



T.C.

SELÇUK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

BT GÖRÜNTÜLERİNDEN SÜRRENAL LEZYONLARIN BELİRLENMESİ VE SINIFLANDIRILMASI

Hasan KOYUNCU

DOKTORA TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Mart-2018
KONYA
Her Hakkı Saklıdır

ÖZET

DOKTORA TEZİ

BT GÖRÜNTÜLERİNDEN SÜRRENAL LEZYONLARIN BELİRLENMESİ VE SINIFLANDIRILMASI

Hasan KOYUNCU

Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Rahime CEYLAN

2018, 150 Sayfa

Jüri
Dr. Öğr. Üyesi Rahime CEYLAN
Prof. Dr. Osman Nuri UÇAN
Prof. Dr. Salih GÜNEŞ
Doç. Dr. Seral ÖZŞEN
Dr. Öğr. Üyesi Hüseyin Oktay ALTUN

Sürrenal lezyonlar böbreküstü bezlerinde meydana gelen ve genellikle rastlantısal olarak tespit edilen tümör tipleridir. Sürrenal lezyonların tespitinde ve karakterizasyonunda genellikle Bilgisayarlı Tomografi (BT) görüntüleme ve biyopsiden faydalanılır. Ancak sürrenal lezyonların anatomik konumu nedeniyle biyopsi işlemi oldukça zordur. Bu durum, bir Bilgisayar Destekli Teşhis (BDT) sisteminin gerekliliğini ortaya koymaktadır. Gerçekleştirilen tez çalışmasında, sürrenal lezyonların tespiti ve karakterizasyonu için bir BDT sistemi tasarlanmıştır. Tasarlanan BDT sistemi; abdomen segmentasyonu, gürültü ve yağ dokusu eliminasyonu, lezyon segmentasyonu ve lezyon sınıflandırma olmak üzere 4 aşamadan oluşmaktadır. Tez çalışması, Selçuk Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalı' ndan alınan 98 BT görüntüsü ile gerçekleştirilmiştir. Önerilen BDT sisteminin abdomen segmentasyonu aşamasında eğitim, test ve validasyon veri setlerinde sırasıyla %99.21, %99.54 ve %99.78 ortalama doğruluk değerleri elde edilmiştir. Gürültü eliminasyonu aşamasında literatürdeki farklı yöntemler karşılaştırılmış ve en iyi sonuç (%93.16 doğruluk) Blok Eşleştirme & 3B Filtreleme (BE3BF) algoritması ile bulunmuştur. Yağ dokusu ve gürültü eliminasyonu aşamasında literatüre göre 0.157 dB üstünlük sağlanmıştır. Sürrenal lezyonların segmentasyonu için önerilen sistem ile %83.06 Dice, %86.44 duyarlılık ve %99.66 özgüllük oranlarına ulaşılmıştır. Ayrıca önerilen BDT sisteminin son aşaması olan sürrenal lezyonların sınıflandırılmasında, dalgacık transformu ve optimizasyon temelli yapay sinir ağı ile %80.70 doğruluk ve %75 duyarlılık elde edilmiştir.

Anahtar Kelimeler: Sürrenal Lezyon, Bilgisayarlı Tomografi, Gürültü Giderme, Yağ Dokusu Eliminasyonu, Abdomen Segmentasyonu, Lezyon Segmentasyonu, Hibrit Sınıflandırıcı

ABSTRACT

Ph.D THESIS

DETECTION AND CLASSIFICATION OF ADRENAL LESIONS BY USING CT IMAGES

Hasan KOYUNCU

The Graduate School of Natural and Applied Science of Selçuk University
The Degree of Doctor of Philosophy in Electrical & Electronics Engineering

Advisor: Asst. Prof. Dr. Rahime CEYLAN

2018, 150 Pages

Jury
Asst. Prof. Dr. Rahime CEYLAN
Prof. Dr. Osman Nuri UÇAN
Prof. Dr. Salih GÜNEŞ
Assoc. Prof. Dr. Seral ÖZŞEN
Asst. Prof. Dr. Hüseyin Oktay ALTUN

Adrenal lesions are the tumor types occurring on adrenal glands, and often being detected as coincidentally. Computed Tomography (CT) scan and biopsy process are generally utilized on the detection and characterization of adrenal lesions. However, the biopsy process stays as a challenging task due to the anatomical location of lesions. This situation reveals the necessity of a Computer Aided Diagnosis (CAD) system. In doctoral thesis, a CAD system was designed to detect and characterize the adrenal lesions. Proposed CAD system was designed on 4 steps that are abdomen segmentation, noise and fat tissue elimination, lesion segmentation and lesion classification. The study was realized using 98 CT images taken from Radiology Department of Medicine Faculty at Selcuk University. Abdomen segmentation system achieved the average accuracy rates as %99.21 (training), %99.54 (test) and %99.78 (validation). Different techniques were compared on the noise elimination, and the best result (%93.16 accuracy) was obtained by Block Matching & 3D Filtering (BM3D) algorithm. On the noise and fat tissue elimination, proposed system outperformed to the literature by achieving 0.157 dB higher result. Lesion segmentation system obtained %83.06 Dice, %86.44 sensitivity and %99.66 specificity rates. At the last step of CAD system, proposed method including wavelet transform and optimized neural network, achieved %80.70 accuracy and %75 sensitivity rates on the classification of adrenal lesions.

Keywords: Adrenal Lesion, Computed Tomography, Denoising, Fat Tissue Elimination, Abdomen Segmentation, Lesion Segmentation, Hybrid Classifier

ÖNSÖZ

Bütün çalışmalarımda değerli bilgi ve tecrübeleriyle bana yol gösteren, gerekli araştırma ve geliştirme çabalarımda yardımlarını esirgemeyen danışmanım Selçuk Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği öğretim üyesi Dr. Öğr. Üyesi Rahime CEYLAN hocama, her türlü maddi ve manevi katkılarını esirgemeyen aileme, 2211-A Genel Yurt İçi Doktora Burs Programı kapsamında doktora çalışmalarımı destekleyen Türkiye Bilimsel ve Teknik Araştırma Kurumu (TÜBİTAK)' na teşekkürü bir borç bilirim.

Hasan KOYUNCU
KONYA-2018

İÇİNDEKİLER

ÖZET ..... **iv**

ABSTRACT ..... **v**

ÖNSÖZ ..... **vi**

İÇİNDEKİLER ..... **vii**

SİMGELER VE KISALTMALAR ..... **ix**

1. GİRİŞ **1**

2. KAYNAK ARAŞTIRMASI **6**

2.1. Sürrenal Bez ve Lezyonlarda BT Kullanımı Üzerine Literatür Çalışmaları 6
2.2. BT Görüntülerinde Gürültü Giderme Üzerine Literatür Çalışmaları 8
2.3. Gaussian Gürültü Eliminasyonu Üzerine Literatür Çalışmaları 11
2.4. BT Görüntülerinde Yağ Dokusu Eliminasyonu Üzerine Literatür Çalışmaları .. 13
2.5. Sürrenal Lezyon Segmentasyonu Üzerine Literatür Çalışmaları 15
2.6. Sürrenal Lezyonların Sınıflandırılması Üzerine Literatür Çalışmaları 17
2.7. Kaynak Araştırması Özeti 18

3. MATERYAL VE YÖNTEM **20**

3.1. Kullanılan Veri Seti Özellikleri 20
3.2. Abdomen Segmentasyonunda Kullanılan Metotlar 24
3.2.1. En geniş obje bulucu 25
3.2.2. Görüntü genişletme 27
3.2.3. Medyan filtre 27
3.2.4. Eğim genliği algoritması 27
3.2.5. Kontrast sınırlı - adaptif histogram eşitleme 28
3.2.6. Uzamsal bulanık-c ortalamalar 28
3.2.7. Morfolojik kapama algoritması 29
3.2.8. Sıfır-geçiş eliminatörü 30
3.3. Gaussian Gürültü Eliminasyonunda Kullanılan Metotlar 31
3.3.1. Blok eşleme ve 3B filtreme (BE3BF) algoritması 32
3.4. Görüntü İyileştirme Çalışmasında Kullanılan Metotlar 34
3.4.1. Hızlı bağlantılı - vuru kortikal modeli 35
3.4.2. Otsu eşikleme algoritması 37
3.5. Sürrrenal Lezyon Segmentasyonunda Kullanılan Metotlar 38
3.5.1. Dörtlü ağaç ayrıştırma tabanlı bölme ve birleştirme yöntemi 39
3.5.2. Ortalama kayma segmentasyon tekniği 40
3.5.3. Geniş gri değer eliminatörü 41
3.5.4. Büyüyen alan algoritması 42
3.6. Sürrenal Lezyonların Sınıflandırılmasında Kullanılan Metotlar 43
3.6.1. Özellik çıkarma aşamasında kullanılan metotlar 43
3.6.2. Sınıflandırmada kullanılan optimizasyon algoritmaları 46
3.6.2.1. Parçacık sürü optimizasyonu 47

3.6.2.2. Yapay arı kolonisi algoritması 48
3.6.2.3. Kâşif parçacık sürü optimizasyonu 49
3.6.3. Optimize YSA metotları ve Sınırlı PSO-YSA tekniği 50

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA 53

4.1. Çalışmada Kullanılan İstatistiksel Metrikler 53
4.2. Abdomen Segmentasyon Çalışması 57
4.2.1. Abdomen segmentasyon sistemi 59
4.2.2. AbSeg sistemine dair parametre ayarlamaları 62
4.2.3. AbSeg ile elde edilen deneysel sonuçlar ve istatistiksel analiz 66
4.2.4. Görsel sonuçlar ve analiz 70
4.3. Gürültü Eliminasyonu Çalışması 71
4.3.1. TİB metriği tabanlı karşılaştırma 82
4.3.2. Ortalama DSGO değerleri üzerinden karşılaştırma 83
4.3.3. Bütün bir abdomen üzerinden görsel çıkış tabanlı karşılaştırma 87
4.3.4. ROI üzerinden DSGO metriği ve görsel çıkış tabanlı karşılaştırmalar 88
4.3.5. CPU işlem süresi üzerinden karşılaştırma 90
4.3.6. Hesaplama maliyeti üzerinden karşılaştırma 91
4.3.7. Gürültü eliminasyonu için sonuçların özetlenmesi 92
4.4. Görüntü İyileştirme Çalışması 93
4.4.1. Görüntü iyileştirme sistemi 93
4.4.2. Deneysel sonuçlar ve istatistiksel analiz 95
4.4.3. Görsel sonuçlar ve analiz 97
4.5. Sürrenal Lezyon Segmentasyonu Çalışması 100
4.5.1. Sürrenal lezyon segmentasyon sistemi 102
4.5.2. ATUS parametre ayarlamaları, deneysel sonuçlar ve istatistiksel analiz 105
4.5.3. Görsel sonuçlar ve analiz 110
4.6. Sürrenal Lezyon Sınıflandırma Çalışması 114
4.6.1. Literatürde kullanılan etkin özellikler ve sınıflayıcılar 117
4.6.2. Özellik çıkarma tabanlı işlemler 118
4.6.3. Deneysel sonuçlar ve istatistiksel analiz 119

5. SONUÇLAR VE ÖNERİLER 126

5.1 Sonuçlar 126
5.2 Öneriler 129

KAYNAKLAR 130

EKLER 136

ÖZGEÇMİŞ 137

SİMGELER VE KISALTMALAR

Simgeler

$f_{görüntü}$: LDOG içerisindeki orijinal görüntü
$g_{görüntü}$: LDOG çıkışında elde edilen kontrastı iyileştirilmiş görüntü
a & b : LDOG kapsamında kontrast seviyesini düzenleyen parametreler
$A \oplus B$: Görüntü genişletme işlemi
$A \bullet B$: Morfolojik kapama
θB : Erozyon işlemi
D_B : Yapı elemanı domeni
A : Görüntü genişletme kapsamında orijinal görüntü
B : Görüntü genişletme kapsamında yapı elemanı
u_{ij} : UBCO algoritması içerisinde üyelikler
v_i : UBCO algoritması içerisinde merkezler
$NB(x_j)$: x_j pikseli üzerinde kare şeklinde bir pencere
h_{ij} : Piksel değerlerinin hangi kümeye ait olduğuna dair olasılık hesabı
$U_{ij}(n)$: İterasyon n olduğu durumda, (i,j) koordinatlarındaki nöronun zar potansiyeli
$U_{ij}(0)$: Zar potansiyelinin başlangıçtaki durumu
S_{ij} : (i,j) koordinatlarındaki nöron üzerine uygulanan harici etki
$\Theta_{ij}(n)$: Eşik değeri
$\Theta_{ij}(0)$: Başlangıç eşik değeri
$Y_{ij}(n)$: Çıkışta üretilen vuru
p_i : $i.$ gri seviye değerinin histogram üzerinden meydana gelme olasılığı
t : Eşik (threshold) değeri
$\sigma_B^2(t)$: Sınıflar arası varyans
μ : Ortalama değer
w : Olasılık dağılımlarının tespitinde kullanılan ağırlık değerleri
x^s : OKS algoritması kapsamında özellik vektörünün uzamsal bölümü
x^r : OKS algoritması kapsamında özellik vektörünün aralık bölümü
$k(x)$: OKS algoritması içindeki genel profili
C : OKS kapsamında normalizasyon sabiti
p : OKS kapsamında görüntü piksellerinin boyutu
h_r : Aralık kerneli band genişliği
h_s : Uzamsal kernel band genişliği
M : Yakınsama kriteri eşiği
H(g) : Gri değer olasılıkları
p(i,j) : Gri değer olasılıkları
σ : Standart sapma
d : Eş-oluşum matrisleri içerisindeki i ve j pikselleri arası mesafe
Θ : Eş-oluşum matrisleri içerisindeki i ve j piksellerinin incelenmesinde yön açısı
σ^2 : Varyans
ω : Atalet ağırlığı
c_1 & c_2 : Hızlandırma katsayıları
r_1 ve r_2: [0,1] aralığında rasgele üretilen sabitler
$V_i(t)$: Önceki sürat değeri
$X_i(t)$: Önceki konum değeri
$X_{pbest(i)}(t)$: $i.$ parçacığa ait bireysel en iyi konum değeri
$X_{gbest}(t)$: Bütün sürüye dair en iyi (global) konum değeri
$V_i(t+1)$: Yeni sürat değeri

$X_i(t+1)$: Yeni konum değeri
x_{mi} : Yiyecek kaynakları
x_m : Yiyecek kaynakları
u_i : Parçacık değerlerine dair üst limit
l_i : Parçacık değerlerine dair alt limit
$rand(0,1)$: [0,1] aralığında üretilen rasgele değişken
v_{mi} : Yeni yiyecek kaynakları
$fit_m(x_m)$: Yiyecek kaynaklarına dair uygunluk değeri
ϕ : [-1,1] aralığında üretilen rasgele bir sabit
$f_m(x_m)$: Uygunluk değerinin hesabında işletilecek olan hata oranı
MAX_I : Orijinal görüntü içindeki maksimum gri seviye değeri
$I(i,j)$: Orijinal görüntü
$\hat{I}(i,j)$: Yeniden yapılandırılan görüntü
σ_{xy} : x ve y arası kovaryans
t_i : Elde edilmesi gereken çıkış
o_i : Elde edilen çıkış
$KOH_{görüntü}$: Orijinal görüntü ile yeniden yapılandırılan görüntü arası KOH değeri
v' : Normalizasyon çıkışı
max_A : A özelliği içerisindeki maksimum değer
min_A : A özelliği içerisindeki minimum değer
new_max_A : A özelliği içerisinde yeni maksimum değer
new_min_A : A özelliği içerisinde yeni minimum değer

Kısaltmalar

AB-BYOO	: Artefakt Baskılayan-Büyük Ölçekli Yerel Olmayan Ortalamalar
ADD	: Ayrık Dalgacık Dönüşümü
AHE	: Adaptif Histogram Eşitleme
AKD	: Ayrık Kosinüs Dönüşümü
AKD-S	: Ayrık Kosinüs Dönüşümü tabanlı Sözlük
AS	: Adaptif Sözlük
ADK	: Alan Tabanlı Düzey Kümesi
ADMIRE	: Advanced Modeled Iterative Reconstruction
AUC	: İşlem Karakteristik Eğrisi altında kalan Alan
BA	: Büyüyen Alan
BDT	: Bilgisayar Destekli Teşhis
BE3BF	: Blok Eşleştirme ve 3B Filtreleme
BT	: Bilgisayarlı Tomografi
BYOO	: Büyük Ölçekli Yerel Olmayan Ortalamalar
ÇDGG	: Çift Domende Gürültü Giderme
DAA-BB	: Dörtlü Ağaç Ayrıştırma Tabanlı Bölme & Birleştirme
DDD	: Durağan Dalgacık Dönüşümü
DDM-TDA	: Tekil Değer Ayrışımı içeren Düşük Dereceli Model
DICOM	: Digital Imaging and Communications in Medicine
DN	: Doğru Negatif
DP	: Doğru Pozitif
DSGO	: Doruk Sinyal Gürültü Oranı
EAK	: Eş Zamanlı Öğrenen Ayrık Kodlama
EBGG	: Eklenebilir Beyaz Gauss Gürültüsü
GDE	: Geniş Gri Değer Eliminatörü
GDEM	: Gri Düzey Eş Oluşum Matrisi
GKM	: Gaussian Karışım Modeli
GOB	: En Geniş Obje Bulucu
GÖ	: GDEM Özellikleri
GSR	: Gaussian Süreç Regresyonu
GMVKÖ	: Genelleştirilmiş Matris Vektör Kuantalamalı Öğrenme
GVKÖ	: Genelleştirilmiş Vektör Kuantalamalı Öğrenme
HB-VKM	: Hızlı Bağlantılı-Vuru Kortikal Modeli
HÖ	: Histogram Özellikleri
HU	: Hounsfield Unit
İK	: İlerleyen Küpler
KOH	: Karesel Ortalama Hata
KPSO	: Kâşif Parçacık Sürü Optimizasyonu
KSA	: Konvolüsyonel Sinir Ağları
KS-AHE	: Kontrast-Sınırlı Adaptif Histogram Eşitleme
K-TDA	: K-Tekil Değer Ayrışımı
LDOG	: Logaritmik Doğrusal Olmayan Germe
LPY-GAK	: Lokal Polinomal Yaklaşım-Güven Aralıklarının Kesişimi
MİB	: Merkezi İşlem Birimi
MİÖ	: Matris İlgili Öğrenme
Mikro-BT	: Mikro Bilgisayarlı Tomografi
MR	: Manyetik Rezonans
NM	: Norm Minimizasyonu

OKS	: Ortalama Kayma Segmentasyonu
OYLB-GKM	: Olası Yama Logaritmik Benzerliği-Gaussian Karışım Modeli
PACS	: Picture Archiving and Communication Systems
PSO	: Parçacık Sürü Optimizasyonu
ROI	: Region of Interest
ŞA-AKD	: Nokta tabanlı Şekle Adaptif Ayrık Kosinüs Dönüşümü
SGO	: Sinyal Gürültü Oranı
TBA	: Temel Bileşen Analizi
TİB	: Toplam İstatistiksel Başarı
TVM	: Toplam Varyasyon Minimizasyonu
UBCO	: Uzamsal Bulanık C-Ortalamalar
VKM	: Vuru Kortikal Modeli
VKÖ	: Vektör Kuantalamalı Öğrenme
YADK	: Yerel Alan Tabanlı Düzey Kümesi
YAKA	: Yapay Arı Kolonisi Algoritması
YBİ	: Yapısal Benzerlik İndeksi
YGTBA	: Yama Tabanlı Global Temel Bileşen Analizi
YHTBA	: Yama Tabanlı Hiyerarşik Temel Bileşen Analizi
YLTBA	: Yama Tabanlı Lokal Temel Bileşen Analizi
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Sürrenal bezler böbrek üstünde yer alan üçgen piramit benzeri organlardır. Sürrenal bezler, *korteks* olarak ifade edilen bir dış tabaka ve *medulla* adı verilen bir iç tabakadan meydana gelir. İnsan vücudu için hayati önem arz eden hormonların büyük bir bölümü sürrenal bezlerden salgılanır. Korteks tabakasında *kortizol* ve *aldosteron*, medulla tabakasında ise *epinefrin* ve *norepinefrin* hormonları salgılanır. Sürrenal bezler, belirtilen dört adet hormonun yanı sıra cinsiyet hormonlarını da salgılar.

Sürrenal bezlerde meydana gelen lezyon(lar) *sürrenal lezyon* olarak isimlendirilir ve bu lezyon türleri genel olarak iki farklı özelliğe göre incelenir. Bunlardan birincisi fonksiyonel özellik, ikincisi ise iyi huylu-kötü huylu karakter durumudur. Fonksiyonel olan lezyonlar belirli hormon(lar) salgılarken, fonksiyonel olmayan lezyonlar hormon salgılamazlar. Fonksiyonel tümörlerin tespitinde hormonal değişimlerin meydana getireceği etkenler, lezyonun türü hakkında ayrıntılı bilgi ihtiva etmektedir. Ancak fonksiyonel olmayan lezyonların tür tahmininde, söz konusu lezyonların hormon salgılamamalarından dolayı kitleye dair özellikler önemlidir. Sürrenal lezyonlar, iyi huylu (benign) ve kötü huylu (malign) olarak karakterize edilir. Lezyon türünün belirlenmesinde lezyon boyutu, lezyon yoğunluğu ve lezyonun çevre dokularla ilişkisi incelenir.

Sürrenal lezyonların tespitinde ve karakterizasyonunda en sık kullanılan görüntüleme tekniği Bilgisayarlı Tomografi (BT)' dir. BT görüntülerinden net bilgi elde edilemediği durumda Dinamik BT' ye başvurulur. Dinamik BT' de hastaya kontrollü bir şekilde kontrast madde verilirken, lezyonun kontrast tutulumu ve diğer etkenler (boyut, yoğunluk, çevre dokularla olan ilişki) analiz edilir. Dinamik BT tarama, kontrast madde tabanlı görünümün lezyona dair ayrıntılı bilgi ihtiva etmesinden dolayı, lezyonun karakterize edilmesinde kullanılır.

Literatür çalışmalarından elde edilen bulgulara göre, lezyon karakterizasyonunda görüntüleme tekniklerinin etkisiz kaldığı durumlarda veya nihai kararın doğrulanmasında biyopsiye başvurulmaktadır. Sürrenal bezler dalak ile karaciğer arasında, omurilik kemiğinin ön bölümündedir. Bu bezler, abdomenin en dış kısmında yer alan kaburga kemikleri ile çevrelenmektedir. Diğer bir deyişle etrafı organ ve kemiksi dokular ile çevrilmiş durumdadır. Bu durum, lezyonun karakterizasyonu için yapılan biyopsi sırasında büyük bir dezavantaj oluşturmaktadır. Sürrenal bezlere biyopsi uygulanırken hastanın nefes alıp-verme durumunun doktor kontrolünde

gerçekleştirilmesi, diyaframın alacağı duruma göre biyopsi iğnesinin sürrenal bezlere ulaşması amaçlanır. Ancak, hastanın nefes alıp-verme işleminin düzgün bir şekilde gerçekleştirilmemesi halinde biyopsi işlemi sonucunda elde edilen parça, gerekli doku harici bir bölgeden alınabilmektedir. İstenilen bölge dâhilinde yapılamayan biyopsi, hem teşhis açısından yanlış bir kararı beraberinde getirmektedir, hem de tekrarlanması durumunda meydana gelebilecek komplikasyon ve yaralanmalar nedeniyle hasta için risk barındırmaktadır. Bu nedenle görüntülenme sırasında alınacak doğru ve net karar, hasta için hayati öneme sahiptir.

Tez çalışması kapsamında sürrenal bezlerde meydana gelen lezyonların, BT görüntülerinden tespiti ve sınıflandırılması gerçekleştirilmiştir. Bu amaçla, 4 aşamadan oluşan bir Bilgisayar Destekli Teşhis (BDT) sistemi sunulmuştur. Gerçekleştirilen BDT sistemi ile aşağıda belirtilen dezavantajların elimine edilmesi amaçlanmıştır:

- Birden fazla tarama tekniği kullanımı kaynaklı zaman kaybı ve iş yükü
- Tekrarlı ve yanlış biyopsi
- Biyopsi ve devamındaki cerrahi işlemler esnasında meydana gelebilecek komplikasyonlar

Söz konusu BDT sistemi 4 temel aşamadan oluşmaktadır. Bu aşamalar şu şekilde sıralanabilir:

1. Abdomen segmentasyonu
2. Görüntü iyileştirme (Gürültü giderme ve yağ dokusu eliminasyonu)
3. Sürrenal lezyon segmentasyonu
4. Sürrenal lezyona dair özellik çıkarma-sınıflandırma

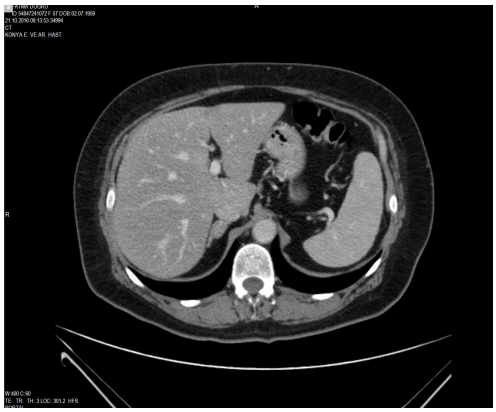
Söz konusu aşamaların gerçekleştirilmesi ile tıp uzmanlarına karar aşamasında yardımcı olabilecek bir sistem tasarımı amaçlanmıştır. Böylece hızlı ve doğru teşhise yardımcı, biyopsi gerçekleştirilmeden önce lezyon özellikleri hakkında bilgi verebilecek (iyi huylu / kötü huylu ayrımı yapabilecek) bir BDT sistemi sunulmuştur. Tasarlanan BDT sistemi sayesinde lezyonların erken aşamada teşhis edilebilmesi ve böylece kötü huylu lezyonlara hızlı müdahale edilebilmesi önerilen BDT sisteminin başlıca avantajlarındandır.

Sürrenal lezyonlar görünüm bakımından birbirinden veya görüntü arka planından farklı olabileceği gibi, bu durumun tam tersi (arka plan veya diğer lezyon türleri ile benzerliklerin olması) de söz konusudur. Dinamik BT görüntülerinde arka plandan farklı olan, ancak heterojen (farklı gri seviyelerde) görünüm ihtiva eden lezyonların ve arkaplan ile benzer görünüme sahip lezyonların tam anlamıyla segmente edilebilmesi, birçok görüntü işleme algoritmasının birarada kullanımını gerektirmektedir.

Tez çalışmasında kullanılan Dinamik BT görüntüleri, segmentasyon ve sınıflandırma çalışmalarını negatif yönde etkileyecek olan farklı dezavantajlara sahiptir. Bu dezavantajlar şu şekilde sıralanabilir:

- Orantısız abdomen boyutları,
- Kenar bilgisi zayıf abdomen,
- BT yatağı görüntüsü,
- Hasta bilgileri,
- Dar histogram,
- Zayıf kontrast,
- Gürültü,
- Yağ dokusu,
- Kontrast madde tutulumu zayıf lezyonlar,
- Diğer organ veya dokulara yapışık görünen lezyonlar,
- Hem homojen hem de heterojen yapıda lezyonların mevcut olması,
- Farklı tür lezyonlarda benzer şekil, boyut ve yoğunluk özelliklerinin mevcut olması,
- Aynı tür lezyonların çok farklı şekil, boyut ve yoğunluk özellikleri ihtiva etmesi.

Bu dezavantajların bazılarını içeren örnek BT görüntüleri Şekil 1.1’ de sunulmuştur.



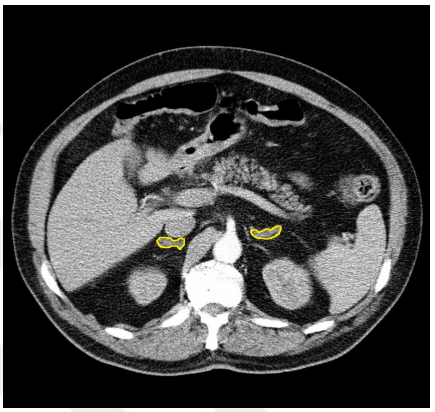
a-) BT yatağı ve hasta bilgilerinin yer aldığı görüntü



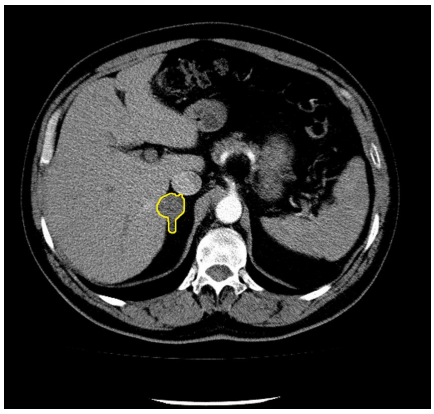
b-) Kenar bilgisi süreksiz abdomen



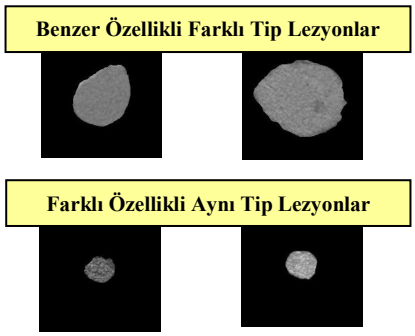
c-) Belirgin yağ dokusu ve gürültü içeren abdomen



d-) Kontrast madde tutulumu zayıf lezyonlar



e-) Yapışık lezyon içeren görüntü



f-) Morfoloji ve yoğunluk ile ilgili handikaplar

Şekil 1.1. Sürrenal lezyonları belirlenmesinde dezavantaj içeren farklı BT görüntüleri

Tasarlanacak olan BDT yapısı içindeki ilk aşama, orantısız boyutlara sahip abdomen bölümlerini segmente edebilecek ve diğer dezavantajlardan etkilenmeyecek bir abdomen segmentasyon sisteminin geliştirilmesidir. Böylece abdomen için standart bir boyut elde edilecektir. İkinci aşama, görüntüdeki gürültülerin ve yağ dokusunun eliminasyonudur. Gürültü ve yağ dokusu eliminasyonu sonucunda elde edilen görüntü,

segmentasyon ve sınıflama için hazırdır. Lezyon segmentasyonu için önerilen algoritma, bütün görüntü tiplerinde (diğer organ ve dokulara yapışık görünümde olan lezyonlar, açık lezyonlar, büyük tekil lezyonlar ve kontrast tutulumu zayıf lezyonlar) sonuç elde edebilmelidir. Ayrıca söz konusu sistemin hem homojen hem de heterojen lezyon türlerinde etkin olarak işlem yapabilmesi gerekmektedir. Özellik çıkarma-sınıflandırma bölümünde, farklı tür lezyonların benzer morfolojik ve yoğunluk özellikleri barındırabildiği gibi, aynı tür lezyonların farklı morfolojik ve yoğunluk özellikleri ihtiva edebildiği de göz önünde bulundurulmalıdır.

2. KAYNAK ARAŞTIRMASI

Bu çalışmada; BT ve Dinamik BT görüntülerinden sürrenal lezyonların tespiti ve sınıflandırılması için 4 temel aşamadan oluşan bir BDT sistemi tasarlanmıştır. Bu aşamalar; abdomen segmentasyonu, gürültü ve yağ dokusu eliminasyonu, sürrenal lezyon segmentasyonu ve özellik çıkarma-sınıflandırma şeklindedir. Çalışmada sunulan abdomen segmentasyonu, literatürde ilk kez gerçekleştirildiğinden konu ile ilgili literatür taramasına yer verilememiştir.

2.1. Sürrenal Bez ve Lezyonlarda BT Kullanımı Üzerine Literatür Çalışmaları

Literatür çalışmaları incelendiğinde sürrenal lezyonların tespiti ve tür tahmininde kullanılan tarama yöntemlerinin ultrasonografi, MR ve BT olduğu görülmüştür.

Masumori ve ark. (1998) sürrenal ve retroperitoneal (karınzarı ardı) lezyonların tespitinde ultrasonografi ve BT cihazlarını kullanmışlardır. Elde edilen bulgulara göre BT ile gerçekleştirilen teşhislerin, ultrasonografi ile gerçekleştirilen teşhislerden daha yüksek doğruluğa sahip olduğu tespit edilmiştir.

Ayres ve ark. (2004) sürrenal lezyonların özel bir tipi olan nöroblastoma üzerine ayrıntılı bir çalışma gerçekleştirmişlerdir. Çalışmada kemoterapi öncesi ve sonrasında, lezyonun dokusal bileşimi hakkında tahmin yapmayı amaçlayan bir teknik tasarlanmıştır. Bu amaçla 4 hastaya ait 10 adet BT görüntüsü, Gaussian Karışım Modeli (GKM) temelli bir algoritmaya tabi tutulmuştur. Yapılan çalışmalar neticesinde tekniğin kemoterapi sonrasında, dokunun hangi aşamada olduğu hakkında bilgi verebileceği öne sürülmüştür. Diğer bir deyişle, hastanın tedaviye verdiği cevap algoritma vasıtasıyla elde edilmeye çalışılmıştır.

Kirshtein ve ark. (2007), 13 adet travma hastasına ait sürrenal bulguları inceleyerek kötü huylu feokromositoma tespiti yapmışlardır. Çalışma neticesinde, incidentalomas olarak işlenen lezyonlar için feokromositoma tetkikinin gerekli olduğu görülmüştür. 13 adet hastadan 5 tanesine ultrasonografi, 2 tanesine sintigrafi, 7 tanesine MR taraması yapılırken, hastaların hepsine BT taraması uygulanmıştır.

Hishiki ve ark. (2008), yeni doğan bir kız çocuğunda gerçekleştirilen biyokimyasal testler neticesinde, 17-hydroxyprogesterone hormonunun yüksek seviyede olduğunu tespit ederek, BT ve ultrasonografi taramalarına başvurmuşlardır.

Görüntüleme neticesinde hastada adrenokortikal tümör tespit edilmiştir. Çalışma sonucunda biyokimyasal test ve görüntüleme yöntemlerinin (BT & ultrasonografi) birlikte kullanımı sayesinde, teşhis işleminin daha hızlı gerçekleştiği öne sürülmüştür.

Narang ve ark. (2009) çalışmalarında 50 yaşında histoplazmoz teşhisi belirtilen birey için birçok görüntüleme tekniğine ve biyopsiye başvurmuşlardır. Ancak gerçek rahatsızlığın teşhisinde görüntüleme tekniklerinin ve biyopsinin yetersiz kaldığı tespit edilmiştir. Bu nedenle hastaya laparoskopik adrenalektomi uygulanmış ve bilateral sürrenal lezyon tespit edilmiştir. Diğer bir deyişle, literatürdeki görüntüleme tekniklerinin ve biyopsinin sürrenal lezyon tespit ve teşhisinde yetersiz kalabileceği görülmüştür.

Ekeh ve ark. (2010) travmalı 3113 hastanın abdominal BT taramalarını incelemişlerdir. Bu hastalardan 1103 tanesinde 1474 tesadüfi bulgu tespit edilmiştir. Çalışma neticesinde böbrek ve karaciğer kistlerinin en sık rastlanan iyi huylu lezyonlar olduğu, kireçlenmemiş akciğer nodülleri ve sürrenal lezyonların ise genelde kötü huylu oldukları tespit edilmiştir.

Goldenberg ve ark. (2011) çalışmalarında 55 yaşında erkek bireye ait büyük bir sürrenal lezyon tespit etmişlerdir. Lezyon türünü belirlemek için laparoskopik adrenalektomi olarak bilinen cerrahi işlem uygulanmış ve lezyon türü sürrenal lipoma olarak belirlenmiştir.

Yao ve ark. (2013) yenidoğan ünitelerindeki 28 hastada sürrenal lezyon tespiti üzerine incelemelerde bulunmuş, bireylerin 22' sinde sürrenal hemoraji (kanama), 1 tanesinde sürrenal teratom ve 5' inde ise sürrenal nöroblastoma tespit edilmiştir. Çalışma neticesinde doğru teşhis için kimyasal testlerin yanı sıra, ultrasonografi ve BT görüntülemenin son derece önemli olduğu belirtilmiştir.

Hanna ve ark. (2015), 29 hasta üzerinde farklı görüntüleme yöntemleri kullanarak incelemelerde bulunmuşlardır. Çalışma neticesinde BT cihazının, sürrenal lezyonların tespitinde ve karakter tahmininde diğer cihazlardan daha etkin olduğu ispat edilmiştir.

Hrabak-Paar ve ark. (2015), 16 hastaya ait sürrenal lezyonların tahmininde MR ve BT cihazlarını karşılaştırmışlardır. Yapılan çalışmalar neticesinde 2 cm'den büyük lezyonların her iki cihaz tarafından tespit edilebildiği, ancak 2 cm' den küçük lezyonlarda MR cihazının etkisiz kaldığı ve BT' nin bu lezyonları da tespit ettiği görülmüştür. 10 HU (Hounsfield Unit) değerinin üzerinde yoğunluğa sahip 4 adet lezyon için, BT taraması ile yapılan teşhisin desteklenmesi amacıyla MR taraması da

kullanılmıştır. Kısaca BT, farklı boyutlardaki lezyonların teşhisinde kullanılan bir tarama tekniğidir.

Dinamik BT, BT taramasından farklı olarak lezyonların kontrast tutma durumuna göre, lezyonun ve bağlantılarının daha açık bir şekilde tespit edilebilmesini sağlamaktadır. Nishikawa ve Omura (2000) 1020 adet hasta üzerinde incelemelerde bulunmuş, tek fazlı BT görüntülerinin primer aldosteronism (conn sendromu) tespitinde yetersiz kaldığını tespit etmişlerdir. Çalışma neticesinde sürrenal venöz görüntünün, yani Dinamik BT görüntünün hastalık teşhisinde gerekli olduğu belirtilmiştir.

Zhao ve Pu (2010), renal hücre karsinomu ve anjiyolipom lezyonları barındıran 93 adet hastaya çok kesitli spiral BT taraması uygulamışlardır. Çalışma içerisinde kullanılan cihazın teşhis işlemine etkisi araştırılmıştır. Lezyona ait BT görüntü sayısı ile renal hücre kasinomunun teşhisi noktasında duyarlılık (sensitivity) ve özgüllük (specificity) değerlerinin iyileştiği tespit edilmiştir.

Şu ana kadar incelenen çalışmalar tıbbi tabanlı çalışmalar olup;

- Sürrenal lezyonların teşhisinde BT kullanımının gerekliliği ortaya çıkmaktadır.
- BT ve diğer görüntüleme tekniklerinin teşhis aşamasında yeterli olmadığı durumlarda, tıp uzmanlarına yardımcı olabilecek ve biyopsiye gerek kalmaksızın tanı sağlayacak bir BDT sisteminin gerekliliği açıkça görülmektedir.
- Dinamik BT ile elde edilen arteryel, portal, venöz ve geç kontrast gibi fazların lezyona dair teşhiste ayrıntılı bilgi sağladığı, bu nedenle BT yerine Dinamik BT kullanımının lezyon tespitinde daha fazla avantaj sağladığı görülmektedir.
- Oluşturulacak BT tabanlı bir BDT sistemi ile yalnızca birden fazla görüntüleme tekniği kullanımının değil, aynı zamanda tekrarlı ve yanlış biyopsinin de önüne geçilebilecektir.

2.2. BT Görüntülerinde Gürültü Giderme Üzerine Literatür Çalışmaları

Literatür çalışmaları incelendiğinde BT görüntüleri içerisinde farklı gürültü tiplerinin ele alındığı ve işlendiği, bu gürültülerin eliminasyonu için birçok farklı yöntemin önerildiği görülmüştür.

Herman ve Davidi (2008) çalışmalarında Toplam Varyasyon Minimizasyonu (TVM) tekniği ile BT görüntüsü içindeki gürültüyü gidermişlerdir. Çalışma içerisinde gürültü tipi spesifik olarak belirtilmemiş olup, işlenen görüntüler beyin tümörü içermektedir. Karşılaştırmalar neticesinde TVM tekniğinin, Norm Minimizasyonu (NM) tekniğine göre daha yüksek performans ile gürültüyü baskıladığı tespit edilmiştir.

Jiao ve ark. (2008) düşük dozlu BT sinogramlarından gürültü eliminasyonu gerçekleştirmişlerdir. Bu amaçla Durağan Dalgacık Dönüşümü (DDD) tekniği, durağan olmayan Gaussian gürültüsüne uygulanmıştır. Çalışma neticesinde DDD tekniğinin görüntü içindeki kenar bozulmalarını önlediği, genel yumuşatma filtrelerine ve dalgacık tabanlı diğer tekniklere gürültü eliminasyonu üzerine üstünlük sağladığı tespit edilmiştir.

Matrecano ve ark. (2010) Mikro Bilgisayarlı Tomografi (Mikro-BT) görüntüleri üzerine gürültü eliminasyonu gerçekleştirmişlerdir. Çalışma içerisinde Blok Eşleştirme & 3B Filtreleme (BE3BF), VisuShrink ve BayesShrink teknikleri Gaussian gürültü eliminasyonu üzerine karşılaştırılmıştır. Çalışma neticesinde BE3BF tekniğinin, diğer tekniklerden daha yüksek performans ile Gaussian gürültüsünü elimine ettiği tespit edilmiştir.

Chen ve ark. (2011) abdominal-düşük doz BT görüntüleri üzerine gürültü ve artefakt eliminasyonu işlemlerini gerçekleştirmişlerdir. Çalışmada gürültü tipi Quantum gürültüsü olarak belirtilmiş olup, Büyük Ölçekli Komşuluklar üzerinden Ağırlıklı Yoğunluk Ortalaması (Weighted Intensity Averaging over Large-scale Neighborhoods: WIA-LN) tekniği ve tekniğe dair parametre değerlerinin optimum olduğu şartlar incelenmiştir.

Chen ve ark. (2012) toraks-düşük doz BT görüntülerinde benekli gürültünün ve artefaktların eliminasyonunu işlemişlerdir. Çalışma içerisinde Artefakt Baskılayan-Büyük Ölçekli Yerel Olmayan Ortalamalar (AB-BYOO) tekniği, Büyük Ölçekli Yerel Olmayan Ortalamalar (BYOO) tabanlı bir yaklaşım ve hibrit difüzyon filtresi tabanlı bir metot ile karşılaştırılmıştır. Sonuç olarak AB-BYOO tekniğinin, benekli gürültüyü ve durağan olmayan metal artefaktlarını daha iyi baskılayabildiği tespit edilmiştir.

Zhu ve ark. (2012) çalışmalarında Gaussian Süreç Regresyonu (GSR) tekniğini kullanarak, BT görüntülerinde gürültü eliminasyonu işlemi gerçekleştirmişlerdir. BT görüntülerindeki gürültünün karakterizasyonu amacıyla elde edilen bulgular, toplam gürültünün normal bir dağılım sergilediğini ve gürültünün Gaussian yapısında olduğunu göstermiştir.

Chen ve ark. (2013) abdominal BT görüntüleri üzerine 4 adet tekniği, benekli gürültü ve metal artefaklarının giderilmesi üzerine karşılaştırmışlardır. Bu teknikler; standart doz BT görüntüleme tekniği, düşük doz BT görüntüleme tekniği, sözlük tabanlı bir yaklaşım ve düşük doz BT tabanlı BYOO tekniği şeklindedir. Çalışma neticesinde sözlük tabanlı yaklaşımın, diğer tekniklere göre daha üstün bir performans sergilediği görülmüştür.

Cong-Hua ve ark. (2014) abdominal BT görüntülerinde Gaussian gürültü eliminasyonu tabanlı bir çalışma gerçekleştirmişlerdir. Kenar bilgisi ve Genelleştirilmiş GKM teknikleri kullanılarak geliştirilen yaklaşımın; kenar bilgisindeki ayrıntıları, görsel kaliteyi ve görüntü gri seviyelerini iyileştirdiği öne sürülmüştür.

Hashemi ve ark. (2015) düşük dozlu BT görüntülerinde Gaussian gürültü eliminasyonu için iteratif bir gürültü giderme algoritması geliştirmişlerdir. Çalışma neticesinde önerilen BE3BF tabanlı yaklaşımın, literatürdeki etkin diğer algoritmalara üstünlük sağladığı tespit edilmiştir.

Karimi ve ark. (2016) düşük doz BT görüntülerinde Poisson gürültüsünün bulunduğunu varsayarak, gürültü eliminasyonu gerçekleştirmişlerdir. Çalışma içerisinde, lokal gürültü giderme işlemi gerçekleştiren bir yaklaşım önerilmiştir. Elde edilen bulgulara göre önerilen yaklaşımın gürültü seviyesinde, uzamsal çözünürlükte ve görsel kalitede dikkate değer gelişim kaydettiği görülmüştür.

Al-Ameen ve ark. (2017), BT görüntülerinde Gaussian gürültü eliminasyonu işlemini gerçekleştirmişlerdir. Bu amaçla Wiener filtresi tabanlı, faz-korumalı bir yaklaşım geliştirmişlerdir. Sonuç olarak geliştirilen tekniğin, farklı gürültü seviyelerinde, literatürdeki diğer birçok tekniğe üstünlük sağladığı tespit edilmiştir.

Chen ve ark. (2017) düşük doz BT görüntülerinde Poisson gürültü eliminasyonu gerçekleştirmişlerdir. Çalışma içerisinde Konvolüsyonel Sinir Ağları (KSA) tekniği üç farklı algoritma ile karşılaştırılmıştır. Bu teknikler; K-Tekil Değer Ayrışımı (K-TDA), BE3BF ve TVM tabanlı bir algoritmadır. Çalışma neticesinde KSA yöntemi ile daha düşük hata değeri ve daha yüksek Doruk Sinyal Gürültü Oranı (DSGO) elde edildiği görülmüştür.

Şu ana kadar incelenen çalışmalar BT görüntülerinde gürültü eliminasyonu temelli olup;

- BT görüntülerindeki gürültü tipi hakkında kesin bir bulgunun yer almadığı görülmektedir.

- Bu noktada Gaussian, Poisson ve Quantum gürültülerinin ön plana çıktığı tespit edilmiştir.
- Çoğu literatür çalışmasının gürültüyü Gaussian veya Gaussian benzeri (Poisson) olarak kabul ettiği bilinmektedir.
- Tez çalışması içerisinde BT görüntülerinde meydana gelen gürültülerin, literatür çalışmalarında sıklıkla ifade edilmesi bakımından Gaussian gürültüsü olduğu varsayılarak işlemler gerçekleştirilmiştir.
- Bu amaçla, literatürde Gaussian gürültü eliminasyonu üzerine kullanılan tekniklerin incelenmesi gerekmektedir.

2.3. Gaussian Gürültü Eliminasyonu Üzerine Literatür Çalışmaları

Bu bölümde, Gaussian gürültü eliminasyonunda kullanılan etkin teknikler incelenmiştir.

Foi ve ark. (2004) benchmark verileri üzerine Gaussian gürültü eliminasyonu gerçekleştirmişlerdir. Bu amaçla Güven Aralıklarının Kesişimi (GAK) ile Lokal Polinomal Yaklaşım (LPY) teknikleri hibrit hale getirilmiş, bu sayede LPY-GAK tekniği geliştirilmiştir. Çalışma neticesinde LPY-GAK tekniğinin, eşdeğer tekniklerden daha yüksek DSGO değerlerine ulaşabildiği kaydedilmiştir.

Elad ve Aharon (2006), Gaussian gürültüsünün gri seviyeli görüntülerde eliminasyonu üzerine çalışmış, K-TDA tabanlı adaptif bir sözlük algoritması önermişlerdir. Önerilen metot, Ayrık Kosinüs Dönüşümü tabanlı Sözlük (AKD-S) ve Global Eğitimli Sözlük (GE-S) ile karşılaştırılmıştır. Çalışma neticesinde Adaptif Sözlük (AS) tekniğinin, diğer tekniklere göre daha yüksek performanslara ulaşabildiği tespit edilmiştir.

Dabov ve ark. (2007), gri seviyeli ve renkli görüntülerde Gaussian gürültü eliminasyonu üzerine çalışmışlardır. Bu amaçla dört farklı adımın temel alındığı bir yaklaşım geliştirilmiştir. Bu adımlar; 3B dönüşüm (3D transform), daralma (shrinkage), gruplama (grouping) ve blok tabanlı işlemler (blok-wise operations) şeklindedir. Üretilen yöntem Blok Eşleştirme ve 3B Filtreleme (BE3BF) olarak ifade edilmekte olup, tekniğin farklı gürültü seviyelerinde yüksek performans ile gürültü giderdiği belirlenmiştir.

Foi ve ark. (2007) LPY-GAK tekniğinden esinlenerek, Nokta Tabanlı Şekle Adaptif Ayrık Kosinüs Dönüşümü (ŞA-AKD) yaklaşımını Gaussian gürültü eliminasyonu üzerine önermişlerdir. Çalışma neticesinde ŞA-AKD tekniğinin, gürültü giderme işlemini hem gri seviyeli görüntülerde hem de renkli görüntülerde, diğer tekniklerden daha yüksek performans ile sağladığı görülmüştür.

Kumar ve ark. (2010) gri seviyede ifade edilen kurt kelebeği görüntüsünde, Gaussian gürültü eliminasyonu üzerine Medyan (Median) filtre ile Wiener filtresini karşılaştırmışlardır. Çalışma neticesinde Wiener filtresinin, Medyan filtreden daha yüksek DSGO ve daha küçük Karesel Ortalama Hata (KOH) değerleri ürettiği tespit edilmiştir.

Zoran ve Weiss (2011), görüntü içerisindeki yamalar üzerinden logaritmik hesap gerçekleştiren bir amaç fonksiyonunu (Olası Yama Logaritmik Benzerliği: OYLB) maksimize ederek, Gaussian gürültü eliminasyonunu sağlamışlardır. OYLB-GKM tekniği, GKM tekniği ve OYLB yaklaşımının hibrit hale getirilmesi ile üretilmiş, gri seviyeli görüntülerde gürültü giderme üzerine önerilmiştir. Çalışma neticesinde OYLB-GKM tekniğinin; BE3BF, K-TDA ve Eş Zamanlı Öğrenen Ayrık Kodlama (EAK) tekniklerine üstünlük sağladığı öne sürülmüştür.

Deledalle ve ark. (2011) Gaussian gürültüsünü üç farklı sözlük tabanlı yaklaşım ile elimine etmişlerdir. Bu yaklaşımlar, eğitim algoritması olarak Temel Bileşen Analizi (TBA) tekniğini içermektedir. Bu yaklaşımlar şu şekilde sıralanabilir:

- Yama Tabanlı Global Temel Bileşen Analizi (YGTBA)
- Yama Tabanlı Lokal Temel Bileşen Analizi (YLTBA)
- Yama Tabanlı Hiyerarşik Temel Bileşen Analizi (YHTBA)

Çalışma neticesinde YLTBA tekniğinin en yüksek DSGO değerlerini elde ettiği, YGTBA tekniğinin ise daha hızlı sonuç verdiği tespit edilmiştir.

Knaus ve Zwicker (2013) Gaussian gürültü eliminasyonu amacı ile Kısa Zamanlı Fourier Dönüşümü (KZFD) ve Bilateral filtre tekniklerini içeren, Çift Domende Gürültü Giderme (ÇDGG) algoritmasını tasarlamışlardır. ÇDGG tekniğinin, renkli ve gri seviyeli görüntüler üzerine yapılan denemelerde (gürültü seviyesi “25” olarak seçildiğinde), BE3BF tekniğine göre daha yüksek DSGO değerleri elde ettiği tespit edilmiştir.

Yang ve ark. (2015) benchmark görüntülerinde gürültü giderme ve bulanıklaştırma işlemlerini, Tekil Değer Ayrışımı içeren Düşük Dereceli Model (DDM-TDA) tekniği ile gerçekleştirmişlerdir. Çalışma neticesinde eşdeğer tekniklere göre, Sinyal Gürültü Oranı (SGO) üzerine üstünlük sağlandığı gözlemlenmiştir.

Şu ana kadar incelenen çalışmalar Gaussian gürültü eliminasyonu temelli olup; BE3BF tekniğinin birçok çalışma içerisinde mevcut olduğu ve tekniğin yüksek başarı ile gürültü eliminasyonu gerçekleştirdiği görülmüştür. Bahsi geçen çalışmalarda yer alan 13 teknik, tez çalışmasında, BT görüntülerinden Gaussian gürültü eliminasyonu için BE3BF tekniği ile karşılaştırılmıştır. Böylece literatürde, BT görüntülerinde gürültü eliminasyonu üzerine en ayrıntılı çalışma gerçekleştirilmektedir.

2.4. BT Görüntülerinde Yağ Dokusu Eliminasyonu Üzerine Literatür Çalışmaları

Tez çalışması kapsamında tasarlanan görüntü iyileştirme sistemi, gürültü ve yağ dokularını elimine eden bir yaklaşımdır. Sistem içerisindeki ilk adım gürültü eliminasyonudur. İkinci adımda ise yağ dokusu eliminasyonu işlemi gerçekleştirilmektedir.

Literatür çalışmaları incelendiğinde, görüntü iyileştirme üzerine her iki konuyu ele alan bir tekniğin mevcut olmadığı, ayrıca yağ dokusu eliminasyonu üzerine herhangi bir çalışmanın bulunmadığı tespit edilmiştir. Bu noktada çalışmaların kısmi yağ dokusu segmentasyonu üzerine gerçekleştirildiği ve bu çalışmaların çok az sayıda olduğu görülmüştür. Bu nedenle, bu bölüm içerisinde yağ dokusu segmentasyonu üzerine gerçekleştirilen çalışmalar ele alınmıştır.

Pednekar ve ark. (2005), BT görüntülerinde abdominal yağ dokusunun segmente edilmesi üzerine çoklu-sınıf, çoklu-özellik ve bulanık yakınlık prosedürlerinin işletildiği, eğitmeli bir yaklaşım önermişlerdir. Çalışma neticesinde yağ dokusunun segmente edilebildiği öne sürülmüştür. Ancak bazı durumlarda, arka plan (groundtruth) kısımlarının %10' a yakın bir değerde ROI (Region of Interest) içine karışabildiği, yine %18' e yakın bir oranda yağ dokusunun segmente edilemediği görülmüştür.

Kadhem ve ark. (2006) akciğer bölümünü içeren BT görüntülerinde, çoklu doku (yağ, kas, kemik, akciğer ve yumuşak dokuların) segmentasyonu işlemini gerçekleştirmişlerdir. Bu amaçla Büyüyen Alan (BA) algoritması ve kümeleme mantığının yer aldığı bir sistem tasarlanmıştır. Sonuç olarak yalnızca yüksek dozlu

çekimlerde, yağ ve kas dokularının segmentasyonu üzerine iyi sonuçlar elde edildiği görülmüştür.

Chung ve ark. (2009) BT görüntülerinde abdominal kas dokusunu, derialtı yağ dokusunu ve iç organlara yakın yağ dokusunu elde etmek amacıyla, TBA tabanlı bir şekilsel model önermişlerdir. Çalışma neticesinde önerilen tekniğin, deri altı yağ dokusunun segmentasyonu üzerine %84.7 (± %7.2)' lik Jaccard oranı sağladığı tespit edilmiştir. Ancak gerçeklenen çalışmada, yağ dokusunun üniform bir değişim sergilediği görülmektedir. Diğer bir deyişle işlenen görüntüler, yağ dokusunun açık bir şekilde gözlenebildiği ve kalitesi yüksek olan görüntülerden oluşmaktadır.

Makrogiannis ve ark. (2013), BT görüntülerinde deri altı ve iç yağ dokularının segmentasyonu için bulanık mantık, eşikleme ve sınıflandırma işlemlerini temel alan bir sistem geliştirmişlerdir. Elde edilen bulgulara göre, deri altı ve iç yağ dokularının sırasıyla %93.1 ve %85.6 Dice oranları ile tespit edilebildiği görülmüştür. Ancak çalışma içerisinde kullanılan görüntüler DICOM (Digital Imaging and Communications in Medicine) formatında olup, arka plan ve yağ dokularının kolaylıkla ayırt edilebileceği açıkça görülmektedir.

Tan ve ark. (2014), MR ve BT görüntülerinde uyluk kesiti üzerinde yağ ve kas dokularının eliminasyonunu gerçekleştirmişlerdir. Bu amaçla kümeleme mantığının ve yoğunluk tabanlı bir yaklaşımın yer aldığı yapı tasarlanmıştır. Çalışma neticesinde iç ve dış yağ dokularının, yaklaşık %90 Dice oranı ile elde edildiği görülmüştür. Ancak çalışma içerisinde işlenen görüntülerde, yağ dokularının arka plandan kolaylıkla ayırt edilebildiği ve kaliteli görüntüler üzerinde işlemlerin gerçekleştirildiği görülmektedir.

Wang ve ark. (2017), BT görüntülerinde deri altı ve iç yağ dokularının abdomen üzerinden segmentasyonu için, KSA yapısı içeren bir sistem önermişlerdir. Çalışma neticesinde %96.8 başarı oranı ile segmentasyon işleminin gerçekleştirildiği öne sürülmüştür. Ancak diğer literatür çalışmalarında olduğu gibi, yağ dokusunun üniform olduğu görüntüler üzerinde işlem yapıldığı ve kaliteli görüntüler kullanıldığı görülmektedir.

Şu ana kadar incelenen çalışmalar BT görüntülerinde yağ dokusu segmentasyonu temelli olup, elde edilen çıkarımlar şu şekildedir:

- Kullanılan BT görüntülerinde yağ dokusunun üniform bir görünüme sahip olduğu ve bu sayede yağ dokularının kolaylıkla elde edilebildiği görülmektedir.

- Kullanılan görüntülerin yüksek kaliteli görüntüler olduğu gözlemlenmiştir.
- Dağınık yağ dokusu ve gürültü içeren görüntülerde işlemlerin henüz gerçekleştirilmediği tespit edilmiştir.
- Bu noktada geliştirilecek olan bir algoritma ile yalnızca sürrenal lezyon segmentasyonundan önce değil, aynı zamanda abdomen içi bütün organ ve dokuların segmentasyonundan önce kullanılabilecek bir metot oluşturulabilecektir.

Tez çalışmasında yukarıda belirtilen durumlar göz önüne alınarak, BT görüntülerinde gürültü ve yağ dokusu eliminasyonu sağlayan bir sistem tasarlanmıştır. Bu sayede, abdomen içi organ ve dokuların segmentasyonlarından önce kullanılabilecek bir sistemin oluşturulması amaçlanmıştır.

2.5. Sürrenal Lezyon Segmentasyonu Üzerine Literatür Çalışmaları

Literatür çalışmaları incelendiğinde, sürrenal lezyon segmentasyonu üzerine yalnızca iki adet çalışmanın olduğu görülmektedir.

Tang ve ark. (2014) çok fazlı kontrast-artırımlı BT görüntülerinde, feokromositoma lezyonunun segmentasyonunu gerçekleştirmişlerdir. Çalışma içerisinde 10 farklı bireyden elde edilen görüntüler işlenmekte olup, bu görüntüler DICOM formatında seçilmiştir. Segmentasyon için üç farklı metodu kapsayan bir sistemin önerildiği görülmektedir. Bu metotlar; Yerel Alan Tabanlı Düzey Kümesi (YADK), histogram analizi ve İlerleyen Küpler (İK)' dir. Elde edilen bulgulara göre feokromositoma lezyonunun segmente edilebildiği görülmüştür. Ancak çalışmada sunulan görüntüler incelendiğinde, lezyon gri seviyesinin, çevre gri seviyelerinden kolaylıkla ayırt edilebildiği görülmektedir. Diğer bir deyişle, yakın gri seviyelere sahip alanlar arasında (arka plan ile benzer gri seviyeye sahip lezyonlarda) segmentasyonun yapılmadığı, yalnızca tek tip tümör (feokromositoma) üzerinde segmentasyon işleminin gerçekleştirildiği görülmektedir.

Chai ve ark. (2015), sürrenal lezyon segmentasyonu üzerine üç farklı metot içeren bir sistem geliştirmişlerdir. Sistem içerisinde K-TDA, BA ve Alan Tabanlı Düzey Kümesi (ADK) yöntemleri kullanılmıştır. Çalışma neticesinde %90.31 sınıflandırma doğruluğu ile lezyon sınırlarının tespit edildiği öne sürülmüştür. Ancak çalışmada

lezyon tipi ve sayısının belirtilmediği görülmektedir. Ayrıca kullanılan görüntülerde kitlelerin çok açık ve net bir şekilde seçilebildiği, sadece tekil yamalar üzerinden işlem yapıldığı, bütün bir abdomen üzerinden segmentasyon işleminin gerçekleştirilmediği görülmektedir.

Şu ana kadar incelenen çalışmalardan elde edilen sonuçlar aşağıda özetlenmiştir:

- Literatürde segmentasyon işlemini farklı türler için gerçekleştirebilen herhangi bir çalışmanın mevcut olmadığı görülmektedir.
- Kontrast maddeyi tutmayan (arka plandan farklı renkte görünmeyen) lezyonların mevcut olması, segmentasyon işlemi esnasında karşılaşılan dezavantajlardan biridir. Kontrast tutmayan lezyon, BT taramalarında olduğu gibi çevre dokularla benzer yoğunluk özelliklerine sahip olmaktadır. Ayrıca heterojen bir biçimde kontrast tutan lezyon tiplerinin mevcut olması, farklı gri seviyeler içeren şekillerin eldesinde kararlı görüntü işleme algoritmalarının kullanımını gerektirmektedir. Tasarlanacak olan bir segmentasyon algoritmasının, bahsi geçen durumlara olabildiğince uyum sağlaması gerekmektedir.
- BT görüntülerinde, bir doku veya organ referans alınarak sürrenal lezyon segmentasyonu mümkün olmamaktadır. Çünkü abdomen içi görüntüler, her bir BT diliminde farklılık gösterebilmektedir. Bu nedenle, kitlenin bulunduğu bölümü içine alacak bir segmentasyonun veya doğrudan kitle segmentasyonunun gerçekleştirilmesi zordur.
- Doğrudan kitle segmentasyonunun, bütün bir abdomen üzerinden, birden fazla lezyon türü için gerçekleştirilmesi halinde literatürde bir ilk olacağı gibi, sınıflandırma performansını artırmada çok önemli bir aşama kaydedileceği açıkça görülmektedir.
- Ayrıca literatürde farklı şartlara sahip lezyonların (açık lezyonlar, büyük tekil lezyonlar, diğer organ ve dokulara yapışık lezyonlar, kontrast tutulumu zayıf lezyonlar) hepsinde işlem yapabilecek, bütün bir abdomen üzerinden segmentasyon işlemini hem homojen hem de heterojen lezyonlar için gerçekleştirebilecek bir yaklaşımın önerilmediği görülmektedir.

Tez çalışması içinde yukarıda bahsi geçen durumlar göz önüne alınarak bir sistem tasarımı geliştirilmiştir. Bu amaçla, BDT sisteminin en önemli aşamalarından biri olan, kalite ve içerdiği bilgi açısından farklı görüntüler üzerinde de yüksek doğrulukla işlem yapabilen bir sürrenal lezyon segmentasyon sistemi önerilmiştir.

2.6. Sürrenal Lezyonların Sınıflandırılması Üzerine Literatür Çalışmaları

Sürrenal lezyonların sınıflandırılması üzerine literatür incelendiğinde çok az çalışmanın mevcut olduğu görülmektedir.

Saiprasad ve ark. (2010) çalışmalarında, sürrenal adenom barındıran 10 adet BT görüntüsü ile 10 adet normal BT görüntüsünü kullanarak, normal-adenom sınıflandırma işlemi gerçekleştirmişlerdir. Çalışma içerisinde, bütün bir böbreküstü bezinin manuel segmentasyonu ardından histogram analizi gerçekleştirilmiş, elde edilen veriler olasılık tabanlı bir prosedür ile istatistiksel olarak sınıflandırılmıştır. Elde edilen bulgulara göre %87 sınıflandırma doğruluğu ile normal-adenom sınıflandırması sağlanmıştır. Kısaca tek tip tümörün, normal görüntüden ayırt edilmesi işlemi gerçekleştirilmiştir.

Biehl ve ark. (2012), iyi huylu ve kötü huylu adrenokortikal lezyon türlerinden yalnızca iki tanesini (adenom ve karsinom lezyonlarını) ayırt etmeye çalışmışlardır. Bu amaçla, Matris İlgili Öğrenme (MİÖ) ve Genelleştirilmiş Vektör Kuantalamalı Öğrenme (GVKÖ) algoritmaları kullanılarak, Genelleştirilmiş Matris Vektör Kuantalamalı Öğrenme (GMVKÖ) algoritması tasarlanmıştır. GMVKÖ yaklaşımı, 147 hastanın idrar örneklerinden elde edilen steroid salgılama profilleri kullanılarak test edilmiştir. Sonuç olarak, bütün steroid işaretçilerinin kullanıldığı durumda %96.5 AUC (ROC eğrisi altında kalan alan) değeri ile yaklaşık %90 duyarlılık ve %90 özgüllük oranları elde edilmiştir. Ancak çalışmada, yalnızca iki tip lezyon üzerinde tahmin yapılmakta ve örüntü sınıflandırma temelli bir işlem gerçekleştirmektedir. Diğer bir deyişle, görüntü üzerinden özellik çıkarma ve sınıflandırma işlemleri yapılmadığı gibi, yalnızca iki tip lezyon türünün iyi huylu-kötü huylu ayrımı gerçekleştirilmiştir.

Biehl (2012) bir diğer çalışmasında GMVKÖ tekniğini ayrıntılı bir şekilde izah etmiş ve tekniği, Vektör Kuantalamalı Öğrenme (VKÖ) yaklaşımının iki adet türevi ile karşılaştırmıştır. Biehl (2012), bir önceki çalışmasında olduğu gibi, adrenokortikal adenom ve karsinom türlerini ayırt etmek için steroid işaretçilerinden faydalanmıştır. Sonuç olarak GMVKÖ tekniğinin, diğer tekniklerden daha yüksek AUC değerlerine ulaşabildiği tespit edilmiştir.

Saiprasad ve ark. (2013) 15 adet BT görüntüsü kullanarak, 30 adet sürrenal bez üzerinde normal-adenom durum tespiti gerçekleştirmiştir. Bu amaçla Rasgele Orman (RO) tekniği, bütün bir böbreküstü bezinin segmentasyonunda kullanılmış, histogram bilgileri ile gerçekleştirilen sınıflandırma işlemi üzerine yaklaşık %80 duyarlılık ve %90 özgüllük oranları elde edilmiştir. Ancak sınıflamada yalnızca adenom kitlesi ile kitle barındırmayan sürrenal bezlerin karşılaştırıldığı görülmektedir. Diğer bir deyişle, birden fazla lezyon türünün sınıflandırılması temelli bir çalışma gerçekleştirilmemekte, yalnızca tek tip lezyonun normal durum ile karşılaştırılması sağlanmaktadır.

Li ve ark. (2017), sürrenal lezyonların ikili sınıflandırması için Gri Düzey Eş Oluşum Matrisi (GDEM) özellikleri ve farklı sınıflayıcı teknikler kullanmışlardır. İşlenen veri setinde 230 adrenal lezyon bulunmaktadır ve kullanılan görüntüler kontrastsız BT taramalarından elde edilmiştir. Ancak çalışma içerisinde kullanılan tümör tip sayısı belirtilmemektedir. Çalışma neticesinde önerilen Bayesian olasılıksal sisteminin, %80 sınıflama doğruluğu sağladığı tespit edilmiştir.

Sınıflandırma temelli çalışmalardan elde edilen sonuçlar şu şekildedir;

- Literatürde tıbbi görüntüleme verileri kullanılarak en fazla bir tip sürrenal lezyonun sınıflandırıldığı görülmektedir.
- İki tip lezyonun sınıflandırıldığı çalışmalarda ise idrar tahlillerinden faydalanıldığı görülmüştür.
- Tıbbi görüntüleme cihazları ile elde edilen veri üzerinden, birden fazla lezyon türünü içine alan bir ikili sınıflandırmanın (iyi huylu / kötü huylu ayrımının) gerçekleştirilmediği tespit edilmiştir.

Tez çalışması içinde yukarıda bahsi geçen durumlar göz önüne alınarak, 117 adet sürrenal lezyon üzerinden ayrıntılı bir ikili (iyi huylu / kötü huylu) sınıflama işlemi gerçekleştirilmiştir. Böylece bir türden fazla sürrenal lezyon türü ilk kez sınıflandırılmıştır. Ayrıca gerçekleştirilen tez çalışması, tür bakımından en çeşitli veri setinin kullanıldığı çalışmadır.

2.7. Kaynak Araştırması Özeti

Literatür çalışmalarından da görüleceği üzere;

- Sürrenal lezyonlar üzerine BT' nin en çok kullanılan görüntüleme tekniği olduğu ve henüz BT temelli bir BDT sistemin üretilmediği,
- BT görüntülerinde gürültü giderme üzerine kapsamlı bir çalışmanın bu çalışmaya kadar mevcut olmadığı,
- Gürültü içeren, görüntü kalitesi düşük olan ve yağ dokusu üniform yapıda olmayan abdominal BT görüntülerinde, gürültü ve yağ dokusunu elimine edebilecek bir yaklaşımın tasarlanmadığı,
- Sürrenal lezyon tespiti aşamasında, BT görüntüsü içinde ilgili bölümün segmentasyonunu birden fazla tür için yapabilen bir tekniğin önerilmediği,
- Sürrenal lezyon segmentasyonunda, hem homojen hem de heterojen lezyonlarda işlem yapabilen bir yaklaşım önerilmediği,
- İkiden fazla kitle türünü içine alan binary sınıflandırmanın (malign / benign ayrımının) gerçekleştirilmediği,
- Farklı özellik çıkarma ve sınıflandırma algoritmalarının içinde bulunduğu komplike sınıflandırıcı yapıların, sürrenal lezyon tür tespitinde kullanılmadığı tespit edilmiştir.

Doktora tez çalışması, yukarıda belirtilen yeniliklerin gerçekleştirilmesi ve bu amaçla etkin algoritmaların önerilmesi üzerine şekillenmiştir. Böylece BT tabanlı bir BDT sisteminin iskelet yapısı oluşturulmuştur.

3. MATERYAL VE YÖNTEM

Sürrenal lezyonların tespitinde ve karakterizasyonunda; birden fazla tarama tekniği kullanımının, tekrarlı biyopsinin ve meydana gelebilecek komplikasyonların önüne geçebilecek bir bilgisayar destekli teşhis sistemine ihtiyaç bulunmaktadır. Bu amaçla farklı görüntü işleme sistemlerinin bir arada kullanılması gereklidir. Tez çalışmasında yalnızca BT taraması üzerinden işlem yapabilen, biyopsi öncesi lezyon lokasyonu ve türü hakkında bilgi verebilen ve böylece tıp uzmanlarına yardımcı olabilecek bir BDT sistemi önerilmiştir.

Önerilen BDT sistemi; abdomen segmentasyonu, gürültü ve yağ dokusu eliminasyonu, lezyon segmentasyonu ve sınıflandırma olmak üzere 4 aşamadan oluşmaktadır. Her aşama en iyi sonuçları veren algoritmalarla gerçekleştirilmiş ve böylece yüksek doğruluklu bir BDT sistemi oluşturulmuştur.

Bu bölümde çalışmada kullanılan veri setinin özellikleri ve sistemin her bir aşamasını oluşturan metotların izahı sunulmuştur. 4. Bölüm' de, önerilen BDT sistemini oluşturan aşamaların sonuçları sunularak detaylı bir şekilde analiz edilmiştir.

3.1. Kullanılan Veri Seti Özellikleri

Tez çalışmasında kullanılan görüntüler, Selçuk Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalı' ndan alınan Dinamik BT görüntüleridir. Oluşturulan veri seti, sürrenal lezyonların yer aldığı abdominal BT görüntülerini içerir.

Verilerin etiketlenmesi ve ilgili diğer işlemler, iki uzman radyolog tarafından gerçekleştirilmiştir. Kullanılan BT cihazının modeli *SIEMENS SOMATOM Definition Flash CT* olup, içerisinde bir görüntü oluşturma algoritması yer almaktadır. Bu algoritma, *Advanced Modeled Iterative Reconstruction (ADMIRE)* olarak isimlendirilir ve endüstrideki ilk ham veri tabanlı iteratif görüntü oluşturma algoritmasıdır. Cihaz çıkışında elde edilen veriler, *Picture Archiving and Communication Systems* (PACS) olarak bilinen depolama birimlerinde kaydedilmektedir. Kullanılan görüntüler, PACS çıkışında *jpg* formatında elde edilmiştir. BT çekimlerinde kullanılan anot-katot arası gerilimin maksimum değeri 120 kVp' dir ve her bir görüntü dilimi 3mm hassasiyetle elde edilmektedir.

Kullanılan verilerin özellikleri ve kullanıldığı çalışmalar Çizelge 3.1' de sunulmuştur.

Çizelge 3.1. Kullanılan veri seti özellikleri ve kullanıldıkları çalışmalara göre dağılımları

Veri No.	Ç1	Ç2	Ç3	Ç4	Ç5	Veri Sağlayıcı	BT Tipi	BT Türü	Unilateral	Bilateral	Faz	Tür	Karakteristik	Yağ Dokusu	Lezyon Durumu	Kontrast Tutulumu
1	X	X	X	X	X	SÜTF	Dinamik	Abdominal		X	Arteryel	Adenom	Benign	Belirgin	Açık Kitle	Yetersiz
2	X	X		X	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenom	Benign	Mevcut Değil	Karaciğere Yapışık	Yeterli
3	X	X		X	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenom	Benign	Belirgin	Dalağa Yapışık	Yeterli
4	X			X	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Metastaz	Malign	Belirgin	Karaciğere Yapışık	Yetersiz
5	X	X		X	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenom	Benign	Mevcut Değil	Dalağa Yapışık	Yetersiz
6	X	X	X	X	X	SÜTF	Dinamik	Abdominal		X	Arteryel	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yetersiz
7	X	X	X	X	X	SÜTF	Dinamik	Abdominal		X	Arteryel	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
8	X	X		X	X	SÜTF	Dinamik	Abdominal		X	Arteryel	Adenom	Benign	Mevcut Değil	Karaciğere Yapışık	Yeterli
9	X		X	X	X	SÜTF	Dinamik	Abdominal		X	Arteryel	Feokromositoma	Benign	Belirgin	Pankreasa Yapışık	Yetersiz
10	X		X	X	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Metastaz	Malign	Belirgin	Büyük Tekil Kitle	Yetersiz
11	X	X	X	X	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yetersiz
12	X	X		X	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenom	Benign	Mevcut Değil	Karaciğere Yapışık	Yetersiz
13	X	X	X	X	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yetersiz
14	X	X		X	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yetersiz
15	X	X	X	X	X	SÜTF	Dinamik	Abdominal		X	Arteryel	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
16	X	X		X	X	SÜTF	Dinamik	Abdominal		X	Arteryel	Adenom	Benign	Mevcut Değil	Karaciğere Yapışık	Yeterli
17	X			X	X	SÜTF	Dinamik	Abdominal	X		Portal	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yetersiz
18	X			X	X	SÜTF	Dinamik	Abdominal	X		Portal	Adenom	Benign	Belirgin	Dalağa Yapışık	Yeterli
19	X			X	X	SÜTF	Dinamik	Abdominal	X		Portal	Adenom	Benign	Belirgin	Açık Kitle	Yeterli
20	X			X	X	SÜTF	Dinamik	Abdominal	X		Portal	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
21	X			X	X	SÜTF	Dinamik	Abdominal	X		Portal	Adenom	Benign	Belirgin	Açık Kitle	Yeterli
22	X			X	X	SÜTF	Dinamik	Abdominal	X		Portal	Adenom	Benign	Belirgin	Dalağa Yapışık	Yetersiz
23	X			X	X	SÜTF	Dinamik	Abdominal		X	Portal	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yetersiz
24	X			X	X	SÜTF	Dinamik	Abdominal		X	Portal	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yetersiz
25	X			X	X	SÜTF	Dinamik	Abdominal	X		Portal	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
26	X			X	X	SÜTF	Dinamik	Abdominal	X		Portal	Adenom	Benign	Belirgin	Pankreasa Yapışık	Yetersiz
27	X			X	X	SÜTF	Dinamik	Abdominal	X		Portal	Metastaz	Malign	Belirgin	Karaciğere Yapışık	Yeterli
28	X			X	X	SÜTF	Dinamik	Abdominal	X		Portal	Metastaz	Malign	Belirgin	Pankreasa Yapışık	Yeterli
29	X			X	X	SÜTF	Dinamik	Abdominal		X	Portal	Metastaz	Malign	Belirgin	Karaciğere Yapışık	Yeterli
30	X			X	X	SÜTF	Dinamik	Abdominal	X		Portal	Metastaz	Malign	Belirgin	Pankreasa Yapışık	Yeterli
31	X			X	X	SÜTF	Dinamik	Abdominal	X		Portal	Metastaz	Malign	Belirgin	Pankreasa Yapışık	Yeterli
32	X			X	X	SÜTF	Dinamik	Abdominal	X		Portal	Metastaz	Malign	Belirgin	Karaciğere Yapışık	Yetersiz
33					X	SÜTF	Dinamik	Abdominal	X		Venöz	Lipom	Benign	Belirgin	Karaciğere Yapışık	Yeterli

34	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitle	Yetersiz
35	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenom	Benign	Belirgin	Açık Kitle	Yeterli
36	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenolipom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
37	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Dalağa Yapışık	Yeterli
38	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
39	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitle	Yeterli
40	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Dalağa Yapışık	Yetersiz
41	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitleler	Yeterli
42	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Dalağa Yapışık	Yeterli
43	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
44	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitle	Yeterli
45	X	SÜTF	Dinamik	Abdominal		X	Venöz	Adenom	Benign	Belirgin	Dalağa Yapışık	Yeterli
46	X	SÜTF	Dinamik	Abdominal	X		Venöz	Hematom	Benign	Belirgin	Dalağa Yapışık	Yeterli
47	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Pankreasa Yapışık	Yeterli
48	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yetersiz
49	X	SÜTF	Dinamik	Abdominal	X		Venöz	Hematom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
50	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitle	Yetersiz
51	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
52	X	SÜTF	Dinamik	Abdominal	X		Venöz	Feokromositoma	Benign	Belirgin	Açık Kitle	Yeterli
53	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitle	Yeterli
54	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Pankreasa Yapışık	Yetersiz
55	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenomyolipom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
56	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Mevcut Değil	Pankreasa Yapışık	Yeterli
57	X	SÜTF	Dinamik	Abdominal	X		Venöz	Hematom	Benign	Mevcut Değil	Karaciğere Yapışık	Yeterli
58	X	SÜTF	Dinamik	Abdominal	X		Venöz	Hematom	Benign	Belirgin	Karaciğere Yapışık	Yetersiz
59	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
60	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenom	Benign	Belirgin	Açık Kitle	Yeterli
61	X	SÜTF	Dinamik	Abdominal	X		Venöz	Myelolipom	Benign	Belirgin	Açık Kitle	Yeterli
62	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenom	Benign	Belirgin	Açık Kitle	Yeterli
63	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitle	Yeterli
64	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenom	Benign	Belirgin	Dalağa Yapışık	Yeterli
65	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
66	X	SÜTF	Dinamik	Abdominal	X		Arteryel	Adenom	Benign	Belirgin	Pankreasa Yapışık	Yeterli
67	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Pankreasa Yapışık	Yeterli
68	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Mevcut Değil	Açık Kitle	Yetersiz
69	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitle	Yeterli
70	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
71	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Pankreasa Yapışık	Yeterli
72	X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitle	Yeterli

73		X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitle	Yetersiz
74		X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Mevcut Değil	Karaciğere Yapışık	Yeterli
75		X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitle	Yetersiz
76		X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
77		X	SÜTF	Dinamik	Abdominal		X	Arteryel	Adenom	Benign	Belirgin	Açık Kitle	Yetersiz
78		X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitle	Yetersiz
79		X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Pankreasa Yapışık	Yeterli
80		X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitle	Yeterli
81		X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Pankreasa Yapışık	Yeterli
82		X	SÜTF	Dinamik	Abdominal		X	Venöz	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
83		X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Açık Kitle	Yeterli
84		X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yeterli
85		X	SÜTF	Dinamik	Abdominal	X		Arteryel	Lipom	Benign	Belirgin	Açık Kitle	Yeterli
86		X	SÜTF	Dinamik	Abdominal	X		Venöz	Adenom	Benign	Belirgin	Karaciğere Yapışık	Yetersiz
87		X	SÜTF	Dinamik	Abdominal	X		Arteryel	Metastaz	Malign	Belirgin	Büyük Tekil Kitle	Yeterli
88		X	SÜTF	Dinamik	Abdominal	X		Arteryel	Metastaz	Malign	Belirgin	Açık Kitle	Yetersiz
89		X	SÜTF	Dinamik	Abdominal	X		Arteryel	Metastaz	Malign	Belirgin	Açık Kitle	Yetersiz
90		X	SÜTF	Dinamik	Abdominal		X	Arteryel	Metastaz	Malign	Belirgin	Karaciğere Yapışık	Yetersiz
91		X	SÜTF	Dinamik	Abdominal	X		Portal / Venöz	Metastaz	Malign	Belirgin	Büyük Tekil Kitle	Yeterli
92		X	SÜTF	Dinamik	Abdominal		X	Portal / Venöz	Metastaz	Malign	Belirgin	Karaciğere Yapışık	Yetersiz
93		X	SÜTF	Dinamik	Abdominal	X		Portal / Venöz	Metastaz	Malign	Belirgin	Karaciğere Yapışık	Yeterli
94		X	SÜTF	Dinamik	Abdominal	X		Arteryel	Metastaz	Malign	Belirgin	Karaciğere Yapışık	Yetersiz
95		X	SÜTF	Dinamik	Abdominal		X	Arteryel	Metastaz	Malign	Belirgin	Karaciğere Yapışık	Yetersiz
96		X	SÜTF	Dinamik	Abdominal	X		Arteryel	Metastaz	Malign	Belirgin	Açık Kitle	Yeterli
97		X	SÜTF	Dinamik	Abdominal	X		Portal / Venöz	Metastaz	Malign	Belirgin	Dalağa Yapışık	Yetersiz
98		X	SÜTF	Dinamik	Abdominal	X		Arteryel	Metastaz	Malign	Belirgin	Dalağa Yapışık	Yeterli
99	X		TCIA	BT	Abdominal				Lezyon içermeyen görüntü				
100	X		TCIA	BT	Abdominal				Lezyon içermeyen görüntü				
101	X		TCIA	BT	Abdominal				Lezyon içermeyen görüntü				
102	X		TCIA	BT	Pelvis				Lezyon içermeyen görüntü				
103	X		TCIA	BT	Toraks				Lezyon içermeyen görüntü				
104	X		TCIA	BT	Abdominal				Lezyon içermeyen görüntü				
105	X		TCIA	BT	Toraks				Lezyon içermeyen görüntü				
106	X		TCIA	BT	Toraks				Lezyon içermeyen görüntü				
107	X		TCIA	BT	Pelvis				Lezyon içermeyen görüntü				
108	X		TCIA	BT	Toraks				Lezyon içermeyen görüntü				
109	X		TCIA	BT	Toraks				Lezyon içermeyen görüntü				
110	X		TCIA	BT	Abdominal				Lezyon içermeyen görüntü				
111	X		TCIA	BT	Abdominal				Lezyon içermeyen görüntü				
112	X		TCIA	BT	Toraks				Lezyon içermeyen görüntü				
113	X		TCIA	BT	Toraks				Lezyon içermeyen görüntü				
114	X		TCIA	BT	Abdominal				Lezyon içermeyen görüntü				

115	X	TCIA	BT	Abdominal	Lezyon içermeyen görüntü
116	X	TCIA	BT	Toraks	Lezyon içermeyen görüntü
117	X	TCIA	BT	Toraks	Lezyon içermeyen görüntü
118	X	TCIA	BT	Toraks	Lezyon içermeyen görüntü
119	X	TCIA	BT	Abdominal	Lezyon içermeyen görüntü
120	X	TCIA	BT	Pelvis	Lezyon içermeyen görüntü
121	X	TCIA	BT	Toraks	Lezyon içermeyen görüntü
122	X	TCIA	BT	Abdominal	Lezyon içermeyen görüntü
123	X	TCIA	BT	Abdominal	Lezyon içermeyen görüntü
124	X	TCIA	BT	Abdominal	Lezyon içermeyen görüntü

(Ç1: Abdomen Segmentasyonu, Ç2: Gürültü Eliminasyonu, Ç3: Görüntü İyileştirme, Ç4: Sürrenal Lezyon Segmentasyonu, Ç5: Lezyon Sınıflandırma, SÜTF: Selçuk Üniversitesi Tıp Fakültesi Radyoloji ABD, TCIA: The Cancer Imaging Archive Kütüphanesi)

Çizelge 3.1' de görüldüğü üzere; 98 adet Dinamik BT ve 26 adet BT görüntüsü tez çalışması dâhilinde kullanılmıştır. Dinamik BT tabanlı veri seti 16 bilateral ve 82 unilateral lezyon içermektedir ve böylece toplamda 114 sürrenal lezyon üzerinde işlem yapılmıştır. Dinamik BT görüntüleri; arteryel (33), portal (16), portal-venöz (4) ve venöz (45) fazlarında elde edilen görüntülerden meydana gelmektedir. Dinamik BT veri seti 5 farklı tip (8 alt-tür) sürrenal lezyon içerir: Adenom (78 adet), Feokromositoma (3 adet), Hematom (4 adet), Metastaz (24 adet), Lipom (5 adet) türevi lezyonlar (Adenomyolipom, Adenolipom, Myelolipom, Lipom). Bu lezyonların 90 adedi iyi huylu (benign) ve 24 adedi kötü huylu (malign) olup, lezyonlara dair farklı-görsel durumların (açık kitle, yapışık kitle ve büyük tekil kitle) mevcut olduğu tespit edilmiştir. Dinamik BT görüntülerinin çoğunda (89 adedinde) yağ dokusunun belirgin olduğu, 9 adet görüntüde ise yağ dokusunun bulunmadığı görülmüştür. Dinamik BT veri seti içindeki 35 görüntüde lezyonların kontrast tutulumunun yetersiz olduğu, 63 görüntüde ise lezyonlara dair kontrast tutulumlarının yeterli seviyede olduğu, bu lezyonların çevre dokulardan yoğunluk temelli ayırt edilebildiği görülmüştür. Çalışmada doğrulama amaçlı olarak The Cancer Imaging Archive (TCIA) veri seti kullanılmıştır. TCIA veri seti 12 abdominal, 11 toraks ve 3 pelvis BT görüntüsünden meydana gelmektedir.

3.2. Abdomen Segmentasyonunda Kullanılan Metotlar

Çalışmada önerilen BDT sistemindeki abdomen segmentasyon aşaması literatürde ilk kez gerçekleştirilmektedir. Abdomen segmentasyonu için önerilen yapı; yoğunluk tabanlı yaklaşımlar, farklı morfolojik işlemler ve histogram tabanlı bir teknik içermektedir. Kullanılan metotlar aşağıda görüldüğü gibidir:

1. En Geniş Obje Bulucu (GOB)
2. Görüntü Genişletme
3. Medyan Filtre
4. Eğim Genliği Algoritması
5. Kontrast Sınırlı - Adaptif Histogram Eşitleme Algoritması (KS-AHE)
6. Uzamsal Bulanık C-Ortalamalar Algoritması (UBCO)
7. Morfolojik Kapama Algoritması
8. Sıfır-geçiş Eliminatörü (SE)

3.2.1. En geniş obje bulucu

En Geniş Obje Bulucu (GOB), görüntü içindeki satırların ve sütunların toplamını kullanmakta, görüntüde yer alan en büyük hacmi ortaya çıkarmaktadır. Dikey ve yatay vektörlerdeki en geniş gri seviye değişimleri, bütün bir görüntünün dikey ve yatay perspektiflerden toplanması ile tespit edilmektedir. Böylece karın bölgesini içeren çerçeve, en büyük gri seviye değişiminin olduğu koordinatlarından yararlanılarak elde edilmektedir.

GOB yaklaşımı ile iki temel dezavantaj elimine edilmektedir: (1) Gereksiz bir bölgeye ait ROI dışı parçalar, (2) Sıfır değerleri içeren satırlar ve sütunlar. Bahsi geçen gereksiz bölge, yatak bölümünün görünümünü ve hasta bilgilerinin bulunduğu alanları ifade etmektedir. GOB yaklaşımının algoritması Çizelge 3.2' de görüldüğü gibidir.

GOB içerisindeki ilk işlem, eşitlik (3.1)' de gösterilen *Logaritmik Doğrusal Olmayan Germe* işlemidir (Van Den Boomgaard ve Van Balen, 1992; Koss ve ark., 1999).

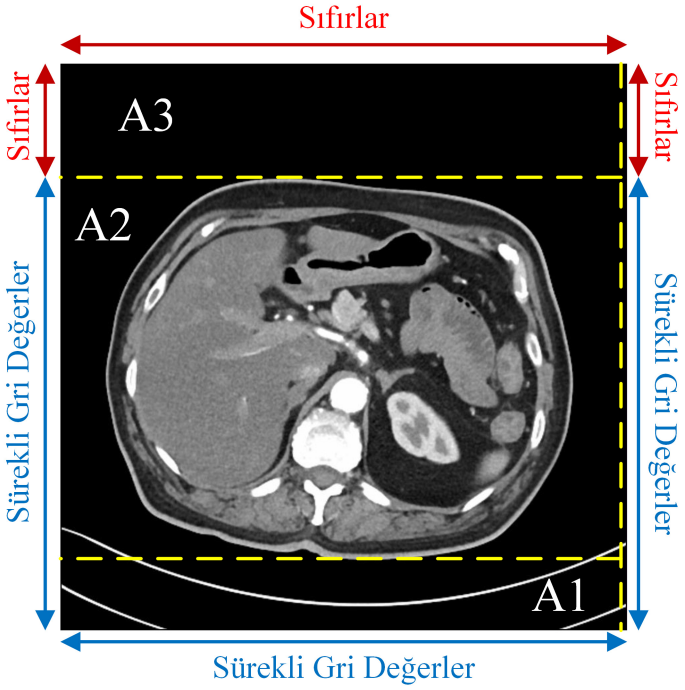
$$g_{görüntü} = b * \log(af_{görüntü} + 1) \tag{3.1}$$

Eşitlik (3.1)' de yer alan $f_{görüntü}$ ve $g_{görüntü}$ sırasıyla orijinal ve kontrastı iyileştirilmiş görüntüleri ifade etmektedir. a ve b değerleri ise kontrast seviyesini düzenleyen parametrelerdir.

Çizelge 3.2. GOB yaklaşımının algoritması

GOB algoritması
- Doğrusal Olmayan Germe ile kontrast iyileştirme işlemini (3.1)' e göre gerçekleştir - Görüntünün yatayda ve dikeydeki toplamlarını (iki adet vektörü) elde et. For i=1 to yatay vektör uzunluğu - Sıfır olmayan değerleri say ve vektörün sonuna kadar bu değerlerin yer aldığı koordinatları kaydet. end For i=1 to dikey vektör uzunluğu - Sıfır olmayan değerleri say ve vektörün sonuna kadar bu değerlerin yer aldığı koordinatları kaydet. end - Yatay ve düşey vektörlerde en geniş uzunlukları hesapla. - En geniş hacmi, en geniş uzunluklar yardımıyla elde et. - En geniş alan dışında kalan gereksiz bölümlere sıfır değerini ata.

GOB yaklaşımı ile abdomen kenar tespitini olumsuz etkileyen yatak kısmı ve hasta bilgileri elimine edilmiştir. Ancak bu yaklaşım, abdomeni çevreleyen görünümdeki BT yatak bölümünün eliminasyonunda iyi sonuçlar vermemiştir. Bunun nedeni, iç içe geçmiş olan yapıya dikey ve yatay perspektiflerden bakıldığında, görüntünün büyük bir bölümünün gri seviye vektörü olarak atfedilmesidir. Şekil 3.1' de söz konusu durum görsel olarak ifade edilmiştir. Şekil 3.1 içerisinde A1+A2 alanı abdomen olarak görülmektedir.



Şekil 3.1. Abdomeni çevreleyen BT yatağı için farklı perspektiflerden gri seviye değişimleri

Abdomen segmentasyonu için önerilen yapının diğer aşamalarında, GOB yaklaşımının etkisiz kaldığı durumların (abdomeni çevreleyen BT yatağı ve hasta bilgilerinin) yanı sıra diğer dezavantajların giderilmesi veya bu kısıtlardan etkilenmeyen operatörlerin işletilmesi sağlanmaktadır.

3.2.2. Görüntü genişletme

Görüntü Genişletme, görüntü içerisindeki objelerin kenarlarını ve diğer bölümlerini belirginleştiren morfolojik bir işlemdir. Bu işlem esnasında kullanılan filtrelere (yapı elemanları / structuring elements) göre objeler genişletilmektedir. Bu yapı elemanları; disk, çizgi (farklı açılarda), elmas, vb. şekilde olabilmektedir.

Gri seviyeli görüntülerde genişletme işleminin formülü (3.2)' de görüldüğü gibidir (Van Den Boomgaard ve Van Balen, 1992; Koss ve ark., 1999).

$$(A \oplus B)(x,y) = max\{A(x-x', y-y') + B(x', y') \mid (x', y') \in D_B\} \tag{3.2}$$

(3.2) eşitliği içerisindeki A ve B, sırasıyla orijinal görüntüyü ve yapı elemanını temsil etmektedir. D_B ise B yapı elemanının domenini ifade etmektedir. Bu noktada $A(x,y)$ değerlerinin domen dışında $-\infty$ olduğu kabul edilmektedir.

3.2.3. Medyan filtre

- Meydan filtre, görüntüler üzerinde yumuşatma ve gürültü giderme işlemlerini gerçekleştiren non-lineer bir yöntemdir (Lim, 1990).
- Meydan filtre uygulamasında piksellerin komşulukları hesaba katılarak işlemler gerçekleştirilmektedir.
- İşlem esnasında bir pikselin yeni gri değeri, komşu piksellerin yer aldığı pencere üzerinden ortanca değer tespiti ile elde edilmektedir.

3.2.4. Eğim genliği algoritması

Eğim, türev işleminin genelleştirilmiş bir formudur (Korn ve Korn, 2000). Eğim, bir fonksiyonda en büyük değişime karşılık gelen yönü ifade etmek için

kullanılmaktadır. Literatürde Eğim Genliği, görüntü içerisinde yer alan objelerin yönlerini bulmak amacıyla kullanılır (Korn ve Korn, 2000). Bu algoritma kenar tespitinde ön plana çıkmaktadır.

3.2.5. Kontrast sınırlı - adaptif histogram eşitleme

Adaptif Histogram Eşitleme (AHE) ile bir komşuluk bölgesinden türevlenen fonksiyon üzerinden her bir piksel dönüştürülmekte, bu sayede düzensiz kontrast dağılımı iyileştirilmektedir. AHE algoritmasının en temel hali için dönüşüm fonksiyonu, pikseli çevreleyen karenin histogramı olmaktadır (Zuiderveld, 1994).

Kontrast Sınırlı - Adaptif Histogram Eşitleme (KS-AHE) algoritması, AHE algoritmasının kullanıldığı ve kontrastın iyileştirildiği bir tekniktir. KS-AHE algoritması, kontrast limitleme özelliği ile genel histogram eşitleme işleminden farklı olmaktadır. Kontrast limitleme işlemi, kontrast seviyesindeki artışa paralel olarak gürültü seviyesinin yükselmesini önlemektedir.

3.2.6. Uzamsal bulanık-c ortalamalar

Uzamsal Bulanık C-Ortalamalar (UBCO) algoritması, veri setini bir veya daha fazla sınıfa ayırmayı sağlayan etkili bir kümeleme tekniğidir. UBCO tekniği, eşitlik (3.3) içerisinde belirtildiği üzere iteratif bir yapı olup, maliyet fonksiyonu minimize olduğu durumda kümeleme işlemini gerçekleştirir.

$$J = \sum_{j=1}^{N} \sum_{i=1}^{c} u_{ij}^{m} \left\| x_j - v_i \right\|^2 \tag{3.3}$$

(3.3) eşitliği içerisinde (Chuang ve ark., 2006; Yang ve Huang, 2012); u_{ij}, *i.* kümeye ait olan x_i' nin üyeliklerini temsil etmekte, *c* parametresi ise kümelerin sayısını ifade etmektedir. v_i, *i.* kümenin merkezini, *m* ise bulanıklık sabitini simgelemektedir. Maliyet fonksiyonunun minimizasyonu, küme merkezlerine yakın değerler üzerinde sağlanmaktadır.

UBCO algoritması içerisinde üyelikler (u_{ij}) ve merkezler (v_i), sırasıyla (3.4) ve (3.5) eşitliklerine göre güncellenmektedir (Chuang ve ark., 2006).

$$u_{ij} = \frac{1}{\sum_{k=1}^{c} \left(\frac{\left\| x_j - v_i \right\|}{\left\| x_j - v_k \right\|} \right)^{\frac{2}{(m-1)}}} \tag{3.4}$$

$$v_i = \frac{\sum_{j=1}^{N} u_{ij}{}^{m} x_j}{\sum_{j=1}^{N} u_{ij}{}^{m}} \tag{3.5}$$

UBCO algoritması, komşu pikseller boyunca uzamsal bilgiyi kullanmaktadır. Diğer bir deyişle, komşu piksellerin benzer özellikler taşıdığı esasına dayanmaktadır. Bu amaçla, (3.6)' da ifade edilen bir uzamsal fonksiyon üzerinden işlem yapılmaktadır.

$$h_{ij} = \sum_{k \in NB(x_j)} u_{ik} \tag{3.6}$$

(3.6) eşitliği içerisinde (Chuang ve ark., 2006); $NB(x_j)$, x_j pikseli üzerinde kare pencereyi ifade etmekte, h_{ij} ise x_j' nin *i.* kümeye ait olup olmadığı koşuluna göre olasılık hesabını gerçekleştirmektedir. Bu noktada h_{ij} değerleri, komşu piksellerin çoğunun, x_j ile aynı sınıfa ait olması durumunda yüksek çıkmaktadır. Uzamsallık özelliği, UBCO algoritmasına (3.7)' de görüldüğü gibi entegre edilmektedir.

$$u_{ij}{}' = \frac{u_{ij}^{p} h_{ij}^{q}}{\sum_{k=1}^{c} u_{kj}^{p} h_{kj}^{q}} \tag{3.7}$$

(3.7) eşitliği içerisindeki p ve q kontrol parametrelerini ifade etmektedir. Bütün bir işlem ise, kümeleme sonuçlarının gürültüden etkilenmesini önlemektedir. Bu aşamada komşu piksellerin yoğunlukları ve ağırlıkları etkin olmaktadır.

3.2.7. Morfolojik kapama algoritması

Morfolojik Kapama, görüntü içerisinde bulunan objelerin gri seviye değerlerini birbirine bağlamak için kullanılmaktadır. Algoritmanın dezavantajı, yapı elemanından

daha küçük bölgeleri de doldurabilmesinden dolayı yüksek gürültü seviyelerinden etkilenmesidir.

Morfolojik Kapama işlemi, Görüntü Genişletme işleminde bulunan yapı elemanlarının aynılarını içermektedir. Morfolojik Kapama, gri seviyeli görüntüler üzerine (3.8) eşitliği kullanılarak gerçekleştirilir (Van Den Boomgaard ve Van Balen, 1992; Koss ve ark., 1999).

$$A \bullet B = (A \oplus B)\theta B \tag{3.8}$$

(3.8) eşitliği içerisinde Kapama ($A \bullet B$) işlemi, Genişletme ($A \oplus B$) ve Erozyon (θB) işlemlerinin birleştirilmesi ile elde edilmektedir.

3.2.8. Sıfır-geçiş eliminatörü

Sıfır-geçiş Eliminatörü (SE), bütün yoğunluk değerlerinin sıfıra eşit olduğu satır ve sütunların görüntüden çıkarılması işlemini gerçekleştirmektedir. SE yaklaşımının algoritması Çizelge 3.3' te görüldüğü gibidir.

Çizelge 3.3. SE yaklaşımının algoritması

SE algoritması
- Görüntü içerisinde dikey ve yatay yönlerde toplam vektörlerini bul
For i=1 to yatay vektör uzunluğu - Görüntünün Sol tarafından itibaren saymaya başla ve bir gri seviye değerine ulaşıldığında koordinatları kaydet end
For i=1 to yatay vektör uzunluğu - Görüntünün Sağ tarafından itibaren saymaya başla ve bir gri seviye değerine ulaşıldığında koordinatları kaydet end
For i=1 to dikey vektör uzunluğu - Görüntünün Üst tarafından itibaren saymaya başla ve bir gri seviye değerine ulaşıldığında koordinatları kaydet end
For i=1 to dikey vektör uzunluğu - Görüntünün Alt tarafından itibaren saymaya başla ve bir gri seviye değerine ulaşıldığında koordinatları kaydet end
- Abdomen kenarlarına en yakın olan son koordinatları tespit et
- Sıfır olmayan çıkışları koordinatları kullanarak elde et

SE yaklaşımı ile sütun ve satırların toplamları üzerinden işlem yapılmaktadır. SE yaklaşımı, toplama işlemi sonrasında görüntü dış - orta noktalarından (dört orta noktadan) abdomene doğru tarama yaparak sıfır değeri içeren vektörleri elimine etmektedir.

3.3. Gaussian Gürültü Eliminasyonunda Kullanılan Metotlar

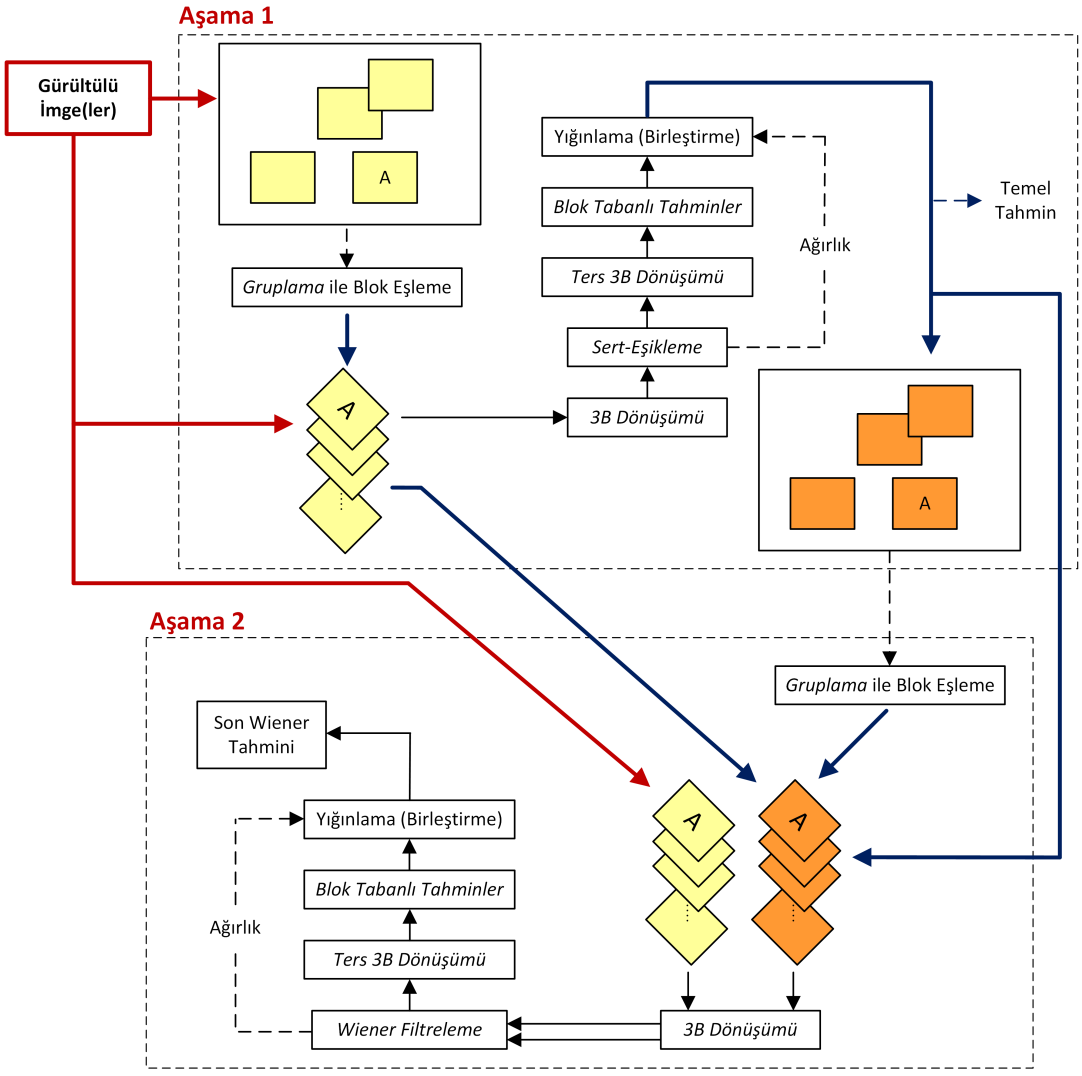
Literatürde Eklenebilir Beyaz Gauss Gürültüsü (EBGG)' nün ele alındığı birçok çalışma vardır. EBGG eliminasyonunda en çok kullanılan algoritma Blok Eşleştirme ve 3B Filtreleme (BE3BF)' dir. Çalışmada, BE3BF ve literatürde yer alan 13 farklı metodun karşılaştırması yapılmıştır. Gaussian gürültü eliminasyonu için BT görüntüleri üzerinde sonuçları karşılaştırılan algoritmalar şunlardır:

1. Medyan filtre
2. Wiener filtresi
3. Durağan Dalgacık Dönüşümü (DDD)
4. LPY-GAK (Lokal Polinomal Yaklaşım – Güven Aralıklarının Kesişimi)
5. Ayrık Kosinüs Dönüşümü Tabanlı Sözlük (AKD-S)
6. Adaptif Sözlük (AS)
7. Çift Domende Gürültü Giderme (ÇDGG)
8. Şekle Adaptif – Ayrık Kosinüs Dönüşümü (ŞA-AKD)
9. Olası Yama Logaritmik Benzerliği – Gaussian Karışım Modeli (OYLB-GKM)
10. Yama Tabanlı Global Temel Bileşen Analizi (YGTBA)
11. Yama Tabanlı Lokal Temel Bileşen Analizi (YLTBA)
12. Yama Tabanlı Hiyerarşik Temel Bileşen Analizi (YHTBA)
13. Tekil Değer Ayrışımı içeren Düşük Dereceli Model (DDM-TDA)
14. Blok Eşleştirme ve 3B Filtreleme (BE3BF)

En iyi sonuçların elde edildiği BE3BF tekniği, bu bölüm içerisinde olabildiğince ayrıntılı bir şekilde izah edilmektedir.

3.3.1. Blok eşleme ve 3B filtreme (BE3BF) algoritması

Blok Eşleştirme ve 3B Filtreleme (BE3BF) tekniği, Dabov ve ark. (2007) tarafından önerilen etkin bir gürültü giderme algoritmasıdır. BE3BF algoritması, dönüşüm domeninde ayrık temsilleri temel alan bir yaklaşımdır. Metot, 2B olarak ifade edilen görüntüyü daha küçük bloklara ayırır. Diğer aşamada 2B bloklar, filtrelerin uygulanacağı 3B domeninde ifade edilmekte, iki boyuttan üç boyuta dönüştürme mantığı üzerinden gürültü giderme gerçekleştirilmektedir. Bu yönüyle 2B veri için 3B domen üzerinde dönüşüm ile işlemi gerçekleştirdiğinden, BE3BF metodu literatürde önerilen birçok gürültü giderme yaklaşımından farklıdır. BE3BF algoritması akış diyagramı Şekil 3.2' de görüldüğü gibidir (Dabov ve ark., 2007).



Şekil 3.2. BE3BF tekniği akış diyagramı

Şekil 3.2 içerisinde gerçekleştirilen işlemler, genel olarak iki temel adımdan meydana gelmektedir. Bu adımlar *Temel Tahmin* ve *Son Tahmin* şeklinde olup, adımlar içinde kullanılan yaklaşımların çalışma prosedürleri aşağıda ifade edildiği üzere gerçekleştirilir (Dabov ve ark., 2007):

1. *Temel Tahmin (Basic Estimate)*

- *Blok Tabanlı Tahminler:* Gürültü içeren görüntüdeki her bir blok için aşağıdaki işlemler gerçekleştirilir.
  - *Gruplama:* İlk aşamada üzerinde işlem yapılan bloğa benzer bloklar tespit edilmekte, ardından bu bloklar bir 3B dizi (grup) oluşturulacak şekilde yığın haline getirilmektedir (Dabov ve ark., 2007).
  - *İşbirlikçi Sert-Eşikleme:* İlk aşamada oluşturulan gruba *3B Dönüşüm* işlemi uygulanmaktadır. Ardından görüntü içindeki gürültü, dönüşüm katsayılarında *Sert-Eşikleme* uygulanması ile baskılanmaktadır. Üçüncü aşamada bütün gruplanmış bloklarda tahminlerin üretimi için *Ters 3B Dönüşüm* işlemi gerçekleştirilir. Son aşamada elde edilen *Blok Tahminleri*, blokların başlangıç görüntüsündeki orijinal konumları temel alınarak yerleştirilir (Lebrun, 2012).

- *Yığınlama:* Gürültü içeren görüntüdeki her bir blok için aşağıdaki işlemler gerçekleştirilir.
  - *Gruplama:* Görüntü *Temel Tahmini*, üst üste çakışan (overlap meydana getiren) *Blok Tabanlı Tahminlerin* ağırlıklı ortalaması üzerinden hesap edilir (Dabov ve ark., 2007).

2. *Son Tahmin (Final Estimate): Temel Tahminler* üzerinden iyileştirilmiş *Gruplama* ve *İşbirlikçi Wiener Filtreleme* işlemleri gerçekleştirilir.

- *Blok Tabanlı Tahminler:* Her bir blok için aşağıdaki işlemler gerçekleştirilir.
  - *Gruplama:* İlk aşamada üzerinde işlem yapılan bloğa benzer blokların lokasyonları, *Temel Tahmin* üzerinde *Blok Eşleme* işleminin gerçekleştirilmesi ile tespit edilir. Bu noktada iki farklı 3B dizi oluşturulmakta, gruplardan biri gürültülü görüntüden (orijinal görüntüden), diğeri ise *Temel Tahmin* üzerinden elde edilmektedir (Lebrun, 2012).

- *İşbirlikçi Wiener Filtreleme:* İlk aşamada her bir bloğa *3B Dönüşümü* uygulanır. İkinci aşamada gürültülü gruba, *Temel Tahmindeki* enerji spektrumu (referans enerji spektrumu) üzerinden *Wiener Filtreleme* işlemi uygulanır. Üçüncü aşamada ise filtrelenen katsayılar üzerinde *Ters 3B Dönüşüm* uygulanmakta, bütün gruplanmış blokların tahminleri bu sayede üretilmektedir. Son aşamada *Blok Tahminleri*, blokların görüntü içerisindeki orijinal lokasyonlarına göre yeniden yerleştirilir (Lebrun, 2012).

- *Yığınlama:* Görüntü üzerine *Son Tahmin* üretilmesi sağlanmaktadır. Bu amaçla, bütün *Lokal Tahminlerin* ağırlıklı ortalaması yığın haline getirilerek, gürültü giderme gerçekleştirilmektedir (Dabov ve ark., 2007; Lebrun, 2012).

  BE3BF algoritması içindeki iki farklı yaklaşımın avantajları şu şekildedir:

  1. Gürültülü (orijinal) görüntü yerine *Temel Tahminin* kullanımı, *Blok Eşleme* ile gerçeklenen *Gruplama* işlemini iyileştirmektedir.
  2. *Temel Tahmin* verisinin yapay *Wiener Filtrelemede* referans olarak kullanımı, (gürültülü verinin 3B spektrumunda) Sert-Eşikleme sonucu oluşacak verinin kullanımından daha kesin ve verimli sonuçlar üretmektedir.

Özetle BE3BF tekniği, gürültü giderme işlemini dört temel mantık üzerinden gerçekleştirmektedir. Bunlar; gruplama, filtreleme, 3B dönüşüm ve yığınlama şeklindedir (Dabov ve ark., 2007).

3.4. Görüntü İyileştirme Çalışmasında Kullanılan Metotlar

Önerilen görüntü iyileştirme sistemi 3 farklı yöntemin hibrit hale getirilmesi ile elde edilmektedir. Bu metotlar şu şekilde sıralanabilir:

- Blok Eşleştirme ve 3B Filtreleme (BE3BF)
- Hızlı Bağlantılı-Vuru Kortikal Modeli (HB-VKM)
- Otsu

BE3BF yaklaşımı, Bölüm 3.3.1 kapsamında izah edilmektedir.

3.4.1. Hızlı bağlantılı - vuru kortikal modeli

Vuru Kortikal Modeli (VKM), Darbe Kuplajlı YSA (Pulse Coupled Neural Network) modelinden esinlenerek geliştirilmiş bir algoritmadır. Literatür çalışmalarında, Darbe Kuplajlı YSA tekniğinin çok fazla parametreye bağımlı olduğu görülmüştür. Zhan ve ark. (2009), bu dezavantajın eliminasyonu için VKM yaklaşımını önermişlerdir. Zhan ve ark. (2015), sonraki çalışmalarında VKM tekniği içerisine *Hızlı Bağlantı* işlemini eklemiş, VKM tekniğinin daha hızlı bir türevi olan Hızlı Bağlantı - Vuru Kortikal Modeli (HB-VKM)' ni geliştirmişlerdir.

HB-VKM yaklaşımı, nöronlara uygulanacak bir etki ile elde edilecek olan tepki üzerine geliştirilmiştir. Buna göre dinlenme evresinde bulunan nöron, dürtü ile uyarıldığı durumda hücre zarı potansiyeli doğrudan yüklü hale gelmektedir (şarj edilmektedir). Aynı zamanda hücre zarı potansiyeli (membran potansiyeli), komşu nöronların postsinaptik aksiyon potansiyeli ile değiştirilebilmektedir. Bu noktada VKM' ne dair zar potansiyeli, etki ve sinaptik değişimin bir kombinasyonu olarak hesap edilmektedir. Nörona dair zar potansiyeli, kendisine uygulanacak dürtünün eşik (threshold) değerini geçmesi halinde bir vuru (spike) meydana getirmektedir. VKM tekniği, yukarıda belirtilen karakteristikler doğrultusunda, nöronlarda meydana gelen elektriksel aktivite üzerine şekillenmektedir. VKM tekniği iki temel aşamadan oluşur: (a) Bağlantı (Linking), (b) Besleme (Feeding). VKM mantığının matematiksel gösterimi (3.9), (3.10) ve (3.11) eşitlikleri ile sunulmaktadır (Zhan ve ark., 2015).

$$U_{ij}(n) = fU_{ij}(n-1) + S_{ij}(1 + \beta \sum_{kl} W_{ijkl} Y_{kl}(n-1)) \tag{3.9}$$

$$Y_{ij}(n) = \begin{cases} 1, & if \;\; U_{ij}(n) > \Theta_{ij}(n-1) \\ 0, & otherwise \end{cases} \tag{3.10}$$

$$\Theta_{ij}(n) = g\Theta_{ij}(n-1) + hY_{ij}(n) \tag{3.11}$$

(3.9), (3.10) ve (3.11) eşitlikleri içerisinde (Zhan ve ark., 2015); her bir nöron (i,j) indisleri ile ifade edilirken, komşu nöronlar (k,l) indisleri ile simgelenmektedir. S_{ij}, (i,j) koordinatlarındaki nöron üzerine uygulanan harici etkiyi, $U_{ij}(n)$ ise iteratif zaman n olduğu durumda zar potansiyelini ifade etmektedir. $\Theta_{ij}(n)$ eşik değerini, $Y_{ij}(n)$ ise çıkışta

üretilen vuruyu temsil etmektedir. Komşu nöronların etkisinde olan merkez nörondaki değişim (modülasyon), *W* ve *Y*' nin konvolüsyonları üzerinden elde edilmektedir. Bu noktada kullanılan *Sinaptik Ağırlık Matrisi* (*W*), *Algısal Alanı* (Receptive Field) simgeleyen Gaussian kerneli özelliğindedir ve matris boyutu *kl* ile ifade edilir. β bağlantı (linking) katsayısını, $f(0 < f < 1)$ zar potansiyelinin sönümleme sabitini, *f* ise zar potansiyelindeki artış hızını simgelemektedir. $g(0 < g < 1)$ eşik değerinde sönümleme sabiti olup, bu sabit değer, Bağıl Mukavemet Periyodu (Relative Refractory Period) üzerine karar verici olmaktadır. Diğer bir deyişle, büyük bir *g* değerine sahip olan nöron, üreteceği vuruyu olması gerekenden daha hızlı üretmektedir. *h* değeri ise, Mutlak Mukavemet Periyodu (Absolute Refractory Period) üzerinde etkin olmaktadır. Bu aşamada henüz vuru üreten bir nöron, yüksek bir dürtü dahi almış olsa kısa zaman içinde yeni bir vuru üretememektedir.

Zar potansiyeli, $\beta = 0$ olduğu durumda (3.12) eşitliğine göre elde edilmektedir (Zhan ve ark., 2015).

$$U_{ij}(n) = fU_{ij}(n-1) + S_{ij} \tag{3.12}$$

(3.12) eşitliği içerisinde; zar potansiyeli ($U_{ij}(n)$) ile iterasyon zamanı (n) arasındaki fonksiyonel bağlantı, (3.13) eşitliğine göre elde edilmektedir (Zhan ve ark., 2015).

$$U_{ij}(n) = \left(U_{ij}(0) - \frac{S_{ij}}{1-f} \right) f^n + \frac{S_{ij}}{1-f} \tag{3.13}$$

(3.13) eşitliği içerisinde yer alan $U_{ij}(0)$, zar potansiyelinin başlangıçtaki durumunu simgelemektedir.

Zar potansiyelinin Stabil Durumu (Stable State), *f* değeri 1' den küçük pozitif bir reel sayı olarak seçildiğinde ve *n* iterasyon sayısı çok büyük değerlere ulaştığı durumda ($S_{ij}/(1-f)$) değerine doğru yönelmektedir.

$\Theta_{ij}(n)$ eşik değeri, nöron ilk vuruyu üretmeden önce, $\Theta_{ij}(0)$ başlangıç değerinden itibaren azalmaya devam etmektedir. Bu durum (3.14) eşitliği içerisinde ifade edilmekte olup, eşitliğin *Lineer Azalma Fonksiyonu* temelli formatı (3.15) kapsamında görüldüğü gibidir (Zhan ve ark., 2015).

$$\Theta_{ij}(n) = \Theta_{ij}(0) g^{n} \tag{3.14}$$

$$\Theta_{ij}(n) = \Theta_{ij}(n-1) - \delta = \Theta_{ij}(0) - n\delta \tag{3.15}$$

VKM yaklaşımı içindeki *Hızlı Bağlantı* (Fast Linking) bölümü, Çizelge 3.4' te görüldüğü gibidir (Zhan ve ark., 2015).

Çizelge 3.4. Hızlı bağlantı algoritması

Hızlı Bağlantı (Fast Linking) Algoritması
1- n=0 (*N*=iterasyon sayısı)
2- **Genel döngü** (n≤N) iken
3- n=n+1;
4- **İkinci döngü**
5- Sonraki_Y=Y;
6- Zar potansiyeli (*U*) ve Vuru (*Y*) değerlerini güncelle
7- **İkinci döngü sonlandırma kriteri** (post_Y=Y)
8- Θ eşiğini güncelle
9- **Genel döngü sonu**

Hızlı Bağlantı, benzer uyarıcılı nöronların eliminasyonunu normalden daha hızlı bir şekilde gerçekleştirmektedir. *Hızlı Bağlantı* bölümü içerisinde iki adet döngü bulunmaktadır. Zar potansiyeli ve aksiyon potansiyeli, iç (ikincil) döngüde aksiyon potansiyeli değeri sabitlenene kadar güncellenmektedir. Eşik değeri ise dış (birincil) döngü içerisinde güncellenmektedir (Zhan ve ark., 2015).

3.4.2. Otsu eşikleme algoritması

Otsu veya Sınıflar Arası Varyans (Between Class Variance) yöntemi, Otsu (1979) tarafından önerilen bir eşikleme algoritmasıdır. Bu parametrik olmayan (nonparametric) ve denetlenmeyen (unsupervised) yöntem, sınıflar arası varyans üzerinden segmentasyon işlemini yerine getirmektedir. Bu amaçla orijinal görüntü (*I*) farklı sınıflara ayrılır ve en iyi eşik değer(ler)i ise sınıflar arası varyansın maksimum olduğu seviyede elde edilir. Sınıflar arası varyansın maksimizasyonu, görüntü histogram analizi ile gerçekleştirilir. Otsu Eşikleme prosedürü, en temel formda aşağıdaki gibi ifade edilmektedir (Otsu, 1979; Devi, 2006):

Piksellerin ait olacağı sınıf sayısı "2" olarak belirlenir (C1 & C2). Böylece C1 & C2' ye dair gri seviye aralıkları sırasıyla [*1,...,t*] & [*t+1,...,L*] şeklinde tanımlanmış olur. İkili sınıf için olasılık dağılımları (p_i), *i.* gri seviyenin görüntüde meydana gelme durumu (p_i=*i. gri seviye tekrar sayısı / piksel sayısı*) olarak bilinir. Eşik değeri *t* olduğu durumda, olasılık dağılımları kullanılarak ağırlık değerleri ($w_1(t)$, $w_2(t)$) elde edilir. Her bir sınıf için olasılıksal işlemler ve ağırlıkların (kümülatif olasılıkların) eldesi sırasıyla (3.16) ve (3.17) eşitlikleri ile tespit edilir.

$$C_1 : p_1 / w_1(t), ..., p_t / w_1(t) \;\; \& \;\; C_2 : p_{t+1} / w_2(t), ..., p_L / w_2(t) \tag{3.16}$$

$$w_1(t) = \sum_{i=1}^{t} p_i \quad \& \quad w_2(t) = \sum_{i=t+1}^{L} p_i \tag{3.17}$$

İkili sınıf için ortalama değerler (μ_1, μ_2) ve sınıflar arası varyans ($\sigma_B^2(t)$), sırasıyla (3.18) ve (3.19) eşitlikleri kullanılarak hesap edilmektedir.

$$\mu_1 = \sum_{i=1}^{t} i.p_i / w_1(t) \;\; \& \;\; \mu_2 = \sum_{i=t+1}^{L} i.p_i / w_2(t) \tag{3.18}$$

$$\sigma_B^2 = w_1(\mu_1 - \mu_T)^2 + w_2(\mu_2 - \mu_T)^2 \tag{3.19}$$

Otsu algoritmasında sınıflar arası varyansın maksimizasyonu, optimum eşik (threshold) değeri (*t*) elde edildiği durumda gerçekleşmektedir.

3.5. Sürrrenal Lezyon Segmentasyonunda Kullanılan Metotlar

Çalışmada sürrenal lezyon segmentasyonu için önerilen yapı 5 farklı teknikten oluşmaktadır. Bu teknikler şu şekilde sıralanabilir:

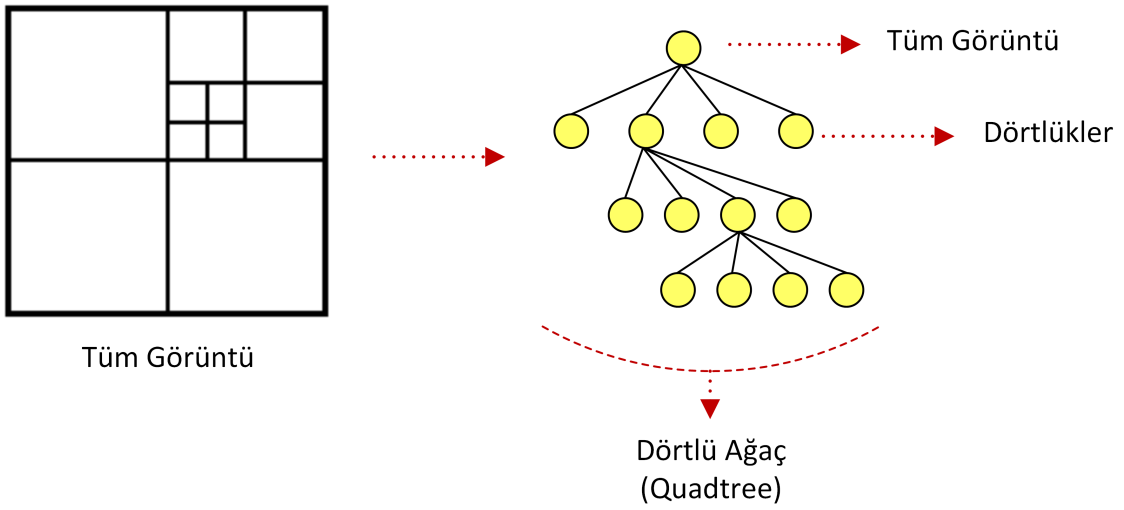
1. Kontrast Sınırlı - Adaptif Histogram Eşitleme Algoritması (KS-AHE)
2. Dörtlü Ağaç Ayrıştırma Tabanlı Bölme ve Birleştirme Yöntemi (DAA-BB)
3. Ortalama Kayma Segmentasyon Tekniği (OKS)
4. Geniş Gri Değer Eliminatörü (GDE)
5. Büyüyen Alan Algoritması (BA)

Yukarıda yer alan tekniklerden KS-AHE yaklaşımı Bölüm 3.2.5' de sunulmuştur.

3.5.1. Dörtlü ağaç ayrıştırma tabanlı bölme ve birleştirme yöntemi

Bölme ve Birleştirme yöntemi, görüntünün düzenli alanlara ayrışmasını sağlamaktadır (Sonka ve Fitzpatrick, 2000).

Alan Bölme (Region Splitting) yöntemleri, Büyüyen Alan (Region Growing) tekniğine zıt bir mantığa sahiptir. Bu teknikler bütün bir görüntü üzerinden işlem yapmaya başlar ve bir benzerlik (uniformity) kriteri üzerinden benzer sonuçlar üreten bölgeleri birleştirir. Kriterin sağlanmadığı durumlarda ise görüntü 4 alt bölüme ayrılır. Bu süreç kriter sağlanıncaya kadar iteratif olarak devam ettirilir. Görüntü, işlem tamamlandığı durumda birçok Dörtlü Ağaç (Quadtree) yapısı olarak ifade edilmektedir. Dörtlü Ağaç yapısının temelinde bir ana düğüm ve buna bağlı 4 çocuk düğüm bulunur. Bu yapının görüntü üzerine uygulanışı Şekil 3.3' de görüldüğü gibidir (Sonka ve Fitzpatrick, 2000).



Şekil 3.3. Dörtlü ağaç (Quadtree) yapısının görüntü üzerinde temsili

Birleştirme bölümünün bölme işlemine entegrasyonu, her aşamada benzer özelliğe sahip alanların birleştirilmesini sağlamaktadır. Kullanılan fonksiyon içerisinde yer alan koşullara uygun (benzer ortalama değerlere, belirli bir varyans içinde sahip olan) alanların eldesi ile segmentasyon işlemi gerçekleştirilir. Bölme ve Birleştirme yöntemi içerisinde, yakın sonuçlara sahip ve aynı ana düğüme bağlı olmayan bitişik

alanlar birleştirilememektedir. Dörtlü Ağaç Ayrıştırma yöntemi ise bu dezavantajı elimine edebilmek amacıyla algoritmanın son adımına eklenmektedir (Sonka ve Fitzpatrick, 2000).

SMQD algoritması üç adımda tanımlanmaktadır (Sonka ve Fitzpatrick, 2000):

1. Bir benzerlik kriteri tanımla
2. Görüntü içerisinde benzerlik kriterini sağlamayan her bir bölgeyi 4 alt bölgeye ayır ve ana düğüme bağlı olan çocuk düğümlerde kriterin sağlandığı bölgeleri birleştir
3. Eğer Bölme veya Birleştirme işlemi yapılamıyorsa, bitişik olan bölgeleri ana düğümlere göre tespit et ve kriteri sağlayan alan varsa birleştir

Çalışma içerisinde kullanılan DAA-BB algoritması, alanların birbirine entegrasyonunu sağlayan iki parametreyi temel alır. *Ortalama* ve *varyans* olarak bilinen bu parametreler, benzerlik kriteri olarak kullanılmaktadır.

3.5.2. Ortalama kayma segmentasyon tekniği

Ortalama Kayma Segmentasyon (OKS) algoritması, özellik uzayında mod değerlerini kullanarak, rasgele şekilli kümeler üzerinde işlem yapmaktadır x veri noktaları üzerinde gradyent hesabı yapılarak, gradyent değerinin sıfıra eşit olduğu ($\nabla f(x) = 0$) değerler mod değerlerini ihtiva olarak atfedilmektedir. OKS yöntemi, kümeler içinde benzer yoğunluğa sahip olan piksel değerlerini birleştirmek (yakın gri seviyelere çekmek) amacıyla kullanılır. Metot, 2B bir görüntüyü müşterek uzamsal – aralık domenine aktarmaktadır. Bu noktada amaç, görüntü içi objelerin yoğunluk yönelimlerinin tespit edilmesidir (Comaniciu ve Meer, 2002).

Uzamsal ve aralık olguları sırasıyla lokasyon ve renk özelliklerini simgelemektedir. Görüntü içinde bir objenin piksel değerleri, uzamsal ve aralık kernelleri kullanılarak mod pikseline doğru yakınsatılır. Kernellerin boyutu (bant genişliği), OKS algoritmasının çalışmasını doğrudan etkilemektedir. Çünkü çalışma alanı ve mod tespiti doğrudan kullanılan kernele bağımlıdır (Comaniciu ve Meer, 2002).

OKS algoritması, piksellerin yakınsamaları noktasında lokasyon (uzamsal) ve renk (aralık) özelliklerinin bağımlı olduğu üç parametreyi kullanmaktadır. Bunlar; uzamsal kernel band genişliği, aralık kerneli band genişliği ve yakınsama kriteri

eşiğidir. Teknik içerisinde kullanılan çoklu kernel yapısı (3.20)' de görüldüğü gibidir (Comaniciu ve Meer, 2002).

$$K_{h_s h_r}(x) = \frac{C}{h_s^2 h_r^p} k\left(\left\|\frac{x^s}{h_s}\right\|^2\right) k\left(\left\|\frac{x^r}{h_r}\right\|^2\right) \tag{3.20}$$

(3.20) eşitliği içerisinde; x^s ve x^r özellik vektörünün uzamsal ve aralık bölümlerini, *k(x)* her iki domende de kullanılan genel profili, *C* normalizasyon sabitini, *p* ise (gri seviyeli görüntülerde 1) görüntü boyutunu simgelemektedir. Uzamsal kernel band genişliği h_s ile ifade edilirken, aralık kerneli band genişliği h_r ile gösterilmektedir. Mod tespitindeki çözünürlük, kernellerin boyutları değiştirilerek en iyi seviyeye getirilebilmektedir (Comaniciu ve Meer, 2002).

OKS, kullanıcı tarafından ayarlanması gereken üç parametre içermektedir. Bu parametreler; aralık kerneli band genişliği (h_r), uzamsal kernel band genişliği (h_s) ve yakınsama kriteri eşiği (*M*)' dir. Yakınsama kriteri eşiğinden daha düşük piksel içeren ayrık alanlar, segmentasyon işlemi dâhilinde elimine edilmektedir. OKS yaklaşımının algoritması Çizelge 3.5' de görüldüğü gibidir (Comaniciu ve Meer, 2002).

Kernel Band Genişlikleri (h_s, h_r), "4" ve katları olarak tanımlandığında etkin sonuçlar üretildiği bilinmektedir (Comaniciu ve Meer, 2002). Yakınsama kriteri eşiği (*M*), gri seviye görüntülerde ve yoğunluk değerleri çift (*double*) olarak belirtildiği durumda sırasıyla [0, 255] ve [0, 1] arasında ifade edilmektedir.

Çizelge 3.5. OKS yaklaşımının algoritması

OKS algoritması
1-) Ortalama kayma filtreleme işlemini gerçekleştir ve görüntüdeki yakınsama noktaları hakkında bilgileri tut
2-) Kümeleri, ortak etki alanında bütün yakınsama noktalarını gruplayarak tanımla. Bu aşamada uzamsal domende h_s ve aralık domeninde h_r boyutundan daha yakın olan yakınsama noktaları gruplanmalıdır. İlgili yakınsama noktalarının bulunduğu alanları birbiri ile bağla
3-) Piksellere ait yeni değerleri yakınsama noktalarına göre ata
4-) *M* adet pikselden daha az piksel içeren ayrık bölgeleri elimine et

3.5.3. Geniş gri değer eliminatörü

Geniş Gri Değer Eliminatörü (GDE), lezyonlardan farklı abdomen içi alanlarda, gri seviyelerin bozulması amacı ile oluşturulmuştur.

Sürrenal lezyonlar, kontrast madde tutmalarından dolayı genel olarak heterojen bir görünüme sahip olmaktadır. GDE yaklaşımı, çok fazla tekrar eden gri seviyelerin (histogram üzerinde en büyük değerlerin) eliminasyonu sağlanmakta, karaciğer vb. geniş dokuların üzerinde işlem yapılmakta, böylece sürrenal lezyonların bir miktar daha ön plana çıkmasını sağlamaktadır. Histogram üzerindeki en büyük ilk altı değer (en sık tekrar eden altı gri seviye) görüntü içerisinden çıkarılmaktadır. Böylece gereksiz dokuların belirli oranda baskılanması sağlanmaktadır. GDE yaklaşımının algoritması Çizelge 3.6' da görüldüğü gibidir.

Çizelge 3.6. GDE yaklaşımının algoritması

GDE yaklaşımının sözde kodu
1-) İmge histogramını elde et
2-) Histogram üzerindeki değerleri büyükten küçüğe sırala
3-) En sık tekrar eden 6 adet gri seviyeyi tespit et
4-) Bütün bir görüntüyü tara ve tespit edilen gri seviyelere sahip olan piksellere "0" değeri ata

3.5.4. Büyüyen alan algoritması

Büyüyen Alan (BA), potansiyel bölge içinde bir pikselle başlamakta, komşu piksellerin benzerliği test edilerek ilgili alan büyütülmektedir. İlk piksel veya belli sayıda başlangıç pikseli (tohum veya tohumlar) manuel ya da otomatik olarak görüntü üzerinden seçilmektedir. Başlangıç pikseli ile küme pikseller arasında bir benzerlik ölçüsü tanımlanmalıdır. Bu ölçüt, büyümenin ana kriteridir (Zharkova ve Jain, 2007).

Gri seviye tolerans aralığı, BA' nın en temel formu ele alındığında sisteme dair tek parametredir. Tohum pikselinin veya alanının yoğunluk değeri, bu aralık dâhilinde komşu pikseller ile karşılaştırılarak yayılma gerçekleştirilir. BA yaklaşımının algoritması Çizelge 3.7' de görüldüğü gibidir (Zharkova ve Jain, 2007). Tolerans değeri, tohum pikselinin komşuluğundaki piksellerden hangisinin alana dâhil olacağına karar vermek için kullanılır (Zharkova ve Jain, 2007).

Çizelge 3.7. BA yaklaşımının algoritması

RG algoritması
1-) Tohum pikselini seç
2-) Komşu pikselleri tara ve tohum pikseline yakın yoğunluk göstermeleri durumda kümeye dâhil et
3-) Bir önceki adımı yeni eklenecek olan bütün piksellere uygula ve hiçbir piksel eklenemeyeceği zaman dur

3.6. Sürrenal Lezyonların Sınıflandırılmasında Kullanılan Metotlar

Tez çalışmasında segmente edilen sürrenal lezyonlar, 5 farklı sınıflayıcıda sınıflandırılarak sonuçlar karşılaştırılmıştır. İkili sınıflama (iyi huylu / kötü huylu) için özellik çıkarma işlemi gerçekleştirilmiştir. Çalışmada farklı özellik çıkarma yaklaşımları kullanılarak sınıflandırıcı performansı artırılmaya çalışılmıştır. Histogram ve GDEM tabanlı özellikler, orijinal görüntü ve dalgacık dönüşümü çıkışları temel alınarak üretilmiştir. Her bir sınıflayıcı metot özellikler ile test edilerek en iyi ikili (özellik çıkarma – sınıflandırıcı) tespit edilmiştir. Kullanılan sınıflayıcılar şu şekilde sıralanabilir:

1. Yapay Sinir Ağları (YSA)
2. Yapay Arı Kolonisi Algoritması - Yapay Sinir Ağları (YAKA-YSA)
3. Parçacık Sürü Optimizasyonu - Yapay Sinir Ağları (PSO-YSA)
4. Kâşif Parçacık Sürü Optimizasyonu - Yapay Sinir Ağları (KPSO-YSA)
5. Sınırlı PSO-YSA

3.6.1. Özellik çıkarma aşamasında kullanılan metotlar

Çalışmada görüntü histogramı, Gri Düzey Eş Oluşum Matrisi (GDEM) yöntemi ve Ayrık Dalgacık Dönüşümü (ADD) kullanılarak sürrenal lezyonlardan özellik çıkarılmıştır. Global ve lokal olmak üzere iki farklı özellik grubu oluşturulmuştur.

Global Özellikler: Histogram, görüntü içindeki gri seviye dağılımının görsel olarak ifade edilmesini sağlar. Histogram tabanlı özellikler, görüntü içi objelerin şekil, boyut ve yoğunlukları hakkında özet bir bilgi sağlamaktadır. Histogram tabanlı özellikler, Global Özellikler veya Birincil Derece İstatistikler olarak ifade edilmektedir (Bevk ve Kononenko, 2002; Hsieh ve ark., 2017). Bu istatistikler; ortalama, varyans, eğrilik, basıklık, enerji ve kazanç olarak sıralanır. Söz konusu istatistikler sırasıyla (3.21) - (3.26) eşitlikleri ile sunulmuştur (Bevk ve Kononenko, 2002; Hsieh ve ark., 2017).

$$Ortalama = \sum_{g=0}^{G-1} gH(g) \tag{3.21}$$

$$Varyans = \sum_{g=0}^{G-1} (g - Ortalama)^2 H(g) \tag{3.22}$$

$$Eğrilik = \frac{\sum_{g=0}^{G-1}(g - Ortalama)^3 H(g)}{Varyans^{3/2}} \tag{3.23}$$

$$Basıklık = \frac{\sum_{g=0}^{G-1}(g - Ortalama)^4 H(g) - 3}{Varyans^2} \tag{3.24}$$

$$Enerji = \sum_{g=0}^{G-1} H(g)^2 \tag{3.25}$$

$$Kazanç = -\sum_{g=0}^{G-1} H(g)\log_2(H(g)) \tag{3.26}$$

(3.21) ve (3.26) arasındaki eşitliklerle ifade edilen H(g), histogram değerinin toplam piksel sayısına oranı ile elde edilen gri değer olasılığıdır (Bevk ve Kononenko, 2002; Hsieh ve ark., 2017).

Lokal Özellikler: Histogram tabanlı özellikler genel olarak uzamsal bilgi üzerine yoğunlaşırken, GDEM tabanlı özellikler frekans tabanlı bilginin değerlendirilmesinde kullanılır. GDEM tabanlı özellikler, İkincil Derece İstatistikler veya Lokal Özellikler olarak da ifade edilmektedir (Bevk ve Kononenko, 2002; Hsieh ve ark., 2017). Bu özellikler, görüntü piksel değerlerini lokal istatistikler üzerinden değerlendirmek için kullanılır.

Bir *G* görüntüsü içerisinden elde edilecek eş-oluşum matrisleri *P=[p(i, j | d, Θ)]* olarak ifade edilsin. Bu noktada eş-oluşum matrisleri, *i.* piksel frekans özellikleri ile *j* komşu piksellerinin frekans özelliklerini, *d* uzaklığını ve *Θ* yönünü referans alarak değerlendirmek için kullanılır.

Tez çalışmasında *d=1* seçilerek ayrıntılı bir analiz gerçekleştirilmiştir. *Θ* açısı ise literatürde önerildiği üzere tek açılı (0°) ve dört açılı (0°,45°,90°,135°) olarak iki farklı durum için analiz edilmiştir (Zhou ve ark., 2013; Hsieh ve ark., 2017). Lokal özellikler, (3.27) - (3.40) eşitlikleri kullanılarak elde edilmiştir (Hsieh ve ark., 2017).

$$Otokorelasyon = \sum_i \sum_j \frac{(p_x - \mu_x)(p_y - \mu_y)}{\sigma_x \sigma_y} \tag{3.27}$$

$$Kontrast = \sum_n n^2 \left\{ \sum_i \sum_j p(i,j) \right\}, |i - j| = n \tag{3.28}$$

$$Korelasyon = \frac{\sum_i \sum_j (i - \mu_x)(j - \mu_y) p(i,j)}{\sigma_x \sigma_y} \tag{3.29}$$

$$Küme\ Prominansı = \sum_i \sum_j (i + j - \mu_x - \mu_y)^4 p(i,j) \tag{3.30}$$

$$Küme\ Tonu = \sum_i \sum_j (i + j - \mu_x - \mu_y)^3 p(i,j) \tag{3.31}$$

$$Benzeşmezlik = \sum_i \sum_j p(i,j)|i - j| \tag{3.32}$$

$$Enerji = \sum_i \sum_j p(i,j)^2 \tag{3.33}$$

$$Kazanç = -\sum_i \sum_j p(i,j) \log_2(p(i,j)) \tag{3.34}$$

$$Homojenlik = -\sum_i \sum_j \frac{1}{1+i-j} p(i,j) \tag{3.35}$$

$$Varyans\ Farkı = \sum_i i^2 p_{x-y}(i) \tag{3.36}$$

$$Kazanç\ Farkı = -\sum_i p_{x+y}(i) \log_2(p_{x+y}(i)) \tag{3.37}$$

$$Korelasyon\ Bilgisi\ Ölçütü = \frac{Küme\ Prominansı + \sum_i \sum_j p(i,j) \log_2(p_x(i) p_y(j))}{\max\{Kazanç(p_x), Kazanç(p_y)\}} \tag{3.38}$$

$$Normalize\ Bilgi\ Farkı = \sum_i \sum_j \frac{1}{1+|i-j|} p(i,j) \tag{3.39}$$

$$Ters\ Fark\ Momenti = \sum_i \sum_j \frac{1}{1+(i-j)^2} p(i,j) \tag{3.40}$$

(3.26) - (3.40) eşitliklerindeki μ_x ve μ_y değerleri ile σ_x ve σ_y değerleri, eş-oluşum matrislerine ($p(i, j \mid d, \Theta)$) dair marjinal dağılımların ortalama ve standart sapma çıkışlarını temsil etmektedir.

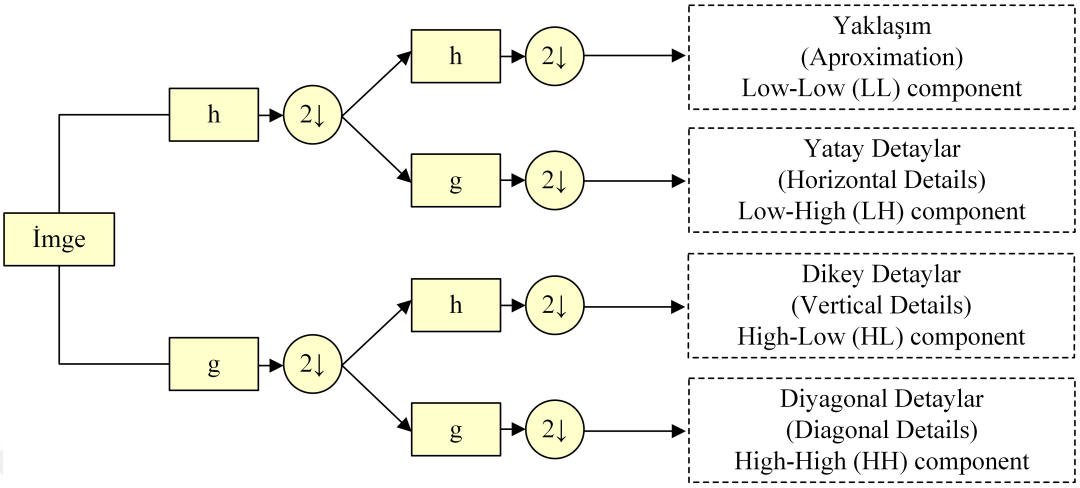
Ortalama ve standart sapma hesaplamaları sırasıyla (3.41) ve (3.42) eşitliklerinde görüldüğü gibidir.

$$\mu_x = \sum_i i \sum_j p(i,j)\ ,\ \mu_y = \sum_j j \sum_i p(i,j) \tag{3.41}$$

$$\sigma_x^2 = \sum_i (i - u_x)^2 \sum_j p(i,j)\ ,\ \sigma_y^2 = \sum_j (j - u_y)^2 \sum_i p(i,j) \tag{3.42}$$

İki Boyutlu Ayrık Dalgacık Dönüşümü: İki boyutlu ADD, yüksek geçiren filtre (g) ve alçak geçiren filtre (h) yardımıyla 2B bir imgeyi, frekans alt bantlarına ayrıştırmayı

sağlayan bir filtre bankasıdır (Eltoukhy ve ark., 2012). ADD yaklaşımı ile alt frekans bantlarının elde edilmesi Şekil 3.4' de görülmektedir.



Şekil 3.4. 2B imgenin birinci seviye çözünürlük üzerinden alt frekans bantlarına ayrıştırılması

Şekil 3.4 kapsamında yaklaşım, yatay detay, dikey detay ve diyagonal detaylar sırasıyla en düşük frekanslara, dikey yüksek frekanslara (yatay kenarlara), yatay yüksek frekanslara (dikey kenarlara) ve her iki yöndeki yüksek frekanslara (diyagonal) karşılık gelmektedir. Ayrıştırma işlemi sürekli olarak yaklaşım alt bandı üzerinden gerçekleştirilmektedir (Singh ve ark., 1997; Eltoukhy ve ark., 2012).

En basit formunda dalgacık denklemi, eşitlik (3.43)' te görüldüğü gibidir. (3.43) eşitliği içerisinde Ψ dalgacığı, a ölçek parametresini ve b ise kaydırma değerini simgelemektedir. Farklı dalgacık tipleri a ve b parametrelerine dair farklı seçeneklerle elde edilmektedir.

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi \left[\frac{t-b}{a} \right] \tag{3.43}$$

3.6.2. Sınıflandırmada kullanılan optimizasyon algoritmaları

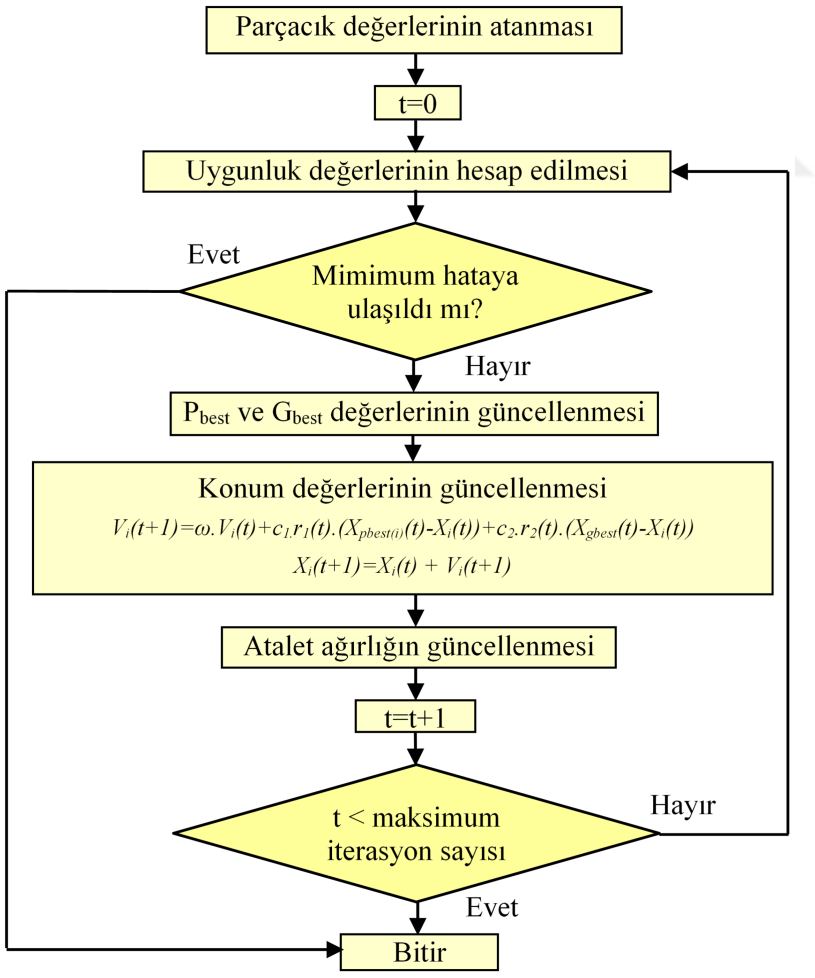
Çalışmada 3 farklı optimizasyon tekniği kullanılarak, Yapay Sinir Ağları (YSA)' nın ağırlık ve bias vektörleri güncellenmiştir. Bu teknikler; Parçacık Sürü Optimizasyonu (PSO), Yapay Arı Kolonisi Algoritması (YAKA) ve Kâşif Parçacık Sürü Optimizasyonu (PSO)' dur.

3.6.2.1. Parçacık sürü optimizasyonu

Parçacık Sürü Optimizasyonu (PSO) tekniği, Eberhart ve Kennedy (1995) tarafından geliştirilen sezgisel bir optimizasyon algoritmasıdır. PSO tekniği, kuş sürülerinin yiyecek bulma davranışlarından esinlenerek geliştirilmiştir. Her bir kuş, farklı bir çözümü ifade etmekte, bu çözümler ise özellik uzayındaki bir parçacık olarak atfedilmektedir. PSO algoritması, optimizasyon problemini çözmek için parçacıkların global ve bireysel performanslarını inceleyerek karar verir. Her bir parçacığın konum değeri, (3.44) ve (3.45) eşitliklerine göre güncellenir (Eberhart ve Kennedy, 1995). PSO tekniğinin akış diyagramı Şekil 3.5' de görüldüğü gibidir (Koyuncu ve Ceylan, 2015).

$$V_i(t+1) = \omega V_i(t) + c_1 r_1 \left(X_{pbest(i)}(t) - X_i(t) \right) + c_2 r_2 \left(X_{gbest}(t) - X_i(t) \right) \quad (3.44)$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (3.45)$$



Şekil 3.5. PSO tekniği akış diyagramı

Eşitlik (3.44) içerisindeki atalet ağırlığı (ω) ve hızlandırma katsayıları (c_1 & c_2) kullanıcı tarafından ayarlanan parametrelerdir. Atalet ağırlığı sürate ait adım büyüklüğü olup, hızlandırma katsayıları ise parçacıkları bireysel ve global olarak en iyi konum değerlerine yönlendiren sabitlerdir. (3.44) ve (3.45) eşitlikleri içerisinde; r_1 ve r_2 katsayıları [0,1] aralığında üretilen rasgele değişkenler, $V_i(t)$ önceki sürat değeri, $X_i(t)$ önceki konum değeri, $X_{pbest(i)}(t)$ *i.* parçacığa ait bireysel en iyi konum değeri, $X_{gbest}(t)$ bütün sürüye dair en iyi (global) konum değeri, $V_i(t+1)$ yeni sürat değeri ve $X_i(t+1)$ yeni konum değeri olarak ifade edilir (Ceylan ve Koyuncu, 2017).

3.6.2.2. Yapay arı kolonisi algoritması

Yapay Arı Kolonisi Algoritması (YAKA), Karaboga (2005) tarafından geliştirilen stokastik bir optimizasyon algoritmasıdır. YAKA algoritması, bal arılarının yiyecek bulma davranışlarından esinlenerek oluşturulmuştur. Metot içerisinde işçi, gözcü ve kâşif olmak üzere 3 farklı arı tipi üzerinden işlem yapılmaktadır. Bu arılar, yiyecek kaynağı tespit etme ve yiyeceği kovana taşımakla sorumludur. En uygun yiyecek kaynağı, sistemin ulaşması gereken optimum seçeneği ifade eder. YAKA tekniği, (3.46) - (3.49) eşitliklerini işleterek optimizasyon problemlerini çözmektedir (Karaboga ve Akay, 2009; Koyuncu ve Ceylan, 2015).

$$x_m = l_i + rand\,(0,1) * (u_i - l_i) \tag{3.46}$$

$$v_{mi} = x_{mi} + \phi_{mi}(x_{mi} - x_{ki}) \tag{3.47}$$

$$fit_m\,(x_m) = \begin{cases} 1/(1+f_m(x_m)), f_m(x_m) \geq 0 \\ 1+\left|f_m(x_m)\right|, x < 0 \end{cases} \tag{3.48}$$

$$P_m = \frac{fit_m\,(x_m)}{\sum_{m=1}^{SN} fit_m\,(x_m)} \tag{3.49}$$

YAKA algoritması temel olarak 4 faz üzerinden işlem yapmaktadır. Bunlar; başlangıç fazı, işçi arı fazı, gözcü arı fazı ve kâşif arı fazı şeklindedir.

Başlangıç fazı içerisinde (3.46) eşitliği kullanılarak, x_{mi} yiyecek kaynaklarının üretilmesi işlemi gerçekleştirilir. u_i ve l_i parçacık değerlerine dair üst ve alt limitleri, *rand(0,1)* ise [0,1] aralığında üretilen rasgele değişkeni temsil eder (Karaboga ve Akay, 2009).

İşçi arı fazında (3.47) ve (3.48) eşitlikleri ile yeni yiyecek kaynakları (v_{mi}) ve kaynaklara dair uygunluk değerleri ($\hat{fit}_m(x_m)$) elde edilir. (3.47) eşitliği içindeki ϕ, [-1,1] aralığında üretilen rasgele bir sabiti, i ise [1,vektör boyutu] aralığında seçilen bir indeksi temsil eder. Yeni yiyecek kaynakları (v_{mi}), m. yiyecek kaynağı ile rasgele seçilen k. yiyecek kaynağı arasındaki (x_{mi}-x_{ki}) fark referans alınarak üretilir. Burada k indeksi ile m indeksi aynı seçilemez ve her iki indeks [1, popülasyon sayısı] aralığında tanımlanır. (3.48) eşitliği içindeki $f_m(x_m)$, uygunluk değerinin bulunmasında kullanılan hata oranıdır (Karaboga ve Akay, 2009).

Gözcü arı fazında (3.49) eşitliği kullanılarak, parçacıklara ait karlılık değerleri hesap edilir. Karlılık değerlerinin, [0,1] aralığında rasgele üretilen bir sayı ile karşılaştırılması sağlanarak, rasgele bir seçim prosedürü takip edilir. Bu sayede belirli parçacıklar üzerine farklılaştırma işlemi sağlanır. Burada popülasyon sayısına eşit sayıda parçacık üzerine işlem yapılır. Diğer adımlarda (3.47) ve (3.48) eşitlikleri ile farklılaştırılan parçacıklar ve bu parçacıklara dair uygunluk değerlerinin eldesi sağlanır. Söz konusu iki işlem, işçi arı fazı kapsamında gerçeklenen işlemler ile aynıdır (Karaboga ve Akay, 2009).

Kendi konumunu, *limit* parametresine eşit iterasyon boyunca iyileştiremeyen parçacıklar, kâşif arı fazında yeniden üretilir. Bu noktada (3.46) eşitliği parçacığın (x_m) yeniden üretilmesini sağlar (Karaboga ve Akay, 2009).

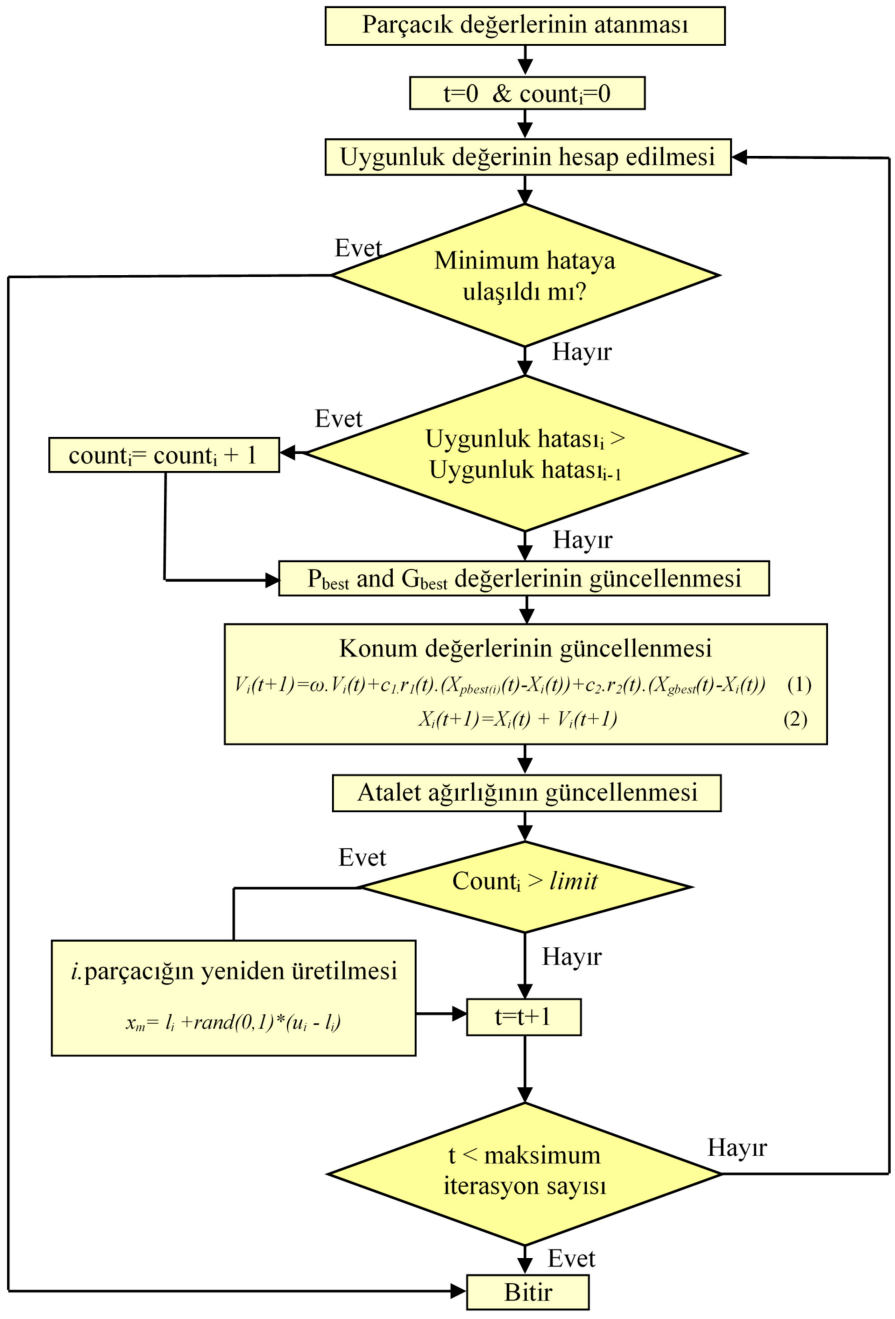
3.6.2.3. Kâşif parçacık sürü optimizasyonu

PSO metodunda parçacıklar sürekli olarak güncellenir. Ancak PSO içinde, parçacık konumlarında iyileştirmeyi sağlayan herhangi bir parametre ya da aşama yoktur. Bu durum, PSO algoritması açısından karşılaşılan en önemli dezavantajdır.

Kâşif Parçacık Sürü Optimizasyonu (KPSO), Koyuncu ve Ceylan (2015) tarafından önerilen hibrit bir optimizasyon algoritmasıdır. KPSO algoritmasının akış diyagramı Şekil 3.6' da görüldüğü gibidir (Koyuncu ve Ceylan, 2015).

KPSO algoritması PSO temelli bir teknik olup, YAKA içindeki kâşif arı fazının PSO yöntemine eklenmesi ile oluşturulmuştur. KPSO algoritmasında (3.44) ve (3.45) eşitlikleri kullanılarak parçacık değerlerinin üretilmesi ve güncellenmesi sağlanır. Son aşamada ise (3.46) eşitliği kullanılarak, kendi konumunu iyileştiremeyen parçacıkların yeniden üretilmesi sağlanır. Bu noktada kullanıcı tarafından belirlenen *limit* parametresi değerince iterasyon sayısı kontrol edilir. Bu iterasyon sayısı boyunca konumunda

iyileşme olmayan parçacıklar yeniden üretilir. Böylece PSO tekniğinde karşılaşılan en önemli dezavantaj elimine edilmiş olur.



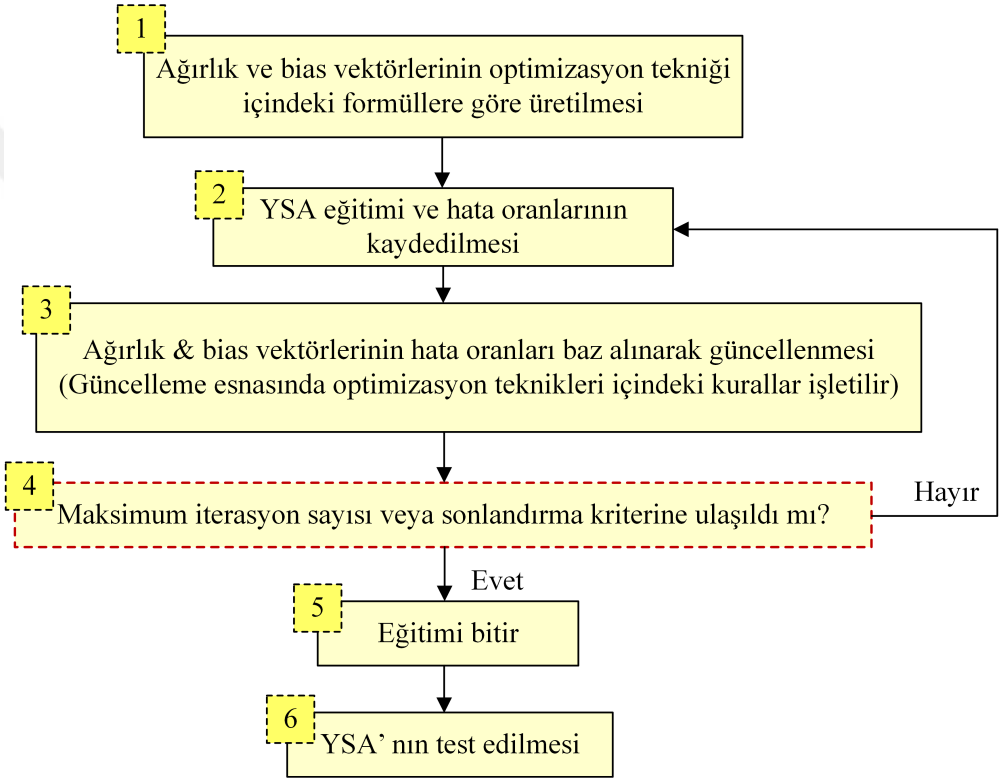
Şekil 3.6. KPSO tekniği akış diyagramı

3.6.3. Optimize YSA metotları ve Sınırlı PSO-YSA tekniği

Geleneksel YSA teknikleri genel olarak geriye-yayılım (back-propagation) temelli algoritmalar içermektedir. Bu tekniklerde hata oranı dalgalanabilmekte, bu

dezavantaj optimizasyon teknikleri kullanılarak giderilmektedir (Ceylan ve Koyuncu, 2016).

Optimizasyon temelli YSA metotlarında, geriye-yayılım (back-propagation) temelli algoritmaların yerini optimizasyon algoritmaları almaktadır (Yu ve ark., 2008; Pedersen ve Chipperfield, 2010; Koyuncu ve Ceylan, 2015; Ceylan ve Koyuncu, 2016; 2017). Optimize YSA metotlarında hata oranı dikey yönlü bir iniş hareketine sahiptir veya sabit olarak kalır. Optimize YSA algoritmalarının genel şeması Şekil 3.7' de görüldüğü gibidir.



Şekil 3.7. Optimize YSA tekniklerinin genel şeması

Şekil 3.7' de görüldüğü üzere;

1. YSA yapısına sunulacak olan ağırlık & bias vektörlerinin üretilmesi sağlanır. Bu aşamada optimizasyon tekniğindeki başlangıç veya temel güncelleme denklemleri işletilir.
2. Eğitim işlemi gerçekleştirilerek hata oranları elde edilir. Hata hesabında Karesel Ortalama Hata fonksiyonu kullanılır (Ceylan ve Koyuncu, 2016). Eğitim işlemi, optimizasyon tekniği tarafından üretilen her bir ağırlık & bias vektörünün YSA yapısına sunulması ile başlar. Bu noktada kullanılan

ağırlık & bias vektör sayısı, optimizasyon tekniği içindeki popülasyon sayısına eşittir. Elde edilen YSA sonuçlarına göre hata hesabı yapılır.

3. Optimizasyon algoritması kullanılarak, hata değerlerine göre ağırlık & bias vektörleri güncellenir. Bu amaçla PSO-YSA tekniği (3.44) ve (3.45) eşitliklerini, YAKA-YSA algoritması (3.46) - (3.49) arası eşitlikleri, KPSO-YSA tekniği ise (3.44), (3.45) ve (3.46) eşitliklerini kullanarak güncelleme işlemini gerçekleştirir.
4. Maksimum iterasyon sayısı veya sonlandırma kriteri (minimum hata değeri) kontrol edilir.
5. Dördüncü aşamadaki koşulların gerçekleşmesi durumunda eğitim sonlandırılır.
6. En düşük hata değerini sağlayan ağırlık & bias vektörü test işlemi için kullanılır.

Sınırlı PSO-YSA metodu, geleneksel PSO-YSA tekniğinin modifiye bir versiyonu olup, tekniğe dair önemli bir handikabın eliminasyonunu sağlamaktadır. Geleneksel PSO-YSA yapısı içinde popülasyon sayısı, atalet ağırlığı, hızlandırma katsayıları ve gizli düğüm sayısı ayarlanmaktadır. Ancak, teknik içerisinde ağırlık & bias vektörlerinin değerlerini sınırlayacak herhangi bir parametre bulunmamaktadır.

Ceylan ve Koyuncu (2016), ağırlık & bias vektörlerinin sürat ve konum değerlerinde *bireysel sınır ayarlamalarını* incelemişlerdir. Çalışma neticesinde ağırlık & bias vektörlerinde, sürat ve konum sınırlamalarının uygulamaya uygun olarak gerçekleştirilmesi gerekliliği ortaya çıkmıştır. Bu sınır ayarlamaları; ağırlık pozisyon aralığı (apa), ağırlık sürat aralığı (asa), bias pozisyon aralığı (bpa) ve bias sürat aralığı (bsa) şeklindedir. Sınırlı PSO-YSA algoritması, Şekil 3.7 içerisinde aşağıdaki değişikliklerin yapılması ile elde edilir (Ceylan ve Koyuncu, 2016):

1. Adım 1 için ağırlık & bias vektörlerinin kullanıcı tarafından belirlenen apa, asa, bpa ve bsa aralıkları içinde üretilmesi sağlanır.
2. Adım 3 kapsamında güncelleme gerçekleştirilirken, sınır değerleri aşan ağırlık & bias değerleri en yakın sınıra çekilir.
3. PSO-YSA tekniği içerisindeki diğer adımlar, Sınırlı PSO-YSA algoritması için de aynıdır.

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Sunulan tez çalışmasında, sürrenal lezyonların BT görüntülerinden belirlenmesi ve sınıflandırılması amacıyla gerçekleştirilen çalışmalar 5 aşamadan oluşmaktadır. Bu aşamalar aşağıda sıralanmıştır:

- Abdomen segmentasyonu
- Gaussian gürültüsünün eliminasyonu
- Görüntü iyileştirme (gürültü giderme ve yağ dokusu eliminasyonu)
- Sürrenal lezyon segmentasyonu
- Sürrenal lezyonlar üzerine özellik çıkarma - ikili sınıflandırma

4.1. Çalışmada Kullanılan İstatistiksel Metrikler

Çalışma kapsamında, literatürde görüntü işleme ve sınıflandırmada sıklıkla tercih edilen ve önerilen istatistiksel metrikler kullanılmıştır. Bu metrikler şu şekilde sıralanabilir (Labatut ve Cherifi, 2012; Franklin ve Rajan, 2014; Alivar ve ark., 2016; Ceylan ve Koyuncu, 2016; Koyuncu ve Ceylan, 2016; Sethi ve Saini, 2016; Koyuncu ve Ceylan, 2017b; 2017c; Lee ve ark., 2017):

- Duyarlılık (Sensitivity)
- Özgüllük (Specificity)
- Kesinlik (Precision)
- Doğruluk (Accuracy)
- Karesel Ortalama Hata (KOH / Mean Squared Error → MSE)
- İşlem Karakteristik Eğrisi Altında Kalan Alan (AUC / Area under ROC Curve)
- Jaccard
- Dice
- Doruk Sinyal Gürültü Oranı (DSGO / Peak Signal-to-Noise Ratio →PSNR)
- Yapısal Benzerlik İndeksi (YBİ / Structural Similarity Index→SSIM)

Kullanılan metriklerin birçoğu, Çizelge 4.1' de ifade edilen Hata Matrisi (Confusion Matrix) tabanlıdır (Sharma ve ark., 2009). Bu matris, daha çok sınıflandırma temelli çalışmalarda kullanılmaktadır. Matrisin segmentasyon analizlerinde içerdiği mantık, örüntü yerine piksellerin durumu üzerinden işlem yapılmasına dayanır.

Çizelge 4.1. Hata matrisi

		Asıl Sınıf	
		Pozitif	Negatif
Tahmin Edilen Sınıf	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

- Doğru Pozitif (DP), pozitif işaretli verinin pozitif olarak sınıflandırıldığı örüntü sayısıdır. Segmentasyonda bu değer, çıkış ve ROI' nin çakıştırıldığı durum için pozitif kesişim kümesindeki piksel sayısıdır (Fawcett, 2006).
- Yanlış Pozitif (YP), negatif işaretli verinin pozitif olarak sınıflandırıldığı örüntü sayısıdır. Segmentasyonda bu değer, ROI olarak elde edilen, ancak ROI' de yer almayan piksel sayısıdır (Fawcett, 2006).
- Yanlış Negatif (YN), pozitif işaretli verinin negatif olarak sınıflandırıldığı örüntü sayısıdır. Segmentasyonda bu değer, ROI olarak elde edilmeyen, ancak ROI' de yer alan piksel sayısıdır (Fawcett, 2006).
- Doğru Negatif (YN), negatif işaretli verinin negatif olarak sınıflandırıldığı örüntü sayısıdır. Segmentasyonda bu değer, çıkış ve ROI alanlarının bileşimi dışında kalan alan (arka plan) için piksel sayısını ifade eder (Fawcett, 2006).

Kullanılan metriklerin matematiksel ifadeleri, aşağıda belirtilen eşitlikler vasıtasıyla elde edilir.

$$Duyarlılık = \frac{DP}{DP + YN} \tag{4.1}$$

$$Özgüllük = \frac{DN}{DN + YP} \tag{4.2}$$

$$Kesinlik = \frac{DP}{DP + YP} \tag{4.3}$$

$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \tag{4.4}$$

$$KOH_{sınıflama} = \frac{1}{n}\sum_{i=1}^{n}(t_i - o_i)^2 \tag{4.5}$$

$$AUC = \frac{1}{mn}\sum_{i=1}^{m}\sum_{j=1}^{n}1_{p_i > p_j} \tag{4.6}$$

$$Jaccard = \frac{DP}{DP + YP + YN} \tag{4.7}$$

$$Dice = \frac{2DP}{2DP + YP + YN} \tag{4.8}$$

$$KOH_{görüntü} = \frac{\sum_{i=1}^{M}\sum_{j=1}^{N}\left(I(i,j) - \hat{I}(i,j)\right)^2}{MN} \tag{4.9}$$

$$DSGO(x,y) = 10\log_{10}\left(\frac{MAX_I^2}{KOH_{görüntü}}\right) \tag{4.10}$$

$$YBİ(x,y) = \frac{\left(2\mu_x\mu_y + c_1\right)\left(2\sigma_{xy} + c_2\right)}{\left(\mu_x^2 + \mu_y^2 + c_1\right)\left(\sigma_x^2 + \sigma_y^2 + c_2\right)},\ c_1 = \left(k_1 L\right)^2,\ c_2 = \left(k_2 L\right)^2 \tag{4.11}$$

$$v' = \frac{v - \min_A}{\max_A - \min_A}(new_max_A - new_min_A) + new_min_A \tag{4.12}$$

Eşitlik (4.1), (4.2), (4.3) ve (4.4)' e göre; duyarlılık (sensitivity) ölçütü, pozitif örneklerde (*DP*+*YN*) pozitif değerlerin elde edilme başarısını, özgüllük (specificity) metriği ise negatif örneklerde (*DN*+*YP*) negatif değerlerin elde edilme başarısını ölçmek için kullanılır (Kanchanaraksa, 2008). Kesinlik (precision) ölçütü, test edilen sistemin pozitif olarak tanımladığı kümede (*DP*+*YP*), pozitifliğin hangi ölçüde doğru olduğunu ifade eden metriktir. Doğruluk (accuracy) ise elde edilen pozitif ve negatif sonuçların (*DP*+*DN*), bütün bir sonuç kümesi üzerine başarısını temsil etmektedir (Popovic ve ark., 2007).

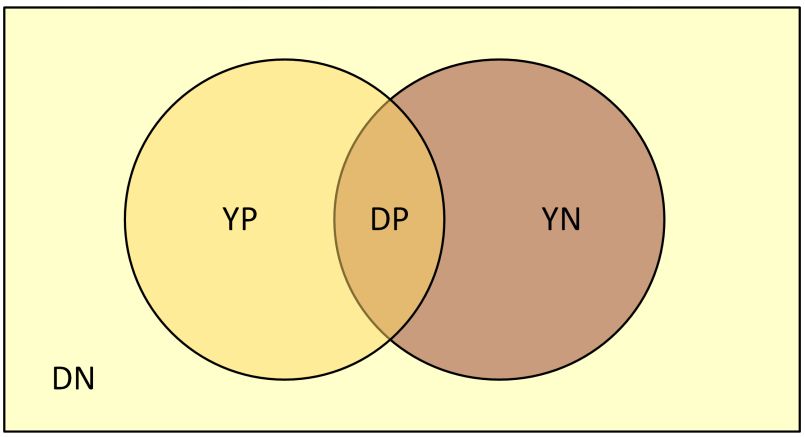
(4.5) eşitliği içerisinde KOH değeri, t_i ve o_i değerleri kullanılarak hesap edilmekte, bu değerler sırasıyla elde edilmesi gereken çıkışı ve üretilen çıkışı

simgelemektedir. *n* değişkeni ise örüntü sayısını temsil etmektedir (Ceylan ve Koyuncu, 2016).

(4.6) eşitliği içinde; *i* değişkeni "1" etiketli *m* data noktasını, *j* değişkeni ise "0" etiketli *n* data noktasını taramakta, p_i ve p_j sırasıyla *i* ve *j* noktalarına sınıflayıcı tarafından verilen çıkış (olasılık) olmaktadır. AUC metriği, sistemin pozitif işaretli verilere verdiği cevapların negatif işaretli verilere verdiği cevaplardan hangi derecede farklı olduğunu niteler. Diğer bir deyişle AUC metriği, sistemin pozitif-negatif arası eğilimini belirlemek için kullanılır (Fawcett, 2006).

(4.7) ve (4.8) içerisinde sırasıyla Jaccard ve Dice benzerlik ölçütleri tanımlanmaktadır. Jaccard indeksi, hedef görüntü ile çıkış arasındaki kesişim alanının (DP), elde edilen ve edilmesi gereken pozitif sonuçlar (*DP*+*YP*+*YN*) üzerinde hangi derecede etkin olduğunu nitelemektedir. Dice indeksi ise, etkin kesişim (*2DP*) alanının bütün bir birleşimde (*YP*+*DP*+*YN*+*DP*) ne kadar etkin olduğunu simgeler. Her ikisi de hedef ile çıkış arasındaki kesişim (overlap) tabanlı metriklerdir (Taha ve Hanbury, 2015).

Pozitif ve negatif alanlar, segmentasyon çalışmalarında Şekil 4.1' de ifade edildiği gibidir (Zou ve ark., 2004).



Şekil 4.1. Segmentasyon üzerine istatistiksel alanların tanımı

Segmentasyon çalışmalarında daha çok pozitif tabanlı metriklerin kullanıldığı görülmektedir. Çünkü DN alanı, obje dışı arka planı ifade etmektedir. Bu sebepten segmentasyonda sıklıkla kesişim (overlap) alanlarının (DP, YN, YP) nitelendiği metrikler önem arz eder.

(4.9) eşitliği içerisinde *I* ve $\hat{I}$ sırasıyla orijinal ve yeniden yapılandırılan görüntüyü temsil eder. *M* ve *N* ise görüntünün yatay ve düşey boyutunu

simgelemektedir. $KOH_{görüntü}$, orijinal ve yeniden yapılandırılan görüntülerin piksel değerleri arasındaki KOH oranıdır (Koyuncu ve Ceylan, 2017c).

(4.10) eşitliğindeki DSGO, yeniden yapılandırılan görüntüde kalite tespiti için $KOH_{görüntü}$ oranını kullanır. MAX_I değeri, orijinal görüntü içindeki maksimum gri seviye değerini simgeler ve tanımlanan veri tipi (ikili veya gri seviye) doğrultusunda değişim göstermektedir (Koyuncu ve Ceylan, 2017c).

YBİ metriği, orijinal ve yeniden yapılandırılan görüntüleri parlaklık, kontrast ve yapı bakımından inceler. Bu amaçla (4.11)' de; simetri, sınırlılık ve tekil maksimum özelliklerinin bulunduğu ifadeler kullanılır. (4.11) eşitliği içinde x ve y sırasıyla orijinal ve yeniden yapılandırılan görüntüyü, μ_x ve μ_y ortalama değerleri, σ_x^2 ve σ_y^2 varyans değerlerini temsil eder. σ_{xy} değeri x ile y arasındaki kovaryansı ifade ederken, k_1 ve k_2 sırasıyla 0.01 ve 0.03 olarak seçilen sabit katsayılardır. L katsayısı gri seviye aralığını ifade ederken, c_1 ve c_2 değişkenleri eşitlik tabanında kalacak olan zayıf değerleri dengelemede kullanılır (Akay, 2013).

(4.12) eşitliği min-max normalizasyon yöntemini ifade eder. v' yeni elde edilecek değeri, v ise min-max normalizasyonuna göre elde edilecek olan ve A özelliği içinde yer alan değeri ifade eder. max_A ve min_A değerleri sırasıyla A özelliği içindeki değerlerden maksimum ve minimum olanını, new_max_A ve new_min_A değerleri ise sırasıyla yeni maksimum ve yeni minimum değerleri simgeler (Modugno ve ark., 2010).

4.2. Abdomen Segmentasyon Çalışması

Çalışmada kullanılan görüntülerde abdomen oranlarının ölçeksiz olduğu, bu durumun, segmentasyon ve sınıflama sonuçlarını negatif yönde etkilediği görülmüştür. Bu nedenle abdomenin mutlaka segmente edilmesi gereklidir. Ancak kullanılan görüntüler, *abdomen segmentasyonunu* zorlaştıran önemli dezavantajlar içermektedir. Bu dezavantajlar, basit segmentasyon algoritmalarının kullanımı ile abdomen eldesini engellediğinden, ayrıntılı bir sistem tasarlanması gerekmiştir.

Abdomen segmentasyonunu zorlaştıran 6 dezavantaj mevcuttur:

- Süreksiz abdomen kenarları
- BT yatağı görüntüsü
- Hasta bilgileri

- Görüntü kenarlarına yakın abdomen
- Düşük kontrast
- Dar histogram

Düşük kontrast ve *dar histogram*, logaritmik lineer olmayan germe ve histogram eşitleme gibi yaklaşımlar ile elimine edilebilir. Ancak *hasta bilgileri*, farklı gri seviyelerde bulunabildiğinden, görüntü kenar bölümlerinde yer alsa dahi düşey ve yatay perspektiflerden bakıldığı durumda sürekli bir değer değişimine sebep olur. Bu nedenle hasta bilgileri, abdomen segmentasyonu için birincil derece dezavantaj oluşturmaktadır.

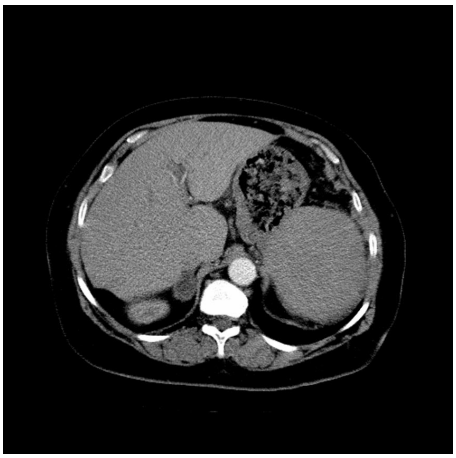
Abdomeni çevreleyen *BT yatağı görüntüsü*, abdomene yakın olması durumunda segmentasyon açısından önemli bir dezavantajdır. Çünkü basit morfolojik işlemler, abdomen-BT yatağı arası değişken değerler (bozucu etki) olması durumunda, BT yatak görüntüsünün, ROI (abdomen bölgesi) içine dâhil olmasına sebep olur. Ayrıca BT yatağı, abdomene çok yakın olduğu durumda, hem yatay hem de dikey perspektiflerden sürekli değer değişimleri söz konusu olacağından, basit segmentasyon yaklaşımları veya basit mantıksal operatörler ile abdomenin elde edilemeyeceği görülmüştür.

Önemli dezavantajlardan bir diğeri de *görüntü kenarlarına yakın abdomendir*. Görüntü kenarları ve abdomen arası bölüm, BT çekiminden kaynaklı gri seviye değişimleri içerebilmektedir. Bu nedenle uygulanacak bir *Morfolojik Kapama* işlemi sonrası, abdomen bölümü ile görüntü kenarları birbirine kenetlenmekte, abdomen-görüntü kenarları arası bölüm de ROI içine dâhil olmaktadır.

Dinamik BT çekimlerinin düşük voltaj ile gerçekleştirildiği durumda, kenarları süreksiz abdomen görüntüleri elde edilebilmektedir. Bu durum, abdomen segmentasyonuna engel teşkil eden en önemli dezavantajdır. Süreksiz abdomen kenarları iyileştirilmediği durumda elde edilecek olan ROI, kaburga kemiklerini dışarıdan çevreleyen deri altı dokusu veya doku parçaları üzerinden elde edilecek alt alanlardır.

Birincil derece önem teşkil eden dezavantajlar için Şekil 4.2’ de birkaç örnek sunulmuştur.

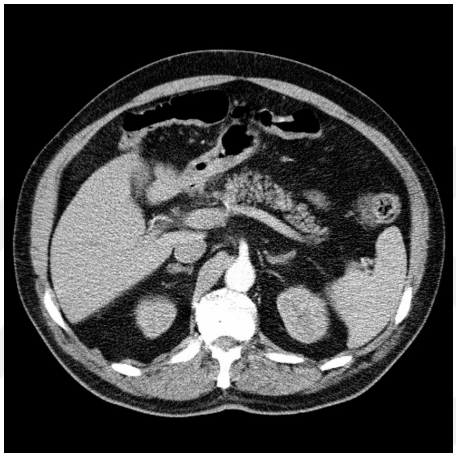
Gerçekleştirilen tez çalışmasında, bu dezavantajlardan etkilenmeyerek abdomen segmentasyonunu yüksek başarı ile sağlayan bir sistem sunulmuştur. Önerilen bu sisteminin adı *AbSeg*’ dir.



a-) Süreksiz kenarlı abdomen



b-) BT yatağı görüntüsü ve hasta bilgileri



c-) Görüntü kenarlarına yakın abdomen

Şekil 4.2. Abdomen segmentasyonu önünde engel teşkil eden birincil dezavantajlar

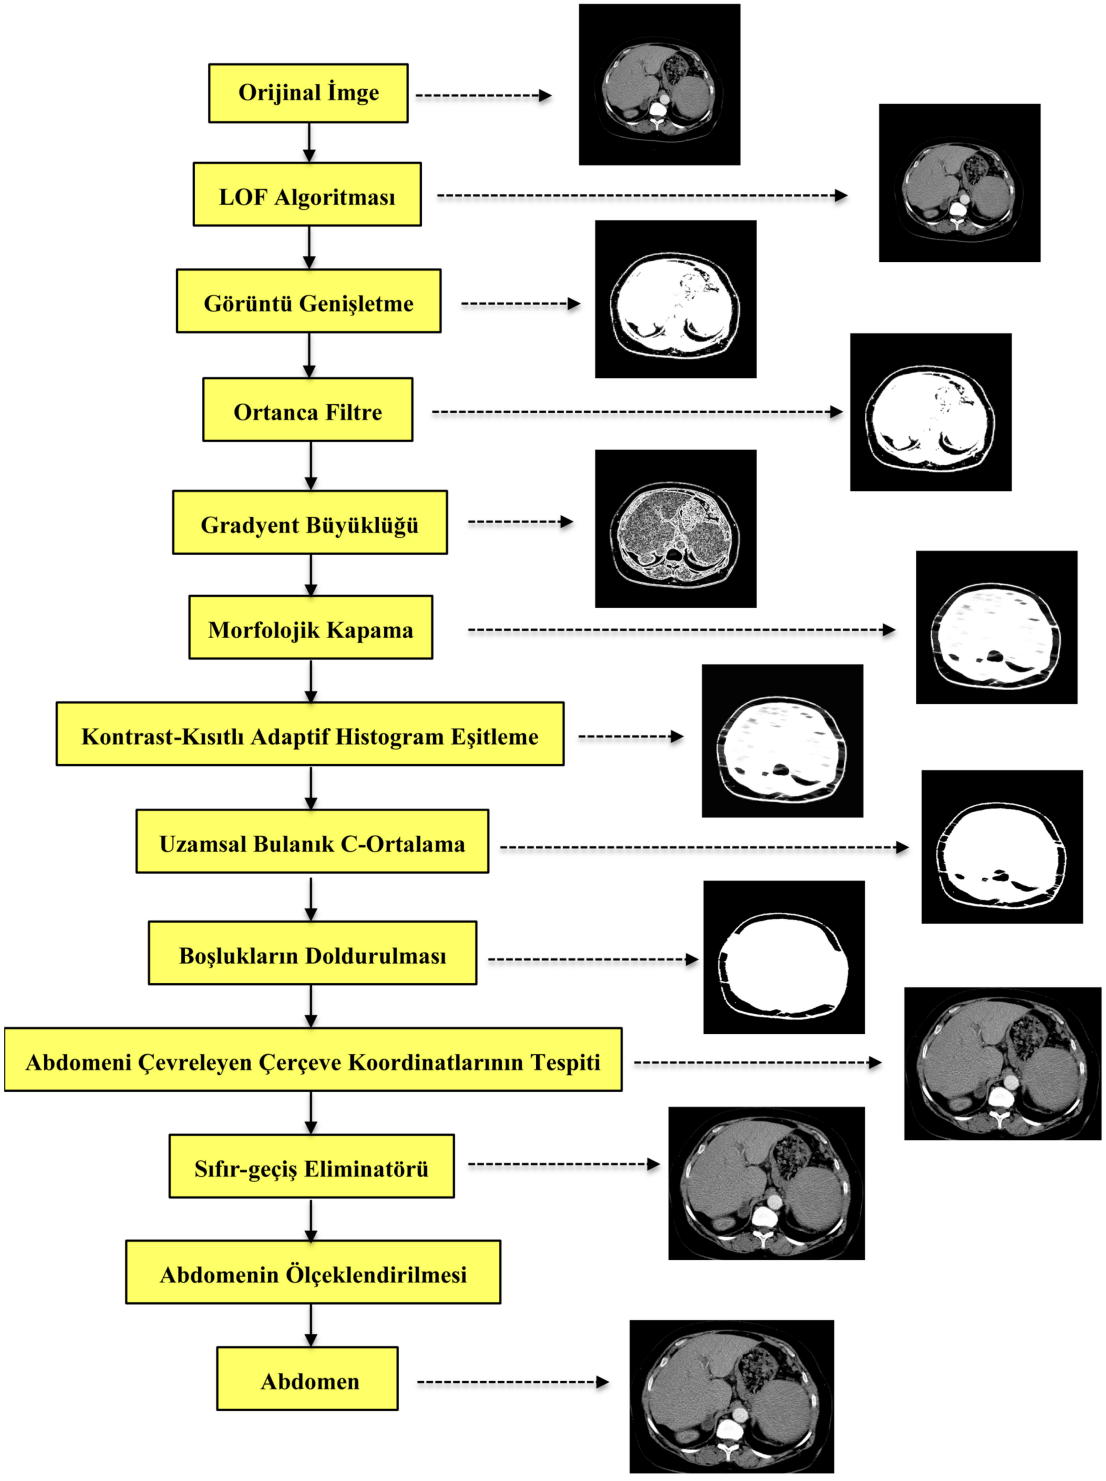
4.2.1. Abdomen segmentasyon sistemi

Abdomen segmentasyon sistemi (AbSeg), hem kaliteli hem de düşük kaliteli (süreksiz) kenarlara sahip olan abdomen görüntülerinde kullanılabilen, abdomenin alt bölümüne yakın olan BT yatağından ve hasta bilgilerinden etkilenmeyen, düşük kontrast ve dar histograma sahip olan görüntülerde de etkin olarak kullanılan bir segmentasyon yapısıdır. AbSeg sisteminin akış diyagramı Şekil 4.3' de görüldüğü gibidir.

Şekil 4.3' de görüldüğü üzere;

1. GOB yaklaşımı, görüntü içindeki gereksiz bölümlerin (BT yatağı ile abdomen üstü ve altında yer alan hasta bilgilerinin) eliminasyonunu sağlar. Bu noktada basit eşikleme algoritmaları kullanılarak, iki dezavantajın eliminasyonu

sağlanabilmektedir. Ancak bu durum, organ ve diğer dokular içinde yer alan yüksek yoğunluktaki piksel değerlerinde bozulmaya sebebiyet verir. Bu nedenle en büyük alan (abdomen), GOB yaklaşımı kullanılarak kayıpsız bir şekilde elde edilebilmektedir.



Şekil 4.3. AbSeg sistemi akış diyagramı

GOB algoritmasının iki temel dezavantajı bulunmaktadır. Bu dezavantajlardan birincisi abdomen bölümünü çevreleyen yatak görüntüsü, ikincisi ise görüntü kenarlarındaki gürültüdür. Bu nedenle, AbSeg sisteminin diğer bölümlerinde bu dezavantajların yanı sıra BT taramalarında etkin diğer dezavantajların eliminasyonu sağlanmaktadır. Ayrıca kullanılan operatörlerin her biri, dezavantajların biri veya birkaçı üzerine etkin olabilmektedir.

2. Görüntü Genişletme (Image Dilation) işlemi, abdomen kenarlarını belirginleştirmek için kullanılmaktadır. Bu aşamada, 36 adet farklı açılı (0°, 5°, …, 175°) çizgi (line) tipi yapı elemanı kullanılarak çıkışlar elde edilmekte, bu çıkışlar son durumda toplanarak abdomen kenar bölümleri pekiştirilmektedir. Böylelikle süreksiz kenarların birbiri ile teması sağlanmaktadır.
3. Ortanca filtre, Görüntü Genişletme neticesinde elde edilen kalınlaştırılmış görüntülerin, düşük oranda (kenar bilgisini bozmayacak şekilde) yumuşatılmasını sağlamaktadır. Ortanca filtre ile abdomen kenarlardaki blur görüntünün daha kararlı (düzgün) olması sağlanır.
4. Gradyent Büyüklüğü, abdomenin kenar kısımlarını ve abdomen içi objelerin kenarlarını daha belirgin hale getirmektedir.
5. Morfolojik Kapama, Gradyent Büyüklüğü çıkış imgesindeki farklı gri seviyelerin birbiri ile temasını sağlamaktadır.
6. KS-AHE metodu, düşük kontrast seviyeli görüntüler için kontrast iyileştirme işlemi gerçekleştirir. Ayrıca bu yaklaşım, Morfolojik Kapama ile elde edilen gri seviyeler arası bağlantıları ön plana çıkarmaktadır.
7. UBCO tekniği, abdomen bölümünü görüntü arka planından ayırmaktadır.
8. UBCO çıkışı, içerisinde boşluklar barındıran ikili (binary) bir görüntü üretir. Bu nedenle (sekizinci aşamada) boşlukların doldurulması işlemi gerçekleştirilerek, birbiri ile bağlantısı olan ve kapalı çevrelerde yer alan boş alanlar doldurulmaktadır.
9. Bu aşamada abdomeni çevreleyen çerçeve koordinatları tespit edilir.
10. SE yaklaşımı, görüntü içinde bütün değerleri sıfıra eşit olan dikey ve yatay vektörleri elimine etmektedir.
11. Son aşamada abdomen görüntüsü 550x700 boyutunda ölçeklendirilir. Bu oranın seçilmesinde, deneysel olarak gerçekleştirilen denemeler etkin

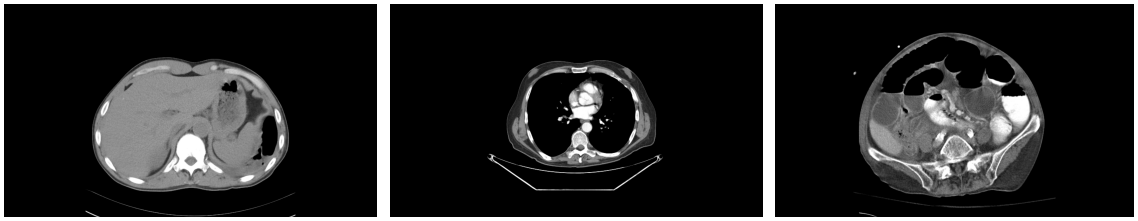
olmaktadır. Abdomenin yatay ve dikey boyutları, 550x700 oranının dışında (farklı oranların seçilmesi durumunda) görsel olarak uyumlu olmamaktadır.

Sonuç olarak, farklı kısıtlardan etkilenmeyerek, BT imgelerinde abdomen segmentasyonu sağlayan bir sistem geliştirilmiştir. AbSeg sistemi, literatürdeki ilk abdomen segmentasyon yapısıdır (Koyuncu ve ark., 2017).

4.2.2. AbSeg sistemine dair parametre ayarlamaları

AbSeg sisteminin performans analizinde Selçuk Üniversitesi Tıp Fakültesi Radyoloji ABD' dan elde edilen 32 adet abdominal BT görüntüsü ile TCIA kütüphanesinden elde edilen 12 abdominal BT, 11 toraks BT ve 3 adet pelvis BT görüntüsü kullanılmıştır (Clark ve ark., 2013). Selçuk Üniversitesi Tıp Fakültesi Radyoloji ABD' dan elde edilen görüntüler 852x852 boyutunda olup, 16 adet görüntü eğitimde ve 16 adet görüntü de test işleminde kullanılmıştır. TCIA kütüphanesinden elde edilen görüntüler ise validasyon seti olarak kullanılmıştır. Bu veri seti, 1920x1080 boyutunda 26 adet BT görüntüsünden oluşmaktadır.

Kullanılan farklı tipteki BT görüntülerinin her biri için Şekil 4.4' de birer örnek sunulmuştur.

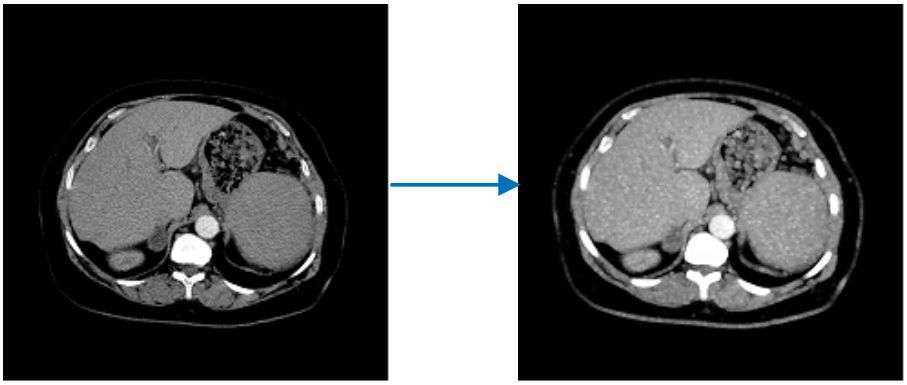


(a) Abdominal BT (b) Toraks BT (c) Pelvis BT

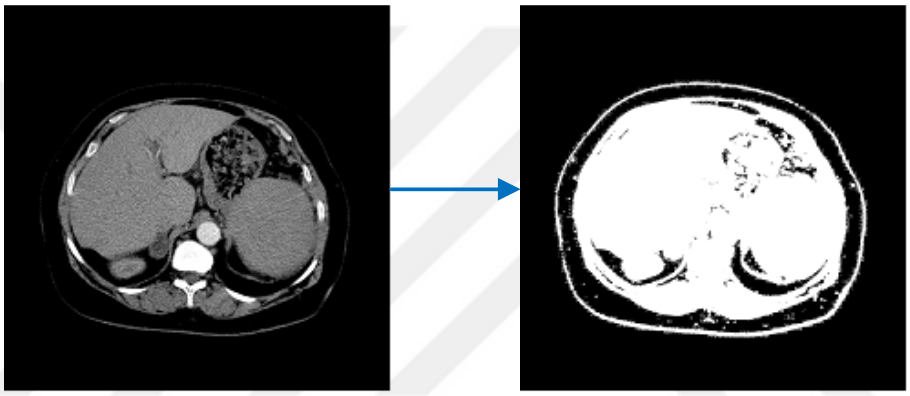
Şekil 4.2. Farklı tipteki BT görüntüleri

Tasarlanan sisteme dair parametre ayarlamaları, BT görüntüsü ve içindeki yapıların özelliklerine (yoğunluk, şekil, yapı, v.b. gibi) ve bu özelliklere bağlı problemlere göre gerçekleştirilmektedir. Bu problemlerden bazıları ve çözümleri Şekil 4.5 ve Şekil 4.6' da görüldüğü gibidir.

Şekil 4.5 (a) ve (b) kapsamında kullanılan BT görüntüleri, süreksiz kenarlı abdomen içermektedir. *Görüntü genişletme* işlemi ile süreksiz kenarların pekiştirilmesi ve birbirleriyle bağlanmaları amaçlanmıştır.



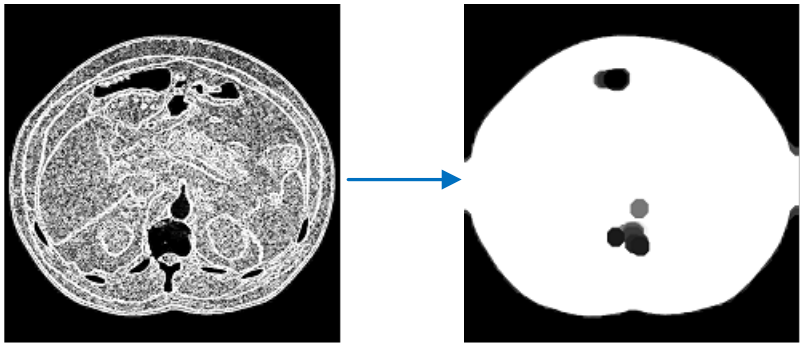
a-) Süreksiz kenarlı abdomen üzerine etkisiz *görüntü genişletme*



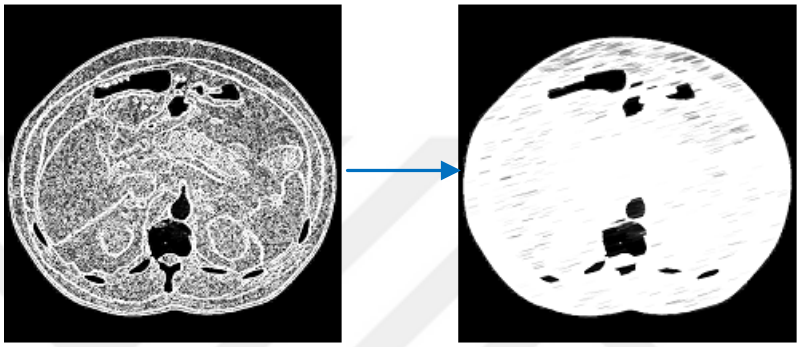
b-) Süreksiz kenarlı abdomen üzerine başarılı *görüntü genişletme*

Şekil 4.5. *Görüntü Genişletme* işlemi üzerine farklı durumlar

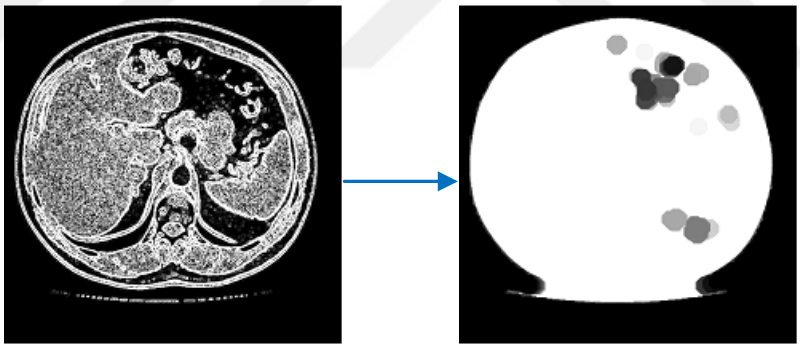
Şekil 4.5 (a)' da sunulan işlemde disk tipi yapı elemanı kullanılmıştır. Ancak abdomen kenarları tam olarak belirginleşmemiştir. Bu noktada farklı çıkışların toplamı ile kenarların belirginleştirilebileceği görülmektedir. Şekil 4.5 (b)' de sunulan işlem, 36 adet çizgi tipi yapı elemanı kullanılarak gerçekleştirilen *görüntü genişletmedir*. Bu işlemde yapı elemanlarının açı değerleri; 0°-175° arası, 5°' lik artış olacak şekilde (0°, 5°, …, 175°) ayarlanmaktadır. Sonrasında bütün çıkışlar toplanarak *görüntü genişletme* yapılmıştır. Böylece bağlantısı olmayan kenar bölümlerinin birbiri ile teması sağlanmıştır. Ayrıca açı değerlerinin 0°-180° aralığında seçilmediği ve 5° adım büyüklüğü kullanılmadığı durumlarda, optimum sonuçların elde edilemediği görülmüştür. Sonuç olarak; yapı elemanı tipi ve açı değerlerinin, kenar pekiştirme sonucunu doğrudan etkileyen parametreler oldukları tespit edilmiştir.



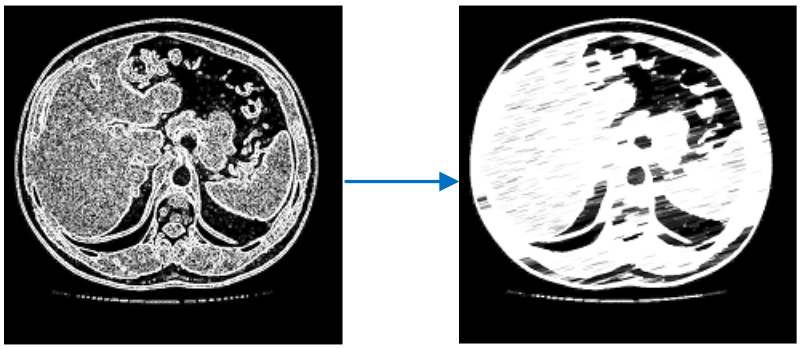
a-) Abdomenin dış kenarlarını görüntü kenarlarına bağlayan (etkisiz) morfolojik kapama



b-) Başarılı morfolojik kapama



c-) Abdomeni BT yatağı ile birleştiren etkisiz morfolojik kapama



d-) Başarılı morfolojik kapama

Şekil 4.6. Morfolojik kapama işlemi üzerine farklı durumlar

Şekil 4.6 (a) ve (b)' de abdomen görüntüsünün, BT kenarlarına yakın olduğu bir durumda *morfolojik kapama* işlemi ele alınmıştır. Şekil 4.6 (a)' da disk tipi yapı elemanı kullanılarak kapama gerçekleştirilmekte, bu noktada abdomen kısmı görüntü kenarlarına bağlanmaktadır. Şekil 4.6 (b)' de iki adet çizgi tipi yapı elemanı kullanılmış, bu elemanların açı değerleri sırasıyla 15° ve 165° olarak belirlenmiştir. Söz konusu açı değerleri dışındaki açılarda veya daha fazla yapı elemanı kullanıldığı durumlarda, sistem çıkışı negatif yönde etkilenmiştir.

Şekil 4.6 (c) ve (d)' de, BT yatağına yakın bir abdomen üzerine *morfolojik kapama* uygulanmıştır. Şekil 4.6 (c)' de abdomen kısmını BT yatağına bağlayan işlem için disk tipi yapı elemanı kullanılmıştır. Şekil 4.6 (d)' de 15° ve 165° yönlerinde iki adet çizgi tipi yapı elemanı kullanılmış, bu sayede BT yatağının abdomenden ayrılabildiği görülmüştür. Yapı elemanının doğru seçimi, görüntüde abdomene yakın BT yatağı olduğu veya görüntü kenarlarına yakın abdomen olduğu durumlarda çok önemlidir.

GOB yaklaşımı içindeki parametreler (*a* & *b*), kontrastı düzenlenmiş ve kenarları iyileştirilmiş abdomeni oluşturacak şekilde atanmıştır. Medyan filtre kapsamında kullanılan yama boyutu [5,5] olarak belirlenmiştir. Bu boyuttan daha küçük Medyan filtreler, görüntü içindeki gürültüleri ve blur görüntüyü elimine edememekte, daha büyük değerler ise bilgi kaybına sebebiyet vermektedir. UBCO tekniği eşik değeri "1" olarak seçilmiş, AbSeg sisteminin adımları da bu kurala göre ayarlanmıştır. AbSeg parametrelerinin optimum değerleri Çizelge 4.2' de görüldüğü gibidir.

Çizelge 4.2. AbSeg parametrelerinin optimum koşulları

AbSeg Operatörü	Parametre Adı	Optimum Koşullar
GOB	*a* & *b*	*a*=10, *b*=1
Görüntü Genişletme	Çizgilerin Uzunluğu	3
	Çizgilerin Açıları	0°, 5°,…, 175°
Medyan Filtre	Boyut	[5 5]
Morfolojik Kapama	Çizgilerin Uzunluğu	23
	Çizgilerin Açıları	15°, 165°
UBCO	Eşik Sayısı	1 (iki sınıf)

4.2.3. AbSeg ile elde edilen deneysel sonuçlar ve istatistiksel analiz

Eğitim aşamasında 16 Dinamik BT görüntüsü üzerine denemeler gerçekleştirilmiş, sistem performansı Dice, Jaccard, duyarlılık, özgüllük, doğruluk ve kesinlik metrikleri üzerinden değerlendirilmiştir. AbSeg sisteminin parametre ayarlamaları eğitim verisi üzerinden sağlanmıştır. Sistemin eğitim sonuçları Çizelge 4.3' te görüldüğü gibidir.

Çizelge 4.3. AbSeg sisteminin eğitim sonuçları

Görüntüler	Jaccard	Dice	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
Arterial_1	99,4741	99,7364	100	98,4158	99,5798	99,5945
Arterial_2	98,7221	99,3569	100	96,8136	99,0795	98,7221
Arterial_3	99,2613	99,6293	100	99,1291	99,5987	99,2613
Arterial_4	98,8633	99,4284	100	98,6689	99,3831	98,8633
Arterial_5	99,0488	99,5221	100	98,8644	99,4797	99,0488
Arterial_6	98,8743	99,4339	100	98,8006	99,4159	98,8743
Arterial_7	99,1987	99,5977	100	99,1811	99,5442	99,3731
Arterial_8	99,5635	99,7812	100	99,3070	99,6972	99,6914
Arterial_9	98,8133	99,4031	100	97,5640	99,1956	98,8133
Arterial_10	99,2672	99,6323	100	98,8434	99,5494	99,2672
Arterial_11	98,7896	99,3911	100	98,3925	99,3047	98,7896
Arterial_12	98,9234	99,4588	100	98,9337	99,4227	99,0667
Arterial_13	98,4711	99,2297	100	98,0364	99,1329	98,4711
Arterial_14	99,0381	99,5167	100	98,8736	99,4784	99,0381
Arterial_15	99,0081	99,5016	100	97,6150	99,2945	99,0081
Arterial_16	97,8232	98,8996	100	98,1300	98,9839	97,8232
Ortalama	**98,9463**	**99,4699**	**100**	**98,4731**	**99,3838**	**98,9816**

AbSeg sistemi, Çizelge 4.3' te görüldüğü gibi segmentasyon işlemini yüksek performansla gerçekleştirmektedir. Altı metrik üzerine ortalama başarının %99 olduğu görülmektedir. Ayrıca Jaccard ve Dice metrikleri üzerine elde edilen yüksek sonuçlar, tasarlanan yapının ve parametre değerlerinin oldukça verimli olduklarını ortaya koymaktadır.

AbSeg sistemini oluşturan temel operatörler, sistem içinden teker teker çıkarılarak sistem çıkışları incelenmiştir (Çizelge 4.4). Bu noktada farklı görüntüler üzerinde denemeler gerçekleştirilmiştir. Çünkü bütün dezavantajları içeren tek bir görüntü bulunmamaktadır.

Çizelge 4.4. AbSeg operatörlerinin performans değerlendirmesi

Çıkarılan Operatör	(Teknik mevcut / Teknik mevcut değil)			
	Görüntü	Jaccard	Dice	Doğruluk
Görüntü Genişletme	Arterial_12	**98,92** / 82,09	**99,46** / 90,16	**99,42** / 90,49
Ortanca Filtre	Arterial_16	**97,82** / 96,72	**98,90** / 98,33	**98,98** / 98,45
Gradyent Büyüklüğü	Arterial_13	**98,47** / 97,83	**99,23** / 98,90	**99,13** / 98,76
Morfolojik Kapama	Arterial_12	**98,92** / 81,77	**99,46** / 89,97	**99,42** / 90,32
Kontrast Sınırlı - Adaptif Histogram Eşitleme	Arterial_12	**98,92** / 84,95	**99,46** / 91,86	**99,42** / 91,99
Sıfır-geçiş Eliminatörü	Arterial_5	**99,05** / 98,90	**99,52** / 99,45	**99,48** / 99,40

Çizelge 4.4 kapsamında yer alan operatörler, en önemli (temel) bölümleri ifade etmektedir. Kullanılan diğer operatörler tek bir görüntüde çalışmamakta, birlikte işletildikleri zaman sistem çıkışını iyileştirmektedir. Çizelge 4.4' de kullanılan Arterial_12 görüntüsü, süreksiz kenarlı bir abdomen görüntüsüdür. Çizelge 4.4' e göre AbSeg operatörleri, farklı durumlarda sistem çıkışı üzerine etkin olmakta, bu operatörlerin yokluğunda maksimum performansların elde edilemediği görülmektedir.

Çizelge 4.5 ve Çizelge 4.6' da üç ayrı eşikleme algoritması, sürekli ve süreksiz kenarlı abdomen görüntüleri üzerine test edilmiştir.

Çizelge 4.5 Süreksiz kenarlı abdomen üzerine eşikleme metotlarının karşılaştırılması

Eşikleme Teknikleri (Arterial_12)	Jaccard	Dice	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
İkili Hale Getirme (Binarization)	98,40	99,19	99,85	98,33	99,14	98,54
Otsu	93,89	96,85	94,36	99,44	96,74	**99,48**
UBCO	**98,92**	**99,46**	**99,85**	**98,93**	**99,42**	99,07

Çizelge 4.6. Sürekli kenarlı abdomen üzerine eşikleme metotlarının karşılaştırılması

Eşikleme Teknikleri (Arterial_4)	Jaccard	Dice	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
İkili Hale Getirme (Binarization)	97,89	98,93	100	97,50	98,84	97,89
Otsu	**98,86**	**99,43**	**100**	**98,67**	**99,38**	**98,86**
UBCO	**98,86**	**99,43**	**100**	**98,67**	**99,38**	**98,86**

Çizelge 4.5' de görüldüğü üzere; en optimum Jaccard, Dice ve doğruluk oranlarının elde edildiği eşikleme algoritması UBCO' dur. İkili Hale Getirme işlemi ise genelde Otsu metoduna göre daha yüksek sonuçlar sağlamaktadır. Çizelge 4.6' da görüldüğü üzere; Otsu ve UBCO algoritmaları aynı sonuçları elde etmekte, bu sonuçlar İkili Hale Getirme işlemine üstünlük sağlamaktadır. Kısaca UBCO algoritması, hem

süreksiz hem de sürekli kenarlı abdomenler üzerine etkin bir şekilde kullanılabilen yegâne tekniktir.

AbSeg sisteminin test verisi sonuçları Çizelge 4.7' de görüldüğü gibidir. Çizelge 4.7' ye göre AbSeg sistemi, bütün metrikler üzerine ortalama %99.5 başarı elde etmektedir. Söz konusu değerler eğitim / test karşılaştırmasına göre %98.95 / %99.36 (Jaccard), %99.47 / %99.67 (Dice), %100 / %99.91 (duyarlılık), %98.47 / %99.23 (özgüllük), %99.38 / %99.63 (doğruluk) ve %98.98 / %99.45 (kesinlik) şeklindedir. Karşılaştırma neticesinde test sonuçlarının, eğitim sonuçlarına göre (*duyarlılık* harici) bütün metriklerde daha yüksek olduğu görülmüştür. Diğer bir deyişle, sistem parametre ayarlamalarının optimum olarak elde edildiği açık bir şekilde görülmektedir.

Çizelge 4.7. AbSeg sisteminin test verisi sonuçları

Görüntüler	Jaccard	Dice	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
Arterial_17	99,3226	99,6602	100	99,2613	99,6454	99,3226
Arterial_18	99,5436	99,7713	100	99,1761	99,7054	99,5436
Arterial_19	99,4610	99,7297	100	99,0167	99,6506	99,4610
Arterial_20	97,6528	98,8125	100	97,1643	98,6991	97,6528
Arterial_21	98,5149	99,2519	98,8342	99,5450	99,1299	99,6731
Arterial_22	99,6077	99,8035	100	99,0005	99,7175	99,6077
Arterial_23	99,3692	99,6836	100	99,3760	99,6853	99,3692
Arterial_24	99,5604	99,7797	100	99,4773	99,7606	99,5604
Arterial_25	99,5505	99,7747	100	99,4889	99,7603	99,5505
Arterial_26	99,5392	99,7691	100	99,3729	99,7337	99,5392
Arterial_27	99,6599	99,8297	100	99,5762	99,8110	99,6599
Arterial_28	99,4008	99,6995	100	99,3165	99,6797	99,4008
Arterial_29	99,6809	99,8402	99,8988	99,6017	99,7935	99,7817
Arterial_30	99,6735	99,8365	100	99,5579	99,8119	99,6735
Arterial_31	99,5726	99,7858	99,8829	99,4332	99,7234	99,6890
Arterial_32	99,6976	99,8486	100	99,2685	99,7856	99,6976
Ortalama	**99,3629**	**99,6798**	**99,9135**	**99,2271**	**99,6308**	**99,4489**

Tasarlanan sisteme dair parametre ayarlamalarının farklı bir veri seti üzerine etkinliği, validasyon verisi üzerine denemeler gerçekleştirilerek incelenmiştir. Validasyon verisi kapsamında abdominal BT görüntülerinin yanı sıra göğüs ve pelvis BT görüntüleri de kullanılmaktadır. Bu görüntülerde elde edilmesi gereken ROI, abdominal BT görüntülerinde olduğu gibi elipsoid bir alandır.

TCIA kütüphanesinden alınan validasyon verisi üzerine AbSeg sonuçları Çizelge 4.8' de sunulmuştur. Çizelge 4.8' e göre validasyon verisinde de, eğitim ve test verileri ile gerçeklenen denemelerde olduğu gibi yüksek başarılara ulaşıldığı görülmektedir.

Çizelge 4.8. AbSeg sisteminin validasyon sonuçları

Görüntü	Jaccard	Dice	Duyarlılık	Özgüllük	Doğruluk	Kesinlik	BT Türü
Görüntü_1	99,6617	99,8306	100	99,8193	99,8821	99,6617	Abdomen
Görüntü_2	99,4603	99,7294	100	99,7984	99,8530	99,4603	Abdomen
Görüntü_3	99,7768	99,8883	100	99,9639	99,9689	99,7768	Abdomen
Görüntü_4	99,6630	99,8312	99,8812	99,8508	99,8631	99,7813	Pelvis
Görüntü_5	99,4940	99,7464	99,8930	99,8226	99,8442	99,6001	Toraks
Görüntü_6	99,6902	99,8448	99,6902	100	99,9374	100	Abdomen
Görüntü_7	99,5080	99,7534	99,6493	99,9317	99,8400	99,8578	Toraks
Görüntü_8	99,5626	99,7808	100	99,8857	99,9093	99,5626	Toraks
Görüntü_9	99,2873	99,6424	99,7758	99,9058	99,8849	99,5094	Pelvis
Görüntü_10	99,7761	99,8879	100	99,8537	99,9115	99,7761	Toraks
Görüntü_11	99,6485	99,8239	99,8713	99,8541	99,8609	99,7766	Toraks
Görüntü_12	99,6514	99,8254	100	99,8301	99,8857	99,6514	Abdomen
Görüntü_13	99,6115	99,8054	100	99,8017	99,8685	99,6115	Abdomen
Görüntü_14	99,5779	99,7885	99,8856	99,7638	99,8166	99,6916	Toraks
Görüntü_15	99,6063	99,8028	99,8924	99,9045	99,9015	99,7133	Toraks
Görüntü_16	99,4921	99,7454	99,6810	99,9642	99,9192	99,8099	Abdomen
Görüntü_17	99,3393	99,6685	99,8051	99,8967	99,8801	99,5324	Abdomen
Görüntü_18	99,5663	99,7827	100	99,6938	99,8202	99,5663	Toraks
Görüntü_19	99,5410	99,7700	99,8667	99,8052	99,8281	99,6735	Toraks
Görüntü_20	99,5526	99,7758	99,8819	99,7938	99,8276	99,6699	Toraks
Görüntü_21	99,6389	99,8191	100	99,8450	99,8914	99,6389	Abdomen
Görüntü_22	99,4790	99,7388	100	99,7879	99,8491	99,4790	Pelvis
Görüntü_23	99,5120	99,7554	99,8534	99,8273	99,8360	99,6576	Toraks
Görüntü_24	99,6653	99,8324	100	99,8144	99,8804	99,6653	Abdomen
Görüntü_25	99,4734	99,7360	100	99,7937	99,8516	99,4734	Abdomen
Görüntü_26	99,6770	99,8382	100	99,8031	99,8775	99,6770	Abdomen
Ortalama	99,5736	99,7863	99,9087	99,8466	99,8726	99,6644	----------

AbSeg sisteminin, farklı tipteki BT görüntülerinde elde ettiği ortalama performans Çizelge 4.9' da sunulmaktadır. Çizelge 4.9' a göre AbSeg sistemi, abdominal BT görüntülerinde (kesinlik harici) bütün metrikler üzerine en yüksek sonuçları elde etmekte, abdomen görüntülerini toraks ve pelvis görüntülerinden daha iyi segmente etmektedir. Toraks ve pelvis segmentasyon performansları için kesin bir yorum yapmak, veri sayısı az olduğundan yanıltıcı olabilir. Ancak elde edilen sonuçlara

göre, AbSeg sisteminin, farklı bir veri seti üzerinde de abdomen segmentasyonu yapabileceği, aynı zamanda (elipsoid şekilli) toraks ve pelvis görüntülerinde de başarı sağlayabileceği görülmüştür.

Çizelge 4.9. AbSeg sisteminin farklı tür BT görüntüleri üzerine ortalama performansı

BT Tarama Türü	Jaccard	Dice	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
Abdomen (12 görüntü)	99,5948	99,7970	99,9314	99,8609	99,8913	99,6632
Toraks (11 görüntü)	99,5768	99,7880	99,8903	99,8306	99,8542	99,6859
Pelvis (3 görüntü)	99,4764	99,7375	99,8857	99,8482	99,8657	99,5899

Çizelge 4.10' da eğitim, test ve validasyon verileri üzerine elde edilen ortalama performanslar sunulmaktadır. Elde edilen sonuçlara göre AbSeg sistemi, validasyon verisinde (duyarlılık haricinde) bütün metrikler için en yüksek sonuçları üretmiştir. Bu noktada önerilen yaklaşım, farklı veri setleri kullanıldığı durumda da etkin bir şekilde kullanılabilmektedir.

Eğitim ve test verilerinde görüntü boyutları 852x852 iken, validasyon verilerinde görüntü boyutları 1920x1080 olarak seçilmiştir. AbSeg sistemi; eğitim, test ve validasyon setlerinde, bütün metriklerin ortalamasına göre sırasıyla %99.21, %99.54 ve %99.78 başarı sağlamaktadır.

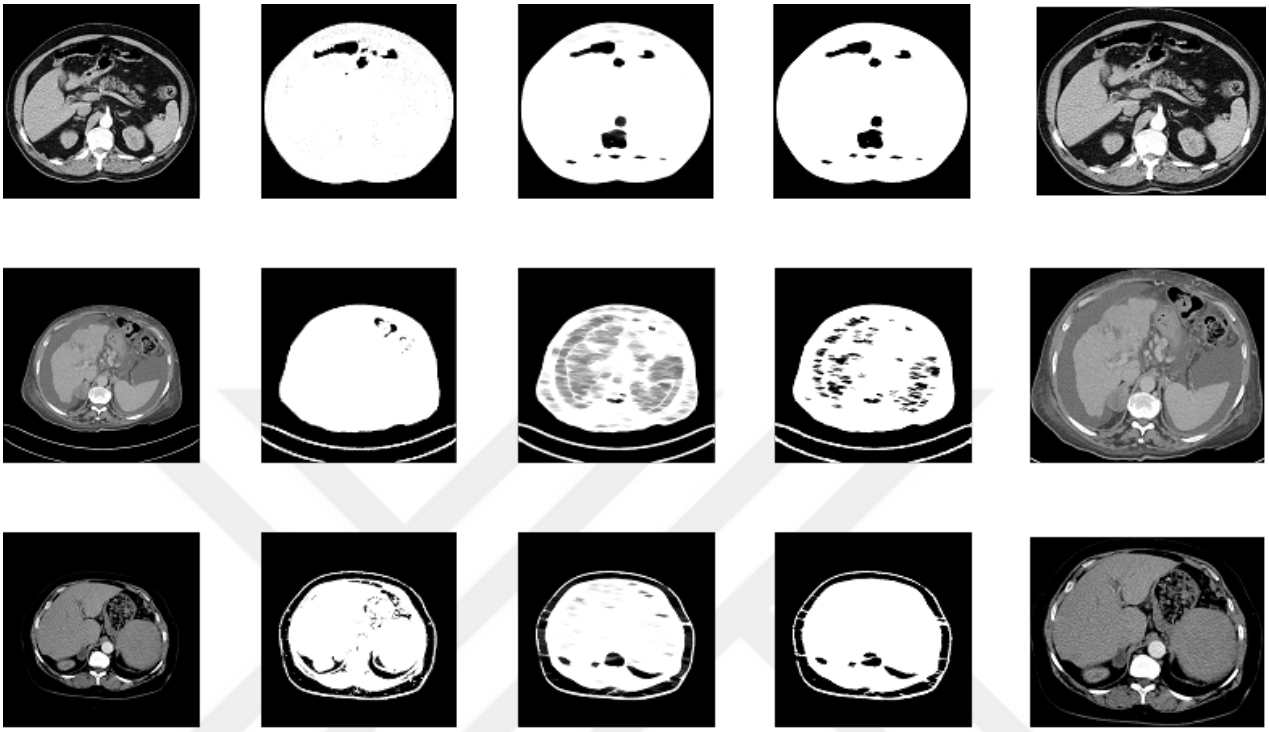
Çizelge 4.10. AbSeg sisteminin eğitim, test ve validasyon veri setlerinde elde ettiği ortalama performaslar

Veri seti	Jaccard	Dice	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
Eğitim (16 görüntü)	98,9463	99,4699	100	98,4731	99,3838	98,9816
Test (16 görüntü)	99,3629	99,6798	99,9135	99,2271	99,6308	99,4489
Validasyon (26 görüntü)	99,5736	99,7863	99,9087	99,8466	99,8726	99,6644

4.2.4. Görsel sonuçlar ve analiz

AbSeg sisteminin temel operatör çıkışları Şekil 4.7' de görsel olarak sunulmuştur. Her bir sütunda farklı operartör çıkışları verilmiştir. Bu çıkışlar sırasıyla orijinal görüntü, görüntü genişletme çıkışı, morfolojik kapama çıkışı, UBCO çıkışı ve sistem çıkışı şeklinde sıralanabilir. İlk görüntü, abdomen kenar bölümleri BT kenarlarına yakın olan görüntüyü, ikinci görüntü abdomeni çevreleyen BT yatağı görüntüsünü, üçüncü görüntü ise süreksiz kenarlı abdomen görüntüsünü ifade etmektedir.

Elde edilen sonuçlara göre AbSeg sistemi; BT yatağı görüntüsü, hasta bilgileri, BT kenarlarına yakın abdomen, düşük kontrast, dar histogram ve süreksiz kenarlı abdomen gibi dezavantajların bulunduğu görüntülerde etkin olarak kullanılabilmektedir.



Şekil 4.7. Etkin AbSeg operatörlerinin farklı dezavantajlarda elde ettiği çıkışlar

Çalışma neticesinde özetle; abdomen segmentasyonu önünde engel teşkil eden dezavantajların eliminasyonunu sağlayan, hem parametre ayarlamalarının sağlandığı veri setinde hem de farklı veri setlerinde işlem yapabilen, yüksek çözünürlükte daha iyi segmentasyon sonuçları üreten, abdomeni yüksek başarı ile segmente edebilmesinin yanı sıra toraks ve pelvis BT görüntülerinde de ümit vadeden istatistiksel bir sistemin tasarımı gerçekleştirilmiştir.

4.3. Gürültü Eliminasyonu Çalışması

Çalışmada literatürde gürültü eliminasyonu için sıklıkla kullanılan BE3BF tekniği, BT görüntülerinde gürültü eliminasyonu üzerine 13 farklı metot ile karşılaştırılmıştır. Karşılaştırılan teknikler; Medyan filtre, Wiener filtresi, DDD, LYP-GAK, AKD-S, AS, ÇDGG, ŞA-AKD, OYLB-GKM, YGTBA, YHTBA, YLTBA,

DDM-TDA ve BE3BF şeklindedir. Bu bölümde metotların genel bir karşılaştırması yapılarak, elde edilen sonuçlara dair ayrıntılı analizler verilmiştir.

Toplam İstatistiksel Başarı (TİB / Total Statistical Success→TSS), algoritmaların başarısını ölçmek için deneylerin ilk bölümünde kullanılmıştır. TİB metriği, en iyi performansların (birinciliklerin) sayısını göstermektedir. TİB metriği temelli karşılaştırma, genelleştirilmiş bir istatistik sunar.

İkinci bölümde metotlar, 13 görüntüde elde edilen DSGO değerlerinin ortalaması üzerinden karşılaştırılmış, farklı gürültü seviyelerinde elde edilen ortalama başarılar incelenmiştir.

Üçüncü bölüm, simülasyon sonuçlarının doğruluğunu test etmek için görsel tabanlı bir karşılaştırma içermektedir. Bu bölümde, en etkin metotlara dair çıkış görüntüleri gürültü eliminasyonu üzerine kıyaslanmıştır.

Dördüncü aşamada ROI tabanlı karşılaştırmalar gerçekleştirilerek, gürültü giderme algoritmalarının etkinliği lezyon çevresinde ölçülmüştür. Bu noktada bütün bir görüntüde DSGO hesaplanması yerine, ROI alanları üzerinden değerler hesap edilmiştir.

Önceki denemelerde ön plana çıkan ilk beş teknik, beşinci aşamada Merkezi İşlemci Birimi (MİB / Central Processing Unit → CPU) zamanı üzerinden karşılaştırılmıştır.

Altıncı bölümde, en iyi performansa sahip olan ilk beş tekniğin hesaplama maliyeti incelenmiştir. Bu noktada en hızlı ve pratik teknik, işletilen kod satırlarının sayısı üzerinden tespit edilmiştir.

Sonuç olarak, BGG' nün eliminasyonu amacıyla 6 farklı karşılaştırma işlemi gerçekleştirilmiştir. Böylece tekniklerin birbirine olan üstünlüğü daha açık ve net bir şekilde sunularak, en optimum seçenek (en yüksek performanslı teknik) belirlenmiştir.

Metotlar farklı gürültü seviyelerinde sınanmış, EBGG standart sapma (σ) değerleri literatürde önerildiği üzere 2, 5, 10, 15, 20, 25, 50, 75 ve 100 şeklinde değiştirilmiştir (Dabov ve ark., 2007). Bu amaçla 14 etkin metot, farklı gürültü seviyelerinde en kararlı olanı tanımlamak için DSGO temelli karşılaştırılmıştır. Çizelge 4.11 ve Çizelge 4.19 arası sunumlar, farklı standart sapma (σ) değerleri (sırasıyla 2, 5, 10, 15, 20, 25, 50, 75 ve 100) için tekniklerin elde ettiği DSGO sonuçlarının genel kıyaslamasını sunmaktadır. Görüntülere gürültü eklenmesi (4.13)' te görüldüğü gibidir.

$$Gürültülü\ Görüntü = Orijinal\ Görüntü + \sigma \times rand(görüntü\ boyutu) \tag{4.13}$$

Çizelge 4.11. σ=2 iken 13 adet arteryal faz BT görüntüsünde tekniklerin DSGO (dB) sonuçları (σ=standart sapma, G_i: i. görüntü)

Metotlar/Görüntü	G_1	G_2	G_3	G_4	G_5	G_6	G_7	G_8	G_9	G_10	G_11	G_12	G_13
Medyan Filtre	24,36	26,39	26,97	28,05	27,39	27,14	28,83	29,81	29,41	29,51	28,15	27,59	28,82
Wiener Filtresi	28,74	31,71	31,91	33,71	37,51	32,39	33,89	39,05	35,54	38,38	37,69	36,78	34,73
DDD	32,68	34,85	35,57	36,84	38	35,73	38,98	40,06	38,17	39,77	38,41	38,49	37,83
LPY-GAK	43,76	45,06	45,47	45,73	46,45	45,24	45,24	46,71	46,67	46,43	46,37	45,4	46,59
AKD-S	44,05	44,74	45,03	45,16	45,72	44,91	45,03	45,92	45,58	45,82	45,7	45,33	45,58
AS	44,14	44,82	45,11	45,23	45,76	44,99	45,13	45,96	45,65	45,85	45,75	45,36	45,65
ÇDGG	44,39	45,68	45,93	46,28	47,26	45,85	45,79	47,63	47,13	47,28	47,17	46,24	47,09
ŞA-AKD	44,66	45,9	46,25	46,66	47,75	46,21	46,31	48,1	47,52	47,82	47,67	46,77	47,56
OYLB-GKM	44,91	46,19	46,52	46,87	47,92	46,42	46,61	48,34	47,75	48,09	47,93	46,99	47,74
YGTBA	**45,04**	46,2	**46,65**	46,9	47,94	46,44	**46,67**	48,34	**47,78**	48,15	47,97	47,13	47,78
YLTBA	45,02	46,14	46,6	46,85	47,95	46,4	46,59	48,33	47,71	48,14	47,95	47,12	47,7
YHTBA	44,94	46,05	46,43	46,73	47,83	46,28	46,48	48,17	47,59	47,96	47,75	46,98	47,57
DDM-TDA	44,92	46,16	46,59	46,8	48,08	46,4	46,66	48,54	47,72	**48,28**	**48,11**	**47,23**	47,78
BE3BF	44,97	**46,21**	46,55	**46,91**	**48,12**	**46,5**	46,64	**48,59**	47,77	48,26	48,1	47,19	**47,81**

Çizelge 4.12. σ=5 iken 13 adet arteryal faz BT görüntüsünde tekniklerin DSGO (dB) sonuçları (σ=standart sapma, G_i: i. görüntü)

Metotlar/Görüntü	G_1	G_2	G_3	G_4	G_5	G_6	G_7	G_8	G_9	G_10	G_11	G_12	G_13
Medyan Filtre	24,34	26,36	26,94	28,01	27,35	27,11	28,77	29,72	29,36	29,43	28,09	27,54	28,77
Wiener Filtresi	28,55	31,37	31,63	33,24	36,79	32,04	33,44	38,02	34,8	37,47	36,91	36,11	34,28
DDD	32,25	34,16	34,76	35,78	36,68	34,88	37,37	38,08	36,78	37,9	36,96	37,02	36,54
LPY-GAK	36,64	38,15	38,49	38,77	40,31	38,32	38,73	40,67	39,76	40,39	40,3	39,35	39,87
AKD-S	37,68	38,72	39,13	39,32	40,53	38,97	39,36	40,88	40	40,73	40,55	40,02	40,09
AS	37,78	38,81	39,21	39,38	40,55	39,04	39,48	40,92	40,07	40,77	40,61	40,05	40,14
ÇDGG	37,53	39	39,46	39,85	41,88	39,38	39,89	42,48	40,81	42,12	41,91	41,09	41,07
ŞA-AKD	37,82	39,3	39,81	40,19	42,04	39,69	40,27	42,6	41,22	42,25	42,04	41,22	41,4
OYLB-GKM	38,11	39,64	40,04	40,35	42,3	39,92	40,59	42,93	41,39	42,63	42,38	41,51	41,53
YGTBA	**38,3**	39,64	40,08	40,36	41,97	39,89	40,46	42,57	41,29	42,36	42,08	41,32	41,39
YLTBA	38,28	39,59	40,06	40,31	42,02	39,88	40,43	42,6	41,22	42,4	42,12	41,39	41,35
YHTBA	38,24	39,56	40	40,27	41,98	39,82	40,4	42,55	41,2	42,35	42,06	41,33	41,33
DDM-TDA	38,27	39,72	40,17	40,45	42,53	40,01	**40,73**	43,21	41,45	42,97	42,68	41,87	41,68
BE3BF	38,28	**39,75**	**40,21**	**40,55**	**42,67**	**40,08**	**40,73**	**43,39**	**41,54**	**43,02**	**42,78**	**41,93**	**41,81**

Çizelge 4.13. σ=10 iken 13 adet arteryal faz BT görüntüsünde tekniklerin DSGO (dB) sonuçları (σ=standart sapma, G_i: i. görüntü)

Metotlar/Görüntü	G_1	G_2	G_3	G_4	G_5	G_6	G_7	G_8	G_9	G_10	G_11	G_12	G_13
Medyan Filtre	24,26	26,24	26,81	27,85	27,21	26,98	28,56	29,44	29,14	29,17	27,9	27,36	28,59
Wiener Filtresi	27,98	30,41	30,81	32,01	34,98	31,08	32,26	35,7	33,12	35,34	34,97	34,4	33,06
DDD	30,98	32,31	32,69	33,29	33,8	32,76	34,13	34,45	33,83	34,36	33,93	33,96	33,72
LPY-GAK	31,85	33,46	33,87	34,27	36,27	33,81	34,4	36,6	35,16	36,28	36,17	35,29	35,41
AKD-S	33,1	34,36	34,86	35,13	36,77	34,74	35,31	37,25	35,93	37,02	36,82	36,14	36,04
AS	33,39	34,67	35,11	35,43	37	35,03	35,69	37,55	36,23	37,33	37,1	36,47	36,33
ÇDGG	33,37	34,93	35,52	35,81	38,15	35,32	36,18	38,86	36,89	38,49	38,24	37,4	37,16
ŞA-AKD	33,41	35,06	35,6	35,89	38,19	35,39	36,26	38,73	37	38,42	38,17	37,32	37,27
OYLB-GKM	33,56	35,2	35,69	36,05	38,48	35,59	36,5	39,13	37,08	38,8	38,53	37,65	37,42
YGTBA	33,61	35,03	35,48	35,82	37,71	35,34	36,09	38,33	36,69	38,07	37,79	37,07	36,87
YLTBA	33,61	34,99	35,49	35,78	37,75	35,34	36,06	38,33	36,64	38,09	37,82	37,14	36,88
YHTBA	33,57	34,97	35,47	35,76	37,75	35,31	36,06	38,33	36,64	38,09	37,83	37,12	36,87
DDM-TDA	33,74	35,35	35,91	36,16	38,56	35,68	36,65	39,41	37,24	39,05	38,79	37,86	37,59
BE3BF	**33,83**	**35,41**	**35,96**	**36,28**	**38,91**	**35,8**	**36,71**	**39,72**	**37,32**	**39,3**	**39,06**	**38,2**	**37,7**

Çizelge 4.14. σ=15 iken 13 adet arteryal faz BT görüntüsünde tekniklerin DSGO (dB) sonuçları (σ=standart sapma, G_i: i. görüntü)

Metotlar/Görüntü	G_1	G_2	G_3	G_4	G_5	G_6	G_7	G_8	G_9	G_10	G_11	G_12	G_13
Medyan Filtre	24,14	26,06	26,6	27,59	26,99	26,76	28,24	29,04	28,8	28,79	27,59	27,09	28,28
Wiener Filtresi	27,28	29,36	29,86	30,73	33,18	30	31,02	33,6	31,58	33,34	33,06	32,64	31,74
DDD	29,45	30,34	30,57	30,91	31,22	30,61	31,4	31,56	31,22	31,51	31,28	31,3	31,17
LPY-GAK	29,35	30,95	31,45	31,98	34,12	31,47	32,05	34,42	32,76	34,07	33,97	33,2	33,09
AKD-S	30,53	31,91	32,4	32,78	34,73	32,34	33	35,23	33,56	34,94	34,77	34,1	33,79
AS	30,88	32,26	32,73	33,11	35,05	32,67	33,43	35,63	33,89	35,33	35,16	34,5	34,14
ÇDGG	31,05	32,63	33,25	33,53	36,17	33,05	34	36,92	34,6	36,51	36,26	35,38	34,97
ŞA-AKD	31,08	32,74	33,31	33,63	36,13	33,12	34,08	36,67	34,7	36,35	36,1	35,22	35,04
OYLB-GKM	31,2	32,85	33,42	33,77	36,36	33,3	34,29	36,99	34,84	36,58	36,38	35,51	35,23
YGTBA	31,02	32,46	32,95	33,34	35,38	32,86	33,65	35,95	34,16	35,66	35,42	34,75	34,43
YLTBA	31,04	32,43	32,97	33,29	35,35	32,85	33,61	35,85	34,07	35,59	35,37	34,74	34,4
YHTBA	31	32,42	32,96	33,29	35,38	32,83	33,61	35,89	34,08	35,62	35,41	34,75	34,41
DDM-TDA	31,28	32,97	33,55	33,83	36,53	33,37	34,39	37,26	34,95	36,89	36,64	35,66	35,3
BE3BF	**31,38**	**33,03**	**33,62**	**33,99**	**36,94**	**33,48**	**34,5**	**37,69**	**34,99**	**37,25**	**37,04**	**36,17**	**35,49**

Çizelge 4.15. σ=20 iken 13 adet arteryal faz BT görüntüsünde tekniklerin DSGO (dB) sonuçları (σ=standart sapma, G_i: i. görüntü)

Metotlar/Görüntü	G_1	G_2	G_3	G_4	G_5	G_6	G_7	G_8	G_9	G_10	G_11	G_12	G_13
Medyan Filtre	23,98	25,82	26,32	27,26	26,71	26,48	27,84	28,54	28,38	28,32	27,21	26,76	27,9
Wiener Filtresi	26,59	28,39	28,94	29,57	31,6	28,99	29,89	31,87	30,27	31,66	31,44	31,12	30,5
DDD	27,95	28,54	28,68	28,9	29,11	28,71	29,22	29,31	29,1	29,27	29,14	29,15	29,08
LPY-GAK	27,73	29,33	29,89	30,52	32,6	29,97	30,52	32,9	31,25	32,55	32,44	31,75	31,6
AKD-S	28,76	30,2	30,75	31,13	33,34	30,84	31,43	33,8	31,97	33,52	33,3	32,75	32,29
AS	29,13	30,59	31,11	31,44	33,74	31,16	31,85	34,27	32,27	34,02	33,76	33,22	32,64
ÇDGG	29,4	31	31,68	32,01	34,93	31,52	32,52	35,64	33,03	35,2	34,99	34,1	33,54
ŞA-AKD	29,48	31,13	31,76	32,17	34,8	31,63	32,6	35,27	33,14	34,97	34,77	33,88	33,57
OYLB-GKM	29,59	31,31	31,89	32,35	34,97	31,87	32,76	35,49	33,35	35,15	34,9	34,09	33,75
YGTBA	29,29	30,73	31,26	31,7	33,77	31,19	32,02	34,25	32,47	33,97	33,76	33,16	32,82
YLTBA	29,31	30,7	31,27	31,62	33,64	31,16	31,93	34,06	32,34	33,8	33,61	33,05	32,72
YHTBA	29,27	30,69	31,27	31,63	33,7	31,16	31,94	34,13	32,36	33,87	33,68	33,1	32,75
DDM-TDA	29,63	31,41	31,96	32,32	35,27	31,88	32,84	35,9	33,29	35,53	35,36	34,37	33,76
BE3BF	**29,74**	**31,43**	**32,09**	**32,52**	**35,63**	**31,97**	**33,05**	**36,3**	**33,49**	**35,88**	**35,68**	**34,82**	**34,08**

Çizelge 4.16. σ=25 iken 13 adet arteryal faz BT görüntüsünde tekniklerin DSGO (dB) sonuçları (σ=standart sapma, G_i: i. görüntü)

Metotlar/Görüntü	G_1	G_2	G_3	G_4	G_5	G_6	G_7	G_8	G_9	G_10	G_11	G_12	G_13
Medyan Filtre	23,79	25,54	26,01	26,89	26,37	26,15	27,41	27,99	27,91	27,8	26,79	26,38	27,46
Wiener Filtresi	25,93	27,52	28,05	28,53	30,2	28,06	28,85	30,38	29,12	30,23	30,04	29,79	29,34
DDD	26,56	26,97	27,07	27,21	27,37	27,08	27,43	27,49	27,34	27,46	27,37	27,38	27,34
LPY-GAK	26,61	28,19	28,81	29,48	31,39	28,92	29,41	31,7	30,19	31,35	31,22	30,62	30,5
AKD-S	27,49	28,96	29,57	30,13	32,21	29,67	30,28	32,69	30,85	32,39	32,16	31,59	31,21
AS	27,88	29,36	29,92	30,43	32,69	29,99	30,69	33,26	31,14	32,93	32,67	32,13	31,53
ÇDGG	28,18	29,8	30,55	30,93	34,03	30,43	31,43	34,69	31,9	34,24	34,06	33,2	32,51
ŞA-AKD	28,28	29,92	30,63	31,12	33,79	30,55	31,5	34,19	32,03	33,95	33,78	32,9	32,53
OYLB-GKM	28,46	30,17	30,76	31,28	33,87	30,76	31,64	34,37	32,22	34	33,83	33,1	32,68
YGTBA	28,03	29,46	30,05	30,49	32,49	29,98	30,81	32,91	31,25	32,63	32,45	31,91	31,62
YLTBA	28,04	29,41	30,01	30,36	32,28	29,9	30,66	32,63	31,06	32,38	32,21	31,72	31,43
YHTBA	28,01	29,41	30,02	30,39	32,35	29,91	30,68	32,73	31,09	32,47	32,31	31,78	31,48
DDM-TDA	28,38	30,17	30,74	31,22	34,32	30,72	31,67	34,9	32,01	34,49	34,41	33,46	32,63
BE3BF	**28,55**	**30,29**	**31,02**	**31,51**	**34,63**	**30,92**	**32,01**	**35,26**	**32,44**	**34,84**	**34,66**	**33,83**	**33,09**

Çizelge 4.17. σ=50 iken 13 adet arteryal faz BT görüntüsünde tekniklerin DSGO (dB) sonuçları (σ=standart sapma, G_i: i. görüntü)

Metotlar/Görüntü	G_1	G_2	G_3	G_4	G_5	G_6	G_7	G_8	G_9	G_10	G_11	G_12	G_13
Medyan Filtre	22,58	23,84	24,15	24,75	24,38	24,24	25,07	25,22	25,38	25,1	24,48	24,24	25,05
Wiener Filtresi	23,13	23,96	24,23	24,43	24,97	24,2	24,65	25,06	24,71	25,01	24,89	24,83	24,75
DDD	21,39	21,49	21,51	21,54	21,61	21,51	21,63	21,63	21,58	21,61	21,6	21,6	21,6
LPY-GAK	23,81	25,28	25,82	26,51	27,45	26	26,21	27,78	27,16	27,48	27,29	26,9	27,16
AKD-S	24,3	25,76	26,48	27,19	28,46	26,69	27,07	28,81	27,77	28,64	28,41	28,05	27,93
AS	24,53	26,02	26,71	27,48	28,99	26,96	27,3	29,49	27,95	29,25	29,02	28,66	28,25
ÇDGG	25,04	26,77	27,67	28,37	30,96	27,73	28,51	31,64	29,11	31,16	30,95	30,37	29,74
ŞA-AKD	25,13	26,56	27,74	28,48	30,48	27,81	28,51	30,62	29,3	30,78	30,48	29,83	29,69
OYLB-GKM	25,26	26,97	27,75	28,43	30,56	27,87	28,5	30,91	29,2	30,53	30,43	29,8	29,7
YGTBA	24,56	25,99	26,56	26,95	28,09	26,5	27,13	28,42	27,69	28,32	28,13	27,76	27,82
YLTBA	24,4	25,71	26,23	26,54	27,59	26,16	26,67	27,81	27,15	27,69	27,58	27,24	27,3
YHTBA	24,41	25,75	26,31	26,65	27,72	26,25	26,75	27,98	27,28	27,85	27,73	27,35	27,44
DDM-TDA	25,14	26,88	27,85	28,59	31,18	27,82	28,6	31,77	29,31	31,32	31,22	30,76	29,9
BE3BF	**25,62**	**27,45**	**28,33**	**29,08**	**31,73**	**28,37**	**29,21**	**32,27**	**29,88**	**31,89**	**31,66**	**31,05**	**30,46**

Çizelge 4.18. σ=75 iken 13 adet arteryal faz BT görüntüsünde tekniklerin DSGO (dB) sonuçları (σ=standart sapma, G_i: i. görüntü)

Metotlar/Görüntü	G_1	G_2	G_3	G_4	G_5	G_6	G_7	G_8	G_9	G_10	G_11	G_12	G_13
Medyan Filtre	21,2	22,06	22,25	22,68	22,4	22,32	22,89	22,86	23,07	22,79	22,38	22,23	22,82
Wiener Filtresi	20,8	21,25	21,38	21,52	21,69	21,37	21,65	21,76	21,67	21,74	21,64	21,62	21,65
DDD	18,05	18,07	18,08	18,08	18,14	18,07	18,14	18,14	18,11	18,12	18,12	18,12	18,13
LPY-GAK	22,38	23,62	24	24,6	24,98	24,18	24,27	25,21	25,19	24,98	24,77	24,43	24,99
AKD-S	22,92	24,28	24,75	25,28	26,09	24,86	25,21	26,34	26,03	26,22	26,01	25,67	25,89
AS	23,04	24,42	24,89	25,46	26,49	25,06	25,32	26,81	26,11	26,71	26,44	26,16	26,09
ÇDGG	23,75	25,45	26,28	27,08	28,88	26,46	26,84	29,47	27,74	29,03	28,86	28,33	28,03
ŞA-AKD	23,79	25,11	26,28	27,03	28,29	26,43	26,8	28,23	27,88	28,62	28,2	27,67	27,95
OYLB-GKM	23,89	25,55	26,25	27,02	28,46	26,49	26,79	28,74	27,79	28,52	28,34	27,83	27,95
YGTBA	22,58	23,97	24,44	24,81	25,12	24,44	24,83	25,49	25,45	25,44	25,33	24,93	25,41
YLTBA	22,23	23,46	23,83	24,12	24,39	23,83	24,09	24,66	24,59	24,61	24,56	24,24	24,6
YHTBA	22,32	23,57	23,98	24,28	24,58	23,98	24,24	24,89	24,82	24,81	24,76	24,4	24,81
DDM-TDA	23,93	25,61	26,41	27,3	28,91	26,61	26,86	29,48	27,79	29,24	28,96	28,67	28,19
BE3BF	**24,36**	**26,14**	**26,96**	**27,85**	**29,78**	**27,14**	**27,57**	**30,2**	**28,55**	**29,9**	**29,67**	**29,17**	**28,84**

Çizelge 4.19. σ=100 iken 13 adet arteryal faz BT görüntüsünde tekniklerin DSGO (dB) sonuçları (σ=standart sapma, G_i: i. görüntü)

Metotlar/Görüntü	G_1	G_2	G_3	G_4	G_5	G_6	G_7	G_8	G_9	G_10	G_11	G_12	G_13
Medyan Filtre	19,83	20,42	20,54	20,86	20,66	20,6	21,01	20,92	21,11	20,88	20,59	20,5	20,93
Wiener Filtresi	18,85	19,11	19,18	19,28	19,34	19,17	19,37	19,38	19,37	19,38	19,3	19,3	19,34
DDD	15,56	15,56	15,56	15,55	15,6	15,55	15,6	15,6	15,57	15,57	15,58	15,58	15,59
LPY-GAK	21,25	22,3	22,57	23,09	23,14	22,72	22,79	23,32	23,63	23,1	22,92	22,57	23,34
AKD-S	21,94	23,24	23,53	24,01	24,54	23,66	23,93	24,72	24,68	24,54	24,31	23,99	24,56
AS	21,98	23,28	23,59	24,05	24,85	23,71	23,97	24,97	24,71	24,81	24,59	24,29	24,65
ÇDGG	22,94	24,52	25,22	25,98	27,22	25,46	25,54	27,69	26,63	27,32	27,15	26,67	26,66
ŞA-AKD	22,95	24,1	25,17	25,93	26,68	25,41	25,61	26,43	26,77	26,99	26,5	26,05	26,64
OYLB-GKM	23,05	24,62	25,25	25,89	26,85	25,41	25,59	27,27	26,75	26,94	26,76	26,27	26,67
YGTBA	21,11	22,45	22,73	23,11	22,96	22,81	23,02	23,34	23,64	23,23	23,23	22,86	23,54
YLTBA	20,59	21,7	21,93	22,22	22,1	22,01	22,1	22,38	22,6	22,28	22,32	22,02	22,54
YHTBA	20,73	21,88	22,14	22,45	22,35	22,21	22,32	22,65	22,89	22,52	22,55	22,23	22,79
DDM-TDA	23,04	24,54	25,15	26,12	27,04	25,58	25,37	27,45	26,58	27,46	27,12	26,9	26,72
BE3BF	**23,53**	**25,21**	**25,93**	**26,86**	**28,24**	**26,21**	**26,31**	**28,56**	**27,5**	**28,34**	**28,08**	**27,65**	**27,57**

4.3.1. TİB metriği tabanlı karşılaştırma

Çizelge 4.11 – Çizelge 4.19 arası sunumlarda ön plana çıkarılan (kalın olarak ifade edilen) sonuçlar, elde edilen en yüksek performansları simgelemektedir. Bu performanslara göre her bir teknik tarafından elde edilen TİB değerleri ve gürültü seviyeleri temel alınarak Çizelge 4.20 oluşturulmuştur. Çizelge 4.11 - Çizelge 4.19 arası sonuçlarda her bir metodun en iyi DSGO değerlerini elde ettiği görüntü sayısına (birincilikler - TİB) göre yapılan karşılaştırma sonuçları Çizelge 4.20' de görüldüğü gibidir.

Çizelge 4.20. Deneylerde elde edilen toplam TİB değerleri

Metot / Standart Sapma (σ)	2	5	10	15	20	25	50	75	100	Toplam TİB
Medyan Filtre	0	0	0	0	0	0	0	0	0	0
Wiener Filtresi	0	0	0	0	0	0	0	0	0	0
DDD	0	0	0	0	0	0	0	0	0	0
LPY-GAK	0	0	0	0	0	0	0	0	0	0
AKD-S	0	0	0	0	0	0	0	0	0	0
AS	0	0	0	0	0	0	0	0	0	0
ÇDGG	0	0	0	0	0	0	0	0	0	0
ŞA-AKD	0	0	0	0	0	0	0	0	0	0
OYLB-GKM	0	0	0	0	0	0	0	0	0	0
YGTBA	**4**	**1**	0	0	0	0	0	0	0	5
YLTBA	0	0	0	0	0	0	0	0	0	0
YHTBA	0	0	0	0	0	0	0	0	0	0
DDM-TDA	**3**	**1**	0	0	0	0	0	0	0	4
BE3BF	**6**	**12**	**13**	**13**	**13**	**13**	**13**	**13**	**13**	**109**

Çizelge 4.11' e göre OYLB-GKM, DDM-TDA, BE3BF tekniklerinin ve TBA tabanlı yaklaşımların benzer DSGO değerleri ürettikleri görülmüştür. YGTBA ve DDM-TDA algoritmalarının en düşük gürültü seviyesinde (σ = 2) benzer TİB değerlerine ulaştığı, BE3BF algoritmasının bu gürültü seviyesinde diğer tekniklerden daha iyi bir performans sergilediği tespit edilmiştir ($TİB_{BE3BF}$=6). YGTBA ve DDM-TDA tekniklerinin Çizelge 4.12' de benzer sonuçlara ulaştığı ($TİB_{YGTBA}$= $TİB_{DDM-TDA}$=1), ancak BE3BF tekniğinin TİB değerinde keskin bir artışın olduğu gözlemlenmiştir ($TİB_{BE3F}$=12). Çizelge 4.13 ve Çizelge 4.19 arası bütün sunumlarda BE3BF tekniğinin, 13 arteriyel faz BT görüntüsünde bütün gürültü seviyeleri için en iyi

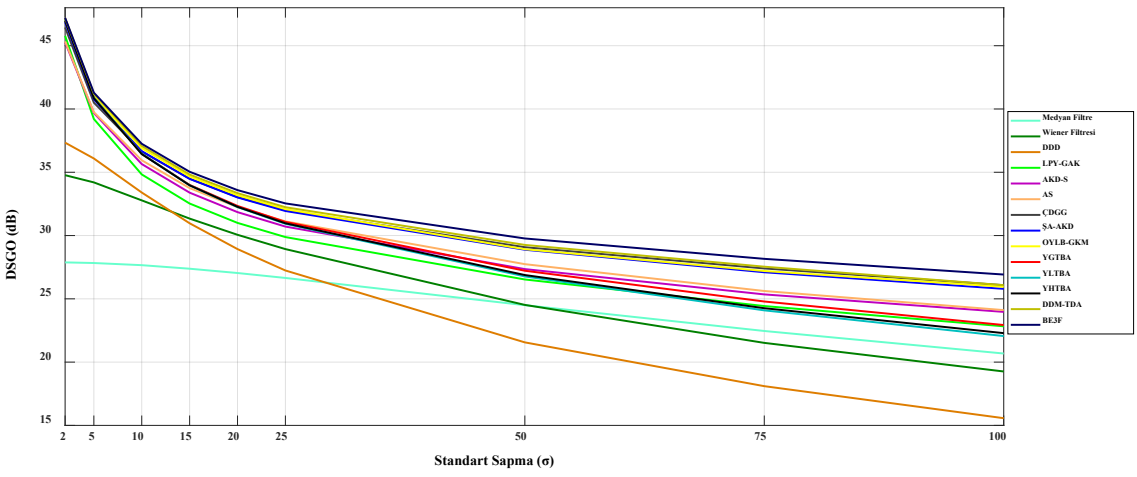
değerleri elde ettiği ve diğer algoritmalara göre daha iyi bir performans sergilediği görülmektedir.

Çizelge 4.20' ye göre BE3BF tekniği, 117 deneme arasında (13 görüntü x 9 farklı gürültü seviyesi) en iyi 109 değere ulaşan metottur (Toplam $T\dot{I}B_{BE3F}$ = 109). BE3BF tekniği, hem farklı gürültü seviyelerinde diğer tekniklere üstünlük sağlamakta, hem de genel karşılaştırmada en yüksek performansları sağlayan teknik olmaktadır. BE3BF algoritması, TİB metriği tabanlı karşılaştırmalar göz önüne alındığında arteryel faz BT görüntülerinde gürültü eliminasyonu üzerine en iyi seçenektir.

TİB tabanlı karşılaştırmada yalnızca en başarılı algoritma ön plana çıkmakta, diğer gürültü giderme yöntemlerinin genel performansları ve birbirlerine olan üstünlükleri açık bir şekilde gözlemlenememektedir. Ayrıca teknik performansları daha detaylı incelenememektedir. Karşılaştırmaların ikinci aşamasında, daha ayrıntılı bir karşılaştırma elde etmek için tekniklerin farklı görüntülerde sahip olduğu ortalama performanslar incelenmiştir. Böylece ortalama performans – gürültü seviyesi eğrileri üzerinden daha ayrıntılı bir analiz gerçekleştirilmiştir (Koyuncu ve Ceylan, 2017b).

4.3.2. Ortalama DSGO değerleri üzerinden karşılaştırma

Bu bölüm içerisinde 13 görüntüden elde edilen ortalama DSGO değerleri, 14 tekniğin ortalama performansı ve gürültü seviyesi (σ) arasında meydana gelen değişim referans alınarak sunulmuştur (Şekil 4.8). Böylece tekniklerin birbirlerine göre performans karşılaştırmaları gerçekleştirilmiş, sonuçlara daha ayrıntılı bir bakış açısı getirilmiştir.



Şekil 4.8. Ortalama DSGO değerleri üzerinden karşılaştırma

Şekil 4.8' de görüldüğü üzere kullanılan bütün teknikler, farklı gürültü seviyelerinde elde edilen ortalama performanslara göre üç gruba ayrılmaktadır. İlk grup bütün standart sapma seviyelerinde en düşük performansları elde eden yaklaşımlar olup, grup içindeki teknikler Medyan filtre, Wiener filtresi ve DDD şeklindedir. İkinci grup AS, AKD-S, LPY-GAK, YHTBA, YLTBA ve YGTBA tekniklerini içermektedir. Bu yöntemlerin elde ettikleri sonuçlar benzer olup, çıkışlar arası farklılıklar oldukça yumuşak geçişlere sahiptir. Üçüncü grup, Şekil 4.8 grafiğinde en üst kısımda yer alan ilk beş teknikten oluşmaktadır. Bu grup; ÇDGG, OYLB-GKM, DDM-TDA, ŞA-AKD ve BE3BF tekniklerini içerir.

Birinci grup içerisinde Medyan filtre, $\sigma = 50$ durumuna kadar diğer tekniklerden daha düşük bir performans sergilemektedir. Ayrıca teknik $50 < \sigma \leq 100$ aralığında en iyi performansa ulaşarak, yüksek gürültülü taramalarda DDD yönteminden ve Wiener filtresinden daha kararlı olduğunu göstermektedir. DDD algoritmasının performansı, düşük gürültü seviyelerinde diğer tekniklere üstünlük sağlamaktadır. Ancak teknik performansı, $5 < \sigma < 20$ olduğu durumda keskin bir şekilde azalmaktadır. DDD tekniği, yaklaşık $\sigma > 25$ durumundan sonra en düşük performansa sahip olmaktadır. Bu nedenle tekniğin düşük gürültülü taramalarda kullanılabilirliği ortaya çıkmaktadır. Wiener filtresinin, ortalama DSGO değerleri - standart sapma (σ) seviyeleri değişimine göre diğer tekniklerden daha kararlı bir performans sergilediği görülmektedir. Bu noktada sistem kararlılığı, tekniğe dair ilk ve son DSGO değerleri arasındaki değişime göre elde edilmektedir. İlk grup içerisindeki karşılaştırmalara göre Wiener filtre çıkışlarının, diğer teknik çıkışlarından daha az sapmaya sebebiyet verdiği görülmüştür.

İkinci grupta yer alan LPY-GAK tekniği, $\sigma = 75$ durumuna kadar en düşük performansa sahip olmaktadır. Bu gürültü seviyesinin ardından yöntem, YHTBA ve YLTBA tekniklerinden daha yüksek performanslara ulaşmaktadır. AKD-S ve AS teknikleri $\sigma = 10$ durumuna kadar benzer bir performans sergilemekte, bu performans YLTBA, YHTBA ve YGTBA tekniklerinden daha düşük olmaktadır. AS tekniği, $\sigma > 25$ olduğu durumda ikinci grup içinde en yüksek performans sağlayan metottur. TBA tabanlı teknikler arasında YGTBA yaklaşımı, $\sigma = 25$ durumundan sonra YLTBA ve YHTBA tekniklerine, geniş bir gürültü seviyesi aralığında (orta ve yüksek gürültü seviyelerinde) üstünlük sağlamaktadır. TBA tabanlı teknikler $\sigma < 25$ durumunda benzer performanslara ulaşmıştır. AS tekniği, ikinci grup içerisindeki en kararlı metottur. Çünkü teknik çıkışı, grup içerisinde yer alan diğer tekniklere nazaran daha düşük bir

sapmaya sahip olmakta, ayrıca teknik $\sigma > 25$ durumundan sonra sürekli olarak en iyi performansı elde etmektedir.

Üçüncü grup içerisindeki teknikler, birbirine yakın performanslara sahip olmaktadır. Bu grup içindeki teknikler Şekil 4.9' da ayrıntılı olarak incelenmiş, farklı gürültü seviyelerinde birbirlerine olan üstünlükleri ön plana çıkarılmıştır.

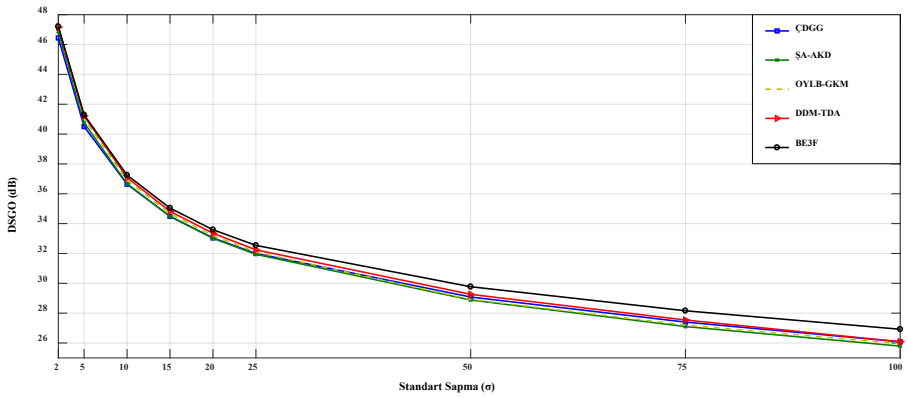
Şekil 4.9 (a)' da görüldüğü üzere tekniklere dair performanslar, genel olarak $\sigma = 5$ durumuna kadar yakın bir grafik sergilemektedir. BE3BF algoritması, $\sigma > 5$ durumu için daha yüksek DSGO değerleri elde ederek diğer tekniklere üstünlük sağlamıştır. Diğer tekniklerin kıyaslanması Şekil 4.9 (a)' da açık bir şekilde gözlemlenememiştir. Bu nedenle, tekniklerin birbirlerine olan üstünlükleri ayrıntılı perspektifler oluşturularak Şekil 4.9 (b), Şekil 4.9 (c) ve Şekil 4.9 (d) kapsamında incelenmiştir.

Şekil 4.9 (b)' de görüldüğü üzere BE3BF ve DDM-TDA teknikleri, $\sigma = 5$ durumuna kadar benzer performanslar göstermektedir. Bu performanslar, düşük gürültü bölgesinde diğer üç teknik performanslarına üstün olmaktadır. $\sigma > 5$ olduğu durumda yöntemlerin performans sırası, düşük gürültü bölgesi için (en yüksekten en düşük olana doğru) sırasıyla BE3BF, DDM-TDA, OYLB-GKM, ŞA-AKD ve ÇDGG şeklindedir.

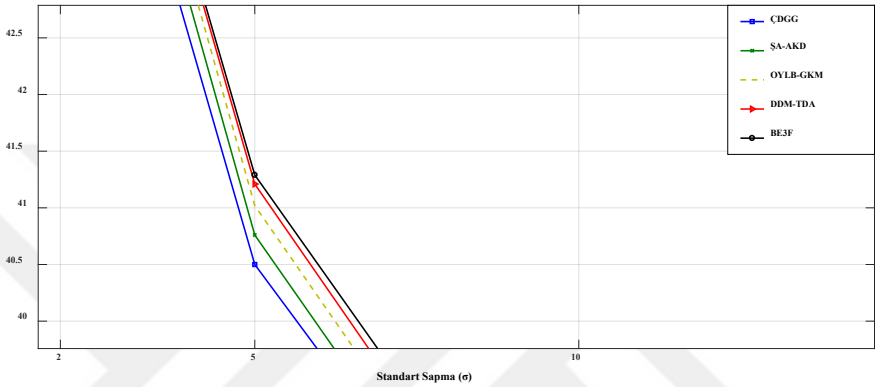
Şekil 4.9 (c)' de görüldüğü üzere ÇDGG algoritması, $\sigma > 15$ durumu için ŞA-AKD yaklaşımından daha yüksek performans sergilemektedir. Ayrıca ÇDGG tekniği, Şekil 4.9 (a)' da $25 < \sigma < 50$ durumunda OYLB-GKM yaklaşımından daha yüksek ortalama başarı sağlamaktadır. Diğer üç algoritmaya dair performans sıralaması, düşük gürültü bölgesinde olduğu gibi orta gürültü bölgesinde de aynı kalmaktadır: BE3BF, DDM-TDA ve OYLB-GKM.

Şekil 4.9 (d)' de görüldüğü üzere ÇDGG yöntemi, $\sigma = 100$ olduğu durumunda DDM-TDA yaklaşımı ile aynı performansı elde etmektedir. Yüksek gürültü bölgesinde performanslar (en yüksekten en düşük olana doğru) sırasıyla BE3BF, DDM-TDA, ÇDGG, OYLB-GKM ve ŞA-AKD şeklindedir.

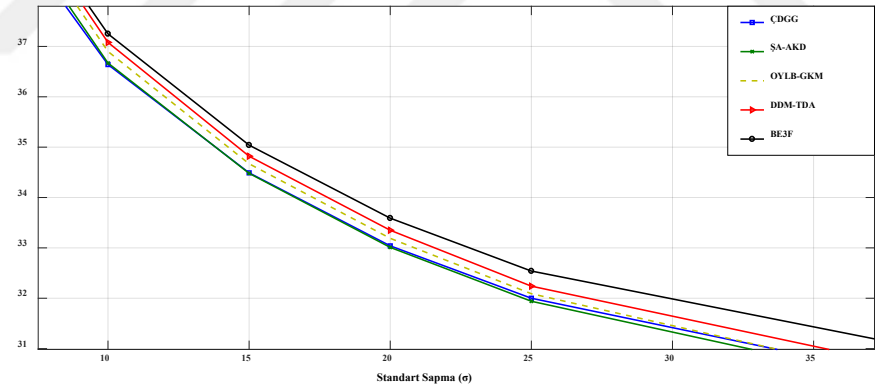
Elde edilen bulgular ışığında; ŞA-AKD yöntemi, orta ve yüksek gürültü seviyeleri için en düşük performansa sahip olmaktadır. OYLB-GKM tekniği, düşük gürültü bölgesinde ÇDGG ve ŞA-AKD algoritmalarından daha yüksek performans sağlamaktadır. ÇDGG yaklaşımı, orta gürültü seviyelerinde ŞA-AKD ve OYLB-GKM tekniklerine oranla daha yüksek performanslara ulaşmaktadır. DDM-TDA metodu, grafik üzerindeki dikey hareketlerde (ortalama DSGO değişiminde) kararlılık baz alındığında ikinci sırada olmaktadır. BE3BF yöntemi, bütün görüntülerde ve gürültü seviyelerinde en yüksek ortalama DSGO değerlerini ve en iyi kararlılığı sağlamıştır.



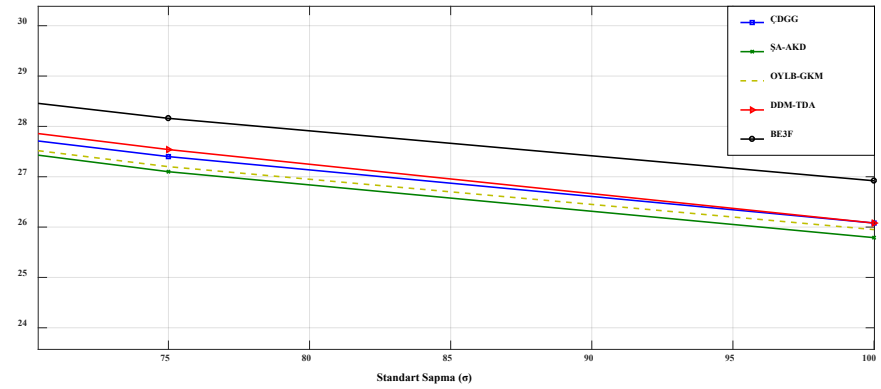
a-) Üçüncü grup içerisindeki tekniklerin genel karşılaştırması



b-) Düşük gürültü bölgesinde performans karşılaştırması



c-) Orta gürültü bölgesinde performans karşılaştırması



d-) Yüksek gürültü bölgesinde performans karşılaştırması

Şekil 4.9. Üçüncü grupta yer alan tekniklerin ayrıntılı performans karşılaştırmaları

Karşılaştırmaların üçüncü bölümünde simülasyon sonuçlarının, görüntüler üzerindeki geçerliliğini sınamak için en yüksek performans sergileyen beş tekniğe (üçüncü grup yaklaşımlarına) dair görsel çıkışlar incelenmiştir (Koyuncu ve Ceylan, 2017b).

4.3.3. Bütün bir abdomen üzerinden görsel çıkış tabanlı karşılaştırma

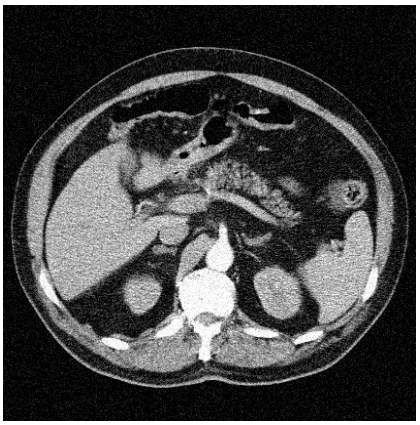
Daha önceki bölümlerde belirtildiği üzere BE3BF tekniği, farklı gürültü seviyelerinde elde edilen DSGO ve TİB değerleri bakımından diğer yaklaşımlara göre daha üstün bir performans sergilemiştir.

Bu bölüm içerisinde bir önceki karşılaştırmada yer alan üçüncü grup teknikleri, daha temiz abdominal BT görüntülerinin eldesi üzerine görsel olarak karşılaştırılmıştır. Bu amaçla Şekil 4.2 (c)' de yer alan üçüncü görüntü, gürültünün yanı sıra yağ dokusunu da içermesi sebebiyle seçilmiş ve orta düzeyde gürültü (σ = 20) ile bozulmuştur. Karşılaştırılan teknikler; BE3BF, DDM-TDA, OYLB-GKM, ŞA-AKD ve ÇDGG şeklindedir (Şekil 4.10).

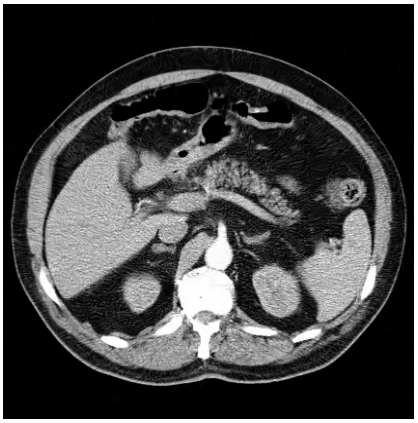
Şekil 4.10' da görüldüğü üzere;

- ŞA-AKD tekniği, abdomen içi ve dışı dâhil olmak üzere görüntü boyunca en gürültülü çıkışı üretmektedir.
- OYLB-GKM algoritması BT taramasını bulanıklaştırmakta, tüm abdomen bölümünün kaba bir görünümünü elde etmektedir.
- DDM-TDA yaklaşımı tümör bölgesini ve abdomeni üniform bir gürültü dağılımı ile elde ederken, ÇDGG tekniği bu görevi parçalı bir şekilde yerine getirmektedir.
- Bütün görüntülerin yakından incelenmesi halinde BE3BF algoritmasının, gürültüyü diğerler yaklaşımlarda daha iyi baskıladığı görülmüştür. Ayrıca BE3BF algoritmasının, abdomen içi kontrast dağılımı noktasında da iyileştirme sağladığı gözlemlenmiştir.

Görsel karşılaştırmaya göre tekniklerin üstünlük sıralaması, abdomen içi gürültü giderme üzerine (en etkinden en pasife doğru) sırasıyla BE3BF, DDM-TDA, ÇDGG, OYLB-GKM ve ŞA-AKD şeklindedir (Koyuncu ve Ceylan, 2017b).



a-) Gürültülü görüntü



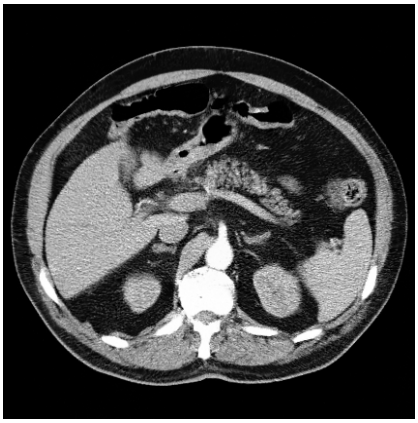
b-) ÇDGG çıkışı



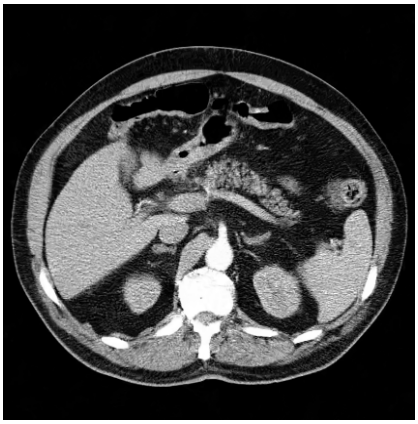
c-) ŞA-AKD çıkışı



d-) OYLB-GKM çıkışı



e-) DDM-TDA çıkışı



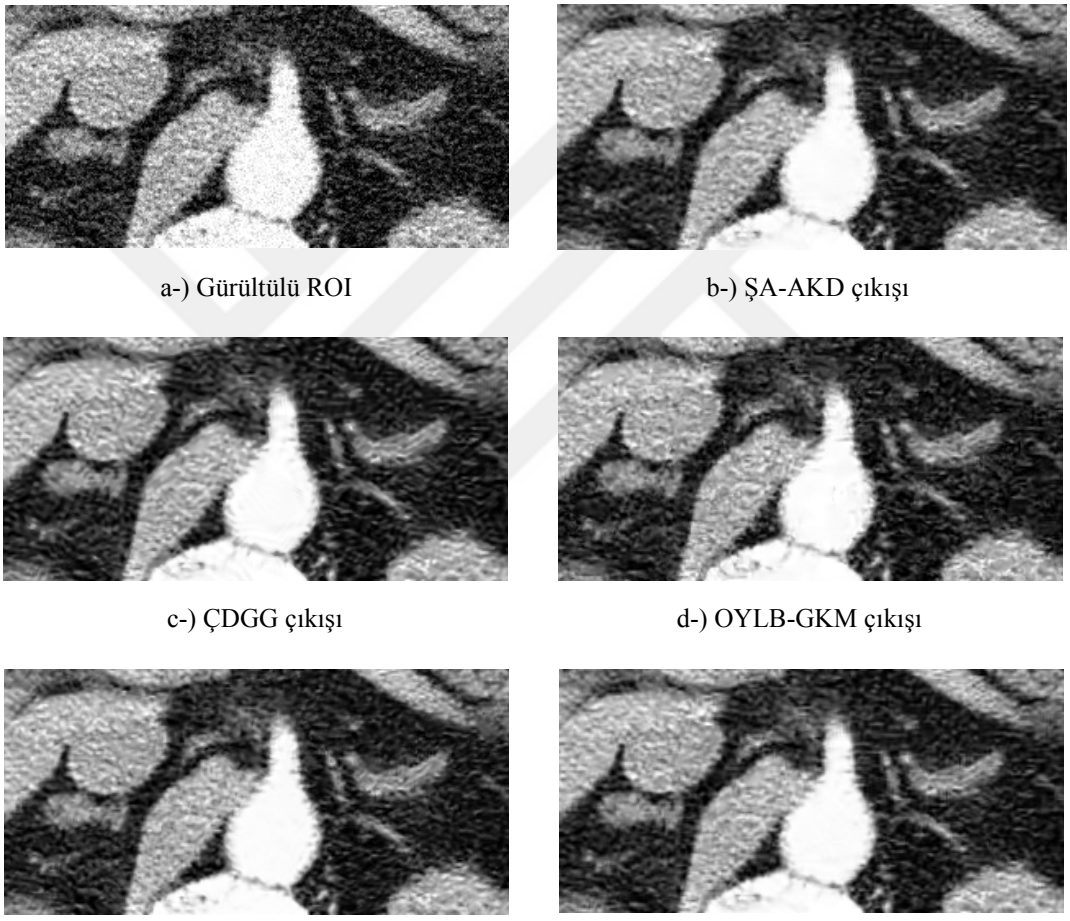
f-) BE3BF çıkışı

Şekil 4.10. Üçüncü grupta yer alan tekniklerin görsel performans karşılaştırmaları

4.3.4. ROI üzerinden DSGO metriği ve görsel çıkış tabanlı karşılaştırmalar

Önceki karşılaştırmalarda görüldüğü üzere BE3BF yöntemi, abdominal BT görüntülerinde gürültü giderme üzerine en iyi performansa sahip tekniktir. Ancak

gürültü giderme performansı sürrenal lezyonlar çevresinde değişiklik gösterebilmektedir. Diğer bir deyişle, lezyon çevresindeki bölüm (ROI) gürültülü olmasına rağmen, BE3BF ile bütün bir abdomen üzerine en yüksek performanslar sağlanmış olabilir. Bu nedenle en yüksek performanslı beş adet tekniğe dair ROI tabanlı analizlerin gerçekleştirilmesi gereklidir. Bu bölümde, lezyon bölgesi üzerinden DSGO değerleri ve görsel perspektifler kullanarak ayrıntılı bir analiz sunulmuştur. Şekil 4.11 ve Çizelge 4.21 sırasıyla etkin beş algoritma tarafından elde edilen ROI çıkışlarını ve DSGO değerlerini göstermektedir.



a-) Gürültülü ROI b-) ŞA-AKD çıkışı

c-) ÇDGG çıkışı d-) OYLB-GKM çıkışı

e-) DDM-TDA çıkışı f-) BE3BF çıkışı

Şekil 4.11. ROI üzerinden görsel performans karşılaştırmaları

Çizelge 4.21. ROI üzerinden DSGO tabanlı karşılaştırma

Yöntem	DSGO Değerleri (dB)
Şekle Adaptif Ayrık Kosinüs Dönüşümü (ŞA-AKD)	26,93
Çift Domende Gürültü Giderme (ÇDGG)	26,93
Olası Yama Logaritmik Benzerliği-Gaussian Karışım Modeli (OYLB-GKM)	27,06
Tekil Değer Ayrışımı içeren Düşük Dereceli Model (DDM-TDA)	27,13
Blok Eşleme ve 3B Filtreleme (BE3BF)	27,19

Şekil 4.11 ve Çizelge 4.21’ de görüldüğü üzere;

- ŞA-AKD ve ÇDGG teknikleri yaklaşık olarak aynı görsel çıkışı elde etmektedir. Bu durum, Çizelge 4.22’ de sunulan DSGO değerleri ile örtüşmektedir. Çünkü her bir teknik aynı performans ile gürültü eliminasyonu sağlamaktadır.
- OYLB-GKM yöntemi, ŞA-AKD ve ÇDGG algoritmalarına göre daha yüksek DSGO değeri elde ederek görüntü kontrastını iyileştirmektedir. Bu noktada lezyon çevresi gürültünün daha iyi baskılandığı gözlemlenmiştir. Ancak görsel OYLB-GKM çıkışında, lezyon sınırlarında düzenliliğin (üniformitenin) sağlanamadığı, bu durumun segmentasyon sonuçlarını olumsuz yönde etkileyeceği açıkça görülmektedir.
- DDM-TDA algoritması, 27.13 dB’ lik bir DSGO değerine ulaşmaktadır. Ayrıca BE3BF çıkışlarında lezyon çevresi gürültünün daha iyi baskılandığı, bu durumun elde edilen DSGO değeri (27.19 dB) ile örtüştüğü görülmektedir.

ROI incelemesi ile elde edilen sonuçlar, bütün bir abdomen üzerine DSGO ve görsel karşılaştırma sonuçları ile kısmen uyuşmaktadır. Bu noktada temel fark, ÇDGG ve ŞA-AKD algoritmalarının ROI tabanlı gürültü eliminasyonunda benzer sonuçlara ulaşmalarıdır. BE3BF yöntemi, dört farklı karşılaştırmada gürültü eliminasyonu üzerine en etkin tekniktir.

Sonuçlara göre; beş etkin tekniğin elde ettiği sonuçlar, yakın bir değişim sergilemektedir. Bu nedenle, etkin gürültü giderme yöntemlerine dair çalışma zamanları değerlendirilmiştir. Bu amaçla ilk beş tekniğin CPU zamanları karşılaştırılmıştır (Koyuncu ve Ceylan, 2017b).

4.3.5. CPU işlem süresi üzerinden karşılaştırma

Gürültü giderme çalışmasında tespit edilen etkin beş algoritmadan her biri, farklı karşılaştırmalarda başarılı sonuçlar elde etmektedir. Teknikler tarafından elde edilen görsel sonuçlar farklı olsa da DSGO tabanlı sonuçlar genelde birbirine yakın

seyretmektedir. Bu amaçla etkin beş algoritma, daha detaylı bir analiz için CPU işlem süresi bakımından karşılaştırılarak, elde edilen sonuçlar Çizelge 4.22' de sunulmuştur.

Çizelge 4.22' de görüldüğü üzere; BE3BF algoritması, 15.8 saniyelik bir çalışma süresi ile en optimum seçenektir. İkinci en iyi zaman ise ŞA-AKD yaklaşımına aittir. Diğer algoritmaların yürütülmesi, BE3BF ve ŞA-AKD tekniklerinden çok daha uzun bir süreye karşılık gelir. Kısaca BE3BF algoritması, CPU süresi tabanlı karşılaştırma üzerine etkin beş algoritma içerisinden en verimli seçecektir.

Çizelge 4.22. Etkin tekniklerin CPU süresi tabanlı karşılaştırmaları

Yöntem	CPU Süresi
Şekle Adaptif Ayrık Kosinüs Dönüşümü (ŞA-AKD)	15,9s
Çift Domende Gürültü Giderme (ÇDGG)	473,1s
Olası Yama Logaritmik Benzerliği-Gaussian Karışım Modeli (OYLB-GKM)	773,2s
Tekil Değer Ayrışımı içeren Düşük Dereceli Model (DDM-TDA)	384,8s
Blok Eşleme ve 3B Filtreleme (BE3F)	15,8s

ŞA-AKD ve BE3BF yöntemleri yakın işlemci sürelerine sahip olduğundan, bir sonraki karşılaştırmada etkin beş algoritmanın hesaplama maliyetleri değerlendirilmiştir (Koyuncu ve Ceylan, 2017b).

4.3.6. Hesaplama maliyeti üzerinden karşılaştırma

Bu bölümde etkin beş algoritmaya dair karmaşıklık incelenmiş, her bir tekniğin hesaplama maliyetleri (computational complexity), algoritmaların ana kısımlarında işletilen kod satırları referans alınarak Çizelge 4.23' te sunulmuştur.

Çizelge 4.23' de görüldüğü üzere BE3BF yöntemi, yalnızca 31 kod satırının yürütülmesini gerektirmekte iken, ikinci en iyi teknik olan ŞA-AKD' nde 1265 koda ihtiyaç duyulmaktadır. ÇDGG algoritması, ŞA-AKD içinde yürütülen kod satırlarının yaklaşık üç katı kadar kod yürütülmesini gerektirmektedir. Diğer algoritmaların hesaplama maliyeti ise ÇDGG tekniğinden çok daha fazla olmaktadır.

Elde edilen bulgular ışığında BE3BF algoritması, düşük hesaplama süresine ek olarak daha düşük hesaplama maliyetine sahip tek seçenektir (Koyuncu ve Ceylan, 2017b).

Çizelge 4.23. Etkin tekniklerin hesaplama maliyeti tabanlı karşılaştırmaları

Yöntem	Yürütülen Kod Satırı Sayısı
Şekle Adaptif Ayrık Kosinüs Dönüşümü (ŞA-AKD)	1265
Çift Domende Gürültü Giderme (ÇDGG)	3388
Olası Yama Logaritmik Benzerliği-Gaussian Karışım Modeli (OYLB-GKM)	7260742
Tekil Değer Ayrışımı içeren Düşük Dereceli Model (DDM-TDA)	703734
Blok Eşleme ve 3B Filtreleme (BE3F)	31

4.3.7. Gürültü eliminasyonu için sonuçların özetlenmesi

Elde edilen sonuçlara göre;

- BE3BF algoritması, abdominal BT görüntülerinde ve sürrenal lezyonların yer aldığı ROI içinde Gaussian gürültü eliminasyonu sağlayan en etkin tekniktir.
- BE3BF algoritması, TİB tabanlı karşılaştırmalara göre diğer tüm tekniklerden daha yüksek bir performans sergilemiştir ($TİB_{BE3F}$ = 109). BE3BF metodu incelenen 117 farklı koşulda elde edilen TİB değerine göre yaklaşık %93.16 (109/117x100) doğruluğa sahiptir.
- BE3BF tekniği, ortalama DSGO değerleri incelendiğinde birinci ve ikinci gruplar içinde yer alan 9 tekniğe açık bir üstünlük sağlamaktadır. BE3BF tekniği, üçüncü grupta yer alan diğer yaklaşımlara göre daha yüksek DSGO değerlerine ulaşmaktadır. Bu noktada BE3BF çıkışının farklı gürültü seviyelerinde en kararlı değişimi sağladığı görülmüştür.
- BE3BF tekniği, bütün bir abdomen üzerine ve lezyonların yer aldığı ROI tabanlı görsel karşılaştırmalarda gürültü giderme üzerine diğer tekniklerden daha başarılıdır.
- BE3BF tekniği, hesaplama zamanı ve hesaplama maliyeti temelli karşılaştırmalarda en az işlem süresine (15.8s) ve minimum hesaplama maliyetine (31 kod satırı) sahiptir.

Özetle, arteriyel faz BT görüntülerinden Gaussian gürültü eliminasyonu için optimum seçenek BE3BF tekniğidir. Söz konusu teknik, abdomen bölgesinde ve sürrenal lezyonların çevresinde etkin olarak gürültü gidermekte, ayrıca görüntünün kontrast kalitesini iyileştirmektedir.

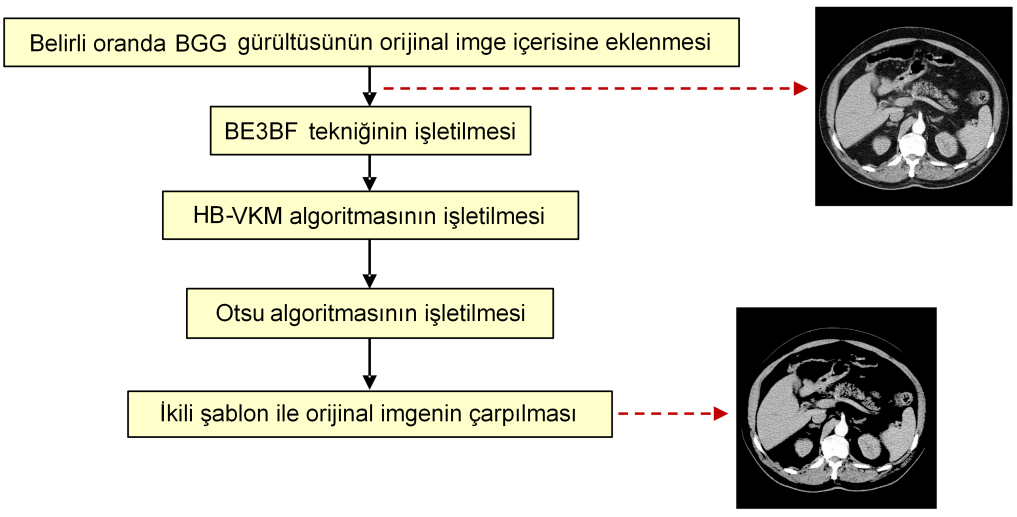
4.4. Görüntü İyileştirme Çalışması

Gaussian gürültüsü BT görüntülerinde bozucu bir etki oluşturmakta, yağ dokusu ise lezyon ve organların arka plan ile benzer görünümde olmasına sebebiyet vermektedir. Bu durumlar, lezyon segmentasyonu öncesi elimine edilmesi gereken iki temel dezavantajdır.

Literatür çalışmaları ayrıntılı bir şekilde incelendiğinde Zhan ve ark. (2015) tarafından önerilen yöntemin, farklı gri seviyelerde segmentasyon işlemi gerçekleştirebildiği görülmüştür. Bu metot, Hızlı Bağlantılı Vuru Kortikal Modeli (HB-VKM / Fast Linking Spike Cortical Model → FL-SCM) olarak bilinmekte, tekniğin arka plandan farklı gri seviyeleri ön plana çıkarabildiği görülmektedir. Bu noktada tekniğin yağ dokusu eliminasyonunda kullanılabileceği öngörülmüştür. Literatür çalışmalarında görüntü içinde İkili Hale Getirme (Binarization) işleminin, Otsu (1979) tarafından geliştirilen Otsu Eşikleme (Otsu Thresholding) yöntemi ile sıklıkla gerçekleştirildiği görülmüştür.

4.4.1. Görüntü iyileştirme sistemi

Tasarlanan görüntü iyileştirme sistemi (BFO), içerdiği tekniklerden (***B****M3D,* ***F****L-SCM,* ***O****tsu*) esinlenerek isimlendirilmiştir. Sistem kapsamında Gaussian gürültüsünün, abdomen iç (viseral) ve dış (sübkütanüs) yağ dokularının ve gereksiz parçaların (lezyon ve organ harici bölümlerin) eliminasyonları sağlanmaktadır. BFO akış diyagramı Şekil 4.12' de sunulmaktadır.



Şekil 4.12. BFO sistemi akış diyagramı

Şekil 4.12’ de görüldüğü üzere;

1. Orta seviyede Gaussian gürültüsü (σ=20), hali hazırda içerisinde gürültü ve yağ dokusu mevcut olan görüntü içine eklenmektedir. Buradaki amaç, parçalı olarak etkin olabilecek gürültünün bütün bir görüntüde etkin olmasını sağlamaktır. Böylece gürültü giderme algoritmasının görüntü içi parçalı gürültüleri es geçmesi engellenebilir.
2. BE3BF tekniği görüntüye uygulanarak, Gaussian gürültüsü elimine edilmektedir.
3. HB-VKM algoritması ile deri altı ve karın içi yağ dokularının eliminasyonu sağlanmaktadır. HB-VKM tekniğinin seçimi, Zhan ve ark. (2015)’ nın çalışmalarında belirtildiği üzere görüntü içi objelerin eldesinde, morfolojik işlemler bakımından hassas ve kararlı bir çıkış sağlamasındandır.
4. HB-VKM’ den sonra Otsu algoritması kullanılarak, lezyon ve organ harici gereksiz parçaların eliminasyonu sağlanır.
5. Son aşamada Otsu çıkışında elde edilen ikili (binary) görüntü ile orijinal görüntü çarpılmakta, böylece sistem çıkışında gürültüsü, yağ dokusu ve gereksiz dokuları elimine edilmiş temiz bir görüntü elde edilmektedir.

BFO sisteminde görüntü içerisine eklenen gürültü seviyesi, 852x852’ lik imgeler için σ=20 düzeyinde seçilmiştir. Bu durumun nedenleri aşağıdaki belirtildiği gibidir:

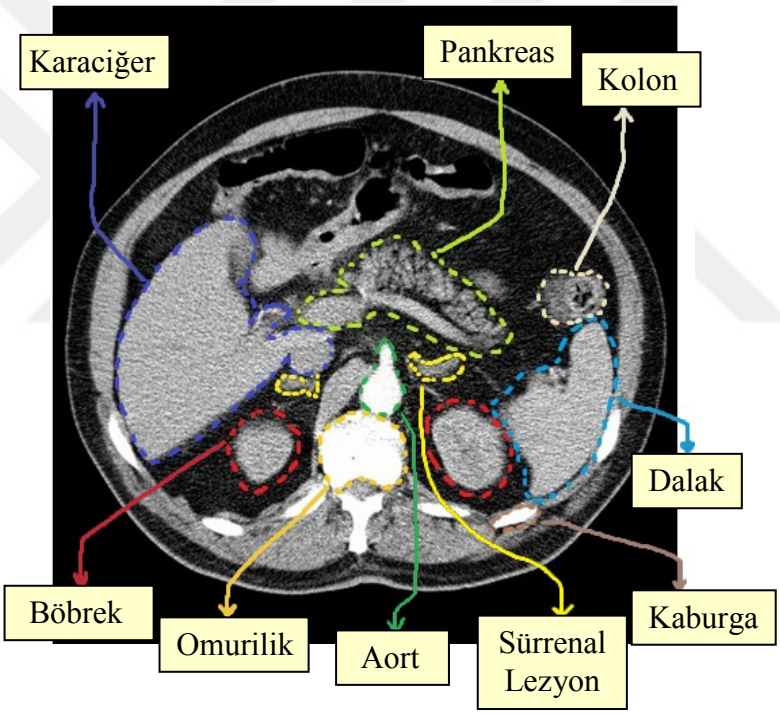
1. Sistem, düşük gürültü seviyesinde gürültü eklendiğinde, görüntü içi gürültüyü tam olarak temizleyememektedir.
2. Yüksek gürültü seviyelerinde gürültü eklendiğinde, abdomen içi objelerin (organ ve lezyonların) kenar bilgileri olumsuz yönde etkilenerek, bozucu bir etki meydana gelmektedir.

Yukarıda belirtilen nedenlerden ötürü σ=20 düzeyinde gürültü eklenmesi, BFO’ ya dair optimum çalışma koşullarının eldesinde en iyi gürültü ekleme seviyesi olarak belirlenmiştir.

4.4.2. Deneysel sonuçlar ve istatistiksel analiz

Çalışma içerisinde kullanılan veri seti, gürültü ve derin yağ dokusu içeren 8 adet arteryel faz BT görüntüsünden oluşmaktadır. Organlar ve lezyonlar, BT görüntülerinde farklı boyut, şekil ve konumlarda bulunabilmektedir. Diğer bir deyişle, bir görüntü içinde yer alan organ veya lezyon bir başka taramada (farklı kesitlerde) farklı bir görünüme sahip olabilmektedir. Bu nedenle farklı durum ve şartlara uyum sağlayabilecek bir sistem geliştirilmiştir.

Sürrenal lezyonların bulunduğu abdominal BT taramalarında genel olarak; karaciğer, dalak, pankreas, kolon, kaburga, omurilik, mide, aort ve böbrekler bulunur. Bu durum Şekil 4.13' te görsel olarak tanımlanmıştır.

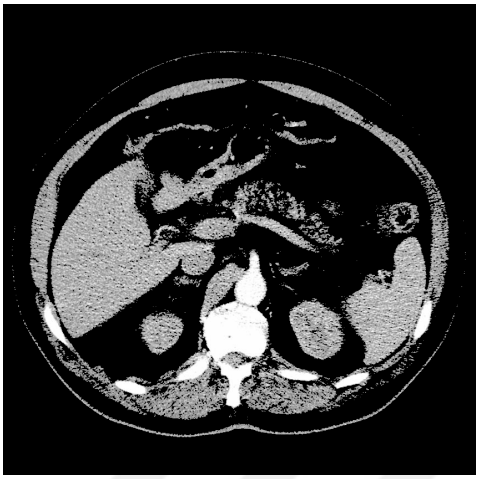


Şekil 4.13. BT taramasında yer alan organlar ve sürrenal lezyonlar

Çalışma kapsamında önerilen sistem, HB-VKM ve BE3BF & HB-VKM yaklaşımları ile karşılaştırılmıştır. Bu amaçla DSGO tabanlı karşılaştırmanın yanı sıra, YBİ kıstası temel alınarak görüntü iyileştirme metotlarının performansları incelenmiştir.

Literatürde DSGO ve YBİ metriklerinin kullanıldığı uygulamalar, hedef ve orijinal görüntüler arasında fazla fark olmadığından, orijinal görüntüyü referans olarak almaktadır. Çalışma içindeki hedef görüntü, orijinal görüntüye İkili Hale Getirme (Binarization) işlemi uygulanarak elde edilmiştir. Bu sayede, referans şeklinde

kullanılması gereken görüntüye çok benzeyen *yaklaşık eşdeğer görüntü* (hedef görüntü) elde edilmiştir. Söz konusu hedef görüntü Şekil 4.14' de sunulmuştur.



Şekil 4.14. Yaklaşık eşdeğer görüntü (referans görüntü)

İlk aşamada DSGO tabanlı karşılaştırma gerçekleştirilmiş, elde edilen sonuçlar Çizelge 4.24' de sunulmuştur.

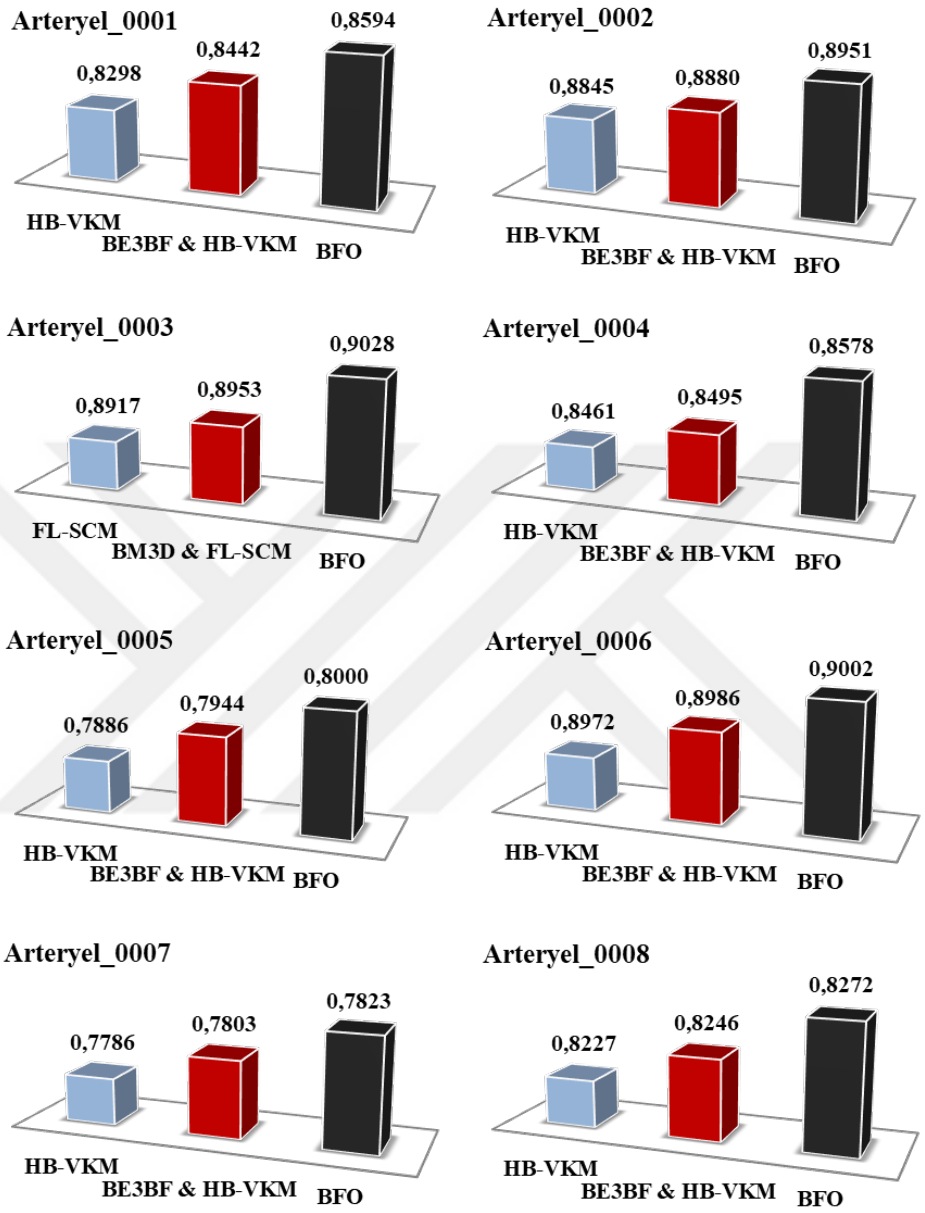
Çizelge 4.24. Görüntü iyileştirme üzerine üç farklı teknik tarafından elde edilen DSGO değerleri

İmge	HB-VKM	BM3EF & HB-VKM	BFO
Arteryel_0001	19,5508	19,6485	**19,8692**
Arteryel _0002	20,6293	20,6756	**20,7970**
Arteryel _0003	21,1996	21,2615	**21,4749**
Arteryel _0004	19,9323	19,9571	**20,1002**
Arteryel _0005	18,0507	18,1069	**18,1659**
Arteryel _0006	21,2923	21,3333	**21,3913**
Arteryel _0007	16,9215	16,9299	**16,9485**
Arteryel _0008	18,1346	18,1713	**18,2223**
Ortalama	19,4639	19,5105	**19,6212**

Çizelge 4.24' de görüldüğü üzere en iyi çıkış değerleri, bütün görüntülerde BFO sistemi tarafından elde edilmiştir. Ayrıca BFO sistemi, HB-VKM tekniğine ortalama 0.157 dB üstünlük sağlarken, BE3BF & HB-VKM yapısına 0.111 dB üstünlük sağlamıştır. YBİ metriği ile gerçekleştirilen karşılaştırma Şekil 4.15' de sunulmaktadır.

Şekil 4.15' de görüldüğü üzere BFO sistemi, bütün imgelerde diğer tekniklerden daha yüksek YBİ değerleri sağlamaktadır. Çizelge 4.24 ve Şekil 4.15' de görüldüğü

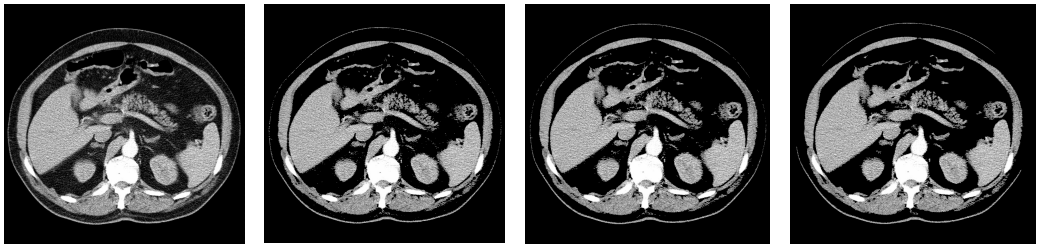
üzere BFO sistemi, her koşulda diğer tekniklere DSGO ve YBİ tabanlı karşılaştırmalar üzerine üstünlük sağlamaktadır.



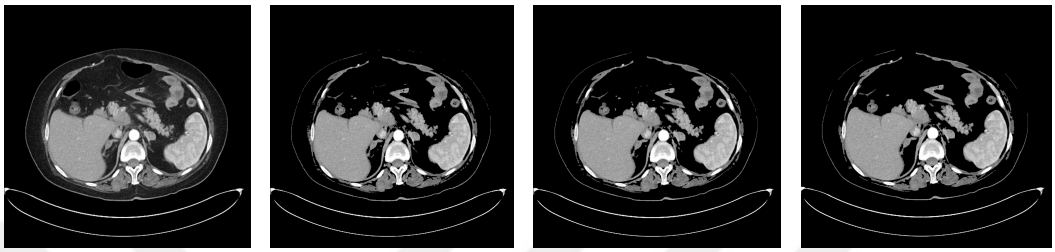
Şekil 4.15. Görüntü iyileştirme üzerine üç farklı teknik tarafından elde edilen YBİ değerleri

4.4.3. Görsel sonuçlar ve analiz

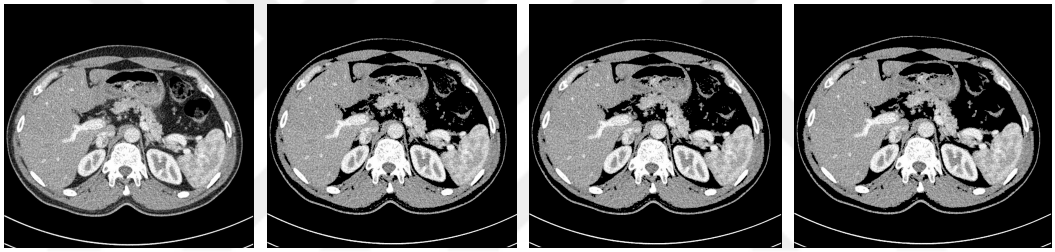
Bu bölümde, önceki aşamalarda elde edilen sonuçlar görsel olarak detaylandırılmıştır. Üç farklı tekniğe dair görüntü tabanlı görsel çıkışlar Şekil 4.16' da sunulmuştur.



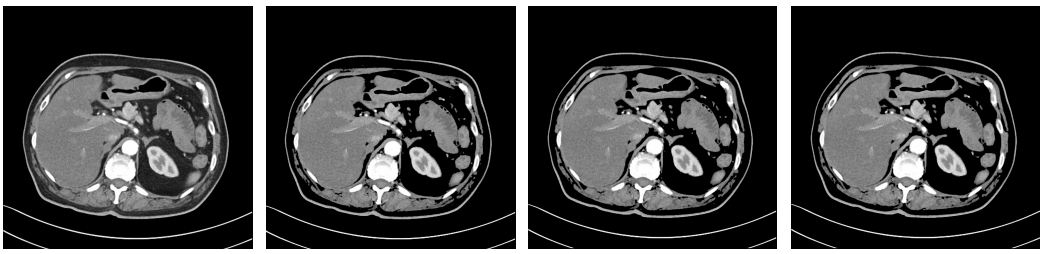
a-) Arteryel 0001



b-) Arteryel 0002



c-) Arteryel _0004



d-) Arteryel _0007

Şekil 4.16. Arteryel faz BT imgelerinde görüntü iyileştirme algoritmalarının görsel karşılaştırması (Soldan Sağa: Orijinal imge, HB-VKM çıkışı, BE3BF & HB-VKM çıkışı, BFO çıkışı)

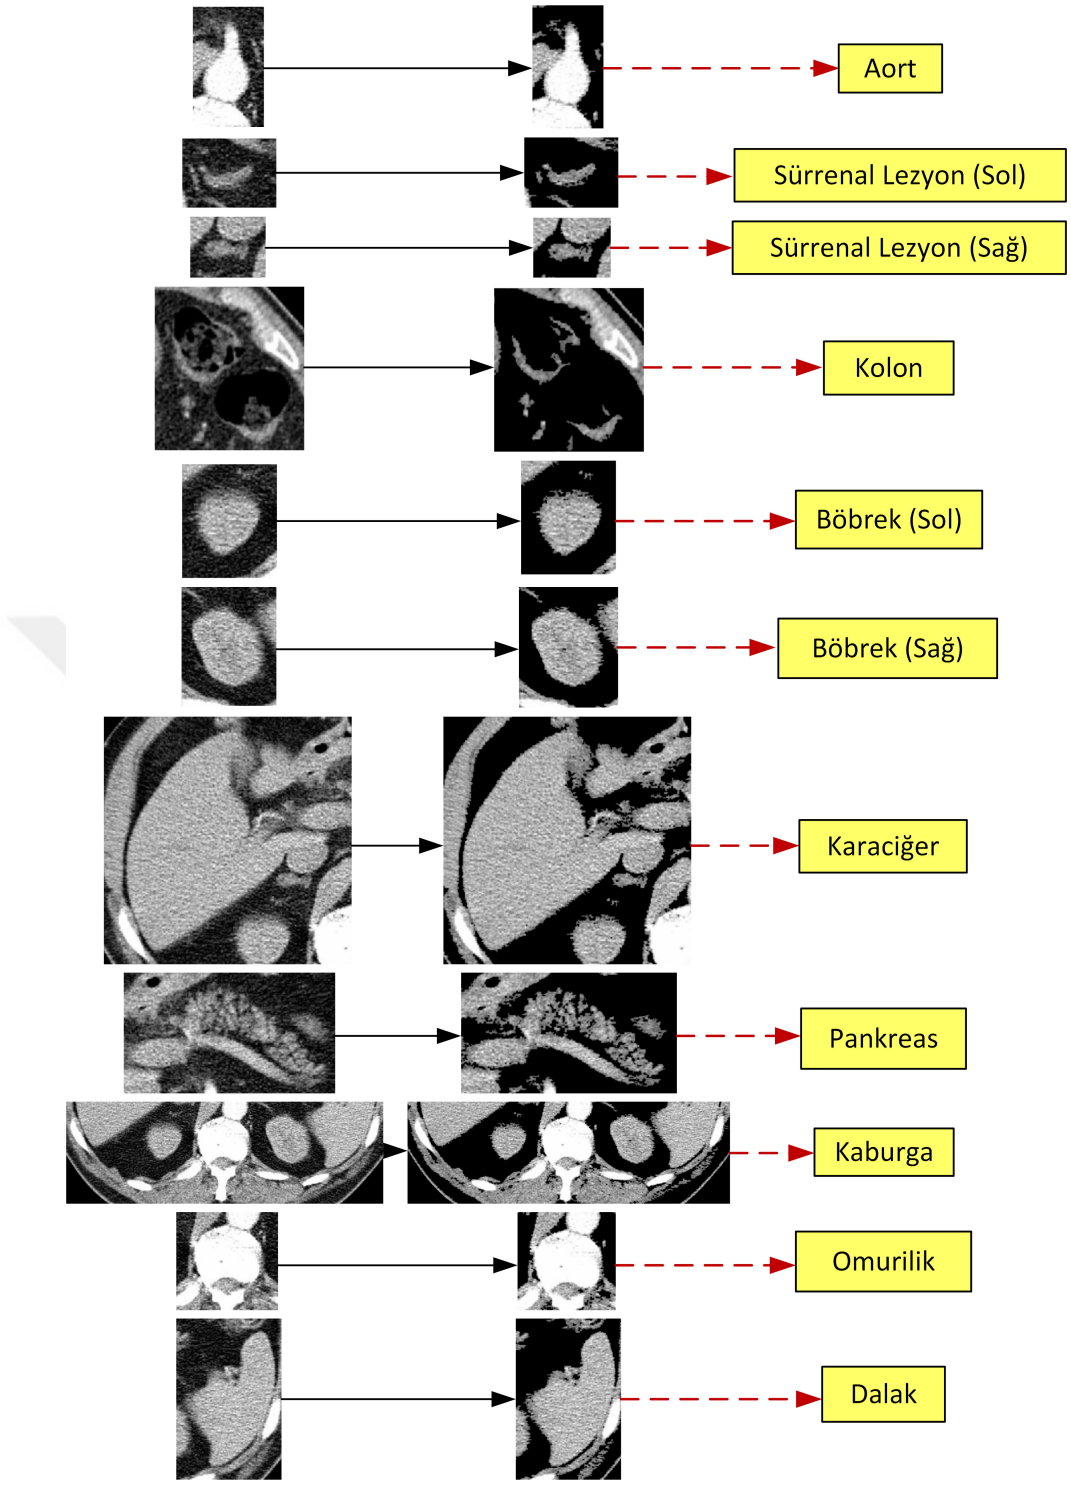
Şekil 4.16' da görüldüğü üzere BE3BF & HB-VKM yaklaşımı, DSGO ve YBİ tabanlı karşılaştırmalarda olduğu gibi HB-VKM' den daha iyi sonuçlar elde etmektedir. BFO algoritması ise diğer tekniklerden daha üstün bir şekilde görüntü iyileştirme sağlamıştır. BFO sistemi ile gürültü giderme, yağ dokusu temizleme ve gereksiz parçaların eliminasyonu işlemlerinin tam olarak yerine getirildiği görülmektedir.

Elde edilen sonuçlara göre BFO sistemi, bütün (görsel, DSGO ve YBİ tabanlı) karşılaştırmalarda en iyi performansları sağlayan tekniktir. Böylece BFO ile abdomen içi organ, doku ve lezyon segmentasyonlarından önce kullanılabilecek-iyileştirilmiş bir abdomen görüntüsü elde edilmektedir. Şekil 4.16' da BFO ile elde edilen sonuçlar (her satırda yer alan dördüncü imgeler); gürültünün, iç-dış yağ dokularının ve gereksiz parçaların eksiksiz bir şekilde elimine edildiğini destekler niteliktedir. BFO yaklaşımı, organları ve dokuları diğer metotlardan daha iyi netleştirmiştir. Ancak Şekil 4.16 (a) ve (c)' de görüldüğü üzere, gri bağlantıların içindeki keskin heterojen değişimler, kolona dair parçaların kaybolmasına sebebiyet vermektedir. Diğer bir deyişle BFO sistemi, belirli bir dereceye kadar heterojeniteye izin vererek lezyon ve organları ön plana çıkarmaktadır. Bu nedenle BFO sistemi; böbrek, sürrenal lezyon, karaciğer, dalak, aort, kaburga, omurilik, pankreas gibi yumuşak heterojen veya homojen geçişlere sahip nesneleri daha açık bir şekilde elde etmektedir.

BFO sisteminin abdomen içi doku ve organları koruma özelliği; görsel, DSGO ve YBİ tabanlı karşılaştırmalarda elde edilen sonuçlar ile desteklenmektedir. Buna ek olarak sağlanan görsel sonuçlar, lezyonlara ve organlara daha yakın bir perspektiften bakmak amacıyla Şekil 4.17' de daha ayrıntılı sunulmaktadır.

Şekil 4.17' de görüldüğü üzere BFO yaklaşımı, gri değerlerin keskin bir şekilde değiştiği kolon (kalın bağırsak) harici bütün dokularda etkilidir. BFO sistemi kenar bilgilerini, diğer organlar ve sürrenal lezyonlar üzerinde eksiksiz bir şekilde koruyabilmektedir.

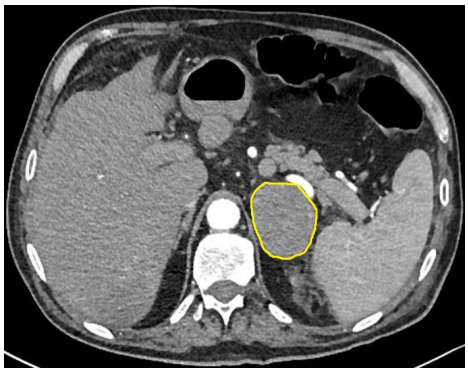
Özetle BFO' nun üç aşamadan oluşan bir sistem vasıtasıyla BT görüntülerinden Gaussian gürültüsünün ve yağ dokusunun eliminasyonu için etkin bir araç olduğu görülmüştür. Görsel perspektifler ile DSGO ve YBİ tabanlı karşılaştırmalar neticesinde elde edilen sonuçlar, BFO sisteminin abdominal BT görüntülerinde HB-VKM ve BE3BF & HB-VKM tekniklerine üstün olduğunu göstermektedir. Ayrıca önerilen sistem, organları ve sürrenal lezyonları görüntü analizindeki bir sonraki aşamaya (segmentasyona) hazır hale getirmektedir.



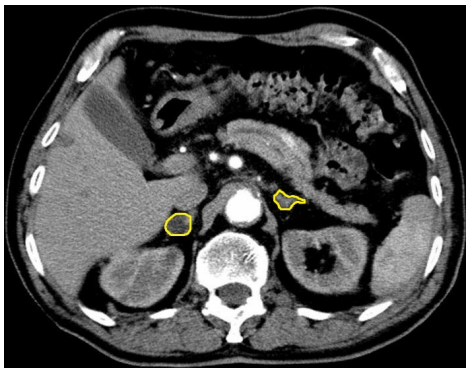
Şekil 4.17. Görüntü iyileştirme için farklı dokularda BFO çıkışlarının görsel sunumu

4.5. Sürrenal Lezyon Segmentasyonu Çalışması

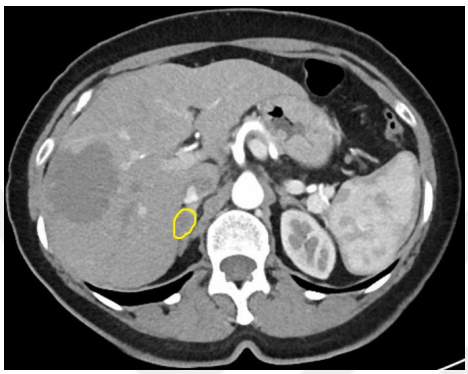
Literatürde abdominal BT görüntülerinden sürrenal lezyon segmentasyonunu gerçekleştiren bir çalışma henüz mevcut değildir. Sürrenal lezyon segmentasyonunu zorlaştıran durumları içeren görüntüler Şekil 4.18' de sunulmuştur.



a-) Unilateral lezyon



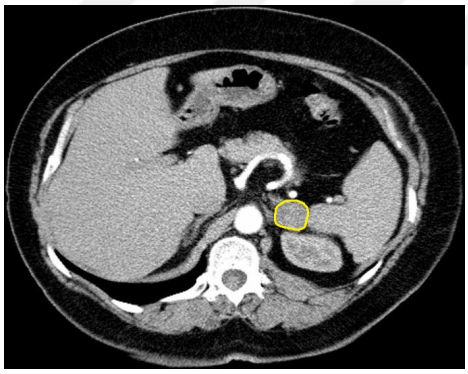
b-) Bilateral lezyon



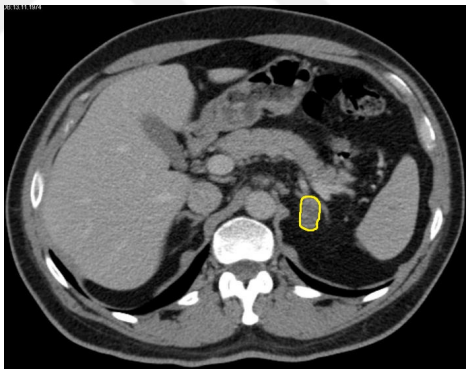
c-) Kontrast tutulumu zayıf lezyon



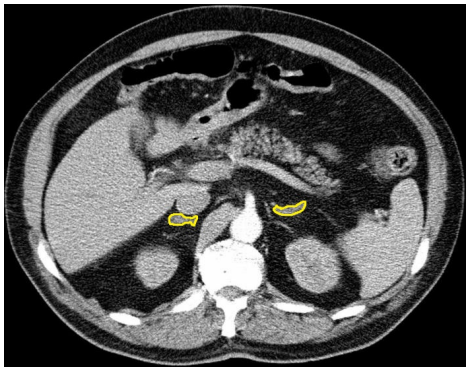
d-) Karaciğere yapışık lezyon



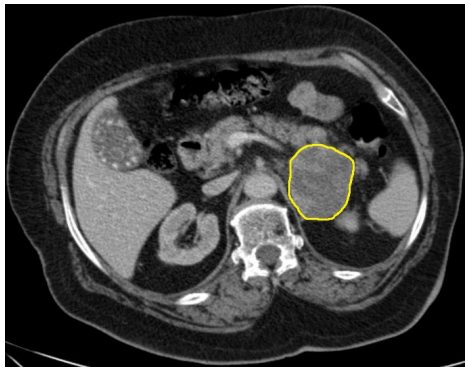
e-) Dalağa yapışık lezyon



f-) Pankreasa yapışık lezyon



e-) Açık lezyonlar



f-) Heterojen yapıda lezyon

Şekil 4.18. Sürrenal lezyon segmentasyonunu zorlaştıran durumları içeren abdomen görüntüleri

Şekil 4.18’ de de görüleceği gibi sürrenal lezyon segmentasyonunu zorlaştıran durumlar şu şekilde özetlenebilir:

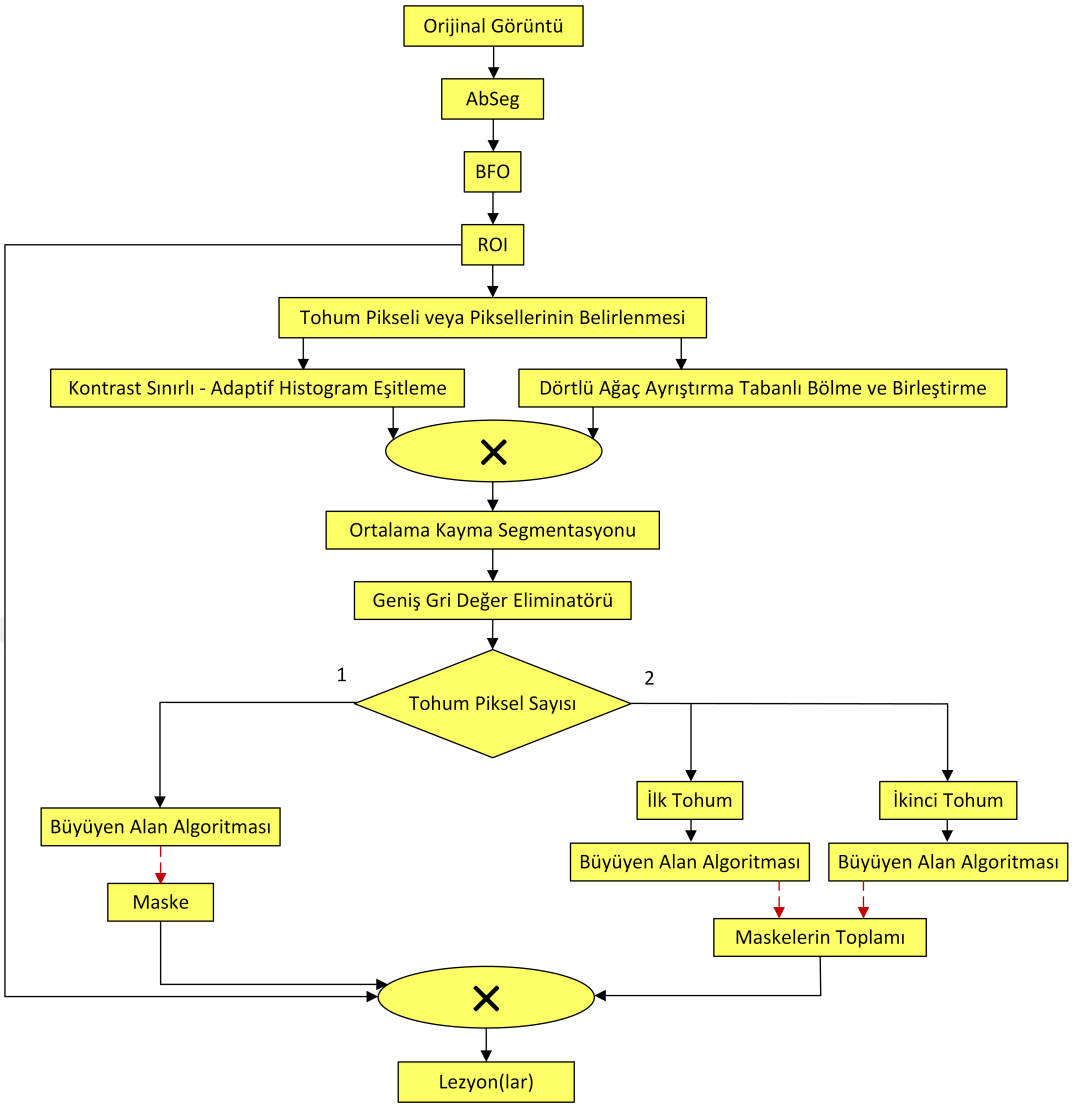
- Lezyonların bazen unilateral, bazen bilateral olması
- Kontrast tutulumu zayıf lezyonların (çevre dokular ile yakın gri seviyeye sahip lezyonların) mevcut olması
- Karaciğer, dalak, pankreas gibi organlara yapışık lezyonların yanı sıra büyük tekil ve açık lezyonların da mevcut olması
- Homojen değişim sergileyen lezyonların yanı sıra heterojen lezyonların da mevcut olması

Sürrenal lezyonlar sabit bir şekil veya yoğunluğa sahip olmadığı gibi, tekil veya çoğul olarak bulunabilmektedir. Ayrıca lezyon lokasyonunun belirlenmesini kolaylaştıracak referans bir organ veya doku mevcut değildir. Bu sebepten otomatik bir lezyon segmentasyon sisteminin tasarımı mümkün olmamaktadır. Dolayısıyla yarı-otomatik, yani kullanıcı tarafından tohum bırakılmasını temel alan bir sistem geliştirilmesi hedeflenmiştir.

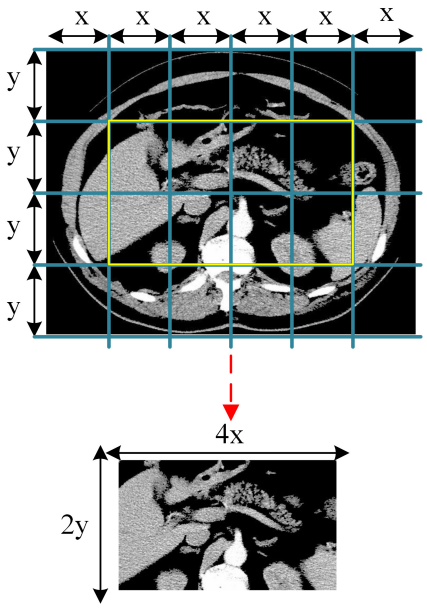
4.5.1. Sürrenal lezyon segmentasyon sistemi

Sürrenal lezyon segmentasyonu için önerilen sistem 5 farklı metottan meydana gelmektedir. Bu algoritmalar; KS-AHE, DAA-BB, OKS, GDE ve BA şeklindedir. Sistem, Sürrenal Lezyon Segmentasyonu (**A**drenal **Tu**mour **S**egmentation) üzerine işlem yapması sebebiyle *ATUS* olarak isimlendirilmiştir. ATUS sisteminin akış diyagramı Şekil 4.19’ da görüldüğü gibidir.

ATUS sistemi içinde ilk iki aşama Abseg ve BFO sistemlerinin uygulanmasıdır. Bu sayede abdomen segmentasyonu ve görüntü iyileştirme işlemleri gerçekleştirilir. Segmente edilen ve iyileştirilen abdomen görüntüsü yatayda 6 bölüme (700/6=x), düşeyde ise 4 bölüme (550/4=y) ayrılır. Görüntünün düşey bölümden orta ikili bölümü, yataydan orta dörtlü kısmı kullanılarak ROI (2y-4x) alanı seçilmektedir. Böylece, ilk üç aşama sonucunda ROI alanı belirlenmiş olur. Bu durum Şekil 4.20’ de görüldüğü gibidir.



Şekil 4.19. ATUS sistemi akış diyagramı



Şekil 4.20. BFO sonrası ROI alanı eldesi

Dördüncü aşamada, tohum pikseli veya piksellerinin konumları ROI alanından kullanıcı tarafından belirlenir. Bu nedenle ATUS, yarı-otomatik bir segmentasyon sistemidir.

Beşinci aşamada kontrast bakımından zayıf görüntülerde iyileştirme yapmak için KS-AHE algoritması kullanılmaktadır. KS-AHE yaklaşımı ile birbirinden çok az da olsa farklı gri değerlere sahip olan bölgeler, daha açık bir şekilde birbirinden farklı hale gelmektedir.

Altıncı aşamada bölme ve birleştirme aşamasıdır. Burada DAA-BB algoritması kullanılarak, abdomen içinde yer alan çok parlak (omurilik, kaburga, vb.) veya çok koyu bölümler (görüntü arkaplanı) elimine edilir. DAA-BB ile belirli bir standart sapma üzerindeki alanlar için bölme ve birleştirme yapılır. DAA-BB algoritması içinde standart sapma kriteri olarak kullanılan eşik değeri, görüntülerin hepsine uyacak şekilde belirlenir. Böylece görüntüde geniş alan kaplayan (karaciğer, pankreas, vb.) ve lezyonlardan daha farklı gri değerlere sahip olan alanlarda küçük siyah bölgelerin oluşturulması sağlanır. Amaç, yedinci aşamada uygulanacak olan OKS algoritmasının, lezyon dışı geniş alanlara (örneğin karaciğere veya omuriliğe) yoğunlaşması yerine doğrudan sürrenal lezyon(lar) üzerine odaklanmasını sağlamaktır. Aksi takdirde sistemin sonuç verme süresi uzamaktadır. Bu dezavantaj DAA-BB algoritmasının kullanılmasıyla elimine edilir.

Yedinci aşamada pikseller, OKS algoritması kullanılarak komşuluklarındaki piksellerin durumlarına göre birbiriyle bağlanır. Diğer bir deyişle, birbirine benzeyen ve komşuluğa sahip olan alanlar yakın gri seviyelere dönüştürülerek, lezyon segmentasyonu öncesinde uygun bir görüntü oluşturulmaya çalışılır.

Sekizinci aşamada görüntüde en sık tekrar eden 6 gri seviye, GDE algoritması kullanılarak elimine edilir. Amaç; karaciğer, dalak, vb. organ ve geniş dokuların içinde boşluklar meydana getirmektir. Çünkü sürrenal lezyonlar; karaciğer, dalak ve pankreasa yapışık bir görünümde olabilmektedir. GDE tekniği ile söz konusu dokular içinde lezyon bölümüne yakın yerlerde boşluklar meydana getirilmekte, harici dokuların lezyon sınırları içine katılması minimize edilmektedir. Böylece bir sonraki aşama olan BA algoritmasının, farklı organlardaki dokuları lezyon sınırı içine katması önlenir.

Dokuzuncu aşamada BA algoritması, OKS çıkışında yakın gri seviyelere çekilen lezyon yoğunluklarını tolerans değerine göre elde etmektedir. Son aşamada ise bir önceki adımda elde edilen maske ile ROI çarpılmakta, bu sayede lezyon segmentasyonu gerçekleştirilmektedir.

DAA-BB tekniği, tahmin fonksiyonu içinde standart sapma ve ortalama fonksiyonlarını kullanmaktadır. Lezyon gri seviyelerinin değişmemesi amacıyla bütün görüntüler üzerine denemeler yapılmıştır. Sonuç olarak, standart sapma değeri "2" den büyük, gri seviye aralığı ise [2, 240] olarak seçildiği durumda bütün görüntülerde iyi sonuçlar sağlanmaktadır. Aksi takdirde sürrenal lezyon(lar) üzerinde bozulmalar meydana gelmektedir.

ATUS içerisinde, kullanıcı tarafından belirlenmesi gereken dört adet parametre bulunmaktadır. Bu parametreler şu şekilde sıralanabilir:

- Uzamsal kernel band genişliği (h_s) → OKS algoritması
- Aralık kerneli band genişliği (h_r) → OKS algoritması
- Yakınsama kriteri eşiği (M) → OKS algoritması
- Tolerans aralığı (t) → BA algoritması

4.5.2. ATUS parametre ayarlamaları, deneysel sonuçlar ve istatistiksel analiz

Çalışmada unilateral - bilateral, yapışık - yapışık olmayan ve homojen - heterojen sürrenal lezyonların segmentasyonu için 32 adet abdominal BT görüntüsü kullanılmıştır. Önerilen tüm segmentasyon sistemi, yalnızca yapışık - yapışık olmayan lezyonlarda değil, aynı zamanda farklı boyut, şekil ve yoğunluk özelliklerine sahip lezyonların segmentasyonlarında verimli sonuçlar üretmektedir. Tümör segmentasyon sistemi, bütün bir abdomen üzerinde segmentasyon yapan literatürdeki en ayrıntılı çalışmadır. Bu amaçla üç tip sürrenal lezyon (adenom, feokromositoma, metastaz) içeren görüntüler üzerinde ATUS sonuçları elde edilmiştir.

Gerçekleştirilen çalışma içerisinde (h_s, h_r) ikilisinden her birinin 16, 24, 32 değerlerine dair farklı kombinasyonlarda iyi sonuç verdikleri görülmüştür. Yakınsama kriteri eşiği (M) geniş bir aralıkta (0.1, 0.2, …, 0.5) incelenmiş, optimum çalışma koşulu araştırılmıştır. Söz konusu aralık dışında anlamlı çıkışlara ulaşılamadığı görülmüştür. Tolerans aralığı değeri 10, 20, 30, 40 alınarak, optimum sonuçlar elde edilmeye çalışılmıştır. Bu tolerans değerleri dışında lezyon dışı büyük alanların, ROI içerisine dâhil olarak segmentasyon sonuçlarını kötü etkilediği görülmüştür.

Segmentasyon performansının değerlendirilmesi için literatürde sıklıkla tercih edilen metrikler (Dice, Jaccard, duyarlılık, özgüllük, doğruluk ve YBİ) kullanılarak

istatistiksel bir analiz sunulmuştur. Optimum parametreler kullanılarak elde edilen ATUS sonuçları Çizelge 4.25' de görülmektedir.

Çizelge 4.25. Önerilen yöntemin segmentasyon çıkışları

Görüntü	Duyarlılık	Özgüllük	Doğruluk	Dice	Jaccard	YBİ
G1	89,32	99,93	99,84	90,41	82,50	99,70
G2	93,58	99,77	99,69	88,56	79,47	99,10
G3	82,48	99,09	98,39	81,25	68,42	96,40
G4	96,81	99,26	99,19	87,50	77,78	97,53
G5	86,97	99,72	99,53	84,69	73,45	98,59
G6	100,00	99,12	99,13	64,69	47,81	97,45
G7	84,83	99,11	98,74	77,54	63,32	96
G8	82,54	99,65	99,35	81,34	68,55	98,66
G9	68,75	99,29	98,92	60,46	43,33	97,20
G10	94,20	99,94	99,55	96,60	93,42	98,56
G11	46,65	99,44	99,04	42,75	27,19	97,68
G12	68,98	99,30	98,84	64,37	47,46	97,80
G13	35,62	99,99	99,62	51,84	34,99	99,17
G14	59,33	99,98	99,58	73,71	58,37	98,95
G15	83,06	99,79	99,69	76,71	62,21	98,96
G16	80,43	99,75	99,61	74,75	59,68	98,80
G17	69,51	99,91	99,71	75,74	60,95	99,18
G18	85,15	99,84	99,75	80,80	67,79	99,26
G19	76,22	99,90	99,78	77,70	63,53	99,52
G20	93,57	99,80	99,75	85,35	74,44	99,26
G21	86,85	99,87	99,81	79,80	66,39	99,45
G22	73,61	99,55	99,36	62,72	45,69	98,04
G23	82,63	99,15	98,86	71,72	55,91	96,88
G24	72,35	99,87	99,55	79,00	65,29	98,56
G25	92,71	99,85	99,82	79,46	65,93	99,33
G26	86,50	99,09	99,01	52,75	35,82	97,72
G27	90,20	99,97	99,89	92,61	86,24	99,62
G28	96,32	99,39	99,05	95,71	91,78	97,65
G29	86,66	99,80	99,64	85,55	74,76	98,77
G30	86,67	98,99	98,18	86,21	75,76	96
G31	81,72	99,92	99,77	85,55	74,75	99,30
G32	87,61	99,83	99,77	77,59	63,39	99,28

Çizelge 4.25' e göre;

- Duyarlılık, özgüllük, doğruluk ve YBİ ölçümleri değerlendirildiğinde önerilen ATUS sisteminin yüksek bir performansa sahip olduğu

görülebilir. Kontrast tutulumu zayıf lezyonların yer aldığı 9 görüntüde (G6, G9, G11, G12, G13, G14, G22, G23, G26 uzantılı görüntülerde) Dice ve Jaccard metrikleri yaklaşık olarak %70' in altında başarı sağlayabilmiştir.

- ATUS, bütün bir veri setinde ortalama %81.31 duyarlılık, %99.62 özgüllük, %99.39 doğruluk, %77.05 Dice, %64.26 Jaccard ve %98.39 YBİ oranı elde etmiştir.
- ATUS, yukarıda belirtilen kontrast tutulumu zayıf görüntülerin dışındaki veri seti (23 görüntü) için ortalama %86.08 duyarlılık, %99.69 özgüllük,%99.48 doğruluk, %83.50 Dice, %72.17 Jaccard ve %98.59 YBİ oranlarına ulaşmaktadır.
- Deneysel sonuçlara göre; önerilen yaklaşım her koşulda segmentasyon işlemini gerçekleştirebilmektedir. Ancak kontrast tutulumu zayıf lezyonların segmentasyonunda çok yüksek başarı sağlayamadığı görülmektedir. Bunun nedeni, kontrast tutulumu zayıf lezyonların, çevre dokulara yakın bir görünümde olmalarıdır.

Tasarlanan sistem performansı, bir sonraki aşamada kontrast tutulumunun yeterli ve tutulumun yetersiz olduğu görüntülerde ayrı ayrı incelenmiştir (Çizelge 4.26).

Çizelge 4.26' da görüldüğü üzere bütün metrik sonuçları incelendiğinde, ATUS segmentasyon performansı kontrast tutulumu yeterli lezyonlarda daha iyidir. Ancak tekniğin kontrast tutulumu zayıf lezyonlar üzerine de kullanılabileceği görülmektedir.

Çizelge 4.26. Kontrast tutulumu yeterli / yetersiz lezyonlar için ATUS sonuçları

Kontrast Tutulumu	Duyarlılık	Özgüllük	Doğruluk	Dice	Jaccard	YBİ
Yetersiz (16 görüntü)	76,18	99,59	99,34	71,03	57,08	98,27
Yeterli (16 görüntü)	86,44	99,66	99,43	83,06	71,44	98,51

Kontrast tutulumu yeterli / yetersiz lezyonlar üzerine segmentasyon sonuçları arasındaki farklar; %10.26 (duyarlılık), %0.07 (özgüllük), %0.09 (doğruluk), %12.03 (Dice), %14.36 (Jaccard) ve %0.24 (YBİ) şeklindedir. Duyarlılık, Dice ve Jaccard değerleri arasındaki farkların büyük olması, önerilen ATUS sisteminin kontrast tutulumu yeterli lezyonların segmentasyonunda daha etkin olduğunun bir göstergesidir.

Çizelge 4.27' de ATUS sisteminin performansı, unilateral / bilateral lezyon segmentasyonu için değerlendirilmiştir. Buna göre önerilen sistem, hem unilateral hem de bilateral lezyonları benzer ve yüksek başarı oranları ile segmente etmektedir.

Çizelge 4.27. Unilateral / Bilateral lezyonlar için ATUS sonuçları

Lateral Durum	Duyarlılık	Özgüllük	Doğruluk	Dice	Jaccard	YBİ
Unilateral	80,51	99,65	99,41	77,42	65,14	98,52
Bilateral	83,06	99,55	99,33	76,22	62,34	98,10

Çizelge 4.28 kapsamında ATUS sisteminin, iyi huylu / kötü huylu lezyon segmentasyonları üzerine elde ettiği sonuçlar karşılaştırılmıştır.

ATUS sistemi genel olarak kötü huylu (daha çok heterojen görünüm ihtiva eden) lezyonlarda segmentasyon işlemini daha iyi gerçekleştirmektedir. Bu noktada duyarlılık, özgüllük, Dice ve Jaccard metrikleri baz alındığında daha yüksek başarıların sağlandığı görülmektedir. Her iki durumda da doğruluk ve YBİ sonuçları oldukça yakındır. ATUS ile iyi huylu lezyon segmentasyonunun kolaylıkla gerçekleştirilebildiği, fakat kötü huylu lezyonlarda elde edilen başarının daha yüksek olduğu görülmektedir. Diğer bir deyişle homojen görünümlü lezyon segmentasyonu sağlanmakla beraber, heterojen lezyonların da yüksek başarı ile segmente edilebildiği tespit edilmiştir.

Çizelge 4.28. İyi huylu / Kötü huylu lezyonlar için ATUS sonuçları

Patolojik Özellik	Duyarlılık	Özgüllük	Doğruluk	Dice	Jaccard	YBİ
İyi Huylu (Benign)	78,40	99,62	99,39	73,25	59,10	98,40
Kötü Huylu (Malign)	90,02	99,64	99,38	88,42	79,74	98,34

Çizelge 4.29' da ATUS sisteminin, diğer organlara yapışık / yapışık olmayan lezyon türleri üzerine segmentasyon sonuçları sunulmuştur. Elde edilen sonuçlara göre önerilen sistem, diğer organlara yapışık olmayan lezyonları dikkate değer bir başarı ile segmente edebilmektedir. Ancak yapışık lezyonlar, genel olarak kontrast tutulumu zayıf lezyonlar olduğundan segmentasyon sonuçları da çok yüksek değildir.

Çizelge 4.29. Yapışık / Yapışık olmayan lezyonlar için ATUS sonuçları

Lezyona Dair Görsel Durum	Duyarlılık	Özgüllük	Doğruluk	Dice	Jaccard	YBİ
Diğer Organlara Yapışık	80,54	99,58	99,34	75,75	62,52	98,26
Yapışık Olmayan	86,65	99,91	99,75	86,13	76,46	99,31

Çizelge 4.30 (a)' da en iyi sonuçların elde edilmesini sağlayan optimum parametre değerleri sunulmaktadır. Çizelge içinde kırmızı renkte belirtilen sonuçlar, sistemin en iyi başarı oranlarına ulaştığı optimum parametre değerlerini, mavi renkteki sonuçlar ise önerilen sistemin en iyi sonuçlara (± %5 sapma ile) yakın değerler elde ettiği ikinci en iyi değerleri göstermektedir.

Çizelge 4.30 (b)' de parametre seçiminin ayrıntılı bir analizi incelenmiş, Çizelge 4.30 (a)' da belirtilen optimum parametre değerlerinin tekrar sayıları özet olarak sunulmuştur.

Çizelge 4.30 (a) Optimum çıkışların elde edildiği parametre değerleri

İmge	[h_s, h_r]	M	t
G1	[16,32], [24,32]	0.1, 0.2, 0.3, 0.4	30, 40, 20
G2	[16,32]	0.1, 0.2, 0.3, 0.4, 0.5	20, 30
G3	[24,32], [32,32]	0.2, 0.3	30
G4	[16,24], [16,16]	0.4, 0.1, 0.2, 0.3	30, 20
G5	[24,24]	0.3, 0.5	30
G6	[32,32]	0.4, 0.3	30
G7	[32,16], [16,32]	0.3	30
G8	[24,24], [24,32]	0.3, 0.1, 0.2, 0.4	30, 40
G9	[24,32]	0.4, 0.1, 0.2, 0.3, 0.5	10, 20, 30
G10	[16,24], [24,32], [32,16]	0.1, 0.2, 0.3, 0.4, 0.5	30
G11	[16,16]	0.4, 0.5	20, 10
G12	[16,32], [16,24], [24,16], [24,24], [32,32]	0.3, 0.4, 0.5	40, 30
G13	[32,16]	0.3, 0.2	10
G14	[16,32], [16,24]	0.3	10
G15	[24,32], [16,32], [24,24], [32,24]	0.5, 0.1, 0.2, 0.3, 0.4	10
G16	[16,24], [16,32], [32,16]	0.5, 0.1, 0.2, 0.3, 0.4	10
G17	[16,16], [32,16]	0.1, 0.2, 0.4	20
G18	[32,32], [32,24]	0.1, 0.2, 0.3, 0.4, 0.5	10
G19	[24,16]	0.2, 0.3, 0.4	30
G20	[16,32], [16,16], [16,24]	0.5, 0.1, 0.2, 0.3, 0.4	30, 20
G21	[16,16], [16,24], [16,32]	0.2, 0.3	30, 20
G22	[16,16], [16,32], [24,24], [24,32], [32,24], [32,32]	0.3, 0.4	20, 10, 30
G23	[16,32]	0.1, 0.2, 0.3, 0.4, 0.5	20
G24	[16,16]	0.2	30
G25	[16,16], [16,24], [16,32]	0.5, 0.1, 0.2, 0.3, 0.4	30, 20
G26	[32,32], [24,32], [32,24]	0.1, 0.2, 0.3, 0.4	30, 20, 40
G27	[24,16]	0.3, 0.1, 0.2, 0.4, 0.5	30, 40
G28	[24,32], [24,24], [32,16], [32,24]	0.4, 0.5, 0.1, 0.2, 0.3	30, 40
G29	[16,32], [16,24]	0.1, 0.2, 0.3, 0.4	20, 30
G30	[16,32], [16,24]	0.5, 0.1, 0.2, 0.3, 0.4	40, 30
G31	[24,16], [16,16]	0.5, 0.3	20, 30
G32	[16,24], [16,16]	0.1, 0.2, 0.3, 0.4	20, 10, 30

Çizelge 4.30 (b) Parametre değerlerinin tekrarlanma durumları

Parametre Ayarlaması	Parametrenin Optimum Değer Ürettiği Görüntü Sayısı
$[h_s, h_r] = [16, 16]$	10
$[h_s, h_r] = [16, 24]$	11
$[h_s, h_r] = [16, 32]$	14
$[h_s, h_r] = [24, 16]$	4
$[h_s, h_r] = [24, 24]$	6
$[h_s, h_r] = [24, 32]$	9
$[h_s, h_r] = [32, 16]$	6
$[h_s, h_r] = [32, 24]$	5
$[h_s, h_r] = [32, 32]$	6
M = 0.1	19
M = 0.2	24
M = 0.3	29
M = 0.4	24
M = 0.5	16
t = 10	8
t = 20	15
t = 30	24
t = 40	7

Çizelge 4.30 (a) ve (b)' ye göre;

- En sık tekrarlanan kernel ikilisi (h_s, h_r), 14 görüntüde [16, 32] ikilisidir.
- En sık tekrarlanan eşik değeri (M), 29 görüntüde "0.3" değeri olmuştur.
- En sık tekrarlanan tolerans (t), 30 görüntüde "30" değeridir.

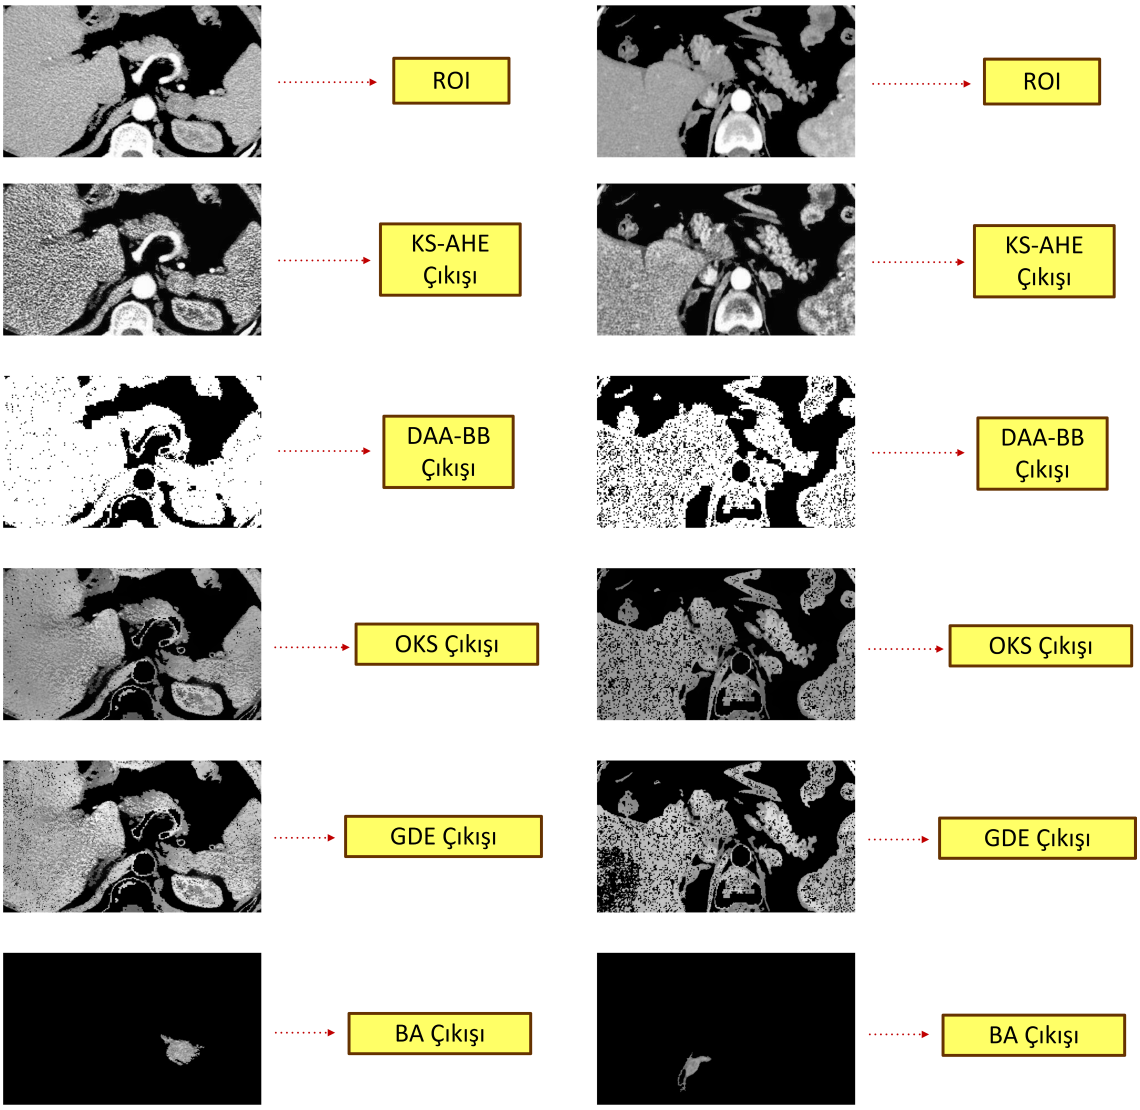
Uzman doktorlar tarafından sürrenal lezyonlar erken fazlarda tespit edildiğinde diğer fazlar çekilmemiştir. Çizelge 4.30 (a) ve (b)' de görüldüğü üzere, ATUS sisteminde yer alan parametreler için kesin ve sabit değerler söz konusu değildir. Çünkü arteryel ve portal fazlarda görüntü gri seviyeleri değişiklik gösterebilmektedir. Sürrenal lezyonların farklı fazlarda değişken gri seviyelere sahip olabildiği, bu durumun sürrenal lezyon temelli yarı-otomatik veya otomatik bir segmentasyon sistemi için önemli bir dezavantaj olduğu görülmektedir.

Çizelge 4.30 (b)' de en sık tekrar eden parametre değerleri, sürrenal lezyon segmentasyonu üzerine yüksek performans sağlamaları sebebiyle önem arz etmektedir.

4.5.3. Görsel sonuçlar ve analiz

ATUS sisteminin her bir adımı için görsel çıktılar Şekil 4.21' de sunulmuştur.

Şekil 4.21’ de dalağa yapışık lezyon (sol bölüm) ve karaciğere yapışık lezyon (sağ bölüm) için elde edilen sonuçlar görülmektedir. ROI, BFO sistemi uygulanarak elde edilen (gürültü ve yağ dokusu elimine edilen) görüntüdür.



Şekil 4.21. ATUS operatör çıkışları

Şekil 4.21’ de görüldüğü üzere;

1. KS-AHE tekniği, histograma dayalı özellikleri kullanarak lezyon çevresi bölgede kontrast kalitesini iyileştirmektedir. Bu sayede lezyonların, yapışık olduğu organlardan daha farklı gri seviyelere çekilmesi sağlanır.
2. DAA-BB yaklaşımı omurilik, kaburga ve arka plan kısımlarını elimine etmektedir. Bu noktada DAA-BB tekniği, OKS algoritmasının girişine

sunulacak olan veri içerisine (lezyon harici bölgelere) küçük-siyah noktalar eklemektedir.

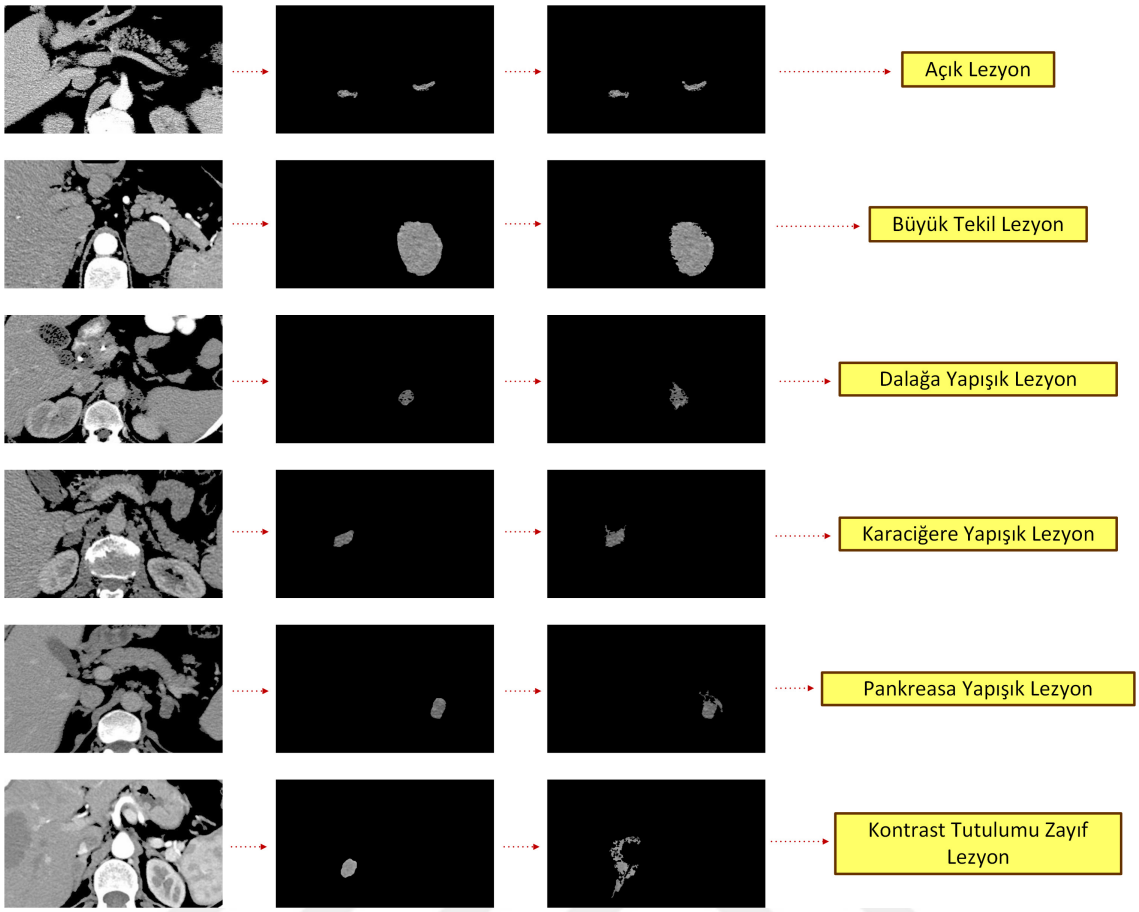
3. OKS tekniği, benzer yoğunluk özelliklerine sahip olan piksel değerlerini birbirine bağlamaktadır. DAA-BB yaklaşımı ile lezyon dışı bölgeler üzerine eklenen siyah bölümler, OKS algoritmasının lezyon üzerine yoğunlaşmasını sağlamaktadır.
4. GDE operatörü, lezyon harici doku ve organlarda gri seviye eliminasyonu yapmaktadır. Diğer bir deyişle, lezyon harici dokuların içerisine siyah alanlar eklemektedir. Böylece son aşama olan BA algoritması ile lezyonun yapışık olduğu dokunun, ROI (lezyon) içine dâhil edilmesi önlenmeye çalışılır.
5. BA algoritması ile belirtilen tolerans değerine uygun pikseller seçilerek, sürrenal lezyon segmentasyonu gerçekleştirilmektedir.

Sonuç olarak ATUS sistemi ile farklı sürrenal lezyon tiplerinin segmente edilebildiği görülmektedir.

Şekil 4.22’ de ATUS sonuçları, farklı durumlardaki sürrenal lezyonlar için sunulmuştur.

Şekil 4.22’ de görüldüğü üzere;

- Önerilen sistem, lezyon kontrast tutulumu yetersiz olduğu durumlarda da lezyon bölgelerini parçalı olarak elde edebilmektedir.
- ATUS sisteminin çalışma performansı, kontrast tutulumu zayıf lezyonlarda biraz düşüktür.
- Ancak ATUS sistemi, birçok farklı şekilsel durumda (açık lezyon, büyük tekil lezyon, dalağa yapışık görünümde lezyon, karaciğere yapışık görünümde lezyon, pankreasa yapışık görünümde lezyon) lezyon segmentasyonunu başarılı bir şekilde gerçekleştirmektedir.
- Şekil 4.22’ de açık kitleler homojen bir görünümde iken, dalağa yapışık lezyon heterojen bir görünüm içermektedir. Bu noktada önerilen yaklaşımın, homojen veya heterojen değişimlere sahip lezyonlarda başarılı bir segmentasyon sağladığı görülmektedir.



Şekil 4.22. Farklı durumlarda ATUS çıkışları
(Soldan sağa: ROI, Şablon, ATUS çıkışı)

Çalışma neticesinde özetle, abdomen görüntülerinden sürrenal lezyon segmentasyonunu gerçekleştiren bir sistem tasarlanmıştır. Çalışma, dört farklı açıdan literatürde sürrenal lezyon segmentasyonu alanındaki ilk çalışmadır:

- Unilateral / bilateral, iyi huylu / kötü huylu ve yapışık / yapışık olmayan sürrenal lezyonlar için segmentasyon işleminin gerçekleştirilmesi,
- Bütün bir abdominal BT görüntüsü üzerinde sürrenal lezyon segmentasyonunu gerçekleştiren yarı otomatik ve istatistiksel bir sistemin tasarlanması,
- Birden fazla sürrenal lezyon tipi için segmentasyon işleminin gerçekleştirilmesi,
- Sürrenal lezyonların şekilsel ve yoğunluk tabanlı özelliklerinden (büyüklük, şekil, konum ve kontrast bakımından farklı durumlardan) etkilenmeyerek segmentasyon işlemini gerçekleştiren ilk metodun sunulması.

Tasarlanan yapı, bir kullanıcı tarafından tohum koordinatlarının belirlenmesine ihtiyaç duyulan (yarı-otomatik) bir sistemdir. Bu noktada, tohum koordinatlarının seçilmesi işleminin hassas bir şekilde gerçekleştirilmesi gerekmektedir. Diğer bir deyişle tohum noktaları, lezyon içi yumuşak yoğunluk geçişlerinin olduğu, en sık tekrar eden gri seviyedeki piksel noktalarına bırakılmalıdır. Aksi takdirde (keskin geçişlerin bulunduğu noktaların seçilmesi durumunda) tohum alanı içinde geniş bir gri seviye aralığı söz konusu olmaktadır. Bu durumda elde edilecek olan alan, gerekli doku harici bölümleri de kapsayabilmektedir.

4.6. Sürrenal Lezyon Sınıflandırma Çalışması

Tez çalışmasında sürrenal lezyonların iyi huylu / kötü huylu (benign / malign) ayrımı için özellik çıkarma tabanlı bir sınıflama sistemi önerilmiştir. Sınıflama sisteminin performansı sürrenal lezyonların 8 alt türünü (5 genel türünü) içeren bir veri seti üzerinde değerlendirilmiştir. Veri setinin 5 genel türü adenom, feokromositoma, metastaz, hematom ve lipom tabanlı lezyonlar (lipom, adenolipom, myelolipom, adenomyolipom) şeklindedir. Söz konusu türlerden yalnızca metastaz kötü huylu bir lezyon türü olup, diğer türler iyi huylu olarak kategorize edilmektedir. Sınıflama işlemi için kullanılan verilerin özellikleri Çizelge 4.31' de sunulmuştur.

Çizelge 4.31. Sınıflandırmada kullanılan veri setinin özellikleri

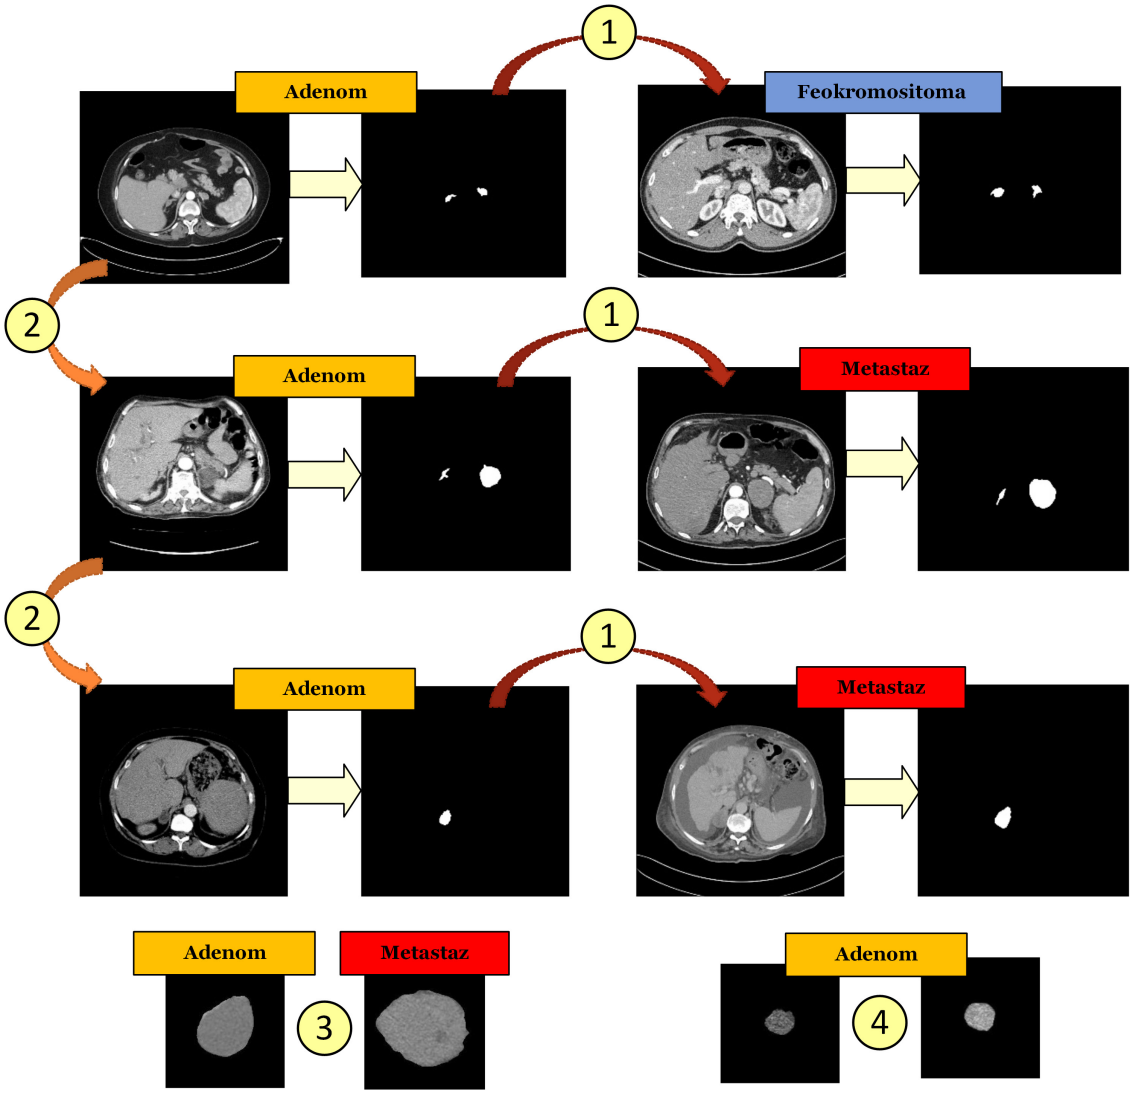
Eğitim	Test	Lezyon Karakteri
Adenom (40)	Adenom (38)	İyi Huylu
Hematom (2)	Hematom (2)	İyi Huylu
Lipom tabanlı Lezyonlar (2)	Lipom tabanlı Lezyonlar (3)	İyi Huylu
Feokromositoma (1)	Feokromositoma (2)	İyi Huylu
Metastaz (12)	Metastaz (12)	Kötü Huylu
57 lezyon (45 iyi huylu / 12 kötü huylu)	57 lezyon (45 iyi huylu / 12 kötü huylu)	114 lezyon (90 iyi huylu / 24 kötü huylu)

Gerçekleştirilen sınıflama çalışması, literatürdeki diğer çalışmalardan aşağıda belirtilen noktalarda farklılıklar içerir:

- Sürrenal lezyonların ikili sınıflaması üzerine en ayrıntılı çalışma
- İkiden fazla sürrenal lezyon tipinin sınıflandırıldığı ilk çalışma
- Görsel dezavantajlara sahip sürrenal lezyonlar içeren bir veri seti ile ilk çalışma:

    1. Benzer şekil ve boyut içeren farklı tür lezyonlar
    2. Farklı şekil ve boyut içeren aynı tür lezyonlar
    3. Benzer gri seviyeler içeren farklı tür lezyonlar
    4. Farklı gri seviyeler içeren aynı tür lezyonlar

Yukarıda belirtilen sürrenal lezyonlar için birkaç örnek Şekil 4.23' te sunulmaktadır.

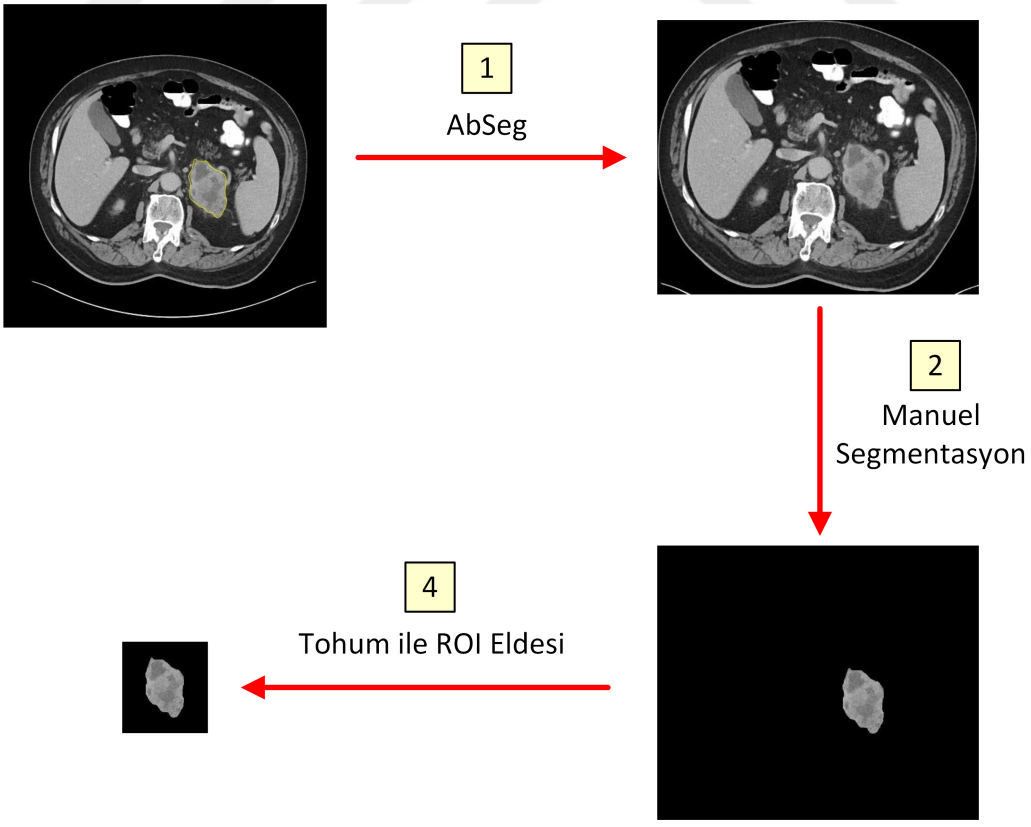


Şekil 4.23. Sürrenal lezyonların sınıflandırılmasında ortaya çıkan dezavantajlar

Kullanılan veri seti, Şekil 4.23' te görüldüğü üzere farklı görüntüye sahip aynı tür lezyonlar içerebildiği için sınıflaması zordur. Ayrıca homojenite ve heterojenite kavramlarının tek tip lezyonda sabit olmadığı, yine farklı tip lezyonlarda da benzerliklerin olabildiği görülmektedir. Bu nedenle gerçekleştirilecek çalışmada, etkili özellik çıkarma algoritmaları ile yüksek performansa sahip sınıflayıcının kullanılması gerekmektedir.

Sınıflama veri setinde yalnızca lezyonların yer aldığı ROI' ler kullanılmaktadır. Verilerin eldesi için manuel segmentasyon gerçekleştirilerek, lezyonların yer aldığı görüntüler elde edilmiştir. Lezyon görüntülerinin eldesini gösteren bir blok diyagram Şekil 4.24' de sunulmuştur.

Şekil 4.24' de görüldüğü gibi, ilk aşamada AbSeg sistemi ham BT görüntülerine uygulanır ve böylece görüntü içindeki abdomen ölçekli olarak elde edilir. Bu işlemin ardından manuel lezyon segmentasyonu gerçekleştirilir. Son aşamada, lezyonun majör ve minör eksenlerinin kesiştiği (merkez) noktalara kullanıcı tarafından tohum bırakılarak, 200x200' lük ROI alanı elde edilir.



Şekil 4.24. Kullanılan ROI alanlarının eldesi

4.6.1. Literatürde kullanılan etkin özellikler ve sınıflayıcılar

Çalışmada özellik çıkarma algoritması olarak histogram, GDEM ve dalgacık dönüşümü kullanılmıştır. Bunun sebebi, bu üç metodun literatürde sıklıkla tercih edilmesidir.

Literatür çalışmalarında histogram ve GDEM özelliklerine ek olarak, farklı dalgacık türlerinin incelendiği görülmüştür. Sınıflama üzerine gerçekleştirilen ve farklı tür özellikleri inceleyen literatür çalışmaları Çizelge 4.32' de sunulmuştur.

Çizelge 4.32. Farklı tür özellikleri inceleyen sınıflama çalışmaları

Çalışma	Veri	Konu	Kullanılan Özellikler
Sun ve ark. (2006)	Gen ifade verileri	Doku tiplerinin sınıflandırılması	Haar, Db2, Bior1.1, Bior2.2, Bior6.8, Coif2, Coif4, Sym2
Dettori ve Semler (2007)	BT görüntüleri	Omurga, kalp, böbrek ve karaciğer dokularının sınıflandırılması	Haar, Db4, Coif6 GDEM (0°,45°,90°,135°)
Zhang ve ark. (2010)	Gen ifade verileri	Tümör sınıflama	Haar, Db2, Db4, Db8, Bior2.2, Bior3.7, Bior6.8
Zhou ve ark. (2013)	Ultrasonografi görüntüleri	İyi huylu / kötü huylu meme lezyonlarının sınıflandırılması	Haar GDEM (0°)
El-Dahshan ve ark. (2014)	MR görüntüleri	Lezyon tabanlı hastalıkların tespiti	Haar
Muramatsu ve ark. (2016)	Mamogram görüntüleri	Meme tümörlerinin tespiti	Db4 GDEM (0°,45°,90°,135°)
Sahoo ve Chandra (2017)	Kontrast artırımlı BT görüntüleri	Serviks lezyonlarının sınıflandırılması	Haar GDEM (0°,45°,90°,135°)

Çizelge 4.32' ye göre GDEM özellikleri, genel olarak dört farklı yönde (0°,45°,90°,135°) ele alınmaktadır (Muramatsu ve ark., 2016; Sahoo ve Chandra, 2017). Ancak bu özelliği tek yönde (0°) inceleyen çalışmalar da mevcuttur (Zhou ve ark., 2013). Haar, Db2, Db4 ve Db8 ise en sık tercih edilen dalgacık türleridir. Bu özellikler, BT görüntülerinin yanı sıra farklı tipteki verilerde de etkin olarak kullanılmaktadır.

Literatür çalışmalarında Optimize YSA yapılarının, medikal görüntü sınıflama ve örüntü analizlerinde sıklıkla kullanıldığı görülmektedir. YSA, PSO-YSA, YAKA-YSA, KPSO-YSA ve Sınırlı PSO-YSA tekniklerinin farklı verisetleri üzerine başarı sağladıkları görülmüştür (Koyuncu ve Ceylan, 2015; Ceylan ve Koyuncu, 2016; 2017). Söz konusu tekniklerin, medikal görüntü ve örüntü işleme temelli çalışmalarda

özgüllük, duyarlılık, doğruluk, AUC gibi metrikler üzerine yüksek başarılar sağladığı ve eşdeğer tekniklere üstün oldukları görülmüştür.

Çalışmada BT görüntülerinden sürrenal lezyonların ikili (iyi huylu / kötü huylu) sınıflandırılması gerçekleştirilmiştir. Bu amaçla histogram tabanlı özellikler, GDEM tabanlı özellikler ve dalgacık tabanlı dönüşümler incelenmiştir. GDEM tabanlı özellikler özellikler literatürde önerildiği üzere hem tek yönde (0°) hem de dört farklı yönde (0°,45°,90°,135°) incelenmiş, literatürde en sık tercih edilen dalgacık türlerinin (Haar, Db2, Db4, Db8) karşılaştırılması sağlanmıştır. Böylece en yüksek performansı sağlayan özellikler elde edilmiştir. YSA, PSO-YSA, YAKA-YSA, KPSO-YSA ve Sınırlı PSO-YSA teknikleri farklı özellik vektörleri ile test edilmiştir. Bu sayede sürrenal lezyonların ikili karakterizasyonu için optimum sistem tasarımı gerçekleştirilmiştir.

4.6.2. Özellik çıkarma tabanlı işlemler

Çizelge 4.33' de görüldüğü gibi özellik vektörleri; histogram tabanlı özellikler, GDEM tabanlı özellikler ve Haar, Db2, Db4, Db8 dalgacıkları kullanılarak oluşturulmuştur.

Çizelge 4.33. Özellik çıkarma ile oluşturulan özellik setleri

Özellik Seti	Kullanılan Metot	Özellikler	Özellik Sayısı	Toplam Özellik Sayısı
ÖS1	**-----**	Histogram tabanlı özellikler	6	20
		GDEM tabanlı özellikler (0°)	14	
ÖS2	**-----**	Histogram tabanlı özellikler	6	62
		GDEM tabanlı özellikler (0°,45°,90°,135°)	14x4	
ÖS3	**Haar dalgacığı**	Histogram tabanlı özellikler	(6x4)	80
		GDEM tabanlı özellikler (0°,45°,90°,135°)	(14x4)	
ÖS4	**Db2 dalgacığı**	Histogram tabanlı özellikler	(6x4)	80
		GDEM tabanlı özellikler (0°,45°,90°,135°)	(14x4)	
ÖS5	**Db4 dalgacığı**	Histogram tabanlı özellikler	(6x4)	80
		GDEM tabanlı özellikler (0°,45°,90°,135°)	(14x4)	
ÖS6	**Db8 dalgacığı**	Histogram tabanlı özellikler	(6x4)	80
		GDEM tabanlı özellikler (0°,45°,90°,135°)	(14x4)	

GDEM tabanlı özellikler literatürde önerildiği üzere 0°' de ve 4 farklı yönde (0°,45°,90°,135°) elde edilmiştir (Masumori ve ark., 1998; Dettori ve Semler, 2007; Zhou ve ark., 2013). Bu işlemin sonucunda orijinal görüntüden sırasıyla ÖS1 ve ÖS2 veri setleri elde edilmiştir. Dalgacık için birinci seviye çözünürlük analizi gerçekleştirilmektedir (Zhou ve ark., 2013; Sahoo ve Chandra, 2017). GDEM tabanlı özelliklerin eldesinde dalgacık alt bantlarından yalnızca yaklaşım bandı kullanılmıştır. Çünkü diğer bantlardan ayrıntılı bilgi elde edilememektedir (El-Dahshan ve ark., 2014). Buna göre Haar, Db2, Db4 ve Db8 dalgacık tiplerinde histogram tabanlı özellikler, temel özellikler olduğundan alt bantların hepsinde elde edilmiştir. GDEM tabanlı özellikler ise yalnızca yaklaşım bandında incelenmektedir. GDEM tabanlı özellikler, literatürde dalgacık üzerine gerçekleştirilen çalışmaların hemen hepsinde 4 yöndeki değişimler için elde edilmektedir. Bu çalışmada da lezyona dair frekans bilgilerinin eldesi için 4 açılı inceleme temel alınmıştır.

4.6.3. Deneysel sonuçlar ve istatistiksel analiz

Çizelge 4.33' de verilen özellik setleri YSA, YAKA-YSA, PSO-YSA, KPSO-YSA ve Sınırlı PSO-YSA teknikleri kullanılarak sınıflandırılmıştır. Her bir sınıflayıcı yapının optimum parametre değerleri kapsamlı bir şekilde incelenerek, elde edilen en yüksek performanslar, farklı özellik setleri referans alınarak değerlendirilmiştir. Çizelge 4.34 – Çizelge 4.39' de ÖS1 - ÖS6 özellik setleri ile elde edilen optimum sistem çıkışlarını sunulmuştur.

Gerçeklenen denemelerde sistem çıkışları duyarlılık, özgüllük ve AUC metrikleri üzerinden analiz edilmiştir. Eğitim ve test aşamalarında kullanılan veri, 90 iyi huylu ve 24 kötü huylu lezyon içeren BT görüntülerinden oluşmaktadır.

Duyarlılık ve AUC oranlarında en düşük sonuçları veren yapı pasif teknik olarak görülmüştür. En optimum çıkışların eldesinde pasif tekniğin ulaşabildiği sonuçlar önemsenmemektedir. Çünkü pasif teknik %97.78 özgüllük ile başarı sağlayabilirken, DP üzerine yoğunlaşan duyarlılık metriği üzerine yalnızca %25 başarı oranı elde edebilmektedir. Bu noktada maksimum özgüllük oranı (%97.78), en optimum tekniğin ve en iyi metrik performanslarının eldesinde yanıltıcı olabilmektedir. Kısaca en kuvvetli teknik, bir veya iki metrik üzerine en iyi sonuçları elde etmeli, ayrıca diğer metrikler üzerine de kabul edilebilir bir performansa sergilemelidir.

Çizelge 4.34' de ÖS1 özellikleri ile elde edilen sınıflandırma sonuçları sunulmuştur. Elde edilen sonuçlara göre YSA, 12 kötü huylu lezyonun yalnızca 3' ünü doğru sınıflayabilmiştir. Diğer yapıların performansları birbirine yakındır. Ancak YAKA-YSA tekniği ile daha yüksek duyarlılık ve AUC oranlarına ulaşılabildiği, ayrıca elde edilen özgüllük oranının kabul edilebilir seviyede olduğu görülmüştür. Sonuç olarak YAKA-YSA tekniğinin, ÖS1 seti ile en optimum performansı sağlayan teknik olduğu ortaya çıkmıştır.

Çizelge 4.34. ÖS1 özellik seti ile elde edilen sınıflandırma sonuçları

Teknik	Duyarlılık	Özgüllük	AUC
YSA	25,00	97,78	61,39
YAKA-YSA	***66,67***	82,22	***74,44***
PSO-YSA	58,33	80,00	69,17
KPSO-YSA	58,33	84,44	71,39
Sınırlı PSO-YSA	50,00	***88,89***	69,44

Çizelge 4.35' de ÖS2 özellikleri ile elde edilen sonuçlar karşılaştırılmıştır. Burada da %25 duyarlılık ve %61.39 AUC ile en kötü sonuçlar YSA' da elde edilmiştir. PSO-YSA, YAKA-YSA ve Sınırlı PSO-YSA teknikleri, bütün metrikler göz önüne alındığında performans bakımından benzer bir grafik çizmektedir. PSO-YSA ve Sınırlı PSO-YSA teknikleri ile aynı sonuçlar elde edilmiştir. Bu iki teknikle en yüksek duyarlılık (%66.67) ve AUC (%74.44) oranlarına ulaşılmıştır. Ayrıca PSO-YSA ve Sınırlı PSO-YSA ile %82.22 özgüllük elde edilmiştir.

Çizelge 4.35. ÖS2 özellik seti ile elde edilen sınıflandırma sonuçları

Teknik	Duyarlılık	Özgüllük	AUC
YSA	25,00	97,78	61,39
YAKA-YSA	58,33	***97,78***	72,50
PSO-YSA	***66,67***	82,22	***74,44***
KPSO-YSA	41,67	91,11	66,39
Sınırlı PSO-YSA	***66,67***	82,22	***74,44***

Çizelge 4.36' da ÖS3 özellikleri ile elde edilen sınıflandırma sonuçları sunulmuştur. Burada en kötü sonuçlar %41.67 duyarlılık ve %67.5 AUC ile KPSO-YSA tekniğine aittir. PSO-YSA, YAKA-YSA ve Sınırlı PSO-YSA teknikleri, ÖS2 tabanlı denemelerde olduğu gibi ÖS3 tabanlı karşılaştırmalarda da dikkate değer performanslara ulaşabilen algoritmalardır. Sınırlı PSO-YSA yapısı, kabul edilebilir özgüllük oranının (%84.44) yanı sıra en yüksek duyarlılık (%66.67) ve AUC (%75.56) oranlarına ulaşmıştır. Sonuç olarak Sınırlı PSO-YSA tekniği, en yüksek performanslar ve ortalama başarı bakımından en kuvvetli teknik olmaktadır.

Çizelge 4.36. ÖS3 özellik seti ile elde edilen sınıflandırma sonuçları

Teknik	Duyarlılık	Özgüllük	AUC
YSA	58,33	80,00	69,17
YAKA-YSA	***66,67***	80,00	73,33
PSO-YSA	58,33	***86,67***	72,50
KPSO-YSA	41,67	93,33	67,50
Sınırlı PSO-YSA	***66,67***	84,44	***75,56***

Çizelge 4.37' de ÖS4 özellikleri ile elde edilen sınıflandırma sonuçları sunulmuştur. YAKA-YSA algoritması, %50 duyarlılık ve %69.44 özgüllük ile en düşük performanslara sahip tekniktir. Sınırlı PSO-YSA yapısı ise %75 duyarlılık ve %78.61 AUC elde etmiştir. Ayrıca teknik, özgüllük oranı üzerine makul bir başarı (%82.22) sağlamıştır. Sınırlı PSO-YSA algoritması, en yüksek performanslar ve ortalama başarı bakımından diğer tekniklere üstünlük sağlayan kuvvetli sınıflayıcıdır. Sınırlı PSO-YSA ile 12 kötü huylu lezyondan 9' unun sınıflanabildiği görülmüştür.

Çizelge 4.37. ÖS4 özellik seti ile elde edilen sınıflandırma sonuçları

Teknik	Duyarlılık	Özgüllük	AUC
YSA	66,67	77,78	72,22
YAKA-YSA	50,00	88,89	69,44
PSO-YSA	58,33	***88,89***	73,61
KPSO-YSA	58,33	84,44	71,39
Sınırlı PSO-YSA	***75,00***	82,22	***78,61***

Çizelge 4.38' de ÖS5 özellikleri ile elde edilen sınıflandırma sonuçları sunulmuştur. YSA ve PSO-YSA algoritmalarının en düşük duyarlılık oranına (%50) ulaştığı, KPSO-YSA ile elde edilen AUC oranının (%69.17) en düşük başarıyı sağladığı görülmüştür. Sınırlı PSO-YSA yapısı ise en yüksek özgüllük (%84.44) ve AUC (%71.39) oranlarını sağlamaktadır. Ayrıca tekniğin duyarlılık oranı da (%58.33) kabul edilebilir düzeydedir. Sınırlı PSO-YSA ile 12 kötü huylu lezyondan 7' sinin sınıflandırılabildiği görülmüştür.

Çizelge 4.38. ÖS5 özellik seti ile elde edilen sınıflandırma sonuçları

Teknik	Duyarlılık	Özgüllük	AUC
YSA	50,00	88,89	69,44
YAKA-YSA	***66,67***	73,33	70,00
PSO-YSA	50,00	93,33	71,67
KPSO-YSA	58,33	80,00	69,17
Sınırlı PSO-YSA	58,33	***84,44***	***71,39***

Çizelge 4.38' de ÖS6 özellikleri ile elde edilen sınıflandırma sonuçları sunulmuştur. YSA ve KPSO-YSA teknikleri ile en düşük duyarlılık ve AUC değerlerini sağlamıştır. YAKA-YSA ve Sınırlı PSO-YSA teknikleri benzer performanslara sahip olmalarına rağmen, YAKA-YSA ile elde edilen özgüllük (%86.67) ve AUC (%76.67) oranları en yüksek başarının sağlandığı durumlardır. YAKA-YSA ile kötü huylu lezyonların 8/12' sinin sınıflanabildiği ve bu oranın en iyi ikinci duyarlılık oranı olduğu görülmüştür.

Çizelge 4.39. Db8 özellik seti ile elde edilen sınıflandırma sonuçları

Teknik	Duyarlılık	Özgüllük	AUC
YSA	58,33	75,56	66,94
YAKA-YSA	66,67	***86,67***	***76,67***
PSO-YSA	58,33	84,44	71,39
KPSO-YSA	50,00	88,89	69,44
Sınırlı PSO-YSA	***75,00***	73,33	74,17

Çizelge 4.40'da bütün veriler üzerine en kuvvetli sınıflayıcı yapıların sonuçları sunulmuştur. Elde edilen bulgular ışığında Sınırlı PSO-YSA tekniğinin, farklı verilerde en yüksek performansları sağladığı tespit edilmiştir. Özellikler temel alınarak yapılan karşılaştırmada, ÖS4 seti ile en yüksek iyi huylu / kötü huylu sınıflama performanslarına ulaşılmıştır. Bu noktada Sınırlı PSO-YSA ile %75 duyarlılık ve %78.61 AUC oranlarının sağlandığı gözlemlenmiştir. Ayrıca teknik ile elde edilen doğruluk (%80.7) ve özgüllük (%82.22) oranlarının da kabul edilebilir düzeyde olduğu görülmüştür. Yalnızca Sınırlı PSO-YSA metodu ile 12 kötü huylu lezyondan 9' unun sınıflanabildiği tespit edilmiştir.

Çizelge 4.40. Farklı özellik setleri ve en kuvvetli sınıflayıcılar için performans karşılaştırması

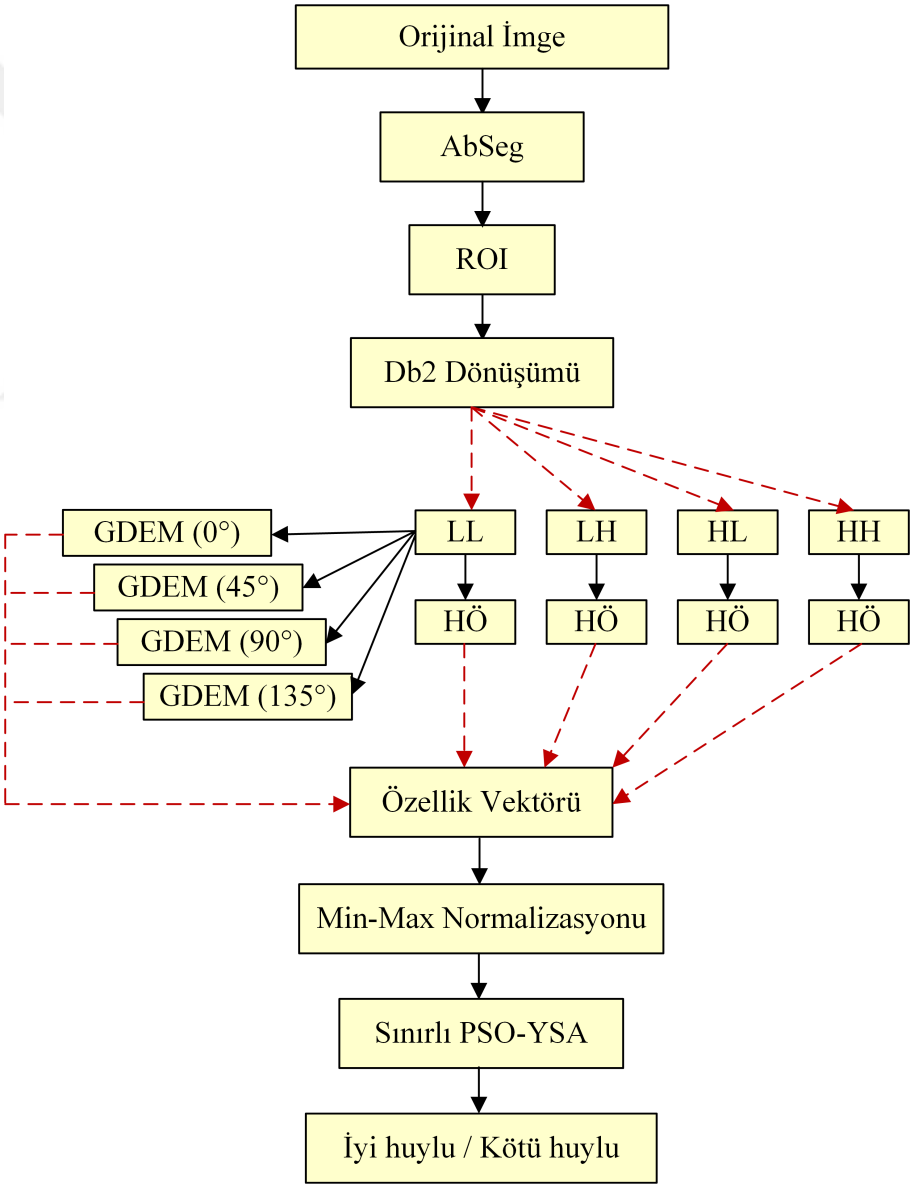
Özellik Setleri	Teknik	Doğruluk	Duyarlılık	Özgüllük	AUC
ÖS1	YAKA-YSA	78,95	66,67	82,22	74,44
ÖS2	PSO-YSA Sınırlı PSO-YSA	78,95	66,67	82,22	74,44
ÖS3	Sınırlı PSO-YSA	80,70	66,67	84,44	75,56
ÖS4	**Sınırlı PSO-YSA**	80,70	***75,00***	82,22	***78,61***
ÖS5	Sınırlı PSO-YSA	78,95	58,33	84,44	71,39
ÖS6	YAKA-YSA	***82,46***	66,67	***86,67***	76,67

Sınırlı PSO-YSA yapısının, ÖS4 özellik setinde en yüksek performansları sağladığı parametre ayarlamaları Çizelge 4.41' de sunulmuştur. Buna göre ağırlık & bias vektörlerinin konum ve sürat aralıklarının bireysel ayarlanması gerektiği görülmektedir. Bu durumun sınıflama performansını artıracağı gözlemlenmiştir. Elde edilen sonuçlar, Ceylan ve Koyuncu (2016) tarafından gerçeklenen denemelerle uyuşmakta, Sınırlı PSO-YSA tekniğinin geleneksel PSO-YSA tekniğinden daha kararlı bir yapı ihtiva ettiği ortaya çıkmaktadır.

Çizelge 4.43. ÖS4 özellik setinde Sınırlı PSO-YSA parametrelerinin değerleri

Parametreler	Parametre Ayarlamaları
Ağırlık pozisyon aralığı (apa)	[-10,10]
Ağırlık sürat aralığı (asa)	[-5,5]
Bias pozisyon aralığı (bpa)	[-5,5]
Bias sürat aralığı (bsa)	[-2.5, 2.5]
Gizli düğüm sayısı	102
Popülasyon sayısı	16
c_1 / c_2	2.04 / 1.94
Atalet ağırlığı	0.9→0.4
Maksimum iterasyon sayısı	3000

Çalışmada üretilen optimum sistem şeması Şekil 4.25' de görüldüğü gibidir.



Şekil 4.25. Önerilen sistem yapısı

Elde edilen sonuçlara göre;

- Sınırlı PSO-YSA tekniği, sürrenal lezyonların ikili sınıflandırılması üzerine en uygun sınıflayıcı yapıdır.
- Farklı tip dalgacıklar üzerine benzer sonuçlar üretilmesine rağmen, Db2 özelliklerinin (ÖS4 özellik setinin) temel alındığı denemelerde daha yüksek duyarlılık ve AUC oranlarına ulaşıldığı, ayrıca elde edilen özgüllük ve doğruluk oranlarının da yüksek başarı sağladığı görülmüştür.
- Db2 tabanlı özellikler (ÖS4 özellik seti) ve Sınırlı PSO-YSA ikilisinin, BT görüntülerinden sürrenal lezyonların iyi huylu / kötü huylu ayrımı için en optimum ikili (özellik seti & hibrit sınıflayıcı) olduğu tespit edilmiştir. Bu noktada ele alınan veri seti, görsel birçok deavantajı içinde barındırmaktadır. Buna bağlı olarak Db2 özellikleri – Sınırlı PSO-YSA yapısının temel alındığı (Şekil 4.25' de ifade edilen) sistemin farklı organlarda meydana gelen lezyonlar üzerine de kullanımının gerçekleştirilebileceği öngörülmektedir.

5. SONUÇLAR VE ÖNERİLER

Çalışmada sürrenal lezyonların belirlenmesi ve sınıflandırılması için ayrıntılı bir BDT sistemi gerçekleştirilmiştir. Önerilen BDT sisteminin tasarımı beş başlık (abdomen segmentasyonu, gürültü giderme, yağ dokusu eliminasyonu, sürrenal lezyon segmentasyonu, lezyon sınıflandırma) altında anlatılmıştır.

Sonuçlar bölümünde gerçeklenen çalışmaların analizleri yapılmıştır. Sürrenal lezyon segmentasyonu ve lezyonların sınıflandırılması üzerine literatür karşılaştırmalarına yer verilmiştir. Bu noktada abdomen segmentasyonu işlemi, literatürde ilk kez gerçekleştirildiğinden dolayı literatür karşılaştırması bulunmamaktadır. Benzer şekilde BFO sisteminde, gürültü giderme ve yağ dokusu eliminasyonu işlemlerinin birlikte ele alınması sebebiyle herhangi bir literatür karşılaştırmasına yer verilememiştir. Çünkü önerilen yapı tarafından gerçekleştirilen görevleri literatürde işleyen herhangi bir çalışma bulunmamaktadır. Gürültü giderme üzerine gerçeklenen çalışma, hâlihazırda literatürde işlenen tekniklerin ayrıntılı karşılaştırmasını sunmaktadır.

5.1 Sonuçlar

Çalışmada önerilen abdomen segmentasyon sistemi, parametre değerlerinin ayarlandığı ve test edildiği veri setlerinin yanı sıra harici bir veri seti üzerinde de yüksek bir performans sağlayabilmiştir. AbSeg sisteminin eğitim, test ve validasyon setlerinde altı metrik ortalaması üzerine başarıları sırasıyla %99.21, %99.54 ve %99.78 şeklindedir. Diğer bir deyişle, AbSeg sisteminde kullanılan parametre ayarlamalarının optimum olarak elde edildiği açık bir şekilde görülmüştür. Çünkü sistem, harici veri seti üzerine aynı parametrelerle daha yüksek segmentasyon sonuçları üretmiştir. AbSeg sisteminin, BT görüntülerindeki dezavantajlardan etkilenmeyerek abdomen segmentasyonunu sağlayan istatistiksel bir yaklaşım olduğu görülmektedir. Önerilen sistem; BT yatağı görüntüsü, hasta bilgileri, BT kenarlarına yakın abdomen, düşük kontrast, dar histogram ve süreksiz kenarlı abdomen gibi dezavantajların bulunduğu görüntülerde etkin bir biçimde kullanılabilmektedir.

Çalışmanın ikinci aşamasında gürültü eliminasyonu gerçekleştirilmiştir. Tez çalışmasında kullanılan BE3BF algoritmasının, abdominal BT görüntülerinde ve sürrenal lezyonların yer aldığı ROI' de Gaussian gürültü eliminasyonu üzerine en etkin

olduğu görülmüştür. BE3BF metodu, TİB tabanlı karşılaştırmalara göre diğer tüm tekniklerden daha yüksek bir başarı sergilemiş, ortalama DSGO değerleri temelli karşılaştırmada her zaman diğer tekniklerdan daha yüksek performans sağlamıştır. Dolayısıyla BE3BF algoritmasının, farklı gürültü seviyelerinde gürültü eliminasyonu için en kararlı yaklaşım olduğu söylenebilir. BE3BF tekniği, bütün bir abdomen üzerinde ve ROI tabanlı görsel karşılaştırmalarda gürültü giderme üzerine diğer tekniklerden daha başarılı olmuştur. Hesaplama zamanı ve hesaplama maliyeti temelli karşılaştırmalarda da en az işlem süresine ve minimum hesaplama maliyetine sahip metot BE3BF' dir.

BFO sistemi, BT görüntülerinden gürültü ve yağ dokusu eliminasyonunda etkin bir performans sergilemiştir. BFO yaklaşımı; DSGO, YBİ ve görsel tabanlı karşılaştırmalarda HB-VKM ve BE3BF & HB-VKM algoritmalarına her görüntüde üstünlük sağlamıştır. Ayrıca önerilen sistem, organları ve sürrenal lezyonları görüntü analizindeki bir sonraki aşamaya (segmentasyon) hazır hale getirmektedir.

Çizelge 5.1' de tasarlanan lezyon segmentasyon sistemi (ATUS) ile literatür çalışmaları karşılaştırılmıştır. Çizelge 5.1' de görüldüğü üzere ATUS sistemi, doğruluk ve özgüllük metrikleri incelendiğinde en yüksek başarıyı sağlamaktadır. Ayrıca teknik ile 3 farklı lezyon tipi ve lezyona dair birçok dezvantaj incelendiğinden kabul edilebilir bir duyarlılık sağlandığı görülmüştür. Burada Tang ve ark. (2014) tarafından önerilen çalışmada yalnızca büyük tekil bir lezyonunun elde alındığı, diğer dezavantajların işlenmediği ve yüksek sayıda veri ile segmentasyon gerçekleştirilmediği göz önüne alınmalıdır.

ATUS sistemi, bütün bir abdomen üzerinden hareket eden ve sürrenal lezyon segmentasyonunu literatürde en ayrıntılı şekilde yerine getiren yaklaşımdır. Unilateral / bilateral, yapışık / yapışık olmayan ve iyi huylu / kötü huylu sürrenal lezyonlarda segmentasyon işlemini başarıyla yerine getirmektedir. Teknik, kontrast tutulumu yüksek lezyonlarda tutulumun az olduğu lezyonlara nazaran daha yüksek bir performans sağlamaktadır. Bu noktada sürrenal lezyonların şekilsel ve yoğunluk tabanlı özelliklerinden (büyüklük, şekil ve gri seviye bakımından farklı durumlardan) etkilenmeyerek segmentasyon işlemini gerçekleştiren ilk sistemdir. Ayrıca çalışmada birden fazla sürrenal lezyon tipi için 30 BT taramasından daha fazla görüntüde segmentasyon yerine getirilmiştir. Özetle literatürde kullanılan veri sayısı, üzerinde işlem yapılan lezyon tipi ve sürrenal lezyonlara dair birçok dezavantajın işlenmesi bakımından en geniş çalışma gerçekleştirilmiştir.

Çizelge 5.1. Sürrenal lezyonların segmentasyonu üzerine literatür çalışmaları

Literatür Çalışmaları	Lezyon Tip Sayısı	Veri Sayısı	Duyarlılık	Özgüllük	Doğruluk
Tang ve ark. (2014)	1	10	%92,5	%92,2	**----**
Chai ve ark. (2015)	-----	30	**----**	**----**	%90,31
Gerçeklenen Çalışma	3	32	%86,44	%99,66	%99,43

Sürrenal lezyon sınıflandırma konusunda literatür karşılaştırması Çizelge 5.2' de sunulmuştur. Doğruluk kriteri temelli alınırsa; çalışmada önerilen sistemin, %80.7 başarı oranına ulaşarak diğer tekniklere üstünlük sağladığı görülmüştür. Diğer metrikler dikkate alındığında elde edilen sonuçların, sürrenal lezyonların 8 alt türü ele alınmasından dolayı kabul edilebilir düzeyde olduğu görülmektedir. Çünkü diğer literatür çalışmalarında veri seti en fazla 2 lezyon türünden meydana gelmektedir. Çalışmada farklı tür lezyonlar üzerinde ayrıntılı işlem yapabilen bir yaklaşım önerilmiştir.

Db2 özellikleri ve Sınırlı PSO-YSA tekniğini içeren sistem, literatür çalışmaları ile karşılaştırıldığında en yüksek doğruluk oranını sağlamaktadır. Sınırlı PSO-YSA tekniğinin diğer yaklaşımlara üstün olmasının nedeni, PSO algoritmasında kullanılan formüller ve bireysel sınır ayarlamalarıdır. Sınıflamada kullanılan veri seti ise lezyon sınıflama üzerine birçok dezavantajın yer aldığı BT görüntülerinden oluşmaktadır. Literatür çalışmaları içerisinde en çok 3 tür sürrenal lezyon incelenmiş olup, bu inceleme de tarafımızdan gerçekleştirilen bir çalışmadır (Koyuncu ve Ceylan, 2017a).

Çizelge 5.2. Sürrenal lezyonların sınıflanması üzerine literatür çalışmaları

Çalışma	Lezyon Tür Sayısı	Görev	Veri	Doğruluk	Duyarlılık	Özgüllük	AUC
Biehl ve ark. (2012)	2	İkili Sınıflama	İdrar Testi	-----	%90	%90	%96.5
Saiprasad ve ark. (2013)	1	Anormallik tespiti	Hacimsel BT	-----	%80	%90	-----
Li ve ark. (2017)	Tanımsız	İkili Sınıflama	Kontrastsız BT	%80	-----	-----	-----
Koyuncu ve Ceylan (2017a)	3	İkili Sınıflama	Dinamik BT	%78.95	-----	-----	%84.29
Koyuncu ve Ceylan (2018)	8	İkili Sınıflama	Dinamik BT	%80.7	%75	%82.22	%78.61

5.2 Öneriler

Elde edilen bulgular neticesinde ve literatür taramalarından elde edilen sonuçlara göre;

- BT taramaları MR görüntüleri ile benzer özellikler içermektedir. AbSeg parametrelerinin, belirli bir MR verisi üzerinden gerçekleştirilecek eğitim sonrası, sistemin MR verileri üzerine uygulanabileceği öngörülmektedir. Aynı zamanda sistemin, pelvis ve toraks BT görüntülerinde de kullanılabileceği tespit edilmiştir. Bu görüntülerde işlenen ROI' nin abdomene benzeyen (elipsoid) bir görünüm ihtiva ettiği bilinmektedir. Bu nedenle, elipsoid şekil içeren benzer BT görüntülerinde de sistemin kullanılabileceği görülmüştür.
- Literatür çalışmalarında BT görüntülerinde Gaussian gürültüsünden farklı gürültü tiplerinin ele alındığı görülmektedir. Gerçeklenen çalışmalar neticesinde (bilhassa BFO sistemi ile elde edilen sonuçlarda), BT görüntülerindeki gürültü tipinin Gaussian olarak atfedilebileceği tespit edilmiştir.
- BFO sistemi, abdomen içi bütün organ ve dokuların segmentasyonundan önce kullanılabilecek bir görüntü iyileştirme sistemidir.
- ATUS sisteminin; homojen / heterojen bir yapı ihtiva edebilen, tekil (organ içerisinde yer almayan) ve farklı tür lezyonlarda kullanılabileceği tespit edilmiştir. ATUS sistemi ile (parametrelerin işlenen lezyona özgü ayarlanması durumunda) yukarıda belirtilen dezavantajları içeren farklı organlardaki lezyon segmentasyonlarının gerçekleştirilebileceği öngörülmektedir.
- Db2 dalgacığı temelli özellikler ve Sınırlı PSO-YSA sistemi ile çok farklı tür sürrenal lezyonların sınıflanabileceği, ayrıca önerilen yapının lezyon sınıflama için görüntüde mevcut birçok dezavantajdan minimal seviye etkilendiği görülmüştür. Literatür çalışmaları bakımından en yüksek doğruluğun önerilen sistem tarafından elde edildiği, bu nedenle sistemin farklı tür organ lezyonlarında da kullanılabileceği öngörülmektedir.

KAYNAKLAR

Akay, B., 2013, A study on particle swarm optimization and artificial bee colony algorithms for multilevel thresholding, *Applied Soft Computing*, 13 (6), 3066-3091.

Al-Ameen, Z., Sulong, G., Rehman, A., Al-Rodhaan, M., Saba, T. ve Al-Dhelaan, A., 2017, Phase-preserving approach in denoising computed tomography medical images, *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 5 (1), 16-26.

Alivar, A., Danyali, H. ve Helfroush, M. S., 2016, Hierarchical classification of normal, fatty and heterogeneous liver diseases from ultrasound images using serial and parallel feature fusion, *Biocybernetics and Biomedical Engineering*, 36 (4), 697-707.

Ayres, F., Zuffo, M., Rangayyan, R., Boag, G. ve Valente, M., 2004, Estimation of the tissue composition of the tumour mass in neuroblastoma using segmented CT images, *Medical and Biological Engineering and Computing*, 42 (3), 366-377.

Bevk, M. ve Kononenko, I., 2002, A statistical approach to texture description of medical images: a preliminary study, *Computer-Based Medical Systems, 2002.(CBMS 2002). Proceedings of the 15th IEEE Symposium on*, 239-244.

Biehl, M., 2012, Admire LVQ—Adaptive Distance Measures in Relevance Learning Vector Quantization, *KI - Künstliche Intelligenz*, 26 (4), 391-395.

Biehl, M., Schneider, P., Smith, D., Stiekema, H., Taylor, A., Hughes, B., Shackleton, C., Stewart, P. ve Arlt, W., 2012, Matrix relevance LVQ in steroid metabolomics based classification of adrenal tumors, *ESANN*.

Ceylan, R. ve Koyuncu, H., 2016, A New Breakpoint in Hybrid Particle Swarm-Neural Network Architecture: Individual Boundary Adjustment, *International Journal of Information Technology & Decision Making*, 15 (06), 1313-1343.

Ceylan, R. ve Koyuncu, H., 2017, A Novel Rotation Forest Modality Based on Hybrid NNs: RF (ScPSO-NN), *Journal of King Saud University-Computer and Information Sciences*.

Chai, H., Guo, Y. ve Wang, Y., 2015, Automatic Segmentation of Adrenal Tumor in CT Images Based on Sparse Representation, *Journal of Medical Imaging and Health Informatics*, 5 (8), 1737-1741.

Chen, H., Zhang, Y., Zhang, W., Liao, P., Li, K., Zhou, J. ve Wang, G., 2017, Low-dose CT via convolutional neural network, *Biomedical optics express*, 8 (2), 679-694.

Chen, Y., Chen, W., Yin, X., Ye, X., Bao, X., Luo, L., Feng, Q. ve Yu, X., 2011, Improving low-dose abdominal CT images by weighted intensity averaging over large-scale neighborhoods, *European Journal of Radiology*, 80 (2), e42-e49.

Chen, Y., Yang, Z., Hu, Y., Yang, G., Zhu, Y., Li, Y., Chen, W. ve Toumoulin, C., 2012, Thoracic low-dose CT image processing using an artifact suppressed large-scale nonlocal means, *Physics in Medicine and Biology*, 57 (9), 2667.

Chen, Y., Yin, X., Shi, L., Shu, H., Luo, L., Coatrieux, J.-L. ve Toumoulin, C., 2013, Improving abdomen tumor low-dose CT images using a fast dictionary learning based processing, *Physics in medicine and biology*, 58 (16), 5803.

Chuang, K.-S., Tzeng, H.-L., Chen, S., Wu, J. ve Chen, T.-J., 2006, Fuzzy c-means clustering with spatial information for image segmentation, *computerized medical imaging and graphics*, 30 (1), 9-15.

Chung, H., Cobzas, D., Lieffers, J., Birdsell, L. ve Baracos, V., 2009, Automated segmentation of muscle and adipose tissue on CT images for human body composition analysis, *SPIE Medical Imaging*, 72610K-72610K.

Clark, K., Vendt, B., Smith, K., Freymann, J., Kirby, J., Koppel, P., Moore, S., Phillips, S., Maffitt, D. ve Pringle, M., 2013, The Cancer Imaging Archive (TCIA): maintaining and operating a public information repository, *Journal of digital imaging*, 26 (6), 1045-1057.

Comaniciu, D. ve Meer, P., 2002, Mean shift: A robust approach toward feature space analysis, *IEEE Transactions on pattern analysis and machine intelligence*, 24 (5), 603-619.

Cong-Hua, X., Jin-Yi, C. ve Wen-Bin, X., 2014, Medical image denoising by generalised Gaussian mixture modelling with edge information, *IET Image Processing*, 8 (8), 464-476.

Dabov, K., Foi, A., Katkovnik, V. ve Egiazarian, K., 2007, Image denoising by sparse 3-D transform-domain collaborative filtering, *IEEE Transactions on image processing*, 16 (8), 2080-2095.

Deledalle, C.-A., Salmon, J. ve Dalalyan, A. S., 2011, Image denoising with patch based PCA: local versus global, *BMVC*, 425-455.

Dettori, L. ve Semler, L., 2007, A comparison of wavelet, ridgelet, and curvelet-based texture classification algorithms in computed tomography, *Computers in biology and medicine*, 37 (4), 486-498.

Devi, H., 2006, Thresholding: A pixel-level image processing methodology preprocessing technique for an OCR System for the Brahmi Script, *Ancient Asia*, 1.

Eberhart, R. ve Kennedy, J., 1995, A new optimizer using particle swarm theory, *Micro Machine and Human Science, 1995. MHS'95., Proceedings of the Sixth International Symposium on*, 39-43.

Ekeh, A. P., Walusimbi, M., Brigham, E., Woods, R. J. ve McCarthy, M. C., 2010, The prevalence of incidental findings on abdominal computed tomography scans of trauma patients, *The Journal of emergency medicine*, 38 (4), 484-489.

El-Dahshan, E.-S. A., Mohsen, H. M., Revett, K. ve Salem, A.-B. M., 2014, Computer-aided diagnosis of human brain tumor through MRI: A survey and a new algorithm, *Expert systems with Applications*, 41 (11), 5526-5545.

Elad, M. ve Aharon, M., 2006, Image denoising via sparse and redundant representations over learned dictionaries, *IEEE Transactions on Image processing*, 15 (12), 3736-3745.

Eltoukhy, M. M., Faye, I. ve Samir, B. B., 2012, A statistical based feature extraction method for breast cancer diagnosis in digital mammogram using multiresolution representation, *Computers in biology and medicine*, 42 (1), 123-128.

Fawcett, T., 2006, An introduction to ROC analysis, *Pattern recognition letters*, 27 (8), 861-874.

Foi, A., Katkovnik, V., Egiazarian, K. ve Astola, J., 2004, Inverse halftoning based on the anisotropic LPA-ICI deconvolution, *Proceedings of Int. TICSP Workshop Spectral Meth. Multirate Signal Process*.

Foi, A., Katkovnik, V. ve Egiazarian, K., 2007, Pointwise shape-adaptive DCT for high-quality denoising and deblocking of grayscale and color images, *IEEE Transactions on Image Processing*, 16 (5), 1395-1411.

Franklin, S. W. ve Rajan, S. E., 2014, Computerized screening of diabetic retinopathy employing blood vessel segmentation in retinal images, *biocybernetics and biomedical engineering*, 34 (2), 117-124.

Goldenberg, A., Rager, J., Szczurek, L., Sandau, R. L. ve Neff, M., 2011, Transabdominal laparoscopic adrenalectomy of a large adrenal lipoma: A case

report and review of literature, *International journal of surgery case reports*, 2 (7), 172-174.

Hanna, S., El-Kalioubie, M., Badawy, H. ve Halim, M., 2015, Optimal diagnosis of adrenal masses, *The Egyptian Journal of Radiology and Nuclear Medicine*, 46 (2), 511-520.

Hashemi, S., Paul, N. S., Beheshti, S. ve Cobbold, R. S., 2015, Adaptively tuned iterative low dose CT image denoising, *Computational and mathematical methods in medicine*, 2015.

Herman, G. T. ve Davidi, R., 2008, Image reconstruction from a small number of projections, *Inverse problems*, 24 (4), 045011.

Hishiki, T., Kazukawa, I., Saito, T., Terui, K., Mitsunaga, T., Nakata, M., Matsuura, G., Minagawa, M., Kohno, Y. ve Yoshida, H., 2008, Diagnosis of adrenocortical tumor in a neonate by detection of elevated blood 17-hydroxyprogesterone measured as a routine neonatal screening for congenital adrenal hyperplasia: a case report, *Journal of pediatric surgery*, 43 (10), e19-e22.

Hrabak-Paar, M., Đido, V. ve Štern-Padovan, R., 2015, Should we use CT or MRI for detection and characterization of benign adrenal lesions?, *Annales d'Endocrinologie*, 272-280.

Hsieh, K. L.-C., Lo, C.-M. ve Hsiao, C.-J., 2017, Computer-aided grading of gliomas based on local and global MRI features, *Computer Methods and Programs in Biomedicine*, 139, 31-38.

Jiao, C., Wang, D., Lu, H., Zhang, Z. ve Liang, J. Z., 2008, Multiscale noise reduction on low-dose CT sinogram by stationary wavelet transform, *Nuclear Science Symposium Conference Record, 2008. NSS'08. IEEE*, 5339-5344.

Kadhem, H., Rodriguez, D., Tena, J.-R., Wells, K., Lewis, E. ve Guy, M., 2006, Ultra low dose CT attenuation correction maps for emission computed tomography, *Nuclear Science Symposium Conference Record, 2006. IEEE*, 2123-2127.

Kanchanaraksa, S., 2008, Evaluation of diagnostic and screening tests: validity and reliability, *Baltimore: John Hopkins University*.

Karaboga, D., 2005, An idea based on honey bee swarm for numerical optimization, *Technical report-tr06, Erciyes university, engineering faculty, computer engineering department*.

Karaboga, D. ve Akay, B., 2009, A comparative study of artificial bee colony algorithm, *Applied mathematics and computation*, 214 (1), 108-132.

Karimi, D., Deman, P., Ward, R. ve Ford, N., 2016, A sinogram denoising algorithm for low-dose computed tomography, *BMC medical imaging*, 16 (1), 11.

Kirshtein, B., Pagliarello, G., Yelle, J. ve Poulin, E., 2007, Incidence of pheochromocytoma in trauma patients during the management of unrelated illness: A retrospective review, *International Journal of Surgery*, 5 (5), 332-335.

Knaus, C. ve Zwicker, M., 2013, Dual-domain image denoising, *Image Processing (ICIP), 2013 20th IEEE International Conference on*, 440-444.

Korn, G. A. ve Korn, T. M., 2000, Mathematical handbook for scientists and engineers: Definitions, theorems, and formulas for reference and review, Courier Corporation, p.

Koss, J. E., Newman, F., Johnson, T. ve Kirch, D., 1999, Abdominal organ segmentation using texture transforms and a hopfield neural network, *IEEE Transactions on medical imaging*, 18 (7), 640-648.

Koyuncu, H. ve Ceylan, R., 2015, Scout particle swarm optimization, *6th European Conference of the International Federation for Medical and Biological Engineering*, 82-85.

Koyuncu, H. ve Ceylan, R., 2016, Optic Disc Segmentation with Kapur-ScPSO Based Cascade Multithresholding, *International Conference on Bioinformatics and Biomedical Engineering*, 206-215.

Koyuncu, H. ve Ceylan, R., 2017a, Classification of adrenal lesions by bounded PSO-NN, *Signal Processing and Communications Applications Conference (SIU), 2017 25th*, 1-4.

Koyuncu, H. ve Ceylan, R., 2017b, Elimination of White Gaussian Noise in Arterial Phase CT Images to Bring Adrenal Tumours into the Forefront, *Computerized Medical Imaging and Graphics*.

Koyuncu, H. ve Ceylan, R., 2017c, A hybrid tool on denoising and enhancement of abdominal CT images before organ & tumour segmentation, *Electronics and Nanotechnology (ELNANO), 2017 IEEE 37th International Conference on*, 249-254.

Koyuncu, H., Ceylan, R., Sivri, M. ve Erdogan, H., 2017, An Efficient Pipeline for Abdomen Segmentation in CT Images, *Journal of digital imaging*, 1-13.

Kumar, S., Kumar, P., Gupta, M. ve Nagawat, A. K., 2010, Performance comparison of median and Wiener filter in image de-noising, *International Journal of Computer Applications (0975–8887) Volume*, 12.

Labatut, V. ve Cherifi, H., 2012, Accuracy measures for the comparison of classifiers, *arXiv preprint arXiv:1207.3790*.

Lebrun, M., 2012, An analysis and implementation of the BM3D image denoising method, *Image Processing On Line*, 2, 175-213.

Lee, H., Troschel, F. M., Tajmir, S., Fuchs, G., Mario, J., Fintelmann, F. J. ve Do, S., 2017, Pixel-Level Deep Segmentation: Artificial Intelligence Quantifies Muscle on Computed Tomography for Body Morphometric Analysis, *Journal of digital imaging*, 1-12.

Li, X., Guindani, M., Ng, C. ve Hobbs, B., 2017, Classification of adrenal lesions through spatial Bayesian modeling of GLCM, *Biomedical Imaging (ISBI 2017), 2017 IEEE 14th International Symposium on*, 147-151.

Lim, J. S., 1990, Two-dimensional signal and image processing, *Englewood Cliffs, NJ, Prentice Hall, 1990, 710 p.*

Makrogiannis, S., Caturegli, G., Davatzikos, C. ve Ferrucci, L., 2013, Computer-aided assessment of regional abdominal fat with food residue removal in CT, *Academic radiology*, 20 (11), 1413-1421.

Masumori, N., Adachi, H., Noda, Y. ve Tsukamoto, T., 1998, Detection of adrenal and retroperitoneal masses in a general health examination system, *Urology*, 52 (4), 572-576.

Matrecano, M., Poderico, M., Poggi, G., Romano, M. ve Cesarelli, M., 2010, Application of denoising techniques to micro-tomographic images, *Information Technology and Applications in Biomedicine (ITAB), 2010 10th IEEE International Conference on*, 1-4.

Modugno, R., Pirlo, G. ve Impedovo, D., 2010, Score normalization by dynamic time warping, *Computational Intelligence for Measurement Systems and Applications (CIMSA), 2010 IEEE International Conference on*, 82-85.

Muramatsu, C., Hara, T., Endo, T. ve Fujita, H., 2016, Breast mass classification on mammograms using radial local ternary patterns, *Computers in biology and medicine*, 72, 43-53.

Narang, V., Sinha, T., Sandhu, A. S., Karan, S. C., Srivastava, A., Sethi, G. S., Talwar, R., Prusty, P., Kotwal, N. ve Adlakha, N., 2009, Clinically inapparent bilateral adrenal masses due to histoplasmosis, *European urology*, 55 (2), 518-521.

Nishikawa, T. ve Omura, M., 2000, Clinical characteristics of primary aldosteronism: its prevalence and comparative studies on various causes of primary aldosteronism in Yokohama Rosai Hospital, *Biomedicine & pharmacotherapy*, 54, 83s-85s.

Otsu, N., 1979, A threshold selection method from gray-level histograms, *IEEE transactions on systems, man, and cybernetics*, 9 (1), 62-66.

Pedersen, M. E. H. ve Chipperfield, A. J., 2010, Simplifying particle swarm optimization, *Applied Soft Computing*, 10 (2), 618-628.

Pednekar, A., Bandekar, A. N., Kakadiaris, I. A. ve Naghavi, M., 2005, Automatic segmentation of abdominal fat from CT data, *Application of Computer Vision, 2005. WACV/MOTIONS'05 Volume 1. Seventh IEEE Workshops on*, 308-315.

Popovic, A., De la Fuente, M., Engelhardt, M. ve Radermacher, K., 2007, Statistical validation metric for accuracy assessment in medical image segmentation, *International Journal of Computer Assisted Radiology and Surgery*, 2 (3), 169-181.

Sahoo, A. ve Chandra, S., 2017, Multi-objective Grey Wolf Optimizer for improved cervix lesion classification, *Applied Soft Computing*, 52, 64-80.

Saiprasad, G., Saenz, N. J., Chang, C.-I. ve Siegel, E. L., 2010, Prototype Decision Support System for Evaluation of Adrenal Glands Incorporated into Routine CT Workflow. Radiological Society of North America 2010 Scientific Assembly and Annual Meeting. Chicago.

Saiprasad, G., Chang, C.-I., Safdar, N., Saenz, N. ve Siegel, E., 2013, Adrenal gland abnormality detection using random forest classification, *Journal of digital imaging*, 26 (5), 891-897.

Sethi, G. ve Saini, B. S., 2016, Computer aided diagnosis system for abdomen diseases in computed tomography images, *Biocybernetics and Biomedical Engineering*, 36 (1), 42-55.

Sharma, D., Yadav, U. ve Sharma, P., 2009, The concept of sensitivity and specificity in relation to two types of errors and its application in medical research, *Journal of Reliability and Statistical studies*, 2 (2), 53-58.

Singh, R., Vasquez, R. E. ve Singh, R., 1997, Comparison of Daubechies, Coiflet, and Symlet for edge detection, *Visual Information Processing*, 6.

Sonka, M. ve Fitzpatrick, J. M., 2000, Handbook of medical imaging(Volume 2, Medical image processing and analysis).

Sun, G., Dong, X. ve Xu, G., 2006, Tumor tissue identification based on gene expression data using DWT feature extraction and PNN classifier, *Neurocomputing*, 69 (4), 387-402.

Taha, A. A. ve Hanbury, A., 2015, Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool, *BMC medical imaging*, 15 (1), 29.

Tan, C., Yan, Z., Zhang, S., Belaroussi, B., Yu, H. J., Miller, C. ve Metaxas, D. N., 2014, An automated and robust framework for quantification of muscle and fat in the thigh, *Pattern Recognition (ICPR), 2014 22nd International Conference on*, 3173-3178.

Tang, S., Guo, Y., Wang, Y., Cao, W. ve Sun, F., 2014, Segmentation and 3D visualization of pheochromocytoma in contrast-enhanced CT images, *Audio, Language and Image Processing (ICALIP), 2014 International Conference on*, 39-43.

Van Den Boomgaard, R. ve Van Balen, R., 1992, Methods for fast morphological image transforms using bitmapped binary images, *CVGIP: Graphical Models and Image Processing*, 54 (3), 252-258.

Wang, Y., Qiu, Y., Thai, T., Moore, K., Liu, H. ve Zheng, B., 2017, A two-step convolutional neural network based computer-aided detection scheme for automatically segmenting adipose tissue volume depicting on CT images, *Computer Methods and Programs in Biomedicine*, 144, 97-104.

Yang, H., Hu, G., Wang, Y. ve Wu, X., 2015, Low-rank approach for image nonblind deconvolution with variance estimation, *Journal of Electronic Imaging*, 24 (6), 063013-063013.

Yang, Y. ve Huang, S., 2012, Image segmentation by fuzzy C-means clustering algorithm with a novel penalty term, *Computing and Informatics*, 26 (1), 17-31.

Yao, W., Li, K., Xiao, X., Zheng, S. ve Chen, L., 2013, Neonatal suprarenal mass: differential diagnosis and treatment, *Journal of cancer research and clinical oncology*, 139 (2), 281-286.

Yu, J., Wang, S. ve Xi, L., 2008, Evolving artificial neural networks using an improved PSO and DPSO, *Neurocomputing*, 71 (4-6), 1054-1060.

Zhan, K., Zhang, H. ve Ma, Y., 2009, New spiking cortical model for invariant texture retrieval and image processing, *IEEE Transactions on Neural Networks*, 20 (12), 1980-1986.

Zhan, K., Shi, J., Li, Q., Teng, J. ve Wang, M., 2015, Image segmentation using fast linking SCM, *Neural Networks (IJCNN), 2015 International Joint Conference on*, 1-8.

Zhang, S.-W., Huang, D.-S. ve Wang, S.-L., 2010, A method of tumor classification based on wavelet packet transforms and neighborhood rough set, *Computers in biology and medicine*, 40 (4), 430-437.

Zhao, X.-j. ve Pu, J.-x., 2010, The Role of Multislice Helical CT in Diagnosing Small Renal Mass, *Bioinformatics and Biomedical Engineering (iCBBE), 2010 4th International Conference on*, 1-4.

Zharkova, V. ve Jain, L. C., 2007, Artificial intelligence in recognition and classification of astrophysical and medical images, Springer Science & Business Media, p.

Zhou, S., Shi, J., Zhu, J., Cai, Y. ve Wang, R., 2013, Shearlet-based texture feature extraction for classification of breast tumor in ultrasound image, *Biomedical Signal Processing and Control*, 8 (6), 688-696.

Zhu, F., Carpenter, T., Gonzalez, D. R., Atkinson, M. ve Wardlaw, J., 2012, Computed tomography perfusion imaging denoising using Gaussian process regression, *Physics in medicine and biology*, 57 (12), N183.

Zoran, D. ve Weiss, Y., 2011, From learning models of natural image patches to whole image restoration, *Computer Vision (ICCV), 2011 IEEE International Conference on*, 479-486.

Zou, K. H., Warfield, S. K., Bharatha, A., Tempany, C. M., Kaus, M. R., Haker, S. J., Wells, W. M., Jolesz, F. A. ve Kikinis, R., 2004, Statistical validation of image segmentation quality based on a spatial overlap index 1: Scientific reports, *Academic radiology*, 11 (2), 178-189.

Zuiderveld, K., 1994, Contrast limited adaptive histogram equalization, *Graphics gems IV*, 474-485.

http://www.itu.dk/~tped/teaching/pervasive/SPCT-F2015/L12-13/11_DataPr_chapter2_data-mining.pdf: [29.08.2017].

http://www.ke.tu-darmstadt.de/lehre/archiv/ws0708/ml-sem/Folien/Jiawei_Du.pdf:

EKLER

EK-1 Tez Çalışması Kapsamında Selçuk Üniversitesi Tıp Fakültesi Hastanesinden Temin Edilen Tıbbi Veriler Hakkında Etik Kurul Raporu

T.C.
SELCUK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞI
GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU

Toplantı Sayısı: 2015/5	Toplantı Tarihi: 03.03.2015

Karar Sayısı 2015/79 S.Ü. Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü Devreler ve Sistemler Anabilim Dalı Öğretim Üyesi Yrd.Doç.Dr. Rahime CEYLAN'ın, "Dinamik Bt Görüntülerinden Sürrenal (Adrenal) Lezyonların Belirlenmesi ve Sınıflandırılması İçin Akıllı Sistem Geliştirilmesi" başlıklı araştırmasının değerlendirilme talebi ile ilgili 24.02.2015 tarihli dilekçesi ve ekleri görüşüldü.

Yapılan inceleme ve görüşmelerden sonra; Yrd.Doç.Dr. Rahime CEYLAN'ın, "Dinamik Bt Görüntülerinden Sürrenal (Adrenal) Lezyonların Belirlenmesi ve Sınıflandırılması İçin Akıllı Sistem Geliştirilmesi" adlı araştırmanın kabulüne, TÜBİTAK desteği alındıktan sonra protokolün dosyaya ilave edilmek üzere Etik Kurul sekretaryasına teslim edilmesine oy birliği ile karar verildi.

Prof. Dr. Hilmi Cevdet ALTINYAZAR
Başkan

Prof.Dr. Ali ÜNLÜ
Başkan Yrd. Üye

Prof. Dr. Duygu FINDIK
Üye

Prof. Dr. İ.İlknur UYSAL
Üye

Doç. Dr. N. Hüldun EMİROĞLU

Doç. Dr. Kadir CEYLAN
Üye

Doç. Dr. Kemal Hakan DOĞAN
Üye

Doç.Dr. Yavuz SELVİ
Üye

Doç.Dr. Seda ÖZBEK
Üye

Yrd.Doç.Dr. Kemal Macit HİSAR
Üye

Yrd. Doç. Dr. Fahrettin ACAR
Üye

Mahmut KESİK
Sekretarya

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı	**:**	Hasan KOYUNCU
Uyruğu	**:**	Türkiye Cumhuriyeti
Doğum Yeri ve Tarihi	**:**	Meram/KONYA-26.07.1989
Telefon	**:**	0536 649 64 64
Faks	**:**	---
e-mail	**:**	hasankoyuncu@selcuk.edu.tr

EĞİTİM

Derece		**Adı, İlçe, İl**	**Bitirme Yılı**
Lise	:	Karatay S.D.M.P. Anadolu Lisesi	2007
Üniversite	:	Selçuk Üniversitesi	2011
Yüksek Lisans	:	Selçuk Üniversitesi	2013
Doktora	:	Selçuk Üniversitesi	2018

İŞ DENEYİMLERİ

Yıl	**Kurum**	**Görevi**
2013	Selçuk Üniversitesi	Araştırma Görevlisi

UZMANLIK ALANI

Biyomedikal Yazılım (Biomedical Software)
Görüntü Segmentasyonu (Image Segmentation)
Gürültü Eliminasyonu (Image Denoising)
Hibrit Sınıflayıcılar (Hybrid Classifiers)
Makine Öğrenimi (Machine Learning)
Medikal Görüntü İşleme (Medical Image Processing)
Optimizasyon (Optimization)
Örüntü Sınıflandırma (Pattern Classification)
Sınıflandırıcı Topluluklar (Ensemble Classifiers)

YABANCI DİLLER

İngilizce - İleri Seviye

YAYINLAR

Ceylan, R. ve Koyuncu, H., 2016, A New Breakpoint in Hybrid Particle Swarm-Neural Network Architecture: Individual Boundary Adjustment, *International Journal of Information Technology & Decision Making*, 15 (06), 1313-1343. (***Yüksek lisans tezinden yapılmıştır***)

Koyuncu, H. ve Ceylan, R., 2013, Artificial neural network based on rotation forest for biomedical pattern classification, *Telecommunications and Signal Processing (TSP), 2013 IEEE 36th International Conference on*, 581-585. (***Yüksek lisans tezinden yapılmıştır***)

Koyuncu, H. ve Ceylan, R., 2016, Optic Disc Segmentation with Kapur-ScPSO Based Cascade Multithresholding, *International Conference on Bioinformatics and Biomedical Engineering*, 206-215. (***Doktora tezinden yapılmıştır***)

Koyuncu, H. ve Ceylan, R., 2017b, A hybrid tool on denoising and enhancement of abdominal CT images before organ & tumour segmentation, *Electronics and Nanotechnology (ELNANO), 2017 IEEE 37th International Conference on*, 249-254.(***Doktora tezinden yapılmıştır***)

Koyuncu, H. ve Ceylan, R., 2017c, Classification of adrenal lesions by bounded PSO-NN, *Signal Processing and Communications Applications Conference (SIU), 2017 25th*, 1-4. (***Doktora tezinden yapılmıştır***)

Koyuncu, H. ve Ceylan, R., 2017a, Elimination of White Gaussian Noise in Arterial Phase CT Images to Bring Adrenal Tumours into the Forefront, *Computerized Medical Imaging and Graphics*. (***Doktora tezinden yapılmıştır***)

Koyuncu, H., Ceylan, R., Sivri, M. ve Erdogan, H., 2017, An Efficient Pipeline for Abdomen Segmentation in CT Images, *Journal of digital imaging*, 1-13. (***Doktora tezinden yapılmıştır***)

Ceylan, R. ve Koyuncu, H., 2018, ScPSO-Based Multithresholding Modalities for Suspicious Region Detection on Mammograms, *Soft Computing Based Medical Image Analysis*, 109-135. (***Doktora tezinden yapılmıştır***)

Koyuncu, H., Ceylan, R., Erdogan, H. ve Sivri, M., 2018, A Novel Pipeline for Adrenal Tumour Segmentation, *Computer methods and programs in biomedicine*. (***Doktora tezinden yapılmıştır***)