



T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MEDİKAL GÖRÜNTÜLERİN ÇOKLU
ÇÖZÜNÜRLÜK METOTLARI İLE ANALİZİ**

Hüseyin YAŞAR

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Şubat-2015
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Hüseyin YAŞAR tarafından hazırlanan “Medikal Görüntülerin Çoklu Çözünürlük Metotları ile Analizi” adlı tez çalışması 11.102/15 tarihinde aşağıdaki jüri tarafından oy birliği / ~~oy çokluğu~~ ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Prof. Dr. Ahmet ARSLAN


Üye

Doç. Dr. Seral ÖZŞEN

Danışman

Yrd. Doç. Dr. Murat CEYLAN

İmza



Yukarıdaki sonucu onaylarım.


Prof. Dr. Aşır GENÇ
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.


Hüseyin YAŞAR

Tarih: 11.02.2015

ÖZET

YÜKSEK LİSANS TEZİ

MEDİKAL GÖRÜNTÜLERİN ÇOKLU ÇÖZÜNÜRLÜK METOTLARI İLE ANALİZİ

Hüseyin YAŞAR

Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. Murat CEYLAN

2015, 118 Sayfa

Jüri

Prof. Dr. Ahmet ARSLAN

Doç. Dr. Seral ÖZŞEN

Yrd. Doç. Dr. Murat CEYLAN

Görüntü işleme, bir görüntüden yeni bir görüntünün veya görüntü içeriğinde bulunan verilerin elde edilmesi işlemlerini gerçekleştiren tüm analiz uygulamalarını kapsayan bir mühendislik alanıdır. Görüntü işlemenin en temel argümanı Fourier dönüşümüdür. Fourier dönüşümü (FD) bir boyutlu veya iki boyutlu verilerin frekans bilgisinin elde edilmesini sağlar. Zaman içinde frekans bilgisi değişmeyen sinyaller için tersine işlem uygulandığında sorunsuz olarak sinyal yeniden elde edilirken, zaman içinde frekans bilgisi değişen sinyaller için hangi frekansın hangi zaman diliminde etkin olduğu bilinemediği için tersine işlem sırasında sorun yaşanmaktadır. FD' nin zaman-frekans düzleminde ki bu yetersizliğinden dolayı çoklu çözünürlük analizlerinin temelini oluşturan dalgacık dönüşümü (DD) ortaya atılmıştır. DD, kaydırma ve ağırlıklandırma işlemleri ile sinyalin özelliklerini çıkarmaktadır. DD katsayılarının her olası kaydırma ve ağırlıklandırma değeri için hesaplanması çok fazla ve kullanılmayan veri üretilmesine neden olur. Kaydırma ve ağırlıklandırma değerlerinin ikinin katlarını temel alacak şekilde seçilmesiyle ayrık dalgacık dönüşümü (ADD) tanımlanmıştır. İki boyutlu ayrık dalgacık dönüşümünün (2BADD) tanımlanmasıyla görüntülerin analizinde de kullanılmaya başlanmıştır.

DD' nin görüntü işleme uygulamalarında üstün özellikleri olmakla birlikte eksik yönleri de vardır. DD' nin en önemli eksikliği sınırlı yönelim sorunudur. Ridgelet dönüşümü (RidD) daha fazla yönde analiz yaparak bu eksikliği ortadan kaldırmıştır. RidD' nin kartezyen koordinat sisteminde ifade edilmesiyle ayrık ridgelet dönüşümü (ARidD) tanımlanmıştır. Yönel filtre bankalarını temel alan contourlet dönüşümü (CoD) ise filtre bankaları sayesinde DD' ye göre daha fazla yön kullanarak görüntü özelliklerini daha az katsayı ile ifade etmiştir.

Curvelet dönüşümü (CuD), temeli RidD' ye dayanan etkili bir çoklu çözünürlük analizidir. CuD, pencereleme ile görüntünün daha ayrıntılı analiz edilmesine imkan sağlamıştır. Birinci nesil curvelet dönüşümü (1NCuD) olarak isimlendirilen bu versiyon, çok fazla kullanılmayan veri ürettiği için daha az parametre ile tanımlanan ikinci nesil curvelet dönüşümü (2NCuD) ortaya atılmıştır. Temeli 2NCuD' ye dayanan hızlı ayrık curvelet dönüşümü (HACuD) ise dönüşümün kompleks katsayılarının elde edilebilmesine imkan sağlamıştır. Yakın zamanda CuD, yeni parametreler kullanılarak geliştirilmiş ve ripplelet-1 dönüşümü (Rip-1D) tanımlanmıştır. Bu tez çalışması ile, HACuD ile benzer prosedürler takip edilerek hızlı ayrık ripplelet-1 dönüşümü (HARip-1D) tanımlanmış ve kompleks değerli hızlı ayrık ripplelet-1 dönüşümü (KD HARip-1D) özellik katsayıları oluşturulmuştur.

Medikal görüntü işleme önemli bir teşhis aracıdır. Medikal görüntüler, görüntüleme sırasında çözünürlüğü olumsuz etkileyen gürültülerden etkilenebilirler. Teşhis başarısının olumsuz etkilenmemesi için bu gürültülerin temizlenmesi gerekir. Tez çalışmasının ilk uygulamasında, retina ve mamografi görüntülerinde gürültü temizleme çalışması gerçekleştirilmiştir. Gürültü temizleme işlemi, bu tez

çalışması ile tanımlanan KDHARip-1D ile reel değerli hızlı ayrık ripplelet-1 dönüşümü (RDHARip-1D) özellik katsayıları kullanılarak yapılmıştır. Tepe sinyal gürültü oranı (TSGO), ortalama yapısal benzerlik indeksi (OYBİ) ve özellik benzerlik indeksi (ÖBİ) kullanılarak sonuçların karşılaştırıldığı uygulamada, KDHARip-1D' nin aynı gürültü temizleme algoritması ile kullanıldığında RDHARip-1D' ye göre daha iyi sonuçlar ürettiği görülmüştür. Uygulama sonucunda DRIVE (Digital Retinal Images for Vessel Extraction) veri tabanına ait 40 adet retina görüntüsü ile yapılan gürültü temizleme uygulamasında üç farklı sigma değeri için RDHARip-1D ile sırasıyla 33.042, 34.387, 36.322 dB TSGO elde edilirken, KDHARip-1D ile sırasıyla 33.300, 34.579, 36.443 dB TSGO elde edilmiştir. MIAS (Mammography Image Analysis Society) veri tabanına ait 322 adet mamografi görüntüsü ile yapılan gürültü temizleme uygulamasında ise üç farklı sigma değeri için RDHARip-1D ile sırasıyla 35.588, 36.714, 38.373 dB TSGO elde edilirken KDHARip-1D ile sırasıyla 35.820, 36.892, 38.488 dB TSGO elde edilmiştir. Uygulama ile elde edilen OYBİ ve ÖBİ değerleri de TSGO sonuçlarını destekler niteliktedir. Ayrıca bu uygulama ile eşikleme sabiti ve ölçek parametrelerindeki değişimin medikal gürültü temizleme sonuçları üzerindeki etkileri ilk kez incelenmiştir.

Göğüs kanseri kadınlarda yaygın görülen kanser türlerinden biridir. Bu durum göğüste meydana gelen anormalliklerin tespit ve sınıflandırılmasını önemli bir bilimsel çalışma alanı haline getirmiştir. Göğüs arka plan doku yoğunluğu, göğüs üzerinde meydana gelen anormallikleri gizleyerek teşhis ve sınıflandırmayı zorlaştırır. Tez çalışmasının ikinci uygulamasında, mamografi görüntülerinde normal-anormal doku sınıflandırılması için iki aşamalı bir sistem oluşturulmuştur. Arka plan sınıflandırma olarak isimlendirilebilecek ilk aşamada ADD, ARidD ve CoD' den elde edilen reel değerli özellik katsayıları ve yapay sinir ağı (YSA) kullanılarak teşhis yapılacak görüntüye ait göğüs arka plan doku yoğunluk tipi sınıflandırılmaktadır. Temel sınıflandırma olarak isimlendirilebilecek ikinci aşamada ise yine bu dönüşümlere ait reel değerli özellik katsayıları ve arka plan sınıflandırma sonucuna göre teşhis yapılacak görüntü ile aynı tip göğüs arka plan doku yoğunluğuna sahip görüntüler ile eğitilen YSA kullanılarak normal-anormal doku sınıflandırılması gerçekleştirilmiştir. MIAS veri tabanına ait 265 mamografi görüntüsü ile gerçekleştirilen uygulamada, arka plan sınıflandırma yapılmadan elde edilen en yüksek temel sınıflandırma başarısı % 86.04, en yüksek özgüllük 0.9686, en yüksek duyarlılık 0.5946, alıcı işlem karakteristiği (AİK) altında kalan en yüksek alan (A_z) 0.862' dir. Arka plan sınıflandırma yapılmasıyla elde edilen temel sınıflandırma sonuçları hissedilir derecede iyileşmiştir. Önerilen yöntemle yapılan sınıflandırma uygulaması sonucunda en yüksek doğruluk % 95.47 ile arka plan sınıflandırma için ADD ve YSA, temel sınıflandırma için ADD ve YSA kullanılarak elde edilmiştir. En yüksek özgüllük 1 ile arka plan sınıflandırma için CoD ve YSA, temel sınıflandırma için ADD ve YSA kullanılarak edilirken, en yüksek duyarlılık 0.8514 ile arka plan sınıflandırma için ADD ve YSA, temel sınıflandırma için ADD ve YSA kullanılarak elde edilmiştir. Uygulama sonucunda en yüksek A_z değeri 0.960 ile arka plan sınıflandırma için ADD ve YSA, temel sınıflandırma için ARidD ve YSA kullanılarak sağlanmıştır. Önerilen normal-anormal sınıflandırma sistemi, arka plan bilgilerinin radyolog veya uzman hekim tarafından sınıflandırılmasıyla, yarı otomatik olarak da gerçekleştirilebilir. Arka plan sınıflandırılmasının radyolog veya uzman tarafından yapılması yani sistemin yarı-otomatik versiyonunun kullanılması durumunda, en yüksek sınıflandırma doğruluğu ADD ve YSA kullanılarak % 97.74; en yüksek özgüllük ADD, ARidD ve YSA kullanılarak 0.9948; en yüksek duyarlılık ADD ve YSA kullanılarak 0.9324; en yüksek A_z ARidD ve YSA kullanılarak 0.974 olarak elde edilmiştir.

Anahtar Kelimeler: Contourlet Dönüşümü, Curvelet Dönüşümü, Dalgacık Dönüşümü, Gürültü Temizleme, Reel ve Kompleks Değerli Ripplelet-1 Dönüşümü, Ridgelet Dönüşümü, Sınıflama.

ABSTRACT

MS THESIS

ANALYSIS OF MEDICAL IMAGES WITH MULTI-RESOLUTION METHODS

Hüseyin YAŞAR

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
SELÇUK UNIVERSITY**

**THE DEGREE OF MASTER OF SCIENCE
IN ELECTRICAL AND ELECTRONICS ENGINEERING**

Advisor: Asst. Prof. Dr. Murat CEYLAN

2015, 118 Pages

Jury

Prof. Dr. Ahmet ARSLAN

Assoc. Prof. Dr. Seral ÖZŞEN

Asst. Prof. Dr. Murat CEYLAN

Image processing is an engineering field in which all applications of analysis, which realize the procedures of obtaining datas related to any contents of images or a new image being obtained from any image, take place. The most fundamental argument in image processing is Fourier transform. Fourier transform (FT) provides one with the frequency information of one or two-dimensional datas. When reverse processing is applied for the signals with unchanged frequency data in time, signal can be re-obtained without any problems; however, for the signals with changing frequency data in time, since the effective frequency in any time period is unknown, problems occur during reverse processing. Due to this deficiency in time-frequency plane of FT, wavelet transform (WT), which lays the basis of multi-resolution analysis, were introduced. WT extracts features of a signal using shifting and scaling. Calculating coefficients of the WT for all possible shifting and weighting values cause many unnecessary and useless datas to be produced. By choosing shifting and scaling values so as to take even frequencies basis, was defined discrete wavelet transform (DWT). The two dimensional discrete wavelet transform (2DDWT) has started to be implemented in analysis of images.

WT has superiorities as well as deficiencies on image processing applications. The major deficiency of WT is limited orientation. Ridgelet transform (RidT) has removed this deficiency analysing in more various directions. With the RidT being represented in the Cartesian coordinates, discrete ridgelet transform (DRidT) has been defined. Contourlet transform (CoT) which takes directional filter banks as basis, defines image features less numbers of coefficients using more numbers of directions than WT.

Curvelet transform (CuT) is a multi-resolution analysis of which foundation lies on the RidT. CuT helps images to be analyzed in more details using windowing. This version, called first generation curvelet transform (1GCuT) because of its producing many more unused datas caused a second generation curvelet transform (2GCuT) to be proposed, which is defined with less numbers of parameters. Fast discrete curvelet transform (FDCuT) which has its foundation on 2GCuT has allowed the complex coefficients of the transform to be obtained. Recently, the CuT has been generalized and the ripplelet-1 transform (Rip-1T) has been defined. With this paper, following similar to the FDCuT procedures, fast discrete ripplelet-1 transform (FDRip-1T) was defined and the features coefficients of the complex valued fast discrete ripplelet-1 transform (CVFDRip-1T) was constituted.

Medical image processing is an important instrumentation of diagnosis. Medical images might be affected by the noises affecting the resolution during imaging. To keep diagnosis clear of such negative factors, it is a must to clear those noises away from images. In the first application of the paper, a work was done in which the noises were denoised. Denoising was achieved using the features coefficients

of defined with this paper CVFDRip-1T and real valued fast discrete ripplelet-1 transform (RVFDRip-1T). In the application in which, peak signal-to-noise ratio (PSNR), medium structural similarity index (MSSI) and features similarity index (FSIM) were used and the results were compared, it was concluded that when used with the same algorithm of denoising, CVFDRip-1T produced better results compared to RVFDRip-1T. In the denoising application using 40 different retinal images belonging to DRIVE (Digital Retinal Images for Vessel Extraction) database, with RVFDRip-1T, for three different sigma values, there were obtained PSNR values respectively, 33.042, 34.387, 36.322 dB; with CVFDRip-1T, for three different sigma values, there were obtained PSNR values respectively, 33.300, 34.579, 36.443 dB. In the denoising application with 322 mammography images belonging to MIAS (Mammography Image Analysis Society) database, with RVFDRip-1T, for three different sigma values, there were obtained PSNR values respectively, 33.588, 36.714, 36.373 dB; with CVFDRip-1T, for three different sigma values, there were obtained PSNR values respectively, 35.820, 36.892, 38.488 dB. MSSI and FSIM values were found out to be supporting the PSNR values calculated. Besides with this paper, the effects of the change in the thresholding constant and scale parameters on the medical noise elimination were studied for the first time.

Breast cancer is one of the most widespread type of cancer among women. This situation made important study field diagnosing and classification of the anomalies in breast. Breast background tissue density causes diagnosis and classification to be more difficult, hiding any anomaly on breast. In the second application of the paper, there have been made up a two-stage system to classify mammography images as normal and abnormal. In the first classification, which could be named as background classification, the density type of the background is classified, using real valued features coefficients obtained from DWT, DRidT, CoT and artificial neural network (ANN). In the second classification though, which could be named as fundamental classification, a normal-abnormal tissue classification was done using a ANN trained by the images which have the same density of breast background tissue as the image to be diagnosed in accordance with the results obtained from the background classification and real valued features coefficients related to these types of transforms. In the applications which made use of 265 mammography images belonging to MIAS database, the highest fundamental classification achievement is % 86.04, the highest specificity 0.9686, the highest sensitivity 0.5946 and the highest area under the receiver operating characteristic (A_z) is 0.862 without making background classification. Through the background classification results obtained from the fundamental classification improved fairly. As a result of the application of the classification that was made using the proposed method, it was found out that the highest accuracy % 95.47 was obtained through DWT and ANN for the background classification, through DWT and ANN for the fundamental classification. The highest specificity 1 was obtained through CoT and ANN for the background classification, through DWT and ANN for the fundamental classification while the highest sensitivity 0.8514 was obtained through DWT and ANN for the background classification, through DWT and ANN for the fundamental classification. The application has led to the conclusion that the highest A_z 0.960 was obtained through DWT and ANN for the background classification, through DRidT and ANN for the fundamental classification. The system of classification, offered in this paper as normal and abnormal could be realized by a radiologist or physician, classifying the datas related to the background semi-automatically. By this choice of using semi-automatic classification version, the highest accuracy of classification % 97.74 was obtained through DWT and ANN, the highest specificity 0.9948 was obtained through DWT, DRidT and ANN, the highest sensitivity 0.9324 was obtained through DWT and ANN, the highest A_z 0.974 was obtained through the DRidT and ANN.

Keywords: Classification, Contourlet Transform, Curvelet Transform, Denoising, Real and Complex Valued Ripplelet-1 Transform, Ridgelet Transform, Wavelet Transform.

ÖNSÖZ

Bütün çalışmalarında değerli bilgi ve tecrübeleriyle bana yol gösteren, gerekli araştırma ve geliştirme çabalarında yardımlarını esirgemeyen danışmanım Selçuk Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği öğretim üyesi Yrd. Doç. Dr. Murat CEYLAN' a, bölümümüzün değerli tüm öğretim elemanlarına, her türlü maddi manevi katkılarını esirgemeyen eşim İmren DAŞDEMİR YAŞAR, annem Hatice YAŞAR, babam Mustafa YAŞAR' a ve öğrenci arkadaşlarıma teşekkür ederim.

Hüseyin YAŞAR
KONYA-2015

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	vi
ÖNSÖZ	viii
İÇİNDEKİLER	ix
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
1.1. Tez Konusunun Tanıtılması	2
1.2. Tez Çalışmasının Önemi ve Amacı.....	3
1.3. Tez Konusunda Yapılan Çalışmaların Tarihsel Gelişimi.....	4
2. ÇOKLU ÇÖZÜNÜRLÜK ANALİZLERİ.....	13
2.1. Dalgacık Dönüşümü	13
2.1.1. Bir boyutlu dalgacık dönüşümü	13
2.1.2. İki boyutlu dalgacık dönüşümü.....	16
2.2. Ridgelet Dönüşümü	18
2.2.1. Sürekli ridgelet dönüşümü	18
2.2.2. Ayırık ridgelet dönüşümü	19
2.3. Curvelet Dönüşümü	20
2.3.1. Birinci nesil curvelet dönüşümü	21
2.3.2. İkinci nesil curvelet dönüşümü	25
2.3.3. Hızlı ayırık curvelet dönüşümü.....	27
2.4. Contourlet Dönüşümü.....	28
2.5. Ripplet-1 Dönüşümü.....	32
2.5.1. Sürekli ripplet-1 dönüşümü	32
2.5.2. Ayırık ripplet-1 dönüşümü.....	33
2.5.3. Hızlı ayırık ripplet-1 dönüşümü.....	33
2.5.4. Kompleks değerli hızlı ayırık ripplet-1 dönüşümü	35
3. YAPAY SİNİR AĞI.....	37
3.1. Geri Yayılım Yapay Sinir Ağı	38
3.1.1. Gradyan iniş metodu	38
3.1.2. İleri besleme.....	39
3.1.3. Hata fonksiyonu ve ağırlıkların güncellenmesi	40
4. ARAŞTIRMA SONUÇLARI.....	42
4.1. Medikal görüntülerden gürültü temizleme uygulaması	42
4.1.1. Uygulamada kullanılan görüntüler	42

4.1.2. Sonuçlarının değerlendirilmesinde kullanılan performans kriterleri	43
4.1.3. Uygulamada kullanılan gürültü temizleme yapıları.....	45
4.1.4. Gürültü temizleme	47
4.1.5. Uygulama sonuçları	47
4.2. Göğüs mamografi görüntülerinden normal-anormal doku sınıflandırılması uygulaması	58
4.2.1. Uygulamada kullanılan görüntüler	58
4.2.2. Sonuçlarının değerlendirilmesinde kullanılan performans kriterleri	60
4.2.3. Uygulamada kullanılan sınıflandırma yapıları ve sınıflandırma	61
4.2.4. Uygulama sonuçları	63
5. TARTIŞMA VE ÖNERİLER	74
5.1 Tartışma	74
5.1.1. Medikal görüntülerden gürültü temizleme uygulaması	74
5.1.2. Göğüs mamografi görüntülerinden normal-anormal doku sınıflandırılması uygulaması	77
5.2 Öneriler	80
5.2.1. Medikal görüntülerden gürültü temizleme uygulaması	80
5.2.2. Göğüs mamografi görüntülerinden normal-anormal doku sınıflandırılması uygulaması	80
KAYNAKLAR	82
EKLER	91
ÖZGEÇMİŞ	102

SİMGELER VE KISALTMALAR

Simgeler

A_z	: AİK Eğrisi Altında Kalan Alan
f	: Frekans
t	: Zaman
τ	: KZFD Zaman Kayması
a	: Ölçek Operatörü
b	: Kayma (Konum) Operatörü
ψ	: Ana DD Fonksiyonu
Ψ	: Ana DD Fonksiyonun Fourier Dönüşümünü
a_0	: ADD Genişletme Adımı
b_0	: ADD Çevirme Adımı
φ	: ADD Ölçekleme Fonksiyonu
Ψ	: Ana RidD Fonksiyonu
θ	: RidD Yön (Açı) Operatörü
δ	: Dirac Dağılımı
P_0	: 1NCuD Alçak Geçiren Katman
Δ_s	: 1NCuD Yüksek Geçiren Katmanlar
w_Q	: 1NCuD Düzgün Bölümleme Penceresi
h_Q	: 1NCuD Frekans Katmanı ve Bölümlere Ayrılmış Görüntü
T_Q	: 1NCuD Normalizasyon Operatörünü
g_Q	: 1NCuD Normalize Edilmiş Görüntü
2^{-j}	: 2NCuD Ölçek Operatörü
θ_l	: 2NCuD ve ARip-1D Yön (Açı) Operatörü
$x_k^{j,l}$	: 2NCuD Konum Operatörü
$\varphi_{j,k,l}$	: Ana 2NCuD Fonksiyonu
$\hat{\varphi}_j(v)$	: Ana 2NCuD Fonksiyonunun Fourier Dönüşümü
$\hat{w}$	: 2NCuD Radyal Pencere
$\hat{v}$	: 2NCuD Açısal Pencere

$\hat{w}_j(v)$	: 2NCuD Radyal ve Açısal Pencerelelerin Kartezyen Eşdeğeri
$H_j(v)$	: 2NCuD Ayrık Bant Geçiren Pencere
S_θ	: Kesme Matrisi
2^l	: CoD Alt Frekans Bölümleri
ρ	: Ana Rip-1D Fonksiyonu
c	: Rip-1D Destek Operatörü
d	: Rip-1D Derece Operatörü
$\hat{\rho}$	: Ana Rip-1D Fonksiyonun Fourier Dönüşümü
R_θ	: Rotasyon Matrisi
a_j	: ARip-1D Ölçek Operatörü
$\bar{b}_k$	: ARip-1D Konum Operatörü
$R_{j,\bar{k}l}$	: ARip-1D Özellik Katsayı Fonksiyonu
$r_{j,k,l}$	: Sayısal Rip-1D Özellik Katsayı Fonksiyonu
η	: YSA Adım Katsayısı
Z_i	: YSA Nöron Girişi
$W_{z,i}$	: YSA Ağırlık Katsayısı
g	: YSA Aktivasyon Fonksiyonu
$Y_{Ağ}$	: YSA Ağ Fonksiyonu
$Y_{Çıkış}$	: YSA Çıkış Fonksiyonu
$B_{Çıkış}$	: YSA Beklenen Çıkış
H	: YSA Hata Fonksiyonu
$TSGO(f, g)$	: TSGO Benzerlik Fonksiyonu
$KOH(f, g)$	: KOH Benzerlik Fonksiyonu
$l(x, y)$	: YBİ Parlaklık Bozulması Bileşeni
$c(x, y)$	: YBİ Kontrast Bozulması Bileşeni
$s(x, y)$	: YBİ Korelasyon Bileşeni
$\bar{x}, \bar{y}$	: YBİ x ve y ' nin Lokal Ortalamaları
s_x^2, s_y^2	: YBİ x ve y ' nin Lokal Varyansları
$s_{x,y}$	: YBİ x ve y arasındaki Kovaryans
$S_1(x, y)$	: YBİ 1. Yerel Pencere

$S_2(x, y)$	: YBİ 2. Yerel Pencere
$YBI(x, y)$	: YBİ Benzerlik Fonksiyonu
$OYBI(x, y)$	: OYBİ Benzerlik Fonksiyonu
FK	: ÖBİ Faz Konfigürasyonu
GB	: ÖBİ Gradyan Büyüklüğü
$S_L(x)$	: ÖBİ Benzerlik Ölçüsü
G_x	: ÖBİ Görüntünün Yatay Yön Boyunca Türevi
G_y	: ÖBİ Görüntünün Dikey Yön Boyunca Türevi
Ω	: ÖBİ Görüntü Boyutu
$ÖBI(x)$	: OYBİ Benzerlik Fonksiyonu
$Sigma$	: Gürültü Oranı
I_n	: Gürültülü Görüntü
N	: Gürültü
N_r	: Rastgele Gürültü
$T(j, l)$	: Sert Eşikleme Fonksiyonu
$M_k(j, l)$	: Sert Eşikleme Özellik Katsayıları
$\hat{M}_k(j, l)$	: Sert Eşikleme Sonuç Fonksiyonu
σ	: Beyaz Gürültü Standart Sapması
k	: Eşikleme Katsayısı
$\mathcal{E}_{(j, l)}$	: Beyaz Gürültü Ortalama Enerji Dağılımı

Kısaltmalar

1BHTFD	: Bir Boyutlu Hızlı Ters Fourier Dönüşümü
1NCuD	: Birinci Nesil Curvelet Dönüşümü
2BHTFD	: İki Boyutlu Hızlı Ters Fourier Dönüşümü
2BHFD	: İki Boyutlu Hızlı Fourier Dönüşümü
2BADD	: İki Boyutlu Ayrık Dalgacık Dönüşümü
2NCuD	: İkinci Nesil Curvelet Dönüşümü
ADD	: Ayrık Dalgacık Dönüşümü
AGÖ	: Ardışık Geliştirmeli Öğrenme
AİK	: Alıcı İşlem Karakteristiği
ARidD	: Ayrık Ridgelet Dönüşümü
BBA	: Bağımsız Bileşen Analizi
BDT	: Bilgisayar Destekli Teşhis
CuD	: Curvelet Dönüşümü
CoD	: Contourlet Dönüşümü
DD	: Dalgacık Dönüşümü
DDA	: Doğrusal Diskriminant Analizi
DN	: Doğru Negatif
DP	: Doğru Pozitif
DRIVE	: Digital Retinal Images for Vessel Extraction
DVM	: Destek Vektör Makinesi
FD	: Fourier Dönüşümü
GSEM	: Gri Seviye Eş-oluşum Matrisi
GSHM	: Gri Seviye Histogram Momenti
HACuD	: Hızlı Ayrık Curvelet Dönüşümü
HARip-1D	: Hızlı Ayrık Ripplet-1 Dönüşümü
k-EYK	: k-En Yakın Komşu
KDHARip-1D	: Kompleks Değerli Hızlı Ayrık Ripplet-1 Dönüşümü
KOH	: Karesel Ortalama Hata
KZFD	: Kısa Zamanlı Fourier Dönüşümü
LP	: Laplas Pramidi
MGSB	: Mekansal Gri Seviye Bağımlılığı
MIAS	: Mammography Image Analysis Society

OSA	: Olasılıksal Sinir Ağı
OYBİ	: Ortalama Yapısal Benzerlik İndeksi
ÖBİ	: Özellik Benzerlik İndeksi
PSO	: Parçacık Sürü Optimizasyonu
RaD	: Radon Dönüşümü
RidD	: Ridgelet Dönüşümü
RDHARip-1D	: Reel Değerli Hızlı Ayrık Ripplet-1 Dönüşümü
Rip-1D	: Ripplet-1 Dönüşümü
RTFSA	: Radyal Taban Fonksiyonlu Sinir Ağı
SDD	: Sürekli Dalgacık Dönüşümü
SRidD	: Sürekli Ridgelet Dönüşümü
SRip-1D	: Sürekli Ripplet-1 Dönüşümü
TBA	: Temel Bileşen Analizi
TSGO	: Tepe Sinyal Gürültü Oranı
YFK	: Yönsel Filtre Kümesi
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağı

1. GİRİŞ

Görüntü işleme, görüntüler üzerinde çeşitli işlemlerin yapılarak yeni görüntülerin elde edilmesini içeren ve üzerinde yoğun olarak çalışılan bir mühendislik alanıdır (Karakoç, 2011). Görüntü işleme, sayısal görüntü kaydının kolaylaşmasıyla günümüzde önemini giderek artırmaktadır. Görüntü işleme teknikleri yüz, parmak izi tanıma gibi güvenlik sistemlerinden, elektromanyetik radar sistemleri, medikal sistemler, yer ve gök bilimi araştırmaları, haritalama ve kontrol sistemlerine kadar değişik alanlarda kullanılmaya başlanmıştır.

Medikal görüntüleme ve medikal görüntülerin analizi, hastalıkların teşhisinde oldukça önemli bir yere sahiptir. Medikal görüntülerin analizi, bu süreçte yer alan uzman radyolog veya hekimler için önemli bir iş yüküdür. Medikal görüntü işleme, iki boyutlu verileri daha kolay değerlendirilebilir hale getirerek uzman personelin iş yükünü hafifletmeyi amaçlar.

Tez çalışmasında medikal görüntülerin analizi için kullanılan mevcut dönüşümlerin incelenmesinin yanı sıra yeni dönüşüm metotları da geliştirilmiştir. Tüm bu metotlar iki temel uygulama ile karşılaştırmalı olarak incelenmiştir. Tez çalışması beş ana bölümden oluşmaktadır. Birinci bölümde, tez konusunun tanıtımı yapılmış, tezin amacı ve önemi açıklanmıştır. Ayrıca, bu alanda yapılmış çalışmaların tarihsel gelişimine yer verilmiştir. İkinci bölümde, çoklu çözünürlük analizleri üzerinde durulmuştur. Bu kapsamda dalgacık dönüşümü (DD), ridgelet dönüşümü (RidD), curvelet dönüşümü (CuD), contourlet dönüşümü (CoD) ve ripplelet-1 dönüşümü (Rip-1D) incelenmiştir. Üçüncü bölümde ise yapay sinir ağı (YSA) irdelenmiştir.

Dördüncü bölümde, tezde kullanılan görüntüler ile ilgili bilgiler verilmiştir. Ayrıca bu bölümde, retina ve mamografi görüntülerinden gürültü temizleme ile mamografi görüntülerinden normal-anormal doku sınıflandırılması üzerine önerilen yapılar ve elde edilen uygulama sonuçları değerlendirilmiştir. Beşinci ve son bölümde ise gerçekleştirilen çalışmanın sonuçları irdelenmiş, literatürde yer alan çalışmalar ile karşılaştırma yapılmıştır. Ayrıca, tez çalışmasında önerilen yapıların avantajları ve dezavantajları tartışılmıştır. Tez çalışmasından sonra gerçekleştirilecek olan ileriye yönelik çalışmalar için önerilerde bulunulmuştur.

1.1. Tez Konusunun Tanıtılması

Gerçekleştirilen tez çalışmasının ilk uygulamasında; retina ve mamografi görüntülerinde gürültü temizleme çalışması gerçekleştirilmiştir. Gürültü temizleme için reel değerli hızlı ayırık ripplet-1 dönüşümü (RDHARip-1D) ve kompleks değerli hızlı ayırık ripplet-1 dönüşümü (KDHARip-1D) kullanılmıştır. Bu uygulama ile yakın zamanda ortaya atılan ve reel değerli özellik katsayıları birçok görüntü işleme uygulamasında kullanılan Rip-1D' nin hızlı ayırık versiyonu tanımlanmış ve ilk defa kompleks değerli özellik katsayıları oluşturulmuştur. Tez çalışmasının bu uygulaması ile retina ve mamografi görüntülerinin elde edilmesi sırasında meydana gelebilen gürültülerin, teşhis sonuçları üzerinde yarattığı olumsuz etkiler azaltılmıştır.

Retina ve mamografi görüntülerinden gürültünün temizlenmesi için yapılan birinci uygulama iki aşamadan oluşmaktadır. Bu uygulamanın ilk aşamasında kullanılacak gürültülü görüntü örneklerini elde etmek için retina ve mamografi görüntülerine 15, 25 ve 35 olmak üzere üç farklı sigma değerine sahip rastgele gürültü uygulanmıştır. Daha sonra gürültülü görüntüler ile orijinal görüntüler arasındaki tepe sinyal gürültü oranı (TSGO) hesaplanarak orijinal görüntülerin ne kadar bozulduğu tespit edilmiştir. İkinci aşamada ise gürültülü retina ve mamografi görüntüleri RDHARip-1D ve KDHARip-1D ile elde edilen özellik katsayıları kullanılarak temizlenmiştir. Temizlenen görüntüler ile orijinal görüntüler arasındaki TSGO, ortalama yapısal benzerlik indeksi (OYBİ) ve özellik benzerlik indeksi (ÖBİ) hesaplanarak temizleme işleminin başarısı test edilmiştir.

Tez çalışmasının ikinci uygulamasında mamografi görüntülerinden normal ve anormal dokuların sınıflandırılmasını gerçekleştiren bir sistem önerilmiştir. Ayırık dalgacık dönüşümü (ADD), ayırık ridgelet dönüşümü (ARidD), CoD ve YSA kullanılarak önerilen sistem ile mamografi görüntülerini yorumlayan radyoloji uzmanlarına ve kesin tanı koymak / tanıyı desteklemek için ihtiyaç duyulan biyopsi işlemini gerçekleştiren uzmanlara yardımcı olabilecek yeni ve akıllı bir bilgisayar destekli teşhis (BDT) sistemi tasarlanmıştır. Bu yeni sistem ile mamografi görüntülerini değerlendiren uzman yorumlarından önce bir ön değerlendirme yapılarak, karar verme aşamasına destek olunması hedeflenmiştir.

Mamografi görüntülerinden normal ve anormal dokuların sınıflandırıldığı bu uygulama iki aşamadan oluşmaktadır. İlk aşamada ADD, ARidD ve CoD' den elde edilen reel değerli özellik katsayıları ile YSA kullanılarak mamografi görüntülerine ait

göğüs arka plan doku yoğunluk tipinin sınıflandırılması gerçekleştirilmiştir. İkinci aşamada ise yine ADD, ARidD ve CoD' den elde edilen reel değerli özellik katsayıları ile YSA kullanılarak normal ve anormal dokuların sınıflandırılması yapılmıştır. İkinci aşamada yararlanılan YSA' nın eğitiminde kullanılan görüntüler birinci aşamada elde edilen göğüs arka plan doku yoğunluk tipinin sınıflandırma sonuçlarına göre seçilmektedir. Bu kaskat sistem sayesinde normal ve anormal sınıflandırılmasına tabi tutulan görüntüler, kendileri ile aynı tip göğüs arka plan doku yoğunluğuna sahip görüntüler kullanılarak eğitilmiş YSA ile sınıflandırılmıştır. Bu kaskat sınıflandırma yapısı, göğüs arka plan doku yoğunluğunun teşhis ve sınıflandırma üzerindeki olumsuz etkilerini azaltmaktadır.

1.2. Tez Çalışmasının Önemi ve Amacı

Medikal görüntüler, tıp alanında önemli bir teşhis aracıdır. Bu görüntüler genellikle görüntüleme esnasında oluşan rastgele gürültülerden etkilenirler. Gürültüler, görüntü üzerindeki çözünürlüğü ve kaliteyi düşüren yapılardır. Bu yapılar teşhis başarısını olumsuz etkilemektedir. Medikal görüntülerden gürültü temizleme, görüntünün elde edilmesi sırasında oluşan gürültüleri temizleyerek görüntünün orijinalliğini korumasını amaçlar. Bu tez çalışmasının birinci uygulamasında retina ve mamografi görüntülerinden gürültü temizleme yapılmıştır. RDHARip-1D ve KDHARip-1D' nin gürültü temizleme başarıları test edilmiştir. Görüntü üzerinde farklı yoğunlukta gürültülerin oluşabileceği düşünülerek çalışma; 15, 25 ve 35 olmak üzere üç farklı sigma değerine sahip rastgele gürültü ile gerçekleştirilmiştir. Çalışmalar sonucunda retina ve mamografi görüntülerinden gürültü temizleme konusunda önemli kazanımlar sağlanmıştır. Ayrıca bu tez çalışması ile daha önce sürekli ve ayırık versiyonu ile birçok uygulama gerçekleştirilen Rip-1D dönüşümünün hızlı ayırık versiyonu tanımlanmış, tanımlanan bu yeni versiyon sayesinde ilk defa kompleks değerli özellik katsayıları elde edilerek literatüre kazandırılmıştır.

Kanser değişik organlarda hücrelerin kontrolsüz çoğalmasıyla oluşan bir hastalıklar grubudur. Göğüs kanseri kadınlarda yaygın görülen kanser türlerinden biridir. Dünya Sağlık Örgütü Kanser Araştırmaları Ajansının tahminlerine göre her yıl 150.000 kadın göğüs kanseri yüzünden hayatını kaybetmektedir. Türkiye Halk Sağlığı Kurumunun yapmış olduğu Türkiye Kanser İstatistiklikleri (2014) önemli bilgilere yer vermektedir. Bu yayında yer alan 2009 yılı Türkiye birleşik veri tabanı bilgilerine göre

kadınlarda en sık görülen kanser türü yüz binde 40.6 ile göğüs kanseridir. Ülkemizin tıp alanında sahip olduğu kısıtlı maddi imkanlar ve yetişmiş uzman sayısındaki yetersizlikler düşünüldüğünde mamografi görüntülerinden normal-anormal doku sınıflandırılmasının yüksek doğruluk oranı ile gerçekleştirildiği yeni BDT sistemlerinin önerilmesi oldukça önemlidir. Bu tez çalışmasının ikinci uygulamasında ADD, ARidD ve CoD' den elde edilen reel değerli özellik katsayıları ve YSA kullanılarak normal ve anormal göğüs dokularının sınıflandırılması yapılmıştır. Elde edilen sonuçlar yeni ve etkili bir BDT sistemi tasarlandığını göstermektedir. Bu yeni BDT sistemi ile hem radyolog kararlarını hem de radyolog kararlarına uygun olarak kesin teşhisi koymak için başvuru biyopsi işlem sonucunu desteklemek ve ön-tanı koymak mümkün olacaktır. Tez çalışması ile radyologun veya biyopsi uzmanının kararlarına destek olabilecek bir mekanizma oluşturulmuştur.

1.3. Tez Konusunda Yapılan Çalışmaların Tarihsel Gelişimi

Fourier dönüşümü (FD) sinyal veya görüntünün frekans bilgisinin elde edilmesini sağlar. Zaman içinde frekans bilgisi değişmeyen sinyaller için tersine işlem uygulandığında sorunsuz olarak sinyal yeniden elde edilirken, zaman içinde frekans bilgisi değişen sinyaller için hangi frekansın hangi zaman diliminde etkin olduğu bilinemediği için tersine işlem sırasında sorun yaşanmaktadır (Polikar, 1996). FD' nin zaman-frekans düzleminde ki bu yetersizliğinden dolayı çoklu çözünürlük analizlerinin temelini oluşturan DD ortaya atılmıştır.

Çoklu çözünürlük analizlerinin temelini oluşturan DD' nin dayandığı birçok altyapı vardır. Sürekli dalgacık dönüşümü (SDD) ilk olarak Morlet ve arkadaşları (1982) tarafından jeofizik alanında uygulanmıştır. Grossmann ve Morlet (1984) tarafından yine bu alanda çalışmalar yapılmıştır. Ancak DD' nin temelleri Chui (1992) ve Meyer (1993) tarafından sağlamlaştırılmıştır. Dönüşümün ayrık yorumu Mallat (1989) ve Daubechies (1992) tarafından geliştirilmiştir. Dalgacık paket analizi, ADD' nin geliştirilmiş hali olup Coifman ve Wickerhauser (1992) tarafından ortaya atılmıştır. Mojsilovic ve arkadaşları (1996) tarafından yapılan çalışma ile DD medikal görüntülere uygulanmaya başlanmıştır.

DD' de sadece yatay, dikey ve 45^0 yönleri için analiz yapılmakta olup bu durum önemli bir dezavantaj oluşturmaktadır. Bu olumsuz durumu ortadan kaldırmak için farklı açısall yönler üzerinde işlem yapılan RidD, Candes ve Donoho (1999) tarafından

ortaya atılmıştır. DD' yi temel alan fakat ondan farklı olarak doğrulardan çok eğrileri temsil etmeyi amaçlayan CuD, yine Candes ve Donoho (2000) tarafından tanımlanmıştır. CuD, temel olarak RidD üzerine inşa edilmiştir. CuD alt bantlara ayrıştırma, düzgün bölümlendirme, renormalizasyon ve RidD olmak üzere dört basamaktan oluşmaktadır. CuD, çok yaygın bir etki yaratmakla birlikte ilk versiyonu çok fazla ve kullanılmayan veri üretmektedir. Bu durum işlem yükünü artırıp hızını azaltmaktadır. Bu olumsuz durumu ortadan kaldırmak için Candes ve Guo (2002) tarafından ikinci nesil curvelet dönüşümünün (2NCuD) tanımlanmasına yönelik çalışmalar yapılmıştır. İlerleyen yıllarda Candes ve arkadaşları (2005) tarafından temeli 2NCuD' ye dayanan hızlı ayırık curvelet dönüşümü (HACuD) geliştirilmiştir.

Do ve Vetterli (2005) tarafından bir başka çoklu çözünürlük analizi olan CoD' nin temelleri atılmıştır. CoD' nin ilk bölümünde görüntü Laplas dönüşümü ile katmanlarına ayrılmaktadır. İkinci bölümde ise görüntü katmanları filtre bankalarından geçirilmektedir. Burada kullanılan filtre bankası yapısı, ADD' deki alçak geçiren filtre-yüksek geçiren filtre blokları mantığına dayanmaktadır.

Özellikle son yıllarda sıklıkla kullanılan DD, RidD, CuD ve CoD, çoklu çözünürlük analizleri içinde temel bir yere sahip olmuştur. Bununla birlikte, kısa zaman içerisinde en az bu temel dönüşümler kadar etki yaratabilecek potansiyele sahip yeni dönüşümler de ortaya atılmıştır. Xu ve arkadaşları (2010) tarafından bu kapsamda ele alınabilecek Rip-1D tanımlanmıştır. Rip-1D, CuD' nin geliştirilmiş halidir. Bu dönüşümde CuD' de tanımlanan parametrelere ek olarak c (destek) ve d (derece) parametresi eklenmiştir. Literatürde, kısa zamanda Rip-1D' yi kullanan birçok çalışma gerçekleştirilmiştir. 2011 yılında Das ve arkadaşları, 2012 yılında Kavutka ve arkadaşları tarafından yapılan medikal görüntü füzyonu çalışmasında Rip-1D kullanılmıştır. 2012 yılında Silvia ve Poovizhi retina görüntülerinden damar yapılarının elde edilmesinde Rip-1D' den yararlanmıştır. Aynı yıl Muhammady ve arkadaşları tarafından Rip-1D tabanlı doku sınıflandırma uygulaması yapılmıştır. 2013 yılında Quraishi ve arkadaşları Rip-1D tabanlı yüz tanıma uygulaması gerçekleştirmiştir. Aynı yıl Sasheendran ve Bhuvaneswari tarafından temeli Rip-1D' ye dayanan içerik tabanlı görüntü algılama algoritması oluşturulmuştur. 2014 yılında Yaşar ve Ceylan (2014-a) Rip-1D' yi kullanarak görüntü şifreleme ve filigranlama çalışması yapmıştır.

Görüntülerden gürültü temizleme üzerinde yaygın olarak çalışılan bir görüntü işleme alanıdır. Çoklu çözünürlük analizlerinin gelişimine paralel olarak bu alanda da önemli gelişmeler yaşanmıştır. Çoklu çözünürlük analizlerin temelini oluşturan DD

özellik katsayıları ve farklı gürültü temizleme algoritmaları kullanılarak birçok başarılı gürültü temizleme uygulaması gerçekleştirilmiştir (Reider ve Hossek, 1997; Pu-chun ve ark., 2001; Zhai ve Zhang, 2005; Li ve Zhu, 2006; Junli ve ark., 2007; Hongqiao ve Shengqian, 2009; Wang ve ark., 2010; Chen ve ark., 2012).

İlerlen yıllarda DD' ye göre daha üstün özellikleri bulunan CuD tanımlanmıştır. Starck ve arkadaşları (2002) tarafından yapılan çalışmada CuD' nin gürültü temizleme için DD' den daha iyi sonuçlar ürettiği ortaya konulmuştur. Bunu takip eden birçok çalışmada da aynı yargıyı destekler nitelikte sonuçlar elde edilmiştir (Sivakumar, 2007; Ma ve ark., 2007; Reddy ve ark., 2008; Patil ve Singhai, 2010; Binh ve Khare, 2010; Shukla ve Changlani, 2013).

Çoklu çözünürlük analizlerinin ilk versiyonlarının en önemli dezavantajı faz bilgisinin eksikliğidir. Faz bilgisinin eksikliği, analiz yapılan yön sayısını kısıtlamaktadır. Lawton (1993) ve Lina (1998), ADD' nin kompleks formda uygulanabileceğini göstermiştir. Selesnick ve arkadaşlarının (2005), iki benzer modelle (Kingsbury'in ve Selesnick'in modelleri), çift-ağaç ayırık tabanlı kompleks değerli DD' yi tanımlamasıyla, reel değerli DD' nin kısıtlı yönelim sorununu aşmaya yönelik bir çalışma ortaya konmuştur. Kompleks değerli DD' nin, reel değerli DD' ye göre gürültü temizleme uygulamalarında (Baradarani ve Runyi, 2007; Yang ve ark., 2008; Song ve YuanPeng, 2009; Yaşar ve ark., 2013) daha iyi sonuçlar ürettiği görülmüştür.

Xu ve arkadaşları (2010) tarafından CuD genelleştirilerek Rip-1D tanımlanmıştır. Ayrıca, bu çalışma ile reel değerli özellik katsayıları kullanılarak gürültü temizleme uygulaması yapılmış, destek ve derece parametrelerinin farklı değerleri için sonuçlar karşılaştırılmıştır. İlerleyen yıllarda, Gupta ve arkadaşları (2014) reel değerli ayırık Rip-1D özellik katsayılarını kullanarak medikal görüntülerden gürültü temizleme uygulaması gerçekleştirmiştir.

Suckling ve arkadaşları tarafından (1994) göğüs görüntüleri üzerine araştırmaları yaygınlaştırmak ve kolaylaştırmak amacıyla kısaca MIAS (Mammography Image Analysis Society) olarak bilinen bir veri tabanı oluşturulmuştur. MIAS veri tabanı; arka plan doku yoğunluk tipi sınıflandırılması, normal-anormal dokuların sınıflandırılması, iyi ve kötü huylu tümör sınıflandırılması, tümör tespit sistemleri gibi konularda yapılan birçok çalışmada kullanılmıştır.

Literatürde yağlı (fatty), yağlı-bezeli (fatty-glandular) ve yoğun (dense-glandular) olmak üzere üç adet yoğunluk tipini esas alan ve MIAS veri tabanı görüntülerinin kullanıldığı birçok göğüs arka plan sınıflandırma çalışması

gerçekleştirilmiştir. 1996 yılında Gulrud ve Loland tarafından yapılan sınıflandırma çalışmasında karesel aynalama filtreleri kullanılarak çıkarılan görüntü özellikleri öğrenmeli vektör kuantalama ile sınıflandırılmıştır. MIAS veri tabanına ait 5 adet yağlı, 7 adet yağlı-bezeli, 7 adet yoğun olmak üzere toplam 19 adet görüntünün kullanıldığı çalışma sonucunda % 73.68 sınıflandırma başarısı elde edilmiştir. Blot ve Zwiggelaar tarafından 2001 yılında yapılan çalışmada ise lokal ve ortalama özellik matrisleri arasındaki farklardan yararlanılmıştır. Karssemeijer model sınıflandırıcı kullanılan çalışma MIAS veri tabanına ait 75 adet yağlı, 95 adet yağlı-bezeli, 95 adet yoğun olmak üzere toplam 265 adet görüntü ile test edilmiştir. Çalışma sonucunda % 65 başarı ile sınıflandırma yapılmıştır.

2005 yılında Oliver ve arkadaşları arka plan sınıflandırma için k-en yakın komşu (k-EYK) sınıflandırıcıdan yararlanmıştır. MIAS veri tabanına ait 90 adet yağlı, 90 adet yağlı-bezeli, 90 adet yoğun olmak üzere toplam 270 adet görüntü kullanılarak test edilen çalışma sonunda sınıflandırma başarısı % 73 olarak gerçekleşmiştir. Muhimmah ve Zwiggelaar tarafından 2006 yılında yapılan çalışmada ise sınıflandırıcı olarak destek vektör makinesi (DVM) kullanılmıştır. MIAS veri tabanına ait 1 adet yoğun görüntü haricinde toplam 321 adet görüntü ile test edilen çalışma sonucunda % 77.57 sınıflandırma başarısı sağlanmıştır.

2010 yılında Subashini ve arkadaşları ön işleme, özellik çıkarma, sınıflandırma olmak üzere üç basamaktan oluşan bir sınıflandırma sistemi önermiştir. Sınıflandırıcı olarak DVM kullanılan çalışmada MIAS veri tabanına ait 14 adet yağlı, 14 adet yağlı-bezeli, 15 adet yoğun olmak üzere toplam 43 adet görüntü kullanılmıştır. Çalışma sonucunda % 95.44 sınıflandırma başarısı sağlanmıştır. Tzikopoulos ve arkadaşları tarafından 2011 yılında yapılan sınıflandırma çalışmasında ise 21 adet görüntü özelliği ve DVM kullanılmıştır. MIAS veri tabanındaki bütün görüntüler (322 adet görüntü) kullanılarak test edilen çalışma sonucunda sınıflandırma başarısı % 85.70 olarak gerçekleşmiştir. 2012 yılında Mustra ve arkadaşları arka plan sınıflandırma için iki aşamalı bir sistem önermiştir. Sistemin birinci aşamasında 7 adet görüntü özelliği çoklu seçim yapılarak gruplandırılmış ve görüntülere ait özellikler elde edilmiştir. Sistemin ikinci aşamasında ise k-EYK kullanılarak görüntüler sınıflandırılmıştır. Önerilen sistem MIAS veri tabanındaki bütün görüntüler kullanılarak test edilmiş ve çalışma sonucunda % 82.5 sınıflandırma başarısı sağlanmıştır. Aynı yıl Liasis ve arkadaşları tarafından yapılan bir başka sınıflandırma çalışmasında DVM sınıflandırıcı kullanılmıştır. Çalışmada, ölçek değişmezliği özellik dönüşümü, yerel ikili örüntü ve histogram

yöntemleri kombine edilerek görüntü özellikleri elde edilmiştir. MIAS veri tabanına ait 62 adet yağlı, 62 adet yağlı-bezeli ve 62 adet yoğun olmak üzere toplam 186 adet görüntünün kullanıldığı çalışma sonucunda sınıflandırma başarısı % 93.54 olarak gerçekleşmiştir. Aynı yıl Silva ve Menotti arka plan sınıflandırması için temel bileşen analizini (TBA) kullanmıştır. MIAS veri tabanına ait 2 adet yağlı görüntü haricindeki 320 adet görüntünün kullanıldığı çalışmada % 77.18 başarı sağlanmıştır. 2013 yılında Petroudi ve arkadaşları genlik ve frekans modülasyonu kullanarak elde edilen görüntü özelliklerini k-EYK ile sınıflandırmıştır. MIAS veri tabanına ait 62 adet yağlı, 62 adet yağlı-bezeli, 62 adet yoğun olmak üzere toplam 186 adet görüntüden yararlanılan çalışmada sınıflandırma başarısı % 84.00 olarak gerçekleşmiştir.

Yaşar ve Ceylan (2014-b), arka plan sınıflandırma için üç aşamalı bir sistem önermiştir. Önerilen sistemin birinci aşamasında görüntülere ADD ve CuD uygulanmıştır. İkinci aşamada birinci aşamada elde edilen özellik matrislerinden minimum değer, maksimum değer, ortalama değer ve standart sapma olmak üzere görüntü özellikleri hesaplanmıştır. Son aşamada ise görüntü özellikleri YSA kullanılarak sınıflandırılmıştır. MIAS veri tabanındaki bütün görüntüler kullanılarak test edilen sınıflandırma sistemi ile % 87.26 başarı sağlanmıştır. 2014 yılında Vallez ve arkadaşları 277 adet görüntü özelliği ve ağırlıklı oy ağacı ile arka plan sınıflandırma gerçekleştiren bir sistem oluşturmuştur. MIAS veri tabanındaki bütün görüntüler kullanılarak test edilen çalışma sonucunda sınıflandırma başarısı % 99.68 olarak gerçekleşmiştir.

MIAS veri tabanının sıklıkla kullanıldığı bir diğer çalışma alanı, göğüs normal-anormal dokularının sınıflandırılmasıdır. Christoyianni ve arkadaşları (1999-a) tarafından yapılan normal-anormal doku sınıflandırılması çalışmasında görüntüler üzerinde pencereleme analizi yapılarak elde edilen görüntü özellikleri, radyal taban fonksiyonlu sinir ağı (RTFSA) kullanılarak sınıflandırmaya tabi tutulmuştur. MIAS veri tabanına ait 76 adet görüntü alanının kullanıldığı çalışmada % 75.2 doğru sınıflandırma başarısına ulaşılmıştır. Bu çalışma sonucunda duyarlılık 0.868 olarak elde edilmiştir. Aynı yıl Christoyianni ve arkadaşları (1999-b) tarafından yapılan bir diğer normal ve anormal dokuların sınıflandırılması çalışmasında ise gri seviye histogram momenti (GSHM) ve mekansal gri seviye bağımlılığı (MGSB) olmak üzere iki yöntem kullanılarak görüntü özellikleri elde edilmiştir. RTFSA ve çok katmanlı algılayıcı sinir ağı olmak üzere iki sınıflandırıcının başarısının karşılaştırıldığı çalışmada MIAS veri

tabanına ait 119 adet görüntü alanı kullanılmıştır. Çalışma sonucunda en yüksek sınıflandırma başarısı % 84.87 olarak gerçekleşmiştir.

Bovis ve Singh (2000) tarafından yapılan çalışmada korelasyon, kontrast, entropi, ters fark momenti, toplam, ortalama, toplam entropi, toplam varyans, fark entropi, fark varyans gibi görüntü özellikleri kullanılmıştır. Sınıflandırıcı olarak YSA kullanılan çalışmada MIAS veri tabanına ait 868 adet görüntü alanı üzerinde çalışılmıştır. Çalışma sonucunda ortalama % 77.0 sınıflandırma başarısı elde edilirken, duyarlılık 0.730, özgüllük 0.25 ve alıcı işlem karakteristiği (AİK) eğrisi altında kalan alan (A_z) 0.74 olarak hesaplanmıştır.

Liu ve arkadaşları (2001) tarafından yapılan normal-anormal doku tespiti ve sınıflandırılması çalışmasında, DD kullanılarak özellik matrisleri elde edilmiştir. İkili sınıflandırma ağacının kullanıldığı çalışma, MIAS veri tabanına ait 38 adet görüntü ile test edilmiştir. Çalışma sonucunda % 84.2 ile % 100 arasında değişen doğru pozitif (DP) oranları elde edilmiştir. Christoyianni ve arkadaşları (2002) tarafından yapılan çalışmada öncelikle görüntülere bağımsız bileşen analizi (BBA), GSHM, MGSB uygulanarak görüntü özellikleri elde edilmiştir. İkinci aşama da ise TBA kullanılarak görüntü özelliklerinin boyutları indirgenmiştir. RTFSA sınıflandırıcı kullanılan çalışma MIAS veri tabanına ait 119 görüntü ile test edilmiştir. Çalışma sonucunda normal ve anormal dokuların sınıflandırılmasında en yüksek sınıflandırma başarısı % 88.23 olarak elde edilmiştir. Mini ve Thomas (2003) tarafından yapılan çalışmada ADD ile görüntü özellikleri çıkarılmıştır. MIAS veri tabanına ait 157 adet görüntü kullanılarak test edilen çalışmada sınıflandırıcı olarak olasılıksal sinir ağı (OSA) kullanılmıştır. Çalışma sonucunda normal-anormal doku sınıflandırılmasında % 71.3' lük başarı oranına ulaşılmıştır.

Jirari (2005) tarafından RTFSA ve özellik çıkarma teknikleri kullanılarak BDT sistemi tasarlanmıştır. MIAS veri tabanına ait 322 görüntü kullanılarak test edilen çalışma sonucunda % 86.74 sınıflandırma başarısı elde edilirken, A_z değeri 0.91 olarak hesaplanmıştır. Selvan ve arkadaşları (2006) tarafından göğüs dokusu yoğunluğunun risk tahmini için bir gösterge olabileceği fikrinden hareketle sezgisel optimizasyon teknikleri kullanılarak bir risk tahmini çalışması gerçekleştirilmiştir.

Hassanien (2007) tarafından yapılan tümör tespit ve sınıflandırma çalışmasında ise bulanık görüntü işleme ve kaba kümeleme teorisi birleştirilerek hibrit bir sistem oluşturulmuştur. Maksimum olasılık, kontrast, ters fark momenti, açısal ikinci moment, entropi gibi görüntü özellikleri kullanılan çalışma MIAS veri tabanına ait 320

görüntüden elde edilen eşit büyüklükte 10 adet görüntü kümesi ile test edilmiştir. Çalışma sonucunda normal-anormal doku sınıflandırılmasında en yüksek sınıflandırma başarısı % 98.46 olarak gerçekleşmiştir. Costa ve arkadaşları (2007) tarafından yapılan sınıflandırma çalışmasında ise BBA ve DVM ile doğrusal diskriminant analizi (DDA) kullanılmıştır. MIAS veri tabanına ait 200 adet görüntünün kullanıldığı çalışmanın sonucunda normal ve anormal dokuların sınıflandırılmasında en yüksek başarı % 97.00 olarak gerçekleşmiştir.

Dua ve arkadaşları (2009), normal-anormal doku sınıflandırılması çalışmasında benzersiz ağırlıklı ortaklık tabanlı sınıflandırıcı kullanmışlardır. MIAS veri tabanının kullanıldığı çalışmada % 89.99 sınıflandırma başarısı elde edilmiştir. Aynı yıl Faye ve arkadaşları ise normal-anormal doku sınıflandırması için DD ve denetimli sınıflandırıcı kullanmışlardır. MIAS veri tabanına ait 163 adet görüntünün seçildiği çalışmada en yüksek sınıflandırma başarısı % 98.55 olarak gerçekleşmiştir. Jasmine ve arkadaşları tarafından (2009) yapılan sınıflandırma çalışmasında ise ADD ve YSA kullanılmıştır. Önerilen sistemin MIAS veri tabanına ait 322 görüntü kullanılarak test edildiği bu çalışmanın sonucunda normal-anormal dokular % 87' lik başarı ile sınıflandırılmıştır.

Eltoukhy ve arkadaşları (2010-a) tarafından yapılan çalışmada iki aşamalı bir sistem önerilmiştir. İlk aşamasında segmentasyon ve göğüs doku yoğunluğu etkisinin azaltıldığı çalışmanın ikinci aşamasında ise normal-anormal doku sınıflandırılması yapılmıştır. MIAS veri tabanına ait 116 adet görüntünün kullanıldığı çalışma sonucunda duyarlılık 0.893, sınıflandırma doğruluğu % 94.66 olarak gerçekleşmiştir. Aynı yıl yine Eltoukhy ve arkadaşları (2010-b) tarafından yapılan bir diğer sınıflandırma çalışmasında ise çok ölçekli CuD kullanılmıştır. Çalışma içinde ADD kullanılarak elde edilen sonuçlar ile karşılaştırma yapılmış ve CuD' nin daha başarılı olduğu görülmüştür. MIAS veri tabanına ait 142 görüntü kullanılarak test edilen çalışma sonucunda normal-anormal doku sınıflandırılmasında % 98.59 başarı elde edilmiştir. Aynı yıl Moayedi ve arkadaşları (2010) tarafından yapılan çalışmada ise CoD ve DVM ailesi kullanılarak sınıflandırma gerçekleştirilmiştir. DVM ailesi kapsamında kullanılan sınıflandırıcılar ardışık geliştirme öğrenme (AGÖ) ağırlıklı DVM, destek vektör tabanlı bulanık sinir ağı ve çekirdek DVM' dir. MIAS veri tabanına ait 90 görüntü alanı kullanılarak test edilen çalışma sonucunda normal-anormal doku sınıflandırılmasında en yüksek sınıflandırma başarısı % 96.6 olarak gerçekleşmiştir. Bu çalışmada duyarlılık 0.958, özgüllük ise 0.990 olarak hesaplanmıştır. Dheeba ve Tamilselvi (2010) tarafından tamsayı DD, Gabor özellikleri ve RTFSA kullanılarak yapılan sınıflandırma çalışması MIAS veri

tabanına ait 322 görüntü alanı ile test edilmiştir. Çalışma sonucunda duyarlılık 0.852 olarak gerçekleşmiştir. Aynı yıl Thangavel ve Mohideen (2010) tarafından yapılan çalışmada ise sınıflandırma için yarı denetimli k-ortalama kümeleme kullanılmıştır. MIAS veri tabanından seçilen 108 adet görüntünün kullanıldığı çalışmanın sonucunda doğruluk oranı % 90.67, A_z değeri 0.91 olarak elde edilmiştir.

Mata ve Meenakshi (2011), normal-anormal doku sınıflandırılması çalışmasında kontrast-sınırlı adaptif histogram eşitleme kullanmıştır. MIAS veri tabanına ait 125 görüntü alanının kullanıldığı çalışma sonucunda % 82.40 sınıflandırma başarısı elde edilmiştir. Ayrıca çalışma sonucunda duyarlılık 0.8, özgüllük 0.826 olarak gerçekleşmiştir. Kitanovski ve arkadaşları (2011) ise normal-anormal doku sınıflandırma çalışmasında; gri seviye fark, lokal binari grafikleme, gri seviye çalışma uzunluğu, Haralick doku özellikleri, Gabor doku özellikleri olmak üzere beş adet özellik çıkarma ve DVM, k-EYK, c4.5 algoritması olmak üzere üç adet sınıflandırma yöntemi kullanmıştır. MIAS veri tabanından seçilen 326 adet görüntü alanının kullanıldığı çalışma sonucunda normal-anormal doku sınıflandırılmasında en yüksek başarı % 98.77 olarak gerçekleşmiştir.

Hussain ve arkadaşları (2012) tarafından yapılan çalışmada Gabor filtre bankası ve AGÖ tabanlı DVM kullanılarak sınıflandırma gerçekleştirilmiştir. MIAS veri tabanına ait 109 görüntü alanı ile test edilen çalışma sonucunda normal-anormal doku sınıflandırılmasında ortalama A_z 0.96 olarak hesaplanmıştır. Aynı yıl Faye tarafından yapılan çalışmada ise ADD kullanılarak elde edilen görüntü özellikleri rastgele seçilerek k-EYK ve DDA ile sınıflandırılmıştır. MIAS veri tabanından seçilen 64 görüntü alanı ile test edilen çalışma sonucunda DDA için % 58.59, k-EYK için % 76.59 sınıflandırma başarısı elde edilmiştir. Eltoukhy ve arkadaşları (2012) tarafından yapılan başka bir çalışmada ise ADD ve CuD ile DVM kullanılarak sınıflandırma yapılmıştır. MIAS veri tabanına ait 322 görüntü ile 5-kat çapraz doğrulama yapılarak test edilen çalışmada ADD için % 95.84, CuD için % 95.98 sınıflandırma başarısı elde edilmiştir. Aynı yıl Padmanabhan ve Sundararajan tarafından yapılan normal-anormal doku tespit ve doku sınıflandırma çalışmasında ise öncelikli olarak segmentasyon ve doku yoğunluk etkisinin azaltılması gerçekleştirilmiştir. İkinci aşamada ADD kullanılarak görüntü özellikleri elde edilmiş ve bu görüntü özellikleri kullanılarak sınıflandırma yapılmıştır. MIAS veri tabanından seçilen 100 adet görüntünün kullanıldığı çalışma sonucunda normal-anormal doku sınıflandırılmasında % 91.0 başarı sağlanmıştır. Aynı yıl Rizzi ve arkadaşları tarafından yapılan çalışmada ise DVM ve YSA sınıflayıcının

sınıflandırma başarıları karşılaştırılmıştır. Çalışma sonucunda iki sınıflayıcının AİK eğirlerinin birbirine çok yakın olduğu görülmüş ve A_z değeri YSA sınıflayıcı için 0.85, DVM sınıflayıcı için 0.82 olarak gerçekleşmiştir. Aynı yıl Wong ve arkadaşları tarafından yapılan çalışmada GSEM ve ikili PSO-kEYK özellik seçici kullanılmıştır. MIAS veri tabanına ait 69 görüntü alanı kullanılarak test edilen çalışma sonucunda % 81.16 sınıflandırma başarıları elde edilmiştir.

Nguyen ve arkadaşları (2013) tarafından yanlış pozitifleri (YP) azaltmayı amaçlayan bir çalışma yapılmıştır. Yerel katsayıların blok varyans özellikleri ve DVM'nin kullanıldığı çalışmada MIAS veri tabanına ait görüntülerden elde edilen ve en büyüğü 4×4 boyutlarında olan 2700 görüntü alanı ile önerilen sistem test edilmiştir. Çalışma sonucunda en yüksek sınıflandırma başarıları % 88.72 olarak gerçekleşirken, en yüksek A_z 0.9325 olarak hesaplanmıştır. Radovic ve arkadaşları (2013) tarafından yapılan çalışmada görüntü özellikleri, ADD ve GSEM kullanılarak elde edilmiştir. DVM, bayes sınıflandırıcı, k-EYK, lojistik regresyon, karar ağacı, rastgele orman sınıflandırıcı ve çok katmanlı algılayıcı olmak üzere yedi farklı sınıflandırıcı ile yapılan çalışma MIAS veri tabanına ait 322 adet görüntü alanı kullanılarak test edilmiştir. Çalışma sonucunda en yüksek sınıflandırma başarıları % 79.33 olarak gerçekleşirken, en yüksek A_z 0.834 olarak hesaplanmıştır. Kumar ve Balakrishnan (2013) tarafından yapılan bir başka sınıflandırma çalışmasında ise ADD ve gömülü olasılıksal komşuluk kullanılmıştır. MIAS veri tabanına ait 155 görüntü kullanılarak test edilen çalışmada sınıflandırıcı olarak k-EYK ve DVM seçilmiştir. Çalışma sonucunda normal-anormal dokular % 93.39 başarı ile sınıflandırılmıştır. Ohmshankar ve Kumar Charlie Paul (2014) tarafından yapılan sınıflandırma çalışmasında ise Haralick özellikleri ve k-EYK kullanılmıştır. MIAS veritabanına ait 142 görüntü alanı kullanılarak test edilen çalışma sonucunda % 92.27 sınıflandırma başarıları elde edilmiştir.

2. ÇOKLU ÇÖZÜNÜRLÜK ANALİZLERİ

Bir veya iki boyutlu sinyal işleme yaklaşımlarının temel amacı uygun bir dönüşüm metodu uygulandıktan sonra sinyalden istenilen bilgiyi elde etmektir. Uygulanan dönüşüm tersinebilir olmalı ve dönüştürülmüş biçim orijinal sinyali bire bir temsil etmelidir. Ayrıca parametre kestirimi, kodlama, veri sıkıştırma ve görüntü tanıma gibi daha karmaşık sinyal işleme işlemlerinin, ilgili özelliklerin daha belirginleşeceği varsayılan dönüştürülmüş sinyal üzerinden gerçekleşmesi istenmektedir (Misiti ve ark., 1997). Bu amaçla çeşitli çoklu çözünürlük analizi yöntemleri ortaya atılmıştır. Bu tez çalışmasında bu analiz yöntemlerinden olan DD, RidD, CuD, CoD ve Rip-1D' den yararlanılmıştır.

2.1. Dalgacık Dönüşümü

Çoklu çözünürlük analizi yöntemlerinin temelini FD oluşturmaktadır. Daha sonraki yıllarda dönüşümün yetersiz kaldığı alanlar için DD ve DD' yi temel alan çoklu çözünürlük analizleri ortaya atılmıştır. DD, bir ve iki boyutlu dalgacık dönüşümü olmak üzere iki alt başlık altında incelenebilir.

2.1.1. Bir boyutlu dalgacık dönüşümü

FD; bir sinyali zaman domeninden frekans domenine çeviren matematiksel bir araçtır. Bir $x(t)$ sinyali için, FD çifti eşitlik (2.1) ve (2.2)' de verilmiştir.

$$x(f) = \int_{-\infty}^{+\infty} x(t) \exp(-j(\frac{2\pi}{\tau})t) dt \quad (2.1)$$

$$x(t) = \int_{-\infty}^{+\infty} x(f) \exp(-j(\frac{2\pi}{\tau})t) df \quad (2.2)$$

FD, $x(t)$ sinyali, bir kaç durağan bileşen içerdiğinde sinyallerin frekans içeriklerini başarılı bir şekilde ifade etme yeteneğine sahiptir. Ancak durağan olmayan sinyaller için tersine işlem uygulanması sırasında sorun yaşanmaktadır.

FD' nin frekans bilgileri ile tersine işlem yapılarak orijinal sinyalin yeniden elde edilmesindeki yetersizliğini ortadan kaldırmak amacı ile Gabor (1946) tarafından kısa zamanlı Fourier dönüşümü (KZFD) ortaya atılmıştır. KZFD' nin hedefi sabit uzunluğa sahip keyfi $g(t)$ penceresi kullanarak gerçekte durağan olmayan sinyalleri yaklaşık

durağan hale getirmektir. KZFD, $x(t)$ sinyalini, farklı τ zamanları için $g(t)$ kayan penceresi kullanarak iki boyutlu zaman-frekans gösterimi $S(\tau, f)$ haline getirir. Eşitlik (2.3) KZFD' yi tanımlamaktadır.

$$KZDF_x(\tau, f) = \int_{-\infty}^{+\infty} x(t)g^*(t-\tau)\exp(-j(\frac{2\pi}{\tau})t)dt \quad (2.3)$$

KZFD işaretin zaman ve frekans tabanlı görünüşleri arasında bir nevi bağlantı sağlamaktadır. Yani KZFD zamanın küçük aralıklarında işaretin içerdiği frekans bilgilerini ortaya çıkarır. Fakat bu bilgilerin elde edilmesini pencerenin büyüklüğü belirler. KZFD' nin zaman ve frekans bilgileri arasındaki uyuşmayı göstermesindeki yararlılığına karşın eksik tarafı zamanda uygulanan pencerenin belirli bir uzunluğa sahip olmasıdır. Bu durumda da pencere bütün frekanslar için aynı kalmaktadır (Misiti ve ark., 1997).

Dalgacık dönüşümü KZFD' den farklı olarak değişen uzunluklu pencereleri içeren yeni bir tekniktir. Bu dönüşüm düşük frekans bilgilerinin istendiği yerde geniş zaman aralığı, yüksek frekans bilgilerinin istendiği yerde dar zaman aralığını parametre olarak kullanmaktadır. Bu dönüşüm, kısa zamandaki yüksek frekans bileşenlerinden ve uzun zamandaki alçak frekans bileşenlerinden oluşan sinyallerin işlenmesi için çok uygundur. Pratik uygulamalarda karşılaşılan sinyaller de bu tür sinyallerdir (Rioul ve Vetterli, 1991; Ceylan, 2009).

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

$$\psi(a,b)(t) = \frac{1}{\sqrt{a}}\psi(\frac{t-b}{a}) \quad (2.4)$$

Eşitlik (2.4)' de, a parametresi ölçekleme faktörü, b parametresi ise kayma faktörüdür. Burada ölçekleme faktörü sıfırdan büyük reel sayı ve kayma faktörü reel sayıdır. $x(t)$ fonksiyonun eşitlik (2.5)' de sürekli dalgacık fonksiyonu tanımlanmıştır.

$$SDD_x(a,b) = \int_{-\infty}^{+\infty} x(t)\psi_{(a,b)}^*(t)dt \quad (2.5)$$

Sürekli dalgacık dönüşümü (SDD) ile $SDD_x(a,b)$ dalgacık katsayılarının bir kümesi elde edilir. Bu katsayılar, sinyalin temel fonksiyona ne kadar benzediğini gösterir. Bu katsayılar kullanılarak sinyalin yeniden elde edilmesi mümkündür.

$$C_\psi = \int_{-\infty}^{+\infty} \frac{|\Psi(w)|^2}{w} dw \quad (2.6)$$

$$x(t) = \frac{1}{C_{\psi}} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} SDD_x(a,b) \psi(a,b)(t) \frac{da.db}{a^2} \quad (2.7)$$

Eşitlik (2.6) ve (2.7)' de verilen $\Psi(w), \psi(t)$ 'nin Fourier dönüşümünü ifade etmektedir. Genellikle SDD uygulamalarında ana dalgacık olarak ortagonal diyardik fonksiyonlar seçilmektedir (Arserim, 2001).

Dalgacık katsayılarını her olası durum için hesaplamak çok fazla işlem yapmayı gerektirir. Ayrıca sinyal işleme çalışmalarının çoğunda bu katsayıların sadece bir kısmı kullanılmaktadır. Dalgacık katsayılarını her olası durum için hesaplanması yerine ikinin katlarını temel alacak bir şekilde ağırlıkları ve pozisyonu seçmemiz dönüşümü çok daha etkin kılacaktır. Bu sebeple DD' nin ayrı bir şekilde ifade edilmesine ihtiyaç duyulmuş ve ADD tanımlanmıştır. ADD' de ölçek ve kayma parametreleri ayrı bir zaman-ölçek düzleminde değerlendirilmiştir. Bu ayrıklaştırma işlemi eşitlik (2.8)' de gösterilmiştir (Daubechies, 1990; Ceylan, 2009).

$$a = a_0^j \text{ ve } b = k.a_0^j.b_0 \quad j, k \in Z \quad (2.8)$$

Burada $a_0 > 1$ genişletme adımı ve $b_0 \neq 0$ ise çevirme adımıdır. ADD için dalgacık ailesi eşitlik (2.9)' deki gibi ifade edilebilir. Bir $x(t)$ fonksiyonunun dalgacık ayrışımı ise eşitlik (2.10)' da verilmiştir.

$$\psi_{j,k}(t) = a_0^{-j/2} \psi(a_0^{-j}t - kb_0) \quad (2.9)$$


$$x(t) = \sum_j \sum_k D_f(j,k) \psi_{j,k}(t) \quad (2.10)$$

Birçok sinyalin sahip olduğu düşük frekanslı bileşenler önem arz eder. Düşük frekans bileşenler sinyaller için genellikle tanınma özelliğini içerir. Diğer yanda yüksek frekanslı bileşenler sinyalin ana kısmına ilave nüanslardır. Buna örnek olarak insan sesi ele alınırsa sesin yüksek frekanslı bileşenlerinin çıkarılması durumunda ses farklılaşmasına rağmen söylenilen şeyler anlaşılır. Düşük frekanslı bileşenlerin bir kısmının çıkarılması durumunda ise söylenilen şeyler anlaşılabilir (Arserim, 2001). ADD ile ana sinyal yüksek ağırlıklı düşük frekanslı bileşenlerine ve düşük ağırlıklı yüksek frekanslı bileşenlerine ayrılabilir. Bu ayırma işlemi birçok kez tekrarlanabilir. Böylece bir işaret daha az çözünürlüklü birçok alt bileşene ayrılacaktır.


2.1.2. İki boyutlu dalgacık dönüşümü

Görüntüler iki boyutlu sinyallerdir. Standart ADD' nin görüntüler için genişletilmesi ile iki boyutlu ayrık dalgacık dönüşümü (2BADD) tanımlanmıştır. Görüntü kodlama algoritmalarının çoğu bir boyutlu ADD' nin görüntünün satırlarına ve sütunlarına ayrı ayrı uygulanması ile elde edilen 2BADD' yi kullanmaktadır (ISO/IEC 1999; Ceylan, 2009).


Tek seviyeli 2BADD' nin analiz filtre bankası uygulaması Şekil 2.1' de görülmektedir (Ceylan, 2009). Bu yapı, üç farklı yönelime (yatay, dikey ve köşegen) uygun olarak üç detaylı alt görüntü (HH, HL, LH) ve düşük çözünürlüklü bir alt görüntü (LL) üretmektedir. LL' nin standart ADD uygulamalarına benzer biçimde birden çok kez ayrıştırılması ile çoklu-seviye ayrıştırma işlemi gerçekleştirilebilir. Bir görüntünün çoklu-seviyeli ayrıştırma hiyerarşisi Şekil 2.2' de görülmektedir. Burada her bir ayrıştırma işlemi ile ana görüntüden dört adet alt görüntü elde edilmektedir. Bu alt görüntülerin her birinin satır ve sütun büyüklüğü ana görüntünün yarısı kadardır. Şekil 2.3' de ise Lena görüntüsü ve görüntünün çoklu-seviyeli ayrıştırma hiyerarşisi kullanılarak ayrıştırılması ile elde edilen alt görüntüler verilmiştir.



Şekil 2.1. 2BADD için bir seviyeli analiz filtre kümesi (Ceylan, 2009)



Şekil 2.2. 2BADD çoklu-seviyeli ayrıştırma hiyerarşisi (Ceylan, 2009)



Şekil 2.3. a) Lena görüntüsü b) Lena görüntüsünün 2BADD ile ayrıştırılması

2BADD’ de kullanılan dalgacıklar, bir boyutlu dalgacık ve ölçekleme fonksiyonları ile oluşturulmaktadır. $\psi(x)$, bir boyutlu ölçekleme fonksiyonu $\varphi(x)$ ile birleştirilmiş bir boyutlu dalgacık olmak üzere; üç alt görüntü ile birleştirilmiş 2BADD eşitlik (2.11) ile ifade edilebilir (Shukla, 2003; Ceylan, 2009).

$$\psi^D(x, y) = \varphi(x)\psi(y) \rightarrow LH$$

$$\psi^Y(x, y) = \psi(x)\varphi(y) \rightarrow HL \quad (2.11)$$

$$\psi^K(x, y) = \psi(x)\psi(y) \rightarrow HH$$

2.2. Ridgelet Dönüşümü

Dalgacık dönüşümünün ayrık versiyonu iki boyutlu verilerin analizinde üstün özellikler taşımasına karşın bir takım sınırlamaları da içermektedir. Bu sınırlamaların en belirginini iki boyutlu verinin yatay, dikey ve 45^0 için analiz edilmesidir. Ancak görüntü içindeki noktasal süreklilikler (çizgisellikler) sadece bu yönler doğrultusunda olmayabilir. Bu durum yatay, dikey ve 45^0 haricindeki yönlerdeki noktasal sürekliliklerin belirgin biçimde ortaya çıkmasında önemli bir engeldir. DD' nin bu dezavantajını ortadan kaldırmak için DD' de kullanılan ölçek ve kayma operatörüne bir de yön (açı) operatörü eklenmiş ve RidD tanımlanmıştır (Candes ve Donoho, 1999). Bu yön operatörü sayesinde DD' den farklı olarak yatay, dikey ve 45^0 dışındaki açılar için işlem yapılabilmektedir.

2.2.1. Sürekli ridgelet dönüşümü

$\Psi(x)$ ridgelet fonksiyonu olarak adlandırılır. Ridgelet fonksiyonu eşitlik (2.12)' deki gibi ifade edilebilir (Candes ve Donoho, 1999).

$$\Psi_{a,b,\theta}(x) = \Psi_{a,b,\theta}(x_1, x_2) = \frac{1}{\sqrt{a}} \Psi\left(\frac{x_1 \cos \theta + x_2 \sin \theta - b}{a}\right) \quad (2.12)$$

Burada verilen, ölçekleme faktörü $a > 0$, konum $b \in \mathbb{R}$ ve yön operatörü $\theta \in [0, 2\pi]$ olmak üzere fonksiyon $\mathbb{R}^2 \rightarrow \mathbb{R}$ ye tanımlıdır. Ridgelet fonksiyonunda kullanılan ölçek ve konum operatörü dalgacık fonksiyonunda kullanılan operatörlerle aynıdır. Yön operatörü ise analizin kutupsal düzlemdeki yönünü tayin ederek hangi açı üzerinde gerçekleştiğini tanımlamaktadır.

Bir $f(x)$ fonksiyonunun iki boyutlu sürekli ridgelet dönüşümü (SRidD) katsayıları eşitlik (2.13) ile hesaplanır (Candes ve Donoho, 1999).

$$SRD_f(a, b, \theta) = \int_{\mathbb{R}^2} f(x) \bar{\Psi}_{a,b,\theta}(x) dx \quad (2.13)$$


SRidD katsayıları kullanılarak $f(x)$ fonksiyonun yeniden elde edilmesi mümkündür. Eşitlik (2.14) SRidD katsayıları ile yapılan bu tersine işlemi ifade etmektedir.

$$f(x) = \int_0^{2\pi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} SRD_f(a, b, \theta) \Psi_{a,b,\theta}(x) \frac{da}{a^3} db \frac{d\theta}{4\pi} \quad (2.14)$$

Eşitlik (2.13) ve (2.14)' den de anlaşılacağı üzere SRidD ile SDD arasında benzerlik vardır. Bu dönüşümler arasındaki fark; DD' nin noktasal konumlarla, RidD' nin ise çizgisel konumlarla ifade edilmesidir.

2.2.2. Ayrık ridgelet dönüşümü

SRidD katsayıları hesaplanırken kutupsal koordinat sisteminde eşit açı aralıkları ile sınırsız işlem yapmak mümkünken kartezyen koordinat sisteminde mümkün değildir. İki boyutlu görüntüler kutupsal koordinat sisteminde değil kartezyen koordinat sisteminde tanımlanmıştır. Bu durum SRidD' nin görüntüler üzerinden analiz yapılan yön sayısını kısıtlayarak ayrık ridgelet dönüşümünü (ARidD) tanımlar. Şekil 2.4' de kartezyen koordinat sistemindeki bir görüntünün ARidD katsayıları hesaplanırken kullanılan kutupsal koordinat yönleri verilmiştir (Fadili ve Starck, 2012).




Şekil 2.4. 8×8 boyutlarında ve kartezyen koordinat sistemindeki görüntünün analiz yapılırken kullanılan kutupsal yönleri (Fadili ve Starck, 2012)

ARidD, Radon dönüşümü (RaD) ve ADD' nin beraber kullanılması ile de inşa edilebilir. RaD eşitlik (2.15)' de tanımlanmıştır.

$$RADf(\theta, t) = \int_{R^2} f(x_1, x_2) \delta(x_1 \cos \theta + x_2 \sin \theta - t) dx_1 dx_2 \quad (2.15)$$

Burada δ dirac dağılımıdır. RaD, Fourier frekans domeninde oluşturulmuş izdüşüm-dilim teoremini temel alan bir yapıdır. RaD, FD kullanılarak ifade edilebilir.

Dirac dağılımı sebebiyle kullanılan FD' nin hızlı olması tercih edilir. Buna göre öncelikle görüntüye iki boyutlu hızlı Fourier dönüşümü (2BHFD) uygulanır. Burada elde edilen frekans fonksiyonu, açısal biçimde dağılmış frekans izdüşümleri elde etmekte kullanılır. Elde edilen her açısal izdüşüm için bir boyutlu hızlı ters Fourier dönüşümü (1BHFTD) uygulanarak RaD dilimleri oluşturulur. ARidD' yi tamamlamak için RaD dilimlerine bir boyutlu ADD uygulanır. ARidD' nin RaD ve ADD' nin kullanılması ile inşa edilmesini anlatan akış şeması Şekil 2.5' de verilmiştir (Fadili ve Starck, 2012). ARidD' nin FD ve ADD üzerine inşa edilmesi sebebiyle işlemlerde kullanılan FD ve ADD parametreleri ARidD sonuçları üzerinde doğrudan etkilidir. Ayrıca; Şekil 2.5' den de görüldüğü üzere işlemlerde FD ve ADD birbirini tamamlar niteliktedir. Bu sebeple, analiz bütünlüğü düşünülerek FD ve ADD parametreleri birbirleri ile uyumlu seçilmelidir.



Şekil 2.5. ARidD akış şeması (Fadili ve Starck, 2012)

ARidD, RaD ve ADD' nin beraber kullanılması ile inşa edilebileceği gibi görüntünün açısal olarak kaydırılması ve hızlı ADD uygulanması ile de elde edilebilir.


2.3. Curvelet Dönüşümü

RidD, görüntü işleme alanında işlem yapılan yön sayısını artırarak yatay, dikey ve 45^0 yönleri haricindeki doğrusalıkların temsilde önemli avantajlar sağlamıştır. Ancak görüntüler üzerindeki çizgisellikler doğrusaldan çok eğriseldir. RidD bu haliyle

eğriselliklerin ifade edilmesinde tam bir çözüm değildir. Bu sebeple RidD' yi de içine alan ve etkin bir özellik çıkarma yöntemi olan CuD tanımlanmıştır (Candes ve Donoho; 2000). CuD' yi, birinci nesil curvelet dönüşümü (1NCuD), ikinci nesil curvelet dönüşümü (2NCuD) ve hızlı ayırık curvelet dönüşümü (HACuD) olmak üzere üç başlık altında incelemek mümkündür.

2.3.1. Birinci nesil curvelet dönüşümü

1NCuD görüntüyü daha küçük görüntü alanlarına ayırarak inceler. Bunun amacı eğrilerin daha küçük parçalara bölünerek doğrusala yakın hale getirilmesidir. Her görüntü alanına RidD uygulanarak doğrusala yaklaşmış eğrisel çizgisellikler ortaya çıkarılmış olur. Şekil 2.6' da bu işlem anlatılmaktadır (Fadili ve Starck, 2012; Candes ve Donoho, 2002).



Şekil 2.6. Eğrisel çizgiselliklerin alt görüntü alanlarına bölünerek doğrusallaştırılması ve RidD ile işlenmesi (Candes ve Donoho, 2002)

1NCuD, alt bantlara ayırıştırma, düzgün bölümlleme, renormalizasyon ve RidD' den oluşmaktadır.

2.3.1.1. Alt bantlara ayırıştırma

1NCuD' nin alt bantlara ayırıştırma kısmında alt bant filtreleri tanımlanmaktadır. Bu filtreler, alçak geçiren filtre ve yüksek geçiren filtrelerdir (Donoho ve Duncan, 2000). Alt bantlara ayırıştırma kısmında f sinyali alt bant filtrelerinden geçirilmektedir. Görüntünün analizinde bu işlem görüntünün katmanlara bölünmesi yani görüntüyü oluşturan frekans bileşenlerinin ayrılması olarak ifade edilebilir. Bu katmanlardan her


biri ana görüntüyü ana hatları ile yansıtmakla birlikte farklı ayrıntılara sahiptir. Katmanlarına ayrılmış bir görüntüyü eşitlik (2.16) ile ifade etmek mümkündür.

$P_0 \rightarrow$ Alçak geçiren filtre

$\Delta_1, \Delta_2, \Delta_s \rightarrow$ Yüksek geçiren filtreler ($s \geq 1$)

$$f \rightarrow (P_0 f, \Delta_1 f, \Delta_2 f, \Delta_s f) \quad (2.16)$$

Örnek bir görüntü ve katmanlarına ayrılmış hali Şekil 2.7’ de görülmektedir (Donoho ve Duncan, 2000). Bu şekilde f ana görüntüyü, $P_0 f$ görüntünün alçak frekanslı katmanını, $\Delta_1 f$ 1. dereceden yüksek frekanslı katmanını, $\Delta_2 f$ ise 2. dereceden yüksek frekanslı katmanını ifade etmektedir.



Şekil 2.7. Örnek görüntü ve katmanları (Donoho ve Duncan, 2000)

Alt bantlarına ayrıştırma işlemi tersinir bir işlemdir. Buna göre f sinyalinin veya görüntüyü alt bantlarından tekrar elde etmek mümkündür. Eşitlik (2.17) alt bantlardan yeniden oluşturmayı tanımlamaktadır.

$$f = P_0(P_0 f) + \sum_s \Delta_s(\Delta_s f) \quad (2.17)$$

1NCuD’ deki alt bantlara ayırma işlemi, temel olarak DD’ deki katsayılarına ayırma işlemine benzemektedir. DD’ de f sinyali A_0 , D_1 , D_2 , D_3 gibi alt frekans bantlarına ayrılmaktadır. 1NCuD’ de $P_0 f$, A_0 ve D_1 den oluşurken, D_1 ’ den dolayı D_2 ve D_3 katsayılarını içermektedir. $\Delta_s f$ ise D_{2s} ve D_{2s+1} den oluşmaktadır (Candes ve Donoho, 2000).

2.3.1.2. Düzgün bölümlleme

1NCuD' de görüntü üzerinde düzgün alt pencereler tanımlanmaktadır. Tanımlanan pencereler $w_Q(x_1, x_2)$ olarak ifade edilebilir (Donoho ve Duncan, 2000). Eşitlik (2.18) pencere boyutlarını formülüle etmektedir.

$$Q(s, k_1, k_2) = \left[\frac{k_1}{2^s}, \frac{k_1+1}{2^s} \times \frac{k_2}{2^s}, \frac{k_2+1}{2^s} \right] \quad (2.18)$$

Bu eşitlikte, düzgün bölümlleme pencere koordinatlarını belirlemek için kullanılan ve görüntü başlangıç ve bitiş koordinatları dikkate alınarak seçilmek zorunda olan k_1 ve k_2 değişken, s ise frekans katmanı için sabittir. Bir önceki aşamada alt bantlarına ayrılmış görüntü katmanlarına düzgün bölümlleme işlemi uygulanır. Bu uygulamanın sonucunda eşitlik (2.19) ile ifade edilen h_Q , frekans katmanına ve bölümlerine ayrılmış görüntü oluşur.

$$h_Q = w_Q \Delta_s f \quad (2.19)$$

2.3.1.3. Renormalizasyon

Düzgün bölümlleme aşamasında farklı boyutlardaki pencereler için işlemler yapılmıştır. Bu durum bütün pencerelerin normalize edilmesini gerektirmektedir. 1NCuD' de renormalizasyon aşamasında her bir pencere çifti $[0,1] \times [0,1]$ birim karesine merkezlenir (Fadili ve Starck, 2012). Eşitlik (2.20) T_Q normalizasyon operatörünü tanımlamaktadır.

$$T_Q f(x_1, x_2) = 2^s f(2^s x_1 - k_1, 2^s x_2 - k_2) \quad (2.20)$$

Frekans katmanına ve bölümlerine ayrılmış görüntü h_Q , renormalize edilerek g_Q görüntüsü elde edilir. Eşitlik (2.21) renormalizasyon işlemini tanımlar.

$$g_Q = T_Q^{-1} h_Q = T_Q^{-1} (w_Q \Delta_s f) \quad (2.21)$$


2.3.1.4. Ridgelet dönüşümü

1NCuD' de alt bantlara ayırıştırma ile elde edilen $\Delta_s f$ katmanı, $[2^{2s}, 2^{2s+2}]$ frekans etki alanını içermektedir. Bu katman için oluşturulan pencerelerin uzunluğu yaklaşık olarak 2^{-s} iken genişliği ise yaklaşık olarak 2^{-2s} ' dir. Burada genişlik uzunluğun yaklaşık olarak karesidir. Genişlik ve uzunluk arasındaki mevcut bu oran verimliliği artırmak içindir.


Renormalize edilmiş g_Q görüntülerine ortonormal RidD uygulanarak 1NCuD tamamlanmış olur. Eşitlik (2.22), $\alpha_{(Q,\lambda)}$ 1NCuD özellik katsayılarını, ρ_λ RidD' yi ifade etmek üzere bu işlemi tanımlamaktadır.

$$\alpha_{(Q,\lambda)} = \langle g_Q, \rho_\lambda \rangle \quad (2.22)$$

Şekil 2.8' de 1NCuD' nin alt bantlarına ayırıştırma, düzgün bölümlleme, renormalizsyon ve ridgelet dönüşümü ile elde edilmesi anlatılmaktadır. Şekil 2.9' de ise 1NCuD' nin akış şeması verilmiştir.



Şekil 2.8. 1NCuD alt basamakları (Donoho ve Duncan, 2000)



Şekil 2.9. 1NCuD akış şeması (Fadili ve Starck, 2012)

2.3.2. İkinci nesil curvelet dönüşümü

1NCuD' nin avantajlarının yanında dezavantajları da vardır. Bu dezavantajların ilki, dönüşümün birbirini takip eden ve her biri ayrı analiz basamakları içeren bir yapı üzerine inşa edilmesi sebebiyle karmaşık olmasıdır. Buna ek olarak, parabolik ölçek oranı (genişliğin uzunluğun karesi olması) yaklaşık bir ifadedir. Bu durum ise analizin hassasiyetini olumsuz etkilemektedir. İkinci olarak, 1NCuD' de düzgün bölümlenme ile oluşabilecek olumsuz etkileri azaltmak için üst üste gelen pencereler kullanılmaktadır. Bu ise dönüşümün işlem yükünü artırıp hızını azaltmaktadır. 1NCuD' nin bu eksikliklerine çözüm bulmak amacıyla 2NCuD tanımlanmıştır. 2NCuD, 1NCuD' ne göre çok daha basit bir yapıdadır (Candes ve Donoho, 2002; Candes ve ark; 2005). Ölçek, yön (açı) ve konum olmak üzere üç parametre kullanılarak dönüşüm basitleştirilmiştir. 2NCuD' de daha iyi bir pencere genişletme yöntemi uygulandığı için sonuca ulaşma hızı yüksektir (Candes ve Donoho, 2002).

2.3.2.1. Sürekli versiyon

2NCuD'nde; ölçek 2^{-j} , yön (açı) θ_l , konum $x_k^{j,l} = R_{\theta_l}^{-1}(2^{-j}k_1, 2^{-j/2}k_2)$ olmak üzere ana curvelet fonksiyonu eşitlik (2.23) ile tanımlanabilir.

$$\varphi_{j,k,l}(x) = \varphi_j(R_{\theta_l}(x - x_k^{j,l})) \quad (2.23)$$

Eşitlik (2.23)' de R_{θ_l}, θ_l açısı boyunca ki rotasyondur ve $0 \leq \theta_l \leq 2\pi$ olmak üzere eşitlik (2.24) ile aşağıdaki gibi ifade edilebilir.

$$\theta_l = 2\pi \cdot 2^{-|j/2|} l \quad (2.24)$$

φ_j fonksiyonun Fourier domenindeki karşılığı $\hat{\varphi}_j(v)$ olmak üzere eşitlik (2.23)' de verilen curvelet fonksiyonu eşitlik (2.25) ile de ifade edilebilir.

$$\hat{\varphi}_j(r, \theta) = 2^{-3j/4} \hat{w}(2^{-j} r) \hat{v}\left(\frac{2^{|j/2|} \theta}{2\pi}\right) \quad (2.25)$$

Eşitlik (2.25)' de $\hat{w}$ ve $\hat{v}$ radyal ve açısal pencereleri ifade etmektedir. Şekil 2.10 (a)' da görülen bu pencereler sayesinde 2NCuD daha etkin bir analiz haline gelmiştir. Sürekli frekans düzleminde bir fonksiyonunun 2NCuD katsayıları ise eşitlik (2.26) ile hesaplanır.

$$c_{j,k,l} := \left\langle f, \varphi_{j,k,l} \right\rangle = \int_{R^2} \hat{f}(v) \hat{\varphi}_j(R_{\theta_l} v) e^{ix_k^{j,l} \cdot v} dv \quad (2.26)$$


2NCuD kendi yönüne dik olacak şekilde salınımlı bir davranış sergiler (Fadili ve Starck, 2012).

2.3.2.2. Ayrık versiyon

Sürekli 2NCuD kutupsal koordinat sisteminde tanımlıdır. 2NCuD' nin kartezyen koordinat sisteminde tanımlanması ile ayrık versiyonu oluşturulmuştur. 2NCuD' nin sürekli versiyonunda tanımlanan radyal ve açısal pencerelerin kartezyen koordinat sistemindeki eşdeğeri $\hat{w}_j(v) = \hat{w}_j(2^{-j} v)$ bant geçiren pencerelerdir. Bu bant geçiren pencereler, h bir boyutlu alçak geçiren filtre ve $H_j(v) = \hat{h}(2^{-j} v_1) \hat{h}(2^{-j} v_2)$ alçak geçiren pencereler olmak üzere eşitlik (2.27)' de tanımlanmıştır.

$$\hat{w}_j(v) = \sqrt{H_{j+1}^2(v) - H_j^2(v)}, \quad \forall j \geq 0 \text{ ve } \hat{w}_0(v) = \hat{h}(v_1) \hat{h}(v_2) \quad (2.27)$$


Şekil 2.10 (b)' de 2NCuD için kartezyen koordinat sisteminde tanımlanmış radyal ve açısal frekans pencereleri görülmektedir.



Şekil 2.10. 2NCuD a) sürekli versiyon (kutupsal koordinat sistemi) b) ayrık versiyon (kartezyen koordinat sistemi) radyal ve açısal frekans pencereleri (Donoho ve Duncan, 2000)

2.3.3. Hızlı ayrık curvelet dönüşümü

HACuD; görüntü üzerindeki nesnelerin kenar özelliklerini hızlı ve etkili bir şekilde ifade etmeyi amaçlayan bir çoklu çözünürlük analizidir (Candes ve ark., 2005). HACuD inşa edilirken ilk olarak 2BHFD kullanılır. 2BHFD sayesinde görüntü iki boyutlu frekans düzlemi dilimlerine ayrılır. Bu dilimler açısal ve radyal bir şekle sahiptir. Daha sonra HACuD özellik katsayılarının oluşturulması için iki boyutlu hızlı ters Fourier dönüşümü (2BHTFD) kullanılır. Şekil 2.11’ de iki boyutlu frekans düzlemi dilimleri görülmektedir (Gedik ve Atasoy, 2013).



Şekil 2.11. HACuD iki boyutlu frekans düzlemi dilimleri (Candes ve ark., 2005)

CuD' nin sayısal olarak tanımlanması da mümkündür. Sayısal CuD katsayıları eşitlik (2.28) ile hesaplanabilir.

$$c_{j,k,l} := \left\langle f, \varphi_{j,k,l}^D \right\rangle = \int_{\mathbb{R}^2} \hat{f}(v) \tilde{\varphi}_j^D(S_{\theta_j}^{-1}v) e^{iS_{\theta_j}^{-T}m.v} dv \quad (2.28)$$

Eşitlik (2.28)' de yer alan S_{θ} eşitlik (2.29)' da verilen kesme matrisidir ve $m \approx [2^{-j}.k_1, 2^{-j/2}.k_2]$ dir.

$$S_{\theta} := \begin{pmatrix} 1 & 0 \\ -\tan\theta & 1 \end{pmatrix} \quad (2.29)$$

Sayısal uygulamalardan da yararlanılarak HACuD, eşit olmayan aralıklı hızlı Fourier dönüşümü ve kaydırma yoluyla da oluşturulabilir. Kaydırma yoluyla HACuD' nin oluşturulması dört ana adımda gerçekleştirilebilir.

Adım 1: $\hat{f}[n_1, n_2]$ frekans düzlemi dilimlerini elde etmek için iki boyutlu hızlı Fourier dönüşümü katsayıları hesaplanır.

Adım 2: Her (j, l) ölçek ve açılı dilime interpolasyon uygulanır ($\tilde{U}_{j,l}[n_1, n_2] \hat{f}[n_1, n_2]$).

Adım 3: İlk iki adımda elde edilen interpolasyonu yapılmış dilimlerin orijin etrafında kaydırılması yapılarak $\tilde{f}[n_1, n_2] = W(\tilde{U}_{j,l} \tilde{f})[n_1, n_2]$ elde edilir. Burada sırasıyla n_1 ve n_2 ; $0 \leq n_1 \leq L_{1,j}$ ve $0 \leq n_2 \leq L_{2,j}$ aralığındadır.


Adım 4: Her bir $\tilde{f}_{j,l}$ kaydırılmış dilimine iki boyutlu hızlı ters Fourier dönüşümü uygulayarak HACuD özellik katsayıları elde edilir.

Kompleks değerli HACuD özellik katsayıları, θ_l yerine $\theta_l + \pi$ açılı düzleminin kullanılmasıyla kolaylıkla oluşturulabilir (Fadili ve Starck, 2012).

2.4. Contourlet Dönüşümü

CoD ile çok ölçekli ve yönsel filtre kümeleri kullanılarak yeni bir 2BADD uygulaması geliştirilmiştir. Standart ADD sadece belirli yönlerde işlem yapmaktadır. Bunun yanında ADD ile çizgisellikler belirli lokal karesel alanlar içinde bölünmüş bir şekilde ifade edilir. Bu durum çizgiselliklerin daha dağınık ifade edilmesi anlamına gelmektedir. CoD ise çoklu ölçeklemede daha esnek yönler kullanarak çizgiselliklerin

çok daha az katsayı ile ve toplu bir şekilde ifade edilmesini sağlar (Do ve Vetterli, 2005). Şekil 2.12’ de ADD ile CoD’ nün çizgisellikleri yakalama performansları karşılaştırılmıştır.




Şekil 2.12. ADD ve CoD’ nin çizgisellikleri yakalama performanslarının karşılaştırılması (Do ve Vetterli, 2005)

Görüntüler üzerindeki çizgisellikler genellikle fiziksel nesnelerin düzgün sınırları üzerinde yer alır. Bu durum, CoD’ nin temel dayanak noktasıdır. CoD’ de yönsel filtre kümesi (YFK), görüntünün yüksek frekans bileşenlerini yakalamak için tasarlanmıştır. Bu sebeple, YFK kullanılarak görüntünün düşük frekanslı bileşenlerin elde edilmesi mümkün değildir. CoD’ de, görüntünün düşük frekans bileşenlerinin elde edilebilmesi için YFK işleminden önce Laplas piramidi (LP) kullanılır. LP içindeki filtre çiftleri görüntü üzerindeki düşük frekanslı noktaları yakalar. YFK ise yüksek frekans bileşenleri elde ederek LP tarafından yakalanan noktaları bir hat üzerinde birleştirir. Bu işlemler sırasında LP’ nin düşük frekanslı bileşenleri, YFK’ nin yüksek frekanslı bileşenleri elde ederek birbirini tamamlar nitelikte olması sayesinde çoklu-seviyeli bant ayrıştırma gerçekleştirilebilir (Do ve Vetterli, 2005).

2.4.1. Laplas piramidi

Laplas piramidinde temel fikir sinyal için alçak geçiren filtreleme ve aşağı örnekleme olmak üzere yaklaşımlar türetmektir. Bu yaklaşıma dayanarak orijinal sinyal tahmin edilmeye çalışılır. Daha sonra hata faktörleri öngörülür. Yeniden oluşturmada sinyal; sinyalin tahminine hatanın eklenmesi ile elde edilir. Bu süreç tekrarlanabilir niteliktedir. Şekil 2.13 (a) ve (b)’ de Laplas piramidinin analiz ve sentez basamakları gösterilmiştir. Şekil 2.13’ de c tahmin edilen sinyal, d tahmin edilen sinyal ile orijinal


sinyal arasındaki farktır. Bu süreç tahmin edilen sinyalinin orijinale yakınlaştırılması için tekrarlanabilir.



Şekil 2.13. Laplas piramidi şeması a) analiz b) sentez karşılaştırılması (Do ve Vetterli, 2005)

2.4.2. Yönsel filtre kümesi


İki boyutlu YFK fikri Bamberger ve Smith (1992) tarafından ortaya atılmıştır. YFK l -seviye ağaç yapısı ile ayrıştırma gerçekleştirir. Bu ayrıştırmada 2^l adet alt frekans bölümü oluşmaktadır. Şekil 2.14' de 3. seviye ayrıştırma sonucu oluşan 8 adet alt frekans bölümü gösterilmiştir.




Şekil 2.14. Yönsel filtre kümesi ile frekans bölümlenme ($l=3$ ve alt frekans bölümü sayısı $2^l=8$) (Do ve Vetterli, 2005)

Görüntü üzerinden istenilen bir frekans kısmını elde etmek için YKF genişletilebilir. YFK, görüntünün yüksek frekans bileşenlerini yakalamak için

tasarlanmıştır. Bu nedenle YFK ile alçak frekans bileşenlerinin yakalanmasında başarı sağlanamaz. Bu durumu düzeltmek için düşük frekanslar LP kullanılarak YFK işleminden önce elde edilir. LP ve YFK kullanılarak oluşturulan bu yapıyı piramitsel YFK olarak isimlendirmek mümkündür. Şekil 2.15’ de piramitsel yönsel filtre kümesi gösterilmektedir. Şekil 2.16’ de ise CoD ve 1NCuD’ nün genel işleyişi karşılaştırılmıştır.



Şekil 2.15. Piramitsel yönsel filtre kümesi a) çok ölçekli ayrıştırma ve yönsel ayrıştırma ile piramitsel yönsel filtre kümesinin uygulanması b) sayı ve yönü değiştirilebilir frekans alt bölümleri (Do ve Vetterli, 2005)



Şekil 2.16. 1NCuD ve CoD’ nin genel işleyişinin karşılaştırılması

2.5. Ripplet-1 Dönüşümü

CuD iki boyutlu verileri alt pencerelere ayırarak analiz eder. Şekil 2.10' da CuD' nin iki boyutlu verileri analiz ederken kutupsal ve kartezyen koordinat sisteminde kullandığı pencereler görülmektedir. Şekil 2.10' dan da anlaşılacağı gibi CuD' de kullanılan pencere uzunluğu ile genişliği arasında karesel bir oran vardır. Eşitlik (2.30)' de verilen bu oranın amacı analiz verimliliğini artırmaktır.

$$genişlik = uzunluk^2 \quad (2.30)$$

Ancak bu sabit oran dönüşümün hareket alanını kısıtlar. Rip-1D ile yeni tanımlanan c (destek) ve d (derece) parametreleri ile bu sabitlik ortadan kaldırılmış ve CuD geliştirilmiştir (Xu ve ark., 2010). Eşitlik (2.31)' de Rip-1D' deki uzunluk ve genişlik arasındaki yeni ilişki verilmiştir. Bu denklemden de görüleceği gibi $c=1$ ve $d=2$ için Rip-1D, CuD' yi ifade etmektedir.

$$genişlik = c.uzunluk^d \quad (2.31)$$

2.5.1. Sürekli ripplet-1 dönüşümü

CuD' nin geliştirilmesi ile elde edilen iki boyutlu ana ripplet-1 fonksiyonu a ölçek, $\vec{b}$ konum ve θ yön (açı) parametreleri olmak üzere eşitlik (2.32) ile tanımlanabilir (Xu ve ark., 2010).

$$\rho_{a\vec{b}\theta}(\vec{x}) = \rho_{a\vec{0}\theta}(R_\theta(\vec{x} - \vec{b})) \quad (2.32)$$

Eşitlik (2.32)' de R_θ rotasyon matrisidir ve $R_\theta = \begin{pmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{pmatrix}$ olarak ifade edilir.

Ripplet-1 fonksiyonunun Fourier domenindeki karşılığı ise eşitlik (2.33) ile ifade edilebilir.

$$\hat{\rho}_\theta(r, w) = \frac{1}{\sqrt{c}} a^{\frac{1+d}{2d}} w(a.r) v\left(\frac{a^{\frac{1}{d}}}{c.a} . \omega\right) \quad (2.33)$$

Eşitlik (2.33)' de w radyal, v ise açısall pencereleri ifade etmektedir. Sürekli frekans düzleminde bir $f(\vec{x})$ fonksiyonunun sürekli ripplet-1 dönüşümü (SRip-1D) katsayıları ise eşitlik (2.34) ile hesaplanır (Xu ve ark., 2010).

$$R(a, \vec{b}, \theta) = \langle f, \rho_{a\vec{b}\theta} \rangle = \int f(\vec{x}) \overline{\rho_{a\vec{b}\theta}(\vec{x})} d\vec{x} \quad (2.34)$$

2.5.2. Ayırık ripplet-1 dönüşümü

SRip-1D kutupsal koordinat sisteminde tanımlıdır. SRip-1D ' nün kartezyen koordinat sisteminde tanımlanması ile ayırık versiyonu oluşturulmuştur (Xu ve ark., 2010). SRip-1D ' deki a , $\vec{b}$ ve θ parametrelerinin ayırık parametre karşılıkları $a_j = 2^{-j}$, $\vec{b}_k = [c.2^{-j}.k_1, 2^{-j/d}.k_2]^T$, $\theta_l = \frac{2\pi}{c} 2^{-|j(1-1/d)|.l}$ dir. $d = n/m$ ($n, m \neq 0 \in \mathbb{Z}$) olmak üzere Rip-1D ' nin ayırık versiyonu Fourier domeninde eşitlik (2.35) ile ifade edilebilir (Xu ve ark., 2010).

$$\hat{\rho}_j(r, w) = \frac{1}{\sqrt{c}} a^{\frac{m+n}{2n}} w(2^{-j}.r) v\left(\frac{1}{c} 2^{-|j\frac{m-n}{n}|} .\omega - l\right) \quad (2.35)$$

Kartezyen koordinat sisteminde tanımlı ve $M \times N$ boyutlarındaki bir görüntünün ayırık ripplet-1 dönüşümü katsayıları ise eşitlik (2.36) ile hesaplanır (Xu ve ark., 2010).

$$R_{j, \vec{k}, l} = \sum_{n_1=0}^{M-1} \sum_{n_2=0}^{N-1} f(n_1, n_2) \cdot \overline{\rho_{j, \vec{k}, l}(n_1, n_2)} \quad (2.36)$$


2.5.3. Hızlı ayırık ripplet-1 dönüşümü

Bu tez çalışması ile daha önce sürekli ve ayırık versiyonu tanımlanan Rip-1 D' nin hızlı ayırık versiyonu tanımlanmıştır. Bu amaçla öncelikle Rip-1D sayısal olarak tanımlanmıştır. Sayısal Rip-1D katsayıları eşitlik (2.37) ile hesaplanır.

$$r_{j, \vec{k}, l} := \left\langle f \cdot \rho_{j, \vec{k}, l}^D \right\rangle = \int_{\mathbb{R}^2} \hat{f}(v) \tilde{\rho}_j^D(S_{\theta_j}^{-1}v) e^{iS_{\theta_j}^{-T}m.v} dv \quad (2.37)$$

Eşitlik (2.37)' de yer alan $m \approx [c.2^{-j}.k_1, 2^{-j/d}.k_2]$ ve S_{θ} eşitlik (2.29)' da verilen kesme matrisidir. Kesme matrisi S_{θ} , R_{θ} rotasyon matrisinin sayısal karşılığıdır.

Hızlı ayırık ripplet-1 dönüşümü (HARip-1D) inşa edilirken ilk olarak 2BHFD kullanılır. 2BHFD sayesinde görüntü iki boyutlu frekans düzlemi dilimlerine ayrılır. Bu dilimler açısal ve radyal bir şekle sahiptir. Daha sonra HARip-1D özellik katsayılarının oluşturulması için 2BHFD kullanılır. Bu aşamada oluşan frekans düzlemi dilimlerinde HACuD' den farklı olarak $[2^{-j}, 2^{-j/2}]$ yerine $[c.2^{-j}, 2^{-j/d}]$ oranı kullanılmıştır. Şekil 2.17' de HARip-1D iki boyutlu frekans düzlemi dilimleri verilmiştir.



Şekil 2.17. HARip-1D iki boyutlu frekans düzlemi dilimleri

Sayısal uygulamalardan da yararlanılarak HARip-1D, eşit olmayan aralıklı hızlı Fourier dönüşümü ve kaydırma yoluyla oluşturulur. Bu uygulamada kaydırma işleminde sayısal Rip-1D’ de yararlanılan normal ızgara yerine eğik ızgara kullanılır. Kaydırma yoluyla HARip-1D’ nin oluşturulması dört ana adımda gerçekleştirilir. Bu işlemlerde kullanılan kaydırma penceresinin boyutu yaklaşık olarak $c.2^j \times 2^{j/d}$ (*genişlik* $\approx c \times (\text{uzunluk})^d$)’ dir.

Adım 1: $\hat{f}[n_1, n_2]$ frekans düzlemi dilimlerini elde etmek için iki boyutlu hızlı Fourier dönüşümü katsayıları hesaplanır.

Adım 2: Her (j, l) ölçek ve açılı dilime interpolasyon uygulanır $(\tilde{U}_{j,l}[n_1, n_2] \hat{f}[n_1, n_2])$.

Adım 3: İlk iki adımda elde edilen interpolasyonu yapılmış dilimlerin orijin etrafında kaydırılması yapılarak $\tilde{f}[n_1, n_2] = W(\tilde{U}_{j,l} \tilde{f})[n_1, n_2]$ elde edilir. Burada sırasıyla n_1 ve n_2 ; $0 \leq n_1 \leq L_{1,j}$ ve $0 \leq n_2 \leq L_{2,j}$ aralığındadır.

Adım 4: Her bir $\tilde{f}_{j,l}$ kaydırılmış dilimine iki boyutlu hızlı ters Fourier dönüşümü uygulayarak HARip-1D özellik katsayıları elde edilir.

HARip-1D’ de, kaydırma penceresinin genişliği ve uzunluğu arasındaki ilişkinin (*genişlik* $= c \times (\text{uzunluk})^d$) kartezyen koordinat sisteminde çalışılması sebebiyle tam olarak uygulanması mümkün değildir. Bu sebeple HACuD’ de olduğu gibi bu oranın yaklaşık eşdeğerleri kullanılmıştır. Bu tez çalışması ile tanımlanan HARip-1D’ nin farklı a (ölçek), c (destek) ve d (derece) parametreleri için frekans düzlemi dilimlerini oluşturmak amacıyla kullandığı ayrışım ağacı Çizelge 2.1’ de verilmiştir.

Çizelge 2.1. Hızlı ayırık ripplet-1 dönüşümü ayrışım ağacı (a (ölçek), c (destek) ve d (derece))


	$c=1, d=2$	$c=1, d=3$	$c=1, d=4$	$c=1, d=5$
$a=4$	[1,2,2]	[1,2,2]	[1,2,4]	[1,2,4]
$a=5$	[1,2,2,4]	[1,2,2,4]	[1,2,4,8]	[1,2,4,8]
$a=6$	[1,2,2,4,4]	[1,2,4,4,8]	[1,2,4,8,8]	[1,2,4,8,16]
$a=7$	[1,2,2,4,4,8]	[1,2,4,4,8,16]	[1,2,4,8,8,16]	[1,2,4,8,16,16]

2.5.4. Kompleks değerli hızlı ayırık ripplet-1 dönüşümü


Kompleks değerli SRip-1D, reel değerli SRip-1D 'nin simetrikleştirilmesi ile kolaylıkla elde edilebilir. $\hat{\rho}_j(r, \omega + \pi)$ dönüşümün imajiner kısmını ifade etmek üzere kompleks değerli SRip-1D fonksiyonu $\hat{\rho}_j(r, \omega) + \hat{\rho}_j(r, \omega + \pi)$ olarak tanımlanabilir. Aynı şekilde bu tez çalışması ile tanımlanan HARip-1D dönüşümünün kompleks versiyonu, θ_l yanında $\theta_l + \pi$ açı düzleminin kullanılmasıyla kolaylıkla tanımlanabilir. Kompleks değerli hızlı ayırık ripplet-1 dönüşümü (KD HARip-1D) özellik katsayıları $KD HARip-1D_R$ ve $KD HARip-1D_I$ sırasıyla reel ve imajiner katsayılar olmak üzere eşitlik (2.38) ile tanımlanır.

$$KD HARip-1D = KD HARip-1D_R + j.KD HARip-1D_I \quad (2.38)$$

Şekil 2.18, KD HARip-1D özellik katsayılarının reel ve imajiner bileşenlerinden oluşumunu göstermektedir.

**Şekil 2.18.** KD HARip-1D özellik katsayılarının oluşumu

Şekil 2.19’ da Lena görüntüsünün c (destek)=1 ve d (derece)=3 değerleri için bir adet reel ve imajiner HARip-1D katsayısı ve bu katsayıların eşitlik (2.38) kullanılarak birleştirilmesi ile elde edilen KDHARip-1D katsayı görselleri verilmiştir.




Şekil 2.19. a) Lena görüntüsü b) Reel HARip-1D özellik katsayıları (c (destek)=1, d (derece)=3) c) İmajiner HARip-1D özellik katsayıları katsayıları (c (destek)=1, d (derece)=3) d) KDHARip-1D özellik katsayıları katsayıları (c (destek)=1, d (derece)=3)

3. YAPAY SİNİR AĞI

YSA, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturulabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacıyla geliştirilen bir yapay zeka metodudur (Ceylan, 2004). İnsan beynini taklit eden YSA ilk olarak McCollach ve Pitts (1946) tarafından ortaya atılmıştır. Hebb (1949), Roseblant (1958), Minsky ve Papert (1969), Grossberg (1976), Hopfield (1984) ve Kohonen (1986) gibi başka araştırmacılar tarafından yapılan öğrenme mantığının modellenmesi çalışmaları ile günümüzdeki halini almıştır. YSA, öğrenme yeteneği, kolayca farklı problemlere uyarlanabilirliği, genelleme yapabilmesi, paralel yapılarından dolayı hızlı çalışabilme yeteneği ve kullanıcının giriş ile çıkış arasındaki ilişkiyi tarif etme mecburiyetinin olmayışı gibi üstünlüklerden dolayı, pek çok uygulamada kullanılmaktadır (Haykin, 1994; Sağiroğlu, 2003). YSA, bir sisteme ilişkin çeşitli parametrelere bağlı olarak tanımlanan girişler ve çıkışlar arasında ilişki kurabilme yeteneğine sahiptir. Bu ilişkinin doğrusal bir formda olması zorunlu değildir (Haykin, 1994).

YSA' lar katman sayısına göre tek ve çok katmanlı olarak ikiye ayrılabilir. Şekil 3.1' de YSA katman yapısı görülmektedir.



Şekil 3.1. YSA katman yapısı

Giriş katmanı, YSA' ya dışarıdan girdilerin geldiği katmandır. Bu katmanda dışarıdan gelecek giriş sayısı kadar nöron bulunmaktadır. Gizli katman ise giriş katmanından çıkan bilgilerin geldiği katmandır. Gizli katmandaki nöron sayıları giriş ve çıkış sayısından bağımsızdır. Birden fazla gizli katman olan ağlarda gizli katmanların kendi aralarındaki nöron sayıları da farklı olabilir. Çıkış katmanı, gizli katmanlardan

gelen bilgileri işleyerek ağıın giriş katmanından gelen verilere karşılık çıktıları üreten katmandır. YSA genel modellemelerine göre incelendiğinde ise ileri beslemeli YSA, kaskat bağlı YSA ve geri beslemeli YSA olmak üzere üç başlık altında incelenebilir. Bu YSA modellerinden geri beslemeli YSA yaygın kullanıma sahiptir (Ceylan, 2004).

3.1. Geri Yayılım Yapay Sinir Ağı

Geri yayılım YSA ileri besleme ve geri yayılım olmak üzere iki temel aşamadan oluşur. YSA' ya giriş verilerin verildiği aşama olan ileri besleme sonucunda elde edilen hata fonksiyonu kullanılarak geri yayılım yapılır ve ağırlıklar güncellenir (Ceylan, 2004). Toplam hatanın minimuma indirilmesi amacıyla gradyan iniş metodu kullanılır.

3.1.1. Gradyan iniş metodu

Türevlenebilir tek değişkenli bir fonksiyon üzerindeki bir noktanın bu fonksiyonun türevinde yerine yazıldığında elde edilecek değer, fonksiyonun eğrisine bu noktada teğet geçen doğrunun eğimidir. Bu doğrunun eğimi, fonksiyondaki artışın hızını ve yön bilgisini verir. Eğime bakılarak yerel minimum noktasının ne yönde olduğu tespit edilebilir. Eğer eğim sıfırdan büyükse minimum değer negatif yönde, sıfırdan küçükse pozitif yönde kaldığı anlaşılır. Fonksiyonun minimum değerine yaklaşıldıkça, teğetlerin eğimi azalır. Bu durumdan yararlanılarak, eğimin adım adım azaltılması suretiyle minimum değerlere yaklaşılması amaçlanır.

Türevi alınabilen tek değişkenli herhangi bir fonksiyonun verilen ilk değere en yakın yerel minimum noktası, gradyan iniş metodu kullanılarak kabul edilebilir bir fark ile tespit edilebilir. Bunun için öncelikle bir başlangıç noktası tespit edilir. Daha sonra adım katsayısı ve duyarlılık değerleri isteğe göre belirlenir. Ancak adım katsayısının belirlenmesinde bazı hususlar göz önünde bulundurulmalıdır. Bu katsayı çok küçük seçildiğinde adımlar küçük olur ve minimuma yaklaşma süreci uzar. Adım katsayısı çok büyük seçildiğinde ise minimum noktanın tek adımda aşılması ve noktanın diğer tarafına geçilmesi söz konusu olabilir. Bu durumda noktanın iki yanına sürekli gidilip gelinir ve nokta yakalanamaz. Bu durumu engellemek için η adım katsayısı olmak üzere eşitlik (3.1) dikkate alınmalıdır.


$$f(x - \eta \cdot f'(x)) < f(x) \quad (3.1)$$

Adım katsayısı ve duyarlılık belirlendikten sonra atılan adımın büyüklüğü, belirlenen duyarlılık değerinden küçük olana kadar $-f'(x)$ yönünde ilerlenerek yerel minimum noktasına yaklaşılır. Eğim azaldıkça adımlar küçüleceğinden, yerel minimuma yaklaşıldıkça adım büyüklüğü duyarlılık değerine yaklaşır. Adım büyüklüğü duyarlılık değerinin altında kaldığında yerel minimuma ulaşılmış olur. Gradyan iniş metodunun genel ifadesi eşitlik (3.2)'de görülmektedir.

$$F(p - \eta \cdot \nabla F(p)) < F(p) \text{ ve } \nabla F = \left(\frac{dF}{dx_1}, \frac{dF}{dx_2}, \dots, \frac{dF}{dx_n} \right) \quad (3.2)$$

3.1.2. İleri besleme

İleri besleme, sinir ağının verilerle beslenerek ağdan çıkış alındığı aşamadır (Sağıroğlu, 2003). Hata tespiti ağdan çıkış alınmadan yapılamayacağından ileri besleme, sonraki adımların da bir parçasıdır. Her nöronun birden fazla girişi ve sadece bir çıkışı vardır. Giriş nöronları hariç tüm nöronların her bir girişi, önceki katmanda bulunun bir başka nöronun çıkışı ile ilişkilidir. Çıkış sinyalleri, sonraki katmanda bulunan nöronlara iletilirken arada bulunan dentrit ağırlık katsayıları ile çarpılır. Çarpım, sonraki nöron için bir giriş sinyali niteliğindedir. Bir nöron çıkış üretirken kendisine iletilen tüm giriş sinyallerini toplar ve bu toplamı aktivasyon fonksiyonundan geçirir. Nöron girişi Z_i , ağırlık katsayısı $W_{z,i}$ ve g aktivasyon fonksiyonu olmak üzere temel sinir yapısı Şekil 3.2' de görülmektedir.



Şekil 3.2. Temel sinir yapısı

Sinir girişine gelen verilerin toplamını ifade eden $Y_{Ağ}$ fonksiyonu ve sinir çıkışını ifade eden $Y_{Çıkış}$ fonksiyonu eşitlik (3.3) ile ifade edilir.

$$Y_{Ağ} = \sum_{i=1}^M W_{z,i} \cdot Z_i \text{ ve } Y_{Çıkış} = g(Y_{Ağ}) \quad (3.3)$$

Aktivasyon fonksiyonu olarak signum, doyum, doğrusal, modifiye edilmiş sinüs, arktanjan, sigmoid ve ötelenmiş sigmoid fonksiyonları kullanılmaktadır (Ceylan, 2004).

3.1.3. Hata fonksiyonu ve ağırlıkların güncellenmesi

Ağdan alınan çıkışların, beklenen değerlere ne kadar uzak olduklarının, gradyan iniş metodu ile minimize edilebilecek bir fonksiyon yardımıyla ölçülmesi gerekir. Geri yayılım algoritmasında, en küçük kareler ortalaması, hata fonksiyonu olarak kullanılır. Her bir çıkış değeri ile beklenen çıkış değerinin farkının karesi alınır ve kareler toplanıp ikiye bölünür. Ağdan alınan çıkış $Y_{Çıkış}$, ağdan beklenen çıkış $B_{Çıkış}$ olmak üzere H hata fonksiyonu eşitlik (3.4) ile ifade edilebilir.

$$H = \frac{1}{2} \sum_j (B_{Çıkış(j)} - Y_{Çıkış(j)})^2 \quad (3.4)$$

Hata fonksiyonunun sonucu, gradyan iniş metodu ile minimum değeri olan sıfıra yaklaştırılır. Sonuç sıfıra yaklaştıkça, çıkış değerleri de beklenen değerlere yaklaşır.

Hata fonksiyonu temelde ağırlıklara bağlı olarak değer alır. Gradyan iniş metoduna göre fonksiyonun minimum olmasını sağlayacak ağırlık değerlerinin hesaplanabilmesi için gradyanının alınması ve ağırlıkların, elde edilen vektörel fonksiyonda yerlerine yazılarak bir vektör elde edilmesi gerekir. Daha sonra bu vektör, öğrenme katsayısı ile çarpılarak ağırlıkların meydana getirdiği vektörden çıkarılır. Böylece ağırlıklar her adımda, hata fonksiyonunun sonucunu daha da küçültecek şekilde güncellenir (Sağıroğlu, 2003). Gradyan için metodunda anlatılan η adım katsayısı öğrenme aşamasında öğrenme oranı ismini alır. Tek katmanlı bir ağda kullanılan geri yayılım için yapılacak değişim miktarı eşitlik (3.5)' de verilmiştir.

$$\Delta W_{zj,i} = -\eta \frac{\partial H}{\partial W_{zj,i}} \quad (3.5)$$

Eşitlik (3.5)' de verilen ifade zincirleme türev fonksiyonu kullanılarak eşitlik (3.6)' daki gibi ifade edilebilir.

$$\Delta W_{zj,i} = -\eta \frac{\partial H}{\partial Y_{Çıkış}} \frac{\partial Y_{Çıkış}}{\partial Y_{Ağ}} \frac{\partial Y_{Ağ}}{\partial W_{zj,i}} \quad (3.6)$$

Eşitlik (3.6)' de verilen kısmi türev ifadelerinin açılımı eşitlik (3.7)' de görülmektedir.

$$\frac{\partial H}{\partial Y_{Çıkış}} = -(B_{Çıkış} - Y_{Çıkış}) \text{ ve } \frac{\partial Y_{Ağ}}{\partial W_{zj,i}} = Z_i \quad (3.7)$$

$\delta_{z,j}$ istenen ve o anki sinir çıkış değerleri arasındaki farkı ifade etmek üzere eşitlik (3.6), eşitlik (3.8) ile ifade edilebilir.

$$\Delta W_{zj,i} = +\eta \delta_{z,j} Z_i \text{ ve } \delta_{z,j} = -\frac{\partial H}{\partial Y_{Çıkış}} \frac{\partial Y_{Çıkış}}{\partial Y_{Ağ}} = (B_{Çıkış} - Y_{Çıkış}) \frac{\partial g(Y_{Ağ})}{\partial Y_{Ağ}} \quad (3.8)$$

Ağırlık katsayıları güncellikten sonra ve YSA' nın istenen ve t anındaki çıkış değerleri arasında oluşan hatanın hesaplanmasından önce, t anındaki çıkış değerleri arasındaki farklar aşağıdaki gibi bulunur ve her bir çıkış için hat katsayıları elde edilir.

$$e(t) = B_{Çıkış(t)} - Y_{Çıkış(t)} \quad (3.9)$$

Bu hata katsayıları kullanılarak T adet çıkış sinirine sahip olan bir ağın toplam hatası ise aşağıdaki gibi hesaplanır.

$$ToplamHata = \sqrt{\frac{1}{T} \sum_{t=0}^T e^2(t)} \quad (3.10)$$

4. ARAŞTIRMA SONUÇLARI

4.1. Medikal görüntülerden gürültü temizleme uygulaması

4.1.1. Uygulamada kullanılan görüntüler

Medikal görüntüler röntgen, bilgisayarlı tomografi, manyetik rezonans görüntüleme gibi çeşitli yöntemlerle elde edilebilmektedir. Medikal görüntülemenin gerçekleştiği vücut bölgesi ve bu bölgeye ait görüntü özellikleri, gürültü oluşumunu ve gürültü temizleme başarısını etkilemektedir. Bu sebeple medikal gürültü temizleme sonuçlarının güvenilirliğinin artırılması için birbirinde farklı ve çok sayıda görüntü kullanılmalıdır. Bu amaçla çalışmada retina ve mamografi görüntüsü olmak üzere iki farklı tip medikal görüntü kullanılmıştır.

Retina görüntüleri; diyabetik retinopati gibi sistemik hastalıklara bağlı bozuklukların, makula hastalıklarının ve retina yırtıklarının tespitinde sıklıkla kullanılır. Bu hastalıkların tespitinde kan damar yapılarının veya yırtık bölgelerinin genel retina görüntüsü üzerinde segmentasyonunun yapılması gerekir. Retina görüntüleri üzerinde meydana gelecek gürültüler bu yapıların birbirinden ayrılmasını zorlaştırır. Bu çalışmada medikal görüntülerden gürültü temizlenmesi için DRIVE (Digital Retinal Images for Vessel Extraction) veri tabanına (Staal ve ark., 2004) ait 40 adet retina fundus görüntüsü kullanılmıştır. Bu görüntüler 584×565 boyutlarında ve JPEG formatındadır. DRIVE veri tabanına ait bu görüntülerin boyutları, retina etrafındaki kör (doku bilgisi içermeyen) alanların işlemler üzerindeki etkisini azaltmak amacıyla yeniden düzenlenmiş ve 512×512 olarak ayarlanmıştır. Kırmızı, yeşil ve mavi olmak üzere üç renk uzayına sahip DRIVE veri tabanına ait görüntülerin yeşil renk uzayı kullanılmıştır. Bu aşamada yeşil renk uzayının kullanılmasının özel bir nedeni olmayıp diğer renk uzaylarında görüntüyü aynı işlemlerde temsil edebilecek niteliktedir.

Mamografi görüntüleri; iyi ve kötü huylu dokuların, yapısal bozuklukların ve asimetri gibi anormalliklerin tespitinde kullanılır. Mamografi görüntüleri yapı itibarıyla retina görüntülerinden farklıdır. Mamografi görüntülerinde göğüs dokusuna ait piksel değerleri birbirine çok yakındır. Bu durum anormal bölgelerin segmentasyonunu güçleştirir. Ayrıca, göğüs dokusuna ait piksel değerlerinin birbirine çok yakın olması görüntüdeki gürültüler ile göğüs dokusunun birbirinden ayrılmasını da zorlaştırmaktadır. Bu uygulamada medikal görüntülerden gürültü temizlenmesi için

kullanılan PGM formatındaki 322 adet mamografi görüntüsü MIAS (Suckling ve ark., 1994) veri tabanına aittir. Boyutları 1024×1024 olan bu görüntülerden, göğüs etrafındaki kör (doku bilgisi içermeyen) alanların işlemler üzerindeki etkisini azaltmak amacıyla 512×512 boyutlarında ilgili alanlar belirlenmiştir.

4.1.2. Sonuçlarının değerlendirilmesinde kullanılan performans kriterleri

4.1.2.1. Tepe sinyal gürültü oranı

$M \times N$ boyutlarında f referans görüntü, g test görüntüsü (8 bit) olmak üzere iki görüntü arasındaki tepe sinyal gürültü oranı (TSGO) eşitlik (4.1) ile hesaplanır. Bu denklemde yer alan karesel ortalama hata (KOH) eşitlik (4.2)' de verilmiştir (Huynh-Thu, 2008).

$$TSGO = 10 \cdot \log_{10} \left(\frac{255^2}{KOH(f, g)} \right) \quad (4.1)$$

$$KOH(f, g) = \frac{1}{MN} \cdot \sum_{i=1}^M \sum_{j=1}^N (f_{i,j} - g_{i,j})^2 \quad (4.2)$$

KOH değeri sıfıra yaklaşırken TSGO sonsuza yaklaşır. Bu durum test görüntüsü ile referans görüntünün maksimum derecede örtüştüğünü gösterir.

4.1.2.2. Ortalama yapısal benzerlik indeksi

İki adet görüntü (x, y) arasındaki yapısal benzerlik indeksi (YBİ) hesaplanırken üç bileşen kullanılır. Bunlar, parlaklık bozulması $l(x, y)$, kontrast bozulması $c(x, y)$ ve korelasyon $s(x, y)$ ' dir. c_1 , c_2 ve c_3 sabit değerler olmak üzere bu bileşenler sırasıyla eşitlik (4.3), (4.4) ve (4.5) ile ifade edilebilir (Wang ve ark., 2004).

$$l(x, y) = \frac{2\overline{xy} + c_1}{(\overline{x})^2 + (\overline{y})^2 + c_1} \quad (4.3)$$

$$c(x, y) = \frac{2s_x s_y + c_2}{s_x^2 + s_y^2 + c_2} \quad (4.4)$$

$$s(x, y) = \frac{s_{x,y} + c_3}{2s_x s_y + c_2} \quad (4.5)$$

Burada $\bar{x}$, $\bar{y}$, s_x^2 , s_y^2 ve $s_{x,y}$ sırasıyla x ve y 'nin lokal ortalamaları, lokal varyansları ve x ve y arasındaki kovaryanstır.

$S_1(x, y)$ ve $S_2(x, y)$ yerel pencereler tarafından hesaplanan benzerlik haritaları ve $c_3 = c_2/2$ olmak üzere iki adet görüntü arasındaki YBİ eşitlik (4.6) ile hesaplanır (Wang ve ark., 2004).

$$\begin{aligned} YB\dot{I} &= S_1(x, y) \cdot S_2(x, y) \\ S_1(x, y) &= l(x, y) \\ S_2(x, y) &= c(x, y) \cdot s(x, y) \end{aligned} \quad (4.6)$$

YBİ, lokal kayan pencereler yoluyla hesaplanır (Thakur ve Devi, 2011). Bu pencereler görüntünün sol üst köşesinden sağ alt köşesine kadar hareket eder. M işlemlerde kullanılan kayan pencere sayısı olmak üzere, ortalama yapısal benzerlik indeksi (OYBİ) eşitlik (4.7) ile hesaplanır.

$$OYB\dot{I}(x, y) = \frac{1}{M} \sum_{j=1}^M YB\dot{I}(x_j, y_j) \quad (4.7)$$

Karşılaştırılan görüntülerin benzerliği arttıkça OYBİ değeri 1'e yaklaşır.

4.1.2.3. Özellik benzerlik indeksi

Görüntüler arasındaki bir diğer benzerlik değerlendirme kriteri olan özellik benzerlik indeksi (ÖBİ), faz konfigürasyonu FK , gradyan büyüklüğü GB ve benzerlik ölçütü S kullanılarak hesaplanır. FK modeli, görüntüler üzerindeki yoğunluk değişimlerini belirlemek yerine Fourier bileşenlerinin tanımlanması aşamasında maksimum özellikleri belirler (Zhang ve ark., 2011).

Bir $f(x, y)$ görüntüsünde GB , gradyan operatörü kullanılarak eşitlik (4.8) ile hesaplanır.

$$GB = \sqrt{G_x^2 + G_y^2} \quad (4.8)$$

Burada G_x ve G_y görüntünün yatak ve dikey yönler boyunca türevleridir. İki görüntü arasındaki $S_L(x)$ benzerlik ölçüsü ise $S_{FK}(x)$ faz konfigürasyonları arasındaki benzerlik ve $S_{GB}(x)$ gradyan büyüklükleri arasındaki benzerlik olmak üzere eşitlik (4.9) ile hesaplanır.

$$S_L(x) = [S_{FK}(x)] \cdot [S_{GB}(x)] \quad (4.9)$$

ÖBİ, Ω görüntünün bütününi temsil etmek üzere eşitlik (4.10)' da verilmiştir.

$$ÖBİ = \frac{\sum_{x \in \Omega} S_L(x) FK_m(x)}{\sum_{x \in \Omega} FK_m(x)} \quad (4.10)$$

4.1.3. Uygulamada kullanılan gürültü temizleme yapıları


Gürültülü görüntü I_n , eşitlik (4.11) ile ifade edilebilir. Eşitlik (4.11)' de I orijinal görüntüyü, N gürültüyü ve N_r rastgele gürültüyü ifade etmektedir. Sigma ise görüntüye eklenecek gürültü miktarını belirleyen orandır. Sigma değerinin artması görüntüyü daha gürültülü bir hale getirmektedir.

$$I_n = I + N = I + \text{sigma} * N_r \quad (4.11)$$

Tez çalışmasının bu uygulamasında; 15, 25 ve 35 olmak üzere üç farklı sigma değeri ile elde edilmiş rastgele gürültü kullanılmıştır.

Büzülmeli gürültü temizleme (shrinkage denoising) algoritması, DD, CuD, CoD gibi çoklu çözünürlük dönüşümü özellik katsayılarını kullanarak gürültü temizleme yapan bir algoritmadır (Bao ve ark., 2008). Şekil 4.1, büzülmeli gürültü temizleme algoritmasının genel işleyişini anlatmaktadır. Bu algoritmayı bu tez çalışması ile tanımlanan RDHARip-1D ve KDHARip-1D özellik katsayıları ile kullanmakta mümkündür. Bu algoritmada, yumuşak ve sert eşikleme olmak üzere iki farklı eşikleme yaklaşımı vardır (Bao ve ark., 2008). Sert eşiklemede sonuç görüntüsüne ait özellik katsayıları oluşturulurken yalnızca 0 ve gürültülü görüntü özellik katsayı değerleri kullanılmaktadır. Yumuşak eşiklemede ise sonuç görüntüsüne ait özellik katsayıları oluşturulurken 0 ve gürültülü görüntü özellik katsayı değerleri haricinde ara değerlerden

de yararlanılmaktadır. Bu durum yumuşak eşikleme yapılarak elde edilen gürültüsü temizlenmiş görüntü üzerindeki sert çizgisel geçişlerin yumuşamasına neden olmaktadır. Medikal görüntüler kullanılarak teşhis yapılırken görüntüler üzerindeki çizgisel yapılar büyük önem taşımaktadır. Bu sebeple, tez çalışmasının bu uygulamasında sert eşikleme kullanılmıştır.



Şekil 4.1. Büzülmeli gürültü temizleme algoritmasının 3. seviye çoklu çözünürlük dönüşümü özellik katsayılarını kullanarak gürültü temizlemesi

Sert eşikleme kullanan büzülmeli gürültü temizleme algoritması eşitlik (4.12) ile tanımlanabilir.

$$\hat{M}_k(j, l) = \begin{cases} 0 & |M_k(j, l)| < T(j, l) \\ M_k(j, l) & |M_k(j, l)| \geq T(j, l) \end{cases} \quad (4.12)$$

Eşitlik (4.12)' de $T(j, l)$, j ölçek ve l açı parametresi olmak üzere eşikleme fonksiyonu

ve $M_k(j, l)$, HARip-1D özellik katsayısıdır. $\hat{M}_k(j, l)$ ise sonuç fonksiyonudur.

Eşikleme fonksiyonu $T(j, l)$ eşitlik (4.13) ile ifade edilebilir (Bao ve ark., 2008).

$$T(j, l) = k \cdot \varepsilon_{(j, l)} \cdot \sigma \quad (4.13)$$

Eşitlik (4.13)' de $\varepsilon_{(j, l)}$, j ölçek ve l açı parametresi olmak üzere HARip-1D özellik katsayısına ait beyaz gürültü ortalama enerji dağılımını ifade etmektedir. σ beyaz gürültünün standart sapması, k ise eşikleme sabitidir. Eşikleme sabiti, literatürde genellikle 3 olarak kullanılmakla birlikte eşikleme sabitinin farklı değerleri için gürültü temizleme sonuçlarının etkilendiği bilinmektedir. Tez çalışmasının bu uygulamasında, sabit eşikleme sabiti kullanmak yerine 2.1 ile 3.4 arasında 0.1 artırımlar ile değişim yapılarak farklı eşikleme sabitleri için gürültü temizleme sonuçları elde edilmiştir.

KDHARip-1D için gürültü temizleme işlemleri aynı yöntemle gerçekleştirilmiştir. Ancak gürültüsü temizlenmiş katsayılar kullanılarak dönüşümün tersine işletilmesi ile elde edilen görüntü matris elemanları karmaşık sayılardan oluşmaktadır. Bu sebeple matris elemanlarının mutlak değerleri eşitlik (4.14) kullanılarak hesaplanmış ve TSGO, OYBİ ve ÖBİ hesaplarında bu sonuçlar kullanılmıştır. Eşitlik (4.14)' de $görüntü_R$ görüntü matris elemanlarının reel kısımlarını, $görüntü_I$ görüntü matris elemanlarının imajiner kısımlarını ifade etmektedir.

$$görüntü_{(a,b)} = \sqrt{(görüntü_{R_{(a,b)}})^2 + (görüntü_{I_{(a,b)}})^2} \quad (4.14)$$

4.1.4. Gürültü temizleme

Bu çalışmada RDHARip-1D ve KDHARip-1D özellik katsayıları kullanılarak medikal görüntülerden gürültü temizleme uygulaması gerçekleştirilmiştir. Çalışmada öncelikle, kullanılacak gürültülü görüntü örneklerini elde etmek için orijinal görüntülere üç farklı sigma değerine sahip (15, 25, 35) rastgele gürültü uygulanmıştır. Elde edilen gürültülü görüntülerin RDHARip-1D ve KDHARip-1D özellik katsayıları dört farklı a (ölçek) ile dört farklı c (destek) ve d (derece) değerleri için elde edilmiştir. Elde edilen RDHARip-1D ve KDHARip-1D özellik katsayıları üzerindeki gürültüler sert eşikleme kullanan büzülmeli gürültü temizleme algoritması ile temizlenmiştir. Temizleme işlemi eşikleme sabitinin 2.1' den başlayarak 0.1 artımlar ile 3.4' e kadar artırılarak ayrı ayrı tekrarlanmıştır. Sert eşikleme ile eşiklenmiş katsayılar kullanılarak dönüşümler tersine işletilmiş ve görüntüler yeniden oluşturulmuştur. Çalışmada son olarak orijinal görüntü ile gürültüsü temizlenmiş görüntüler arasındaki TSGO, OYBİ ve ÖBİ değerleri hesaplanmıştır. Sonuçların kararlılığının artırılması amacıyla bu işlemler görüntü gruplarındaki her görüntü için 25 kez tekrarlanmış ve sonuçların ortalamaları alınmıştır.

4.1.5. Uygulama sonuçları

4.1.5.1. Retina görüntülerinden gürültü temizleme uygulama sonuçları

Gürültü temizleme uygulamasında 40 adet retina görüntüsüne üç farklı sigma değeri (15, 25, 35) için gürültü eklenmesiyle elde edilen gürültülü görüntüler ile orijinal görüntüler arasındaki ortalama TSGO değerleri Çizelge 4.1' de verilmiştir.

Çizelge 4.1. Retina görüntülerine farklı sigma değerleri için gürültü eklenmesi ile oluşan ortalama TSGO sonuçları

	Sigma=35	Sigma=25	Sigma=15
Ortalama TSGO (dB)	17.24	20.17	24.60

Gürültülü retina görüntülerinden gürültü temizleme sonuçlarının verildiği Çizelge 4.2-4.4 incelendiğinde, en başarılı gürültü temizleme sonuçları a (ölçek) değerinin 5 olması durumunda elde edilmiştir. Ayrıca gürültü temizleme uygulamalarında önemli bir etken olan eşikleme sabitinin KDHARip-1D ile RDHARip-1D ile yapılan işlemlerde farklı kullanılması gerektiği görülmektedir. Bu görüntüler için RDHARip-1D katsayıları ile yapılan gürültü temizleme uygulamasında eşikleme sabitinin 2.7 ile 3.3 arasındaki değerleri için başarılı sonuçlar elde edilmiştir. KDHARip-1D katsayıları ile yapılan gürültü temizleme uygulamasında ise bu değerler arasında elde edilen sonuçların RDHARip-1D katsayıları ile yapılan uygulama sonuçlarına göre düşük olduğu görülmektedir. KDHARip-1D katsayıları ile yapılan gürültü temizleme uygulamasında eşikleme sabitinin 2.2 ile 2.5 arasındaki değerleri için başarılı sonuçlar elde edilmiştir. Ayrıca bu aralıkta elde edilen TSGO değerleri bu gürültü temizleme uygulamalarında elde edilen en iyi sonuçlardır. Çizelge 4.2-4.4 incelendiğinde, sigma=35 için 17.24 dB olan gürültülü görüntülerin ortalama TSGO değerinin RDHARip-1D ile 33.042 dB' e, KDHARip-1D ile 33.300 dB' e kadar yükseltildiği görülmektedir. Benzer şekilde; sigma=25 için 20.17 dB olan gürültülü görüntülerin ortalama TSGO değeri RDHARip-1D ile 34.387 dB, KDHARip-1D ile 34.579 dB; sigma=15 için 24.60 dB olan gürültülü görüntülerin ortalama TSGO değeri RDHARip-1D ile 36.322 dB, KDHARip-1D ile 36.443 dB seviyesine çıkarılmıştır.

Şekil 4.2' de çalışmalarda kullanılan orijinal retina görüntüsü, üç farklı sigma değeri için gürültü uygulanmış görüntüler ve farklı c (destek) ve d (derece) değerleri için gürültü temizleme yapılması ile yeniden elde edilmiş görüntüler yer almaktadır.

Çizelge 4.2. Retina görüntülerinden gürültü temizleme uygulaması TSGO sonuçları ($\sigma=35$, a (ölçek), c (destek), d (derece), k (eşikleme sabiti))

Reel değerli hızlı ayrık ripplet-1 (curvelet) dönüşümü $c=1, d=2$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	30.16	30.70	31.15	31.57	31.92	32.19	32.41	32.58	32.68	32.74	32.75	32.73	32.69	32.64
$a=6$	30.22	30.77	31.26	31.70	32.06	32.34	32.57	32.75	32.86	32.94	32.97	32.95	32.92	32.86
$a=5$	30.25	30.80	31.30	31.74	32.08	32.38	32.61	32.80	32.93	33.00	33.04	33.04	33.02	32.98
$a=4$	29.76	30.24	30.65	31.02	31.30	31.56	31.74	31.90	32.01	32.07	32.11	32.13	32.16	32.14

Kompleks değerli hızlı ayrık ripplet-1 (curvelet) dönüşümü $c=1, d=2$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	32.69	32.90	33.01	33.05	33.03	32.97	32.89	32.81	32.69	32.59	32.47	32.38	32.28	32.19
$a=6$	32.84	33.07	33.19	33.24	33.24	33.18	33.12	33.03	32.91	32.82	32.70	32.58	32.49	32.39
$a=5$	32.87	33.11	33.24	33.30	33.30	33.25	33.19	33.12	33.03	32.96	32.86	32.75	32.67	32.56
$a=4$	31.98	32.16	32.28	32.34	32.37	32.36	32.34	32.30	32.25	32.21	32.12	32.08	32.04	31.98

Reel değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=3$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	30.04	30.57	31.03	31.42	31.74	32.00	32.20	32.35	32.43	32.48	32.48	32.46	32.43	32.39
$a=6$	30.19	30.73	31.19	31.61	31.97	32.24	32.47	32.64	32.74	32.81	32.83	32.81	32.78	32.72
$a=5$	30.20	30.76	31.24	31.69	32.04	32.33	32.56	32.75	32.88	32.96	33.00	32.99	32.97	32.92
$a=4$	29.74	30.22	30.64	31.02	31.31	31.57	31.75	31.90	32.02	32.09	32.13	32.15	32.17	32.16

Kompleks değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=3$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	32.47	32.67	32.76	32.78	32.75	32.70	32.62	32.54	32.44	32.34	32.25	32.15	32.03	31.93
$a=6$	32.74	32.97	33.07	33.11	33.10	33.03	32.97	32.89	32.77	32.67	32.55	32.44	32.36	32.27
$a=5$	32.81	33.05	33.18	33.25	33.25	33.20	33.14	33.08	32.99	32.90	32.81	32.71	32.63	32.54
$a=4$	32.00	32.19	32.30	32.36	32.39	32.37	32.35	32.30	32.25	32.21	32.12	32.08	32.04	31.98

Reel değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=4$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	29.99	30.50	30.95	31.32	31.62	31.86	32.03	32.16	32.24	32.27	32.27	32.23	32.20	32.14
$a=6$	30.14	30.67	31.14	31.54	31.88	32.15	32.38	32.53	32.61	32.67	32.68	32.66	32.64	32.58
$a=5$	30.26	30.81	31.29	31.72	32.07	32.36	32.60	32.78	32.90	32.98	33.02	33.01	32.99	32.94
$a=4$	29.74	30.22	30.64	31.02	31.31	31.57	31.75	31.90	32.02	32.09	32.13	32.15	32.17	32.16

Kompleks değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=4$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	32.31	32.48	32.56	32.56	32.53	32.48	32.38	32.28	32.18	32.08	31.98	31.87	31.73	31.61
$a=6$	32.62	32.84	32.93	32.95	32.94	32.89	32.82	32.74	32.62	32.53	32.42	32.32	32.23	32.13
$a=5$	32.84	33.08	33.20	33.27	33.27	33.22	33.17	33.11	33.02	32.93	32.83	32.73	32.65	32.56
$a=4$	32.00	32.19	32.30	32.36	32.39	32.37	32.35	32.30	32.25	32.21	32.12	32.08	32.04	31.98

Reel değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=5$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	30.00	30.50	30.93	31.29	31.57	31.80	31.96	32.07	32.14	32.17	32.17	32.15	32.11	32.05
$a=6$	30.11	30.65	31.13	31.52	31.86	32.14	32.36	32.51	32.60	32.66	32.67	32.65	32.64	32.59
$a=5$	30.26	30.81	31.29	31.72	32.07	32.36	32.60	32.78	32.90	32.98	33.02	33.01	32.99	32.94
$a=4$	29.74	30.22	30.64	31.02	31.31	31.57	31.75	31.90	32.02	32.09	32.13	32.15	32.17	32.16

Kompleks değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=5$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	32.18	32.32	32.41	32.42	32.40	32.35	32.25	32.16	32.07	31.98	31.88	31.76	31.64	31.53
$a=6$	32.60	32.82	32.92	32.95	32.94	32.89	32.82	32.74	32.63	32.54	32.44	32.33	32.24	32.15
$a=5$	32.84	33.08	33.20	33.27	33.27	33.22	33.17	33.11	33.02	32.93	32.83	32.73	32.65	32.56
$a=4$	32.00	32.19	32.30	32.36	32.39	32.37	32.35	32.30	32.25	32.21	32.12	32.08	32.04	31.98

Çizelge 4.3. Retina görüntülerinden gürültü temizleme uygulaması TSGO sonuçları ($\sigma=25$, a (ölçek), c (destek), d (derece), k (eşikleme sabiti))

Reel değerli hızlı ayrık ripplet-1 (curvelet) dönüşümü $c=1, d=2$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	32.28	32.69	33.04	33.34	33.60	33.77	33.90	33.99	34.05	34.08	34.06	34.03	33.99	33.92
$a=6$	32.35	32.79	33.17	33.50	33.75	33.94	34.09	34.18	34.25	34.29	34.27	34.25	34.21	34.16
$a=5$	32.43	32.87	33.26	33.59	33.84	34.03	34.19	34.29	34.36	34.39	34.38	34.37	34.34	34.30
$a=4$	32.10	32.50	32.84	33.13	33.35	33.54	33.68	33.77	33.84	33.87	33.89	33.88	33.87	33.83

Kompleks değerli hızlı ayrık ripplet-1 (curvelet) dönüşümü $c=1, d=2$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	34.12	34.23	34.29	34.31	34.26	34.21	34.13	34.04	33.93	33.83	33.75	33.67	33.56	33.47
$a=6$	34.28	34.41	34.45	34.48	34.44	34.39	34.31	34.23	34.14	34.04	33.96	33.87	33.77	33.66
$a=5$	34.37	34.53	34.58	34.58	34.56	34.51	34.44	34.36	34.29	34.20	34.12	34.02	33.93	33.84
$a=4$	33.82	33.95	34.03	34.04	34.04	34.00	33.95	33.91	33.85	33.80	33.73	33.69	33.64	33.59

Reel değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=3$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	32.12	32.54	32.89	33.18	33.41	33.58	33.70	33.78	33.84	33.84	33.81	33.79	33.75	33.67
$a=6$	32.30	32.71	33.06	33.36	33.62	33.80	33.94	34.03	34.10	34.13	34.11	34.08	34.05	33.98
$a=5$	32.36	32.81	33.19	33.52	33.78	33.97	34.12	34.23	34.32	34.35	34.34	34.33	34.31	34.27
$a=4$	32.08	32.48	32.83	33.13	33.37	33.55	33.69	33.78	33.85	33.90	33.92	33.91	33.90	33.86

Kompleks değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=3$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	33.91	34.02	34.08	34.07	34.02	33.96	33.88	33.79	33.67	33.57	33.46	33.37	33.25	33.16
$a=6$	34.14	34.27	34.33	34.35	34.30	34.25	34.17	34.09	33.97	33.87	33.79	33.71	33.61	33.51
$a=5$	34.32	34.47	34.52	34.54	34.52	34.48	34.42	34.34	34.25	34.17	34.10	34.00	33.90	33.81
$a=4$	33.85	33.99	34.06	34.08	34.08	34.04	33.99	33.95	33.89	33.83	33.77	33.73	33.67	33.62

Reel değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=4$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	32.04	32.45	32.79	33.06	33.26	33.43	33.54	33.61	33.65	33.65	33.62	33.58	33.53	33.45
$a=6$	32.23	32.64	33.00	33.28	33.52	33.70	33.84	33.92	33.97	33.99	33.96	33.94	33.90	33.82
$a=5$	32.40	32.84	33.22	33.53	33.79	33.99	34.14	34.25	34.32	34.35	34.34	34.34	34.31	34.28
$a=4$	32.08	32.48	32.83	33.13	33.37	33.55	33.69	33.78	33.85	33.90	33.92	33.91	33.90	33.86

Kompleks değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=4$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	33.74	33.84	33.87	33.85	33.81	33.74	33.65	33.55	33.45	33.36	33.24	33.14	33.02	32.93
$a=6$	34.03	34.15	34.21	34.21	34.16	34.11	34.02	33.92	33.81	33.71	33.60	33.51	33.41	33.31
$a=5$	34.32	34.46	34.52	34.54	34.53	34.49	34.43	34.36	34.28	34.20	34.12	34.03	33.94	33.84
$a=4$	33.85	33.99	34.06	34.08	34.08	34.04	33.99	33.95	33.89	33.83	33.77	33.73	33.67	33.62

Reel değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=5$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	32.03	32.42	32.74	32.99	33.17	33.33	33.42	33.47	33.49	33.49	33.45	33.40	33.35	33.27
$a=6$	32.20	32.62	32.98	33.27	33.50	33.69	33.82	33.91	33.96	33.98	33.95	33.93	33.89	33.81
$a=5$	32.40	32.84	33.22	33.53	33.79	33.99	34.14	34.25	34.32	34.35	34.34	34.34	34.31	34.28
$a=4$	32.08	32.48	32.83	33.13	33.37	33.55	33.69	33.78	33.85	33.90	33.92	33.91	33.90	33.86

Kompleks değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=5$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	33.58	33.66	33.67	33.66	33.62	33.53	33.44	33.34	33.24	33.15	33.05	32.95	32.85	32.76
$a=6$	34.01	34.13	34.20	34.20	34.14	34.10	34.01	33.92	33.80	33.70	33.59	33.51	33.41	33.31
$a=5$	34.32	34.46	34.52	34.54	34.53	34.49	34.43	34.36	34.28	34.20	34.12	34.03	33.94	33.84
$a=4$	33.85	33.99	34.06	34.08	34.08	34.04	33.99	33.95	33.89	33.83	33.77	33.73	33.67	33.62

Çizelge 4.4. Retina görüntülerinden gürültü temizleme uygulaması TSGO sonuçları ($\sigma=15$, a (ölçek), c (destek), d (derece), k (eşikleme sabiti))

Reel değerli hızlı ayrık ripplet-1 (curvelet) dönüşümü $c=1, d=2$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	35.11	35.37	35.57	35.72	35.84	35.92	35.96	35.98	35.96	35.94	35.89	35.84	35.78	35.72
$a=6$	35.21	35.50	35.72	35.89	36.02	36.09	36.14	36.15	36.14	36.13	36.10	36.05	35.99	35.92
$a=5$	35.32	35.60	35.84	36.02	36.15	36.23	36.29	36.31	36.32	36.31	36.28	36.24	36.18	36.12
$a=4$	35.22	35.48	35.71	35.88	36.02	36.11	36.17	36.20	36.22	36.21	36.20	36.18	36.14	36.09

Kompleks değerli hızlı ayrık ripplet-1 (curvelet) dönüşümü $c=1, d=2$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	36.08	36.10	36.09	36.06	36.00	35.94	35.86	35.77	35.67	35.58	35.49	35.40	35.31	35.22
$a=6$	36.25	36.28	36.27	36.24	36.18	36.11	36.04	35.95	35.86	35.78	35.69	35.60	35.52	35.42
$a=5$	36.39	36.43	36.44	36.41	36.35	36.29	36.22	36.14	36.06	35.97	35.87	35.80	35.71	35.62
$a=4$	36.24	36.30	36.33	36.31	36.28	36.23	36.18	36.13	36.06	35.99	35.90	35.84	35.76	35.69

Reel değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=3$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	34.93	35.18	35.38	35.53	35.63	35.71	35.74	35.76	35.75	35.73	35.68	35.62	35.56	35.50
$a=6$	35.12	35.38	35.58	35.73	35.84	35.92	35.97	35.98	35.97	35.95	35.90	35.85	35.80	35.73
$a=5$	35.24	35.53	35.76	35.93	36.06	36.14	36.20	36.23	36.22	36.21	36.19	36.14	36.08	36.02
$a=4$	35.21	35.48	35.71	35.89	36.03	36.12	36.19	36.21	36.23	36.23	36.22	36.19	36.15	36.11


Kompleks değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=3$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	35.86	35.89	35.88	35.85	35.79	35.74	35.67	35.59	35.50	35.40	35.31	35.22	35.13	35.03
$a=6$	36.08	36.10	36.09	36.06	36.00	35.94	35.86	35.77	35.68	35.58	35.50	35.41	35.32	35.22
$a=5$	36.30	36.34	36.34	36.31	36.26	36.20	36.13	36.05	35.97	35.90	35.81	35.74	35.66	35.57
$a=4$	36.25	36.31	36.33	36.31	36.28	36.24	36.19	36.14	36.08	36.01	35.93	35.86	35.78	35.72

Reel değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=4$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	34.83	35.07	35.26	35.40	35.49	35.56	35.59	35.59	35.57	35.55	35.50	35.43	35.37	35.31
$a=6$	35.04	35.28	35.48	35.63	35.74	35.81	35.85	35.86	35.85	35.83	35.78	35.73	35.67	35.60
$a=5$	35.25	35.53	35.75	35.91	36.04	36.12	36.18	36.23	36.19	36.18	36.16	36.11	36.06	36.00
$a=4$	35.21	35.48	35.71	35.89	36.03	36.12	36.19	36.21	36.21	36.23	36.22	36.19	36.15	36.11

Kompleks değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=4$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	35.69	35.71	35.70	35.66	35.61	35.54	35.47	35.39	35.29	35.20	35.11	35.02	34.93	34.83
$a=6$	35.96	35.99	35.98	35.94	35.88	35.82	35.74	35.66	35.56	35.46	35.38	35.29	35.19	35.09
$a=5$	36.25	36.31	36.33	36.31	36.28	36.24	36.19	36.14	36.08	36.01	35.93	35.86	35.78	35.72
$a=4$	36.27	36.30	36.31	36.28	36.24	36.18	36.11	36.03	35.95	35.87	35.79	35.71	35.64	35.55

Reel değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=5$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	34.78	35.00	35.18	35.31	35.38	35.43	35.45	35.44	35.42	35.38	35.33	35.27	35.19	35.12
$a=6$	34.99	35.24	35.44	35.59	35.70	35.77	35.80	35.82	35.82	35.79	35.74	35.69	35.64	35.57
$a=5$	35.25	35.53	35.75	35.91	36.04	36.12	36.18	36.23	36.19	36.18	36.16	36.11	36.06	36.00
$a=4$	35.21	35.48	35.71	35.89	36.03	36.12	36.19	36.21	36.21	36.23	36.22	36.19	36.15	36.11

Kompleks değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=5$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	35.53	35.55	35.54	35.49	35.43	35.36	35.27	35.18	35.08	34.99	34.89	34.79	34.70	34.60
$a=6$	35.92	35.95	35.94	35.91	35.85	35.79	35.72	35.64	35.54	35.45	35.36	35.27	35.18	35.08
$a=5$	36.25	36.31	36.33	36.31	36.28	36.24	36.19	36.14	36.08	36.01	35.93	35.86	35.78	35.72
$a=4$	36.27	36.30	36.31	36.28	36.24	36.18	36.11	36.03	35.95	35.87	35.79	35.71	35.64	35.55



Şekil 4.2. a1) Orijinal retina görüntüsü a2) Gürültülü görüntü ($\sigma=35$) a3) RDHARip-1D ile temizleme ($c=1, d=2$) a4) KDHARip-1D ile temizleme ($c=1, d=2$) a5) RDHARip-1D ile temizleme ($c=1, d=3$) a6) KDHARip-1D ile temizleme ($c=1, d=3$) a7) RDHARip-1D ile temizleme ($c=1, d=4$) a8) KDHARip-1D ile temizleme ($c=1, d=4$) a9) RDHARip-1D ile temizleme ($c=1, d=5$) a10) KDHARip-1D ile temizleme ($c=1, d=5$)
b1) Orijinal retina görüntüsü b2) Gürültülü görüntü ($\sigma=25$) b3) RDHARip-1D ile temizleme ($c=1, d=2$) b4) KDHARip-1D ile temizleme ($c=1, d=2$) b5) RDHARip-1D ile temizleme ($c=1, d=3$) b6) KDHARip-1D ile temizleme ($c=1, d=3$) b7) RDHARip-1D ile temizleme ($c=1, d=4$) b8) KDHARip-1D ile temizleme ($c=1, d=4$) b9) RDHARip-1D ile temizleme ($c=1, d=5$) b10) KDHARip-1D ile temizleme ($c=1, d=5$)
c1) Orijinal retina görüntüsü c2) Gürültülü görüntü ($\sigma=15$) c3) RDHARip-1D ile temizleme ($c=1, d=2$) c4) KDHARip-1D ile temizleme ($c=1, d=2$) c5) RDHARip-1D ile temizleme ($c=1, d=3$) c6) KDHARip-1D ile temizleme ($c=1, d=3$) c7) RDHARip-1D ile temizleme ($c=1, d=4$) c8) KDHARip-1D ile temizleme ($c=1, d=4$) c9) RDHARip-1D ile temizleme ($c=1, d=5$) c10) KDHARip-1D ile temizleme ($c=1, d=5$)

4.1.5.2. Mamografi görüntülerinden gürültü temizleme uygulama sonuçları

Gürültü temizleme uygulamasında 322 mamografi görüntüsüne üç farklı sigma değeri (15, 25, 35) için gürültü eklenmesiyle elde edilen gürültülü görüntüler ile orijinal görüntüler arasındaki ortalama TSGO değerleri Çizelge 4.5’ de verilmiştir.

Çizelge 4.5. Mamografi görüntülerine farklı sigma değerleri için gürültü eklenmesi ile oluşan ortalama TSGO sonuçları

	Sigma=35	Sigma=25	Sigma=15
Ortalama TSGO (dB)	17.21	20.14	24.63

Mamografi görüntüleri yapı itibariyle retina görüntülerinden farklıdır. Mamografi görüntülerinde göğüs dokusuna ait piksel değerleri birbirine çok yakındır. Bu durum bu görüntülere uygulanan gürültüler ile göğüs dokusu yapılarının birbirinden ayrılmasını zorlaştırmaktadır. Gürültülü mamografi görüntülerinden gürültü temizleme sonuçlarının verildiği Çizelge 4.6-4.8 incelendiğinde, retina görüntülerinin aksine en iyi sonuçların sabit değil birbirinden farklı a (ölçek) değerleri için ortaya çıktığı görülmektedir. Ancak mamografi görüntüleri için elde edilen sonuçlardan da eşikleme sabitinin KDHARip-1D ile RDHARip-1D özellik katsayıları ile yapılan işlemlerde farklı kullanılması gerektiği görülmektedir. Mamografi görüntüleri için RDHARip-1D özellik katsayıları ile yapılan gürültü temizleme uygulamasında eşikleme sabitinin 3.0 ile 3.4 arasındaki değerleri için, KDHARip-1D özellik katsayıları ile yapılan gürültü temizleme uygulamasında eşikleme sabitinin 2.3 ile 2.7 arasındaki değerleri için başarılı sonuçlar elde edilmiştir. Çizelge 4.6-4.8 incelendiğinde, sigma=35 için 17.21 dB olan gürültülü görüntülerin ortalama TSGO değerinin RDHARip-1D ile 35.588 dB’ e, KDHARip-1D ile 35.820 dB’ e kadar yükseltildiği görülmektedir. Benzer şekilde; sigma=25 için 20.14 dB olan gürültülü görüntülerin ortalama TSGO değeri RDHARip-1D ile 36.714 dB, KDHARip-1D ile 36.892 dB; sigma=15 için 24.63 dB olan gürültülü görüntülerin ortalama TSGO değeri RDHARip-1D ile 38.373 dB, KDHARip-1D ile 36.488 dB seviyesine çıkarılmıştır.

Şekil 4.3’ de çalışmalarda kullanılan orijinal mamografi görüntüsü, üç farklı sigma değeri için gürültü uygulanmış görüntüler ve farklı c (destek) ve d (derece) değerleri için gürültü temizleme yapılması ile yeniden elde edilmiş görüntüler yer almaktadır.

Çizelge 4.6. Mamografi görüntülerinden gürültü temizleme uygulaması TSGO sonuçları ($\sigma=35$, a (ölçek), c (destek), d (derece), k (eşikleme sabiti))

Reel değerli hızlı ayrık ripplet-1 (curvelet) dönüşümü $c=1, d=2$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	31.12	31.81	32.47	33.05	33.56	34.00	34.35	34.64	34.90	35.08	35.18	35.23	35.25	35.24
$a=6$	31.02	31.71	32.36	32.95	33.45	33.88	34.20	34.48	34.73	34.91	35.02	35.06	35.09	35.11
$a=5$	30.97	31.63	32.25	32.82	33.31	33.74	34.07	34.35	34.57	34.75	34.85	34.90	34.94	34.94
$a=4$	30.29	30.83	31.32	31.74	32.09	32.41	32.67	32.88	33.03	33.16	33.24	33.31	33.34	33.35

Kompleks değerli hızlı ayrık ripplet-1 (curvelet) dönüşümü $c=1, d=2$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	34.59	35.03	35.29	35.44	35.49	35.51	35.47	35.42	35.33	35.21	35.12	35.02	34.90	34.79
$a=6$	34.48	34.87	35.12	35.26	35.30	35.32	35.31	35.28	35.21	35.14	35.06	34.97	34.90	34.82
$a=5$	34.34	34.72	34.96	35.09	35.17	35.18	35.16	35.14	35.07	35.02	34.95	34.89	34.84	34.79
$a=4$	32.84	33.12	33.30	33.41	33.48	33.50	33.50	33.49	33.47	33.45	33.42	33.39	33.35	33.32

Reel değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=3$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	31.12	31.84	32.49	33.10	33.66	34.11	34.48	34.79	35.03	35.21	35.33	35.40	35.44	35.44
$a=6$	31.13	31.83	32.49	33.08	33.59	34.03	34.38	34.68	34.95	35.12	35.24	35.30	35.33	35.35
$a=5$	30.94	31.62	32.26	32.84	33.35	33.78	34.12	34.42	34.68	34.88	35.00	35.06	35.10	35.13
$a=4$	30.29	30.84	31.34	31.78	32.14	32.46	32.72	32.93	33.07	33.21	33.29	33.35	33.39	33.39

Kompleks değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=3$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	34.68	35.13	35.42	35.58	35.67	35.71	35.68	35.63	35.54	35.44	35.37	35.26	35.13	35.04
$a=6$	34.64	35.08	35.37	35.52	35.56	35.58	35.56	35.52	35.47	35.38	35.30	35.20	35.12	35.04
$a=5$	34.36	34.76	35.03	35.19	35.26	35.30	35.31	35.31	35.26	35.20	35.14	35.08	35.04	34.99
$a=4$	32.89	33.17	33.35	33.45	33.52	33.55	33.54	33.54	33.51	33.49	33.46	33.42	33.38	33.35

Reel değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=4$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	31.16	31.89	32.55	33.16	33.72	34.16	34.52	34.84	35.07	35.23	35.34	35.41	35.45	35.46
$a=6$	31.15	31.86	32.53	33.14	33.66	34.09	34.46	34.77	35.03	35.20	35.32	35.40	35.44	35.46
$a=5$	31.05	31.73	32.37	32.95	33.45	33.89	34.24	34.55	34.81	35.00	35.13	35.20	35.23	35.26
$a=4$	30.29	30.84	31.34	31.78	32.14	32.46	32.72	32.93	33.07	33.21	33.29	33.35	33.39	33.39

Kompleks değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=4$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	34.70	35.14	35.42	35.58	35.68	35.71	35.68	35.64	35.55	35.46	35.39	35.29	35.17	35.07
$a=6$	34.69	35.12	35.42	35.57	35.64	35.66	35.64	35.62	35.57	35.50	35.43	35.34	35.24	35.18
$a=5$	34.47	34.89	35.18	35.35	35.41	35.44	35.45	35.44	35.38	35.32	35.23	35.17	35.12	35.06
$a=4$	32.89	33.17	33.35	33.45	33.52	33.55	33.54	33.54	33.51	33.49	33.46	33.42	33.38	33.35

Reel değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=5$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	31.27	31.99	32.67	33.28	33.82	34.28	34.63	34.94	35.17	35.32	35.42	35.48	35.52	35.52
$a=6$	31.15	31.88	32.54	33.16	33.70	34.16	34.53	34.85	35.11	35.30	35.43	35.51	35.56	35.59
$a=5$	31.05	31.73	32.37	32.95	33.45	33.89	34.24	34.55	34.81	35.00	35.13	35.20	35.23	35.26
$a=4$	30.29	30.84	31.34	31.78	32.14	32.46	32.72	32.93	33.07	33.21	33.29	33.35	33.39	33.39

Kompleks değerli hızlı ayrık ripplet-1 dönüşümü $c=1, d=5$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	34.77	35.18	35.46	35.62	35.71	35.75	35.72	35.66	35.57	35.49	35.42	35.32	35.21	35.11
$a=6$	34.77	35.23	35.54	35.70	35.78	35.82	35.81	35.78	35.73	35.65	35.60	35.49	35.40	35.34
$a=5$	34.47	34.89	35.18	35.35	35.41	35.44	35.45	35.44	35.38	35.32	35.23	35.17	35.12	35.06
$a=4$	32.89	33.17	33.35	33.45	33.52	33.55	33.54	33.54	33.51	33.49	33.46	33.42	33.38	33.35

Çizelge 4.7. Mamografi görüntülerinden gürültü temizleme uygulaması TSGO sonuçları ($\sigma=25$, a (ölçek), c (destek), d (derece), k (eşikleme sabiti))

Reel değerli hızlı ayrık ripplelet-1 (curvelet) dönüşümü $c=1, d=2$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	33.47	34.04	34.58	35.04	35.42	35.75	36.00	36.19	36.34	36.45	36.49	36.51	36.48	36.44
$a=6$	33.38	33.96	34.49	34.96	35.36	35.67	35.90	36.07	36.19	36.29	36.34	36.35	36.35	36.32
$a=5$	33.35	33.92	34.45	34.90	35.29	35.61	35.85	36.04	36.17	36.27	36.31	36.34	36.34	36.33
$a=4$	32.81	33.30	33.73	34.10	34.39	34.66	34.87	35.03	35.16	35.24	35.28	35.32	35.33	35.34

Kompleks değerli hızlı ayrık ripplelet-1 (curvelet) dönüşümü $c=1, d=2$														
	k=2.1	k=2.2	k=2.3	k=2.4	k=2.5	k=2.6	k=2.7	k=2.8	k=2.9	k=3.0	k=3.1	k=3.2	k=3.3	k=3.4
a=7	36.17	36.46	36.64	36.72	36.69	36.69	36.64	36.58	36.51	36.42	36.32	36.22	36.13	36.06
a=6	36.07	36.33	36.47	36.55	36.53	36.52	36.48	36.42	36.35	36.26	36.17	36.07	35.98	35.90
a=5	36.04	36.34	36.50	36.57	36.59	36.57	36.52	36.49	36.42	36.33	36.25	36.17	36.09	36.00
a=4	34.99	35.22	35.34	35.41	35.45	35.47	35.46	35.45	35.43	35.39	35.34	35.32	35.27	35.22

Reel değerli hızlı ayrık ripplelet-1 dönüşümü $c=1, d=3$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	33.46	34.06	34.60	35.06	35.47	35.81	36.07	36.28	36.43	36.53	36.58	36.60	36.59	36.56
$a=6$	33.48	34.07	34.60	35.07	35.47	35.79	36.05	36.25	36.39	36.49	36.55	36.57	36.56	36.52
$a=5$	33.33	33.92	34.45	34.93	35.33	35.65	35.90	36.09	36.24	36.36	36.42	36.45	36.46	36.46
$a=4$	32.84	33.34	33.78	34.17	34.48	34.76	34.97	35.14	35.27	35.36	35.41	35.45	35.47	35.47

Kompleks değerli hızlı ayrık ripplelet-1 dönüşümü $c=1, d=3$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	36.21	36.51	36.67	36.79	36.79	36.78	36.73	36.70	36.61	36.54	36.47	36.37	36.27	36.21
$a=6$	36.21	36.51	36.68	36.76	36.75	36.75	36.70	36.65	36.59	36.50	36.41	36.32	36.25	36.16
$a=5$	36.07	36.35	36.53	36.62	36.63	36.64	36.61	36.59	36.54	36.46	36.40	36.32	36.25	36.17
$a=4$	35.10	35.35	35.49	35.57	35.61	35.63	35.61	35.60	35.57	35.51	35.47	35.43	35.37	35.32

Reel değerli hızlı ayrık ripplelet-1 dönüşümü $c=1, d=4$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	33.49	34.09	34.64	35.11	35.52	35.86	36.10	36.30	36.44	36.54	36.58	36.61	36.61	36.58
$a=6$	33.50	34.10	34.64	35.11	35.52	35.85	36.11	36.31	36.45	36.55	36.61	36.64	36.63	36.60
$a=5$	33.43	34.02	34.56	35.03	35.43	35.75	36.02	36.22	36.38	36.49	36.58	36.60	36.61	36.61
$a=4$	32.84	33.34	33.78	34.17	34.48	34.76	34.97	35.14	35.27	35.36	35.41	35.45	35.47	35.47

Kompleks değerli hızlı ayrık ripplelet-1 dönüşümü $c=1, d=4$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	36.21	36.50	36.66	36.78	36.80	36.79	36.74	36.70	36.61	36.53	36.45	36.36	36.26	36.21
$a=6$	36.25	36.56	36.72	36.81	36.82	36.81	36.77	36.72	36.65	36.56	36.47	36.38	36.32	36.23
$a=5$	36.19	36.49	36.68	36.76	36.80	36.81	36.77	36.75	36.71	36.64	36.58	36.50	36.46	36.37
$a=4$	35.10	35.35	35.49	35.57	35.61	35.63	35.61	35.60	35.57	35.51	35.47	35.43	35.37	35.32

Reel değerli hızlı ayrık ripplelet-1 dönüşümü $c=1, d=5$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	33.59	34.18	34.73	35.20	35.60	35.93	36.17	36.36	36.50	36.58	36.62	36.65	36.63	36.61
$a=6$	33.50	34.11	34.66	35.13	35.55	35.90	36.15	36.37	36.51	36.61	36.68	36.71	36.71	36.68
$a=5$	33.43	34.02	34.56	35.03	35.43	35.75	36.02	36.22	36.38	36.49	36.58	36.60	36.61	36.61
$a=4$	32.84	33.34	33.78	34.17	34.48	34.76	34.97	35.14	35.27	35.36	35.41	35.45	35.47	35.47

Kompleks değerli hızlı ayrık ripplelet-1 dönüşümü $c=1, d=5$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	36.25	36.52	36.68	36.78	36.80	36.79	36.73	36.69	36.61	36.54	36.47	36.38	36.28	36.23
$a=6$	36.30	36.61	36.77	36.88	36.89	36.89	36.86	36.83	36.77	36.69	36.61	36.52	36.46	36.38
$a=5$	36.19	36.49	36.68	36.76	36.80	36.81	36.77	36.75	36.71	36.64	36.58	36.50	36.46	36.37
$a=4$	35.10	35.35	35.49	35.57	35.61	35.63	35.61	35.60	35.57	35.51	35.47	35.43	35.37	35.32

Çizelge 4.8. Mamografi görüntülerinden gürültü temizleme uygulaması TSGO sonuçları ($\sigma=15$, a (ölçek), c (destek), d (derece), k (eşikleme sabiti))

Reel değerli hızlı ayırık ripplet-1 (curvelet) dönüşümü $c=1, d=2$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	36.60	37.00	37.35	37.63	37.83	38.00	38.12	38.19	38.24	38.25	38.24	38.21	38.17	38.11
$a=6$	36.54	36.94	37.29	37.56	37.77	37.95	38.08	38.14	38.17	38.17	38.17	38.13	38.09	38.04
$a=5$	36.53	36.93	37.26	37.53	37.75	37.92	38.04	38.12	38.17	38.17	38.17	38.15	38.12	38.08
$a=4$	36.26	36.63	36.94	37.18	37.38	37.55	37.66	37.75	37.81	37.85	37.87	37.86	37.85	37.83

Kompleks değerli hızlı ayırık ripplet-1 (curvelet) dönüşümü $c=1, d=2$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	38.24	38.35	38.40	38.41	38.38	38.32	38.24	38.17	38.10	38.01	37.92	37.83	37.74	37.67
$a=6$	38.19	38.30	38.35	38.34	38.30	38.24	38.16	38.09	38.01	37.92	37.83	37.72	37.63	37.55
$a=5$	38.17	38.30	38.36	38.36	38.33	38.28	38.21	38.15	38.08	38.00	37.93	37.84	37.78	37.71
$a=4$	37.76	37.88	37.96	37.99	38.00	37.98	37.94	37.92	37.87	37.82	37.77	37.73	37.68	37.64

Reel değerli hızlı ayırık ripplet-1 dönüşümü $c=1, d=3$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	36.61	37.02	37.37	37.65	37.87	38.04	38.16	38.24	38.29	38.30	38.29	38.27	38.23	38.17
$a=6$	36.62	37.02	37.37	37.65	37.86	38.03	38.16	38.23	38.28	38.29	38.28	38.24	38.20	38.15
$a=5$	36.52	36.92	37.27	37.55	37.76	37.95	38.07	38.15	38.20	38.21	38.22	38.21	38.18	38.15
$a=4$	36.30	36.68	37.00	37.26	37.48	37.66	37.79	37.88	37.95	37.99	38.02	38.02	38.01	38.00


Kompleks değerli hızlı ayırık ripplet-1 dönüşümü $c=1, d=3$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	38.27	38.39	38.44	38.44	38.40	38.34	38.28	38.18	38.11	38.02	37.93	37.83	37.77	37.69
$a=6$	38.26	38.37	38.42	38.43	38.40	38.34	38.27	38.21	38.13	38.05	37.96	37.87	37.78	37.71
$a=5$	38.19	38.32	38.38	38.38	38.36	38.31	38.25	38.20	38.14	38.07	38.00	37.92	37.86	37.79
$a=4$	37.89	38.04	38.12	38.15	38.17	38.16	38.12	38.10	38.06	38.02	37.97	37.93	37.90	37.85

Reel değerli hızlı ayırık ripplet-1 dönüşümü $c=1, d=4$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	36.62	37.03	37.38	37.66	37.88	38.05	38.17	38.24	38.28	38.29	38.28	38.26	38.22	38.17
$a=6$	36.64	37.05	37.39	37.67	37.89	38.06	38.19	38.26	38.31	38.32	38.30	38.27	38.23	38.18
$a=5$	36.61	37.01	37.35	37.64	37.84	38.02	38.14	38.23	38.29	38.31	38.32	38.30	38.28	38.25
$a=4$	36.30	36.68	37.00	37.26	37.48	37.66	37.79	37.88	37.95	37.99	38.02	38.02	38.01	38.00

Kompleks değerli hızlı ayırık ripplet-1 dönüşümü $c=1, d=4$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	38.25	38.39	38.43	38.43	38.39	38.33	38.26	38.16	38.09	38.00	37.92	37.82	37.76	37.68
$a=6$	38.26	38.39	38.44	38.44	38.41	38.37	38.30	38.23	38.15	38.07	37.98	37.89	37.81	37.73
$a=5$	38.25	38.38	38.45	38.46	38.44	38.40	38.35	38.31	38.25	38.19	38.12	38.05	38.00	37.94
$a=4$	37.89	38.04	38.12	38.15	38.17	38.16	38.12	38.10	38.06	38.02	37.97	37.93	37.90	37.85

Reel değerli hızlı ayırık ripplet-1 dönüşümü $c=1, d=5$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	36.70	37.10	37.45	37.72	37.93	38.10	38.21	38.28	38.31	38.31	38.29	38.27	38.22	38.17
$a=6$	36.64	37.06	37.41	37.69	37.92	38.10	38.23	38.31	38.36	38.37	38.36	38.34	38.30	38.25
$a=5$	36.61	37.01	37.35	37.64	37.84	38.02	38.14	38.23	38.29	38.31	38.32	38.30	38.28	38.25
$a=4$	36.30	36.68	37.00	37.26	37.48	37.66	37.79	37.88	37.95	37.99	38.02	38.02	38.01	38.00

Kompleks değerli hızlı ayırık ripplet-1 dönüşümü $c=1, d=5$														
	$k=2.1$	$k=2.2$	$k=2.3$	$k=2.4$	$k=2.5$	$k=2.6$	$k=2.7$	$k=2.8$	$k=2.9$	$k=3.0$	$k=3.1$	$k=3.2$	$k=3.3$	$k=3.4$
$a=7$	38.29	38.40	38.44	38.44	38.40	38.33	38.25	38.15	38.08	37.99	37.90	37.80	37.74	37.67
$a=6$	38.30	38.43	38.48	38.49	38.46	38.42	38.35	38.29	38.21	38.13	38.04	37.95	37.87	37.79
$a=5$	38.25	38.38	38.45	38.46	38.44	38.40	38.35	38.31	38.25	38.19	38.12	38.05	38.00	37.94
$a=4$	37.89	38.04	38.12	38.15	38.17	38.16	38.12	38.10	38.06	38.02	37.97	37.93	37.90	37.85



Şekil 4.3. a1) Orijinal mamografi görüntüsü a2) Gürültülü görüntü ($\sigma=35$) a3) RDHARip-1D ile temizleme ($c=1, d=2$) a4) KDHARip-1D ile temizleme ($c=1, d=2$) a5) RDHARip-1D ile temizleme ($c=1, d=3$) a6) KDHARip-1D ile temizleme ($c=1, d=3$) a7) RDHARip-1D ile temizleme ($c=1, d=4$) a8) KDHARip-1D ile temizleme ($c=1, d=4$) a9) RDHARip-1D ile temizleme ($c=1, d=5$) a10) KDHARip-1D ile temizleme ($c=1, d=5$)


b1) Orijinal mamografi görüntüsü b2) Gürültülü görüntü ($\sigma=25$) b3) RDHARip-1D ile temizleme ($c=1, d=2$) b4) KDHARip-1D ile temizleme ($c=1, d=2$) b5) RDHARip-1D ile temizleme ($c=1, d=3$) b6) KDHARip-1D ile temizleme ($c=1, d=3$) b7) RDHARip-1D ile temizleme ($c=1, d=4$) b8) KDHARip-1D ile temizleme ($c=1, d=4$) b9) RDHARip-1D ile temizleme ($c=1, d=5$) b10) KDHARip-1D ile temizleme ($c=1, d=5$)

c1) Orijinal mamografi görüntüsü c2) Gürültülü görüntü ($\sigma=15$) c3) RDHARip-1D ile temizleme ($c=1, d=2$) c4) KDHARip-1D ile temizleme ($c=1, d=2$) c5) RDHARip-1D ile temizleme ($c=1, d=3$) c6) KDHARip-1D ile temizleme ($c=1, d=3$) c7) RDHARip-1D ile temizleme ($c=1, d=4$) c8) KDHARip-1D ile temizleme ($c=1, d=4$) c9) RDHARip-1D ile temizleme ($c=1, d=5$) c10) KDHARip-1D ile temizleme ($c=1, d=5$)

4.2. Göğüs mamografi görüntülerinden normal-anormal doku sınıflandırılması uygulaması


4.2.1. Uygulamada kullanılan görüntüler

Tez çalışmasının ikinci uygulaması olan mamografi görüntülerinden normal-anormal doku sınıflandırılması için önerilen sistem, MIAS veri tabanına ait görüntüler kullanılarak test edilmiştir. MIAS veri tabanı yağlı (fatty), yağlı-bezeli (fatty-glanduar) ve yoğun (dense) olmak üzere üç göğüs arka plan doku yoğunluk tipinden oluşmaktadır. MIAS veri tabanına ait göğüs arka plan doku yoğunluk tiplerine ait örnekler Şekil 4.4’ de verilmiştir.



Şekil 4.4. MIAS veri tabanına ait farklı göğüs arka plan doku yoğunluk tiplerine ait örnekler
a) yağlı, b) yağlı-bezeli, c) yoğun

Göğüs üzerinde meydana gelen anormallikler mikrokalsifikasyon (microcalcification), sınırlı kitle (circumscribed mass), hastalıklı kitle (ill-defined mass), spikule kitle (spiculated mass), yapısal bozukluk (architectural distortion) ve asimetridir (asymmetry). MIAS veri tabanı 161 hastanın sağ ve sol göğsünden elde edilen 322 mamografi görüntüsünden oluşmaktadır. Bu görüntülerden 115’ i anormal, 207’ si ise normal dokular içermektedir. MIAS veri tabanında yer alan anormal dokulara ait örnekler Şekil 4.5’ de verilmiştir.



Şekil 4.5. MIAS veri tabanına ait farklı anormallik tiplerine ait örnekler a) sınırlı kitle (circumscribed mass), b) hastalıklı kitle (ill-defined mass), c) asimetridir (asymmetry), d) yapısal bozukluk (architectural distortion), e) spikule kitle (spiculated mass), f) mikrokalsifikasyon (microcalcification)

Tez çalışmasının ikinci uygulamasında 1024×1024 boyutlarında toplam 265 adet görüntü kullanılmıştır. MIAS veritabanına ait 322 görüntünün tamamının kullanılmamasının ana sebebi bazı görüntülerdeki (mdb105, mdb107, mdb315 gibi) anormal doku büyüklüklerinin çalışmada kullanılan pencere boyutundan büyük olmasıdır. Ayrıca bazı görüntülerde (mdb104 gibi) sayısal ortama aktarılma esnasında çizgisel olarak devam eden bozulmalar mevcuttur. Tez çalışmasında kullanılan verilerin arka plan doku yoğunluk ve anormallik tiplerine göre dağılımları Çizelge 4.9’ da verilmiştir. Ek-5’ de tez çalışmasında kullanılan görüntülere ait daha ayrıntılı bilgiler yer almaktadır.

Çizelge 4.9. Uygulamada kullanılan görüntülerin dağılımı

		Doku Yoğunluk Tipi			Toplam	
		Yağlı	Yağlı-Bezeli	Yoğun		
Anormal	Mikrokalsifikasyon	3	3	2	8	74
	Sınırlı kitle	10	6	2	18	
	Hastalıklı kitle	6	4	1	11	
	Spikule kitle	4	4	5	13	
	Yapısal bozukluk	5	6	3	14	
	Asimetri	4	4	2	10	
Normal		57	60	74	191	
Toplam		89	87	89	265	

4.2.2. Sonuçlarının değerlendirilmesinde kullanılan performans kriterleri

Biyomedikal verilerin sınıflandırılması (tez çalışmasında YSA kullanılmıştır) için kullanılan sistemler genellikle aşağıda yer alan istatistiki ölçümler kullanılarak değerlendirilirler (Sharma ve ark., 2009).

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

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

Yanlış Pozitif (YP): Uzman tarafından sağlıklı (normal) olarak etiketlenmiş bir verinin YSA tarafından hasta (anormal) olarak sınıflandırılması.

Yanlış Negatif (YN): Uzman tarafından hasta (anormal) olarak etiketlenmiş bir verinin YSA tarafından sağlıklı (normal) olarak sınıflandırılması.

Doğru sınıflandırılmış veri sayısının tüm veri sayısına oranı sınıflama doğruluğunu verir. Sınıflama doğruluğu eşitlik (4.15) ile hesaplanabilir.

$$\text{Doğruluk}(\%) = \left(\frac{DP + DN}{DP + DN + YP + YN} \right) \quad (4.15)$$


Sınıflama performanslarının değerlendirilmesinde doğruluk kriterinin yanı sıra duyarlılık (4.16) ve özgüllük (4.17) kriterleri de kullanılmaktadır (Sharma ve ark., 2009).

$$\text{Duyarlılık} = \left(\frac{DP}{DP + YN} \right) \quad (4.16)$$

$$\text{Özgüllük} = \left(\frac{DN}{DN + YP} \right) \quad (4.17)$$

Doğruluk, duyarlılık ve özgüllük kriterleri ile birlikte alıcı işlem karakteristiği (AİK) eğrisinin yorumlanması da etkili bir performans karşılaştırma kriteridir. Bu eğri, duyarlılık ve özgüllük değerlerinin farklı karar noktaları (ayrışım değeri) için birbirlerine göre değişimlerini yansıtmaktadır. Bu eğrinin kullanılmasındaki temel amaç, uygulamalarda farklı sayıda normal veya anormal örnek kullanılmasının sonuçlar


üzerinde oluşturduğu etkinin azaltılmasıdır. AİK eğrisi altında kalan alan (A_z) değerinin 1 olmasının anlamı sınıflandırmanın mükemmel bir şekilde gerçekleştirildiğidir. Bu değer 0 olması ise sınıflandırma işleminin başarısız olduğunu gösterir. Şekil 4.6’ da örnek bir AİK eğrisi ve A_z alanı verilmiştir.



Şekil 4.6. Örnek AİK eğrisi ve A_z alanının gösterimi

4.2.3. Uygulamada kullanılan sınıflandırma yapıları ve sınıflandırma

Tez çalışmasının bu uygulamasında göğüs arka plan sınıflandırmasını da içine alan bir göğüs normal-anormal doku sınıflandırma sistemi önerilmektedir. Göğüs arka plan doku yoğunluğu, göğüs üzerinde meydana gelen anormallikleri gizleyerek teşhis ve sınıflandırmayı zorlaştırmaktadır. Normal-anormal doku sınıflandırılmasında kullanılan ve YSA’ nın eğitim kümesinde yer alan görüntülerin sınıflandırma yapılacak görüntüye ait göğüs arka plan doku yoğunluğu ile aynı tipli olması bu sorunu ortadan kaldıracabilecek bir çözüm olacaktır. Şekil 4.7’ de önerilen sistem blok gösterim ile anlatılmaktadır.



Şekil 4.7. Önerilen sınıflandırma sistemi

Gerçekleştirilen tez çalışmasında otomatik bir sistem oluşturulmuş ve normal-anormal doku sınıflandırmasından önce kullanılacak eğitim kümesinin seçilebilmesi amacıyla göğüs arka plan doku yoğunluk tipi sınıflandırılmıştır. Yağlı, yağlı-bezeli ve yoğun olmak üzere üç tip göğüs arka plan doku yoğunluğu ile sınıflandırılma yapılan ve arka plan sınıflandırma olarak isimlendirebileceğimiz bu aşamada YSA ile birlikte ADD, ARidD ve CoD' nin reel değerli özellik katsayıları kullanılmıştır. Orijinal boyutları 1024×1024 olan görüntülerden göğüs arka plan doku yoğunluğu sınıflandırılmasında kullanılmak üzere 256×256 boyutlarında görüntü alanları belirlenmiştir. Belirlenen görüntü alanlarına ADD, ARidD ve CoD uygulanarak elde edilen özellik matrisleri üzerinden minimum değer, maksimum değer, ortalama ve standart sapma değerleri hesaplanarak özellik vektörleri oluşturulmuştur. Bu işlemler sırasında ADD, ARidD ve CoD için kullanılan ölçek parametresinin değeri 1' dir. Bu işlemlerde ADD uygulanarak elde edilen özellik matrislerinin boyutları 128×128 , ARidD uygulanarak elde edilen özellik matrislerinin boyutları 257×512 , CoD uygulanarak elde edilen özellik matrislerinin boyutları 128×128 ' dir. Sınıflandırma esnasında sınıflandırılan görüntü haricindeki 264 adet özellik vektörü YSA eğitiminde kullanılmıştır. Burada eğitim hedeflerine yağlı için 0, yağlı-bezeli için 1, yoğun için 2 değeri atanmıştır. Test işlemi sınıflandırılmaya tabi tutulacak 265 görüntü için tekrarlanmıştır. Sonuç değeri 0.5 değerinden küçük ise görüntü yağlı, 0.5 ile 1.5 arasında ise görüntü yağlı-bezeli, 1.5 değerinden büyük ise görüntü yoğun tip göğüs arka plan doku yoğunluğuna sahip olarak kabul edilmiştir. Önerilen sistemin birinci aşaması olan arka plan sınıflandırma sonucunda görüntüler göğüs arka plan doku yoğunluk tipine göre sınıflandırılmışlardır.

Mamografi göğüs görüntüleri, arka plan sınıflandırma sonucuna göre kendisiyle aynı tipli göğüs arka plan doku yoğunluğuna sahip görüntüler ile eğitilmiş YSA kullanılarak normal-anormal doku sınıflandırılmasına tabi tutulmuştur. Temel sınıflandırma olarak isimlendirebileceğimiz bu ikinci aşama işlem için YSA ile birlikte ADD, ARidD ve CoD kullanılmıştır. Orijinal boyutları 1024×1024 olan görüntülerden normal-anormal doku sınıflandırılmasında kullanılmak üzere 128×128 boyutlarında normal ve anormal dokular içeren görüntü alanları belirlenmiştir. ADD, ARidD ve CoD kullanılarak özellik matrisleri oluşturulmuştur. Özellik matrislerinden minimum değer, maksimum değer, ortalama ve standart sapma değerleri hesaplanarak yeni özellik vektörleri elde edilmiştir. Bu işlemler sırasında ADD, ARidD ve CoD için kullanılan ölçek parametresinin değeri 2' dir. Bu işlemlerde ADD uygulanarak elde edilen özellik

matrislerinin boyutları 32×32 , ARidD uygulanarak elde edilen özellik matrislerinin boyutları 65×256 , COD uygulanarak elde edilen özellik matrislerinin boyutları 32×32 dir. Sınıflandırılan görüntü haricindeki görüntülerin özellik vektörleri YSA' nın eğitiminde kullanılmıştır. Eğitim için kullanılan görüntüler, arka plan sınıflandırma ile göğüs arka plan doku yoğunluk tipi belirlenen ve bu aşamadan sonra normal-anormal sınıflandırılmasına tabi tutulacak görüntü ile aynı tip göğüs arka plan doku yoğunluğuna sahiptir. Örneğin arka plan sınıflandırma sonucu göğüs arka plan doku yoğunluk tipi yağlı olarak belirlenen bir görüntünün normal-anormal doku sınıflandırılmasındaki eğitim kümesi, doku yoğunluk tipi yağlı olan görüntülerden oluşmaktadır. İşlemlerde eğitim hedeflerine normal dokular için 1, anormal dokular için 0 değeri atanmıştır. Test işlemi sınıflandırılmaya tabi tutulacak 265 görüntü için tekrarlanmıştır. Bu sayede her görüntü için çapraz doğrulama (leave-one-out cross-validation) yapılarak sonuçların güvenilirliği artırılmıştır. Sonuç değeri 0 ile 0.5 arasında ise doku anormal, 0.5 ile 1 arasında ise doku normal olarak kabul edilmiştir. Çalışmada kullanılan ileri besleme geri yayımlı YSA' ya ait özellikler Çizelge 4.10' da verilmiştir. Bu çizelgede verilen hata hedefi; işlemlerde hedeflenen toplam hatayı, gizli düğüm sayısı; gizli katmanda kullanılan toplam düğüm sayısını, öğrenme oranı; öğrenme algortimasındaki eğitim ağırlıklarının değişim miktarını, momentum sabiti; bir önceki katmandan bir sonraki katmana geçerken ağırlık güncelleme miktarını, maksimum iterasyon sayısı; maksimum eğitim yineleme sayısını ifade etmektedir. Bu özellikler deneme-yanılma yoluyla optimize edilmiştir.

Çizelge 4.10. Tez çalışmasında kullanılan YSA' ya ait özellikler


Hata Hedefi	Gizli Düğüm Sayısı	Öğrenme Oranı	Momentum Sabiti	Maksimum İterasyon Sayısı
1e-20	200	0.05	0.2	1000

4.2.4. Uygulama sonuçları

4.2.4.1. Arka plan sınıflandırma yapılmadan elde edilen temel sınıflandırma sonuçları

Önerilen sistemin sınıflandırma üzerindeki etkisini test etmek amacıyla göğüs arka plan doku yoğunluk tipi dikkate alınmaksızın göğüs dokusu normal-anormal olarak sınıflandırılmıştır. Şekil 4.8, bu işlemi göstermektedir. Çizelge 4.11' de arka plan

sınıflandırma yapılmadan ADD, ARidD ve CoD ile YSA kullanılarak 265 görüntü ile elde edilen temel sınıflandırma sonuçları verilmiştir. Bu şartlar altında elde edilen en yüksek sınıflandırma başarısı % 86.04' dür. Çizelge 4.12' de ise arka plan sınıflandırma yapılmadan elde edilen temel sınıflandırma DP, YN, YP ve DN sonuçları yer almaktadır. Gerçekleştirilen çalışmada normal-anormal doku sınıflandırılmasında karar noktası (ayrışım değeri) 0.5 olarak kabul edilmiştir. 0 ile 1 arasında 10^{-6} duyarlılıklı olmak üzere farklı karar noktaları için elde edilen sonuçlar ışığında çizilen AİK eğrileri Şekil 4.9' da verilmiştir. Çizelge 4.13' de ise duyarlılık, özgünlük sonuçları ve Şekil 4.9' da verilen eğriler kullanılarak hesaplanan A_z değerleri yer almaktadır. Çizelge 4.13' den de görüleceği gibi arka plan sınıflandırılması yapılmadan elde edilen en yüksek duyarlılık 0.5946, en yüksek özgünlük 0.9686, en yüksek A_z 0.862' dir.



Şekil 4.8. Arka plan doku yoğunluk tipi dikkate alınmadan bir göğüs dokusunun normal-anormal olarak sınıflandırılması

Çizelge 4.11. Arka plan doku yoğunluk tipi dikkate alınmadan gerçekleştirilen temel sınıflandırma için doğruluk sonuçları

Sınıf	Doğruluk (%)		
	ADD + YSA	ARidD + YSA	CoD + YSA
Anormal	59.46 (44/74)	58.11 (43/74)	58.11 (43/74)
Normal	94.76 (181/191)	96.86 (185/191)	93.72 (179/191)
Toplam	84.91 (225/265)	86.04 (228/265)	83.77 (222/265)

Çizelge 4.12. Arka plan doku yoğunluk tipi dikkate alınmadan gerçekleştirilen temel sınıflandırma için DP, YN, YP ve DN sonuçları

a) ADD + YSA için sınıflandırma sonucu


		Asıl Sınıf	
		Normal	Anormal
Tahmin edilen sınıf	Normal	181 (DN)	30 (YN)
	Anormal	10 (YP)	44 (DP)

b) ARidD + YSA için sınıflandırma sonucu

		Asıl Sınıf	
		Normal	Anormal
Tahmin edilen sınıf	Normal	185 (DN)	31 (YN)
	Anormal	6 (YP)	43 (DP)

c) CoD + YSA için sınıflandırma sonucu

		Asıl Sınıf	
		Normal	Anormal
Tahmin edilen sınıf	Normal	179 (DN)	31 (YN)
	Anormal	12 (YP)	43 (DP)



Şekil 4.9. Arka plan doku yoğunluk tipi dikkate alınmadan gerçekleştirilen temel sınıflandırma için AİK eğrileri

Çizelge 4.13. Arka plan doku yoğunluk tipi dikkate alınmadan gerçekleştirilen temel sınıflandırma için duyarlılık, özgüllük ve A_z sonuçları

METOT	Duyarlılık	Özgüllük	A_z
ADD+YSA	0.5946	0.9476	0.855
ARidD+YSA	0.5811	0.9686	0.857
CoD+YSA	0.5811	0.9372	0.862

Arka plan sınıflandırılma yapılmadan gerçekleştirilen temel sınıflandırma sonuçları, literatürde yapılan çalışmalarla elde edilen birçok sınıflandırma sonucundan daha düşüktür. Bu durum, sınıflandırma işlemlerinde göğüs arka plan doku farklılıklarının sınıflandırmayı olumsuz etkilediğini ve daha iyi sınıflandırma sonuçları için yeni bir sınıflandırma sisteminin ortaya konulması gerektiğini göstermektedir.

4.2.4.2. Arka plan sınıflandırması

Göğüs arka plan doku farklılıklarının sınıflandırma üzerindeki olumsuz etkisinin azaltılması için bu farklılıklar, normal-anormal doku sınıflandırılmasında dikkate alınmalıdır. Bu amaçla önerilen sistemin birinci aşamasında göğüs arka planı, doku yoğunluk tiplerine göre sınıflandırılmıştır. Bu aşamada ADD, ARidD ve CoD ile YSA kullanılarak elde edilen sınıflandırma sonuçları Çizelge 4.14’ de verilmiştir.

Çizelge 4.14. Arka plan doku yoğunluk tipi sınıflandırma sonuçları


METOT	Yağlı	Yağlı-bezeli	Yoğun	Toplam
ADD + YSA	93.26 (83/89)	65.52 (57/87)	78.65 (70/89)	79.25 (210/265)
ARidD + YSA	86.52 (77/89)	71.26 (62/87)	70.79 (63/89)	76.23 (202/265)
CoD + YSA	86.52 (77/89)	58.62 (51/87)	83.15 (74/89)	76.23 (202/265)

4.2.4.3. Arka plan sınıflandırma yapılarak elde edilen temel sınıflandırma sonuçları

Arka plan sınıflandırma sonucuna göre kendisiyle aynı tipli göğüs arka plan doku yoğunluğuna sahip görüntüler ile eğitilmiş YSA kullanılarak normal-anormal doku sınıflandırması (temel sınıflandırma) gerçekleştirilmiştir. Önerilen sistemin blok diyagramı Şekil 4.10’ da yer almaktadır.

Çizelge 4.15’ de arka plan sınıflandırma için ADD ile YSA, temel sınıflandırma için ADD, ARidD ve CoD ile YSA kullanılarak elde edilen temel sınıflandırma sonuçları verilmiştir. Çizelge 4.15-4.18’ da yer alan “Y” yağlı , “YB” yağlı-bezeli ve “YO” yoğun göğüs arka plan doku yoğunluk tipini temsil etmektedir. Çizelge 4.15’ den de görüleceği gibi en yüksek sınıflandırma başarısı % 95.47 ile temel sınıflandırma için ADD ile YSA kullanılarak sağlanmıştır.

Çizelge 4.16’ da arka plan sınıflandırma için ARidD ile YSA, temel sınıflandırma için ADD, ARidD ve CoD ile YSA kullanılarak elde edilen temel sınıflandırma sonuçları verilmiştir. Çizelge 4.16’ dan da görüleceği gibi en yüksek sınıflandırma başarısı % 93.96 ile temel sınıflandırma için ADD ile YSA kullanılarak sağlanmıştır.



Şekil 4.10. Arka plan doku yoğunluk tipi sınıflandırılması yapılarak bir göğüs dokusunun normal-anormal olarak sınıflandırılması

Çizelge 4.15. Arka plan sınıflandırma için ADD ile YSA kullanılarak elde edilen temel sınıflandırma sonuçları

Sınıf	Doğruluk (%)								
	ADD-YSA + ADD-YSA			ADD-YSA + ARidD-YSA			ADD-YSA + CoD-YSA		
	Y	YB	YO	Y	YB	YO	Y	YB	YO
Anormal	93.75 (30/32)	81.48 (22/27)	73.33 (11/15)	96.88 (31/32)	74.07 (20/27)	60.00 (9/15)	93.75 (30/32)	77.78 (21/27)	73.33 (11/15)
Normal	100 (57/57)	98.33 (59/60)	100 (74/74)	100 (57/57)	98.33 (59/60)	95.95 (71/74)	100 (57/57)	98.33 (59/60)	93.24 (69/74)
Toplam	97.75 (87/89)	93.10 (81/87)	95.51 (85/89)	98.88 (88/89)	90.80 (79/87)	89.89 (80/89)	97.75 (87/89)	91.95 (80/87)	89.89 (80/89)
	95.47 (253/265)			93.21 (247/265)			93.21 (247/265)		

Çizelge 4.16. Arka plan sınıflandırma için ARidD ile YSA kullanılarak elde edilen temel sınıflandırma sonuçları

Sınıf	Doğruluk (%)								
	ARidD-YSA + ADD-YSA			ARidD-YSA + ARidD-YSA			ARidD-YSA + CoD-YSA		
	Y	YB	YO	Y	YB	YO	Y	YB	YO
Anormal	84.38 (27/32)	81.48 (22/27)	80.00 (12/15)	87.50 (28/32)	77.78 (21/27)	66.67 (10/15)	84.38 (27/32)	77.78 (21/27)	80.00 (12/15)
Normal	100 (57/57)	96.67 (58/60)	98.65 (73/74)	100 (57/57)	100 (60/60)	95.95 (71/74)	100 (57/57)	96.67 (58/60)	93.24 (69/74)
Toplam	94.38 (84/89)	91.95 (80/87)	95.51 (85/89)	95.51 (85/89)	93.10 (81/87)	91.01 (81/89)	94.38 (84/89)	90.80 (79/87)	91.01 (81/89)
	93.96 (249/265)			93.21 (247/265)			92.08 (244/265)		

Çizelge 4.17’ de arka plan sınıflandırma için CoD ile YSA, temel sınıflandırma için ADD, ARidD ve CoD ile YSA kullanılarak elde edilen temel sınıflandırma sonuçları verilmiştir. Çizelge 4.17’ den de görüleceği gibi en yüksek sınıflandırma başarısı % 94.34 ile temel sınıflandırma için ADD ile YSA kullanılarak sağlanmıştır.

Çizelge 4.17. Arka plan sınıflandırma için CoD ile YSA kullanılarak elde edilen temel sınıflandırma sonuçları

Sınıf	Doğruluk (%)								
	CoD-YSA + ADD-YSA			CoD-YSA + ARidD-YSA			CoD-YSA + CoD-YSA		
	Y	YB	YO	Y	YB	YO	Y	YB	YO
Anormal	84.38 (27/32)	77.78 (21/27)	73.33 (11/15)	87.50 (28/32)	74.07 (20/27)	60.00 (9/15)	84.38 (27/32)	74.07 (20/27)	73.33 (11/15)
Normal	100 (57/57)	100 (60/60)	100 (74/74)	100 (57/57)	100 (60/60)	97.30 (72/74)	100 (57/57)	100 (60/60)	94.59 (70/74)
Toplam	94.38 (84/89)	93.10 (81/87)	95.51 (85/89)	95.51 (85/89)	91.95 (80/87)	91.01 (81/89)	94.38 (84/89)	91.95 (80/87)	91.01 (81/89)
	94.34 (250/265)			92.83 (246/265)			92.45 (245/265)		

Önerilen sistemin birinci aşaması olan arka plan sınıflandırmada Çizelge 4.14’ den de görüleceği gibi en yüksek % 79.25’ lik başarı sağlanmıştır. Arka plan sınıflandırmanın tam doğrulukla yani % 100 başarı ile gerçekleştirilememiş olması önerilen sistemin temel sınıflandırma başarısını etkileyen bir unsurdur. Bu durumun çalışma üzerindeki etkisini incelemek amacıyla arka plan sınıflandırma işleminin tam doğrulukla gerçekleştirilmesi halinde elde edilecek temel sınıflandırma sonuçları Çizelge 4.18’ de verilmiştir. Önerilen sistem bu hali ile arka plan bilgileri manuel belirlenerek yarı otomatik olarak çalıştırılmıştır. Bu şartlar altında en yüksek sınıflandırma başarısı % 97.74 ile temel sınıflandırma için ADD ile YSA kullanılarak sağlanmıştır.

Çizelge 4.18. Arka plan sınıflandırmanın tam doğrulukla yapılması durumunda elde edilen temel sınıflandırma sonuçları

Sınıf	Doğruluk (%)								
	ADD + YSA			ARidD + YSA			CoD + YSA		
	Y	YB	YO	Y	YB	YO	Y	YB	YO
Anormal	96.88 (31/32)	96.30 (26/27)	80.00 (12/15)	100 (32/32)	85.19 (23/27)	60 (9/15)	96.88 (31/32)	92.59 (25/27)	73.33 (11/15)
Normal	100 (57/57)	98.33 (59/60)	100 (74/74)	100 (57/57)	100 (60/60)	98.65 (73/74)	100 (57/57)	98.33 (59/60)	95.95 (71/74)
Toplam	98.88 (88/89)	97.70 (85/87)	96.63 (86/89)	100 (89/89)	95.40 (83/87)	92.13 (82/89)	98.88 (88/89)	96.55 (84/87)	92.13 (82/89)
	97.74 (259/265)			95.85 (254/265)			95.85 (254/265)		

Çalışma sonucunda elde edilen duyarlılık ve özgüllük sonuçları Çizelge 4.19’ da verilmiştir. Arka plan sınıflandırılması yapılarak en yüksek duyarlılık değeri 0.8514 ile arka plan sınıflandırma için ADD ile YSA, temel sınıflandırma için ADD ile YSA kullanarak; en yüksek özgüllük değeri 1 ile arka plan sınıflandırma için CoD ile YSA, temel sınıflandırma için ADD ile YSA kullanılarak sağlanmıştır. Arka plan bilgilerinin manuel belirlendiği (tam doğrulukla arka plan sınıflandırma yapılarak) yarı otomatik sistem durumunda ise en yüksek duyarlılık 0.9324 ile temel sınıflandırma için ADD ile YSA kullanarak, en yüksek özgüllük 0.9948 ile temel sınıflandırma için ADD ile YSA ve ARidD ile YSA kullanılarak sağlanmıştır.


Önerilen sistemde normal-anormal doku sınıflandırılmasında karar noktası (ayrışım değeri) 0.5 olarak kabul edilmiştir. 0 ile 1 arasında 10^{-6} duyarlılık olmak üzere farklı karar noktaları için elde edilen sonuçlar ışığında çizilen AİK eğrileri Şekil 4.11-4.13’ de verilmiştir. Çizelge 4.20’ de ise Şekil 4.11-4.13’ de verilen eğriler kullanılarak hesaplanan A_z değerleri yer almaktadır. Arka plan sınıflandırılması yapılarak en yüksek A_z değeri 0.960 ile arka plan sınıflandırma için ADD ile YSA, temel sınıflandırma için ARidD ile YSA kullanarak sağlanmıştır. Şekil 4.14’ de önerilen sistemin yarı otomatik çalıştırılması durumunda elde edilen AİK eğrileri verilmiştir. Bu durumda en yüksek A_z değeri 0.974 olarak temel sınıflandırma için ARidD ile YSA kullanarak elde edilmiştir.


Çizelge 4.19. Önerilen sistem için elde edilen duyarlılık ve özgüllük sonuçları

Sistemin Çalışması	Arka Plan Sınıflandırma	Temel Sınıflandırma	DP	YN	YP	DN	Duyarlılık	Özgüllük
Otomatik	ADD+YSA	ADD+YSA	63	11	1	190	0.8514	0.9948
	ADD+YSA	ARidD+YSA	60	14	4	187	0.8108	0.9791
	ADD+YSA	CoD+YSA	62	12	6	185	0.8378	0.9686
	ARidD+YSA	ADD+YSA	61	13	3	188	0.8243	0.9843
	ARidD+YSA	ARidD+YSA	59	15	3	188	0.7973	0.9843
	ARidD+YSA	CoD+YSA	60	14	7	184	0.8108	0.9634
	CoD+YSA	ADD+YSA	59	15	0	191	0.7973	1
	CoD+YSA	ARidD+YSA	57	17	2	189	0.7703	0.9895
	CoD+YSA	CoD+YSA	58	16	4	187	0.7838	0.9791
Yarı Otomatik	Manuel Belirleme	ADD+YSA	69	5	1	190	0.9324	0.9948
	Manuel Belirleme	ARidD+YSA	64	10	1	190	0.8649	0.9948
	Manuel Belirleme	CoD+YSA	67	7	4	187	0.9054	0.9791


Çizelge 4.20. Önerilen sistem için elde edilen A_z sonuçları

Arka Plan Sınıflandırma	Temel Sınıflandırma	A_z
ADD+YSA	ADD+YSA	0.955
ADD+YSA	ARidD+YSA	0.960
ADD+YSA	CoD+YSA	0.951
ARidD+YSA	ADD+YSA	0.918
ARidD+YSA	ARidD+YSA	0.952
ARidD+YSA	CoD+YSA	0.923
CoD+YSA	ADD+YSA	0.923
CoD+YSA	ARidD+YSA	0.943
CoD+YSA	CoD+YSA	0.923
Manuel Belirleme	ADD+YSA	0.970
Manuel Belirleme	ARidD+YSA	0.974
Manuel Belirleme	CoD+YSA	0.966


**Şekil 4.11.** Arka plan sınıflandırma için ADD ile YSA kullanılarak elde edilen temel sınıflandırma AİK eğrileri



Şekil 4.12. Arka plan sınıflandırma için ARiD ile YSA kullanılarak elde edilen temel sınıflandırma AİK eğrileri



Şekil 4.13. Arka plan sınıflandırma için CoD ile YSA kullanılarak elde edilen temel sınıflandırma AİK eğrileri



Şekil 4.14. Arka plan sınıflandırma tam doğrulukla yapılarak elde edilen temel sınıflandırma AİK eğrileri

5. TARTIŞMA VE ÖNERİLER

5.1 Tartışma

5.1.1. Medikal görüntülerden gürültü temizleme uygulaması

Tez çalışmanın ilk uygulamasında RDHARip-1D ve KDHARip-1D özellik katsayıları kullanılarak medikal görüntülerden gürültü giderilmiştir. Bu uygulamada daha önce birçok görüntü işleme uygulamasında kullanılan Rip-1D' nin ilk defa hızlı ayırık formu tanımlanarak kompleks değerli katsayıları elde edilmiştir. Daha önce yapılan çalışmalardan DD ve RidD gibi çoklu çözünürlük analizlerinin kompleks özellik katsayıları kullanılarak, reel değerli katsayılar göre görüntülerden gürültü temizleme uygulamalarında daha yüksek başarılar elde edildiği bilinmektedir. Bu uygulama ile bu durumun Rip-1D içinde geçerli olduğu görülmüştür. Dördüncü bölümde Çizelge 4.2-4.4 ve Çizelge 4.6-4.8 ile verilen sonuçlar incelendiğinde görüleceği gibi bütün a (ölçek), c (destek) ve d (derece) parametreleri için KDHARip-1D ile elde edilen sonuçlar RDHARip-1D ile elde edilen sonuçlardan daha iyidir. Bunlara uygun olarak Çizelge 5.1 ve 5.2' de yer alan retina ve mamografi görüntüleri ile gürültü temizleme uygulamasında elde edilen en yüksek OYBİ ve ÖBİ sonuçları bu durumu destekler niteliktedir.

Çizelge 5.1. Uygulama sonucunda farklı c (destek) ve d (derece) parametresi için elde edilen en yüksek OYBİ sonuçları


	Retina görüntüleri			Mamografi görüntüleri		
	Sigma			Sigma		
	35	25	15	35	25	15
RDHARip-1D $c=1, d=2$	0.79777	0.82872	0.86467	0.85890	0.86955	0.88824
KDHARip-1D $c=1, d=2$	0.80950	0.83505	0.86861	0.87292	0.87376	0.88906
RDHARip-1D $c=1, d=3$	0.79500	0.82767	0.86419	0.85855	0.86966	0.88824
KDHARip-1D $c=1, d=3$	0.80839	0.83326	0.86775	0.87211	0.87344	0.88906
RDHARip-1D $c=1, d=4$	0.79490	0.82762	0.86419	0.85585	0.86966	0.88824
KDHARip-1D $c=1, d=4$	0.80846	0.83328	0.86775	0.87211	0.87344	0.88906
RDHARip-1D $c=1, d=5$	0.79490	0.82762	0.86419	0.86280	0.87365	0.88853
KDHARip-1D $c=1, d=5$	0.80846	0.83328	0.86775	0.87514	0.87732	0.88907

Çizelge 5.2. Uygulama sonucunda farklı c (destek) ve d (derece) parametresi için elde edilen en yüksek ÖBİ sonuçları

	Retina görüntüleri			Mamografi görüntüleri		
	Sigma			Sigma		
	35	25	15	35	25	15
RDHARip-1D $c=1, d=2$	0.89022	0.91513	0.94659	0.91049	0.92354	0.94851
KDHARip-1D $c=1, d=2$	0.89398	0.91743	0.94712	0.91079	0.92558	0.94886
RDHARip-1D $c=1, d=3$	0.88995	0.91460	0.94650	0.91104	0.92410	0.94867
KDHARip-1D $c=1, d=3$	0.89372	0.91711	0.94703	0.91125	0.92626	0.94901
RDHARip-1D $c=1, d=4$	0.89000	0.91463	0.94650	0.91262	0.92498	0.94867
KDHARip-1D $c=1, d=4$	0.89379	0.91711	0.94703	0.91279	0.92702	0.94901
RDHARip-1D $c=1, d=5$	0.89000	0.91463	0.94650	0.91349	0.92509	0.94867
KDHARip-1D $c=1, d=5$	0.89379	0.91711	0.94703	0.91387	0.92723	0.94902

Tez çalışmasının ilk uygulamasında ek olarak, a (ölçek) değerindeki değişimin medikal görüntülerden gürültü temizleme sonuçları üzerindeki etkileri incelenmiştir. Çizelge 4.2- 4.4 ile Çizelge 4.6-4.8' den de görüleceği gibi retina görüntüleri için en iyi sonuçlar a (ölçek) değerinin 5 olması durumunda elde edilirken mamografi görüntülerinde en iyi sonuçlar farklı a (ölçek) değerleri için elde edilmiştir. Yine bu uygulama ile eşikleme sabitindeki değişimin medikal görüntülerden gürültü temizleme sonuçlarına etkileri de incelenmiştir. RDHARip-1D ve KDHARip-1D özellik katsayıları ile yapılan uygulamalarda eşikleme sabitinin farklı aralıklarda seçilmesi gerektiği görülmektedir. Çizelge 4.2-4.4 ile Çizelge 4.6-4.8 incelendiğinde reel değerli özellik katsayıları ile yapılan uygulamalarda eşikleme sabitinin 2.7 ile 3.4 arasındaki değerleri için en iyi sonuçların elde edildiği ortaya çıkmıştır. Bu durum daha önce reel değerli özellik katsayıları ile yapılan uygulamalarda karşılaşılan eşikleme sabitinin genellikle 3 olarak seçilmesi gerektiği fikrini desteklemektedir. Bu tez çalışması ile, kompleks değerli özellik katsayıların kullanıldığı gürültü temizleme uygulamalarında eşikleme sabitinin 2.2 ile 2.7 aralığında seçilmesi gerektiği gösterilmiştir.

Ölçek parametresindeki değişimin eşikleme sabiti değerine etkisi de incelenmesi gereken önemli bir husustur. RDHARip-1D ve KDHARip-1D özellik katsayıları ile yapılan uygulamalarda a (ölçek) parametresi artarken en iyi sonucun elde edildiği eşikleme sabiti değeri azalma eğilimi göstermektedir. Şekil 5.1' de retina ve mamografi görüntüleri ile yapılan uygulamada a (ölçek) değerleri ve bu değerler için en iyi sonuçların elde edildiği eşikleme sabiti değerleri arasındaki değişim görülmektedir.



Şekil 5.1. Ölçek değerleri ile en iyi sonucun elde edildiği eşikleme sabiti değerlerinin birbirlerine göre değişimi a) RDHARip-1D özellik katsayıları ile gürültü temizleme b) KDHARip-1D özellik katsayıları ile gürültü temizleme

Çizelge 5.3’ de retina ve mamografi görüntülerinden gürültü temizleme uygulamasında farklı a (ölçek), c (destek) ve d (derece) parametreleri için elde edilen en yüksek TSGO sonuçları görülmektedir. Çizelge 5.3’ e göre retina görüntüleri için en yüksek gürültü temizleme başarısı c (destek)=1, d (derece)=2 değerleri; mamografi görüntüleri için en yüksek gürültü temizleme başarısı c (destek)=1, d (derece)=5 değerleri için elde edilmiştir.

Çizelge 5.3 incelendiğinde retina görüntüleri için c (destek)=1, d (derece)=3; c (destek)=1, d (derece)=4; c (destek)=1, d (derece)=5 değerleri için elde edilen en iyi sonuçlar arasındaki değişimlerin çok az olduğu görülmektedir. Bu durumun ortaya çıkmasında bu görüntüler için en iyi sonuçların a (ölçek) parametresinin 5 değeri için gerçekleşmiş olmasının etkisi vardır. İkinci bölümde Çizelge 2.1 ile ayrıntıları açıklanan ve HARip-1D frekans düzlemi dilimlerini oluşturmak amacıyla kullanılan ayrışım ağacı incelendiğinde a (ölçek) parametresinin değeri arttıkça ayrışımın çeşitlendiği görülmektedir. Retina görüntülerinde yapılan gürültü temizleme uygulamasında en iyi sonuçların elde edildiği a (ölçek) değerinin 5 olması sebebiyle ayrışım ağacı çeşitlenmesi sınırlı bir şekilde gerçekleşmiştir. Ancak mamografi görüntülerinde en iyi sonuçların elde edildiği a (ölçek) parametresi farklılıklar göstermektedir. Bu durum ölçek değerinin büyümesine bağlı olarak ayrışım ağacı çeşitlenmesini artırmaktadır. Çeşitlenmenin artması mamografi görüntülerinde gürültü temizleme uygulamasında en iyi sonuçların c (destek)=1, d (derece)=5 değerleri için elde edilmesinde etkili olmuştur.


Bu sonuçlar medikal görüntülerden gürültü temizleme yapılırken a (ölçek), c (destek) ve d (derece) parametrelerinin standart değerler yerine kullanılan görüntüye uygun olarak belirlenmesi gerektiğini ortaya koymuştur.

Çizelge 5.3. Uygulama sonucunda farklı c (destek) ve d (derece) parametresi için elde edilen en yüksek TSGO sonuçları

	Retina görüntüleri			Mamografi görüntüleri		
	Sigma			Sigma		
	35	25	35	25	35	25
RDHARip-1D $c=1, d=2$	33.042	34.387	36.322	35.247	36.508	38.254
KDHARip-1D $c=1, d=2$	33.300	34.579	36.443	35.510	36.719	38.412
RDHARip-1D $c=1, d=3$	33.005	34.345	36.234	35.444	36.603	38.303
KDHARip-1D $c=1, d=3$	33.246	34.540	36.340	35.711	36.794	38.445
RDHARip-1D $c=1, d=4$	33.022	34.348	36.234	35.463	36.640	38.320
KDHARip-1D $c=1, d=4$	33.270	34.543	36.329	35.713	36.815	38.460
RDHARip-1D $c=1, d=5$	33.022	34.348	36.234	35.588	36.714	38.373
KDHARip-1D $c=1, d=5$	33.270	34.543	36.329	35.820	36.892	38.488

5.1.2. Göğüs mamografi görüntülerinden normal-anormal doku sınıflandırılması uygulaması

Tezde gerçekleştirilen göğüs mamografi görüntülerinden normal-anormal doku sınıflandırma uygulaması ile göğüs arka plan yoğunluğunun sınıflandırma üzerindeki olumsuz etkilerinin azaltılmasında önemli sonuçlar elde edilmiştir. Göğüs normal-anormal dokularının sınıflandırılmasında arka plan sınıflandırma uygulamadan ve arka plan sınıflandırma uygulayarak elde edilen sonuçların karşılaştırılması Şekil 5.2’ de görülmektedir. Arka plan sınıflandırma uygulamadan en yüksek sınıflandırma başarısı % 86.04 olarak elde edilirken, arka plan sınıflandırma uygulanarak bu başarı % 95.47’ ye çıkarılmıştır. Önerilen sistemin arka plan bilgilerinin manuel belirlenerek (tam doğrulukla arka plan sınıflandırma yapılarak) yarı otomatik çalıştırılması durumunda ise sınıflandırma başarısı % 97.74’ e kadar yükselmektedir.



Şekil 5.2. Göğüs normal-anormal doku sınıflandırma sonuçlarının karşılaştırılması

Çalışma sonucunda farklı göğüs arka plan doku yoğunluk tipleri için % 60 ile % 100 arasında değişen sınıflandırma başarısı elde edilmiştir. Genel olarak normal-anormal dokuların sınıflandırılmasında en yüksek doğruluk % 95.47 ile arka plan sınıflandırma için ADD ile YSA, temel sınıflandırma için ADD ile YSA kullanılarak; en yüksek duyarlılık 0.8514 ile arka plan sınıflandırma için ADD ile YSA, temel sınıflandırma için ADD ile YSA kullanarak; en yüksek özgüllük 1 ile arka plan sınıflandırma için CoD ile YSA, temel sınıflandırma için ADD ile YSA kullanılarak sağlanmıştır. Çalışmada en yüksek A_z değeri 0.960 ile arka plan sınıflandırma için ADD ile YSA, temel sınıflandırma için ARidD ile YSA kullanarak elde edilmiştir.

Önerilen sistemin arka plan bilgilerinin manuel belirlenerek (tam doğrulukla arka plan sınıflandırma yapılarak) yarı otomatik çalıştırılması durumunda en yüksek doğruluk % 97.74 ile temel sınıflandırma için ADD ile YSA kullanarak, en yüksek duyarlılık 0.9324 ile temel sınıflandırma için ADD ile YSA kullanarak, en yüksek özgüllük 0.9948 ile temel sınıflandırma için ADD ve ARidD ile YSA kullanılarak sağlanmıştır. En yüksek A_z değeri 0.974 ile temel sınıflandırma için ARidD ile YSA kullanarak elde edilmiştir.

Çizelge 5.4' de, MIAS veritabanında yer alan görüntüler üzerinde normal-anormal doku sınıflandırma konusunda daha önce gerçekleştirilen çalışmalar ile bu tez çalışmasında elde edilen en yüksek sınıflandırma sonuçları karşılaştırılmıştır. Diğer çalışmalarda kullanılan görüntü alanlarına, doku arka plan yoğunluk tiplerine ve görüntü etiketlerine dair ayrıntılar yer almadığı için tam anlamıyla bir karşılaştırma

yapmak mümkün değildir. Ancak bu tez çalışmasında önerilen sistem ile elde edilen A_z değeri, çalışmanın literatür içerisindeki yeri hakkında fikir vermektedir.

Çizelge 5.4. MIAS veritabanı üzerinde gerçekleştirilen normal-anormal doku sınıflandırma çalışmaları

Çalışma	Yıl	Görüntü Alanı Sayısı	Doğruluk (%)	Duyarlılık	Özgüllük	A_z
Christoyianni ve arkadaşları-(a)	1999	76	75.20	0.868	-	-
Christoyianni ve arkadaşları-(b)	1999	119	84.87	-	-	-
Bovis ve Singh	2000	868	77.00	0.730	0.25	0.740
Christoyianni ve arkadaşları	2002	119	88.23	-	-	-
Mini ve Thomas	2003	157	71.30	-	-	-
Jirari	2005	322	86.74	-	-	0.910
Hassanien	2007	320	98.46	-	-	-
Costa ve arkadaşları	2007	100	97.00	-	-	-
Dua ve arkadaşları	2009	322	89.99	-	-	-
Faye ve arkadaşları	2009	163	98.55	-	-	-
Jasmine ve arkadaşları	2009	322	87.00	-	-	-
Eltoukhy ve arkadaşları-(a)	2010	116	94.66	0.893	-	-
Eltoukhy ve arkadaşları-(b)	2010	142	98.59	-	-	-
Moayedi ve arkadaşları	2010	90	96.60	0.958	0.990	-
Dheeba ve Tamil Selvi	2010	322	-	0.852	-	-
Thangavel ve Mohideen	2010	108	90.67	-	-	0.910
Mata ve Meenakshi	2011	125	82.40	0.800	0.826	-
Kitanovski ve arkadaşları	2011	326	98.77	-	-	-
Hussain ve arkadaşları	2012	109	-	-	-	0.960
Faye	2012	64	76.59	-	-	-
Eltoukhy ve arkadaşları	2012	322	95.98	-	-	-
Padmanabhan ve Sundararajan	2012	100	91.00	-	-	-
Wong ve arkadaşları	2012	69	81.16	-	-	-
Nguyen ve arkadaşları	2013	2700	88.72	-	-	0.9325
Radovic ve arkadaşları	2013	322	79.33	-	-	0.834
Kumar ve Balakrishnan	2013	155	93.39	-	-	-
Ohmshankar ve K. Charlie Paul	2014	142	92.27	-	-	-
Tez Çalışması (Tam Otomatik Sistem)	2015	265	95.47	0.8514	1	0.960
Tez Çalışması (Yarı Otomatik Sistem)	2015	265	97.74	0.9324	0.9948	0.974

5.2 Öneriler

5.2.1. Medikal görüntülerden gürültü temizleme uygulaması

Tez çalışmasının birinci uygulamasında Rip-1D' nin hızlı ayırık versiyonu tanımlanmış ve kompleks değerli özellik katsayıları oluşturulmuştur. Ayrıca yine bu tez çalışması sırasında tanımlanan KDHARip-1D ilk kez bir medikal görüntü işleme uygulamasında kullanılmıştır. Uygulama sonucunda KDHARip-1D' nin RDHARip-1D' ye göre medikal görüntülerden gürültü temizleme uygulamalarında daha başarılı sonuçlar ürettiği görülmüştür.

Çoklu çözünürlük dönüşümleri alanında yeni tanımlanan dönüşümler çoğu zaman daha önce tanımlanan dönüşümlerin eksik yönlerini ortadan kaldırmayı hedeflemektedir. Yeni tanımlanacak dönüşümler ile görüntü özelliklerinin daha etkin şekilde ifade edilmesi mümkün olacaktır. Bu durum, görüntü özelliklerini kullanarak görüntülerden gürültü temizleme yapan çalışmaların başarısını artıracaktır. Ayrıca bu tez çalışmasında olduğu gibi daha önce tanımlanan dönüşümlerin kompleks formda ifade edilmesi de görüntülerden gürültü temizleme başarısına olumlu katkılarda bulunacaktır. Bu kapsamda RidD' nin genelleştirilmesi ile oluşturulan ripplet-2 dönüşümünün kompleks formda ifade edilmesinin medikal görüntü işleme alanında önemli kazanımlar sağlayacağı öngörülmektedir.

5.2.2. Göğüs mamografi görüntülerinden normal-anormal doku sınıflandırılması uygulaması

Tezde gerçekleştirilen göğüs mamografi görüntülerinden normal-anormal doku sınıflandırılması uygulamasında ADD, ARidD ve CoD olmak üzere üç adet çoklu çözünürlük dönüşümü kullanılmıştır. Tez çalışmasında önerilen sınıflandırma yapısında farklı ve yeni çoklu çözünürlük dönüşümleri kullanılması sınıflandırma başarısını artıracak önemli bir unsur olacaktır. Ayrıca daha önce göğüs normal-anormal dokuların sınıflandırılması çalışmalarında çoklu çözünürlük dönüşümlerinin kompleks versiyonları kullanılmamıştır. Gelecek çalışmalarda bu çoklu çözünürlük dönüşümlerinin reel versiyonlarının yanında kompleks versiyonlarının da kullanılması sınıflandırma başarısını etkileyecektir. Ayrıca bu uygulamada maksimum değer, minimum değer, ortalama ve standart sapma olmak üzere sadece 4 adet istatistiki özellik

kullanılmıştır. Daha fazla ve farklı istatistiki özelliklerin kullanılması çalışma başarısını artıracaktır. Gerçekleştirilen uygulamada kullanılan görüntü özelliklerinin optimizasyonunun yapılarak özellik boyutlarının azaltılmasına veya seçilmesine yönelik herhangi bir optimizasyon yöntemi (parçacık sürü optimizasyonu, çok sürülü optimizasyon, arı koloni optimizasyonu gibi) kullanılmamıştır. Çalışmada kullanılan görüntü özelliklerinin optimize edilmesinin sonuçlara olumlu katkılar sağlayacağı düşünülmektedir.

KAYNAKLAR

- Arserim, M. A., 2001, Beyin sinyallerinin modern spektral analiz yöntemleri ile kestirimi, Yüksek lisans tezi, *Dicle Üniversitesi Fen Bilimleri Enstitüsü*, Diyarbakır, 11-20.
- Bamberger, R. H. and Smith, M. J. T., 1992, A filter bank for the directional decomposition of images: Theory and design, *IEEE Transactions on Signal Processing*, 40 (4), 882 -893.
- Bao, O. Z., Gao, J. H. and Chen, W. C., 2008, Local adaptive shrinkage threshold denoising using curvelet coefficients, *Electronics Letters*, 44 (4), 277-278.
- Baradarani, A. and Runyi, Y., 2007, A dual-tree complex wavelet with application in image denoising, *IEEE International Conference on Signal Processing and Communications*, Dubai, 1203-1206.
- Binh, N. T. and Khare, A., 2010, Multilevel threshold based image denoising in curvelet domain, *Journal of Computer Science and Technology*, 25 (3), 632-640.
- Bovis, K. and Singh, S., 2000, Detection of masses in mammograms using texture features, *International Conference on Pattern Recognition*, Barcelona-Spain, 2, 267-270.
- Blot, L. and Zwiggelaar, R., 2001, Background texture extraction for the classification of mammographic parenchymal patterns, *Medical Image Understanding and Analysis*, Edgbaston-UK, 145-148.
- Chui, C. K., 1992, An introduction to wavelets, *Academic Press*, San Diego-California, 1-18.
- Coifman, R. R. and Wickerhauser, M. V., 1992, Entropy based algorithms for best basis selection, *IEEE Transactions on Information Theory*, 38 (2), 713-718.
- Candes, E. J. and Donoho, D. L., 1999, Ridgelets: A the key to higher-dimensional intermittency, *Philosophical Transactions of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, 357, 2495-2509.
- Candes, E. J. and Donoho, D. L., 2000, Curves and surface fitting (Curvelets-A surprisingly effective nonadaptive representation for objects with edges), *Vanderbilt University Press*, Nashville, 105-120.
- Candes, E. J. and Donoho, D. L., 2002, New tight frames of curvelets and optimal representations of objects with smooth singularities, Technical report, Statistics-Stanford University.
- Candes, E. J. and Guo, F., 2002, New multiscale transforms, minimum total variation synthesis: application to edge-preserving image reconstruction, *Signal Processing*, 82 (11), 1519-1543.

- Candes, E. J., Demanet, L., Donoho, D. L. and Ying, L., 2005, Fast discrete curvelet transforms, *Applied and Computational Mathematics, California Institute of Technology*.
- Ceylan, M., 2004, Kompleks değerli yapay sinir ağı ile algortima geliştirilmesi ve uygulamaları, Yüksek lisans tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 9-31.
- Ceylan, M., 2009, Bilgisayar tomografili akciğer görüntülerinin değerlendirilmesinde kompleks değerli yeni bir akıllı sistem tasarımı, Doktora tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 21-50.
- Chen, G., Zhu, W. P. and Xie, W., 2012, Wavelet-based image denoising using three scales of dependency, *IET Image Process*, 6 (6), 756-760.
- Christoyianni, I., Dermatas, E. and Kokkinakis, G., 1999-a, Fast detection of masses in digitized mammograms, *International Conference on Acoustics, Speech, and Signal Processing*, Phoenix-USA, 4, 2355-2358.
- Christoyianni, I., Dermatas, E. and Kokkinakis, G., 1999-b, Neural classification of abnormal tissue in digital mammography using statistical features of the texture, *International Conference on Electronics, Circuits and Systems*, Pafos-Cyprus, 1, 117-120.
- Christoyianni, I., Koutras, A., Dermatas, E. and Kokkinakis, G., 2002, Computer aided diagnosis of breast cancer in digitized mammograms, *Computerized Medical Imaging and Graphics*, 26 (5), 309-319.
- Costa, D. D., Campos, L. F., Barros, A. K. and Silva, A. C., 2007, Independent component analysis in breast tissues mammograms images classification using LDA and SVM, *International Special Topic Conference on Information Technology Applications in Biomedicine*, Tokyo-Japan, 231-234.
- Das, S., Chowdhury, M. and Kundu, M. K., 2011, Medical image fusion based on ripplet transform type-I, *Progress in Electromagnetics Research B*, 30, 355-370.
- Das, S. and Kundu, M. K., 2011, Ripplet based multimodality medical image fusion using pulse-coupled neural network and modified spatial frequency, *International Conference on Recent Trends in Information Systems*, Kolkata-Hindistan, 21-23.
- Daubechies, I., 1990, The Wavelet Transform, Time-Frequency Localization and Signal Analysis, *IEEE Trans. Info. Theory*, 36, 961-1005.
- Daubechies, I., 1992, Ten lectures on wavelets, *Society for Industrial and Applied Mathematics*, Philadelphia- Pennsylvania, 331-333.
- Donoho, D. L. and Duncan, M. R., 2000, Digital curvelet transform: strategy, implementation and experiments, *SPIE Wavelet Applications VII*, Orlando-USA, 4056, 12-29.

- Dheeba, J. and Tamil Selvi, S., 2010, Screening mammogram images for abnormalities using radial basis function neural network, *International Conference on Communication Control and Computing Technologies*, Tamil Nadu-India, 554-559.
- Do, M. N. and Vetterli, M., 2005, The contourlet transform: an efficient directional multiresolution image representation, *IEEE Transactions on Image Processing*, 14 (12), 2091-2106.
- Dua, S., Singh, H. and Thompson, H. W., 2009, Associative classification of mammograms using weighted rules, *Expert Systems with Applications*, 36 (5), 9250-9259.
- Eltoukhy, M. M. M., Faye, I. and Samir, B. B., 2010-a, Automatic detection of breast masses in digital mammograms using pattern matching, *EMBS Conference on Biomedical Engineering and Sciences*, Kuala Lumpur-Malaysia, 73-76.
- Eltoukhy, M. M. M., Faye, I. and Samir, B. B., 2010-b, Breast cancer diagnosis in digital mammogram using multiscale curvelet transform, *Computerized Medical Imaging and Graphics*, 34 (4), 269-276.
- Eltoukhy, M. M. M., Faye, I. and 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.
- Fadili, M. J. and Starck, J. L., 2012, Curvelets and ridgelets, *Springer New York*, Nashville, 754-773.
- Faye, I., 2012, A random feature selection method for classification of mammogram images, *International Conference on Intelligent Systems Modelling and Simulation*, Kota Kinabalu-Malaysia, 330-333.
- Faye, I., Samir, B. B. and Eltoukhy, M. M. M., 2009, Digital mammograms classification using a wavelet based feature extraction method, *International Conference on Computer and Electrical Engineering*, Dubai-United Arab Emirates, 2, 318-322.
- Gabor, D, 1946, Theory of communication, *Journal of the IEEE*, 93 (26), 429-441.
- Gedik N. and Atasoy, A., 2013, A computer-aided diagnosis system for breast cancer detection by using a curvelet transform, *Turkish Journal of Electrical Engineering & Computer Sciences*, 21, 1002-1014.
- Grossmann, A. and Morlet, J., 1984, Decompsotition of Hardy functions into square integrable wavelets of constant shape, *SIAM Journal on Mathematical Analysis*, 15 (4), 723-736.

- Gulstrud, T. O. and Loland, E., 1996, Multichannel filtering for texture feature extraction in digital mammograms, *International Conference of the IEEE Engineering in Medicine and Biology Society*, Amsterdam-Netherlands, 3, 1153-1154.
- Gupta, D., Anand, R. S. and Tyagi, B., 2014, Ripplet domain non-linear filtering for speckle reduction in ultrasound medical images, *Biomedical Signal Processing and Control*, 10, 79-91.
- Hassanien, A., 2007, Fuzzy rough sets hybrid scheme for breast cancer detection, *Image and Vision Computing*, 25 (2), 172-183.
- Haykin, S., 1994, Neural Networks: A Comprehensive Foundation, *Macmillan College Publishing Company*, New York.
- Hongqiao, L. and Shengqian, W., 2009, A new image denoising method using wavelet transform, *International Forum on Information Technology and Applications*, Chengdu-China, 111-114.
- Huynh-Thu, Q., 2008, Scope of validity of PSNR in image/video quality assessment, *Electronics Letters*, 44 (13), 800.
- <http://www.iarc.fr/> [Ziyaret Tarihi: 24 Kasım 2014].
- Hussain, M., Khan, S., Muhammad, G. and Bebis, G., 2012, A comparison of different gabor features for mass classification in mammography, *International Conference on Signal Image Technology and Internet Based Systems*, Naples-Italy, 142-148.
- ISO/IEC JTC 1/SC 29/WG1 N943, 1999, JPEG2000 Requirements and Profiles, International Organization of Standardization, Copenhagen.
- Jasmine, J. S. L., Govardhan, A. and Baskaran, S., 2009, Microcalcification detection in digital mammograms based on wavelet analysis and neural networks, *International Conference on Control, Automation, Communication and Energy Conservation*, Tamilnadu-India, 1-6.
- Jirari, M., 2005, A computer aided detection system for digital mammograms based on radial basis functions and feature extraction techniques, *Annual International Conference of the Engineering in Medicine and Biology Society*, Shanghai-China, 4457-4460.
- Junli, L., Yanqin, H., Ping, W. and Gang, C., 2007, A novel method for the determination of the wavelet denoising threshold, *International Conference on Bioinformatics and Biomedical Engineering*, Wuhan-China, 713-716.
- Karakoç, M., 2011, İnternet üzerinde görüntü işleme, *XVI. Türkiye'de İnternet Konferansı*, İzmir-Türkiye, 67.

- Kavitha, C. T., Chellamuthu, C. and Rajesh, R., 2012, Medical image fusion using combined discrete wavelet and ripplelet transform, *Procedia Engineering*, 38, 813-820.
- Kitanovski, I., Jankulovski, B., Dimitrovski, I. and Loskovska, S., 2011, Comparison of feature extraction algorithms for mammography images, *International Congress on Image and Signal Processing*, Shanghai-China, 2, 888-892.
- Kumar, S. M. and Balakrishnan, G., 2013, Multi resolution analysis for mass classification in digital mammogram using stochastic neighbor embedding, *International conference on Communication and Signal Processing*, Melmaruvathur-India, 101-105.
- Lawton, W., 1993, Applications of complex valued wavelet transforms to subband decomposition, *IEEE Transactions on Signal Processing*, 41 (12), 3566-3568.
- Li, X. and Zhu, S., 2006, Image denoising based on wavelet domain spatial context modeling, *The Sixth World Congress on Intelligent Control and Automation*, Dalian-China, 2, 9504-9508.
- Liasis, G., Pattichis, C. and Petroudi, S., 2012, Combination of different texture features for mammographic breast density classification, *International Conference on Bioinformatics & Bioengineering*, Larnaca-Cyprus, 732-737.
- Lina, J. M., 1998, Inverse problems, tomography, and image processing, *Springer*, New York, 95-112.
- Liu, S., Babbs, C. F. and Delp, E. J., 2001, Multiresolution detection of spiculated lesions in digital mammograms, *Transactions on Image Processing*, 10 (6), 874-884.
- Ma, L., Ma, J. and Shen, Y., 2007, Pixel fusion based curvelets and wavelets denoise algorithm, *Engineering Letters*, 14 (2), 1-5.
- Mallat, S., 1989, A theory for multiresolution signal decomposition: the wavelet representation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11 (7), 674-693.
- Mata, B. N. B. U. and Meenaksh, M., 2011, A novel approach for automatic detection of abnormalities in mammograms, *Recent Advances in Intelligent Computational Systems*, Trivandrum-India, 831-836.
- Meyer, Y., 1993, Wavelets and operators, Cambridge Studies in Advanced Mathematics 37, *Cambridge University Press*, Cambridge.
- Mini, M. G. and Thomas, T., 2003, A neural network method for mammogram analysis based on statistical features, *Conference on Convergent Technologies for the Asia-Pacific Region*, Bangalore-India, 4, 1489-1492.

- Misiti, M., Misiti, Y., Oppenheim, G. and Poggi, J. M., 2004, Wavelet toolbox users guide, *MathWorks*, Natick-Massachusetts.
- Muhammady, T., Ghassemian, H. and Razzazi, F., 2012, Using co-occurrence features extracted from ripplelet-I transform in texture classification, *Iranian Conference on Electrical Engineering*, Teheran-Iran, 1292-1297.
- Muhimmah, I. and Zwiggelaar, R., 2006, Mammographic density classification using multiresolution histogram information, *International Special Topic Conference on Information Technology in Biomedicine*, Epirus-Greece, 6 pages.
- Moayed, F., Azimifar, Z., Boostani, R. and Katebi, S., 2010, Contourlet-based mammography mass classification using the SVM family, *Computers in Biology and Medicine*, 40 (4), 373-383.
- Mojsilovic, A., Popovic, M. and Sevic, D., 1996, Classification of the ultrasound liver images with the $2N \times 1$ -D wavelet transform, *International Conference on Image Processing*, Lausanne-Swiss, 1, 367-370.
- Morlet, J., Arehs, G., Forugeau, I. and Giard, D., 1982, Wave propagation and sampling theory, *Geophysics*, 47, 203-236.
- Musta, M., Grgic, M. and Delac, K., 2012, Breast density classification using multiple feature selection, *Journal for Control, Measurement, Electronics, Computing and Communications*, 53 (4), 362-372.
- Nguyen, M. P., Truong, Q. D., Nguyen, D. T., Nguyen, T. D. and Nguyen, V. D., 2013, An alternative approach to reduce massive false positives in mammograms using block variance of local coefficients features and support vector machine. *Procedia Computer Science*, 20, 399-405.
- Ohmshankar, S., Kumar Charlie Paul, C., 2014, Haralick features based mammogram classification system, *International Conference on Current Trends in Engineering and Technology*, Coimbatore-India, 409-413.
- Oliver, A., Freixenet, J., Bosch, A., Raba, D. and Zwiggelaar R., 2005, Automatic classification of breast tissue, *Lecture Notes in Computer Science*, 3523, 431-438.
- Padmanabhan, S. and Sundararajan, R., 2012, Enhanced accuracy of breast cancer detection in digital mammograms using wavelet analysis, *International Conference on Machine Vision and Image Processing*, Taipei-Taiwan, 153-156.
- Patil, A. A. and Singhai, J., 2010, Image denoising using curvelet transform: an approach for edge preservation. *Journal of Scientific & Industrial Research*, 69 (1), 34-38.
- Petroudi, S., Constantinou, I., Tziakouri, C., Pattichis, M. and Pattichis, C., 2013, Investigation of AM-FM methods for mammographic breast density classification, *International Conference on Bioinformatics & Bioengineering*, Chania, 1-4.

- Polikar, R., The Wavelet Tutorial, 1996, users.rowan.edu/~ polikar/WAVELETS/WTtutorial.html [Ziyaret Tarihi: 24 Kasım 2014].
- Pu-chun, C., Xi-zhen, Z., Shou-ping, X., Long-long, F. and Reich, W., 2001, Application of Debauchies wavelet to the de-noising of radio maps, *Chinese Astronomy and Astrophysics*, 25 (1), 132-137.
- Quraishi, I., Das, G., Das, A., Dey, P. and Tasneem, A., 2013, A novel approach for face detection using artificial neural network, *International Conference on Intelligent Systems and Signal Processing*, Gujarat-Hindistan, 179-184.
- Radovic, M., Djokovic, M., Peulic, A. and Filipovic, N., 2013, Application of data mining algorithms for mammogram classification, *International Conference on Bioinformatics and Bioengineering*, Chania-Greece, 1-4.
- Reddy, G. J., Prasad, T. J. C. and Prasad, M. N. G., 2008, Fingerprint image denoising using curvelet transform, *ARPN Journal of Engineering and Applied Sciences*, 3 (3), 31-35.
- Reider, P. and Nossek, J. A., 1997, Implementation of orthogonal wavelet transforms and their applications, *IEEE International Conference on Application-Specific Systems, Architectures and Processors*, Zurich-Swiss, 489-498.
- Rioul, O. and Vetterli, M., 1991, Wavelets and Signal Processing, *IEEE Signal Processing Magazine*, 8 (4), 14-38.
- Rizzi, M., D'Aloia, M., Guaragnella, C. and Castagnolo, B., 2012, Health care improvement: comparative analysis of two cad systems in mammographic screening, *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, 42 (6), 1385-1395.
- Sağıroğlu, Ş., Beşdok, E. ve Erler, M., 2003, Mühendislikte Yapay Zeka Uygulamaları-I / Yapay Sinir Ağları, *Ufuk Yayınevi*, Kayseri.
- Sasheendran, N. and Bhuvaneswari, C., 2013, An effective CBIR (content based image retrieval) approach using ripplelet transforms, *International Conference on Circuits. Power and Computing Technologies*, Nagercoil- Hindistan, 917-922.
- Selesnick, I. W., Baraniuk, R. G. and Kingsbury, N. C., 2005, The dual-tree complex wavelet transform, *IEEE Signal Processing Magazine*, 22 (6), 123-151.
- Selvan, S. E., Xavier, C. C., Karssemeijer, N., Sequeira, J., Cherian, R. A. and Dhala, B. Y., 2006, Parameter estimation in stochastic mammogram model by heuristic optimization techniques, *IEEE Transactions on Information Technology in Biomedicine*, 10 (4), 685-695.
- Sharma, D., Yadav, U. B. and 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, 53-58.

- Shukla, P. D., 2003, Complex wavelet transforms and their applications, MS Thesis, *The University of Strathclyde*.
- Shukla, M. and Changlani, S., 2013, A comparative study of wavelet and curvelet transform for image denoising. *IOSR Journal of Electronics and Communication Engineering*, 7 (4), 63-68.
- Sivakumar, R., 2007, Denoising of computer tomography images using curvelet transform, *ARPJ Journal of Engineering and Applied Sciences*, 2 (1), 21-26.
- Silvia, M. J. and Poovizhi, S., 2012, Retinal image analysis using ripplelet-I transform and segmentation using morphological gradient, *International Journal of Emerging Technology and Advanced Engineering*, 2 (12) , 2012.
- Silva, W. R. and Menotti, D., 2012, Classification of mammograms by the breast composition, *International Conference on Image Processing, Computer Vision, and Pattern Recognition*, Las Vegas-USA, 6 pages.
- Song, Z. and YuanPeng, L., 2009, A novel image denosing scheme via combining dual-tree complex wavelet transform and bandelets, *Third International Symposium on Intelligent Information Technology Application*, Nanchang-China, 509-512.
- Staal, J., Abramoff, M. D., Niemeijer, M., Viergever, M. A. and Ginneken, B., 2004, Ridge based vessel segmentation in color images of the retina, *IEEE Transactions on Medical Imaging*, 23 (4), 501-509.
- Starck, J. L., Candes, E. J. and Donoho, D. L., 2002, The curvelet transform for image denosing, *IEEE Transactions on Image Processing*, 11 (6), 670-684.
- Suckling, J., Parker, J., Dance, D. R., Astley, S., Hutt, I., Boggis, C., Ricketts, I., Stamatakis, E., Cerneaz, N., Kok, S. L., Taylor, P., Betal, D. and Savage, J., 1994, The mammographic image analysis society digital mammogram database. *Second International Workshop on Digital Mammography*, 1069, 375-378.
- Subashini, T. S., Ramalingam, V. and Palanivel, S., 2010, Automated assessment of breast tissue density in digital mammograms, *Computer Vision and Image Understanding*, 114, 33-43.
- Thakur, N. and Devi, S., 2011, A new method for color image quality assessment, *International Journal of Computer Applications*, 15 (2), 10-17.
- Thangavel, K. and Mohideen, K. A., 2010, Semi-supervised k-means clustering for outlier detection in mammogram classification, *Trendz in Information Sciences & Computing*, Chennai-India, 68-72.
- Tzikopoulou, S. D., Mavroforakis, M. E., Georgiou, H. V., Dimitropoulos, N. and Theodoridis, S., 2011, A fully automated scheme for mammographic segmentation and classification based on breast density and asymmetry, *Computer Methods And Programs in Biomedicine*, 102, 47-63.

- Türkiye Kanser İstatistikleri, 2014; Editör: Murat Gültekin, Güledal Boztaş, T.C. Sağlık Bakanlığı Türkiye Halk Sağlığı Kurumu, Ankara.
- Vallez, N., Bueno, G., Deniz, O., Dorado, J., Seoane, J. A., Pazos, A. and Pastor, C., 2014, Breast density classification to reduce falsepositives in CADe systems, *Computer Methods and Programs in Biomedicine*, 113, 569-584
- Wang, Z., Bovik, A. C., Sheikh, H. R. and Simoncelli, E. P., 2004, Image quality assessment: from error measurement to structural similarity, *IEEE Transactions on Image Processing*, 13 (4), 600-612.
- Wang, X., Yang, H. and Fu, Z., 2010, A new wavelet-based image denoising using undecimated discrete wavelet transform and least squares support vector machine, *Expert Systems with Applications*, 37 (10), 7040-7049.
- Wong, M. T., He, X., Nguyen, H. and Yeh, W., 2012, Particle swarm optimization based feature selection in mammogram mass classification, *International Conference on Computerized Healthcare*, Hong Kong-China, 152-157.
- Xu, J., Yang, L. and Wu, D., 2010, Ripplet: A new transform for image processing. *Journal of Visual Communication and Image Representation*, 21 (7), 627-639.
- Yang, J., Xu, W., Wang, Y. and Dai, Q., 2008, 2-D anisotropic dual-tree complex wavelet packets and its application to image denoising. *IEEE International Conference on Image Processing*, San Diego-USA, 2328-2331.
- Yaşar, H., Ceylan, M. and Öztürk, A. E., 2013, Comparison of real and complex-valued versions of wavelet transform, curvelet transform and ridgelet transform for medical image denoising, *International Journal of Electronics; Mechanical and Mechatronics Engineering*, 3 (1), 427-436.
- Yaşar, H. ve Ceylan, M., 2014-a, RGB görüntülerin bit değişimi ve ripplet-I dönüşümü tabanlı şifreleme ile filigranlanması, *7. Uluslararası Bilgi Güvenliği ve Kriptoloji Konferansı*, İstanbul-Türkiye, 49-54.
- Yaşar, H. and Ceylan, M., 2014-b, An approach for tissue density classification in mammographic images using artificial neural network based on wavelet and curvelet transforms, *International Conference on Image, Vision and Computing*, Paris-France, IV007.
- Zhai, J. and Zhang, S., 2005, Image denoising via wavelet threshold: single wavelet and multiple wavelets transform, *International Conference on Machine Learning and Cybernetics*, Guangzhou-China, 5, 3232-3236.
- Zhang, L., Zhang, D., Mou, X. and Zhang, D., 2011, FSIM: A feature similarity index for image quality assessment, *IEEE Transactions on Image Processing*, 20 (8), 2378-2386.

EKLER

EK-1 Reel ve Kompleks Değerli Hızlı Ayırık Ripplet-1 Dönüşümü Matlab Yazılımı

```
function C = fdrpt_wrapping(x, is_real, finest, nbscales,
nbangles_coarse, ckc, dkd)

% fdrpt_wrapping.m - Fast Discrete Ripplet-1 Transform via wedge
wrapping
% Inputs
% x          M-by-N matrix
% Optional Inputs
% is_real     Type of the transform
%             0: complex-valued ripplet-1
%             1: real-valued ripplet-1
%             [default set to 0]
% finest      Chooses one of two possibilities for the coefficients
% at the
%             finest level:
%             1: curvelets
%             2: wavelets
%             [default set to 2]
% nbscales    number of scales including the coarsest wavelet level
%
% nbangles_coarse
%             number of angles at the 2nd coarsest level, minimum 8,
%             must be a multiple of 4. [default set to 16]
% ckc support
%             number of support ripplet-1 [default set to 1]
% dkd degree
%             number of degree ripplet-1 [default set to 2]
% Outputs
% C           Cell array of ripplet-1 coefficients.
%             C{j}{l}(k1,k2) is the coefficient at
%             - scale j: integer, from finest to coarsest scale,
%             - angle l: integer, starts at the top-left corner
% and
%             increases clockwise,
%             - position k1,k2: both integers, size varies with
% j
%             and l.
% Not: Bu matlab programı 2004 yılında Laurent Demanet tarafından
% oluşturulan fdct_wrapping.m programının 2014 yılında Hüseyin Yaşar
% tarafından yeniden düzenlenmesi ile hızlı ayırık ripplet-1 dönüşümü
% için uyarlanmış halidir.

X = fftshift(fft2(ifftshift(x)))/sqrt(prod(size(x)));
[N1,N2] = size(X);
if nargin < 2, is_real = 0; end;
if nargin < 3, finest = 2; end;
if nargin < 4, nbscales = ceil(log2(min(N1,N2)) - 3); end;
if nargin < 5, nbangles_coarse = 16; end;
if nargin < 6, ckc = 1; end;
if nargin < 7, dkd = 2; end;
lseed = 1:floor(nbscales)-1;
Levelsss = floor(max(lseed*(1-1/dkd-log2(ckc)),0));
nbangles = [1, nbangles_coarse .* 2.^(Levelsss)];
if finest == 2, nbangles(nbscales) = 1; end;
C = cell(1,nbscales);
```

```

for j = 1:nbscales
    C{j} = cell(1,nbangles(j));
end;
M1 = N1/3;
M2 = N2/3;
if finest == 1,

    bigN1 = 2*floor(2*M1)+1;
    bigN2 = 2*floor(2*M2)+1;
    equiv_index_1 = 1+mod(floor(N1/2)-floor(2*M1)+(1:bigN1)-1,N1);
    equiv_index_2 = 1+mod(floor(N2/2)-floor(2*M2)+(1:bigN2)-1,N2);
    X = X(equiv_index_1,equiv_index_2);
    window_length_1 = floor(2*M1) - floor(M1) - 1 - (mod(N1,3)==0);
    window_length_2 = floor(2*M2) - floor(M2) - 1 - (mod(N2,3)==0);
    coord_1 = 0:(1/window_length_1):1;
    coord_2 = 0:(1/window_length_2):1;
    [wl_1,wr_1] = fdct_wrapping_window(coord_1);
    [wl_2,wr_2] = fdct_wrapping_window(coord_2);
    lowpass_1 = [wl_1, ones(1,2*floor(M1)+1), wr_1];
    if mod(N1,3)==0, lowpass_1 = [0, lowpass_1, 0]; end;
    lowpass_2 = [wl_2, ones(1,2*floor(M2)+1), wr_2];
    if mod(N2,3)==0, lowpass_2 = [0, lowpass_2, 0]; end;
    lowpass = lowpass_1'*lowpass_2;
    Xlow = X .* lowpass;
    scales = nbscales:-1:2;
else

    M1 = M1/2;
    M2 = M2/2;
    window_length_1 = floor(2*M1) - floor(M1) - 1;
    window_length_2 = floor(2*M2) - floor(M2) - 1;
    coord_1 = 0:(1/window_length_1):1;
    coord_2 = 0:(1/window_length_2):1;
    [wl_1,wr_1] = fdct_wrapping_window(coord_1);
    [wl_2,wr_2] = fdct_wrapping_window(coord_2);
    lowpass_1 = [wl_1, ones(1,2*floor(M1)+1), wr_1];
    lowpass_2 = [wl_2, ones(1,2*floor(M2)+1), wr_2];
    lowpass = lowpass_1'*lowpass_2;
    hipass = sqrt(1 - lowpass.^2);
    Xlow_index_1 = ((-floor(2*M1)):floor(2*M1)) + ceil((N1+1)/2);
    Xlow_index_2 = ((-floor(2*M2)):floor(2*M2)) + ceil((N2+1)/2);
    Xlow = X(Xlow_index_1, Xlow_index_2) .* lowpass;
    Xhi = X;
    Xhi(Xlow_index_1, Xlow_index_2) = Xhi(Xlow_index_1, Xlow_index_2)
    .* hipass;
    C{nbscales}{1} =
    fftshift(iff2(iff2shift(Xhi)))*sqrt(prod(size(Xhi)));
    if is_real, C{nbscales}{1} = real(C{nbscales}{1}); end;

    scales = (nbscales-1):-1:2;
end;
for j = scales,

    M1 = M1/2;
    M2 = M2/2;
    window_length_1 = floor(2*M1) - floor(M1) - 1;
    window_length_2 = floor(2*M2) - floor(M2) - 1;
    coord_1 = 0:(1/window_length_1):1;
    coord_2 = 0:(1/window_length_2):1;
    [wl_1,wr_1] = fdct_wrapping_window(coord_1);
    [wl_2,wr_2] = fdct_wrapping_window(coord_2);

```

```

lowpass_1 = [wl_1, ones(1,2*floor(M1)+1), wr_1];
lowpass_2 = [wl_2, ones(1,2*floor(M2)+1), wr_2];
lowpass = lowpass_1'*lowpass_2;
hipass = sqrt(1 - lowpass.^2);
Xhi = Xlow;
Xlow_index_1 = ((-floor(2*M1)):floor(2*M1)) + floor(4*M1) + 1;
Xlow_index_2 = ((-floor(2*M2)):floor(2*M2)) + floor(4*M2) + 1;
Xlow = Xlow(Xlow_index_1, Xlow_index_2);
Xhi(Xlow_index_1, Xlow_index_2) = Xlow .* hipass;
Xlow = Xlow .* lowpass;

l = 0;
nbquadrants = 2 + 2*(~is_real);
nbangles_perquad = nbangles(j)/4;
for quadrant = 1:nbquadrants
    M_horiz = M2 * (mod(quadrant,2)==1) + M1 *
(mod(quadrant,2)==0);
    M_vert = M1 * (mod(quadrant,2)==1) + M2 *
(mod(quadrant,2)==0);
    if mod(nbangles_perquad,2),
        wedge_ticks_left =
round((0:(1/(2*nbangles_perquad)):.5)*2*floor(4*M_horiz) + 1);
        wedge_ticks_right = 2*floor(4*M_horiz) + 2 -
wedge_ticks_left;
        wedge_ticks = [wedge_ticks_left, wedge_ticks_right(end:-
1:1)];
    else
        wedge_ticks_left =
round((0:(1/(2*nbangles_perquad)):.5)*2*floor(4*M_horiz) + 1);
        wedge_ticks_right = 2*floor(4*M_horiz) + 2 -
wedge_ticks_left;
        wedge_ticks = [wedge_ticks_left, wedge_ticks_right((end-
1):-1:1)];
    end;
    wedge_endpoints = wedge_ticks(2:2:(end-1));
    wedge_midpoints = (wedge_endpoints(1:(end-1)) +
wedge_endpoints(2:end))/2;

    l = l+1;
    first_wedge_endpoint_vert =
round(2*floor(4*M_vert)/(2*nbangles_perquad) + 1);
    length_corner_wedge = floor(4*M_vert) - floor(M_vert) +
ceil(first_wedge_endpoint_vert/4);
    Y_corner = 1:length_corner_wedge;
    [XX,YY] = meshgrid(1:(2*floor(4*M_horiz)+1),Y_corner);
    width_wedge = wedge_endpoints(2) + wedge_endpoints(1) - 1;
    slope_wedge = (floor(4*M_horiz) + 1 -
wedge_endpoints(1))/floor(4*M_vert);
    left_line = round(2 - wedge_endpoints(1) +
slope_wedge*(Y_corner - 1));

    [wrapped_data, wrapped_XX, wrapped_YY] =
deal(zeros(length_corner_wedge,width_wedge));
    first_row = floor(4*M_vert)+2-
ceil((length_corner_wedge+1)/2)+...
    mod(length_corner_wedge+1,2)*(quadrant-2 == mod(quadrant-
2,2));
    first_col = floor(4*M_horiz)+2-ceil((width_wedge+1)/2)+...
    mod(width_wedge+1,2)*(quadrant-3 == mod(quadrant-3,2));

    for row = Y_corner

```

```

        cols = left_line(row) + mod((0:(width_wedge-1))-
(left_line(row)-first_col),width_wedge);
        admissible_cols = round(1/2*(cols+1+abs(cols-1)));
        new_row = 1 + mod(row - first_row, length_corner_wedge);
        wrapped_data(new_row,:) = Xhi(row,admissible_cols) .*
(cols > 0);
        wrapped_XX(new_row,:) = XX(row,admissible_cols);
        wrapped_YY(new_row,:) = YY(row,admissible_cols);
    end;
    slope_wedge_right = (floor(4*M_horiz)+1 -
wedge_midpoints(1))/floor(4*M_vert);
    mid_line_right = wedge_midpoints(1) +
slope_wedge_right*(wrapped_YY - 1);

    coord_right = 1/2 + floor(4*M_vert)/(wedge_endpoints(2) -
wedge_endpoints(1)) * ...
        (wrapped_XX - mid_line_right)./(floor(4*M_vert)+1 -
wrapped_YY);
    C2 = 1/(1/(2*(floor(4*M_horiz))/(wedge_endpoints(1) - 1) - 1)
+ 1/(2*(floor(4*M_vert))/(first_wedge_endpoint_vert - 1) - 1));
    C1 = C2 / (2*(floor(4*M_vert))/(first_wedge_endpoint_vert - 1)
- 1);
    wrapped_XX((wrapped_XX - 1)/floor(4*M_horiz) + (wrapped_YY-
1)/floor(4*M_vert) == 2) = ...
        wrapped_XX((wrapped_XX - 1)/floor(4*M_horiz) +
(wrapped_YY-1)/floor(4*M_vert) == 2) + 1;
    coord_corner = C1 + C2 * ((wrapped_XX - 1)/(floor(4*M_horiz))
- (wrapped_YY - 1)/(floor(4*M_vert))) ./ ...
        (2-((wrapped_XX - 1)/(floor(4*M_horiz)) + (wrapped_YY -
1)/(floor(4*M_vert))));
    wl_left = fdct_wrapping_window(coord_corner);
    [wl_right,wr_right] = fdct_wrapping_window(coord_right);
    wrapped_data = wrapped_data .* (wl_left .* wr_right);

    switch is_real
    case 0
        wrapped_data = rot90(wrapped_data,-(quadrant-1));
        C{j}{1} =
fftshift(iff2(iff2shift(wrapped_data)))*sqrt(prod(size(wrapped_data))
);
    case 1
        wrapped_data = rot90(wrapped_data,-(quadrant-1));
        x =
fftshift(iff2(iff2shift(wrapped_data)))*sqrt(prod(size(wrapped_data))
);
        C{j}{1} = sqrt(2)*real(x);
        C{j}{1+nbangles(j)/2} = sqrt(2)*imag(x);
    end;

    length_wedge = floor(4*M_vert) - floor(M_vert);
    Y = 1:length_wedge;
    first_row = floor(4*M_vert)+2-ceil((length_wedge+1)/2)+...
        mod(length_wedge+1,2)*(quadrant-2 == mod(quadrant-2,2));
    for subl = 2:(nbangles_perquad-1);
        l = l+1;
        width_wedge = wedge_endpoints(subl+1) -
wedge_endpoints(subl-1) + 1;
        slope_wedge = ((floor(4*M_horiz)+1) -
wedge_endpoints(subl))/floor(4*M_vert);
        left_line = round(wedge_endpoints(subl-1) + slope_wedge*(Y
- 1));

```

```

        [wrapped_data, wrapped_XX, wrapped_YY] =
deal(zeros(length_wedge,width_wedge));
        first_col = floor(4*M_horiz)+2-ceil((width_wedge+1)/2)+...
        mod(width_wedge+1,2)*(quadrant-3 == mod(quadrant-
3,2));
        for row = Y
            cols = left_line(row) + mod((0:(width_wedge-1))-
(left_line(row)-first_col),width_wedge);
            new_row = 1 + mod(row - first_row, length_wedge);
            wrapped_data(new_row,:) = Xhi(row,cols);
            wrapped_XX(new_row,:) = XX(row,cols);
            wrapped_YY(new_row,:) = YY(row,cols);
        end;
        slope_wedge_left = ((floor(4*M_horiz)+1) -
wedge_midpoints(subl-1))/floor(4*M_vert);
        mid_line_left = wedge_midpoints(subl-1) +
slope_wedge_left*(wrapped_YY - 1);
        coord_left = 1/2 + floor(4*M_vert)/(wedge_endpoints(subl)
- wedge_endpoints(subl-1)) * ...
        (wrapped_XX - mid_line_left)./(floor(4*M_vert)+1 -
wrapped_YY);
        slope_wedge_right = ((floor(4*M_horiz)+1) -
wedge_midpoints(subl))/floor(4*M_vert);
        mid_line_right = wedge_midpoints(subl) +
slope_wedge_right*(wrapped_YY - 1);
        coord_right = 1/2 +
floor(4*M_vert)/(wedge_endpoints(subl+1) - wedge_endpoints(subl)) *
...
        (wrapped_XX - mid_line_right)./(floor(4*M_vert)+1 -
wrapped_YY);
        wl_left = fdct_wrapping_window(coord_left);
        [wl_right,wr_right] = fdct_wrapping_window(coord_right);
        wrapped_data = wrapped_data .* (wl_left .* wr_right);
        switch is_real
            case 0
                wrapped_data = rot90(wrapped_data,-(quadrant-1));
                C{j}{1} =
fftshift(iff2(iff2shift(wrapped_data)))*sqrt(prod(size(wrapped_data)
));
            case 1
                wrapped_data = rot90(wrapped_data,-(quadrant-1));
                x =
fftshift(iff2(iff2shift(wrapped_data)))*sqrt(prod(size(wrapped_data)
));
                C{j}{1} = sqrt(2)*real(x);
                C{j}{1+nbangles(j)/2} = sqrt(2)*imag(x);
        end;
    end;

    l = l+1;
    width_wedge = 4*floor(4*M_horiz) + 3 - wedge_endpoints(end) -
wedge_endpoints(end-1);
    slope_wedge = ((floor(4*M_horiz)+1) -
wedge_endpoints(end))/floor(4*M_vert);
    left_line = round(wedge_endpoints(end-1) +
slope_wedge*(Y_corner - 1));
    [wrapped_data, wrapped_XX, wrapped_YY] =
deal(zeros(length_corner_wedge,width_wedge));
    first_row = floor(4*M_vert)+2-
ceil((length_corner_wedge+1)/2)+...

```

```

        mod(length_corner_wedge+1,2)*(quadrant-2 == mod(quadrant-
2,2));
        first_col = floor(4*M_horiz)+2-ceil((width_wedge+1)/2)+...
        mod(width_wedge+1,2)*(quadrant-3 == mod(quadrant-3,2));
        for row = Y_corner
            cols = left_line(row) + mod((0:(width_wedge-1))-
(left_line(row)-first_col),width_wedge);
            admissible_cols = round(1/2*(cols+2*floor(4*M_horiz)+1-
abs(cols-(2*floor(4*M_horiz)+1))));
            new_row = 1 + mod(row - first_row, length_corner_wedge);
            wrapped_data(new_row,:) = Xhi(row,admissible_cols) .*
(cols <= (2*floor(4*M_horiz)+1));
            wrapped_XX(new_row,:) = XX(row,admissible_cols);
            wrapped_YY(new_row,:) = YY(row,admissible_cols);
        end;
        slope_wedge_left = ((floor(4*M_horiz)+1) -
wedge_midpoints(end))/floor(4*M_vert);
        mid_line_left = wedge_midpoints(end) +
slope_wedge_left*(wrapped_YY - 1);
        coord_left = 1/2 + floor(4*M_vert)/(wedge_endpoints(end) -
wedge_endpoints(end-1)) * ...
        (wrapped_XX - mid_line_left)./(floor(4*M_vert) + 1 -
wrapped_YY);
        C2 = -1/(2*(floor(4*M_horiz))/(wedge_endpoints(end) - 1) - 1 +
1/(2*(floor(4*M_vert))/(first_wedge_endpoint_vert - 1) - 1));
        C1 = -C2 * (2*(floor(4*M_horiz))/(wedge_endpoints(end) - 1) -
1);
        wrapped_XX((wrapped_XX - 1)/floor(4*M_horiz) == (wrapped_YY -
1)/floor(4*M_vert)) = ...
        wrapped_XX((wrapped_XX - 1)/floor(4*M_horiz) ==
(wrapped_YY - 1)/floor(4*M_vert)) - 1;
        coord_corner = C1 + C2 * (2-((wrapped_XX -
1)/(floor(4*M_horiz)) + (wrapped_YY - 1)/(floor(4*M_vert)))) ./ ...
        ((wrapped_XX - 1)/(floor(4*M_horiz)) - (wrapped_YY -
1)/(floor(4*M_vert)));
        wl_left = fdct_wrapping_window(coord_left);
        [wl_right,wr_right] = fdct_wrapping_window(coord_corner);

        wrapped_data = wrapped_data .* (wl_left .* wr_right);
        switch is_real
            case 0
                wrapped_data = rot90(wrapped_data,-(quadrant-1));
                C{j}{1} =
fftshift(iff2(iff2shift(wrapped_data)))*sqrt(prod(size(wrapped_data))
);
            case 1
                wrapped_data = rot90(wrapped_data,-(quadrant-1));
                x =
fftshift(iff2(iff2shift(wrapped_data)))*sqrt(prod(size(wrapped_data))
);
                C{j}{1} = sqrt(2)*real(x);
                C{j}{1+nbangles(j)/2} = sqrt(2)*imag(x);
        end;

        if quadrant < nbquadrants, Xhi = rot90(Xhi); end;
    end;
end;
C{1}{1} = fftshift(iff2(iff2shift(Xlow)))*sqrt(prod(size(Xlow)));
if is_real == 1,
    C{1}{1} = real(C{1}{1});
end;

```

EK-2 Mamografi Görüntülerinden Normal-Anormal Doku Sınıflandırılmasında Kullanılan Ayırık Dalgacık Dönüşümü Matlab Yazılımı

```
function w = dwt2D(x, J, af)

% discrete 2-D wavelet transform
%
% USAGE:
%   w = dwt2D(x, stages, af)
% INPUT:
%   x - N by M matrix
%       1) M, N are both even
%       2) min(M,N) >= 2^(J-1)*length(af)
%   J - number of stages
%   af - analysis filters
% OUTPUT:
%   w - cell array of wavelet coefficients
% EXAMPLE:
%   [af, sf] = farras;
%   x = rand(128,64);
%   J = 3;
%   w = dwt2D(x,J,af);
%   y = idwt2D(w,J,sf);
%   err = x - y;
%   max(max(abs(err)))
%
% WAVELET SOFTWARE AT POLYTECHNIC UNIVERSITY, BROOKLYN, NY
% http://taco.poly.edu/WaveletSoftware/

for k = 1:J
    [x w{k}] = afb2D(x, af, af);
end
w{J+1} = x;
```

EK-3 Mamografi Görüntülerinden Normal-Anormal Doku Sınıflandırılmasında Kullanılan Ridgelet Dönüşümü Matlab Yazılımı

```
% RT = RIDGELET( X, L, md )
%
% Input Parameters:
% X = Input image of square size
% L = No. of scales in the ridgelet transform
% md = if 1, o/p is cell; if 0, o/p is a vector.
%
% Output Parameters:
% RT = Ridgelet transform of X
%
% See also iridgelet
%          fft_iso_dwt          fft_iso_idwt
%          cart_2_rectopolar    rectopolar_2_cart
%
% References:
% [1] J.L. Starck, E.J. Candes, and D.L. Donoho, "The Curvelet
% Transform
% for Image Denoising," IEEE Trans. on Image Proc., Vol 11, No. 6,
% June
% 2002.
%
% Author: Sandeep Palakkal (sandeep.dion@gmail.com)
% Orgn: IIT Madras
% Date: May 1, 2010
% Modified on: May 7, 2010

function rt = ridgelet( x, L, md )

if ~exist( 'md', 'var' )
    md = 0;
end

[l1 l2] = size( x );
if rem( l1,2 ) == 0 && rem( l2,2 ) == 0
    pt1 = l1 + 1; pt2 = l2 + 1;
end

yr = fft2( x, pt1, pt2 );
yp = cart_2_rectopolar( yr );
l = size( yp, 1 );
if md == 0
    rt = fft_iso_dwt( yp(1,:), L, md );
elseif md == 1
    rt = cell(l,1);
    rt{1} = fft_iso_dwt( yp(1,:), L, md );
end
for jj = 2:l
    if md == 0
        rt(jj,:) = fft_iso_dwt( yp(jj,:), L, md );
    elseif md == 1
        rt{jj} = fft_iso_dwt( yp(jj,:), L, md );
    end
end
end
```

EK-4 Mamografi Görüntülerinden Normal-Anormal Doku Sınıflandırılmasında Kullanılan Contourlet Dönüşümü Matlab Yazılımı

```

function y = pdfbdec(x, pfilt, dfilt, nlevs)
% PDFBDEC   Pyramidal Directional Filter Bank (or Contourlet)
Decomposition
%
%   y = pdfbdec(x, pfilt, dfilt, nlevs)
%
% Input:
%   x:       input image
%   pfilt:    filter name for the pyramidal decomposition step
%   dfilt:    filter name for the directional decomposition step
%   nlevs:    vector of numbers of directional filter bank decomposition
levels
%           at each pyramidal level (from coarse to fine scale).
%           If the number of level is 0, a critically sampled 2-D
wavelet
%           decomposition step is performed.
%
% Output:
%   y:       a cell vector of length length(nlevs) + 1, where except
y{1} is
%           the lowpass subband, each cell corresponds to one
pyramidal
%           level and is a cell vector that contains bandpass
directional
%           subbands from the DFB at that level.
%
% Index convention:
%   Suppose that nlevs = [l_J,...,l_2, l_1], and l_j >= 2.
%   Then for j = 1,...,J and k = 1,...,2^l_j
%       y{J+2-j}{k}(n_1, n_2)
%   is a contourlet coefficient at scale 2^j, direction k, and
position
%       (n_1 * 2^(j+l_j-2), n_2 * 2^j) for k <= 2^(l_j-1),
%       (n_1 * 2^j, n_2 * 2^(j+l_j-2)) for k > 2^(l_j-1).
%   As k increases from 1 to 2^l_j, direction k rotates clockwise from
%   the angle 135 degree with uniform increment in cotan, from -1 to 1
for
%   k <= 2^(l_j-1), and then uniform decrement in tan, from 1 to -1
for
%   k > 2^(l_j-1).
%
% See also: PFILTERS, DFILTERS, PDFBREC

if length(nlevs) == 0
    y = {x};

else
    % Get the pyramidal filters from the filter name
    [h, g] = pfilters(pfilt);

    if nlevs(end) ~= 0
        % Laplacian decomposition
        [xlo, xhi] = lpdec(x, h, g);

        % DFB on the bandpass image
        switch dfilt
            % Decide the method based on the filter
name

```

```

        case {'pkva6', 'pkva8', 'pkva12', 'pkva'}
            % Use the ladder structure (whihc is much more
efficient)
            xhi_dir = dfbdec_l(xhi, dfilt, nlevs(end));

        otherwise
            % General case
            xhi_dir = dfbdec(xhi, dfilt, nlevs(end));
        end

    else
        % Special case: nlevs(end) == 0
        % Perform one-level 2-D critically sampled wavelet filter bank
        [xlo, xLH, xHL, xHH] = wfb2dec(x, h, g);
        xhi_dir = {xLH, xHL, xHH};
    end

    % Recursive call on the low band
    ylo = pdfbdec(xlo, pfilt, dfilt, nlevs(1:end-1));

    % Add bandpass directional subbands to the final output
    y = {ylo{:}, xhi_dir};
end

```

EK-5 Mamografi Görüntülerinden Normal-Anormal Doku Sınıflandırılmasında Kullanılan MIAS Veri Tabanı Görüntüleri

	Yağlı			Yağlı- Bezeli			Yoğun		
Anormal	'mdb005'	'mdb010'	'mdb012'	'mdb001'	'mdb002'	'mdb013'	'mdb063'	'mdb099'	'mdb198'
	'mdb025'	'mdb069'	'mdb080'	'mdb017'	'mdb021'	'mdb265'	'mdb199'	'mdb223'	'mdb240'
	'mdb274'	'mdb097'	'mdb132'	'mdb032'	'mdb081'	'mdb083'	'mdb244'	'mdb290'	'mdb163'
	'mdb142'	'mdb150'	'mdb152'	'mdb121'	'mdb127'	'mdb188'	'mdb193'	'mdb111'	'mdb170'
	'mdb160'	'mdb271'	'mdb204'	'mdb191'	'mdb218'	'mdb219'	'mdb171'	'mdb179'	'mdb202'
	'mdb248'	'mdb252'	'mdb312'	'mdb270'	'mdb023'	'mdb072'			
	'mdb314'	'mdb028'	'mdb075'	'mdb090'	'mdb115'	'mdb117'			
	'mdb092'	'mdb095'	'mdb134'	'mdb120'	'mdb124'	'mdb178'			
	'mdb141'	'mdb148'	'mdb155'	'mdb181'	'mdb209'	'mdb264'			
	'mdb158'	'mdb184'	'mdb206'						
	'mdb238'	'mdb267'							
Normal	'mdb006'	'mdb009'	'mdb011'	'mdb007'	'mdb008'	'mdb014'	'mdb003'	'mdb004'	'mdb033'
	'mdb026'	'mdb027'	'mdb060'	'mdb016'	'mdb018'	'mdb020'	'mdb034'	'mdb035'	'mdb036'
	'mdb070'	'mdb076'	'mdb077'	'mdb022'	'mdb024'	'mdb041'	'mdb037'	'mdb038'	'mdb322'
	'mdb078'	'mdb079'	'mdb087'	'mdb042'	'mdb043'	'mdb044'	'mdb040'	'mdb053'	'mdb054'
	'mdb088'	'mdb096'	'mdb098'	'mdb045'	'mdb046'	'mdb047'	'mdb057'	'mdb061'	'mdb062'
	'mdb131'	'mdb133'	'mdb135'	'mdb048'	'mdb049'	'mdb050'	'mdb064'	'mdb065'	'mdb066'
	'mdb136'	'mdb139'	'mdb140'	'mdb051'	'mdb052'	'mdb055'	'mdb067'	'mdb068'	'mdb100'
	'mdb143'	'mdb147'	'mdb149'	'mdb056'	'mdb071'	'mdb073'	'mdb101'	'mdb103'	'mdb106'
	'mdb153'	'mdb154'	'mdb156'	'mdb074'	'mdb082'	'mdb084'	'mdb108'	'mdb109'	'mdb112'
	'mdb159'	'mdb168'	'mdb173'	'mdb085'	'mdb086'	'mdb089'	'mdb129'	'mdb137'	'mdb138'
	'mdb313'	'mdb183'	'mdb196'	'mdb093'	'mdb279'	'mdb113'	'mdb146'	'mdb161'	'mdb162'
	'mdb203'	'mdb205'	'mdb232'	'mdb114'	'mdb116'	'mdb118'	'mdb164'	'mdb166'	'mdb169'
	'mdb247'	'mdb237'	'mdb255'	'mdb119'	'mdb122'	'mdb123'	'mdb172'	'mdb180'	'mdb194'
	'mdb272'	'mdb273'	'mdb293'	'mdb128'	'mdb176'	'mdb177'	'mdb197'	'mdb200'	'mdb201'
	'mdb294'	'mdb297'	'mdb298'	'mdb291'	'mdb185'	'mdb187'	'mdb208'	'mdb215'	'mdb221'
	'mdb299'	'mdb300'	'mdb301'	'mdb189'	'mdb192'	'mdb210'	'mdb224'	'mdb225'	'mdb235'
	'mdb302'	'mdb303'	'mdb304'	'mdb212'	'mdb217'	'mdb220'	'mdb242'	'mdb243'	'mdb250'
	'mdb305'	'mdb306'	'mdb307'	'mdb228'	'mdb234'	'mdb292'	'mdb321'	'mdb257'	'mdb258'
	'mdb308'	'mdb309'	'mdb310'	'mdb266'	'mdb269'	'mdb275'	'mdb259'	'mdb260'	'mdb261'
				'mdb276'	'mdb277'	'mdb278'	'mdb262'	'mdb281'	'mdb282'
							'mdb283'	'mdb284'	'mdb285'
							'mdb286'	'mdb287'	'mdb288'
							'mdb289'	'mdb295'	'mdb296'
							'mdb316'	'mdb317'	'mdb318'
							'mdb319'	'mdb320'	

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Hüseyin YAŞAR
Uyruğu : Türkiye Cumhuriyeti
Doğum Yeri ve Tarihi : Konya-01.02.1987
Telefon : 0 546 440 64 74
Faks :
e-mail : mirhendise@gmail.com

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	Selçuklu Dumlupınar Lisesi	2004
Üniversite	Selçuk Üniversitesi Elk-Elt. Müh. Bölümü	2010
Yüksek Lisans	Selçuk Üniversitesi Elk-Elt. Müh. A.B.D.	2015

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2009	Konya Gençlik Hizmetleri ve Spor İl Müdürlüğü	Bekçi-Bakıcı
2010	Meram EDAŞ	İşletme Mühendisi
2011	28.Mknz P.Tuğ.K. lığı (Barış Gücü)	Bkm. Takım Komutanı
2012	Sağlık Bakanlığı Sağlık Yatırımları Genel Müdürlüğü	Kontrol Mühendisi

UZMANLIK ALANI

Hastane Elektrik-Elektronik Sistemleri, Görüntü İşleme, Medikal Görüntü İşleme, Çoklu Çözünürlük Analizleri

YABANCI DİLLER

İngilizce-Orta Seviye

YAYINLAR

- 1.*Yaşar, H., Ceylan, M. and Öztürk, A. E., 2013, Comparison of real and complex-valued versions of wavelet transform, curvelet transform and ridgelet transform for medical image denoising, 6. *International Image Processing and Wavelet on Real World Applications Conference*, İstanbul-Turkey, Abstract.

- 2.*Yaşar, H., Ceylan, M. and Öztürk, A. E., 2013, Comparison of real and complex-valued versions of wavelet transform, curvelet transform and ridgelet transform for medical image denoising, *International Journal of Electronics; Mechanical and Mechatronics Engineering*, 3 (1), 427-436.
- 3.Ceylan, M. and Yaşar, H., 2013, Blood vessel extraction from retinal images using complex wavelet transform and complex-valued artificial neural network, *International Conference on Telecommunications and Signal Processing* , Rome-Italy, 822-825.
- 4.Yaşar, H. ve Ceylan, M., 2014-a, RGB görüntülerin bit değişimi ve ripplelet-I dönüşümü tabanlı şifreleme ile filigranlanması, *7. Uluslararası Bilgi Güvenliği ve Kriptoloji Konferansı*, İstanbul-Türkiye, 49-54.
- 5.Yaşar, H. and Ceylan, M., 2014-b, An approach for tissue density classification in mammographic images using artificial neural network based on wavelet and curvelet transforms, *International Conference on Image, Vision and Computing*, Paris-France.

* Aynı içeriğe sahip yayınlardır.