T.C.

SELÇUK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR TOMOGRAFİLİ AKCİĞER GÖRÜNTÜLERİNİN DEĞERLENDİRİLMESİNDE KOMPLEKS DEĞERLİ YENİ BİR AKILLI SİSTEM TASARIMI

Murat CEYLAN

DOKTORA TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
Konya, 2009

T.C.

SELÇUK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR TOMOGRAFİLİ AKCİĞER GÖRÜNTÜLERİNİN DEĞERLENDİRİLMESİNDE KOMPLEKS DEĞERLİ YENİ BİR AKILLI SİSTEM TASARIMI

Murat CEYLAN

DOKTORA TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Bu tez 07/05/2009 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

Prof. Dr. Osman Nuri UÇAN
(Üye)

Prof. Dr. Ahmet ARSLAN
(Üye)

Doç. Dr. Yüksel ÖZBAY
(1. Danışman)

Doç. Dr. Salih GÜNEŞ
(Üye)

Yrd. Doç. Dr. Nihat YILMAZ
(Üye)

ÖZET

Doktora Tezi

BİLGİSAYAR TOMOGRAFİLİ AKCİĞER GÖRÜNTÜLERİNİN DEĞERLENDİRİLMESİNDE KOMPLEKS DEĞERLİ YENİ BİR AKILLI SİSTEM TASARIMI

Murat CEYLAN

Selçuk Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

1. Danışman: Doç. Dr. Yüksel ÖZBAY
2. Danışman: Prof. Dr. Osman Nuri UÇAN

2009, 154 sayfa

Jüri: Prof Dr. Osman Nuri UÇAN
Prof Dr. Ahmet ARSLAN
Doç. Dr. Yüksel ÖZBAY
Doç. Dr. Salih GÜNEŞ
Yrd. Doç. Dr. Nihat YILMAZ

Akciğer kanseri, diğer kanser türleri ile karşılaştırıldığında en yüksek ölüm oranına sahip olan kanser türüdür ve akciğer kanserinin neden olduğu ölümler her geçen yıl düzgün bir artış göstermektedir. Birçok ülke, akciğer kanserinin yayılım hızını düşürebilmek amacı ile en etkili yol olarak sigara kullanımını yasaklamıştır. Bununla birlikte kanserin erken aşamalarında şüpheli nodüllerin doğru bir şekilde ayrıştırılabilmesi, yani benign (iyi huylu) ve malign (kötü huylu) nodüllerin başarı ile sınıflandırılabilmesi, hem hastalığın takibi hem de hastalığın tedavisinin şekillendirilmesi için oldukça önemlidir.

Akciğer nodüllerinin görüntülenmesinde kullanılan akciğer bilgisayarlı tomografi (BT) taraması, tek dedektörlü sistemlerde tipik olarak 40 ila 100 eksenel görüntü kesiti üretirken, daha yeni versiyonlarında, yani çok dedektörlü sistemlerde 300 ile 600 görüntü kesiti elde edilmektedir. Bu çok sayıdaki görüntüyü okumak ve yorumlamak, radyologların önemli bir çaba göstermesini gerektirmekle birlikte insan hatası ve kanserli nodüllerin kaçırılması gibi dezavantajlar ile sıklıkla karşılaşılmaktadır. Bu yüzden, bilgisayar destekli teşhis (BDT) yaklaşımlarına, radyologların iş yükünü azaltmak ve sınıflama hassasiyetini artırmak amacı ile gittikçe artan bir şekilde ihtiyaç duyulmaktadır.

Tez çalışmasında, akciğer BT görüntülerini yorumlayan radyologların, karşılaştıkları nodüller hakkında karar vermelerine yardımcı olabilmek amacı ile yeni bir akıllı BDT sistemi önerilmiştir. Sistem Başkent Üniversitesi Konya Uygulama ve

Araştırma Hastanesinden alınan ve biyopsi sonuçlarına uygun olarak etiketlenmiş 22 malign ve 10 benign nodülü içeren 32 BT görüntüsü kullanılarak test edilmiştir.

Geliştirilen sistem, iki temel işlem bloğu şeklinde tasarlanmıştır. İlk olarak segmentasyon işlemi gerçekleştirilmiştir. Bu amaçla, BT cihazından alınan akciğer görüntüleri üzerinde kompleks-değerli dalgacık dönüşümü (KDDD) kullanılarak boyut azaltımı yapılmış ve elde edilen görüntülerde akciğer bölgesi haricindeki bölgeler atılmıştır. Bu işlem, kompleks-değerli yapay sinir ağı (KDYSA) ve hücresel yapay sinir ağı (HYSA) gibi iki farklı YSA modelinin kullanıldığı yeni bir hibrit YSA modeli olan Kompleks Değerli Hibrit Hücresel Yapay Sinir Ağı (KDHHYSA) kullanılarak gerçekleştirilmiştir. Elde edilen ortalama doğruluk oranı test için % 99.71' dir.

Geliştirilen BDT sisteminin ikinci bileşeni, segmente edilen akciğer BT görüntüsünde yer alan nodüllerin sınıflandırılmasıdır. Segmente edilen BT görüntülerine dört farklı seviyede KDDD uygulanmış ve ayrı ayrı her bir seviye için dört istatistik özellik (en küçük değer, en büyük değer, ortalama değer, standart sapma) çıkarılarak KDYSA ile sınıflandırılmıştır. Sınıflama geçerliliğini kanıtlamak için 10-kat çapraz geçerlilik yöntemi uygulanmıştır. En iyi sonuçlar, dördüncü seviye KDDD kullanıldığında elde edilmiş ve 22 malign nodülün 22' si malign olarak, 10 benign nodülün 9 tanesi ise benign olarak sınıflandırılmıştır. Duyarlılık % 95.2, belirlilik % 100, ortalama belirleme oranı % 97.6, doğruluk % 96.7, pozitif tahmin testi % 100 ve negatif tahmin testi % 90 olarak elde edilmiştir.

Anahtar Kelimeler: Akciğer segmentasyonu, nodül sınıflama, kompleks-değerli dalgacık dönüşümü, kompleks-değerli yapay sinir ağı, kompleks-değerli hibrit hücresel yapay sinir ağı

ABSTRACT

PhD Thesis

A NEW COMPLEX-VALUED INTELLIGENT SYSTEM DESIGN ON EVALUATING OF THE LUNG IMAGES WITH COMPUTERIZED TOMOGRAPHY

Murat CEYLAN

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

Supervisor: Assoc. Prof. Dr. Yüksel ÖZBAY
Co- Supervisor: Prof. Dr. Osman Nuri UÇAN

2009, 154 pages

Jury: Prof Dr. Osman Nuri UÇAN
Prof Dr. Ahmet ARSLAN
Assoc. Prof. Dr. Yüksel ÖZBAY
Assoc. Prof. Dr. Salih GÜNEŞ
Asst. Prof. Dr. Nihat YILMAZ

The mortality rate for lung cancer is higher than that for other kinds of cancers and it appears that the rate has been steadily increasing. No smoking is considered the most effective way to reduce the incidence of lung cancer in most countries. Detection of suspicious nodules in the early stages of cancer and classification of benign and malign nodules is very important for both disease control and management of treatment.

In the screening of lung nodules, thoracic computed tomography (CT) scan using a single detector scanner typically generates 40 to 100 axial image slices, the newer, multi-detector scanner generate 300 to 600 image slices. To read and interpret these massive amounts of image data requires significant radiologist effort and predisposes the screening process to human error and missed detection of cancerous nodules. Thus, computer-aided diagnostic (CAD) approaches are becoming increasingly necessary for both reducing radiologists' effort and improving detection sensitivity.

In thesis study, a new intelligence CAD system which provide interpretation of lung CT image and decision making about nodules easiness to radiologists was proposed. System was tested using 32 CT images including 22 malign nodules and 10 benign nodules. These images were taken from Başkent University Konya Application and Research Hospital and images were labeled according to biyopsy reports.

The improved system was formed as two process blocks. Firstly, segmentation was done. In this aim, size of lung CT images was decreased using complex-valued wavelet transform (CVWT). Unnecessary regions were extracted from whole image and lung region was obtained. This process was realized using a new hybrid Articial Neural Network (ANN) model including two different ANN models as Complex-Valued ANN (CVANN) and Cellular ANN (CANN). The new hybrid ANN model was called as Complex-Valued Hybrid Cellular ANN (CVHCANN). Averaged accuracy rate for test process was obtained as 99.71 %.

Second part of improved CAD system was contained classification of nodules in segmented lung CT images. CVWT with four different level was applied to segmented images. For each level, four statistical features (minimum value, maximum value, averaged value and standard deviation) extracted for classification via CVANN. To prove of classification validity, ten-fold cross validation method was done. The best results were obtained using fourth level CVWT. 22 of 22 malign nodules were classified as malign nodule. 9 of 10 benign nodules were classified as benign nodule and 1 benign nodule was classified as malign nodule. Sensitivity, specificity, averaged detection rate, accuracy, positive predictive value and negative predictive value was obtained as 95.2%, 100%, 97.6%, 96.7%, 100% ve 90%, respectively.

Keywords: Lung segmentation, nodule classification, complex-valued wavelet transform, complex-valued artificial neural network, complex-valued hybrid cellular artificial neural network.

TEŞEKKÜR

Doktora tez çalışmalarım boyunca değerli katkılarıyla beni yönlendiren Sayın Doç. Dr. Yüksel ÖZBAY ve Prof. Dr. Osman Nuri UÇAN' a ve bölümümüz öğretim elemanlarına, her türlü desteğini esirgemeyen eşime, kızıma ve aileme teşekkür ederim. Ayrıca BT görüntülerinin kaydedilmesi, incelenmesi ve yorumlanması aşamalarında sonsuz bir sabır ile destek veren Yrd. Doç. Dr. Erkan YILDIRIM' a ve Başkent Üniversitesi Konya Araştırma ve Uygulama Hastanesi personeline teşekkür ederim.

İÇİNDEKİLER

ÖZET…….. i
ABSTRACT……..... iii
TEŞEKKÜR……..... v
İÇİNDEKİLER…….. vi
SİMGELER VE KISALTMALAR…… x
ŞEKİLLER LİSTESİ……. xii
ÇİZELGELER LİSTESİ…… xiv

1. GİRİŞ……..... 1
1.1. Tez Konusunun Tanıtılması……..... 2
1.2. Tez Çalışmasının Amacı ve Önemi…… 3
1.3. Bu Konuda Yapılan Çalışmaların Tarihsel Gelişimi……. 5

2. GÖRÜNTÜ SEGMENTASYONU ……..... 13
2.1. Yapay Sinir Ağları İle Görüntü Segmentasyonu……..... 15
2.1.1. Geriye yayılım yapay sinir ağı……. 16

3. DALGACIK DÖNÜŞÜMÜ……. 21
3.1. Dalgacık Tanımı……. 21
3.2. Dalgacık Karakteristikleri……..... 21
3.3. Dalgacık Analizi..…… 22
3.4. Dalgacık Dönüşümünün Geliştirilmesi……..... 22
3.4.1. Fourier Dönüşümü……..... 23
3.4.2. Kısa Zamanlı Fourier Dönüşümü……. 23
3.4.3. Dalgacık dönüşümüne geçiş……. 25
3.5. Dalgacık Dönüşümünün Teorik İfadesi…….. 25
3.5.1. Sürekli dalgacık dönüşümü……..... 25
3.5.2. Ayrık dalgacık dönüşümü…… 26
3.6. ADD' nin Gerçekleştirilmesi…….. 28

3.6.1. Filtre kümesi uygulaması…… 28
3.6.2. Mükemmel yeniden oluşturma…… 29
3.7. ADD' nin İki Boyut İçin Genişletilmesi…… 30
3.8. Ayrık Dalgacık Dönüşümünün Sınırları…… 32
3.8.1. Değişime duyarlılık……. 32
3.8.2. Zayıf yönlülük……. 33
3.8.3. Faz bilgisinin eksikliği…… 34

4. KOMPLEKS DEĞERLİ DALGACIK DÖNÜŞÜMÜ…… 36
4.1. KDDD' nin Tarihçesi……. 36
4.2. Fazlalık Kompleks Değerli Dalgacık Dönüşümü……..... 37
4.2.1. Analitik filtre yapıları……..... 37
4.2.2. İkili ağaç – kompleks değerli dalgacık dönüşümü (İA-KDDD)……. 39
4.2.2.1. İA-KDDD' nin filtre kümesi yapısı……. 40
4.2.2.2. Kingsbury' nin İA-KDDD (İA-KDDD(K)) …… 43
4.2.2.2.1 Değişime karşı sabitliğin kısıtlamaları……..... 45
4.2.2.2.2 Tek-çift uzunluktaki filtreler……..... 46
4.2.2.2.3 Çeyrek-kaymalı filtreler…….. 46
4.2.2.3. Selesnick' in İA-KDDD (İA-KDDD(S)) …… 47
4.2.3. İA-KDDD' nin özellikleri…… 49
4.2.3.1. Değişime duyarsızlık…… 49
4.2.3.2. Yönlülük……... 50
4.2.3.3. Faz bilgisi……. 51
4.2.3.4. Mükemmel yeniden oluşturma……. 51
4.2.3.5. Sınırlı fazlalık…… 51

5. KOMPLEKS-DEĞERLİ YAPAY SİNİR AĞI (KDYSA)…….. 53
5.1. Kompleks Değerli Öğrenme Teoremi……. 54
5.2. Reel Geriye Yayılım Algoritmasının Kompleks Değerli Geriye Yayılım Algoritmasına Genelleştirilmesi……..... 55
5.3. Kompleks Değerli Aktivasyon Fonksiyonu…… 58

6. HÜCRESEL YAPAY SİNİR AĞI……. 61
6.1. HYSA Mimarisi…….. 61
6.2. HYSA Eğitimi…… 65
6.3. HYSA Yapısı……. 67

7. KOMPLEKS DEĞERLİ HİBRİT HÜCRESEL YAPAY SİNİR AĞI…. 69

8. AKCİĞER KANSERİ……..... 75
8.1. Akciğer Tümörleri……..... 76
8.1.1. Benign nodüller…… 76
8.1.2. Malign nodüller…… 77
8.2. Akciğer Nodüllerinin Görüntülenmesi…….... 77
8.2.1. Konvansiyonel BT……..... 78
8.2.2. Yüksek çözünürlüklü BT……. 78
8.2.3. Spiral BT……. 78
8.3. Akciğer Nodüllerine Biyopsi Uygulaması…….. 79

9. AKCİĞER NODÜLLERİNİN SINIFLANDIRILMASI İÇİN GELİŞTİRİLEN YAPILAR VE UYGULAMALARI…… 80
9.1. Tez Çalışmasında Kullanılan BT Görüntüleri…… 81
9.2. Uygulama Sonuçlarının Değerlendirilmesinde Kullanılan Performans Kriterleri……. 83
9.2.1. Segmentasyon sonuçlarının değerlendirilmesi…… 83
9.2.2. Sınıflama sonuçları için eğitim ve test hatası……..... 84
9.2.3. Sınıflayıcı performanslarının değerlendirilmesi……..... 84
9.3. Akciğer Bölgesinin Segmentasyonu……... 86
9.3.1 KDDD-KDHHYSA ile gerçekleştirilen segmentasyon sonuçları…… 88
9.4. Akciğer Nodüllerinin Sınıflandırılması……..... 96

10. TARTIŞMA……. 105

11.SONUÇLAR VE ÖNERİLER……. 107

11.1. Sonuçlar…….. 107
11.2.Öneriler……..... 120

12. KAYNAKLAR……..... 122

EKLER……..... 133
EK 1: Kompleks-Değerli Hibrit Hücresel Yapay Sinir Ağı Algoritması Matlab Kodları……..... 134
EK 2: Nodül Sınıflama İçin Kompleks-Değerli Yapay Sinir Ağının Matlab Kodları……..... 144
EK 3: Akciğer Görüntülerinin Alındığı Philips MX-8000 BT Cihazı 154

SİMGELER VE KISALTMALAR

YSA: Yapay sinir ağları

MR: Manyetik Rezonans

BT: Bilgisayarlı Tomografi

PET: Positron emission tomography

SPECT: Single photon emission computed tomography

DD: Dalgacık dönüşümü

ADD: Ayrık dalgacık dönüşümü

SDD: Süreklı dalgacık dönüşümü

2B ADD: 2 boyutlu ayrık dalgacık dönüşümü

FD: Fourier dönüşümü

KZFD: Kısa zamanlı Fourier dönüşümü

KDDD: Kompleks değerli dalgacık dönüşümü

İA-KDDD: İkili-Ağaç Kompleks Değerli Dalgacık Dönüşümü

İA-KDDD(K): Kingsbury' e ait İkili-Ağaç Kompleks Değerli Dalgacık Dönüşümü

İA-KDDD(S): Selesnick' e ait İkili-Ağaç Kompleks Değerli Dalgacık Dönüşümü

FKDDD: Fazlalık Kompleks Değerli Dalgacık Dönüşümü

KDYSA: Kompleks-değerli yapay sinir ağı

GY: Geriye yayılım

KGY: Kompleks geriye yayılım

$\psi(t)$: Ana dalgacık fonksiyonu

$\Psi(w)$: $\psi(t)$ ' nin Fourier dönüşümü

$\widetilde{f(t)}$: ters dalgacık dönüşümü ile yeniden elde edilen sinyal

y: Yapay sinir ağı çıkışı

W_{nm}: n ve m nöronu arasındaki ağırlık

X_m: m nöronu için giriş sinyali

f_C: Kompleks değerli aktivasyon fonksiyonu

f_R: Reel değerli aktivasyon fonksiyonu

ΔW_{ml}: Gizli katman ağırlıklarının güncelleme değeri

$\Delta\theta_{m1}$: Gizli katman biaslarının güncelleme değeri

ΔV_{nm1}: Çıkış katmanı ağırlıklarının güncelleme değeri

$\Delta\gamma_n$: Çıkış katman biaslarının güncelleme değeri

HYSA: Hücresel yapay sinir ağı

KDHHYSA: Kompleks değerli hibrit hücresel yapay sinir ağı

DP: Doğru pozitif

DN: Doğru negatif

YP: Yanlış pozitif

YN: Yanlış negatif

BDT: Bilgisayar destekli teşhis

ŞEKİLLER LİSTESİ

Şekil-2.1. Sınıflama için kullanılan en basit nöron yapısı…… 17

Şekil-2.2 Bir gizli katmanlı ileri beslemeli geriye yayılım yapay sinir ağı…….. 18

Şekil 3.1 Dalga (a) ve dalgacığın (b) gösterimi……..... 22

Şekil 3.2 Zaman-ölçek düzleminde standart ADD gösterimi……... 27

Şekil 3.3 Üçüncü seviyeden analiz filtre kümesi……..... 28

Şekil 3.4 Üçüncü seviyeden sentez filtre kümesi……..... 29

Şekil 3.5 Basit bir iki kanallı filtre kümesi yapısı…….……... 29

Şekil 3.6. İki boyutlu ADD için bir seviyeli analiz filtre kümesi…..... 30

Şekil 3.7 İki boyutlu ADD ile bir görüntünün çoklu-seviyeli ayrıştırma hiyerarşisi ……. 31

Şekil 3.8 İki boyutlu ADD için frekans düzlem paylaşımı..…… 31

Şekil 3.9 Bir boyutlu standart ADD' nin değişime duyarlılığı…… 33

Şekil 3.10 İki boyutlu standart ADD' nin Yönlülüğü ……. 34

Şekil 3.11 Reel (a) ve analitik (b) dalgacığın gösterimi ……. 35

Şekil 4.1 Hilbert dönüşümü (a) kutupsal düzlemde (b) frekans düzleminde ….. 38

Şekil 4.2 Bir analitik filtrenin 2-reel filtre ile ifade edilmesi …….. 39

Şekil 4.3 (a) Bir boyutlu İA-KDDD için analiz filtre kümesi,(b) Bir boyutlu İA-KDDD için sentez filtre kümesi…….. 41

Şekil 4.4 İki boyutlu İA-ADD için filtre kümesi yapısı……... 42

Şekil 4.5. Şekil 4.4' te yer alan ağaç-a için filtre kümesi yapısı…….. 42

Şekil 4.6 Tek-çift filtreler kullanan analiz ağacı…….. 44

Şekil 4.7 Çeyrek-kaymalı filtreler kullanan analiz ağacı …… 44

Şekil 4.8 İA-KDDD için analiz ve sentez yapısı ……. 45

Şekil 4.9 Bir boyutlu İA-ADD' nün değişime duyarsızlık özelliği ……. 50

Şekil 4.10 İki boyutlu İA-ADD' nün yönlülük özelliği ……... 51

Şekil 5.1 Kompleks-değerli bir sayının (a) Reel-değerli YSA ile işlenmesi (b) Kompleks-değerli YSA ile işlenmesi ……..... 53

Şekil 5.2. KGY algoritmasında kullanılan nöron modeli (giriş, çıkış ve ağırlıklar kompleks sayıdır)..…… 56

Şekil 6.1. İki boyutlu (3x3), HYSA gösterimi…….. 62

Şekil 6.2. Hücrenin dinamik yapısı…….. 63

Şekil 6.3. r=1 ve r=2 komşuluk için HYSA'nın hücre ilişkileri …….. 64

Şekil 6.4. Hücresel yapay sinir ağı yapısı …… 67

Şekil 7.1. Kompleks değerli hibrit hücresel YSA ……... 73

Şekil 7.2. Kompleks değerli hibrit hücresel YSA' nın akış şeması ……. 74

Şekil 8.1 26 no.lu hasta için BT klavuzluğunda iğne biopsisi görüntüsü (a)-(b)-(c)' de yer alan beyaz renkli oklar biopsi iğnesinin akciğer bölgesine girişini ve nodül içerisinden parça alışına işaret etmektedir……. 79

Şekil 9.1 Benign nodüller içeren BT görüntüleri (a) 1 nolu hastaya ait görüntü (b) 3 nolu hastaya ait görüntü (c) 7 nolu hastaya ait görüntü (b) 8 nolu hastaya ait görüntü …… 82

Şekil 9.2 Malign nodüller içeren BT görüntüleri (a) 11 nolu hastaya ait görüntü (b) 22 nolu hastaya ait görüntü (c) 26 nolu hastaya ait görüntü (b) 28 nolu hastaya ait görüntü ……..... 82

Şekil 9.3 Segmentasyon için önerilen yapının blok gösterimi …… 88

Şekil9.4 KDHHYSA' ya segmente edilmesi için sunulan giriş görüntüleri (a-c-e-g) ve bunlara karşılık gelen hedef görüntüleri (b-d-f-h)…… 89

Şekil 9.5 Akciğer nodüllerinin sınıflandırılması için önerilen yapı……... 98

Şekil 9.6 Segmentasyon ve sınıflama bloklarından oluşan tüm sistem…….. 99

ÇİZELGELER LİSTESİ

Çizelge 1.1. Tez konusunun veri tabanı istatistikleri……..... 12

Çizelge 4.1. İA-KDDD ve Standart ADD' nin karşılaştırmalı özeti…… 52

Çizelge 9.1. Tezde kullanılan BT görüntülere ait özellikler…..... 83

Çizelge 9.2 Sınıflayıcılar için karmaşıklık matrisi……... 85

Çizelge 9.3 S1-KDHHYSA ile gerçekleştirilen segmentasyon sonuçları…… 91

Çizelge 9.4 S2-KDHHYSA ile gerçekleştirilen segmentasyon sonuçları…… 92

Çizelge 9.5 S3-KDHHYSA ile gerçekleştirilen segmentasyon sonuçları ……... 95

Çizelge 9.6 S4-KDHHYSA ile gerçekleştirilen segmentasyon sonuçları……..... 96

Çizelge 9.7 S1 KDDD-KDYSA İçin Nodül Sınıflama Sonuçları ……... 102

Çizelge 9.8 S2 KDDD-KDYSA İçin Nodül Sınıflama Sonuçları ……... 103

Çizelge 9.9 S3 KDDD-KDYSA İçin Nodül Sınıflama Sonuçları ……..... 103

Çizelge 9.10 S4 KDDD-KDYSA İçin Nodül Sınıflama Sonuçları ……. 103

Çizelge 9.11 S2 KDDD-KDYSA - S4 KDDD-KDYSA Yapıları ile 2. Ve 9. Geçerlilik Setleri için Elde Edilen Test Sonuçları ve Hedefler…… 104

Çizelge 11.1 Segmentasyon için önerilen yapılar ile elde edilen sonuçlar..…… 108

Çizelge 11.2 Benign ve Malign görüntüler için KDHHYSA' nın en iyi ve en kötü doğruluk ile segmente ettiği görüntülerin KDYSA ile segmente edilmesi ve sonuçlar.……... 109

Çizelge 11.3 Nodül sınıflaması için kullanılan yapıların elde ettiği sınıflama sonuçlarının karmaşıklık matrisi ile gösterimi (a) S1-KDDD KDYSA (b) S2-KDDD KDYSA (c) S3-KDDD KDYSA (d) S4-KDDD KDYSA……. 110

Çizelge 11.4 Sınıflama sonuçlarının değerlendirilmesi……... 112

Çizelge 11.5 Tez çalışmasının literatür ile karşılaştırılması……. 115

1. GİRİŞ

Akciğer kanseri akciğer dokularındaki hücrelerin kontrolsüz çoğaldığı bir hastalıktır. Bu çoğalan hücrelerin komşu hücreleri etkilemesi ve başka dokulara nüfuz etmesi halinde yayılma meydana gelir. Akciğer kanserinin belirtileri hastalığın nerede başladığına, nasıl yayılmış olduğuna ve vücudun hastalığa tepkilerinin varlığına bağlı olarak fark edilebilir. En sık görülen belirtileri, nefes darlığı, öksürme ve kilo kaybıdır. Bu belirtiler sadece akciğer kanserine özgü olmadığı için hastaların tanı alması gecikebilir. Akciğer kanseri tanısında genellikle bilgisayarlı tomografi (BT) görüntülerinden faydalanılır. Kesin tanı ise biyopsi ile konulmaktadır ve bu işlem BT-yardımlı biyopsi ile gerçekleştirilir. BT ile akciğerde kansere sebep olan nodüllerin (genellikle küresel şekilli, nispeten sert bir hücre grubu) belirlenmesi oldukça önemlidir. Belirleme işlemi için, görüntülemede kullanılan BT cihazının desteklediği bir bilgisayar destekli teşhis (BDT) yazılımı ya da bu amaç için geliştirilmiş akıllı BDT yazılımları mevcuttur.

Tez çalışmasında, akciğer BT görüntülerinden akciğer bölgesini çıkartan (segmentasyon işlemi) ve akciğer içerisinde yer alan benign (iyi huylu) ve malign (kötü huylu) nodülleri birbirinden ayıran (sınıflama işlemi) yeni bir akıllı BDT sistemi oluşturulmuştur. Tez çalışması on iki ana bölümden oluşmaktadır.

Birinci bölümde, tez konusunun tanıtımı yapılmış, tezin amacı ve önemi açıklanmıştır. Ayrıca, bu alanda yapılmış çalışmaların tarihsel gelişimine yer verilmiştir. İkinci bölümde, görüntü segmentasyonu üzerinde durulmuştur. Segmentasyonun tanımı ve yapay sinir ağları (YSA) ile segmentasyon işleminin nasıl yapıldığı incelenmiştir. Üçüncü bölümde reel-değerli dalgacık dönüşümü ve özelliklerine değinilmiştir. Dördüncü bölümde, tezde kullanılan biyomedikal görüntülerden özelliklerin çıkarılması veya görüntülerin boyutlarının azaltılması amacı ile kullanılan kompleks-değerli dalgacık dönüşümü incelenmiştir. Kompleks değerli dalgacık dönüşümünün tarihi, geliştirilmesi, reel-değerli dalgacık dönüşümü yerine kullanılmasının sebepleri detaylı olarak açıklanmıştır.

Beşinci bölümde kompleks-değerli öğrenme algoritmaları ve reel-değerli YSA' nın kompleks-değerli YSA (KDYSA) olacak şekilde genelleştirilmesi incelenmiştir. Görüntü işleme uygulamalarında oldukça geniş bir yer bulan hücresel

yapay sinir ağı (HYSA) ve öğrenme teoremleri altıncı bölümde ele alınmıştır. Yedinci bölümde KDYSA ile HYSA kullanılarak oluşturulan ve yeni bir yapı olan kompleks-değerli hibrit hücresel yapay sinir ağı (KDHHYSA) tanımlanmıştır.

Sekizinci bölümde, tez çalışmasına konu olan akciğer kanserinin tanımı, medikal altyapısı, görüntülenmesi ve değerlendirilmesi incelenmiştir.

Dokuzuncu bölümde, tezde kullanılan görüntüler ile ilgili istatistiki bilgiler verilmiş, akciğer segmentasyonu ve nodül sınıflandırılması için önerilen yapılar ve elde edilen uygulama sonuçları değerlendirilmiştir.

Onuncu bölümde, tez çalışmasında önerilen yapının avantajları ve dezavantajları tartışılmıştır. On birinci bölümde, gerçekleştirilen çalışmanın sonuçları irdelenmiş, literatürde yer alan çalışmalar ile karşılaştırma yapılmıştır. Tez çalışmasından sonra gerçekleştirilecek olan ileriye yönelik çalışmalar için önerilerde bulunulmuştur.

On ikinci bölümde ise, tez çalışması sırasında faydalanılan bilimsel literatürün listesi yer almaktadır.

1.1. Tez Konusunun Tanıtılması

Gerçekleştirilen tez çalışmasında, akciğer BT görüntülerini yorumlayan radyoloji uzmanlarına ve kesin tanı koymak / tanıyı desteklemek için ihtiyaç duyulan biyopsi işlemini gerçekleştiren uzmanlara yardımcı olabilecek yeni bir akıllı BDT sistemi tasarlanmıştır. Bu yeni sistem ile, akciğer BT görüntülerini inceleyen uzmanların, akciğer bölgesinde yer alan nodüller hakkında ki yorumlarından (benign ya da malign olarak sınıflandırılmasından) önce bir ön değerlendirme yapılarak, karar verme aşamasına destek olunacaktır.

Bu yeni akıllı BDT sistemi, iki alt sistemin birleşiminden oluşmuştur. İlk olarak BT cihazından alınan görüntüden, sadece akciğer bölgesinin çıkartılması ve böylece gereksiz detayların ilgi alanından (yorumlamanın yapılacağı görüntü alanından) uzaklaştırılması işlemi gerçekleştirilmiştir. Bu amaçla iki yapay zeka metodunun (HYSA ve KDYSA) hibrit bir yapı içerisinde birleştirilmesi ile elde

edilen yeni bir yapay zeka algoritması (KDHHYSA) kullanılmıştır. Bu algoritmanın kullanımı sonucunda elde edilen ve sadece akciğer bölgesini içeren yeni görüntünün boyutları, işlem kolaylığı sağlayabilmek ve işlem süresini azaltabilmek amacı ile kompleks-değerli dalgacık dönüşümü kullanılarak azaltılmıştır. Boyutu azaltılmış görüntüler kompleks-değerli yapay sinir ağları ile sınıflandırılmış ve akciğer BT görüntüleri, içerisinde yer alan nodüllerin benign ve malign olmasına göre ayrıştırılmıştır..

Gerçekleştirilen bu BDT yazılımı, hastanelerde kullanılan BT cihazları ile birlikte kullanılan BDT yazılımlarında veya literatürde yer alan farklı BDT yazılımlarında yer almayan yeni bir özelliği yani benign ve malign nodüllerin sınıflandırılmasını içermektedir.

1.2. Tez Konusunun Amacı ve Önemi

Dünya Sağlık Örgütü' nün 2004 yılında yayınladığı "Dünya Sağlık Raporu" ve 2008 yılında yayınladığı "Kanser Raporu" na göre tüm kanser türleri arasında en ölümcül kanser türü olan akciğer kanseri tüm dünyada kanser türleri arasında, erkeklerde en sık ölüme neden olan birinci, kadınlarda ise ikinci kanser türüdür ve tüm dünyada her yıl yaklaşık 1.3 milyon ölüme neden olmaktadır. Akciğer kanseri, 20. yüzyılın başlarında nadir bir hastalık iken, bugün her iki cinsiyette de kanserden ölümlerinin başında yer almaktadır. Ölüm oranı oldukça yüksek olan bu kanser türünde dünya genelinde sigara içme alışkanlıklarındaki değişmeye bağlı olarak görülme sıklığında artma gözlenmiştir (Köktürk ve ark. 2004).

Türkiye'de kanserli hasta verilerinin toplanmasındaki sorunlar sebebiyle, bu konuda istatistik sonuçları oldukça yetersizdir. Ancak, T.C. Sağlık Bakanlığı'nın 2007 yılında yapmış olduğu Türkiye' de Kanser Kontrolü isimli yayın önemli istatistiki bilgilere yer vermektedir. Buna göre, kanser insidansı (hastalığın yeni vakalar gösterme oranı) 2000 yılı için yüzbinde 49.29, 2001 yılında yüzbinde 60.49 ve 2002 yılında yüzbinde 70.24' dür. Cinsiyete göre kanser insidans hızı 2000 yılı için kadınlarda yüzbinde 40.16 iken erkeklerde yüzbinde 58.18 olmuştur. 2002 yılı

verileri incelendiğinde ise insidans hızlarınının arttığı ve kadınlarda yüzbinde 59.57' ye, erkeklerde ise yüzbinde 80.43' e ulaştığı görülmüştür. 2002 yılı içinde en sık görülen beş kanser türüne bakıldığında yüzbinde 11.26 insidans hızı ile akciğer kanserinin birinci sırada yer aldığı belirlenmiştir. Akciğer kanserini sırasıyla meme kanseri (yüzbinde 7.79), mide kanseri (yüzbinde 4.92), deri kanseri (yüzbinde 4.55) ve mesane kanseri (yüzbinde 3.66) izlemektedir.

2005 yılında dünyada meydana gelen toplam 58 milyon ölümün yaklaşık 7.6 milyonu (%13' ü) kanserden kaynaklanmıştır. Genel kanser ölümleri arasındaki en yüksek orana ise 1.3 milyon ölüm / yıl ile akciğer kanseri sahiptir. Hazar 2006, Türkiye' de her yıl yaklaşık 25000 kişinin akciğer kanserinden öldüğü tahminine yer vermiştir.

Türkiye için erkeklerde ve kadınlarda kanserlere bağlı 2010, 2020 ve 2030 yılında beklenen ölüm sayılarına göre kansere bağlı gerçekleşmesi beklenen ölüm sayısı erkekler için 2010 yılında 44616, 2020 yılında 61076 ve 2030 yılında 89117 olarak tahmin edilmektedir. Buna göre kanserlere bağlı gerçekleşmesi beklenen ölüm sayısı kadınlarda 2010 yılı için 25037, 2020 yılı için 31099 ve 2030 yılı için 39094 olarak tahmin edilmektedir. 2030 yılı için tüm dünyada kanser sebebi ile ölüm sayısı ise 11.4 milyon olarak tahmin edilmektedir (Türkiye' de Kanser Kontrolü, 2007).

Hem yüksek ölüm oranına sahip olması hem de tedavi maliyetlerinin çok yüksek olması akciğer kanserinin teşhisini de oldukça önemli hale getirmiştir. Akciğer kanserleri genellikle BT kullanılarak görüntülenmektedir. BT cihazından elde edilen görüntüler uzman radyologlar tarafından değerlendirilmektedir. Radyologların, BT görüntülerinden belirledikleri nodüller hakkında benign ya da malign kararı vermelerini kolaylaştırmak amacı ile BDT sistemleri kullanılmaktadır. Literatürde yer alan birçok çalışmada, BDT sistemlerinin ve BT görüntülerini yorumlayan radyologların deneyim sürelerinin kanser hakkında verilen kararın doğruluğu üzerine yaptığı etkiler incelenmiştir. Gerçekleştirilen bu çalışmaların sonucunda, BDT sistemlerinin radyologların performansını geliştirdiği ve radyologların uzmanlık alanları ile bu alanda çalıştıkları yıl sayısına bağlı olarak yapılan teşhislerdeki doğruluğun arttığı görülmüştür.

Tez çalışmasında yeni bir akıllı BDT sistemi tasarlanmıştır. Bu BDT sistemi ile, kompleks-değerli dalgacık dönüşümü ve kompleks-değerli yapay sinir ağlarının bu alandaki ilk uygulamalarının gerçekleştirilmesinin yanı sıra, kompleks-değerli hibrit hücresel yapay sinir ağı ilk kez bu tez çalışması ile akciğer bölgesinin segmentasyonu işleminde kullanılmak üzere önerilmiştir. Gerçekleştirilen BDT sistemi ile akciğerde bulunan benign ve malign nodülleri sınıflandıran ve şu anda sadece nodüllerin tespit edilmesi için kullanılan mevcut BDT sistemlerinin yerine geçebilecek yeni bir BDT sisteminin oluşturulması amaçlanmıştır. Uzman doktor yorgunluğu, tecrübe eksikliği, görüntüde oluşan nodüle benzeyen yapıların ayrıştırılmasındaki zorluklar, biyopsi sonuçlarının bile tamamen doğru olmaması vb. faktörlerin hastalığın teşhisinde doğruluk yüzdesinin azalmasına sebep olduğu düşünüldüğünde geliştirilen bu yeni BDT sisteminin önemi ortaya çıkmaktadır (*Osma 2000: İğne biyopsisi ile malign nodüllerde % 95 oranında tanı alınabilmekte iken, benign nodüllerde bu oran % 70' lere kadar düşmektedir*).

Ülkemizin tıp alanında sahip olduğu kısıtlı maddi imkanlar ve yetişmiş uzman sayısındaki yetersizlikler düşünüldüğünde, mevcut BT görüntüleme sistemlerine entegre edilerek, sistemlerin üzerinde bulunan BDT yazılımlarından veya bu alana yönelik olarak önerilmiş olan diğer akıllı BDT yazılımlarından daha yüksek doğruluk oranına sahip yeni bir BDT sisteminin önerilmesi oldukça önemlidir. Bu yeni BDT sistemi ile, hem radyolog kararlarını hem de radyolog kararlarına uygun olarak kesin teşhisi koymak için başvurulan biyopsi işlem sonucunu desteklemek ve ön-tanı koymak mümkün olacaktır. Tez çalışması ile radyoloğun veya biyopsi uzmanının kararlarına destek olabilecek bir mekanizma oluşturulmuştur.

1.3. Bu Konuda Yapılan Çalışmaların Tarihsel Gelişimi

Çeşitli bilgisayar destekli teşhis metotları, akciğer nodüllerinin tespitinde uzmanlara yardımcı olarak kullanılmışlardır. Ginger ve ark. (1994), nodül tespiti için çoklu gri seviye eşikleme ve kurala dayalı yaklaşım metodu kullanırlarken, Lo ve

ark. (1995) iki aşamalı bir sistem önermişlerdir. Buna göre, ilk aşamada nodül olması muhtemel örnekler yerleştirilmiş, ikinci aşamada hücresel yapay sinir ağı (HYSA) kullanılarak nodül olanlar ile olmayanlar ayrıştırılmıştır. Nodüllerin tespitinde YSA kullanımını takip eden bir diğer çalışmada ise Xu ve ark. 1997, ileri yönlü YSA ve karar kurallarının bir kümesini kullanmışlardır. Bu çalışmalar, akciğer nodüllerinin tespitinde YSA' nın kullanımına ilişkin erken dönem çalışmaları olarak adlandırılabilirler.

Kanazawa (1998), bulanık kümeleme, Penedo ve ark. (1998) ise iki ayrı yapay sinir ağı (ilk ağ ile şüpheli bölgelerin tespiti, ikinci ağ ise sınıflama için) kullanarak çeşitli çalışmalar geliştirmişlerdir. Bu sistemde şüpheli bölgeler düşük-çözünürlüklü bir görüntüden elde edilmiş ve sonra nodülleri yerleştirmek için yerel görüntü eğrilikleri (eğimleri) analiz edilmiştir. 90 gerçek, 288 simüle edilmiş nodül YSA ile sınıflandırılmış ve duyarlılık % 89- % 96, görüntü başına yanlış pozitif sayısı ise 5-7 olarak elde edilmiştir. Bu çalışmayı takiben, yanlış pozitiflerin sayısını düşürebilmek amacı ile farklı yapay-zeka teknikleri ve hibrit sistemlerin kullanıldığı yeni çalışmalar da ortaya çıkmıştır. Bulanık kümeleme ve model temelli bölütleme teknikleri kullanarak akciğer nodül tespiti için hastaya-özel bir model geliştiren Brown ve ark. (2001), nodüllerin tespitinde % 81' lik bir doğruluk oranı elde etmişler ve 27 nodülün 22 ' sini doğru olarak belirlemişlerdir. Yanlış pozitif oranı ise 10 olarak tespit edilmiştir.

BT görüntülerinden pulmoner nodüllerin tespitinde farklı yapay zeka tekniklerinin kullanımına örnek olabilecek diğer bir çalışma Lee ve ark.(2001)' na aittir. Şablon eşleştirme için farklı referans örneklerinden yeterli şablon görüntülerini seçmek ve incelenen görüntüdeki hedef pozisyonunu verimli bir şekilde tanımlamak için genetik algoritmanın önerildiği bu çalışmada 20 farklı hastaya ait olan görüntülerde yer alan toplam 98 nodülden 71'i (% 72) doğru (nodül) olarak eşleştirilmiştir.

Jianzhong ve ark. (2002), geliştirilen BDT sistemlerinin, radyologların nodül tespitinde vermiş oldukları kararların doğruluğunu artırdığını gösteren bir çalışma gerçekleştirmişlerdir. Otomatik adaptif histogram analizi, dinamik çapraz korelasyon analizi ve veri boyutunu azaltma teknikleri kullanarak otomatik hacim izdüşüm analizi yöntemleri ile bir nodül belirleme sistemi tasarlanmıştır. Bu sistem, düşük-

dozlu çoklu-dilimli BT ile incelenmiş 10 hastadan alınan görüntüler üzerine uygulanmış ve görüntü başına ortalama 3.2 yanlış pozitif elde edilmiştir. Bu sistemi kullanan radyoloğun, sistemi kullanmadan sadece kendi yorumu ile tespit edebildiği nodül sayısından yaklaşık iki kat fazla sayıda nodülü tespit edebildiği görülmüştür. Bu sonuç, radyologlara yardımcı olacak yeni BDT sistemlerinin tasarımının gerekliliğini bir kez daha ortaya koymuştur. Bu gerekliliği destekleyen diğer bir çalışma, Matsuki ve ark. (2002) tarafından yapılan, yüksek-çözünürlüklü BT' de kötü huylu nodüllerden iyi huylu nodüllerin ayrılması işleminde YSA' nın yararlılığının, alıcı işletim karakteristik analizi yapılarak değerlendirilmesidir. Çalışmada 3 cm den küçük olan 155 nodül (99 kötü huylu nodül ve 56 iyi huylu nodül) kullanılmıştır. 7 klinik parametre ve 16 radyolojik bulgudan oluşan özellikler YSA' da kullanılmıştır. Yüksek çözünürlüklü BT görüntüleri 12 farklı radyoloğa ilk olarak YSA çıkışları olmadan, daha sonra da YSA çıkışları ile birlikte verilmiştir. YSA sonuçları olmaksızın radyologların yaptığı nodül tespitlerinin ortalaması alınarak alıcı işletim karakteristik eğrisi çizdirilmiş ve eğri altında kalan alan 0.831 olarak hesaplanmıştır. Radyologlara YSA çıkışları ile birlikte BT görüntülerinin verilmesi halinde ise bu alan 0.959 olarak (ideal değer 1' e daha yakın) bulunmuştur.

BDT sistemlerine bir diğer örnek, Armato ve ark. (2002)' nın gerçekleştirdiği, iki boyutlu işlem (bölütleme), üç boyutlu analiz (gri seviye eşikleme, nodül adaylarının belirlenmesi ve özelliklerinin hesaplanması) ve özellik çıkarma (kural temelli sistem kullanarak yanlış pozitiflerin azaltılması ve otomatik sınıflayıcı) bloklarından oluşan bir otomatik akciğer nodülü belirleme sistemidir. Bu sistem ile, 38 kanserli nodülün 32' si (% 84) doğru sınıflanmıştır.

Coppini ve ark. (2003), YSA ile Gabor ve LoG filtreleri kullanarak bir BDT sistemi oluşturmuşlardır. Bu sistem, 247 radyogramdan oluşan bir veritabanı üzerinde denedikten sonra, 65 radyogram ile de test edilmiştir. Sistemin hassasiyeti %60-75, görüntü başına yanlış pozitiflerin sayısı ise 4-10 olarak bulunmuştur.

Farag ve ark. (2004), aynı tip nodüller içinde, tipik geometrileri ve gri-seviye dağılımlarını tanımlayan değişebilir 2 ve 3 boyutlu şablonlar kullanarak, nodül belirleme için yeni bir algoritma önermişlerdir. Belirleme algoritması, genetik optimizasyon kullanan çapraz-korelasyon şablon eşleştirme ve Bayesian sınıflama sonrası işlemlerini birleştirmiştir. Bu algoritma ile 130 nodülün 107' si doğru olarak

sınıflandırılmıştır. YSA temelli bulanık bir sistem ile BT görüntülerinden nodüllerin otomatik tespitini gerçekleştiren bir diğer çalışma ise Lin ve ark. (2005) tarafından önerilmiştir. 29 klinik vaka üzerinde çalışma yapılmış ve toplam duyarlılık % 89.3 olarak bulunmuştur. 2005 yılında yapılan bir diğer çalışma Suzuki ve ark. (2005)' na aittir. İyi huylu ve kötü huylu nodülleri birbirinden ayırabilmek için tüm eğitimli bir YSA (massive training ANN-MTANN) kullanarak bir BDT tasarımı gerçekleştirilmiştir. Çalışmada birbirinden farklı altı tip iyi huylu nodül ile kötü huylu nodülü sınıflamak için yedi adet MTANN den oluşan çoklu- MTANN tasarlanmıştır. Her bir MTANN, 10 farklı nodül ile eğitilmiştir. Test işlemi için 73 hastadan elde edilen 76 kötü huylu nodül ve 342 hastadan alınan 413 iyi huylu nodül kullanılmıştır. Nodül büyüklükleri 3 mm ile 29 mm arasında değişmektedir. Çalışmanın sonucunda, kötü huylu nodüllerin tamamı (76/76) doğru tanımlanırken, iyi huylu nodüller ancak % 48 (200/413) gibi düşük bir oranla tanımlanabilmiştir. İyi huylu nodüllerin sınıflanmasındaki bu başarısızlık, önerilen sistemin geliştirilmesi gerektiğini ortaya koymuştur.

Bae ve ark. (2005)' nın gerçekleştirdiği çalışmada ise morfolojik eşleştirme algoritması kullanılarak, BT görüntülerinden nodül tespitini otomatik olarak yapabilen bir BDT sistemi tasarlanmıştır. Bu sistemin ortalama duyarlılığı % 95.1 (164 nodülün 156' sı tespit edilmiştir) olarak bulunmuştur. Boyu 3 mm ile 5 mm arasında değişen nodüllerin tespitinde duyarlılık % 91.2 (52/57), 5 mm' den büyük nodüller için duyarlılık ise % 97.2 (104/107) olarak elde edilmiştir.

Yuan ve arkadaşlarının 2006 yılında yaptıkları çalışma BDT sisteminin nodül belirleme üzerine etkisini ortaya koymuştur. BT cihazına ait BDT sistemi kullanılmıştır. Ortalama sınıflama oranı sadece radyoloğun değerlendirmesi için % 83 ve sadece BDT sistemi için % 73 olarak bulunmuştur. Bu çalışmaya benzer bir diğer çalışma Awai ve ark. tarafından yine aynı yıl gerçekleştirilmiştir ve 2 yıllık bir çalışmanın sonuçlarını içermektedir. Bu çalışmada 18 malign ve 15 benign nodül değerlendirilmiştir. Nodüllerin sınıflandırılması için 10 adet 8-26 yıl arasında tecrübeye sahip radyolog, 9 adet te 1-4 yıl arası tecrübeye sahip radyologdan yardım alınmıştır. Radyologlar tarafından ilgili alanın belirlenmesi, segmentasyon, YSA ile sınıflama ve malign olasılığının tahmininden oluşan bir BDT sistemi tasarlanmıştır. Çalışma sonuçları şu şekilde özetlenmiştir. Duyarlılık değeri % 76.1 (8-26 yıl tec.

rad.), % 67.3 (1-4 yıl tec. rad.), % 71.9 (Tüm. rad.), % 72.2 (BDT); Belirlilik değeri % 89.3 (8-26 yıl tec. rad.), % 74.8 (1-4 yıl tec. rad.), % 82.5 (Tüm. rad.), % 75 (BDT) ve Pozitif Tahmin Oranı ise % 90 (8-26 yıl tec. rad.), % 77.2 (1-4 yıl tec. rad.), % 84 (Tüm. rad.), % 81.3 (BDT) olarak elde edilmiştir.

Yine 2006 yılında, Das ve ark., 1 yıl, 3 yıl ve 6 yıllık tecrübeye sahip 3 radyologun nodül belirleme performanslarını 2 BDT sistemini kullanarak test etmişlerdir. Kullanılan BDT sistemleri ImageChecker CT (R2 teknoloji) ve Nodule Enhanced Viewing (NEC) (Siemens) firmalarına aittir. 25 hastadan alınan BT görüntüleri ile çalışılmıştır. Duyarlılık oranları: 1 yıl tecrübesi bulunan radyolog için % 68 (BDT yok), % 79 (IC ile), % 79 (NEV ile); 3 yıl tecrübesi bulunan radyolog için % 78 (BDT yok), % 90 (IC ile), % 90 (NEV ile); 6 yıl tecrübesi bulunan radyolog için % 82 (BDT yok), % 84 (IC ile), % 86 (NEV ile)' dır.

Katı akciğer nodülleri üzerine Aubry ve arkadaşlarının 2006 yılında gerçekleştirdikleri çalışmada 25 görüntü için 2 radyologun nodül belirleme performansları üzerine BDT sisteminin etkisi incelenmiştir. BDT sistemi ile birinci radyologun nodül belirleme duyarlılığı % 9.6, ikinci radyologun nodül belirleme duyarlılığı % 23 oranında artmıştır. Ortalama doğruluk % 91.3 olarak elde edilmiştir.

Son dört çalışmada elde edilen sonuçlar incelendiğinde, mevcut BT görüntüleme sistemleri ile birlikte kullanılan BDT yazılımlarının radyologların tecrübelerine de bağlı olmak üzere, karar verme aşamasında onların performanslarını arttırdığı ancak yine de yeterli olamadığını ve yeni bir BDT sistemine ihtiyaç duyulduğunu ortaya koymuştur.

Lee ve ark. (2007), hastaların akciğer BT' lerinin görüntülenmesinde kullanılan iş istasyonu üzerinde bulunan BDT sisteminin (Siemens Medical Solutions- LungCARE VB20) performansını incelemişlerdir. 30 hastaya ait BT' ler incelenmiş ve toplam 210 nodül üzerinde çalışılmıştır. BDT sisteminin toplam eşleştirme oranı % 66.7 (140/210) olarak bulunmuş ve eşleştirme oranlarının, akciğer başına toplam nodül sayısının artması ile azaldığı belirlenmiştir. Osman ve ark. (2007), akciğer nodüllerinin belirlenmesinde 3 boyutlu şablon eşleştirme metodu kullanmışlardır. Üç boyutlu BT kullanarak, ilgi alanı dilimleri 3 boyutlu ilgi alanı

görüntülerine kombine edilmiştir. üç boyutlu şablon kullanarak nodüllerin benzer özellikli yapıları bulunmuştur.

2007 yılında Edis ve Karlıkaya tarafından yapılan ve akciğer kanserinin Türkiye' ye maliyetini hesaplayan çalışmanın sonuçları incelendiğinde, önerilen projenin önemi bir kez daha anlaşılabilmektedir. Ocak 2002-şubat 2003 tarihleri arasında Trakya Üniversitesi Tıp Fakültesi, Göğüs Hastalıkları Kliniği' ne başvuran 103 akciğer kanseri vakası üzerinde gerçekleştirilen çalışmaya göre, akciğer kanseri toplam maliyeti çalışma grubunda 1473530 Amerikan Doları ($) iken, hasta başına ortalama maliyet 14306 $ olarak bulunmuştur. Çalışmada, tüm kanser vakalarının (tahmini maliyeti 20 milyar $), % 20' sinin akciğer kanseri olduğu belirtilerek, Türkiye için yıllık maliyetin 3-4 milyar $ olacağı öngörülmüştür. Akciğer kanserine sebep olan nodüllerin erken ve doğru tespitinde radyologların karar vermesine ve uzman tarafından tedavi sürecinin yönetilmesine yardımcı olacak yeni BDT sistemlerinin ortaya çıkarılmasının, hastalığın tedavisindeki maliyeti azaltacağı ortadadır.

Enquobahrie ve ark.'nın 2007 yılında yaptıkları çalışmada akciğer nodüllerinin aranacağı alanın belirlenmesi, aday nodüllerin seçimi ve yanlış pozitif sayısının düşürülmesini içeren 3 adımlı bir BDT sistemi ile nodüller belirlenmiştir. Çalışılan görüntü veri tabanı nodül büyüklüklerine göre A ve B olmak üzere iki sınıfa ayrılmıştır. A veri tabanı için duyarlılık % 72.1, B veri tabanı için duyarlılık ise % 82.3 olarak elde edilmiştir.

2007 yılında yapılan bir diğer çalışmada ise Dehmeshki ve ark., şekil temelli genetik algoritma şablon-eşleştirme metodu kullanarak nodülleri belirlemişlerdir, sistemin oratalama doğruluğu % 90 olarak verilmiştir.

Hirose ve ark. 2008, çoklu dedektör BT ile alınan akciğer BT görüntülerinden nodül tespit edilmesi işleminde BDT sisteminin performansını incelemişlerdir. 21 hastadan alınan görüntülerin 6 tanesi nodül içermezken 15 tanesi nodül içermektedir. BDT kullanıldığında radyoloğun nodül belirleme duyarlılığı % 39.5' ten % 81' e çıkmıştır.

Hardie ve ark. 2008, adaptif uzaklık temelli eşik metodunu segmentasyon için kullanmışlardır. Görüntüye ait 114 özellik çıkarılmış ve daha sonra Fisher

diskriminant analiz metodu ile 46 özellik kullanılarak nodüller belirlenmiştir. Önerilen sistemin doğruluğu % 78.1' dir.

Bu alanda en son yapılan çalışmalardan birisi Kakar ve Olsen' e aittir. 2009 yılında yapılan bu çalışmada, Gabor filtre ile görüntüden özellikler çıkartılmış ve bulanık c-ortalamalar kümesi ile segmentasyon yapılmıştır. Daha sonra istatistiki özellikler çıkartılarak destek vektör makineleri ile nodüller belirlenmiştir. Elde edilen doğruluk % 92.47, duyarlılık ise % 89.48 olarak elde edilmiştir.

Bu alanda yapılan en yeni çalışmalardan biri de, Lee ve ark. 2009 tarafından gerçekleştirilmiştir. 92 kişiden alınan BT görüntülerinin kullanıldığı bu çalışmada farklı ilgi alan boyutları (32x32, 64x64) seçilmiş ve centrilobular emphysema, mild centrilobular emphysema, bronchiolitis obliterans ve normal akciğer olmak üzere 4 farklı akciğer rahatsızlığı saf Bayesian sınıflayıcısı (SBS), Bayesian sınıflayıcısı (BS), YSA ve destek vektör makineleri (DVM) metotları kullanılarak 5-kat çapraz geçerlilik prosedürü ile sınıflandırılmışlardır. En iyi sonuç DVM ile elde edilmiştir. Duyarlılık % 82.78, belirlilik % 94.2 ve doğruluk % 83.1 olarak belirlenmiştir.

Yukarıda verilen literatür özeti analiz edildiğinde, akciğer BT görüntülerinden kanserli bölgelerin belirlenmesi, iyi ve kötü huylu nodüllerin ayrıştırılması işleminde birbirinden oldukça farklı metotların kullanıldığı ancak bu metotların hiçbirinde nodüllerin ya da kanserli bölgelerin tamamının doğru olarak belirlenemediği (düşük hassasiyet oranı, yüksek yanlış pozitif sayısı) görülmüştür. Bu yetersizliği ortadan kaldırmak amacı ile tez çalışmasında, hücresel yapay sinir ağı, kompleks dalgacık dönüşümü temelli kompleks değerli yapay sinir ağı gibi literatürde bu alanda ilk kez yer alacak farklı yapay zeka metotları kullanılmıştır.

Tez çalışmasında gerçekleştirilen BDT sistemini oluşturan yapılar ile ilgili veri tabanı istatistikleri Çizelge 1.1' de sunulmuştur. Çizelge, en önemli üç veri tabanından (IEEE, Elsevier ve Web of Science), mart 2009 itibari ile yapılan taramalardan oluşturulmuştur. Çizelgeden de görüleceği gibi, literatürde bugüne kadar akciğer segmentasyonu ve nodüllerin sınıflandırılması alanında kompleks dalgacık dönüşümü, kompleks değerli yapay sinir ağı ve kompleks değerli hibrit hücresel yapay sinir ağı kullanılarak gerçekleştirilen herhangi bir çalışma yoktur.

Çizelge 1.1. Tez konusunun veri tabanı istatistikleri

Aranan kelime	IEEE		Elsevier Science Direct		Web of Science	
	Toplam	Son 2 yıl	Toplam	Son 2 yıl	Toplam	Son 2 yıl
Lung Segmentation	31	16	110	45	462	161
Lung Segmentation + WT	2	2	3	0	3	2
Lung Segmentation + CWT	0	0	0	0	0	0
Lung Segmentation + NN	0	0	33	12	27	6
Lung Segmentation + CVNN	0	0	0	0	0	0
Lung Segmentation + CVHCNN	0	0	0	0	0	0
Lung Nodule Classification	2	1	4	1	126	32
Lung Nodule Classification + WT	0	0	0	0	0	0
Lung Nodule Classification + CWT	0	0	0	0	0	0
Lung Nodule Classification + NN	1	1	4	1	16	3
Lung Nodule Classification + CVNN	0	0	0	0	0	0

WT: Wavelet Transform, CWT: Complex Wavelet Transform, NN:Neural network, CVNN:Complex Valued Neural Network, CVHCNN : Complex Valued Hybrid Cellular Neural Network

2. GÖRÜNTÜ SEGMENTASYONU

Görüntü segmentasyonu, ilgili görüntü yapısının zeminden (arka plandan) ve diğer görüntü bileşenlerinden ayrılması işlemidir (Bankman 2000). Bu işlem için görüntü işleme alanında oldukça çok sayıda algoritma geliştirilmiştir. Segmentasyon işleminde temel amaç, bir veya birden fazla karakteristik veya özelliğe uygun olarak görüntünün bölümlere (sınıflara veya alt kümelere) ayrılması işlemidir (Fu ve Mui 1981, Liang 1993, Suetens 1993, Bezek ve ark. 1993, Clarke ve ark. 1995).

Segmentasyon, medikal görüntü işleme uygulamalarında oldukça önemli bir araçtır. Biyomedikal alanda, anjiyogramda koroner sınırların belirlenmesi, çoklu doku sertleşmesi lezyonlarının ölçülmesi, ameliyat simülasyonları, cerrahi planlama, nodül hacminin ve terapiye cevabının ölçülmesi, fonksiyonel haritalama, kan hücrelerinin otomatik sınıflandırılması, beyin gelişiminin incelenmesi, mamografilerde mikro kireçlenmelerin belirlenmesi, görüntü kaydı, atlas-eşleştirme, kalp anjiyosundan kalp görüntüsünün çıkarılması, nodüllerin belirlenmesi, BT, MR vb. biyomedikal görüntülerden istenilen organların ya da dokuların (akciğer, karaciğer vb..) ileri aşamadaki işlemlerde kullanılabilmesi için ayrılması gibi işlemler segmentasyon işlemine örnektir (Golston ve ark. 1990, Brzakovic ve ark. 1990, Suetens 1993, Kikinis ve ar. 1996, Lucas-Quesade ve ark. 1996, Zhu ve ark. 1997).

Medikal görüntülemede, segmentasyon işlemi özellik çıkarma, imge ölçümü ve imge görüntülenmesi için önemlidir. Bir çok uygulamada imge piksellerinin kemik, kas ve kan damarları gibi anatomik alanlara ve kanser, doku deformasyonları, çoklu doku sertleşmesi lezyonları gibi patolojik alanlara ayrılması oldukça kullanışlı olmaktadır. Bir çok çalışmada amaç, giriş imgesini beyaz madde, siyah madde ve beynin serebrospinal (beyin ve omurilik ile ilgili) akışkan maddesi gibi (manyetik rezonans görüntüsünden beyin nodülünün çıkarılması örneğinde olduğu gibi) alt alanlara ayrılmasıdır.

Literatürde oldukça fazla segmentasyon tekniği yer almaktadır (Fu ve Mui 1981, Haralick ve Shapiro 1985, Mitiche ve Aggarwal 1985, Pal ve Pal 1993, Bezdek ve ark. 1993, Clarke ve ark. 1995, Nixon ve Aguado 2002, Bezdek ve ark. 2005).

Bununla birlikte, bütün görüntü uygulamaları için tatminkar sonuçlar üretecek standart bir segmentasyon tekniği yoktur. Segmentasyon işlemi, görüntünün tipine ve çalışmanın amacına uygun olarak seçilecek farklı segmentasyon algoritmalarının kullanılması ile gerçekleştirilmektedir.

Segmentasyon teknikleri aşağıdaki gibi sınıflandırılabilir (Bnakman 2000, Gonzalez ve Woods 2001):

1- Manuel, yarı-otomatik ve otomatik
2- Piksel tabanlı (yerel metotlar) ve alan tabanlı (global metotlar)
3- Manuel tarif, düşük-seviyeli segmentasyon (eşikleme, alan geliştirme vb..) ve model tabanlı segmentasyon (özellik haritalama teknikleri, dinamik programlama, kontur takibi vs..)
4- Klasik (eşikleme, kenar tabanlı ve alan tabanlı teknikler), istatistiksel, bulanık ve sinir ağı teknikleri

Ortak kullanılan segmentasyon teknikleri iki geniş kategoriye ayrılabilirler (Bankman 2000):

1- Verilen homojenite kriterine uygun alanlar arama esasına dayanan *alan segmentasyon teknikleri*
2- Farklı karakteristikler ile alanlar arasında sınırlar (kenarlar) arayan *kenar tabanlı segmentasyon teknikleri*

Eşikleme bir ortak alan segmentasyon metodudur. Bu teknikte bir eşik değeri seçilir ve imge piksel değerlerinin eşik değerinden büyük yada küçük olmasına göre piksel grupları sınıflandırılır. Farklı eşikleme metotları vardır: Gri seviye histogramlarını temel alan global eşikleme, yerel özellikleri temel alan global metotlar, yerel eşik seçimi ve dinamik eşikleme. Kümeleme algoritmaları, imgeyi özellik uzayında birbirlerine oldukça benzerlik gösteren piksellerin kümelerine veya setlere ayıran alan segmentasyonu kullanırlar. En basit işlem, her bir pikseli incelemek ve bu pikselleri, özelliklerini en iyi şekilde temsil eden kümeye dahil etmektir. Alan geliştirme, önceden seçilmiş yakınlık kriterlerine göre imge değerleri birbirine yakın olan komşu pikselleri yada alanları aynı segmente atayan diğer bir alan segmentasyon algoritmasıdır.

Kenar tabanlı segmentasyon algoritmalarının amacı, nesnelerin sınırlarını bulmak ve segment alanlarını bu sınırlarla çevirmektir. Bu algoritmalar, imgenin

karakteristiğine uygun olarak bir kenar operatörü tarafından üretilmiş genlik ve/veya faz imgelerinin kenarlarında işlem yaparlar. Örnek olarak, Prewitt, Kirsch veya Roberts operatörleri gibi en bilinen eğim operatörleri ideal bir adım kenarını temel almaktadır.

Geleneksel olarak, görüntü segmentasyon teknikleri görüntü tiplerinden birini (MR, BT, PET, SPECT, ultrason vb..) kullanırlar. Bununla birlikte, bu tekniklerin performansı farklı kaynaklardan alınan görüntülerin birleştirilmesi ile geliştirilebilirler.

2.1. Yapay Sinir Ağları İle Görüntü Segmentasyonu

Yapay sinir ağları (YSA) görüntü segmentasyonunda oldukça fazla kullanılan piksel sınıflama metotlarından birisidir (Dhawan 2003). YSA' lar doğru sınıflama için temel sınıf ihtimal dağılımını gerektirmemektedirler. Daha çok piksel sınıflama için iteratif eğitim işlemi ile karar sınırları oluştururlar. Bir çok YSA tabanlı segmentasyon işlemi medikal görüntüler için oldukça iyi sonuçlar vermiştir. Her bir medikal görüntünün sahip olduğu farklı karakteristik yapı sebebi ile adaptif doğrusal olmayan segmentasyon metotlarının önemi ortaya çıkmıştır. Özellikle geriye yayılım, radyal tabanlı fonksiyon ve kendinden organize özellik haritaları gibi YSA örnekleri kullanılmaktadır.

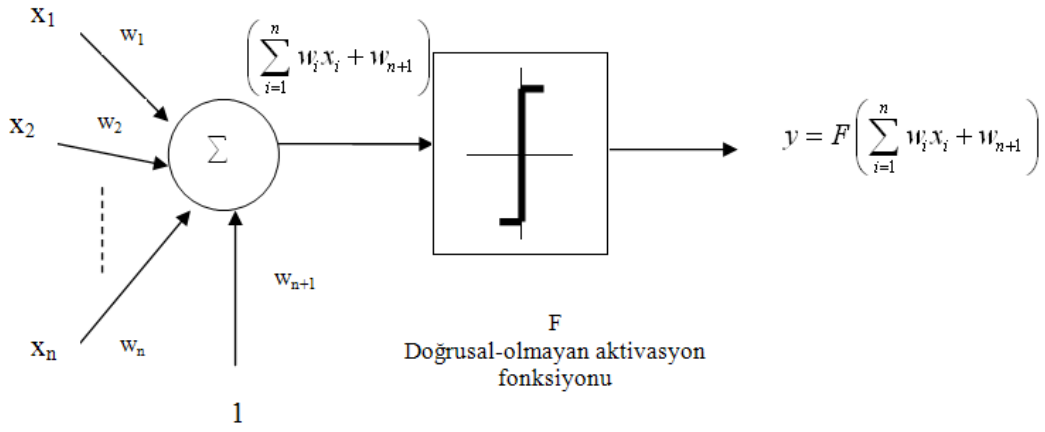
YSA' lar bir eğitim setindeki örnekleri kullanarak öğrenme işlemini gerçekleştirirler. Eğitim seti, manuel metotlar kullanılarak elde edilmiş piksel sınıflama işleminin sonuçlarını içermektedir. Etiketlenmiş örnekler için istenilen çıkış (hedef) ile giriş özellikleri arasındaki doğrusal olmayan haritalama fonksiyonu, herhangi bir harici parametre olmaksızın YSA tarafından öğrenilir. Öğrenme işleminden sonra yeni görüntüdeki pikseller, YSA tarafından segmente edilmesi amacı ile sınıflandırılırlar.

YSA' ya giriş olarak sunulan görüntülerin faydalı bir özellik setinin çıkartılması, sınıflama işlemi için oldukça önem taşımaktadır. Benzer şekilde, eğitim örneklerinin seçimi de oldukça önemlidir. Bu örnekler, giriş görüntüsünün istatistiki

bir dağılımını içermelidir. Ağın yapısı ve eğitim örneklerinin dağılımı, ağın performansının, genelleştirme kabiliyetinin ve sağlamlılığının tanımlanabilmesinde oldukça büyük bir rol oynar. En basit şekli ile, görüntüdeki önceden tanımlı komşulukta bulunan pikselin gri seviye değerleri, YSA' ya giriş olarak kullanılabilir. Böylece ağ, uygun komşuluktaki piksellerin tüm setini temel alan komşuluğun merkez pikselini sınıflayabilir. Bir komşuluk penceresi ile komşuluklara uygun olarak yeniden ifade edilen yani özelliği çıkarılan görüntü, komşulukların merkezinde yer alan piksele göre sınıflandırılabilir.

2.1.1. Geriye yayılım yapay sinir ağı

Geriye yayılım ağı, sinyal işleme ve sınıflama uygulamaları için en yaygın olarak kullanılan sinir ağıdır. Yapay sinir ağları, birbirine bağlı sinirsel (nöral) elemanların bir kümesi şeklinde oluşturulmuştur. Bu kümeler, katman olarak adlandırılmıştır. Perseptron olarak adlandırılan sayısal sinir elemanları bütün girişlerin ağırlıklandırılmış toplamlarının bir eşikten geçirilmiş hallerini çıkış olarak kullanırlar. Nöral elemanların basit bir fonksiyonu Şekil-2.1' de gösterilmektedir. Bu fonksiyon gösterimi biyolojik nöronların sinaptik aktivitelerine paralel bir gösterime sahiptir. Katmanlara sahip sinir ağı yapısında kullanılan nöral elemanlar, diğer nöral elemanlardan veya giriş vektörlerinden girişi alırlar. Bu girişlerin ağırlıklandırılmış toplamları, sigmoid fonksiyonu gibi bir doğrusal-olmayan aktivasyon fonksiyonunun girişlerini oluşturular. Aktivasyon fonksiyonunun sahip olduğu eşik değeri kullanılarak elde edilen yeni sonuç, nöral elemanın çıkışı olarak ifade edililir (Dhawan 2003).

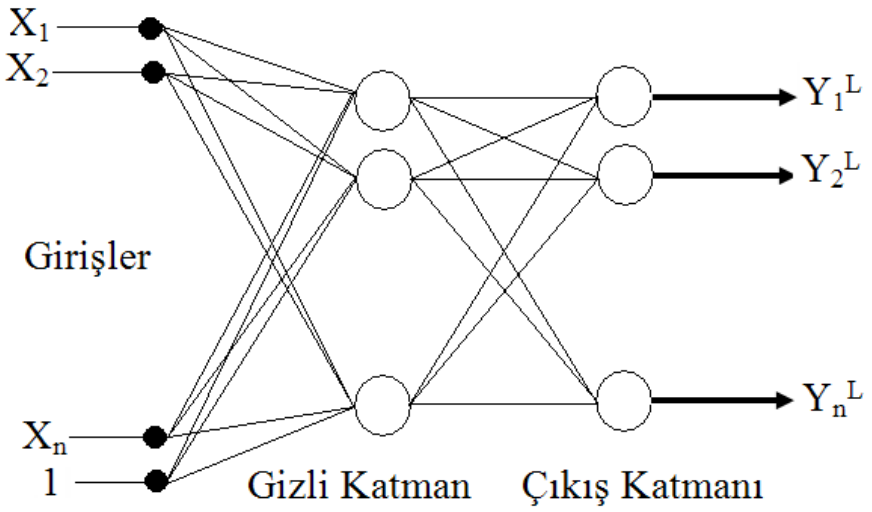


Şekil-2.1. Sınıflama için kullanılan en basit nöron yapısı

Giriş vektörlerinin sınıflandırılması için Widrow-Hoff Delta kuralı (Zurada 1992) olarak da adlandırılan en küçük ortalama kare algoritması gibi iteratif bir öğrenme algoritması kullanılarak giriş vektörleri ve ait oldukları sınıf bilgisi ile etiketlenmiş eğitim örnekleri sınıflandırılırlar. Örnek olarak, giriş vektörleri iki sınıfa ayrılacaksa, girişlerin ağırlıklandırılmış toplamları, 0 ve 1 ikili değerlerine göre eşiklendirilebilirler. Yani, çıkışın 0 olması birinci sınıfı, çıkışın 1 olması ikinci sınıfı gösterir. Öğrenme algoritması, eğitim için kullanılan giriş setini sinir ağına defalarca sunarak, uygun sınıflama çıkışlarını elde etmek üzere ağı zorlar. Ağ, tüm eğitim örneklerini istenilen sınıflara uygun olarak ayırdığında, bir başka deyişle sınıflama işlemi öğrenilmiş olduğunda, ağa yeni giriş vektörleri sunularak bu örneklerin de sınıflandırılması beklenir. Nöral elemanların çıkışı aşağıdaki şekilde ifade edilebilir:

$$y = F\left(\sum_{i=1}^{n} w_i x_i + w_{n+1}\right) \tag{2.1}$$

Burada F doğrusal-olmayan aktivasyon fonksiyonudur. x_i girişleri, w_i ağırlık katsayılarını, w_{n+1} ise bias elemanını göstermektedir. Şekil-2.2, bir gizli katmana sahip ileri beslemeli geriye yayılım yapay sinir ağını göstermektedir.



Şekil-2.2 Bir gizli katmanlı ileri beslemeli geriye yayılım yapay sinir ağı

L katmanlı ve N perseptronlu bir çok-katmanlı ileri-beslemeli YSA' nın her bir katmanı için,

$$y^{(k)} = F\left(W^{(k)} y^{(k+1)}\right) \qquad \text{k=1,2,...L} \tag{2.2}$$

ifadesi genelleştirilebilir. Burada $y^{(k)}$, k. katmanın çıkışını ifade etmektedir. k' nın 0 değerini alması halinde $y^{(0)}$ giriş katmanını göstermektedir. $w^{(k)}$ k. katman için ağırlık matrisidir. $y^{(k)}$ ve $w^{(k)}$ aşağıdaki eşitliklerle ifade edilebilir.

$$y^{(0)} = \begin{bmatrix} x_1 \\ x_2 \\ . \\ x_n \\ 1 \end{bmatrix} \; ; \; y^{(k)} = \begin{bmatrix} y_1^{(k)} \\ y_2^{(k)} \\ . \\ y_n^{(k)} \\ y_{(n+1)^k}^{(k)} \end{bmatrix} \tag{2.3}$$

$$w^{(k)} = \begin{bmatrix} w_{11}^{(k)} & w_{12}^{(k)} & \cdots & w_{1(n+1)}^{(k)} \\ w_{21}^{(k)} & w_{22}^{(k)} & \cdots & w_{2(n+1)}^{(k)} \\ . & . & \cdots & . \\ w_{(n+1)1}^{(k)} & w_{(n+1)2}^{(k)} & \cdots & w_{(n+1)(n+1)}^{(k)} \end{bmatrix} \tag{2.4}$$

YSA, girişler ve istenilen sınıflara uygun olarak etiketlenmiş çıkışlar kullanılarak eğitilir. Eğitimin amacı, eğitim setindeki her bir giriş vektörü için

istenilen çıkışı elde etmeyi sağlayan ağırlık matrisini tanımlamaktır. En küçük ortalama kare hatası algoritması [Fahlman ve Lebeire 1990, Zurada 1992] aşağıdaki adımlar takip edilerek kullanılarak ileri beslemeli YSA' nın eğitimi için kullanılmıştır:

1. Bütün w_{ij}^{k} ağırlıklarını [-1 +1] aralığında rastgele olarak belirle,
2. Eğitim setindeki her bir sınıflanmış örüntü çifti $\left[y^{(0)}, y^{L} \right]$ için aşağıdaki adımları uygula
   a- Başlangıçta rastgele olarak belirlenen ağırlık matrisini kullanarak her bir nöronun çıkış değerini hesapla
   b- Hesaplanan çıkış vektörü ile istenilen (hedef) vektörü arasındaki $e^{(k)}$ hatasını bul
   c- Bütün katmanlar için $\Delta w^{(k)} = \alpha . e^{(k)} \left[y(k-1) \right]$ olarak ifade edilen $\Delta w^{(k)}$ değişimini kullanarak ağırlıkları yeniden düzenle (α, öğrenme oranıdır ve genellikle 0-1 aralığında seçilmektedir)
3. Hata vektörü, her bir eğitim seti örneği için 0 değerine ya da kullanıcı tarafından belirlenen 0' a oldukça yakın bir değere ulaşıncaya kadar 2. adımı tüm örneklere uygula

Hata vektörü hesaplanırken, göz önünde bulundurulması gereken en önemli noktalardan birisi de doğrusal-olmayan aktivasyon fonksiyonunun kullanılmasıdır. Genellikle aktivasyon fonksiyonu olarak Eşitlik-2.5 ile ifade edilen sigmoid aktivasyon fonksiyonu veya bu fonksiyonun türevleri kullanılır. Seçilen aktivasyon fonksiyonun tanımlı olduğu aralık, YSA çıkışlarının tanımlı olduğu aralık olacağı için sınıflama problemlerinin çözümünde seçilecek aktivasyon fonksiyonunun tanım bölgesi göz önünde bulundurularak belirlenmesi gereklidir.

$$F(y) = \frac{1}{1+e^{-y}} \tag{2.5}$$

İleri beslemeli YSA' nın eğitimi için yukarıda tanımlanan bu eğim azalım algoritması geriye yayılım algoritması olarak da adlandırılır. Geriye yayılım algoritması kullanan YSA ile örüntülerin sınıflandırılmasında ağın genelleştirme performansının iyileştirilmesi için ağın yerel minimumlara ulaşmasını önleyecek

şekilde başlangıç ağırlıklarının seçilmesi ve eğitim setinin mümkün olduğu kadar bozuk örneklerden ayıklanmış olması gerekmektedir. Diğer bir önemli husus, optimum ağ yapısının yani optimum gizli katman sayısının ve gizli katmanda bulunacak nöron sayılarının belirlenmesidir. Optimum ağ yapısı genellikle deneme-yanılma yolu ile kullanıcı tarafından belirlenmektedir.

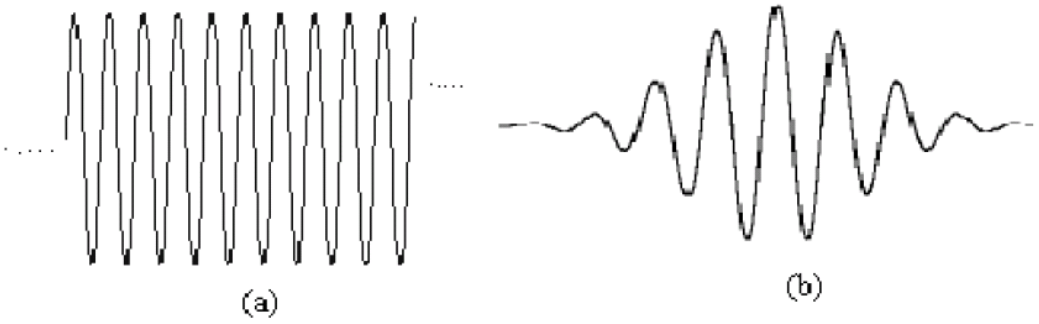
3. DALGACIK DÖNÜŞÜMÜ

3.1. Dalgacık Tanımı

'Dalgacık', zamanda enerjisi yoğunlaşmış küçük bir dalga olarak tanımlanmıştır. Dalgacık, anlık zaman ve frekans analizine imkan sağlayan ve geçici, durağan olmayan ve zamanla değişim sağlayan osilasyonlu bir dalga karakteristiği gösterir (Burrus ve ark. 1998, Mallat 1999).

3.2. Dalgacık Karakteristlikleri

Dalga (sinüsoidal) ve dalgacık arasındaki fark Şekil 3.1' de görülmektedir. Dalgalar, düzgün, tahmin edilebilir ve sonsuzdurlar. Dalgacıklar ise sınırlı bir süreye sahiptirler, düzensizdirler ve asimetrik olabilirler. Dalgalar, zamanda herhangi bir değişim göstermeyen (zamanda sabit olan) fonksiyonların (sinyallerin) genişletilmesi için Fourier analizindeki temel fonksiyonları belirleyici olarak kullanırlar. Dalgacıkların önemli bir karakteristiği, en iyi zaman-frekans gösterimini sağlamak amacı ile bir çok doğal sinyalin üretilmesi ve analizi için farklı fonksiyonları kullanırlar. Geleneksel Fourier analizi ile dalgacık fonksiyonunun oluşturulması mümkün değildir (Shukla 2003).



Şekil 3.1 Dalga (a) ve dalgacığın (b) gösterimi

3.3. Dalgacık Analizi

Dalgacık analiz prosedürü, 'analiz dalgacığı' veya 'ana dalgacık' olarak adlandırılan prototip bir dalgacık fonksiyonunu benimsemektir. Geçici analiz, prototip dalgacığın yüksek frekans versiyonu olarak bir daraltma işlemi gerçekleştirmektir. Frekans analizi, aynı dalgacığın alçak frekans versiyonunda gerçekleştirilir ve bir genişletme işlemi olarak ifade edilebilir. Dalgacıklar kullanarak sinyalin genişletilmesi için matematiksel formülasyon Fourier dönüşüm çiftine benzer şekilde bir dalgacık dönüşüm çifti olarak elde edilir. Dalgacık dönüşümünün (DD) ayrık-zaman ve ayrık-parametre versiyonu, literatürde Ayrık Dalgacık Dönüşümü (ADD) olarak adlandırılmaktadır (Cohen 1989, Daubechies 1990, Burrus ve ark. 1998).

3.4. Dalgacık Dönüşümünün Geliştirilmesi

Durağan olmayan sinyaller (müzik, konuşma, görüntü vb.) için zaman ve frekans yerleşimlerinin bilinmesi ve sinyallerin sahip oldukları anlık şekillerin görülebilmesi gibi ihtiyaçlar, oldukça popüler olan Fourier dönüşümünden dalgacık dönüşümünün geliştirilmesine yol açmıştır. Farklı zaman-frekans sunumları, DD' nin

modellenebilmesi ve anlaşılabilmesi için oldukça bilgilendiricidir (Hlawatsch ve Boudreaux-Bartles 1992).

3.4.1. Fourier dönüşümü

Fourier dönüşümü (FD), bilginin verimli olarak elde edilmesi için zaman domenindeki sinyali frekans domenine çeviren ve bu işlemin tersini de gerçekleştirebilen oldukça iyi bilinen matematiksel bir araçtır. Bir $x(t)$ sinyali için, Fourier dönüşümü şu şekilde verilebilir:

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi ft} dt \qquad (3.1)$$

DD, $x(t)$ sinyali bir kaç durağan bileşeni içerdiğinde (sinüs dalgası gibi) sinyallerin frekans içeriklerini oldukça başarılı bir şekilde elde etme yeteneğine sahiptir. Bununla birlikte, durağan olmayan bir $x(t)$ sinyali için zamanda anlık bir değişim olduğunda bu etki $X(f)$' in tüm frekans eksenine yayılır. Bu yüzden, dirac-delta fonksiyonu ile örneklenmiş zaman domenindeki sinyal zaman ekseninde oldukça belirgin bir konuma sahip olmasına rağmen tüm frekans bandı üzerinde yer almaktadır. DD' nin sahip olduğu bu sınırlılık (dezavantaj) sinyalin aynı zaman ve frekans yerleşimlerini vermemesi olarak ifade edilebilir.

3.4.2. Kısa zamanlı fourier dönüşümü

Standart FD' nin sahip olduğu dezavantajı ortadan kaldırmak amacı ile Gabor (Cohen 1989) tarafından Kısa Zamanlı Fourier Dönüşümü (KZFD) ortaya atılmıştır. KZFD' nin avantajı, analiz için sabit uzunluğa sahip keyfi $g(t)$ penceresi kullanarak gerçekte durağan olmayan sinyalleri yaklaşık durağan gibi kabul etmesidir. KZFD, $x(t)$ sinyalini, farklı τ zamanları için $g(t)$ kayan penceresi kullanarak iki boyutlu

zaman-frekans gösterimi S(τ,f) haline getirir. Böylece pencerelenmiş $x(t)g^*(t-\tau)$ sinyalinin FD, KZFD olarak sonuçlanır:

$$KZFD_x(\tau, f) = \int_{-\infty}^{\infty} x(t)g^*(t-\tau)e^{-j2\pi ft}dt \tag{3.2}$$

Filtre kümesi yorumu KZFD' nin sinyalin pencerelenmesi noktasını anlamak için diğer bir alternatif yoldur (Allen ve Rabinar 1977, Portnoff 1980). Modüle edilmiş filtre kümeleri ile sinyalin f frekansında modüle edilmiş pencere fonksiyonunun darbe cevabı ile f frekansında merkezlenmiş bant geçiren bir filtreden geçirilmesi işlemi gerçekleştirilmektedir. Frekansların dağılımı düzgündür.

Frekans gibi zamanda da orijinin çevresinde merkezlenmiş $g(t)$ penceresi ve onun FD, $G(f)$ için $\int t|g(t)|^2 dt = 0$ ve $\int f|G(f)|^2 df = 0$ olarak kabul edilerek, zaman ve frekans için şu şekilde ifade edilebilir:

$$\Delta_t^2 = \frac{\int_{-\infty}^{\infty} t^2|g(t)|^2 dt}{\int_{-\infty}^{\infty} |g(t)|^2 dt} \tag{3.3}$$

$$\Delta_f^2 = \frac{\int_{-\infty}^{\infty} f^2|G(f)|^2 df}{\int_{-\infty}^{\infty} |G(f)|^2 df} \tag{3.4}$$

Böylece, KZFD' nin zaman-frekans çözünürlüğü onların çarpılması ile en düşük sınırını tanımlar:

$$Zaman - Frekans\ Çarpımı = \Delta_t\Delta_f \geq \frac{1}{4\pi} \tag{3.5}$$

KZFD için bir pencere seçildiği zaman, aynı pencere bütün frekanslarda kullanılacağı için tüm zaman-frekans ekseni boyunca zaman-frekans çözünürlüğü sabit olacaktır. Bu, KZFD' de zaman çözünürlüğü ile frekans çözünürlüğü arasında daima bir seçim yapmayı (ödün vermeyi) gerektirmektedir..

3.4.3. Dalgacık dönüşümüne geçiş

KZFD' nin sabit frekans çözünürlüğü yetersizliğini ortadan kaldırabilmek ve çoklu çözünürlüğü elde edebilmek amacı ile Δ_t ve Δ_f çözünürlükleri zaman-frekans düzleminde değiştirilebilir. Dalgacık dönüşümü ve dalgacık dönüşümünün sürekli şekli (sürekli dalgacık dönüşümü, SDD), yüksek frekans bileşenleri incelendiğinde daralan, alçak frekans bileşenleri incelendiğinde ise genişleyen esnek bir zaman-frekans penceresine sahiptir. Böylece düşük frekanslarda iyi bir frekans çözünürlüğü elde edilirken yüksek frekanslarda iyi bir zaman çözünürlüğü elde edilir. Bu tür bir analiz kısa zamandaki yüksek frekans bileşenlerinden ve uzun zamandaki alçak frekans bileşenlerinden oluşan sinyaller için uygundur. Pratik uygulamalarda karşılaşılan sinyaller de bu tür sinyallerdir (Rioul ve Vetterli 1991).

3.5. Dalgacık Dönüşümünün Teorik İfadesi

3.5.1. Sürekli dalgacık dönüşümü

Örnek bir $\psi(t)$ fonksiyonu ana dalgacık olarak adlandırılır ve fonksiyon ailesi $\psi(t)$' nin kaydırılması ve ölçeklenmesi ile elde edilir.

$$\psi_{ab}(t) = \frac{1}{\sqrt{a}}\psi(\frac{t-b}{a}) \text{ ..... } a,b \in R \ (a>0) \tag{3.6}$$

Burada, a parametresi ölçekleme faktörü, b parametresi ise kayma faktörüdür. Normalizasyon $\|\psi_{a,b}(t)\| = \|\psi(t)\|$'i gerçekleştirir. Ana dalgacık aşağıdaki şart durumuna sahiptir:

$$C_\psi = \int_{-\infty}^{\infty} \frac{|\Psi(w)|^2}{w} dw < \infty \tag{3.7}$$

Burada $\Psi(w)$, $\psi(t)$' nin Fourier dönüşümüdür. Pratikte $\Psi(w)$ için şart durumu aşağıdaki şekilde yeniden ifade edilebilir:

$$\int_{-\infty}^{\infty} \psi(t)dt = \Psi(0) = 0 \tag{3.8}$$

Böylece, bir dalgacık bant geçiren karakteristiğe sahip olur.

$f(t)$ 'nin sürekli dalgacık dönüşümü şu şekilde tanımlanabilir:

$$SDD_f(a,b) = \int_{-\infty}^{\infty} \psi^*_{a,b}(t) f(t)dt = \langle \psi_{a,b}(t), f(t) \rangle \tag{3.9}$$

$\psi_{a,b}(t)$ temel fonksiyonu, bir filtre bankasının dürtü cevabı olarak görülebilir. Ölçekteki (a>1) artış ile birlikte, $\psi_{a,b}(t)$ fonksiyonu $f(t)$ fonksiyonunu daha uzun bir zaman peryodu için incelenebilmesi amacı ile zamanda genişletilmiştir. Genelde, çok küçük ölçek sinyalin detaylı bir görüntülenmesi, çok büyük bir ölçek ise sinyalin çok geniş çaplı görüntülenmesi anlamına gelir. Ölçek ile ilgili bir diğer kavram olan çözünürlük sinyalin frekans içeriği ile sınırlıdır. SDD deki sürekli zamanlı sinyallerin ölçek değişimi çözünürlüklerini değiştirmez.

SDD analizi ile $SDD_f(a,b)$ dalgacık katsayılarının bir kümesi elde edilir. Bu katsayılar, sinyalin temel fonksiyona ne kadar benzediğini göstermektedir. $f(t)$ fonksiyonu, SDD' den yeniden elde edilebilir.

$$f(t) = \frac{1}{C_\psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} SDD_f(a,b) \psi_{a,b}(t) \frac{dadb}{a^2} \tag{3.10}$$

3.5.2. Ayrık dalgacık dönüşümü

SDD' de sürekli değerler alan (a,b) parametreleri, gerekenden çok daha fazla olan gösterimi ve pratik olmaması gibi sebepler ile ayrık bir ifadeye ihtiyaç duymuştur. Bu amaçla, ölçek ve kayma parametreleri ayrık bir zaman-ölçek düzleminde değerlendirilmiştir. Bu ayrıklaştırma işlemi şu şekilde gösterilebilir (Daubechies 1990):

$$a = a_0^{\,j} \text{ ve } b = k a_0^{\,j} b_0 \qquad j,k \in Z \tag{3.11}$$

Burada $a_0 > 1$ genişletme adımı ve $b_0 \neq 0$ ise çevirme adımıdır. Dalgacık ailesi şu şekilde ifade edilebilir:

$$\psi_{j,k}(t) = a_0^{-j/2} \psi(a_0^{-j} t - k b_0) \tag{3.12}$$

Bir $f(t)$ fonksiyonunun dalgacık ayrışımı

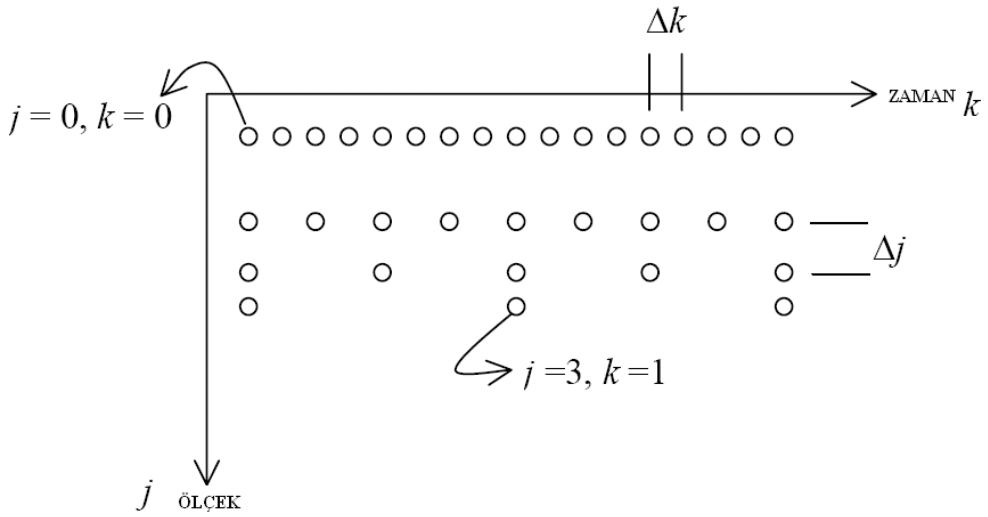
$$f(t) = \sum_j \sum_k D_f(j,k)\psi_{j,k}(t) \tag{3.13}$$

olarak ifade edilir. Burada $D_f(j,k)$ katsayılarının 2 boyutlu kümesi, verilen bir $f(t)$ fonksiyonunun ayrık dalgacık dönüşümü olarak adlandırılır.

Ayrıklaştırma işleminin en yaygın olarak kullanılan şekli, $a_0 = 2$ ve $b_0 = 1$ olmak üzere Şekil 3.2' deki zaman-ölçek düzleminde gösterilmiştir. Şekil 3.2' de yer alan dalgacık dönüşümü, standart ayrık dalgacık dönüşümü (ADD) olarak tanımlanmıştır.

Eşitlik (3.14) yer alan ADD' de dalgacık fonksiyonun seçilmesi önemlidir. Literatürde (Battle 1987 ve 1988, Meyer 1990, Stromberg 1992) $f(t)$' yi değerlendirebilmek için çok sayıda dalgacık fonksiyonu yer almaktadır. Bütün bu dalgacıklar, ADD katsayılarına ve istenilen çözünürlüğe uygun olarak türetilebilirler.

$$D_f(j,k) = \int_{-\infty}^{\infty} \psi^*_{j,k}(t) f(t) dt = \left\langle \psi_{j,k}(t) f(t) \right\rangle \tag{3.14}$$



Şekil 3.2 Zaman-ölçek düzleminde standart ADD gösterimi

3.6. ADD' nin Gerçekleştirilmesi

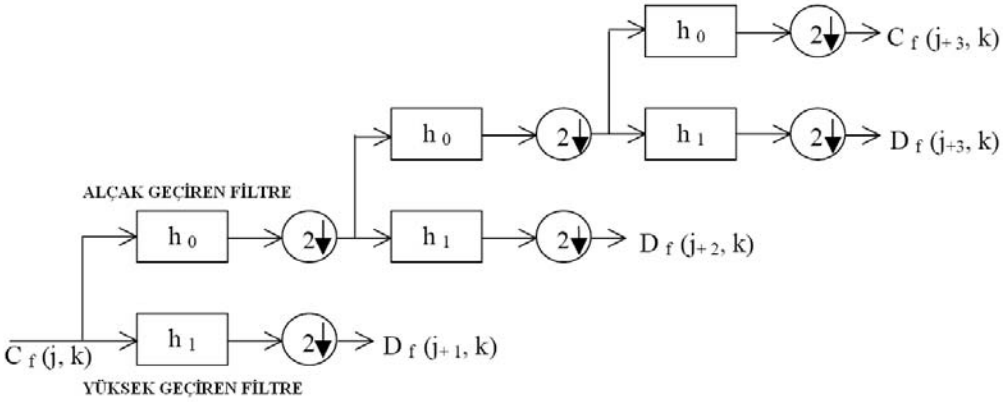
3.6.1. Filtre kümesi uygulaması

$C_f(j,k)$ ve $D_f(j,k)$' nin sırasıyla ölçekleme katsayısı (yaklaşım katsayısı) ve dalgacık katsayısı (detay katsayısı), $h_0[n]$ ve $h_1[n]$' nin de sırasıyla alçak geçiren ve yüksek geçiren filtre katsayıları olduğu göz önünde bulundurularak bir $f(t)$ fonksiyonu için ardışık filtre çıkışları aşağıdaki gibi ifade edilebilir:

$$C_f(j+1,k) = \sum_n h_0[n-2k]\, C_f(j,n)$$

$$D_f(j+1,k) = \sum_n h_1[n-2k]\, D_f(j,n) \qquad (3.15)$$

Bu eşitlikler Şekil 3.3' de görüldüğü gibi 3 seviyeli bir analiz filtre kümesi olarak uygulanabilir (Mallat 1989). ADD' nin analiz filtre küme seviyesi probleme yönelik olarak belirlenebilmektedir.

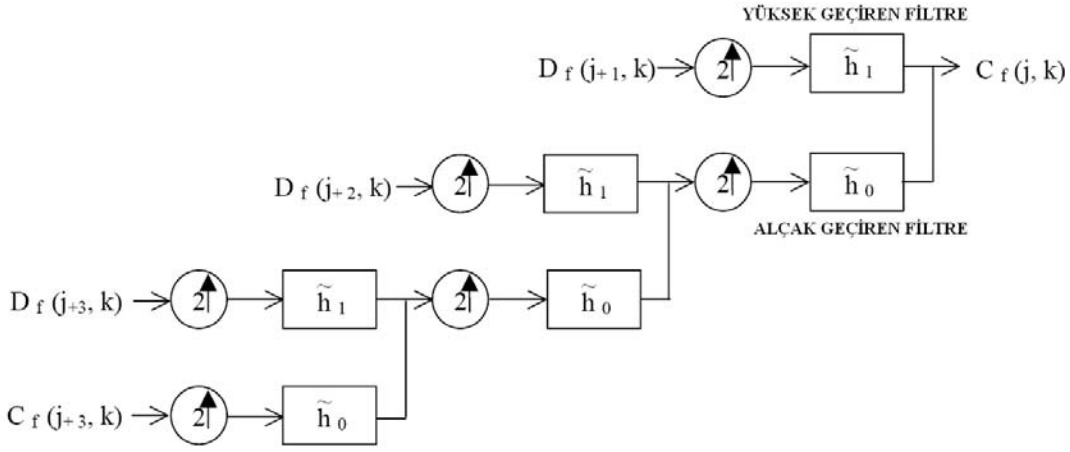


Şekil 3.3 Üçüncü seviyeden analiz filtre kümesi

Standart ayrık dalgacık dönüşümünde, yaklaşım ve detay katsayıları her bir ayrıştırma seviyesi için 2' nin katları şeklinde artmaktadır. Bu, çoklu-çözünürlüğe sahip bir sinyalin gösteriminde kolaylık sağlamaktadır.

Yeniden oluşturma fitre kümesi yapısı, Şekil 3.4' de gösterildiği gibi tekrarlamalı bir sentez yapısını içermektedir. Sentez işlemi, analiz işlemi ile çeşitli

seviyelerde incelenen sinyalin yeniden oluşturulmasını içermektedir. Burada $\widetilde{h}_0$ ve $\widetilde{h}_1$ yeniden yapılandırma filtreleri kullanılmaktadır (Shukla 2003).

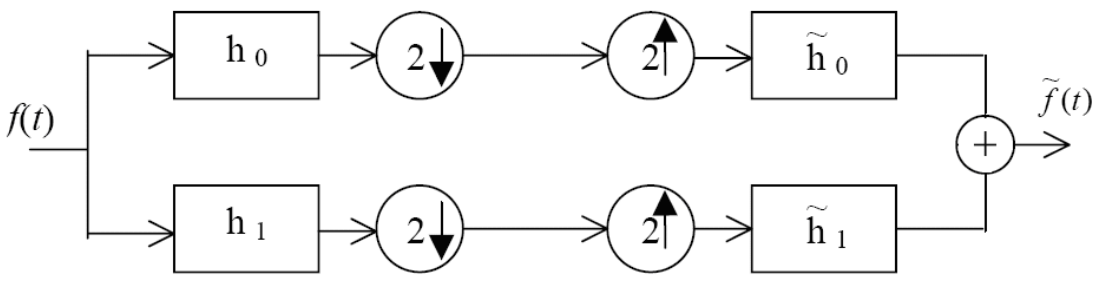


Şekil 3.4 Üçüncü seviyeden sentez filtre kümesi

ADD' nin filtre kümesi uygulamalarındaki (alt bandlara ayrıştırma işlemindeki) en önemli kriter sinyalin yeniden elde edilmesidir. Bu durum, literatürde 'mükemmel yeniden oluşturma' terimi ile ifade edilmiştir (Vetterli 1986, Vidyanathan 1993, Figde 1994, Vetterli ve Kovacevic 1995, Strang ve Nguyen 1996).

3.6.2. Mükemmel yeniden oluşturma

Yeniden elde edilmiş $\widetilde{f(t)}$ sinyali, orijinal $f(t)$ ile özdeş olduğunda analiz ve sentez filtrelerinin birleştirilmesi ile oluşturulmuş basit iki kanallı bir filtre kümesi yapısı Şekil 3.5' te gösterilmiştir. Sinyalin mükemmel bir şekilde yeniden oluşturulması özelliğine sahip olan ADD, sinyal işleme uygulamalarında oldukça yaygın kullanılmaktadır.

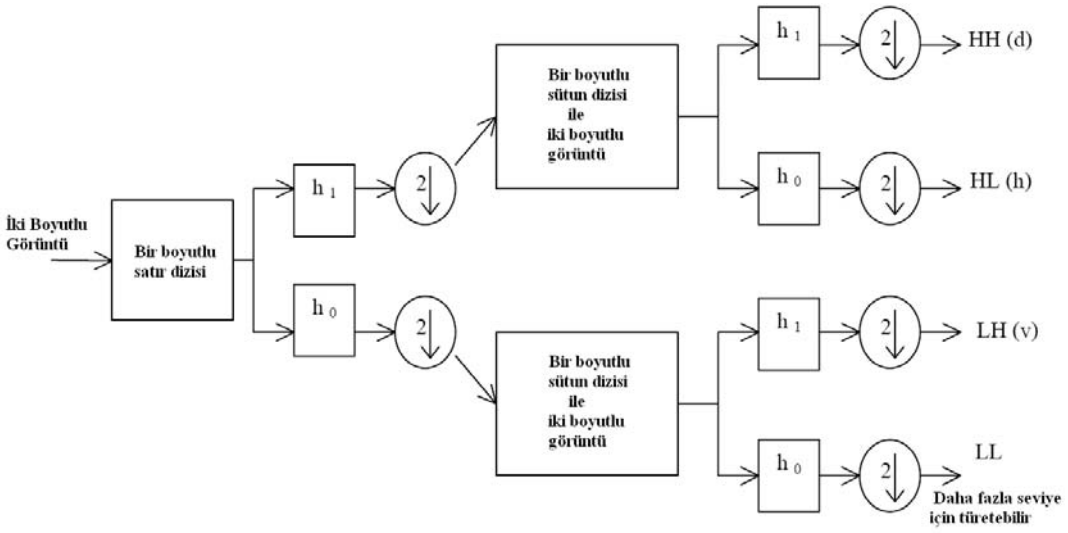


Şekil 3.5 Basit bir iki kanallı filtre kümesi yapısı

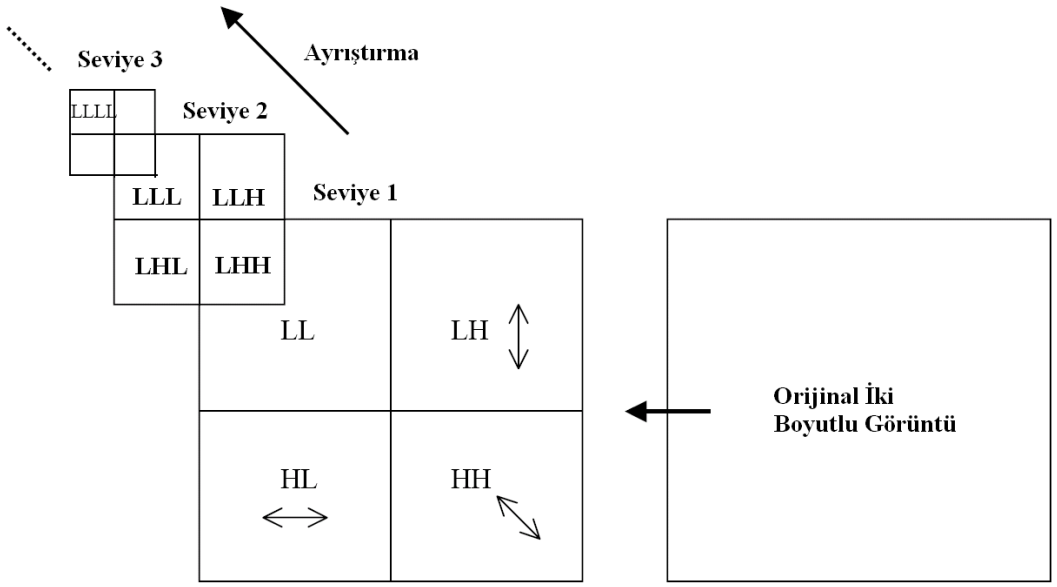
3.7. ADD' nin İki Boyut İçin Genişletilmesi

Standart ADD' nin görüntüler için genişletilmesi iki boyutlu (2B) ADD'yi tanımlamaktadır. Bölüm 3.5' te ele alınan filtre bankası yapısı bir boyutlu (1B) ADD' nin basit bir uygulamasıdır. Görüntü işleme uygulamalarında ise dalgacık dönüşümünün 2B uygulaması gerekmektedir. 2B ADD' nin uygulamaları literatürde çok boyutlu dalgacık dönüşümü olarak geçmektedir (Mallat 1989, Karlson ve Vetterli 1990, Rioul ve Vetterli1991). JPEG2000 standardı gibi görüntü kodlama algoritmalarının çoğu 1B ADD' nin görüntünün satırlarına ve sütunlarına ayrı ayrı uygulanması ile elde edilen 2B ADD' yi kullanmaktadırlar (ISO/IEC 1999).

Tek seviyeli 2B ADD' nin analiz filtre bankası uygulaması Şekil 3.6' da gösterilmektedir. Bu yapı, üç farklı yönelime (yatay, dikey ve köşegen) uygun olarak üç detaylı alt-görüntüyü (HH,HL,LH) ve düşük çözünürlüklü bir alt görüntüyü (LL) üretmektedir. Filtre kümesi yapısı LL' nin tek seviyeli yapıdakine benzer bir şekilde iteratif olarak analiz edilmesi –ayrıştırılması- ile çoklu-seviye ayrıştırma işlemini gerçekleştirebilmektedir. Bir görüntünün çoklu-seviyeli ayrıştırma hiyerarşisi Şekil 3.7' de görülmektedir.

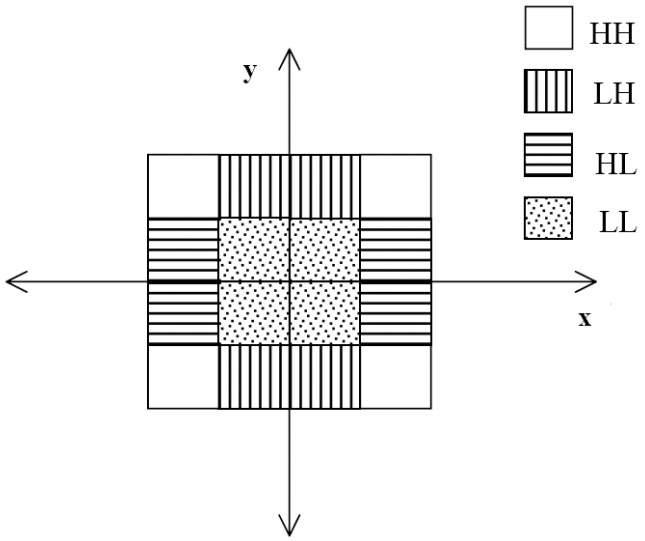


Şekil 3.6. İki boyutlu ADD için bir seviyeli analiz filtre kümesi



Şekil 3.7 İki boyutlu ADD ile bir görüntünün çoklu-seviyeli ayrıştırma hiyerarşisi

Herbir ayrıştırma işlemi ile ana görüntüden dört adet alt görüntü elde edilmektedir. Bu alt görüntülerin her birinin büyüklüğü ana görüntünün dörtte biri kadardır. Alt görüntüler, Şekil 3.8' de gösterilen frekans düzleminin iki boyutlu bölümlerindeki alt band pozisyonlarına uygun olarak konumlanmışlardır. Sentez filtre kümesi yapısı, analiz filtre kümesi yapısının tersinin alınması ile elde edilmektedir.



Şekil 3.8 İki boyutlu ADD için frekans düzlem paylaşımı

2B ADD' de kullanılan dalgacıklar , 1B dalgacık ve ölçekleme fonksiyonları ile oluşturulmaktadır. Eğer, $\psi(x)$, bir boyutlu ölçekleme fonksiyonu $\varphi(x)$ ile birleştirilmiş bir boyutlu dalgacık ise, üç alt görüntü ile birleştirilmiş 2B dalgacık şu şekilde ifade edilebilir (Shukla 2003):

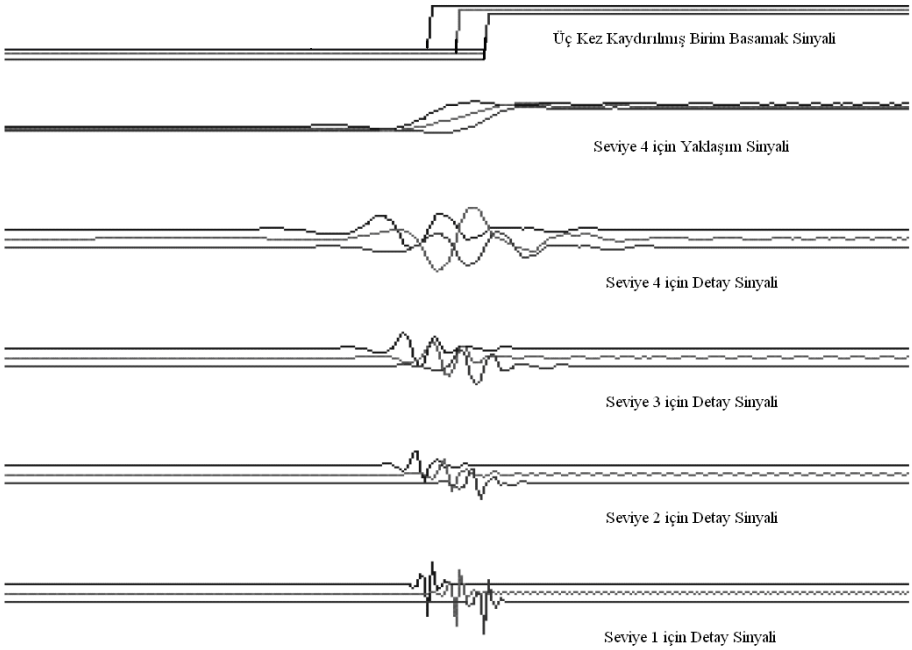
$$\begin{aligned} \psi^D(x,y) &= \varphi(x)\psi(y) \rightarrow \quad \text{LH} \\ \psi^Y(x,y) &= \psi(x)\varphi(y) \rightarrow \quad \text{HL} \\ \psi^K(x,y) &= \psi(x)\psi(y) \rightarrow \quad \text{HH} \end{aligned} \tag{3.16}$$

3.8. Ayrık Dalgacık Dönüşümünün Sınırları

Standart ADD, güçlü bir araç olmasına rağmen, sinyal ve görüntü işleme uygulamalarında üç büyük dezavantaja sahiptir. Bu dezavantajlar aşağıdaki başlıklarda incelenmiştir.

3.8.1. Değişime duyarlılık

Giriş sinyali için zamanda bir değişim (kayma, sapma) meydana geldiğinde dönüşüm katsayılarında tahmin edilemeyen bir değişim oluşuyorsa, bu dönüşüm değişime duyarlı olarak tanımlanmaktadır. Değişime duyarlılık istenilmeyen bir özelliktir. Çünkü ADD katsayıları giriş-sinyali değişimlerini ayırt etmekte başarısız olmaktadır (Guo 1995, Strang ve Nguyen 1995). ADD' nin farklı değişim yapısı Şekil 3.9' da adım sinyalinin üç kez kaydırılmış hali kullanılarak gösterilmiştir. Şekil 3.9' da, değişmiş giriş sinyali 4. seviyeden 'db5' dalgacık dönüşümü kullanılarak ayrıştırılmıştır. Şekilde, çeşitli seviyelerdeki detay sinyallerinde ve yaklaşım sinyalinde tahmin edilemeyen değişimler görülmektedir.

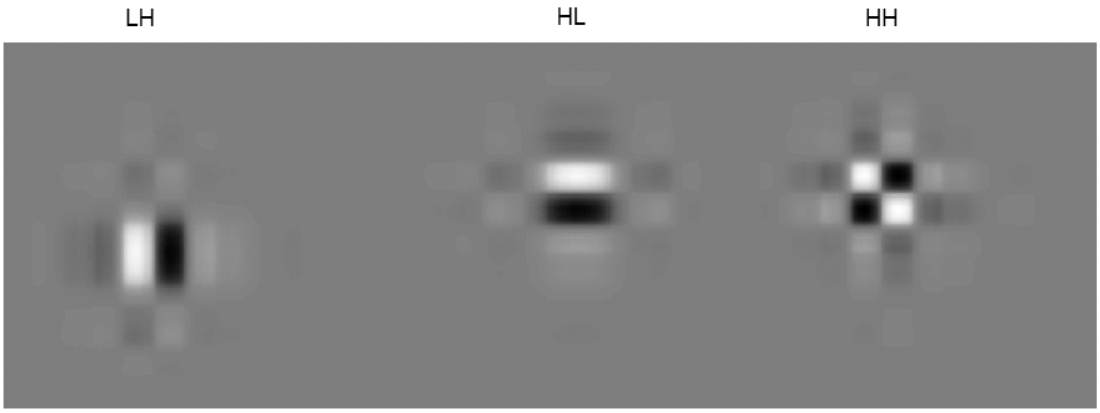


Şekil 3.9 Bir boyutlu standart ADD' nin değişime duyarlılığı

3.8.2. Zayıf yönlülük

Bir m-boyutlu dönüşüm (m>1), dönüşüm katsayıları uzay kümesinde sadece bir kaç özellik yönelimini açığa çıkarırsa 'zayıf yönlülüğe' sahip olarak ifade edilir. Bölüm 3.7' de ifade edildiği gibi, 2B ADD frekans kümesini üç yönlü alt banda ayırır.

Şekil 3.10' da görüldüğü gibi 2B ADD sadece yatay (HL), düşey (LH) ve köşegen (HH) özellik yönelimlerine sahiptir. Doğal görüntüler, rastgele yönelimler içerirler. Bu yüzden, zayıf yönlülük dezavantajı, standart 2B ADD ile doğal görüntülerin en uygun biçimde gösterimini etkiler.

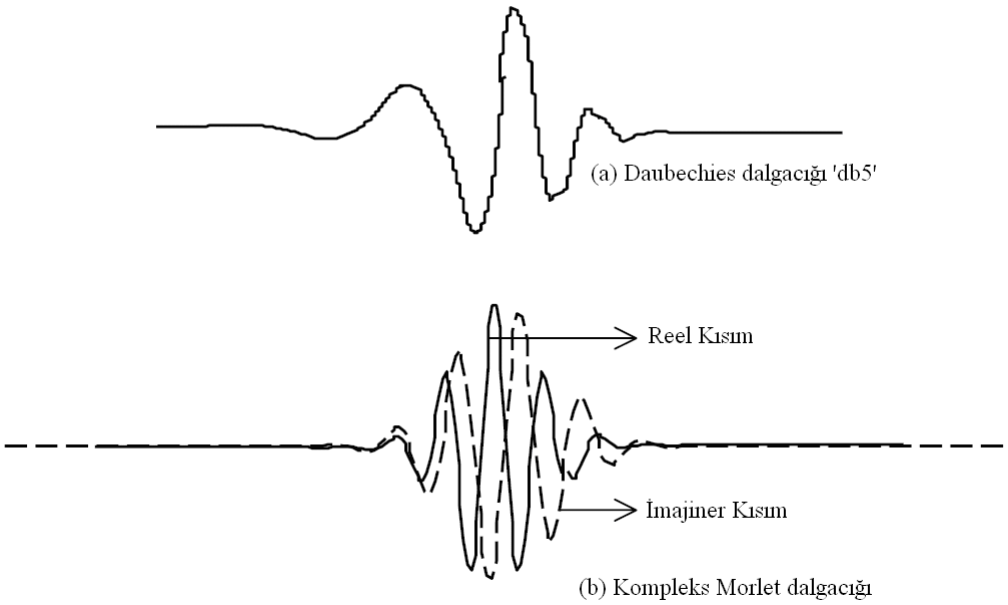


Şekil 3.10 İki boyutlu standart ADD' nin Yönlülüğü

3.8.3. Faz bilgisinin eksikliği

Kompleks değerli bir sinyal ya da vektör için faz bilgisi, reel ve imajiner bileşenler kullanılarak hesaplanabilir. Sayısal görüntü iki boyutlu bir veri matrisidir. 2B ADD ile bir görüntüyü filtrelemek görüntünün boyutunu artırır ve bir faz bozulması (distorsiyonu) ekler. İnsanın görsel sistemi faz bozulmasına oldukça duyarlıdır (Morrone ve Burr 1988). Ayrıca, 'lineer faz' filtreleme, görüntü işlemedeki artan veri boyutu probleminden kaçınmak için simetrik genişleme metotlarını kullanabilmektedir (Morrone ve Burr 1988). Faz bilgisi, bir çok sinyal ve görüntü işleme uygulaması (görüntü şıkıştırma, güç ölçümü (Lorenzetto ve Kovesi 1999, Driesen ve Belmans 2002)) için oldukça değerlidir.

Birçok ADD dönüşümü uygulaması, reel değerli yaklaşım ve detay katsayılarını üretecek reel değerli dalgacıklar ile birleştirilmiş reel katsayılı filtreler kullanan ayrılabilir bir filtreleme içerir. Ancak, ADD uygulamaları yerel faz bilgisi içermezler. Bütün doğal sinyaller temel olarak reel değerlidir ve bu yüzden lokal faz bilgisinden faydalanmak için kompleks değerli filtreleme gerekmektedir (Lawton 1993, Lina 1997-a). Reel ve analitik dalgacıklar arasındaki fark Şekil 3.11' de gösterilmiştir.



Şekil 3.11 Reel (a) ve analitik (b) dalgacığın gösterimi

4. KOMPLEKS DEĞERLİ DALGACIK DÖNÜŞÜMÜ

Bölüm 3.8' de tartışıldığı gibi standart ADD ve onun 2B' ye genişletilmiş versiyonu bazı dezavantajlara sahiptir. Kompleks değerli ADD' nin geliştirilmesine ilk olarak 'faz bilgisinin eksikliği' dezavantajına çözüm bulabilmek amacı ile ihtiyaç duyulmuştur (Lawton 1993). Kompleks değerli dalgacık dönüşümleri (KDDD), reel veya kompleks sinyalleri dönüşüm kümesinde reel ve imajiner bölümlere ayrıştıran kompleks değerli filtreler (analitik filtreler) kullanırlar. Reel ve imajiner katsayılar genlik ve faz bilgisini elde etmek amacı ile kullanılmışlardır.

4.1. KDDD' nin Tarihçesi

Standart ADD' nin kompleks düzleme genişletilmesi için tek bir yol yoktur. Lawton (1993) ve Lina (1997-b), Daubechies dalgacıklarının kompleks çözümlerinin var olduğunu göstermişlerdir. Kompleks değerli simetrik Daubechies dalgacıkları görüntü geliştirme, onarma ve kodlama gibi uygulamalarda kullanılmıştır (Lawton 1993, Belzar ve ark. 1995, Lina 1997-a, 1997-b). Ortogonallik (dik açılı olma durumu), simetri ve lineer faz gibi kullanışlı özellikleri ile kompleks dalgacıkları üretmek için bir filtre kümesi dizaynı, Zang ve ark. (1999) tarafından tanımlanmıştır.

Ortogonallik dönüşüm kümesinde enerjiyi korumak için gereklidir. Filtrenin simetri özelliği sonlu uzunluktaki sinyaller için sınır problemini incelemeyi kolaylaştırmaktadır (Starng ve Nguyen 1996). Filtrenin lineer faz cevabı, lineer olmayan faz bozulması tarafından oluşturulan görsel yapay bozulmaları azaltmak ve böylece daha kaliteli bir görüntü elde etmek için gereklidir (Vetterli ve Herley 1992). Bütün bu kompleks çözümler (Lawton 1993, Lina 1997-a, Zang ve ark. 1999), ortogonal, simetrik ve lineer faz filtre çiftleri ile elde edilirler. Bu yararlı özelliklerin bir kombinasyonunu reel değerli filtre kümeleri ile elde etmek mümkün değildir.

KDDD' nin geliştirilmesi için son zamanlarda yapılan çalışmalar temel olarak iki ana sınıfa ayrılmıştır. Bunlar; Fazlalık KDDD ve Fazlalık Olmayan KDDD' dir. Dördüncü bölümün sonunda yer alan Çizelge 4.1' de, KDD' nin ayrıldığı sınıfların detayları görülmektedir. Standart ADD, verilen sinyalin N örneği için dönüşüm kümesinde N örnek vermektedir. Fazlalık dönüşümünde verilen giriş sinyalinin N örneği için dönüşüm kümesinde M örnek verir (M>N) ve böylece bu dönüşümün M/N faktörüne uygun olarak daha maliyetli olduğu söylenebilir. Fazlalık olmayan dönüşüm ise verilen N örneğe karşılık N örnek üretecek şekilde dönüşümün dizayn edilmesi amacı ile bir yaklaşım getirmiştir (Spaendonck ve ark. 2000, Fernandes ve ark. 2000, Fernandes 2002, Fernandes ve ark. 2003, Spaendonck ve ark. 2003).

Fazlalık KDDD, birbirine benzeyen iki tane KDDD içerir. Bu dönüşüm İkili-Ağaç Kompleks Değerli Dalgacık Dönüşümü (İA-KDDD) olarak birbirleri ile hemen hemen aynı iki versiyon olmak üzere Kingsbury (1998) ve Selesnick (2001-a) tarafından tanıtılmışlardır. Bu versiyonlar İA-KDDD(K) ve İA-KDDD(S) olarak adlandırılmaktadır. Bu fazlalık dönüşümleri uygun filtreler ile birbirine paralel olarak çalışan iki geleneksel ADD filtre kümesi ağacından oluşmaktadır. Her iki İA-KDDD' nin filtre kümesi yapıları aynıdır ancak filtre katsayılarını üretmek için kullandıkları metotlar birbirlerinden farklıdır. Her iki İA-KDDD' de faz bilgisi sağlamakla birlikte geliştirilmiş yönlülük özelliğine de sahiptirler (Kingsbury 1999, Selesnick 2001-a,b). Selesnick [2001-a,b], İA-KDDD(K) için alternatif bir filtre dizayn metodu önermiştir ve İA-KDDD(S)' yi tasarlamıştır.

4.2. Fazlalık Kompleks Değerli Dalgacık Dönüşümü

4.2.1. Analitik filtre yapıları

Gabor, Hilbert dönüşümünü sinyal teorisi içerisinde ilk kez 1946 yılındaki çalışması ile ortaya koymuş ve reel bir $f(t)$ sinyalinin kompleks hale genişletilmesini şu şekilde tanımlamıştır:

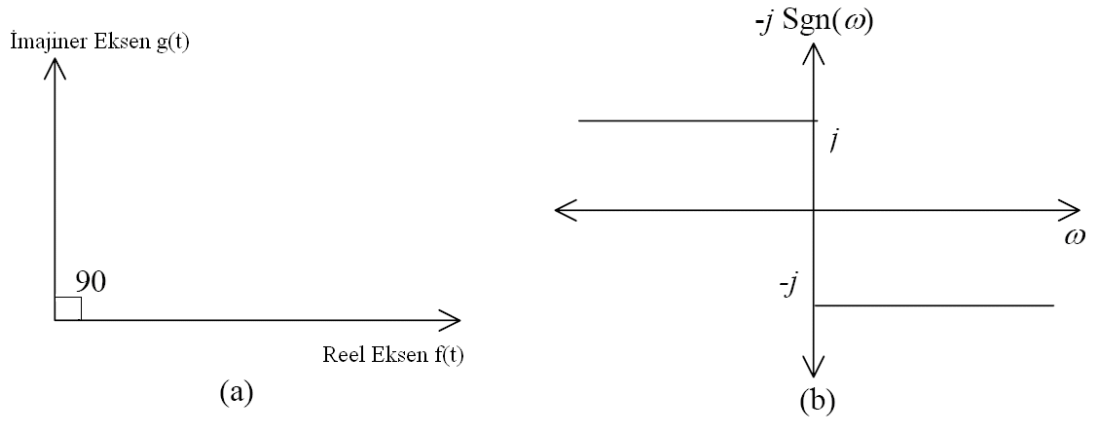
$$x(t) = f(t) + jg(t) \tag{4.1}$$

Burada, $g(t)$, $f(t)$' nin Hilbert dönüşümüdür. $H\{f(t)\}$ olarak gösterilmektedir ve $j = (-1)^{1/2}$ ' dir.

$g(t)$ sinyali, Şekil 4.1' de de görülebileceği gibi $f(t)$' nin 90^0 kaymış versiyonudur. Analitik $x(t)$ sinyalinin reel kısmı $f(t)$ dir. $x(t)$ sinyalinin imajiner kısmı olan $g(t)$, Hilbert uzayında orijinal reel $f(t)$ sinyalinin izdüşümü olarak adlandırılır. $g(t)$ sinyali, $f(t)$ sinyaline ortagonaldir (dik açılıdır). Zaman kümesinde $g(t)$' nin matematiksel ifadesi (Hahn 1996)

$$g(t) = H\{f(t)\} = \frac{1}{\pi}\int_{-\infty}^{\infty}\frac{f(t)}{t-\tau}d\tau = f(t)\frac{1}{\pi t} \tag{4.2}$$

olarak ifade verilir.



Şekil 4.1 Hilbert dönüşümü (a) kutupsal düzlemde (b) frekans düzleminde

Eğer $f(t)$ sinyalinin Fourier dönüşümü $F(\omega)$, $g(t)$ sinyalinin Fourier dönüşümü $G(\omega)$ ise $f(t)$ ve $g(t)$ sinyalleri arasındaki Hilbert dönüşümü ilişkisi frekans düzleminde şu şekilde ifade edilebilir:

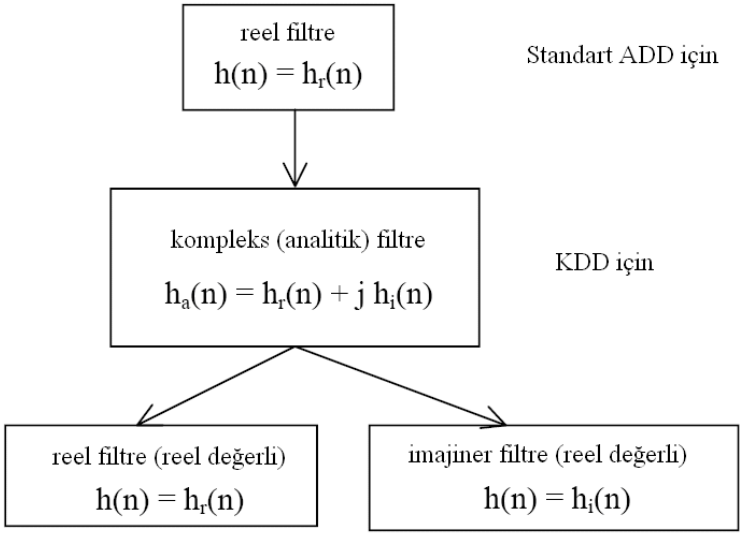
$$G(\omega) = F\{H\{f(t)\}\} = -jSgn(\omega)F(\omega) \tag{4.3}$$

Burada $-jSgn(\omega)$, modifiye edilmiş bir 'signum' fonksiyonudur ve Şekil 4.1.b' de görülmektedir. Bu analitik genişleme, verilen bir $x(t)$ sinyalinin anlık frekans ve genlik değerlerinin bulunmasına imkan sağlar. Böylece $x(t)$ sinyalinin genlik ve açı değerleri aşağıdaki gibi elde edilebilir:

Genlik $x(t) = \sqrt{(f(t)^2 + g(t)^2)}$

Açı $x(t) = \tan^{-1}\left[g(t)/f(t)\right]$ (4.4)

Analitik veya dikgen formülasyonun aynı kavramları kompleks çözümler üretmek için standart ADD' nin filtre kümesine uygulanmıştır ve böylece KDDD' ye geçiş yapılmıştır. Reel değerli filtre katsayıları, yakınsaklık için uygun şartların göz önünde bulundurulması ile uygun dizayn metotları kullanılarak kompleks değerli filtre katsayıları ile yer değiştirirler. Böylece kompleks filtre, tekrar iki reel değerli filtreye ayrıştırılabilir. Böylece, reel değerli filtrelerin dürtü cevabı Hilbert dönüşüm çiftleri olarak tanımlanır. Bu şekildeki iki filtrenin birleştirilmiş çifti analitik filtre olarak ifade edilir. Analitik filtrelerin formülasyonu ve gösterimi Şekil 4.2' de yer almaktadır.



Şekil 4.2 Bir analitik filtrenin 2-reel filtre ile ifade edilmesi

4.2.2. İkili ağaç – kompleks değerli dalgacık dönüşümü (İA-KDDD)

Kingsbury ve Selesnick tarafından geliştirilen İA-KDDD' leri, birbirine paralel çalışan iki geleneksel ADD filtre kümesinden oluşan ağaç mimarileri sebebi ile fazlalık dönüşümü olarak adlandırılırlar. Bu dönüşümler, her ağaçta kullanılan filtrelerin birbirine dik olmaları sebebi ile kompleks olarak yorumlanırlar. Diğer bir

ifade ile, her iki ağacın bütün ayrıştırma seviyelerinde, İA-KDDD' lerinin ölçekleme ve dalgacık fonksiyonları Hilbert çifti şeklini almaktadır.

4.2.2.1. İA-KDDD' nin filtre kümesi yapısı

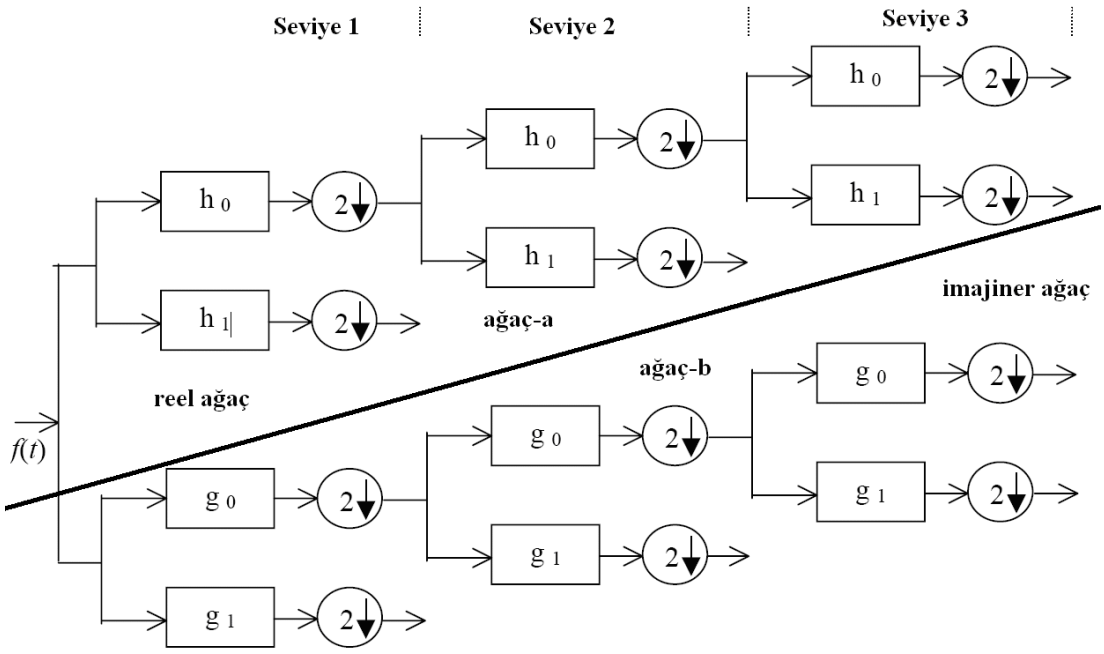
Her iki İA-KDDD' nün filtre kümesi yapıları, birbirleri ile özdeştir. Şekil 4.3, üç seviye için 1 boyutlu analiz ve sentez filtre kümesi yapılarını göstermektedir. Görüldüğü gibi İA-KDDD, standart ADD' ne göre iki kat daha karmaşık bir yapıya sahiptir ve paralel olarak işleyen iki ADD olarak da düşünülebilmektedir. Ağaçlardan birisi reel ağaç olarak, diğeri ise imajiner ağaç olarak adlandırılmaktadır. Tezin ilerleyen bölümlerinde, reel ağaç *ağaç-a*, imajier ağaç ise *ağaç-b* olarak ifade edilecektir. Bir boyutlu İA-KDDD' de kullanılan eşlenik filtreler şu şekilde verilmektedir :

$$h_x + jg_x \tag{4.5}$$

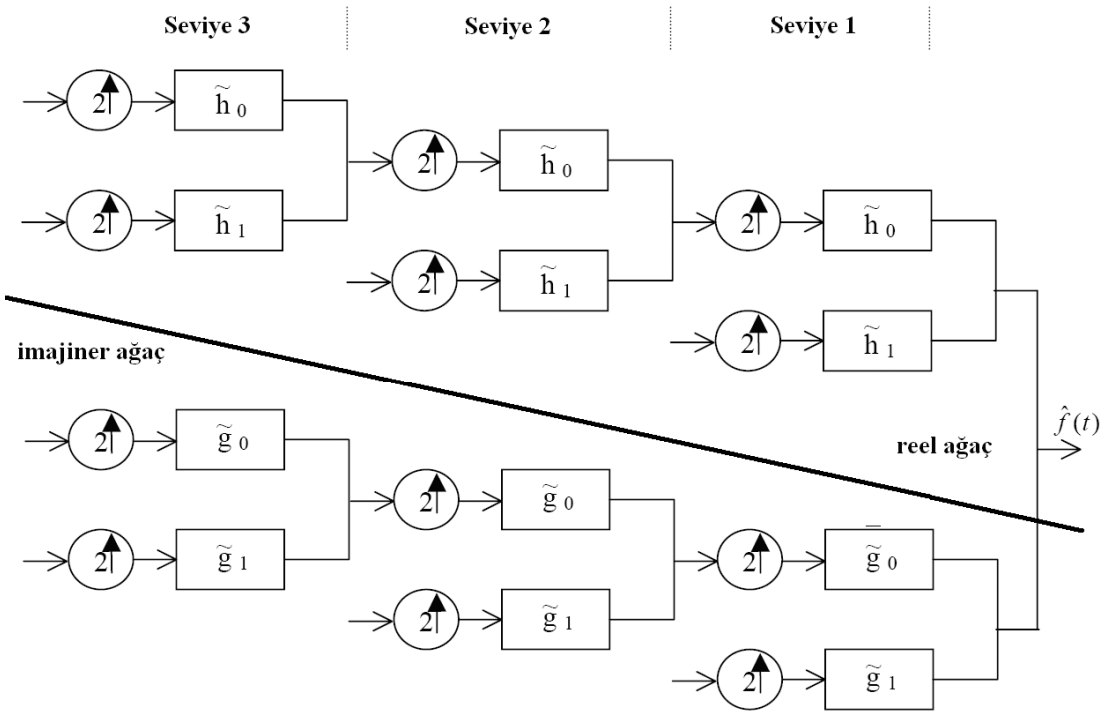
Burada, h_x, $\{h_0, h_1\}$ filtrelerinin kümesini, g_x ise $\{g_0, g_1\}$ filtrelerinin kümesini göstermektedir. Her iki kümede bir boyutludur. h_0 ve h_1 reel ağaç için reel değerli alçak geçiren ve yüksek geçiren filtreler; g_0 ve g_1 ise imajiner ağaç için reel değerli alçak geçiren ve yüksek geçiren filtrelerdir. Sentez filtre çiftleri olan $\tilde{h}_0, \tilde{h}_1$ ve $\tilde{g}_0, \tilde{g}_1$ (Şekil 4.3-b), Şekil 4.3-a' daki analiz filtrelerinde yer alan filtre çiftlerinin tamamı ile eştir. İki boyutlu İA-KDDD yapısı eşlenik filtrelerin iki boyutlu duruma genişletilmesi ile elde edilir. 2B ikili ağacın filtre kümesi yapısı Şekil 4.4' te görülmektedir. İki boyutta hem analiz hem de sentez için dört ağaca ihtiyaç duyulmaktadır. Eşlenik filtre çiftleri iki boyuta (x ve y) uygulanarak aşağıda yer alan ifade elde edilir:

$$(h_x + jg_x)(h_y + jg_y) = (h_x h_y - g_x g_y) + j.(h_x g_y - g_x h_y) \tag{4.6}$$

Ağaç-a' nın filtre kümesi yapısı, standart 2B ADD' ye benzer şekildedir ve Şekil 4.5, 3 seviye için bu yapıyı göstermektedir. Diğer bütün ağaçlar (ağaç-b,c,d), satır ve sütun filtreleme için filtrelerin uygun kombinasyonu ile benzer yapılara sahiptirler. Bütün iki boyutlu ikili ağaç yapıları, standart iki boyutlu ADD' den 4 kez daha fazlalığa sahiptir. Ağaç-a ve ağaç-b, analiz için filtre kümesinin reel çiftlerini; ağaç-c ve ağaç-d ise imajiner çiftlerini ifade etmektedir.

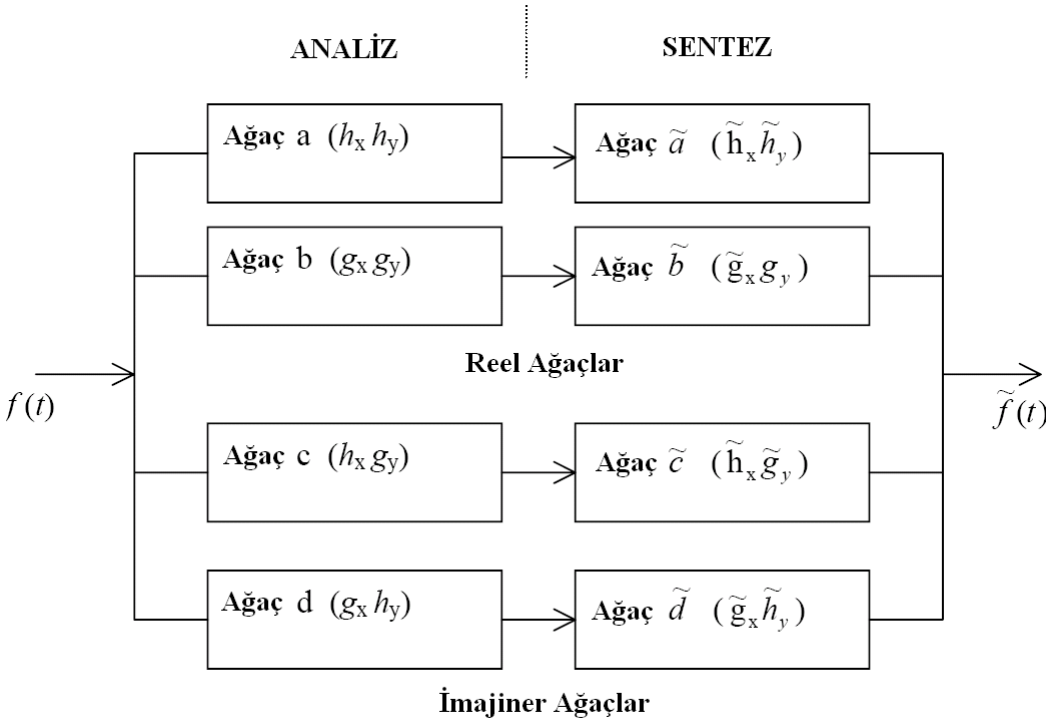


(a)

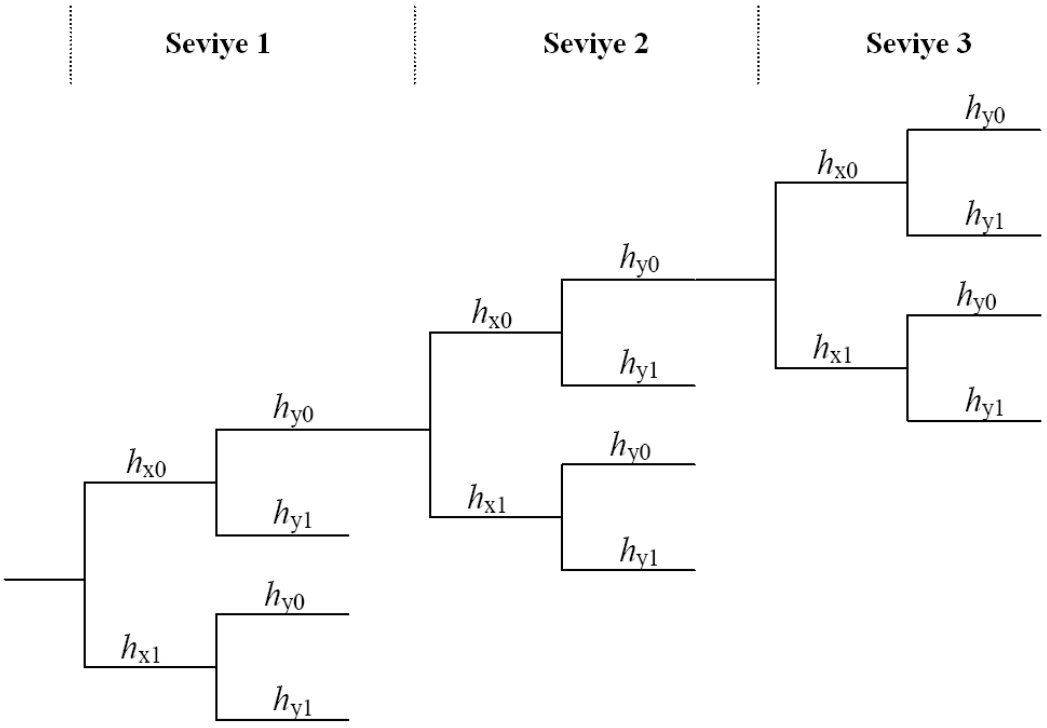


(b)

Şekil 4.3 (a) Bir boyutlu İA-KDDD için analiz filtre kümesi
(b) Bir boyutlu İA-KDDD için sentez filtre kümesi



Şekil 4.4 İki boyutlu İA-ADD için filtre kümesi yapısı

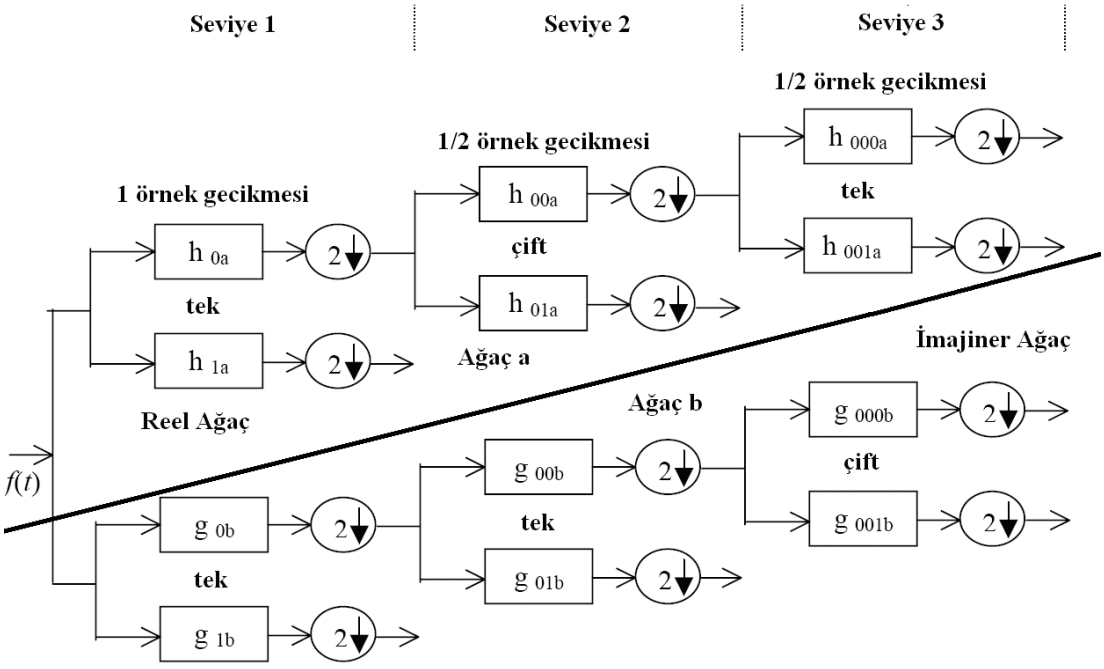


Şekil 4.5. Şekil 4.4' te yer alan ağaç-a için filtre kümesi yapısı

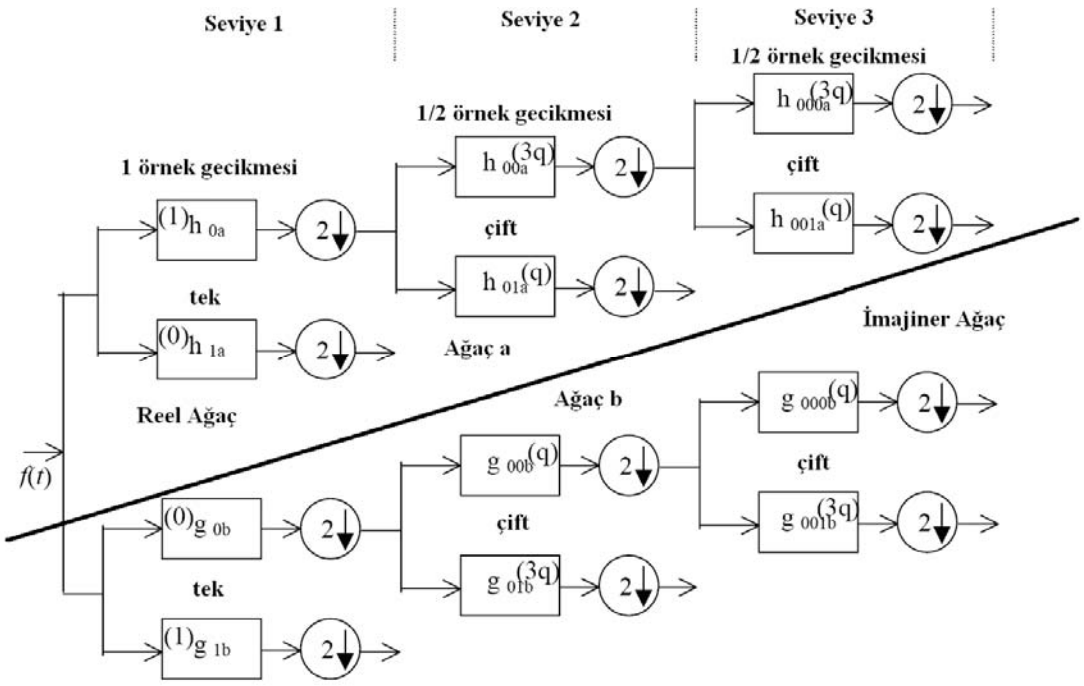
4.2.2.2. Kingsbury' nin İA-KDDD (İA-KDDD(K))

Ağaç yapısının her bir seviyesinde bulunan örnekleme oranının ikiye katlanması ile standart ADD kullanılarak da (ağaç-a gibi) yaklaşık kayma değişimsizliğini gözlemek mümkündür (Kingsbury 2001). Bunun için, örnekler eşit olarak yer almalı ve aşağı örnekleyiciler birinci seviye filtrelerinden sonra elimine edilmelidir. Eğer ağaç-b' nin birinci seviye filtrelerinin gecikmesi ağaç-a' daki karşılık gelen filtreler ile denk (dengeli) ise, bu yapı birbirine paralel çalışan iki ağaçtan (Şekil 4.3 'deki reel (ağaç-a) ve imajiner (ağaç-b) ağaçlar gibi) oluşmuş olarak düşünülebilir. Bu dengeli yapıda, birinci seviyeden sonraki her iki ağacın örnekleri arasında düzgün bir dağılım sağlamak için, bir ağaçta bulunan filtreler diğer ağaçta yer alan örneklerden yarım örnek gecikme sağlamak mecburiyetindedir.

İA-KDDD(K) gerekli gecikmelere sahip olmayı sağlayacak iki yolla dizayn edilebilir. Bu yollardan birincisi, tek-çift uzunluktaki filtreleri temel alır; ikincisi ise çeyrek-kaymalı (Q-shift, quarter shift) filtre dizaynıdır. Tek-çift filtreler ve çeyrek-kaymalı filtreler içeren analiz ağacının filtre kümesi yapıları, sırasıyla Şekil 4.6 ve Şekil 4.7' de yer almaktadır. İA-KDDD(K)' nın tasarımındaki anahtar konu, herhangi bir filtre kullanarak değişime karşı duyarsızlığı elde etmektir (yaklaşmaktır).



Şekil 4.6 Tek-çift filtreler kullanan analiz ağacı



Şekil 4.7 Çeyrek-kaymalı filtreler kullanan analiz ağacı

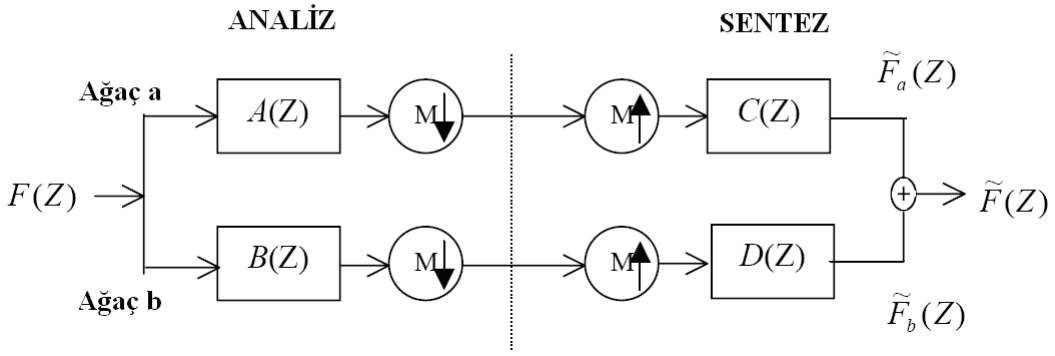
4.2.2.2.1 Değişime karşı sabitliğin kısıtlamaları

Değişime karşı sabitliği test etmek için, herhangi bir seviyedeki her iki ağacın katsayılarının (hem dalgacık hem de ölçekleme) sadece bir tipi tutulur ve diğer seviyelerdeki bütün diğer katsayılar sıfıra eşitlenir. Eğer bu katsayılar kullanılarak yeniden oluşturulan $\tilde{f}(t)$ sinyali örtüşmeden bağımsızsa ve dönüşümden sonra mükemmel bir yeniden oluşturma sağlanabiliyorsa, o seviyede 'değişime karşı sabittir (duyarsızdır)' olarak ifade edilir.

İA-KDDD(K) modeli için mükemmel yeniden oluşturulma durumu (Şekil 4.8 ' de görüldüğü gibi), aşağıdaki gibi verilebilir (Strang ve Nguyen 1996):

$$\begin{aligned}\tilde{F}(Z) &= \tilde{F}_a(Z) + \tilde{F}_b(Z) = F(Z) \\ &= \frac{1}{M}\sum_{k=0}^{M-1} X(W^k Z)\left[A(W^k Z)C(Z)+B(W^k Z)D(Z)\right]\end{aligned} \tag{4.7}$$

Burada, $M = 2^m$ ikili ağacın seviye sayısı (m) tarafından tanımlanan toplam yukarı/aşağı örnekleme faktörüdür. $W = e^{\frac{j2\pi}{M}}$ olarak ifade edilir. A, B analiz ikili ağacın transfer fonksiyonlarını; C,D ise sentez ikili ağacın transfer fonksiyonlarını göstermektedir.



Şekil 4.8 İA-KDDD için analiz ve sentez yapısı

Basitlik olması için (m=3 alınarak), ve sadece 3. seviye dalgacık katsayıları seçilerek İA-KDDD(K)' nın değişime karşı sabitliğin kısıtlamaları elde edilmeye çalışılmıştır. Bu durumda transfer fonksiyonu $A(Z)$ (h_{0a}' dan h_{001a}' ya) ve $B(Z)$ (g_{0b}' den g_{001b}' ye) , şekil 4.6' da da görüldüğü gibi şu şekilde modellenebilir:

$$A(Z) = H_{0a}(Z)H_{00a}(Z^2)H_{001a}(Z^4)$$
$$B(Z) = G_{0b}(Z)G_{00b}(Z^2)G_{001b}(Z^4) \quad (4.8)$$

Benzer şekilde $C(Z)$ ve $D(Z)$, sentez ağacı için türetilebilir.

Eğer Eşitlik 4.7' deki $A(W^kZ)C(Z)$ ve $B(W^kZ)D(Z)$ örtüşme terimlerinin her ikisi de çok küçük veya $k \neq 0$ için iptal edilmişse, İA-KDDD(K) değişime duyarsız olabilir.

4.2.2.2.2 Tek-çift uzunluktaki filtreler

Her iki ağacın birinci seviyesinden sonraki seviyelerde bulunan filtreler arasında bulunması gereken gecikme dengelerine sahip lineer faz filtrelerini elde etmek için bir ağaçta tek-uzunlukta filtre, diğer ağaçta ise çift uzunlukta filtreye sahip olmak gerekmektedir (Şekil 4.6). İki ağaç arasında daha büyük bir simetri elde etmek için bir seviyeden bir seviyeye sıra ile tek ve çift filtrelerin kullanılması gerekmektedir. Her iki ağacın birinci seviyesindeki filtreler tek uzunluktadır ve uygun alçak geçiren ve yüksek geçiren filtre çiftleri bir örnekle ayrılırlar.

4.2.2.2.3 Çeyrek-kaymalı filtreler

Tek-çift uzunluktaki filtrelerin uygulanmasında bazı problemler vardır. İlk problem, aşağı örnekleme yapıları simetrik değildir (verilen bir ölçekte dalgacık ve ölçekleme fonksiyonları iyi bir örtüşüme sahip değildir). Problemlerden ikincisi iki ağacın oldukça az da olsa birbirlerinden farklı frekans cevaplarına sahip olmalarıdır. Bir diğer problem ise filtrelerin daima çiftdikgen olması zorunluluğudur.

Yukarıda sayılan tüm bu olumsuzlukların üstesinden gelebilmek için, İA-KDDD(K) yapısında çeyrek-kaymalı filtreler kullanılmıştır (Şekil 4.7). Bu yapıda, birinci seviyeden sonraki bütün filtreler çift uzunluktadır (Kingsbury 2001). Bu filtreler yaklaşık $1/4$ örneklik (q) grup gecikmesine sahip olarak dizayn edilmişlerdir. Her iki ağacın uygun filtreleri arasında gerekli gecikme farkı ($1/2$ örnek (2q)), ağaç-b' deki ağaç-a filtrelerinin zaman terslerinin kullanılması ile elde edilmiştir. Böylece ağaç-b' deki filtrelerin gecikmesi 3q olmuştur. Filtre katsayıları

simetrik olduğu için, mükemmel yeniden oluşturma filtre kümeleri birim boyutludur ve sentez filtreleri her iki ağaçta bunlara karşılık gelen analiz filtrelerinin tam olarak zamanda tersidir.

İA-KDDD(K)' nın çeyrek kaymalı filtre versiyonunun dizayn edilmesi için anahtar, $1/4$ örnek gecikmeli ve çift örnek uzunluğuna sahip alçak geçiren $H_L(Z)$ filtresinin seçilmesidir. Yaklaşık $1/4$ örnek gecikmeli 2n uzunluğundaki alçak geçiren $H_L(Z)$ filtresi, 4n uzunluğundaki $H_{L2}(Z)$ lineer faz alçakgeçiren FIR filtresi ile dizayn edilmiştir:

$$H_{L2}(Z) = H_L(Z^2) + Z^{-1}H_L(Z^2) \tag{4.9}$$

Burada H_{L2} istenilen band genişliğinin yarısına, istenilen gecikmenin iki katına sahiptir. İA-KDDD(K)' nın birinci seviyesinden sonra filtreler şu şekilde türetilebilir:

$$\begin{aligned} H_{00a}(Z) &= z^{-1}H_L(Z^{-1}) \\ H_{01a}(Z) &= H_L(Z) \\ H_{00b}(Z) &= H_L(Z) \\ H_{01b}(Z) &= z^{-1}H_L(-Z^{-1}) \end{aligned} \tag{4.10}$$

Aynı filtreler analiz ağacındaki diğer seviyeler için de kullanılabilirler. Bu filtrelerin zamanı tersine çevrilmiş versiyonları da sentez ağaçlarında kullanılabilir.

4.2.2.3. Selesnick' in İA-KDDD (İA-KDDD(S))

İA-KDDD(S), Şekil 4.3' de gösterildiği gibi, bir boyutlu filtre kümesi yapısına sahip KDDD' nin İA-ADD şeklidir. İA-KDDD(S), Kingsbury' nin İA-KDDD(K)' ne alternatif olarak dizayn edilmiştir.

Selesnick (2001-a,b)' de, özel uzunluklara sahip ve aralarında 90^0 faz farkı bulunan dalgacık çiftleri ile dizayn için alternatif bir yol verilmiştir. İA-KDDD(S), Hilbert dönüşüm çifti şeklindeki iki dalgacık için, her iki ağacın ölçekleme filtrelerinin yarım örnek ile dengelenmesi gerektiğini kanıtlamıştır. Bu dizayn, yaklaşık değişim duyarsızlığı için iki alçak geçiren filtrelerin ara değer kestirimi kavramından farklı olarak sonsuz üretim formülü tarafından tanımlanmış limit

fonksiyonunu temel alır (İA-KDDD(K)' da olduğu gibi). İA-KDDD(S)' in tasarımındaki zorluklar, Selesnick 2001-b' deki anahtar eşitklikler ile tartışılmıştır.

Filtre kümesi yapısı için, Şekil 4.3' de gösterildiği gibi, h_0 ve h_1 eşlenik dördün (quadrature) filtre (EDF) çiftini temsil etmektedir. Bunlar,

$$h_1(n) = (-1)^{(1-n)} h_0(1-n) \tag{4.11}$$

olarak verilir ve Z dönüşümleri

$$\begin{aligned} &H_0(Z)H_0(\frac{1}{Z}) + H_0(-Z)H_0(-\frac{1}{Z}) = 2 \\ &H_1(Z) = \frac{1}{Z}H_0(-\frac{1}{Z}) \end{aligned} \tag{4.12}$$

g_0 ve g_1 filtreleri ikinci EDF' dir.

İA-KDDD(S)' in bütün h_1 ve g_1 reel-değerli filtreleri için, genişleme ve dalgacık eşitlikleri, reel ağaç için ölçekleme ve dalgacık fonksiyonlarını verir:

$$\begin{aligned} \varphi_h(t) &= \sqrt{2}\sum_n h_0(n)\varphi_h(2t-n) \\ \psi_h(t) &= \sqrt{2}\sum_n h_1(n)\psi_h(2t-n) \end{aligned} \tag{4.13}$$

Ölçekleme fonksiyonu $\varphi_g(t)$ ve dalgacık $\psi_g(t)$, imajiner ağaç için benzer şekilde tanımlanabilir.

Bölüm 4.2' de tanımlandığı gibi, $\psi_g(t)$, $\psi_h(t)$ ' nin Hilbert dönüşümüdür.

$$\begin{aligned} \psi_g(\omega) &= -j\psi_h(\omega), \omega > 0 \\ &= j\psi_h(\omega), \omega < 0 \end{aligned}$$ durumları gerçekleştiğinde

$$\psi_g(t) = H\{\psi_h(t)\} \tag{4.14}$$

olur. Burada, $\psi_h(\omega)$ ve $\psi_g(\omega)$, İA-KDDD(S)' in reel ve imajiner kısımlarının yüksek geçiren filtreler ile birleştirilmiş dalgacıklarının Fourier dönüşümleridir. Benzer şekilde $H_0(\omega) = \text{AZFD}\{h_0(n)\}$ ve $G_0(\omega) = \text{AZFD}\{g_0(n)\}$, sırasıyla, h_0 ve g_0 ölçekleme filtrelerinin ayrık zamanlı Fourier dönüşümleridir (AZFD).

$\psi_h(t)$ ve $\psi_g(t)$ Hilbert döüşüm çiftleri şeklindeki ifadelerinde,

$$|\psi_h(\omega)| = |\psi_g(\omega)|$$

$$\left|H_0(\omega)\right| = \left|G_0(\omega)\right| \tag{4.15}$$

dir. Bu iki alçak geçiren filtre birbirleri ile aşağıdaki şekilde ilişkilidir:

$$G_0(\omega) = H_0(\omega)e^{-j\theta(\omega)} \tag{4.16}$$

Bu ifade, Selesnick 2001-a' da yer alan sonsuz-üretim formülü kullanılarak türetilmiştir ve ancak

$$\theta(\omega) = \frac{\omega}{2}, \quad \left|\omega\right| < \pi \tag{4.17}$$

durumunda geçerlidir. Buna benzer şekilde, $g_0(n)$ sayısal filtresi, $h_0(n)$' nin yarım örnek gecikmiş versiyonudur.

$$g_0(n) = h_0(n - 1/2) \tag{4.18}$$

İA-KDDD(S)' nin analiz filtre kümesinin birinci seviyesi, Hilbert dalgacıklarının bir çiftini üreten ve alçak geçiren bir filtre çiftini kullanır. İlk seviyeden sonra, alçak geçire filtrenin ikinci çifti İA-KDDD(S)' in tüm alt seviyelerinde Hilbert dalgacıklarının çiftlerini üretmek için yapının geri kalanına tekrar uygulanır.

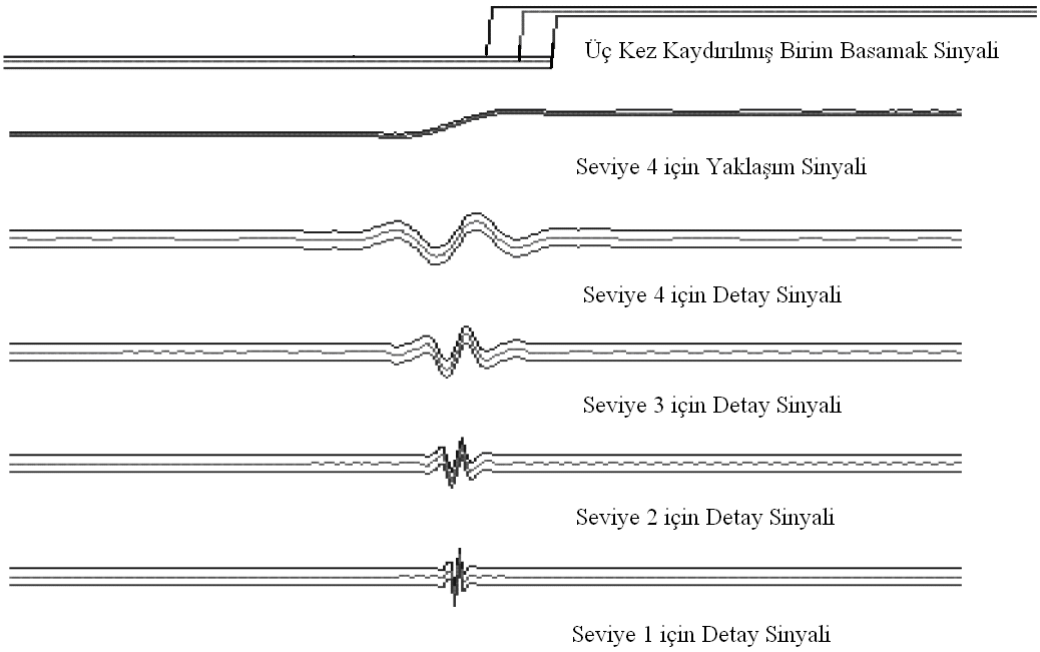
4.2.3. İA-KDDD' nin özellikleri

Her iki İA-KDDD de özdeş filtre kümesi yapılarını kullandıkları için benzer özelliklere sahiptirler. Standart ADD ile karşılaştırma yapabilmek için kullanılabilecek önemli özellikler değişim duyarlılığı, yönlülük ve faz bilgisidir. İA-KDDD(K) ve İA-KDDD(S)' in anahtar özellikleri (Kingsbury 2001,2003, Selesnick 2001-a,b):

4.2.3.1. Değişime duyarsızlık

İA-KDDD' leri yaklaşık olarak değişime karşı duyarsızdırlar, diğer bir ifade ile, standart ADD ile karşılaştırıldığında zamanda meydana gelen kaymalara karşı gelişmiş bir duyarlılığa sahiptir. Farklı seviyelerdeki yeniden yapılandırılmış detay katsayıları ve son seviyedeki yaklaşım katsayıları, zaman ekseninde kaydırılmış birim basamak fonksiyonları için hemen hemen düzgün bir kaymaya sahiptir. Bu özellik, Şekil 4.9 ve Şekil 3.9 karşılaştırılarak da anlaşılabilmektedir. Değişime karşı

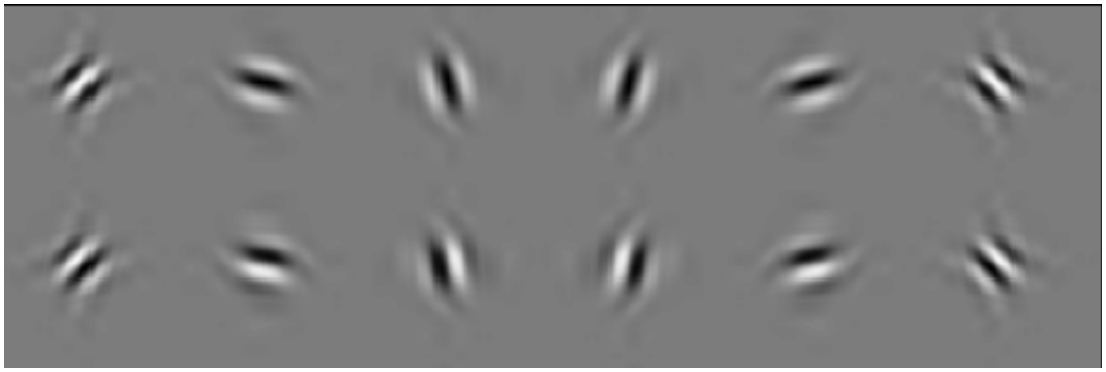
duyarsızlık özelliği İA-KDDD' nü hareket tahmini (Magarey ve Kingbury 1998) ve görüntü birleştirme (Hill ve ark. 2002) gibi çeşitli uygulamalar için oldukça uygun olduğunu ortaya koymuştur.



Şekil 4.9 Bir boyutlu İA-ADD' nün değişime duyarsızlık özelliği

4.2.3.2. Yönlülük

İA-KDDD, standart ADD' den çok daha iyi yönlülük seçiciliğine sahiptir. Standart ADD, daha önce Şekil 3.10' da da verilmiş olduğu gibi, köşegen özellikleri seçmede başarısızdır ve sadece 3 yönde seçiciliğe sahiptir. Halbuki, İA-KDDD' leri Şekil 4.10' da görüldüğü gibi iki boyutta $\pm 15, \pm 45, \pm 75$ derecelerde yönlenmiş 12 adet dalgacığa (reel ağaç için 6 adet, imajiner ağaç için 6 adet) sahiptir. Geliştirilmiş yönlülük özelliği, İA-KDDD' ne doku analizi (Hatipoğlu ve ark. 2000) gibi yönlü görüntü işleme uygulamalarında geniş bir çalışma sahası sunmaktadır.



Şekil 4.10 İki boyutlu İA-ADD' nün yönlülük özelliği

4.2.3.3. Faz bilgisi

Faz bilgisinin çıkarılması işlemi iki paralel ağaç içeren İA-KDDD tarafından gerçekleştirilmektedir. Verilen herhangi bir seviyedeki herhangi bir alt bandın fazı, onun reel ve imajiner katsayıları kullanılarak hesaplanabilir. Bir boyutlu kompleks dalgacık, reel ve imajiner dalgacıkların bir zarfıdır.

4.2.3.4. Mükemmel yeniden oluşturma

Orijinal sinyal İA-KDDD katsayıları kullanılarak mükemmel bir şekilde yeniden oluşturulabilir.

4.2.3.5. Sınırlı fazlalık

İA-KDDD, bir boyut (m-boyut) için 2:1 (2^m:1) fazlalığına sahiptir. Bu yüzden, standart ADD' ne göre daha maliyetlidir. Ancak, değişime duyarlılık, geliştirilmiş yönlülük, faz bilgisine sahip olma gibi avantajları sayesinde standart ADD' ye göre sınırlı fazlalık dezavantajını telafi etmektedir.

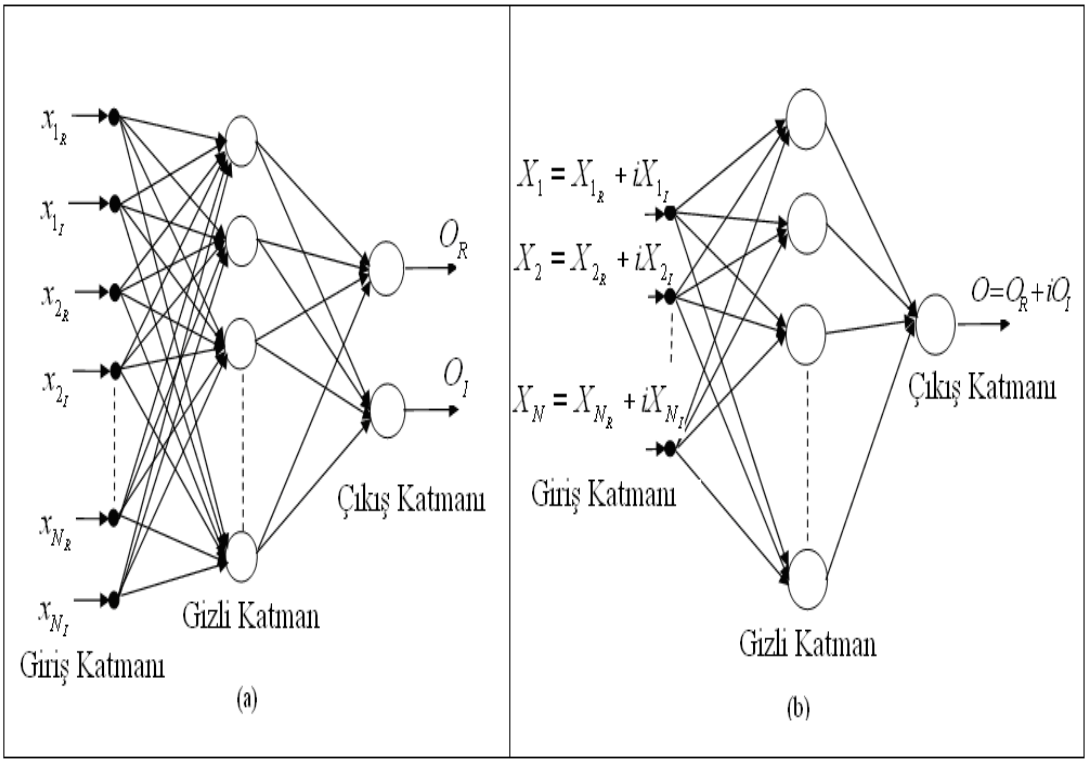
İA-KDDD' nün karşılaştırmalı bir özeti Çizelge 4.1' de yer almaktadır (Shukla 2003).

Çizelge 4.1. İA-KDDD ve Standart ADD' nin karşılaştırmalı özeti

Özellikler	Dalgacık Dönüşümünün Tipi		
	Standart ADD	İA-KDDD (K)	İA-KDDD (S)
Yapıyı Öneren	Mallat (1989)	Kingsbury (1999)	Selesnick (2001)
Anahtar Tanımlayıcı Özellik	Çoklu seviyeli çözünürlük	İki adet paralel çalışan standart ADD ağacı	İki adet paralel çalışan standart ADD ağacı
Değişime Duyarsızlık	Yok	Var	Var
Yönlülük (2B için)	Her seviyede 3 adet	Her bir ağaç için her bir seviyede 6 adet (toplam 12 adet)	Her bir ağaç için her bir seviyede 6 adet (toplam 12 adet)
Faz Bilgisi	Yok	Var	Var
Fazlalık (2B için)	Yok 1:1	Sabit 4:1	Sabit 4:1
Mükemmel Yeniden Oluşturma	Var	Var	Var
Standart ADD' ye göre geliştirilmiş özellikler ile elde edilen uygulama alanları	-	Gürültü Arındırma Görüntü İyileştirme Segmentasyon Hareket Tahmini Görüntü Birleştirme Doku Analizi	Gürültü Arındırma Görüntü İyileştirme Segmentasyon Hareket Tahmini Görüntü Birleştirme Doku Analizi

5. KOMPLEKS-DEĞERLİ YAPAY SİNİR AĞI (KDYSA)

Kompleks-değerli yapay sinir ağları, adından da anlaşılabileceği gibi ağırlık, eşik değeri, giriş ve çıkış gibi parametreleri kompleks sayılardan oluşan bir yapay sinir ağı türüdür. Kompleks değerli sayılar içeren problemlerin çözümünde, bilinen reel değerli yapay sinir ağları kullanıldığında, reel ve imajiner kısımlar için YSA' nın ayrı ayrı uygulanması gerekmektedir. Halbuki aynı problem için KDYSA uygulandığında veriler üzerinde doğrudan işlem yapabilme kabiliyeti ile işlem zamanının azaldığı ve doğruluk oranının artırıldığı görülmüştür (Nitta 1997). Reel değerli YSA ile kompleks-değerli YSA' ların kompleks değerli sayıların işlenmesi ile ilgili farklılıkları Şekil 5.1' de gösterilmiştir.



Şekil 5.1 Kompleks-değerli bir sayının (a) Reel-değerli YSA ile işlenmesi
(b) Kompleks-değerli YSA ile işlenmesi

Geriye yayılım algoritması (Rumelhart ve ark. 1986) (burada reel değerli geriye yayılım algoritması- reel GY olarak ifade edilecektir) sinyal ve görüntü tanıma gibi alanlardaki sınıflama uygulamalarında yer alan çok-katmanlı sinir ağlarının eğitiminde oldukça sık bir şekilde kullanılmaktadır. Kompleks-değerli GY algoritması, reel GY' nin kompleks değerli bir versiyonudur. Kompleks-değerli GY algoritması 1990' ların başında birbirinden bağımsız olarak pek çok araştırmacı tarafından önerilmiştir (Kim ve Guest 1990, Nitta ve Furuya 1991, Benvenuto ve Piazza 1992, Georgiou ve Koutsougeras 1992, Nitta 1993). Kompleks-değerli GY algoritması, çok-katmanlı YSA'lara ağırlıkları, eşik değerleri, giriş ve çıkış sinyallerinin tamamı kompleks olacak şekilde uygulanmıştır. Bu algoritma kompleks-değerli örüntülerin ağ tarafından doğal olarak öğrenilmesine imkan vermekte ve geometrik şekillerin dönüşümlerini analiz edebilme yeteneği sağlamaktadır. Miyauchi ve ark (1992 ve 1993), KDYSA' yı bilgisayarlı görme alanına uygulamışlardır. Optiksel akış görüntüsü olarak ifade edilen bir görüntü setindeki iki boyutlu vektörlere KDYSA uygulamışlar ve dönüşüm geometrik şekillerini elde etmişlerdir. Bahsedilen çalışmada, dönüşüm geometrik şekillerin optiksel akışın tahmini için gerektiği ve nesnelerin nasıl hareket ettiğinin belirlenmesinde kullanıldığı belirtilmiştir. Bu işlem için 1-n-1' lik (giriş-gizli düğüm-çıkış) bir KDYSA mimarisi kullanılmış ve giriş olarak iki boyutlu vektörün başlangıç noktası verilmiştir. Çıkışta ise iki boyutlu vektörün bitiş noktası ağ tarafından öğrenilmiş olarak sonuç elde edilmiştir. Hirose 2003' e göre, Miyauchi ve ark (1992 ve 1993)' nın yaptığı bu çalışma KDYSA' nın görüntü işleme alanındaki ilk uygulaması olarak kabul edilmektedir.

5.1. Kompleks Değerli Öğrenme Teoremi

Bu algoritma olasılıklı-iniş metodunun (Amari 1967) kompleks değerli versiyonudur. Kompleks değerli örüntüleri sınıflandıran bir model olarak ortaya çıkmıştır. Bu algoritma aşağıdaki şekilde ifade edilebilir.

Eğer n ayrık zamanı ifade eden bir parametre olarak ifade edilirse, kompleks değerli w parametresi şu şekilde değiştirilebilir:

$$Y_n \; w_{n+1} = w_n + \Delta w_n \tag{5.1}$$

Burada w_n, n zamanındaki kompleks değerli parametreyi göstermektedir. Eşitlik (5.1) aşağıdaki şekilde yeniden yazılabilir:

$$\begin{aligned} \mathrm{Re}\left[w_{n+1}\right] &= \mathrm{Re}\left[w_n\right] + \mathrm{Re}\left[\Delta w_n\right] \\ \mathrm{Im}\left[w_{n+1}\right] &= \mathrm{Im}\left[w_n\right] + \mathrm{Im}\left[\Delta w_n\right] \end{aligned} \tag{5.2}$$

Burada $\mathrm{Re}\left[z\right]$ ve $\mathrm{Im}\left[z\right]$, z kompleks sayısının sırasıyla reel ve imajiner kısımlarını göstermektedir. Bu tanımlamalara uygun olarak, $\mathrm{R}\left[w\right]$ ortalama hatası yerel değere ya da global minimuma ulaştıysa optimal w parametresine ulaşılmış olarak kabul edilebilir (Nitta 1997).

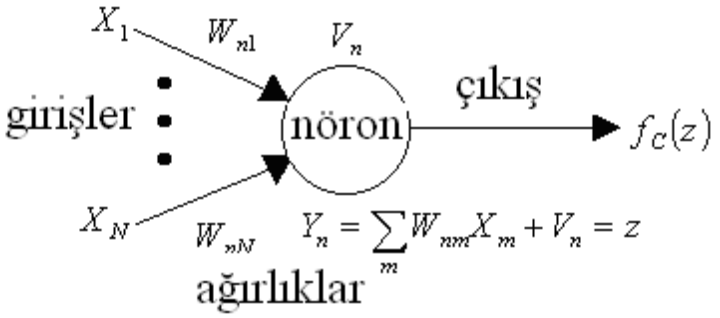
A pozitif belirli bir matris olarak kabul edildiğinde, aşağıdaki güncelleme kuralları kullanılabilir:

$$\begin{aligned} \mathrm{Re}\left[\Delta w_n\right] &= -\varepsilon A \Delta^{\mathrm{Re}} r\left(z\left(w_n, x_n\right), y_n\right) \\ \mathrm{Im}\left[\Delta w_n\right] &= -\varepsilon A \Delta^{\mathrm{Im}} r\left(z\left(w_n, x_n\right), y_n\right) \end{aligned} \quad \text{n=0,1...} \tag{5.3}$$

Yeteri kadar küçük bir öğrenme oranı seçildiğinde ($\varepsilon > 0$ olmak üzere) kompleks değerli w parametresi optimum değere yakınsayabilir. Eşitlik (5.3)' de Δ^{Re} ve Δ^{Im}, w' nın sırasıyla reel ve imajiner kısımları için eğim operatörünü ifade etmektedir.

5.2. Reel Geriye Yayılım Algoritmasının Kompleks Değerli Geriye Yayılım Algoritmasına Genelleştirilmesi

Bu bölümde, kompleks geriye yayılım (KGY) algoritması çok katmanlı kompleks değerli yapay sinir ağlarına (KDYSA) uygulanmıştır. Bu amaçla ilk olarak kompleks geriye yayılım modeli açıklanmıştır. Şekil 5.2' de KGY algoritmasında kullanılan bir nöron modeli verilmiştir.



Şekil 5.2. KGY algoritmasında kullanılan nöron modeli
(giriş, çıkış ve ağırlıklar kompleks sayıdır)

Burada giriş sinyalleri, ağırlıklar, eşik değerleri ve çıkış sinyallerinin tamamı kompleks sayılardan oluşmaktadır. Nöronun Y_n aktif değeri şu şekilde tanımlanabilir;

$$Y_n = \sum_m W_{nm} X_m + V_n \tag{5.4}$$

Eşitlik (5.4)' de, W_{nm}, n nöronu ile m nöronu arasındaki kompleks değerli bağlantı ağırlığıdır. X_m, m nöronunun kompleks değerli giriş sinyali ve V_n ise n nöronunun kompleks değerli eşik değeridir. Kompleks değerli çıkış sinyalini elde edebilmek için Y_n aktif değeri, reel ve imajiner kısım olarak aşağıda gösterildiği gibi iki bileşene dönüştürülür;

$$Y_n = x + iy = z \tag{5.5}$$

Burada i, $\sqrt{-1}$ değerini ifade etmektedir. Her bir nöronun çeşitli çıkış fonksiyonları göz önünde bulundurulduğunda, çıkış fonksiyonu aşağıdaki eşitlik kullanılarak tanımlanabilir;

$$f_C(z) = f_R(x) + i.f_R(y) \tag{5.6}$$

Burada $f_R(u)=1/(1+\exp(-u))$, genel ifadesi sigmoid fonksiyonu olarak adlandırılmaktadır.

Bu çalışmada kullanılan KDYSA üç katmana (giriş, gizli ve çıkış katmanı) sahiptir. Burada W_{ml} giriş katman nöronu l ve gizli katman nöronu m arasındaki ağırlık, V_{nm} gizli katman nöronu m ve çıkış katmanı nöronu n arasındaki ağırlık, θ_m gizli katman nöronu m için eşik değeri ve γ_n çıkış katmanı nöronu n için eşik değerini

ifade etmektedir. I_l, H_m, O_n sırasıyla giriş katmanı nöronu l, gizli katman nöronu m ve çıkış katmanı nöronu n için çıkış değerini ifade etmektedir. Benzer şekilde U_m ve S_n, sırasıyla, gizli katman nöronu m ve çıkış katmanı nöronu n'nin aktif değeridir.

$$U_m = \sum_l W_{ml} I_l + \theta_m \tag{5.7}$$

$$S_n = \sum_m V_{nm} H_m + \gamma_n \tag{5.8}$$

$$H_m = f_C(U_m) \tag{5.9}$$

$$O_n = f_C(S_n) \tag{5.10}$$

olarak ifade edilmektedir. $\delta^n = T_n - O_n$, , n çıkış katmanı nöronunda elde edilen çıkış O_n ve hedef çıkış T_n arasındaki hata ifadesidir. p örüntüsü için karesel hata,

$$E_p = \left(1/2\right) \sum_{n=1}^{N} \left| T_n - O_n \right|^2 \tag{5.11}$$

olarak ifade edilmektedir. Burada N çıkış katmanındaki nöronların sayısıdır.

Şimdi, KGY modeli için öğrenme kuralı tanımlanacaktır. Ağırlıkların ve eşik değerlerinin düzenlenmesi aşağıdaki eşitliklere göre yapılmaktadır (Nitta 1997).

$$\Delta V_{nm} = -\varepsilon . \frac{\partial E_p}{\partial \operatorname{Re}\left[V_{nm}\right]} - i.\varepsilon \frac{\partial E_p}{\partial \operatorname{Im}\left[V_{nm}\right]} \tag{5.12}$$

$$\Delta \gamma_n = -\varepsilon . \frac{\partial E_p}{\partial \operatorname{Re}\left[\gamma_n\right]} - i.\varepsilon \frac{\partial E_p}{\partial \operatorname{Im}\left[\gamma_n\right]} \tag{5.13}$$

$$\Delta W_{ml} = -\varepsilon \frac{\partial E_p}{\partial \operatorname{Re}\left[W_{ml}\right]} - i.\varepsilon \frac{\partial E_p}{\partial \operatorname{Im}\left[W_{ml}\right]} \tag{5.14}$$

$$\Delta \theta_m = \varepsilon \frac{\partial E_p}{\partial \operatorname{Re}\left[\theta_m\right]} - i.\varepsilon \frac{\partial E_p}{\partial \operatorname{Im}\left[\theta_m\right]} \tag{5.15}$$

Eşitlik (5.12)' den (5.15)' e kadar verilen ifadeler aşağıdaki şekilde yeniden yazılabilir:

$$\Delta V_{nm} = \overline{H_m} \Delta \gamma_n \tag{5.16}$$

$$\Delta \gamma_n = \varepsilon \begin{pmatrix} \operatorname{Re}\left[\delta^n\right]\left(1 - \operatorname{Re}\left[O_n\right]\right)\operatorname{Re}\left[O_n\right] \\ + i.\operatorname{Im}\left[\delta^n\right]\left(1 - \operatorname{Im}\left[O_n\right]\right)\operatorname{Im}\left[O_n\right] \end{pmatrix} \tag{5.17}$$

$$\Delta W_{ml} = \overline{I_l} \Delta \theta_m \tag{5.18}$$

$$\Delta\theta_m = \varepsilon\left[\begin{array}{l}(1-\mathrm{Re}[H_m])\mathrm{Re}[H_m] \\ \times\sum_n \left(\begin{array}{l}\mathrm{Re}[\delta^n](1-\mathrm{Re}[O_n]) \\ \mathrm{Re}[O_n]\mathrm{Re}[V_{nm}] \\ +\mathrm{Im}[\delta^n](1-\mathrm{Im}[O_n]) \\ \mathrm{Im}[O_n]\mathrm{Im}[V_{nm}]\end{array}\right)\end{array}\right] - i\varepsilon\left[\begin{array}{l}(1-\mathrm{Im}[H_m])\mathrm{Im}[H_m] \\ \times\sum_n \left(\begin{array}{l}\mathrm{Re}[\delta^n](1-\mathrm{Re}[O_n]) \\ \mathrm{Re}[O_n]\mathrm{Im}[V_{nm}] \\ -\mathrm{Im}[\delta^n](1-\mathrm{Im}[O_n]) \\ \mathrm{Im}[O_n]\mathrm{Re}[V_{nm}]\end{array}\right)\end{array}\right] \quad (5.19)$$

Kompleks GY Algoritmasının Özeti

1. Hazırlık

Bütün ağırlık ve eşik değerlerini sıfırdan büyük olmak üzere küçük kompleks değerli sayılar olarak ata

2. Girişlerin ve Çıkışların (Hedefin) Sunulması

N, eğitimde kullanılacak örüntülerin sayısı olmak üzere, kompleks değerli giriş vektörlerini (X(1), X(2),….,X(N)) ve bunlara karşılık gelen kompleks değerli çıkış (hedef) vektörlerini (T(1), T(2),….T(N)), kullanılacak olan aktivasyon fonksiyonunun tanımlı olduğu bölgeye uygun olarak normalize ettikten sonra ağa sun.

3. Anlık Çıkışın Hesaplanması

Eşitlik (5.4)' ü kullanarak anlık çıkışı hesapla

4. Ağırlıkların ve Eşiklerin Değiştirilmesi

(5.16)-(5.19) eşitliklerini kullanarak ağırlıkları ve eşikleri güncelle ve hata minimize olana kadar bu işleme devam et.

5.3. Kompleks Değerli Aktivasyon Fonksiyonu

Geriye yayılım algoritmasının kompleks düzlemde uygulanmasında karşılaşılan güçlüklerden biri, uygun aktivasyon fonksiyonunun seçilmesidir (Haykın 2002). Sigmoid fonksiyonunun reel düzlemden kompleks düzleme doğru genişletilmesi yetersizdir. Örnek bir sigmoid fonksiyona z kompleks bir girişi uygulandığında

$$\frac{1}{1+e^{-z}} \to \infty \qquad z = \pm j(2k+1)\pi \ (k \text{ herhangi bir tam sayı}) \tag{5.20}$$

ifadesi elde edilir.

Kompleks çok katmanlı perceptronun pratik bir uygulaması için, aktivasyon fonksiyonunun sınırlı olması gereklidir. Aktivasyon fonksiyonu sınırlandırılmadığı zaman çok katmanlı perseptronun yazılım ve donanım uygulamalarında hatalara sebebiyet verdiği görülmüştür.

Georgiou and Koutsougeras (1992), geriye yayılım algoritması ile eğitilmiş çok katmanlı perseptronda kullanılabilecek kompleks aktivasyon fonksiyonunun bir özellik kümesini geliştirmişlerdir. Özetle, bu özellikler aşağıdaki gibidir:

1. Aktivasyon fonksiyonu $\varphi(z)$, z ' in reel ve imajiner kısımları olan Z_R ve Z_I ' nın her ikisinde de doğrusal olmamalıdır. Aksi takdirde, çok katmanlı perseptronun herhangi bir avantajı olmayacaktır. Doğrusal bir çok katmanlı perseptron, tek katmanlı bir perseptrona eşit hale gelecektir. Çok katmanlı perseptron kullanmak, fonksiyonların genel bir setinin, doğrusal bir ağ ile hesaplanabilecek olanından daha fazlasını hesaplayabilen bir doğrusal olmayan ağa sahip olma imkanı verir.

2. $\varphi(z)$ fonksiyonu sınırlı olmalıdır. Çok katmanlı perseptronun ileriye doğru geçişi için tanımlanan formüller sınırlı olmayı gerektirmektedir. Aksi takdirde eğitim esnasında kesintiler olmaktadır.

3. $\varphi(z)$ ' in kısmi türevleri mevcut ve sınırlı olmalıdır. Öğrenim aşaması, çok katmanlı perseptronların kompleks ağırlıklarını kısmi türevlere orantılı olarak günceller. Bu sebeple, kısmi türevlerin sınırlı olmasına ihtiyaç duyulur.

4. $\varphi(z)$ fonksiyonu, kompleks düzlemin her yerinde analitik olan kompleks bir fonksiyon gibi tanımlanmış olmalıdır.

5. Maliyet fonksiyonu $\varepsilon(n)$ ' nin kısmi türevleri, şu şartı sağlamalıdır:

$$\frac{\partial \varepsilon}{\partial u} + j.\frac{\partial \varepsilon}{\partial v} \neq 0 \tag{5.21}$$

Bu şartın gerçeklenmesi için ise, $\varphi(z)$ ' in kısmi türevleri,

$$u_R v_I = u_I v_R \tag{5.22}$$

ilişkisini sağlamalıdır. Eşitlik (5.23), Benvenuto ve Piazza (1992) tarafından ortaya atılan kompleks aktivasyon fonksiyonunu gösterir. Fonksiyon, reel ve imajiner sigmoidlerin süper pozisyonudur ve şu şekilde gösterilir:

$$\varphi(z) = \frac{c}{1+\exp(-kZ_r)} + j.\frac{c}{1+\exp(-kZ_i)} \tag{5.23}$$

Georgiou ve Koutsougeras (1992) tarafından tartışılan diğer aktivasyon fonksiyonu ise sigmoid-benzeri fonksiyonudur ve şu şekilde belirtilir:

$$\varphi(z) = \frac{z}{c + (1/r)|z|} \tag{5.24}$$

Bu fonksiyon z düzleminde $|z| < r$ şartını sağlayan bir çember belirler. Bu yüzden, aktivasyon fonksiyonu $|\varphi(z)|$ ' i $[0, r]$ aralığına sıkıştırır.

Literatürde sıklıkla kullanılan (Nitta 1997, Benvenuto 1992, Arena ve ark. 1993, Solazzi ve ark. 2001) logaritmik sigmoid aktivasyon fonksiyonu

$$\varphi(Z) = \frac{C}{1+\exp(-Z_r)} + j.\frac{C}{1+\exp(-Z_i)} \tag{5.25}$$

ve tanjant sigmoid aktivasyon fonksiyonu

$$\varphi(Z) = \left(\frac{2}{1+\exp(-2\times Z_r)} - 1\right) + j.\left(\frac{2}{1+\exp(-2\times Z_i)} - 1\right) \tag{5.26}$$

şeklinde verilebilir. Logaritmik sigmoid fonksiyonunun (0,1); tanjant sigmoid fonksiyonunun ise (-1,1) aralıklarında tanımlı olmaları sebebiyle, aktivasyon fonksiyonları kullanılırken örüntüler bu aralıklarda normalize edilmelidir.

6. HÜCRESEL YAPAY SİNİR AĞI

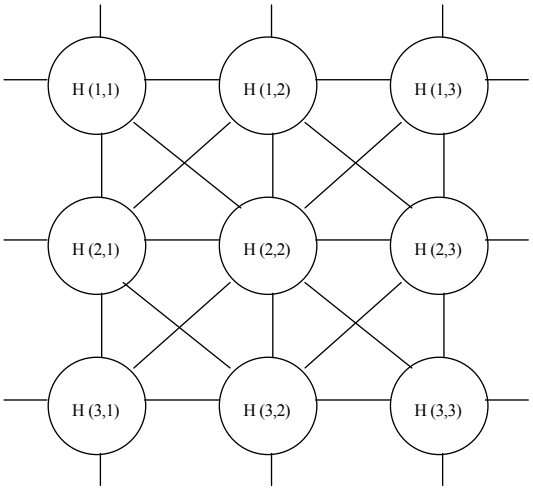
Özel bir dinamik yapay sinir ağı olan Hücresel Yapay Sinir Ağı (HYSA) ilk olarak Leon Chua ve Lin Yang tarafından 1988 yılında ortaya atılmıştır (Chua ve Yang 1988-a,b). HYSA' nın birbirine bağlı iki boyutlu hücreler ve bu hücreler arasındaki bağlantılara dayanan bir yapısı vardır. İki boyutlu hücrenin bileşenleri arasındaki bağlantı ağırlıklarının değişmez olması, HYSA' yı diğer YSA' lardan ayıran en önemli özelliğidir. Bu özellik de HYSA' yı klasik anlamdaki YSA' lara göre oldukça avantajlı bir konuma sokmaktadır. Bilinen anlamdaki YSA' ların bazı temel özelliklerini taşımasının yanı sıra özellikle iki boyutlu yapılarından dolayı HYSA' lar pratikte görüntü işleme ve örüntü tanıma konularında oldukça fazla uygulama alanları bulmuşlardır (Chua 1991, Suzuki ve ark. 1992, Sziranyi ve Csapodi 1994, Genç ve ark. 1996, Özmen ve ark. 1999-a,b, Uçan ve ark. 2006).

Görüntü işlemede HYSA kullanılması durumunda, HYSA' nın hücresel yapısı, işlenecek resim üzerinde hareket ettirilerek resmin sürekli taranması sağlanır. Dolayısıyla resmi oluşturan her hücresel yapı benzeri parçacığı hakkında bilgiler hücre yapısına bir desen olarak tanıttırılır. Böylece resmin ayırt edici özellikleri hücre tarafından öğrenilir. Paralel çalışma ve iki boyutlu özelliklerinden dolayı bu ağ yapısı, karakterlerin bazı ayırt edici özelliklerinin çıkarılmasını sağlayan bir ön işleme elemanı olarak kullanılır. Burada üzerinde işlem yapılacak olan görüntüdeki her nokta bir nörona karşılık gelir. HYSA' lar, görüntü işlemenin yanı sıra hareket sezme işlemlerinde de kullanılmaktadır (Chua ve Yang 1988-a,b).

6.1. HYSA Mimarisi

Bir Hücresel Yapay Sinir Ağındaki hücre, komşusu olan hücreler ile belli bir komşuluk ilişkisi içindedir. Şekil 6.1'de HYSA için örnek bir hücre ve komşuluk

gösterimi verilmiştir. Her bir hücre kendi içerisinde belli komşuluklarla tanımlanmış sinirlerden oluşmaktadır.



Şekil 6.1. İki boyutlu (3x3), HYSA gösterimi

Görüntü işlemede kullanılan HYSA' nın temel görevi, herhangi bir giriş görüntüsünü istenilen amaca uygun olarak bir çıkış görüntüsüne dönüştürmektir. HYSA ile elde edilen çıkış görüntüsünün her bir pikseli –1 veya +1 değerliği ile sınırlandırılır. Giriş resmi ise, istenirse renkli, istenirse gri seviyede, istenirse bit eşlenik resim formunda olabilir. HYSA' dan geçirilen bir resim gerekli başlangıç ve diğer koşulların sağlanması durumunda her zaman kararlı sabit bir durum noktasına yaklaşır.

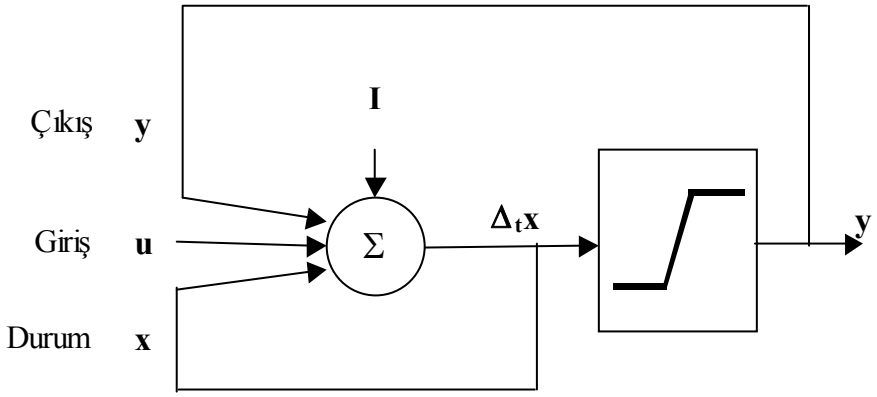
Görüntü işlemede kullanılan HYSA' da giriş resmi, dinamik bir işlemden geçirildikten sonra çıkış resmi olarak elde edilir. HYSA yapısının dinamik olmasından dolayı istenilen kararlı görüntü durumu elde edilene kadar çıkış görüntüsü her an sürekli değişim göstermektedir. Hücresel yapay sinir ağlarının komşuluk düzenindeki yapıları özellikle tüm devre olarak gerçekleştirilmesinde büyük kolaylıklar sağlamıştır.

HYSA' yı diğer YSA' lardan ayıran başlıca özellikleri aşağıdaki gibi özetleyebiliriz (Özmen 2001, Bal 2002):

- İki boyutlu bir ızgaraya benzer hücreler sadece kendi komşuları ile ilişkilidirler.

- Hücreler içindeki bağlantı ağırlıkları, tüm hücrelerde aynıdır.
- Hücrelerin hücre dışı bağlantı ağırlıkları da aynıdır.

HYSA' larında her bir hücre ağırlıklı toplama yapan doğrusal bir giriş birimi, doğrusal bir dinamik ara birimi ve *n* parçalı (genellikle üç parçalı) orijine göre simetrik bir çıkış biriminden oluşur. Şekil 6.2'de bir hücrenin dinamik yapısı gösterilmiştir.



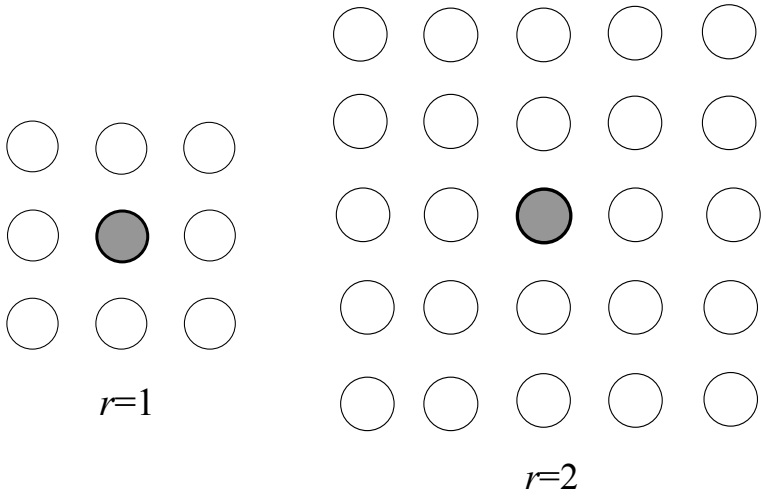
Şekil 6.2. Hücrenin dinamik yapısı

HYSA ile ilgili hücre yapısının ilk ortaya çıkışı devresel bir gösterim ile olmuştur. Bu devredeki hücrelerin her biri doğrusal ve doğrusal olmayan dirençler, kapasiteler ile akım ve gerilim kontrollü kaynaklar içerir.

M satır ve *N* kolondan oluşan bir *MxN* lik HYSA göz önüne alınırsa *i*. satır ve *j*. sütuna (*i,j*) hücresi adı verilecektir ve *H*(*i,j*) olarak ifade edilecektir. Burada herhangi bir *H*(*i,j*) hücresinin *r* komşuluğu aşağıdaki gibi tanımlanabilir (Chua ve ark. 1988.a).

$$K_r(i,j) = \left\{ H(k,l) \;\middle|\; \max\left(|i-k|, |j-l|\right) \le r, \quad 1 \le \mathrm{i} \le \mathrm{M}; 1 \le j \le \mathrm{N} \right\} \tag{6.1}$$

Burada komşuluğu gösteren *r*, pozitif bir tamsayıdır ve bu tamsayı verilen bir hücrenin kendisinden ne kadar uzaklıktaki hücreler tarafından doğrudan etkileneceğine işaret eder. Şekil 6.3'de, *r*=1 komşuluğunda yapı içerisindeki her bir hücrenin sadece çevresindeki hücreler tarafından etkilendiği, *r=2* komşuluğunda ise her bir hücrenin kendinden iki hücre uzaklığındaki hücreler tarafından da etkilenebileceğini göstermektedir (Chua ve Yang 1988-a).



Şekil 6.3. r=1 ve r=2 komşuluk için HYSA'nın hücre ilişkileri

r=1 komşuluk derecesi söz konusu olduğunda genellikle "3x3", *r*=2 komşuluk derecesi söz konusu olduğunda "5x5" komşu hücre mevcuttur. Bir *r* derece komşuluğu içerisinde *(2r+1)(2r+1)* tane hücre bulunur. Hücreler aynı zamanda simetri özelliğine de sahiptir. Yani $H(k,l) \in K_r(i,j)$ ise $H(i,j) \in K_r(k,l)$ dir.

Hücresel yapay sinir ağındaki bir hücrenin dinamiklerini çıkış geri beslemesinin etkisini belirleyen *A(i,j;k,l)* parametresi ile girişin kontrol etkisini belirleyen *B(i,j;k,l)* parametreleri oluşturur. Bu parametreler ayrıca *A(i,j;k,l)* G*eri Besleme Ağırlık Katsayısı* ve *B(i,j;k,l)* G*iriş Ağırlık Katsayısı* olarak da adlandırılırlar. *A* geri besleme ve *B* giriş ağırlık katsayıları, 1. dereceden bir komşuluk için matris formda aşağıdaki gibi gösterilebilirler;

$$A = \begin{bmatrix} a_1 & a_2 & a_3 \\ a_4 & a_5 & a_4 \\ a_3 & a_2 & a_1 \end{bmatrix} \qquad B = \begin{bmatrix} b_1 & b_2 & b_3 \\ b_4 & b_5 & b_4 \\ b_3 & b_2 & b_1 \end{bmatrix} \tag{6.2}$$

Filtre özelliği gösteren HYSA yapısı A ve B parametrelerinin kullanılması ile elde edilir. İstenilen görüntü dönüşümünün sağlanabilmesi için filtre parametrelerinin nasıl seçilmesi gerektiği günümüzde halen önemli bir araştırma konusu olarak yer almaktadır. Uygulamalarda, *A* geri besleme bağlama ağırlık katsayılarının simetrik seçilmesinin yanında *B* giriş bağlama ağırlık katsayıları da simetrik seçilirler. İlgilenilen görüntü işleme uygulamalarında görüntü hücre yapılarının birbirlerine göre simetrik bir ilişki ile işlemlere girmesinin bazen bir zorunluluk olması, bazen de

asimetrik işlemenin önemli bir getirisinin olmaması dolayısıyla hesap karmaşasını azaltmak için simetrik parametreler seçmek gerekir.

6.2. HYSA Eğitimi

HYSA'da kullanılan öğrenme metotları klasik geri yayılımlı YSA'larda kullanılan metotlara benzerdir. Genel olarak HYSA'da eğiticili öğrenme metodundan bahsedilebilir (Bal 2002).

Eğiticili öğrenme algoritmaları, aşağıda (6.3) eşitliğinde tanımlanan notasyonlardaki giriş (v) ve istenen kalıcı çıkış (d) örnek değerleri ile verilen bilinmeyen bir $d=f(v)$ fonksiyonuna, en az hata veren bir HYSA ile yaklaşmaya dayanır.

$$\{(v_1, d_1), (v_2, d_2), ..., (v_n, d_n)\} \tag{6.3}$$

Minimuma düşürülmeye çalışılan hata değeri, gerçek ve kalıcı çıkışlar arasındaki farkın bir ölçüsüdür. Tüm örnek desenler için hesaplanan hata değeri, her bir desenin hatalarının toplamına eşittir. Kalıcı çıkış $y(\infty)$,istenen çıkış d ile ifade edilirse; her bir giriş için kalıcı çıkış ile istenen çıkış arasındaki hata, $\varepsilon_i(w)$;

$$\varepsilon(w) = \sum_{i=1}^{n} \varepsilon_i = \sum_i \sum_{k,l} (y_{k,l}^i(\infty) - d_{k,l}^i)^2 \tag{6.4}$$

eşitliğinden hesaplanabilir.

- Yukarıdaki tanımların ışığında, ikili kararlı durum çıkış modunda çalıştırılan tam kararlı HYSA'nın durum çıkışlarının eğiticili öğrenilmesi, kısıtlamalı bir optimizasyon problemi olarak ortaya konabilir. Burada minimuma indirgenecek desenlerin hatalarının toplamı $\varepsilon(w)$ toplam hatasıdır.

  Eşitlik (6.4)' de verilen toplam hata hesabında kullanılan sabitler atılarak;

$$\varepsilon(w) = \sum_{k,l,i} y_{k,l}^i(\infty)(y_{k,l}^i(\infty) - d_{k,l}^i) = \sum_{(k,l,i)\in D^+} y_{k,l}^i(\infty) - \sum_{(k,l,i)\in D^-} y_{k,l}^i(\infty) \tag{6.5}$$

şeklinde toplam hata terimi yeniden yazılabilir.

Buradaki D^+ ve D^- terimlerini aşağıdaki gibi tanımlanabilir;

$$D^{+} = \left\{ (k,l,i) \mid y^{i}_{k,l}(\infty) = -d^{i}_{k,l} = 1 \right\}$$
$$D^{-} = \left\{ (k,l,i) \mid y^{i}_{k,l}(\infty) = -d^{i}_{k,l} = -1 \right\} \tag{6.6}$$

Hücrenin kalıcı durumdaki toplam girişi aşağıdaki gibi kısaca ifade edilebilir;

$$\boldsymbol{Y}^{i}_{k,l} = \left[\left[\boldsymbol{y}^{i}_{k,l} \right]^{T} \left[\boldsymbol{u}^{i}_{k,l} \right]^{T} \boldsymbol{I} \right]^{T} \tag{6.7}$$

(6.7) ile verilen eşitlikteki anlık kararlı durum çıkışları ($\boldsymbol{y}^{i}_{k,l}$) ve hücre girişleri ($\boldsymbol{u}^{i}_{k,l}$);

$$\boldsymbol{y}^{i}_{k,l} = \left[y^{i}_{k-1,l-1}(\infty) + y^{i}_{k+1,l+1}(\infty) \quad y^{i}_{k-1,l}(\infty) + y^{i}_{k+1,l}(\infty) \quad y^{i}_{k-1,l+1}(\infty) + y^{i}_{k+1,l-1}(\infty) \right.$$
$$\left. y^{i}_{k,l-1}(\infty) + y^{i}_{k,l+1}(\infty) \quad y^{i}_{k,l}(\infty) \right]^{T} \tag{6.8}$$

$$\boldsymbol{u}^{i}_{k,l} = \left[u^{i}_{k-1,l-1} + u^{i}_{k+1,l+1} \;\; u^{i}_{k-1,l} + u^{i}_{k+1,l} \;\; u^{i}_{k-1,l+1} + u^{i}_{k+1,l-1} \;\; u^{i}_{k,l-1} + u^{i}_{k,l+1} \;\; u^{i}_{k,l} \right]^{T} \tag{6.9}$$

şeklinde ifade edilebilir.

HYSA'da ardışıl öğrenmeyi sağlayabilmek için bağlantı ağırlık vektörü *w* (bir sonraki adımda sinir çıkışlarının hesabında kullanılacaktır) aşağıdaki gibi hesaplanabilir.

$$\boldsymbol{w}(n+1) = \left[\boldsymbol{w}(n) - \boldsymbol{e}(n).\Re\left[\boldsymbol{w}(n)\right] \right] \tag{6.10}$$

(6.10) ile verilen eşitlikdeki $\Re[w]$, (6.11) eşitliğinde tanımlanan özellikteki bir fonksiyondur. Bu fonksiyon, hataların toplamının minimum olmasını sağlayan bir hesaplama içerir ve matematiksel olarak;

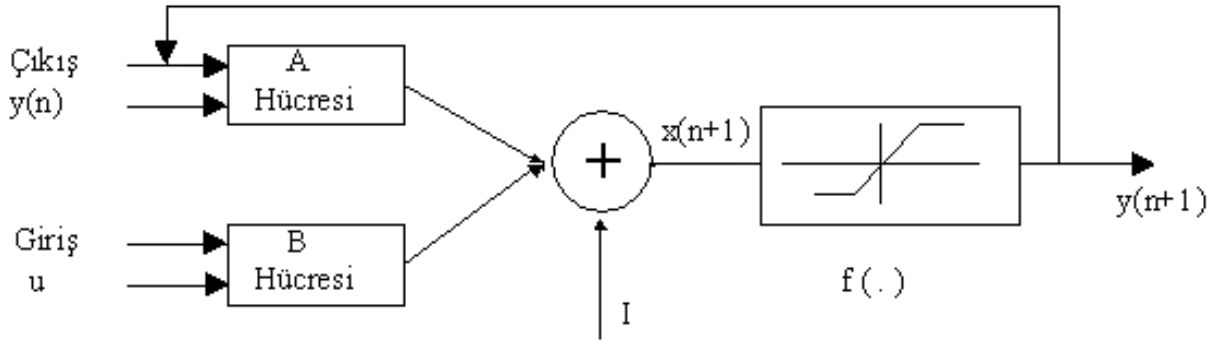
$$\Re[\boldsymbol{w}(n)] = \left(\sum_{(k,l,i)\in D^{+}} \boldsymbol{Y}^{i}_{k,l}(n) - \sum_{(k,l,i)\in D^{-}} \boldsymbol{Y}^{i}_{k,l}(n) \right) \tag{6.11}$$

eşitliğinden hesaplanabilir.

(6.10) eşitliğindeki $\boldsymbol{e}(n)$ ise, çoğunlukla küçük bir sayı olarak seçilen öğrenme oranıdır.

6.3. HYSA Yapısı

Hücresel yapay sinir ağının yapısı Şekil 6.4' te gösterilmektedir.



Şekil 6.4. Hücresel yapay sinir ağı yapısı

Hücresel yapay sinir ağının matematiksel ifadeleri şu şekildedir:

$$x_{i,j}(n+1) = \sum A\, y_{i,j}(n) + \sum B\, u_{i,j} + I \tag{6.12}$$

$$y_{i,j}(n) = 0.5\,(\,|x_{i,j}(n)+1| - |x_{i,j}(n)-1|\,) \tag{6.13}$$

HYSA' nın tasarımında amaç, uygun A, B şablonlarının (filtrelerinin) ve I bias değerinin bulunmasıdır. Bu amaçla geliştirilen algoritma için öncelikle çıkış fonksiyonunun türevi alınabilir olması gerekmektedir. (6.13) eşitliğinin açık ifadesi şu şekildedir:

$$F(x) = \begin{Bmatrix} 1 & x \geq 1 \\ -1 & x \leq -1 \\ x & -1 < x < 1 \end{Bmatrix} \tag{6.14}$$

Bu fonksiyonun bölgelere ayrılarak türevi alındığında,

$$F'(x) = \begin{Bmatrix} 0 & x \leq -1 \quad \text{and} \quad x \geq 1 \\ 1 & -1 < x < 1 \end{Bmatrix} \tag{6.15}$$

elde edilir. Yukarıda ifade edilen standart aktivasyon fonksiyonları (Chua ve Yang 1988-a,b) haricinde HYSA' nın eğitim performansının artırılabilmesi için Lyapunov

fonksiyonu (Zhou ve Zhang 2001), trapezoidal fonksiyon (Bilgili ve ark. 2005) vb.. farklı aktivasyon fonksiyonları da kullanılmaktadır.

7. KOMPLEKS DEĞERLİ HİBRİT HÜCRESEL YAPAY SİNİR AĞI

Geriye yayılım algoritmasının ileri yönlü ağlarda kullanımı oldukça yaygındır ve genelde optimum sonuçlar vermektedir. Bu algoritmanın HYSA için öğrenme algoritması olarak kullanılması için dinamik yapıya uygun olacak şekilde birtakım düzenlemelerin yapılması zorunludur:

- HYSA yapısında kullanılan A ve B hücreleri 3x3, 5x5 gibi küçük boyutlarda olduğundan değişik boyutlardaki görüntü matrisleri ile matris çarpımı yapılamamaktadır. Bu matrisler arasında konvolüsyon işlemi uygulanmaktadır. Geriye yayılım algoritmasının çalışması, ağırlık matrislerinin boyutlarının, giriş görüntüsünün boyutuna ve gizli katmanda kullanılan nöron sayısına bağlı olarak oldukça büyük olması gibi sebepler ile konvolüsyon çarpımı için uygun değildir.
- Eğim düşüm formülünde giriş değerleri kullanılmaktadır. HYSA' nda giriş değerleri çıkışla birlikte değiştiğinden eğitim sonucu ıraksamaktadır.
- Geriye yayılım sürecinde iki farklı yöntem uygulanabilmektedir.
    1) Ağın yapısını perseptron yapısına benzetmek
    2) Algoritma içinde HYSA' nın kendi yapısını kullanmak
- Görüntü işleme amaçlı kullanılan ayrık HYSA' nın çıkış fonksiyonu sürekli olmadığından geriye yayılım algoritmasının kullanılabilmesi için türevi alınabilir bir fonksiyonun olması gerekmektedir.

Yukarıda ifade edilen tüm bu kısıtlamaların ortaya koyduğu ana problem, HYSA yapısında yer alan A, B ve I şablonlarının güncellenmesidir. Bugüne kadar güncelleme için geriye yayılım algoritması üzerinde çeşitli değişiklikler ve adaptasyonlar yapılmış olsa da, bu çalışmalar A, B ve I matrislerinin bulanık kümeleme üyelik fonksiyonu olarak belirlenmesi (Lin ve ark. 2004), genetik algoritma ile optimize (Özekes ve ark. 2008) edilmesi vb. yaklaşımlar üzerinde durmuşlardır.

Tez çalışmasında gerçekleştirilen Kompleks Değerli Hibrit Hücresel Yapay Sinir Ağı (KDHHYSA) yapısı, Hücresel YSA (HYSA) ile Kompleks Değerli YSA (KDYSA)' nın birlikte çalıştığı yeni bir danışmanlı YSA modelidir. Burada amaç,

konvolüsyonu temel alan ve iki boyutlu bir yapıya sahip HYSA' nın A, B ve I parametrelerinin güncellenmesi işlemini kompleks değerli geriye yayılım algoritması içerisine yerleştirerek, KDYSA' nın ağırlıklarının güncellenmesi ile A, B ve I parametrelerinin de güncellenmesi ve istenilen çıkışa daha doğru bir şekilde yakınsama sağlanmasıdır. Böylece ön-işleme / özellik çıkarma işleminden sonra kompleks değere sahip olabilecek görüntü üzerinde HYSA' nın basit yapısını ve KDYSA' nın işlem gücünü birleştirecek bir yapı önerilmiştir. Geliştirilen KDHHYSA yapısı, Şekil 7.1' de görülmektedir.

KDHHYSA algoritmasının görüntüler üzerine uygulamasına geçilmeden önce bazı ön-işlemler gerçekleştirilmektedir. Bu ön-işlemlerin ilki gri ölçekli BT görüntüsünün ikili-değere (0 ve 1) sahip görüntüler şekline getirilmesidir. Böylece akciğer bölgesine dahil olan (ikili sistemde 1) / olmayan (ikili sistemde 0) piksellerin ayrılacağı segmentasyon işlemi için en uygun ön-işlem uygulamalarından birisi gerçekleştirilecektir. Daha sonra piksel değerleri 0 ve 1 ikili sayılarından oluşan ancak oldukça büyük boyutlara sahip olan (orijinal görüntü boyutu ile aynı) görüntülerin KDDD ile boyutlarının azaltılması işlemleridir. Bu işlemlerden sonra hem boyutu azaltılan hemde kompleks-değerli hale gelen görüntü KDHHYSA' nın ilk aşaması olan KDYSA' ya sütun vektörleri şeklinde sunulmuştur. Öncelikle birinci sütun vektörü, daha sonra ikinci sütun vektörü olmak üzere görüntünün tüm elemanları sütun vektörleri şeklinde KDYSA'ya giriş olarak verilmiştir.

KDYSA' da, ilk başta [0,1] aralığından seçilen rastgele kompleks sayılar olarak belirlenen ağırlıklara uygun olarak bir çıkış görüntüsü elde edilir. Elde edilen bu çıkış görüntüsü ile giriş görüntüsü, sırasıyla A ve B şablonları ile iki boyutlu konvolüsyonlarının gerçekleştirilmesi amacı ile HYSA' ya verilir. İki boyutlu konvolüsyonların ardından I eşiği ile de toplanan yeni görüntü matrisi bir aktivasyon fonksiyonundan geçirilerek çıkış elde edilir. Böylece bir iterasyonluk işlem tamamlanmış olur. A, B ve I matrislerinin ilk iterasyon için değerleri, KDYSA' da ilk başta rastgele belirlenen ağırlık değerlerinden alınırlar. Elde edilen çıkış görüntüsü istenilen hata değerine yakınsamadığında (piksel bazında karşılaştırma yapıldığında çıkış ile hedef pikselleri bire bir örtüşmüyorsa) ya da belirlenen maksimum iterasyon değerine ulaşılmadığında bir sonraki iterasyona geçilir. Elde edilen çıkış görüntüsü ile hedef görüntüsü arasındaki hata fonksiyonuna uygun

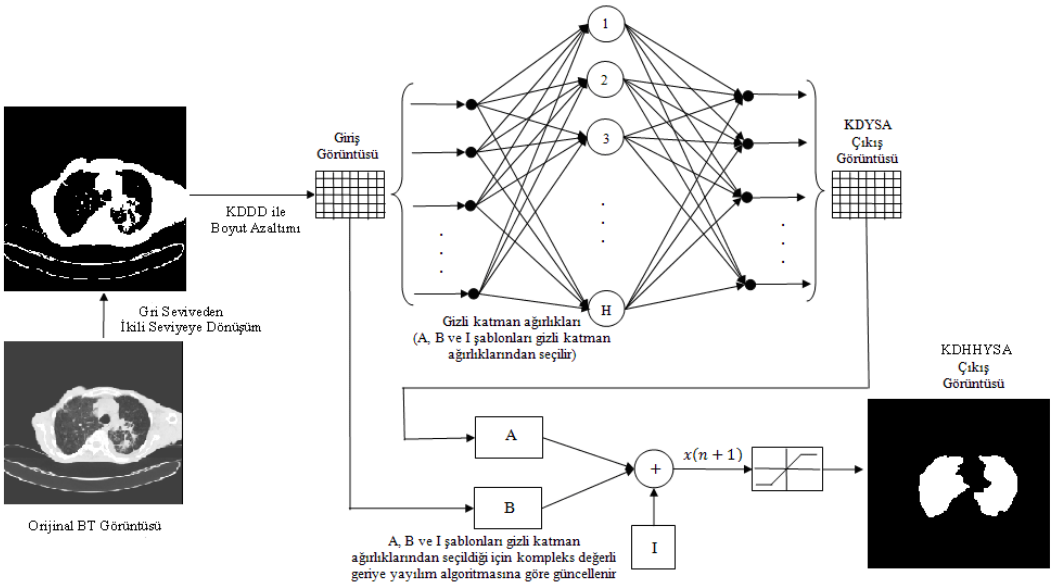
olarak kompleks değerli geriye yayılım algoritması ile KDYSA' nın ağırlıkları güncellenerek yeni bir çıkış elde edilir ve bu da bir önceki iterasyonda olduğu gibi HYSA' ya A, B ve I parametreleri ile konvole edilebilmesi için sunulurlar.

HYSA' nın A, B ve I parametreleri KDYSA' nın kompleks değerli ağırlık matrisi içerisinden çalışılacak bölgeyi maskeleyecek şekilde (akciğer bölgesinin segmentasyonu işleminde tüm BT görüntüsü düşünüldüğünde sadece akciğerin bulunduğu kısmı içerisine alacak bölge) alınarak kompleks değerli HYSA yeniden çalıştırılmış olur. Bir başka deyişle, konvolüsyonda kullanılacak A, B ve I parametreleri kompleks değerli geriye yayılım algoritması ile güncellenmiştir. Tüm bu işlemlerden sonra elde edilen sonuç görüntüsünün hedef görüntüsüne yakınsamasına bağlı olarak bir sonraki iterasyona geçilir ve işlem bu şekilde sürdürülür.

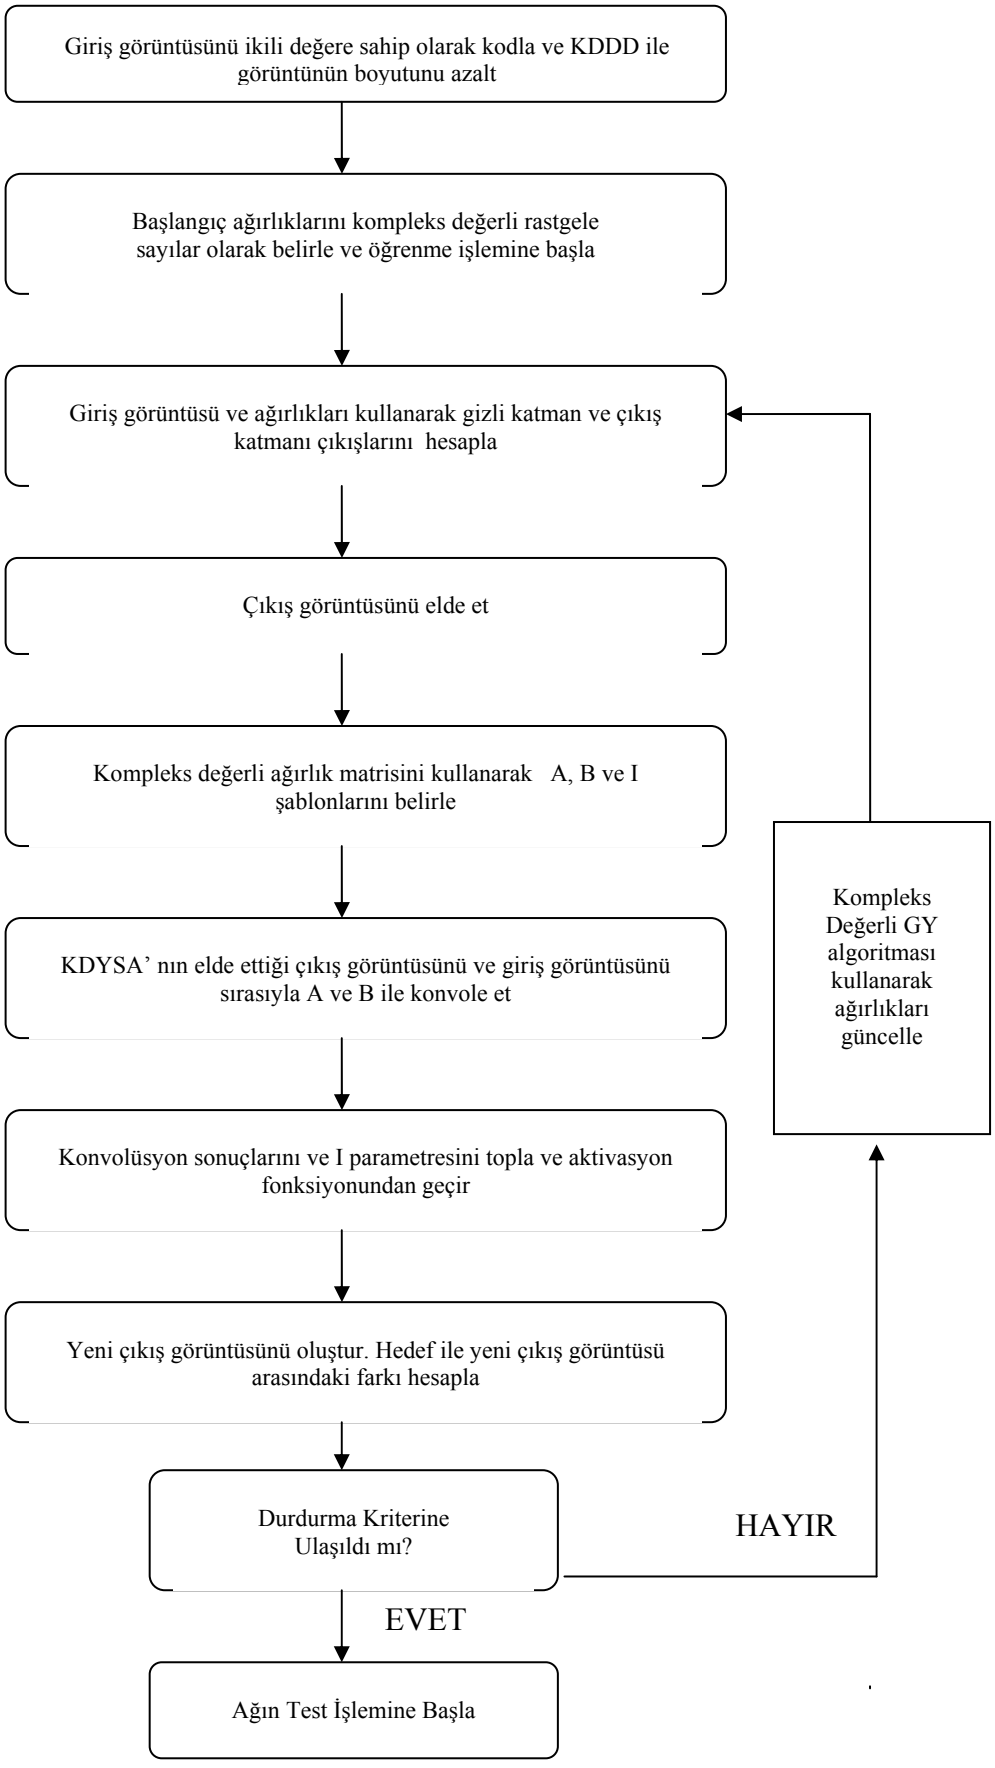
Akciğer bölgesinin segmentasyonu işleminde, KDYSA' nın ağırlık matrisinden sadece akciğere karşılık gelecek bölgesinden A, B ve I parametrelerinin seçilmesinin nedeni şu şekilde açıklanabilir: Segmentasyon işleminde görüntü ikili sisteme çevirilerek değerlendirilmektedir. Yani görüntü sadece 0 (siyah) ve 1 (beyaz) değerlerinden oluşmaktadır. Akciğerin haricindeki bölgeler siyah, akciğer bölgesi ise beyaz renk ile belirlenmektedir. Ağırlık matrislerinin değişimleri incelendiğinde, akciğer haricindeki 0 değerine sahip bölgeleri temsil eden ağırlıkların sıfıra oldukça hızlı bir şekilde yaklaştığı ve yeni iterasyonlarda büyük değişimler göstermediği görülmüştür. Ağırlık matrisinin akciğer bölgesine karşılık gelen kısmındaki değerlerinin iterasyona bağlı olarak değişimi rahatlıkla gözlenebilmektedir. Yani ağın 1 değerine yakınsaması iterasyona bağlı değişimler (yani güncellemeler) ile elde edilebilmektedir. Ağırlık matrisinin akciğer haricindeki bir bölgeyi kapsayacak şekilde seçilmesi durumunda ağırlık katsayılarındaki değişimler çok çok küçük olduğundan çıkış görüntüsünün iki iterasyon arasındaki değişimi de çok çok küçük olmakta ve hedefe ulaşma işlemi ya çok uzun sürmekte ya da tamamlanamamaktadır.

Tez çalışmasında, BT görüntülerinde yer alan akciğer bölgelerinin boyutlarının birbirinden farklı olması sebebi ile A, B ve I şablonlarının seçildiği matris maskesi, boyutu ne olursa olsun kesinlikle akciğer bölgesini kapsayabilmek amacı ile tüm görüntü matrisinin yaklaşık ortası olacak şekilde algoritma tarafından otomatik olarak seçilmektedir. HYSA' da aktivasyon fonksiyonu olarak logaritmik

sigmoid (Eşitlik 5.25) kullanılmıştır. KDHHYSA' ya ait öğrenme algoritması akış şeması Şekil 7.2' de yer almaktadır.



Şekil 7.1. Kompleks değerli hibrit hücresel YSA



Şekil 7.2. Kompleks değerli hibrit hücresel YSA' nın akış şeması

8. AKCİĞER KANSERİ

Akciğer kanseri, özellikle gelişmiş endüstriyel ülkelerde görülen en öldürücü hastalıklar arasındadır. Akciğer kanserine sebep olan kötü huylu nodüllerin teşhisinde kullanılan Bilgisayarlı Tomografinin (BT), göğüs X- ışını görüntülemesinden daha başarılı olduğu kanıtlanmıştır. 2005 verilerine göre son 5 yılda, nodüllerin yerlerinin erken safhada belirlendiği durumlarda, hastaların hayatta kalma oranları %14' ten % 49' a yükselmiştir. Bununla birlikte, BT, akciğer kanserinin safhalarının belirlenmesinde önemli bir rol oynamaktadır. Ancak BT ile nodüllerin tespitinde, düşük kontrast, nodül boyutu ve yerleşim değişimleri gibi zorluklar mevcuttur.

Akciğer kanseri problemlerinin erken teşhisi ve hastalığın ilerleyişi için doktor tahminine yardımcı olacak bilgisayar destekli teşhis (BDT) sistemleri oldukça değer kazanmıştır. Akciğer kanserinin tedavisindeki başarı ve hastalığın ilerleyişi hakkında uzman tarafından yorum yapılabilmesi, küçük ve yerleşmiş nodüllerin erken teşhisine bağlıdır. BT görüntülerinde karmaşık akciğer yapısı, kireçlenme, nodülün yoğunluğu, şekli, dokusu, çevreleyen yapılar gibi etkenlerin çok sayıda olmasından dolayı, doktorun teşhisine destek olabilmek için özelliklerin sayısal ölçümlerinin sağlanması gereklidir. Bir BDT sistemi medikal görüntülerin değerlendirilmesinde sayısal ve tekrarlanabilir ölçümler yapabilme, zamanında teşhis, verilerin tekrar elde edilmesi, çok sayıda hastadan elde edilen verilerin birbiriyle karşılaştırılması ve uzman yorgunluğundan kaynaklanan hataların azaltılması gibi avantajlara sahiptir. Yaygın olarak kullanılan BDT sistemleri, BT görüntülerindeki akciğer bölgesinin tanımlanması (segmentasyonu) ile bu bölgede yer alan kansere aday nodüllerin bulunması ve sınıflandırılmasını içermektedir.

8.1. Akciğer Tümörleri

Akciğer tümörleri (nodülleri) benign (iyi huylu) ve malign (kötü huylu) olmak üzere iki ana sınıfa ayrılmışlardır.

8.1.1. Benign nodüller

Tüm akciğer nodüllerinin %1.2-2 gibi çok düşük bir yüzdesini oluşturan benign nodüller genelde herhangi bir belirti vermezler ve raslantısal olarak saptanırlar. Yavaş büyüyen bu nodüller yıllarca değişmeden kalabilirler. Klinik ve radyolojik bulgular nodülün yerine bağlıdır.

Çevresel dokulara yerleşimli olanlar belirti vermezler ve göğüs grafisinde akciğer nodülü olarak görülürler. Bu lezyonlarda belign-malign ayırımı radyoloğun en çok zorlandığı konulardan birisidir. Düzgün kenar, periyodik izlenim görüntülerinde yavaş büyüme benign lezyonlarda sık görülen bir özelliktir. Nodüller içinde kalsifikasyon olabilir, bunların yaygın homojen, merkezi, ince veya patlamış mısır şeklinde olmaları benignite, merkezi olmaması veya çok sayıda küçük kalsifikasyonlar malignite olarak yorumlanır.

BT incelenmesinde nodül içinde yağ yoğunluğu değerlerinin saptanması yağ nodülünü (yağ dokusunun bulunduğu yerde büyümesi ile oluşan zararsız nodül yapısı) düşündürür. Diğer taraftan kontrastlı dinamik çalışmada lezyonun 20 HU (Hounsfield Unit)' nun altında kontrastlanma göstermesi benignite lehinedir. Bu değerin üzerindeki kontrastlanmalar çoğunlukla malign nodüllerde görülmektedir. Yukarıda sayılan bulgulara karşın akciğer kanserinin yüksek ölüm oranına sahip olması nedeniyle lezyonun mutlaka histopatolojik tanısına ulaşmak gerektiği bugün yaygın olarak kabul edilen bir görüştür (Osma 2000).

8.1.2. Malign nodüller

Akciğer kanseri en sık görülen kanser türüdür ve hızlı seyirli olup ölüm nedenleri arasında 2. sıradadır. Erken tanı alıp cerrahi operasyon ve diğer tedavi yöntemleri uygulananlar da bile 5 yıllık yaşam şansı % 40' ın altındadır. Görülme sıklığı giderek artmakta olup A.B.D' de kadınlarda 1988 yılında meme kanserini geçerek 1. sıraya gelmiştir. Türkiye' de ölüm nedenleri arasında kalp-damar hastalıklarından sonra 2. sırada yer alır. Akciğer kanseri önlenebilir tek kanser türüdür. Çünkü olguların %80-90 kadarı doğrudan sigara içimi ile ilgilidir. Diğer risk faktörleri, yaş (en sık 50-70 yaşları arasında görülür), ırk (zenci ırkta daha sık görülür), asbestle temas, radyasyon, geçirilmiş akciğer hastalıkları, A, E, C vitaminlerinin ve selenyum gibi anti-kanserojen olduğu bilinen maddelerin yetersiz alınması ve genetik yatkınlık olarak sıralanabilir (Osma 2000).

Histapatolojik olarak akciğer kanserlerinin sınıflanması aşağıdaki şekilde yapılabilir (Osma 2000):

1- Skuamoz hücreli karsinom
2- Küçük hücreli karsinom
3- Adenokarsinom
4- Büyük hücreli karsinom
5- Adenoskuamöz hücreli karsinom
6- Karsinoid
7- Bronş bez karsinomları
8- Diğer

Akciğer kanserlerinin % 90-95' ini ilk dört tip oluşturur. Bu kanser tiplerinin en çok merkezi sinir sistemi, lenf bezleri ve iskelet sistemine yayıldığı görülmüştür.

8.2. Akciğer Nodüllerinin Görüntülenmesi

Bilgisayarlı tomografi, kesit yöntemine dayalı radyolojik inceleme yöntemlerinden akciğerde en yaygın kullanılanıdır. Çeşitli ortamların X ışını geçirgenliğinin farklı olması sebebiyle bir kesit içindeki tüm yapılardan maksimum bilgi almak mümkündür. Kitlesel lezyonların veya bu lezyonları taklit eden ışık

geçirmeyen yapıların ve akciğer duvarına yerleşmiş lezyonların tespit edilmesi, lezyonların damarlar ile ilişkilerinin ortaya çıkartılması gibi geniş bir yelpazede başarı ile kullanılmaktadır. Cihazlardaki teknolojik gelişmeler ön tanıya göre değişik inceleme seçenekleri sunmaktadır. Bilgisayarlı tomografi görüntüleme temelde üç alt başlıkta incelenebilir (Osma 2000). Bunlar; konvansiyonel BT, yüksek çözünürlüklü BT ve spiral BT' dir.

8.2.1. Konvansiyonel BT

Genelde 10 mm kesit kalınlığı ile göğüs bölgesinin taranması yöntemidir. Nefes tutma iyi ayarlanabilirse akciğerin görüntülenemeyen hiç bir yeri kalmamaktadır. Spesifik bir ön tanı veya lokalizasyon belirtilmeyen patolojilerde tercih edilen yöntemdir.

Konvansiyonel BT günümüzde iğne biyopsilerinde rehber olarak sık kullanılan, emniyetli bir yöntemdir. Lezyona en uygun yerden yaklaşılacak şekilde hastaya pozisyon verildikten sonra alınan kesitte en kısa lezyon-cilt uzaklığı ölçülür ve ince iğne ile lezyona girilir. Önemli olan patolojiye en az akciğer dokusu katederek ulaşmak ve doku ölümü (nekroz) olmayan bölümden örnek alabilmektir.

8.2.2. Yüksek çözünürlüklü BT

1-3 mm kalınlığında alınan kesitler ile yapılan BT tetkikidir. Bu yöntemle akciğer dokusundan çok iyi detaylar alabilmek mümkün olmaktadır. Nodüllerin kenar özelliklerinin ve çevre ilişkilerinin gösterilmesinde, kalsiyum ve yağ içeriklerinin saptanmasında konvansiyonel BT' lerden daha üstündürler.

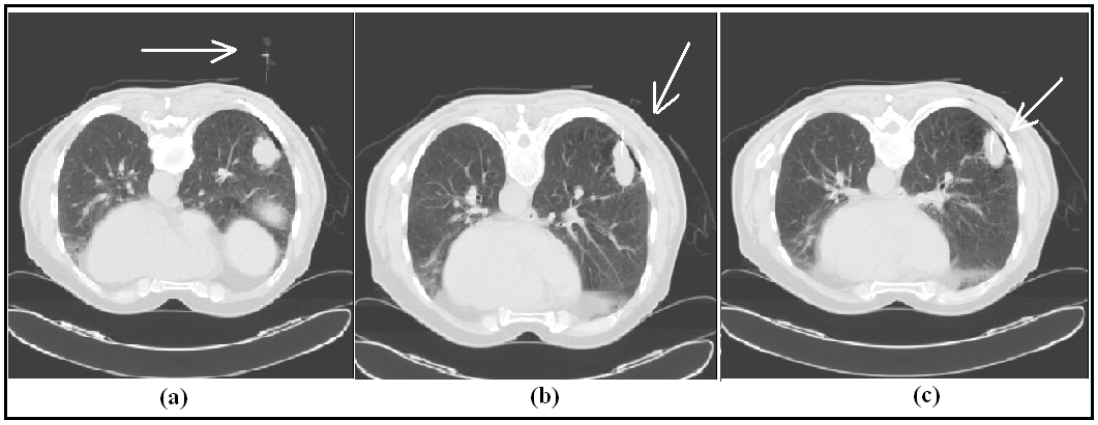
8.2.3. Spiral BT

Spiral tarama ile bir hacimden bilgi toplama yöntemidir. Sistem, X ışığı kaynağı ile dedektörler devamlı dönerken hasta masasının devamlı ileri doğru hareketine dayanır. Bu durum hastanın tek düzlemde değil spiral şekilde taranması sonucunu ortaya çıkarır. Neticede tek nefes tutabilme süresi içinde istenilen

hacimden spiral projeksiyonda devamlı bilgi depolanması mümkün olur. Görüntüler istenilen kesit kalınlığı ve kesit aralığı ile sonradan oluşturulur. Gerçek görüntüyü elde edebilmek için spiral verilerin birleştirilmesine ihtiyaç vardır.

8.3. Akciğer Nodüllerine Biyopsi Uygulaması

Nodüllerin tanısı ve tedavisi amacıyla görüntüleme yöntemlerinin klavuzluğunda kullanılan girişimsel teknikler, vücudun diğer bölümlerinde olduğu gibi göğüs bölgesinde de günümüzde başarı ile uygulanmaktadır. Bu işlemlerden en basit olanı akciğer nodülünün iğne ile aspirasyon (emme) biyopsisidir. Son yıllarda görüntüleme yöntemlerindeki gelişmelere paralel olarak bu alandaki uygulamaların sayısında da önemli oranda artış görülmektedir. Örneğin BT' deki gelişmeler ile birlikte, pek çok girişimsel yöntem akciğer nodüllerinin tanı ve tedavisi amacıyla bu alanda kullanılmaya başlanmıştır. İğne biyopsisi ile malign nodüllerde % 95 oranında tanı alınabilmekte iken, benign nodüllerde bu oran % 70' lere kadar düşmektedir.



Şekil 8.1 26 no.lu hasta için BT klavuzluğunda iğne biyopsisi görüntüsü (a)-(b)-(c)' de yer alan beyaz renkli oklar biyopsi iğnesinin akciğer bölgesine girişini ve nodül içerisinden parça alışına işaret etmektedir.

9. AKCİĞER NODÜLLERİNİN SINIFLANDIRILMASI İÇİN GELİŞTİRİLEN YAPILAR VE UYGULAMALARI

Akciğer kanseri, dünya üzerindeki en ciddi sağlık problemlerinden birisidir. 2004 yılı için yeni teşhis edilmiş akciğer kanseri sayısı 173700, beklenen ölüm sayısı ise 164400 olarak rapor edilmiştir (Spira ve ark. 2004). Fidaner ve ark. tarafından 2001 yılında yapılan çalışma sonuçları akciğer kanserinin erkekler arasında % 38.6 ile bütün kanser türleri arasında birinci sırada olduğu; kadınlar arasında ise % 5.2 ile onbirinci sırada olduğunu belirlemiştir. Edis ve Karlıkaya' nın 2007 yılında yayınladıkları çalışmanın sonuçları ise akciğer kanserinin Türkiye' deki maliyetini ortaya koymuştur. Ortalama sağ kalım süresi 6.8 ay olarak belirlenirken, hasta başına ortalama maliyetin 5480 Amerikan doları ve her bir yaşam yılı için tıbbi maliyeti ortalama 18058 Amerkan doları olduğu ifade edilmiştir. Akciğer kanserinin, diğer kanser türleri arasındaki görülme sıklığının oldukça fazla olduğu ve hastalığın maliyeti düşünüldüğünde, gerek hastalığın teşhisinde gerekse hastalığın tedavi aşamasında uzman doktora ve/veya biyopsi uzmanına karar verme aşamasında destek olabilecek akıllı sistemlere ihtiyaç duyulduğu açıktır.

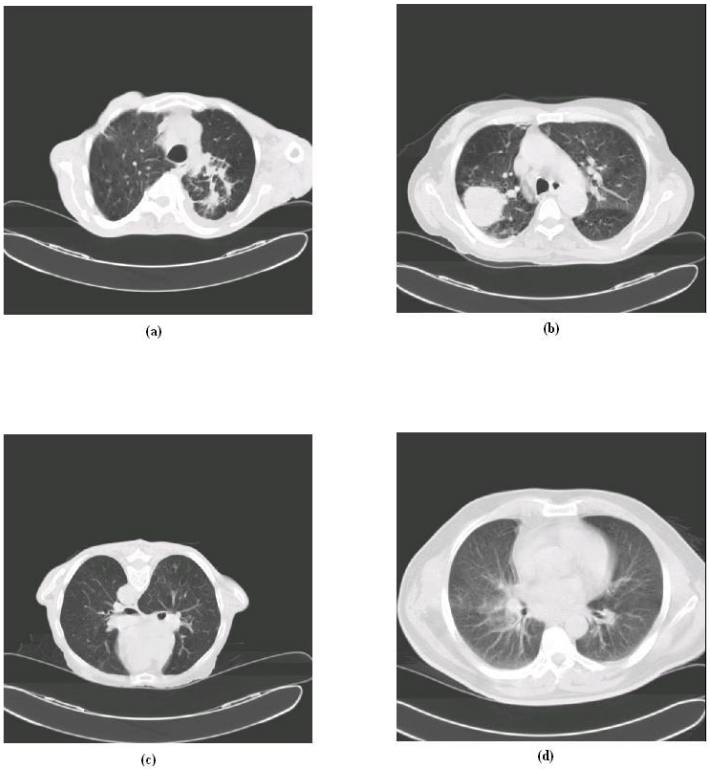
Gerçekleştirilen tez çalışmasında, akciğer kanserinin teşhisine ve yorumlanmasına yardımcı olabilmek amacı ile akciğer bölgesinin segmentasyonunu ve akciğerde bulunan nodüllerin sınıflandırılmasını sağlayan yeni sistemler geliştirilmiştir. Özellikle akciğer nodüllerinin sınıflandırılması aşamasında, benign-malign ayırımında radyologların oldukça zorlandığı ve iğne ile gerçekleştirilen biyopside bile malign nodüllerin %95 oranında tanınmasına karşılık benign nodüllerin ancak % 70 oranında tanınıyor olması önerilen akıllı karar destek sisteminin gerekliliğini ortaya koymaktadır.

9.1. Tez Çalışmasında Kullanılan BT Görüntüleri

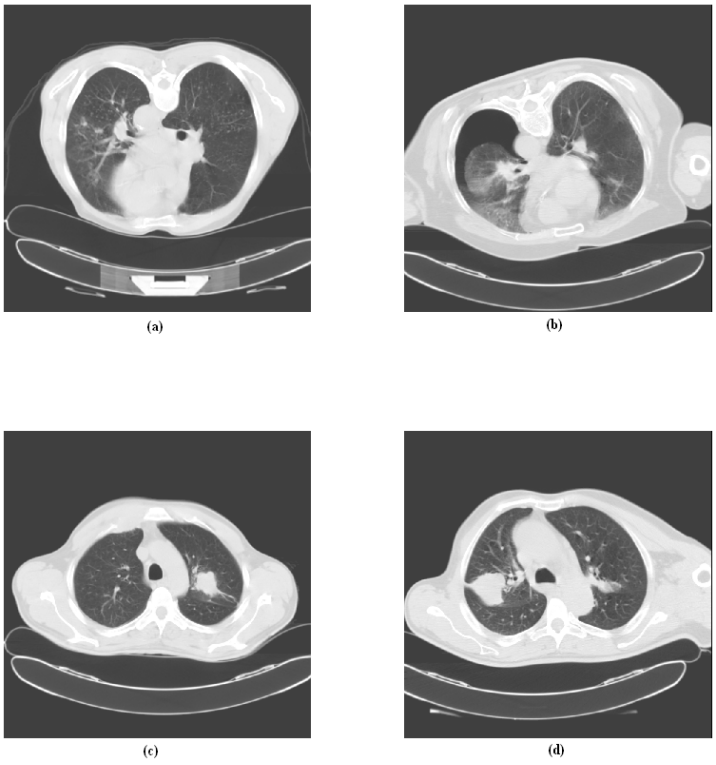
Tez çalışmasında, Başkent Üniversitesi Konya Uygulama ve Araştırma Hastanesi Radyoloji Bölümünden alınan 32 adet BT görüntüsü kullanılmıştır (Görüntülerin alınması için kullanılan Siemens MX-8000 BT cihazına ait resim, ekler bölümünde yer almaktadır). Görüntü koleksiyonu, uzman radyolog doktorun gözetimi altında her bir görüntü kesiti tek tek incelenerek, nodülün bulunduğu BT kesitinin kaydedilmesi ile oluşturulmuştur. Kaydedilen bu görüntülere ait biyopsi sonuçları kullanılarak da görüntülerin doğru bir şekilde etiketlenmesi (benign veya malign) sağlanmıştır.

Elde edilen bu etiketlenmiş veri tabanında yer alan 32 görüntünün 10 tanesi iyi huylu nodül, 22 tanesi ise kötü huylu nodül içermektedir. Görüntüleri alınan hastaların 6 tanesi kadın (2 tanesi iyi huylu nodül, 4 tanesi kötü huylu nodül taşımaktadır); 26 tanesi ise erkektir (8 tanesi iyi huylu nodül, 18 tanesi kötü huylu nodül taşımaktadır). Hastaların yaş dağılımları 52 ile 77 arasında değişmektedir. Yaş ortalaması 64' tür. Hastalara ait BT görüntülerinde yer alan nodüllerin en küçüğünün çapı 15 mm, en büyüğünün çapı ise 130 mm' dir. Ortalama nodül çapı ise 41.28 mm' dir. Görüntüler sayısal ortamda 752x752 pikselden ve gri seviyeden oluşmaktadır.

Tez çalışmasında kullanılan görüntülere ait detaylı bilgiler Çizelge 9.1' de verilmiştir. İlk on sırada yer alan görüntüler benign, daha sonraki 22 görüntü ise malign nodül içermektedir. Görüntü veri tabanı içerisiden rastgele seçilmiş benign ve malign nodüller içeren BT görüntüleri, sırasıyla Şekil 9.1 ve Şekil 9.2' de yer almaktadır.



Şekil 9.1 Benign nodüller içeren BT görüntüleri (a) 1 nolu hastaya ait görüntü (b) 3 nolu hastaya ait görüntü (c) 7 nolu hastaya ait görüntü (b) 8 nolu hastaya ait görüntü



Şekil 9.2 Malign nodüller içeren BT görüntüleri (a) 11 nolu hastaya ait görüntü (b) 22 nolu hastaya ait görüntü (c) 26 nolu hastaya ait görüntü (b) 28 nolu hastaya ait görüntü

Çizelge 9.1. Tezde kullanılan BT görüntülere ait özellikler

Görüntü No	Cinsiyet	Yaş	Nodül Çapı (mm)	Patoloji Bulgusu
1	E	54	100	LEİOMYOM
2	E	78	29	ANTRAKOZİS
3	E	64	18	FİBROZİS ANTRAKOZİS
4	K	61	15	GRANÜLAMATÖZ İNFLAMASON
5	E	68	29	SOLİTER FİBRÖZ NODÜL
6	E	65	20	MİGZOİD KARAKTERLİ BENİNG LEZYON
7	K	64	16	GRANÜLAMATÖZ İNFLAMASON
8	E	60	27	BENİNG
9	E	57	35	FİBROZİS İNFLAMASYON
10	E	65	16	ANTRAKOZİS
11	E	52	130	KÜÇÜK HÜCRELİ KARSİNOM
12	E	53	33	ADENOKARSİNOM
13	E	58	28	KÜÇÜK HÜCRELİ OLMAYAN KARSINOM
14	E	67	67	ADENOKARSİNOM
15	K	75	50	BÜYÜK HÜCRELİ KARSİNOM
16	K	69	40	ADENOKARSİNOM
17	K	55	70	SKUAMÖZ HÜCRELİ KARSİNOM
18	E	56	34	MEZETELYOMA
19	E	77	26	ADENOKARSİNOM
20	E	63	55	KÜÇÜK HÜCRELİ OLMAYAN KARSINOM
21	E	66	19	ADENOKARSİNOM
22	E	68	35	SKUAMÖZ HÜCRELİ KARSİNOM
23	E	52	16	KÜÇÜK HÜCRELİ KARSİNOM
24	E	62	45	SKUAMÖZ HÜCRELİ KARSİNOM
25	E	69	76	KÜÇÜK HÜCRELİ KARSİNOM
26	E	66	70	ADENOKARSİNOM
27	E	67	34	KÜÇÜK HÜCRELİ KARSİNOM
28	E	76	36	ADENOKARSİNOM
29	E	63	41	MALİGNİTE
30	E	73	31	ADENOKARSİNOM
31	K	60	36	ADENOKARSİNOM
32	E	64	44	KÜÇÜK HÜCRELİ KARSİNOM

9.2. Uygulama Sonuçlarının Değerlendirilmesinde Kullanılan Performans Kriterleri

9.2.1. Segmentasyon sonuçlarının değerlendirilmesi

Segmentasyon sonuçlarının değerlendirilmesinde görüntünün tüm pikselleri göz önüne alındığında, bunlara karşılık gelen kaç tane pikselin doğru olarak tanındığının oranı hesaplanmıştır. Tez çalışmasında kullanılan doğruluk ifadesinin matematiksel açıklaması Eşitlik (9.1) ile açıklanmıştır.

$$Doğruluk = \frac{Doğru\ Sınıflanan\ Piksel\ Sayısı}{Görüntüdeki\ Toplam\ Piksel\ Sayısı}\% \quad (9.1)$$

9.2.2 Sınıflama sonuçları için eğitim ve test hatası

YSA kullanılarak gerçekleştirilen sınıflama uygulamalarında doğru olarak sınıflandırılan örüntülerin veri setinde bulunan toplam örüntülere oranı önemli bir değerlendirme kriteri olmakla beraber, YSA çıkışı ile hedef arasındaki hatanın sayısal olarak ifade edilmesi de sınıflayıcı performansının bir bütün olarak değerlendirilmesi anlamında oldukça önemlidir.

Çizelgelerde yer alan eğitim ve test hataları aşağıda yer alan (9.2) eşitliğine göre hesaplanmıştır:

$$\text{Eğitim ve Test Hatası } (\%) = \left(\frac{\sum_{i=1}^{k} |t(i) - a(i)|}{m * n} \right) * 100 \quad (9.2)$$

Burada *t(i)* istenilen çıkış, *a(i)* ise YSA' nın çıkışıdır. *k* eğitim ve test verisindeki örneklerin sayısı,, *m* ise eğitim ve test verisindeki set sayısıdır. *n,* eğitim ve test prosedürü için YSA' nın çıkış sayısıdır (Ozbay ve ark. 2006).

9.2.3. Sınıflayıcı performanslarının değerlendirilmesi

Biyomedikal bilgi sistemleri üzerine uygulanan YSA algoritmaları, aşağıda yer alan ölçümler kullanılarak değerlendirilirler (Kohavi ve Provost 1998):

Doğru Pozitif (DP): Uzman tarafından hasta (malign) olarak etiketlenmiş bir verinin YSA tarafından hasta (malign) olarak sınıflandırılması

Doğru Negatif (DN): Uzman tarafından sağlıklı (benign) olarak etiketlenmiş bir verinin YSA tarafından sağlıklı (benign) olarak sınıflandırılması

Yanlış Pozitif (YP): Uzman tarafından sağlıklı (benign) olarak etiketlenmiş bir verinin YSA tarafından hasta (malign) olarak sınıflandırılması

Yanlış Negatif (YN): Uzman tarafından hasta (malign) olarak etiketlenmiş bir verinin YSA tarafından sağlıklı (benign) olarak sınıflandırılması

Bu ölçümlerden faydalanılarak sınıflayıcı sonuçları ve verilerin etiketlerine uygun olarak gerçek sınıflarının yer aldığı genel gösterim *karmaşıklık matrisi* (Kohavi ve Provost 1998) ile ifade edilebilmektedir. Karmaşıklık matrisi gösterimi Çizelge 9.2' de yer almaktadır:

Çizelge 9.2 Sınıflayıcılar için karmaşıklık matrisi

Verilerin Gerçek Sınıfı	Sınıflayıcının Sonucu	
	Pozitif (Malign)	Negatif (Benign)
Pozitif (Malignn) Etiketli Veri	DP	YP
Negatif (Benign) Etiketli Veri	YN	DN

Sınıflayıcıların, sınıflama performansları ise DP, DN, YP ve YN kriterlerini kullanarak formülize edilen duyarlılık, belirlilik, ortalama belirleme oranı ve doğruluk kavramları ile değerlendirilirler (Şengür 2006). Bu kavramlar:

Duyarlılık : Sınıflayıcının hastalığı belirleyebilme oranıdır.

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \tag{9.3}$$

Belirlilik : Sınıflayıcının sağlıklıyı belirleyebilme oranıdır.

$$\text{Belirlilik} = \frac{DN}{DN + YP} \tag{9.4}$$

Ortalama Belirleme Oranı : Duyarlılık ve belirliliğin ortalamasıdır.

$$\text{Ortalama Belirleme Oranı} = (\text{Duyarlılık}+\text{Belirlilik}) / 2 \tag{9.5}$$

Doğruluk : Testin hasta ve sağlıklıyı toplam belirleme oranıdır.

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + YN + DN} \tag{9.6}$$

Yukarıda verilen kriterlere ek olarak pozitif tahmin değeri ve negatif tahmin değeri kriterleri de sınıflayıcı performansını değerlendirebilmek amacı ile kullanılmaktadır.

Pozitif Tahmin Testi : Pozitif testte bir kişinin hasta olma olasılığı

$$\text{Pozitif Tahmin Testi} = \frac{DP}{DP + YP} \tag{9.7}$$

Negatif Tahmin Testi : Negatif testte bir kişinin sağlıklı olma olasılığı

$$\text{Negatif Tahmin Testi} = \frac{DN}{DN + YN} \tag{9.8}$$

9.3. Akciğer Bölgesinin Segmentasyonu

Bilgisayar destekli teşhis sistemleri kullanılarak gerçekleştirilen nodül tespitindeki ilk ve en önemli adım akciğer bölgesinin segmentasyonunun doğru bir şekilde gerçekleştirilmesidir. Segmentasyon, BT görüntüsünde akciğer ile birlikte yer alan diğer organların, yapıların veya çekim sırasında oluşan bozulmaların ortadan kaldırılabilmesi için, görüntüden sadece akciğer bölgesinin seçilmesi işlemidir. Segmentasyon işleminin yapılmaması ya da başarısız olması, incelenen görüntü üzerindeki bir çok gereksiz detayın işleme katılması ile gerçekte nodül olmayan oluşumların da nodül olarak algılanmasını sağlayarak, nodül belirleme işleminin doğruluktan uzaklaşmasına neden olur.

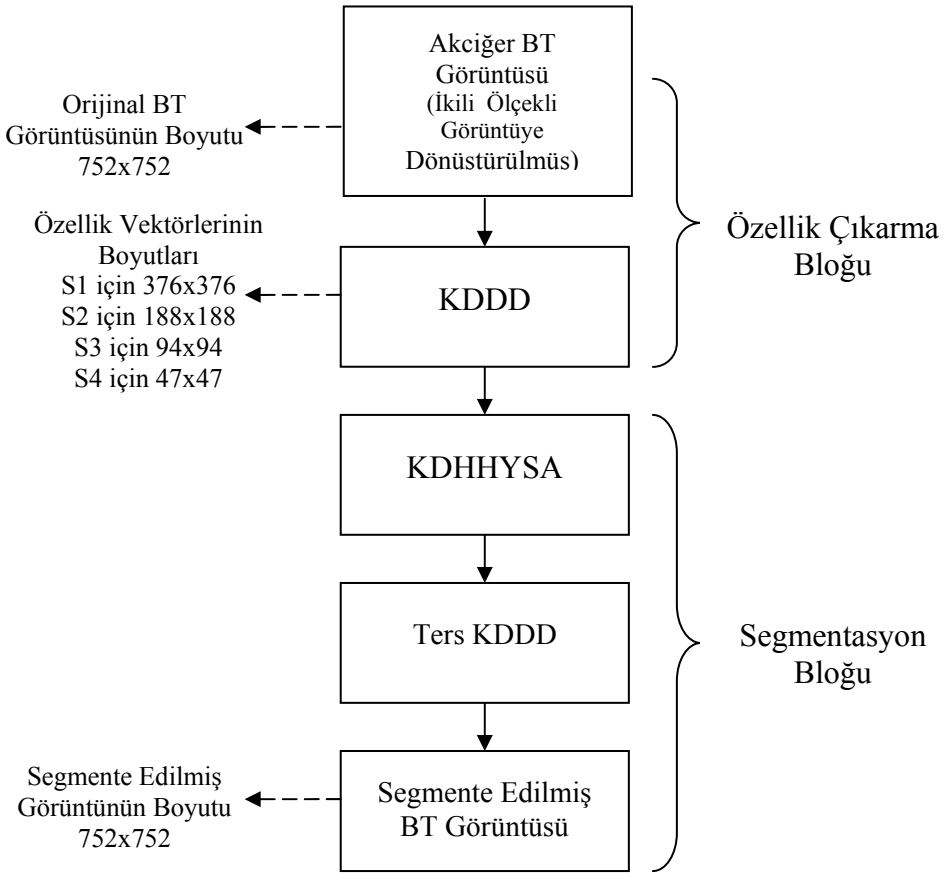
Tez çalışması kapsamında, akciğer bölgesinin segmentasyonu için kompleks değerli dalgacık dönüşümünü ve kompleks değerli hibrit hücresel yapay sinir ağını içeren yeni bir yapı önerilmiştir. Bu yapı ile ilk kez kompleks-değerli bir YSA modelinin biyomedikal görüntü segmentasyonunda kullanımı gerçekleştirilmiştir.

Görüntü işleme uygulamalarında karşılaşılan en büyük güçlüklerden biri, görüntü boyutunun (ya da görüntüyü ifade eden matris boyutunun) büyüklüğüdür. Görüntü boyutlarının büyüklüğü, hem işlem kabiliyetini azaltmakta hem de işlem süresini oldukça arttırmaktadır. Özellikle YSA ile birleştirilen uygulamalarda büyük boyutlu matrisler ile işlem yapmak, YSA modelinde seçilen katman sayılarına ve bu katmanlarda yer alan nöronların sayılarına bağlı olarak işlem yükünü artırmakta ve

hedeflenen sonuca yakınsamayı zorlaştırmaktadır. Bu problemi ortadan kaldırabilmek ve matris boyutlarını küçültebilmek amacı ile özellik çıkartma metotlarına sıklıkla başvurulmaktadır. Bu metotlar arasında en çok kullanılan dalgacık dönüşümüdür. Dalgacık dönüşümleri sinyal işleme uygulamalarında özellik çıkarma elemanı olarak oldukça başarılı olurken, Bölüm-4' te de anlatıldığı gibi, görüntü işleme uygulamalarında giriş değişimlerine karşı duyarsızlık, yön bilgisinde eksiklik ve faz bilgisinin kaybedilmesi gibi üç temel dezavantaja sahiptir. Bu dezavantajları ortadan kaldırabilmek amacı ile Kingsbury tarafından İA-KDD(K) (tezin bundan sonraki kısmında kısaca KDDD olarak ifade edilecektir) ortaya atılmış ve görüntü işleme uygulamalarında kullanılmaya başlanmıştır.

Bu tez çalışmasında 752x752' lik boyuta sahip olan görüntü matrisleri, sahip oldukları gri ölçekli görüntüden ikili ölçekli görüntüye dönüştürüldükten sonra, KDDD kullanılarak 4 farklı seviyeye ayrıştırılmışlardır. Görüntü matrislerinin boyutları birinci seviye (S1) için 376x376, ikinci seviye (S2) için 188x188, üçüncü seviye (S3) için 94x94 ve dördüncü seviye (S4) için de 47x47 olarak elde edilmiştir. KDDD' den geçirildikten sonra boyutu azaltılan ve uygulanan dönüşümün doğası gereği kompleks hale gelen yeni özellik matrisleri (görüntüleri) KDHHYSA kullanılarak segmente edilmişlerdir. KDYSA, yapısı gereği kompleks sayıları (herhangi bir ön-işlem olmaksızın) doğal olarak işleyebilen bir YSA modelidir. HYSA ise matrisel işlemlere izin veren iki boyutlu yapısı ve konvolüsyonu temel alan kolay işlem özellikleri gibi avantajlara sahiptir ve bu sebeple görüntü işleme alanında sıklıkla kullanılmaktadır. Bu iki YSA modeli, hibrit bir yapı içerisinde değerlendirilmişlerdir. Elde edilen çıkış görüntüsünü yeniden orijinal haline getirebilmek amacı ile ters-KDDD alınmış ve giriş görüntüsü ile aynı boyutlara sahip çıkış görüntüsü elde edilmiştir. KDHHYSA' nın A, B ve I parametreleri kompleks değerli geriye yayılım algoritması kullanılarak güncellenmiştir. Bu güncellemeye uygun olarak, elde edilen parametrelerde kompleks değerlidir. Tez çalışmasında kullanılan A ve B parametreleri, literatürde sıklıkla kullanıldığı gibi 3x3' lük matrisler olarak seçilmişlerdir. I parametresinin boyutu ise 1x1' dir.

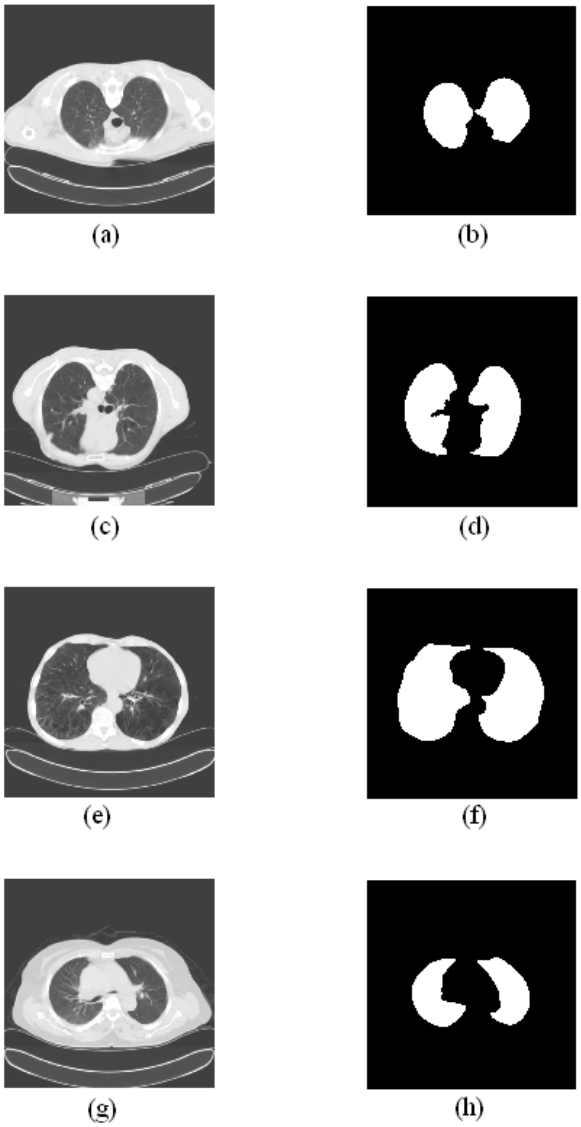
Segmentasyon için önerilen yapıya ait blok diyagramı Şekil 9.3' te verilmiştir.



Şekil 9.3 Segmentasyon için önerilen yapının blok gösterimi

9.3.1 KDDD ve KDHHYSA ile gerçekleştirilen segmentasyon sonuçları

Segmentasyon işlemi için akciğer BT görüntüsüne KDDD uygulanarak görüntü matrisinin boyutları düşürülmüş ve KDHHYSA' ya verilmiştir. Danışmanlı bir yapı olan KDHHYSA' nın eğitimi işlemi için segmentasyon sonucunda ulaşılması hedeflenen görüntüler de verilmiştir. Bu hedef görüntüleri, giriş görüntü setinde yer alan her bir akciğer görüntüsünün tek tek sınırlarının belirlenmesi ve ikili ölçekte kodlanması ile oluşturulmuştur. Gizli düğüm sayısı ile öğrenme oranı değiştirilerek en iyi sonucu elde edebilecek optimum yapı belirlenmiş ve bu optimum yapı ile test işlemine geçilmiştir. Şekil 9.4; KDHHYSA' ya hedef olarak sunulan ve segmente edilmiş akciğer bölgesini temsil eden örnek görüntüleri içermektedir.



Şekil9.4 KDHHYSA' ya segmente edilmesi için sunulan giriş görüntüleri (a-c-e-g) ve bunlara karşılık gelen hedef görüntüleri (b-d-f-h)

Segmentasyon sonuçları Çizelge 9.3-9.6' da detaylı olarak yer almaktadır. Çizelge 9.3, Çizelge 9.4, Çizelge 9.5 ve Çizelge 9.6 sırasıyla birinci seviye KDDD-KDHHYSA (S1-KDHHYSA), ikinci seviye KDDD-KDHHYSA (S2-KDHHYSA), üçüncü seviye KDDD-KDHHYSA (S3-KDHHYSA) ve dördüncü seviye KDDD-KDHHYSA (S4-KDHHYSA) için elde edilen segmentasyon sonuçlarını göstermektedir. Bütün işlemler için maksimum iterasyon sayısı 20 olarak belirlenmiştir. İteratif işlemlerin gerçekleştirildiği bilgisayar 3.0 GHZ' lik bir işlemciye ve 3 GB RAM' e sahiptir.

S1-KDHHYSA için en iyi sonuçlar 0.1 öğrenme oranı ve 10 gizli düğüm için oluşan optimum ağ yapısı ile elde edilmiştir. Çizelge 9.3' ten de görülebileceği gibi toplam 565504 (752x752) piksellik hedef görüntüsü ile elde edilen sonuç görüntüsü piksel piksel karşılaştırılmış ve ortalama 564017 pikselin doğru olarak tanındığı görülmüştür. Piksel bazında gerçekleştirilen tanıma işleminde aşağıdaki algoritma çalıştırılmıştır:

```
        Hedef görüntüdeki her bir pikselin değeri P_H,
        Elde edilen görüntüdeki her bir pikselin değeri P_S
        Sütun Sayısı: süt, Satır Sayısı: sat
süt=1:752
        sat=1:752
                Eğer P_H (sat,süt) - P_S (sat,süt) = 0 ise
           Doğru sınıflanan piksellerin sayısını bir arttır
                   Değilse
        Yanlış sınıflanan piksellerin sayısını bir arttır
```

Doğru olarak tanınan piksellerin toplam piksel sayısına oranı düşünüldüğünde ise ortalama doğruluğun % 99.7371 olarak elde edildiği görülmektedir. Her bir akciğer BT görüntüsünün bu doğruluk ile segmente edilebilmesi için geçen sürenin ortalama 232 saniye olduğu belirlenmiştir. İterasyon sonunda S1-KDHHYSA için elde edilen A, B ve I parametreleri aşağıdaki şekildedir:

$$
\begin{aligned}
A &= \begin{bmatrix} 9.2106 + 2.2408\text{i} & 9.3634 + 2.0925\text{i} & 9.2106 + 2.2408\text{i} \\ 9.3634 + 2.0925\text{i} & 9.3732 + 2.0875\text{i} & 9.3634 + 2.0925\text{i} \\ 9.2106 + 2.2408\text{i} & 9.3634 + 2.0925\text{i} & 9.2106 + 2.2408\text{i} \end{bmatrix} \\
B &= \begin{bmatrix} 9.3550 + 2.0467\text{i} & -0.0110 - 0.0022\text{i} & 9.3550 + 2.0467\text{i} \\ -0.0110 - 0.0022\text{i} & 9.3731 + 2.0878\text{i} & -0.0110 - 0.0022\text{i} \\ 9.3550 + 2.0467\text{i} & -0.0110 - 0.0022\text{i} & 9.3550 + 2.0467\text{i} \end{bmatrix} \\
I &= \begin{bmatrix} 9.3938 + 2.0720\text{i} \end{bmatrix}
\end{aligned}
\tag{9.9}
$$

Çizelge 9.3 S1-KDHHYSA ile gerçekleştirilen segmentasyon sonuçları

Örnek Numarası	Doğru Sınıflanan Piksel Sayısı	Yanlış Sınıflanan Piksel Sayısı	Doğruluk (%)	Süre (saniye)
N1	564040	1464	99.7411	215.3256
N2	564172	1332	99.7645	212.9129
N3	564042	1462	99.7415	220.7148
N4	564119	1385	99.7551	263.0837
N5	564178	1326	99.7655	265.3181
N6	563906	1598	99.7174	264.5059
N7	564136	1368	99.7581	261.9278
N8	563829	1675	99.7038	264.9748
N9	564192	1312	99.7680	265.0136
N10	564449	1055	99.8134	220.8364
H1	563827	1677	99.7035	212.1877
H2	563978	1526	99.7302	212.2433
H3	564079	1425	99.7480	212.2304
H4	563836	1668	99.7050	210.0329
H5	564234	1270	99.7754	263.3644
H6	564278	1226	99.7832	264.0565
H7	564043	1461	99.7416	262.7487
H8	563996	1508	99.7333	264.6121
H9	564171	1333	99.7643	262.9199
H10	563725	1779	99.6854	260.6978
H11	563732	1772	99.6867	212.8905
H12	564069	1435	99.7462	212.0974
H13	563924	1580	99.7206	214.2817
H14	564014	1490	99.7365	213.0144
H15	563757	1747	99.6911	214.4817
H16	564309	1195	99.7887	211.5229
H17	563964	1540	99.7277	213.3588
H18	564080	1424	99.7482	212.1243
H19	563746	1758	99.6891	213.2460
H20	563853	1651	99.7080	213.8963
H21	563880	1624	99.7128	213.7767
H22	564000	1504	99.7340	212.6941
ORTALAMA	564017	1487	99.7371	232.4091

İkinci seviye (S2) KDDD için 188x188’ lik boyuta indirgenen BT görüntülerinin segmentasyonunda elde edilen sonuçlar Çizelge 9.4’ te verilmiştir. S2-KDHHYSA için elde edilen optimum yapı 2 gizli düğüm ve 0.00001 öğrenme oranına sahiptir. Bu yapı ile elde edilen ortalama doğruluk yaklaşık olarak % 99.71 ile S1-KDHHYSA yapısından % 0.02’ lik bir farkla kötü olarak gözükmesine rağmen her bir BT görüntüsü için harcanan segmentasyon zamanındaki yaklaşık % 65’ lik iyileştirme oldukça önemlidir.

Çizelge 9.4 S2-KDHHYSA ile gerçekleştirilen segmentasyon sonuçları

Örnek Numarası	Doğru Sınıflanan Piksel Sayısı	Yanlış Sınıflanan Piksel Sayısı	Doğruluk (%)	Süre (saniye)
N1	563541	1963	99.6529	83.0721
N2	563955	1549	99.7261	83.5164
N3	563874	1630	99.7118	83.6576
N4	563942	1562	99.7238	70.1320
N5	564039	1465	99.7409	82.8927
N6	563700	1804	99.6810	85.7426
N7	563927	1577	99.7211	82.6857
N8	563641	1863	99.6706	82.6503
N9	564070	1434	99.7464	82.7470
N10	564405	1099	99.8057	80.9976
H1	563633	1871	99.6691	82.9659
H2	563838	1666	99.7054	83.6257
H3	563897	1607	99.7158	83.2197
H4	563678	1826	99.6771	86.1657
H5	564122	1382	99.7556	82.8474
H6	564185	1319	99.7668	82.7668
H7	563887	1617	99.7141	83.3288
H8	563905	1599	99.7172	82.9014
H9	564032	1472	99.7397	77.5411
H10	563588	1916	99.6612	82.4276
H11	563596	1908	99.6626	78.0101
H12	563920	1584	99.7199	82.4242
H13	563749	1755	99.6897	82.9218
H14	563886	1618	99.7139	67.0411
H15	563593	1911	99.6621	83.4817
H16	564202	1302	99.7698	60.6080
H17	563766	1738	99.6927	82.8371
H18	563947	1557	99.7247	84.0247
H19	563543	1961	99.6532	66.6503
H20	563665	1839	99.6748	73.9707
H21	563682	1822	99.6778	84.1142
H22	563895	1609	99.7155	83.2762
ORTALAMA	563853	1651	99.7080	80.4764

İterasyon sonunda S2-KDHHYSA için elde edilen A, B ve I parametreleri aşağıda verilmiştir:

$$A = \begin{bmatrix} -0.4868 - 0.2258i & 1.6039 - 0.2475i & -0.4868 - 0.2258i \\ 1.6039 - 0.2475i & -0.6479 + 0.1827i & 1.6039 - 0.2475i \\ -0.4868 - 0.2258i & 1.6039 - 0.2475i & -0.4868 - 0.2258i \end{bmatrix}$$
$$B = \begin{bmatrix} 1.0776 + 0.1951i & 1.3041 - 0.2574i & 1.0776 + 0.1951i \\ 1.3041 - 0.2574i & -0.0703 - 0.3780i & 1.3041 - 0.2574i \\ 1.0776 + 0.1951i & 1.3041 - 0.2574i & 1.0776 + 0.1951i \end{bmatrix} \quad (9.10)$$
$$I = \begin{bmatrix} 0.6924 + 2.6640i \end{bmatrix}$$

Üçüncü seviye (S3) ve dördüncü seviye (S4) KDDD ile elde edilen yapılar için bulunan optimum ağ yapıları S2-KDHHYSA ile aynıdır. Çizelge 9.5 ve Çizelge 9.6, sırasıyla, S3-KDHHYSA ve S4-KDHHYSA kullanılarak elde edilen segmentasyon sonuçlarını içermektedir. S3-KDHHYSA için iterasyon sonunda elde edilen parametre değerleri aşağıda yer almaktadır:

$$A = \begin{bmatrix} 0.2273 - 0.6214i & -0.4264 + 0.6152i & 0.2273 - 0.6214i \\ -0.4264 + 0.6152i & -0.7104 + 0.8597i & -0.4264 + 0.6152i \\ 0.2273 - 0.6214i & -0.4264 + 0.6152i & 0.2273 - 0.6214i \end{bmatrix}$$
$$B = \begin{bmatrix} 0.8567 - 1.0295i & -1.1985 - 0.8261i & 0.8567 - 1.0295i \\ -1.1985 - 0.8261i & 0.6420 + 1.0659i & -1.1985 - 0.8261i \\ 0.8567 - 1.0295i & -1.1985 - 0.8261i & 0.8567 - 1.0295i \end{bmatrix} \quad (9.11)$$
$$I = \begin{bmatrix} -0.7255 + 0.0984i \end{bmatrix}$$

S4-KDHHYSA için iterasyon sonunda elde edilen parametre değerleri ise:

$$A = \begin{bmatrix} -0.4630 + 0.9666i & 0.7323 + 0.5668i & -0.4630 + 0.9666i \\ 0.7323 + 0.5668i & -2.4222 + 0.3944i & 0.7323 + 0.5668i \\ -0.4630 + 0.9666i & 0.7323 + 0.5668i & -0.4630 + 0.9666i \end{bmatrix}$$
$$B = \begin{bmatrix} 0.1110 - 1.2466i & 0.1144 - 1.6917i & 0.1110 - 1.2466i \\ 0.1144 - 1.6917i & 0.0173 - 0.1041i & 0.1144 - 1.6917i \\ 0.1110 - 1.2466i & 0.1144 - 1.6917i & 0.1110 - 1.2466i \end{bmatrix} \quad (9.12)$$
$$I = \begin{bmatrix} -0.1357 - 0.8839i \end{bmatrix}$$

şeklindedir.

Segmentasyon için önerilen dört yapı ile elde edilen sonuçlar incelendiğinde en düşük tanıma oranının % 99.6637 ile S4-KDHHYSA' ya ait olduğu ancak bu sonucun en yüksek tanıma oranına sahip S1-KDHHYSA' nın % 99.7371' lik oranından sadece % 0.07' lik farkla kötü olduğu, diğer bir deyişle toplam 565504 piksellik bir görüntü içerisinde sadece 415 pikselin S1-KDHHYSA yapısına göre tanınamadığı belirlenmiştir. Ancak her bir görüntü için gereken işlem süreleri karşılaştırıldığında 376x376 boyutundaki matrisler yerine 47x47 boyutundaki matrisler ile işlem yapan S4-KDHHYSA yapısının sadece ortalama 22.3714 saniyeye ihtiyaç duyduğu görülmüştür. Bu iki yapının harcadığı sürelerin somut bir şekilde karşılaştırılması yapıldığında, S1-KDHHYSA bir BT görüntüsü üzerinde çalışma gerçekleştirirken S4-KDHHYSA yapısı ile 10 BT görüntüsünün sonuçlarına ulaşılmış olacağı açıktır. Önerilen dört yapı ile elde edilen sonuçların özet bir değerlendirmesi Bölüm 11' de yer almaktadır.

Çizelge 9.5 S3-KDHHYSA ile gerçekleştirilen segmentasyon sonuçları

Örnek Numarası	Doğru Sınıflanan Piksel Sayısı	Yanlış Sınıflanan Piksel Sayısı	Doğruluk (%)	Süre (saniye)
N1	562808	2696	99.5233	52.5947
N2	564024	1480	99.7383	50.6859
N3	564005	1499	99.7349	51.0255
N4	564044	1460	99.7418	51.5668
N5	564123	1381	99.7558	50.5467
N6	563815	1689	99.7013	50.8615
N7	564076	1428	99.7475	49.8026
N8	563771	1733	99.6935	51.2499
N9	564095	1409	99.7508	50.1118
N10	564385	1119	99.8021	50.6333
H1	563710	1794	99.6828	51.2091
H2	563815	1689	99.7013	50.4899
H3	563905	1599	99.7172	50.1702
H4	563683	1821	99.6780	51.8032
H5	564120	1384	99.7553	51.2026
H6	564270	1234	99.7818	51.9933
H7	563958	1546	99.7266	51.2561
H8	563926	1578	99.7210	51.1991
H9	564039	1465	99.7409	51.4720
H10	563562	1942	99.6566	51.6377
H11	563564	1940	99.6569	51.3095
H12	563935	1569	99.7225	37.3896
H13	563696	1808	99.6803	39.9377
H14	563958	1546	99.7266	39.9669
H15	563684	1820	99.6782	40.0419
H16	564229	1275	99.7745	39.5866
H17	563774	1730	99.6941	39.5751
H18	563932	1572	99.7220	39.7382
H19	563587	1917	99.6610	39.6138
H20	563605	1899	99.6642	40.0019
H21	563668	1836	99.6753	39.9028
H22	563815	1689	99.7013	39.6792
ORTALAMA	563862	1642	99.7096	47.1330

Çizelge 9.6 S4-KDHHYSA ile gerçekleştirilen segmentasyon sonuçları

Örnek Numarası	Doğru Sınıflanan Piksel Sayısı	Yanlış Sınıflanan Piksel Sayısı	Doğruluk (%)	Süre (saniye)
N1	561200	4304	99.2389	24.4384
N2	563757	1747	99.6911	20.5193
N3	563827	1677	99.7035	23.4793
N4	563792	1712	99.6973	23.5013
N5	563952	1552	99.7256	23.4714
N6	563427	2077	99.6327	23.5927
N7	563726	1778	99.6856	23.1789
N8	563516	1988	99.6485	23.4904
N9	563819	1685	99.7020	23.4865
N10	564169	1335	99.7639	23.4791
H1	563428	2076	99.6329	23.1243
H2	563442	2062	99.6354	23.5159
H3	563612	1892	99.6654	23.6523
H4	563353	2151	99.6196	23.5419
H5	564012	1492	99.7362	15.4126
H6	563987	1517	99.7317	15.4934
H7	563840	1664	99.7057	23.5608
H8	563591	1913	99.6617	23.5630
H9	563800	1704	99.6987	23.4973
H10	563432	2072	99.6336	23.5066
H11	563455	2049	99.6377	23.3404
H12	563703	1801	99.6815	21.6588
H13	563531	1973	99.6511	23.4832
H14	563610	1894	99.6651	20.4625
H15	563582	1922	99.6601	23.4935
H16	564073	1431	99.7470	21.1802
H17	563790	1714	99.6969	17.5395
H18	563675	1829	99.6766	23.5004
H19	563370	2134	99.6226	21.6375
H20	563643	1861	99.6709	23.5987
H21	563519	1985	99.6490	22.3000
H22	563632	1872	99.6690	22.1837
ORTALAMA	563602	1902	99.6637	22.3714

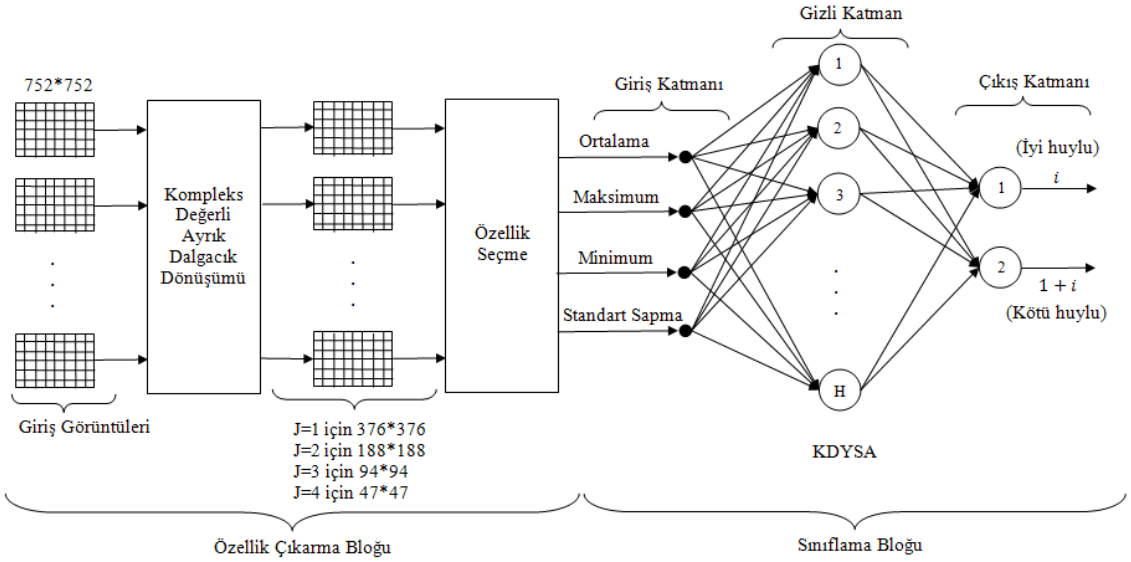
9.4. Akciğer Nodüllerinin Sınıflandırılması

Akciğer kanserine sebep olan kötü huylu nodüllerin tespit edilmesi ve iyi huylu nodüllerden ayrılabilmesi için akciğer BT görüntüleri kullanılmaktadır. BT görüntülerini değerlendiren radyologların karmaşık akciğer yapısı, çevreleyen yapıların çok sayıda olması, dokuların iç içe geçmesi, nodüllerin birbirine benzeyen

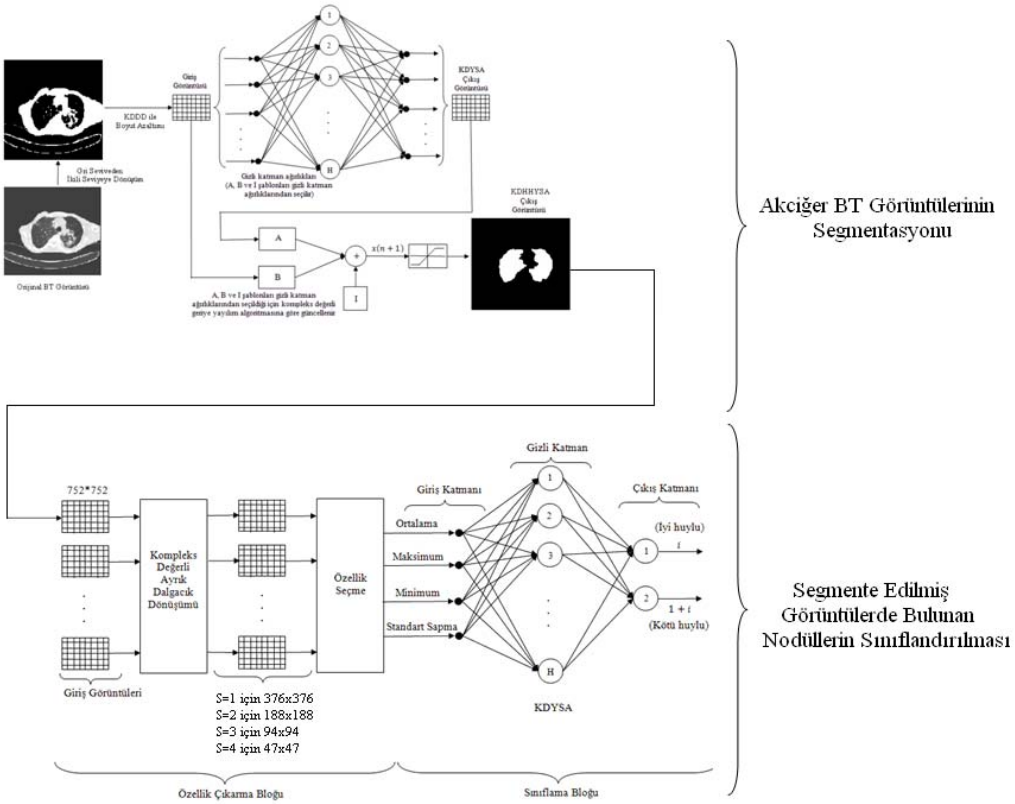
şekillere sahip olması ve insan faktörü gibi etkenler yüzünden karar verme aşamasında zorluklar yaşamaları bilgisayar-destekli teşhis (BDT) sistemlerinin kullanımını gerekli hale getirmiştir. Mevcut BDT sistemleri ile genellikle nodül tespitinin yapılıyor olması ve nodül sınıflama işleminin gerçekleştirilememesi, bu tez çalışması kapsamında yeni bir yapay zeka tabanlı karar destek sisteminin ortaya atılması fikrine öncülük etmiştir.

Gerçekleştirilen tez çalışmasında, radyolog tarafından gözlemlenebilen ve sonrasında biyopsi işlemine tabi tutulacak olan akciğer nodüllerinin (iğne biyopsisinde malign nodüllerin % 95'i, benign nodüllerin % 70' i sınıflandırılabilmektedir) bu işlemlerden önce sınıflandırılması ve benign/malign ayrımlarının yapılması hedeflenmiştir. Böylece hem radyolojik değerlendirmeye hem de biyopsi değerlendirmesine yardımcı olacak bir sistem önerilmiştir.

Tez çalışmasında, literatürde ilk kez, KDDD ile akciğer nodülllerinden özellik vektörleri çıkartılmış ve elde edilen bu özellik vektörleri KDYSA ile sınıflandırılmıştır. Görüntüler öncelikle KDDD ile dört farklı seviyeye ayrıştırılmıştır. Birinci seviye (S1), ikinci seviye (S2), üçüncü seviye (S3) ve dördüncü seviye (S4) dönüşümleri ile 752x752' lik görüntü matrislerinin boyutları sırası ile 376x376, 188x188, 94x94, 47x47' ye düşürülmüştür. Alt seviyelere ayrıştırılan görüntülerin dört istatistik özelliği (en büyük değer, en küçük değer, standart sapma ve ortalama) hesaplanarak her bir görüntü için yeni bir özellik vektörü oluşturulmuştur. Hem KDDD' den elde edilen azaltılmış görüntü matrislerinin hem de bu matrislerden çıkartılan özelliklerden oluşan özellik vektörlerinin kompleks değerli olması sınıflayıcının da kompleks değerli olması gereğini ortaya koymuştur. Bu amaçla sınıflama işlemi, girişleri, ağırlıkları ve çıkışları kompleks değerli sayılardan oluşan bir YSA modeli olarak ifade edilebilen KDYSA kullanılarak gerçekleştirilmiştir. Böylece akciğer nodüllerinin sınıflandırılması alanında yapılmış sınırlı sayıdaki çalışmaya KDYSA ile yapılmış ilk çalışma olma özelliği ile katkıda bulunulmuştur. Önerilen yapıya ait blok gösterim ve segmentasyon ile sınıflama bloklarını içeren sisteme ait blok gösterim, sırasıyla Şekil 9.5 ve Şekil 9.6' da yer almaktadır.



Şekil 9.5 Akciğer nodüllerinin sınıflandırılması için önerilen yapı



Şekil 9.6 Segmentasyon ve sınıflama bloklarından oluşan tüm sistem

Gerçekleştirilen çalışmada 32 hastaya ait BT görüntüleri kullanılmıştır. Kullanılan görüntülerden 10 tanesi benign nodüller içermekte, 22 tanesi ise malign nodüller içermektedir.

Sınıflama işleminin doğruluğunu onaylayabilmek ve önerilen ağın genelleştirme kabiliyetini test edebilmek amacı ile 10 kat çapraz-geçerlilik testi uygulanmıştır. Bu teste göre tüm veri seti 10 eşit veri setine ayrılmakta ve ağın eğitim işlemi için bu 10 setten 9'u kullanılırken, geriye kalan 1 set ile ağ test edilmektedir. Test işlemi bittiğinde bu kez testte kullanılan set eğitim kümesine dahil edilirken eğitim kümesinden bir set de test kümesine alınmaktadır. Bu işlem 10 kez tekrarlandığında veri setinde bulunan tüm veriler ile ağın hem eğitilmesi hem de test edilmesi sağlanmaktadır. Belirtilen bu test prosedürüne uygun olarak, kullanılan veri setindeki 10 benign nodüle sahip görüntüden 1 tanesi, 22 malign nodüle sahip görüntüden ise 2 tanesi test setini oluşturmak için ayrılmıştır. Böylece ağ, 9 benign ve 20 malign nodül ile eğitilirken, 1 benign ve 2 malign nodül ile test edilmiştir. Bu eğitim ve test işlemi 10 kez tekrarlanmıştır. Ağın eğitme işlemi sırasında gizli düğüm sayıları ve öğrenme oranları değiştirilerek en yüksek sınıflama oranının elde edildiği optimum ağ yapısına öğrenme oranı 1, gizli düğüm sayısı 50 alındığında ulaşılmıştır. Maksimum iterasyon sayısı 1000 olarak belirlenmiştir.

KDYSA çıkışında benign nodüller 'i', malignler ise '1+i' olarak kodlanmışlardır. Doğru sınıflanan veri sayısını belirleyebilmek amacı ile aşağıda yer alan algoritma kullanılmıştır:

Benign Sınıflandırması

Eğer

KDYSA çıkışının reel kısmı $0 \le R_B \le 0.5$

ve

KDYSA çıkışının imajiner kısmı $0.5 < I_B \le 1$

ise

Benign için doğru sınıflananların sayısını 1 arttır

değilse

Benign için yanlış sınıflananların sayısını 1 arttır

Malign Sınıflandırması

Eğer

KDYSA çıkışının reel kısmı $0.5 < R_M \leq 1$

ve

KDYSA çıkışının imajiner kısmı $0.5 < I_M \leq 1$

ise

Malign için doğru sınıflananların sayısını 1 arttır

değilse

Malign için yanlış sınıflananların sayısını 1 arttır

S1, S2, S3 ve S4 için KDDD-KDYSA yapısı kullanılarak elde edilen sınıflama sonuçları Çizelge 9.7, Çizelge 9.8, Çizelge 9.9 ve Çizelge 9.10' da verilmiştir. Çizelgelerde 10 kat çapraz geçerlilik prosedürüne uygun olarak, her bir geçerlilik seti için eğitim ve test sınıflama sonuçları ve hata değerleri ile işlem süreleri yer almaktadır. Sınıflama sonuçlarının yer aldığı sütunlar BB+BM / MM+MB olarak ifade edilmiştir. Burada: BB, benign olup benign olarak sınıflananları; BM, benign olup malign olarak sınıflananları; MM, malign olup malign olarak sınıflananları; MB ise malign olup benign olarak sınıflananları göstermektedir. Bu tanımlama göz önünde tutularak sözü edilen çizelgeler incelendiğinde tüm seviyeler (1, 2, 3 ve 4) için KDDD alınıp sınıflama işlemi için KDYSA kullanıldığında malign olarak etiketlenmiş yirmi görüntünün tamamının malign olarak sınıflandığı görülmektedir. Ancak benign görüntüler için sınıflama sonuçları incelendiğinde ikinci ve üçüncü seviye KDDD kullanılan yapı için on benign görüntünün sadece dördünün benign olarak tanındığı geriye kalan altı tanesinin ise malign olarak tanındığı görülmektedir.

Birinci seviye KDDD kullanan yapıda ise on benign görüntünün beşi benign olarak sınıflandırılmıştır. Önerilen yapılar arasındaki en iyi çözüm dördüncü seviyeden KDDD ve KDYSA yapısı ile elde edilmiştir. Bu yapı ile on benign görüntünün dokuzu benign olarak sınıflandırılırken sadece bir görüntü için malign olarak karar verilmiştir. Tüm bu tanıma işlemleri ortalama olarak 17 saniye gibi kısa bir sürede sonuçlandırılmıştır.

En kötü sınıflama sonucu elde edilen S2 KDDD-KDYSA yapısı ile en iyi sınıflama sonucunun elde edildiği S4 KDDD-KDYSA yapısı için ağa sunulan hedefler ile ağın elde ettiği sonuçlar Çizelge 9.11' de verilmiştir. Bu çizelgede her iki yapı tarafından da test veri setinin doğru olarak sınıfladığı 2. geçerlilik setleri ile yine her iki yapı tarafından da benign görüntülerin yanlış sınıflandığı 9. geçerlilik setleri örnek olarak verilmiştir. Çizelge 9.11 incelendiğinde, sınıflama sonuçları aynı olmasına rağmen S2 KDDD-KDYSA yapısı ile S4 KDDD-KDYSA yapısının aynı hedefe ulaşmak için ürettikleri çıkışların sayısal olarak birbirlerinden farklı oldukları görülmektedir. Bu farklar Çizelge 9.8 ve 9.10' daki 2. ve 9. geçerlilik setleri için elde edilen eğitim ve test hatalarındaki sayısal farklılıkları ortaya koymaktadır. Örneğin, çizelge 9.11' de de görülebileceği gibi, test işleminde, 2. geçerlilik seti için sağlıklı (benign) nodülü ifade eden hedef değeri olan "0+i" için S4 KDDD-KDYSA yapısı "0+i" çıkışını elde ederek, hedefi bire bir yakınsamıştır. Ancak S2 KDDD-KDYSA yapısı elde ettiği "0.020+0.9997i" çıkışı ile, doğru sınıflama kriterlerine uygun olarak sağlıklı görüntüyü sağlıklı olarak sınıflasa bile hedefe yakınsaması S4 KDDD-KDYSA yapısına göre kötü olduğu için daha yüksek bir test hatasına sahiptir.

Tüm bu ifadeler elde edilen sonuçlar için genelleştirildiğinde, tanımlanan kompleks-değerli sınıflama algoritmasına göre sınıflama sonuçlarının eşit olarak elde edilmesine rağmen ağ sonuçlarının hedefe yakınsamasındaki farklılığına uygun olarak farklı test hatalarının elde edileceği şeklindedir.

Çizelge 9.7 S1 KDDD-KDYSA İçin Nodül Sınıflama Sonuçları

Geçerlilik Seti	Eğitim Sınıflama Sonucu BB+BM / MM+MB	Test Sınıflama Sonucu BB+BM / MM+MB	Eğitim Hatası (%)	Test Hatası (%)	Süre (saniye)
1	8+1 / 19+1	0+1 / 2+0	3.6073	32.1814	13.9241
2	8+1 / 19+1	1+0 / 2+0	3.7271	3.3997	14.4232
3	8+1 / 19+1	1+0 / 2+0	3.7266	5.2265	13.9729
4	8+1 / 19+1	1+0 / 2+0	3.7305	0.0034	19.6391
5	8+1 / 19+1	0+1 / 2+0	3.2053	36.5098	17.5005
6	8+1 / 19+1	0+1 / 2+0	3.4183	31.3644	13.8620
7	8+1 / 19+1	0+1 / 2+0	3.7630	26.7625	14.9591
8	8+1 / 19+1	0+1 / 2+0	3.7602	26.7548	16.8341
9	8+1 / 19+1	1+0 / 2+0	4.1466	7.7294	14.3811
10	8+1 / 19+1	1+0 / 2+0	3.6798	0.0034	14.3432
ORTALAMA		5+5 / 20+0	3.6765	16.9935	15.3839

Çizelge 9.8 S2 KDDD-KDYSA İçin Nodül Sınıflama Sonuçları

Geçerlilik Seti	Eğitim Sınıflama Sonucu BB+BM / MM+MB	Test Sınıflama Sonucu BB+BM / MM+MB	Eğitim Hatası (%)	Test Hatası (%)	Süre (saniye)
1	8+1 / 19+1	0+1 / 2+0	3.1867	32.9009	14.4336
2	8+1 / 19+1	1+0 / 2+0	3.3237	0.7346	14.0457
3	8+1 / 19+1	0+1 / 2+0	3.3936	27.8539	14.4042
4	8+1 / 19+1	1+0 / 2+0	3.4704	0.0277	14.7396
5	8+1 / 19+1	1+0 / 2+0	3.4837	10.7932	13.8478
6	8+1 / 19+1	0+1 / 2+0	2.8513	33.9053	14.0850
7	8+1 / 19+1	0+1 / 2+0	3.4649	30.6500	13.9220
8	8+1 / 19+1	0+1 / 2+0	3.4416	30.6806	13.9814
9	8+1 / 19+1	0+1 / 2+0	3.9407	19.6297	14.4477
10	9+0 / 19+1	1+0 / 2+0	3.3714	0.5280	14.4295
ORTALAMA		4+6 / 20+0	3.3928	18.7704	14.2337

Çizelge 9.9 S3 KDDD-KDYSA İçin Nodül Sınıflama Sonuçları

Geçerlilik Seti	Eğitim Sınıflama Sonucu BB+BM / MM+MB	Test Sınıflama Sonucu BB+BM / MM+MB	Eğitim Hatası (%)	Test Hatası (%)	Süre (saniye)
1	9+0 / 19+1	0+1 / 2+0	2.1579	33.2149	13.8171
2	9+0 / 19+1	1+0 / 2+0	2.3770	0.6238	18.9966
3	8+1 / 19+1	0+1 / 2+0	3.4459	32.6682	15.9174
4	8+1 / 19+1	1+0 / 2+0	3.7310	5.6656	15.3538
5	8+1 / 19+1	1+0 / 2+0	3.5834	14.3105	14.8529
6	8+1 / 19+1	0+1 / 2+0	3.8658	29.6265	16.0744
7	8+1 / 19+1	0+1 / 2+0	3.6674	31.3455	15.9818
8	8+1 / 19+1	0+1 / 2+0	3.4030	31.2264	15.5021
9	8+1 / 19+1	0+1 / 2+0	4.1212	30.5314	16.2805
10	8+1 / 19+1	1+0 / 2+0	4.8816	5.5506	15.7419
ORTALAMA		4+6 / 20+0	3.5234	21.4763	21.4778

Çizelge 9.10 S4 KDDD-KDYSA İçin Nodül Sınıflama Sonuçları

Geçerlilik Seti	Eğitim Sınıflama Sonucu BB+BM / MM+MB	Test Sınıflama Sonucu BB+BM / MM+MB	Eğitim Hatası (%)	Test Hatası (%)	Süre (saniye)
1	9+0 / 20+0	1+0 / 2+0	0.0509	0.1458	16.0446
2	9+0 / 20+0	1+0 / 2+0	0.0199	0.0837	15.9000
3	9+0 / 20+0	1+0 / 2+0	0.1453	0.0657	16.1385
4	9+0 / 20+0	1+0 / 2+0	0.0381	8.0586e-004	16.0578
5	9+0 / 20+0	1+0 / 2+0	0.1626	0.4728	16.2670
6	9+0 / 20+0	1+0 / 2+0	0.0282	0.7348	18.2192
7	8+1 / 20+0	1+0 / 2+0	3.6103	0.2710	21.7408
8	9+0 / 20+0	1+0 / 2+0	0.0421	0.0555	16.4409
9	9+0 / 20+0	0+1 / 2+0	0.4249	31.5303	16.4081
10	9+0 / 20+0	1+0 / 2+0	0.1030	0.0026	16.4731
ORTALAMA		9+1 / 20+0	0.4625	3.3363	16.969

Çizelge 9.11 S2 KDDD-KDYSA - S4 KDDD-KDYSA Yapıları ile 2. Ve 9. Geçerlilik Setleri için Elde Edilen Test Sonuçları ve Hedefler

HEDEF	Ağın Elde Ettiği Sonuçlar			
	2. Geçerlilik Seti		9. Geçerlilik Seti	
	S4 KDDD-KDYSA	S2 KDDD-KDYSA	S4 KDDD-KDYSA	S2 KDDD-KDYSA
0 + i (B)	0.0000 + 1.0000i	0.0220 + 0.9997i	0.9459 + 1.0000i	0.5889 + 0.9999i
1 + i (M)	0.9975 + 1.0000i	0.9991 + 1.0000i	0.9999 + 1.0000i	0.9999 + 1.0000i
1 + i (M)	1.0000 + 1.0000i	0.9992 + 1.0000i	1.0000 + 1.0000i	1.0000 + 0.9999i

B: Benign; M: Malign

10. TARTIŞMA

Kalp-damar hastalıklarından sonra en fazla görülen hastalık olan kanserin, en sık görülen türü akciğer kanseridir. Akciğer kanserinin erken teşhisi, hastanın yaşamını sürdürebilmesi için en önemli olgudur. Akciğer kanserine sebep olan malign nodüllerin teşhisi (ya da benign nodüllerden ayırılması) için radyologlara yardımcı olabilmek amacı ile bazı BDT sistemlerinin kullanıldığı bilinmektedir. Hastanelerde kullanılan BT cihazları ile birlikte üretici firmalar tarafından sunulan BDT sistemlerinin radyologların karar verme süreçlerine destek verdiği ancak bu sistemler kullanılarak elde edilen sonuçların istenilen doğruluğa her zaman ulaşamadığı literatürde ifade edilmektedir (Yuan ve ark. 2006, Das ve ark. 2006). Mevcut BDT sistemlerindeki yetersizlik, akıllı BDT sistemlerine duyulan ihtiyacı artırarak yeni çalışmalara yön vermiştir. Bu çalışmalar yapay zeka teknikleri kullanarak akciğer bölgesinin göğüs bölgesi BT görüntüsü içerisinden çıkartılması (segmentasyon) ve akciğer nodüllerinin tespit edilmesi gibi birbirini tamamlayan iki işlem bloğundan oluşan yeni akıllı BDT sistemleri üzerine şekillendirilmiştir.

Tez çalışmasında, segmentasyon işlemini en yüksek doğruluk ile en kısa sürede tamamlayabilecek yeni bir akıllı sistem tasarlanmıştır. Bu çalışmaya ek olarak, literatürde sadece nodüllerin yerini belirlemek üzere yoğunlaşan BDT sistemlerinin yerine radyologların ve biyopsi uzmanlarının ihtiyaçlarına yönelik olarak benign ve malign nodülleri sınıflayan bir akıllı karar destek sistemi önerilmiştir. Bu sistem, yüksek doğruluk ile nodülleri sınıflarken, radyoloğun akciğer BT'si üzerinde yaptığı incelemede karşılaştığı şüpheli yapının hangi sınıfa dahil olduğu konusunda karar vermesine yardımcı olmaktadır. Ayrıca, hastanın tedavi sürecinin yönetilmesinde çok önemli bir nokta olan biyopsi değerlendirmesinin gerçekleştirilmesi konusunda da biyopsi uzmanına ön tanı koyma aşaması ile destek vereceği düşünülmüştür. Tasarlanan bu sistemin hem mevcut BDT sistemlerine entegre edilebilir olması hem de yeni akıllı BDT sistemlerinde kullanılabilecek olması oldukça önemlidir.

Tez çalışmasında gerçekleştirilen BDT sistemi, biyomedikal görüntülerin segmentasyonunda ve/veya sıkıştırılmasında oldukça sıklıkla kullanılan dalgacık dönüşümünün yerine bu dönüşümün görüntü işleme alanında kullanımında karşılaşılan dezavantajları ortadan kaldırmak üzere geliştirilmiş olan kompleks-değerli versiyonu ilk kez akciğer BT görüntüleri üzerinde kullanılmıştır. Kompleks-değerli dalgacık dönüşümü ile hem segmentasyon öncesi görüntü boyutu azaltılmış hem de sınıflama öncesinde segmente edilmiş görüntülerden özellik çıkarılması aşamasında görüntünün çeşitli seviyelerde ayrıştırılması ve istatistiki özelliklerinin çıkarılmasında kullanılmıştır. Segmentasyon için geliştirilen yeni yapay zeka metodunda KDYSA ile HYSA birlikte değerlendirilerek, KDHHYSA olarak isimlendirilen hibrit sistem başarılı ile kullanılmıştır. Bu hibrit sistemin bu tez çalışmasından sonra da özellikle diğer biyomedikal görüntüler üzerinde de başarı ile uygulanabileceği öngörüsü, tez çalışmasının literatüre olan katkısının ileride de artarak devam edeceğini düşündürmektedir.

Literatüre yeni katkı anlamında yerini bulabilecek diğer bir çalışma ise gerçekleştirilen tezde yer alan nodüllerin sınıflandırılması ile ilgili bölümdür. Bu bölümde mevcut BDT sistemlerinin çok büyük bir çoğunluğunun aksine nodül tespiti yerine nodül sınıflama yapılarak, benign ve malign nodüllere sahip BT görüntüleri başarı ile ayrılmıştır. Bu ayırma işleminde, yine literatürde ilk kez olmak üzere, KDYSA kullanılmıştır.

Sonuç olarak, akciğer kanserinin yüksek görülme sıklığı, bu hastalığa yakalanan kişilerdeki yüksek ölüm oranı ve tedavi maliyetlerinin büyüklüğü gibi parametreler düşünüldüğünde tez çalışmasında geliştirilen bu yeni akıllı BDT sisteminin önemi ortaya çıkmaktadır.

11. SONUÇLAR ve ÖNERİLER

11.1. Sonuçlar

Tez çalışmasında, akciğer BT görüntüleri üzerinde akciğer bölgesinin segmentasyonu ve akciğer kanserine neden olan kötü huylu nodüllerin iyi huylu nodüllerden ayrılması (sınıflandırılması) işlemleri kompleks-değerli özellik çıkarıcılar ve yapay zeka metotları kullanılarak gerçekleştirilmiştir. Böylece mevcut BDT sistemlerinin performaslarının geliştirilmesi ve nodüllerin akıllı bir sistem vasıtası ile sınıflanması gibi oldukça önemli bir probleme çözüm üretilmesi amaçlanmıştır.

İlk olarak akciğer bölgesinin segmentasyonu üzerine çalışmalar yapılmıştır. Biyomedikal görüntülerin boyutlarının büyük olması sebebi ile gerçekleştirilen işlemlerin yavaş olması, işlem sonucu elde edilen çıktıların istenilen doğruluktan uzak olması ve tüm bu işlemler için yüksek performanslı bilgisayar sistemlerine ihtiyaç duyulması gibi dezavantajları ortadan kaldırabilmek amacı ile her görüntü işleme uygulamasında olduğu gibi bir özellik çıkarma ön-işlemi gerçekleştirilmiştir.

Literatürde en sık kullanılan ön-işleme (özellik çıkarma ya da sinyal sıkıştırma, boyut azaltma) metodu olan (reel değerli) dalgacık dönüşümü yerine, bu dönüşümün sahip olduğu giriş değişimlerine karşı duyarsızlık, yön bilgisinde eksiklik ve faz bilgisinin kaybedilmesi gibi dezavantajları ortadan kaldıran kompleks-değerli dalgacık dönüşümü kullanılarak orijinal boyutu 752x752 piksel olan BT görüntüsü, birinci seviye boyut azaltımı için 376x376’ ya, ikinci seviye boyut azaltımı için 188x188’ e, üçüncü seviye boyut azaltımı için 94x94’ e ve dördüncü seviye boyut azaltımı için 47x47’ ye düşürülmüştür.

Kompleks-değerli dalgacık dönüşümü kullanılarak gerçekleştirilen görüntü boyutundaki azaltım sonucu elde edilen kompleks-değerli yeni özellik vektörleri (ya da sıkıştırılmış görüntüden elde edilen matrisler) segmentasyon işleminin gerçekleştirilmesi amacı ile tez çalışmasında ortaya konulan yeni bir hibrit kompleks-değerli yapay zeka algoritması (kompleks-değerli hibrit hücresel YSA,

KDHHYSA)' na verilmiştir. Bu yapı, KDYSA' nın kompleks değerli sayılar ile işlem yapabilme kabiliyetini, HYSA' nın iki boyutlu yapısı sebebi ile görüntü işleme alanına uygunluğunu birleştirmektedir. Bu yeni hibrit yapıdan, hedef olarak verilen segmente edilmiş görüntüleri elde etmesi istenmiştir.

Dokuzuncu bölümde Çizelge 9.3 - 9.6 ile detaylı olarak ifade edilen segmentasyon çalışmasının sonuçları, birinci (S1), ikinci (S2), üçüncü (S3) ve dördüncü (S4) seviye KDDD ve KDHHYSA yapıları için bir özet şekilde Çizelge 11.1' de yer almaktadır.

Çizelge 11.1 Segmentasyon için önerilen yapılar ile elde edilen sonuçlar

YAPI	Doğru Sınıflanan Piksel Sayısı	Yanlış Sınıflanan Piksel Sayısı	Doğruluk (%)	Süre (saniye)
S1-KDDD KDHHYSA	564017	1487	99.7371	232.4091
S2-KDDD KDHHYSA	563853	1651	99.7080	80.4764
S3-KDDD KDHHYSA	563862	1642	99.7096	47.1330
S4-KDDD KDHHYSA	563602	1902	99.6637	22.3714

Çizelge 11.1' den de görülebileceği gibi en yüksek doğruluk yüzdesine S1-KDDD KDHHYSA yapısı sahiptir. Yine aynı çizelge incelendiğinde en düşük doğruluk yüzdesinin S4-KDDD KDHHYSA ile elde edildiği görülmektedir. Ancak bu iki yapının doğruluk yüzdeleri karşılaştırıldığında aradaki farkın sadece % 0.07 olduğu açıktır. İşlem süreleri karşılaştırıldığında ise aradaki farkın oldukça önemli olduğu görülmektedir. S4-KDDD KDHHYSA yapısı ile bir akciğer BT görüntüsünün segmente edilmesi yaklaşık 22 saniye sürmekte, S1-KDDD KDHHYSA' de ise bu süre yaklaşık 232 saniyeye çıkmaktadır. Bu sonuçlara göre, önerilen yapılar arasında S4-KDDD KDHHYSA' nın akciğer BT görüntüsünden akciğer bölgesinin segmentasyonu işlemini hem hızlı hem de yüksek doğrulukla gerçekleştirdiği ortaya çıkmıştır. Bir diğer önemli nokta ise, geliştirilen KDHHYSA' nın görüntü boyutunun çok büyük ya da çok küçük olması durumlarında bile segmentasyon işlemini yaklaşık aynı doğruluk ile yapılıyor olmasıdır (S1-KDDD yapısı ile S4-KDDD yapısı arasında matris boyutu 8 kat küçülmüş, görüntü matrisindeki toplam piksel sayısı ise 64 kat azalmıştır). Bu sonuç, sistemin genelleştirilebilir sonuçlar ürettiğinin bir yansıması olarak adlandırılabilir. Bu yorumu desteklemek amacı ile, her bir seviye için

KDHHYSA' nın benign ve malign nodüller içeren BT görüntüleri içerisinde en yüksek ve en düşük doğruluk oranları ile segmente ettiği görüntüler KDYSA ile de segmente edilmiş ve doğrulukları Çizelge 11.2' de karşılaştırmalı olarak verilmiştir.

Çizelge 11.2 Benign ve Malign görüntüler için KDHHYSA' nın en iyi ve en kötü doğruluk ile segmente ettiği görüntülerin KDYSA ile segmente edilmesi ve sonuçlar

Seviye (S)	Görüntü Numarası (B:Benign) (M:Malign)	DOĞRULUK (%) KDHHYSA	KDYSA
1	B10 (en iyi)	99.8134	87.3651
	B8 (en kötü)	99.7038	79.7328
	M16 (en iyi)	99.7887	85.5462
	M10 (en kötü)	99.6854	76.7374
2	B10 (en iyi)	99.8057	99.7834
	B1 (en kötü)	99.6529	99.6426
	M16 (en iyi)	99.7698	99.7606
	M19 (en kötü)	99.6532	99.6426
3	B10 (en iyi)	99.8021	99.7910
	B1 (en kötü)	99.5233	99.5233
	M6 (en iyi)	99.7818	99.7740
	M10 (en kötü)	99.6566	99.6541
4	B10 (en iyi)	99.7639	99.7639
	B1 (en kötü)	99.2389	99.2391
	M16 (en iyi)	99.7470	99.7480
	M4 (en kötü)	99.6196	99.6189

Çizelge 11.2' den de görülebileceği gibi önerilen KDHHYSA yerine KDYSA kullanıldığında, özellikle birinci seviyeden KDDD uygulandığında elde edilen yeni görüntünün segmente edilmesi işleminde ulaşılan en iyi doğruluk ancak % 85.5462' dir. Üstelik KDHHYSA' nın benign nodüller içeren görüntüler arasında en kötü doğruluk ile sonuca ulaştığı B8 kodlu görüntü için segmentasyon sonucu % 99.7038 iken, aynı görüntü için KDYSA ancak % 79.7328' lik bir doğruluk elde edebilmiştir. Benzer durum malign nodül içeren M10 kodlu görüntü içinde geçerlidir. KDHHYSA' nın elde ettiği doğruluk % 99.6854 olarak hesaplanmışken, KDYSA'nın ulaştığı doğruluk % 76.7374' te kalmıştır. Diğer seviye KDDD' ler için segmentasyon sonuçları incelendiğinde genellikle sonuçların birbirine çok yakın olduğu ancak çok küçük farklar ile KDHHYSA' nın elde ettiği sonuçların daha iyi olduğu söylenebilir. Kısacası, KDYSA görüntü boyutu 376x376' ya düşürüldüğünde başarısız olmakta (diğer yapılar ile karşılaştırıldığında en düşük doğruluk oranına

sahip olmakta), görüntü matrislerinin boyutları daha da küçüldüğünde istenilen başarılı sonuçları yakalayabilmektedir. Ancak KDHHYSA görüntünün boyutlarından bağımsız olarak yaklaşık aynı doğruluk ile segmentasyon işlemini tamamlayabilmiştir.

Tez çalışmasının ikinci bölümünde, segmente edilen akciğer BT görüntülerinde yer alan benign ve malign nodüller sınıflandırılmıştır. Literatürdeki çalışmaların büyük bir kısmının sadece nodülü belirleme konusunda yoğunlaştığı düşünüldüğünde, nodül teşhisi yerine nodül türünü sınıflayan yeni bir BDT sisteminin ortaya atılması oldukça önemlidir.

Önerilen nodül sınıflama yapısı özellik çıkartma ve sınıflama bloklarından oluşmaktadır. Özellik çıkarma işlemi, segmentasyon uygulamasında olduğu gibi farklı seviyelerden KDDD ile gerçekleştirilmiştir. Boyutları azaltılan görüntü matrislerinden dört temel istatistiki özellik çıkartılmış ve bu istatistiki özellikler KDYSA ile sınıflandırılmıştır.

Her bir yapı için sınıflama sonucunda oluşan karmaşıklık matrisi Çizelge 11.3-a,b,c ve d' de gösterilmektedir. Bu çizelgelerde, pozitif (malign) ve negatif (benign) olduğu bilinen veriler ile sınıflayıcının bu etiketli verileri hangi sınıflara ayırdığı detaylı olarak görülebilmektedir.

Çizelge 11.3 Nodül sınıflaması için kullanılan yapıların elde ettiği sınıflama sonuçlarının karmaşıklık matrisi ile gösterimi (a) S1-KDDD KDYSA (b) S2-KDDD KDYSA (c) S3-KDDD KDYSA (d) S4-KDDD KDYSA

(a)

Verilerin Gerçek Sınıfı	Sınıflayıcının Sonucu	
	Pozitif (Malign)	Negatif (Benign)
Pozitif (Malignn) Etiketli Veri	20	0
Negatif (Benign) Etiketli Veri	5	5

(b)

Verilerin Gerçek Sınıfı	Sınıflayıcının Sonucu	
	Pozitif (Malign)	Negatif (Benign)
Pozitif (Malignn) Etiketli Veri	20	0
Negatif (Benign) Etiketli Veri	4	6

(c)

Verilerin Gerçek Sınıfı	Sınıflayıcının Sonucu	
	Pozitif (Malign)	Negatif (Benign)
Pozitif (Malignn) Etiketli Veri	20	0
Negatif (Benign) Etiketli Veri	4	6

(d)

Verilerin Gerçek Sınıfı	Sınıflayıcının Sonucu	
	Pozitif (Malign)	Negatif (Benign)
Pozitif (Malignn) Etiketli Veri	20	0
Negatif (Benign) Etiketli Veri	1	9

Yukarıda ki çizelge de yer alan karmaşıklık matrisleri incelendiğinde bütün yapılar için pozitif (malign) etiketli görüntülerin tamamının pozitif olarak sınıflandırıldığı ancak benign etiketli görüntülerde sınıflama hatalarının olduğu görülmektedir. Bu sonuç, Bölüm 8.3' te yer alan *"İğne biyopsisi ile malign nodüllerde % 95 oranında tanı alınabilmekte iken, benign nodüllerde bu oran % 70' lere kadar düşmektedir"* ifadesinin, malign nodülleri sınıflama oranının benign nodülleri sınıflama oranına göre daha yüksek olduğu bilgisini desteklediği hatta tez çalışmasında önerilen yeni BDT sistemi ile bu ifade de yer alan oranların da üstüne çıkıldığı görülmektedir.

Karmaşıklık matrisinde yer alan sınıflandırma sonuçları, Bölüm 9.2.3' te ifade edilen sınıflayıcı performansı ölçüm kriterlerinden duyarlılık, belirlilik, ortalama belirleme oranı, doğruluk, pozitif tahmin testi ve negatif tahmin testi kullanılarak Çizelge 11.4' te değerlendirilmiştir. Çizelge 11.4' ten, ilk üç yapının dördüncü yapıya benzer şekilde pozitif verileri doğru sınıfladığı ancak, dördüncü yapıdan farklı olarak negatif verileri sınıflandırma da başarısız olduğu ve bunun sonucu olarak da negatif tahmin testlerinin düşük olduğu görülmektedir. Ayrıca ilk üç yapı için duyarlılık oranı % 80' i, ortalama belirleme oranı ise % 90' ı geçememiştir. Dördüncü yapıda ise negatif tahmin değeri % 90' a ulaşmış ve yapının toplam doğruluğu % 96.7 olarak elde edilmiştir. Bu sonuçlar S4-KDDD KDYSA yapısının benign ve malign nodüllerin sınıflandırılabilmesi amacı ile kullanılabileceğini ortaya koymaktadır.

Çeşitli seviyelerdeki KDDD kullanıldığında orijinal görüntü boyutlarının azaltıldığı, bir başka deyişle orijinal görüntü boyutundan (752x752) dört farklı dönüşüm seviyesi için dört farklı boyutta (1. seviye için 376x376, 2. seviye için 188x188, 3. seviye için 94x94, 4. seviye için 47x47) özellik matrislerinin elde edildiği açıktır. Ancak tüm bu özellik matrislerinden her bir seviye için aynı sayıda istatistiki özellik (maksimum değer, minimum değer, ortalama değer ve standart sapma) seçilerek, her bir yapı için aynı büyüklükteki özellik vektörleri KDYSA' nın girişi olarak kullanılmıştır.

Çizelge 11.4 Sınıflama sonuçlarının değerlendirilmesi

YAPI	Duyarlılık (%)	Belirlilik (%)	Ortalama Belirleme Oranı (%)	Doğruluk (%)	Pozitif Tahmin Testi (%)	Negatif Tahmin Testi (%)
S1-KDDD KDYSA	80	100	90	83.3	100	50
S2-KDDD KDYSA	76.9	100	88.45	80	100	40
S3-KDDD KDYSA	76.9	100	88.45	80	100	40
S4-KDDD KDYSA	95.2	100	97.6	96.7	100	90

Elde edilen tüm bu sonuçların, literatürdeki çalışmalar içerisinde bulunduğu yeri belirleyebilmek amacı ile Çizelge 11.5' te karşılaştırmalı bir literatür özeti verilmiştir. Bu çizelgede, gerçekleştirilen tez çalışmasında elde edilen sonuçlar ile diğer 21 çalışmanın içeriği ve sonuçları karşılaştırıldığında, ilk olarak göze çarpan farklılık sadece 4 çalışmada nodül sınıflandırması işleminin gerçekleştirmesidir.

Nodülleri sınıflandıran çalışmalar detaylı olarak incelendiğinde, ilk olarak Penedo ve ark. (1998)' nın iki YSA' nın oluşturduğu bir sistem gerçekleştirerek % 94 duyarlılık ve % 89 belirlilik ile nodülleri sınıflandırdığı görülmektedir. Gerçekleştirilen tez çalışmasında ise % 95.2 duyarlılık ve % 100 belirlilik değerlerine ulaşılmıştır. Nodül sınıflandırması ile ilgili bir diğer çalışma ise, Suzuki ve ark. tarafından 2005 yılında gerçekleştirilmiştir. Masif eğitimli YSA kullanılarak malign nodüller % 100 duyarlılık ile sınıflandırılırken, benign nodüller için sınıflama duyarlılığı ancak % 48' e ulaşabilmiştir. Yani toplam benign nodüllerin yaklaşık yarısı malign olarak sınıflandırılmıştır. Buna karşılık, tez çalışmasında 22 malign nodülün tamamı malign olarak sınıflanırken, 10 benign nodülün sadece 1 tanesi malign olarak sınıflandırılmıştır. Awai ve ark.' nın 2006 yılında yaptıkları çalışma, tez çalışmasında kullanılan veri setleri ile bu çalışmada kullanılan veri setlerinin sayısal olarak büyüklüklerinin birbirine yakın olması sebebi ile bir karşılaştırma yapılabilmesi anlamında oldukça önemlidir. Awai ve ark., iki yıllık bir çalışmanın sonucu olarak oluşturdukları 18 malign (tez çalışmasında 22 malign) ve 15 benign (tez çalışmasında 10 benign) olmak üzere toplam 33 nodülden (tez çalışmasında 32) oluşan veri setine, segmentasyon, YSA ile sınıflama ve malign tahminini içeren bir BDT sistemi uygulamıştır. Önerilen bu BDT sistemi ile pozitif tahmin oranı en yüksek % 90 olarak elde edilirken, tez çalışmasında kullanılan bütün yapılar için elde edilen % 100' lük pozitif tahmin oranı ile Awai ve ark. nın yaptıkları çalışmanın başarısının üstüne çıkılmıştır. Bu alanda yapılmış en son çalışma Lee ve ark. (2009)' na aittir. Nodüllerin neden olduğu dört farklı akciğer rahatsızlığı, Bayesian sınıflayıcı, YSA ve destek vektör makineleri kullanarak sınıflandırılmıştır. En iyi sonuçlar, destek vektör makineleri kullanılarak elde edilmiştir. Duyarlılık % 82.78 (tez çalışmasında % 95.2), belirlilik % 94.2 (tez çalışmasında %100), doğruluk % 83.1 (tez çalışmasında % 96.7) olarak elde edilmiştir.

Nodül sınıflama çalışmalarının sayısının son derece yetersiz olduğu üstelik tez çalışmasında elde edilen sınıflama sonuçlarının, diğer çalışmaların sonuçlarından çok daha iyi olması, önerilen sistemin oldukça başarılı olduğunu ortaya koymaktadır. Özellikle mevcut çalışmaların malign nodüllerin sınıflandırılmasında nispeten iyi sonuçlar elde ettiği ancak benign nodüllerin sınıflandırılmasında başarısız olduğu dikkati çekmektedir. Buna karşılık, pozitif (malign) tahmin testinin % 100, negatif (benign) tahmin testinin ise % 90 ile sonuçlanması tez çalışmasının literatür içerisindeki yerini daha net bir şekilde ifade etmektedir.

Çizelge 11.5' de yer alan diğer çalışmalar incelendiğinde bu çalışmaların segmentasyon ve nodüllerin belirlenmesi üzerine yoğunlaştığı görülmektedir. Bu çalışmalarda elde edilen sonuçlar ile Çizelge 11.5' in en son satırında yer alan ve tez çalışmasında elde edilen sonuçların bir özetini içeren bölüm karşılaştırıldığında tez çalışmasının başarısı bir kez daha ortaya çıkmaktadır.

Çizelge 11.5 Tez çalışmasının literatür ile karşılaştırılması

Çalışma	Çalışma Özeti	Nodül Sınıflama Mevcut mu?	SONUÇ
Penedo ve ark. 1998 (IEEE Trans. On Medical Imaging)	Şüpheli nodül alanlarını belirleyen ve sonra onları sınıflayan iki YSA' dan oluşan sistem kullanılmıştır.	Evet	Duyarlılık: % 94 Belirlilik: % 89 Ortalama Belirleme Oranı: % 92.5
Shirashi ve ark. 2000 (American Journal of Roentgenology)	154 nodül üzerinde çalışılmıştır. 100 malign, 54 benign' dir. Farklı uzmanlıktaki ve tecrübedeki radyologların nodülleri belirleyebilme oranları incelenmiştir.	Hayır	Duyarlılık = Göğüs uzmanı radyologlar : % 80.4 Genel radyologlar : % 81.3 Tüm radyologlar : % 80.9
Lee ve ark. 2001 (IEEE Trans. On Medical Imaging)	Genetik algoritma temelli şablon eşleştirme metodu kullanılmış ve görüntülerden çıkartılan özellikler eşleştirilerek nodül belirlenilmiştir.	Hayır	Doğruluk: % 72
Brown ve ark. 2001 (IEEE Trans. On Medical Imaging)	Tekrarlamalı taramayı içeren bir model geliştirilerek, ilk taramada nodül adayları belirlenmiş ikinci taramada belirlenen adayların nodül olup olmadığına karar verilmiştir. 17 hastadan alınan 20 nodülün 16 sı belirlenmiştir.	Hayır	Doğruluk: % 80
Armato ve ark. 2002 (Radiology)	Klinik yorumlama esnasında kaçırılan ancak biyopsi yapıldığında belirlenen nodüllerin gri-seviye eşikleme tekniği ve kural-tabanlı sınıflayıcı ile belirlenmesini içeren bir sistem kullanılmıştır. 38 BT' den alınan 50 nodülün 40' tanınmıştır. 50 nodülden 38 tanesi kaçırılan nodüllerdir. Bunlarında 32 tanesi sistem ile belirlenmiştir.	Hayır	Duyarlılık= % 84

Coppini ve ark. 2003 (IEEE Trans. On Information Technology in Biomedicine)	Çoklu ölçekli yapı ilgili alanın seçimi yöntemleri ile YSA kullanan bir BDT sistemi tasarlanmıştır. Göğüs radyografisinden nodüller belirlenmiştir.	Hayır	Duyarlılık= % 94.45 Belirlilik= % 79.75 Doğruluk= % 87.1
Li ve ark. 2005 (Radiology)	Eşleştirme filtresi kullanılarak BT görüntüsündeki nodülleri baskın hale getiren bir BDT sistemi tasarlamışlardır. 17 hastadan alınan BT görüntüleri 14 radyologa gösterilmiş ve duyarlılık % 52 bulunmuş, daha sonra BDT uygulandıktan sonra radyologlara gösterilmiş ve duyarlılık % 68' e çıkarılmıştır.	Hayır	Duyarlılık= % 68
Lin ve ark. 2005 (Computerized Medical Imaging and Graphics)	Bulanık sistem tabanlı YSA kullanarak BT görüntülerinden nodülleri belirlemişlerdir.	Hayır	Duyarlılık = % 89.3
Armato ve ark. 2005 (Academic Radiology)	Akciğer kanseri izleme programı kapsamında alınan BT görüntülerinden nodül belirleme işlemi gerçekleştirilmiştir.	Hayır	Duyarlılık= % 70 (Toplam) Duyarlılık= % 83 (Malign)
Suzuki ve ark. 2005 (IEEE Trans. On Medical Imaging)	Masif eğitimli YSA ile malign ve benign nodüller sınıflandırılmıştır. Görüntüler 73 hastadan alınmıştır.	Evet	Duyarlılık= % 100 (Malign) Duyarlılık= % 48 (Benign)
Yuan ve ark. 2006 (American Journal of Roentgenology)	BDT sisteminin nodül belirleme üzerine etkisi incelenmiştir. BT cihazının kendi BDT sistemi kullanılmıştır.	Hayır	Ortalama Sınıflama Oranı = % 83 (Radyolog) ve % 73 (BDT)

Awai ve ark. 2006 (Radiology)	2 yıllık bir çalışmanın sonuçlarıdır. 18 malign ve 15 benign nodül değerlendirilmiştir. Nodüllerin sınıflandırılması konusunda 10 tane 8-26 yıl arası tecrübeli radyolog, 9 tane de 1-4 yıl arası tecrübeli radyolog kullanılmıştır. Ayrıca, radyologlar tarafından ilgili alanın belirlenmesi, segmentasyon, YSA ile sınıflama ve malign olasılığının tahmininden oluşan bir BDT sistemi tasarlanmıştır.	Evet	Duyarlılık= % 76.1 (8-26 yıl tec. rad.) % 67.3 (1-4 yıl tec. rad.) % 71.9 (Tüm. rad.) % 72.2 (BDT) Belirlilik= % 89.3 (8-26 yıl tec. rad.) % 74.8 (1-4 yıl tec. rad.) % 82.5 (Tüm. rad.) % 75 (BDT) Pozitif Tahmin Oranı= % 90 (8-26 yıl tec. rad.) % 77.2 (1-4 yıl tec. rad.) % 84 (Tüm. rad.) % 81.3 (BDT)
Das ve ark. 2006 (Radiology)	1 yıl, 3 yıl ve 6 yıllık tecrübeye sahip 3 radyoloğun nodül belirleme performansları 2 BDT sistemi kullanılarak test edilmiştir. Kullanılan BDT sistemleri ImageChecker CT (R2 tek.) ve Nodule Enhanced Viewing (NEC) (Siemens) firmalarına aittir. 25 hastadan alınan BT ile çalışılmıştır.	Hayır	Duyarlılık oranları = 1 yıl tecrübesi bulunan rad. İçin % 68 (BDT yok) % 79 (IC ile) % 79 (NEV ile) 3 yıl tecrübesi bulunan rad. İçin % 78 (BDT yok) % 90 (IC ile) % 90 (NEV ile) 6 yıl tecrübesi bulunan rad. İçin % 82 (BDT yok) % 84 (IC ile) % 86 (NEV ile)
Aubry ve ark. 2006 (American Journal of Roentgenology)	Katı akciğer nodülleri üzerine gerçekleştirilen çalışmada 25 örnek üzerinde 2 radyologun nodül belirleme performansları üzerine BDT sisteminin etkisi incelenmiştir.	Hayır	BDT sistemi ile birinci radyologun nodül belirleme duyarlılığı % 9.6, ikinci radyologun nodül belirleme duyarlılığı % 23 oranında artmıştır. Ortalama doğruluk= % 91.3' tür.
Enquobahrie ve ark. 2007 (Academic Radiology)	Nodülün aranacağı alanın belirlenmesi, aday nodüllerin seçimi ve yanlış pozitif sayısının düşürülmesini içeren 3 adımlı bir BDT sistemi ile nodüllerin belirlenmiştir.	Hayır	Çalışılan görüntü veri tabanı nodül büyüklüklerine göre A ve B olmak üzere iki sınıfa ayrılmıştır. Duyarlılık= % 72.1 (A) Duyarlılık= % 82.3 (B)

Dehmeshki ve ark. 2007 (Computerized Medical Imaging and Graphics)	Nodüller, şekil temelli genetik algoritma şablon-eşleştirme metodu kullanılarak belirlenmişlerdir.	Hayır	Doğruluk = % 90
Özekes 2007 (İstanbul Ticaret Üniv. Fen Bil. Derg.)	12 kişiye ait BT görüntüleri kullanılmıştır. Kural tabanlı bir segmentasyon sonrasında genetik algoritma ile eğitilmiş şablon eşleştirme metodu kullanılmıştır.	Hayır	Duyarlılık = % 93.4
Özekes ve ark. 2008 (Korean Journal of Radiology)	Genetik HYSA ile segmente edilen BT görüntülerinden, bulanık kural tabanlı eşikleme ve 3 boyutlu eşleştirme kullanılarak nodül belirleme işlemi yapılmıştır.	Hayır	Duyarlılık = % 100
Hirose ve ark. 2008 (Academic Radiology)	Çoklu dedektör BT ile alınan akciğer BT görüntülerinden nodül tespitinde BDT sistem performansı incelenmiştir. 21 hastadan alınan görüntülerin 6 tanesi nodül içermezken 15 tanesi nodül içermektedir. BDT kullanıldığında radyoloğun nodül belirleme duyarlılığı % 39.5' ten % 81' e çıkmıştır.	Hayır	Duyarlılık = % 81
Hardie ve ark. 2008 (Medical Image Analysis)	Adaptif uzaklık temelli eşik metodu segmentasyon için kullanılmıştır. Görüntüye ait 114 özellik çıkarılmış ve daha sonra Fisher disc. analiz metodu ile 46 özellik kullanılarak nodüller belirlenmiştir.	Hayır	Doğruluk = % 78.1

Kakar ve Olsen 2009 (Computerized Medical Imaging and Graphics)	Segmentasyon aşamasında, Gabor filtre ile özellikler çıkartılmış ve bulanık c-ortalamalar kümesi ile segmentasyon yapılmıştır. Daha sonra istatistiki özellikler çıkartılarak destek vektör mekineleri ile nodüller belirlenmiştir.	Hayır	Segmentasyon doğruluğu = % 92.47 Duyarlılık = % 89.48
Lee ve ark. 2009 (Computer Methods and Programs in Biomedicine)	92 kişiden alınan BT görüntüleri üzerinde gerçekleştirilen çalışmada farklı ilgi alan boyutları (32x32, 64x64) seçilmiş ve centrilobular emphysema, mild centrilobular emphysema, bronchiolitis obliterans ve normal akciğer olmak üzere 4 farklı akciğer rahatsızlığı saf Bayesyan sınıflayıcısı (SBS), Bayesian sınıflayıcısı (BS), YSA ve destek vektör makineleri (DVM) metotları kullanılarak 5-kat çapraz geçerlilik prosedürü ile sınıflandırılmışlardır.	Evet	Duyarlılık = SBS= % 65.1 BS= %80.7 YSA= %80.2 DVM= % 82.78 Belirlilik = SBS= % 88.38 BS= %93.5 YSA= %93.28 DVM= % 94.2 Doğruluk = SBS= % 66.1 BS= %81.2 YSA= %80.5 DVM= % 83.1
Ceylan 2009 (Tez Çalışması)	32 kişiden alınan akciğer BT görüntüleri KDDD ve KDHHYSA ile segmente edilmiş ve KDYSA ile benign nodüller ile malign nodüller sınıflandırılmıştır.	Evet	<u>Segmentasyon için</u> Doğruluk = 99.6637 <u>Sınıflama için</u> Duyarlılık = % 95.2 Belirlilik= % 100 Ortalama Belirleme Oranı = % 97.6 Doğruluk = % 96.7 Pozitif Tahmin Testi= % 100 Negatif Tahmin Testi= % 90

11.2. Öneriler

Tez çalışmasında kompleks değerli özellik çıkarma algoritması olarak KDDD ve segmentasyon işleminin sağlanabilmesi amacı ile KDHHYSA önerilmiştir. Çalışma kapsamında ortaya çıkarılan bu yeni hibrit ağ yapısı, KDYSA' ya adapte edilmiş HYSA yapısı şeklinde düşünülmüştür. İleri de yapılabilecek çalışmalarda bu hibrit ağ yapısını geliştirebilmek amacı ile farklı yapay-zeka metotlarının kompleks-değerli sayılar ile işlem yapabilecek alt yapıyı oluşturabilecek şekilde tasarlanması ve bu yeni yapının HYSA ile kombine edilmesi düşünülebilir. Ayrıca kullanılan aktivasyon fonksiyonunun yeniden belirlenmesi (trapezoidal, dalgacık fonksiyonları vb…) ve bu yeni fonksiyonunun segmentasyon doğruluğu üzerinde etkilerinin incelenmesi de faydalı bir çalışma olacaktır.

Akciğer kanserine sebep olan malign nodüllerin belirlenmesi ve benign nodüllerden ayrılması ile ilgili olarak gerçekleştirilen çalışmada görüntü boyutlarının azaltılması için kullanılan KDDD ilk kez bu çalışma ile akciğer BT görüntülerine uygulanmış ve elde edilen yeni görüntüden istatistiki özellikler çıkartılarak bu özellikler KDYSA ile sınıflandırılmıştır. Gelecekte bu alanda yapılabilecek çalışmalarda, KDD sonucunda elde edilen kompleks-değerli görüntü, bu alanda getirilebilecek yeni bir yaklaşım ile faz-tabanlı veya genlik-tabanlı olmak üzere ayrıştırılıp sınıflandırılabilirler.

Akciğer BT görüntüleri üzerine uygulanan KDDD ve KDYSA, bu alana getirdiği yeniliğin yanısıra kompleks-değerli sinyal işleme metotlarının uygulanmaya başlandığı manyetik rezonans görüntüleri üzerine de uygulanabilecektir. Özellikle beyin görüntüleri üzerine uygulamaların yapılabileceği öngörülmektedir.

Tüm bu önerilere ek olarak, tüm dünyada olduğu gibi ülkemizde de en sık rastlanan kanser türlerinden biri olan akciğer kanserinin erken teşhisi için, literatürde sıklıkla görüldüğü gibi, ülke çapında yaygın bir akciğer kanseri tarama programı başlatılmalı ve bu program dahilinde yeni geliştirilen BDT sistemleri ile radyologların performanslarının artırılması sağlanmalıdır. Bu hem BDT sistemlerinin daha geniş bir veri tabanı üzerinde uygulama imkanı bulmasına hem de

radyologlardan gelecek geri dönüşlere bağlı olarak sistemlerin gelişimine katkıda bulunacaktır.

12. KAYNAKLAR

Allen, J. B., Rabinar, L. R., 1977, A Unified Approach to Short-Time Fourier Analysis and Synthesis, Proc. IEEE, vol.65, 1558-1564.

Amari, S., 1967, A theory of adaptive pattern classifiers, IEEE Trans. on Electronics Computers, vol.16, no.3, 299-307.

Arena, P., Fortuna, L., Re, R., Xibilla, M. G., 1993, On the capability of neural networks with complex neurons in complex valued functions approximation, Proceeding of the IEEE International Symposium on Circuits and Systems, Chicago, 2168-2171

Armato, S. G., Li, F. Giger, M. L., MacMahon, H., Sone, S., Doi, K., 2002, Lung cancer: performance of automated lung nodule detection applied to cancers missed in a CT screening program, Radiology, vol.225, 685-692.

Armato, S. G., Roy, A. S., MacMahon, H., Li, F., Doi, K., Sone, S., Altman, M. B., 2005, Evaluation of automated lung nodule detection on low-dose computed tomography scans from a lung cancer screening program, Academic Radiology, vol.12, no.3, 337-346.

Aubry, C. B., Raffy, P., Yang, W., Castellino, R. A., Grenier, P. A., 2007, Computer-aided detection of solid lung nodules on follow-up MDCT screening: evaluation of detection, tracking and reading time, American Journal of Roentgenology, vol.189, 948-955.

Awai, K., Murao, K., Ozawa, A., Nakayama, Y., Nakaura, T., Liu, D., Kawanaka, K., Funama, Y., Morishita, S., Yamashita, Y., 2006, Pulmonary nodules: estimation of malignancy at thin-section helical CT-effect of computer-aided diagnosis on performance of radiologists, Radiology, vol.239, no.1, 276-284.

Bae, K. T., Kim, J. S., Na, Y. H., Kim, K. G., Kim, J. H., 2005, Pulmonary nodules: automated detection on CT images with morphologic matching algorithm-preliminary results, Radiology, vol.236, 286-294.

Bal, A., 2002, Dalgacık Yapay Sinir Ağları ve Öğrenme Algoritması, Doktora Tezi, Yıldız Teknik Üniversitesi, FBE.

Bankman, I. N., 2000, Handbook of medical imaging, processing and analysis, Academic Press.

Battle, G., 1987, A Block Spin Construction of Ondeletts; Part I: Lamarie Functions, Commu. Math. Phys., vol.110, 601-615.

Battle, G., 1988, A Block Spin Construction of Ondeletts; Part I: The QFT Connection, Commu. Math. Phys., vol.114, 93-102.

Belzar, B. Lina, J. M., Villasenor, J., 1995, Complex Linear Phase Filters for Efficient Image Coding, IEEE Trans. Sig. Proc.

Benvenuto, N., Piazza, F., 1992, On the complex back-propagation algorithm, IEEE Transactions on Signal Processing, vol. 40, 967-969.

Bezdek, J. C., Hall, L. O., Clarke L. P., 1993, Review of MR image segmentation techniques using pattern recognition, Med. Phys., vol.20, no. 4, 1033-1048.

Bezdek,J. C., Keller, J., Krisnapuram, R., Pal, N. R., 2005, Fuzzy models and algorithms for pattern recognition and image processing, Springer

Bilgili, E., Göknar, İ. C., Uçan, O. N., 2005, Cellular neural network with trapezoidal activation function, Int. Journal of Circuit Theory and Applications, vol.33, 393-417.

Brown, M. S., McNitt-Gray, M. F., Goldin, J. G., Suh, R. D., Sayre, J. W., Aberle, D. R., 2001, Patient-specific models for lung nodule detection and surveillance in CT images, IEEE Transactions on Medical Imaging, vol.20, no.12, 1242-1250.

Brzakovic, D., Luo, X. M., Brzakovic, P., 1990, An automated detection of tumors in mammograms, IEEE Transaction on Medical Imaging, vol.9, no.3, 233-241.

Burrus, C. S., Gopinath, R. A., Guo, H., 1998, Introduction to Wavelets and Wavelet Transforms: A Primer, Prentice Hall, NJ.

Chua, L. O., Yang, L., 1988-a, Cellular Neural Networks: Application, IEEE Transactions on Circuit and Systems, vol. 35, no. 10, 1273-1290.

Chua, L. O., Yang, L., 1988-b, Cellular Neural Networks: Theory, IEEE Transactions on Circuit and Systems, vol. 35, no. 10, 1257-1272.

Chua, L. O., 1991, An Analytic Method for Designing Simple Cellular Neural Networks, IEEE Transactions on Circuit and Systems, vol. 38, no. 11, 1332-1341.

Clarke L. P., Velthuizen R. P., Camacho, M. A., Heine J. J., Vaidyanathan, M., Hall, L. O., Thatcher, R. W., Silbiger, M. L., 1995, MRI segmentation: methods and applications, Magnetic Resonance Imaging, vol. 5, 345-352.

Coppini, G., Diciotti, S., Falchini, M., Villari, N., Valli, G., 2003, Neural networks for computer-aided diagnosis: detection of lung nodules in chest radiograms, IEEE Transactions on Information Technology in Biomedicine, vol.7, no.4, 344-357.

Cohen, L., 1989, Time-Frequency Distributions- A Review, Proc. of IEEE, vol.77, no.7, 941-981.

Das, M., Mühlenbrunch, G., Mahnken, A. H., Flohr, T. G., Gündel, L., Stanzel, S., Kraus, T., Günther, R. W., Wildberger, J. E., 2006, Small pulmonary nodules: effect of two computer-aided detection systems on radiologists performance, Radiology, vol.241, no.2, 564-571.

Daubechies, I., 1990, The Wavelet Transform, Time-Frequency Localization and Signal Analysis, IEEE Trans. Info. Theory, vol.36, 961-1005.

Dehmeshki, J., Ye, X., Lin, X. Y., Valdivieso, M., Amin, H., 2007, Automated detection of lung nodules in CT images using shape-based genetic algorithm, Computerized Medical Imaging and Graphics, vol.31, 408-417.

Dhawan, A. P., 2003, Medical image analysis, Wiley.

Driesen, J., Belmans, R., 2002, Time-Frequency Analysis in Power Measurement Using Complex Wavelets, IEEE Int. Sympo. on Cir. and Sys. (ISCAS2002), 681-684.

Dünya Sağlık Örgütü, 2004, Dünya Sağlık Raporu

Dünya Sağlık Örgütü, 2008, Kanser Raporu

Edis, E. Ç., Karlıkaya, C., 2007, The cost of lung cancer in Turkey, Tüberküloz ve Toraks Dergisi, vol.55, 51-58.

Enquobahrie, A. A., Reeves, A. P., Yankelevitz, D. F., Henscheke, I., 2007, Automated detection of small pulmonary nodules in whole lung CT scans, Academic Radiology, vol.14, no.5, 579-593.

Fahlman, S. E., Lebeire, C., 1990, The cascade-correlation learning architecture, Tech Report, School of Computer Science, Carnegie University.

Farag, A.A., El-Baz, A., Gimel'farb, G., Falk, R., 2004, Detection and recognition of lung abnormalities using deformable templates, Proceedings of the 17th International Conference on Pattern Recognition, vol.3, 738–741.

Fernandes, F., 2002, Directional, Shift-Insensitive, Complex Wavelet Transforms with Controllable Redundancy, PhD Thesis, Rice University.

Fernandes, F., Van Spaendonck, R., Coates, M., Burrus, C. S., 2000, Directional Complex Wavelet Processing, in Wavelet Applications VII, Proc. of SPIE.

Fernandes, F., Selesnick, I. W., Spaendonck, R., Burrus, C., 2003, Complex Wavelets Transforms with Allpass Filters, Preprint, EURASIP 2003.

Fligde, N. J., 1994, Multirate Digital Signal Processing, John Wiley & Sons.

Fu, K. S., Mui, J. K., 1981, A survey on image segmentation, Pattern Recognition, vol.13, no.1, 3-16.

Gabor, D, 1946, Theory of Communication, Journal of the IEE, vol. 93, 429-457.

Genç, İ., Güzeliş, C., Göknar, İ. C., 1996, ***Acoustic alarm signal classication with CNNs using wavelet transformation***, IEEE Int. Workshop on Cellular Neural Networks and their Applications, 375-379.

Georgiou, G. M., Koutsougeras, 1992, Complex domain backpropagation, IEEE Trans. on Circuits and Systems-II: Analog and Digital Processing, vol.39, no.5, 330-334.

Ginger, M. L., Giger, M.L., Bae, K.T., MacMahon, H., 1994, Computerized detection of pulmonary nodules in computed tomography images, Invest. Radiol. 29, 459–465.

Gonzalez, R. C., Woods, R. E., 2001, Digital image processing-second edition, Prentice Hall.

Guo, H., 1995, Theory and Applications of Shift-invariant, Time-varying and Undecimated Wavelet Transform, MSc Thesis, Rice University.

Hahn, S., 1996, Hilbert Transforms in Signal Processing, Artech House, Boston.

Haralick, R. M., Shapiro, L. G., 1985, Survey: image segmentation techniques, Comp. Vision Graph Image Proc., vol.29, 100-132.

Hardie, R. C., Rogers, S. K., Wilson, T., Rogers, A., 2008, Performance analysis of a new computer aided detection system for identifying lung nodules on chest radiographs, Medical Image Analysis, vol.12, 240-258.

Hatipoglu, S., Mitra, S. K., Kingsbury, N. G., 2000, Image Texture Description using Complex Wavelet Transform, Proc. Int. Conf. Image Proc., Vancouver, B.C., Canada, vol.2, 530-533

Haykin, S., 2002, Adaptive Filter Theory, Prentice Hall.

Hazar, A., 2006, Akciğer kanserli hastalarda malondialdehit (MDA) ve total antioksidan kapasite (TAOK) düzeyi ölçümü ile oksidan-antioksidan dengenin araştırılması. Uzmanlık Tezi, İstanbul.

Hill, P., Canagarajah, N., Bull, D., 2002, Image Fusion using Complex Wavelets, BMVC 2002, Cardiff University

Hirose, A., 2003, Complex-valued neural networks, Theories and Applications, World Scientific.

Hirose, T., Nitta, N., Shiraishi, J., Nagatani, Y., Takahashi, M., Murata, K., 2008, Evaluation of computer-aided diagnosis software for the detection of lung nodules on multidetector row computed tomography: JAFROC study for the improvement in radiologists diagnostic accuracy, Academic Radiology, vol.15, no.12, 1505-1512.

Hlawatsch, F., Boudreaux-Bartles, G. F., 1992, Linear and Quadratic Time-Frequency Signal Representations, IEEE Sig. Proc. Magazine, vol.9, no.2, 21-67.

ISO/IEC JTC 1/SC 29/WG1 N943, 1999, JPEG2000 Requirements and Profiles, International Organization of Standardization, Copenhagen.

Jianzhong, Q. Fan, L., Wei, G., Novak, C. L., Odry, B., Shen, H., Zhang, L., David, D. P., Ko, J. P., Rubinowitz, A. N., McGuinness, G., Kohl, G., Klotz, E., 2002, Knowledge-based automatic detection of multi-type lung nodules from multi-detector CT studies, Progress in Biomedical Optics and Imaging, vol.3, no.2, 689-697.

Kakar, M., Olsen, D. R., 2009, Automatic segmentation and recognition of lungs and lesion from CT scans of thorax, Computerized Medical Imaging and Graphics, vol.33, 72-82.

Kanazawa, K. Kawata, Y. N. Niki, H. Satoh, H. Ohmatsu, R. Kakinuma, Computer-aided diagnostic system for pulmonary nodules based on helical CT images, in: K. Doi, H. MacMahon, M.L. Giger, K. Hoffmann (Eds.), Computer-aided Diagnosis in Medical Imaging, (1998) 131–136.

Karlson, G., Vetterli, M., 1990, Theory of Two-Dimensional Multirate Filterbanks, IEEE Trans. Sig. Proc., vol.38, no.6, 925-937.

Kikinis, R., Shenton, M. E., Iosifescu, D. V., McCarley, R. W., Saiviroonporn, P., Hokama, H. H., Robatino, A., Metcalf, D., Wible, C. G., Portas, C. M., Donnino, R., Jolesz, F. A., 1996, Digital brain atlas for surgical planning, model driven segmentation and teaching, IEEE Transaction on Visulalization and Computer Graphics, vol.2, no.3.

Kim, M. S., Guest, C. C., 1990, Modification of backpropagation networks for complex-valued signal processing in frequency domain, Proceedings of the IJCNN, 27-31.

Kingsbury, N. G., 1998, The dual-tree complex wavelet transform: a new technique for shift invariance and directional filters, IEEE Digital Signal Processing Workshop, DSP 98, no.86.

Kingsbury, N. G., 1999, Shift Invariant Properties of the Dual-Tree Complex Wavelet Transform, Proc. IEEE Conf. on Acoustics, Speech and Signal Processing.

Kingsbury, N. G., 2001, Complex Wavelets for Shift Invariant Analysis and

Filtering of Signals, Journal of Applied and Computational Harmonic Analysis, vol.10, no.3, 234-253.

Kingsbury, N. G., 2003, Design of Q-shift Complex Wavelets for Image Processing using Frequency Domain Energy Minimization, Preprint, ICIP03.

Kohavi, R., Provost, F., 1998, Glossary of Terms, Editorial for the Special Issue on Applications of Machine Learning and the Knowledge Discovery Process, vol.30, no. 2/3

Köktürk N., Yeğin D., Ulukavak Çiftçi T., Bilgin Mullaoğlu S., Öztürk C., 2004, Akciğer Kanserlerinde Epidemiyolojik Özellikler Yıllar İçinde Değişim Gösteriyor mu?, Türk toraks dergisi, Cilt 5, Sayı 3, 137-142.

Lawton, W., 1993, Applications of Complex Valued Wavelet Transforms to Subband Decomposition, IEEE Trans. Sig. Proc., vol.41, no.12, 3566-3568.

Lee, Y. Hara, T., Fujita, H., Itoh, S., Ishigaki, T.,2001, Automated detection of pulmonary nodules in helical CT images based on an improved template-matching technique, IEEE Transactions on Medical Imaging, vol.20, no.7, 595-604.

Lee, K. W., Kim, M., Gierada, D. S., Bae, K. T.,2007, Performance of a computer-aided program for automated matching of netastatic pulmonary nodules detected on follow-up chest CT, American Journal of Radiology, vol.189, 1077-1081.

Lee, Y., Seo, J. B., Lee, J. G., Kim, S. S., Kim, N., Kang, S. H., 2009, Performance testing of several classifiers for differentiating obstructive lung diseases based on texture analysis at high-resolution computerized tomography, Computer Methods and Programs in Biomedicine, vol.93, 206-215.

Li, F., Arimura, H., Suzuki, K., Shiraishi, J., Li, Q., Abe, H., Engelmann, R., Sone, S., MacMahon, H., Doi, K., 2005, Computer-aided detection of peripheral lung cancers missed at CT: ROC analyses without and with localization, Radiology, vol.237, 684-690.

Liang, Z., 1993, Tissue classification and segmentation of MR images, IEEE in Medicine and Biology, vol.12, no.1, 81-85.

Lin, C. T., Chang, C. L., Cheng, W. C., 2004, A recurrent fuzzy cellular neural network system with automatic structure and template learning, IEEE Trans. on Circuits and Systems-I: Regular papers, vol.51, no.5, 1024-1035.

Lin, D. T., Yan, C. R., Chen, W. T.,2005, Autonomous detection of pulmonary nodules on CT images with a neural network-based fuzzy system, Computerized Medical Imaging and Graphics, vol.29, 447-458.

Lina, J. M., 1997-a, Image Processing with Complex Daubechies Wavelets, J. of Math. Imaging and Vision, vol.7, 211-223.

Lina, J. M., 1997-b, Complex Daubechies Wavelets: Filter Design and Applications, Proc.ISAAC Conf., University of Delaware.

Lo, S.C.B., Lou, S.-L.A., Lin, J.-S., Freedman, M., Chien, M.V., Mun, S.K., 1995, Artificial convolutional neural network techniques and applications for lung nodule detection, IEEE Transactions on Medical Imaging, 14, 711–718.

Lucas-Quesada, F. A., Sinha, U., Sinha, S., 1996, Segmentation strategies for breast tumors from dynamic MR images, Jornal of Magnetic Resonance Imaging, vol.6, 753-763.

Lorenzetto, G. P., Kovesi, P., 1999, A Phase Based Image Comparison Technique, DICTA99, University of Western Australia.

Magarey, J., Kingsbury, N. G., 1998, Motion Estimation using Complex-valued Wavelet Transform, IEEE Trans. Sig. Proc., vol.46, no.4.

Mallat, S., 1999, A Wavelet Tour of Signal Processing, 2/ed, Academic Press

Mallat, S., 1989, A Theory for Multiresolution Signal Decomposition: The Wavelet Representation, IEEE Trans. Pattern Recognition and Machine Intelligence, vol.11, no.7, 674 693.

Matsuki, Y., Nakamura, K., Watanabe, H., Aoki, T., Nakata, H., Katsuragawa, S., Doi, K., 2002, Usefulness of an artificial neural network for differentiating benign from malignant pulmonary nodules on high-resolution CT: evaluation with receiver operating characteristic analysis, American Journal of Radiology, vol.178, 657-663.

Meyer, Y., 1990, Ondeletts, Ondeletts et Operateurs, Paris: Hermann.

Mitiche, A., Aggarwal, J. K., 1985, Image segmentation by conventional and information-integrating techniques: a synopsis, Image and Vision Computing, vol.3, no.2, 50-62.

Miyauchi, M., Seki, M., Watanabe, A., Miyauchi, A., 1992, Interpretation of optical flow through neural network learning, Proceedings of IAPR Workshop on Machine Vision Applications, Tokyo, 523-528.

Miyauchi, M., Seki, M., Watanabe, A., Miyauchi, A., 1993, Interpretation of optical flow through complex neural network, Proceedings of International Workshop on Artificial Neural Network, Barcelona, 645-650.

Morrone, M. C., Burr, D. C., 1988, Feature Detection in Human Vision: A Phase Dependent Energy Model, Proc. R. Soc. Lond., B 235, 221.

Nitta, T., Furuya, T., 1991, A complex back-propagation learning, Trans. of Information Processing Society, vol.32, no.10, 1319-1329.

Nitta, T., 1993, A complex numbered version of the back-propation algorithm, Proc. of the WCNN, 576-579.

Nitta, T., 1997, An extension of the back-propagation algorithm to complex numbers, Neural Networks, vol.10, no.8, 1391-1415.

Nixon, M. S., Aguado, A. S., 2002, Feature extraction and image processing, Elsevier.

Osman, O., Ozekes S., Ucan, O. N., 2007, Lung nodule diagnosis using 3D template matching, Computers in Biology and Medicine, vol. 37, no.8, 1167-1172.

Osma, E., 2000, Solunum sistemi radyolojisi, Dokuz Eylül Üniversitesi Yayınları.

Özbay, Y., Ceylan, R., Karlik, B.,2006, A fuzzy clustering neural network architecture for classification of ECG arrhytmias, Computers in Biology and Medicine, vol.36, 376-388.

Özekeş, S., 2007, Rule-based lung region segmentation and nodule detection via genetic algorithm trained template matching, İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, Yıl.6, sayı. 11, 17-30.

Özekeş, S., Osman, O., Uçan, O. N., 2008, Nodule detection in a lung region that's segmented with using genetic cellular neural networks and 3D template matching with fuzzy rule based thresholding, Korean J. Radiology, vol.9, no.1.

Özmen, A., Uçan, O.N., Albora, A.M., 1999-a, Arkeolojik Sahalarda Ölçülen Cisimlerin Hücresel Yapay Sinir Ağları Kullanılarak Görüntülenmesi, TMMOB Jeofizik Mühendisleri Odası İzmir Şubesi-İzmir, 24.

Özmen, A., Albora, A. M., Uçan, O.N., 1999-b, Hücresel Yapay Sinir Ağları (HYSA) Kullanarak Sivas Bölgesi Kötüyuttepe mevkiinin Modellenmesi, 11. Mühendislik Haftası Yerbilimleri Sempozyumu Isparta, 373-381.

Özmen, A., 2001, Hücresel Yapay Sinir Ağı ve Görüntü İşleme Uygulamaları, Doktora Tezi, İstanbul Üniversitesi FBE.

Pal, N. R., Pal, S. K., 1993, A review on image segmentation techniques, Pattern Recognition, vol.26, no.9, 1227-1249

Penedo, M.G. ,Carreira, M., Mosquera, A., Cabello, D., 1998, Computer-aided diagnosis: a neural-network-based approach to lung nodule detection, IEEE Transactions on Medical Imaging vol.17, 872–880.

Portnoff, M. R., 1980, Time-Frequency Representation of Digital Signals and Systems Based on Short-Time Fourier Analysis, IEEE Trans. ASSP, vol. 28, 55-69.

Rioul, O., Vetterli, M., 1991, Wavelets and Signal Processing, IEEE Sig. Proc. Mag., 14-38.

Rumelhart, D. E., Hinton, G. E., Williams, R. J., 1986, Learning internal representations by error propagation, Paralel Distributed processing: Explorations in The Microstructures of cognition, vol.1, 318-362.

Selesnick, I. W., 2001-a, Hilbert Transform Pairs of Wavelet Bases, IEEE Sig. Proc. Letters, vol.8, no.6,170-173.

Selesnick, I. W., 2001-b, The Design of Hilbert Transform Pairs of Wavelet Bases via the Flat Delay Filter, Proc. of ICASSP, Salt lake City.

Shirashi, J., Katsuragawa, S., Ikezoe, J., Matsumoto, T., Kobayashi, T., Komatsu, K., Matsui, M., Fujita, H., Kodera, Y., Doi, K., 2000, Development of a digital image database for chest radiographs with and without a lung nodule: receiver operating characteristic analysis of radiologists detection of pulmonary nodules, American Journal of Roentgenology, vol.174, 71-74.

Shukla, P. D., 2003, Complex wavelet transforms and their applications, MSc Thesis, The University of Strathclyde.

Solazzi, M., Uncini, A., Claudio, E. D., Parisi, R., 2001, Complex discriminative learning bayesian neural equalizer, Signal Processing, 2493-2502.

Spaendonck, R., Blue, T., Baraniuk, R., Vetterli, M, 2003, Orthogonal Hilbert Transform Filterbanks and Wavelets, ICASSP03.

Spaendonck, R., Fernandes, F, Coates, M, Burrus, C.,2000, Non-redundant, Directionally Selective, Complex Wavelets, IEEE Proc. of Int. Conf. Image Proc., 379-382.

Strang, G., Nguyen, T., 1996, Wavelets and Filter Banks, Wellesley-Cambridge Press.

Stromberg, J. O., 1992, A Modified Franklin System and Higher Order Spline Systems on R^N as Unconditional Bases for Hardy Spaces, in W Beckner(editor): Proc. of Conf. In Honour of A Zygmund, Wadsworth Mathematics Series, 475-493.

Suetens, P., Bellon, E., Vandermeulen, D., Smet, M., Marchal, G., Nuyts, J., Mortelman, L., 1993, Image segmentation: methods and applications in diagnostic radiology and nuclear medicine, European Journal of Radiology, vol.17, 14-21.

Suzuki, H., Matsimoto, T., Chua, L. O., 1992, A CNN Handwritten Character Recognizer, International Journal of Circuit Theory and Application, vol. 20, 601-612.

Suzuki, K., Li, F., Sone, S., Doi, K., 2005, Computer-aided diagnostic scheme for distinction between benign and malignant nodules in thoracic low-dose CT by use of massive training artificial neural network, IEEE Transactions on Medical Imaging, vol.24, no.9, 1138-1150.

Sziranyi, T., Csapodi, M., 1994, Texture Classification and Segmentation by Cellular Neural Netvvork using Genetic Learning, Research Report, Computer and Automation Institute Hungarian Academy of Sciences.

Şengür, A., 2006, Endoskopik Görüntülerin Değerlendirilmesinde Görüntü İşleme Temelli Akıllı Karar Destek Sistemi, Doktora Tezi, Fırat Üniversitesi, FBE.

Türkiye' de Kanser Kontrolü, 2007, Editör: A. Murat Tuncer,T.C. Sağlık Bakanlığı Kanserle Savaş Dairesi, Ankara.

Uçan, O. N., O. Osman, Albora, A. M., 2006, Görüntü İşleme Teknikleri ve Mühendislik Uygulamaları, Nobel Yayınları.

Vetterli, M., 1986, Filterbanks Allowing Perfect Reconstruction, Sig. Proc., vol.10, no.3, 219-244.

Vetterli, M., Herley, C, 1992, Wavelets and Filterbanks: Theory and Design, IEEE Trans. ASSP, 2207-2232.

Vetterli, M., Kovacevic, J., 1995, Wavelets and Subband Coding, Prentice Hall, NJ.

Vidyanathan, P. P., 1993, Multirate Systems and Filter Banks, Prentice Hall.

Yuan, R., Vos., P. M., Cooperberg, P. L., 2006, Computer-aided detection in screening CT for pulmonary nodules, American Journal of Roentgenology, vol.186, 1280-1287.

Xu, X.W., Doi, K., Kobayashi, T., MacMahon, H., Giger, M., 1997, Development of an improved CAD scheme for automated detection of lung nodules in digital chest images, Medical Physics, 24, 1395–1403

Zang, X. P., Desai, M., Peng, Y. N., 1999, Orthogonal Complex Filter Banks and Wavelets: Some Properties and Design, IEEE Trans. Sig. Proc., vol. 47, no.4.

Zhou, D. M., Zhang, L,M, 2001, Global exponential stability of cellular neural network, Proc. of International Conf. on Neural Information Processing, China.

Zhu, Y., Yan, H., 1997, Computerized tumor boundary detection using a Hopfield neural network, IEEE Transaction on Medical Imaging, vol.16, no.1, 55-67.

Zurada, J. M., 1992, Introduction to Artificial Neural Systems, West Publishing Co., Boston.

EKLER

EK 1: Kompleks-Değerli Hibrit Hücresel Yapay Sinir Ağı Algoritması Matlab Kodları

EK 2: Nodül Sınıflama İçin Kompleks-Değerli Yapay Sinir Ağının Matlab Kodları

EK 3: Akciğer Görüntülerinin Alındığı Philips MX-8000 BT Cihazı

EK 1: Kompleks-Değerli Hibrit Hücresel Yapay Sinir Ağı Algoritması Matlab Kodları

```
clc
clear all
close all
format short

%=========NORMAL (BENIGN)===================

% Görüntülerim okutturulması
% Gri seviyeden siyah-beyaz seviyeye eşiklenmesi

a1=imread('nor1.bmp');
a11=a1(1:752,1:752);
A1=graythresh(a11);
A1new=im2bw(a11,A1);

a2=imread('nor2.bmp');
a22=a2(1:752,1:752);
A2=graythresh(a22);
A2new=im2bw(a22,A2);

a3=imread('nor3.bmp');
a33=a3(1:752,1:752);
A3=graythresh(a33);
A3new=im2bw(a33,A3);

a4=imread('nor4.bmp');
a44=a4(1:752,1:752);
A4=graythresh(a44);
A4new=im2bw(a44,A4);

a5=imread('nor5.bmp');
a55=a5(1:752,1:752);
A5=graythresh(a55);
A5new=im2bw(a55,A5);

a6=imread('nor6.bmp');
a66=a6(1:752,1:752);
A6=graythresh(a66);
A6new=im2bw(a66,A6);

a7=imread('nor7.bmp');
a77=a7(1:752,1:752);
A7=graythresh(a77);
A7new=im2bw(a77,A7);

a8=imread('nor8.bmp');
a88=a8(1:752,1:752);
A8=graythresh(a88);
A8new=im2bw(a88,A8);
```

```
a9=imread('nor9.bmp');
a99=a9(1:752,1:752);
A9=graythresh(a99);
A9new=im2bw(a99,A9);

a10=imread('nor10.bmp');
a100=a10(1:752,1:752);
A10=graythresh(a100);
A10new=im2bw(a100,A10);

%==========HASTA (MALIGN)=======================

b1=imread('hst1.bmp');
b11=b1(1:752,1:752);
B1=graythresh(b11);
B1new=im2bw(b11,B1);

b2=imread('hst2.bmp');
b22=b2(1:752,1:752);
B2=graythresh(b22);
B2new=im2bw(b22,B2);

b3=imread('hst3.bmp');
b33=b3(1:752,1:752);
B3=graythresh(b33);
B3new=im2bw(b33,B3);

b4=imread('hst4.bmp');
b44=b4(1:752,1:752);
b4=graythresh(b44);
B4new=im2bw(b44,b4);

b5=imread('hst5.bmp');
b55=b5(1:752,1:752);
B5=graythresh(b55);
B5new=im2bw(b55,B5);

b6=imread('hst6.bmp');
b66=b6(1:752,1:752);
B6=graythresh(b66);
B6new=im2bw(b66,B6);

b7=imread('hst7.bmp');
b77=b7(1:752,1:752);
B7=graythresh(b77);
B7new=im2bw(b77,B7);

b8=imread('hst8.bmp');
b88=b8(1:752,1:752);
B8=graythresh(b88);
B8new=im2bw(b88,B8);

b9=imread('hst9.bmp');
b99=b9(1:752,1:752);
B9=graythresh(b99);
B9new=im2bw(b99,B9);
```

```
b10=imread('hst10.bmp');
b100=b10(1:752,1:752);
B10=graythresh(b100);
B10new=im2bw(b100,B10);

b11=imread('hst11.bmp');
b101=b11(1:752,1:752);
B11=graythresh(b101);
B11new=im2bw(b101,B11);

b12=imread('hst12.bmp');
b102=b12(1:752,1:752);
B12=graythresh(b102);
B12new=im2bw(b102,B12);

b13=imread('hst13.bmp');
b103=b13(1:752,1:752);
B13=graythresh(b103);
B13new=im2bw(b103,B13);

b14=imread('hst14.bmp');
b104=b14(1:752,1:752);
B14=graythresh(b104);
B14new=im2bw(b104,B14);

b15=imread('hst15.bmp');
b105=b15(1:752,1:752);
B15=graythresh(b105);
B15new=im2bw(b105,B15);

b16=imread('hst16.bmp');
b106=b16(1:752,1:752);
B16=graythresh(b106);
B16new=im2bw(b106,B16);

b17=imread('hst17.bmp');
b107=b17(1:752,1:752);
B17=graythresh(b107);
B17new=im2bw(b107,B17);

b18=imread('hst18.bmp');
b108=b18(1:752,1:752);
B18=graythresh(b108);
B18new=im2bw(b108,B18);

b19=imread('hst19.bmp');
b109=b19(1:752,1:752);
B19=graythresh(b109);
B19new=im2bw(b109,B19);

b20=imread('hst20.bmp');
b200=b20(1:752,1:752);
B20=graythresh(b200);
B20new=im2bw(b200,B20);
```

```
b21=imread('hst21.bmp');
b201=b21(1:752,1:752);
B21=graythresh(b201);
B21new=im2bw(b201,B21);

blsz1=imread('blsz1.bmp');
b202=blsz1(1:752,1:752);
B22=graythresh(b202);
B22new=im2bw(b202,B22);

%==========hedefler=======================

load nor1_h;
load nor2_h;
load nor3_h;
load nor4_h;
load nor5_h;
load nor6_h;
load nor7_h;
load nor8_h;
load nor9_h;
load nor10_h;
load hst1_h;
load hst2_h;
load hst3_h;
load hst4_h;
load hst5_h;
load hst6_h;
load hst7_h;
load hst8_h;
load hst9_h;
load hst10_h;
load hst11_h;
load hst12_h;
load hst13_h;
load hst14_h;
load hst15_h;
load hst16_h;
load hst17_h;
load hst18_h;
load hst19_h;
load hst20_h;
load hst21_h;
load blsz1_h;

tic

%=========================================

% DUALTREE2D' NİN ÇALIŞMASI

J=4;

[Faf,Fsf]=FSfarras;
[af,sf]=dualfilt1;

egtgiris=B16new;
```

```
egthedef=hst16_h;


% Eğitim için
w_egt=dualtree2D(egtgiris,J,Faf,af);
w_egitim1=w_egt{J+1}{1}+i.*w_egt{J+1}{2};
w_egitim=w_egitim1;

% Hedef için
w_hedefinp=dualtree2D(egthedef,J,Faf,af);
w_hedef1=w_hedefinp{J+1}{1}+i.*w_hedefinp{J+1}{2};
w_hedef=w_hedef1;

% %========================Test================
%
 testgiris=A5new;
 testhedef=nor5_h;

 % Test girişi için
 w_test=dualtree2D(testgiris,J,Faf,af);
 w_test1=w_test{J+1}{1}+i.*w_test{J+1}{2};
 w_test=w_test1;
%
 % Hedef için
 w_testhedefinp=dualtree2D(testhedef,J,Faf,af);
 w_testhedef1=w_testhedefinp{J+1}{1}+i.*w_testhedefinp{J+1}{2};
 w_testhedef=w_testhedef1;

%
=========================================================================
=================================================================

% CVNN nin parametrelerinin klavyeden girilmesi

% lr=input('Ogrenme oranini giriniz:');
% H=input('Gizli dügüm sayisini giriniz:');
% max_iter=input('Maximum iterasyon sayisini giriniz:');


% Bulunan optimum öğrenme oranı ve gizli düğüm sayıları

lr=0.00001;
H=2;
max_iter=20;

% cvnn_yeni dosyası KDDHYSA' yı çalıştırır

[hata,ckc,egitim_hatasi,tckc,test_hatasi]=cvnn_yeni(w_egitim,w_hedef
,lr,max_iter,H,w_test,w_testhedef);

sure=toc

% Hedef dosyasından görüntünün elde edilmesi

% J=4 icin
```

```
% egitim için

Z{5}{1}=real(ckc);
Z{5}{2}=imag(ckc);
Z{4}{1}=w_hedefinp{4}{1};
Z{4}{2}=w_hedefinp{4}{2};
Z{3}{1}=w_hedefinp{3}{1};
Z{3}{2}=w_hedefinp{3}{2};
Z{1}{1}=w_hedefinp{1}{1};
Z{1}{2}=w_hedefinp{1}{2};
Z{2}{2}=w_hedefinp{2}{2};
Z{2}{1}=w_hedefinp{2}{1};

% test için

K{5}{1}=real(tckc);
K{5}{2}=imag(tckc);
K{4}{1}=w_hedefinp{4}{1};
K{4}{2}=w_hedefinp{4}{2};
K{3}{1}=w_hedefinp{3}{1};
K{3}{2}=w_hedefinp{3}{2};
K{1}{1}=w_hedefinp{1}{1};
K{1}{2}=w_hedefinp{1}{2};
K{2}{2}=w_hedefinp{2}{2};
K{2}{1}=w_hedefinp{2}{1};

% J=3 icin

% Z{4}{1}=real(ckc);
% Z{4}{2}=imag(ckc);
% Z{3}{1}=w_hedefinp{3}{1};
% Z{3}{2}=w_hedefinp{3}{2};
% Z{2}{1}=w_hedefinp{2}{1};
% Z{2}{2}=w_hedefinp{2}{2};
% Z{1}{1}=w_hedefinp{1}{1};
% Z{1}{2}=w_hedefinp{1}{2};

% J=2 icin

% Z{3}{1}=real(ckc);
% Z{3}{2}=imag(ckc);
% Z{2}{1}=w_hedefinp{2}{1};
% Z{2}{2}=w_hedefinp{2}{2};
% Z{1}{1}=w_hedefinp{1}{1};
% Z{1}{2}=w_hedefinp{1}{2};


% J=1 icin

% Z{1}{1}=w_hedefinp{1}{1};
% Z{1}{2}=w_hedefinp{1}{2};
% Z{2}{1}=real(ckc);
% Z{2}{2}=imag(ckc);

% ters KDD alma işlemi
```

```
y=idualtree2D(Z,J,Fsf,sf);

y1=idualtree2D(K,J,Fsf,sf);

% sonucun eşikten geçirilmesi ve düzenlenmesi

bw1=im2bw(y,0.5);
bw2=bw1+B2new;

% EGITIM SINIFLANDIRMA SONUCUNUN INCELENMESI

% hedef ile elde edilen sonucun örtüştürülmesi

I1=egthedef;
I2=bw1+I1;

% dogru olarak belirlenen piksel sayısının belirlenmesi

egt_dogru=0;egt_yanlis=0;

for k=1:752
    for m=1:752
    if I1(m,k)-I2(m,k)==0
    egt_dogru=egt_dogru+1;
    else egt_yanlis=egt_yanlis+1;
    end
    end
end
egt_dogru
egt_yanlis
egt_toplam=egt_dogru+egt_yanlis

dogruluk=100*(egt_dogru/egt_toplam)



function
[hata,ckc,egitim_hatasi,tckc,test_hatasi]=cvnn_yeni(train_inp,desire
d_out,lr,max_iter,H,test,test_hedef)

randn('state',0)

%parametreler
G=size(train_inp,1); %giris katmani dugum sayisi
C=size(desired_out,1); %cikis sayisi
set_say=size(desired_out,2); %set sayisi

%baslangic agirliklari
for k=1:G
    for j=1:H
        whreal=randn(j,k);
        whimag=randn(j,k);
    end
end
wh=whreal+i*whimag;
for k=1:H
```

```
    for j=1:C
        wcreal=randn(j,k);
        wcimag=randn(j,k);
    end
end
wc=wcreal+i*wcimag;


for j=1:H
        bhreal(1:j,1)=1;
        bhimag(1:j,1)=1;
end
bh=bhreal+i*bhimag;
for j=1:C
        bcreal(1:j,1)=1;
        bcimag(1:j,1)=1;
end
bc=bcreal+i*bcimag;


%Gizli Katman ve cikis katmani icin
hlg=0; hlc=0;
ckg=0; ckc2=0;
n=1;
hlg=zeros(H,set_say);
hlc=zeros(H,set_say);
ckg=zeros(C,set_say);
ckc2=zeros(C,set_say);
hlcC=zeros(set_say,H);
inpC=zeros(set_say,G);


clear hata;

for n=1:max_iter
    for g=1:set_say

        %Gizli katman hesaplari
        hlg(:,g)=(wh*train_inp(:,g))+bh;
        hlgreal(:,g)=real(hlg(:,g));
        hlgimag(:,g)=imag(hlg(:,g));
        hlc(:,g)=logsig(hlgreal(:,g))+i*logsig(hlgimag(:,g));

        %Cikis katmani hesabi
        ckg(:,g)=(wc*hlc(:,g))+bc;
        ckgreal(:,g)=real(ckg(:,g));
        ckgimag(:,g)=imag(ckg(:,g));
        ckc(:,g)=logsig(ckgreal(:,g))+i*logsig(ckgimag(:,g));

        % güncellenen KDYSA ağırlıklarından HYSA parametrelerinin
alınması

        s=size(wh,1)*size(wh,2);

        wh(((s./2)-3):((s./2)+3));
```

```
        A0=wh((s./2)-3);
        A1=wh((s./2)-2);
        A2=wh((s./2)-1);
        A=[A2 A1 A2;A1 A0 A1;A2 A1 A2]

         B0=wh((s./2));
         B1=wh((s./2)+1);
         B2=wh((s./2)+2);
         B=[B2 B1 B2;B1 B0 B1;B2 B1 B2]

% KDYSA' dan alınan parametreler ile HYSA' nın birleştirilmesi ve
KDHHYSA' nın oluşturulması

I1=wh((s./2)+3)

        Vym1(:,g)=conv2(ckc(:,g),A,'same');
        Vum1(:,g)=conv2(desired_out(:,g),B,'same');
        Vxm1(:,g)=(Vym1(:,g)+Vum1(:,g))+I1;

        Vo(:,g)=logsig(Vxm1(:,g));
        Vo1(:,g)=Vo(:,g);



[wh,wc,bh,bc]=whc2_update_bias(ckg,Vo1,hlg,hlc,wh,wc,bh,bc,train_inp
,desired_out,lr,g,H,G);
    end

    %hata hesabi
        err=0;fark2=0;
        fark1=desired_out-ckc; fark2=desired_out-Vo1;farkT=fark2;
        farkTC=conj(fark2);
        err=(farkT.*farkTC);
        hata(n)=sqrt(sum(sum(err)));
        fprintf('iterasyon sayisi=%d, egt.hata=%f\n',n,hata(n));

        if n>1
          if hata(n)<(1e-5),break,end;% durdurma kriteri
        end
end

% figure
% plot(hata);grid
egitim_hatasi=(sqrt((sum(sum((farkT).*conj(farkT)))))/(set_say*C))*1
00
%egitim_hatasi=(sqrt((sum(sum((desired_out-ckc).*conj(desired_out-
ckc)))))/(set_say*C))*100

s=size(test_hedef,2); % test set sayisi

for m=1:s

        thlg(:,m)=(wh*test(:,m))+bh;
        thlgreal(:,m)=real(thlg(:,m));
        thlgimag(:,m)=imag(thlg(:,m));
        thlc(:,m)=logsig(thlgreal(:,m))+i*logsig(thlgimag(:,m));
```

```
        %Cikis katmani hesabi
        tckg(:,m)=(wc*thlc(:,m))+bc;
        tckgreal(:,m)=real(tckg(:,m));
        tckgimag(:,m)=imag(tckg(:,m));
        tckc(:,m)=logsig(tckgreal(:,m))+i*logsig(tckgimag(:,m));


 end

 test_hatasi=(sqrt((sum(sum((test_hedef-tckc).*conj(test_hedef-
tckc))))/(s*C))*100
```

EK 2: Nodül Sınıflama İçin Kompleks-Değerli Yapay Sinir Ağının Matlab Kodları

```
clc
clear all
close all

%=========NORMAL=========================================

a1=imread('A1.bmp');
a11=a1(1:752,1:752);
A1=graythresh(a11);
A1new=im2bw(a11,A1);

a2=imread('A2.bmp');
a22=a2(1:752,1:752);
A2=graythresh(a22);
A2new=im2bw(a22,A2);

a3=imread('A3.bmp');
a33=a3(1:752,1:752);
A3=graythresh(a33);
A3new=im2bw(a33,A3);

a4=imread('A4.bmp');
a44=a4(1:752,1:752);
A4=graythresh(a44);
A4new=im2bw(a44,A4);

a5=imread('A5.bmp');
a55=a5(1:752,1:752);
A5=graythresh(a55);
A5new=im2bw(a55,A5);

a6=imread('D1.bmp');
a66=a6(1:752,1:752);
A6=graythresh(a66);
A6new=im2bw(a66,A6);

a7=imread('G1.bmp');
a77=a7(1:752,1:752);
A7=graythresh(a77);
A7new=im2bw(a77,A7);

a9=imread('I1.bmp');
a99=a9(1:752,1:752);
A9=graythresh(a99);
A9new=im2bw(a99,A9);

a11=imread('M1.bmp');
a101=a11(1:752,1:752);
A11=graythresh(a101);
A11new=im2bw(a101,A11);

a13=imread('N1.bmp');
```

```
a103=a13(1:752,1:752);
A13=graythresh(a103);
A13new=im2bw(a103,A13);

%==========HASTA=============================================

b1=imread('A11.bmp');
b11=b1(1:752,1:752);
B1=graythresh(b11);
B1new=im2bw(b11,B1);

b2=imread('A12.bmp');
b22=b2(1:752,1:752);
B2=graythresh(b22);
B2new=im2bw(b22,B2);

b3=imread('B11.bmp');
b33=b3(1:752,1:752);
B3=graythresh(b33);
B3new=im2bw(b33,B3);

b4=imread('C11.bmp');
b44=b4(1:752,1:752);
b4=graythresh(b44);
B4new=im2bw(b44,b4);

b6=imread('E11.bmp');
b66=b6(1:752,1:752);
B6=graythresh(b66);
B6new=im2bw(b66,B6);

b7=imread('H11.bmp');
b77=b7(1:752,1:752);
B7=graythresh(b77);
B7new=im2bw(b77,B7);

b8=imread('H12.bmp');
b88=b8(1:752,1:752);
B8=graythresh(b88);
B8new=im2bw(b88,B8);

b11=imread('M11.bmp');
b101=b11(1:752,1:752);
B11=graythresh(b101);
B11new=im2bw(b101,B11);

b12=imread('M12.bmp');
b102=b12(1:752,1:752);
B12=graythresh(b102);
B12new=im2bw(b102,B12);

b15=imread('M13.bmp');
b105=b15(1:752,1:752);
B15=graythresh(b105);
B15new=im2bw(b105,B15);

b16=imread('M14.bmp');
```

```
b106=b16(1:752,1:752);
B16=graythresh(b106);
B16new=im2bw(b106,B16);

b17=imread('M16.bmp');
b107=b17(1:752,1:752);
B17=graythresh(b107);
B17new=im2bw(b107,B17);

b20=imread('M17.bmp');
b200=b20(1:752,1:752);
B20=graythresh(b200);
B20new=im2bw(b200,B20);

b23=imread('M18.bmp');
b203=b23(1:752,1:752);
B23=graythresh(b203);
B23new=im2bw(b203,B23);

b24=imread('N11.bmp');
b204=b24(1:752,1:752);
B24=graythresh(b204);
B24new=im2bw(b204,B24);

b25=imread('N12.bmp');
b205=b25(1:752,1:752);
B25=graythresh(b205);
B25new=im2bw(b205,B25);

b26=imread('O11.bmp');
b206=b26(1:752,1:752);
B26=graythresh(b206);
B26new=im2bw(b206,B26);

b27=imread('O12.bmp');
b207=b27(1:752,1:752);
B27=graythresh(b207);
B27new=im2bw(b207,B27);

b28=imread('S11.bmp');
b208=b28(1:752,1:752);
B28=graythresh(b208);
B28new=im2bw(b208,B28);

b29=imread('S12.bmp');
b209=b29(1:752,1:752);
B29=graythresh(b209);
B29new=im2bw(b209,B29);

b30=imread('S13.bmp');
b300=b30(1:752,1:752);
B30=graythresh(b300);
B30new=im2bw(b300,B30);

b31=imread('Y11.bmp');
b301=b31(1:752,1:752);
B31=graythresh(b301);
```

```
B31new=im2bw(b301,B31);

%=================================================================
=====

% DUALTREE2D' NİN ÇALIŞMASI
J=4;
[Faf,Fsf]=FSfarras;
[af,sf]=dualfilt1;

egtgirisn1=A1new;
w_egt1=dualtree2D(egtgirisn1,J,Faf,af);
w_egitim1=w_egt1{J+1}{1}+i.*w_egt1{J+1}{2};

egtgirisn2=A2new;
w_egt2=dualtree2D(egtgirisn2,J,Faf,af);
w_egitim2=w_egt2{J+1}{1}+i.*w_egt2{J+1}{2};

egtgirisn3=A3new;
w_egt3=dualtree2D(egtgirisn3,J,Faf,af);
w_egitim3=w_egt3{J+1}{1}+i.*w_egt3{J+1}{2};

egtgirisn4=A3new;
w_egt4=dualtree2D(egtgirisn4,J,Faf,af);
w_egitim4=w_egt4{J+1}{1}+i.*w_egt4{J+1}{2};

egtgirisn5=A5new;
w_egt5=dualtree2D(egtgirisn5,J,Faf,af);
w_egitim5=w_egt5{J+1}{1}+i.*w_egt5{J+1}{2};

egtgirisn6=A6new;
w_egt6=dualtree2D(egtgirisn6,J,Faf,af);
w_egitim6=w_egt6{J+1}{1}+i.*w_egt6{J+1}{2};

egtgirisn7=A7new;
w_egt7=dualtree2D(egtgirisn7,J,Faf,af);
w_egitim7=w_egt7{J+1}{1}+i.*w_egt7{J+1}{2};

egtgirisn9=A9new;
w_egt9=dualtree2D(egtgirisn9,J,Faf,af);
w_egitim9=w_egt9{J+1}{1}+i.*w_egt9{J+1}{2};

egtgirisn11=A11new;
w_egt11=dualtree2D(egtgirisn11,J,Faf,af);
w_egitim11=w_egt11{J+1}{1}+i.*w_egt11{J+1}{2};

egtgirisn13=A13new;
w_egt13=dualtree2D(egtgirisn13,J,Faf,af);
w_egitim13=w_egt13{J+1}{1}+i.*w_egt13{J+1}{2};

%========Hastalık için CWT dönüşümü==============================

egtgirish1=B1new;
w_egt15=dualtree2D(egtgirish1,J,Faf,af);
w_egitim15=w_egt15{J+1}{1}+i.*w_egt15{J+1}{2};
```

```
egtgirish2=B2new;
w_egt16=dualtree2D(egtgirish2,J,Faf,af);
w_egitim16=w_egt16{J+1}{1}+i.*w_egt16{J+1}{2};

egtgirish3=B3new;
w_egt17=dualtree2D(egtgirish3,J,Faf,af);
w_egitim17=w_egt17{J+1}{1}+i.*w_egt17{J+1}{2};

egtgirish4=B4new;
w_egt18=dualtree2D(egtgirish4,J,Faf,af);
w_egitim18=w_egt18{J+1}{1}+i.*w_egt18{J+1}{2};

egtgirish6=B6new;
w_egt20=dualtree2D(egtgirish6,J,Faf,af);
w_egitim20=w_egt20{J+1}{1}+i.*w_egt20{J+1}{2};

egtgirish7=B7new;
w_egt21=dualtree2D(egtgirish7,J,Faf,af);
w_egitim21=w_egt21{J+1}{1}+i.*w_egt21{J+1}{2};

egtgirish8=B8new;
w_egt22=dualtree2D(egtgirish8,J,Faf,af);
w_egitim22=w_egt22{J+1}{1}+i.*w_egt22{J+1}{2};

egtgirish11=B11new;
w_egt25=dualtree2D(egtgirish11,J,Faf,af);
w_egitim25=w_egt25{J+1}{1}+i.*w_egt25{J+1}{2};

egtgirish12=B12new;
w_egt26=dualtree2D(egtgirish12,J,Faf,af);
w_egitim26=w_egt26{J+1}{1}+i.*w_egt26{J+1}{2};

egtgirish15=B15new;
w_egt29=dualtree2D(egtgirish15,J,Faf,af);
w_egitim29=w_egt29{J+1}{1}+i.*w_egt29{J+1}{2};

egtgirish16=B16new;
w_egt30=dualtree2D(egtgirish16,J,Faf,af);
w_egitim30=w_egt30{J+1}{1}+i.*w_egt30{J+1}{2};

egtgirish17=B17new;
w_egt31=dualtree2D(egtgirish17,J,Faf,af);
w_egitim31=w_egt31{J+1}{1}+i.*w_egt31{J+1}{2};

egtgirish20=B20new;
w_egt34=dualtree2D(egtgirish20,J,Faf,af);
w_egitim34=w_egt34{J+1}{1}+i.*w_egt34{J+1}{2};

egtgirish23=B23new;
w_egt37=dualtree2D(egtgirish23,J,Faf,af);
w_egitim37=w_egt37{J+1}{1}+i.*w_egt37{J+1}{2};

egtgirish24=B24new;
w_egt38=dualtree2D(egtgirish24,J,Faf,af);
w_egitim38=w_egt38{J+1}{1}+i.*w_egt38{J+1}{2};
```

```
egtgirish25=B25new;
w_egt39=dualtree2D(egtgirish25,J,Faf,af);
w_egitim39=w_egt39{J+1}{1}+i.*w_egt39{J+1}{2};

egtgirish26=B26new;
w_egt40=dualtree2D(egtgirish26,J,Faf,af);
w_egitim40=w_egt40{J+1}{1}+i.*w_egt40{J+1}{2};

egtgirish27=B27new;
w_egt41=dualtree2D(egtgirish27,J,Faf,af);
w_egitim41=w_egt41{J+1}{1}+i.*w_egt41{J+1}{2};

egtgirish28=B28new;
w_egt42=dualtree2D(egtgirish28,J,Faf,af);
w_egitim42=w_egt42{J+1}{1}+i.*w_egt42{J+1}{2};

egtgirish29=B29new;
w_egt43=dualtree2D(egtgirish29,J,Faf,af);
w_egitim43=w_egt43{J+1}{1}+i.*w_egt43{J+1}{2};

egtgirish30=B30new;
w_egt44=dualtree2D(egtgirish30,J,Faf,af);
w_egitim44=w_egt44{J+1}{1}+i.*w_egt44{J+1}{2};

egtgirish31=B31new;
w_egt45=dualtree2D(egtgirish31,J,Faf,af);
w_egitim45=w_egt45{J+1}{1}+i.*w_egt45{J+1}{2};


%================İstatistiki Özelliklerin Çıkarılması===============

%==========Sütun Vektörü Haline Getirme İşlemi=====================

w1=w_egitim1(:);w2=w_egitim2(:);w3=w_egitim3(:);w4=w_egitim4(:);w5=w
_egitim5(:);w6=w_egitim6(:);w7=w_egitim7(:);
w9=w_egitim9(:);w11=w_egitim11(:);w13=w_egitim13(:);w15=w_egitim15(:
);w16=w_egitim16(:);
w17=w_egitim17(:);w18=w_egitim18(:);w20=w_egitim20(:);w21=w_egitim21
(:);w22=w_egitim22(:);
w25=w_egitim25(:);w26=w_egitim26(:);w29=w_egitim29(:);w30=w_egitim30
(:);w31=w_egitim31(:);w34=w_egitim34(:);w37=w_egitim37(:);w38=w_egit
im38(:);w39=w_egitim39(:);w40=w_egitim40(:);
w41=w_egitim41(:);w42=w_egitim42(:);w43=w_egitim43(:);w44=w_egitim44
(:);w45=w_egitim45(:);

%=========Ortalama,Max,Min,Std Özellikleri=========================

%============Sağlıklılar İçin Özellik Vektörünün Oluşturulması======

ort1=mean(w1);max1=max(w1);min1=min(w1);std1=std(w1)+i;oz1=[ort1;max
1;min1;std1];
ort2=mean(w2);max2=max(w2);min2=min(w2);std2=std(w2)+i;oz2=[ort2;max
2;min2;std2];
ort3=mean(w3);max3=max(w3);min3=min(w3);std3=std(w3)+i;oz3=[ort3;max
3;min3;std3];
```

```
ort4=mean(w4);max4=max(w4);min4=min(w4);std4=std(w4)+i;oz4=[ort4;max
4;min4;std4];
ort5=mean(w5);max5=max(w5);min5=min(w5);std5=std(w5)+i;oz5=[ort5;max
5;min5;std5];
ort6=mean(w6);max6=max(w6);min6=min(w6);std6=std(w6)+i;oz6=[ort6;max
6;min6;std6];
ort7=mean(w7);max7=max(w7);min7=min(w7);std7=std(w7)+i;oz7=[ort7;max
7;min7;std7];
ort9=mean(w9);max9=max(w9);min9=min(w9);std9=std(w9)+i;oz9=[ort9;max
9;min9;std9];
ort11=mean(w11);max11=max(w11);min11=min(w11);std11=std(w11)+i;oz11=
[ort11;max11;min11;std11];
ort13=mean(w13);max13=max(w13);min13=min(w13);std13=std(w13)+i;oz13=
[ort13;max13;min13;std13];


%==========Hastalar İçin Özellik Vektörünün Oluşturulması==========

ort15=mean(w15);max15=max(w15);min15=min(w15);std15=std(w15)+i;oz15=
[ort15;max15;min15;std15];
ort16=mean(w16);max16=max(w16);min16=min(w16);std16=std(w16)+i;oz16=
[ort16;max16;min16;std16];
ort17=mean(w17);max17=max(w17);min17=min(w17);std17=std(w17)+i;oz17=
[ort17;max17;min17;std17];
ort18=mean(w18);max18=max(w18);min18=min(w18);std18=std(w18)+i;oz18=
[ort18;max18;min18;std18];
ort20=mean(w20);max20=max(w20);min20=min(w20);std20=std(w20)+i;oz20=
[ort20;max20;min20;std20];
ort21=mean(w21);max21=max(w21);min21=min(w21);std21=std(w21)+i;oz21=
[ort21;max21;min21;std21];
ort22=mean(w22);max22=max(w22);min22=min(w22);std22=std(w22)+i;oz22=
[ort22;max22;min22;std22];
ort25=mean(w25);max25=max(w25);min25=min(w25);std25=std(w25)+i;oz25=
[ort25;max25;min25;std25];
ort26=mean(w26);max26=max(w26);min26=min(w26);std26=std(w26)+i;oz26=
[ort26;max26;min26;std26];
ort29=mean(w29);max29=max(w29);min29=min(w29);std29=std(w29)+i;oz29=
[ort29;max29;min29;std29];
ort30=mean(w30);max30=max(w30);min30=min(w30);std30=std(w30)+i;oz30=
[ort30;max30;min30;std30];
ort31=mean(w31);max31=max(w31);min31=min(w31);std31=std(w31)+i;oz31=
[ort31;max31;min31;std31];
ort34=mean(w34);max34=max(w34);min34=min(w34);std34=std(w34)+i;oz34=
[ort34;max34;min34;std34];
ort37=mean(w37);max37=max(w37);min37=min(w37);std37=std(w37)+i;oz37=
[ort37;max37;min37;std37];
ort38=mean(w38);max38=max(w38);min38=min(w38);std38=std(w38)+i;oz38=
[ort38;max38;min38;std38];
ort39=mean(w39);max39=max(w39);min39=min(w39);std39=std(w39)+i;oz39=
[ort39;max39;min39;std39];
ort40=mean(w40);max40=max(40);min40=min(w40);std40=std(w40)+i;oz40=[
ort40;max40;min40;std40];
ort41=mean(w41);max41=max(41);min41=min(w41);std41=std(w41)+i;oz41=[
ort41;max41;min41;std41];
ort42=mean(w42);max42=max(42);min42=min(w42);std42=std(w42)+i;oz42=[
ort42;max42;min42;std42];
ort43=mean(w43);max43=max(43);min43=min(w43);std43=std(w43)+i;oz43=[
ort43;max43;min43;std43];
```

```
ort44=mean(w44);max44=max(44);min44=min(w44);std44=std(w44)+i;oz44=[
ort44;max44;min44;std44];
ort45=mean(w45);max45=max(45);min45=min(w45);std45=std(w45)+i;oz45=[
ort45;max45;min45;std45];


% egitim ve test için girişler

giris_egt=[oz2 oz3 oz4 oz5 oz6 oz7 oz9 oz11 oz13 oz15 oz16 oz20 oz21
oz22 oz25 oz26 oz29 oz30 oz31 oz34 oz37 oz38 oz39 oz40 oz41 oz42
oz43 oz44 oz45];

giris_test=[oz1 oz17 oz18];

% egitim ve test için hedefler

desired_out_egt=zeros(1,29);
desired_out_egt(1,1:9)=i;
desired_out_egt(1,10:29)=1+i;

desired_out_test=zeros(1,3);
desired_out_test(1,1)=i;
desired_out_test(1,2:3)=1+i;

%=========================================================================

% CVNN nin parametrelerinin klavyeden girilmesi

lr=input('Ogrenme oranini giriniz:');

H=input('Gizli dügüm sayisini giriniz:');

max_iter=input('Maximum iterasyon sayisini giriniz:');


%=========================================================================

% CPU süresinin başlangıcı

tic

%================CVNN============================

[hata,ckc,egitim_hatasi,tckc,test_hatasi]=cvnn(giris_egt,desired_out
_egt,lr,max_iter,H,giris_test,desired_out_test);

sure=toc

% sonucların ekrana yazdırılması

sonuc_egt=[ckc.' desired_out_egt.'];
sonuc_test=[tckc.' desired_out_test.'];
sonuc_egt
sonuc_test
```

```
function
[hata,ckc,egitim_hatasi,tckc,test_hatasi]=cvnn(train_inp,desired_out
,lr,max_iter,H,test,test_hedef)

randn('state',0)

%parametreler
G=size(train_inp,1); %giris katmani dugum sayisi
C=size(desired_out,1); %cikis sayisi
set_say=size(desired_out,2); %set sayisi

%baslangic agirliklari
for k=1:G
    for j=1:H
        whreal=randn(j,k);
        whimag=randn(j,k);
    end
end
wh=whreal+i*whimag;
for k=1:H
    for j=1:C
        wcreal=randn(j,k);
        wcimag=randn(j,k);
    end
end
wc=wcreal+i*wcimag;


for j=1:H
        bhreal(1:j,1)=1;
        bhimag(1:j,1)=1;
end
bh=bhreal+i*bhimag;
for j=1:C
        bcreal(1:j,1)=1;
        bcimag(1:j,1)=1;
end
bc=bcreal+i*bcimag;


%Gizli Katman ve cikis katmani icin
hlg=0; hlc=0;
ckg=0; ckc2=0;
n=1;
hlg=zeros(H,set_say);
hlc=zeros(H,set_say);
ckg=zeros(C,set_say);
ckc2=zeros(C,set_say);
hlcC=zeros(set_say,H);
inpC=zeros(set_say,G);

clear hata;

for n=1:max_iter
    for g=1:set_say
```

```
        %Gizli katman hesaplari
        hlg(:,g)=(wh*train_inp(:,g))+bh;
        hlgreal(:,g)=real(hlg(:,g));
        hlgimag(:,g)=imag(hlg(:,g));
        hlc(:,g)=logsig(hlgreal(:,g))+i*logsig(hlgimag(:,g));

        %Cikis katmani hesabi
        ckg(:,g)=(wc*hlc(:,g))+bc;
        ckgreal(:,g)=real(ckg(:,g));
        ckgimag(:,g)=imag(ckg(:,g));
        ckc(:,g)=logsig(ckgreal(:,g))+i*logsig(ckgimag(:,g));


[wh,wc,bh,bc]=whc2_update_bias(ckg,ckc,hlg,hlc,wh,wc,bh,bc,train_inp
,desired_out,lr,g,H,G);

    end
    %hata hesabi
        err=0;
        fark=desired_out-ckc;
        farkC=conj(fark);
        err=(fark.*farkC);
        hata(n)=sqrt(sum(sum(err)));
        fprintf('iterasyon sayisi=%d, egt.hata=%f\n',n,hata(n));

        if n>1
          if hata(n)<(1e-5),break,end;% durdurma kriteri
        end
end

% figure
% plot(hata);grid
egitim_hatasi=(sqrt((sum(sum((desired_out-ckc).*conj(desired_out-
ckc)))))/(set_say*C))*100

s=size(test_hedef,2); % test set sayisi

for m=1:s

        thlg(:,m)=(wh*test(:,m))+bh;
        thlgreal(:,m)=real(thlg(:,m));
        thlgimag(:,m)=imag(thlg(:,m));
        thlc(:,m)=logsig(thlgreal(:,m))+i*logsig(thlgimag(:,m));

        %Cikis katmani hesabi
        tckg(:,m)=(wc*thlc(:,m))+bc;
        tckgreal(:,m)=real(tckg(:,m));
        tckgimag(:,m)=imag(tckg(:,m));
        tckc(:,m)=logsig(tckgreal(:,m))+i*logsig(tckgimag(:,m));
 end

 test_hatasi=(sqrt((sum(sum((test_hedef-tckc).*conj(test_hedef-
tckc)))))/(s*C))*100
```

EK 3: Akciğer Görüntülerinin Alındığı Philips MX-8000 BT Cihazı



