İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY SİNİR AĞLARI KULLANARAK ULTRASONİK GÖRÜNTÜLERDE DOKULARIN BÖLÜTLENMESİ

YÜKSEK LİSANS TEZİ

Müh. Zafer İŞCAN

Anabilim Dalı : ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ

Programı : BİYOMEDİKAL MÜHENDİSLİĞİ

KASIM 2005

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY SİNİR AĞLARI KULLANARAK ULTRASONİK GÖRÜNTÜLERDE DOKULARIN BÖLÜTLENMESİ

YÜKSEK LİSANS TEZİ

Müh. Zafer İŞCAN
(504021404)

Tezin Enstitüye Verildiği Tarih : 24 Ekim 2005
Tezin Savunulduğu Tarih : 23 Kasım 2005

Tez Danışmanı : Prof.Dr. Tamer ÖLMEZ
Diğer Jüri Üyeleri Doç.Dr. Mehmet KORÜREK
Doç.Dr. Tülay YILDIRIM (Y.T.Ü.)

KASIM 2005

İÇİNDEKİLER

KISALTMALAR **v**
TABLO LİSTESİ **vı**
ŞEKİL LİSTESİ **vıı**
SEMBOL LİSTESİ **xi**
ÖZET **xii**
SUMMARY **xiii**

1. GİRİŞ VE ÇALIŞMANIN AMACI **1**
1.1. Ön İşleme 2
1.2. Öznitelik Çıkartma 3
1.3. Öznitelik Seçme 4
1.4. Bölütleme 4

2. ULTRASONİK GÖRÜNTÜLEME TEKNİKLERİ **9**
2.1. Ultrasonik Görüntülerin Tıp Dünyası'ndaki Yeri 9
2.2. Ultrasonik görüntülerin oluşumu 10
2.3. Ultrasonik ekipman 11
2.3.1. Gönderici 11
2.3.2 Dönüştürücü (Prob) 12
2.3.3. Alıcı 13
2.3.4. İşaret İşleyici 13
2.3.5. Kayıt Üniteleri 13
2.4. Ultrasonografide görüntüleme modları 14
2.4.1. A Mod 14
2.4.2. B Mod 14
2.4.3. M Mod 14
2.5. Ultrasonik görüntülerde teşhisi zorlaştıran etmenler 14
2.6. Suni Fantom Verileri 15

3. ULTRASONİK GÖRÜNTÜLER İÇİN ÖZNİTELİK BELİRLEME YÖNTEMLERİ **18**
3.1. Gri Seviyeleri 18
3.2. 3 Gri (3G) Değeri 18
3.3. Ayrık Fourier Dönüşümü (AFD) 19
3.4. Ayrık Kosinüs Dönüşümü (AKD) 21
3.5. Sürekli Dalgacık Dönüşümü (SDD) 23

4. SINIFLAYICI OLARAK YAPAY SİNİR AĞLARI **27**
4.1. GAL (Grow and Learn, Büyü ve Öğren) Ağı 28
4.2. KOHONEN Ağı 30
4.3. DAYSA (Denetimsiz Artımsal Yapay Sinir Ağı) 31

5. YAPAY SİNİR AĞLARI İLE ULTRASONİK GÖRÜNTÜLERİN SINIFLANDIRILMASI **36**
5.1. GAL Ağı ile Sınıflama 36
5.1.1. Fantom Görüntü 36
5.1.2. Meme Görüntüsü 38
5.1.3. Karın Görüntüsü 40
5.1.4. Prostat Görüntüsü 42
5.1.5. GAL Ağı Sınıflama Sonuçları 45
5.2. KOHONEN Ağı ile Sınıflama 45
5.2.1. Fantom Görüntü 45
5.2.2. Meme Görüntüsü 47
5.2.3. Karın Görüntüsü 49
5.2.4. Prostat Görüntüsü 51
5.2.5. KOHONEN Ağı Sınıflama Sonuçları 53
5.3. DAYSA ile Sınıflama 53
5.3.1. Fantom Görüntü 53
5.3.2. Meme Görüntüsü 57
5.3.3. Karın Görüntüsü 59
5.3.4. Prostat Görüntüsü 61
5.3.5. DAYSA Sınıflama Sonuçları 63
5.4. Renklendirme 65
5.5. Öznitelik Çıkartma Yöntemlerinin Değerlendirilmesi 65
5.5. Benzetim Ortamı 67
5.6. Fantom Görüntü için Başarım Sonuçları 67

6. TARTIŞMA **70**

KAYNAKLAR **71**

EKLER **75**

ÖZGEÇMİŞ **79**

KISALTMALAR

AFD : Ayrık Fourier Dönüşümü
AKD : Ayrık Kosinüs Dönüşümü
ANN : Artificial Neural Network
CAD : Bilgisayar Destekli Teşhis
CRT : Cathode Ray Tube
CT : Computer Tomography
DAYSA : Denetimsiz Artımsal Yapay Sinir Ağı
DCT2 : 2 Boyutlu Ayrık Kosinüs Dönüşümü
DTCWT : Dual-Tree Complex Wavelet Transformation
EEG : Elektroensefalogram
EKG : Elektrokardiyogram
EMG : Elektromiyogram
FFT2 : 2 Boyutlu Hızlı Fourier Dönüşümü
FWP : Tam Wavelet Paket
GAL : Grow And Learn
GVF : Gradyan Vektör Akış
IRMA : İçerik Tabanlı Görüntü Elde Edilmesi
ISOM : Incremental Self Organising Map
KG : Kalite Güvencesi
K-NN : K Nearest Neighbour
LDA : Lineer Ayrıştırma Analizi
LVQ : Learning Vector Quantization
MRI : Magnetic Resonance Imaging
PCA : Principal Component Analysis
PRF : Pulse Repetition Frequency
PZT : Polycrystalized Tetragonal Zirconia
RBF : Radyal Tabanlı Fonksiyon
SDD : Sürekli Dalgacık Dönüşümü
SLR : Stepwise Logistic Regression
SOM : Self Organising Map
SVM : Support Vector Machines
TD : Tanjant Mesafesi
TGC : Time Gain Compensation
US : Ultrasonik
VTR : Video tape recorder
YSA : Yapay Sinir Ağı

TABLO LİSTESİ

		Sayfa No
Tablo 2.1.	Yumuşak Dokularda Ultrasonun Yayılma Hızı …….	10
Tablo 2.2.	Dokularda Zayıflama Katsayıları ……..	11
Tablo 5.1.	Fantom AKD tablosu (GAL)……	33
Tablo 5.2.	Fantom AFD tablosu (GAL)…….	34
Tablo 5.3.	Fantom Gri tablosu (GAL)……	34
Tablo 5.4.	Fantom 3 Gri tablosu (GAL)…….	34
Tablo 5.5.	Fantom SDD tablosu (GAL)…….	35
Tablo 5.6.	Meme AKD tablosu (GAL)……..	35
Tablo 5.7.	Meme AFD tablosu (GAL)……...	36
Tablo 5.8.	Meme Gri tablosu (GAL)…….	36
Tablo 5.9.	Meme 3 Gri tablosu (GAL)……..	37
Tablo 5.10.	Meme S.D.D. tablosu (GAL)……...	37
Tablo 5.11.	Karın AKD tablosu (GAL)……..	38
Tablo 5.12.	Karın AFD tablosu (GAL)……...	38
Tablo 5.13.	Karın Gri tablosu (GAL)…….	38
Tablo 5.14.	Karın 3 Gri tablosu (GAL)……..	39
Tablo 5.15.	Karın SDD tablosu (GAL)……..	39
Tablo 5.16.	Prostat AKD tablosu (GAL)……...	40
Tablo 5.17.	Prostat AFD tablosu (GAL)……	40
Tablo 5.18.	Prostat Gri tablosu (GAL)……..	40
Tablo 5.19.	Prostat 3 Gri tablosu (GAL)……...	41
Tablo 5.20.	Prostat SDD tablosu (GAL)……	41
Tablo 5.21.	Fantom AKD tablosu (Kohonen)……...	42
Tablo 5.22.	Fantom AFD tablosu (Kohonen)……	43
Tablo 5.23.	Fantom Gri tablosu (Kohonen)……..	43
Tablo 5.24.	Fantom 3 Gri tablosu (Kohonen)……...	43
Tablo 5.25.	Fantom SDD tablosu (Kohonen)……...	44
Tablo 5.26.	Meme AKD tablosu (Kohonen)…….	44
Tablo 5.27.	Meme AFD tablosu (Kohonen)…….	44
Tablo 5.28.	Meme Gri tablosu (Kohonen)……	45
Tablo 5.29.	Meme 3 Gri tablosu (Kohonen)…….	45
Tablo 5.30.	Meme SDD tablosu (Kohonen)…….	45
Tablo 5.31.	Meme AKD tablosu (Kohonen)…….	46
Tablo 5.32.	Karın AFD tablosu (Kohonen)……..	46
Tablo 5.33.	Karın Gri tablosu (Kohonen)…….	47
Tablo 5.34.	Karın 3 Gri tablosu (Kohonen)…….	47
Tablo 5.35.	Karın SDD tablosu (Kohonen)…….	47
Tablo 5.36.	Prostat AKD tablosu (Kohonen)……..	48
Tablo 5.37.	Prostat AFD tablosu (Kohonen)……	48
Tablo 5.38.	Prostat Gri tablosu (Kohonen)……..	49

Tablo 5.39. Prostat 3 Gri tablosu (Kohonen)……... 49
Tablo 5.40. Prostat SDD tablosu (Kohonen)…… 49
Tablo 5.41. Fantom AKD tablosu (DAYSA)……. 50
Tablo 5.42. Fantom AFD tablosu (DAYSA)…….. 51
Tablo 5.43. Fantom Gri tablosu (DAYSA)……. 52
Tablo 5.44. Fantom 3 Gri tablosu (DAYSA)…….. 52
Tablo 5.45. Fantom SDD tablosu (DAYSA)…….. 53
Tablo 5.46. Meme AKD tablosu (DAYSA)…… 54
Tablo 5.47. Meme AFD tablosu (DAYSA)……. 54
Tablo 5.48. Meme Gri tablosu (DAYSA)…… 55
Tablo 5.49. Meme 3 Gri tablosu (DAYSA)……. 55
Tablo 5.50. Meme SDD tablosu (DAYSA)……. 56
Tablo 5.51. Karın AKD tablosu (DAYSA)……. 56
Tablo 5.52. Karın AFD tablosu (DAYSA)……. 57
Tablo 5.53. Karın Gri tablosu (DAYSA)…… 57
Tablo 5.54. Karın 3 Gri tablosu (DAYSA)……. 57
Tablo 5.55. Karın SDD tablosu (DAYSA)……. 58
Tablo 5.56. Prostat AKD tablosu (DAYSA)…….. 58
Tablo 5.57. Prostat AFD tablosu (DAYSA)…….. 59
Tablo 5.58. Prostat Gri tablosu (DAYSA)……. 59
Tablo 5.59. Prostat 3 Gri tablosu (DAYSA)…….. 59
Tablo 5.60. Prostat SDD tablosu (DAYSA)…….. 60
Tablo 5.61. YSA'ların 2 sınıflı Fantom Görüntü için Performans Karşılaştırması..... 68

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1 : Tez içerisinde kullanılan fantom modeli ve görüntüsü …… 16
Şekil 3.1 : 3 Gri öznitelik değeri a) 1.öznitelik b)2. öznitelik c) 3. Öznitelik..... 19
Şekil 3.2 : Görüntü için aynalama işlemi (N1=4, N2=3)…….... 22
Şekil 3.3 : 30, 20, 10 ve 5 Hz frekans bileşenlerine sahip durağan olmayan bir işaret……. 25
Şekil 3.4 : Şekil 3.3'teki işaretin Sürekli Dalgacık Dönüşümü……. 25
Şekil 3.5 : SDD özniteliklerinin oluşturulması 26
Şekil 4.1 : GAL Ağının Yapısı…….. 28
Şekil 4.2 : GAL ağının iki boyutlu uzayda sınıfları birbirinden ayırması…. 30
Şekil 4.3 : Yapay olarak oluşturulmuş fantom görüntü..... 33
Şekil 4.4 : Eşik (Otomatik) = 109 için histogramdan seçilen 6 düğümün dağılımı..... 33
Şekil 4.5 : Eşik = 20 için histogramdan seçilen 80 düğümün dağılımı..... 34
Şekil 4.6 : Eşik = 10 için histogramdan seçilen 250 düğümün dağılımı..... 34
Şekil 5.1 : Orijinal fantom görüntüsü…..... 36
Şekil 5.2 : Fantom Eğitim Kümesi (GAL)……. 36
Şekil 5.3 : Fantom AKD Bölütlemesi (GAL)…… 36
Şekil 5.4 : Fantom AFD Bölütlemesi (GAL)..... 37
Şekil 5.5 : Fantom Gri Bölütlemesi GAL)..... 37
Şekil 5.6 : Fantom 3 Gri Bölütlemesi (GAL)……. 37
Şekil 5.7 : Fantom S.D.D. Bölütlemesi (GAL)…….. 38
Şekil 5.8 : Orijinal meme görüntüsü……..... 38
Şekil 5.9 : Meme Eğitim Kümesi (GAL)……..... 38
Şekil 5.10 : Meme AKD Bölütlemesi (GAL)…….. 38
Şekil 5.11 : Meme AFD bölütlemesi (GAL)…… 39
Şekil 5.12 : Meme Gri bölütlemesi (GAL)…….. 39
Şekil 5.13 : Meme 3 Gri bölütlemesi (GAL)…… 40
Şekil 5.14 : Meme S.D.D. bölütlemesi (GAL)……. 40
Şekil 5.15 : Orijinal karın görüntüsü…… 40
Şekil 5.16 : Karın Eğitim Kümesi (GAL)…… 40
Şekil 5.17 : Karın AKD bölütlemesi (GAL)…… 41
Şekil 5.18 : Karın AFD bölütlemesi (GAL)……. 41
Şekil 5.19 : Karın Gri bölütlemesi (GAL)…… 41
Şekil 5.20 : Karın 3 Gri bölütlemesi (GAL)……. 42
Şekil 5.21 : Karın SDD bölütlemesi (GAL)……. 42
Şekil 5.22 : Orijinal prostat görüntüsü……. 43
Şekil 5.23 : Prostat Eğitim Kümesi (GAL)…….. 43
Şekil 5.24 : Prostat AKD bölütlemesi (GAL)…….. 43
Şekil 5.25 : Prostat AFD bölütlemesi (GAL)……... 43

Şekil 5.26 : Prostat Gri bölütlemesi (GAL)…… 44
Şekil 5.27 : Prostat 3 Gri bölütlemesi (GAL)…….. 44
Şekil 5.28 : Prostat SDD bölütlemesi (GAL)…….. 44
Şekil 5.29 : Fantom AKD Bölütlemesi (Kohonen)…….. 45
Şekil 5.30 : Fantom AFD Bölütlemesi (Kohonen)……... 46
Şekil 5.31 : Fantom Gri Bölütlemesi (Kohonen)…… 46
Şekil 5.32 : Fantom 3 Gri Bölütlemesi (Kohonen)…….. 46
Şekil 5.33 : Fantom SDD Bölütlemesi (Kohonen)…….. 47
Şekil 5.34 : Meme AKD Bölütlemesi (Kohonen)…… 47
Şekil 5.35 : Meme AFD Bölütlemesi (Kohonen)……. 47
Şekil 5.36 : Meme Gri Bölütlemesi (Kohonen)…… 48
Şekil 5.37 : Meme 3 Gri Bölütlemesi (Kohonen)……. 48
Şekil 5.38 : Meme SDD Bölütlemesi (Kohonen)……. 48
Şekil 5.39 : Karın AKD Bölütlemesi (Kohonen)…… 49
Şekil 5.40 : Karın AFD Bölütlemesi (Kohonen)……. 49
Şekil 5.41 : Karın Gri Bölütlemesi (Kohonen)……. 50
Şekil 5.42 : Karın 3 Gri Bölütlemesi (Kohonen)…….. 50
Şekil 5.43 : Karın SDD Bölütlemesi (Kohonen)…….. 50
Şekil 5.44 : Prostat AKD Bölütlemesi (Kohonen)……... 51
Şekil 5.45 : Prostat AFD Bölütlemesi (Kohonen)…… 51
Şekil 5.46 : Prostat Gri Bölütlemesi (Kohonen)…….. 52
Şekil 5.47 : Prostat 3 Gri Bölütlemesi (Kohonen)…… 52
Şekil 5.48 : Prostat SDD Bölütlemesi (Kohonen)…… 52
Şekil 5.49 : Fantom AKD Bölütlemesi (DAYSA)…….. 53
Şekil 5.50 : Fantom AKD Histogram (DAYSA)…… 54
Şekil 5.51 : Fantom AFD Bölütlemesi (DAYSA)…….. 54
Şekil 5.52 : Fantom AFD Histogram (DAYSA)…… 54
Şekil 5.53 : Fantom Gri Bölütlemesi (DAYSA)……. 55
Şekil 5.54 : Fantom Gri Histogram (DAYSA)…… 55
Şekil 5.55 : Fantom 3 Gri Bölütlemesi (DAYSA)…….. 55
Şekil 5.56 : Fantom 3 Gri Histogram (DAYSA)…… 56
Şekil 5.57 : Fantom SDD Bölütlemesi (DAYSA)…….. 56
Şekil 5.58 : Fantom SDD Histogram (DAYSA)…… 56
Şekil 5.59 : Meme AKD Bölütlemesi (DAYSA)…… 57
Şekil 5.60 : Meme AKD Histogram (DAYSA)…….. 57
Şekil 5.61 : Meme AFD Bölütlemesi (DAYSA)…… 57
Şekil 5.62 : Meme Gri Bölütlemesi (DAYSA)…… 58
Şekil 5.63 : Meme 3 Gri Bölütlemesi (DAYSA)…… 58
Şekil 5.64 : Meme SDD Bölütlemesi (DAYSA)…… 59
Şekil 5.65 : Karın AKD Bölütlemesi (DAYSA)…… 59
Şekil 5.66 : Karın AFD Bölütlemesi (DAYSA)…….. 60
Şekil 5.67 : Karın Gri Bölütlemesi (DAYSA)……. 60
Şekil 5.68 : Karın 3 Gri Bölütlemesi (DAYSA)…….. 60
Şekil 5.69 : Karın SDD Bölütlemesi (DAYSA)……... 61
Şekil 5.70 : Prostat AKD Bölütlemesi (DAYSA)…… 61
Şekil 5.71 : Prostat AFD Bölütlemesi (DAYSA)……. 62
Şekil 5.72 : Prostat Gri Bölütlemesi (DAYSA)……. 62
Şekil 5.73 : Prostat 3 Gri Bölütlemesi (DAYSA)……. 62
Şekil 5.74 : Prostat SDD Bölütlemesi (DAYSA)……. 63
Şekil 5.75 : 3 Bölgeli Bölütleme Sonucu…… 64

Şekil 5.76 : 2 Sınıflı Birleştirme Sonucu 64
Şekil 5.77 : Performans Analizi için seçilen Test kümesi 67
Şekil 5.78 : GAL Ağı ile bölütleme (solda) ve test kümeli sınıflama sonucu. 68
Şekil 5.79 : KOHONEN Ağı ile bölütleme (solda) ve test kümeli sınıflama sonucu 68
Şekil 5.80 : DAYSA ile bölütleme (solda) ve test kümeli sınıflama sonucu .. 68

SEMBOL LİSTESİ

t	**:** Zaman
f	**:** Frekans
π	**:** Pi sabiti
$x(t)$	**:** Tek boyutlu sürekli işaret
$X(f)$	**:** Tek boyutlu Fourier Dönüşümü alınmış işaret
$x(n_1)$	**:** Tek boyutta Ters Ayrık Fourier Dönüşümü alınmış işaret
$X(k_1)$	**:** Tek boyutlu Ayrık Fourier Dönüşümü alınmış işaret
$X(k_1,k_2)$	**:** İki boyutlu Ayrık Fourier Dönüşümü alınmış işaret
$x(n_1,n_2)$	**:** İki boyutlu Ters Ayrık Fourier Dönüşümü alınmış işaret
$f(x)$	**:** Tek boyutlu işaret
$f(x,y)$	**:** İki boyutlu işaret
$C(u)$	**:** Tek boyutlu Ayrık Kosinüs Dönüşümü alınmış işaret
$C(u,v)$	**:** İki boyutlu Ayrık Kosinüs Dönüşümü alınmış işaret
N, M	**:** Dönüşümlerde kullanılan işaret ve pencere boyutları
n, k	**:** Dönüşüm sabitleri
$\alpha(u)$	**:** Kosinüs dönüşümde kullanılan bir fonksiyon
τ	**:** Zamanda öteleme
ψ	**:** Dönüşüm (pencere) fonksiyonu
s	**:** Ölçek parametresi
Dj	**:** Giriş vektörü ile j'inci ağ düğümü arasındaki Öklit mesafesi
Cc	**:** Sınıf katmanı
x_i	**:** Giriş vektör elemanları
wj	**:** j'inci düğüm
Ee	**:** 0 ya da 1 değeri alan, ağın birinci katmanının çıkışı.
T	**:** Bağlantı katsayısı
d	**:** Öklit mesafesi
η	**:** Kazanç sabiti

YAPAY SİNİR AĞLARI KULLANARAK ULTRASONİK GÖRÜNTÜLERDE DOKULARIN BÖLÜTLENMESİ

ÖZET

Yapılan çalışmada, ilk olarak literatürde yer alan, konuya ilişkin makaleler incelenmiş, bölütleme için hangi tür ağların ve özniteliklerin kullanıldığı ve kullanılan yöntemlerin başarımı araştırılmıştır. Ayrıca, günümüz tıp dünyasında konuyla ilgili yeni ihtiyaçların var olup olmadığı, varsa bunların neler olduğunun belirlenmesi adına, radyoloji uzmanları ile görüşmeler yapılmıştır.

Bütün bu ön hazırlık sürecinin ardından, algoritmalar arasında karşılaştırma yapılabilmesi için, ultrasonik görüntülerin bölütlenmesi 3 farklı Yapay Sinir Ağı (YSA) ile gerçekleştirilmiştir. Bu ağlar, GAL (Büyü ve Öğren), Kohonen ve DAYSA'dır (Denetimsiz Artımsal Yapay Sinir Ağı).

Görüntüyü bölütlemek için kullanılan öznitelikler ise, görüntünün frekans özelliklerini kullanan AKD (Ayrık Kosinüs Dönüşümü) ve AFD (Ayrık Fourier Dönüşümü), zaman-frekans özelliklerini kullanan SDD (Sürekli Dalgacık Dönüşümü) ile, görüntünün gri seviyelerini referans alan Gri seviyeleri ve Üç-gri (3G) değeridir.

Tez çalışması boyunca, bu 3 adet ağın algoritmaları yazılmıştır ve bulunan sonuçlar kullanılan parametreler cinsinden yorumlanmıştır.

Sonuç olarak DAYSA'nın en önemli problemi olan eşik belirleme sorunu, yazılan bir eşik fonksiyonu ile ultrasonik görüntüler için giderilmiştir. Eşik fonksiyonu, kullanılan özniteliklere, öznitelik sayısına ve öznitelik uzayında vektörlerin dağılımına bağlı olarak, uygun bir eşik üretmede oldukça başarılıdır.

Görüntü bölütlemesinde, dokular birbirlerine olan benzerliklerine göre interpolasyon kullanılarak renklendirilmiş ve böylelikle, yalnız farklı dokuların gösterilmesi değil, dokuların birbirlerine yakınlığının da görsel olarak ifade edilebilmesi mümkün olmuştur.

Tez içerisindeki algoritmalar mümkün olduğunca esnek hazırlanmıştır. Kullanıcıya, algoritmanın türüne göre kullanılan farklı parametreleri değiştirme imkânı sunulmuştur. Böylelikle farklı parametrelerin sonuçta oluşan görüntüye yansımaları kolaylıkla değerlendirilebilmektedir. Ancak algoritmaların bu kadar esnek olması, bazı parametreler için algoritmaların sonuçlanma süresini de bir miktar uzatmaktadır. Dolayısıyla, bazı parametrelerin sabitlenmesi durumunda algoritma süreleri biraz daha kısalmaktadır.

Bölütleme sonuçları uzman bir radyoloji uzmanı tarafından değerlendirilmiş ve çalışmanın teşhise yardımcı olacak ipuçları verdiği görülmüştür. Kullanılan ağlar eğitilirken, algoritmalara farklı doku türleri ve ultrasonik ekipmanların özellikleri için bir ön parametre yüklemesi yapılırsa, doktorlara kesinlikle yardımcı olabilecek şekilde önemli bir gelişme sağlanacağı düşünülmektedir.

SEGMENTATION OF ULTRASOUND IMAGES BY USING ARTIFICIAL NEURAL NETWORKS

SUMMARY

In this study, first of all, the articles in the literature related to subject have been examined and the neural networks and features which were used for segmenation and their performance have been analysed. Furthermore, in order to determine the latest needs of medicine in this field, interviews with radiologists have been done.

At the end of this preparation, 3 Artificial Neural Networks have been used for comparison of segmentation results between the networks. These netwoks are called GAL (Grow and Learn), Kohonen and DAYSA (Incremental Self Organised Artificial Neural Network).

The features which were used to segment the biomedical images are: DCT (Discrete Cosine Transform) and DFT (Discrete Fourier Transform) which are using frequency properties of the images, CWT (Continuous Wavelet Transform) which uses time-frequency properties and Gray Levels & Three-Gray values which take the gray value properties as reference.

During thesis studies, algorithms of these 3 networks have been written and the obtained results have been interpretated according to the parameters used.

In conclusion, the most important problem of DAYSA, decision of threshold value, was solved by writing a simple threshold function for ultrasound images. This function can produce a proper threshold value depending on features, feauture number and distribution of feature vectors in feature space.

In image segmentation, tissues have been colored according to their similarities to eachother by using interpolation. In this way, not only the the different tissues have been showed but also the vicinity of the tissues.

The algorithms in thesis have been prepared as flexible as possible. Depending on the type of the algorithm used, opportunity of modifying different parameters had been provided for the user. In this way, the effects of different parameters to the segmentation results can be possible. However, the flexibility of the algorithms extends the segmentation time. Therefore, if some parameters would be constant, the segmentation time becomes shorter.

Segmentation results were examined by a radiologist and obtained results were seemed to have signs to help diagnosis. It is considered that, if pre-parameter loading to the algorithms for different tissue types and ultrasound equipments can be done during training step of networks, there could be a significant development in the obtained results which the operators can use for diagnosis absolutely.

1. GİRİŞ VE ÇALIŞMANIN AMACI

Günümüzde elektronik ve bilgisayar alanındaki hızlı gelişmeler, tıp dünyasını da doğrudan etkilemekte, insan sağlığını ilgilendiren yeni tekniklere ve uygulamalara vesile olmaktadır. Doktorlara teşhis ve tedavide yardımcı araçlar sunulabilmekte [1-3], böylece insan sağlığı gibi kritik bir alanda, en etkili ve en az hata ile çalışılması sağlanmaktadır.

Yıllar içerisinde yapılan araştırmalarla sürekli geliştirilen ultrasonografi, insan sağlığına zararlı olmaması, kolay uygulanabilirliği ve ucuz bir yöntem olması bakımından günümüzde hâlâ geçerliliğini koruyan etkin bir teşhis aracıdır. Bununla birlikte teşhisin, tekniğin bünyesinde barındırdığı gürültüler nedeniyle operatöre oldukça bağımlı olması, bu tekniğin dezavantajı olarak değerlendirilmektedir.

Tez çalışmasında, ultrasonografi alanında otomatik doku bölütlemesini gerçekleştirmek, böylelikle özellikle tecrübesiz operatörler için kullanışlı olabilecek yardımcı bir teşhis yöntemi hazırlanması amaçlanmıştır. Bu amaçla, öncelikle ultrasonografi alanında çalışan doktorlar ile görüşülmüş [4], otomatik doku bölütlemesi konusundaki fikirleri ve beklentileri belirlenmiştir. Bu sürecin ardından yapılan çalışmalarda, ultrasonografi alanında literatürde yer alan geçmiş tecrübelerden yararlanılarak, doktorların hastalık teşhisinde tercih edebileceği görüntü özellikleri ve sınıflama yöntemleri anlatılmış, elde edilen tecrübeler ve Matlab yazılımı aracılığıyla bulunan sonuçlar yorumlanmıştır.

Otomatik doku bölütlemesine geçmeden önce, dokunun tanımını yapmak uygun olacaktır. Gool ve arkadaşları [5], dokuyu: "Birbirine az ya da çok benzeyen eleman veya örüntülerin belli bir düzende bir araya gelmesinden oluşan yapı" şeklinde tanımlamışlardır. Dokular, yapısal dokular ve istatistiksel dokular olmak üzere iki ana gruba ayrılmaktadır. Yapısal bir dokuda, ana örüntü ve alt örüntüler çeşitli yerleşim kurallarına göre uzaysal bir dağılıma sahiptir. İstatistiksel doku ise, istatistiksel modellerle tanımlanabilen karmaşık bir örüntü dağılımına sahiptir. Ultrasonik (US) görüntüler, istatistiksel dokulara örnek olarak gösterilmektedir. Bu şekilde tanımlanan dokuları bölütlemek için literatürde çok sayıda çalışma

mevcuttur. Biyomedikal görüntülerde bölütleme, Kapur [6] tarafından: "Biyomedikal görüntüdeki anatomik yapıyı belirlemek amacıyla, görüntüdeki her bir benek için bir etiket verme işlemi" olarak tanımlanmıştır.

1.1 Önişleme

US görüntülerde beneklenme (speckle) gürültünün en önemli parçasını oluşturur ve teşhis için gerekli bilgi kaybedilmeden bunun giderilmesi gerekir. Bu iş için geliştirilen teknikler üç ana gruba ayrılmaktadır.

1. 3x3, 5x5 veya daha geniş boyutta kayan pencereler kullanılarak yapılan, görüntü komşuluğunun istatistiksel özelliklerini kullanan teknikler: Bunlar da kendi içinde üçe ayrılmaktadır:
- Komşuluktaki 1. moment (ortalama) ve 2. moment (varyans) gibi istatistiksel bilgileri kullanan teknikler,
- Komşuluktaki daha yüksek dereceden (3. ve 4. moment) istatistiksel bilgileri kullanan teknikler,
- Lineer olmayan iteratif algoritmalar olan geometrik teknikler.

2. Frekans spektrumunu kullanan teknikler: Beneklenme gideriminde, görüntü iyileştirmede ve restorasyonunda yararlı bulunmadığı kanıtlanmıştır.

3. Değişik uzaysal pozisyonlardan elde edilen korele olmayan görüntülerin ortalamasının alındığı, hesap yükü çok fazla olan teknikler.

Literatürdeki çalışmaların çoğunun belirli sınırlamaları vardır:

a) Kullanılan pencere boyutu ve şekline duyarlıdırlar. Pencere boyutu ve şekline bağlı olarak, anlamlı bilginin kaybedilmesi veya gürültünün giderilememe durumu oluşmaktadır.

b) Kenarları iyileştirmemekte, sadece kenarların yakınlarında yumuşatmayı engellemektedirler. Filtrelemenin getirdiği yumuşatma (alçak geçiren süzgeç) etkisinden kenarları korumalarına karşın, kenarları daha belirgin hale getirememektedirler.

c) Yönlü değillerdir, bir kenarın varlığında yumuşatma işlemi tamamen saf dışı bırakılmaktadır.

d) Pencere tabanlı yaklaşımlarda filtreleme için kullanılan eşikler gürültüyü gidermek için yeterli değildir. [7,8].

Loizou ve arkadaşları [9], bu sınırlamaları dikkate alan beneklenme giderme filtreleri hazırlamışlardır. Stippel ve arkadaşları [10] da, beneklenmenin morfolojik özelliklerini ve değişik dokulardaki değişik beneklenme istatistiklerine dair önbilgiyi göz önüne alan yeni bir beneklenme yok etme tekniği tanıtmışlardır. Teknik, leukomalacia tarafından etkilenen (düşük kiloda (<1.5 kg) doğan bebeklerin %20 - %50'sinde görülmektedir) neonatal beyin görüntülerine uygulanmış ve bir uzman bölütlemesine yakın bir sonuç elde edilmiştir. Donnell ve arkadaşları [11], ses hızı değişiminin görüntü kalitesindeki etkisini azaltmak üzere, 2D (2 boyutlu) anizotropik ışınlar için faz kayması düzeltme teknikleri geliştirmişlerdir. Sonuç olarak, faz kayması düzeltme teknikleri ile görüntü üzerinde büyük bir iyileştirme sağlanabileceği görülmüştür.

1.2. Öznitelik Çıkartma

Öznitelikler, dokunun kendine özgü belirli parametrelerini temsil eden değerlerdir. Bu değerlerin bir araya gelmesiyle öznitelik vektörleri yapılandırılmakta ve bölütlemede kullanılmaktadır. Literatürde çok sayıda öznitelik çıkartma yöntemi mevcuttur. Ancak, her görüntü için geçerli olan bir teknik bulunmamaktadır. İstatistiksel metotlar, dokuyu gri seviye değerlerinin istatistiği ile karakterize etmektedir. Bu metot, rastgele görünen dokularda göreceli olarak iyi sonuç verse bile, geniş boyutlu ve fazla yapılı dokularda uygun değildir. Yapısal metotlar, dokuların, ilksellerin (primitive) belirli kurallara göre yerleştirilmesiyle üretildiğini varsayar ve bu bakımdan yapısal görüntülerde kullanılmaya elverişlidirler. Doğal dokular ise hem yapısal hem de istatistiksel özellikler içerirler. Wold doku modeline göre dokulu örüntü, deterministik ve deterministik olmayan iki ana homojen rastgele alandan oluşmaktadır. İki alan da değişik tipte modellerle temsil edilebilir. Gabor modeli tabanlı çok-kanallı model, deterministik alanları göstermede etkiliyken, Gauss Markov rastgele alan modeli, deterministik olmayan alanlarda başarılıdır [12,13]. En sık kullanılan öznitelikler; otokorelasyon katsayıları [14], görüntünün gri seviyelerini temel alan yaklaşımlar [9,15,16], varoluş matrisleri [17-19], dalgacık dönüşümü katsayıları [20], ayrık kosinüs [21] ve ayrık fourier dönüşümünden [22] elde edilen katsayılardır. Bununla birlikte, tümör daireselliği, alan oranı, sıfır geçiş

sayısı, sınır pürüzlülüğü [23], ve trace dönüşümünden [18] elde edilen öznitelikler de çeşitli görüntülere uygulanmıştır. Görüntü işleme uygulamalarının temel sorunu, öznitelik çokluğu ve pozisyon, yönelme ve ölçekleme değişimleri ile baş edememe olarak ifade edilmektedir. Bu yüzden daha akıllı, değişmeyen öznitelik çıkartma ve öznitelik seçme yöntemlerine ihtiyaç vardır. Bu amaçla ön bilgi veya beklenen görüntü içeriği gibi parametrelerin kullanımının bu ihtiyaca cevap vereceği düşünülmektedir [24].

1.3 Öznitelik Seçme

Öznitelik uzayının boyutu hesap yükü ile doğrudan ilişkili olduğundan, öznitelik seçme algoritmaları ile bu boyutun küçültülmesi istenir. Bazı aday öznitelikler ilgisiz (yararlı bilgiye gürültü ekleyebilir) veya diğer özniteliklerin olduğu durumlarda gereksiz olabilirler. Öznitelik seçme işlemi, doku bölütleme hedefine yönelik olarak ilgili özniteliklerin alınmasını sağlamaktadır. Genelde boyut azaltma için başlıca bileşen analizi (PCA) ve Fischer Lineer Ayrıştırma analizi (LDA) kullanılmaktadır. Bhalero ve arkadaşları [25], öznitelik seçimi için, tam wavelet paket ayrıştırması (FWP) ve Gabor tipi ayrıştırma adı verilen iki alt-bant filtreleme tekniği göstermişlerdir. Alt-bant özniteliği ile ilişkili olan bedel fonksiyonunun değeri, o alt-bandın ilgililik ölçüsü olarak değerlendirilmektedir ve öznitelikleri ilgililik ölçülerine göre sıralayan hızlı öznitelik seçme algoritmasında kullanılmaktadır. Chou ve arkadaşları [23] da, katı meme tümörlerinin US diferansiyel teşhisini yaptıkları çalışmada, öznitelik seçimi için stepwise analiz yöntemini kullanmışlardır.

Öznitelik azaltmak haricinde, algoritmaların hızlandırılması için, eğitimde kullanılacak örneklerin de azaltılması istenir. Chen ve arkadaşları [26], US teknolojinin katı meme tümörlerindeki teşhis yeteneğini arttırmak amacıyla yaptıkları çalışmada önyükleme (bootstrap) tekniğini kullanmışlar ve örnek sayısı arttığında bu tekniğin önemli bir performans artışı sergilediğini göstermişlerdir.

1.4. Bölütleme

US görüntülerde bölütleme, medikal görüntü analizinde kritik bir konudur. Bunun için aktif çizgiler (active contours) ve bölge büyütme, kullanılan iki ana yaklaşımdır. Aktif çizgi metodu, gri seviyesi ya da başka özellikleri çevre bölgesinden belirgin bir

biçimde farklı olan bölgeler için uygundur. Ne yazık ki US görüntüler her zaman güçlü bir beneklenme gürültüsü ve zayıflama bozulmasıyla karşı karşıyadır. Hao ve arkadaşları [16], çalışmalarında yeni bir bölge büyütme metodu göstermişlerdir. Bölge büyütme, çok öznitelikli vektör uzayında gerçekleştirilmiştir. Bölge büyütmesi için üç yeni kriter geliştirilmiştir. İlk olarak, geleneksel bölge büyütme algoritmalarında kullanılan yerel bilgi değil de genel bilgi kullanılmaktadır. İkinci olarak, beneklenme gürültüsü ve zayıflama bozulmalarını gidermek için coğrafi benzerlik diye bir düşünce ortaya atılmıştır. Üçüncü olarak da, sonuçların işlem sırasından bağımsız olmasına olanak tanıyan, eşit fırsatlı yarışma kriteri kullanılmıştır. Sonuçlar verimli ve güvenilir bulunmuştur.

Geleneksel kenar-tabanlı bölütleme metotları, cisim sınırlarını bulmada genellikle gradyanı (görüntü şiddetinin değişimi) kullanmaktadırlar. Bu yöntemler, görüntü şiddetinin süreksizliğini algılamak için tasarlanmamışlardır. Bu yüzden de US görüntülerde iyi sonuç vermezler. Ayır-ve-birleştir, bölge büyütme ve watershed dönüşümü gibi bölge-tabanlı yöntemler, görüntüdeki gürültü ve karşıtlığa (contrast) duyarlıdır. Değişik yaklaşımlarla watershed'in performansını iyileştiren önişleme teknikleri önerilmiştir. Bununla beraber, US görüntülerindeki dokular aşırı değişkenlik ve sınır süreksizliği gösterdiğinden, cisim sınırlarını hassas bir şekilde bulmakta zorluk çıkarmaktadırlar. Huang ve Lin [27], uyguladıkları teknikte, US görüntülerdeki meme tümörünün sınırlarını çıkarmak için yapay sinir ağı (YSA) sınıflaması ve watershed bölütleme tekniklerinin avantajlarını birleştirmişlerdir.

Chang ve arkadaşları [8], 3 boyutlu yılan (snake) tekniği ile 3D US görüntülerde mammotome kullanılarak yapılan operasyon öncesi ve sonrası tümör çizgilerinin elde edilmesini sağlamaya çalışmışlardır. Bu teknik doktora, cerrahi müdahalenin etkisini değerlendirme olanağı vermektedir. Kenar iyileştirmesi için stick (çubuk) deteksiyonu kullanılmıştır. Değişik yönlerde kısa çizgi kesitlerinden oluşan çubuk, yerel olarak sınırlara yaklaşır ve beneklenmeyi gidererek kenar bilgisini iyileştirir. Ardından ikili görüntü elde etmek için otomatik eşik metodu uygulanır. Son olarak gradyan vektör akış (GVF) yılanı tümör çizgisini elde etmek için kullanılır. Bu teknikler 3D'ye genişletilerek bölütleme sonuçlarının doğruluğunu ve gürbüzlüğünü (robustness) arttırır. Böylelikle meme tümörü için minimal invasive (asgari direkt) operasyonun geliştirilmesine yardımcı olunması amaçlanmıştır.

Won ve arkadaşları [28], dokunun bloklarla ilişkili olan birçok durumun karışımı olduğunu varsayarak, blok tabanlı bölütlemede global ve yerel istatistiklerin modellenmesinin performansını araştırmışlardır. Geleneksel dalgacık dönüşümünün yerine Gizli Markov ve Kompleks Gizli Markov Ağacı modellerinden türetilen dual-tree kompleks dalgacık dönüşümü (DTCWT) kullanmışlardır. Kompleks dalgacıkların kayma-değişmez özelliği yerel bağımlılık modelini daha dayanıklı kılmaktadır. Ayrıca maksimum olasılık (maximum likelihood) bölütlemesinde, farklı çözünürlüklerde eş zamanlı olarak kullanılabilecek ağaçyapılı olasılık elde etmek için bir algoritma geliştirilmiştir. Bu hızlı algoritma, benek-seviyesinde sonuç bölütleme elde etmek için çok çözünürlüklü birleşme algoritmasının girişleri olarak kullanılabilecek işlenmemiş bölütleme sonuçları sağlar. Birkaç Brodatz dokusu için diğer algoritmalarla yapılan deneysel performans karşılaştırması bu tekniğin özellikle küçük blok boyutlarında daha iyi sonuç verdiğini göstermiştir. Hazırlanan tekniğin bir kusuru, eğitim dokularının ayrı kümelerine ihtiyaç duymasıdır.

Keysers ve arkadaşları [29], içerik tabanlı görüntü elde edilmesi (IRMA) işlemi adımlarına değindikleri çalışmalarında, Kernel sınıflayıcısı ile TD'ye (tanjant mesafesi) bakılarak sınıflama yapmışlar ve ve bunu Euclid ve Mahalanobis mesafesi ile karşılaştırmışlardır.

Chou ve arkadaşları [23], katı meme tümörlerinin US diferansiyel teşhisini yapmak amacıyla SLR (Stepwise logistic regression) analizini kullanmışlardır. Analizden önce, radyoloji uzmanları el yordamıyla tümörleri belirlemişlerdir. Katı meme tümörlerini ayırt etmede yüksek başarımı yeteneğiyle bu modelin, deneyimsiz operatörlerin yanlış teşhis yapmasını engelleyeceği öngörülmüştür. SLR modeli eğitilebilir olduğundan, daha geniş tümör kümeleri sağlanarak optimize edilebilmektedir.

Kotropoulos ve Pitas [30] çalışmalarında, yaygın olarak kullanılan, istatistiksel öğrenme teorisinin garantili risk sınırlarına dayalı genel bir algoritması olan destek vektör makinelerinin (support vector machines , SVM) US görüntülerin lezyonlarının bölütlemesinde kullanımını ve lezyon algılama yeteneklerinin değerlendirilmesini amaçlamışlardır. Eğitilen SVM'lerin radyal tabanlı fonksiyon çekirdeği (RBF) ile US görüntüleri tatmin edici bir şekilde bölütleyebildiği ortaya konulmuştur.

Huang ve Liu [31] da, katı meme tümörlerinin teşhisinde, eğitiminin çok hızlı ve kararlı olması nedeniyle SVM'leri kullanmışlardır. Önerdikleri SVM sistemininin

eğitim ve teşhis prosedürünün çok katmanlı sinir ağlarına nazaran neredeyse 700 kat daha hızlı olduğunu belirtmişlerdir. Gösterilen yöntemin, yüksek doğrulukta tümörleri ayırt etme yeteneğiyle, deneyimsiz doktorları yanlış teşhis yapma riskinden kurtardığı ifade edilmektedir.

Chang ve arkadaşları [32], ultrasonografi için yüksek hassasiyetli bilgisayar destekli teşhis (CAD) sistemi önerdikleri çalışmalarında, meme tümörlerini doku bilgisine bağlı olarak sınıflandırmak için SVM kullanmışlardır.

Petersen ve arkadaşları [24], görüntü işleme konularında (sıkıştırma, iyileştirme, bölütleme) hangi tip YSA'ların seçilmesi gerektiğine dair yaptıkları çalışmada, YSA'ların görüntü işlemedeki 200'den fazla uygulamasını incelemişlerdir. Algoritma tarafından yapılan görevin (ön işleme, veri azaltma…vb.) ve bu görevi yaparken kullanılan giriş bilgisinin (benek özelliği, yapı özelliği, nesne özelliği…vb.) oluşturduğu iki boyutlu bir sınıflama yapmışlardır. Sonuç olarak günümüzde YSA'ların, herhangi bir sınıflamada her zaman en iyi çözümü veremediğini, uyarlamalı yaklaşım veya hızlı, paralel çözümler gerektiğinde ilginç sonuçlar verebildiklerini, ancak SVM gibi yeni gelişmelere açık olmak gerektiğini belirtmişlerdir. YSA'ların büyük, uyarlamalı sistemlerde birlikte çalışan modüllerin yapı blokları olarak kullanılmasının doğru bir tercih olacağını, ayrıca YSA'ların yapıları itibariyle, değişken çevrelerde kullanılmaya elverişli olduklarını ifade etmişlerdir.

Wu ve arkadaşları [33], geleneksek K-NN sınıflayıcıların hesap yükü çok fazla olduğu için, bu olumsuzluğu gidermek üzere bu sınıflayıcıya template condensing (şablon yoğunlaşması) ve önişleme tekniklerini dahil ederek, sınıflama hızını arttırırken, başarımdan ödün vermeyen bir sınıflama tekniği geliştirmişlerdir. Şablon yoğunlaşması ile, bir sınıfa ait yoğun homojen örnekleri seyreltmek amaçlanmıştır. Bu da, yüksek çekim kapasitesine sahip örüntüleri iteratif bir şekilde eleyerek gerçekleştirilmiştir. Önişleme tekniği, bilinmeyen örüntüyle uyuşmayan prototiplerin büyük bölümünü filtrelemektedir. Bu da, özellikle öznitelik uzayının geniş boyutlu olduğu durumlarda, sınıflandırma işlemini hızlandırmaktadır. Örnek bir çalışmada bu iki tekniğin eklenmesiyle 7 katlık bir hızlanma sağlanmıştır.

Bautista ve Lambino [17] kereste dokularını sınıflandırdıkları çalışmalarında, sınıflayıcı olarak LVQ (Learning Vector Quantization) ağı kullanmışlardır ve başarılı sonuçlara ulaşmışlardır.

Scheipers ve arkadaşları [34], prostat kanserinde, ultrason ile tümörün erken safhada algılanmasına olanak sağlamak amacıyla yaptıkları çalışmada paralel çalışan iki bulanık çıkarım sistemi kullanmışlardır.

Pavlopoulos ve arkadaşları [15], karaciğer görüntülerinde uyguladıkları yeni bir bulanık sinir ağı sınıflayıcısının verimini araştırmışlar ve elde ettikleri sonuçlar, önerdikleri yöntemin verimli olduğunu göstermiştir.

Tao ve arkadaşları [22], doku sınıflandırması için Hamming mesafesi tabanlı YSA kullanmışlardır. Önerilen metot, hem istatistiksel hem de yapısal dokuları içeren 96 görüntüden oluşan Brodatz veri tabanına uygulanmış ve test edilmiştir. Sonuçta, sınıflayıcı olarak Hamming tabanlı sinir ağının uygun bir yapıda olmadığı görülmüştür.

Chen ve Arkadaşları [14], çalışmalarında SOM ağının sonografik meme lezyonlarındaki habis ve iyi huylu tümörleri teşhis yeteneğini değerlendirmeyi amaçlamışlardır.

Fernandes ve arkadaşları [35], fetal ekokardiyografi görüntülerinin bölütlenmesi için yeni bir yaklaşım tanıtmaktadırlar. Bu metot, SOM ve LEGION sinir ağlarını kullanmaktadır. SOM ile elde edilen öbekler K-ortalamalar algoritması ile işlenip, ardından LEGION ağı ile kalp yapısının ölçülmesinde kullanılacak ikili (binary) görüntü oluşturulmaktadır.

Kurnaz ve arkadaşları [36], çalışmalarında kullandıkları ISOM ağıyla US görüntüleri bölütlemişler ve bu tekniğin Kohonen ağından [37] daha üstün olduğunu ortaya koymuşlardır.

Ölmez ve Dokur [38], geliştirdikleri DAYSA ile US görüntüleri bölütlemişler ve bu tekniğin üstünlüğünü diğer ağlarla karşılaştırarak göstermişlerdir.

2. ULTRASONİK GÖRÜNTÜLEME TEKNİKLERİ

2.1. Ultrasonik Görüntülerin Tıp Dünyası'ndaki Yeri

İkinci Dünya Savaşı sırasında denizaltıların yerinin belirlenmesi amacıyla kullanılan sonarların temelini teşkil eden ultrason dalgaları, sonradan demiryolu raylarındaki çatlakları belirlemek maksadıyla kullanılmış, bir süre sonra tıpta da kullanılmaya başlanmış ve geniş bir uygulama alanı bulmuştur. Bunlar;

a. Fizik tedavide düşük frekanslı ses dalgaları aracılığıyla dokunun ısıtılması,
b. Soğuk buhar üretimi (nebülizatör),
c. Tıbbi cihazların suyu titreştirmek suretiyle mikro seviyede temizliği,
d. Teşhis amaçlı görüntüleme olarak özetlenebilir.

Teşhis amaçlı görüntülemede kullanılan ultrasonografinin hızla gelişimi 1970'li yıllardan sonra başlamıştır [39].

US görüntüleme, iyonlaşmayan doğası nedeniyle, hasta ve doktor açısından risk faktörünü en aza indirgeyebilen, akustik görüntülemenin benzersiz özelliklerinden dolayı da diğer teşhis yöntemlerini tamamlayabilen bir yapıda olduğundan, medikal görüntülemede önemli bir yere sahiptir. Pulse-echo (Darbe-yansımalı) US sistemler, karın, kalp, karaciğer, prostat, göğüs, göz…vb. organların kesit görüntülerini elde etmek için rutin olarak kullanılmaktadır ve anne karnındaki çocuğun (fetus) görüntülenmesi için uluslararası bir standart haline gelmiştir. Ultrasonografiyi avantajlı kılan özellikler, kanıtlanmış klinik yararının yanı sıra, gerçek zamanlı çalışması, güvenli oluşu, kolay kullanımı ve ekonomik sistemlerin olanaklı olmasıdır. Bu alandaki ilerlemeler (gelişmiş US ışınlar ve dijital işleme, prob küçülmesi, görüntü iyileştirmesi, yüksek frekans dönüştürücüleri (çözünürlüğü arttırmaktadır)), gelişmiş işaret-görüntü oranı ve örüntü tanıma tekniklerine ek olarak, bu yöntemin teşhis potansiyelini arttırmaktadır. Ayrıca 2 boyutlu US görüntülemeden 3 boyutlu US görüntülemeye geçiş de bu yöntemin medikal klinik uygulamalarında daha geniş olarak kullanılmasına katkıda bulunmuştur [40].

2.2. Ultrasonik görüntülerin oluşumu

Ultrasonun temelini darbe-yansıma (pulse-echo) prensibi oluşturmaktadır [39]. Vücutla temas halindeki prob (dönüştürücü) vasıtasıyla üretilen ultrason dalgaları, incelenmek istenen anatomik yapıdan yansıyarak geri dönerler. Yansıyan ekolar yine aynı prob vasıtasıyla geri alınır ve işlendikten sonra ekranda görüntülenir. Bu görüntüler yardımıyla doktor vücudun iç yapısında oluşan tümör, kist gibi anormal yapıları da görebilmektedir.

Dokularda sesin yayılma hızı, dokunun iki parametresine bağlıdır. Bunlardan birincisi dokunun sertliği, ikincisi ise dokunun kütle yoğunluğudur. Tablo 2.1'de ultrasonun yumuşak dokulardaki yayılma hızları gösterilmiştir [41].

Tablo 2.1 - Yumuşak Dokularda Ultrasonun Yayılma Hızı

Doku	Yayılma Hızı (mm/μs)
Yağ	1.44
Beyin	1.51
Karaciğer	1.56
Böbrek	1.56
Kas	1.57
Yumuşak Doku Ortalaması	1.54

Ultrason demeti dokulardan geçerken gücünde zayıflama olmaktadır. Ultrason dalgalarının yoğunluğunun azalmasına ve enerjisinin bir kısmını kaybetmesine yol açan zayıflamaya (attenuation) üç temel etken yol açmaktadır. Bunlardan birincisi soğurma (absorption)'dır. Dokudan geçen ultrasonun enerjisinin bir kısmı doku tarafından soğurulmakta ve soğurulan enerji ısı olarak ortaya çıkmaktadır.

Zayıflamaya yol açan ikinci etmen saçılmadır. Saçılma sonucunda birim alandan geçen enerji miktarı azalmaktadır. Zayıflamaya neden olan üçüncü faktör, ultrason demetinin belirli bir mesafeden sonra genişleyerek yayılmasıdır. Enerji yoğunluğu kesit alanıyla ters orantılıdır. Demet genişlediğinde kesit alanı arttığından, dokudan geçen enerji yoğunluğu da buna bağlı olarak azalmaktadır.

Doku kalınlığı ve frekans arttıkça, zayıflama da artmaktadır. Düşük frekanstaki ultrason dalgaları daha derindeki dokulara nüfuz edebilirler [39]. Tablo 2.2'de iki farklı frekanslar için farklı dokulardaki zayıflama katsayıları görülmektedir [41].

Tablo 2.2 – Dokularda Zayıflama Katsayıları

	Zayıflama Katsayısı (dB/cm)	
Doku	1 MHz	10 MHz
Yağ	0.6	7.6
Beyin	0.6	8.4
Karaciğer	0.7	9.4
Böbrek	0.9	10.7
Kas	1.0	12.6
Kalp	1.1	13.3
Yumuşak Doku Ortalaması *	0.8	10.1
* Yağ, karaciğer, böbrek, kas		

2.3. Ultrasonik ekipman

Temel bir ultrasonografi sistemi;

- Gönderici (Transmitter),
- Dönüştürücü (Transducer),
- Alıcı (Receiver),
- İşaret işleyici,
- Görüntüleme ünitesi,
- Kayıt ünitelerinden oluşur [39].

2.3.1. Gönderici

Gönderici; yüksek genlikli, kısa süreli darbeleri üretir ve uygun darbe tekrarlama hızı ile (pulse repetition frequency - PRF) bu darbeleri gönderir. Darbelerin genlikleri, dönüştürücüdeki mevcut kristalleri titreştirebilecek kadar büyük olmalıdır. Yakın alandan gelen ve bir önceki üretilmiş olan darbelerin üzerine binmemesi için, darbe süreleri mümkün olduğu kadar kısa olmalıdır. Darbe tekrarlama frekansı, yeni bir darbe üretilmeden önce işaretlerin maksimum derinliğe nüfuz ederek dönüştürücüye geri gelmesini sağlayabilmek için, darbeler arasında yeterli zamanı bırakacak hızda olmalıdır. Üretilen ikinci darbe çok kısa bir süre sonra gönderilirse, bir önceki işaretin yansıyarak gelen ekosu ile üst üste çakışacaktır. Diğer taraftan, darbelerin arasındaki süre çok uzun olduğunda, belirli bir sürede elde edilen bilgi miktarı azalacağından, çözünürlük düşecektir.

2.3.2 Dönüştürücü (Prob)

Ultrason cihazının hasta ile doğrudan temas eden tek parçasıdır. Ultrason dalgalarının gönderilmesi ve algılanması dönüştürücü yardımıyla olmaktadır. İçerdiği piezoelektrik kristali, gerilim uygulandığında, uygulanan voltajın polaritesine, kristalin geometrisine ve ilk polarizasyonuna bağlı olarak boyuna, enine veya radyal olarak çevresine doğru genişler ya da daralır. Bu daralıp genişleme sonucunda US dalgalar meydana gelir. Günümüzde kullanılan probların büyük bir bölümünde PZT (Polycrystalized Tetragonal Zirconia) kristali, polarize edilmiş seramik kristal kullanılmaktadır. İstenilen frekansta ultrason dalgası üretmek için uygun kristal kalınlığı seçilir.

Ultrason probları hem dalgaları göndermek amacıyla, hem de almak amacıyla kullanılmaktadır. Darbe-eko prensibine göre çalışan ultrason cihazlarında prob, zamanın % 0.1'inde US dalgaları göndermekte, geri kalan % 99.9'unda yansıyan dalgaları almakta ve bu dalgalar işaret işleme birimi tarafından görüntü oluşumuna hazır hale getirilmektedir.

Odaklanmamış bir probdan çıkan ultrason dalgaları belirli bir mesafeden sonra genişleyerek dağılırlar.

Ultrason problarının odaklanması iki yöntemle yapılmaktadır. Bunlardan ilki, akustik lensler kullanılarak yapılan mekanik odaklamadır. İkinci yöntemde ise, odaklanmış ultrason demeti elde etmek için, 7 veya 8 kristalden bir grup oluşacak şekilde kristaller gruplandırılmaktadır. Her bir kristalin tetiklenmesi belirli bir gecikme ve zamanlama ile yapılmak suretiyle, odak uzaklığı ve demet yönü değiştirilmektedir. Bu odaklama metoduna da elektronik odaklama denmektedir.

Ultrasonda çözünürlük, cihazın yanyana iki küçük nesneyi ayırt edebilme gücünü göstermektedir. İki tip çözünürlük vardır.

a. Axial çözünürlük: Ultrason demetiyle aynı doğrultudaki iki farklı doku grubunun ayırt edilebilme yeteneğidir. Fizik prensiplerine göre axial çözünürlük gönderilen vurum süresinin yarısı kadar olabilir. Ultrasonda bir tek vurum içinde birkaç darbe olduğundan, uygulamada axial çözünürlük; örneğin 3,5 MHz frekansı için yaklaşık olarak 1 mm'dir.

b. Lateral çözünürlük: Ultrason demetine dik düzlemdeki iki noktanın ayırt edilebilme yeteneğidir. Huzme genişliği azaldıkça, lateral çözünürlük artmaktadır.

Lateral çözünürlük, odak uzaklığı mesafesinde en iyi olmaktadır. Frekans arttıkça çözünürlük de artmakta, ancak dalgalar daha derin dokulara nüfuz edememektedir. Derin dokuları incelemek için prob yüzeyini genişletmek (lineer prob) ve frekansı düşürmek gerekmektedir.

2.3.3. Alıcı

Alıcı birimin ana görevi, gönderilen ultrason dalgalarının vücuttaki çeşitli dokulardan yansıyarak gelen kısmını algılamak ve yükseltme işlemlerini yapmaktır. Alma işlemi sırasında probdaki kristallere geri gelerek çarpan eko işaretleri, kristali sıkıştırır veya gevşetir. Böylece gönderme durumunun aksine, kristalin uçlarında bir gerilim oluşmaktadır. Bu gerilimin yükseltilmesi de alıcıda yapılmaktadır. Alıcıda özel bir yükselteç kullanılarak, derindeki dokulardan zayıf olarak gelen eko işaretleri daha çok yükseltilirken, yüzeydeki dokulardan kuvvetli olarak yansıyan işaretler daha az yükseltilmektedir. Böylece zaman-kazanç dengelemesi (time gain compensation) (TGC) ile istenilen derinlikteki organlar istenilen netlikte gözlenebilmektedir.

2.3.4. İşaret İşleyici

Görüntülemeye hazır hale gelen bilgilerin genel bir CRT (Cathode Ray Tube) ekran yardımıyla görüntülendiği birimdir. Renkli görüntüleme yapılabileceği gibi, gri seviyeler biçiminde de görüntüleme yapılabilmektedir. Ekranda görüntüyü dondurmak, filtreleme işlemleri yapmak, iki görüntüyü yanyana izlemek, üç boyutlu görüntü oluşturmak mümkündür.

2.3.5. Kayıt Üniteleri

Görüntüler ekranda gösterilebileceği gibi, aşağıdaki kayıt birimleri yardımıyla kaydedilip saklanabilmektedir.

- Polaroid kamera yardımıyla görüntünün fotoğrafı çekilerek saklanabilir,

- Multiformat kamera yardımıyla birden çok görüntü bir röntgen filmi gibi sert bir film üzerine düşürülerek saklanabilir,

- Video tape recorder (VTR) yardımıyla birden çok görüntü bir röntgen filmi gibi kaydedilebilir (özellikle ekokardiyografide),

- Strip chart recorder (thermal recorder) yardımıyla görüntü kağıt üzerine aktarılır.

2.4. Ultrasonografide görüntüleme modları

Ultrasonografide üç tip görüntüleme modu bulunmaktadır.

2.4.1. A Mod

Bu modda farklı yoğunluktaki doku katmanlarından yansıyarak gelen eko işaretlerinin şiddetleri derinliğe bağlı olarak gösterilmektedir. Ekranda elde edilen işaretler işaret üretecinden elde edilen sinüs dalgasının osiloskop ekranında görüntülenmesine benzetilebilir. Günümüzde A mod görüntüler, görüntüleme maksadıyla kullanılan ultrason cihazlarında pek kullanılmamaktadır. A mod görüntüleme daha çok EMG, EEG ve EKG işaretlerinin izlenmesinde kullanılır.

2.4.2. B Mod

Ultrason cihazlarında en çok kullanılan görüntüleme modudur. TV yayınlarında olduğu gibi parlaklık esasına dayanan bir görüntüleme yöntemidir.

2.4.3. M Mod

Hareket modu olarak tanımlanmaktadır. Özellikle kalp kapakçıkları gibi hareketli organların hareketlerinin incelenmesinde kullanılmaktadır. Yatay eksende zaman, dikey eksende derinlik bilgisi mevcuttur [39].

2.5. Ultrasonik görüntülerde teşhisi zorlaştıran etmenler

Geleneksel US görüntüler teşhis bilgisini taşırken, diğer görüntüleme tekniklerinde (MRI, CT) olmayan bir fenomen sonucu bozulmaya uğrarlar. Bu bozulmalar ultrasonun bağdaşık karakteri, US dalgaların ve dokuların karmaşık etkileşimleri ve görüntülemenin yansımadan elde edilmesi nedeniyle oluşmaktadır. Bu etmenler, görüntü içerisinde rastgele benek oluşmasına ve çözünürlüğün değişmesine neden olmaktadırlar. Bu bozulmalar, kullanılan malzemelerle ve onların ayarlarıyla da oldukça ilişkilidir.

Görüntü bozulmaları, geleneksel örüntü tanıma tekniklerinin US görüntülere doğrudan uygulanmasına ve nesnel teşhis teknikleri için doku özniteliklerinin belirlenmesi çabalarına da engel olurlar.

Bu tür etmenler, US görüntülerin iyileştirilmesine ve nicel doku değerlendirmesi için bir çerçeve elde edilmesine yönelik yapılan araştırmaları tahrik etmiştir [40].

2.6. Suni Fantom Verileri

Birçok ultrasonografi kullanıcısı, yeni bir ultrason cihazını satın almak veya test etmek için değerlendirirken, kendisini ya da başka birini taramaktadır. Ancak, bazı özel görüntüleme problemlerinin cihazdan mı yoksa taranan kişilerden mi kaynaklandığını tarafsız ve çabucak saptamak zor olmaktadır. Teşhis amaçlı görüntüleme cihazlarının kalite güvencesi için düzenlemeler, Amerika ve Avrupa'da hazırlanmaktadır. Yakın gelecekte, rutin KG (Kalite güvencesi) testleri zorunlu hale gelecektir.

Bir fantom ile, görüntü kalitesi için belirleyici unsurların çoğu, tarafsız ve çabucak değerlendirilebilmektedir. Günlük kullanımda, geometri, ayrıntı çözünürlüğü, karşıtlık çözünürlüğü, tarama düzlemi kalınlığı, axial çözünürlük, nüfuz homojenliği ve beneklenme örüntüsü gibi önemli görüntü kalitesi bileşenlerinin değerlendirilmesi, en net US görüntüleri elde etmek için birkaç dakika içerisinde yapılabilmektedir.

Bir fantom ile başarım kontrolü, az miktarda talimata ihtiyaç duymaktadır. Canlı bir modele göre fantom, zamana karşı değişmemektedir. Bu durum kullanıcıya, düzenli aralıklarla fantom görüntülerinin kopyasını alıp, önceden elde edilen görüntülerle karşılaştırmak suretiyle, uzun vadede cihazın doğruluğunu izleme imkânını vermektedir. Şekil 2.1'de, tez çalışmasında kullanılan fantom modeli ve bu modelden elde edilen US görüntü gösterilmektedir. Modele ilişkin bazı parametreler aşağıda belirtilmiştir.

- Fantom 15 cm. genişliğinde, 25 cm. yüksekliğinde ve 4 cm. derinliğindedir.

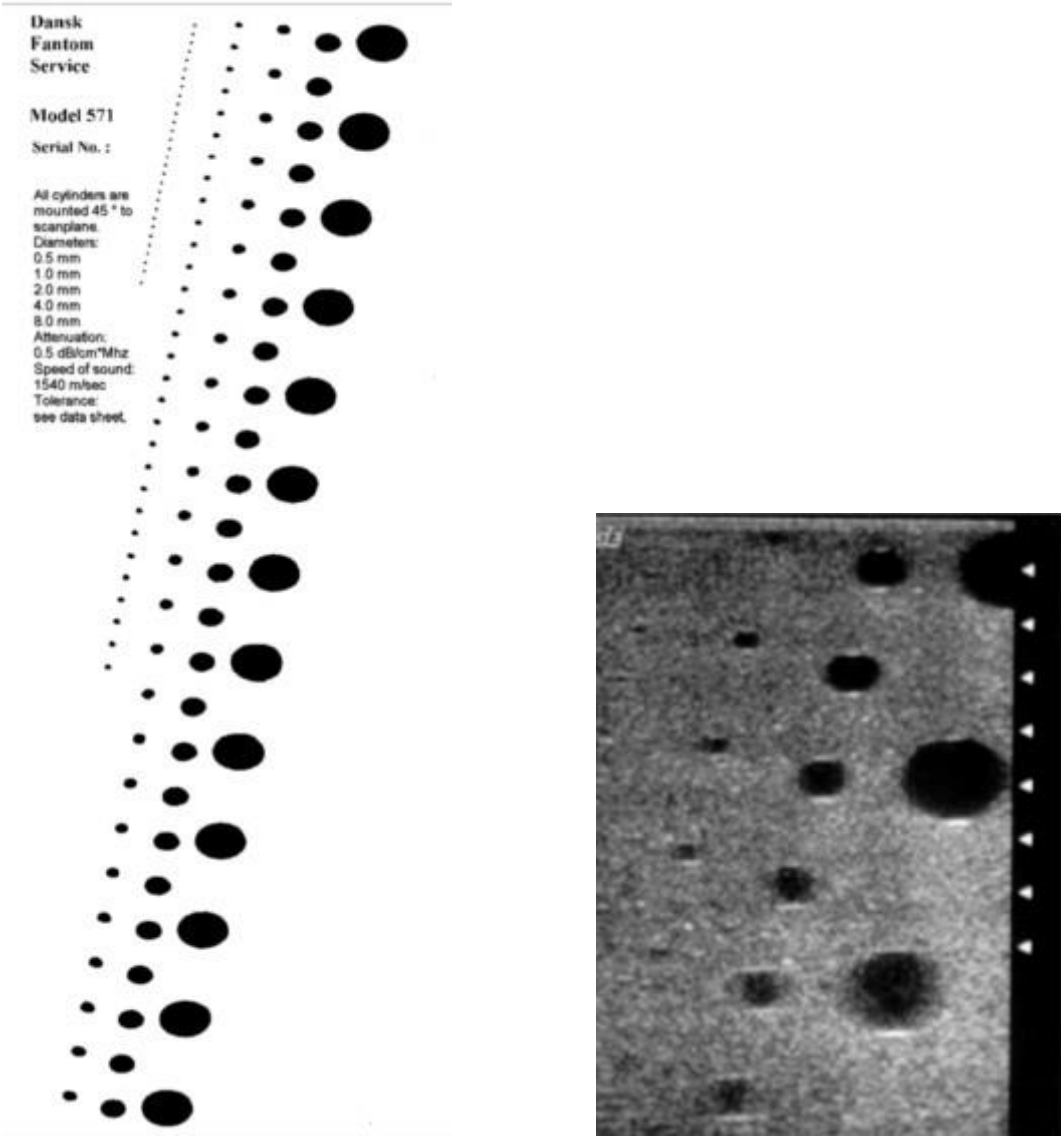
- 30 adet 0.5 mm.'lik, 30 adet 1 mm.'lik, 25 adet 2 mm.'lik, 25 adet 4 mm.'lik ve 13 adet 8 mm'lik silindir içermektedir.

- Arkaplan maddesinin zayıflaması 0.5 dB*cm* MHz,

- Arkaplan maddesinin ses hızı 1540 m/sn.,

- Dış ebatlar: 18 cm * 9 cm * 28 cm,

- Ağırlık: ~ 3 kg olarak verilmiştir [42].



Şekil 2.1 – Tez içerisinde kullanılan fantom modeli ve görüntüsü

Bir diğer yaklaşıma göre fantomlar, gerçek vücut bölgelerini temsil etmek için tasarlanmalarına rağmen, zaman alıcı ve pahalı bir yöntemdir. Birçok radyoloji uzmanı, fantom görüntüleri taramanın hastaları taramakla aynı olmadığını söylemektedir ve elde edilen sonuçların gerçek dünyayı yansıtmayarak, sistemin gerçek toplam değerini göstermediğini öne sürmektedir. Bir US sistem, güzel bir fantom görüntü oluşturabilmesine rağmen, gerçek hastalarda, hastaların hareketi ve nefes almasına bağlı olarak daha düşük kalitede sonuç üretmektedir.

Doku eşdeğeri fantomların ortaya çıkışı fantomların gerçekten canlı dokulara ne kadar benzediği sorusunu gündeme getirmiştir. Pratik bir bakış açısından, yalnızca belirlenmiş zayıflama, geriye saçılma, ses hızı ve frekansa bağlı geriye saçılımı genel

olarak akustiksel homojen olan maddeler doku eşdeğeri olarak uygundur. Parametrelerin çoğu sıcaklığa bağımlıdır ve belirli sıcaklıklardaki tolerans değerleriyle tanımlanmalıdır. Doku eşdeğeri madde akustik olarak karaciğer görüntüsünü taklit etse de, meme ve karın duvarı gibi homojen olmayan dokuların geniş kısmı, karaciğere nazaran çok farklı özellikler göstermektedir.

Dokularda bu kadar farklılıklar varsa neden doku eşdeğeri kullanılmaktadır? Bu konudaki detaylı bir çalışma göstermiştir ki, incelenen dokuların çoğu genel olarak homojendirler ve homojen olmayan ortamdaki görüntü kalitesinin hesabı ancak homojen ortamdaki görüntü kalitesi bilindiğinde mümkün olmaktadır [43].

3. ULTRASONİK GÖRÜNTÜLER İÇİN ÖZNİTELİK BELİRLEME YÖNTEMLERİ

Tez çalışmasında kullanılan öznitelikler;

- Görüntünün seçilen bir benek etrafında, belirli bir komşuluktaki gri seviyeleri,

- Görüntünün gri seviyelerini temel alan üç gri değeri,

- Frekans dağılımını ifade eden 2D ayrık fourier dönüşümünden elde edilen katsayılar,

- Frekans dağılımını ifade eden 2D ayrık kosinüs dönüşümünden elde edilen katsayılar,

- Hem frekans hem de zaman dağılımını ifade eden sürekli dalgacık dönüşümünün (SDD), görüntüyü farklı frekans bantlarına ayırmasıyla elde edilen görüntülerin benek değerleridir.

3.1 Gri Seviyeleri

Bu öznitelikler, temsil edilecek beneğin belirli bir komşuluğu içerisindeki diğer beneklerin gri seviyesinin - herhangi bir dönüşüm yapılmadan - doğrudan alınmasıyla elde edilmektedir. Tez çalışmasında, komşuluk değerinin 2 olduğu (Pencere boyutu 5x5) durum incelenmiştir.

3.2. 3 Gri (3G) değeri

Bu öznitelikler, görüntünün seçilen bir penceredeki gri seviyesini ve değişimini ifade ederler. Birinci öznitelik, temsil edilecek beneğin gri seviye değeridir. İkinci öznitelik, beneğin seçilen komşuluğundaki beneklerin aritmetik ortalaması, üçüncü öznitelik ise 1. ve 2. öznitelik arasındaki farktır. Şekil 3.1'de 1 komşuluk (Pencere boyutu 3x3) için bu öznitelikler açıkça görülmektedir.



a) X1 = x5 b) X2 = (x1+x2+x3+x4+x6+x7+x8+x9)/8 c) X3 = X2 – X1

Şekil 3.1 – 3 Gri öznitelik değeri a) 1.öznitelik b)2. öznitelik c) 3. Öznitelik

Önerilen bu üç öznitelik değeri ile görüntünün gri seviye değişimi ifade edilebilmektedir. Ayrıca ikinci özniteliğin bulunma aşamasında yapılan ortalama alma işlemi, bu yöntemin gürültüye karşı duyarlılığını azaltmaktadır. Böylelikle yöntem, gri seviyelerini doğrudan öznitelik olarak atama durumuna göre, gürültüye karşı daha gürbüz öznitelik değerleri üretebilmektedir.

3.3. Ayrık Fourier Dönüşümü (AFD)

Pratikteki işaretlerin çoğu, işlenmemiş halde zaman uzayı işaretleridir. Bu işaretler görüntülendiğinde zaman-genlik gösterilimi elde edilmektedir. Çoğu durumda, işaretteki en ayırıcı bilgi frekans dağılımında saklı olmaktadır. Görüntünün frekans içeriğini elde etmek için, işaretin zaman uzayındaki Fourier Dönüşümü alınarak, frekans-genlik gösterilimi elde edilmektedir. Böylelikle, işarette hangi frekanstan ne kadar olduğu bilinebilmektedir.

Fourier Dönüşümü tersine çevrilebilir bir dönüşümdür. Böylelikle fourier dönüşümü yapılmış işaretten, işlenmemiş (dönüşüm yapılmamış) işarete geçiş yapılabilmektedir.

Fourier Dönüşümü, işareti farklı frekanslardaki karmaşık üstel fonksiyonlara ayrıştırmaktadır. (3.1) ve (3.2) denklemlerinde bu durum matematiksel olarak ifade edilmiştir [44].

$$X(f) = \int_{-\infty}^{\infty} x(t) \cdot e^{-j2\pi ft} dt \qquad \text{x(t)'nin Fourier Dönüşümü} \qquad (3.1)$$

$$x(t) = \int_{-\infty}^{\infty} X(f) \cdot e^{j2\pi ft} df \qquad \text{X(f)'nin Ters Fourier Dönüşümü} \qquad (3.2)$$

Bu ifadelerde, t zamanı, f frekansı, x de işaretin kendisini temsil etmektedir. x zaman uzayındaki işareti temsil ederken, X frekans uzayındaki işareti göstermektedir.

x(t) işareti, belirli bir f frekansı için üstel bir terimle çarpılmakta ve bütün zamanlar için integrali alınmaktadır.

(3.1) denklemindeki üstel terim (3.3) denkleminde olduğu gibi yazılabilir.

$$Cos(2.\pi.f.t) + j.Sin(2.\pi.f.t) \tag{3.3}$$

Bu ifade, f frekansında reel bir kosinüs ve aynı frekansta sanal bir sinüs bileşeninden oluşmaktadır. Kısacası gerçekte yapılan iş, orijinal işareti f frekansında kosinüs ve sinüs işaretine sahip karmaşık bir ifade ile çarpmak şeklindedir. Ardından bu çarpımın integrali alınmakta, başka bir deyişle bütün noktalar bu çarpıma katılmaktadır. İntegralin sonucu büyük bir değerse, x(t) işareti f frekansında baskın bir dağılım bileşenine sahiptir. İntegral sonucu küçük bir değerse, işaretin f frekansında ana bir bileşene sahip olmadığı anlaşılmaktadır.

Ayrık Fourier Dönüşümü'nün tek boyutlu işaretler için matematiksel ifadesi (3.4) ve (3.5) denklemlerinde görülmektedir.

$$X(k_1) = \sum_{n_1=0}^{N_1-1} x(n_1) \cdot e^{-\frac{j2\pi k_1 n_1}{N_1}} \qquad \text{Ayrık Fourier Dönüşümü} \tag{3.4}$$

$$x(n_1) = \frac{1}{N_1} \sum_{k_1=0}^{N_1-1} X(k_1) \cdot e^{\frac{j2\pi k_1 n_1}{N_1}} \qquad \text{Ayrık Ters Fourier Dönüşümü} \tag{3.5}$$

Ayrık Fourier Dönüşümü'nün iki boyutlu işaretler için matematiksel ifadesi (3.6) ve (3.7) denklemlerinde görülmektedir.

$$X(k_1, k_2) = \sum_{n_1=0}^{N_1-1} \sum_{n_2=0}^{N_2-1} x(n_1, n_2) \cdot e^{-\frac{j2\pi k_1 n_1}{N_1}} \cdot e^{-\frac{j2\pi k_2 n_2}{N_2}} \qquad \text{AFD} \tag{3.6}$$

$$x(n_1, n_2) = \frac{1}{N_1 \cdot N_2} \sum_{k_1=0}^{N_1-1} \sum_{k_2=0}^{N_2-1} X(k_1, k_2) \cdot e^{\frac{j2\pi k_1 n_1}{N_1}} \cdot e^{\frac{j2\pi k_2 n_2}{N_2}} \qquad \text{ATFD} \tag{3.7}$$

N_1 ve N_2 sabitlerinin değerinin seçimi kritik bir konudur ve işlenmemiş görüntüye dönüşüm uygulanmadan önce belirlenmelidir. N_1 ve N_2 sabitlerinin değeri büyük tutulduğunda, frekans uzayında görüntü işaretini temsil eden ana bileşenler daha hassas bir şekilde belirlenebilmektedir. Bununla birlikte, pencerenin çok büyük olması, işaret içindeki ani değişimlerin frekans uzayında iyi bir şekilde temsil edilememesine neden olmaktadır. Bu durumda, ani değişimler frekans uzayında ana bileşenler etrafında yayılmakta ve diğer bileşenlerin değerlerini etkilemektedir. Pencerenin büyük seçilmesi hesap yükünün de artmasına neden olmaktadır.

Frekans uzayında ortaya çıkan X(k) işareti iki bileşenden oluşmaktadır. X(k), reel ve sanal bileşen ya da modül ve fazdan meydana gelmektedir. İşaretin pencere içerisindeki kayması (gecikmesi) frekans uzayında sadece fazı değiştirmektedir. Bu nedenle öznitelik olarak modül bileşenlerinin kullanımı, öznitelik vektörlerinin gecikmeden etkilenmemesini sağlamaktadır.

Tez çalışmasında, görüntünün seçilen bölgesi için frekans spektrumuna ait bilgiler taşıyan öznitelikler elde etmek için Matlab Programında yerleşik olarak bulunan 2 boyutlu hızlı fourier dönüşümü fonksiyonu (fft2) kullanılmıştır. AFD öznitelikleri oluşturulurken, pencere boyutu 5x5 olarak seçilmiştir. Oluşan 25 adet katsayıdan, en anlamlı 9 tanesi öznitelik olarak belirlenmiştir.

3.4. Ayrık Kosinüs Dönüşümü (AKD)

AKD, Ayrık Fourier Dönüşümü gibi sinüzoidal tabanlı bir dönüşümdür. Aralarındaki en önemli fark AKD'nin yalnızca kosinüs terimlerini kullanması, böylelikle kompleks bileşenler içermemesidir.

1 boyutlu N elemanlı bir *f(x)* işaretinin Ayrık Kosinüs Dönüşümü ve Ters Ayrık Kosinüs Dönüşümü (3.8) ve (3.9) denklemlerinde gösterilmiştir.

$$C(u) = \sqrt{\frac{2}{N}}\alpha(u)\sum_{x=0}^{N-1} f(x)\cos\left[\frac{(2x+1)u\pi}{2N}\right] \tag{3.8}$$

$$f(x) = \sqrt{\frac{2}{N}}\sum_{u=0}^{N-1}\alpha(u)C(u)\cos\left[\frac{(2x+1)u\pi}{2N}\right] \tag{3.9}$$

$$\alpha(u) = \begin{cases} \frac{1}{\sqrt{2}} & u = 0 \\ 1 & 1 \le u \le N-1 \end{cases} \tag{3.10}$$

Dönüşüm sonrasında sanal katsayıların üretilmemesi, bellekten kazanç sağlamaktadır. İşarete ait enerjinin büyük bir bölümü, ilk başlardaki katsayılarda yığılma göstermektedir. Bu sayede işaret, belli toleranslar ile başlangıçta bulunan az sayıda katsayıyla (daha az parametre ile) temsil edilebilmektedir. Kosinüs dönüşümü, enerji yoğunlaştırma özelliği nedeniyle görüntü sıkıştırma konusunda sıkça kullanılmaktadır.

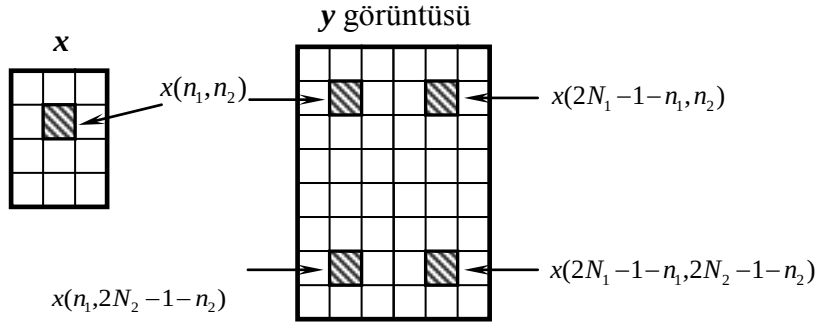
N x M boyutlu bir *f(x,y)* görüntüsünün ayrık kosinüs dönüşümü ve ters ayrık kosinüs dönüşümü (3.11) ve (3.12) denklemlerinde verilmiştir.

$$C(u,v) = \frac{2}{\sqrt{MN}} .\alpha(u)\alpha(v) \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x,y) \cos\left[\frac{(2x+1)u\pi}{2M}\right] \cos\left[\frac{(2y+1)u\pi}{2N}\right] \tag{3.11}$$

$$f(x,y) = \frac{2}{\sqrt{MN}} \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} \alpha(u)\alpha(v) C(u,v) \cos\left[\frac{(2x+1)u\pi}{2M}\right] \cos\left[\frac{(2y+1)u\pi}{2N}\right] \tag{3.12}$$

u = 0,1,2,…,M-1, v = 0,1,2,…,N-1,

Görüntü için kosinüs dönüşümü, tek boyutlu işaretler için izlenen adımlara benzer bir şekilde elde edilmektedir. Görüntü işaretleri için üç kez aynalama gerçekleşmektedir. Şekil 3.2'de, x(n1,n2) görüntüsü anlaşılır olması açısından 4x3 benekten, y(n1,n2) aynalanmış görüntüsü ise 8x6 benekten meydana gelmiştir.



Şekil 3.2 Görüntü için aynalama işlemi (N_1=4, N_2=3)

Kosinüs katsayıları, öznitelik vektörünün elemanlarını oluşturmaktadır. Örneğe ait işaretler çok sayıda ayrık veriden oluşuyorsa, kosinüs katsayılarının kullanımı öznitelik vektörünün boyutunu önemli ölçüde azaltmaktadır. Genlik normalizasyonu

için genellikle seçilen pencere içindeki işaretin gücü sabitlenmektedir. Vektör elemanları, seçilen pencere içindeki işaretin kaymasından etkilenmektedir. Bu nedenle, pencere içindeki işaretin ilk değerinin belirlenmesi için ayrı bir normalizasyon işlemine daha ihtiyaç duyulmaktadır.

Tez çalışmasında ayrık kosinüs dönüşümü için, Matlab Programında yerleşik olarak bulunan 2 boyutlu ayrık kosinüs dönüşümü fonksiyonu (dct2) kullanılmıştır. AKD öznitelikleri oluşturulurken, pencere boyutu 5x5 olarak seçilmiştir ve en anlamlı 9 adet AKD katsayısı öznitelik olarak seçilmiştir.

3.5. Sürekli Dalgacık Dönüşümü (SDD)

Fourier ve kosinüs dönüşümlerinde, integral eksi sonsuzdan, artı sonsuza kadar alındığından, integral tarafından sağlanan bilgi, bütün zaman aralıklarındaki örneklere karşılık gelmektedir. Bu durumda işaretteki f frekansı hangi aralıkta oluşursa oluşsun, integral sonucunu aynı oranda etkilemektedir. Bu bakımdan fourier ve kosinüs dönüşümü, zamanla değişen frekanslara sahip (durağan olmayan) işaretlerde kullanılmaya elverişli değildir. Spektral bileşenlerin zamandaki yerleşimleri bilinmek istendiğinde, işaretin zaman-frekans gösterilimine ihtiyaç duyulmaktadır. Dalgacık dönüşümü bu ihtiyaca karşılık veren bir dönüşümdür [45]. Aynı gösterilimi ifade edebilen başka dönşümler de mevcuttur (Kısa Zamanlı Fourier Dönüşümü, Wigner dağılımları…vb.).

Dalgacık dönüşümü, zamanda değişken çözünürlük verebilen bir yapıya sahiptir. Dalgacık dönüşümüne, frekans cevabı zamanla değişen durağan olmayan işaretlerin analizinde ihtiyaç duyulmaktadır.

Dalgacık dönüşümünde işaret, dalgacık olarak adlandırılan bir fonksiyonla çarpılmakta ve dönüşüm, zaman uzayındaki işaretin farklı bölümleri için ayrı ayrı hesaplanmaktadır. SDD'de sanal üstel bir terim kullanılmamaktadır. Ayrıca, her spektral bileşen için dönüşüm hesaplanırken pencerenin genişliği değiştirilmektedir. Bu durum, dalgacık dönüşümünün en önemli özelliğini oluşturmaktadır.

SDD aşağıdaki şekilde ifade edilmektedir:

$$SDD_x^{\psi}(\tau,s) = W_x(\tau,s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t)\cdot\psi^*\left(\frac{t-\tau}{s}\right)\cdot dt \quad \tau, s \in \Re;\ s \neq 0 \quad (3.13)$$

x(t); orijinal işareti, *; kompleks konjugeyi ifade etmektedir. τ zamanda öteleme, *s* ise ölçek parametresidir. $\psi(t)$ dönüşüm (pencere) fonksiyonudur ve ana dalgacık (mother wavelet) olarak adlandırılmaktadır.

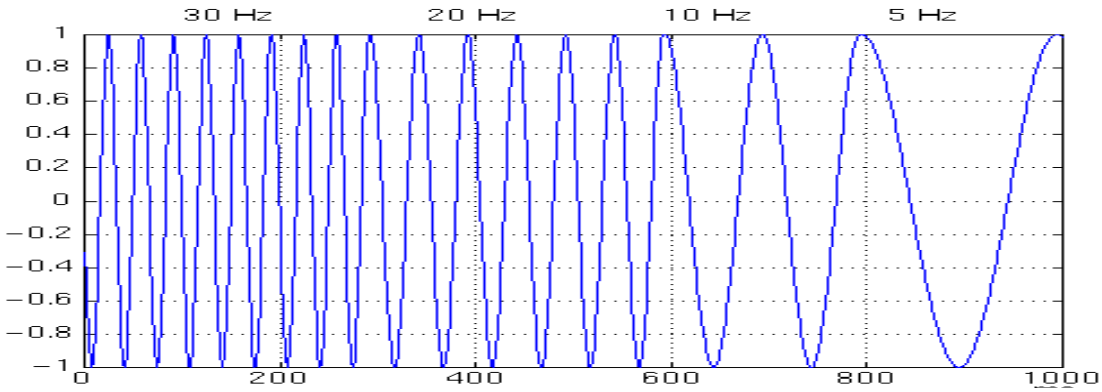
(3.13) ifadesinden, SDD'nin öteleme ve ölçek değişkenlerinin bir fonksiyonu olduğu anlaşılmaktadır.

Dönüşümde kullanılan farklı genişliğe sahip diğer pencere fonksiyonları, ana dalgacıktan ölçekleme yoluyla türetilmektedir. Öteleme terimi, pencerenin yerini ifade etmektedir. Pencere, işaret üzerinde gezdirilmekte, dönüşümden zaman bilgisi öteleme ile sağlanmaktadır. Frekans parametresi yerine, 1/frekans olarak tanımlanan ölçek parametresi (*s*) kullanılmaktadır.

Ölçek değeri büyük olduğunda (düşük frekanslar) işaret hakkında global (genel) bir bilgi elde edilir. Ölçek değeri küçük olduğunda ise (yüksek frekanslar) işaretteki detaylar (kısa süren değişimler) ön plana çıkmaktadır. Ölçek parametresinin değeri değiştirilerek, ana dalgacığın sıkıştırılması ya da genişletilmesiyle SDD'de kullanılan pencereler elde edilir. Morlet, Meyer, Meksika şapkası, Daubechies dalgacıkları… vb. fonksiyonlar, pencere fonksiyonu olarak kullanılan fonksiyonlara örnektir.

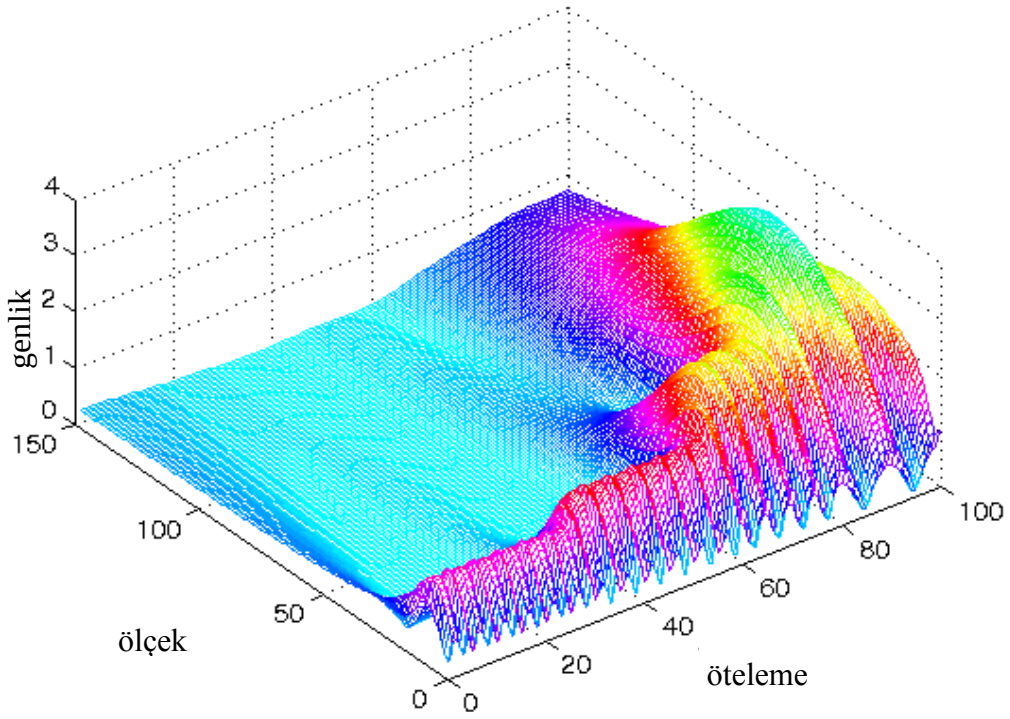
Ana dalgacık bir kez belirlendikten sonra ölçek değeri *s*'nin tüm değerleri için hesap yapmak gereksiz olmaktadır. Bunun nedeni, pratikte, analiz edilen işarete bağlı olarak, işaretin bandının sınırlandırılması ve bu şekilde sınırlı bir ölçek aralığı için dönüşümün hesaplanmasının yeterli olmasıdır. Seçilen *s* değeri için dalgacık, analiz edilen $x(t)$ işaretinin t=0'a karşılık gelen başlangıç noktasına yerleştirilmektedir. İşaret ile dalgacık çarpılmakta ve tüm zaman üzerinden integrali alınmaktadır. Ayrıca, integrasyon sonucu $1/\sqrt{s}$ sabit sayısıyla çarpılarak enerji normalizasyonu sağlanmaktadır. Bu çarpım, dönüştürülen işaretin her ölçekte aynı enerjiye sahip olmasını temin etmektedir. Daha sonra dalgacık, zamanda τ kadar sağa ötelenmekte ve aynı işlem tekrarlanmaktadır. Bu şekilde işaretin sonuna ulaşıldığında, zaman-ölçek düzlemi üzerinde bir satırda (*s*'nin bir tek değerine karşılık) bulunan tüm noktalar hesaplanmış olmaktadır. Arzu edilen tüm *s* değerleri için işlemler tekrarlandığında, işaretin SDD'si hesaplanmış olur ve işaretin zaman-ölçek-genlik değerlerinden oluşan üç boyutlu gösterilimi analizler için hazır hale gelir. Pencerenin zamanda kaydırılması, işaretin zamanda, ölçek değerinin değiştirilmesi ise işaretin frekans uzayında incelenmesine olanak sağlamaktadır.

Sürekli Dalgacık Dönüşümü'ne ait bir örnek Şekil 3.3'te gösterilmiştir. Dönüşümü yapılan işaret durağan değildir ve içerisinde 30 Hz, 20 Hz, 10 Hz ve 5 Hz'lik frekans bileşenlerine sahiptir.



Şekil 3.3 - 30, 20, 10 ve 5 Hz frekans bileşenlerine sahip durağan olmayan bir işaret

Şekil 3.3'teki işaretin Sürekli Dalgacık Dönüşümü, Şekil 3.4'te gösterilmiştir.



Şekil 3.4 – Şekil 3.3'teki işaretin Sürekli Dalgacık Dönüşümü

Öteleme doğrudan zamanla ilişkili olmasına rağmen, ölçek, frekansın tersine karşılık gelmektedir. Şekil 3.4'ten görüldüğü üzere, küçük ölçekler yüksek frekanslara karşılık gelmektedir. Ölçek değeri azaldıkça frekans artmaktadır. Sıfırın etrafındaki

ölçekler, analizdeki en yüksek frekanslara karşılık gelmektedir. Orijinal işarette 30 Hz'lik en yüksek frekans bileşeni zamanın ilk anlarında gözlendiğinden, bu bileşene karşılık 0-30 öteleme bölgesinde, en küçük ölçekte değişimler gözlenmektedir. 5 Hz'lik bileşen ise, öteleme ekseninin en sonunda ve yüksek ölçeklerde (alçak frekanslar) görülmektedir.

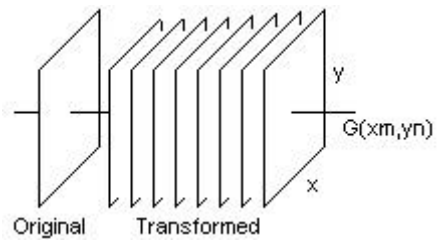
Dalgacık dönüşümü, yüksek frekanslarda zamanda iyi, frekansta kötü çözünürlük verirken, düşük frekanslarda zamanda kötü, frekansta iyi çözünürlük vermektedir.

Şekil 3.4'te, küçük ölçekler (yüksek frekanslar) daha iyi zaman çözünürlüğüne sahiptir. Ölçeğin dar olması, zamanın gerçek değerinin ne olacağındaki belirsizliği azaltmaktadır. Ancak zamanda çözünürlüğün iyi olması, frekansta kötü çözünürlüğe karşılık gelmektedir. Benzer şekilde, yüksek ölçeklerde de ölçeğin destek bölgesi genişlediğinden, zaman değerlerinin doğru saptanmasındaki belirsizlik artmakta ve düşük frekanslarda frekans çözünürlüğü iyileşmektedir.

Şekil 3.4'te eksenler normalize edilmiştir. Kabaca söylemek gerekirse, öteleme eksenindeki 100'üncü nokta değeri 1000 ms'ye, ölçek eksenindeki 150'nci nokta değeri ise 40 Hz'lik frekans bandına karşılık gelmektedir.

Dalgacık dönüşümü görüntüyü hem frekans hem de zaman uzayında inceleme imkanı vermektedir. Bu bakımdan, yalnızca frekans uzayı analizine izin veren Fourier ve Kosinüs dönüşümüne nazaran daha kapsamlı bir doku analizi gerçekleştirilmesine olanak sağlamaktadır.

Tez çalışmasında, bölütlenecek görüntünün öznitelik vektörleri, görüntünün farklı parametrelerle SDD'leri alındıktan sonra elde edilen 8 görüntü ile orijinal görüntünün aynı koordinatlardaki benek değerleri alınarak oluşturulmuştur (Şekil 3.5). Bu şekilde, görüntü bölütlenirken benek bazındaki (yerel) bilgi yerine global (genel) bilgi öznitelik olarak kullanılmıştır.



Şekil 3.5 - SDD özniteliklerinin oluşturulması

4. SINIFLAYICI OLARAK YAPAY SİNİR AĞLARI

Bugüne kadar yapılan birçok görüntü işleme çalışmasında, Yapay Sinir Ağları sınıflayıcı olarak kullanılmıştır. YSA'ların sınıflayıcı olarak kullanılmasının nedenleri başlıca beş kısma ayrılabilir:

(i) Eğitim kümesindeki vektörler kullanılarak sonuca adım adım yaklaşılmaktadır,

(ii) Eğitim kümesinde bulunmayan giriş vektörlerine uygun cevap üretilmektedir (genelleme yeteneği),

(iii) Literatürde geliştirilmiş çoğu ağ fiziksel olarak kolaylıkla gerçeklenebilmektedir,

(iv) Ağlar paralel bir yapıya sahip olduğu için sınıflama işleminde hızlı cevap üretmektedir,

(v) YSA'lar kompleks sınıf dağılımlarını temsil edebilme yeteneğine sahiplerdir.

Tez içerisinde kullanılan ağlar, GAL (Grow and Learn), Kohonen ve DAYSA'dır (Denetimsiz Artımsal Yapay Sinir Ağı).

Genel olarak bir YSA'nın öğrenmesi, çevreden ve varsa eğiticiden aldığı girişler uyarınca (çoğunlukla belirli bir amacı daha iyi yapabilmek için) giriş-çıkış işlevini, iç yapısını uyarlayarak değiştirmesi olarak tanımlanmaktadır. İç yapıdaki değişiklikler; yeni bağlantılar oluşturmak, mevcut bağlantıları yok etmek veya mevcut bağlantıların ağırlıkları değiştirilerek gerçekleşmektedir.

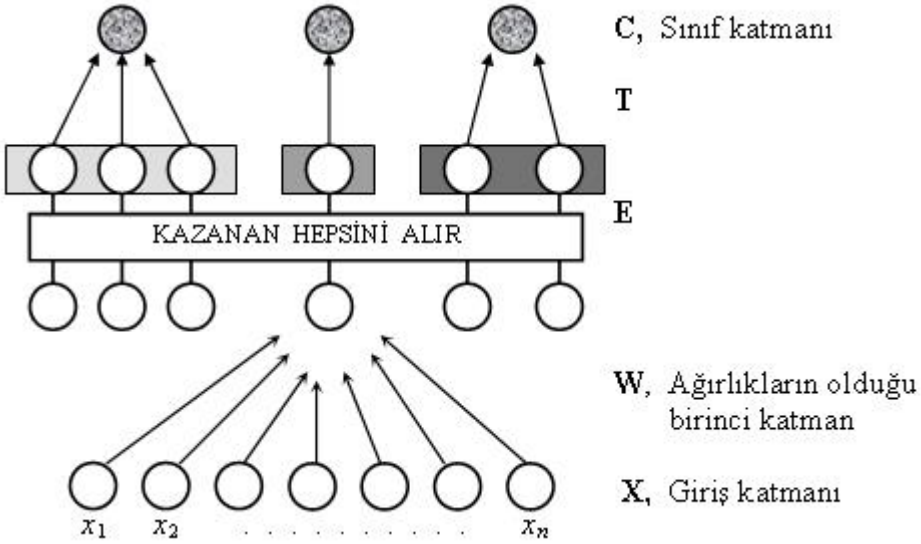
Denetimli öğrenme yöntemlerinde ağ, kendi çıkışı ile arzu edilen çıkış arasındaki farkı azaltacak şekilde parametrelerini değiştirmektedir. Ağın eğitim kümesi, her sınıftan aynı sayıda rastgele seçilmiş vektörlerden oluşmaktadır. Tez içerisinde kullanılan GAL ağı denetimli bir YSA'dır.

Denetimsiz öğrenme yönteminde ağ, sınıfların öznitelik uzayındaki dağılımını inceleyerek kendi parametrelerini değiştirmektedir. Bu yöntemde arzu edilen çıkış yoktur veya eğitim algoritması tarafından kullanılmaz, eğitimde kullanılan denklemler içinde de gözükmez. Tez içerisinde kullanılan Kohonen ağı ve DAYSA denetimsiz YSA'lardır.

4.1 GAL (Grow and Learn, Büyü ve Öğren) Ağı

GAL ağı [46], öznitelik uzayındaki sınıf sınırlarını en yakın öklit mesafesi ölçütüne göre belirlemektedir. Ağın en önemli özelliği, düğüm sayısının eğitim sırasında problemin yapısına bağlı olarak kendiliğinden belirlenebilmesi, yani artımsal olmasıdır.

Şekil 4.1'de GAL ağının yapısı gösterilmiştir [44]. Ağ, iki katmandan meydana gelmektedir. Ağın içindeki düğümlerin yapısı (4.1) ve (4.2) denklemleriyle ifade edilmektedir.



Şekil 4.1- GAL Ağının Yapısı

$$D_j = \sum_{i=1}^{n} \left(x_i - w_j\right)^2 \qquad \mathrm{E}_e = \begin{cases} 1 & D_e = \min_j \left\{D_j\right\} \\ 0 & \text{aksi taktirde} \end{cases} \tag{4.1}$$

$$\mathrm{C}_c = \sum_e \mathrm{E}_e \cdot \mathrm{T}_{ec} \qquad \text{Çıkış katmanı} \tag{4.2}$$

x_i, giriş vektörünün elemanlarını; w_j, j-inci düğümü; Dj, giriş vektörü ile j-inci ağ düğümü arasındaki öklit mesafesini, $\mathrm{E_e}$, birinci katmandaki düğümlerin çıkışını; T_{ec}, sadece 0 veya 1 değerini alan OR'lama işlemini gerçekleyen bağlantı katsayısını; n ise giriş vektörü sayısını göstermektedir.

İlk katman, düğüm ağırlıkları ile giriş vektörü arasında minimum mesafeyi bulmada kullanılırken, ikinci katman, ağdaki düğümlerin ait oldukları sınıfı tanımlamak için kullanılmaktadır. İkinci katmandaki ağırlıklar başlangıçta 0 değerini alır ve eğitim

sırasında bu bağlantılar 1'lenir. İkinci katman, aynı sınıftan çıkışları lojik olarak OR'lamak için kullanılmaktadır.

Eğitim öncesinde, el yordamı ile seçilerek oluşturulmuş eğitim kümesindeki her sınıftan bir adet öznitelik vektörü alınır ve ağın başlangıç düğümleri olarak atanır.

Ağın algoritması şu adımlar dahilinde özetlenebilir:

1- Eğitim kümesinden bir öznitelik vektörü alınır. Bu vektör ile ağın düğümleri arasındaki minimum Euclid mesafesine bakılır.

2- Bulunan minimum mesafedeki ağ düğümünün sınıfı, giriş vektörünün sınıfından farklı ise kullanılan öznitelik vektörü yeni bir düğüm olarak ağa sunulur.

3- Eğitim kümesindeki tüm vektörler kullanıldıysa algoritma sonlandırılır. Aksi halde 1. Adım'a geçilir.

Bu şekilde eğitim tamamlandıktan sonra, ağdaki gereksiz (olup olmaması sınıflama sonucunu değiştirmeyen) düğümleri ağdan çıkartmak için, GAL ağının unutma algoritması uygulanır. Unutma algoritması şu adımlar dahilinde özetlenebilir.

1- Sırayla ağdan bir düğüm geçici olarak kaldırılır ve kaldırılan düğüm ağa giriş olarak verilir.

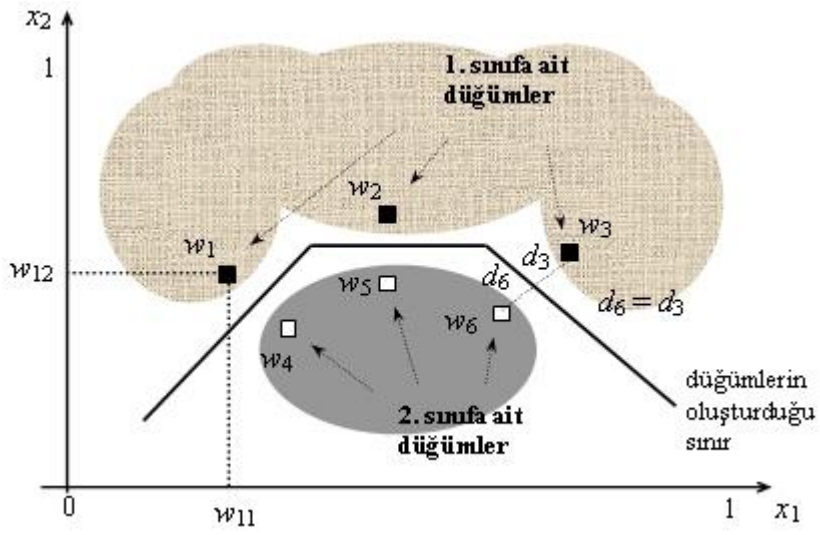
2- Giriş vektörü ile ağın düğümleri arasındaki Euclid mesafeleri hesaplanır. Minimum mesafedeki düğümün sınıfı, giriş vektörünün sınıfından farklı ise çıkarılan düğüm tekrar ağa ilave edilir.

3- Ağdaki bütün düğümler kullanıldıysa, algoritma sonlandırılır. Aksi halde 1. Adım'a geçilir.

Sınıf sınırlarının birbirlerine yaklaşması durumunda, eğitim algoritması aşırı sayıda düğüm üretmektedir. Sınıfların sınırlarının birbirine yaklaşması, özniteliklerin iyi belirlenememesi durumuna karşılık gelmektedir.

GAL ağında düğüm ağırlıkları, giriş vektörünün elemanlarının doğrudan alınmasıyla oluşturulmaktadır. Bu nedenle ağ, ezberci bir eğitim algoritmasına sahiptir.

Şekil 4.2'de iki-boyutlu uzayda ağ düğümleri yardımıyla sınıfların birbirinden ayrılması gösterilmiştir.



Şekil 4.2 – GAL ağının iki boyutlu uzayda sınıfları birbirinden ayırması

Sınıflama kararında en yakın mesafe kuralı kullanıldığı için iki farklı sınıftan düğüm iki-boyutlu uzayda bir doğru oluşturmaktadır. Suni olarak oluşturulan bu doğru, sınıf sınırını meydana getirmektedir. Çok-boyutlu uzayda da aynı mekanizma geçerlidir. Farklı iki sınıftan düğüm arasında, bu iki düğüme eşit mesafede sınıf sınırı olarak adlandırılan hayali bir hiper düzlem oluşmaktadır.

4.2 KOHONEN Ağı

Kohonen ağı da, GAL ağı gibi iki katmandan meydana gelmektedir. Ağın genel yapısı, Şekil 4.1'deki GAL ağı ile aynıdır. GAL ağına ilişkin (4.1) ve (4.2) denklemleri, Kohonen ağı için de geçerlidir.

Ağdaki ilk katman, düğüm ağırlıkları ile giriş vektörü arasında minimum mesafeyi bulmada kullanılırken, ikinci katman, ağdaki düğümlerin ait oldukları sınıfı tanımlamak için kullanılmaktadır. İkinci katmandaki ağırlıklar, eğitim tamamlandıktan sonra bir etiketleme işlemi ile belirlenmektedir. İkinci katman, aynı sınıfa ait çıkış düğümlerini lojik olarak OR'lamak için kullanılır.

Kohonen ağının düğümleri, GAL ağının öznitelik uzayını bölmelemesine benzer şekilde sınıfları birbirlerinden ayırır. Bununla birlikte, ağlar arasında, iki temel fark bulunmaktadır. GAL ağında düğüm sayısı ihtiyaca göre artarak oluşmakta ve düğüm ağırlıkları, giriş vektörlerinin doğrudan alınmasıyla elde edilmektedir. Kohonen ağında ise düğüm sayısı önceden belirlenmekte ve düğüm ağırlıkları ilk etapta rastgele değerlerle oluşturulmaktadır.

Ağın eğitiminde, yalnızca kazanan (minimum Euclid mesafesindeki) düğümün ağırlığı değil, seçilen belirli bir komşuluktaki çevre düğümlerin ağırlıkları da değiştirilmektedir. Öğrenme esnasında, bu komşuluğun sınırları zamanla lineer olmayacak şekilde azaltılmaktadır.

İlk olarak, çıkış düğüm sayısı, kazanç, komşuluğun zamanla değişimi ve iterasyon sayısı belirlenmektedir. Ağdaki düğümlerin ağırlıklarına 0 ile 1 arasında rastgele değerler verilmektedir.

Ağın algoritması şu adımlar dahilinde özetlenebilir:

1- Eğitim kümesinden bir öznitelik vektörü alınır. Bu öznitelik vektörü ile ağın düğümleri arasındaki minimum Euclid mesafesine bakılır.

2- Bulunan minimum mesafedeki düğümün ve seçilen komşuluktaki düğümlerin ağırlıkları, (4.3) bağıntısı uyarınca giriş vektörüne yakınsayacak şekilde değiştirilir. Kazanç değeri düşürülür.

$$w_{ji}(k+1) = w_{ji}(k) + \eta(t) \cdot \left(x_i - w_{ji}(k)\right) \tag{4.3}$$

3- Eğitim kümesindeki tüm vektörler kullanıldıysa algoritma sonlandırılır. Aksi halde 1. Adım'a geçilir.

Eğitim tamamlandıktan sonra düğümlerin sınıflarını belirlemek için her düğüme sınıf sayısı kadar sınıf etiketi atanır. Eğitim kümesi içindeki her bir vektörün, hangi çıkış düğümüne yakın olduğu araştırılır. İncelen giriş vektörüne en yakın düğümün sınıf etiketi gözü, giriş vektörünün sınıfı ile ilişkili olarak artırılır. Bu işlem tamamlandıktan sonra, etiket gözleri içerisindeki en yüksek değeri veren sınıf değerleri, düğümlerin sınıfı olarak belirlenmektedir.

4.3 DAYSA (Denetimsiz Artımsal Yapay Sinir Ağı)

DAYSA [38], ISOM [36] ağının geliştirilmesiyle ortaya çıkmıştır. Ağ deneticisiz ve artımsal bir ağ olması bakımından önem taşır. DAYSA da GAL ve Kohonen ağları gibi iki katmandan oluşmaktadır.

Ağın eğitiminde ilk olarak, eğitim kümesinden bir öznitelik vektörü başlangıç düğümü olarak atanır ve kazanç değeri belirlenir.

Ağın algoritması şu adımlar dahilinde özetlenebilir:

1- Eğitim kümesinden bir öznitelik vektörü alınır. Bu öznitelik vektörü ile ağın düğümleri arasındaki minimum Euclid mesafesine bakılır.

2- Bulunan minimum mesafe belirli bir eşikten büyükse, kullanılan öznitelik vektörü yeni bir düğüm olarak ağa sunulur. Bu düğümün kullanılma sayacı arttırılır. 1. Adım'a gidilir.

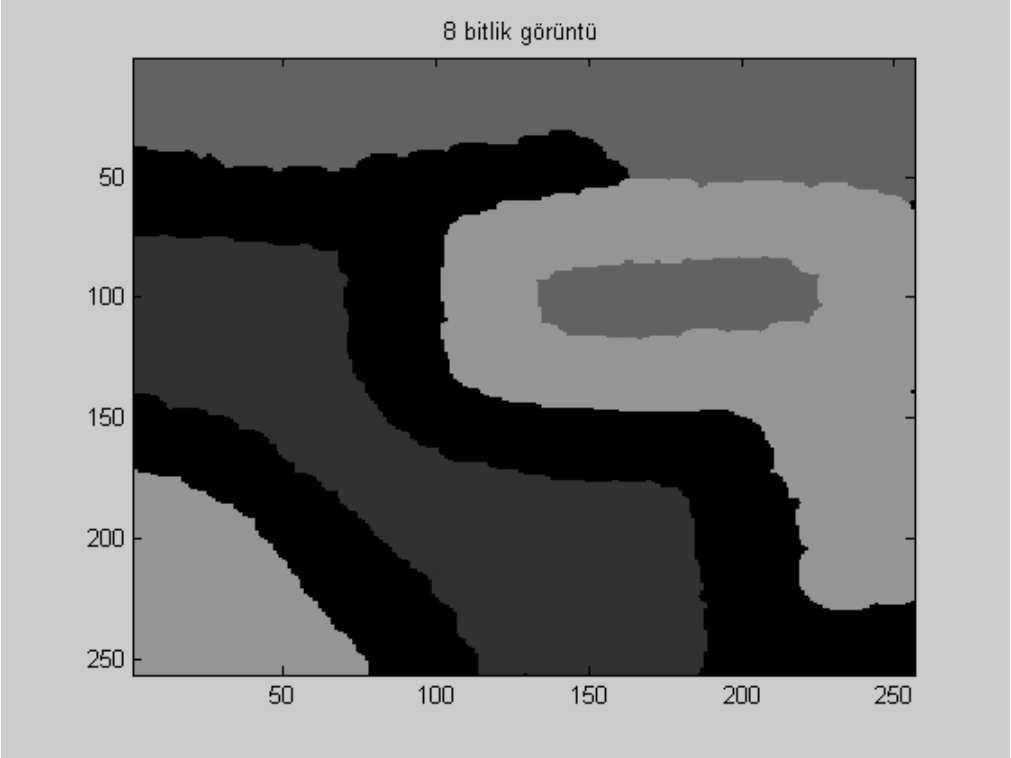
3- Bulunan minimum mesafe belirli bir eşikten küçükse, minimum mesafeli düğüm (4.3) bağıntısı kullanılarak, kullanılan öznitelik vektörüne yaklaştırılır. Kazanç değeri azaltılır ve bu düğümün kullanılma sayacı arttırılır. 1. Adım'a gidilir.

Bu şekilde eğitim tamamlandıktan (düğümler oluşturulduktan) sonra, sınıflama işlemine geçmeden önce düğümlerin etiketlenmesi gerekir. Kullanıcı etiketleme işlemine karışmadığı durumda ağın her düğümü, bir sınıfı temsil edecektir. Gerektiği zaman kullanıcı, düğümleri bir sınıf altında toplayabilir.

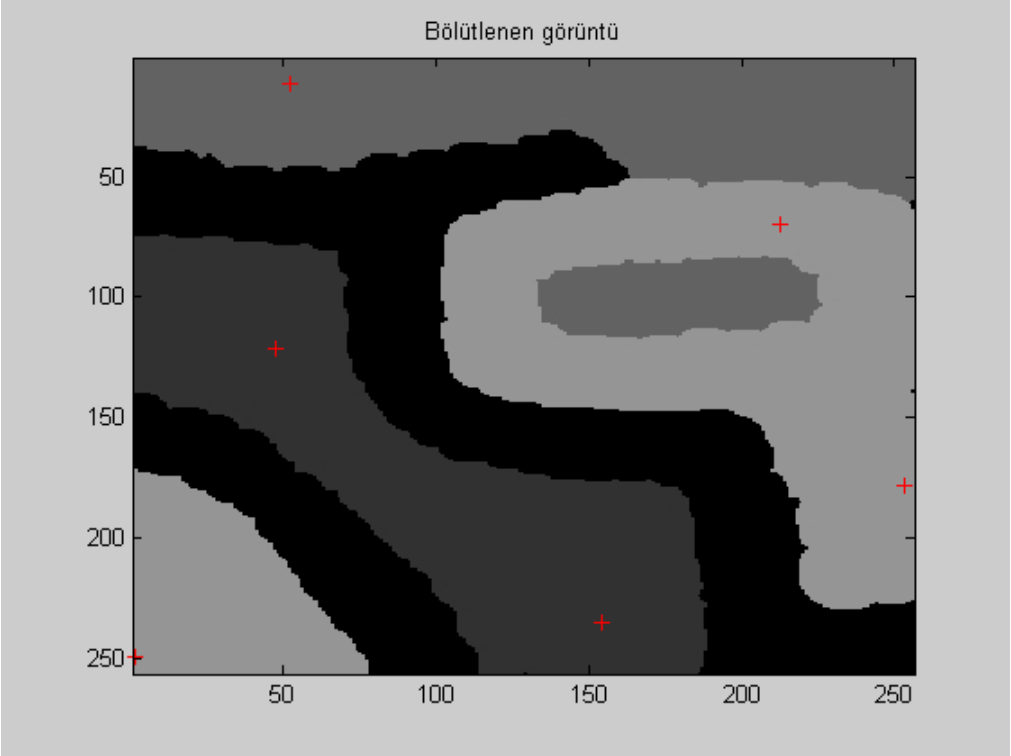
Ağın ürettiği aşırı sayıda düğüm, kullanım sayacı tarafından kontrol edilmektedir. Düğüm kullanım sayacındaki değer, tüm vektör sayısının belirli bir oranının altında ise düğüm ağdan çıkartılır. Böylelikle, sadece belirli bir oranın üzerinde kullanılan düğümler, sınıf olarak tanımlanmaktadır.

Etiketleme işleminden sonra, test kümesinden öznitelik vektörleri ağın girişine verilir. Birinci katmandaki düğümler ile giriş vektörü arasında Euclid mesafeleri hesaplanır. İkinci katmanda düğümlerin sınıf etiketleri saklanmaktadır. Minimum mesafedeki düğümün sınıf etiketi ağın kararı olarak kullanılmaktadır.

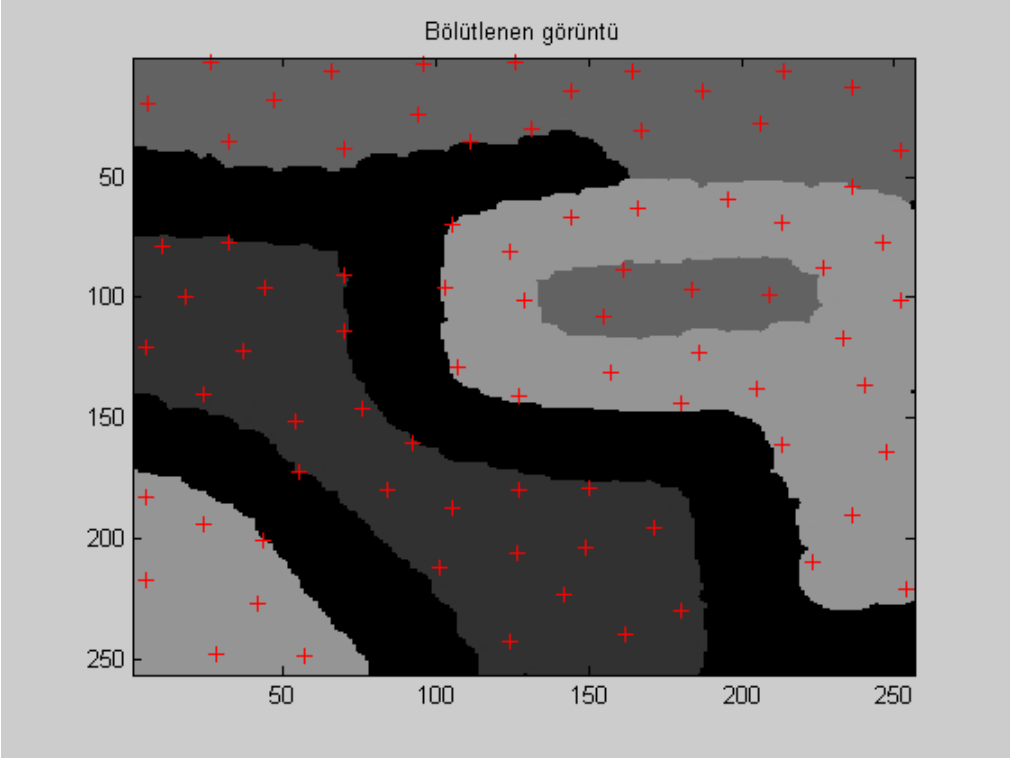
DAYSA'nın düğümleri de öznitelik uzayını GAL ağının bölmelemesine benzer bir şekilde ayırmaktadır. Şekil 4.3'te yapay olarak oluşturulmuş bir fantom görüntü görülmektedir. Görüntüdeki siyah bölgeler herhangi bir sınıfı belirtmemekte, diğer renkli bölgeler ise farklı sınıfları temsil etmektedir. DAYSA'nın oluşturduğu düğümlerin, öznitelik uzayındaki temsilini gösterebilmek amacıyla, bütün sınıflardan rastgele olarak x ve y koordinatları öznitelik olarak alınıp, 2 boyutlu öznitelik vektörleri oluşturulmuştur. Şekil 4.4, 4.5 ve 4.6'da DAYSA'nın farklı eşik değerlerine bağlı olarak oluşturduğu düğümlerin öznitelik uzayındaki dağılımı görülmektedir.



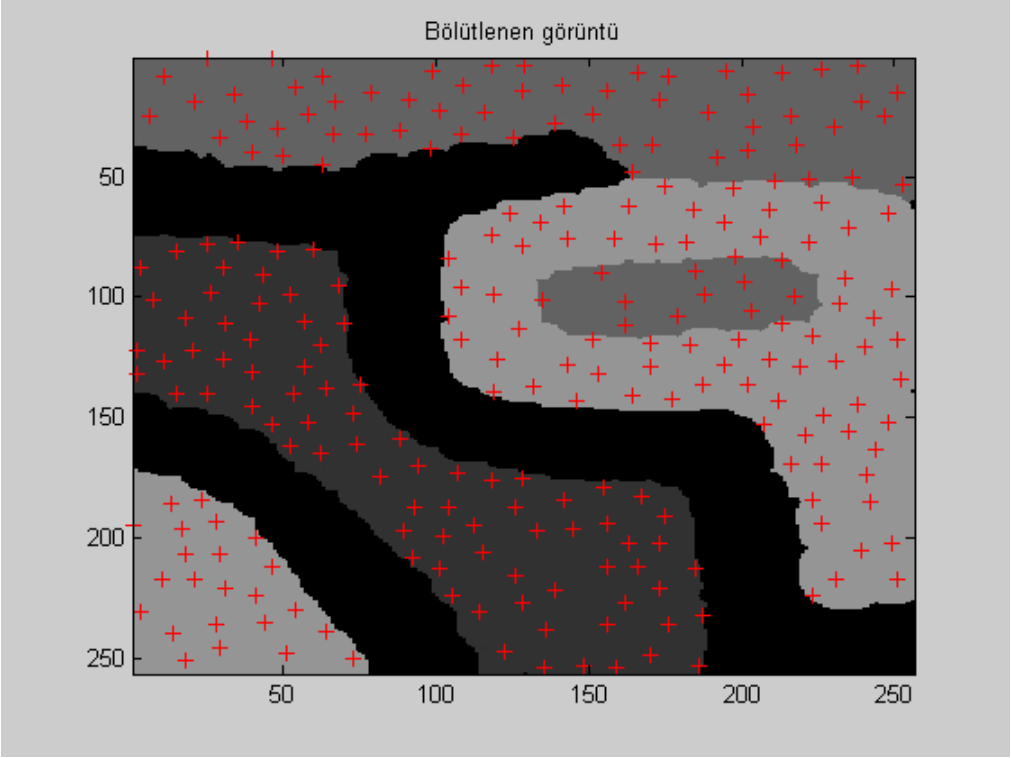
Şekil 4.3 – Yapay olarak oluşturulmuş fantom görüntü



Şekil 4.4 - Eşik (Otomatik) = 109 için histogramdan seçilen 6 düğümün dağılımı



Şekil 4.5 - Eşik = 20 için histogramdan seçilen 80 düğümün dağılımı



Şekil 4.6 - Eşik = 10 için histogramdan seçilen 250 düğümün dağılımı

Şekillerde görüldüğü üzere DAYSA, öznitelik uzayındaki düğümleri, belirli bir eşik (öklit mesafesi) değerine bakarak oluşturmaktadır. Şekil 4.4'te oluşturulan 6

düğümün sınıf sınırlarını belirlemekte yetersiz kaldığı, Şekil 4.5 ve 4.6'da ise, düğüm sayısının artmasıyla birlikte, bu sınırların belirgin hale geldiği (çözünürlüğün arttığı) gözlenebilmektedir. Bu görüntüde öznitelikler, sınıfı temsil eden görüntü koordinatlarının doğrudan alınmasıyla elde edildiği için, sınıflara ait ayırt edici bilgileri içermemektedir.

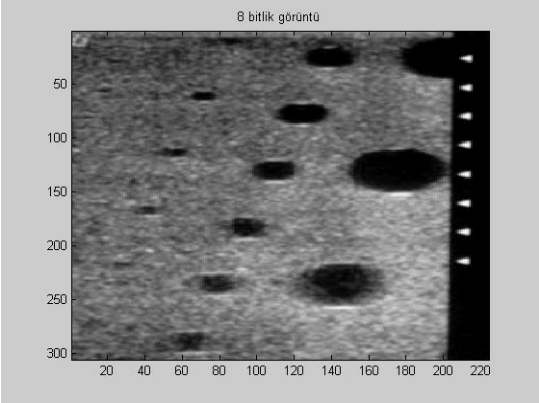
DAYSA ve GAL ağı arasında iki önemli fark bulunmaktadır: DAYSA'nın düğüm ağırlıkları, giriş vektörlerinin elemanları doğrudan alınarak oluşturulur ve eğitim sırasında ağırlıklar değiştirilir. Ayrıca DAYSA'nın eğitici kararlarına ihtiyacı yoktur.

5. YAPAY SİNİR AĞLARI İLE ULTRASONİK GÖRÜNTÜLERİN BÖLÜTLENMESİ

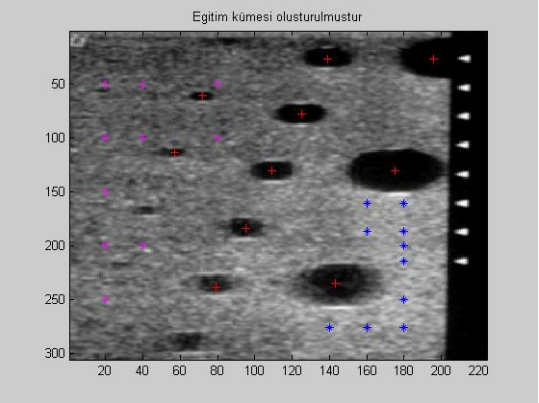
5.1 GAL Ağı ile Sınıflama

5.1.1 Fantom Görüntü

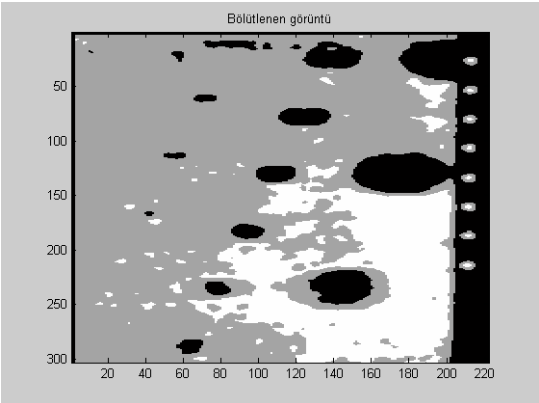
Şekil 5.1'deki orijinal fantom görüntüden Şekil 5.2'de görüldüğü üzere eğitim kümesi oluşturulmuş ve GAL ağı ile bölütleme sonucu Şekil 5.3'te gösterilmiştir. Bölütlemeye ilişkin parametreler Tablo 5.1'de yer almaktadır.



Şekil 5.1-Orijinal fantom görüntüsü



Şekil 5.2-Fantom Eğitim Kümesi (GAL)

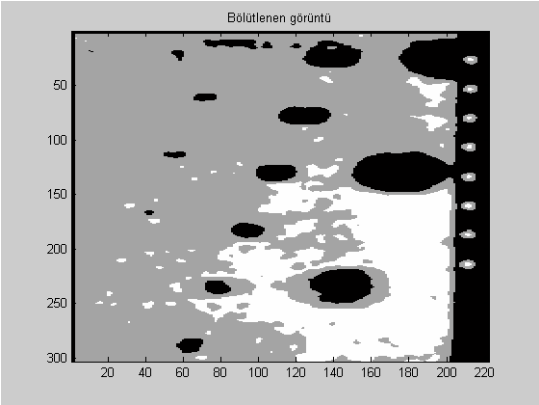


Şekil 5.3-Fantom AKD Bölütlemesi (GAL)

Tablo 5.1-Fantom AKD tablosu (GAL)

Öznitelikler	AKD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 41.45
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	9

Tablo 5.2 parametreleriyle bölütlenen görüntü Şekil 5.4'te yer almaktadır.

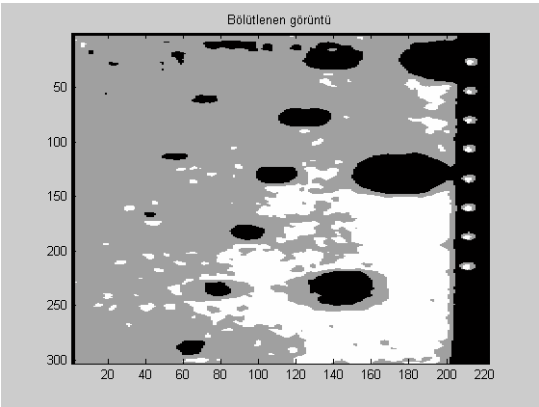


Tablo 5.2-Fantom AFD tablosu (GAL)

Öznitelikler	AFD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0 sn.
Sınıflama Süresi	~ 27.8
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	9

Şekil 5.4-Fantom AFD Bölütlemesi (GAL)

Tablo 5.3 parametreleriyle bölütlenen görüntü Şekil 5.5'te yer almaktadır.

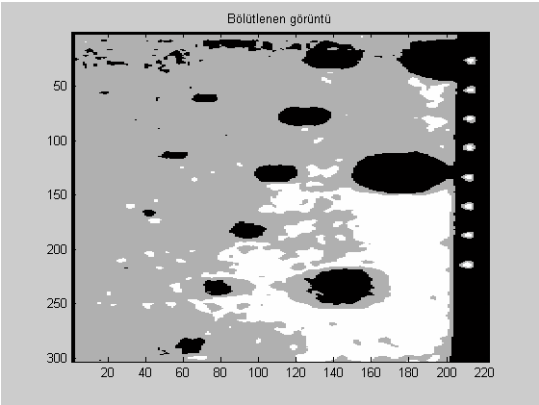


Tablo 5.3-Fantom Gri tablosu (GAL)

Öznitelikler	Gri seviyeleri
Pencere boyutu	5x5
Her sınıftan alınan vektör	10 adet
Eğitim Süresi	~ 0 sn.
Sınıflama Süresi	~ 14.88 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	25

Şekil 5.5-Fantom Gri Bölütlemesi (GAL)

Tablo 5.4 parametreleriyle bölütlenen görüntü Şekil 5.6'te yer almaktadır.



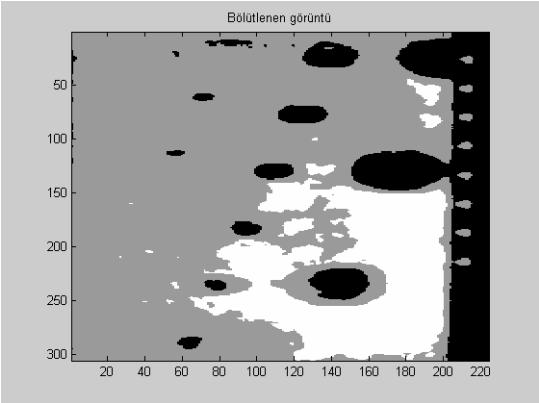
Tablo 5.4-Fantom 3 Gri tablosu (GAL)

Öznitelikler	3 Gri değeri
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 16.44 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	3

Şekil 5.6-Fantom 3 Gri Bölütlemesi (GAL)

Tablo 5.5 parametreleriyle bölütlenen görüntü Şekil 5.7'te yer almaktadır.

Öznitelikler	SDD



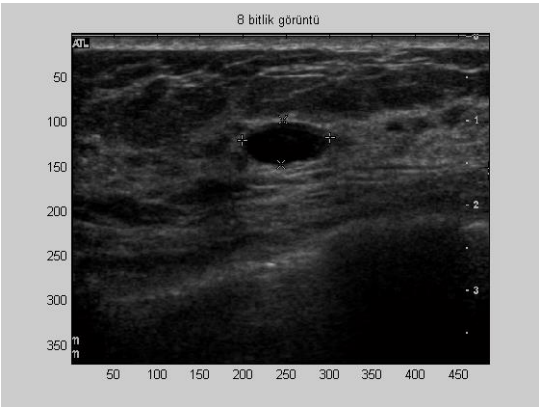
Şekil 5.7-Fantom S.D.D. Bölütlemesi (GAL)

Tablo 5.5-Fantom SDD tablosu (GAL)

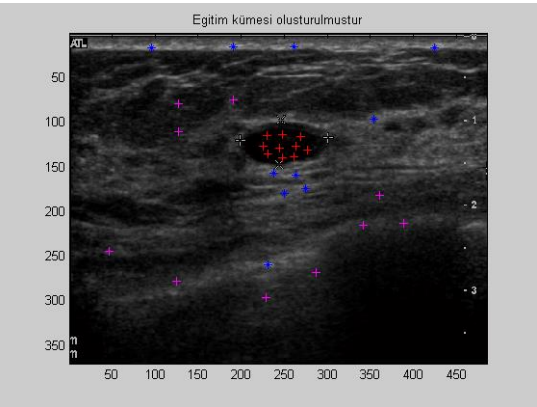
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0 sn.
Sınıflama Süresi	~ 5.49 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	9

5.1.2 Meme Görüntüsü

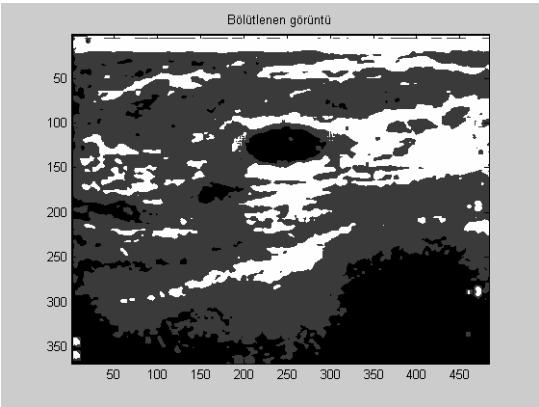
Şekil 5.8'deki orijinal meme görüntüsünden Şekil 5.9'de görüldüğü üzere eğitim kümesi oluşturulmuş ve GAL ağı ile bölütleme sonucu Şekil 5.10'da gösterilmiştir. Bölütlemeye ilişkin parametreler Tablo 5.6'da yer almaktadır.



Şekil 5.8-Orijinal meme görüntüsü



Şekil 5.9- Meme Eğitim Kümesi (GAL)



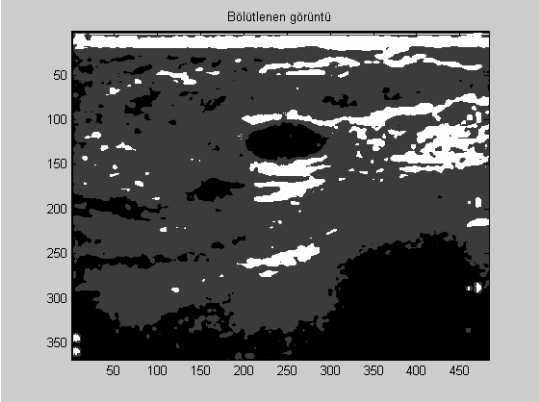
Şekil 5.10-Meme AKD Bölütlemesi (GAL)

Tablo 5.6-Meme AKD tablosu (GAL)

Öznitelikler	AKD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0 sn.
Sınıflama Süresi	~ 108.17 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	9

Meme görüntülerinin bölütlenmesinde kullanılan her öznitelik için farklı eğitim kümesi kullanılmıştır. Sonuçlardaki farklılık eğitim kümesi seçimine de bağlıdır.

Tablo 5.7 parametreleriyle bölütlenen görüntü Şekil 5.11'de yer almaktadır.

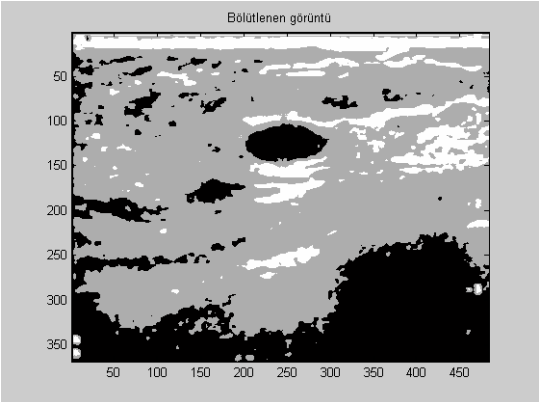


Tablo 5.7-Meme AFD tablosu (GAL)

Öznitelikler	AFD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 71.59 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	9

Şekil 5.11-Meme AFD bölütlemesi (GAL)

Tablo 5.8 parametreleriyle bölütlenen görüntü Şekil 5.12'de yer almaktadır.



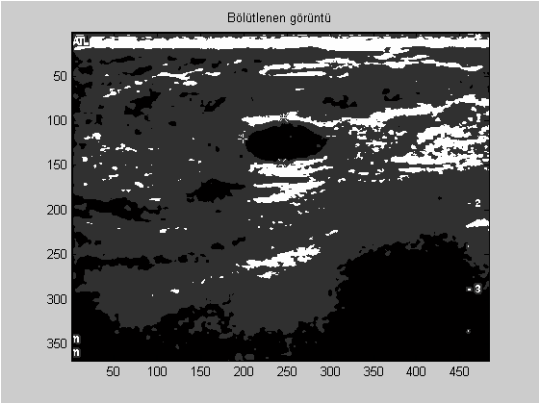
Tablo 5.8-Meme Gri tablosu (GAL)

Öznitelikler	Gri seviyeleri
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.05 sn.
Sınıflama Süresi	~ 41.87 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	4
Öznitelik Sayısı	25

Şekil 5.12-Meme Gri bölütlemesi (GAL)

Tablo 5.9 parametreleriyle bölütlenen görüntü Şekil 5.13'de yer almaktadır.

Öznitelikler	3 Gri değeri

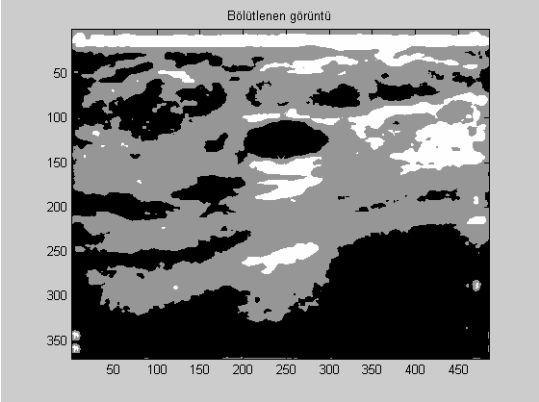


Şekil 5.13-Meme 3 Gri bölütlemesi (GAL)

Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0 sn.
Sınıflama Süresi	~ 43.69 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	3

Tablo 5.9-Meme 3 Gri tablosu (GAL)

Tablo 5.10 parametreleriyle bölütlenen görüntü Şekil 5.14'de yer almaktadır.



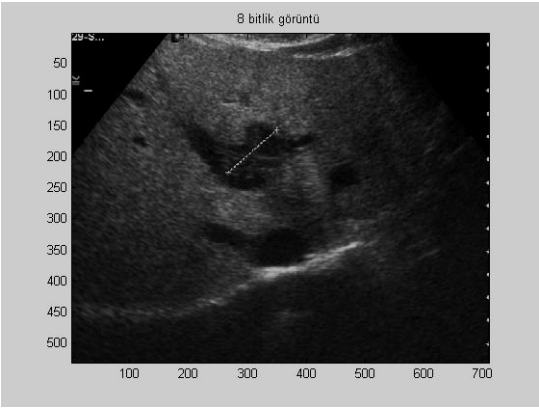
Şekil 5.14-Meme SDD bölütlemesi (GAL)

Tablo 5.10-Meme SDD tablosu (GAL)

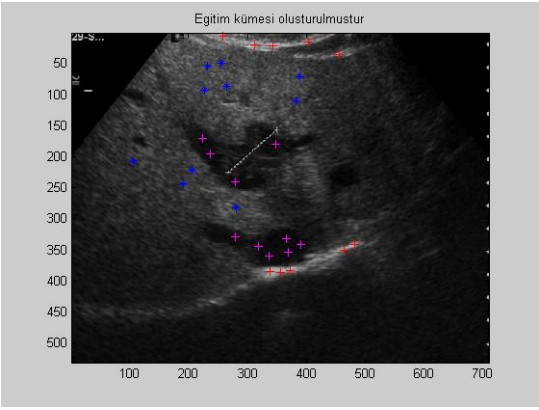
Öznitelikler	SDD
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.1 sn.
Sınıflama Süresi	~ 14.51 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	9

5.1.3 Karın Görüntüsü

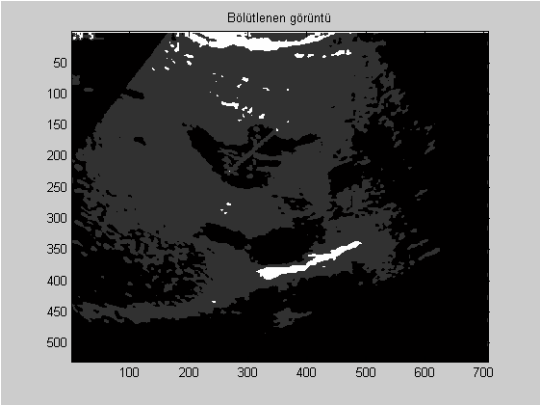
Şekil 5.15'teki orijinal karın görüntüsünden Şekil 5.16'da görüldüğü üzere eğitim kümesi oluşturulmuş ve GAL ağı ile bölütleme sonucu Şekil 5.17'de gösterilmiştir. Bölütlemeye ilişkin parametreler Tablo 5.11'de yer almaktadır.



Şekil 5.15-Orijinal karın görüntüsü



Şekil 5.16- Karın Eğitim Kümesi (GAL)



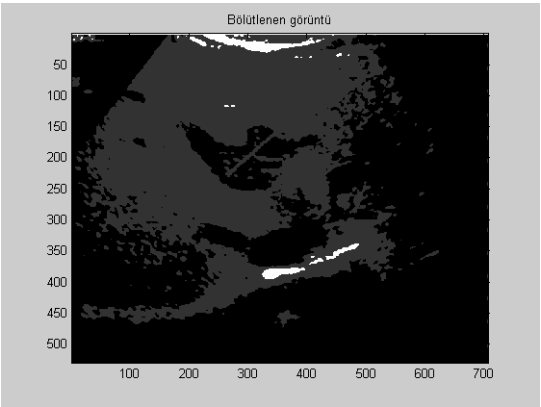
Şekil 5.17-Karın AKD bölütlemesi (GAL)

Tablo 5.11-Karın AKD tablosu (GAL)

Öznitelikler	AKD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0 sn.
Sınıflama Süresi	~ 229.8 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	9

Karın görüntülerinin bölütlenmesinde kullanılan her öznitelik için farklı eğitim kümesi kullanılmıştır. Sonuçlardaki farklılık eğitim kümesi seçimine de bağlıdır.

Tablo 5.12 parametreleriyle bölütlenen görüntü Şekil 5.18'de yer almaktadır.

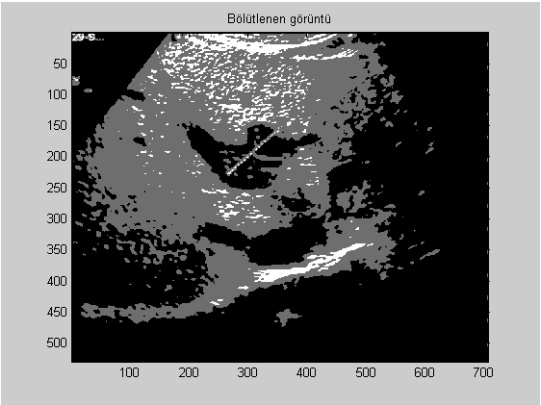


Şekil 5.18-Karın AFD bölütlemesi (GAL)

Tablo 5.12-Karın AFD tablosu (GAL)

Öznitelikler	AFD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 159.36 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	4
Öznitelik Sayısı	9

Tablo 5.13 parametreleriyle bölütlenen görüntü Şekil 5.19'de yer almaktadır.

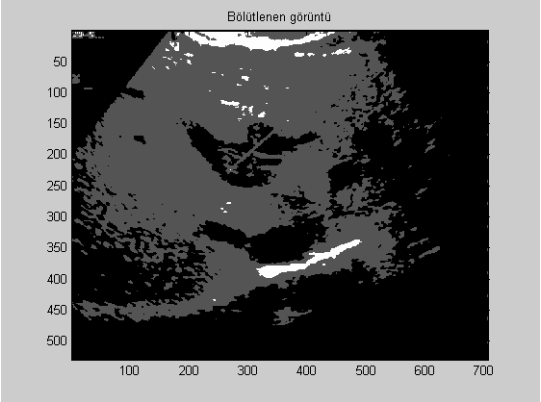


Şekil 5.19-Karın Gri bölütlemesi (GAL)

Tablo 5.13-Karın Gri tablosu (GAL)

Öznitelikler	Gri katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 89.73 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	4
Öznitelik Sayısı	25

Tablo 5.14 parametreleriyle bölütlenen görüntü Şekil 5.20'de yer almaktadır.

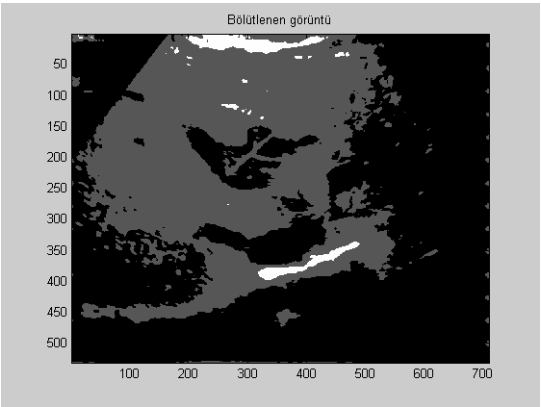


Tablo 5.14-Karın 3 Gri tablosu (GAL)

Öznitelikler	3 Gri değeri
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 100.17 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	4
Öznitelik Sayısı	3

Şekil 5.20-Karın 3 Gri bölütlemesi (GAL)

Tablo 5.15 parametreleriyle bölütlenen görüntü Şekil 5.21'de yer almaktadır.



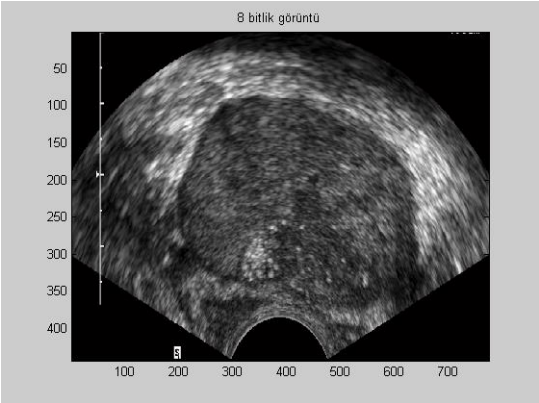
Tablo 5.15-Karın SDD tablosu (GAL)

Öznitelikler	SDD
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0 sn.
Sınıflama Süresi	~ 37.94 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	4
Öznitelik Sayısı	9

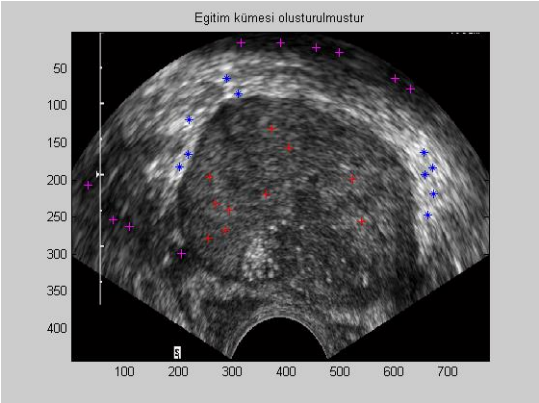
Şekil 5.21-Karın SDD bölütlemesi (GAL)

5.1.4 Prostat Görüntüsü

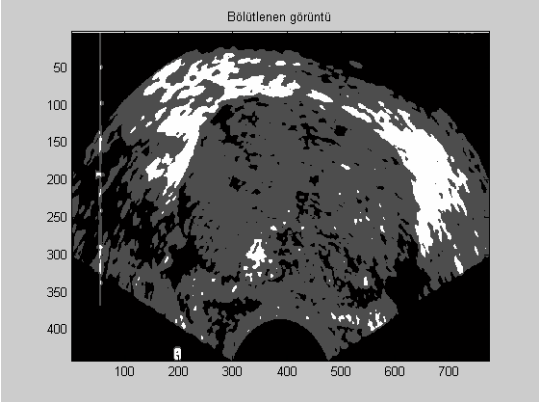
Şekil 5.22'deki orijinal prostat görüntüsünden Şekil 5.23'de görüldüğü üzere eğitim kümesi oluşturulmuş ve GAL ağı ile bölütleme sonucu Şekil 5.24'te gösterilmiştir. Bölütlemeye ilişkin parametreler Tablo 5.16'da yer almaktadır.



Şekil 5.22-Orijinal prostat görüntüsü



Şekil 5.23- Prostat Eğitim Kümesi (GAL)

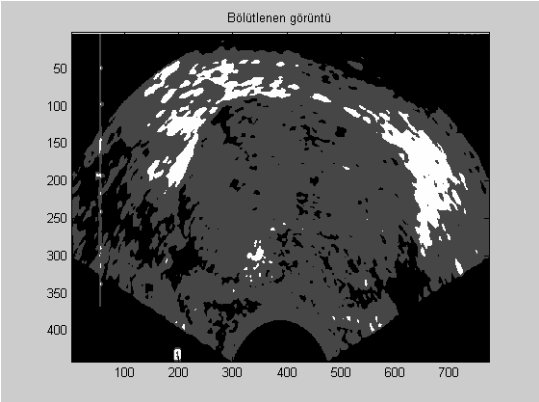


Şekil 5.24-Prostat AKD bölütlemesi (GAL)

Tablo 5.16-Prostat AKD tablosu (GAL)

Öznitelikler	AKD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0 sn.
Sınıflama Süresi	~ 208.96 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	9

Tablo 5.17 parametreleriyle bölütlenen görüntü Şekil 5.25'de yer almaktadır.



Şekil 5.25-Prostat AFD bölütlemesi (GAL)

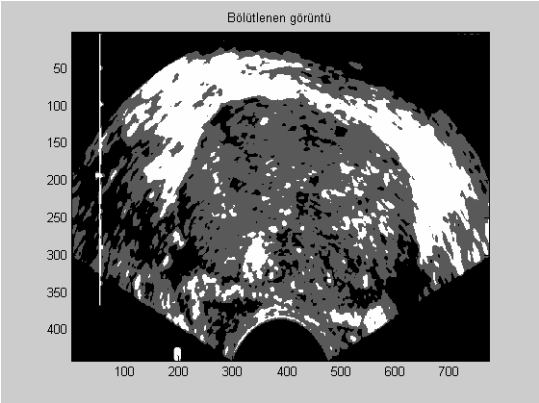
Tablo 5.17-Prostat AFD tablosu (GAL)

Öznitelikler	AFD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0 sn.
Sınıflama Süresi	~ 138.39n.
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	9

Prostat görüntülerinde de, her öznitelik için farklı eğitim kümesi kullanılmıştır.

Tablo 5.18 parametreleriyle bölütlenen görüntü Şekil 5.26'da yer almaktadır.

Öznitelikler	Gri seviyeleri

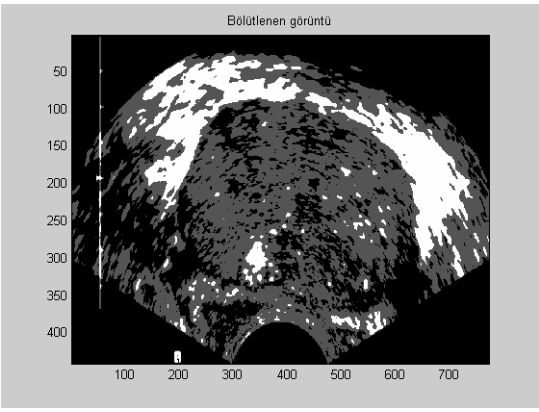


Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 76.31 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	25

Tablo 5.18-Prostat Gri tablosu (GAL)

Şekil 5.26-Prostat Gri bölütlemesi (GAL)

Tablo 5.19 parametreleriyle bölütlenen görüntü Şekil 5.27'da yer almaktadır.

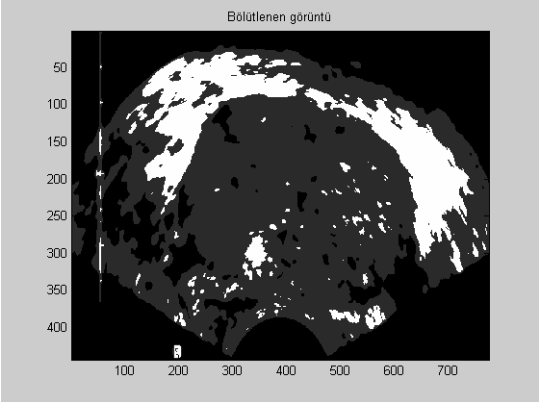


Tablo 5.19-Prostat 3 Gri tablosu (GAL)

Öznitelikler	3 Gri değeri
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 85.45 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	3

Şekil 5.27-Prostat 3 Gri bölütlemesi (GAL)

Tablo 5.20 parametreleriyle bölütlenen görüntü Şekil 5.28'de yer almaktadır.



Tablo 5.20-Prostat SDD tablosu (GAL)

Öznitelikler	SDD
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 28.61 sn.
Belirlenen Sınıf	3
Oluşan Düğüm	3
Öznitelik Sayısı	9

Şekil 5.28-Prostat SDD bölütlemesi (GAL)

5.1.5 GAL Ağı Sınıflama Sonuçları

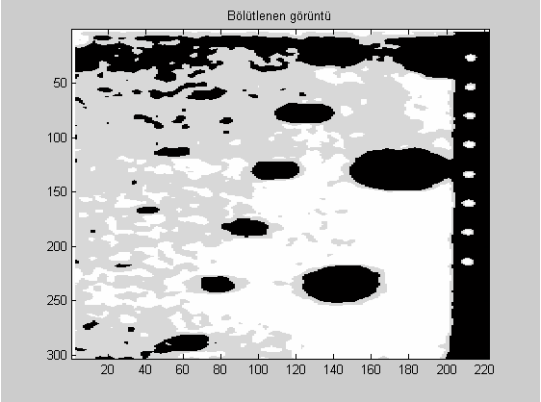
Yapılan çalışmada, oldukça basit ve hızlı olan klasik GAL ağı aynen uygulanmıştır. GAL ağının yapısı, başlangıçta ağa verilen giriş vektörlerinin sırasına çok bağlıdır. Ayrıca, eğitim kümesinin iyi seçilemediği durumlarda uygun olmayan sonuçlar (çok farklı doku yapıları) üretmektedir. Dolayısıyla, US görüntülerde bu ağın kullanılması, ancak tecrübeli operatörler tarafından tercih edilmelidir.

Tezin amaçlarından biri de, doku bölütlemesinin mümkün olduğunca otomatik bir şekilde yapılması olduğundan, GAL ağı bu amacı gerçekleştirme yeteneğinden denetimli bir ağ olması bakımından yoksundur.

5.2 KOHONEN Ağı ile Bölütleme

5.2.1 Fantom Görüntü

Şekil 5.1'deki orijinal fantom görüntüden Şekil 5.2'de görüldüğü üzere eğitim kümesi oluşturulmuş ve Kohonen ağı ile bölütleme sonucu Şekil 5.29'da gösterilmiştir. Bölütlemeye ilişkin parametreler Tablo 5.21'de yer almaktadır.



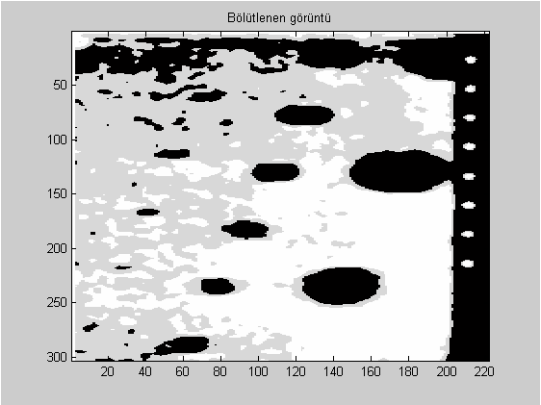
Tablo 5.21-Fantom AKD tablosu (Kohonen)

Öznitelikler	AKD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 43.30 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	9

Şekil 5.29-Fantom AKD Bölütlemesi (Kohonen)

Tablo 5.22 parametreleriyle bölütlenen görüntü Şekil 5.30'da yer almaktadır.

Öznitelikler	AFD katsayıları

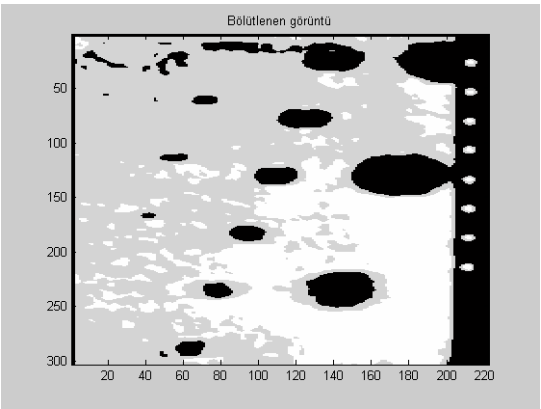


Tablo 5.22-Fantom AFD tablosu (Kohonen)

Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 29.51 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik sayısı	9

Şekil 5.30-Fantom AFD Bölütlemesi (Kohonen)

Tablo 5.23 parametreleriyle bölütlenen görüntü Şekil 5.31'de yer almaktadır.

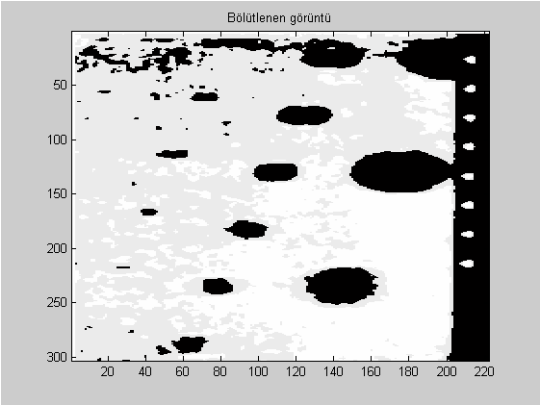


Tablo 5.23-Fantom Gri tablosu (Kohonen)

Öznitelikler	Gri seviyeleri
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 16.52 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik sayısı	25

Şekil 5.31-Fantom Gri Bölütlemesi (Kohonen)

Tablo 5.24 parametreleriyle bölütlenen görüntü Şekil 5.32'de yer almaktadır.



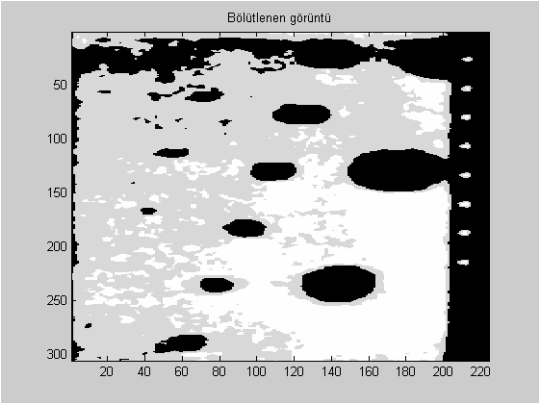
Tablo 5.24-Fantom 3 Gri tablosu (Kohonen)

Öznitelikler	3 Gri değeri
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 20.87 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik sayısı	3

Şekil 5.32-Fantom 3 Gri Bölütlemesi (Kohonen)

Tablo 5.25 parametreleriyle bölütlenen görüntü Şekil 5.33'de yer almaktadır.

Öznitelikler	SDD



Tablo 5.25-Fantom SDD tablosu (Kohonen)

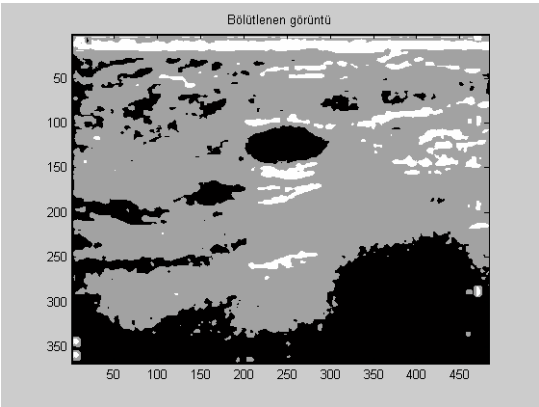
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 9.22 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	9

Şekil 5.33-Fantom SDD Bölütlemesi (Kohonen)

5.2.2 Meme Görüntüsü

Şekil 5.8'deki orijinal meme görüntüsünden her öznitelik için eğitim kümesi oluşturulmuş ve Kohonen ağı ile bölütleme sonuçları gösterilmiştir.

Tablo 5.26 parametreleriyle bölütlenen görüntü Şekil 5.34'te yer almaktadır.

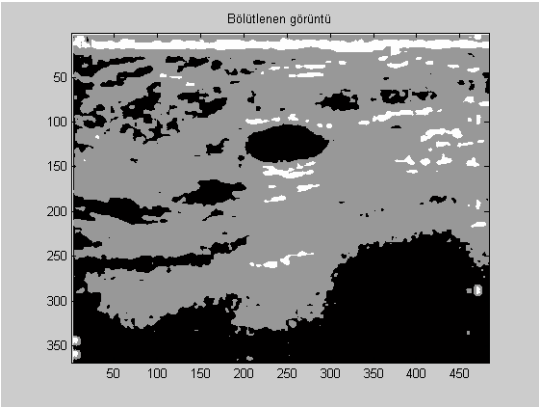


Tablo 5.26-Meme AKD tablosu (Kohonen)

Öznitelikler	AKD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 121.67 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	9

Şekil 5.34-Meme AKD Bölütlemesi (Kohonen)

Tablo 5.27 parametreleriyle bölütlenen görüntü Şekil 5.35'te yer almaktadır.

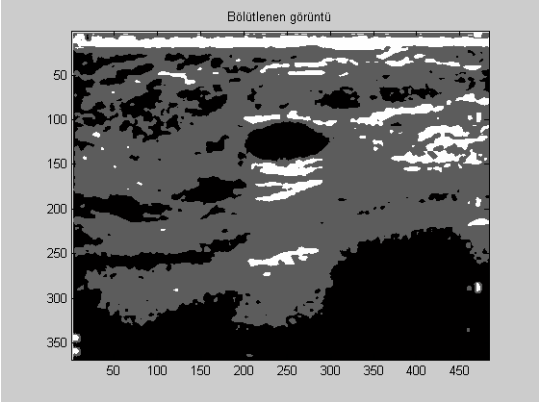


Tablo 5.27-Meme AFD tablosu (Kohonen)

Öznitelikler	AFD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 81.65 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	9

Şekil 5.35-Meme AFD Bölütlemesi (Kohonen)

Tablo 5.28 parametreleriyle bölütlenen görüntü Şekil 5.36'te yer almaktadır.

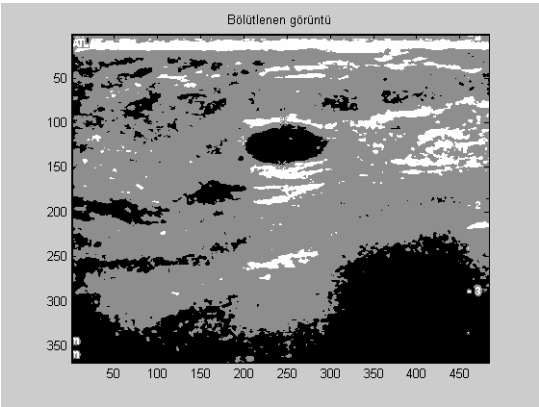


Tablo 5.28-Meme Gri tablosu (Kohonen)

Öznitelikler	Gri seviyeleri
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 44.30 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	25

Şekil 5.36-Meme Gri Bölütlemesi (Kohonen)

Tablo 5.29 parametreleriyle bölütlenen görüntü Şekil 5.37'de yer almaktadır.

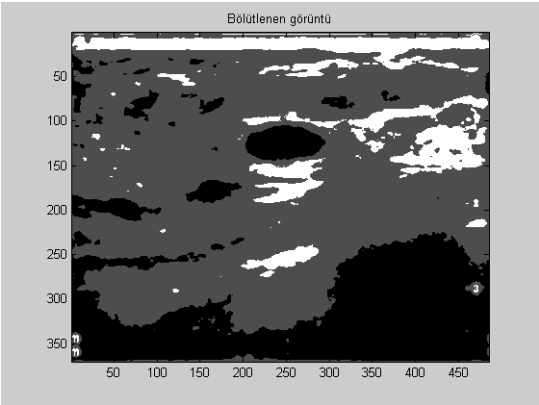


Tablo 5.29-Meme 3 Gri tablosu (Kohonen)

Öznitelikler	3 Gri değeri
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 53.31 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	3

Şekil 5.37-Meme 3 Gri Bölütlemesi (Kohonen)

Tablo 5.30 parametreleriyle bölütlenen görüntü Şekil 5.38'de yer almaktadır.



Tablo 5.30-Meme SDD tablosu (Kohonen)

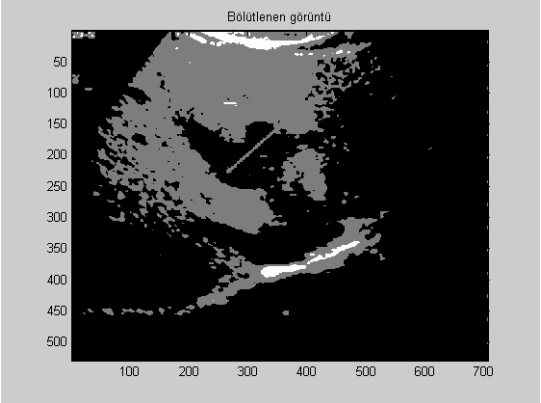
Öznitelikler	SDD
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 24.18 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	9

Şekil 5.38-Meme SDD Bölütlemesi (Kohonen)

5.2.3 Karın Görüntüsü

Şekil 5.15'teki orijinal karın görüntüsünden her öznitelik için eğitim kümesi oluşturulmuş ve Kohonen ağı ile bölütleme sonuçları gösterilmiştir.

Tablo 5.31 parametreleriyle bölütlenen görüntü Şekil 5.39'de yer almaktadır.

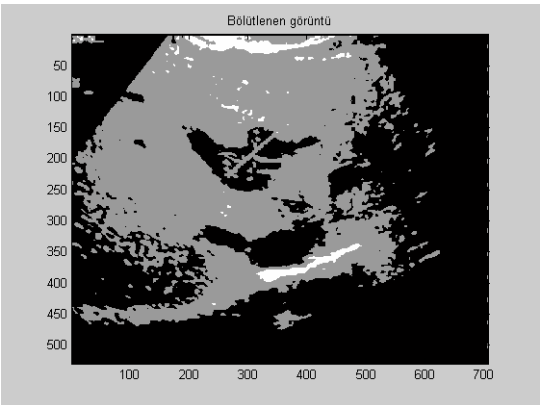


Tablo 5.31-Karın AKD tablosu (Kohonen)

Öznitelikler	AKD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 245.32 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	9

Şekil 5.39-Karın AKD Bölütlemesi (Kohonen)

Tablo 5.32 parametreleriyle bölütlenen görüntü Şekil 5.40'ta yer almaktadır.



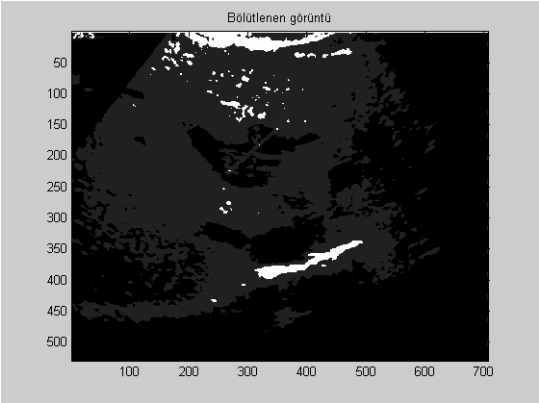
Tablo 5.32-Karın AFD tablosu (Kohonen)

Öznitelikler	AFD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.02 sn.
Sınıflama Süresi	~ 175.15 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik sayısı	9

Şekil 5.40-Karın AFD Bölütlemesi (Kohonen)

Tablo 5.33 parametreleriyle bölütlenen görüntü Şekil 5.41'de yer almaktadır.

Öznitelikler	Gri seviyeleri

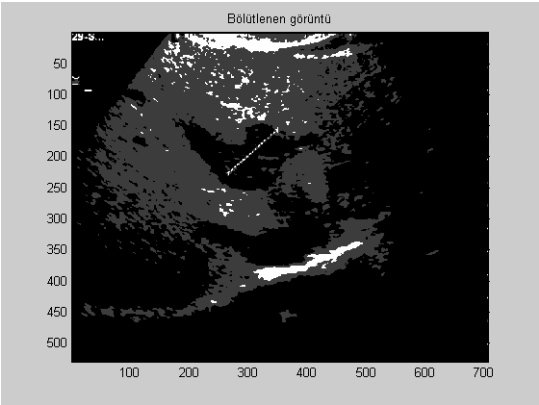


Tablo 5.33-Karın Gri tablosu (Kohonen)

Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 106.52 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	25

Şekil 5.41-Karın Gri Bölütlemesi (Kohonen)

Tablo 5.34 parametreleriyle bölütlenen görüntü Şekil 5.42'de yer almaktadır.

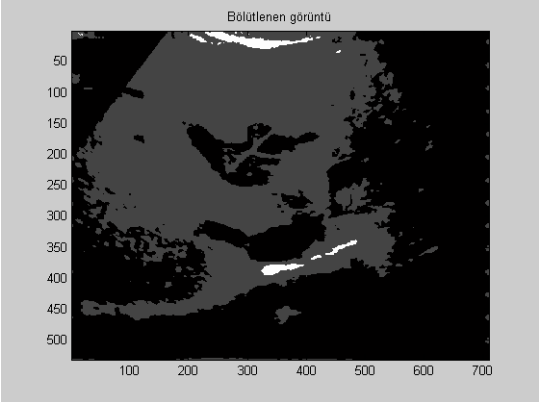


Tablo 5.34-Karın 3 Gri tablosu (Kohonen)

Öznitelikler	3 Gri değeri
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 114.09 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	3

Şekil 5.42-Karın 3 Gri Bölütlemesi (Kohonen)

Tablo 5.35 parametreleriyle bölütlenen görüntü Şekil 5.43'te yer almaktadır.



Tablo 5.35-Karın SDD tablosu (Kohonen)

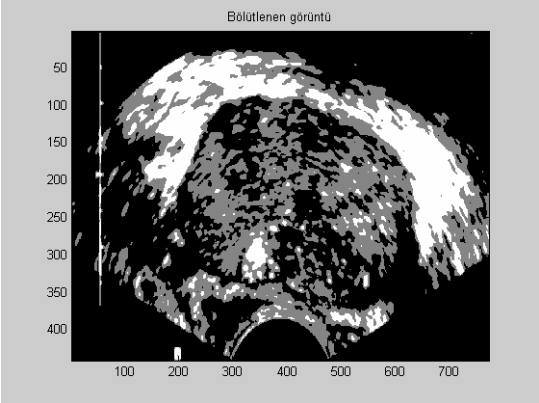
Öznitelikler	SDD
Vektör Sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 58.22 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	9

Şekil 5.43-Karın SDD Bölütlemesi (Kohonen)

5.2.4 Prostat Görüntüsü

Şekil 5.22'deki orijinal prostat görüntüsünden her öznitelik için eğitim kümesi oluşturulmuş ve Kohonen ağı ile bölütleme sonuçları gösterilmiştir.

Tablo 5.36 parametreleriyle bölütlenen görüntü Şekil 5.44'te yer almaktadır.

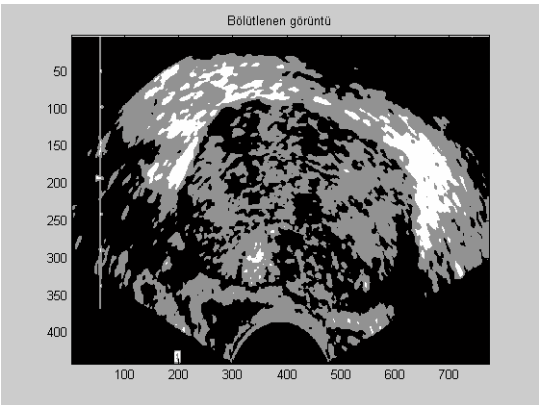


Tablo 5.36-Prostat AKD tablosu (Kohonen)

Öznitelikler	AKD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 230.25 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	9

Şekil 5.44- Prostat AKD Bölütlemesi (Kohonen)

Tablo 5.37 parametreleriyle bölütlenen görüntü Şekil 5.45'te yer almaktadır.



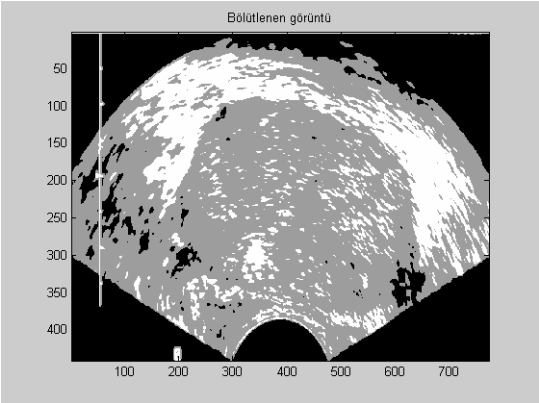
Tablo 5.37-Prostat AFD tablosu (Kohonen)

Öznitelikler	AFD katsayıları
Pencere boyutu	5x5
Vektör sayısı	10'ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 155.15 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	9

Şekil 5.45- Prostat AFD Bölütlemesi (Kohonen)

Tablo 5.38 parametreleriyle bölütlenen görüntü Şekil 5.46'da yer almaktadır.

Öznitelikler	Gri seviyeleri

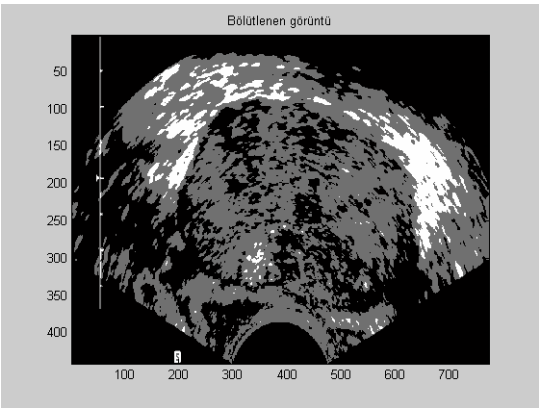


Tablo 5.38-Prostat Gri tablosu (Kohonen)

Pencere boyutu	5x5
Vektör sayısı	10’ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 94.73 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	25

Şekil 5.46- Prostat Gri Bölütlemesi (Kohonen)

Tablo 5.39 parametreleriyle bölütlenen görüntü Şekil 5.47’de yer almaktadır.

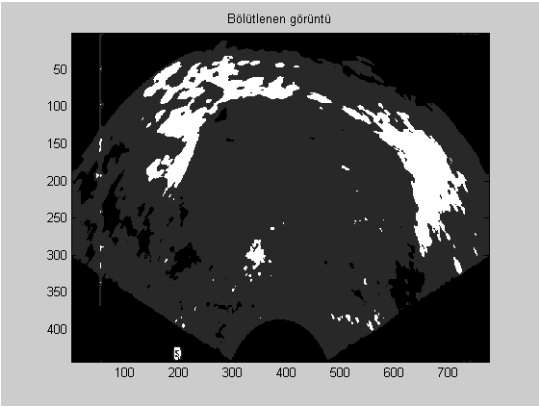


Tablo 5.39-Prostat 3 Gri tablosu (Kohonen)

Öznitelikler	3 Gri değeri
Pencere boyutu	5x5
Vektör sayısı	10’ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 90.03 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	3

Şekil 5.47- Prostat 3 Gri Bölütlemesi (Kohonen)

Tablo 5.40 parametreleriyle bölütlenen görüntü Şekil 5.48’de yer almaktadır.



Tablo 5.40-Prostat SDD tablosu (Kohonen)

Öznitelikler	SDD
Vektör sayısı	10’ar adet
Eğitim Süresi	~ 0.01 sn.
Sınıflama Süresi	~ 42.7 sn.
Kazanç değeri	0.5
Belirlenen Sınıf	3
Düğüm Sayısı	3 x 3
Öznitelik Sayısı	9

Şekil 5.48-Prostat SDD Bölütlemesi (Kohonen)

5.2.5 KOHONEN Ağı Sınıflama Sonuçları

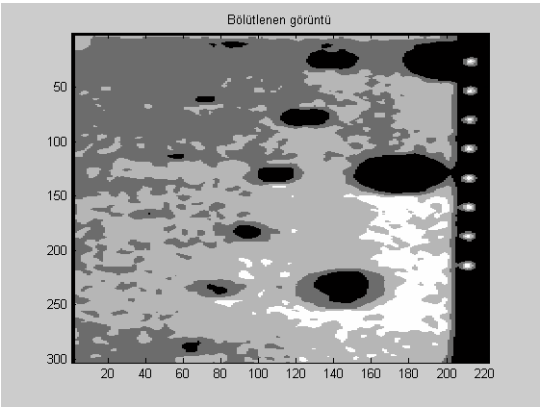
Yapılan çalışmada, klasik KOHONEN ağına ilave olarak, (varsa) kullanılmayan düğümlerin çıkarılması işlemi uygulanmıştır. Böylelikle, kullanılmayan düğüm olmadığı durumlarda, sınıflama zamanının bir miktar düşürülmesi imkânı getirilmektedir.

KOHONEN ile elde edilen bölütleme sonuçlarında, sınıfları temsil eden renklerin değişimleri göz önüne alındığında, iç yapısını her zaman optimum bir şekilde uyarlayamadığı anlaşılmıştır. Farklı görüntüler için optimum düğüm sayısının ne olması gerektiğinin bilinmemesi ağın en büyük dezavantajı olarak değerlendirilmektedir.

5.3 DAYSA ile Sınıflama

5.3.1 Fantom Görüntü

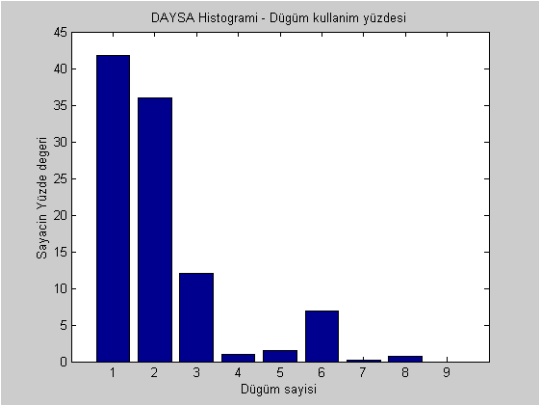
Şekil 5.1'deki orijinal fantom görüntünün DAYSA ile bölütleme sonucu Şekil 5.49'da gösterilmiştir. Ağın oluşturduğu histogram Şekil 5.50'de görülmektedir. Bölütlemeye ilişkin parametreler Tablo 5.41'de yer almaktadır.



Şekil 5.49-Fantom AKD Bölütlemesi (DAYSA)

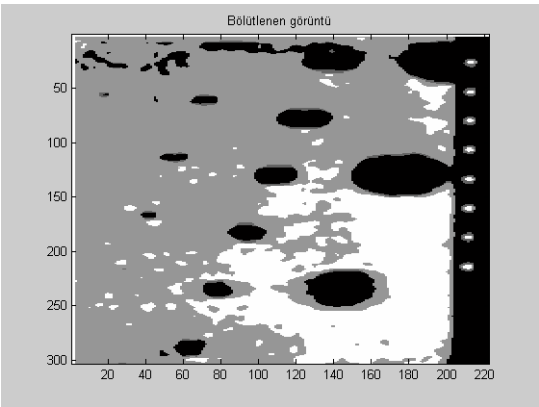
Tablo 5.41-Fantom AKD tablosu (DAYSA)

Öznitelikler	AKD katsayıları
Pencere boyutu	5x5
Kullanılan vektör	700 rastgele
Eğitim Süresi	~ 0.69 sn.
Sınıflama Süresi	~ 42.23 sn.
Eşik (Otomatik)	~ 216.36
Kazanç değeri	0.1
Sınıf Sayısı	4
Düğüm Sayısı	9
Öznitelik Sayısı	9



Şekil 5.50-Fantom AKD Histogram (DAYSA)

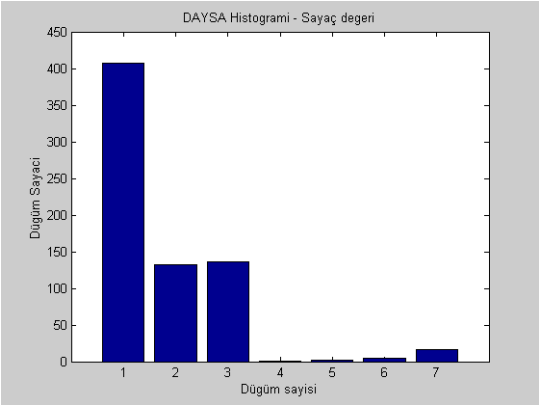
Tablo 5.42 parametreleriyle bölütlenen görüntü ve ağın oluşturduğu histogram, Şekil 5.51 ve Şekil 5.52'de yer almaktadır.



Şekil 5.51-Fantom AFD Bölütlemesi (DAYSA)

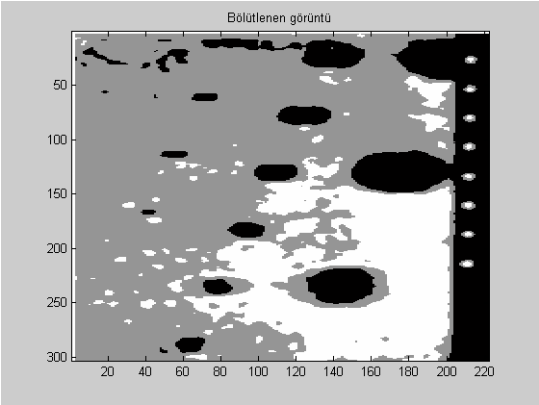
Tablo 5.42-Fantom AFD tablosu (DAYSA)

Öznitelikler	AFD katsayıları
Pencere boyutu	5x5
Kullanılan vektör	700 rastgele
Eğitim Süresi	~ 0.48 sn.
Sınıflama Süresi	~ 27.72 sn.
Eşik (Otomatik)	~ 1136.4
Kazanç değeri	0.1
Sınıf Sayısı	3
Düğüm Sayısı	7
Öznitelik Sayısı	9



Şekil 5.52-Fantom AFD Histogram (DAYSA)

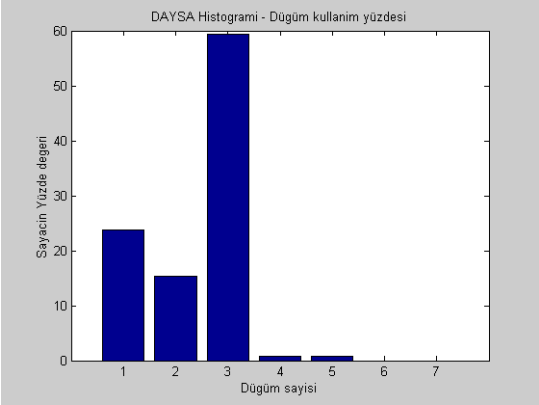
Tablo 5.43 parametreleriyle bölütlenen görüntü ve ağın oluşturduğu histogram, Şekil 5.53 ve Şekil 5.54'te yer almaktadır.



Şekil 5.53-Fantom Gri Bölütlemesi (DAYSA)

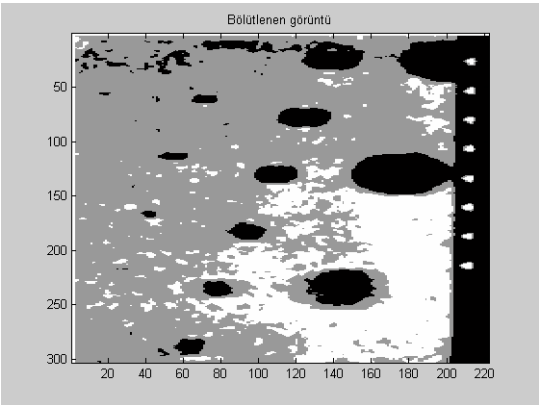
Tablo 5.43-Fantom Gri tablosu (DAYSA)

Öznitelikler	Gri seviyeleri
Pencere boyutu	5x5
Kullanılan vektör	700 rastgele
Eğitim Süresi	~ 0.26 sn.
Sınıflama Süresi	~ 15.24 sn.
Eşik (Otomatik)	~ 250.36
Kazanç değeri	0.1
Sınıf Sayısı	3
Düğüm Sayısı	7
Öznitelik Sayısı	25



Şekil 5.54-Fantom Gri Histogram (DAYSA)

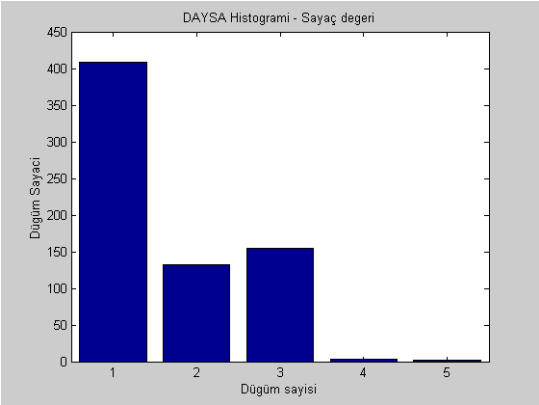
Tablo 5.44 parametreleriyle bölütlenen görüntü ve ağın oluşturduğu histogram, Şekil 5.55 ve Şekil 5.56'da yer almaktadır.



Şekil 5.55-Fantom 3 Gri Bölütlemesi (DAYSA)

Tablo 5.44-Fantom 3 Gri tablosu (DAYSA)

Öznitelikler	3 Gri değeri
Pencere boyutu	5x5
Kullanılan vektör	700 rastgele
Eğitim Süresi	~ 0.27 sn.
Sınıflama Süresi	~ 16.86 sn.
Eşik (Otomatik)	~ 65.49
Kazanç değeri	0.1
Sınıf Sayısı	3
Düğüm Sayısı	5
Öznitelik Sayısı	3

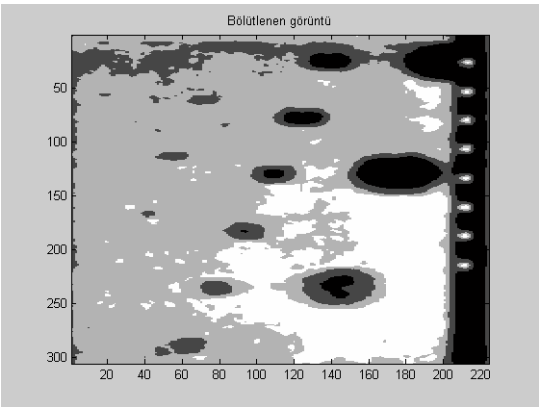


Şekil 5.56-Fantom 3 Gri Histogram (DAYSA)

Aynı görüntüde komşuluğun iki yerine bir alınmasıyla elde edilen görüntü ve ağ histogramı Şekil A.1 ve Şekil A.2'de gösterilmiştir.

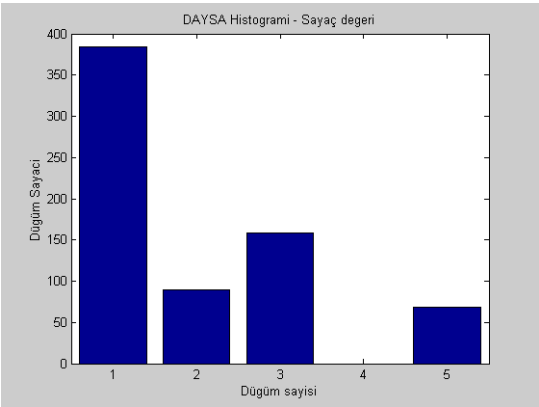
Tablo 5.45 parametreleriyle bölütlenen görüntü ve ağın oluşturduğu histogram, Şekil 5.57 ve Şekil 5.58'de yer almaktadır.

Tablo 5.45-Fantom SDD tablosu (DAYSA)



Öznitelikler	SDD
Kullanılan vektör	700 rastgele
Eğitim Süresi	~ 1.42 sn.
Sınıflama Süresi	~ 6.87 sn.
Eşik (Otomatik)	~ 157.55
Kazanç değeri	0.1
Sınıf Sayısı	4
Düğüm Sayısı	5
Öznitelik Sayısı	9

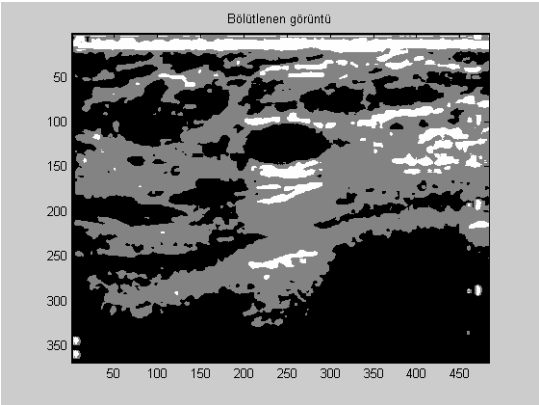
Şekil 5.57-Fantom SDD Bölütlemesi (DAYSA)



Şekil 5.58-Fantom SDD Histogram (DAYSA)

5.3.2 Meme Görüntüsü

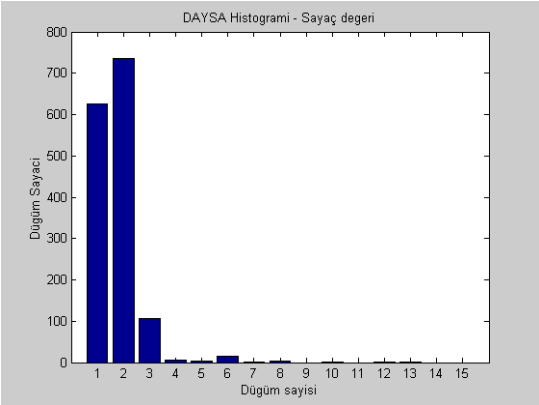
Şekil 5.8'deki orijinal meme görüntünün DAYSA ile bölütleme sonucu Şekil 5.59'da gösterilmiştir. Ağın oluşturduğu histogram Şekil 5.60'da görülmektedir. Bölütlemeye ilişkin parametreler Tablo 5.46'da yer almaktadır.



Şekil 5.59-Meme AKD Bölütlemesi (DAYSA)

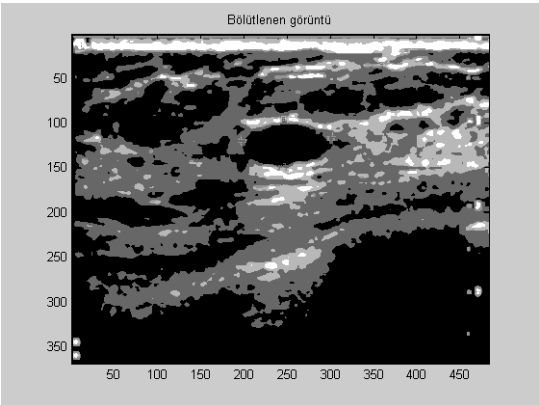
Tablo 5.46-Meme AKD tablosu (DAYSA)

Öznitelikler	AKD katsayıları
Pencere boyutu	5x5
Kullanılan vektör	1500 rastgele
Eğitim Süresi	~ 1.24 sn.
Sınıflama Süresi	~ 109.3 sn.
Eşik (Otomatik)	~ 150.33
Kazanç değeri	0.1
Sınıf Sayısı	3
Düğüm Sayısı	15
Öznitelik Sayısı	9



Şekil 5.60-Meme AKD Histogram (DAYSA)

Tablo 5.47 parametreleriyle bölütlenen görüntü Şekil 5.61'de yer almaktadır.



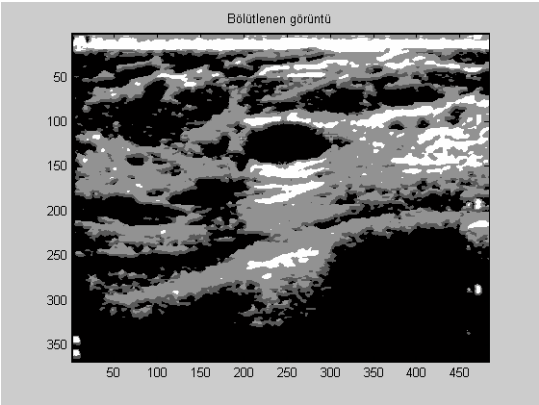
Şekil 5.61-Meme AFD Bölütlemesi (DAYSA)

Tablo 5.47-Meme AFD tablosu (DAYSA)

Öznitelikler	AFD katsayıları
Pencere boyutu	5x5
Kullanılan vektör	1500 rastgele
Eğitim Süresi	~ 0.92 sn.
Sınıflama Süresi	~ 78.17 sn.
Eşik (Otomatik)	~ 555.98
Kazanç değeri	0.1
Sınıf Sayısı	5
Düğüm Sayısı	14
Öznitelik Sayısı	9

Ağın oluşturduğu histogram Şekil A.3'te görülmektedir.

Tablo 5.48 parametreleriyle bölütlenen görüntü Şekil 5.62'de yer almaktadır.



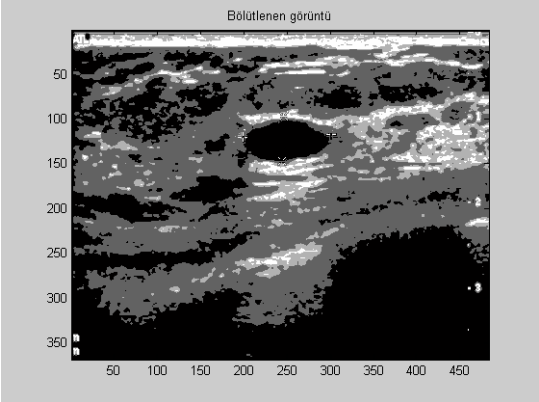
Şekil 5.62-Meme Gri Bölütlemesi (DAYSA)

Tablo 5.48-Meme Gri tablosu (DAYSA)

Öznitelikler	Gri seviyeleri
Pencere boyutu	5x5
Kullanılan vektör	1500 rastgele
Eğitim Süresi	~ 0.96 sn.
Sınıflama Süresi	~ 43.87 sn.
Eşik (Otomatik)	~ 143.13
Kazanç değeri	0.1
Sınıf Sayısı	4
Düğüm Sayısı	38
Öznitelik Sayısı	25

Ağın oluşturduğu histogram Şekil A.4'te görülmektedir.

Tablo 5.49 parametreleriyle bölütlenen görüntü Şekil 5.63'te yer almaktadır.



Şekil 5.63-Meme 3 Gri Bölütlemesi (DAYSA)

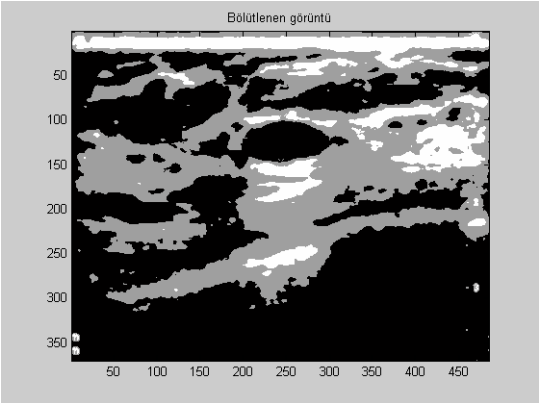
Tablo 5.49-Meme 3 Gri tablosu (DAYSA)

Öznitelikler	3 Gri değeri
Pencere boyutu	5x5
Kullanılan vektör	1500 rastgele
Eğitim Süresi	~ 0.59 sn.
Sınıflama Süresi	~ 47.70 sn.
Eşik (Otomatik)	~ 38.98
Kazanç değeri	0.1
Sınıf Sayısı	4
Düğüm Sayısı	7
Öznitelik Sayısı	3

Ağın oluşturduğu histogram Şekil A.5'te görülmektedir.

Tablo 5.50 parametreleriyle bölütlenen görüntü Şekil 5.64'te yer almaktadır.

Ağın oluşturduğu histogram Şekil A.6'da görülmektedir.



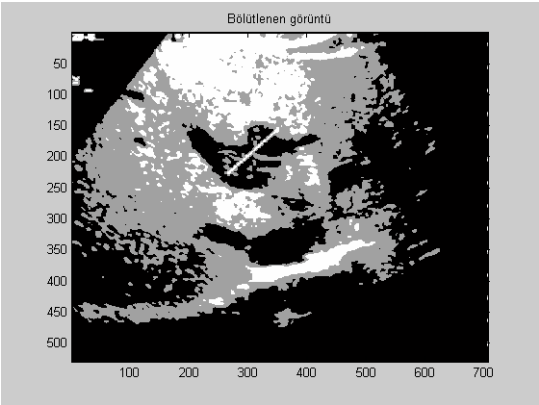
Şekil 5.64-Meme SDD Bölütlemesi (DAYSA)

Tablo 5.50-Meme SDD tablosu (DAYSA)

Öznitelikler	SDD
Kullanılan vektör	1500 rastgele
Eğitim Süresi	~ 4.33 sn.
Sınıflama Süresi	~ 15.91 sn.
Eşik (Otomatik)	~ 134.79
Kazanç değeri	0.1
Sınıf Sayısı	3
Düğüm Sayısı	6
Öznitelik Sayısı	9

5.3.3 Karın Görüntüsü

Şekil 5.15'teki orijinal karın görüntünün DAYSA ile bölütleme sonucu Şekil 5.65'te gösterilmiştir. Bölütlemeye ilişkin parametreler Tablo 5.51'de yer almaktadır.



Şekil 5.65-Karın AKD Bölütlemesi (DAYSA)

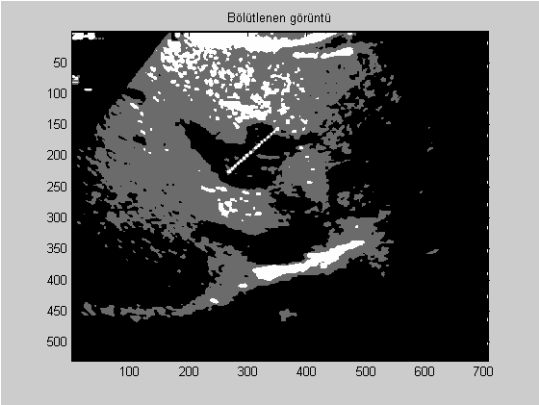
Tablo 5.51-Karın AKD tablosu (DAYSA)

Öznitelikler	AKD katsayıları
Pencere boyutu	5x5
Kullanılan vektör	3000 rastgele
Eğitim Süresi	~ 2.78 sn.
Sınıflama Süresi	~ 230.29 sn.
Eşik (Otomatik)	~ 128.44
Kazanç değeri	0.1
Sınıf Sayısı	3
Düğüm Sayısı	19
Öznitelik Sayısı	9

Ağın oluşturduğu histogram Şekil B.1'de görülmektedir.

Tablo 5.52 parametreleriyle bölütlenen görüntü Şekil 5.66'da yer almaktadır.

Ağın oluşturduğu histogram Şekil B.2'de görülmektedir.



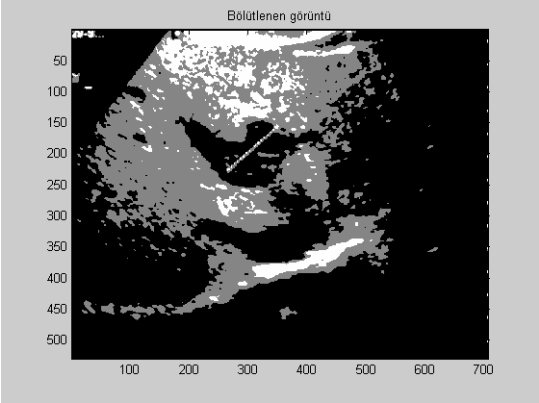
Şekil 5.66-Karın AFD Bölütlemesi (DAYSA)

Tablo 5.52-Karın AFD tablosu (DAYSA)

Öznitelikler	AFD katsayıları
Pencere boyutu	5x5
Kullanılan vektör	3000 rastgele
Eğitim Süresi	~ 1.96 sn.
Sınıflama Süresi	~ 154.08 sn.
Eşik (Otomatik)	~ 813.79
Kazanç değeri	0.1
Sınıf Sayısı	3
Düğüm Sayısı	13
Öznitelik Sayısı	9

Tablo 5.53 parametreleriyle bölütlenen görüntü Şekil 5.67'de yer almaktadır.

Ağın oluşturduğu histogram Şekil B.3'te görülmektedir.

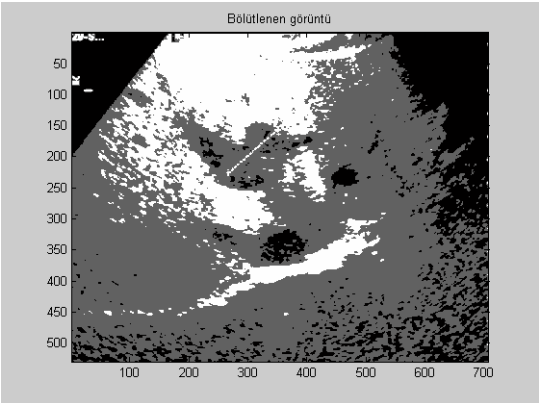


Şekil 5.67-Karın Gri Bölütlemesi (DAYSA)

Tablo 5.53-Karın Gri tablosu (DAYSA)

Öznitelikler	Gri seviyeleri
Pencere boyutu	5x5
Kullanılan vektör	3000 rastgele
Eğitim Süresi	~ 1.39 sn.
Sınıflama Süresi	~ 88.02 sn.
Eşik (Otomatik)	~ 138.89
Kazanç değeri	0.1
Sınıf Sayısı	3
Düğüm Sayısı	21
Öznitelik Sayısı	25

Tablo 5.54 parametreleriyle bölütlenen görüntü Şekil 5.68'de yer almaktadır.



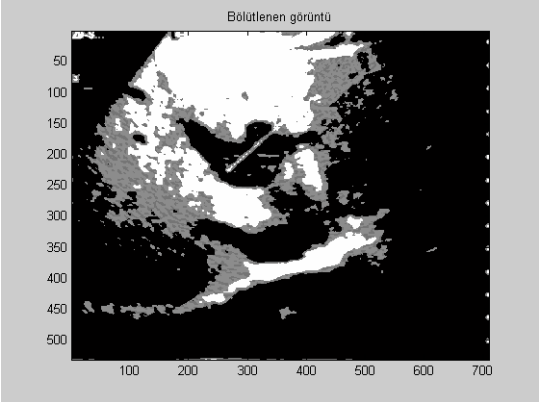
Şekil 5.68-Karın 3 Gri Bölütlemesi (DAYSA)

Tablo 5.54-Karın 3 Gri tablosu (DAYSA)

Öznitelikler	3 Gri değeri
Pencere boyutu	5x5
Kullanılan vektör	3000 rastgele
Eğitim Süresi	~ 1.29 sn.
Sınıflama Süresi	~ 96.32 sn.
Eşik (Otomatik)	~ 35.49
Kazanç değeri	0.1
Sınıf Sayısı	3
Düğüm Sayısı	13
Öznitelik Sayısı	3

Ağın oluşturduğu histogram Şekil B.4'te görülmektedir.

Tablo 5.55 parametreleriyle bölütlenen görüntü Şekil 5.69'da yer almaktadır.



Tablo 5.55-Karın SDD tablosu (DAYSA)

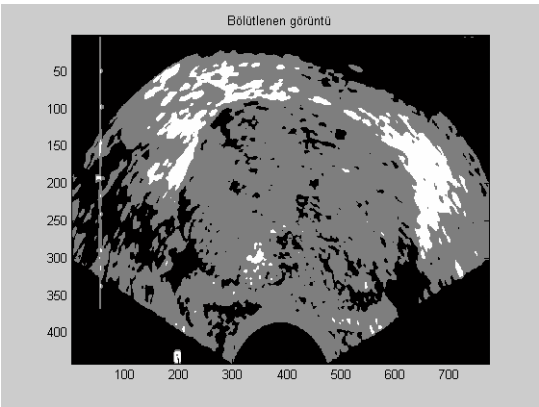
Öznitelikler	SDD
Kullanılan vektör	3000 rastgele
Eğitim Süresi	~ 11.63 sn.
Sınıflama Süresi	~ 40.10 sn.
Eşik (Otomatik)	~ 117.35
Kazanç değeri	0.1
Sınıf Sayısı	4
Düğüm Sayısı	9
Öznitelik Sayısı	9

Şekil 5.69-Karın SDD Bölütlemesi (DAYSA)

Ağın oluşturduğu histogram Şekil B.5'te görülmektedir.

5.3.4 Prostat Görüntüsü

Şekil 5.22'deki orijinal prostat görüntünün DAYSA ile bölütleme sonucu Şekil 5.70'te gösterilmiştir. Bölütlemeye ilişkin parametreler Tablo 5.56'da yer almaktadır.



Tablo 5.56-Prostat AKD tablosu (DAYSA)

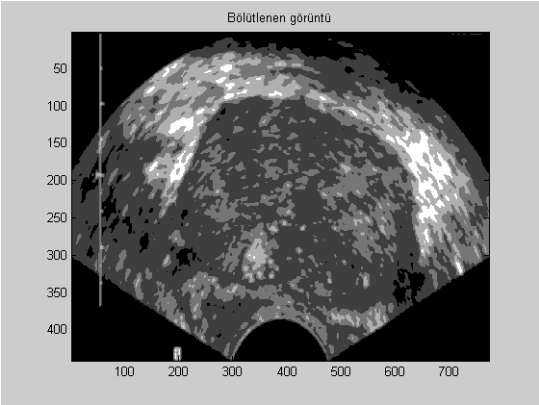
Öznitelikler	AKD katsayıları
Pencere boyutu	5x5
Kullanılan vektör	3000 rastgele
Eğitim Süresi	~ 2.47 sn.
Sınıflama Süresi	~ 208.56 sn.
Eşik (Otomatik)	~ 285.42
Kazanç değeri	0.1
Sınıf Sayısı	3
Düğüm Sayısı	11
Öznitelik Sayısı	9

Şekil 5.70-Prostat AKD Bölütlemesi (DAYSA)

Ağın oluşturduğu histogram Şekil C.1'de görülmektedir.

Tablo 5.57 parametreleriyle bölütlenen görüntü Şekil 5.71'de yer almaktadır.

Ağın oluşturduğu histogram Şekil C.2'de görülmektedir.



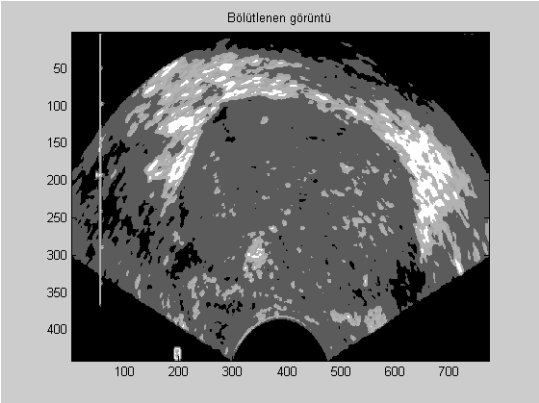
Şekil 5.71-Prostat AFD Bölütlemesi (DAYSA)

Tablo 5.57-Prostat AFD tablosu (DAYSA)

Öznitelikler	AFD katsayıları
Pencere boyutu	5x5
Kullanılan vektör	3000 rastgele
Eğitim Süresi	~ 1.86 sn.
Sınıflama Süresi	~ 149.2 sn.
Eşik (Otomatik)	~ 1193.7
Kazanç değeri	0.1
Sınıf Sayısı	5
Düğüm Sayısı	11
Öznitelik Sayısı	9

Tablo 5.58 parametreleriyle bölütlenen görüntü Şekil 5.72'de yer almaktadır.

Ağın oluşturduğu histogram Şekil C.3'te gösterilmiştir.

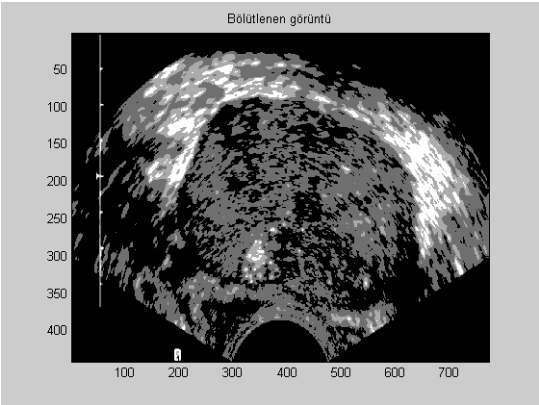


Şekil 5.72-Prostat Gri Bölütlemesi (DAYSA)

Tablo 5.58-Prostat Gri tablosu (DAYSA)

Öznitelikler	Gri seviyeleri
Pencere boyutu	5x5
Kullanılan vektör	3000 rastgele
Eğitim Süresi	~ 1.51 sn.
Sınıflama Süresi	~ 93.56 sn.
Eşik (Otomatik)	~ 285.54
Kazanç değeri	0.1
Sınıf Sayısı	5
Düğüm Sayısı	22
Öznitelik Sayısı	25

Tablo 5.59 parametreleriyle bölütlenen görüntü Şekil 5.73'de yer almaktadır.



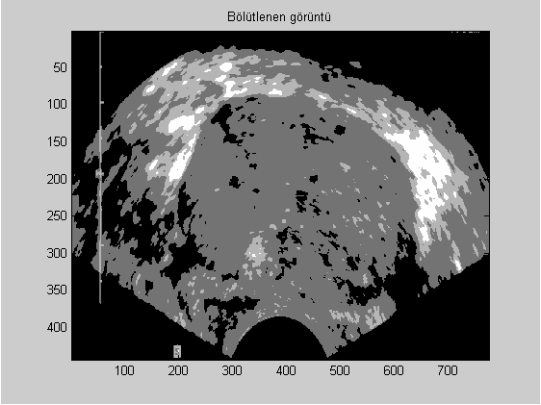
Şekil 5.73-Prostat 3 Gri Bölütlemesi (DAYSA)

Tablo 5.59-Prostat 3 Gri tablosu (DAYSA)

Öznitelikler	3 Gri değeri
Pencere boyutu	5x5
Kullanılan vektör	3000 rastgele
Eğitim Süresi	~ 1.24 sn.
Sınıflama Süresi	~ 92.8 sn.
Eşik (Otomatik)	~ 68.38
Kazanç değeri	0.1
Sınıf Sayısı	4
Düğüm Sayısı	9
Öznitelik Sayısı	3

Ağın oluşturduğu histogram Şekil C.4'te gösterilmiştir.

Tablo 5.60 parametreleriyle bölütlenen görüntü Şekil 5.74'te yer almaktadır.



Tablo 5.60-Prostat SDD tablosu (DAYSA)

Öznitelikler	SDD
Kullanılan vektör	3000 rastgele
Eğitim Süresi	~ 11.13 sn.
Sınıflama Süresi	~ 35.78 sn.
Eşik (Otomatik)	~ 156.33
Kazanç değeri	0.1
Sınıf Sayısı	4
Düğüm Sayısı	5
Öznitelik Sayısı	9

Şekil 5.74-Prostat SDD Bölütlemesi (DAYSA)

Ağın oluşturduğu histogram Şekil C.5'te gösterilmiştir.

5.3.5 DAYSA Sınıflama Sonuçları

Tez çalışmasına başlamadan önce, klasik DAYSA'nın eşik değerinin optimum olarak belirlenmesi büyük bir sorun olarak durmaktaydı. Eşik değeri büyük olunca bazı bölgeler (dokular) belirlenememekte, küçük olması durumunda da ayrıntıları temsil eden düğümler üretilerek hesap yükü artmaktaydı.

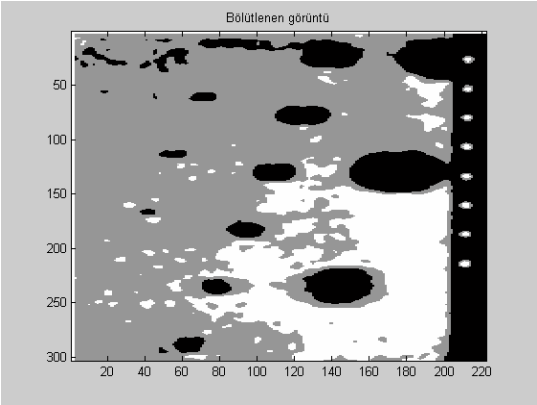
Yapılan çalışmada, klasik algoritmada deneme-yanılma metodu ile bulunan belirli bir eşik değeri yerine, otomatik eşik değeri kullanılmıştır. DAYSA eşiği, rastgele alınan örneklerin çok boyutlu uzaydaki standart sapması olarak belirlenmiştir. (5.1) denkleminde, önerilen otomatik eşik fonksiyonunun matematiksel ifadesi gösterilmiştir.

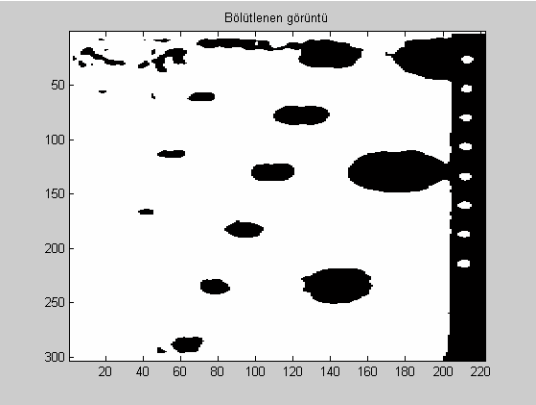
$$\text{Eşik} = \sqrt{\frac{1}{M}\sum_{i=1}^{M}\sum_{j=1}^{N}\left(x_{ij} - m_j\right)^2} \qquad (5.1)$$

Bu eşitlikte, öznitelik vektörü (X) matrisinin boyutu M x N olmaktadır. Matrisin her satırı öznitelik vektörleri ile oluşturulmuştur. mj, j sütunundaki özniteliklerin ortalamasını ifade etmektedir.

Bu şekilde çok basit olarak ifade edilen eşik fonksiyonunun, kullanılan özniteliklere, öznitelik sayısına ve öznitelik uzayında vektörlerin dağılımına bağlı olarak, US görüntüler için uygun (referans olarak alınabilecek) bir eşik üretmede oldukça başarılı olduğu görülmüştür. Bununla birlikte, DAYSA eşiği seçilirken ilk etapta eşiğin düşük tutulması doğru bir yaklaşım olacaktır. Eşiğin büyük seçildiği

durumlarda, birbirine çok yakın ama birbirinden farklı dokular aynı sınıfa ait gözükecektir. Bu yüzden otomatik eşik programı uygun eşik üretmesine karşın, bu eşiğin biraz altında (belirli bir yüzde civarında) bir eşik seçilip, ona göre bir bölütleme yapmak daha akılcı olacaktır. Doktor, tecrübesine dayanarak, aynı sınıfa ait olması gereken bölütleme sonuçlarını birleştirebilir. Şekil 5.75 ve 5.76'da, 3 bölgeye ayrılmış bir bölütleme sonucu ve seçilen 2 bölgenin birleştirilmesiyle elde edilen 2 sınıflı sonuç gösterilmiştir.





Şekil 5.75 – 3 Bölgeli Bölütleme Sonucu Şekil 5.76 – 2 Sınıflı Birleştirme Sonucu

Otomatik eşik fonksiyonu ile beraber, düğüm sınırlandırma algoritması da önerilmiştir. Böylelikle uygun olmayan bir eşik verildiğinde, düğüm sayısının çok fazla artmasının önüne geçilerek, ayrıntıların da düğüm oluşturması engellenmiştir.

Görüntü, n adet bölgeye ayrılmak isteniyorsa, en çok kullanılan n adet düğüm histograma bakılarak seçilmekte ve o şekilde bir bölütleme gerçekleştirilmektedir. Bununla birlikte, eşiğin farklı değerleri için elde edilen histogramlara bakıp, makûl bir sınıf sayısı tanımlamak da akılcı bir yaklaşım olacaktır. Şekil D.1'de böyle bir yaklaşımın ürettiği sonuç görülmektedir. Doktor gözlemlediği belirli bir bölge içindeki farklı doku sayısını tahmin edebiliyorsa, uygun sayıda düğüm oluşturan histogramı seçebilir ve böylelikle daha etkin bir bölütleme yapabilir. Ancak, farklı eşik değerleri için histogramlar elde edilirken, eğitim zamanının arttığı da göz önünde bulundurulmalıdır.

DAYSA'da seçilen kazanç değerine göre oluşan düğüm sayısı, buna bağlı olarak sınıflama zamanı değişmekte ve farklı bölütleme sonuçları üretilmektedir. Dolayısıyla, kazanç değeri de oldukça önemli olmaktadır. Çok büyük olması durumunda, eşikten küçük bir uzaklık için, düğümü, verilen eğitim vektörüne yaklaştırmaktan ziyade, eğitim vektörüne atamaktadır. Böyle olunca, öbekleşme iyi

sağlanamamaktadır. Çok küçük olduğu durumda ise, düğümü eğitim vektörüne pek fazla yaklaştıramadığından, düğüm sayısı artmaktadır.

DAYSA'nın eğitiminde, aynı sayıda vektör için eğitim vektörlerinin rastgele alınması, düğümlerin (öbekleşmelerin) daha iyi oluşmasına imkân vermektedir. Rastgele alınan çok az sayıda vektörle bile dokuların bölütlenebildiği görülmüştür. Bu yaklaşımın eğitim zamanını oldukça indirgeyerek, başarılı sonuçlar verdiği görülmüş ve bu durumun tercih edilmesi gereği ortaya çıkmıştır.

5.4. Renklendirme

Kullanılan tüm ağlar için, görüntü bölütlemesinde dokular, birbirlerine olan benzerliklerine göre interpolasyon tekniği kullanılarak renklendirilmiş ve böylelikle, yalnız farklı dokuların gösterilmesi değil, dokuların birbirlerine olan yakınlığı da görsel olarak ifade edilebilmiştir. Bu yöntemde öncelikle ağ içerisindeki birbirine en uzak düğümler Öklit mesafeleri hesaplanarak tespit edilmektedir. Bulunan bu düğümlere 0 (siyah) ve 255 (beyaz) renk kodları verilmektedir. Ağ içerisindeki diğer düğümlerin renkleri, bu düğümlere olan uzaklıklarına göre belirlenmektedir. Yapılan işlemin matematiksel ifadesi (5.2) eşitliğinde gösterilmektedir.

$$C(n) = \frac{\frac{C(a)}{d(n,a)} + \frac{C(b)}{d(n,b)}}{\frac{1}{d(n,a)} + \frac{1}{d(n,b)}} \tag{5.2}$$

Bu eşitlikte C(n); n. Düğümün Renk kodu, C(a) ve C(b) birbirine en uzak a ve b düğümlerinin renk kodları (0, 255) olmak üzere d(n,a) ve d(n,b) n. düğüm ile a ve b düğümleri arasındaki Öklit mesafesi olmaktadır.

5.4. Öznitelik Çıkartma Yöntemlerinin Değerlendirilmesi

Tez çalışmasında öznitelik çıkartma adımından önce önişleme yapılmamıştır. Bunun sebebi, önişleme yapılırken doku özelliğini belirten bilginin kaybedilme riski olmasıdır. Önişleme adımının yapılması, gürültünün yapısı bilindiğinde uygundur.

Çalışmada öznitelikleri seçmek için seçilen pencere boyutu 5x5 olarak belirlenmiştir. Görüntüyü bölütlerken, pencerelerin 1'er benek kaydırılmasıyla elde edilen sonuç daha tatminkâr olmasına karşın eğitim ve sınıflama zamanı çok daha uzun sürmektedir. Daha büyük adımlarda, eğitim ve sınıflama zamanı oldukça azalmakta,

ancak bölütlenmiş görüntünün çözünürlüğü buna paralel olarak düşmektedir. Bu nedenle, pencere adımının 1 olarak seçildiği durum kabul edilebilir seçenek olarak görülmüştür.

Pencere boyutunun 3x3 olarak alındığı durumda, bölütlemede ayrıntılar ön plana çıkmaktadır. Komşuluğun 1 yerine 2 alınması durumunda ise, seçilen beneğin komşuluğundaki benekler, o beneğe ait bölütleme yapılırken bir tür alçak geçiren süzgeç etkisi yaptığından, benek daha genel olarak değerlendirilmektedir. Bu durum, SDD ile yapılan bölütlemeye benzer bir sonucun ortaya çıkmasına neden olmaktadır. Ancak, algoritma süresi de önemli ölçüde (Yaklaşık iki kat) artmaktadır. Komşuluğun 2'den fazla alındığı durumlarda ise çözünürlük epeyce düşmektedir.

Öznitelik çıkartma yöntemleri hızlıdan yavaşa doğru Gri Seviyeleri – 3 Gri değeri – AFD katsayıları ve AKD katsayıları şeklinde sıralanmıştır. Sürekli Wavelet kullanılarak elde edilen öznitelikler farklı bir yaklaşımla seçildiği için bu sıralamada ele alınmasının doğru olmayacağı düşünülmüştür. Ancak, aynı şartlarda diğer tekniklerden daha yavaş olduğu bilinmektedir. AKD ve AFD ile elde edilen özniteliklerin başarımının birbirine oldukça yakın olduğu görülürken, 3 Gri değerinin diğer özniteliklere göre daha başarısız bir sonuç ürettiği gözlenmiştir.

Ayrık dalgacık dönüşümü alındıktan sonra elde edilen görüntülerden alınan öznitelik değerleri ile bulunan sonuçlar, çok verimli olmamaktadır. Bunun nedeni, ayrık dönüşüm sonucu elde edilen görüntünün boyutlarını orijinal hale getirirken kaybedilen bilgidir. Bu nedenle, öznitelik çıkartma metodunda SDD kullanılmalıdır.

Öznitelik olarak SDD kullanıldığında, görüntünün benek bazında değil, genel (makro) olarak değerlendirilmesi, dolayısıyla bölütlenebilmesi imkânı oluşmaktadır. SDD ile ilgili göz önünde bulundurulması gereken bir diğer faktör, seçilen ölçek değeridir. Bu değer çok büyük seçildiğinde (alçak geçiren süzgeç etkisi) ayrıntılar kaybolmaktadır. Diğer taraftan, SDD ile küçük detayların elenerek, diğer özniteliklere nazaran daha homojen bir bölütleme sonucu elde edilmesi olanaklı hale gelmektedir.

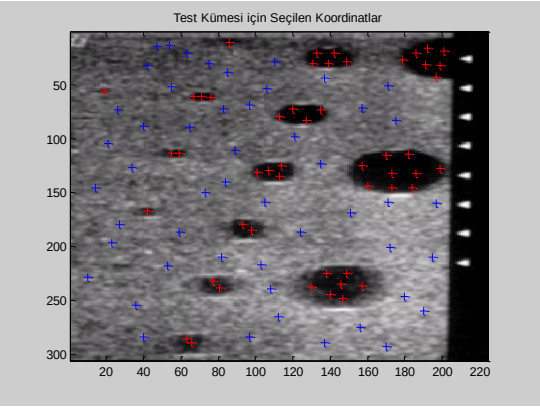
Literatürdeki yaklaşımdan [21] hareketle, AFD ve AKD dönüşümlerinde sadece 1 adet en anlamlı öznitelik alınarak bulunan sonucun komşuluk değerine göre 9 ya da 25 öznitelikli duruma nazaran çok farklı bir sonuç vermediği görülmüş ve tek bir öznitelikle de başarılı bir bölütleme yapılabileceği gözlenmiştir.

5.5. Benzetim Ortamı

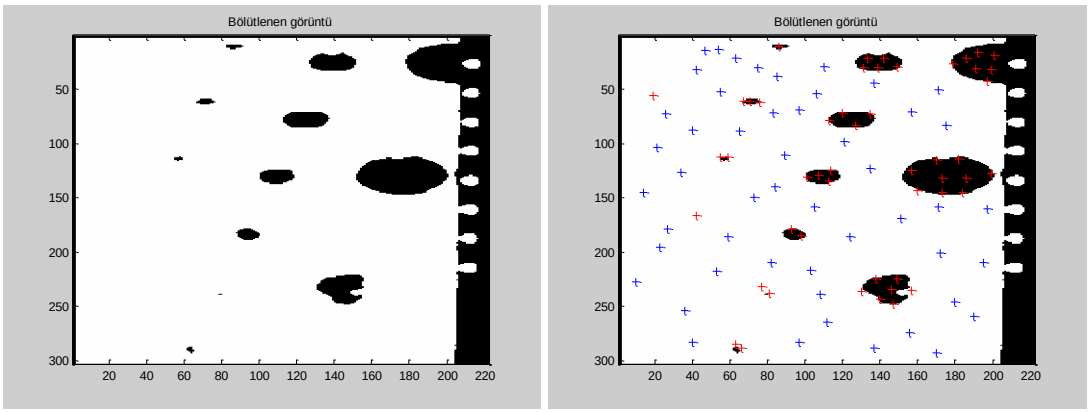
Görüntü işleme alanında kullanılmak üzere barındırdığı fonksiyonlar ve kolay kullanılabilirliği sebebiyle MATLAB programı kullanılmıştır. Günümüzde MATLAB, içerdiği birçok araç (Toolbox) ve fonksiyon yardımıyla, değişik alanlarda kullanılmaktadır. MATLAB, veri analizi, görüntülemesi, algoritma ve uygulama geliştirmek için, temel matematik ve gelişmiş grafiksel araçlar sağlar. İçerdiği 600'den fazla matematiksel, istatistiksel ve mühendislik fonksiyonları ile MATLAB, mühendis ve bilim adamlarının teknik hesaplama ihtiyaçları için güvendikleri bir platform haline gelmiştir [47]. Tez içerisindeki algoritmalar mümkün olduğunca esnek hazırlanmıştır. Kullanıcıya, algoritmanın türüne göre kullanılan farklı parametreleri değiştirme imkânı sunulmuştur. Böylelikle farklı parametrelerin sonuçta oluşan görüntüye yansımaları kolaylıkla değerlendirilebilmektedir. Ancak algoritmaların bu kadar esnek olması, bazı parametreler için algoritmaların sonuçlanma süresini de bir miktar uzatmaktadır. Dolayısıyla, bazı parametrelerin sabitlenmesi durumunda algoritma süreleri biraz daha kısalmaktadır.

5.6 Fantom Görüntü için Başarım Sonuçları

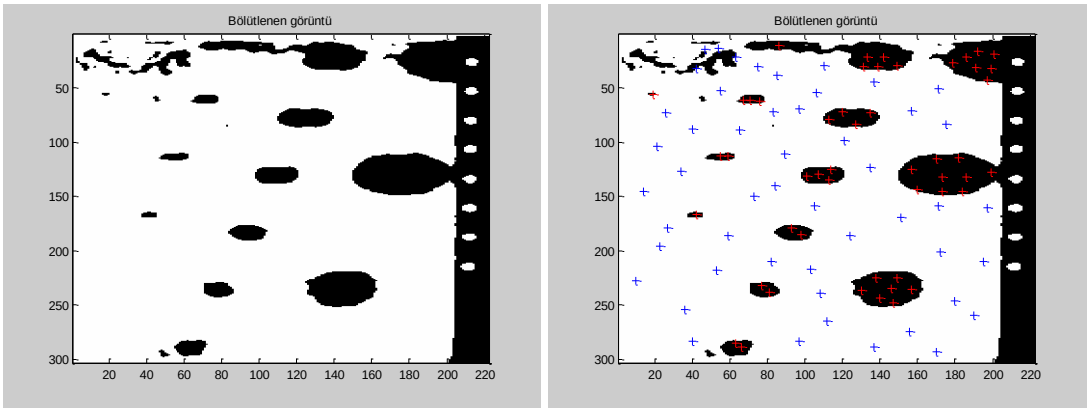
Tez içerisinde kullanılan fantom görüntünün karakteristiği bilindiğinden dolayı, aynı öznitelik çıkartma yöntemi için farklı ağların başarım karşılaştırması olanaklı hale gelmektedir. Şekil 5.77'de, Şekil 5.1'deki orjinal fantom görüntüsü için iki sınıftan alınan 50'şer adet test kümesi koordinatları gösterilmiştir. Şekil 5.78, 5.79 ve 5.80'de ise aynı öznitelik vektörleriyle (100 tane) eğitilmiş GAL, Kohonen ve DAYSA'nın iki sınıflı bölütleme sonuçları gösterilmektedir. Seçilen test kümesine göre başarım oranları Tablo 5.61'de görülmektedir.



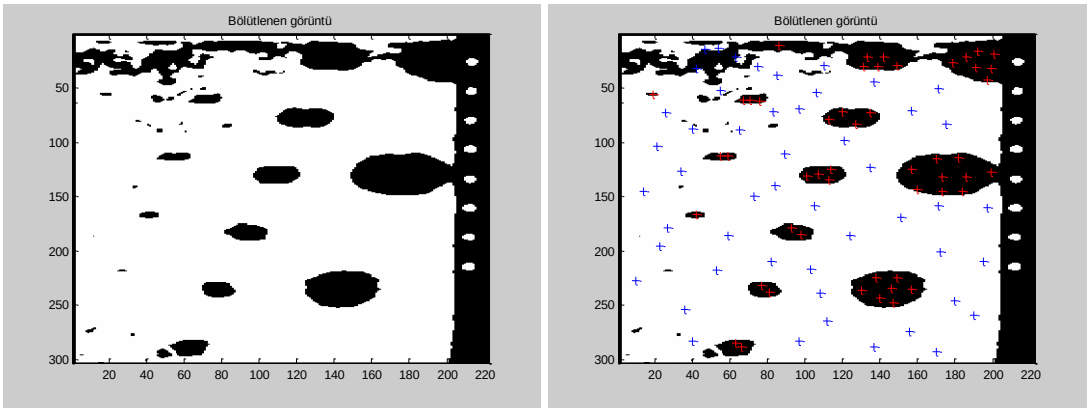
Şekil 5.77 – Performans Analizi için seçilen Test kümesi



Şekil 5.78 – GAL Ağı ile bölütleme (solda) ve test kümeli sınıflama sonucu



Şekil 5.79 - KOHONEN Ağı ile bölütleme (solda) ve test kümeli sınıflama sonucu



Şekil 5.80 – DAYSA ile bölütleme (solda) ve test kümeli sınıflama sonucu

Tablo 5.61 - YSA'ların 2 sınıflı Fantom Görüntü için Performans Karşılaştırması

YSA	Öznitelik	Eğitim Zamanı (sn)	Sınıflama Zamanı (sn)	Oluşan Düğüm Sayısı	Yanlış Sınıf	Doğru Sınıf	Başarım (%)
GAL	AFD	<0.1	30.80	2	12	88	88
KOHONEN	AFD	<0.1	32.46	(2x2) = 4	2	98	98
DAYSA	AFD	<0.1	30.48	3	2	98	98

Tablo 5.61'de görüldüğü gibi, Kohonen ağı ve DAYSA'nın başarımı, GAL Ağına göre çok daha yüksek olmuştur. Bu sonucun çıkmasında, GAL ağının ezberci yapısı ve eğitimde kullanılan öznitelik vektörlerine olan duyarlığı etkili olmuştur. Kohonen ve DAYSA'nın oluşturduğu düğüm sayıları etiketleme sonucu 2 sınıfa indirgenmiş ve böylelikle ağların karşılaştırılması olanaklı hale gelmiştir.

6. TARTIŞMA

Tez içerisinde US görüntülerin bölütlenmesinde, beş ayrı öznitelik çıkartma yöntemi, üç farklı YSA üzerinde denenmiş ve elde edilen sonuçlar karşılaştırmalı olarak yorumlanmıştır. Yapılan çalışmalar sonucunda, DAYSA'nın en önemli sorunu olan eşik problemi, kullanılan otomatik eşik fonksiyonu ile US görüntüler için büyük ölçüde giderilmiştir. Ağların başarımı, kullanılan fantom görüntünün bölütleme sonuçlarına bakarak yorumlanmıştır.

DAYSA'da, sınıf sayısı histograma bakılarak seçilmiş, buna bağlı olarak elde edilen sonuçlar başarılı bulunmuştur. DAYSA, histogram özelliği sayesinde, görüntüdeki farklı dokuları daha iyi inceleyebilme imkânı vermektedir.

Elde edilen sonuçlar bir radyoloji uzmanı tarafından değerlendirilmiş ve yapılan çalışmanın teşhise yardımcı olabilecek yönde ipuçları verdiği, bir miktar daha geliştirilmesi durumunda, özellikle karmaşık kistlerin içeriğinin çözümlenmesi konusunda doktorların kesinlikle tercih edebileceği bir yöntem olabileceği kanısına varılmıştır [48]. Kullanılan ağlar eğitilirken, algoritmalara dokuların tipi (göğüs, karaciğer, prostat…vb) ve US ekipmanların özellikleri (frekans, görüntü boyutları…vb) için, bir ön parametre yüklemesi yapılırsa, sonuçların beklenen gelişmeyi sağlayabileceği düşünülmektedir.

Yapısal dokular için de uygun bir otomatik eşik fonksiyonu bulunduğu takdirde DAYSA'nın, farklı uygulama alanlarında Kohonen ağı gibi önemli bir yere sahip olacağı düşünülmektedir. Dolayısıyla, böyle bir fonksiyonun hazırlanması önemli bir çalışma alanı olarak değerlendirilmektedir.

Gelecekte, artan görüntü çözünürlüğü ve gürültü bastırma yöntemleri ile birlikte, ultrasonografi alanında teşhisin daha kolay gerçekleştirilebileceği aşikârdır. Gelişen teknoloji, çok daha hızlı ve hassas bir şekilde 3 boyutlu görüntülemeye de olanak verecektir. Böylelikle doktorlara en az hata ile teşhis yapma imkânı verecek sistemler mevcut olacaktır.

KAYNAKLAR

[1] **http://www.r2tech.com**

[2] **http://www.deustech.com**

[3] **http://www.icadmed.com**

[4] **Hekimoğlu, İ. ve Özdemir, Ö.,** 2004. Kişisel Görüşme.

[5] **Gool, L. V., Dewaele P. and Oosterlinck, A.,** 1985. Survey: Texture Analysis Anno 1983, *Computer Vision, Graphics and Image Processing*, **29**, pp.336-357.

[6] **Kapur T,** 1999. Model based three dimensional Medical image Segmentation, *Ph.D. Thesis*, Artificial Intelligence Laboratory, Massachusetts Institute of Technology, Cambridge, MA.

[7] **Khaled, Z. A.E., Abou-Bakr, M.Y. and Yasser M.K.,** 2002. Real-Time Speckle Reduction and Coherence Enhancement in Ultrasound Imaging via Nonlinear Anisotropic Diffusion, *IEEE Transactions on Biomedical Engineering*, **49**, 997-1014.

[8] **Chang, R.F., Wu, W.J., Tseng, C.C.,Chen, D.R. and Moon, W. K.,** 2003. 3-D Snake for US in Margin Evaluation for Malignant Breast Tumor Excision Using Mammotome, *IEEE Transactions On Information Technology in Biomedicine*, **7**, No. 3

[9] **Loizou C., Christodoulou C., Pattichis, C.S., Istepanian, R., Pantziaris, M. and Nicolaides, A.,** 2002. Speckle Reduction in Ultrasonic Images of Atherosclerotic Carotid Plaque, *14th International IEEE Conference on Digital Signal Processing*, Santorini, Greece, July 1-3, 525-528.

[10] **Stippel, G. Philips, W. and Lemahieu, I.,** 2002. A new denoising technique for ultrasound images using morphological properties of speckle combined with tissue classifying parameters, *SPIE Medical Imaging Conference Proceedings*, San Diego CA, USA, February.

[11] **O'Donnell, M. and Rigby, K.W.,** 2003. Real-Time Aberration Correction For Medical Ultrasound, *World Congress on Ultrasonics*, Paris, September 7-10.

[12] **Huang, Y. and Chan, K.L.,** 2002. Multi-model Feature Integration For Texture Classification, 5th Asian Conference on Computer Vision, Melbourne, Australia, January 23-25.

[13] **Varma, M. and Zisserman, A.,** 2003. Texture Classification: Are Filter Banks Necessary?, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Madison, Wisconsin, USA, June 16-22, 691-698.

[14] **Chen, D.R., Chang R.F. and Huang, Y.L.,** 2000. Breast Cancer Diagnosis Using Self-Organizing Map For Sonography, *World Federation for Ultrasound in Medicine & Biology*, **26**, No. 3, 405–411.

[15] **Pavlopoulos S., Kyriacou E., Koutsouris, D., Blekas, K., Stafylopatis, A. and Zoumpoulis, P.,** 2000. Fuzzy Neural Network Computer Assisted Characterization of Diffused Liver Diseases Using Image Texture Techniques on Ultrasonic Images, *IEEE Engineering in Medicine and Biology Magazine,* **19,** No.1, 39-47.

[16] **Hao, X., Bruce, C., Pislaru, C. and Greenleaf, J.W.,** 2000. A Novel Region Growing Method for Segmenting Ultrasound Images, *IEEE International Ultrasonics Symposium*, San Juan, Puerto Rico, October 22-25.

[17] **Bautista P.A. and Lambino, M.A.,** 2001. Co-Occurrence Matrices for Wood Texture Classification, *3rd Samahang Pisika ng Visayas at Mindanao National Physics Conference-Workshop,* Ateneo de Zamboanga University, Zamboanga, Philippines, October 23-25.

[18] **Kadyrov, A., Talepbour, A. and Petrou, M.,** 2002. Texture classification with thousands of features. *13th British Machine Vision Conference*, Cardiff, UK, September 2-5.

[19] **Partio, M., Cramariuc, B., Gabbouj, M. and Visa, A.,** 2002. Rock Texture Retrieval Using Gray Level Co-Occurrence Matrix, *5th Nordic Signal Processing Symposium*, Hurtigruten, Norway, October 4-7.

[20] **Rajpoot, N.M.,** 2002. Texture Classification Using Discriminant Wavelet Packet Subbands, *45th IEEE Midwest Symposium on Circuits and Systems*, Tulsa, Oklahoma USA, August 4-7.

[21] **Sorwar G., Abraham A and. Dooley L. S.,** 2001. Texture Classification Based on DCT and Soft Computing, *10th IEEE International Conference on Fuzzy Systems*, Melbourne, Australia, December 2-5.

[22] **Tao, Y., Muthukkumarasamy V.,Verma, B., Blumenstein, M.,** 2003. A Texture Feature Extraction Technique Using 2D–DFT and Hamming Distance, 5-th International Conference on Computational Intelligence and Multimedia Applications, Xi'an, China, September 27 – 30.

[23] **Chou, Y.H., Tiu, C.M., Hung, G.S., Wu, S.C., Chang, T.Y. and Chiang, H.K.,** 2001. Stepwise Logistic Regression Analysis of Tumor Contour Features for Breast Ultrasound Diagnosis, *World Federation for Ultrasound in Medicine & Biology*, **27**, No.11, 1493-1498.

[24] **Petersen, M. Ridder, D. and Handels, H.,** 2002. Image processing with neural networks – a review, *Journal of Pattern Recognition,* **35**, 2279–2301.

[25] **Bhalero, A.H. and Rajpoot, N.M.,** 2003. Discriminant Feature Selection for Texture Classification, *14th British Machine Vision Conference*, Norwich, UK, September 9-11.

[26] **Chen, D.R., Kuo W.J., Chang R.F., Moon, W.K. and Cheng, C.L.,** 2002. Use Of The Bootstrap Technique With Small Training Sets For Computer-

Aided Diagnosis in Breast Ultrasound, *World Federation for Ultrasound in Medicine & Biology*, **28**, No. 7, 897–902.

[27] **Huang, Y.L. and Lin, X.Y.,** 2002. Contour Detection for the Breast Tumor in Ultrasonic Images Using Watershed Segmentation, *International Computer Symposium 2002 (ICS 2002): Workshop on Artificial Intelligence*, Hualien, Taiwan, G2-5, December 2002. (NSC 90-2213-E-029-011)

[28] **Won, J.H., Pyun, K. and Gray R.M.,** 2003. Hidden Markov Multiresolution Texture Segmentation Using Complex Wavelets, *10th International Conference on Telecommunications*, Tahiti, Papeete, French Polynesia, February 23 - March 1, **2**, 1624-1630.

[29] **Keysers D., Wein B.B. and Lehmann, T.M.,** 2003. Statistical framework for model-based image retrieval in medical applications, *Journal of Electronic Imaging* **12**(1), 59–68.

[30] **Kotropoulos C. and Pitas I.,** 2003. Segmentation of Ultrasonic Images Using Support Vector Machines, *Pattern Recognition Letters*, 24, 715-727.

[31] **Huang, Y.L. and Liu, Y.G.,** 2003. Diagnosis of Solid Breast Tumors with Sonographic Texture Analysis, *16th IPPR Conference on Computer Vision, Graphics and Image Processing*, Kinmen, Taiwan, August 2003, 70-77.

[32] **Chang, R.F., Wu, W.J., Moon, W.K. and Chen, D.R.,** 2003. Improvement In Breast Tumor Discrimination By Support Vector Machines and Speckle-Emphasis Texture Analysis, *World Federation for Ultrasound in Medicine & Biology*, **29**, No. 5, 679–686.

[33] **Wu, Y., Ianakiev, K. and Govindaraju, V.,** 2002. "Improved k-nearest neighbor classification", *Journal of Pattern Recognition*, **35**, 2311–2318.

[34] **Scheipers, U., Lorenz, A., Pesavento, A., Ermert, H., Sommerfeld, H.J., Schurmann, M.G., Kuhne, K., Senge, T. and Philippou S.,** 2001. Ultrasonic Multifeature tissue characterization for the early detection of prostate cancer, *IEEE 2001 Ultrasonics Symposium Proceedings*, Atlanta, Georgia, USA, 1265-1268.

[35] **Fernandes, D., Siqueira, M. and Navaux, P.O.A.,** 2001. Segmentation of Fetal Echocardiographic Images Using Self-Organizing Maps and Oscillatory Neural Networks, *VI Iber-American Symposium on Pattern Recognition (SIARP'2001)*, Florianópolis, Brasil, 27 - 28 June 2001, 55-60.

[36] **Kurnaz, M. N., Dokur, Z., Ölmez, T.,** 2001. Segmentation of ultrasound images by using an incremental self-organized map, *23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Istanbul, Turkey, October 25-28.

[37] **Kohonen T.,** 1988. Self-Organization and Associative Memory, Springer-Verlag, New York.

[38] **Ölmez, T., Dokur, Z.,** 2002. Ultrasonik Görüntülerin Artımsal Yapay Sinir Ağı ile Bölütlenmesi, *URSI-Türkiye 2002 Birinci Ulusal Kongresi,* İstanbul, Türkiye, 18-20 Eylül, s. 435-438.

[39] **Kalender, O. ve Kavalcı R.,** 2001. Ultrasonografi.

[40] **Lizzi, F. L., Feleppa, E. J., Alam, S. K. and Deng, C. X.,** 2003. Ultrasonic Spectrum Analysis for Tissue Evaluation, *Pattern Recognition Letters,* **24**, 637-658.

[41] **Kremkau, F. W.,** 1984. *Diagnostic Ultrasound Principles, Instrumentation and Exercises*, pp. 10-24, Grune & Stratton, Inc., Florida.

[42] **http://www.fantom.suite.dk/571.htm**

[43] **http://www.degum.de/175.html**

[44] **Dokur Z.,** 2000., Yapay sinir ağları ve genetik algoritmalar kullanılarak EKG vurularının sınıflandırılması, *Doktora tezi*, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul.

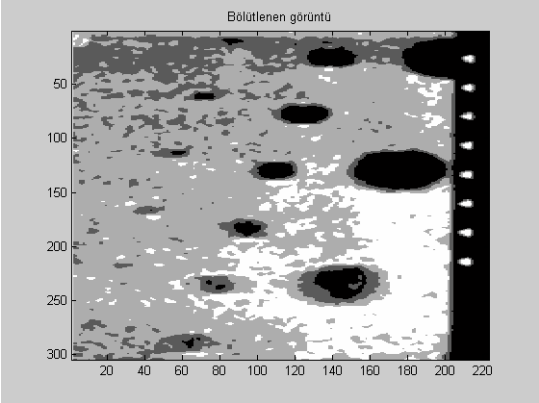
[45] **Polikar R**., 1996., Fundamental Concepts & An Overview Of The Wavelet Theory,*Tutorial*, http://users.rowan.edu/~polikar.

[46] **Alpaydın E.,** 1994. GAL: Networks that Grow when they Learn and Shrink when they Forget, *International Journal of Pattern Recognition and Artificial Intelligence*, **8**, 391-414.

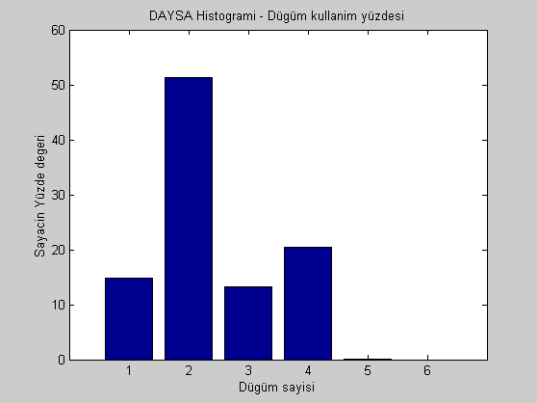
[47] **http://www.mathworks.com/products/family_overview.html**

[48] **Özdemir, Ö.,** 2005. Kişisel Görüşme.

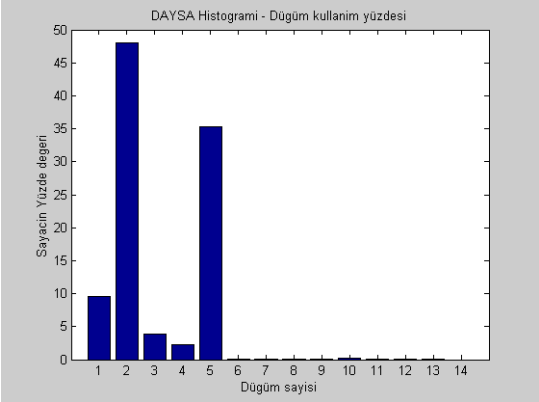
EKLER



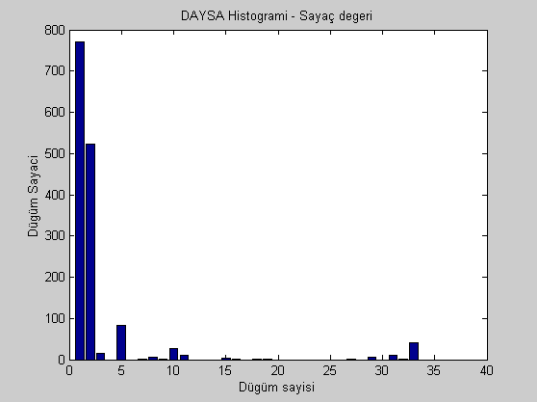
Şekil A.1 Fantom DAYSA (3 Gri)



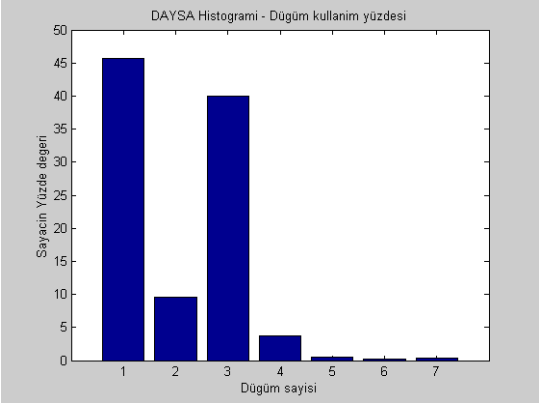
Şekil A.2 Fantom DAYSA (3 Gri)



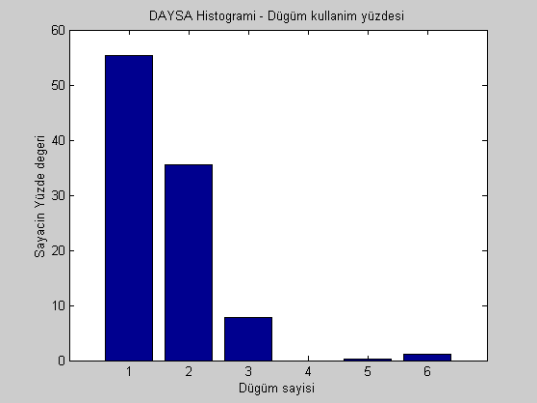
Şekil A.3 Meme DAYSA (AFD)



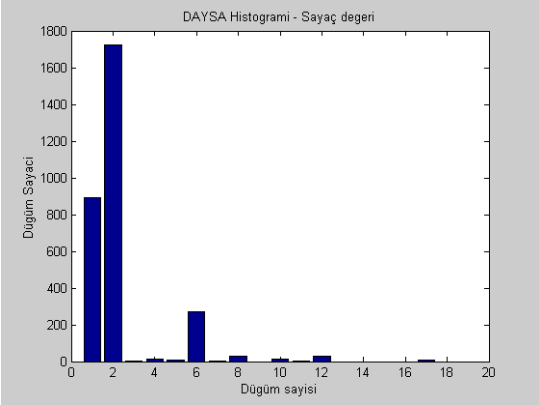
Şekil A.4 Meme DAYSA (Gri)



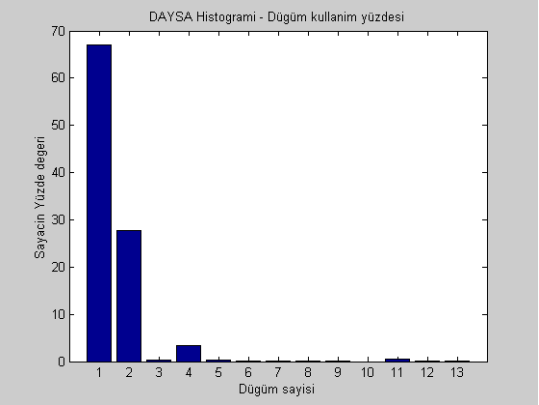
Şekil A.5 Meme DAYSA (3 Gri)



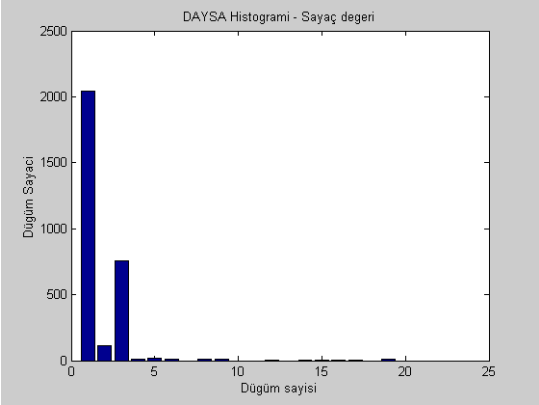
Şekil A.6 Meme DAYSA (SDD)



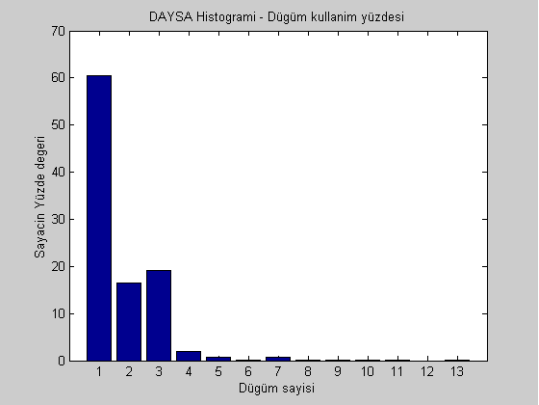
Şekil B.1 Karın DAYSA (AKD)



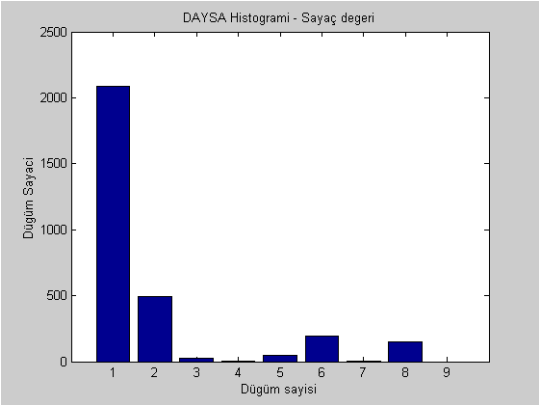
Şekil B.2 Karın DAYSA (AFD)



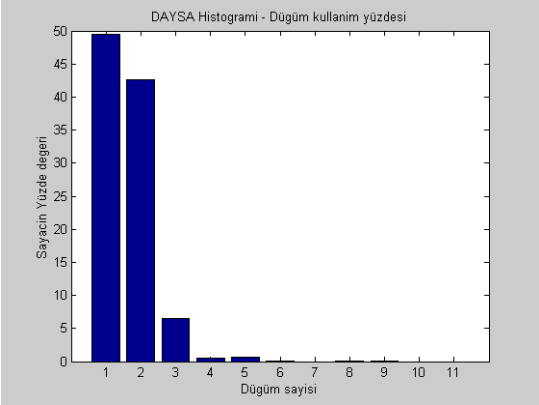
Şekil B.3 Karın DAYSA (Gri)



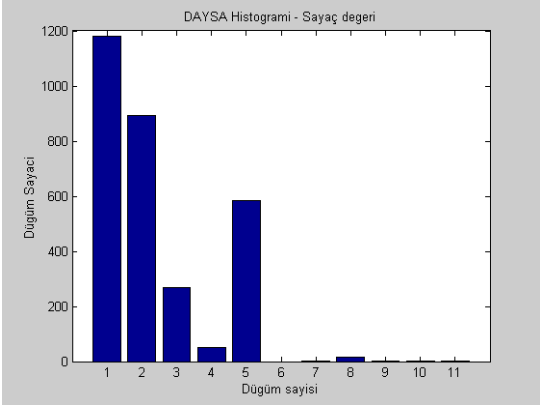
Şekil B.4 Karın DAYSA (3 Gri)



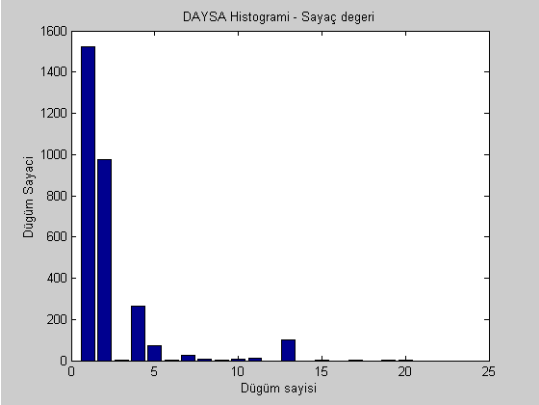
Şekil B.5 Karın DAYSA (SDD)



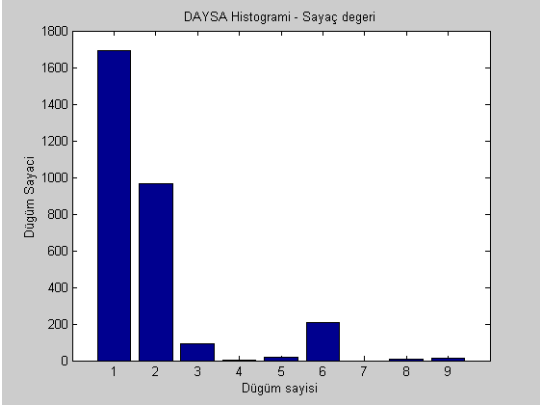
Şekil C.1 Prostat DAYSA (AKD)



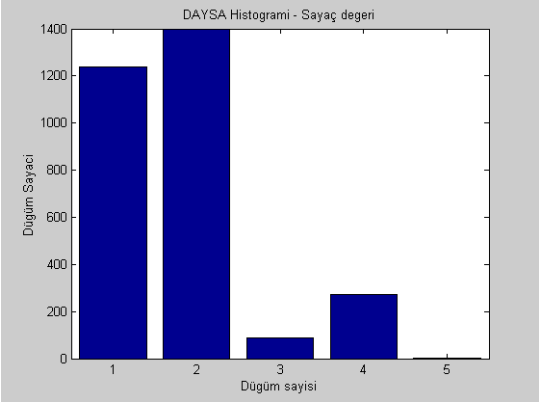
Şekil C.2 Prostat DAYSA (AFD)



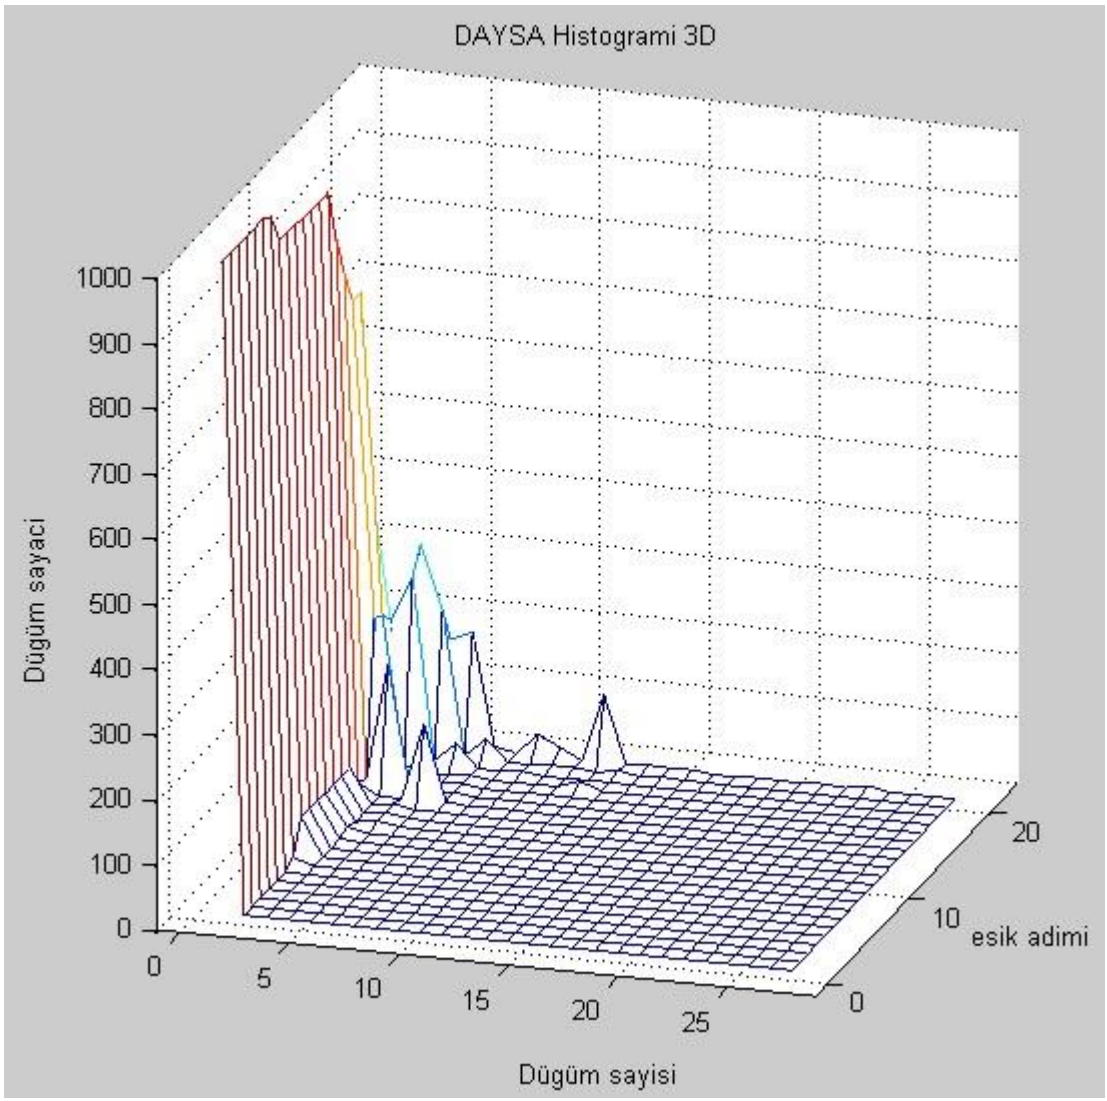
Şekil C.3 Prostat DAYSA (Gri)



Şekil C.4 Prostat DAYSA (3 Gri)



Şekil C.5 Prostat DAYSA (SDD)



Şekil D.1 DAYSA eşiğine bağlı olarak oluşan düğüm sayıları ve sayaç değerleri

ÖZGEÇMİŞ

Müh. Zafer İŞCAN, 1981 senesinde Üsküdar'da doğdu. 1998 yılında İstanbul Teknik Üniversitesi'nin Elektronik ve Haberleşme Mühendisliği Bölümü'nü kazandı. 2002 yılında Elektronik ve Haberleşme Mühendisi ünvanıyla mezun olarak, aynı yıl İTÜ Fen Bilimleri Enstitüsü'ne bağlı olan Biyomedikal Mühendisliği Yüksek Lisans Programı'na kabul edildi. Tez aşamasında olduğu dönemde, İTÜ tarafından Avrupa Birliği'nin Leonardo da Vinci programı kapsamında hazırlanan bir proje ile, 6 aylık bir süre için, İtalya'da biyomedikal alanında faaliyet gösteren TSD Projects şirketine gönderilerek, alanında mesleki eğitim gördü.

Ağustos 2005'te İTÜ Elektrik-Elektronik Fakültesi'nin Elektronik Anabilim Dalı'na Araştırma Görevlisi olarak kabul edildi. Halen bu görevini sürdürmektedir.

Üniversite yılları süresince İTÜ Amatör Tiyatro Topluluğu (1998), Boğaziçi Üniversitesi Folklor Kulübü (2001-2002) gibi kulüplere devam etmiştir. Ayrıca 2001 senesinden beri Çağdaş Yaşamı Destekleme Derneği Beşiktaş şubesi üyesidir. İyi derecede ingilizce, orta derecede italyanca ve fransızca bilmektedir.