d) \text{ veya } (k - m = -d, \quad l - n = d), \quad I(k, l) = i, I(m, n) = j \end{array} \right. \quad (3.11)$$


$$P(i, j, d, 90^\circ) = \# \left\{ \begin{array}{l} ((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x) \\ |k - m| = d, \quad l - n = 0 \quad I(k, l) = i, \quad I(m, n) = j \end{array} \right. \quad (3.12)$$

$$P(i, j, d, 135^\circ) = \# \left\{ \begin{array}{l} ((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x) \\ |(k - m = d, \quad l - n = d) \text{ veya } (k - m = -d, \quad l - n = -d), \quad I(k, l) = i, I(m, n) = j \end{array} \right. \quad (3.13)$$

Burada $\#$, küme içindeki eleman sayısını göstermektedir. Şekil 3.4'de seçilen piksel etrafında 45°'lik açılar için yönler gösterilmektedir.

Her bir d ve θ değeri için ayrı bir $G \times G$ kare matris oluşturulmaktadır. Aşırı hesap yükü olması nedeniyle, genellikle $d=1$ ve 2 piksel, $\theta = 0^\circ, 45^\circ, 90^\circ$, ve 135° açı değerleri için matrisler oluşturulur. Görüntüyü daha az sayıda gri-tona nicemleyerek (gri-ton adedini azaltarak) hesap yükünü hafifletmek mümkündür. Ancak, bu durumda bir miktar dokusal bilgi

kaybının olacağını da unutmamak gerekir. Aşağıda, eş-oluş hesabıyla ilgili $d=1$ için bir örnek verilmiştir.



Şekil 3.4. Seçilen piksel etrafında çeşitli açılar için yönlerin gösterilmesi

Örnek :

0	0	1	1
0	0	1	1
0	2	2	2
2	2	3	3

görüntü

$i \setminus j$	0	1	2	3
0	#(0,0)	#(0,1)	#(0,2)	#(0,3)
1	#(1,0)	#(1,1)	#(1,2)	#(1,3)
2	#(2,0)	#(2,1)	#(2,2)	#(2,3)
3	#(3,0)	#(3,1)	#(3,2)	#(3,3)

$G=4$ için eş-oluş matrisinin oluşturulması

$$P(1,0^\circ) = \begin{pmatrix} 4 & 2 & 1 & 0 \\ 2 & 4 & 0 & 0 \\ 1 & 0 & 6 & 1 \\ 0 & 0 & 1 & 2 \end{pmatrix}$$

$$P(1,45^\circ) = \begin{pmatrix} 4 & 1 & 0 & 0 \\ 1 & 2 & 2 & 0 \\ 0 & 2 & 4 & 1 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$

$$P(1,90^\circ) = \begin{pmatrix} 6 & 0 & 2 & 0 \\ 0 & 4 & 2 & 0 \\ 2 & 2 & 2 & 2 \\ 0 & 0 & 2 & 0 \end{pmatrix}$$

$$P(1,135^\circ) = \begin{pmatrix} 2 & 1 & 3 & 0 \\ 1 & 2 & 1 & 0 \\ 3 & 1 & 0 & 2 \\ 0 & 0 & 2 & 0 \end{pmatrix}$$

Yapısal öznitelikler için, yukarıda verilen eş-oluş matrislerinden elde edilen bazı ölçümler, görüntünün dokusal karakteristikleriyle (homojenlik, kontrast, görüntü içinde organize yapıların varlığı) ilişkilidir. Diğer bazı ölçümler ise görüntüde oluşan gri-ton

geçişlerinin doğasını ve karmaşıklığını karakterize etmektedir. Her ne kadar bu öznitelikler görüntünün dokusal karakteristikleri hakkında bilgi içerseler de hangi yapısal karakteristiğin hangi öznitelik tarafından temsil edildiğini belirlemek oldukça zordur. Aşağıda altı adet dokusal özniteliğin tanımı verilmiştir.

Notasyon:

$p(i,j) = P(i,j)/R$: normalize eş-oluş matrisinde (i,j) -inci giriş.

R , eş-oluş matrisindeki toplam piksel sayısını göstermektedir.

Yukarıda verilen örnek için $p(1,0^\circ)$ aşağıda gösterilmiştir (Örnekte $R=24$),

$$p(1,0^\circ) = \begin{pmatrix} \frac{1}{6} & \frac{1}{12} & \frac{1}{24} & 0 \\ \frac{1}{12} & \frac{1}{6} & 0 & 0 \\ \frac{1}{24} & 0 & \frac{1}{4} & \frac{1}{24} \\ 0 & 0 & \frac{1}{24} & \frac{1}{12} \end{pmatrix}$$

$p_x(i)$: marjinal olasılık matrisinde i -inci giriştir. $p(i,j)$ 'nin satırları toplanarak elde edilir.

$$p_x(i) = \sum_{j=0}^{G-1} p(i,j) \quad (3.14)$$

G : Nicemlenmiş (kuantalanmış) görüntüde farklı gri-ton adedidir.

$$p_y(j) = \sum_{i=0}^{G-1} p(i,j) \quad p_{x+y}(k) = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} p(i,j) \quad i+j=k; \quad k=0,1,\dots,2(G-1) \quad (3.15)$$

Eş-oluş matrisinden elde edilen yapısal öznitelikler:

1) Açısal ikinci moment (enerji)

$$f_1 = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} [p(i,j)]^2 \quad (3.16)$$

2) Kontrast (atalet)

$$f_2 = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i-j)^2 p(i,j) \quad (3.17)$$

3) Ters fark momentı

$$f_3 = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{1}{1+(i-j)^2} p(i,j) \quad (3.18)$$

4) Toplamın ortalaması

$$f_4 = \sum_{i=0}^{2(G-1)} i \cdot p_{x+y}(i) \quad (3.19)$$

5) Toplamın entropisi

$$f_5 = - \sum_{i=0}^{2(G-1)} p_{x+y}(i) \log_2 \{p_{x+y}(i) + \varepsilon\} \quad (3.20)$$

6) Entropi

$$f_6 = - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} p(i,j) \log_2 (p(i,j) + \varepsilon) \quad (3.21)$$

7) Korelasyon

$$f_8 = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{i \cdot j \cdot p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3.22)$$

Burada, μ_x , μ_y ve σ_x , σ_y matrisin satır ve sütun toplamalarının, sırasıyla, ortalama ve standart sapmalarıdır [126].


3.2. Sınıflandırma

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

Örüntü sınıflandırıcılarını geleneksel ve akıllı olarak gruplara ayırmak mümkündür. Geleneksel sınıflandırma algoritmaları istatistiksel bir yapı olan Bayes karar teorisi üzerine kuruludur. Bunların dezavantajları, özellik uzayını sınıflandırma uzayını dönüştürürken, bir gürültünün çıkması ve her bir sınıf için hata kriterinin belli olmamasıdır. Geleneksel sınıflandırıcılara; çok değişkenli Gauss modelleri, en yakın komşu, maksimum olabilirlik, ikili ağaç sınıflandırıcıları ve Fisher'in doğrusal sınıflandırıcıları örnek olarak verilebilir [127]. Buna karşın akıllı sınıflandırma yapıları genellikle YSA tabanlı olup, günümüzde en yaygın kullanılan ve başarımını ispatlamış çok güçlü sınıflandırıcı türleridirler. Özellikle de genelleme

yetenekleri, örüntü tanıma uygulamalarının çok büyük boyutlu verileri açısından önemlidir.

Şekil 3.5.' de akıllı sınıflandırma yapısı gösterilmektedir. Eğitim verisi sınıflandırıcının hafızası içinde şifrelenir. Önceki bölümlerde de belirtildiği gibi, sınıflandırıcı hafızası uyarlanabilen ϕ parametrelerinden oluşmaktadır [110].




Şekil 3.5. Akıllı sınıflama yapısı.

3.2.1. Yapay Sinir Ağı Sınıflandırıcıları

Yapay sinir ağları biyolojik nöron hücresinin yapısı ve öğrenme karakteristiklerinden esinlenerek geliştirilmiş bir hesaplama sistemi olup, örüntü tanımda çok kuvvetli sınıflandırıcılardır. Yapay sinir ağları, özellikle bilgisayar teknolojisinin gelişmesi ile mühendislik sahasında çok geniş bir uygulama alanı bulmuştur [128-130]. Yapay sinir ağları aşağıdaki karakteristiklere sahip paralel bilgi işleme yapılarıdır:

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

Bu üstün özellikleri, yapay sinir ağlarının karmaşık problemleri çözebilme yeteneğini gösterir. Şekil 3.6.da biyolojik nörondan esinlenerek ortaya konmuş işlem elemanının basit bir matematiksel modeli gösterilmiştir [110]. Bu modelde, i . işlem elemanının çıkışı Denklem 3.23.de verilmiştir.



Şekil 3.6. Bir nöron hücresinin matematiksel modeli.

$$y(t+1) = a \left(\sum_{j=1}^m w_{ij} x_j(t) - \theta_i \right) \quad (3.23)$$

Burada $a(.)$ etkinleştirme fonksiyonu, θ_i ise i . işlem elemanının eşik değeridir. İşlem elemanlarının bilgi işlemleri iki kısımdan oluşur: Giriş ve çıkış. Bir işlem elemanı dışardan almış olduğu x_j giriş bilgilerini bağlı bulundukları w_{ij} ağırlıkları üzerinden birleştirerek bir *net* değeri üretir. i . işlem elemanının *net* değeri Denklem 3.24. ile hesaplanır.

$$f_i \triangleq \text{net}_i = \sum_{j=1}^m w_{ij} x_j - \theta_i \quad (3.24)$$

Her bir işlem elemanının ikinci süreci, *net* değerini bir $a(.)$ etkinleştirme fonksiyonundan geçirerek çıkış değerini bulmaktır. Etkinleştirme fonksiyonları işlem elemanlarının çok geniş aralıktaki çıkışını belli aralıklara çekmektedir. Böylece her bir işlem elemanının tepkisi yumuşak olmaktadır ve bağlantı ağırlıklarının değişimlerinin de daha küçük değerlerde olması sağlanır. Dolayısıyla yapay sinir ağının eğitiminde, hata değişiminin ıraksaması engellenerek kararlılığa ulaşmasına yardımcı olunur. Çok yaygın olarak kullanılan bazı etkinleştirme fonksiyonları: Birim basamak, signum, rampa, tek ve çift yönlü sigmoid gibi [110].

Yapay sinir ağ örüntü sınıflandırıcılarını hem popüler yapan, hem de geleneksel sınıflandırma metotlarından ayıran bir takım temel özellikleri vardır. Bunlar aşağıda sıralanmaktadır [131]:

- 1.Öğrenme :** Yapay sinir ağları, örüntüler hakkındaki ilişkiyi belirli bir algoritmaya dayanarak çözmek yerine o ilişkiyi gösteren örüntü örneklerini incelemek suretiyle çözümler üretirler. Burada, sınıflandırılacak örüntü ile alakalı sinir ağına örneklerden

başka hiç bir ön bilginin verilmemiş olması dikkat çekicidir. Ağ, kendisine gösterilen örnekleri tekrar tekrar inceleyerek aradaki ilişkiyi kavramaya çalışır. Her yeni örnek, ağın sahip olduğu bilgiye bir yenisini ekler ve bu işlem tekrar ettikçe ilgili örüntü sınıflandırma problemi hakkında bazı genellemeler yapılır.

2. Genelleme : Alışıl gelmiş bir takım sınıflandırma karakteristiklerinde, istenen çıkışı üretmek için tam olarak doğru girişlere gereksinim duyulmasıdır. Öte yandan yapay sinir ağları, girişlerinde değişimler olsa bile doğru çıkışı üretebilirler. Yani sistem, daha önce o tipten hiç bir şey görmemiş olmasına rağmen, insanlar gibi tamam olmayan veya kısmen hatalı girişlerle bile, doğru tanımlama yapabilmektedir. Bu da işaret etmektedir ki, yapay sinir ağları kendilerine gösterilen bir örüntüyü daha önce öğrendikleri ile mukayese ederek ve aradaki benzerlikleri ortaya koyarak, belirli sınıflara ayırma özelliklerine sahiptirler.

3. Çıkarım yapma : Yapay sinir ağları tam doğru olmayan bir eğitime kümesinden, tam doğruyu çıkarabilirler. Ses örüntülerini tanımak için eğitilmiş bir yapay sinir ağına, gürültü tarafından bozulmuş ses verilebilir. Buna rağmen eğitimden sonra, sistem girişi bozuk ses olmasına rağmen, çıkışta ses mükemmel bir şekilde oluşturulabilir. Yani sistem, eğitim kümesinin özünü çıkarıp saklamıştır. Böylece, eksik veya gürültülü girişlere karşın uygun şekilde cevap verebilmektedir.


4. Hata toleransı : Verilerde eğer bir eksiklik söz konusu olursa, geleneksel yöntemler çalışmazlar. Daha önce belirtildiği üzere, iyi eğitilmiş ve genelleme kapasitesi yüksek bir sinir ağı, kendisine takdim edilen veriler eksik olsa da karar verme işlemine devam eder. Aynı şekilde, yapay sinir ağı üzerinde birtakım problemler ve bozukluklar olabilir. Geleneksel sistemlerin tersine yapay sinir ağları, bu durumda da çalışmalarına devam ederler. Verilerdeki eksiklik veya yapay sinir ağındaki yapısal bozukluk arttıkça yapay sinir ağının performansı yavaş yavaş azalmaya başlar. Fakat sistem fonksiyonunu tamamen durdurmaz ve mutlaka bir sonuç üretilir. Bu özellikler yapay sinir ağının yapısından kaynaklanmaktadır. Çünkü ağın sahip olduğu bilgi, ağ üzerindeki hücrelerin birbiri ile olan bağlantıları üzerine dağıtılmıştır. Zaten böyle bir durumda tek bir bağlantı ve onun üzerindeki bilgi, başlı başına hiçbir zaman bir mana ifade etmez. Ancak, bir gurup halinde ve tam olarak bağlantıların birlikte düşünülmesi sonucu anlamlı bilgiler üretilir. Bundan dolayı birkaç bağlantının etkisiz hale gelmesi, sonucu ya etkilemez veya performansı yavaş yavaş düşürür. Yapay sinir ağı, sahip olduğu diğer bağlantılar nedeniyle işlevine devam eder. Geleneksel sistemlerin ardışıl

alışmalarından dolayı, sistemdeki en küçük bir hatanın veya bozulmanın ulaşabileceđi boyutlar düşünülürse, bu özelliđin ne kadar önemli olduđu ortaya çıkar.

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

Yaklaşık 60 yıl önce mütevazı çalışmalar ile başlayan YSA çalışmaları, bugün teorik olarak olgunlaşmış ve birçok uygulamada yeri doldurulamaz bir araç olmuştur. Yapay sinir ađlarının görevlerini gerçekleştirmede, sahip oldukları fiziksel yapının da önemi vardır. Bugün 50 'ye yakın farklı yapılanma, diđer bir deyişle farklı model, görülmekte ve bu sayı her geçen gün artmaktadır. Farklı yapılaşma, işlem elemanlarının birbirleri ile olan bađlantılarından ve uygulanan öğrenme kuralından kaynaklanmaktadır. İşlem elemanları ya tamamen birbirleri ile bađlantılı veya yerel olarak guruplar halinde bađlantılı olabildikleri gibi deđişik şekilde de birbirleri ile bađlanabilmektedirler. Bilgi akışı bu bađlantılar üzerinden tek yönlü olduđu gibi, çift yönlü de olabilir. Bir gurup işlem elemanı bir araya gelerek bir katman oluştururlar. Genel itibariyle yapay sinir ađlarında 3 tür katman bulunur. Sinir ađının dış dünya ile bađlantısını kuran girdi katmanı, gelen bilgileri işleme kabiliyetine sahip ara katmanlar ve sinir ađının kararlarını dış dünyaya aktaran bir çıktı katmanı. Girdi katmanında çođu zaman bilgi işleme söz konusu olmaz. Bu katmandaki işlem elemanları aldıkları bilgiyi herhangi bir deđişikliğe uğratmadan ara katmandaki işlem elemanlarına aktarırlar. Burada sözü edilen bilgi, sinir ađının işlem elemanları arasındaki bađlantı hatları üzerinde bulunan ağırlıklarla ifade edilir. Dolayısı ile bilgi, bütün ađa dağıtılmış demektir. Bu bilgiler, yapay sinir ađının belleđidir veya diđer bir deyişle yapay sinir ađları eğitildikten sonra kullanılacağı sistem için bir veri tabanıdır [110].

Tüm YSA modellerini bir örüntü sınıflandırıcısı olarak kullanmak mümkündür, fakat en yaygın kullanılan ve en güçlü örüntü sınıflandırıcısı çok katmanlı ileri beslemeli ađ olup, tüm yapay sinir ađı uygulamalarının %90 nını kaplamaktadır. Örüntü sınıflandırıcısı olarak kullanılan YSA türleri hiyerarşik bir biçimde Şekil 3.7. de gösterilmiştir [110].



Şekil 3.7. Yapay sinir ağ örüntü sınıflandırıcıları.

Yaygın olarak kullanılan çok katmanlı ileri beslemeli YSA 'nın eğitiminde çeşitli eğitim algoritmaları kullanılmakla birlikte en başarılı sonuçlar geri yayılım (backpropagation) algoritması ile elde edilmiştir. Bu algoritma, eğim düşme metoduna dayalıdır. Çok katmanlı YSA yapısı ve geri yayılım algoritması tüm YSA çalışmalarında geniş bir yer tutar. Çok katmanlı YSA yapısının kaç katmanlı olacağı ve katmanlarda kaç nöron bulunacağı, etkinleştirme fonksiyon türü seçimi genellikle uygulamalara bağlıdır. Geri yayılım öğrenme algoritmalı çok katmanlı YSA, geniş giriş vektörüne sahip olan örüntü tanıma çalışmalarında en iyi başarımın elde edildiği yapıdır. Çünkü örüntü sınıflandırıcılarından beklen, istenen ayrımı yapabilmeleridir [110].

3.3. Eğiticişiz Sınıflandırıcılar

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 [132]. Bu kriter önceden bilinmeyebilir. Ağ, kendi öğrenme kriterlerini kendisi oluşturmaktadır. Öğrenme işleminin, başlangıçtaki rasgele seçilmiş ağırlıkların, belirli bir kurala göre değiştirilmesine dayandığı belirtilmiştir. Bu öğrenme kurallarının önemli olanlarından bazıları aşağıda yer almaktadır. Bu algoritmalarda, $w_i = [w_{i1} \ w_{i2} \ ... \ w_{im}]$ vektörü ağdaki i. hücreye gelen n tane girişin ağırlık katsayılarını, $x = [x_1 \ x_2 \ ... \ x_n]$ vektörü ağa gelen n tane girişi, y_i ve d_i 'de sırasıyla i. hücrenin hesaplanan ve istenen çıkışını temsil etmektedirler.

3.3.1. Klasik C-Ortalama

Klasik c-ortalama'da verilerin her birisi, yalnız bir kümeye atanacak şekilde klasik mantık ile sınıflandırılır. Bu bölütler (kümeler) ayrıca verilerin parçalara ayrılması şeklinde, ayırma (partition) olarak da isimlendirilir [133]. Böylece bölütler;

$$\bigcup_{i=1}^c A_i = X \quad (3.25)$$

$$A_i \cap A_j = \emptyset \quad (3.26)$$

$$\emptyset \subset A_i \subset X, \text{ bütün } i \text{ için} \quad (3.27)$$

ile ifade edilir. Burada A_i seti ($i=1,2,...,c$), X 'in klasik bölütlenmiş durumu ve görüntü kümesi $X = \{x_1, x_2, x_3, ..., x_n\}$ sonlu set verilerini içermektedir. Küme veya ayırma sayısı c ile gösterilmektedir. Kümeler arasında girişim olmaktadır. Yani:

$$\bigvee_{i=1}^c X_{A_i}(x_k) = 1 \text{ bütün } k\text{'lar için} \quad (3.28)$$

$$X_{A_i}(x_k) \wedge X_{A_j}(x_k) = 0 \text{ bütün } k\text{'lar için} \quad (3.29)$$

$$0 < \sum_{k=1}^n X_{Ai}(x_k) < n \quad \text{bütün } i\text{'ler için} \quad (3.30)$$

olur. $X_{Ai}(x_k)$ karakteristik fonksiyon klasik mantıkta

$$X_{Ai}(x_k) = \begin{cases} 1 & x_k \in A_i \\ 0 & x_k \notin A_i \end{cases} \quad (3.31)$$

ile ifade edilir.

Veri x_k , yalnız bir c kümesine ait olur. Notasyonun basitleştirilmesi için i . küme içersinde j . Verinin üyelik ataması $X_{ij} \equiv X_{Ai}(x_k)$ ile tanımlanmıştır. U matrisi, X_{ij} ($i = 1, 2, 3, \dots, c; j = 1, 2, 3, \dots, n$) elemanlarının birleşiminden oluşan c satırlı ve n kolonlu bir matristir.

Verilerin küme içersine parçalanmasının en iyi şekilde yapılabilmesi için $J(U, v)$ amaç fonksiyonunun minimizasyonu göz önüne alınarak gerçekleştirilir.

$$J(U, v) = \sum_{k=1}^n \sum_{i=1}^c X_{ik} (d_{ik})^2 \quad (3.32)$$

burada d_{ik} , k . veri x_k ile i . küme merkezi v_i arasındaki öklit mesafe bölütüdür ve

$$d_{ik} = d(x_k - v_i) = \|x_k - v_i\| \quad (3.33)$$

v_i ($v_1, v_2, v_3, \dots, v_c$) küme merkezleridir.

Klasik c -ortalama iteratif optimizasyon yöntemi aşağıda verilen algoritma ile gerçekleştirilir [132]:

1. U matrisine başlangıç değerleri atanır.
2. Küme merkezleri hesaplanır.

$$v_i = \frac{\sum_{k=1}^n X_{ik} x_k}{\sum_{k=1}^n X_{ik}} \quad (3.34)$$

3. $U^{(r)}$ yeniden güncellenir.

$$X_{ik} = \begin{cases} 1 & d^{(r)}_{ik} = \min\{d^{(r)}_{jk}\}, \text{ bütün } j \in c \text{ için} \\ 0 & \text{diğer} \end{cases} \quad (3.35)$$

4. Eğer $\|U^{(r+1)} - U^{(r)}\| < \epsilon$ ise iterasyon sonlandırılır, tersi durumda $r=r+1$ yapılarak ikinci maddeye geçilir.

3.3.2. Bulanık C-Ortalama

Bulanık bölütleme de klasik bir yaklaşım olan bulanık c-ortalama (FCM-Fuzzy C-Means) algoritması kullanılarak gerçekleştirilir. İlk olarak Dunn tarafından tanıtılan ve Bezdek tarafından geliştirilen FCM, klasik bölütleme tekniklerinde olduğu gibi en küçük kare hatasının minimizasyonu üzerine kurulan bir tekniktir [134]. FCM, görüntüdeki pikseller ile küme merkezi arasındaki mesafeyi ve piksellerin kümelerdeki üyelik değerlerini temel alan bir amaç fonksiyonunun iteratif olarak minimizasyonu ile gerçekleştirir.

Sınırlı sayıda bir küme ele alındığında $X = (x_1, x_2, x_3, \dots, x_n)$, $x_j \in \mathbb{R}^p$, $(j=1, 2, 3, \dots, n)$ görüntü X küme seti c sayısı ile ifade edilen kümelerle parçalanacaktır. Bölütleme sonucunun iyi olması için amaç fonksiyonunun minimize edilmesi gerekir. Amaç fonksiyonu aşağıdaki ifadeyle gösterilmiştir.

$$J(\mu_{ij}, v_i) = \sum_{i=1}^c \sum_{j=1}^n \mu_{ij}^m d(x_j, v_i) \quad (3.36)$$

$$\sum_{i=1}^c \mu_{ij} = 1, 1 \leq j \leq n \quad (3.37)$$

Bölütleme algoritmasının bulanıklılığı, m ile kontrol edilmektedir. İyi bir m değerinin seçiminde teorik bir ifade olmamakla birlikte genel olarak $1.1 < m \leq 5$ arasında bir değer seçilmesi çok daha uygundur.

Denklem 3.36 deki n , görüntüdeki piksel sayısını, μ_{ij} , j . pikselin i . kümedeki üyelik değeri, v_i , bölüt merkezleri ve $d(x_j, v_i)$ ise piksellerin küme merkezleri ile arasındaki $d_{ji} = \|x_j - v_i\|$ olan Euclidean mesafesidir. Amaç fonksiyonunda minimizasyon probleminin çözümü için, amaç fonksiyonun v_i 'ye göre kısmi türevi alınır ve μ_{ij} 'ye göre kısmi türev alınarak aşağıdaki ifade bulunur.

$$v_i = \frac{\sum_{j=1}^n \mu_{ij}^m x_j}{\sum_{j=1}^n \mu_{ij}^m}, \quad i = 1, 2, \dots, c \quad (3.38)$$

$$\mu_{ij} = \frac{\left(\frac{1}{\|x_j - v_i\|} \right)^{1/(m-1)}}{\sum_{k=1}^c \left(\frac{1}{\|x_j - v_k\|} \right)^{1/(m-1)}}, \quad i = 1, 2, \dots, c; j = 1, 2, \dots, n \quad (3.39)$$

Bu iki denklem analitik olarak çözülemez. Bununla birlikte, FCM algoritmasında amaç fonksiyonun minimum olması için iteratif yaklaşımlar yapılır. Bu iteratif yaklaşımda μ_{ij} ve v_i değerleri hesaplanarak minimum amaç fonksiyonu bulunur. Algoritmanın başında c küme sayısı, m bulanıklık değeri, ε iterasyon kriteri olarak sabit değerlerinin belirlenmesinden sonra, v_i küme merkezleri rasgele atanmaktadır. Her pikselin küme merkezi ile olan uzaklığı hesaplanarak üyelik değerleri bulunmaktadır. Üyelik değerleri bulunan piksellerin yeni küme merkezleri hesaplanmaktadır. Yeni bulunan küme merkeziyle bir önceki bulunan küme merkezi arasındaki fark hesaplanıp ε iterasyon kriteri ile karşılaştırılarak iterasyona devam edilir veya durulur. Algoritma sonunda yeni üyelik değerleri ve bölüt merkezleri bulunmaktadır. Üyelik değerleri piksellerin hangi kümeye ait olduğunu kesin olarak belirlemek için kullanılmakta ve bölütlenmiş görüntüyü ortaya çıkarabilmek için her bir piksel maksimum üyelik derecesine sahip olduğu kümeye atanmaktadır. FCM algoritması aşağıdaki gibidir;

- Küme sayısı c , m 'yi ve ε iterasyon kriteri seçilir ve başlangıç küme merkezleri atanır $v^{(0)}$
- μ_{ij} 'yi hesapla, denklem 3.39
- $v^{(l+1)}$ değerini hesapla denklem 3.38
- $\Delta = \|v^{(l+1)} - v^{(l)}\|$, eğer $\Delta > \varepsilon$ ise $L=L+1$ yapılır ve ikinci adıma geri gidilir. Eğer $\Delta \leq \varepsilon$ ise iterasyon durdurulur.
- Piksellerin yeni üyelik değerlerine ve küme merkezlerine göre görüntü oluşturulur.

3.3.3. Geçerlilik Ölçütü

Geçerlilik ölçütü, farklı algoritmalar sonucu ortaya çıkan bölütlemelerin değerlendirilmesinin yanı sıra, aynı algoritmanın farklı parametrelerine göre ortaya çıkarılan bölütlemelerin sonucunun incelenmesinde kullanılır. Ayrıca bölütleme işleminde kaç bölge içerisine bölütleme yapılacağı, herhangi bir kabullenme yapılmadan geometrik mesafe, bölüt merkezlerinin birbirine olan uzaklığı ve bölüt içersindeki noktaların merkeze olan uzaklığı göz önüne alınarak hesaplanmaktadır. Böyle bir geçerlilik fonksiyonu tamamen sıkı (compact) ve ayrık bir bulanık bölütleme ile sağlanmaktadır. Klasik bölütlenmenin geçerlik fonksiyonu şöyledir [135];

$$D_1 = \min_{2 \leq c \leq n} \left\{ \min_{i+1 \leq j \leq c-1} \left\{ \frac{dis(U_i, U_j)}{\max_{1 \leq k \leq c} \{dia(U_k)\}} \right\} \right\} \quad (3.40)$$

$$dia(U_k) = \max_{x_i, x_j \in U_k} d(x_i, x_j) \quad (3.41)$$

$$dis(U_i, U_j) = \min_{x_i \in U_i, x_j \in U_j} d(x_i, x_j) \quad (3.42)$$

Burada X görüntüsünün sıkı ve ayrık bölütlenmesi $\max_{2 \leq c \leq n} \{\max_{\Omega_c} D_1\}$ denkleminin çözümüyle elde edilir. Bu ifadeyi sağlayacak c değeri, bölütlemeyi sıkı ve ayrık olmasını sağlamaktadır. Fakat böyle bir işlemi yapmak oldukça fazla hesaplama yükü getirmektedir. Bulanık bölütlenmenin kalitesini ölçecek geçerlilik fonksiyonları bölütleme katsayısı (PC), sınıflandırılmış entropi (CE), orantı üssü (PE) ve CSC indistir.

- Bölütleme katsayısı (Partition coefficient, PC):
-

$$PC(\mu, c) = \frac{\sum_{i=1}^N \sum_{j=1}^c \mu_{ij}^2}{n} \quad (3.43)$$

Burada N toplam nokta sayısını, μ_{ij} ise noktaların küme içersindeki üyelik değerleridir. Burada belirlenen bir c bölüt sayısı PC 'nin bire yakın olması veya PC 'nin 1 olması, c değerinde geçerli bir bölütleme yapıldığı $\max_c [\max_{\Omega_c \in U} \{PC(\mu, c)\}]$ ifadesi ile gösterilmektedir.

- Sınıflandırılmış entropi (Classification entropy, CE):

$$CE(\mu, c) = - \frac{\sum_{i=1}^N \sum_{j=1}^c \mu_{ij} \ln \mu_{ij}}{n} \quad (3.44)$$

Burada c 'ye bağlı en küçük CE değeri olan $\min_c [\min_{\Omega_c \in U} \{CE(\mu, c)\}]$ ifadesi bölütlemenin geçerliliği için bir çözümdür.

- Orantı üssü (Proportion exponent, PE):

$$PE(\mu, c) = \ln \left[\prod_{j=1}^n \left[\prod_{l=1}^{\mu_l} (-1)^{j+1} \binom{c}{j} (1 - j\mu_l)^{c-1} \right] \right]; \mu_l = \max_i \{\mu_{ij}\} \quad (3.45)$$

Burada c 'ye bağılı en büyük değeri olan $\max_c [\max_{\Omega_c \in U} \{PE(\mu, c)\}]$ ile bölütlenmenin geçerliliği için bir çözümdür. PC ve CE daha geniş bir alanı kapsadığı için PE 'ye göre daha genel bir ifade olup daha hassastır. Her üç bulanık geçerlilik ölçüsünün eksik tarafı geometrik özelliklerinden yoksun olmasıdır. Geometrik özellikleri de içeren geçerlilik fonksiyonu S aşağıdaki gibi ifade edilmekte ve bu sıklığın ayrıklığı oranı şeklindedir.

$$S = \frac{\pi}{s} \quad (3.46)$$

Burada π , her bölüt içersindeki dağılım karakteristiğinin fonksiyonu olup her noktanın ne kadar sıkı olduğunu ölçer. Bölütteki sıklık (compactness) arttıkça π değeri küçülür.

$$\pi = \frac{\sigma}{n} \quad (3.47)$$

Burada $\sigma = \sum \sigma_i$, $i = 1, 2, \dots, c$; c bölüt sayısı,

$$\sigma_i = \sum (d_{ij})^2 = (d_{i1})^2 + (d_{i2})^2 + (d_{i3})^2 + \dots + (d_{in})^2, j = 1, 2, 3, \dots, n; n, \text{ nokta sayısı}$$

$$d_{ij} = \mu_{ij} \|x_j - v_i\| : i. \text{ bölüt ile } x_j \text{ arasındaki bulanık sapma,}$$

$$\mu_{ij}: j. \text{ Noktanın } i. \text{ bölütteki üyelik değeri,}$$

$$s = (d_{\min})^2 \quad (3.48)$$

s , bulanık bölütlenmenin ayrıklığı ve $d_{\min} = \min_{ij} \|v_i - v_j\|$, bölüt merkezleri arasındaki fark,

$$S = \frac{\pi}{s} = \frac{\frac{\sigma}{n}}{(d_{\min})^2} \quad (3.49)$$


$$S = \frac{\sum_{i=1}^c \sum_{j=1}^n \mu_{ij}^2 \|v_i - x_j\|^2}{n \min_{ij} \|v_i - v_j\|^2} \quad (3.50)$$

ile ifade edilmektedir. Burada c 'ye bağılı en küçük S değeri olan $\min_c [\min_{\Omega_c \in U} \{S(\mu, c, v)\}]$ ifadesi bölütlenmenin geçerliliği için bir çözüm oluşturmaktadır [135].


3.3.4. Kohonen Ağları

Kendi kendini düzenleyen öznitelik haritaları, eğitici olmayan durumda giriş sinyallerinin 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, beyin 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, beyindeki benzer, kendi kendini düzenleme öznitelik haritası adını verdiği bir ağ modeli sunmuştur[131].

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. Basit işlem elemanlarından oluşan Kohonen yapay sinir ağı, Şekil 3.8 '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 da 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 3.9 'de gösterilmiştir. Şekilde de görüleceği üzere Kohonen yapay sinir ağı giriş ve çıkış gibi iki katmanına sahiptir [131].



Şekil 3.8. Kohonen 'in kendi kendini düzenleme haritasının ağ birimleri.




Şekil 3.9. Kohonen sistem modeli.

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


Bir biyolojik sinir sisteminin dış uyarıya cevabı, tek bir sinir hücresi üzerinde yoğunlaşmış olmasına rağmen, çok sayıda geri besleme bağlantısından oluşan oldukça karmaşık etkileşimler ile belirlenir. Yani komşu sinir hücreleri arasında yerel bir etkileşim söz konusudur.

Benzer şekilde Kohonen yapay sinir ağında, 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 (Şekil 3.10).



Şekil 3.10. Meksika şapkası fonksiyonu.

Kohonen yapay sinir ağı, iki boyutlu bir yapıya sahiptir. İki boyutlu ağ içindeki etkileşimlerin yapısı, hangi işlem elemanlarının komşu olduklarını belirler. Ağırlık vektörünün başlangıçtaki keyfi dağılımı, giriş örüntü vektörlerinin ağ tarafından öğrenilmeye başlanması ile kendi kendine ayarlanır. Giriş sinyaline karşı istenen en iyi cevabı veren işlem elemanı etrafında, bir $N_c(t)$ komşuluk kümesi oluşur. Bu komşuluk kümesi iki boyutlu düzlem üzerinde, dikdörtgen vb. yapılarda oluşabilir (Şekil 3.11).



Şekil 3.11. Bir işlem elemanının yapısal komşuluğu ($t_1 < t_2 < t_3$).

Herhangi bir çıkış işlem elemanının, 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 [131].

Aşağıda Kohonen'in kendi kendini düzenleyen öznitelik haritasını sağlayan algoritmanın işlem adımları verilmiştir:

- 1. adım :** N tane giriş düğümlerinden M tane çıkış düğümlerine olan ağırlıklar küçük rasgele değerlere ayarlanır ve komşuluğun ilk yarıçap (eşik) değeri belirlenir.
- 2. adım :** Yeni giriş uygulanır.
- 3. adım :** Girişin, tüm çıkış düğümlerine (sınıflara) olan mesafesi hesaplanır.

$$d_j = \sum_{i=1}^N \left(x_i(t) - w_{ij}(t) \right)^2 \quad (3.51)$$

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,

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(t) \cdot (x_i(t) - w_{ij}(t)), \quad \forall i \in Nc(t) \quad (3.52)$$

- Yarışmayı kaybeden çıkış düğümleri için,

$$w_{ij}(t+1) = w_{ij}(t), \quad \forall i \notin Nc(t) \text{ olur.}$$

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

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

- 6. adım :** 2. adıma gidilerek işlemler tekrarlanır.

3.3.5. Ortalama Kaydırma Kümeleme Algoritması

Ortalama kaydırma (Mean-shift), Hostler ve Fukunaga (1975) tarafından önerilmiş ve daha sonra Comaniciu ve Meer (2002) tarafından görüntü işleme literatürüne gerçekleştirilen bir bölütleme uygulaması ile sunulmuştur [136, 76]. Yöntem, bir veri kümesinin olasılık yoğunluk fonksiyonunu parametrik olmayan, iteratif bir algoritma ile bulmaya çalışır. Algoritma Kernel

adı verilen bir fonksiyon kullanarak x görüntü noktaları konum vektörünün yeni bir x_n konumuna olan Δx uzaklığı hesaplanır. $\Delta x = x_n - x$ olup şöyle tanımlanır;

$$\Delta x = \frac{\sum_{s \in S} K(s-x)w(s)s}{\sum_{s \in S} K(s-x)w(s)} - x = \frac{\sum_{s \in S} K(s-x)w(s)(s-x)}{\sum_{s \in S} K(s-x)w(s)} \quad (3.53)$$

Burada, K kernel fonksiyonu, w piksellere ait ağırlık fonksiyonudur ve toplamlar x konumu çevresini kapsayan S penceresi üzerinden yapılır (sCS). Ortalama kaydırma algoritması veri noktalarını yerel S penceresi içerisindeki tüm veri noktalarının ortalaması kadar değiştiren (kaydıran) iteratif bir işlemdir.

Ortalama kaydırma algoritmasının parametrik olmayan ve karmaşık hesaplamalar gerektirmeyen bir yöntem olması nedeniyle, algoritma son yıllarda renge dayalı görüntü bölütleme ve kümeleme gibi uygulamalarda kolaylıkla kullanılmıştır. Yöntemin en önemli avantajı uygun parametre değeri seçildiğinde algoritmasının optimum küme sayısına yakınsayabilme özelliğidir. Algoritmada kullanılan kernel fonksiyonu önemlidir. En çok kullanılan fonksiyonlar denklem 3. 54 ile gösterilen normal Gauss kernel ile denklem 3.55 de verilmiş Epanechnikov kernel fonksiyondur ve şöyle tanımlanırlar.

$$K_N(x) = (2\pi)^{-d/2} \exp\left(-\frac{1}{2} x^T x\right) \quad (3.54)$$

$$K_e(x) = \begin{cases} \frac{d+2}{2c_d} (1-x^T x) & \text{if } x^T x < 1 \\ 0 & \text{diger} \end{cases} \quad (3.55)$$

Burada d veri kümesinin boyutunu, Epanechnikov kernelinde kullanılan c_d ise birim kürenin hacmini göstermektedir.

4. POISSON MARKOV RASSAL ALANLARI İLE EĞİTİCİSİZ GÖRÜNTÜ BÖLÜTLEME

Bir görüntüyü homojen ve birbirinden bağımsız bölgelere ayırma işlemine görüntü bölütleme denir [97]. Diğer bir tanımlama ile görüntü bölütleme, bir görüntüyü oluşturan piksellerin daha önceden belirlenmiş bazı özelliklere veya kriterlere bağlı olarak gruplandırılması veya farklı sınıflara atanması işlemine verilen addır. Örüntü tanıma uygulamalarında görüntü bölütleme çok önemlidir ve görüntü bölütlemenin başarımı örüntü tanıma sisteminin başarımına doğrudan katkıda bulunur.

Literatürde birçok görüntü bölütleme yöntemi mevcuttur [41]. Eşikleme yöntemi en çok kullanılan yöntemlerin başında gelmektedir [137]. Bundan başka, kümeleme yöntemleri [138], bölge büyütme ve parçalama [104] ve çoklu çözünürlük teknikleri [139, 140], görüntü bölütleme uygulamalarında kullanılan diğer yöntemlerdir. Markov Rassal Alanları (MRA), görüntü bölütlemeye kullanılan diğer önemli bir yöntemdir. MRA, model temelli bir yöntemdir. Eldeki görüntüyü stokastik bir model ile belirtmeye çalışır. Bu yöntemin görüntü bölütleme de kullanılmasının önemli avantajları vardır. Bunlardan ilki; piksellerin uzamsal ilişkilerinin görüntü bölütlemeye entegre edilmesi şüphesiz en önemli avantajıdır. İkinci önemli avantajı ise; MRA'nın, görüntülerin farklı özelliklerini kullanabilen Bayes yapısına dayalı bir model olmasıdır. Piksel sınıflarının dağılımları, MRA model olasılığının maksimizasyonu esnasında elde edilmesi üçüncü önemli avantajıdır. Besag'ın makalesi ile görüntü işleme ve bilgisayar görmesi dünyasına tanıtılan MRA, birçok yeni metodolojik gelişmelerin yaşanmasını ve bunu takip eden önemli uygulamaların ortaya çıkmasını sağlamıştır [47]. Görüntüyü, piksellerin yerel komşuluk ilişkilerine bağlı olarak tanımlayan MRA, görüntü işleme için oldukça etkili bir araçtır. Geçmiş yıllarda MRA'nın görüntü bölütlemeye kullanıldığı birçok makale sunulmuştur. Liu ve ark., MRA'yı kullanarak, renkli görüntülerin bölütlenmesi için çoklu çözünürlüklü bir teknik önermişlerdir [139]. Önerilen yöntem genel olarak bir gevşetme işlemidir. Ayrıca çalışmada, önerilen bölütleme yönteminin değerlendirilmesi için yeni bir fonksiyon önerilmektedir. Önerilen yeni değerlendirme fonksiyonunun en önemli avantajı herhangi bir eşik değere ihtiyaç duymaksızın, sezgisel bazı kriterlerin birleştirildiği bir yapıya sahip olmasıdır. Üç farklı MRA yönteminin karşılaştırıldığı farklı bir çalışma Dubes ve ark. tarafından sunulmuştur [49]. Çeşmeli ve diğ., Gauss Markov Rassal Alanları (GMRA) ve osilatör sinir ağı kullanarak doku görüntülerinin analizini gerçekleştirmişlerdir [56]. Önerilen yöntem iki bölümden oluşmaktadır. GMRA ile doku görüntülerini karakterize edecek özellik

vektörünün elde edilmesi, önerilen yöntemin ilk bölümünü oluştururken, osilator sinir ağı yapısını kullanan sınıflandırıcı, önerilen yöntemin ikinci parçasını oluşturmaktadır. MRA modellerini kullanarak gri seviyeli ve dokulu görüntülerin özelliklerine bağlı olarak optimum görüntü bölütlemeyi amaçlayan basit bir teknik Sarkar ve diğ. tarafından önerilmiştir [141]. Önerilen teknik, ilk başta aşırı bölütlenmiş ve orijinal görüntüyü giriş olarak almakta ve daha sonra bölütlenmiş görüntüden her bir komşu bölge için MRA yapısı oluşturmaktadır. Kato ve diğ., renkli görüntülerin bölütlenmesi için eğiticişiz bir MRA yapısı önermişleridir [142]. Önerilen yöntem, görüntü histogramında ayırt edici pikler olmasa dahi başarılı bir şekilde MRA modeli için gerekli olan başlangıç ortalama vektörünü elde edebilmektedir. Yang ve diğ., görüntü bölütleme için yine eğiticişiz bir MRA yapısı önermişlerdir [143]. Önerilen yöntemde, ilk önce görüntü kabaca bölütlenmekte, daha sonra sınır MRA yaklaşımı ile her bir bölüt daha hassas hale getirilmektedir. Ibanez ve diğ., MRA ile bölütleme yöntemleri ve parametre tahmin yöntemlerini karşılaştırmalı olarak analiz etmişlerdir [144]. Deng ve diğ., model parametrelerini otomatik olarak bulan ve eğiticişiz görüntü bölütleme gerçekleştiren bir MRA yapısı önermiştir [145]. Diğer taraftan Clausi ve diğ., iki doku analiz metodunun ayırt edici başarımlarını incelemişlerdir [146]. Bu yöntemler MRA ve gri-seviye eş oluşum olabirlik yöntemleridir. Kim ve diğ., gürültülü video görüntülerinin bölütlenmesi için eğiticişiz bir MRA yapısı önermiştir [147]. Her bir kare MRA ile modellenmiş ve genetik algoritma ile MRA parametrelerinin optimizasyonu sağlanmıştır. Yu ve diğ., MRA parametrelerinin belirlenmesi için hem Metropolis-Hastings yöntemini hem de eğitim yöntemini kullanmıştır [148].

MRA, birleşik Gauss dağılımına sahip şartlı bir modeldir. MRA'da Gauss dağılımının kullanılmasının başlıca sebebi giriş verilerinin çoğunlukla merkezi limit teoremi göre Gauss dağılıma sahip olmasından kaynaklanmaktadır. Bundan başka gri-seviyesi görüntüler sıklıkla bir çok Gauss dağılımının birleşiminden oluşan bir model olarak tanımlanır. Diğer taraftan, Pal ve Pal, gri seviyesi görüntülerin histogramlarının, Gauss dağılımdan çok Poisson dağılım ile daha uygun modellenebileceğini önermiştir [149]. Buna bağlı olarak burada gri seviyesi görüntülerin bölütlenmesinde kullanılan MRA yapısındaki Gauss dağılımı yerine Poisson dağılımının kullanılması önerilmiştir. Oluşturulan yapay görüntüler ve gerçek görüntüler ile yapılan deneysel çalışmalarla, gri seviyesi görüntülerin bölütlenmesi için önerilen Poisson MRA (PMRA) yapısının, GMRA yapısına oranla daha iyi sonuçlar verdiği hem sezgisel hem de kullanılan diğer değerlendirme kriterleri ile gösterilmiştir.

4.1. Görüntü Bölütleme Modeli

Bu bölümde genel olarak MRA yapısı ve görüntü analizine uyarlanması kısaca incelenecektir. MRA, ayrık bir kafes üzerinde tanımlanmış n -boyutlu rasgele bir süreçtir. Bu kafes genelde iki boyutlu bir ızgaradır [150]. Rassal bir alanın, MRA olarak düşünülebilmesi için olasılık dağılımının kendisine ve komşu olduğu diğer alanlara bağlı olması gerekmektedir. Cliff-Hammersley teoremine göre herhangi bir MRA, Gibbs formunun olasılık dağılımı olarak tanımlanabilir;

$$p(x) = \frac{1}{Z} e^{(-U(x))} \quad (4.1)$$

burada x rassal bir alanı, Z normalizasyon sabitini ve $U(x)$ ise enerji fonksiyonunu göstermektedir. Enerji fonksiyonu şöyle tanımlanır;

$$U(x) = \sum_{c \in C} V_c(x) \quad (4.2)$$

$V_c(x)$ potansiyel fonksiyonudur.

Gri seviyesi görüntünün $M \times N$ boyutunda dikdörtgen bir kafes olduğu düşünölsün. $L = \{(i, j), 1 \leq i \leq M, 1 \leq j \leq N\}$ ve c ise ya tek bir pikselden yada bir grup pikselden oluşan ve klik olarak adlandırılan bir dizi pikseli ifade etmektedir. Şekil 4.1-(a)'da birinci dereceden uzamsal komşuluklar gösterilmiştir. 1 birinci dereceden komşulukları, 2 ikinci dereceden komşulukları göstermektedir. Şekil 4.1-(b) ise görüntünün vektör formunda olduğu durumlar için komşuluk ilişkisini göstermektedir.

5	4	3	4	5	t:-11	t:-7	t:-6	t:+8	t:+12
4	2	1	2	4	t:-9	t:-3	t:-2	t:+4	t:+10
3	1	t	1	3	t:-5	t:-1	t	t:+1	t:+5
4	2	1	2	4	t:-10	t:-4	t:+2	t:+3	t:+9
5	4	3	4	5	t:-12	t:-8	t:+6	t:+7	t:+11

Şekil 4. 1. Piksel komşulukları **a-)** Matris formatında gösterim **b-)** Vektör formatında gösterim

Görüntünün, Y değişkenlerinden oluşan ve $M \times N$ boyutunda bir vektör olduğu düşünülürse, Y görüntüsü için yoğunluk modeli şöyle tanımlanır;

$$f(y | X = x) = \prod_{t=1}^{MN} f_t(y_t | x_t) \quad (4.3)$$

$f_t(. | x_t)$, t pikselinin, Y_t için şartlı olasılık yoğunluk fonksiyonudur. $f_t(y_t | x_t)$ fonksiyonu, ortalaması λ_{x_t} olan Poisson olasılık yoğunluk fonksiyonudur ve denklem 4.4'deki gibi tanımlanır;

$$f_t(x_t | \lambda) = \frac{\lambda^{x_t}}{x_t!} e^{-\lambda} \quad (4.4)$$

Verilen bir görüntü için $Y = y$, piksellerin gri seviyesini gösterirken, X değişkeni de görüntüdeki piksellerin etiketlerini gösterebilir. Bu durumda belirlenen komşuluk klik sistemine göre Gibbs rassal alanları denklem 4.5'deki gibi ifade edilir.

$$P(X = x | Y = y) = \frac{e^{-U(x|y)}}{Z} \quad (4.5)$$

burada Z normalizasyon sabitidir. Enerji fonksiyonu $U(x/y)$ ise şöyle tanımlanır;

$$U(x | y) = \sum_{t=1}^{MN} [x_t \ln(\lambda_{x_t}) - \lambda_{x_t} - \ln(x_t!)] + \sum_{r=1}^c [\theta_r J(x_t, x_{t:r})] \quad (4.6)$$

Verilen denklemde $a = b$ olduğu durumda $J(a, b) = -1$ değerini alırken, a 'nın b 'den farklı olduğu durumlar için $J(a, b) = 0$ olmaktadır. Ayrıca birinci dereceden komşuluk modeli için $c = 2$ dir. $[\theta_1, \dots, \theta_c]$ klik parametrelerini göstermektedir. MRA'nın yerel özellikleri Gibbs rassal alanlarından türetilir. $X_{\partial t}$, t pikselinin komşu piksellerin gri seviyelerini ($[x_{t:r} x_{t-r}]$ $r = 1$ 'den c 'ye kadar) tutsun, X_t 'nin şartlı olasılığı şöyle ifade edilir;

$$P(X_t = x_t | X_{\partial t} = x_{\partial t}, Y = y) = \frac{e^{-U_t(x_t, x_{\partial t} | y)}}{Z} \quad (4.7)$$

ve

$$U(x_t, x_{\partial t} | y) = \sum_{t=1}^{MN} [x_t \ln(\lambda_{x_t}) - \lambda_{x_t} - \ln(x_t!) + \sum_{r=1}^c \theta_r [J(x_t, x_{t:r}) + J(x_t, x_{t:-r})]] \quad (4.8)$$

Böylece görüntü bölütleme problemi, verilen y değerlerine bağlı olarak görüntüdeki piksellerin uygun sınıflara atanması işlemine dönüşür. Görüntü piksellerinin uygun sınıflara atanması sonrasal maksimum olabilirlik tahmini ile yapılabilir. Bu yöntemde $P(X=x | Y=y)$ 'yi maksimum yapacak x etiketi y değerine atanmaktadır.

4.2. İteratif Şartlı Kipler (Iterated Conditional Modes, ICM)

ICM bir optimizasyon yöntemidir. Hesaplama yükünün fazla olduğu sonrasal maksimum olabilirlik metoduna alternatif olarak Besag tarafından önerilmiştir [47]. ICM yönteminde her bir site hiçbir sınırlama olmaksızın sıra ile taranır ve $P(X=x | Y=y)$ 'yi maksimum yapan x' etiketi o sitenin tahmin edilen sınıfı olur. Önerilen bu yöntemde hesaplama zamanı oldukça kısadır. ICM yöntemi aşağıda verilen denklemle özetlenebilir, şöyle ki;

$$P(X_t = x_t | y, X_{S|t} = x_{S|t}) = f_t(y_t | x_t) P(X_t = x_t | X_{\partial t} = x_{\partial t}) \quad (4.9)$$

Burada t , etiketlenecek pikseli gösterirken, y pikselin gri seviyesi değerini ve $x_{\partial t}$ ise etiketi belirlenecek pikselin bütün komşu piksellerinin etiket değerlerini göstermektedir. Denklem (4.9) ile verilen şartlı olasılık yoğunluk fonksiyonun maksimizasyonu, enerji fonksiyonun minimizasyonuna eşdeğerdir. ICM yöntemi kısaca şu adımlardan oluşmaktadır;

1.Adım: Bütün pikseller için $f_t(y_t | x_t)$ maksimizasyonu ile başlangıç x değerleri elde edilir.

2.Adım: $t = 1$ 'den MN ye kadar x_t değerleri, eşitlik 4,8'de verilen enerji fonksiyonu maksimum olacak şekilde x'_t olarak güncellenir.

3. Adım: Daha sonra adım 2'ye geri dönülür ve bu işlem N kez tekrarlanır.

4.3. Beklentilerin Maksimizasyonu İle Parametre Tahmini

Verilen bir görüntüdeki piksel etiketlerinin Poisson ve Gaussian olasılık dağılımlarının belirlenmesinde, Poisson dağılımı için ortalama değer λ_{x_t} 'nin, Gauss dağılım için de ortalama

değer μ_{x_t} 'in ve $\sigma_{x_t}^2$ varyans değerinin hesaplanması gerekmektedir. Görüntüdeki her bir sınıf için olasılık dağılım parametrelerin tahmininde herhangi bir ön bilgi bulunmadığı için maksimum olabilirlik yöntemi kullanılamaz. İstatistikte buna tamamlanmamış veri problemi denir. Burada sadece Poisson dağılım parametrelerin tahmini verilecektir, Gauss dağılım için ilgili referans incelenebilir [151]. Dempster ve diğ. tarafından önerilen beklentilerin maksimizasyonu yöntemi olasılık dağılımlarının parametrelerinin tahminin de kullanılır [152]. Beklentilerin maksimizasyonu yöntemi iki adımdan oluşmaktadır. Bunlar E-adımı ve M-adımıdır. Algoritma başlangıç p_m^0 ve λ_m^0 değerlerinden başlar ve her bir iterasyon için E ve M adımlarını icra ederek istenilen yakınsama değerine ulaşır. θ 'nin t iterasyon sonunda θ^t değerine yakınsadığı düşünülürse, (t+1)'inci iterasyonda E adımının beklenen logaritmik olasılık fonksiyonu aşağıda verilen denklemle hesaplar;

$$Q(\theta, \theta^t) = \sum_{k=1}^K \sum_{m=1}^M \{\log \alpha_m p(x_k | \theta_m)\} P(m | x_k; \theta^t) \quad (4.10)$$

$P(m | x_k; \theta^t)$ sonrasal olasılıktır ve şöyle hesaplanır;

$$P(m | x_k; \theta^t) = \frac{\alpha_k^t p(x_k | \theta_m^t)}{\sum_{l=1}^M \alpha_l^t p(x_k | \theta_l^t)}$$

(4.11)

M adımı, $Q(\theta, \theta^t)$ 'i maksimize ederek, θ 'nin t+1 anındaki θ^t değerini şöyle hesaplar;

$$\alpha_m^{t+1} = \frac{1}{K} \sum_{k=1}^K P(m | x_k; \theta^t) \quad (4.12)$$

$$\lambda_m^{t+1} = \frac{\sum_{k=1}^K x_k P(m | x_k; \theta^t)}{\sum_{k=1}^K P(m | x_k; \theta^t)} \quad (4.13)$$

4.4. Uygulama Sonuçları ve Değerlendirme Kriteri


Görüntü bölütleme başarımı, genellikle kişilerin izlenimlerine ve sezgisel değerlendirmelerine bağlı olarak gerçekleştirilir. Bölütleme başarımının ölçülmesinde çok daha nesnel olan ve Liu [139] tarafından önerilen değerlendirme fonksiyonu (Denklem 4.14), yapılan bölütleme uygulamalarının başarımını kıyaslamak için kullanmıştır. Bu metodun faydası herhangi bir eşik değere ihtiyaç duymaksızın bölütleme sonuçlarını değerlendirebilmesidir. Bu fonksiyon şöyle tanımlanmaktadır;

$$F(I) = \frac{1}{1000 \times M \times N} \sqrt{R} \sum_{i=1}^R \frac{e_i^2}{\sqrt{A_i}} \quad (4.14)$$

burada I bölütlenecek görüntüyü, N , M görüntünün boyutlarını ve R ise bölütlenmiş görüntüdeki bölge sayısını göstermektedir. A_i i. bölgenin alanını veya i 'ninci bölgedeki piksel sayısını, e_i ise i .ninci bölgenin toplam renk hatasını göstermektedir. e_i renk hatası, orijinal görüntüdeki i 'ninci bölge ile bölütlenmiş görüntüdeki i 'ninci bölgenin pikselleri arasındaki renk farklarının toplamı olarak alınmıştır. Küçük $F(I)$ değeri gerçekleştirilen bölütlemenin iyi olduğunu göstermektedir.

Önerilen PMRA yöntemi, yapay ve gerçek görüntülerin kullanıldığı bir dizi uygulama ile test edilmiştir. Önerilen yöntemin test edildiği benzetim, MATLAB (ver. 5.3, The MathWorks Inc.) ortamında hazırlanan yazılımlarla sağlanmıştır. Şekil 4.2'de önerilen yöntemin blok diyagramı gösterilmiştir. Bölütleme işlemi yapılmadan önce her iki yöntem için parametre tahmini EM algoritması ile yapılmaktadır. Burada, görüntünün kaç sınıfa ayrılacağı kullanıcı tarafından girilmektedir. Bu değer tahmin edilmesinde görüntü histogramı faydalı olabilir. Fakat bu durum gürültülü görüntüler için her zaman doğru olmayabilir. Elde edilen parametre değerleri ile giriş görüntüsü her iki yöntem ile bölütlenmekte ve elde edilen bölütlenmiş görüntüler değerlendirme kriteri kullanılarak yöntemlerin başarımları kıyaslanmaktadır. EM algoritması için başlangıç değerleri çoğunlukla rasgele seçilmektedir. Bu durum yakınsamanın yavaş olmasına sebep olmaktadır. Bu problemin giderilmesi için başlangıç değerleri K-ortalamar algoritması üzerinden atanmıştır. $[\theta_1, \dots, \theta_c]$ klik parametrelerine 2 sabit değeri atanmıştır. MATLAB ortamında üretilen yapay görüntüler 128 x 128 boyutundadır. Gerçek görüntüler ise caip.rutgers.edu sitesinden alınmıştır [153]. Görüntüler normalde renklidir fakat uygulama için 8 bitlik gri seviyeye dönüştürülmüşlerdir. Şekil 4.3'de üç sınıf olacak şekilde yapay olarak üretilmiş bir görüntü, histogramı, PMRA bölütleme sonucu ve GMRA bölütleme sonucu verilmiştir. Bu görüntü için yanlış sınıflandırılmış pikseller

sayıldığında PMRA yaklaşımının, GMRA ya göre 1 piksel daha iyi sonuç verdiği görülmektedir. Diğer taraftan denklem 4.14 ile verilen fonksiyon sonuçlarından da PMRA'nın daha iyi sonuç verdiği görülmektedir. Uygulama sonuçlarının değerlendirilmesi Tablo 4.1. den görülebilir.





Şekil 4. 2. Mevcut yöntemle önerilen yöntemin karşılaştırmalı blok diyagramı


Şekil 4. 4’de dört sınıf olacak şekilde yine yapay bir görüntü, histogramı ve her iki yöntemle elde edilen bölütleme sonuçları gösterilmiştir. Yine bu örnekte de önerilen yöntemin etkinliği hem görsel hem de denklem 4.14’ün ürettiği sonuç itibarıyla görülmektedir. Şekil 4. 5, Şekil 4. 6, Şekil 4. 7, Şekil 4. 8 ve Şekil 4. 9 gerçek resimleri ve yine PMRA ve GMRA yöntemlerine göre bölütleme sonuçlarını göstermektedirler. Yine PMRA’nın üstünlüğü hem görsel hem de ilgili değerlendirme kriterine bağlı olarak gösterilmiştir.

Tablo 4. 1. Bölütleme yöntemlerinin başarımı


Görüntü	GMRA	PMRA
Şekil 4.3	2.2482e+003	2.2463e+003
Şekil 4.4	3.8408e+003	1.6670e+003
Şekil 4.5	1.5750e+004	3.7916e+003
Şekil 4.6	3.2445e+004	1.2124e+004
Şekil 4.7	1.2821e+004	8.8572e+003
Şekil 4.8	1.5627e+004	1.2334e+004
Şekil 4.9	2.0588e+004	8.8572e+003
Şekil 4.10	1.1499e+005	3.0437e+004
Şekil 4.11	9.3786e+004	5.1147e+004




Şekil 4. 3. (a) Orijinal üç parçalı yapay görüntü (b) Histogramı (c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu




(a)



(b)





(c)



(d)


Şekil 4. 4. (a) Orijinal dört parçalı yapay görüntü (b) Histogramı (c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu



Şekil 4. 5. (a) Orijinal görüntü (b) Histogramı (c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu



(a)



(b)



(c)




(d)

Şekil 4. 6. (a) Orijinal ev görüntüsü (b) Histogramı (c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu



(a)



(b)



(c)




(d)

Şekil 4. 7. (a) Gerçek kadın görüntüsü (b) Histogramı (c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu



(a)



(b)




(c)



(d)


Şekil 4. 8. (a) Gerçek el görüntü (b) Histogramı (c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu




Şekil 4. 9. (a) Orijinal hücre görüntüsü (b) Histogramı (c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu

Şekil 4. 10 ve Şekil 4. 11’de sırası ile $SNR = 10$ dB ve $SNR = 20$ dB’ lik gürültü eklenmiş görüntüler ve yine bunların her iki yöntemle bölütlenmiş sonuçları verilmiştir. PMRA gürültülü görüntüler de dahi üstünlük göstermiştir.


Uygulama çalışmaları sırasında PMRA’nın üstün kılınması için hiçbir ön işlem yapılmamakla birlikte, hem her iki dağılımın parametre tahmini içinde yine önerilen yöntemin iyiliğini ortaya koyacak hiçbir ön işlem yapılmamıştır. Her iki yöntem içinde bütün şartlar eşit tutulmuştur. Ayrıca rasgele başlangıç değerlerinden doğacak tesadüflerin giderilmesi için aynı görüntü için bölütleme işlemleri birkaç kez tekrarlanmış ve en iyi sonuçlar gösterilmiştir. ICM algoritmasının çalışması görüntüdeki piksellerin etiketlerinin değişmediği ve kararlı duruma geçtikleri anda durdurulmaktadır. Diğer taraftan Şekil 4.2’de verilen blok diyagramın her bir kolunun; şöyle ki EM+PMRA ve EM+GMRA işlem süreleri göz önüne alındığında EM+PMRA’nın daha kısa zamanlarda istenilen sonuçları verdiği görülmüştür.



(a)



(b)



(c)

Şekil 4. 10. (a) SNR = 20 dB gürültülü görüntü (b) Histogramı (c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu



Şekil 4. 11. (a) $\text{SNR} = 10$ dB gürültülü görüntü (b) Histogramı (c) GMRA bölütleme sonucu (d) PMRA bölütleme sonucu

5. DALGACIK DÖNÜŞÜMÜ EŞ-OLUŞUM MATRİSLERİNİN İSTATİSTİKSEL ÖZNİTELİKLERİ ve OSİLATOR SİNİR AĞI İLE GÖRÜNTÜ BÖLÜTLEME

Bilgisayar ve robot görmesi uygulamalarında ilgilenilen görüntüdeki bazı bölgelerinin veya nesnelerin, görüntünün tamamından ayrıştırılması veya daha belirgin bir hale getirilmesi istenir ki; bunu gerçekleştirecek sistemlerin tasarımı ve uygulaması oldukça zordur.


Literatürde, doku analizinin üç farklı uygulaması görülmektedir. Bunlar doku sınıflandırma, doku bölütleme ve şekillerine göre nesne tanımadır. Doku sınıflandırmada amaç, bilinmeyen bir doku örneğinin bazı özniteliklere bağlı olarak daha önceden bilinen doku sınıflarından birine atanması işlemidir [61]. Bu işlem eğitici bir süreçtir. Doku bölütleme ise iki adımdan oluşmaktadır. Bunlar; öznitelik çıkarımı ve sınıflandırma adımlarıdır [154]. Aslında doku bölütleme de bir tür doku sınıflandırma problemi olarak görülebilir. Diğer taraftan şekillerine göre nesne tanımda görüntü tanıma problemi içinde varsayılır.

İnsan görü sistemi ile ilgili yapılan çalışmalar, frekans ve ölçek bilgisinin dokuların insan tarafından algılanışında önemli iki olgu olduğunu göstermiştir. Bundan dolayı son yıllarda çoklu-çözünürlüklü ve çoklu- ölçekli doku analiz yaklaşımları oldukça değer kazanmışlardır. Dalgacık dönüşümü de süre gelen zamanda doku bölütleme uygulamaları için vazgeçilmez olmuştur. Doku bölütleme probleminin çözümüne uygun geçmişte birçok yöntem önerilmiştir. İlk önerilen doku analiz yöntemleri genelde birinci ve ikinci dereceden istatistiğe dayalıdır [155]. Daha sonraları GMRA ve GRA modelleri, doku bölütleme için kullanılmıştır [51, 45]. Bunların dışında, Gabor ve dalgacık dönüşümünü kullanan yöntemler en çok ilgi gören doku bölütleme yaklaşımları olmuşlardır [62, 83]. Lu ve diğ., hızlı dalgacık dönüşümü ile doku bölütleme önermiştir [156]. Önerilen yöntem eğitici bir sınıflandırıcı kullanır. Bölütlenecek doku mozaigindeki sınıf sayısı algoritma tarafından belirlenmektedir. Doku özniteliklerinin elde edilmesinde dalgacık dönüşümden elde edilen yüksek frekanslı kanallar kullanılmıştır. Busch ve diğ., MR görüntülerinin bölütlenmesinde doku analizi ve yeni bir Kohonen özellik harita sınıflandırıcısı kullanmışlardır [157]. Acharyya ve diğ., M-bandı dalgacık dönüşümü kullanarak doku görüntülerinin bölütmesini gerçekleştiren eğitici bir yöntem önermişlerdir [158]. Önerilen yöntemde, ortogonal ve doğrusal fazlı M-bandı dalgacık dönüşümü kullanılmıştır. Arivazhagan ve diğ., dalgacık eş oluşum matrislerinden elde ettikleri ikinci dereceden istatistiksel öznitelikleri kullanarak doku bölütleme için yeni bir algoritma önermişlerdir. Önerilen yöntem de önce doku görüntüsü bloklar halinde incelenmektedir. Her bir blok için elde edilen öznitelik vektörü hem yatayda hem de dikeyde bir sonraki blok ile karşılaştırılarak kaba bir bölütleme sağlanmakta, akabinde morfolojik iskeletleştirme ile mozaik doku görüntüsünün

sınırları belirlenerek istenilen bölütlenme gerçekleştirilmektedir [61]. Xiaodan ve diğ., doku görüntülerinin bölütlenmesinde ağaç yapılı dalgacık dönüşümünü ve bulanık Kohonen kümeleme ağ yapısını kullanmıştır [159]. Önerilen yöntem üç aşamadan meydana gelmiştir. Bunlar; öznitelik çıkarma, öznitelik kümeleme ve sınır rötuşlamadır.

Özniteliklerin gruplandırılması için önerilen geçici korelasyon (Temporal correlation), görüntü bölütleme için önemlidir. Wang ve Terman tarafından önerilen osilasyonlu korelasyon, geçici korelasyonun özel bir formudur. Yerel Uyartımlı Küresel İnhibitörlü Osilatör Sinir Ağı (YUKİOSA), (Locally Excitatory Globally Inhibitory Oscillator Neural Networks, (LEGION)) osilasyonlu korelasyon prensibine dayanır ve 1995’de Wang ve Terman tarafından görüntü bölütleme de kullanılmıştır [75]. YUKİOSA yapısı çalıştırıldığında, aynı bölgeye ait osilatörler senkronize olarak aynı fazla osilasyon yaparlar. Diğer bölgeleri temsil eden osilatörler de farklı fazlarda çalışırlar. Bu faz farklılıklarına bağlı olarak görüntü farklı bölgelere bölütlenmektedir.

Bu bölümde dalgacık osilatör sinir ağı kullanılarak doku bölütleyen bir algoritma sunulmuştur. Önerilen yöntemin blok diyagramı Şekil 5.1.’de gösterilmiştir. Önerilen yöntemde, öznitelik çıkarımını, YUKİOSA sınıflandırıcısı takip etmektedir. Öznitelikler, dalgacık dönüşümü ile elde edilen detay görüntülerin eş-oluşum matrislerinden elde edilmiştir. Bu öznitelikler istatistikseldir. YUKİOSA algoritmasında kullanılan yerel bağlaşımlar elde edilen özniteliklerden hesaplanmaktadır. Önerilen yöntem farklı mozaik doku görüntülerinde denenmiştir. Elde edilen sonuçlar gerçek bölütleme sonuçlarına oldukça yakındır.



Şekil 5.1. Önerilen yöntemin blok gösterimi

5.1. Teorik Bilgiler

5.1.1. Dalgacık Dönüşümü

Dalgacıklar, veriyi farklı frekans bileşenlerine ayıran ve sonra kendi ölçekleriyle eşleştirilmiş bir çözünürlüğe sahip bileşenler üzerinde çalışan matematiksel fonksiyonlardır. İşaretin süreksizliklere ve keskin, sivri uçlara sahip olduğu fiziksel durumları incelemeye, Fourier metotlarına göre daha avantajlıdır. Dalgacıklar matematik, kuantum fiziği, elektrik mühendisliği ve sismik jeoloji alanlarından bağımsız olarak geliştirilmişlerdir. Son on yıl içerisinde bu alanlar arasındaki yer değiştirmeler resim sıkıştırma, haberleşme, insanın görme gücü ve radar gibi birçok yeni dalgacık uygulamalarına yol açmıştır. Dalgacık dönüşümü, fonksiyonları, operatörleri veya veriyi farklı frekanstaki bileşenlerine ayıran ve ayrı ayrı her bileşen üzerinde çalışmamıza izin veren bir araçtır [110].

$\psi(x)$ ile gösterilen ana dalgacığın ötelenip genleşmesiyle elde edilen ve aşağıda tanımlanan $\psi_{m,n}(x)$ fonksiyonları bir birim küme oluştururlar şöyle ki;

$$\psi_{m,n}(x) = 2^{-m/2} \psi(2^{-m}x - n) \quad (5.1)$$

Burada m ve n tam sayılardır. Herhangi bir $f(x)$ sinyalinin $\psi_{m,n}(x)$ fonksiyonları ile çözümlenmesi DD olarak tanımlanır. $\psi_{m,n}(x)$ fonksiyonları birim dik bir küme oluşturduklarından $f(x)$ sinyali için, sırasıyla, aşağıdaki analiz ve sentez formülleri yazılabilir;

$$c_{m,n} = \int_{-\infty}^{+\infty} f(x) \psi_{m,n}(x) dx \quad (5.2)$$

$$f(x) = \sum_{m,n} c_{m,n} \psi_{m,n}(x) \quad (5.3)$$

Ana dalgacık iki aşamada tanımlanabilir. Birinci aşama aşağıdaki fark denklemini sağlayan bir ölçekleme fonksiyonu $\phi(x)$ 'in tanımlanmasıdır. İkinci aşamada ise ana dalgacık ölçekleme fonksiyonu ile ilişkilendirilir. Bu ifadeler sırasıyla aşağıda verilmiştir;

$$\phi(x) = \sqrt{2} \sum_k h(k) \phi(2x - k) \quad (5.4)$$

$$\psi(x) = \sqrt{2} \sum_k g(k) \phi(2x - k) \quad (5.5)$$

Burada $g(k) = (-1)^k h(1 - k)$. Çözümleme aşamasında ölçekleme ve ana dalgacık fonksiyonlarının hesaplanması gerekmemektedir; $h(k)$ ve $g(k)$ fonksiyonlarını kullanılarak dönüşüm katsayıları yinelemeli olarak bulunabilir. J - seviyesinde bir çözümleme şu şekilde ifade edilebilir;

$$\begin{aligned} f(x) &= \sum_k c_{0,k} \phi_{0,k}(x) \\ &= \sum_k (c_{J+1,k} \phi_{J+1,k}(k) + \sum_{j=0}^J d_{j+1,k} \psi_{j+1,k}(x)) \end{aligned} \quad (5.6)$$

Burada $c_{0,k}$ katsayıları bilinmektedir ve $j+1$ seviyesindeki $c_{j+1,n}$ ve $d_{j+1,n}$ katsayıları, j seviyesindeki $c_{j,n}$ katsayıları ile şu şekilde ilişkilidirler ($0 \leq j \leq J$);

$$c_{j+1,n} = \sum_k c_{j,k} h(k - 2n) \quad (5.7a)$$

$$d_{j+1,n} = \sum_k d_{j,k} g(k - 2n) \quad (5.7b)$$


Bu ifadelerin sinyal işleme yönünden yorumu ise şöyledir: $j+1$ çözünürlüğündeki $c_{j+1,n}$ ve $d_{j+1,n}$ katsayılarının elde edilmesi için, j çözünürlüğündeki $c_{j,n}$ ve $d_{j,n}$ katsayılarının $\tilde{h}(n)$ ve $\tilde{g}(n)$ fonksiyonları ile evriştirilip örnek sayısının iki kere seyreltilmesi gerekmektedir. Burada $\tilde{h}(n)$ ve $\tilde{g}(n)$ fonksiyonları, sırasıyla L alçak geçiren dördün ikiz ve H yüksek geçiren dördün ikiz süzgeçleridir ve aşağıdaki şekilde tanımlanmışlardır;

$$\tilde{h}(n) = h(-n) \quad (5.8a)$$

$$\tilde{g}(n) = g(-n) \quad (5.8b)$$


Bu işlemin sonucunda her j -seviyesindeki çözünürlük için alçak çözünürlüğe sahip $c_{j,n}$ katsayıları ve detayları gösteren $d_{j,n}$ katsayıları elde edilir. Şekil 5.2’de tek boyutlu dalgacık filtrelerin iki boyutlu görüntüye nasıl uyarlandığı gösterilmiştir. Görüntünün satırları ve

sütunları ayrı ayrı alçak ve yüksek geçiren filtrelerden geçirilip, örnek sayısı yarıya düşürülür. Böylece görüntünün yaklaşığı ile detayları elde edilir.



Şekil 5.2. Tek seviyeli dalgacık analiz filtre bankası

Sinyaller sadece alçak geçiren bantların kullanılması ile piramit yapıda dalgacık dönüşümü ile alt bantlara ayrıştırılabileceğı gibi tüm alt bantları kullanan dalgacık paket dönüşümü ile de alt bantlara ayrıştırılabilir. 2-boyutlu uzaydaki 2-düzeyle bir dalgacık paket ağaç yapısı Şekil 5.3'de gösterilmiştir. A harfi yaklaşığı, H harfi yatay, V harfi dikey, D harfi ise köşegensel detayı temsil etmektedir.



Şekil 5.3. DD ayrışımı (a) Tek seviyeli ayrışım (b) İki seviyeli ayrışım.

5.1.2. Doku Öznitelik Çıkarımı

Doku, bir görüntüdeki farklı bölgelere işaret eden önemli bir bilgidir. Doku, aslında çoklu-ölçekli bir fenomen olduğundan, dalgacık dönüşümü gibi çoklu çözünürlüklü yaklaşımlar doku analizi uygulamalarında oldukça iyi sonuçlar vermektedir. Ayrıca yapılan son çalışmalar, küresel ve bölgesel bilgileri açığa çıkarması açısından uzamsal/frekans gösteriminin dokuları karakterize edecek yeterlilikte olduğunu ortaya koymuştur. Dalgacık dönüşümü de orijinal bir görüntüyü uzamsal/frekans sunumu ile farklı ölçeklerde ayrıştıran bir araçtır. Bunun için, dalgacık dönüşümü ölçeklenebilir temel bir dalgacık fonksiyonu kullanıp sabit çözünürlük problemine çözüm getirerek, işaretin farklı çözünürlüklerde daha esnek bir zaman bölgesi analizini yapar. Dalgacık dönüşümü zaman – ölçek metoduna dayalı olduğu için, odağa tam olarak ayarlanarak işaretin farklı kısımlarını gözetleyebilen bir matematik mikroskobu gibi davranır.

Dokuları karakterize edecek öznitelikler, dalgacık dönüşümü ile elde edilen alt görüntülerin eş-oluşum matrislerinden elde edilmiştir. Gri seviyesi eş oluşum matrisleri Haralick tarafından doku analizi yöntemi olarak kullanılmıştır [155]. Burada kabul edilen doku bilgisi dalgacık ayrışımı ile elde edilen düzeylerin tüm veya ortalama uzamsal komşuluk bağlarında bulunur. Doku bilgisi, gri seviyesi uzamsal bağımlılık matrisleri ile belirtilir. Bu matrisler değişik açı ve uzaklık değerlerinde hesaplanabilir. Elde edilen bu matrislerden çeşitli istatistiksel öznitelikler çıkarılabilir. Haralick 1973’de yaptığı çalışmada gri-seviyesi eş oluşum matrislerinden 14 tane istatistiksel öznitelik önermiştir [155]. Bu uygulamada bunlardan sadece 5 tanesi kullanılmıştır. Kullanılan öznitelikler; enerji, korelasyon, bölgesel homojenlik, entropi ve kümeleme ayrıntısıdır(cluster shade). Bu öznitelikler sırası ile şöyle tanımlanırlar;

$$F_1 = \sum_{x=1}^N \sum_{y=1}^N p(x, y)^2 \quad (5.9)$$

$$F_2 = \sum_{x=1}^N \sum_{y=1}^N \frac{1}{1 + (x - y)^2} p(x, y) \quad (5.10)$$

$$F_3 = \sum_{x=1}^N \sum_{y=1}^N (x - y)^2 p(x, y) \quad (5.11)$$

$$F_4 = \sum_{x=1}^N \sum_{y=1}^N (x - M_x + y - M_y)^3 p(x, y) \quad (5.12)$$

$$F_5 = \sum_{x=1}^N \sum_{y=1}^N p(x, y) \log_2(p(x, y)) \quad (5.13)$$

$$M_x = \sum_{x=1}^N \sum_{y=1}^N x.p(x, y) \text{ ve } M_y = \sum_{x=1}^N \sum_{y=1}^N y.p(x, y) \quad (5.14)$$

burada $p(x,y)$, (x,y) 'ninci girişin normalize edilmiş eş oluşum matrisidir, N ise gri seviyesini belirtir.

5.1.3. Osilatör Sinir Ağı

Burada kullanılan osilatör sinir ağı, Wang ve Terman tarafından önerilen YUKİOSA, osilasyon ilkesine dayanır. Bu ilkeye göre aynı bölgeye ait ya da öznitelik vektörleri aynı olan fakat farklı nitelikleri temsil eden osilatörler fazlarını aynılaştırarak o bölgede nitelikleri bir bütün olarak temsil ederler [74]. YUKİOSA ağındaki her bir osilatör iki adet diferansiyel denklemle ifade edilir;

$$\frac{\partial x_i}{\partial t} = 3x_i - x_i^3 + 2 - y_i + I_i + p \quad (5.15a)$$

$$\frac{\partial y_i}{\partial t} = \varepsilon \left(\gamma \left(1 + \tanh \left(\frac{x_i}{\beta} \right) \right) - y_i \right) \quad (5.15b)$$

YUKİOSA' daki i osilatörü, uyarıcı birim x_i ile inhibitör birimi y_i arasında geri beslemeli döngü şeklinde tanımlanmıştır. Burada p Gauss gürültü değişkenidir, I_i ise i osilatörün toplam giriş değeridir. β , ε ve γ parametre değerleridir. Şekil 5.4 (a)' daki x-sıfır eğrisi ($x_i = 0$) kübik bir eğri iken y-sıfır eğrisi ($y_i = 0$) bir sigmoid eğridir.

$$I_i = I_{input} H(P - \theta) + S_i \quad (5.16)$$

Eğer denklem 5.16 ile tanımlanmış I_i değeri sıfırdan büyük olursa bu iki eğri birbirini kübik eğrinin orta dalında keser ve osilasyon gözlenir. Bu osilasyon sol dalı ve sağ dalı kapsayacak



şekilde, Şekil 5.4 (a)' da verilen koyu oklu çizgiler boyunca hareket ederek döngüsünü tamamlar. Yalnız osilasyonun bu şekilde olması için, osilatörün sağ diz ve sol diz noktalarında atlama yapması gerekir. Diğer taraftan eğer I_i sıfırdan küçük olursa iki eğri sol dalda kesişir ve osilasyon gözlenmez. Ayrıca osilasyonun olması için β , ε ve γ parametrelerinin dikkatli seçilmesi gerekir. Örneğin ε küçük seçilmelidir. I_{input} değeri harici uyarıcıdır. $S_i = \sum_{k \in N_i} W_{ik} H(x_k - \theta_x) - W_z z$ ise yanal potansiyel değişkeni ile diğer osilatörlerden ve global inhibitörden gelen bağlaşım ağırlıklarını içermektedir. Ayrıca W_{ik} i osilatörü ile k osilatörü arasındaki bağlaşım ağırlığını, H birim basamak işlevini, θ_x x değerleri için bir eşik değer ve W_z ise global inhibitörün bağlaşım ağırlığını göstermektedir. N yerel bağlaşım komşuluğunu göstermektedir. Şekil 5.4 (b)'de birinci dereceden yerel komşuluk bağlantıları gösterilmiştir. Görüntüdeki homojen bölgelerin ayırt edilmesi için her bir osilatöre bir potansiyel değeri P atanmıştır.

$$\frac{\partial P}{\partial t} = \lambda(1 - P)H\left[\sum_{k \in N_i} T_{ik} H(x_k - \theta_x) - \theta_p\right] - \mu\varepsilon P \quad (5.17)$$

Burada λ ve μ parametre değerleridir, T_{ik} ise k ile i osilatörleri arasındaki sabit ağırlık değerleridir. Eğer N yerel komşuluk bağlaşımındaki aktif osilatörlerin ağırlıkları toplamı θ_p eşik değerini aşıyorsa o osilatör lider seçilmektedir. Bir osilatörün aktif olabilirliliği global inhibitöre, yani z 'ye bağlıdır.

$$dz / dt = H\left[\sum_k H(x_k) - 1\right] - z \quad (5.18)$$

Eğer aktif bir osilatör yoksa z sıfıra doğru azalır, aksi halde bire doğru yükselir. Lider olan bir osilatör ancak $z < 0.5$ olduğu anda aktifleşir. Aksi durumda bir osilatör ancak aktif halde bulunan osilatörle güçlü bağlaşımlara sahipse tetiklenir.



Şekil 5. 4. (a) x-sıfır eğrisi ve y-sıfır eğrisi, (b) 3x 3'lük LEGION yapısı

5.2.Önerilen Yöntem

Bilindiği gibi doku analizi bölgesel bir olgudur ve doku üzerinde herhangi bir işlem yapılacaksa, dokunun tamamı yerine, belirli bir bölgesi üzerinde işlemler yapılmalıdır. Burada bölge olarak tanımlanan, doku piksellerinin $N \times N'$ lik bir pencere içinde kalan kısımlarıdır. Önerilen doku bölütleme yönteminin blok diyagramı Şekil 5.1.'de verilmiştir.

Dalgacık Dönüşümü: Önerilen doku bölütleme sisteminin ilk basamağını ayrık dalgacık dönüşümü oluşturmaktadır. Bu amaçla 9/7 biortogonal dalgacık filtresi ile doku mozaik görüntüleri alt görüntülere ayrıştırılmıştır. 9/7 biortogonal dalgacık filtresinin kullanılması ayıricılık özelliği ve etkinliliğinden kaynaklanmaktadır [160]. Sadece 1 seviyeli dalgacık ayrışımı kullanılmıştır ve detay görüntüler eş-oluşum matrislerinin hesaplanması için kullanılmıştır. Bu basamak şöyle formülize edilmiştir.

$$(D_i) \quad i = 1, 2, 3. \quad (5.19)$$

D, detay görüntüleri göstermektedir.

Öznitelik Çıkarma: Doku görüntülerinin ikinci dereceden istatistiksel özniteliklerinin elde edilmesi için, dalgacık ayrışımı ile oluşturulan üç detay görüntü kullanılmıştır. Hesaplanan öznitelikler her bir detay görüntüden oluşturulan ve 0, 45, 90 ve 135 derecelik açılar için oluşturulmuş eş oluşum matrisleri üzerindendir. Böylece 4 eş oluşum matrisi ve 3 detay görüntü için toplam 12 adet eş oluşum matrisi elde edilmiştir.

$$es_ol_{\alpha}(D_i), \quad i = 1, 2, 3 \text{ ve } \alpha = 0^{\circ}, 45^{\circ}, 90^{\circ}, 135^{\circ} \quad (5.20)$$

Elde edilen bu 12 eş oluşum matrisinin her biri için denklem (5.9)-(5.14) numaraları ile verilen öznitelikler hesaplanmaktadır. Sonuç olarak her bir N x N pencere için 12 x 5 =60 elemanlı bir öznitelik vektörü elde edilmektedir.

$$F_n(es - ol_{\alpha}(D_i)), \quad i = 1, 2, 3. \quad \alpha = 0^{\circ}, 45^{\circ}, 90^{\circ}, 135^{\circ} \text{ ve } n = 1, 2, 3, 4, 5. \quad (5.21)$$

Burada n ilgili denklem numarasını belirtmektedir.

Osilatör Sinir Ağı Sınıflandırıcısı: Önerilen doku bölütleme sisteminin son bileşenini osilatör sinir ağı sınıflandırıcısı oluşturmaktadır. Osilatör sinir ağı sınıflandırıcısı için önemli olan hücre ağırlıkları, bir önceki adımda elde edilen öznitelik vektörlerinden hesaplanmaktadır. Her bir hücrenin ağırlığı hesaplanırken, o hücre ile o hücreye komşu diğer hücrelerin öznitelik vektörleri kullanılmaktadır. Uygulama için, ağırlık işleyişini sağlayan diferansiyel denklemlerin uygun bir yöntem ile çözülmesi gerekmektedir. Diferansiyel denklemlerin çözümünde genel olarak dördüncü dereceden Runge-Kutta yöntemi kullanılır. Bu yöntemle diferansiyel denklemlerin çözümlenmesi büyük hesaplama yükü getirmektedir. Bu hesaplama yükünü ve

karmaşasını gidermek için Wang ve Terman, 1997’de önerdikleri yeni bir yöntemle osilatör sinir ağının çalışmasına uygun bir kümeleme algoritması geliştirmiştir [74]. Hesaplama yükü açısından daha avantajlı olan bu yöntem, deneysel çalışmalarımızda kullanılmıştır. Önerilen kümeleme algoritması kısaca şöyle çalışmaktadır. Osilatör sinir ağı modelinin boyutu giriş görüntüsü ile aynı boyuttadır. Yani her bir piksel, ağda bir hücreye denk gelmektedir. Bütün hücreler verilen komşulukta birbirleri ile bağlantılıdır ve her bir hücre aynı zamanda global inhibitöre bağlıdır. Her bir piksel için hesaplanan öznitelik vektörü, o hücrenin girişi olmakta ve ağırlıklar bu değerlerden aşağıda verilen denklemle hesaplanmaktadır.

$$W_{ij} = \frac{|F_i| * |F_j|}{1 + \sum |F_i - F_j|} \quad (5.22)$$

Burada $| |$, öznitelik vektörünün genliğini göstermektedir. Böylece her bir hücre kendisine bağlı diğer hücrelerle ağırlık vektörlerinin değerlerine göre güçlü bağlantılı veya zayıf bağlantılı olarak adlandırılırlar. Giriş görüntüsündeki benzer özellik gösteren piksellerin öznitelikleri yakın değerlerde olacağından bu hücreler arası bağlantılar da kuvvetli olacaktır. Güçlü bağlantılara sahip hücreler daha sonra lider olarak adlandırılırlar ve bu liderlerin kendi bölgelerini oluşturmalarına izin verilir. Bu yöntem diğer taraftan bir bölge büyüme algoritması olarak görülebilir. Global inhibitör bir liderin kendi bölgesini oluştururken, diğer liderin durması gerektiğini bildirir ve böylece farklı zamanlarda farklı liderler kendi bölgelerini oluşturarak bölümlenmeyi tamamlarlar.

5.3. Uygulamalar ve Sonuçları

Önerilen yöntemin başarımının test edilmesi için 128 x 128 boyutunda farklı mozaik doku görüntüleri kullanılmıştır. Bu mozaik doku görüntüleri, Brodatz albümünden alınmış farklı doku örneklerinin birleştirilmesinden oluşturulmuştur. Gerçekleştirilen çalışmaların uygulama adımları aşağıda açıklanmıştır.

Adım 1: Mozaik doku görüntüsü alınmıştır.

Adım 2: Alınan doku görüntüsü 9/7 biortogonal dalgacık filtresi kullanılarak ayrıştırılmış ve sadece detay görüntüler kullanılmak üzere seçilmiştir.


Adım 3: 9 x 9’luk kayan bir pencere bir önceki adımda elde edilen her bir detay görüntüyü aynı anda taramaktadır.

Adım 4: Bir önceki adımda oluşturulan 9×9 'luk her bir pencere için dört doğrultuda ve tek piksel mesafe için eş-oluşum matrisleri oluşturulmaktadır. Eş-oluşum matrislerinin boyutları 64×64 ile sınırlandırılmıştır. Daha büyük boyutlu eş-oluşum matrisleri kullanıldığında bölütleme başarımları çok da değişmemektedir.

Adım 5: Elde edilen eş-oluşum matrislerinden öznitelikler elde edilmektedir. Bu adım ile her bir pencere için 60 adet öznitelik oluşturulmaktadır.


Adım 6: Elde edilen öznitelikler kullanılarak, osilatör sinir ağı ağırlıkları oluşturulur ve bölütleme başlatılır.

Şekil 5.5' deki örnekte, önerilen bölütleme yönteminin her bir adımı ve bu adımlar sonucunda oluşan görüntüler verilmiştir. Sisteme giriş olarak kullanılan mozaik doku görüntüsü 128×128 boyutunda olup, her bir karesi farklı bir doku görüntüsünden alınmıştır. Bölütleme işlemi dalgacık dönüşümü ile başlamaktadır ve detay görüntüler bir sonraki adım için saklanmaktadır. Detay görüntüler Şekil 5.5 a,b,c' de sırası ile gösterilmiştir. Her bir detay görüntünün 9×9 pencere ile taranması ve dört açı değeri için eş-oluşum matrislerin elde edilmesi ve bu matrislerden istatistiksel özniteliklerin elde edilmesi diğer bir adımda gerçekleştirilmektedir. Uygulamada dört doğrultu için oluşturulan eş-oluşum matrisi toplanarak tek bir eş-oluşum matrisi oluşturulmuştur. Böylece her bir pencere için 60 elemanlı öznitelik vektörü yerine 15 elemanlı (3 eş-oluşum matrisi $\times$ 5 istatistiksel özellik) öznitelik vektörü kullanılmıştır.



Şekil 5.5. Orijinal görüntü (b) Yatay Detay (c) Dikey Detay (d) Diyagonal Detay
(e) Bölütlenmiş mozaik doku

Elde edilen her bir öz nitelik, doku ile ilgili farklı bir bilgi taşımaktadır. Oluşturulan 15 adet öz nitelik Şekil 5.6’da gösterilmiştir. Doku görüntüsü 9 x 9’luk kayan bir pencere ile tarandığı için oluşan öz nitelik görüntülerinin boyutları 120 x 120’ dir. Öz nitelik değerleri daha sonra lineer normalizasyon ile 1-256 değer aralığına normalize edilmiştir.




Şekil 5.6. Özniteliklerin görüntüye dönüştürülmüş durumları

Osilatör sinir ağının yerel bağlaşımları belirlendikten sonra bölütleme işlemi 120×120 'lik osilatör ağına gerçekleştirilmektedir. Bütün osilatörlerin başlangıç çalışma noktaları, faz grafiğinin sol dalıdır (Şekil 5.4. (a)). Hesaplama etkinliği olması açısından öznitelik vektörleri aynı olan hücreler benzer fazlarda başlatılmışlardır. Başlangıç anından itibaren birkaç iterasyondan sonra

bir grup osilatör aktifleşirken diğer osilatörler, global inhibitörün etkisiyle pasifleşirler. Osilatörlerin senkronizasyonu ve de-senkronizasyonu işlemi sırasında, her bir doku parçası farklı zamanlarda aktif olmakta ve bölütleme işlemi böylece tamamlanmaktadır. Osilatör sinir ağı yapısında önemli iki parametre mevcuttur. Bunlar W_z ve θ_p dir. W_z , global inhibitörün bağlaşım ağırlığıdır. θ_p ise lider seçiminde kullanılan eşik değeridir. W_z değerinin büyük seçilmesi osilatörlerin senkronizasyonunu zorlaştırır ve aynı özniteliğe sahip hücrelerin gruplaşmasını engeller. Bölütleme sonucunda oluşan bölgelerin homojen olması için W_z çok dikkatli seçilmelidir. Diğer taraftan θ_p nin büyük seçilmesi lider seçimini zorlaştırmakta ve olması gerekenden farklı bölgeler oluşabilmektedir. Orijinal görüntüdeki bölge sayısının doğru olarak tahmin edilmesindeki en önemli parametre θ_p dir. Yine bu parametrenin uygun seçilememesi durumda çok sayıda lider oluşacaktır ve görüntü olması gerekenden daha fazla bölgeye ayrıştırılacaktır. Bu çalışmada $\theta_p=4.85e+5$ and $W_z=3.5763e+4$ olarak belirlenmiştir. Şekil 5.7’de farklı dokulardan ve farklı geometrik şekillerden oluşturulan doku mozaikleri ve bölütleme sonuçları verilmiştir. Önerilen yöntemin etkinliğinin test edilmesi için oluşturulan mozaik doku görüntüleri sırası ile dört, iki, iki ve üç sınıf olacak şekilde farklı geometrilere yerleştirilmişlerdir.

Uygulama sonuçlarından da görüleceği gibi önerilen yöntemle, sınıf sayısı önceden belirtilmeksizin kullanılan mozaik doku görüntüleri başarılı bir şekilde bölütlenmiştir. Oluşan hataların çoğunluğu sınır bölgelerinde oluşmaktadır. Başarımın artması için hiçbir şekilde sonuçlara sonradan bir işlem yapılmamıştır. Şekil 5.7’nin ilk test dokusu yapay bir görüntü olup, her bir karede farklı yönlerde çizilmiş çizgiler ile doku yapısı kazandırılmaya çalışılmıştır. Bu görüntünün bölütleme sonucu hemen hemen hatasızdır. Sadece diyagonal çizgilerin oluşturduğu doku yapısının bölütlenmesinde hatalar oluşmuştur. Yine benzer sonuçlar diğer mozaik doku görüntüleri için de elde edilmiştir. Önemli diğer bir hatada doku görüntülerin çözünürlükleri ile öznitelik elde edilen tarama penceresinin boyutlarından kaynaklanmaktadır. Eğer pencere doku özniteliklerini karakterize edebilecek büyüklükte olmadığı takdirde, yöntem istenmeyen sonuçlar üretmektedir.



Şekil 5.7. Bölütleme sonuçları

6. DALGACIK PAKET SİNİR AĞI İLE GÖRÜNTÜ SINIFLANDIRMA

Sklansky' ye göre bir görüntüdeki herhangi bir bölgenin istatistiksel özellikleri yavaş yavaş değişiyorsa veya yaklaşık olarak periyodikse, görüntünün o bölgesi doku özelliği gösteriyor demektir. Doku, doğa görüntüleri, uydu fotoğrafları ve biyomedikal görüntüler gibi birçok görüntünün analizinde kullanılan çok önemli bir karakteristiktir [161]. Dokuların insan tarafından algılanış şekli, örüntü tanıma sistemleri için model oluşturmaktadır. Ayrıca doku, görüntü bölgesinin gri seviyelerinin bölgesel komşuluk özelliklerinin bir kümesi olarak da tanımlanabilir. Doku sınıflandırma, iki temel adımda özetlenebilir. Birinci adım, doku öznelik saptanması, ikinci adım ise, saptanan doku öznelikleri ile dokuların sınıflandırılmasıdır. Doku sınıflandırmanın amacı, bilinmeyen doku örneklerini, bazı özneliklere veya sınıflandırma kurallarına bağlı olarak var olan sınıflara atamaktır.

Son yıllarda yapılan çalışmalar, dalgacık dönüşümünün, çoklu çözünürlük analizlerinde kullanılan oldukça önemli bir araç olduğunu göstermiştir. Haberleşme, görüntü analizi, görüntü sıkıştırma, görüntü bölütleme, işaret işleme gibi geniş bir alanda uygulama imkânı bulmuştur. Öncelikle çoklu ölçekli dalgacık analizi, doku analizi için ideal bir yaklaşımdır. Çünkü bilindiği gibi ölçek doku bilgisini açığa çıkaran önemli bir karakteristiktir. Doku sınıflandırma problemine çözüm olacak birçok yöntem literatürde mevcuttur [45]. Weszka ve diğ., Fourier güç spektrumu öznelikleri ve ikinci dereceden gri seviyesi istatistiksel özellikleri ve ayrıca birinci dereceden istatistiksel özellikleri kullanarak doku sınıflandırma için karşılaştırmalı bir çalışma gerçekleştirmişlerdir [162]. Muneeswaran ve diğ., doku görüntüleri için döndürmeden ve ölçeklendirmeden bağımsız yeni öznelikler önermişlerdir [164]. Önerilen yöntemde değişmez öznelik çıkarımı için Meksika şapkası, Gauss ve ortogonal dalgacık aileleri kullanılmıştır. Li ve diğ., doku sınıflandırma için diyadik dalgacık, dalgacık çerçeve ve Gabor dalgacık özneliklerini hem bireysel hem de kombine olarak kullanmışlardır [164]. Sınıflandırıcı olarak ise destek vektör makinelerini (DVM) kullanılmıştır. Yine doku sınıflandırma için DVM ve ayrık dalgacık çerçeve dönüşümü kullanılarak, döndürmeden bağımsız öznelik çıkarımı Kwok ve diğ. tarafından önerilmiştir [165]. Arivazhagan ve diğ., dalgacık dönüşümü istatistiksel öznelikleri, dalgacık eş oluşum matrisi öznelikleri ve bunların kombinasyonlarını kullanarak farklı öznelik vektörleri ile doku sınıflandırmışlardır. Önerilen yöntemde basit bir mesafe sınıflandırıcısı kullanılmıştır [61]. Mojsilovic ve diğ., dokuların karakterize edilmesinde kullanılan ayrışım filtresinin ne kadar önemli olduğunu ve dokuları karakterize edecek baskın öznelik vektörünün tayin edilmesini araştırma makalelerinde göstermişlerdir [60]. Çalışmada 23 adet Brodatz doku örneği kullanılmıştır.

Uygulama sonuçlar ile kullanılan ayrışım filtresinin dokuların özelliklerinin çıkarılmasındaki etkisi ortaya konmuştur. Çalışmada en uygun 19 adet ayrışım filtresi tespit edilmiştir. Chen ve diğ., doku sınıflandırma için önerilen filtreleme metotlarının performanslarını değerlendiren, karşılaştırmalı bir çalışma gerçekleştirmişlerdir [64]. Çalışmada incelenen filtreleme yöntemleri, Fourier dönüşümü, uzamsal filtre, Gabor filtresi ve dalgacık dönüşümüdür. Çalışmanın deneysel sonuçları ile dalgacık dönüşümünün üstünlüğü gösterilmiştir. Wang ve Liu dokuları tanımlamak için çoklu çözünürlük bir MRA modeli önermişlerdir [166]. Bu model hem MRA' nın avantajını hem de çoklu çözünürlüğün avantajını tek bir modelde birleştirerek, doku sınıflandırma için dayanıklı bir yapı oluşturmuştur. Bu model de ayrıca hem yüksek geçiren hem de alçak geçiren bileşenler kullanılmıştır.

Bilindiği gibi, 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 tümlşik 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. Diğer taraftan dalgacık paket sinir ağı yapısı, dalgacık paket dönüşümünü öznitelik çıkarım amaçlı kullanan ve sinir ağı yapısını da sınıflandırma amaçlı kullanan dayanıklı bir yapıdır. Böylece bu çalışma da DPSA (Dalgacık Paket Sinir Ağı) algoritması kullanılarak Brodatz doku albümünün 10 adet dokusu sınıflandırılmıştır.

6.1. Matematiksel Temeller


6.1.1. Dalgacık Paket Ayrışımı

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 6.1. deki gibi ifade edilebilir.

$$d_m(t_m) = x(t)\psi_m\left(\frac{t-t_m}{2^m}\right) \quad (6.1)$$

burada $x(t)$ işaretin kendisini ve ψ_m m frekans seviyesindeki ayrışım filtresini temsil eder. Ayrışım filtresinin etkisi, m seviyede 2^m ile skalalanır. DPA, ADD' ye benzer olup, işaret üzerinde mümkün olan birçok ayrışımı 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. DPA' nın avantajı asıl işaretin en uygun ZFG' sini elde etmek için ayrışımın farklı seviyelerini birleştirmeyi mümkün kılmasıdır.

Şekil 6,1'de ikinci seviyeden dalgacık paket ayrışımı gösterilmiştir. Böylece toplam 4^n , n ayrışım seviyesi olmak üzere, 16 alt görüntü elde edilmektedir.




Şekil 6. 1. DPA ile DD ayrışımının ağaç yapısı

6.1.2. Dalgacık Paket Sinir Ağları

Dalgacık sinir ağları (DSA), YSA' ların karar yapıları ile dalgacık dönüşümünün özellik çıkarma ve seçme yeteneklerini birleştirir [167]. 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 [168, 170].

DSA'nın çeşitli alanlarda uygulamaları bulunmaktadır. Bunlardan bazıları; kroner arter hastalıklarını sınıflama [169], protez kalp kapaklarının karakteristik durumlarını belirleme, biyo-işaretleri sınıflama, Radar hedef sınıflama, zaman serilerinin tahmini gibi.

Dalgacık dönüşüm temelli olan DSA' ların yapısı Şekil 6.2.'de verilmiştir [110]. Bu YSA yapısının çıkış Denklemi 6.2'de tanımlanmıştır.



Şekil 6.2. Dalgacık sinir ağı yapısı.


$$y = F\left(\sum_{k=1}^m w_k \cdot \sum_{t=1}^n x(t) \cdot \psi\left(\frac{t-t_k}{2^k}\right)\right) \quad (6.2)$$

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 çekmede kullanılan etkinleştirme fonksiyonunu göstermektedir. DSA 'nın ağırlık parametreleri hata geri yayılım türü bir algoritma ile ayarlanır. 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.

6.2. Metodoloji


Bu bölümde doku görüntülerine uygulanan ve kaynak [110, 170] çalışmalarında geliştirilen dalgacık paket dönüşüm sinir ağı ile öznetelik çıkarma ve sınıflandırma yöntemi kullanılmıştır. DPSA algoritmasının doku sınıflandırma problemine uyarlanması iki adımda gerçekleştirilmiştir.

Adım 1: DPSA yapısının girişine 512 x 512 boyutundaki Brodatz doku albümünden elde edilen 128 x 128 boyutundaki örtüşen doku görüntüleri verilmektedir. Örnek bir doku görüntüsü Şekil 6. 3.'de gösterilmiştir.



Şekil 6. 3. Örnek doku görüntüsü (Tuğla duvar)


Adım 2: DPSA, hem öznitelik çıkarımını hem de sınıflandırma işlemini kapsamaktadır. Şekil 6. 4.'de DPSA'nın blok diyagramı verilmiştir [110]. Bir örüntü tanıma sisteminde en önemli aşama öznitelik çıkarımıdır. Başka bir deyişle bu aşama, örüntü tanıma sisteminin başarımında anahtar rolü oynar. Giriş örnekleri arasında ayrımı gerçekleştirmek için örüntü özniteliklerinin 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 çıkarımı üzerine yoğunlaşmıştır. Öznitelik çıkarımının yapılmasındaki en önemli amaç ölçüm veya örnek uzayından daha küçük boyuta dönüşmeyi sağlamaktır. Böylece, sınıflandırıcının daha küçük hatalarla eğitilmesi ve daha kısa sürede karar aşamasına ulaşılması mümkün olacaktır. Diğer taraftan bu adım iki kısımdan oluşmaktadır; bunlar sırası ile dalgacık katmanı ve çok katmanlı algılayıcı katmanlarıdır.



Şekil 6.4. DPSA blok diyagramı

(i) **Dalgacık katmanı:** Bu katman giriş doku örneklerinden öznitelik çıkarma ile yükümlüdür. Ayrıca öznitelik çıkarımı üç aşamadan oluşmaktadır.

Aşama 1. Dalgacık Paket Ayırımı: Doku görüntülerin dalgacık dönüşümü için ağaç yapılı dalgacık paket dönüşümü ve ayrışım seviyesi 2 olan Daubechies-3 dalgacık filtresi kullanılmıştır. Şekil 6. 5’de iki seviye dalgacık ağaç ayrışımı kullanılarak elde edilen görüntüler gösterilmiştir.



Şekil 6.5. Orijinal doku görüntüsünün 2 seviyeli dalgacık paket ayrışımı

Aşama 2. Dalgacık Paket Entropi: Entropi kavramı, bir sistemin düzenliliğini ölçmek amacı ile termodinamik fiziğinde iyi bilinen bir kavramdır. Öznitelik çıkarımı için denklem 6.3 ile verilen norm entropi, dalgacık paket ayrışımı ile elde edilen ağaç yapısının her bir yaprağına uygulanmıştır. Böylece, 2 seviyeli bir ayrışım için norm entropilerden oluşan öznitelik vektörünün boyu 16 olmaktadır.

$$E(f_{doku}) = \sum_x \sum_y |f(x, y)|^P \quad (6.3)$$

Burada $f(x,y)$ dalgacık paket ayrışım ile elde edilen her bir görüntünün (x,y) noktasındaki değeridir. P değeri ise norm entropi için kullanılan bir parametre olup, $1 \leq P < 2$ aralığında seçilir.

Aşama 3. Dalgacık Paket Enerji: Turkoğlu ve diğ., önerdikleri yöntemde sadece entropi değerlerinden oluşan öznitelik vektörü kullanmışlardır [170]. Doku görüntülerinin karakterize edilmesinde dalgacık katsayılarının enerjileri kullanılan diğer önemli özniteliktir. Bundan dolayı burada entropi özniteliklerinin yanı sıra l_1 normu ve l_2 normu enerjiler de öznitelik vektörüne ilave edilmiştir. Böylece daha etkin öznitelik vektörü elde edilmiştir. l_1 normu ve l_2 normu enerji denklemleri şöyle ifade edilir;


$$En_1 = \frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N |f(x, y)| \quad (6.4)$$

$$En_2 = \frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N f(x, y)^2 \quad (6.5)$$

(ii) Çok katmanlı algılayıcı katmanı: Bu katman, dalgacık katmanından elde edilen öznitelik vektörlerinin akıllı sınıflandırılmasında kullanılmaktadır. Tablo 6.1.'de bu uygulama için kullanılan ÇKA'nin yapısal değerleri ile eğitim parametreleri verilmiştir. Ayrıca Şekil 6.6'da eğitim başarımlar eğrisi gösterilmiştir.

Tablo 6.1. ÇKA' nın yapısal ve eğitim parametreleri

YSA mimarisi	
Katman sayısı	3
Her bir katmandaki hücre sayıları	Giriş : 10 Ara : 6 Çıkış : 1
Başlangıç ağırlıkları	Rasgele
Aktivasyon fonksiyonları	Tangent Sigmoid
Eğitim parametreleri	
Öğrenme kuralı	Levenberg-Marquardt geriye yayılım
Öğrenme oranı	0.8
Toplam karesel hata	1e-07



Şekli 6. 6. DPSA eğitim başarımları

6.3. Uygulamalar ve Sonuçları

Uygulamalar ilgili referansta verilen web sitesinden alınan 10 adet Brodatz albümüne ait doku görüntüleri üzerinde yapılmıştır [171]. Görüntüler 512 x 512 boyutunda olup 8 bit gri-seviyelidirler. Şekil 6.7’de kullanılan doku görüntüleri verilmiştir. Gerçekleştirilen çalışmaların uygulama adımları aşağıda açıklanmıştır.


Adım 1: Her bir doku görüntüsünden eğitim amaçlı, 15 adet 128 x 128 boyutunda örtüşen rasgele örnekler alınmıştır. Böylece toplam $10 \times 15 = 150$ adet 128 x 128 lik doku görüntüleri eğitim için hazırlanmıştır.

Adım 2: Her bir doku görüntüsü bir önceki metodoloji bölümünde anlatılan süreçlerden geçirilerek her bir görüntü için öznitelik vektörü elde edilmiştir. Öznitelik vektörünün boyutu 48 x150'dir. Eğitim için kullanılacak her bir doku görüntüsü, Daubechies-3 filtresi ile 2 seviyeli dalgacık paket ayrışımına tabi tutulursa, 3 öznitelik (dalgacık paket entropi, l_1 ve l_2 normu 2 dalgacık paket enerjisi) x 16 alt doku görüntüsü = 48 öznitelik elde edilir.

Adım 3: Eğitim için elde edilen öznitelik vektörü, Tablo 6.1. de verilen çok katmanlı sinir ağı ile eğitilmiştir. Eğitimde, istenilen hata değerine 250 iterasyonda ulaşılmıştır.

Adım 4: Önerilen yöntemin test edilmesi için her bir doku için yine 128 x 128 boyutunda rasgele, örtüşen 100 alt görüntü oluşturuldu. Toplam 1000 adet görüntüden elde edilen 48 x 1000'lik öznitelik vektörü ile eğitilen DPSSA yapısı test edilmiştir.

Deneysel sonuçlar Tablo 6.2. de gösterilmiştir. Tablo'2 den de görüleceği gibi 5 tane doku görüntüsü, önerilen sistemle, %100 doğru sınıflandırılmıştır. % 100 oranında doğru sınıflandırılan doku örnekleri şunlardır; D9, Gravel, Herringbone weave, Rough wall ve D19. D68 doku örneğini ise %99'luk bir başarı ile sınıflandırılmıştır. D94, D12 ve Herringbone weave ise yaklaşık %90'lık bir başarı oranı ile tanınmıştır. Sistemin genel başarımı %96 dır.




Şekil 6.7. Kullanılan Brodatz doku örnekleri

Tablo 6.2. Uygulama Sonuçları

Doku görüntüleri	Doğru sınıflandırılan örüntü sayısı	Yanlış sınıflandırılan örüntü sayısı	Toplam örüntü sayısı
Brick wall (D94)	87	13	100
Grass (D9)	100	0	100
Gravel	100	0	100
Bark (D12)	94	6	100
Herringbone weave	100	0	100
Plastic bubbles (D112)	91	9	100
Rough wall	100	0	100
Straw	86	14	100
Woolen cloth (D19)	100	0	100
Wood grain (D68)	99	1	100

7. GELİŞTİRİLEN YÖNTEMLERİN ENDOSKOPIK GÖRÜNTÜLERE UYGULANMASI

Bu bölümde, özellik çıkarımı için geliştirilen yöntemlerin endoskopik görüntülere uygulanması gerçekleştirilmiştir. Endoskopik görüntülerin doğrudan kullanılması pek elverişli olmadığından, bu görüntülere ön işlem süreci uygulanmıştır. Şekil 7.1’de önerilen akıllı karar destek sisteminin yapısı verilmiştir. Alt bölümlerde ise şekilde gösterilen her bir bloğun işlevi açıklanmıştır.



Şekil 7.1. Geliştirilen yöntemlerin Endoskopik görüntülere uygulama yapısı

7.1. Gastrointestinal Sistem Endoskopisi

Sindirim sisteminin tetkikinde uzun süre radyolojik yöntemler kullanılmıştır. Birçok hastada yararlı olmasına karşın bazı vakalarda tanı güçlükleri veya yanlış tanı konulması yeni yöntem arayışlarını getirmiş ve bunun sonucu organların direkt görülerek incelenmesi ihtiyacı doğurmuştur. İlk kez rijid endoskoplara ile direkt görüş sağlanmakla birlikte bu zor ve tecrübe gerektiren işlem kısa süre kullanılmıştır. 1930-40'lı yıllarda yarı esnek gastroskoplara geliştirilmiştir. Ancak 1960'ların sonunda tam esnek ve manevra kabiliyeti üst düzeyde olan endoskoplara geliştirilmesiyle üst gastrointestinal sistem (GİS) endoskopisi rutin bir işlem haline gelmiş ve radyolojik incelemelerin yerini almıştır.

7.1.1. Üst GİS Endoskopisi İncelenmesi

Üst GİS endoskopi ile incelenmesinde yemek borusu, mide ve on iki parmak bağırsağının ilk kısımları endoskop aracılığı ile direkt veya ekrandan görülüp incelenebilir, gerekli yerlerden biyopsi ve bazı örnekler alınabilir, tedavi amaçlı girişimler yapılabilir. Üst GİS endoskopisinde, panendoskopi, özofagogastroduodenoskopi veya kısaca gastroskopi terimleri kullanılmaktadır.

7.1.2. Alt GİS Endoskopik İncelenmesi

Alt GİS endoskopisi ile rektal kanamalar, gizli kanamalar, inflamatuvar barsak hastalıkları, polip, kanser şüphesi, izah edilemeyen karın ağrıları, barsak alışkanlığındaki değişiklikler incelenebilir. Alt GİS endoskopisinde, rektosigmoidoskopi ve kolonoskopi terimleri kullanılmaktadır.

7.1.3. Rektosigmoidoskopi

Genelde 25–35 cm boyutlarında metal bir borudan yapılmıştır. Son yıllarda tek kullanımlık plastik şekilleri mevcuttur. Rijid endoskoplara ile ortalama 20 cm'lik bir alan incelenebilir. Esnek fiber optik sigmoidoskop'lar; 65 cm uzunluğunda olup, hastalar tarafından iyi tolere edilebilirler. Vakaların çoğunda (%80) inen kolon, bir kısmında splenik fleksuraya kadar olan kısımlar tetkik edilebilir.

Biyopsi alınması ve polipektomi inceleme sırasında görülen lezyonlardan biyopsi alınabilir. Sigmoidoskopi sırasında kolonoskopide olduğu gibi standart elektrokoagülasyon yöntemi ile polipektomi uygulanabilir.

7.1.4. Kolonoskopi

Cihaz, esnek fiberoptik kolonoskoplar yapı olarak gastroskoplara benzerler, ancak çapları daha kalın ve boyları 120–180 cm olmak üzere daha uzundur.

Biyopsi alınması ve tedavi amaçlı uygulamalar, tanı amacıyla kolonun değişik segmentlerinden biyopsiler alınabilir. Tedavi amacıyla kolonoskopik polipektomiler uygulanabilir; saplı polipler elektrokoagülasyon ile kolayca çıkarılabilirler. Sapsız poliplerde ise bu işlem daha güçtür. Sapsız polip değişik açılardan kesilerek çıkarılabilir.

7.2. Endoskopik Görüntüleme

Endoskopi genellikle, gastrointestinal alanda teşhis ve biyopsilerde kullanılmak üzere tasarlanmış fiber optik tüpe monte edilmiş bir görüntüleme aygıtından oluşmaktadır. Endoskopi, minyatür bir kamera ile gastrointestinal alanda küçük ölçekli (doku yakma gibi) cerrahi müdahalelerin gerçekleştirilmesine izin verecek teçhizatla donatılmıştır. Bu cerrahi müdahaleler çoğunlukla açık cerrahi müdahalelerden çok daha az travmatiktir. Endoskopinin kolon mukozasını incelemesine olanak tanıyan versiyonu ise kolonoskopi olarak adlandırılmaktadır. Standart kolonoskopinin ortalama boyu 185 cm, çapı ise 1,2–1,3 cm dir. Aletin uç kısmına ayrı bir kablo üzerinden birçok farklı yardımcı aygıt bağlanabilir, örneğin emme kutusu, harici soğuk ışık kaynağı ve kolon içinde kamerayı temizleyebilecek olan suyu depolayan tank gibi. Kolonoskopi görüntülerinin kayıt edilmesi için ya bilgisayara bağlı bir yakalama kartı ya da standart bir video kayıt cihazı kullanılır [172].

Endoskop ile kolon yada rektumdan elde edilen renkli görüntüler, rektal ve kolonda bulunan farklı hastalıkların teşhisinde önemli ölçüde kolaylıklar sağlamaktadır. Endoskopik bir kamera çoğunlukla $i = K, Y, M$ ile sembolize edilen üç farklı ışık sensöründen oluşmaktadır. Bu sensörlerden her biri farklı λ dalga boylarına duyarlılığını gösteren $S_i(\lambda)$ spektral yanıt fonksiyonu ile karakterize edilir. Bu sensörlerin spektral yanıt fonksiyonları, kırmızı, mavi ve yeşil dalga boylarının merkezlerine yerleşmiş olan görünür spektrumdaki kesişim aralıklarına karşılık gelmektedir. Bu kesişim, RGB bileşenleri arasındaki korelasyona işaret eder. Bir endoskobun renk üretme karakteristiği birkaç faktöre bağlıdır, şöyle ki [172];

1. Spektral radyan dağılıma sahip aydınlatma $E(\lambda)$,
2. $i = R, G, B$ sensörlerinin $S_i(\lambda)$ spektral hassasiyetlerine
3. Görüntüleme merceklerinin spektral iletkenliklerine $L(\lambda)$
4. Mukozal yüzeyin spektral yansıtıcılığı $O(\lambda)$

Işık, kaynağından çıkıp, mukozal yüzeyden yansiyarak tekrar mercekler üzerinden sensörlere ulaştığında, spektrumu değişmiştir. Her bir sensöre gelen ışık ışınları, sensörün yanıt fonksiyonu ile çarpılır. Böylece, gelen ışık ışınlarına cevap veren sensörün herhangi bir (x,y) noktasındaki parlaklık değeri $V_i(x, y)$ şöyle hesaplanır;

$$V_i(x, y) = \int_w E(\lambda) S_i(\lambda) L(\lambda) O(\lambda, x, y) d\lambda \quad (7.1)$$

λ dalga boyu aralığını göstermektedir.

7.3. Veri Alımı


Kolonoskopik görüntüler, Fırat Tıp Merkezi, İç Hastalıklar Bölümü, Gastroenteroloji kliniğindeki, Olympus CV-260 cihazı ile 50 farklı hastadan 6 aylık bir zaman diliminde alınmıştır. Olympus CV-260' nın özellikleri EK-1'de verilmiştir. Kolonoskopi cihazının bir görüntüsü Şekil 7.2'de gösterilmiştir. Alınan görüntüler 5–10 saniyelik yakın çekim görüntülerdir. Şekil 7.3'de bir hastadan alınan kolonoskopik görüntü örneği gösterilmiştir. Kolonoskopik görüntüde, ilave olarak o günün tarihi, saati, hasta ismi ve doğum tarihi gibi bilgiler de bulunmaktadır.

7.4. Ön İşlem Süreci


Kolonoskopik görüntüler için ön işlem süreci, görüntülerdeki tarih, saat, hasta ismi vb. bilgilerin elimine edilmesi böylece sadece ilgilenilen bölgenin elde edilmesi işlemi olarak tanımlanmaktadır [173]. Ayrıca, kolonoskopik görüntüler kaydedildikleri bu ilk halleriyle değil de, yeniden boyutlandırılmış son halleriyle kullanılmaktadırlar. Yeniden boyutlandırılmış görüntüler 192 x 192 boyutlarındadır. Görüntü kırılarak yapılan bu yeniden boyutlandırma işlemi Şekil 7.4'de gösterilmiştir. Sonraki polip tanıma işlemlerinin gerçekleştirileceği yeni görüntü biçimi ise Şekil 7.5'de gösterilmiştir.



Şekil 7.2. Olympus CV-260 Endoskopi cihazı



Şekil 7.3. Kolonoskopik görüntü



Şekil 7.4. Ön İşlem Süreci



Şekil 7.5. Kırpılmış görüntü

7.5. Bölütleme Algoritmalarının Uygulanması

Bölüm 5, 6’ da sunulan öznitelik çıkarma yöntemlerinin kolonoskopik görüntüler üzerinde uygulaması aşağıdaki ilgili yöntemlere ait bölümlerde verilmiştir.


7.5.1. Görüntünün Dalgacık Paket Dönüşüm Ağacından Entropi ve Enerji Hesaplanması

Bölüm 6’de verilen dalgacık paket dönüşüm ağacından entropi ve enerji öznitelik çıkarım yönteminin uygulaması endoskopik görüntüler üzerinde yapılmıştır [110]. Polipli ve normal dokulardan 32 x 32 boyutunda bir pencere kullanılarak 1000 ab-normal ve 1500 normal örnek alındı. Örnekler alınırken özellikle görüntülerin çok koyu renkli ve ışık yansımalarının çok olduğu bölgelerden alınmamasına dikkat edildi. Her bir görüntü RGB uzayında R, G ve B

bileşenlerine ayrıştırıldı ve her bir bileşene ayrı olarak dalgacık paket ayrışımı uygulandı. Şekil 7.6’da bir endoskopik görüntünün biortogonal 4.4 dalgacık filtresi kullanılarak 2 seviyeli dalgacık paket ayrışımının uç yaprak katsayı görüntüleri görülmektedir. Bu işlem sonucunda $4^2 = 16$ adet alt görüntü elde edilir. Elde edilen bu alt görüntülerden denklem 7.2 ve denklem 7.3’de verilen norm entropi ve enerji öznitelikleri hesaplanarak öznitelik vektörü oluşturuldu. Böylece her bir görüntü için elde edilen öznitelik vektörü 96 elemanlı bir dizi olmaktadır.

$$E(f_{doku}) = \sum_x \sum_y |f(x, y)|^p \quad (7.2)$$

$$En_1 = \frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N f(x, y)^2 \quad (7.3)$$



Şekil 7.6. Endoskopik bir görüntünün dalgacık paket dönüşüm ile elde edilen alt bantları

7.5.2. Görüntünün Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Özniteliklerin Hesaplanması

Bölüm 5’de verilen dalgacık dönüşümü eş-oluşum matrislerinin özniteliklerinin çıkarımı yönteminin endoskopik görüntülere uygulanması gerçekleştirildi. Polipli ve normal dokulardan 32 x 32 boyutunda bir pencere kullanılarak 1000 ab-normal ve 1500 normal örnek alındı [174]. Örnekler alınırken özellikle görüntülerin çok koyu renkli ve ışık yansımalarının çok olduğu bölgelerden alınmamasına dikkat edildi. Her bir görüntü RGB uzayında R, G ve B bileşenlerine ayrıştırıldı. Her bir bileşene 9/7 biortogonal dalgacık filtresi ile tek seviyeli ayrışım uygulandı. Bu işlem sonucunda $3k+1$ adet dalgacık katsayı görüntü elde edildi. Burada k ayrışım seviyesini belirtmektedir. Tek seviyeli ayrışım uygulandığı için 3 adet detay ve tek adet yaklaşık görüntü elde edildi. Öznitelik çıkarımı için sadece detay görüntüler kullanıldı. Detay görüntülerin ikinci dereceden istatistiksel özniteliklerinin elde edilmesi için, dalgacık ayrışımı ile oluşturulan üç detay görüntü kullanıldı. Hesaplanan öznitelikler her bir detay görüntüden oluşturulan ve 0, 45, 90 ve 135 derecelik açılar için oluşturulmuş eş oluşum matrisleri üzerindendir. Elde edilen bu dört eş oluşum matrisinin daha sonra ortalaması alınarak tek eş oluşum matrisi elde edilmiştir. Böylece 1 eş oluşum matrisi, 3 detay görüntü ve 3 renk bileşeni için toplam 9 adet eş oluşum matrisi elde edildi. Elde edilen eş-oluşum matrislerinden 4 adet öznitelik hesaplanmıştır. Böylece elde edilen öznitelik vektörü 36 elemanlı bir dizi olmaktadır. Kullanılan öznitelikler, enerji, ters fark momenti, kontrast ve entropidir. Sırası ile aşağıdaki gibi tanımlanırlar;

$$F_1 = \sum_{x=1}^N \sum_{y=1}^N p(x, y)^2 \quad (7.4)$$

$$F_2 = \sum_{x=1}^N \sum_{y=1}^N \frac{1}{1 + (x - y)^2} p(x, y) \quad (7.5)$$

$$F_3 = \sum_{x=1}^N \sum_{y=1}^N (x - y)^2 p(x, y) \quad (7.6)$$

$$F_4 = \sum_{x=1}^N \sum_{y=1}^N p(x, y) \log_2(p(x, y)) \quad (7.7)$$


Uygulama için, MATLAB ortamında programlar geliştirilmiştir. Kullanılan ileri beslemeli çok katmanlı YSA 'nın eğitim parametreleri ve yapısı Tablo 7. 1’de gösterilmiştir.

7.5.3. Yapay Sinir Ağı ile Sınıflandırma

Sınıflandırmanın amacı, geliştirilen özellik çıkarma yöntemlerinin etkinliğini ve başarımını göstermektir. Bu amaçla, akıllı örüntü tanıma uygulamalarında güçlü bir sınıflandırıcı olan yapay sinir ağları kullanılmıştır. Kullanılan yapay sinir ağı, tüm yapay sinir ağı çalışmalarının %90'nın da tercih edilen çok katmanlı ileri beslemeli yapay sinir ağı olup, bu YSA modelinin eğitimi için kullanılan en önemli öğrenme algoritması ise hata geri yayılım algoritmasıdır [110, 175, 176]. Aşağıda bu algoritma kısaca açıklanmıştır:

Geri yayılım YSA : Geriye yayılım ağı, çok katmanlı ileri yön bağlamalı bir ağıdır. Giriş ile çıkış katmanları arasında, birden fazla katmanın kullanıldığı yapay sinir ağı sistemidir. Gizli katman olarak isimlendirilen bu ara katmanlarda, aracısız giriş alamayan ve aracısız çıkış veremeyen işlem elemanları vardır. Şekil 7.7 'de çok katmanlı algılayıcı yapay sinir ağının genel yapısı verilmiştir [110].

Çok katmanlı ağlarda veriler, giriş katmanı tarafından kabul edilirler. Ağ içindeki işlemler sonucunda çıkış katmanında oluşan cevap ile giriş verisine karşı istenen cevap karşılaştırılır. Hesaplanan cevap ile istenen cevap arasında herhangi bir farklılık varsa, katmanlar arasında bulunan ağırlıklar bu farkı azaltacak şekilde yeniden düzenlenir. Yapay sinir ağının girişindeki veriler, ağırlıklar uygun noktaya ulaşana kadar değişmez. Hesaplanan çıkış cevapları, istenen cevaplarla karşılaştırılarak, sonuçta hata işareti elde edilir. Hata işareti, ara katmanlardan çıkış katmanına olan ağırlıkları değiştirmekte de kullanılır. Çok sayıda ara katmana sahip sistemlerde her katmanın hata işaretleri, bir önceki katmanın düzeltilmiş hata işaretlerinden çıkartılarak işlem tekrarlanır. Sonuç olarak ağırlık düzeltme işlemi çıkış seviyesine bağlı ağırlıklardan başlar ve işlem ters yönde giriş seviyesine varana kadar devam eder. Sistem, sonuçta yine hatalar yapar, fakat bu hatalardan bir şeyler öğrenip istenen cevabı bulana kadar işlem tekrarlanır. Bu yönteme hatanın geriye yayılma algoritması denir. Denklem 7.8. de bu algoritmanın öğrenme sürecinde kullanılan matematiksel yapısı verilmiştir.



Şekil 7.7. Çok katmanlı ileri beslemeli yapay sinir ağları.

$$w_{ij}(t+1) = w_{ij}(t) + \varepsilon \cdot h_j \cdot y_i + \alpha \cdot (w_{ij}(t) - w_{ij}(t-1)) \quad (7.8)$$

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

Hata geri yayılım algoritması eğiticili bir öğrenmedir. Eğiticili 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/çıktı ikilisinden oluşan örnekler sunulur. Bu ikili, ağın öğrenmesi gereken özellikleri temsil eder. Hata geri yayılım öğrenme algoritmasının başarımını etkileyen önemli birkaç faktör bulunmaktadır. Bunlar [110]:

- 1. Başlangıç ağırlıkları:** Çok katmanlı ileri beslemeli ağların başlangıç ağırlıkları, sonuca ulaşmak açısından oldukça kuvvetli bir etkiye sahiptir. Başlangıç ağırlıklarını küçük rast gele değerler olarak seçmek yerine, etkileştirme fonksiyonları üzerinden hesaplanması öğrenme sürecinin hızlı olmasına katkıda bulunur.
- 2. Öğrenme oranı:** Geri yayılım öğrenme algoritmasının yakınsama etkinliği açısından bir diğer önemli parametrede öğrenme oranıdır. Bu oran büyük seçildiğinde ağırlıkların değişimleri büyük salınımlar yapacaktır ve dolayısı ile eğitim sürecinde bir kararsızlık oluşmasına neden olacaktır. Küçük seçildiğinde ise, öğrenme süreci yavaşlayacaktır.

Uygun bir öğrenme oranı seçimi için, belirli bir kriter yoktur. Çoğu zaman ilgili sınıflama probleminin birçok denemesinden sonra en uygun öğrenme oranı belirlenir.

3.Momentum katsayısı: Öğrenme oranı çok geniş bir aralıkta değişim sergilemektedir.

Bundan dolayı, öğrenme oranının seçiminden kaynaklanan problemlerin etkisini azaltmak için, ağılıkların düzenlenmesinde ikinci bir parametre olarak momentum katsayısı kullanılır.

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

5.Etkinleştirme fonksiyonları: Etkinleştirme fonksiyonunun seçimi, sınıflandırılacak olan örüntünün yapısına bakarak çıkış katmanında kısmen yapılabilse de genellikle, tecrübeler ve deneysel çalışmalara bağlı olarak bu fonksiyonlar bulunabilmektedirler [110]. Etkinleştirme fonksiyonları YSA' nın işlem elemanlarının çok geniş aralıktaki çıkışını belli aralıklara çekmektedir. Böylece her bir işlem elemanının tepkisi yumuşak olmaktadır ve bağlantı ağırlıklarının değişimlerinin, daha küçük değerlerde olması sağlanmaktadır. Dolayısıyla yapay sinir ağının eğitimi sırasında, hata değişiminin ıraksaması engellenerek kararlılığa ulaşmasına yardımcı olunur. Adım, rampa, signum, logaritma ve tanjant fonksiyonları yaygın olarak kullanılan bazı etkinleştirme fonksiyonlarıdır.

Uygulama için, MATLAB ortamında programlar geliştirilmiştir. Kullanılan ileri beslemeli çok katmanlı YSA 'nın eğitim parametreleri ve yapısı Tablo 7. 1'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. DPA ağacından entropi ve enerji öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları Şekil 7.9.'da, DD eş-oluşum matrislerinin istatistiksel öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları ise Şekil 7.10.'da verilmiştir. Burada, (a) orijinal görüntüyü, (b) Bölütlenmiş görüntüyü ve (c) ise bölütleme sonucu ile orijinal görüntünün eşleştirilmiş durumunu göstermektedir.


Tablo 7.1. Kullanılan YSA modelinin yapısı ve eğitim parametreleri.

YSA yapısı


YSA modeli	Çok katmanlı ileri beslemeli
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş : Öznitelik vektörünün bileşen sayısı Gizli : Öznitelik çıkarım yöntemine göre değişken Çıkış : 1
Başlangıç ağırlıkları ve eşik değerleri	Rasgele
Etkinleştirme fonksiyonları	Tanjant sigmoid

YSA eğitim parametreleri


Öğrenme kuralı	Hata geri yayılım
Adaptif öğrenme oranı	Başlangıç : 0.001 Artış katsayısı : 1.05 Azalış katsayısı : 0.7
Momentum sabiti	0.95
Toplam karesel hata	0.0001




Şekil 7. 8. YSA modelinin eğitim başarımı.




Şekil 7.9. DPA ağacından entropi ve enerji öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (1/3).




Şekil 7.9. DPA ağacından entropi ve enerji öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (2/3).




Şekil 7.9. DPA ağacından entropi ve enerji öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (3/3).




Şekil 7.10. Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (1/6).




Şekil 7.10. Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (2/6).




Şekil 7.10. Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (3/6).



Şekil 7.10. Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (4/6).



Şekil 7.10. Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (5/6).



Şekil 7.10. Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonuçları (6/6).

7. 6. Değerlendirme Kriteri

Negatif ve pozitif örüntülerin sınıflandırılmasının gerektiği birçok tıbbi karar destek uygulamalarında, sınıflandırılacak veri kümesi oldukça dengesiz bir yapıdadır. Bunun anlamı, sağlıklı örneklere işaret eden örüntülerin, patolojik örüntülerden çok daha fazla olmasıdır. Bu uygulamaya konu olan video karelerinde de yine benzer bir problem söz konusudur. Normal olmayan örüntülerin normal örüntülere oranı ortalamada %10'u geçmemektedir. Doğru sınıflandırılan örnek sayısının toplam örnek sayısına oranlanarak elde edilen doğruluk, makine öğrenmesi uygulamalarında sıkça kullanılan bir başarımlı değerlendirme kriteridir. Bu kriter, oluşturulan sınıfların dağılımlarının bilinmediğini, değişmediğini ve yanlış pozitif ve yanlış negatif olarak atanan örüntülerinde eşit olduğunu varsayar. Bu varsayımlar, dengesiz veri kümelerinin performans değerlendirmesi için bu yöntemin güvenilir kılınmamaktadır. Bu tür durumlarda, azınlık sınıfına ait olan örüntülerin doğru olarak sınıflandırılması, çoğunluk sınıfına ait olan örüntülerin doğru olarak sınıflandırılmasından çok daha önemlidir. Bu uygulamalar için çok daha güvenilir başarımlı testlerin gerçekleştirilmesi için istatistikçiler Tablo 7.2'de verilen karışıklık matrisini kullanmaktadırlar [177].

Tanı testinin değerlendirilmesi ya gerçek hasta ve sağlamlar üzerinde ya da gerçeği yansıttığından kuşku bulunmayan bir ana tanı testi (Altın standart) sonucuna göre yapılır. Bir tanı testinin değerlendirilmesi, aşağıdaki tablo (2x2) tipi çerçevesinde; üstte gerçek sonuçlar, yanda ise deneysel sonuçlar olmak üzere gözlere verilen adlar belirlidir.

Tablo 7.2. Karşılaştırma matrisi.

		Gerçek Sonuçlar	
		Pozitif	Negatif
Uygulama Sonuçlar	Pozitif	a (GP)	b (YP)
	Negatif	c (YN)	d (GN)

Gerçek hastalara konan tanı açısından; “a” gözü gerçek tanıya uygun olarak tanı testinin de hasta dediği olgular yani GP olarak adlandırılır. Buna karşılık “c” gözündeki olgular, gerçekte hasta olup, tanı testinin hatalı olarak sağlam dediği yani YN olgulardır. Bu çerçevede testin geneli için aşağıdaki tanımlar verilmiştir [178];

1) DUYARLILIK (Sensitivity): Testin, gerçek hastalar içinden hastaları ayırma yeteneğidir.
$$\text{DUYARLILIK} = a / (a+c) = \text{GP} / (\text{GP} + \text{YN})$$

Gerçek sağlamlara konan tanılar açısından; “d” gözü gerçek tanı sonucuna uygun olarak testinde sağlam dediği GN olgulardır. “b” gözü ise gerçekte sağlam oldukları halde testin hatalı olarak hasta dediği YP olgulardır.

2) KESİNLİK (Specificity) testin, gerçek sağlamlar içinden sağlamları ayırma yeteneğidir. $KESİNLİK = d / (d + b) = GN / (GN + YP)$

Duyarlılık ve kesinlik oranlarının tersi olan, testin hatalı yargıları da hesaplanabilir.

3) YANLIŞ NEGATİF ORANI: Gerçek hastalar içinden testin hatalı olarak sağlam dediği olgulardır. $YN = (1-DUYARLILIK) = c / (a + c) = YN / (YN + GP)$

Testin hatalı olarak hasta bulduğu olguların oranı da, yanlış pozitif oranı adını alır.

4) YANLIŞ POZİTİF ORANI: Gerçek sağlamlar içinden testin hatalı olarak hasta dediği olgulardır. $YP = (1-KESİNLİK) = b / (b+d) = YP / (YP+GN)$

Bu oranların yanı sıra çok önem taşıyan bir başka oran ise test sonucu olasılık oranıdır.

5) Pozitif test sonucu olasılık oranı (L+): Testin, hastalığa var dediği zaman doğruyu bildirmesinin yanılmasına oranıdır. (hastalık tanısı koymanın doğruluk oranı)

$$L+ = DUYARLILIK / (1-KESİNLİK) = a / (b+d) = GP / (GP+YP)$$

Bu oran ne kadar yüksek olursa, gerçek hastalar o derecede iyi ayrımlanmaktadır.

7) Negatif test sonucu olasılık oranı (L -): Sağlam tanısının doğruluk oranıdır.

$$L- = (1-DUYARLILIK) / (KESİNLİK) = c / (a+c) = YN / (YN+GN)$$

Bu oran ne kadar küçük olursa, gerçek sağlamlar o kadar iyi ayrımlanabilmektedir.

7) DOĞRULUK (Accuracy): Gerçekte testin hasta ve sağlam olarak toplam doğru tanı oranına doğruluk denir.

$$DOĞRULUK = (a+d) / (a+b+c+d) = (GP+GN) / (GP+YP+YN+GN)$$

Gerçekte araştırmacıların yanıt aradığı en önemli soru; Tanı testi sonucu pozitif olanın, gerçek bir hasta olma olasılığı nedir? (veya Tanı testi sonucu negatif olanın gerçekten sağlam olma

olasılığı nedir?) sorusudur. Bu kavram “KESTİRİM DEĞERİ” adını alır ve Bayes kuramı çerçevesinde çözümlenir.

1) POZİTİF SONUCUN KESTİRİM DEĞERİ (PKD): Tanı testi hasta yargısı verdiğinde, gerçekten hasta olma olasılığıdır. $PKD = P(H+/T+) = A / (A+B) = GP / (GP+YP)$

2) NEGATİF SONUCUN KESTİRİM DEĞERİ (NKD): Tanı testi sağlam dediğinde gerçekten sağlam olma olasılığıdır. $NKD = P(H-/T+) = D / (D+C) = GN / (GN+YN)$

Özellikle iç dağılımın farklı özellikler açısından karmaşık olduğu durumlarda çeşitli nedenler aynı sonucu vermiş olabilirler. Sonucun hangi olasılıkla, hangi nedenlerden kaynaklandığını bulmak için Bayes teoremi kullanılmaktadır. Bu kural ters olasılık veya nedenler olasılığı adını da almaktadır. Konuyu somutlaştırmak için bir örnekle açıklamak gerekirse; Gerçekten A hastası olduğu bilinen ve gerçekten sağlam olduğu bilinen kişilerden oluşan bir gruba, A hastalığı tanısı koymada kullanılan bir test uygulanarak aşağıdaki dağılım tablosu elde edilmiştir. Bu tablo Tablo 7.3’de gösterilmiştir.

Tablo 7.3. A tanısı değerlendirme matrisi.

		Gerçek Sonuçlar		
		Pozitif (H+)	Negatif (H-)	Toplam
Tanı Testi Sonucu	Pozitif (H+)	75	18	93
	Negatif (H-)	10	97	107
	Toplam	85	115	200

Burada;

i) Tanı testinin hasta dediği bir kişinin gerçekten de hasta olma olasılığı (PKD);

$$P(H+ / T+) = [P(H+) * P(T+/H+)] / [(P(H+) * P(T+/H+)) + (P(H-) * P(T+/H-))]$$

$$P(H+ / T+) = (0.42 * 0.88) / [(0.425 * 0.88) + (0.575 * 0.157)] = 0.374 / 0.374 + 0.09 = 0.806$$

ii) Tanı testinin sağlam dediği bir kişinin gerçekte hasta olma olasılığı;

$$P(H+/T-) = [P(H+) * P(T-/H+)] / [(P(H+) * P(T-/H+)) + (P(H-) * P(T-/H-))]$$


$$= [0.425 * 0.12] / [(0.425 * 0.12) + (0.575 * 0.84)]$$

$$= 0.051 / [0.051+0.483] = 0.096$$

Bu oran ne kadar küçük olursa tanı testi, sağlamları o derecede iyi ayırmaktadır. Tanı testi performanslarının değerlendirilmesi ve kıyaslanması için en yaygın kullanıma sahip olan yöntem ROC eğrisidir. Klinik çalışmalarda sürekli sayıların kullanıldığı ölçümlerde olguları ayırma (hasta/sağlam), çözümlemeyi karmaşık hale getirir ve hata olasılığını yükseltir. Sonuçta, klinik şartlara bağlı olarak tanı testinin optimum etki noktası değişmektedir. Bu çerçevede seçilen farklı eşik değerleri için bulunan farklı duyarlılık-kesinlik karakterlerine bağlı olarak ara seçenekler belirlenerek, ROC eğrileri oluşturulmuştur. ROC eğrisi yöntemi [177];


- Testin ayırt etme gücünün belirlenmesine,
- Çeşitli testlerin etkinliklerinin kıyaslanmasına,
- Uygun pozitiflik eşiğinin belirlenmesine,
- Laboratuvar sonuçlarının kalitesinin izlenmesine,
- Uygulayıcının gelişiminin izlenmesine,
- Farklı uygulayıcıların etkinliklerinin kıyaslanmasına olanak sağlar.

ROC eğrisinin oluşturulacağı koordinat sisteminin ordinatında tanı testinin gerçek pozitif değeri (duyarlılık), apsisinde ise yanlış pozitif değeri (1-kesinlik) yer alır. Tanı testi ne kadar iyi ise eğri o kadar yukarıya (yüksek duyarlılık bölgesi) ve sola (düşük yanlış pozitif oranı bölgesi) doğru kayar. Yanlış değerlere sahip olmayan ideal bir testte ROC eğrisi (0,0)- (0,1)-(1,1) noktalarını birleştirmektedir. Buna karşın ROC çizimi $y=x$ fonksiyonuna yaklaştıkça başarısız bir test ortaya çıkar. Bu fonksiyonun altındaki ROC eğrisine sahip test başarısızdır (Şekil 7.11.).



Şekil 7.11. (a) İdeal (b) Kötü, performans göstergesi olan ROC eğrileri.

Böylece, bir tanı testi için ROC altında kalan alan etkinlik düzeyine bağlı olarak 0.50 ile 1.00 arasında değerler alabilecektir. Bu alan ne kadar büyükse, tanı testi o denli ayırım yeteneğine sahip olacaktır. Bu alan 0.975 ve daha üzerinde ise mükemmel sayılmaktadır. ROC çözümlemesi niceleyici verilerin elde edildiği testlerin tanımlanabilmesi için matematiksel yaklaşımları belirleyerek farklı klinik durumlarda uygulanan tanı testlerini bütünüyle değerlendiren bir yöntemdir. Başarılı tanı testinin performansının tanımlayarak yeni bir tanı testinin gelişimini de açıklar. Uygulamada karışık (hasta/sağlam) olgular ele alınarak, tanıları belirlenir ve iki ayrı grup meydana getirirler. Teorik olarak çalışma grubundaki sağlam ve hasta olguların normal dağılıma uygun olduğu kabul edilirse, ordinatta frekans, apsiste ise popülasyon standart sapmaları olduğu halde gruplara ait normal dağılım eğrileri çizilerek, eşik seçimi ve ROC eğrisinin fonksiyonunu daha basit bir şekilde açıklayabiliriz. Şekil 7.12'deki grafik üzerinde görülen üç dikey çizgi seçilmesi olası üç farklı eşik düzeyini göstermektedir [178].



Şekil 7. 12. Normal dağılım eğrileri, girişim bölgesi ve pozitiflik eşik seçenекleri.

Normal dağılım gösteren bu guruplar, özellikle yanlış değerler olarak da adlandırdığımız, birbirlerine doğru bir girişim bölgesi oluştururlar. İşte bu girişim bölgesinin en ideal yerinden bir ayırım sınırı seçerek maksimum doğrulukta bir sonuç elde edebilir. Mümkün olabilecek tüm eşik düzeyleri için hesaplanan duyarlılık ve kesinlik çakışım noktaları yani, $\text{duyarlılık} = f(1 - \text{kesinlik})$ fonksiyonu ROC eğrisini meydana getirir. Testin performansı ve tanı sonucunun doğruluğu, testinin özgün oranları ve hastalığın prevalansına(yaygınlık) bağlıdır. Tarama konumlarında özellikle sağlamların belirlenmesi söz konusu olduğunda testin “NKD” önem kazanır. NKD’nin büyümesi için yanlış negatiflerin oranı azalmalı yani testin duyarlılığı büyümelidir. Buna karşılık tanıda, hastalığın varlığının doğrulanması gerekir, dolayısıyla PKD önem kazanır. Bu yanlış pozitiflerin oranı azaltılarak sağlanabilir. Uygun bir tedavisi olan ve hasta olmayanlara yanlışlıkla uygulandığında ağır sonuçlar getirmeyen hastalık tanısına yönelik testlerde duyarlılık yüksek tutulmalıdır. Buna karşın, daha az ağır sonuçlara sahip hastalıklarda

hele yanlış pozitiflerin yanlış tedavisi ağır yan etkilere sahip ise kesinlik yüksek tutulmalıdır. Pozitiflik eşiğinin düşük olduğu durumlarda, testin duyarlılığı çok yüksek olacak, ancak çok sayıda yanlış pozitif elde edilecektir. Eşik yükseldikçe kesinlik yükselecek yanlış pozitifler azalacak, buna karşılık yanlış negatifler artacak ve böylece tedaviye alınmamış hastalar ortaya çıkacaktır. Tüm teorik yaklaşımlar, doğru tanının niceliksel ifadesini çok popüler bir bulgu olan eğrisi altındaki alana indirgemeyi amaçlamaktadır. Bu alan bağımsız örneklemeler için non-parametrik Wilcoxon Mann-Whitney uyarlamasıyla hesaplanabilir. ROC eğrisi altındaki alan, tanı testinin uygulandığı (hasta ve sağlam) iki veri dizisi için matematiksel olarak teorik bir z değeri ve bu z'nin standart normal değerleri tablosuna göre dönüşüm yapılarak elde edilmektedir. Eğri altı alanının varyansı denklem (7.9) ile hesaplanabilir.

$$SD_A = \frac{A * (A - 1) + (n_H - 1) * (Q_1 - A^2) + (n_S - 1) * (Q_2 - A^2)}{n_H * n_S} \quad (7.9)$$

Burada; A hesaplanan ROC alanı, n_H hasta denek sayısı, n_S sağlam denek sayısı $Q_1 = A / (2 - A)$ ve $Q_2 = 2A^2 / (1 + A)$ bağımsız iki ROC alanı arasındaki farklılığın önemi aşağıdaki z eşitliğine göre test edilebilir.

$$z = \frac{A_1 - A_2}{\sqrt{SD_1 + SD_2}} \quad (7.10)$$


İncelenen olgular, iki ayrı grup olarak iki ayrı teknikte elde edilen veri dizileri olmalıdır ve çalışılan her bir vaka üzerinde karşılaştırılan her iki tekniğinde uygulanması durumunda eşli diziler elde edilmiş olur. Eşli dizilerde ROC eğrisi altındaki alanların kıyaslanması denklem (7.11)'de verilen eşitlik kullanılarak yapılabilir.

$$z = \frac{A_1 - A_2}{\sqrt{SD_1 + SD_2 - 2 * r_s * SD_1 * SD_2}} \quad (7.11)$$


Burada; r_s üzerinde iki tanı testinin de uygulandığı denekler için hesaplanan Spearman korelasyon katsayısıdır. Alanlar arası korelasyon katsayısının yüksek olduğu örneklerde denek sayısı daha düşük alınabilmektedir.

7. 7. Uygulama Sonuçlarının Değerlendirilmesi

Bir önceki bölümde verilen değerlendirme kriteri, uygulama sonuçlarının analizinde kullanılmıştır. Kullanılan değerlendirme analizi için önemli olan altın standart, uzman hekim tarafından endoskopik görüntüler üzerinde manuel olarak tanımlanmıştır. Diğer bir deyişle, polipli ve normal dokuların bulunduğu görüntülerden yapay siyah (normal doku) ve beyaz (abnormal doku) bir görüntü elde edilmiştir [174]. Elde edilen bu altın standart görüntüler Şekil 7.13’de gösterilmiştir. Dalgacık paket entropi ve enerji öznitelikleri ile yapay sinir ağı sınıflandırıcısı kullanılarak gerçekleştirilen uygulamalar da ortalama % 86.2 duyarlılık ve % 85.7 kesinlik değerleri elde edilmiştir. Diğer taraftan, dalgacık dönüşümü eş oluşturma matrislerinin istatistiksel öznitelikleri ile yapay sinir ağı sınıflandırıcısı kullanılarak gerçekleştirilen uygulamalar da ise ortalama % 90.2 duyarlılık ve % 88.7 kesinlik değerleri elde edilmiştir.




Şekil 7. 13. Örnek kolonoskopik görüntü ve değerlendirme analizi için oluşturulan altın standart görüntü (1/2).



Şekil 7. 13. Örnek kolonoskopik görüntü ve değerlendirme analizi için elde oluşturulan altın standart görüntü (2/2).


Şekil 7.14’de bir kolonoskopik görüntü için başarımlar analiz örneği verilmiştir. Kullanılan orijinal kolonoskopik görüntü, DPA entropi ve enerji öznelikleri kullanılarak elde edilen tanı testi sonucu ve değerlendirmede kullanılan referans (altın standart) görüntü Şekil 7.14’de sırası ile verilmiştir. Referans görüntü ve tanı testi sonucu kullanılarak Tablo 7.4 oluşturulmuştur. Bu değerlere bağlı olarak, bu tanı testi için duyarlılık $= 9550 / 10795 = 0.884$ ve kesinlik $= 25220 / 28985 = 0.87$ dir. Şekil 7.15’de duyarlılık ve 1-kesinlik grafiği verilmiştir. Şekil 7.11’deki ideal performanslı ROC eğrisi göz önüne alınırsa, kullanılan yöntemin başarılı sonuç verdiği görülmektedir.



Şekil 7.14 (a) Orijinal görüntü (b) DPA ağacından entropi ve enerji öznitelikleri ve YSA sınıflandırıcısı ile elde edilen uygulama sonucu (c) Altın Standart görüntü.


Tablo 7.4. Örnek görüntü için DPA ağacından entropi ve enerji öznitelikleri ve YSA sınıflandırıcısı kullanılarak yapılan tanı testi sonucu elde edilen karşılaştırma matrisi.

		Gerçek Sonuçlar		
		(piksel sayısı)		
		Pozitif (H+)	Negatif (H-)	Toplam
Tanı Testi Sonucu (piksel sayısı)	Pozitif (H+)	9550	3765	13315
	Negatif (H-)	1245	25220	26465
	Toplam	10795	28985	39780



Şekil 7.15. Örnek görüntü için DPA entropi ve enerji öznitelikleri kullanılarak yapılan tanı testi sonucu elde edilen duyarlılık ve kesinlik grafiği.


Kullanılan orijinal kolonoskopik görüntü ve Dalgacık Dönüşümü Eş-Oluşum Matrislerinin İstatistiksel Öznitelikleri ve YSA sınıflandırıcısı ile elde tanı testi sonucu ve değerlendirmede kullanılan referans (altın standart) görüntü Şekil 7.16’da görülmektedir. Referans görüntü ve tanı testi sonucu kullanılarak Tablo 7.5 oluşturulmuştur. Bu değerlere bağlı olarak, bu tanı testi için duyarlılık = $9677 / 10795 = 0.896$ ve kesinlik = $25676 / 28985 = 0.885$ dir. Şekil 7.17’de duyarlılık ve 1-kesinlik grafiği verilmiştir. Yine Şekil 7.11’deki ideal performanslı ROC eğrisi göz önüne alınırsa, kullanılan yöntemin başarılı sonuç verdiği görülmektedir.



Şekil 7.16. (a) Orijinal görüntü (b) DD Eş-oluşum matrislerinin istatistiksel öznitelikleri ve YSA sınıflandırıcısı kullanılarak gerçekleştirilen tanı testi sonucu (c) Altın standart görüntü.

Tablo 7.5. Örnek görüntü için DD Eş-oluşum matrislerinin istatistiksel öznitelikleri ve YSA sınıflandırıcısı kullanılarak yapılan tanı testi sonucu elde edilen karşılaştırma matrisi.

		Gerçek Sonuçlar (piksel sayısı)		
		Pozitif (H+)	Negatif (H-)	Toplam
Tanı Testi Sonucu (piksel sayısı)	Pozitif (H+)	9677	3309	12986
	Negatif (H-)	1118	25676	26794
	Toplam	10795	28985	39780



Şekil 7.17. Örnek görüntü için DD Eş-oluşum matrislerinin istatistiksel öznitelikleri ve YSA sınıflandırıcısı kullanılarak yapılan tanı testi sonucu elde edilen duyarlılık ve kesinlik grafiği.

8. SONUÇ VE DEĞERLENDİRME

Bu tez çalışmasında, gri seviyesi ve renkli görüntülerin bölütlenmesi için üç farklı yöntem önerilmiştir. Önerilen yöntemlerden ilkinin, gri seviyesi görüntülerin bölütlenmesi için literatürde sıkça kullanılan Gauss olasılık yoğunluk fonksiyonu kullanan MRA yapısı yerine, Poisson olasılık yoğunluk fonksiyonu kullanan MRA yapısı oluşturmaktadır. Önerilen yöntemin etkinliği, gerçek ve yapay görüntüler üzerinde gerçekleştirilen uygulamalar ile gösterilmiştir. Önerilen diğer yöntemden biri özellik çıkarım sürecini de içeren ve sınıflayıcının eğitim başarımına göre özellik uzayını uyarlayabilen ve daha önceden kalp Doppler işaretlerinden özellik çıkarımı için geliştirilen entropi tabanlı dalgacık sinir ağı yapısıdır. Bu yöntem ilk önce iki boyutlu görüntüler için yeniden uyarlanmış ve dokulu görüntülerin sınıflandırılmasında kullanılmıştır. Önerilen yöntemdeki entropi özniteliklerinin yanı sıra enerji öznitelikleri de eklenerek daha dayanıklı ve etkili öznitelik vektörü oluşturulmuştur. Bu tez çalışmasında önerilen son yöntem de ise dalgacık ayrışımı ve osilator sinir ağı yapısını kullanarak eğitici-siz dokulu görüntülerin bölütlenmesini sağlayan bir sistem önerilmiştir. Sistemin en büyük avantajı, eğitici-li örüntü tanıma sistemlerindeki gibi eğitim verisine ihtiyaç duyulmaksızın istenilen bölütlemenin doğru olarak gerçekleştirebilmesidir. Bölüm 5 ve 6 da önerilen öznitelikler, Bölüm 7’de kolonoskopik video görüntülerinden polipli dokuların tespit edilmesinde kullanılmıştır. Öznitelik olarak hem dalgacık paket entropi ve enerji değerleri hem de dalgacık dönüşümü eş oluşum matrisinin istatistiksel öznitelikleri kullanılmıştır. Her iki öznitelik gurubu için YSA sınıflandırıcısı kullanılmıştır.

8.1. Sonuçların Değerlendirilmesi

1. Geliştirilen PMRA yapısında, literatürdeki [142-146] çalışmaların aksine (Gauss olasılık yoğunluk fonksiyonu yerine) Poisson olasılık yoğunluk fonksiyonu kullanılmıştır. Poisson olasılık yoğunluk fonksiyonun kullanılmasındaki asıl sebep, gri-seviyesi görüntülerin histogramlarının karma Gauss olasılık dağılım fonksiyonları ile modellemek yerine karma Poisson olasılık dağılım fonksiyonları ile modellemenin daha uygun olması gerçeğidir [149]. Böylece daha yüksek doğruluk ile bölütleme yapmak mümkündür. Önerilen sistemde kullanılan Poisson parametreleri, EM algoritması ile tahmin edilmektedir. EM algoritmasının başlangıç değerleri ise K-ortalamalar algoritması ile hesaplanmaktadır. Gerçekleştirilen uygulamalardan Poisson parametrelerinin EM algoritması ile hesaplama süresinin yine EM algoritması ile Gauss

parametrelerinin hesaplanma süresinden daha az olduğu görülmüştür. PMRA yönteminin tek dezavantajı bölütlenecek görüntünün kaç sınıfa ayrılacağına kullanıcı tarafından belirlenecek olmasıdır.

2. Önerilen yöntemin başarımlarını değerlendirme, daha çok sezgisel bir değerlendirme yöntemi olan ve Liu ve diğ. tarafından önerilen algoritma ile gerçekleştirilmiştir [139]. Uygulama sonuçları önerilen PMRA yapısının hem gerçek hem de yapay görüntüler için GMRA yapısından daha iyi bölütleme gerçekleştirdiğini göstermiştir.
3. Öznitelik çıkarım sürecini de içeren ve sınıflayıcının eğitim başarımına göre özellik uzayını uyarlayabilen ve daha önceden kalp Doppler işaretlerinden özellik çıkarımı için geliştirilen entropi tabanlı dalgacık paket sinir ağı yapısı, iki boyutlu verilere de (görüntülere) uygulanabilecek bir formata dönüştürülmüştür. Entropi özniteliklerine ek olarak enerji öznitelikleri de yönteme eklenerek daha etkili ve dayanıklı bir yapı elde edilmiştir. Kullanılan YSA sınıflandırıcısının başarımları % 96'dır. Eklenen yeni öznitelikler ile birlikte YSA girişine uygulanacak olan öznitelik vektörünün boyutu iki katına çıkmıştır. Bu durum YSA'ya getireceği hesaplama yükü bakımından bir dezavantaj olarak görülse de, günümüzün güçlü bilgisayarları bu boyutlardaki bir giriş vektörünü kısa sürede eğitebilmektedir.
4. Önerilen dalgacık dönüşümü eş-oluşum matrislerinin istatistiksel öznitelikleri ve osilatör sinir ağı modeli eğitici-siz bir yapıdır. Modelin en büyük avantajı önerilen önceki yöntemlerin aksine bölütlenecek görüntüdeki sınıf sayısının kullanıcı tarafından değil de, yöntem tarafından otomatik olarak bulunmasıdır. Sınıf sayısının otomatik olarak belirlenmesi, osilatör sinir ağı parametrelerinin dikkatli seçimiyle sağlanmaktadır. Diğer taraftan dalgacık domeninde eş oluşum matrisleri oluşturmak ve elde edilen bu eş oluşum matrislerinden istatistiksel öznitelik çıkarmak, görüntünün tamamında aynı karakteristik özellikleri gösteren dokulu görüntüler için oldukça önemli bir ipucudur. Eş oluşum matrisleri dört farklı açıda ve bir piksel uzaklık için hesaplanmıştır. Öznitelik vektörünün boyutlarının indirgenmesi için daha sonra oluşturulan bu dört eş oluşum matrisinin ortalaması alınmış ve bu yeni eş oluşum matrisi üzerinden istatistiksel öznitelikler hesaplanmıştır.
5. Önerilen yöntemin osilatör sinir ağı yapısı aslında bir kümeleme algoritması gibi çalışmaktadır. Sinir ağının ağırlıkları öznitelik vektörlerinden hesaplanmakta, benzer

özniteliğe sahip hücreler arasında kuvvetli bağlar oluşturulurken, farklı özniteliğe sahip hücreler arasında zayıf bağlar kurulmaktadır. Lider hücre oluşturan parametre ile küresel inhibitörün lider osilatörleri yönlendiren parametresi sistemin en önemli parametreleri olup dikkatli seçilmelidirler. Önerilen öznitelik çıkarımı ve osilatör sinir ağı sınıflandırıcısı ile gerçekleştirilen uygulama sonuçları, sistemin bölütlemeyi yüksek başarı ile tamamladığını göstermiştir. Sistemin en büyük dezavantajı parametrelerin iyi bir şekilde ayarlanamamasından kaynaklanan yanlış bölütlemelerdir.

6. Önerilen öznitelik çıkarım yöntemleri ile eğitici YSA yapısı kolonoskopik video görüntülerden normal ve ab-normal (polip) dokuların teşhisi için kullanılmıştır. Kolon kanseri dünyada en çok artış gösteren hastalıkların başında gelmektedir. Kolonda bulunan ve polip olarak adlandırılan bu abnormaliteler erken teşhis edilmedikleri takdirde kanserli dokulara dönüşmeleri kuvvetli bir ihtimaldir [172-174]. Poliplerin erken safhada teşhisi ve tedavisi oldukça önemlidir. Uygulamanın amacı kolonoskopik görüntüleri inceleyen hekime yardımcı olabilecek bir karar destek sisteminin geliştirilmesidir. Birinci öznitelik vektörünü dalgacık paket entropi ve enerji değerleri oluşturmaktadır. Bu öznitelik vektörünün boyutunun diğer öznitelik vektöründen düşük olması, YSA sınıflandırıcısının eğitiminde oldukça önemli avantajlar sağlamaktadır.
7. Uygulama sonuçlarının değerlendirilmesi için ROC analiz yöntemi kullanılmıştır [177, 178]. Negatif ve pozitif örüntülerin sınıflandırılmasının gerektiği birçok tıbbi karar destek uygulamalarında, sınıflandırılacak veri kümesi oldukça dengesiz bir yapıdadır. Bunun anlamı, sağlıklı örneklerle işaret eden örüntülerin, patolojik örüntülerden çok daha fazla olmasıdır. Doğru sınıflandırılan örnek sayısının toplam örnek sayısına oranlanarak elde edilen doğruluk, makine öğrenmesi uygulamalarında sıkça kullanılan bir başarımlı değerlendirme kriteridir. Bu kriter, oluşturulan sınıfların dağılımlarının bilinmediğini, değişmediğini ve yanlış pozitif ve yanlış negatif olarak atanan örüntülerinde eşit olduğunu varsayar. Bu varsayımlar, dengesiz veri kümelerinin performans değerlendirmesi için bu yöntemin güvenilir kılınmamaktadır. Bu tür durumlarda, azınlık sınıfına ait olan örüntülerin doğru olarak sınıflandırılması, çoğunluk sınıfına ait olan örüntülerin doğru olarak sınıflandırılmasından çok daha önemlidir. Önerilen dalgacık paket entropi ve enerji öznitelikleri ile yapay sinir ağı sınıflandırıcısı kullanılarak gerçekleştirilen uygulamalar da ortalama % 86.2 duyarlılık ve % 85.7 kesinlik değerleri elde edilirken, dalgacık dönüşümü eş-oluşum matrislerinin istatistiksel öznitelikleri ile yapay sinir ağı sınıflandırıcısı kullanılarak gerçekleştirilen

uygulamalar da ise ortalama % 90.2 duyarlılık ve % 88.7 kesinlik değerleri elde edilmiştir.

8.2. Öneriler

1. Bölüm 3’de önerilen PMRA yapısı her ne kadar eğiticişiz bir model olarak görölse de, görüntüyü oluşturan sınıf sayısının kullanıcı tarafından modele bildirilmesi önemli bir zorluk ve dezavantajdır. Çünkü gerçek dünya görüntüleri ve gürültülü görüntüler için sınıf sayısının bilinmesi mümkün olmayabilir. Verilen bir görüntü için sınıf sayısını otomatik bulan bir algoritma önerilen yönteme entegre edilebilir. Diğer taraftan EM algoritması iteratif bir yöntem olup, istenen değerlere yakınsama zaman gerektirmektedir. EM algoritması ile aynı görevi yapan fakat daha az bir zamanda gerçekleştiren yeni bir metot geliştirilebilir.
2. Bölüm 4’de önerilen öznitelik çıkarım yönteminin en önemli dezavantajı, dalgacık paket ayrışım seviyesi arttıkça öznitelik vektörünün boyutunun da artmasıdır. bu durum YSA sınıflandırıcısının eğitimi için oldukça fazla hesaplama yükü ve zaman gerektirmektedir. Bu durum gerçek zamanlı uygulamalar için istenmeyen bir durumdur. Bu problemin giderilmesi için öznitelik vektörünün boyutunu indirgeyen yöntemler sisteme eklenebilir. Örneğin LDA veya PCA kullanılabilir.
3. Bölüm 5’de önerilen osilatör sinir ağı yapısı tek katmanlı bir yapıdır. Çok katmanlı osilatör sinir ağı yapıları tasarlanarak görüntü bölütleme üzerindeki performans etkisi incelenebilir.
4. Bu tez çalışmasında kullanılan ve geliştirilen algoritmalarda veri alma, özellik çıkarma ve sınıflama işlemlerinin daha hızlı yapılabilmesi problemi ileride, DSP kullanılarak giderilebilir.

8.3. Yayınlar

Bu tez çalışmasında gerçekleştirilen uygulamalardan 4 adet uluslararası dergi yayını, [179-182], 4 adet yurtiçi uluslararası konferans yayını [183-186] ve 2 adet ulusal konferans yayını ile sonuçlanmıştır [130, 187].

KAYNAKLAR

1. Haralick, R. M., Shapiro L.G., Survey, Image segmentation techniques, Computer Vision, Graphics and Image Processing, 29, 100-132, 1985.
2. Otsu, N., A Threshold Selection Method from Gray-Level Histogram, IEEE Trans. on Systems, Man, and Cybernetics SMC-9, pp. 62--66, Jan, 1979.
3. Kitler, J., Illingworth, J., Minimum error thresholding, Pattern Recognition, Vol. 19, no. 1, Pages 41-47, 1985
4. Cho, S., Haralick, R., and Yi, S., Improvement of Kittler and Illingworth's minimum error thresholding, Pattern Recog. Vol. 22, no.5, pp. 609-617, 1989.
5. Kurita T., Otsu, N., Abdelmalek, N., Maximum likelihood thresholding based on population mixture models, Pattern recognition, vol. 25, no. 10, pp. 1231-1240, 1992.
6. Bongiovanni G., Cinque, L., Levialdi, S. Rosenfeld, A., Image Segmentation by a Multiresolution Approach, Pattern Recognition, Vol. 26, No. 12, pp. 1845-1854, 1993.
7. Sekita, I., Kurita, T., Otsu, N. and Abdelmalek, N. N., A thresholding method using the mixture of normal density functions, International symposium on speech image processing and neural Networks, 1994.
8. Huang, L. K. and Wang, M. J. J., Image thresholding by minimizing the measures of fuzziness, Pattern Recognition, Volume 28, Issue 1, January, Pages 41-51, 1995.
9. Li, L., Gong, J. and Chen, W., Grey-level image thresholding based on Fisher linear projection of two-dimensiona histogram. Pattern recognition 30(5): 743-749, 1997.
10. Friel, N. and Molchanov, I. S., A new thresholding technique based on random sets, Pattern Recognition, Volume 32, September, pp.1507-1517, 1999.
11. Jawahar, C. V., Biswas, P. K., and Ray A. K., Analysis of fuzzy thresholding schemes Pattern Recog., Vol. 33, Issue 8, August, pp. 1339-1349, 2000.
12. Wang, Q., Chi, Z. and Zhao, R., Image Thresholding by Maximizing the Index of Nonfuzziness of the 2-D Grayscale Histogram, Computer Vision and Image Understanding, Volume 85, Issue 2, February, pp. 100-116, 2002.
13. Zhao, M.S., Fu, A.M.N., Yan, H., A technique of three-level thresholding based on probability partition and fuzzy 3-partition. IEEE Trans. Fuzzy Systems 9 (3), 469-479, 2001.
14. Tobias, O., Image segmentation by histogram thresholding using fuzzy sets. IEEE Transactions on Image Processing, 11(12):1457-1465, December, 2002.
15. Chaira, T. and Ray, A. K., Threshold selection using fuzzy set theory Pattern Recognition Letters, Volume 25, Issue 8, June , pp. 865-874, 2004.

16. Cheng, H. D. and Lui, Y. M., Automatic bandwidth selection of fuzzy membership functions Information Sciences, Vol. 103, December, pp. 1-21, 1997.
17. Mitchell, H. B., Pattern recognition using type-II fuzzy sets Information Sciences, Vol. 170, February, pp. 409-418, 2005.
18. Wang, W. J., New similarity measures on fuzzy sets and on elements Fuzzy Sets and Systems, Volume 85, February Pages 305-309, 1997.
19. Cheng, H. D., Chen, C. H. and Chiu, H. H., Image segmentation using fuzzy homogeneity criterion Information Sciences, Vol. 98, May, pp. 237-262, 1997.
20. Brink A. D., Thresholding of digital images using two dimensional entropies, Pattern Recognition, vol. 25, no. 8, pp. 803-808, 1992.
21. Sahoo P. K. and Arora G., A thresholding method based on two dimensional Renyi's entropy, Pattern Recognition, vol. 37, pp. 1149-1161, 2004.
22. Sezgin, M. and Sankur, B., Survey over image thresholding techniques and quantative performance evaluation, Journal of Electronic Imaging 13 (1), 146-165, January, 2004.
23. Sahoo, P., Wilkins, C. and Yeager, J., Threshold selection using Renyi's entropy Pattern Recognition, Volume 30, Issue 1, pp. 71-84, January, 1997.
24. Brink, A.D., Minimum spatial entropy threshold selection, IEE proc.-Vis. image signal proces. Vol. 142 no:3 June, 1995.
25. Pun T., Entropic thresholding, a new method, CGIP 16, 210-239, 1981.
26. Kapur J.N., Sahoo, P.K. and Wong, A.K.C., A new method of gray level picture thresholding using the entropy of the histogram. Comput. Vision Graphics Image Process.,29, 273-285, 1985.
27. Li E. H., Lee C. K., Minimum cross-entropy thresholding, Pattern Recognition, 617-625, 1992.
28. Pal N. R., On minimum cross-entropy thresholding, Pattern Recognition, vol. 29, pp. 575-580, 1996.
29. Brink A. D. and Pendock N. E., Minimum cross-entropy threshold selection, Pattern Recognition, vol. 29, no. 1, pp. 179-188, 1996.
30. Abutaleb A. S., Automatic thresholding of grey level pictures using two dimensional entropy, Comput. Vision Graphics Image process. Vol. 47, pp. 22-32, 1989.
31. Pal N. R. and Pal S. K., Entropy thresholding , Signal Process. Vol. 16, pp. 97-108, 1989.
32. Pham, T. D. and Yan, H., Color image segmentation using fuzzy integral and mountain clustering Fuzzy Sets and Systems, Volume 107, Issue 2, 16 October, pp. 121-130, 1999.
33. Tao, W., Burkhardt, H., An effective image thresholding method using a fuzzy compactness measure, 1994.

34. Zenzo, S. G., Cinque, L. and Levialdi, S., Image thresholding using fuzzy entropies, IEEE Trans. Syst., Man, Cybern. Part B, vol. 28, pp.15–23, Feb, 1998.
35. Chein-I Chang, Kebo Chen, Jianwei Wang and Mark L. G. Althouse, A relative entropy-based approach to image thresholding Pattern Recognition, Vol. 27, September, pp. 1275-1289, 1994.
36. Wang, J., Du, Y., Chang, C. I. and Thouin, P. D., Relative entropy-based methods for image thresholding", IEEE International Symposium on Circuits and Systems (ISCAS), Vol. 2, pp. 265-268, May, 2002.
37. Pitas, I. Milios, E., A minimum entropy approach to rule learning from examples, IEEE trans. on sys. Man. And cybernetics, vol:22, no:4, 1992.
38. Kesavan, H. K., Kapur, J. N., The generalized maximum entropy principle, IEEE trans. on sys. Man. And cybernetics, vol:19, no:5, 1989.
39. N. Pavesic, S. Ribaric, Gray level thresholding using the havrda and charvat entropy, 10 th. Mediterranean Elect. Conference, vol. 2, 2000.
40. Sahoo P.K. and Wong A.K.C., A gray level threshold selection method based on maximum entropy principle, IEEE Trans. On Sys. Man. And Cybernetics, vol:19, no:4, 1989.
41. Sankur B. and Sezgin M. A survey over image thresholding techniques and quantitative performance evaluation. Journal of Electronic Imaging, 13(1): 146-165, 2004.
42. Fu K.S. and Mui J.K., A survey on image segmentation. Pattern Recognition, 13(1): 3-16, 1981.
43. Zhang Y.J. A survey on evaluation methods for image segmentation. Pattern Recognition, 29(8): 1335-1346, 1996.
44. Pal N.R. and Pal S.K., A review on image segmentation techniques. Pattern Recognition, 26(9): 1277-1294, 1993.
45. Chellappa R, Chatterjee S., Classification of textures using gaussian markov random fields. IEEE Tr. Acoustic, Speech and Signal Processing, 33: 959-963. 10, 1985.
46. Li S. Z., Markov random field modeling in computer vision. Springer, New York,, 2001.
47. Besag J., On the statistical analysis of dirty pictures, J. Roy. Statist Soc. Ser. 48, pp.259-302, 1986.
48. Kato Z., Zerubia J., Berthod M., Unsupervised paralel image classification using Markovian models, Patt. Recog., vol. 32, pp. 591-604, 1999.
49. Dubes R. C., Jain A. K., Nadabar S.G. and Chen C.C., MRF model based algorithms for image segmentation, IEEE, 1990.
50. Sarkar A., Biswas M, K, and Sharma K. M. S., A simple Unsupervised MRF model based image segmentation approach. IEEE Trans. on image processing, vol. 9 no: 5 May, 2000.

51. Cross, G. R. and Jain, A. K., Markov random field texture models," IEEE Trans. Pattern Anal. Machine Intell., vol. 5, no. 1, pp. 25-39, 1983.
52. Derin, H. and Cole, W. S., Segmentation of textured images using Gibbs random fields. Computer Vision, Graphics and Image Processing, 35:72—98, 1986.
53. Hassner, M. and Slansky, J., The use of Markov random field as models of texture, Computer Graphics Image Processing, 12:357—370, 1980.
54. Yu, L. Y., New results on image segmentation and interpretation using the MRF model, RPI Rep., June, 1988.
55. Chang, T. and Kuo, C. C. T., Texture analysis and classification with tree-structured wavelet transform, IEEE Trans. on Image Processing, vol. 2 no. 4, pp.429-441, 1993.
56. Cesmeli, E. and Wang, D., Texture segmentation using Gaussian Markov random fields and LEGION, IEEE conference, 1997.
57. Cesmeli, E., Texture Segmentation Using Gabor Filters and LEGION, MAICS96, 1996.
58. Wang, D. L., Terman, D., Locally excitatory globally inhibitory oscillator Networks Neural Networks, IEEE Transactions on Vol. 6, no. 1, pp. 283-286 Jan, 1995.
59. Jain, A.K., Farrokhnia, F., Unsupervised texture segmentation using Gabor filters, Patt. Recog., 24, 1167-1186, 1991.
60. A. Mojsilovic, D. Rackov, M. Popovic, On the selection of an optimal wavelet basis for texture characterization", IEEE Trans. On Image Processing, vol. 9, no. 12, December, 2000.
61. Arivazhagan, S. and Ganesan, L., Texture classification using wavelet transform, Pattern Recog. Lett. 24, 1513-1521, 2003.
62. Unser, M., Eden, M., Multiresolution feature extraction and selection for texture segmentation. IEEE Trans. Pattern Anal. 2, 717—728, 1989.
63. Chun, S. L., Pau C. C. and Chih F. C., Unsupervised texture segmentation via wavelet transforms. Pattern Recognition, Vol. 30, pp. 729-742, May, 1997.
64. Chen, C. C., Chen, C. C., Filtering methods for texture discrimination, Patt. Rec. Lett. 20, 783-790, 1999.
65. Coggins, L. M. and Jain, A. K., A Spatial Filtering Approach to Texture Analysis, Pattern Recognition Letters, vol. 3, no. 3, pp. 195-203, 1985.
66. Blanz, W.E., Gish, S. L. , A Connectionist Classifier Architecture Applied to Image Segmentation, Proc. 10th ICPR, pp. 272-277, 1990.
67. Babaguchi, N., Yamada, K. and Tezuka, T., Connectionist Model Binarization, Proc. 10th ICPR, pp. 51-56, 1990.
68. Ghosh, A., Pal N.R. and Pal, S. K., Image Segmentation Using Neural Network, Biol. Cybern. 66, pp. 151-158, 1991.

69. Ghosh, A., Pal N.R. and Pal, S. K., Neural Network, Gibbs Distribution and Object Extraction, Intelligent Robotics, TataMcGraw-Hill, pp. 95-106, 1991.
70. Türkoğlu, İ., Arslan, A. ve İlkay, E., A pattern recognition system for diagnose of the heart mitral valve diseases based on wavelet packet and neural network, *Fırat Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 14(1), 1-10, (2002).
71. Ong, S. H., Yeo, N. C., Lee, K. H., Venkatesh, Y. V., and Cao, D. M., Segmentation of color images using a two-stage self-organizing network, *Image and Vision Computing*, Vol. 20, April, pp. 279-289, 2002.
72. Vinod, V. V., et al., A Connectionist Approach for gray Level Image Segmentation., 11th International Conference On Pattern Recognition, pp. 489-492, 1992.
73. Chen, K. et al, Weight adaptation and oscillatory correlation for image segmentation, *IEEE Trans. On neural Networks*, vol. 11, no.5, 2000.
74. Wang, D.L. and Terman, D., Image segmentation based on oscillatory correlation. *Neural Computation*, vol. 9, 805-836, 1997.
75. Wang, D.L. and Terman, D., Locally excitatory globally inhibitory oscillator networks. *IEEE Transactions on Neural Networks*, vol. 6(1), 283-286, 1995.
76. Shareef, N., Wang, D.L., and Yagel, R., Segmentation of medical images using LEGION. *IEEE Transactions on Medical Imaging*, vol. 18, 74-91, 1999.
77. Comaniciu, D., Meer P., Mean Shift: A Robust Approach toward Feature Space Analysis, *IEEE Trans. Pattern Analysis Machine Intell.*, Vol. 24, No. 5, 603-619, 2002.
78. Comaniciu, D., Meer P., Mean Shift Analysis and Applications, *IEEE Int. Conf. Computer Vision (ICCV'99)*, Kerkyra, Greece, pp.1197-1203, 1999.
79. Comaniciu, D., Meer P., Cell Image Segmentation for Diagnostic Pathology, (Invited), in *Advanced Algorithmic Approaches to Medical Image Segmentation*, Suri, Setarehdan, and Singh (Eds), ISBN: 1-85233-389-8, Springer, 2002.
80. Comaniciu, D., Meer P., Image Guided Decision Support System for Pathology, *Machine Vision and Applications*, Vol. 11, No. 4, 213-224, 2000.
81. Rushing, J.A., Ranganath, H.S., Hinke, T.H. Graves, S.J., Using association rules as texture features, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 23, 845 – 858, Aug, 2001.
82. Rushing, J.A., Ranganath, H.S., Hinke, T.H., Graves, S.J., Image segmentation using association rule features, *IEEE Transactions on Image Processing* Vol. 11, 558 – 566, May, 2002.
83. Manjunath, B.S., Ma, W. Y., Texture features for browsing and retrieval of image data, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18(8), 837-842, 1996.
84. Bhandarkar, S.M., and Zhang, H., Image Segmentation Using Evolutionary Computation. *IEEE Transactions on Evolutionary Computation*, Vol. 3, April, pp. 1-21, 1999.

85. Chun, D. N. and Yang, H. S., Robust image segmentation using genetic algorithm with a fuzzy measure, *Pattern Recognition*, Vol. 29, July, pp.1195-1211, 1996.
86. Yoshimura, M. and Oe, S., Evolutionary segmentation of texture image using genetic algorithms towards automatic decision of optimum number of segmentation areas, *Pattern Recognition*, Vol. 32, December, pp.2041-2054, 1999.
87. Sammouda, R., Sammouda, M., Improving the performance of Hopfield Neural Network to segment pathological liver color images. *CARS*, pp.232-239, 2003.
88. Lam, R.W.K., Ip, H.H.S., Cheung, K.K.T., Tang, L.H.Y., Hanka, R., Similarity measures for histological image retrieval *Pattern Recognition, Proceedings. 15th International Conference on Vol. 2*, Sept., pp.295 – 298, 2000.
89. Esgiar AN, Naguib RNG, Sharif BS, Bennett MK, Murray A. Fractal analysis in the detection of colonic cancer images. *IEEE Trans Info Technol Biomed*; 6: 54-8, 2002.
90. Krishnan, S. M. Yap, C. J., Asari, K. V. and Goh, P. M. Y., Neural network based approaches for the classification of colonoscopic images In: *Proceedings of the 20th annual international conference of the IEEE Engineering in Medicine and Biology Society*, 20: 1678- 1680, 1998.
91. Asari, K. V., A fast and accurate segmentation technique for the extraction of gastrointestinal lumen from endoscopic images, *Medical Engineering & Physics*, 22, pp.89-96, 2000.
92. Mena, J. B., Malpica, A. J., An automatic method for road extraction in rural and semi-urban areas starting from high resolution satellite imagery. *Pattern Recognition Letters* 26(9): 1201-1220, 2005.
93. Zhang, C., Wang, P., A New Method of Color Image Segmentation Based on Intensity and Hue Clustering, *icpr*, p. 3617, 15th International Conference on Pattern Recognition (ICPR'00) – Vol. 3, 2000.
94. Bergman, L., Verikas, A., Bacauskiene, M., Unsupervised colour image segmentation applied to printing quality assessment, *IVC(23)*, No. 4, 1 April, pp. 417-425, 2005.
95. Chen, T.Q., Lu, Y., Color image segmentation-an innovative approach, *Pattern recognition*, 25: 395-405, 2001.
96. Cheng, H. D., Jiang, X. H., Sun, Y. and Wang, J., Color image segmentation: advances and prospectus, *Pattern Recognition*, 34: 2259-2281, 2001.
97. Gonzalez, R. C., Woods, R. E., *Digital image processing*, Prentice Hall, 2002.
98. Nazif, A. M. and Levine, M. D., Low Level Image Segmentation: An Expert System, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, pp. 555-577, 1984.
99. Raya, S.P., Low Level Image Segmentation 3-D MR Brain Images-A Rule Based System, *IEEE Trans. On Medical Imaging*, 9, pp. 237-246, 1990.

100. Darwish, A. M., Jain, A.K., A rule based approach for visual pattern inspection, IEEE PAMI, 10, pp. 56-68, 1988.
101. Dubes, R. C., Jain, A. K., Models and methods in cluster validity, technical report, MSU, College of Engineering, USA, 1977.
102. Healey, G., Modelling color images for machine vision. Advances in image processing and machine vision, Springer –Verlag, Ed. J. Sans, pp. 129-146, 1996.
103. Perez, P., Markov Random Field and Images, Publication Intern No. 1196, France, 1998.
104. Adams, R., Bischof, L., Seeded region growing. IEEE Trans. on PAMI, 16, pp. 641-647, 1994.
105. Haralick, R. M. and Kelly, G. L., Pattern recognition with measurement space and spatial clustering for multiple images. Proc. IEEE 57, 4, 654-665, 1969.
106. Coleman, G. B. and Andrews, H. C., Image segmentation by clustering, Proceedings of the IEEE, vol. 67, no. 5, pp. 773-785, 1979.
107. Pappas, T., An adaptive clustering algorithm for image segmentation, IEEE Trans. Signal Process., vol. SP-40, pp. 901-914, 1992.
108. Pavlidis, T., and Liow, Y., Integrating Region Growing and Edge Detection, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 12, pp. 225-233, 1990.
109. Qian, Y., Zhao, R., Image Segmentation Based on Combination of Global and Local Information. ICIP (1), pp. 204-207, 1997.
110. Türkoğlu, İ., Durağan Olmayan İşaretler İçin Zaman-Frekans Entropilerine Dayalı Akıllı Örüntü Tanıma, Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, 2002.
111. Türkoğlu, İ., Arslan, A. ve İlkay, E., A Computer Aided Method for Diagnose of The Heart Mitral Valve Diseases, International Journal for Engineering Modelling, 15(1-4), 1-9, 2002.
112. Kara, S., “Doppler cihazı ve autoregresif spektral analiz metoduyla mitral ve triküspit kapaklarındaki kan akışının incelenmesi”, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Doktora tezi, 60s, 1994,
113. Şengür, A., ve Türkoğlu, İ., Classifing Analogue Modulated Communication Signals Using Bayes Decision Criterion, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü Dergisi, 7(3), 32-36, 2003.
114. Avcı, E., Türkoğlu, İ., ve Poyraz, M., Intelligent Target Recognition Based on Wavelet Packet Neural Network”, Expert Systems with Applications, 29(1), 175-182, 2005.
115. Akin, M., Arserim, M.A., Kıymık, M.K. and Türkoğlu, İ., 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), 2001.

116. Akay, M., "Investigating the effects of vasodilator drugs on the turbulent sound caused by femoral artery stenosis using short-term fourier and wavelet transform methods", IEEE Transaction ob Biomedical Engineering, 41,921-928, 1994.
117. Shannon, C.E., "A mathematical theory of communication", Bell System Technology Journal, 27, 379-423, 1948.
118. Overwijk, M.H.F. and Reefman, D., "Maximum-entropy deconvolution applied to electron energy-loss spectroscopy", Pergamon Micron, 31, 325-331, 2000.
119. Li, X., "Edge directed statistical inference with applications to image processing", Doktora Tezi, Princeton Üniversitesi, 131s, 2000.
120. Zhang, X.S. and Roy, R.J., Derived fuzzy knowledge model for estimating the depth of anesthesia, IEEE Transactions on Biomedical Engineering, 48, No.3, 312-323, 2001.
121. Karras, D.A., Karkanis, S.A. and Mertzios, B.G., 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, 1998.
122. Hoang, M., Aaron, R. and Shiffman, C.A., Maximum entropy method for Magnetoencephalography, IEEE Transactions on Biomedical Engineering, 44,1,98-102, 1997.
123. Coifman, R.R. and Wickerhauser, M.V., Entropy-based algorithms for best basis selection, IEEE Transaction on Information Theory, 38, 2, 713-718, 1992.
124. Penny, W.D., Signal Processing Course, 178s, 28 Nisan 2000.
125. Wouwer G. Van de, Scheunders P., Livens S and Van Dyck D, Wavelet correlation signatures for color texture characterization, Pattern Recognition, Vol. 32, Issue 3, pp. 443-451, 1999.
126. Amet, A., Ertüzün, A. and Erçil, A., An Efficient Method for Texture Defect Detection: Subband Domain Co-Occurrence Matrices, Image and Vision Computing, May, pp.543-553, 2000.
127. Kil, D.H. ve Shin, F.B., Pattern Recognition and Prediction with Applications to Signal Characterization. AIP Press, USA, 417s, 1996.
128. Principe, J.C., Euliano, N.R. and Lefebvre, W.C., 2000, Neural and Adaptive Systems. John Wiley & Sons, 1. Baskı, New York, 656s,
129. Türkoğlu, İ., ve Hanbay, D., Yapay Sinir Ağı ve HFD Kullanarak DTMF Sinyal Örüntülerini Tanıma Sistemi", Elektrik - Elektronik – Bilgisayar Mühendisliği 9. Ulusal Kongresi, 431-434, Kocaeli, 2001.
130. Şengür, A., Türkoğlu, İ., ve İnce, M.C., Eğiticişiz Yapay Sinir Ağları ile Görüntü Bölütleme Uygulamaları, IEEE 13. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 271-274, Kayseri, 2005.

131. Türkoğlu, İ., Yapay Sinir Ağları İle Nesne Tanıma, Y. Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, s. 93, 1996.
132. Duda, R.O. and Hart, P.E., Pattern Classification and Scene Analysis. Stanford Research Institute, 483s, 1989.
133. Anderberg, M.R., Cluster Analysis for Applications, Academic Press, Inc., Newyork, NY, 1973.
134. Bezdek, J. C., A Convergence Theorem for the Fuzzy ISODATA Clustering Algorithms, IEEE Transaction On Pattern Analysis and Machine Intelligence, pp.1-8, 1980.
135. Xie, X. L., Beni, G., A Validity Measure for Fuzzy Clustering, IEEE Transaction on Pattern Analysis and Machine Intelligence, vol. 13 (8), pp.841-847, 1991.
136. Fukunaga, K. and Hostetler, I. D., The Estimation of the Gradient of a Density Function,with Applications in Pattern Recognition. IEEE Trans. Info. Theory, IT-21: p. 32-40, 1975.
137. Sahoo, P. K., Soltani, S., Wong, A. and Chen, Y., A survey of thresholding techniques, Computer Vision Graphics Image Processing, vol. 41, pp. 233-260, 1988.
138. Tsao, E.C.K., Bezdek, J. C. and Pal, N.R., Fuzzy Kohonen clustering networks, Patt. Recog. vol. 27, pp. 757-764, 1994.
139. Liu, J. and Yang Y. H., Multiresolution color image segmentation. IEEE Trans. On Pattern Analysis and Machine Int. Vol., No: 7, July, 1994.
140. Kurugollu, F., Sankur, B. and Harmanci, A. E., Color image segmentation using histogram multithresholding and fusion, Image and Vision Computing, vol. 19, pp. 915-928, 2001.
141. Sarkar, A., Biswas, M. K. and Sharma, K. M. S., A simple Unsupervised MRF model based image segmentation approach. IEEE Trans. on image processing, vol. 9 no: 5 May, 2000.
142. Kato, Z., Zerubia, J., Berthod, M., Unsupervised paralel image classification using Markovian models, Patt. Recog., vol. 32, pp. 591-604, 1999.
143. Yang, X. and Liu, J., Unsupervised texture segmentation with one-step mean shift and boundary Markov random fields, Pattern Recognition Letters, Vo. 22,pp. 1073-1081, 2001.
144. Ibanez, M. V. and Simo, A., Parameter estimation in Markov random field image modeling with imperfect observations. A comparative study, Patt. Recog. Letters, 24, pp. 2377-2389, 2003.
145. Deng, H., Clausi, D. A., Unsupervised image segmentation using a simple MRF model with a new implementation schema, Patt. Recog. Vol. 37, pp. 23223-2335, 2004.
146. Clausi, D. A. and Yue, B., Comparing cooccurrence probabilities and Markov random fields for texture analysis of SAR sea ice imagery., IEEE Trans. on Geosciences and Remote Sensing., vol. 42, no:1, January, 2004.

147. Kim, E. Y., Park, S. H and Kim, H. J., A genetic algorithm-based segmentation of markov random fields modeled images, *IEEE Signal Process. Lett.* Vol. 7, No:11, November, 2000.
148. Yu, Y. and Cheng, Q., MRF parameter estimation by an accelerated method. *Patt. Recog. Lett.* 24, pp. 1251-1259, 2002.
149. Pal, N.R. and Pal, S. K., Image Model, Poisson distribution and object extraction. *Int. J. Patt. Recog. Artific. Intell.* 5 (3) pp. 459-483, 1991.
150. Geman, S., Geman, D., Stochastic relaxation, Gibbs distributions, and Bayesian restoration of images, *IEEE Trans. PAMI*, vol. 6, pp. 721-741, 1984.
151. McLachlan, G., Krishnan, T., *The EM algorithm and extensions*, New York, John Wiley and Sons, 1997.
152. Dempster, A., Laird, N., and Rubin, D., Maximum likelihood estimation from incomplete data via the EM algorithm, *J. Royal Statistical Soc. B.* vol. 39 pp. 1-38, 1977.
153. Internet: www.caip.rutgers.edu/~comanici/segm_images.html, 2004.
154. Cesmeli, E.; Wang, D. Texture segmentation using Gaussian-Markov random fields and neural oscillator Networks, *Neural Networks, IEEE Transactions on* Vol. 12, no. 2, pp. 394-404, 2001.
155. Haralick, R.M., Shanmugam, K.K., Dinstein, I., Texture features for image classification. *IEEE Trans. Syst. Man Cyb.* 8 (6), 610-621, 1973.
156. Lu, C. S., Chung, P. C. and Chen, C. F., Unsupervised texture segmentation via wavelet transform. *Pattern Recognition*, Vol. 30, pp. 729-742, May, 1997.
157. Busch, C., Wavelet based texture segmentation of multi-modal topographic images. *Computers & Graphics*, Vol. 21, pp.347-358, May-June, 1997.
158. Acharyya M., and Kundu, M. K., An adaptive approach to unsupervised texture segmentation using M-Band wavelet transform., *Signal Processing*, Vol. 81, pp. 1337-1356, July, 2001.
159. Wang, X., Hua, J. and Rongchun, Z., Texture segmentation method based on incomplete tree structured wavelet transform and fuzzy Kohonen clustering network, *Intelligent Control and Automation*, 2000. *Proceedings of the 3rd World Congress*, Vol. 4, pp. 2684-2687, June, 2000.
160. Cohen, A., Daubechies, I. and Feauveau, J. C., Biorthogonal bases of compactly supported wavelets, *Commun. Pure Appl. Math.* Vol. 45, pp. 485-560, 1992.
161. Sklansky J., Image segmentation and feature extraction. *IEEE Trans. System Man Cybernat.*, 8,237-247, 1978.
162. Weszka, J. S., Dyer, C.R., Rosenfeld, A., A comparative study of texture measures for terrain classification, *IEEE Trans. Syst. Man. Cybernet.* 6, 269-285, 1976.

163. Muneeswaran, K., Ganesan, L., Arumugam, S. and Soundar, K., Texture classification with combined rotation and scale invariant wavelet features, *Pattern Recognition*, 38, 10, 1495-1506, 2005.
164. Li, S. and Taylor, J. S., Comparison and fusion of multiresolution features for texture classification, *Pattern Recognition Letters*, 26, 5, 633-638, 2005.
165. Li, S., Kwok, J. T., Zhu, H. and Wang, Y., Texture classification using the support vector machines *Pattern Recognition*, 36, 12, 2883-2893, 2003.
166. Wang, L. and Liu, J., Texture classification using multiresolution Markov random field models, *Pattern Recognition Letters*, 20, 2, 171-182, 1999.
167. Dickhous, H. and Heinrich, H., Classifying Biosignals with Wavelet Networks, *IEEE Engineering in Medicine and Biology*, Eylül/Ekim, 103-111, 1996.
168. Zhang, Q. and Benveniste, A., "Wavelet Network", *IEEE Transaction on neural networks*, 3, No.6, Kasım 1992, 889-898, 1992.
169. Tkacz, E.J. and Kostka, P., An application of wavelet neural network for classification of patients with coronary artery disease based on HRV analysis, *Engineering in Medicine and Biology Society, Proceedings of the 22nd Annual International Conference of the IEEE*, 2, 1391-1393, 2000.
170. Turkoglu, I., Arslan, A. and Ilkay, E., An intelligent system for diagnosis of the heart valve diseases with wavelet packet neural Networks, *Computers in Biology and Medicine*, 33, 4, 319-331, 2003.
171. İnternet: <http://sipi.usc.edu/database/database.cgi?volume=textures&image=1#top>, 2005.
172. Iakovidis, D.K., Maroulis, D.E. Karkanis, S.A., Papageorgas, P. and Tzivras, M, Texture multichannel measurements for cancer precursors' identification using support vector machines *Measurement*, vol.36, pp.297-313, October-December, 2004.
173. Karkanis, S.A., Magoulas, G.D., Iakovidis, D.K, Karras, D.A. and Maroulis, D.E., Evaluation Of Textural Feature Extraction Schemes For Neural Network-Based Interpretation Of Regions In Medical Images, *IEEE International Conference in Image Processing (ICIP) Proceedings*, pp. 281-284, Thessaloniki, Greece, 2001.
174. Karkanis, S. A., Iakovidis, D. K., Maroulis, D. E., Karras, D. A., and Tzivras, M. D., Computer Aided Tumor Detection in Endoscopic Video using Color Wavelet Features, *IEEE Transactions on Information Technology in Biomedicine*, vol. 7, no. 3, 2003.
175. Haykin, S., *Neural networks, A Comprehensive Foundation*. Macmillan College Publishing Company Inc., New York, 417s, 1994.
176. Rothe, H., Fecht, A., Kasper, A., and Rinder, T., Practical Applications of pattern recognition techniques, *NATO-RTO Lecture Series 214*, Lisbon Portugal, 12-1,12-25, 1998.
177. Metz, C. E., Basic principle of ROC analysis, *Stat. Nucl. Med.*, vol. 8, pp. 283-298, 1978.

178. Dirican, A. Tanı testi performanslarının değerlendirilmesi ve kıyaslanması, Cerrahpaşa J Med. Vol. 32, s. 25-30, Ocak-Mart, 2001.
179. Şengür, A., Türkoğlu, İ., ve İnce, M.C., Unsupervised Image Segmentation Using Markov Random Fields”, Lecture Notes in Artificial Intelligence, LNAI 3949, 158 – 167, 2006.
180. Şengür, A., Türkoğlu, İ., ve İnce, M.C., Wavelet Packet Neural Networks For Texture Classification, Expert systems with applications, 32(2), Mart, 2007.
181. Şengür, A., Türkoğlu, İ., ve İnce, M.C., Performance Comparison of Thresholding Algorithms on Uneven Illuminated Image, Asian Journal of Information technology, 3(10), 956-959, 2004.
182. Şengür, A., Türkoğlu, İ., ve İnce, M.C., A Comparative Study On Entropic Thresholding Methods, Istanbul University-Journal of Electrical&Electronics Engineering (IU-JEEE), 6(2), 2006.
183. Şengür, A., Türkoğlu, İ., ve İnce, M.C., Comparison Of Fuzzy Image Thresholding Techniques, European University Of Lefke, Creating The Future, 3rd FAE International Symposium, 411-414, KKTC, 2004.
184. Şengür, A., Türkoğlu, İ., ve İnce, M.C., Medikal İmgelerde Histogram Tabanlı Bölütleme Uygulamaları”, 4. Uluslar Arası İleri Teknolojiler Sempozyumu, 1-5, Konya, 2005.
185. Şengür, A., Türkoğlu, İ., ve İnce, M.C., Unsupervised Image Segmentation Using Markov Random Fields, TAINN-2005, 79-87, İzmir, 2005.
186. Şengür, A., Türkoğlu, İ., İnce, M.C., Bahçecioğlu, İ.H., Salient Region Extraction from Endoscopic Images, TAINN, 33-40, Muğla, 2006.
187. Şengür, A., Türkoğlu, İ., ve İnce, M.C., İki Boyutlu Entropi İle Görüntü Eşikleme Uygulamaları, IEEE 13. Sinyal İşleme Ve İletişim Uygulamaları Kurultayı, 275–278, Kayseri, 2005.

EK – 1

EVIS LUCERA OLYMPUS CV-260 ENDOSKOP

1- Gerçeğe çok yakın yüksek çözünürlüğe sahip HDTV görüntüler yanı sıra IHB analizi sağlayan bu sistem, daha önceki videoendoskopi sistemlerin sağladığı çözünürlüğün iki katı çözünürlük sunar ve mhaemoglobin seviyesine bağlı olarak ince mukozal renk değişikliklerinin görülmesini sağlar.

2- EVIS LUCERA önceki sistemlere oranla kullanımı kolay çok yönlü bir sistemdir. Ultra-ince dış tüp, değişebilen sertlik ayarı (tüm kolonoskoplarda bulunan standart bir özelliktir), gökkuşağı renk doğrulama, ön-dondurma imkanı, dokunmatik klavye, flat ekran LCD teknolojisi gibi özelliklere sahiptir.

3- LUCERA sisteminin kendine ait video prosesörü ve ışık kaynağı bulunmaktadır bununla birlikte CV-260 ve CLV-260 geriye dönük 200, 230 ve 240 serisi videoskoplarla uyumludur. Bu da sistemi kolay ve uygun fiyatlı hale getirmektedir.

ÖZGEÇMİŞ

Abdulkadir ŞENGÜR

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

Tel : 424 – 2370000 – 4292
E.posta : ksengur@firat.edu.tr

- 1977** Elazığ da doğdu.
- 1988 – 1995** Elazığ Anadolu Lisesini tamamladı.
- 1995 – 1999** Fırat Üniversitesi Teknik Eğitim Fakültesi Elektronik ve Bilgisayar Eğitimi Bölümünden mezun oldu.
- 2000 – 2003** Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Bilgisayar Eğitimi Anabilim Dalında “Yapay sinir ağları ile analog modülasyonlu haberleşme işaretlerinin sınıflandırılması ” konusunda yaptığı tez çalışması ile Yüksek Lisans derecesini aldı.
- 1999 – 2001** T. C. M.E.B. da çalıştı.
- 2001 – ...** Fırat Üniversitesi, Teknik Eğitim Fakültesi Elektronik-Bilgisayar bölümünde araştırma görevlisi olarak çalışmaktadır.