



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



YENİDOĞAN YOĞUN BAKIM ÜNİTELERİ
İÇİN TERMAL GÖRÜNTÜ ANALİZİ

Duygu SAVAŞCI

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Temmuz-2019
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Duygu SAVAŐCI tarafından hazırlanan ‘‘Yenidođan Yođun Bakım Üniteleri için Termal Görüntü Analizi’’ adlı tez çalışması 01/07/2019 tarihinde aŐađıdaki jüri tarafından oy birliđi / ~~oy çokluđu~~ ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliđi Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiŐtir.

Jüri Üyeleri

Başkan

Doç. Dr. Hasan Erdiñ KOÇER

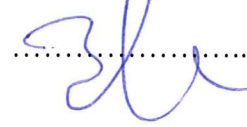
Danışman

Doç. Dr. Murat CEYLAN

Üye

Doç. Dr. Bayram AKDEMİR

İmza



Yukarıdaki sonucu onaylarım.

Prof. Dr. Yakup KARA
Enstitü Müdürü

Bu tez çalışması TÜBİTAK tarafından 215E019 nolu proje ile desteklenmiştir.

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.



Duygu SAVAŞCI

Tarih: 01.07.2019

ÖZET

YÜKSEK LİSANS TEZİ

YENİDOĞAN YOĞUN BAKIM ÜNİTELERİ İÇİN TERMAL GÖRÜNTÜ ANALİZİ

Duygu SAVAŞCI

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

Danışman: Doç. Dr. Murat CEYLAN

2019, 108 Sayfa

Jüri

**Doç. Dr. Hasan Erdiñ KOÇER
Doç. Dr. Bayram AKDEMİR
Doç. Dr. Murat CEYLAN**

Sıcaklık ölçümü günlük yenidoğan bakımı için hayati önem taşımaktadır. Özellikle erken doğan ve çok düşük doğum ağırlığına sahip olan yenidoğanların vücut sıcaklığının sabit tutulması oldukça önemlidir. Dolayısıyla sıcaklığın doğru bir şekilde ölçümü ve sıcaklık değişimlerinin hızlı bir şekilde tespit edilmesi yenidoğan takibi için büyük önem arz etmektedir. Medikal kızılötesi termal görüntüleme teknolojilerinin hızlı gelişimi, sıcaklığın temassız ve doğru bir şekilde ölçülmesine imkân sağlamaktadır. Temassız, iyonize olmayan, non-invazif (cerrahi işlem gerektirmeyen) ve zararsız bir metot olan kızılötesi termal görüntülemenin yenidoğan yoğun bakım ünitesinde kullanılması son zamanlarda önem kazanmıştır.

Kızılötesi termal görüntüleme, vücudun yaydığı kızılötesi enerjiyi yakalayarak, organlardan ve dokulardan yayılan sıcaklık dağılımını ölçmek için kullanılan bir görüntüleme tekniğidir. Termal görüntüleme, fizyolojik fonksiyon bozukluklarının lokalize olduğu yerdeki sıcaklık değişimlerinin saptanabilmesine olanak sağlamaktadır. Vücudun sıcaklık dağılımında ortaya çıkan asimetrielerin anormalliklere işaret etmesi, termal görüntüler kullanılarak bir ön-tanı sisteminin geliştirilebileceği fikrini ortaya çıkarmıştır.

Bu tez çalışması, termal görüntüleme ile yenidoğanlardan alınan termal görüntülerin sağlıklı-hasta olarak sınıflandırılmasına yönelik gerçekleştirilen çalışmaları içermektedir. Bu tezde kullanılan görüntü koleksiyonu, TÜBİTAK tarafından desteklenen 215E019 numaralı proje kapsamında, Selçuk Üniversitesi Tıp Fakültesi Yenidoğan Yoğun Bakım Ünitesinde bulunan yenidoğan bebeklerden alınan termal görüntüler (vücut sıcaklık haritası görüntüleri) ile oluşturulmuştur. İlk olarak, termal görüntülerde bebeğin vücut bölgesi dışında kalan arka planı (sınıflandırma sonucunu olumsuz etkileyebilecek) çıkarmak için görüntüleme segmentasyon işlemi uygulanmıştır. İkinci olarak, segmente edilmiş görüntüleme çoklu çözünürlük analizi yöntemleri uygulanarak özellik vektörleri elde edilmiştir. Tezde kullanılan çoklu çözünürlük analizi yöntemleri; Ayrık Dalgacık Dönüşümü (ADD), Ayrık Ridgelet Dönüşümü (ARiD), Curvelet Dönüşümü (CuD) ve Contourlet Dönüşümü (CoD)'dür. Son olarak, elde edilen özellik vektörleri YSA kullanılarak sağlıklı-hasta olarak sınıflandırılmıştır. İlk kez bu tez çalışması ile çoklu çözünürlük analizi yöntemlerinin yenidoğan bebeklerin termal görüntülerinin sağlıklı-hasta olarak sınıflandırılmasındaki performansları değerlendirilmiştir. Elde edilen sonuçlar karşılaştırmalı olarak sunulmuştur.

Tez çalışmasının ilk aşamasında, 19 sağlıklı ve 19 hasta yenidoğana ait 190 termal görüntünün sıcaklık haritaları kullanılarak sınıflandırılması işlemi gerçekleştirilmiştir. Segmente edilmiş 190 termal görüntüye çoklu çözünürlük analizi yöntemleri (ADD, ARiD, CuD ve CoD) uygulanarak özellik vektörleri çıkarılmış ve bu özellik vektörleri YSA kullanılarak sağlıklı-hasta olarak sınıflandırılmıştır. En yüksek sınıflandırma başarısı %100 ile ADD, en yüksek hassasiyet oranı %100 ile ADD, ARiD ve CuD, en yüksek özgüllük oranı ise %100 ile ADD kullanılarak elde edilmiştir. Daha sonra, özellik vektörlerinin boyutlarının azaltılabilmesi için çoklu çözünürlük analizi yöntemlerinin uygulanması sonucu elde edilen yaklaşım katsayılarından istatistiki özellikler (ortalama, standart sapma, varyans, çarpıklık katsayısı (skewness), basıklık katsayısı (kurtosis) ve moment) çıkarılarak YSA ile sınıflandırma işlemi gerçekleştirilmiştir. Bu sınıflandırmada termal görüntüler; ADD ile %74.74, ARiD ile %72.11, CuD ile %68.42, CoD ile %71.58 doğrulukla sınıflandırılmıştır. En yüksek hassasiyet oranı %81.05 ile ARiD, en yüksek özgüllük oranı ise %86.32 ile ADD kullanılarak elde edilmiştir.

Tez çalışmasının ikinci aşamasında ise yenidoğan bakım ünitesinde kalp hastalığı (AORT Koarktasyon, Pulmoner atreti) teşhisi konulmuş 14 hasta ve 29 sağlıklı prematüre (PRM) bebeğin RGB (kırmızı-yeşil-mavi) renk uzayına sahip termal görüntüleri kullanılmıştır. ADD, ARiD, CuD ve CoD uygulanarak özellik vektörleri çıkarılmış ve bu özellik vektörlerinin YSA kullanılarak sağlıklı-hasta olarak sınıflandırılması gerçekleştirilmiştir. Sınıflandırma sonucunda; ADD ile %81.40, ARiD ile %74.42, CuD ile %72.09 ve CoD ile %74.42 başarı sağlanmıştır. En yüksek hassasiyet oranı %57.14 ile CuD, en yüksek özgüllük oranı ise %100 ile ADD kullanılarak elde edilmiştir. Çıkan sınıflandırma sonuçlarına göre kullanılan termal görüntülerin sayısının yetersiz olduğu düşünülmüş ve bu nedenle ikinci bir sınıflandırma işlemi gerçekleştirilmiştir. Bu sınıflandırma işleminde ilk olarak, termal görüntülerin sayısının sentetik olarak artırılması için veri artırma yöntemi kullanılmıştır. 43 termal görüntü üzerinde veri artırma yöntemi uygulanarak her bir görüntüden 5 farklı görüntü daha elde edilmiştir. Böylece görüntü koleksiyonu 43 termal görüntüden 258 termal görüntüye artırılmıştır. Gerçekleştirilen sınıflandırma işleminde termal görüntüler; ADD ile %90.7, ARiD ile %90.7, CuD ile %91.09, CoD ile %91.09 doğrulukla sınıflandırılmıştır. En yüksek hassasiyet oranı %86.91 ile ADD, en yüksek özgüllük oranı ise %94.25 ile CuD kullanılarak elde edilmiştir. Sonuç olarak veri artırma yöntemi uygulanarak gerçekleştirilen sınıflandırmada daha yüksek doğruluk, hassasiyet ve özgüllük oranlarına ulaşılabildiği görülmüştür.

Anahtar Kelimeler: Çoklu Çözünürlük Analizi, Kızılötesi Termal Görüntüleme, Yapay Sinir Ağı, Yenidoğan.

ABSTRACT

MS THESIS

THERMAL IMAGE ANALYSIS FOR NEONATAL INTENSIVE CARE UNITS

Duygu SAVAŞCI

**Konya Technical University
Institute of Graduate Studies
Department of Electrical-Electronic Engineering**

Advisor: Assoc. Prof. Dr. Murat CEYLAN

2019, 108 Pages

Jury

**Assoc. Prof. Dr. Hasan Erdinç KOÇER
Assoc. Prof. Dr. Bayram AKDEMİR
Assoc. Prof. Dr. Murat CEYLAN**

Measuring temperature has crucial importance for neonatal care. Especially keeping the body temperature of neonates who are premature and have low birth-weight constant is vital. Therefore, measuring the temperature correctly and detecting temperature changes quickly are quite important. Fast developments in medical infrared thermal imaging provided us with measuring temperature contactless and correctly. Using the infrared thermal imaging which is contactless, non-ionized, non-invasive, and harmless in neonatal intensive care units has gained importance recently.

The medical thermal imaging is an imaging technique which is used to measure temperature distribution emitted by organs and tissues by catching infrared energy of the body. Thermal imaging can detect temperature changes which occurs at a body region where there are physiological dysfunctions. The detection of anomalies by the aid of the asymmetries observed at body temperature distribution revealed the idea of pre-diagnosing system installation by using thermal images.

This thesis covers studies conducted to classify thermal images of neonates as a healthy or unhealthy. The thermal images (body temperature map images) used in this thesis were captured from the neonates in the Neonatal Intensive Care Unit of Selcuk University Faculty of Medicine within the scope of the project numbered 215E019 supported by TUBITAK. Firstly, the images were segmented to remove the background from the neonates' body region to avoid the effect of background on classification result. Secondly, multiresolution analysis methods were applied to segmented images to obtain feature vectors. Multiresolution analysis methods used in the thesis are Discrete Wavelet Transform (DWT), Discrete Ridgelet Transform (DRiT), Curvelet Transform (CuT), and Contourlet Transform (CoT). Finally, the obtained feature vectors were classified as healthy or unhealthy by using ANN. To the best of our knowledge, performance evaluation of multiresolution analysis methods used to classify thermal images of neonates as a healthy or unhealthy was carried out in this thesis for the first time. The evaluation results were presented comparatively.

In the first stage of the thesis, the temperature map of 190 thermal images belonging to 19 unhealthy and 19 healthy neonates was classified. In the first implementation, multiresolution analysis methods (DWT, DRiT, CuT and CoT) were applied to the segmented 190 thermal images to extract the feature vectors. Then, these feature vectors were classified as healthy or unhealthy by using ANN. In the considered this implementation, the following statistical results were observed: the highest classification success (100%) with DWT, the best sensitivity rate (100%) was with DWT, DRiT, and CuT and the best

specificity rate (100%) with DWT. In the second implementation, some statistical features (mean, standard deviation, variance, skewness, kurtosis, and moment) from approximation coefficients obtained by applying multiresolution analysis methods were extracted in order to reduce the dimension of feature vectors. After that, these statistical features were classified by using ANN. In this implementation, classification success for DWT, DRiT, CuT, and CoT was 74.74%, 72.11%, 68.42%, and 71.58%, respectively. The highest sensitivity rate (81.05%) was achieved with DRiT, while the highest specificity rate (86.32%) was reached with DWT.

In the second stage of the thesis study, RGB color space conversion of thermal images belonging to 29 healthy premature (PRM) infants and 14 neonates who were diagnosed as heart disease (Aortic Coarctation, pulmonary artery) in the neonatal care unit were used. The feature vectors were extracted by using DWT, DRiT, CoT, and CuT. Then, these feature vectors were classified as healthy or unhealthy by using ANN. In this implementation, accuracy of classification for DWT, DRiT, CuT, and CoT was 81.4%, 74.42%, 72.09%, and 74.42%, respectively. The highest sensitivity rate (57.14%) was achieved with CuT, while the highest specificity rate (100%) was reached with DWT. Based on these results, it was thought that the number of thermal images used in the study was insufficient. As a result, a second implementation was performed. In this implementation, firstly the data augmentation method was used to increase the number of thermal images artificially. The data augmentation method was performed on 43 images which were used in the previous implementation in order to create further 5 different images from each image. Thus, the number of thermal images was increased from 43 to 258. In the second implementation, accuracy of classification for DWT, DRiT, CuT, and CoT was 90.7%, 90.7%, 91.09%, and 91.09%, respectively. The highest sensitivity rate (86.91%) was achieved with DWT, whereas the highest specificity rate (94.25%) was reached with CuT. The results of the second implementation show how the higher accuracy, sensitivity and specificity rates were achieved by using the data augmentation method.

Keywords: Multiresolution Analysis, Infrared Thermal Imaging, Artificial Neural Network, Neonatal.

ÖNSÖZ

Tüm çalışmalarında değerli bilgi ve tecrübeleriyle bana yol gösteren, gerekli araştırma ve geliştirme çabalarında yardımlarını esirgemeyen, danışmanım Doç. Dr. Murat CEYLAN' a, Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Elektrik Elektronik Mühendisliği öğretim üyelerine, Selçuk Üniversitesi Yenidoğan Bakım Ünitesinde bulunan bebeklerin termal görüntülerinin alınması aşamasında yardımcı olan Hanifi SOYLU ve ekibine, projemize destek veren TÜBİTAK' a, her türlü maddi manevi katkılarını esirgemeyen sevgili eşim Mehmet SAVAŞCI' ya ve aileme teşekkür ederim.

Duygu SAVAŞCI
KONYA-2019

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. MATERYAL VE YÖNTEM	12
2.1. Kızılötesi Termal Görüntüleme.....	12
2.2. Termal Görüntülerin Elde Edilmesi	16
2.2.1. Termal görüntü yaklaşımları	17
2.3. Çoklu Çözünürlük Analizi Yöntemleri	19
2.3.1. Dalgacık dönüşümü.....	19
2.3.2. Ridgelet dönüşümü.....	23
2.3.3. Curvelet dönüşümü.....	26
2.3.4. Contourlet dönüşümü	35
2.4. İstatistiki Özellik Çıkarma Yöntemleri	36
2.5. Yapay Sinir Ağı	37
2.5.1. Çok katmanlı yapay sinir ağı.....	39
2.6. Performans Değerlendirme Yöntemleri	42
2.6.1. Doğruluk, hassasiyet ve özgüllük	43
2.6.2. k kat çapraz geçerlilik yöntemi.....	44
3. SINIFLANDIRMA SONUÇLARI	46
3.1. Bebeklerin Sağlıklı-Hasta Olarak Belirlenmesi	46
3.1.1. Uygulamada kullanılan görüntüler	47
3.1.2. Sıcaklık haritası çıkarılmış termal görüntülerin segmentasyonu	49
3.1.3. Termal görüntülerin çoklu çözünürlük analizi yöntemleri ile sınıflandırılması	52
3.2. Kalp Hastalığı Olan Bebeklerin Belirlenmesi	57
3.2.1. Uygulamada kullanılan görüntüler	58
3.2.2. RGB termal görüntülerin segmentasyonu	59
3.2.3. Kalp hastalığı olan bebeklerin termal görüntülerinin sınıflandırılması	60
3.2.4. Veri artırma yöntemi uygulanması sonucu elde edilen termal görüntülerin sınıflandırılması	63
4. TARTIŞMA VE ÖNERİLER	66
4.1. Tartışma	66
4.1.1. Bebeklerin sağlıklı-hasta olarak belirlenmesi.....	66
4.1.2. Kalp hastalığı olan bebeklerin belirlenmesi	69
4.2. Öneriler	72
KAYNAKLAR	73
EKLER	80



SİMGELER VE KISALTMALAR

Simgeler

$M(\lambda, T)$: Radyasyon gücü
$P(\lambda, T)$: Yayılan foton sayısı
c	: Işık hızı
h	: Plank sabiti
k	: Boltzman sabiti
T	: Mutlak sıcaklık
λ	: Dalga boyu
ε	: Cismin yayıcılığı- emisyon (emissivity)
$SDD(a, b)$: Sürekli Dalgacık dönüşümü
a	: Dalgacık Dönüşümü Ölçek Faktörü
b	: Dalgacık Dönüşümü Kayma Operatörü
$\Psi(t)$: Ana dalgacık fonksiyonu
*	: Kompleks eşlenik
C_{Ψ}	: Kabul edilebilirlik sabiti
$\Psi(w)$: Ana dalgacık fonksiyonun Fourier Dönüşümü
k	: Örnek sayısı
j	: Seviye
h	: Bir boyutlu alçak geçiren filtre
g	: Bir boyutlu yüksek geçiren filtre
\mathbb{R}	: Reel sayı
Z	: Tam Sayı
$\psi_{a,b,\theta}(\cdot)$: Ridgelet fonksiyonu
$RiD_f(a, b, \theta)$: Sürekli Ridgelet Dönüşümü katsayıları
θ	: Ridgelet Dönüşümü açılı/yön parametresi
δ	: Dirac dağılımı
$R_f(\theta, t)$: Radon Dönüşümü katsayıları
$W(r)$: 2NCuD radyal pencere fonksiyonunu
$V(t)$: 2NCuD açılal pencere fonksiyonunu
j	: 2NCuD ölçek parametresi
k	: 2NCuD öteleme parametresi
l	: 2NCuD rotasyon parametresi
U_j	: 2NCuD kutupsal dilim filtresi
φ_j	: 2NCuD için ana curvelet fonksiyonu
$x_k^{j,\ell}$: 2NCuD konum operatörü
θ_ℓ	: 2NCuD yön/açı operatörü
R_{θ_ℓ}	: 2NCuD rotasyon matrisi
$c(j, \ell, k)$: 2NCuD katsayısı
$\varphi_{j_0k}(\cdot)$: Kaba ölçekli curvelet fonksiyonu
$H_j(\cdot)$: Alçak geçiren pencere fonksiyonu
$\hat{w}_j(\cdot)$: Kartezyen düzlem için radyal pencere fonksiyonu
$\hat{v}_{j,\ell}(\cdot)$: Kartezyen düzlem için açılal pencere fonksiyonu
$\hat{u}_{j,\ell}$: Frekans uzayı dilim filtreleri

S_{θ_ℓ}	: Dilimleme (shear) matrisi
$\hat{\varphi}_j$: Kartezyen curvelet fonksiyonu
$\hat{\varphi}_j^D$: Kartezyen curvelet fonksiyonun uzamsal gösterimi
$\hat{\varphi}_{j,\ell,k}^D$: Ayrık Curvelet Dönüşümü katsayıları
m	: Curvelet Dönüşümü konum parametresi
x_i	: Yapay sinir ağı nöron giriş değeri
w_{ji}	: j ile i nöron arasındaki ağırlık katsayısı
y	: Yapay sinir ağı nöron çıkış değeri
φ	: Aktivasyon fonksiyonu
φ_j	: j nöronun aktivasyon fonksiyonu
d_j	: j nöron için ağırlık üretmesi beklenen hedef değer
y_j	: j nöronun çıktısı değeri
e_j	: j nöron için hata değeri
δ_j	: j nöronu için yerel eğim değeri
δ_k	: k nöronu için yerel eğim değeri
φ_k	: k nöronun aktivasyon fonksiyonu
d_k	: k nöron için ağırlık üretmesi beklenen hedef değer
e_k	: k nöron için hata değeri
y_k	: k nöronun çıktısı değeri
η	: Öğrenme oranı
Δw_{ji}	: Ağırlık matrisindeki değişim miktarı
α	: Momentum sabiti

Kısaltmalar

1B	: Bir Boyutlu
2B	: İki Boyutlu
1NCuD	: Birinci Nesil Curvelet Dönüşümü
2NCuD	: İkinci Nesil Curvelet Dönüşümü
ADD	: Ayrık Dalgacık Dönüşümü
ARiD	: Ayrık Ridgelet Dönüşümü
BP	: Geriye Yayılım Algoritması (Backpropagation)
BT	: Bilgisayarlı Tomografi (Computed Tomography)
CLAHE	: Kontrast Sınırlı Adaptif Histogram Eşitleme
CoD	: Contourlet Dönüşümü
CuD	: Curvelet Dönüşümü
ÇÇA	: Çoklu Çözünürlük Analizi
DD	: Dalgacık Dönüşümü
DIN	: Alman Standartlaştırma Enstitüsü (Deutsches Institut Für Normung)
DN	: Doğru negatif
DP	: Doğru pozitif
EKG	: Elektrokardiyografi
FIR	: Uzak Kızılötesi (Far-Infrared)
HFD	: Hızlı Fourier Dönüşümü
HH	: Dalgacık dönüşümü katsayılarının köşegen detay bileşenleri
HL	: Dalgacık dönüşümü katsayılarının yatay yöndeki detay bileşenleri
IR	: Kızılötesi (Infrared)
k-NN	: K-En yakın komşu algoritması (k-nearest neighbors algorithm)
LBP	: Yerel İkili Desen (Local Binary Pattern)
LDA	: Doğrusal Ayırma Analizi (Linear Discriminant Analysis)
LH	: Dalgacık dönüşümü katsayılarının dikey yöndeki detay bileşenleri
LL	: Dalgacık dönüşümü katsayılarının yaklaşım bileşenleri
LP	: Laplas Pramidı
LWIR	: Uzun Dalga Kızılötesi (Long Wave Infrared)
MRG	: Manyetik Rezonans Görüntüleme
MWIR	: Orta Dalga Kızılötesi (Medium Wave Infrared)

NEC	: Necrotizan Enterokolit
NIR	: Yakın Kızılötesi (Near-Infrared)
RGB	: Kırmızı-Yeşil-Mavi (KYM) Renk Uzayı
PRM	: Prematüre
PYFB	: Piramidal Yönel Filtre Bankası
RiD	: Ridgelet Dönüşümü
ROI	: İlgi Alanı (Region of Interest)
SDD	: Sürekli Dalgacık Dönüşümü
SVM	: Destek Vektör Makinesi (Support Vector Machine)
SWIR	: Kısa Dalga Kızılötesi (Short Wave Infrared)
TÜBİTAK	: Türkiye Bilimsel ve Teknolojik Araştırma Kurumu
UV	: Morötesi Dalga (Ultraviyole)
YFK	: Yönel Filtre Kümesi
YN	: Yanlış negatif
YP	: Yanlış pozitif
YSA	: Yapay Sinir Ağı

1. GİRİŞ

Yaşamsal parametrelerin izlenmesi günlük yenidoğan bakımı için önemlidir. Yaşamsal parametreler, vücuttan ölçülen vücut sıcaklığı, kalp atış hızı, solunum hızı, kan basıncı ve benzeri fiziksel büyüklüklerdir. Bir yenidoğanın farklı sağlık durumları belirli ölçüm şekilleriyle ilişkilendirilebilmektedir. Örneğin; vücut sıcaklığı, solunum hızı, kan basıncı gibi ölçümler göz önüne alınarak yenidoğanın fizyolojik sistemlerinin normal çalışıp çalışmadıkları veya bazı patolojilere sahip olup olmadığı hakkında çıkarımlar yapılabilmektedir (Quinn, 2007).

Sıcaklık ölçümü günlük yenidoğan bakımı için hayati bir önem taşımaktadır. Erken doğan veya çok düşük doğum ağırlığına sahip olan yenidoğanın vücut sıcaklığının sabit tutulması oldukça önemlidir. Dolayısıyla sıcaklığın doğru bir şekilde ölçümü ve sıcaklık değişimlerinin hızlı bir şekilde tespit edilmesi yenidoğan takibi için kritik noktalar arasındadır. Medikal kızılötesi termal görüntüleme teknolojilerinin hızlı gelişimi, sıcaklığın temassız ve doğru bir şekilde ölçülmesine imkân sağlamaktadır. Non-invazif, iyonize olmayan, hızlı ve güvenilir bir metot olan kızılötesi termal görüntülemenin yenidoğan yoğun bakım ünitesinde kullanılması son zamanlarda önem kazanmıştır. Vücudun sıcaklık dağılımında ortaya çıkan asimetrielerin anormalliklere işaret etmesi, termal görüntüler kullanılarak bir ön-tanı sisteminin tasarlanabileceği fikrini ortaya çıkarmıştır.

Tez çalışması dört ana bölümden oluşmaktadır. Birinci bölümde, tez konusunun tanıtımı yapılmış, tezin amacı ve önemi açıklanmıştır. Ayrıca, bu alanda yapılmış çalışmaların tarihsel gelişimine de yer verilmiştir. İkinci bölümde, tezde kullanılan materyal ve yöntemler detaylı olarak sunulmuştur. Bu kapsamda kızılötesi termal görüntüleme yöntemi anlatılmış, çoklu çözünürlük analiz yöntemlerinden olan Dalgacık Dönüşümü, Ridgelet Dönüşümü, Curvelet Dönüşümü ve Contourlet Dönüşümü üzerinde durulmuştur. Son olarak da Yapay Sinir Ağı' na değinilmiştir. Üçüncü bölümde, tezde kullanılan görüntüler ile ilgili bilgiler verilmiştir. Ayrıca bu bölümde, bebeklerin sağlıklı-hasta olarak belirlenmesi için gerçekleştirilen uygulamalar sunulmuş ve elde edilen sonuçlar değerlendirilmiştir. Dördüncü bölümde, uygulamaların sonuçları irdelenmiş ve tartışılmıştır. Gelecek çalışmalar için önerilerde bulunulmuştur.

1.1. Tez Konusunun Tanıtılması

Bu tez çalışmasında yenidoğan bebeklerin termal görüntülerinin çoklu çözünürlük analiz yöntemleri ile sınıflandırma performansı değerlendirilmiştir. Önerilen ön-tanı sisteminin elde ettiği sonuçların genelleştirilebilmesi için, uzman doktorlar tarafından teşhis konmuş (sağlıklı veya hasta etiketli) bebeklerden alınan termal görüntülerin analiz edilmesiyle ortaya çıkan sonuçlar ile etiket değerleri karşılaştırılmış ve analiz yöntemlerinin başarıları reel olarak değerlendirilmiştir.

Gerçekleştirilen tez çalışmasının ilk aşamasında; 19 sağlıklı ve 19 hasta yenidoğan bebekten alınan termal görüntünün sıcaklık haritaları kullanılarak sağlıklı-hasta teşhisine yönelik sınıflandırma çalışması gerçekleştirilmiştir. Termal görüntülerin sınıflandırılması iki farklı uygulama ile gerçekleştirilmiştir. Birinci uygulamada, segmente edilmiş 190 termal görüntüden çoklu çözünürlük analizi yöntemleri (ADD, ARiD, CuD ve CoD) uygulanarak özellik vektörleri çıkarılmıştır. Bu özellik vektörleri farklı YSA modelleri kullanılarak sınıflandırılmıştır. İkinci uygulamada, çoklu çözünürlük analizi yöntemlerinden elde edilen yaklaşım katsayılarının istatistiki özellikleri (ortalama, standart sapma, varyans, skewness, kurtosis ve moment) çıkarılarak farklı YSA modelleri ile sınıflandırma işlemi gerçekleştirilmiştir. Elde edilen sınıflandırma sonuçlarının performansları değerlendirilmiş ve kıyaslanmıştır.

Tez çalışmasının ikinci aşamasında gerçekleştirilen sınıflandırma çalışmasında, yenidoğan bakım ünitesinde kalp hastalığı (AORT Koarktasyon, Pulmoner atreti) teşhisi konmuş 14 hasta ve sağlıklı 29 PRM bebeğin RGB termal görüntüleri kullanılmıştır. Termal görüntülerin sınıflandırılması iki farklı uygulama ile gerçekleştirilmiştir. Birinci uygulamada, çoklu çözünürlük analizi yöntemleri kullanılarak özellik vektörleri çıkarılmış ve bu özellik vektörleri farklı YSA modelleri kullanılarak sağlıklı-hasta olarak sınıflandırılmıştır. Elde edilen sınıflandırma sonuçlarının performansları değerlendirilmiş ve kıyaslanmıştır. Sınıflandırma sonuçları değerlendirildiğinde kullanılan termal görüntülerin sayısının yetersiz olduğu düşünülmüş ve ikinci bir uygulama gerçekleştirilmiştir. Bu uygulamada, termal görüntülerin sayısının sentetik olarak artırılması için veri artırma yöntemi kullanılmıştır. Önceki uygulamada kullanılan 43 görüntü üzerinde veri artırma yöntemi uygulanarak her bir görüntüden 5 farklı görüntü daha elde edilmiştir. Toplamda 258 termal görüntü incelenmiştir. 258 termal görüntüden çoklu çözünürlük analizi yöntemleri ile özellik vektörleri çıkarılmış ve bu özellik vektörleri farklı YSA modelleri ile sınıflandırılarak performansları değerlendirilmiştir.

1.2. Tez Çalışmasının Önemi ve Amacı

Termal görüntüleme yenidoğan yoğun bakım üniteleri için oldukça önemli bir görüntüleme tekniğidir. Bunun sebebi temassız, iyonize olmayan, non-invazif ve zararsız bir metodun yoğun bakımda yer alan bebeklerin sürekli takibi için uygun olmasıdır. Termal görüntüleme bebekteki fizyolojik bozuklukları ve patolojik değişimleri tespit etmek için kullanılan bir görüntüleme tekniğidir. Bebeğin herhangi bir radyasyona maruz bırakılmaksızın hastalıkların lokalize olduğu yerdeki sıcaklık değişimlerinin saptanabilmesine olanak sağlar.

Cilt yüzey sıcaklığı, dokular arası ısı transferine ve kan akışına bağlıdır. Hastalıklar kan akışında değişikliklere neden olduğundan cilt yüzeyinde termal değişimler meydana gelmektedir. Dolayısıyla hastalıkların ön-teşhisinde ya da teşhis sonrası tedavi takibinin değerlendirilmesinde “termal asimetrimin” veya “zamana bağlı olarak ortaya çıkan termal farklılıkların” izlenmesinin önemi oldukça büyüktür. Bu durum göz önüne alınarak gerçekleştirilen tezin amacı; temassız, non-invazif ve iyonize olmayan kızılötesi termal görüntülemeyi temel alan bir ön tanı sistemi oluşturmaktır.

Yenidoğan bebeklerin farklı çevresel etkiler altında vücut sıcaklıklarının takip edilebilmesi ve sıcaklık profillerinin çıkartılabilmesi için kızılötesi termal görüntülemenin oldukça kullanışlı ve kolay uygulanabilen bir yöntem olduğu literatürde vurgulanmıştır. Yenidoğan yoğun bakım üniteleri için geliştirilen termal görüntüleme tabanlı uygulamalar mevcut olsa da bu sistemlerin yüksek mortalite oranına sahip hastalıkların erken teşhisine ya da ortaya çıkan hastalık bulgularının takibine yönelik kullanımı Nekrotizan Enterokolit (NEC) hastalığı haricinde yoktur. NEC, yenidoğanlarda sık görülen bir gastrointestinal sistem hastalığıdır.

Yenidoğan yoğun bakım ünitesinde bulunan bebeklerin yaşamsal parametrelerinin (solunum hızı, vücut sıcaklığı vs.) onlara herhangi bir rahatsızlık vermeden veya cildinde tahrişe sebep olmadan sürekli olarak izlenmesi gerekmektedir. Bu parametrelerin izlenip değerlendirilmesi; acil müdahale ihtiyacı, yeni tedavi planlaması veya stabil durumun korunması gibi hayati kararların alınmasını sağlamaktadır. Bu parametrelerin ölçümü genelde bebeğin vücuduna fiziksel temaslı ve rahatsızlık veren sensörlerden alınan bilgi akışı ile sağlanmaktadır. Bu sistemlerden elde edilen klinik bilgiler ise sınırlıdır. Örneğin, fiziksel temaslı sensörlerin bebekle bağlantısı kesildiğinde okunan değerler sıfıra düşme eğiliminde olmaktadır. Teşhis amaçlı olarak yenidoğan bebeklerde Bilgisayarlı Tomografi (BT) ve Manyetik Rezonans Görüntüleme

(MRG) sıkça kullanılmaktadır. Fiziksel olarak dezavantajlı bebeklerin sık sık radyoloji bölümüne götürülmesi, dakikalarca süren çekimler ve sonrasında bu bebeklerin vücut sıcaklıklarında yaşanabilecek düşüşler onların hipotermiye girmelerine neden olabilmektedir. Solunum destek cihazına bağlı bebeklerin radyoloji bölümüne götürülmesi ise çok daha zor olabilmektedir. Ayrıca, bebekler bilgisayarlı tomografinin kullanımı sırasında radyasyona maruz kalmaktadırlar. Bu durumlar göz önüne alındığında, kızılötesi termal görüntüleme ile yenidoğan yoğun bakımında bulunan bebeklerin herhangi bir radyasyona maruz bırakılmadan ve cerrahi işlem uygulanmadan bebeklerin hastalıklarının erken tespiti, teşhisi ve tedavi sürecinin izlenmesi mümkün olabilmektedir. Ayrıca, fiziksel temaslı sensörlü sistemlerin termal hassasiyeti 0.5°C iken termal görüntüleme ile hassasiyet 0.05°C ' ye artırılmıştır. Bu sayede çok küçük sıcaklık farklarının dahi algılanabilmesi sağlanmıştır.

1.3. Tez Konusunda Yapılan Çalışmaların Tarihsel Gelişimi

Kızılötesi radyasyon kavramı, astronom Frederick William Herschel tarafından 1800 yılında ortaya atılmıştır. F. William Herschel, Newton' un güneş ışınlarının bir prizma ile ayrı renk bileşenlerine ayrılması ilkesini kullanarak bir üçgen prizma ile güneşten gelen ışığı kırmış ve tayfin içinde kırmızının altında bulunan kızılötesi ışınımı bir termometre sayesinde tespit etmiştir. Daha sonra John Herschel, evaporograph tekniğini kullanıp güneş ışığından ilk termal görüntüyü elde etmiştir. Bu görüntüyü tanımlamak için termogram ismini kullanmıştır. Bu tanımlama günümüzde de yaygın olarak kullanılmaktadır (Ring, 2004).

İlk kızılötesi görüntüleme sistemleri 1940' lı yıllarda kullanılmaya başlanmıştır. 1960 ve 1970' li yıllar boyunca da Amerika, Avrupa ve Japonya kızılötesi görüntüleme sistemlerini daha da geliştirmiştir ve bu sistemler yaygın bir şekilde kullanılmaya başlanmıştır (Ring, 2004).

Kızılötesi görüntülemenin ilk tanısal kullanımı, 1956' da Lawson' nın kadınlarda meme kanseri hastalarının göğüslerinin termal görüntülerini, damarlanma ve asimetric sıcak noktalar açısından incelemesi ile başlamıştır. Bu çalışmada, memedeki kanserli bir dokudaki cilt sıcaklığının normal dokununkinden daha yüksek olduğu görülmüştür. 1960' larda kızılötesi görüntülemenin medikal uygulamaları ağırlıklı olarak meme kanseri teşhisi üzerine yapılmıştır. Örneğin, Lloyd-Williams ve Handley (1961), Handley (1962), Lawson ve Chughtai (1963), Gershen-Cohen ve ark. (1965) ve Haberman (1968) termal

görüntüleme ile meme kanserinin teşhisi üzerine çeşitli araştırmalar yapmışlardır. Termal görüntülemenin kullanımına yönelik meme kanseri teşhisi dışında ayrıca periferik dolaşım bozuklukları (Winsor ve Bendezu, 1964) ve vasküler hastalıklar (Skversky ve ark., 1964), ortopedi (Albert ve ark., 1964), travma (Connel ve ark., 1964), romatizmal eklem iltihabı (Boas, 1964), göğüs hastalıkları (Lane, 1964), diyabetik nöropati veya vasküler bozukluklar (Sandrow ve ark., 1972), Raynaud fenomeni (Ring ve Bacon, 1977), cilt hastalıkları (Hartmann ve ark., 1981) ve yanık yaraları (Cole ve ark., 1990; Liddington ve Shakespeare, 1996), diş hekimliği (Soffin ve ark., 1983; Gratt ve ark., 1989) ve çene eklem patolojisi (Steed, 1991), carpal tünel sendromu (Herrick, 1987), tiroit hastalıkları (Shatsova ve Popov, 1989; Chan ve ark., 1995) gibi diğer birçok medikal alanlarda da çalışmalar mevcuttur.

Yenidoğan bakımında termal kamera ile yenidoğanların vücut sıcaklıklarının tespitinin yapılabileceği konusunu ilk olarak vurgulayanlar Clark ve Stothers olmuştur. Kızılötesi termal görüntüleme kullanarak yenidoğanın cilt sıcaklık dağılımını ölçmüşlerdir. Yenidoğanın üst kol, uyluk ve kalça bölgelerinin ortalama cilt sıcaklık değerine sahip olduğunu ve çevresel sıcaklık değişimlerine duyarlı oldukları sonucuna varmışlardır. Üst karın bölgesinin derisinin sıcak olduğunu ve çevresel sıcaklık değişikliklerine nispeten duyarsız olduğunu gözlemlemişlerdir.

Anderson ve ark. (1990) tarafından yapılan çalışmada, farklı termal koşullar altında uyuyan 2-3 aylık bebeklerin benzer şekilde cilt vücut sıcaklıklarını korudukları tespit edilmiştir. Çalışmada, 5 yenidoğan üzerinde termal görüntüleme yapılmıştır. 4 yenidoğan sıcaklığı benzer olan ortamlarda, diğeri ise daha sıcak bir ortamda uyutulmuştur. Böylece farklı termal ortamlarda neredeyse aynı rektal sıcaklık düzenini koruyan iki bebeğin vücut sıcaklık ölçümleri ve termal görüntüleri karşılaştırılarak termoregülasyonun nasıl sağlandığı incelenmiştir. Uyuyan bebeklerin cilt sıcaklıkları ölçülmüş ve uyku sırasında baş ve ellerde belirgin ısı kaybının olduğu görülmüştür.

Christidis ve ark. (2003) tarafından, yenidoğanlarda doğumdan sonraki ilk bir saat içinde yüzey sıcaklık profillerini inceleyen bir araştırma yapılmıştır. Ayrıca, farklı ortam koşullarının yüzey sıcaklığı açısından etkisi de incelenmiştir. Çalışmada, 42 yenidoğan incelenmiştir. Vücut yüzey sıcaklığı, kızılötesi termal görüntüleme kullanılarak çeşitli çevresel koşullar altında kaydedilmiştir. Doğumdan hemen sonra yenidoğanlarda yüzey sıcaklığının oldukça düzgün olduğu ancak bunun hem annenin hem de yenidoğanın vücut ısılarından çok daha düşük olduğu görülmüştür. Doğumdan kısa bir süre sonra periferik bölgelerin daha soğuk hale geldiği görülmüştür. Yenidoğanın ılık su ile banyo

yaptırılmasından sonra ise yenidoğanın vücut sıcaklık profilinin daha dengeli olduğu görülmüştür.

Abbas ve Leonhardt (2008) tarafından gerçekleştirilen çalışmada, kızılötesi termal görüntülerdeki kafa bölgesinin sıcaklık dağılımları ICA ayrıştırma tekniği kullanılarak sınıflandırılmıştır. Çalışmada, 12 adet termal görüntü kullanılmıştır. Gerçek zamanlı video verisi üzerinden ortalama kafa cilt sıcaklığı tespit edilmiştir. Termal görüntü katsayıları, dalgacık dönüşümü kullanılarak elde edilmiş ve farklı negatif olmayan matris ICA ayrıştırma testleri ile analiz edilmiştir. Sınıflandırma sonucunda, kafa bölgesinde sıcaklık değişimine karşı bir duyarlılık gözlenmiş; ICA algoritması kullanılarak yapılan özellik çıkarımı ile yenidoğandaki sıcaklık değişiminin aydınlatma koşullarından veya diğer klinik prosedürlere bağımsız olarak arka plandan (yatak çerçevesi) kolayca ayırt edilebildiği görülmüştür.

Catalan (2009) tarafından, yenidoğan kızılötesi termal görüntü işleme konulu tez çalışması gerçekleştirilmiştir. Yenidoğandan seçilen ilgili bölgenin (Region of Interest-ROI) sıcaklık bilgisi çıkarılarak sıcaklık aktif olarak izlenmiştir. Böylece, yenidoğan kuvöz sıcaklığının termal görüntüleme ile takip edilmesinin erken teşhis tekniği olarak kullanışlı olabileceği belirtilmiştir.

Rice ve ark. (2010) tarafından, çok düşük doğum ağırlığına sahip bebeklerde karın cilt sıcaklığının değerlendirilmesinde termal görüntülemenin uygulanabilirliği incelenmiştir. Termal görüntüleme kullanılarak karın ve göğüs cilt sıcaklıkları ölçülmüş ve karşılaştırılmıştır. Ayrıca, karın cilt sıcaklığı ile NEC arasındaki ilişki de araştırılmıştır. Çalışmalarında 13 bebeğin (<1000 gr ve <29 hafta) radyografik ve termal görüntüleme verileri incelenmiştir. Genel olarak ortalama karın cilt sıcaklığının, göğüs bölgesindeki cilt sıcaklığından daha düşük olduğu, ancak bu farkın bazı bebeklerde NEC nedeniyle ortaya çıktığı görülmüştür. NEC olan bebeklerin, NEC olmayan bebeklere kıyasla daha düşük ortalama karın cilt sıcaklığına sahip oldukları görülmüştür. NEC olmayan bebeklerde ise karın ve göğüs cilt sıcaklıklarının benzer olduğu görülmüştür.

Abbas ve ark. (2011) tarafından, yenidoğan yoğun bakım ünitesi için gerçek zamanlı kızılötesi termal görüntüleme kullanan temassız bir solunum izleme yöntemi önerilmiştir. Yenidoğanların solunum hızları, burun deliklerinin sıcaklık profilinin analizine dayanarak izlenmiştir. Çalışma, 5 yenidoğan üzerinde gerçekleştirilmiştir. Görüntü akışı içindeki solunum sinyalini tespit etmek için daubechies dalgacık işlevine dayalı sürekli dalgacık dönüşümü uygulanmıştır. Soluk alıp verme evreleri arasındaki 0.3°C ile 0.5°C sıcaklık farkı ile solunum hızı tespit edilmiştir. Abbas ve ark. (2012)'nin

gerçekleştirdiği bir diğer çalışmada ise farklı klinik senaryolar (kapalı kuvöz, anne kucağı ve açık kuvöz) altında ortalama 31 haftalık doğan 12 prematüre bebek üzerinde termal görüntülemenin doğruluğu ve güvenilirliği test edilmiştir. Sonuçlar, değişken tolerans değerlerine rağmen tatmin edici bulunmuştur.

Abbas ve ark. (2011) tarafından gerçekleştirilen termal görüntüleme ile soluk alıp verme hızının tespitine benzer bir çalışma Al-Khalidi ve ark. (2011) tarafından Sheffield Çocuk Hastanesinde gerçekleştirilmiştir. Bu çalışmada, solunum hızının değerini otomatik olarak izleyen termal görüntüleme tabanlı bir yöntem geliştirilmiştir. Çalışma için 16 çocuğun yüz termal görüntüleri incelenmiştir. Elde edilen termal görüntüler filtrelenmiş ve burun bölgesini tanımlamak için bölümlere ayrılmıştır. Tanımlanan burun bölgesini otomatik olarak takip etmek için bir algoritma geliştirilmiştir. Bu bölge, eş merkezli sekiz bölüme ayrılmıştır. Burun bölgesinde tek bir termal özellik üretmek üzere her bölüm içindeki piksel değerlerinin ortalaması alınmıştır. Her bölümün özelliği zamana karşı çizilerek bir solunum sinyali elde edilmiştir. Çocukların solunum oranları çeşitli konvansiyonel temaslı yöntemler kullanılarak da ölçülmüştür. Termal görüntüleme yöntemi kullanılarak ölçülen solunum hızları ile en etkili konvansiyonel temaslı solunum yöntemi kullanılarak elde edilenler arasında bir korelasyon olduğu gözlenmiştir.

Kızılötesi termal görüntülemenin son yıllarda kazandığı önemi gösteren işaretlerden biri de Chen ve ark. (2012)'nin editörlüğünü yaptığı ve yenidoğan görüntüleme teknolojilerini konu aldıkları kitabın bir bölümünün yenidoğan kızılötesi termal görüntülemeye ayrılmış olmasıdır. Bu bölüm Abbas ve ark. (2012) tarafından hazırlanmış olup termal görüntüleyiciler, kalibrasyon gereksinimleri, sıcaklık görüntüleme teknikleri ve sıcaklık dağılım haritası gibi temel konular hakkında geniş bilgiler verilmiştir.

Silva ve ark. (2012)'nin gerçekleştirdikleri çalışmada, pediatrik ekstremite travmasında kızılötesi termal görüntülerin etkinliği değerlendirilmiştir. Çalışmada, pediatrik acil serviste bacak travması nedeniyle 2 aylık sürede kontrol edilen hastalar incelenmiştir. Ayrıca, aynı gün hastaların röntgen filmi de çekilmiştir. İncelenen 51 hastanın semptomatik ve asemptomatik uzuv olmak üzere toplam 102 termal görüntüsü elde edilmiştir. Her termal görüntünün en sıcak alanı, röntgen filmindeki ağrı ve/veya kırılma bölgesi ile karşılaştırılmıştır. Termal görüntüleme ile ağrılı bölgelerin %73'ü doğru eşleşmiştir. Röntgen filminde 11 hastada kırık görülmüştür. Termal görüntüleme ile kırık görülen 11 hastadan 7'si doğru eşleşmiştir (%64). Yaralanma bölgesini saptamada

termal görüntülemenin performansı yetersiz görülse de daha ileri değerlendirmeler için çalışmalar yapılması gerektiği öngörülmüştür.

Frize ve ark. (2013) tarafından, termal görüntüleme kullanarak NEC hastalığının tespiti üzerine bir çalışma gerçekleştirilmiştir. Prematüre bebeklerin karın termal görüntüleri, NEC olan ve olmayan bebekleri tanımlamak için istatistiksel yöntemler ve karar ağaçları kullanılarak sınıflandırılmış ve analiz edilmiştir. Çalışmada, 9 NEC bebek ve 20 normal bebek incelenmiştir. Karın bölgesinin ayrılıp incelenmesi için ROI belirlenmiştir. ROI üst, alt, sağ ve sol olmak üzere dört bölgeye ayrılmış ve dört bölgenin ortalama ve medyan değerleri hesaplanmıştır. Üst ve alt karın bölgelerin ortalama ve ortanca sıcaklıkları arasındaki fark (U-L), sol ve sağ karın bölgelerin ortalama ve ortanca sıcaklıkları arasındaki fark (L-R) her bir görüntü için hesaplanmıştır. Üst ve alt karın bölgeleri arasındaki ortalama ve ortanca sıcaklık farkları ile sol ve sağ karın bölgeleri arasındaki ortalama ve ortanca sıcaklık farkları karar ağacı sınıflandırıcısı kullanılarak belirlenmiştir. Sınıflandırma performansında, üst ve alt karın bölgelerin arasındaki medyan sıcaklık farkları kullanıldığında daha iyi sonuçlar elde edilmiştir. Sınıflandırma sonucunda, üst ve alt karın (U-L) bölgeleri arasındaki medyan sıcaklık farkları özgüllük $90 \pm \%12$, hassasiyet $78 \pm \%18$; ortalama sıcaklık farkları ise özgüllük $88 \pm \%14$, hassasiyet $69 \pm \%12$ olarak bulunmuştur. Üst ve alt karın bölgeleri arasındaki sıcaklık farkının parametrik olmayan istatistiksel testler kullanıldığında normal bebeklerden önemli ölçüde farklı olduğu görülmüştür. Sol ve sağ karın bölgeleri arasındaki sıcaklık farkının hesaplanması ile NEC ve NEC olmayan bebeklerin tanımlanmasında önemli sonuçlar verilmediği görülmüştür.

Frize ve ark. (2013)'nin yaptığı çalışma, NEC ve normal bebekler arasında ayırma yeteneğini artırmak için Nur ve Frize (2013) tarafından görüntü geliştirme teknikleri uygulanarak yeniden incelenmiştir. Bu çalışmada, görüntülere Gaussian gürültüsü eklenmiş ve gürültüyü gidermek için Wiener (5x5) filtresi kullanılmıştır. Arka plan kaldırma tekniği olarak Otsu algoritması ve kontrastı artırmak için CLAHE uygulanmıştır. NEC grubundaki U-L sıcaklık farklarında normal gruba göre gözle görülür bir artış gözlemlenmiştir. NEC grubunda L-R sıcaklık farklılıklarının da normal gruptan yüksek olduğu görülmüştür. Görüntü geliştirme işleminin tüm aşamaları boyunca tutarlı olan NEC grubunun daha yüksek derecede bir termal asimetriye sahip olduğu görülmüştür. Özellikle kontrast geliştirme kullanıldığında NEC grubunun hem ortalama hem de medyan özelliklerin normal gruba göre daha yüksek derecede bir termal asimetriye sahip olduğu görülmüştür.

Nur' un (2013) yayınlamış olduğu tezde, NEC hastalığının tespitine yönelik kapsamlı bir çalışma gerçekleştirilmiştir. Bu çalışmada, vücut üzerindeki karın bölgesinin ayrılıp incelenmesi için ROI belirlenmiştir. ROI üst, alt, sağ ve sol olmak üzere dört bölgeye ayrılmıştır. Her bir ilgi alanı için birinci ve ikinci dereceden istatistiksel parametreler çıkartılmıştır. Bu parametreler; sıcaklık dağılımının ortalama, medyan, mod, maksimum, minimum, varyans, standart sapma, kurtosis ve skewness değerleridir. Her bir görüntü için hem üst ve alt karın bölgelerinin istatistiksel değerleri arasındaki fark hem de sol ve sağ bölgelerinin istatistiksel değerleri arasındaki fark hesaplanmıştır. Bu istatistiksel değerlere bakılarak NEC hastalığı belirlenmeye çalışılmıştır.

Heimann ve ark. (2013) tarafından gerçekleştirilen çalışmada, termal görüntüleme ile prematüre bebeklerin vücutlarının çeşitli bölgelerinin cilt sıcaklıkları incelenmiştir. Prematüre bebeklerin cilt sıcaklık değişimleri iki farklı yöntemle analiz edilmiştir. Bebeklerin cilt sıcaklığı hem kuvözde hem de anneyle cilt teması aşamasında farklı konumlarda, birden fazla merkezi ve çevresel vücut alanlarında değerlendirilmiştir. Çalışmada, 10 prematüre bebeğin bacak, sırt, kol, kafa ve üst karın alanlarının termal görüntüsü kullanılmıştır. Her bölge için 10 dakikada bir 4 farklı sıcaklık ölçümü yapılmıştır. Anne ile cilt teması sırasında ortalama cilt sıcaklığının, kafa ve bacak bölgesinin ısınmasına bağlı olarak arttığı görülmüştür. Kuvöze tekrar yerleştirildikten sonra sıcaklığın kol hariç tüm alanlarda başlangıçtaki kuvöz değerlerine göre anlamlı derecede belli bir seviyeye düştüğü görülmüştür. Yüzüstü pozisyonda, konvansiyonel sıcaklık sensörü tarafından ölçülen üst karın bölgesinin sıcaklığının, termal görüntüleme ile elde edilen sonuçlara benzer olduğu bulunmuştur. Ayrıca, prematüre bebeklerin bakımında avantaj sağlayabilecek olan invazif olmayan bir ölçümle kablo elektrotunun değiştirilmesinin mümkün olacağı sonucuna varılmıştır. Buna karşılık, aynı pozisyonda sırt bölgesindeki sıcaklık sensörü, sıcaklık düşüşünü düzgün bir şekilde izleyememiş ve bu durum klinik yararlılığını sınırlamıştır. Sonuç olarak, termal görüntüleme ile prematüre bebeklerin sıcaklığındaki değişimlerin tespit edilebileceği görülmüştür.

Villarroel ve ark. (2014), Oxford John Radcliffe Hastanesi Yenidoğan Yoğun Bakım Ünitesinde temassız bir şekilde hayati sinyallerin (kalp atış hızı, solunum hızı ve oksijen satürasyonu) gözlenmesi için termal görüntüleme kullanmışlardır. Bu üç parametrenin termal kamera ile sürekli tahminlerinin klinik olarak yüksek bir doğrulukla hesaplanabileceğini göstermişlerdir. Termal kameradan elde edilen kalp atış hızı tahminleri ile EKG' den elde edilen referans değeri arasındaki ortalama mutlak hatanın,

EKG' den elde edilen deęer ile nabız oksimetresindeki kalp atıř hızı arasındaki ortalama mutlak hatanın benzer olduęu gözlemlenmiřlerdir.

Abbas ve ark. (2014)' nin gerekleřtirdięi alıřmada, uzmanların yenidoęanın cilt sıcaklıęı modellerini yorumlamalarına yardımcı olabilecek sanal sıcaklık algılama uygulamasının tasarımı ve uygulaması sunulmuřtur. Termal grntleme teknięi kullanılarak yenidoęanın vcut yzey sıcaklıęı eřitli klinik kořullar altında kaydedilmiřtir. Gerek zamanlı video olarak kaydedilen sıcaklık daęılımları, ortalama cilt sıcaklıklarını deęerlendirmek iin analiz edilmiřtir. Yenidoęanın geometrisi zerinde tanımlanmıř ilgili blgenin aktif takibi iin bir izleme algoritması tasarlanmıř ve řablon eřleřtirme algoritmasına dayanarak test edilmiřtir. alıřmada, radyant ısıtıcı ile tedavi gren 5 yenidoęan ve konvektif kuvz iine yerleřtirilmiř 5 yenidoęan zerinden elde edilen veriler kullanılmıřtır. Termal sanal sensrden elde edilen sonular, bir yenidoęanın dıř anatomisi zerinde farklı geometrik profilleri ve řekilleri doęru bir řekilde takip etme yeteneęini gstermiřtir. ROI izleme bařarı oranı %74 ile %89 arasında ($p < 0.01$) bulunmuřtur. Hareket algılamanın sadece kk bir yzdesi, alıřılan ROI tanımlayıcısı iin uygun bir eřleřtirme matrisi olmadıęı iin izlemeyi bařaramamıřtır.

Al-Alwani ve Chahir (2014)' nin alıřmasında, yerel ikili desen (LBP, Local Binary Pattern) ve dalgacık eřięi teknięi kullanılarak prematre bebeklerin aęrı ve normal durumların gnlk bakım izleme sırasında tespit edilmesi ve tanınması iin bir yaklařım sunulmuřtur. alıřma, termal video dizilerinden prematrenin aęrı durumunu temsil eden 20 klip ve normal durumunu temsil eden 20 klip ieren grntler zerinde gerekleřtirilmiřtir. Prematre bebeęin yznde yerel ilgi alanı olarak 11 x 11 boyutlarında bir grnt yaması tanımlanmıřtır. İlk ařamada, LBP kullanarak yerel termal zellikleri tanımlanmıř ve sonra bu zellikler bir boyutlu histogram vektryle birleřtirilmiřtir (LBPH). Histogramı daha verimli hale getirmek iin, sırasıyla Hausdorffs ve entropi mesafe fonksiyonu kullanılarak histogram vektrleri arasındaki benzerlik matrisi deęerlendirilmiřtir. İkinci ařamada, histogram vektrlerine dalgacık dnřm uygulanmıř ve yaklařık katsayılarına dalgacık eřikleme teknięi kullanılarak zellik ıkarımı elde edilmiřtir (WTLBP). İlk ařamada olduęu gibi, zellik ıkarımının iyileřtirilmesi iin benzerlik matrisleri benimsenmiřtir. zellik ıkarımının son adımımda, ikili zellik seti zerinde Doęrusal Ayırma Analizi (LDA, Linear Discriminant Analysis) gerekleřtirilmiřtir. Daha sonra, SVM ve k-NN sınıflandırıcıları kullanılarak prematre olaylarının sınıflandırılmasını gerekleřtirilmiřtir. En iyi doęruluk, histogram vektrleri arasına ikili mesafe metrikleri kullanıldıęında elde edilmiřtir. Sınıflama sonuları


karşılaştırıldığında, LBP' nin Hausdorff mesafesi ve entropi mesafesinin WTLBP' den daha iyi performans gösterdiği görülmüştür. Prematüre olaylarının tanınmasında, LBPH' nin ikili mesafe ile kullanıldığında performansın daha iyi olabileceği sonucuna varılmıştır.

Bu tez çalışmasında, yenidoğan yoğun bakım ünitesinde bulunan 19 sağlıklı ve 19 hasta bebekten alınan termal görüntünün sıcaklık haritaları kullanılarak sağlıklı-hasta teşhisine yönelik sınıflandırma çalışması gerçekleştirilmiştir. İlk olarak, termal görüntülerin arka planını çıkarmak için segmentasyon işlemi uygulanmıştır. Daha sonra segmente edilmiş termal görüntülerin çoklu çözünürlük analizi yöntemleri (ADD, ARiD, CuD ve CoD) uygulanarak özellik vektörleri elde edilmiş ve bu özellik vektörleri YSA kullanılarak sınıflandırılmıştır. Sınıflandırma sonucunda, %100 doğruluk oranı elde edilmiştir. Daha sonra, özellik vektörlerinin boyutlarının azaltılabilmesi için çoklu çözünürlük analizi yöntemlerinin uygulanması sonucu elde edilen yaklaşım katsayılarından istatistikî özellikler (ortalama, standart sapma, varyans, skewness, kurtosis ve moment) çıkarılmış ve bu istatistikî özellikler YSA kullanılarak sınıflandırılmıştır. Bu sınıflandırma işleminde %75' ten daha az doğruluk oranı elde edilmiştir. Ayrıca, yenidoğan bakım ünitesinde kalp hastalığı (AORT Koarktasyon, Pulmoner atreti) teşhisi konmuş 14 hasta ve sağlıklı 29 PRM bebeğin RGB termal görüntüleri kullanılarak sağlıklı-hasta teşhisine yönelik sınıflandırma çalışması da gerçekleştirilmiştir. Sınıflandırma sonucunda; ADD ile %81.40, ARiD ile %74.42, CuD ile %72.09, CoD ile %74.42 başarı elde edilmiştir. Sınıflandırma sonuçlarına bakılarak kullanılan termal görüntülerin sayısının yetersiz olduğu düşünülmüş ve ikinci bir sınıflandırma çalışması gerçekleştirilmiştir. Bu çalışmada, termal görüntülerin sayısının sentetik olarak artırılması için veri artırma yöntemi kullanılmıştır. 43 görüntü üzerinde veri artırma yöntemi uygulanarak her bir görüntüden 5 farklı görüntü daha elde edilmiştir. Böylece görüntü koleksiyonu 43 termal görüntüden 258 termal görüntüye artırılmıştır. Gerçekleştirilen sınıflandırma işleminde termal görüntüler; ADD ile %90.7, ARiD ile %90.7, CuD ile %91.09, CoD ile %91.09 doğrulukla sınıflandırılmıştır. Sonuç olarak veri artırma yöntemi uygulanarak gerçekleştirilen sınıflandırmada daha yüksek doğruluk, hassasiyet ve özgüllük oranlarına ulaşılabildiği görülmüştür.

2. MATERYAL VE YÖNTEM

2.1. Kızılötesi Termal Görüntüleme

Kızılötesi (Infrared veya IR), elektromanyetik spektrum içinde yer alan bir radyasyon olup, termal radyasyon olarak da nitelendirilmektedir. Tüm cisimler mutlak sıcaklığının bir sonucu olarak ışınım enerjisi ya da termal radyasyon yayarlar. Radyasyon, birbirini gören farklı sıcaklıktaki cisimler arasındaki ısı transferi olup ısı enerjisi, kızılötesi dalga boyunda iletilir (Bouzida ve ark., 2009). Kızılötesi radyasyon, elektromanyetik spektrumda görünür ışık ve mikrodalga bölgelerinin arasında bulunur ve dalgaboyu 0.75 mikrometre ile 1000 mikrometre arasındadır (Knobel ve ark., 2011). Görünür ışık spektrumunun en uzun dalga boyu olan kırmızı ışığın ötesinde bir bölgeye karşılık gelmesinden dolayı “Kızılaltı” veya “Kızılötesi” olarak adlandırılmaktadır. Elektromanyetik spektrumun dalga boylarına göre ayrılmış bölgeleri ve kızılötesi bandının spektrumdaki yeri Şekil 2.1’de gösterilmiştir.



Şekil 2. 1. Elektromanyetik spektrum ve kızılötesi bant (Knobel ve ark., 2011)

Nesneler oldukça geniş bir tayfta kızılötesi radyasyon yaymalarına rağmen algılayıcılar sadece belli bant genişliklerini algılayabilirler. Bu nedenle kızılötesi bant, daha küçük alt bantlara bölünmüştür. Alman Standartlar Enstitüsü (DIN) tarafından belirlenen ve sıkça kullanılan bir bölümlenme biçimi şöyledir:

- Yakın Kızılötesi (NIR): 0.75-1 µm,
- Kısa Dalga Kızılötesi (SWIR): 1-3 µm,

- Orta Dalga Kızılötesi (MWIR): 3-5 μm ,
- Uzun Dalga Kızılötesi (LWIR): 8-15 μm ,
- Uzak Kızılötesi (FIR): 15-1000 μm .

Tüm nesnelere sürekli titreşen atomlardan oluşur. Dolayısıyla daha yüksek enerjili atomlar daha sık titreşir. Atomlar ve tüm yüklü parçacıkların titreşimi, elektromanyetik dalgalar üretir. Atomların titreşimi cismin sıcaklığı ile orantılıdır. Bir nesnenin sıcaklığı ne kadar yüksek olursa, titreşim o kadar hızlı ve bu nedenle spektral yayılım enerjisi de o kadar fazla olur. Sonuç olarak, mutlak sıfırın (0 K, -273.15°C) üzerinde bir sıcaklığa sahip tüm nesnelere, spektral yayılımına (emisyona - ϵ) ve nesnenin sıcaklığına bağlı olarak sürekli bir kızılötesi radyasyon yayarlar (Rogalski ve Chrzanowski, 2012).

Radyasyon yayılımı genellikle kara cisim kavramı ile ele alınmaktadır. Kara cisim, elektromanyetik dalgaların tüm dalga boylarını absorbe eden ve Planck yasasına göre sürekli enerji yayan bir nesne olarak kabul edilir (Lahiri ve ark, 2012). Bir kara cismin yaydığı enerji, verilen sıcaklıkta teorik olarak mümkün olan maksimum değerdedir. Bir kara cisim için termal radyasyon gücünün (veya yayılan foton sayısı) dalga boyu ile değişimi, Planck'ın radyasyon yasasına göre eşitlik (2.1) ve eşitlik (2.2) ile tanımlanmaktadır.

$$M(\lambda, T) = \frac{2\pi hc^2}{\lambda^5} \left[\exp\left(\frac{hc}{\lambda kT}\right) - 1 \right]^{-1} \text{ (Watt/cm}^2\mu\text{m)} \quad (2.1)$$

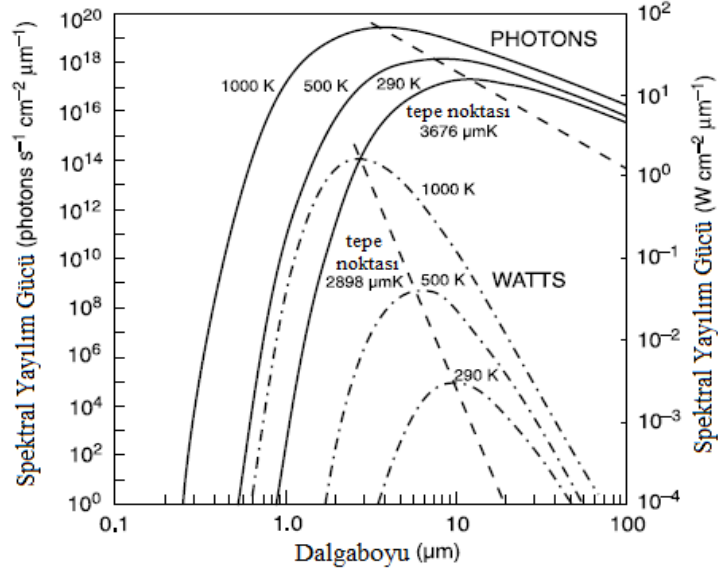
$$P(\lambda, T) = \frac{2\pi h}{\lambda^4} \left[\exp\left(\frac{hc}{\lambda kT}\right) - 1 \right]^{-1} \text{ (photons/s cm}^2\mu\text{m)} \quad (2.2)$$

Burada λ dalga boyunu, T mutlak sıcaklığı, c (3×10^8 m/s) ışık hızını, h (6.6256×10^{-34} Ws²) Planck sabitini ve k (1.38054×10^{-23} JK⁻¹) Boltzmann sabitini göstermektedir. Maksimum yayılım dalgaboyu, Wien'in yer değiştirme kanunu ile eşitlik (2.3) ve eşitlik (2.4)'de ifade edilmektedir (Rogalski ve Chrzanowski, 2012). Bu eşitliklere göre nesnenin mutlak sıcaklığı ile maksimum yayılım dalga boyu ters orantılıdır.

$$\lambda_{mw}T = 2898 \mu\text{mK, maksimum güç için} \quad (2.3)$$

$$\lambda_{mp}T = 3670 \mu\text{mK, maksimum foton için} \quad (2.4)$$

Şekil 2.2’ de kara cisimlerin Planck yasasına göre spektral yayımları gösterilmektedir. Sıcaklık arttıkça herhangi bir dalga boyunda yayılan enerji miktarı artmakta, tepe yayılım dalgaboyu ise azalmaktadır (Rogalski ve Chrzanowski, 2012). Şekilden de görüldüğü gibi sıcak bir cismin yayılım tepe noktası soğuk bir cisme göre daha yükseklerde olacaktır. Tepe yayılım dalgaboyu ise sıcak cisimlerde kısa dalga boylarında iken soğuk cisimlerde uzun dalga boylarında olacaktır.




Şekil 2. 2. Planck yasasının spektral yayılımı (Rogalski ve Chrzanowski, 2012)

Cilt emisyon oranı, cilt sıcaklığını belirlemede önemli bir faktördür. Emisyon, aynı sıcaklıkta radyasyon yansıtma yeteneği olmayan bir nesneye göre bir nesneden ne kadar radyasyon salındığının bir ölçüsüdür (Knobel ve ark., 2011). Emisyon 0 ile 1 arasında bir değere sahiptir ve dalga boyuna göre değişebilmektedir. Normal insan cildinin emisyon değeri ise yaklaşık 0.98 olduğu görülmüştür (Hejazi ve Spangler, 1992). İnsan cildinin emisyon değeri 1’ e yakın olduğundan bir karacisim gibi davranır (Ring ve Ammer, 2012). Dolayısıyla insan cildinden yayılan kızılötesi radyasyon doğrudan sıcaklık değerlerine dönüştürülebilmektedir.

Termal kameralar, nesnenin görüntüsünü kaydetmek için üzerinde bulunan detektörler aracılığıyla kızılötesi radyasyonu yakalar ve her bir uzamsal konumda yayılan kızılötesi radyasyon miktarını kaydeder (Knobel ve ark., 2011). Daha sonra kaydedilen bu kızılötesi radyasyon miktarını elektronik sinyallerine dönüştürür. Bu sinyaller ekranda görüntülenir ve radyasyon miktarına göre renklerle eşleşir (Hildebrandt ve ark., 2012). Elde edilen görüntülere termogram adı verilir. Şekil 2.3’ de termogram örneği

gösterilmiştir. Termogramlar, incelenilen nesnenin yüzeyindeki sıcaklık dağılımının farklı renk tonlarıyla görsel olarak görülmesini sağlar. Renklerin dağılımı, vücut yüzeyinden yayılan kızılötesi radyasyon miktarındaki azalma ya da artışı gösterir. Termogramlar iki boyutlu bir dizide piksel olarak görüntülenir (Knobel ve ark., 2011). Her bir piksel, görüntülenen bölgenin sıcaklık değerlerini gösterir.




Şekil 2. 3. Termogram

Medikal uygulamalarda kullanılan termal kameralar genellikle orta dalga 3-5 μm ve uzun dalga 8-13 μm aralığında çalışmaktadır. 5-7 μm arası atmosferdeki su buharı nedeniyle soğurulduğu için termal kameralar bu aralıkta tespit yapamazlar (Rogalski ve Chrzanowski, 2012). Kullanılacak kamera tipinin seçimi, incelenecek nesnelerin sıcaklık aralığına bağlıdır. İnsan vücudu çoğunlukla 2-20 μm dalga boyu aralığında sürekli olarak bir kızılötesi radyasyon yaymaktadır. Normal vücut sıcaklığına sahip insanlar, yaklaşık 9-10 μm dalga boyu aralığında bir kızılötesi radyasyon yayarlar. Plank Yasasına göre, insanlarda yayılan kızılötesi radyasyonun yaklaşık %90' ı ise 8-15 μm dalga boyu aralığındadır (Steketee, 1973). Dolayısıyla, medikal uygulamalarda genellikle uzun dalga boyu termal kameralar tercih edilmektedir.


Medikal kızılötesi termal görüntüleme, vücudun yaydığı kızılötesi radyasyonu yakalayıp organlarda ve dokularda sıcaklık dağılımını ölçmek için kullanılan bir görüntüleme tekniğidir. Termal görüntüleme tanı aracı olarak kullanıldığında, tedaviyi planlamak, etkilerini değerlendirmek ve normal kişilerde fizyolojik fonksiyonları incelemek için çeşitli koşullarda kullanılabilir (Sruthi ve Sasikala, 2015). Böylece, fizyolojik fonksiyon bozukluklarının lokalize olduğu yerdeki sıcaklık değişikliklerinin saptanabilmesine olanak sağlar. Kızılötesi termal görüntüleme, vücut sıcaklık değişikliklerini izlemek için diğer klinik termometrelere göre hızlı, pasif, temassız ve

invazif olmayan bir tekniktir. Ayrıca hastalık teşhisinde kullanılan manyetik rezonans görüntüleme ve bilgisayarlı tomografi taramalarına tamamlayıcı niteliktedir.

Sıcaklık, dokuların enerji seviyesinin bir ölçüsüdür ve o dokuda depolanan ısı miktarını verir. Vücutta meydana gelen tümörler, iltihaplanma ve enfeksiyon gibi fizyolojik fonksiyon bozuklukları, sıcaklık artışlarına neden olmaktadır. Bu artışlar, termal görüntülerde sıcak noktalar veya asimetric desenler olarak gösterilir. Sağlıklı bir insan vücudunun cilt sıcaklık dağılımı kontralateral simetriyi gösterir. Belirli bir seviyenin üstünde asimetri gösteren sıcaklık dağılımı genellikle anormalliklerin güçlü bir göstergesidir (Jones, 1998). Dolayısıyla normal vücut termal olarak simetrik olduğundan asimetric sıcaklıklar termal görüntüler üzerinde kolaylıkla fark edilebilmektedir. Şekil 2.4 ve Şekil 2.5’ te sırasıyla simetrik ve asimetric termogram örnekleri gösterilmektedir.



Şekil 2. 4. Simetrik termogram örnekleri



Şekil 2. 5. Asimetric termogram örnekleri

2.2. Termal Görüntülerin Elde Edilmesi

Yenidoğan bebeklerin termal görüntüleri, Selçuk Üniversitesi Tıp Fakültesi Yenidoğan Yoğun Bakım Ünitesinde uzun dalga boyu aralığında çalışan InfraTec® VarioCAM HD kızılötesi kamera tarafından kaydedilmiştir. Görüntülerin kullanımı için

gerekli etik kurul kararı alınmış ve Ek-1' de sunulmuştur. Kullanılan kameranın çözünürlüğü 640×480 ve termal duyarlılığı yaklaşık 0.05°C ' dir. Termal görüntüler veya termal video dizileri, yoğun bakım kuvözünün yanında bulunan taşınabilir bir bilgisayara transfer edilmiştir. Termal kameranın kendi yazılım aracı (IRBIS Professional 3.0) sadece transfer aşamasında kullanılmış termal görüntüler jpeg ve ASCII formatına dönüştürülmüştür. Kamera ölçümü sırtüstü pozisyonda yatan yenidoğandan yaklaşık 60-100 cm uzaklıkta gerçekleştirilmiştir. Yenidoğandan 60 saniyelik süre içinde 100 çerçevelik bir görüntü kaydı alınmıştır. Şekil 2.6' da yenidoğandan termal görüntü alınımının nasıl yapıldığını göstermektedir.



Şekil 2. 6. Yenidoğandan termal görüntü alma prosedürü


2.2.1. Termal görüntü yaklaşımları

Termal kameralar bebeğin vücudundan yayılan kızılötesi radyasyonu algılayarak vücut yüzey sıcaklık değerlerini kaydetmektedir. Dolayısıyla termal kameranın bu sıcaklık değerlerini hassas olarak ölçmesi ve görselleştirmesi gerekmektedir. Termal kameranın yaptığı ölçümler; RGB görüntülere ve sıcaklık haritalarına dönüştürülerek görüntülenebilmektedir.

2.2.1.1. RGB görüntü

RGB görüntüler, termal kameranın yazılım programında kullanıcının belirleyeceği bir alt eşik ve üst eşik sıcaklık değerleri arasında, termal görüntülerin

renklendirilerek kırmızı, yeşil mavi (RGB) renk uzayına dönüştürülmesi ile elde edilmektedir. Alt ve üst eşik sıcaklık aralıkları ortamın sıcaklığına ve yenidoğanın vücut sıcaklık değerlerine bağlı olarak değişebilmektedir. Şekil 2.7’ de görüldüğü gibi iki görüntü aynı sıcaklık değerine sahipken, termal görüntülerin eşik aralığı değiştirilerek görüntüler farklı tonlarda gösterilebilmektedir. (Örnek ve ark., 2018). Tez çalışmasında 30–40°C sıcaklık değerlerinde renklendirilmiş termal görüntüler kullanılmıştır.



Şekil 2. 7. Termal görüntülerin farklı eşik değerleri kullanılarak elde edilmesi a) 28-40°C sıcaklık aralığındaki RGB termal görüntü (b) 26-39°C sıcaklık aralığındaki RGB termal görüntü

2.2.1.2. Termal sıcaklık haritaları

Sıcaklık haritası, doğrudan termal görüntülerin sıcaklık değerlerini temsil eden iki boyutlu dizilerdir. Elde edilen termal görüntüler herhangi bir eşiklemeye tutulmadan ASCII formatında kaydedilir. Şekil 2.8 (a)’ da 30–40 derece aralığında renklendirilerek kaydedilmiş görüntünün gri seviyeli hali Şekil 2.8 (b)’ de sıcaklık değerlerinin görselleştirilmesi ile oluşturulmuş görüntü gösterilmiştir.



Şekil 2. 8. (a) 30–40°C aralığında renklendirilerek kaydedilmiş termal görüntünün gri seviyeli hali (b) sıcaklık haritalarının görselleştirilmesi ile oluşan termal görüntü

2.3. Çoklu Çözünürlük Analizi Yöntemleri

Çoklu Çözünürlük Analizi (ÇÇA) iyi bir zaman çözünürlüğü elde etmek için tasarlanmıştır. Yüksek frekanslarda daha az frekans çözünürlüğü gösterirken, düşük frekanslarda daha az zaman çözünürlüğü gösterir. Bu yaklaşım, kısa sürelerde yüksek frekans bileşen içeren ve uzun sürelerde düşük frekans bileşen içeren sinyallerde faydalıdır. Genellikle 2 boyutlu görüntüler bu frekans modelini takip eder. Dolayısıyla çoklu çözünürlük analizi, görüntülerin bilgi içeriğinin analizinde oldukça etkilidir (Polikar, 1996).

Çoklu Çözünürlük Analizi yöntemleri özellikle dalgacıkların (wavelet) gelişimiyle birlikte çok popüler hale gelmiştir. Dalgacık Dönüşümü tüm ölçeklerde ve konumlarda meydana gelen yön bağımsız izotropik elemanlara dayanır. Bu nedenle çizgisel veya eğrisel yapılar gibi yüksek dereceli yön bağımlı anizotropik elemanları olan nesnelere etkili bir şekilde temsil edemezler ve ölçekten bağımsız yönlü elemanları sadece sabit bir sayıda içerirler (Fadili ve Starck, 2009). Bu sorunları ortadan kaldırmak için bazı yeni yöntemler geliştirilmiştir. Bu yöntemler; Ridgelet, Curvelet ve Contourlet Dönüşümleridir. Bu bölümde, tez çalışmasında kullanılan çoklu çözünürlük analizi yöntemleri dört ayrı alt başlıkta incelenmiştir.

2.3.1. Dalgacık dönüşümü

Dalgacık Dönüşümü (DD), sinyalleri frekans bantlarına ayırarak, değişen çözünürlüklerde durağan olmayan sinyalleri analiz edebilen bir dönüşüm tekniğidir. Dalgacık Dönüşümü hem zaman hem de frekansta lokalizasyonlu sinyalin çoklu çözünürlük analizini gerçekleştirmektedir (Shukla, 2003).

Dalgacık Dönüşümü, ana dalgacık olarak adlandırılan prototip bir dalgacık fonksiyonuna sahiptir. Bu dalgacık, sınırlı süreli ve ortalama değeri sıfır olan küçük bir dalga formuna sahiptir. Ayrıca düzensiz ve asimetric özellik eğilimindedir (Ceylan, 2009).

Dalgacık Dönüşümünün en önemli özelliği sinyalin yerel olarak analizinin yapılabilmesidir. Bu özellik ile büyük bir sinyal küçük bir alanda analiz edilebilmektedir. Böylece geçici ve tekillikler içeren parçalı düzenli sinyallerin algılanması, oluşum zamanlarının ve karakteristiklerinin belirlenmesi mümkün olabilmektedir (Mallat, 1999).

Ayrıca sinyallerde bulunan süreksizlik noktaları, eğimli ve kırılma noktaları Dalgacık Dönüşümü ile daha iyi analiz edilebilmektedir.

Dalgacık Dönüşümü, Sürekli Dalgacık Dönüşümü (SDD- Continuous Wavelet Transform-CWT) ve Ayrık Dalgacık Dönüşümü (ADD-Discrete Wavelet Transform-DWT) olmak üzere iki tür ayrıştırma işlemi ile temsil edilebilir.

2.3.1.1. Sürekli Dalgacık Dönüşümü

Sürekli Dalgacık Dönüşümü, giriş işaretinin ana dalgacık fonksiyonunun ölçeklendirilmiş ve kaydırılmış haliyle çarpılıp tüm zaman boyunca toplanmasıyla elde edilir. Herhangi bir $x(t)$ sinyalinin Sürekli Dalgacık Dönüşümü eşitlik (2.5)' te tanımlanır.

$$SDD(a, b) = \int_{-\infty}^{\infty} x(t) \Psi_{(a,b)}^*(t) . dt \quad (2.5)$$

Burada a ölçekleme faktörünü, b kayma faktörünü ve $*$ kompleks eşleniği ifade etmektedir. $\Psi(t)$ ise ana dalgacık fonksiyonudur. Ana dalgacık fonksiyonunun b ile ötelenmesi ve a ile ölçeklenmesiyle eşitlik (2.6)' da tanımlanan dalgacık fonksiyonu ailesi elde edilir.

$$\Psi_{(a,b)}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) dt \quad a, b \in \mathbb{R} (a > 0) \quad (2.6)$$

$\Psi \in L^2(\mathbb{R})$ olmak üzere bir dalgacık, ortalaması sıfır olan bir fonksiyondur. Böylece, bir dalgacık fonksiyonu bant geçiren karakteristiğe sahip olur.

$$\int_{-\infty}^{\infty} \Psi(t) dt = \Psi(0) = 0 \quad (2.7)$$

Ana dalgacık fonksiyonu $t = 0$ civarında normalize durumdadır. Dalgacık fonksiyonu ailesi de $\|\Psi_{(a,b)}(t)\| = \|\Psi(t)\|$ ile normalize durumdadır.

Dalgacık Dönüşümü, enerji korunumu ve kabul edilebilirlik şartını sağlamaktadır. C_ψ kabul edilebilirlik şartı eşitlik (2.8) ile tanımlanır. $\Psi(w)$ ise ana dalgacık fonksiyonu $\Psi(t)$ ' nin Fourier dönüşümünü gösterir.

$$C_\psi = \int_{-\infty}^{\infty} \frac{|\Psi(w)|^2}{|w|} dw < \infty \quad (2.8)$$

Bir işaretin Dalgacık Dönüşümü alındıktan sonra tekrar başlangıç işaretini veride herhangi bir kayıp ya da bozulma olmadan geri üretmek mümkündür. Eşitlik (2.9) ile $x(t)$ fonksiyonu, Sürekli Dalgacık Dönüşümünden yeniden elde edilebilir (Vetterli ve Kovacevic, 1995; Ceylan, 2009)

$$x(t) = \frac{1}{C_\psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} SDD(a, b) \Psi_{a,b}(t) \frac{dadb}{a^2} \quad (2.9)$$

2.3.1.2. Ayrık dalgacık dönüşümü

Sürekli Dalgacık Dönüşümünde dalgacık katsayıların her bir kaydırma ve ölçekleme için hesaplanması, çok fazla ve kullanılmayan verinin üretilmesine neden olmaktadır. Dalgacık Dönüşümünün ölçekleme ve kayma parametrelerinin ayrık bir zaman-ölçek düzleminde değerlendirilmesi, ADD' yi ortaya çıkarmıştır (Yaşar, 2015). ADD' de ölçek değerleri, 2' nin kuvvetleri biçiminde seçilir. Bu diyadik seçim belli noktalarda katsayıları hesaplar, böylece işlem sayısı azalır.

Ayrıklaştırma işlemi eşitlik (2.10)' da verilen sürekli dalgacık dönüşümünde a ölçek katsayısı yerine 2^j ve b öteleme katsayısı yerine de $2^j k$ konularak elde edilir. Elde edilen dalgacık ailesi eşitlik (2.11) ile gösterilir (Polikar, 1999).

$$\Psi_{(a,b)}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) = \frac{1}{\sqrt{2^j}} \Psi\left(\frac{t-2^j k}{2^j}\right) \quad (2.10)$$

$$\Psi_{j,k}(t) = 2^{-j/2} \Psi(2^{-j} t - k) \quad j, k \in Z \quad (2.11)$$

Bir $x(t)$ fonksiyonunun dalgacık ayrışımı ise eşitlik (2.12)' de verilmiştir. Eşitlik (2.13)' de tanımlanan $D_x(j, k)$ katsayılarının 2 boyutlu kümesi, verilen bir $x(t)$ fonksiyonunun Ayırık Dalgacık Dönüşümü olarak adlandırılır (Ceylan, 2009).

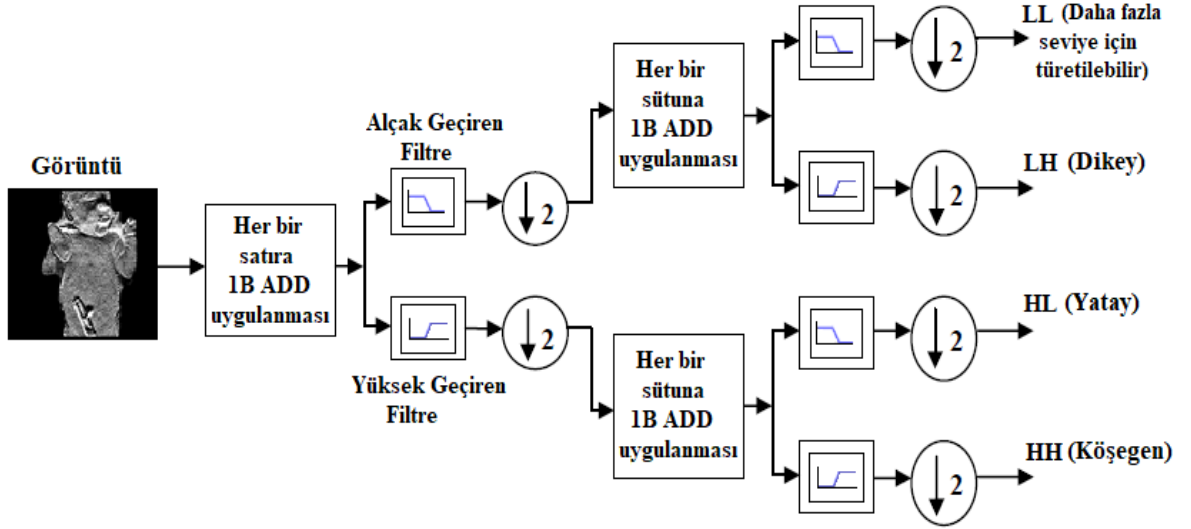
$$x(t) = \sum_j \sum_k D_x(j, k) \Psi_{j,k}(t) \quad (2.12)$$

$$D_x(j, k) = \int_{-\infty}^{\infty} \Psi_{j,k}^*(t) x(t) dt = \langle \Psi_{j,k}(t), x(t) \rangle \quad (2.13)$$


ADD, çoklu çözünürlük analizi ve filtre banka yapısı olmak üzere iki türde açıklanabilmektedir. ADD' nin filtre banka yapısı ile gerçekleşmesinde bir sinyal, alçak geçiren ve yüksek geçiren filtrelerden geçirilerek alt bantlara ayrılır. Alt bantlara ayırma sonucunda yüksek geçiren filtreden detay katsayıları, alçak geçiren filtreden ise yaklaşım katsayıları elde edilir. Sinyal, ayrıştırma işlemini art arda birden fazla seviye için tekrarlayarak görüntü istenen frekans aralığına bölünür (Shukla, 2003; Ceylan, 2009).

Görüntüler için bir boyutlu (1B) ADD, iki boyutlu (2B) olarak kolayca genişletilebilir. İki boyutlu ADD, görüntünün satır ve sütunlarına 1B ADD' nin ayrı ayrı uygulanmasıyla elde edilir. Tek seviyeli 2 boyutlu bir görüntünün ADD filtre yapısı Şekil 2.9' da gösterilmiştir (Öztürk, 2015).


2B ADD' de görüntü, her ayrıştırma seviyesinde 4 alt banda ayrılır. Bu alt görüntülerin her biri, ana görüntü boyutunun dörtte biri kadardır (Shukla, 2003). 2 boyutlu görüntünün bir seviye ayrıştırılması ile LL, LH, HL ve HH alt bantları elde edilir. LL bandı, yaklaşım bileşenine ait katsayıları içerir ve önemli bilgi bu bantta tutulur. HL, LH ve HH bantları sırasıyla yatay, dikey ve köşegen detay bileşenlerine ait katsayıları içerir. Şekil 2.10' da gösterilen bir görüntünün çoklu-seviye ayrıştırması, yaklaşım bileşeninin birçok kez ayrıştırılmasıyla gerçekleştirilir (Kulkarni ve Shelke, 2014). Şekil 2.11' de çalışmada kullanılan bir görüntü ve bu görüntünün 2B ADD ile 4 seviyeye kadar ayrıştırılması ile elde edilen alt görüntüler verilmiştir.



Şekil 2. 9. İki boyutlu görüntünün ADD için bir seviyeli filtre yapısı (Öztürk 2015)



Şekil 2. 10. Görüntünün 2B ADD ile çoklu-seviyeli ayrıştırma adımları (Kulkarni ve Shelke 2014)



Şekil 2. 11. (a) Orijinal görüntü b) Görüntünün 2B ADD ile ayrıştırılması

2.3.2. Ridgelet dönüşümü

Dalgacık Dönüşümü bir boyutlu parçalı düzgün fonksiyonlarda noktasal tekillikleri yakalamada başarılı bir yöntem olmasına rağmen, çizgisel veya eğrisel yapılar

(örneğin kenarlar) gibi yüksek oranda anizotropik elemanlara sahip nesnelere verimli bir şekilde temsil edememektedir. Bunun nedeni, dalgacıkların geometrik olmaması ve kenar eğrisi düzenliliğinden yararlanamamasıdır (Candes ve Donoho, 2004). Dalgacık Dönüşümünün bu zayıflığını gidermek için iki boyutlu çizgisel tekilliklerde daha etkili olan Ridgelet Dönüşümü (RiD) önerilmiştir.

$a > 0$ ölçek parametresi, $b \in \mathbb{R}$ konum parametresi ve $\theta \in [0, 2\pi)$ yön parametresi olmak üzere $\mathbb{R}^2 \rightarrow \mathbb{R}$ ye tanımlı ridgelet fonksiyonu (ψ) eşitlik (2.14) ile tanımlanır.

$$\psi_{a,b,\theta}(x) = \psi_{a,b,\theta}(x_1, x_2) = a^{-\frac{1}{2}} \cdot \psi\left(\frac{x_1 \cos\theta + x_2 \sin\theta - b}{a}\right) \quad (2.14)$$

Ridgelet fonksiyonu ($\psi_{a,b,\theta}$), θ açıda yönlendirilirse çizgiler boyunca sabit olur ($x_1 \cos\theta + x_2 \sin\theta = \text{sabit}$). Ridgelet fonksiyonunun tersi dalgacık fonksiyonunu vermektedir. Bir $f(x)$ fonksiyonunun sürekli ridgelet katsayıları eşitlik (2.15) ile hesaplanmaktadır (Candes ve Donoho, 1999).

$$RiD_f(a, b, \theta) := \langle f, \psi_{a,b,\theta} \rangle = \int_{\mathbb{R}^2} f(x) \bar{\psi}_{a,b,\theta}(x) dx \quad (2.15)$$

Ridgelet Dönüşümü, Radon alanında dalgacık analizi olarak da yapılandırılabilir. Buradaki temel fikir, Radon Dönüşümünü kullanarak çizgisel tekilliği noktasal tekilliğiyle eşleştirmek ve Radon alanındaki noktasal tekilliği etkin bir şekilde ele almak için Dalgacık Dönüşümünün kullanılmasıdır (Do ve Vetterli, 2003)

Verilen $f(x_1, x_2)$ fonksiyonunun Radon Dönüşümü, $(\theta, t) \in [0, 2\pi) \times \mathbb{R}$ tarafından indekslenen çizgi integrallerinin koleksiyonudur ve eşitlik (2.16) ile tanımlanmaktadır. Burada δ , Dirac dağılımıdır.


$$R_f(\theta, t) = \int_{\mathbb{R}^2} f(x_1, x_2) \delta(x_1 \cos\theta + x_2 \sin\theta - t) dx_1 dx_2 \quad (2.16)$$

Radon Dönüşümü, izdüşüm-dilim teoremine dayanarak Fourier alanında oluşturulur. Buna göre görüntüye önce İki Boyutlu Hızlı Fourier Dönüşümü (2B HFD) uygulanır. Daha sonra elde edilen frekans fonksiyonu, orijin içinden geçen ve açısız olarak homojen bir şekilde yayılan ışınların kutupsal koordinattaki frekans değerlerini değerlendirmek için kullanılır. İki boyutlu görüntüler kartezyen koordinat düzleminde

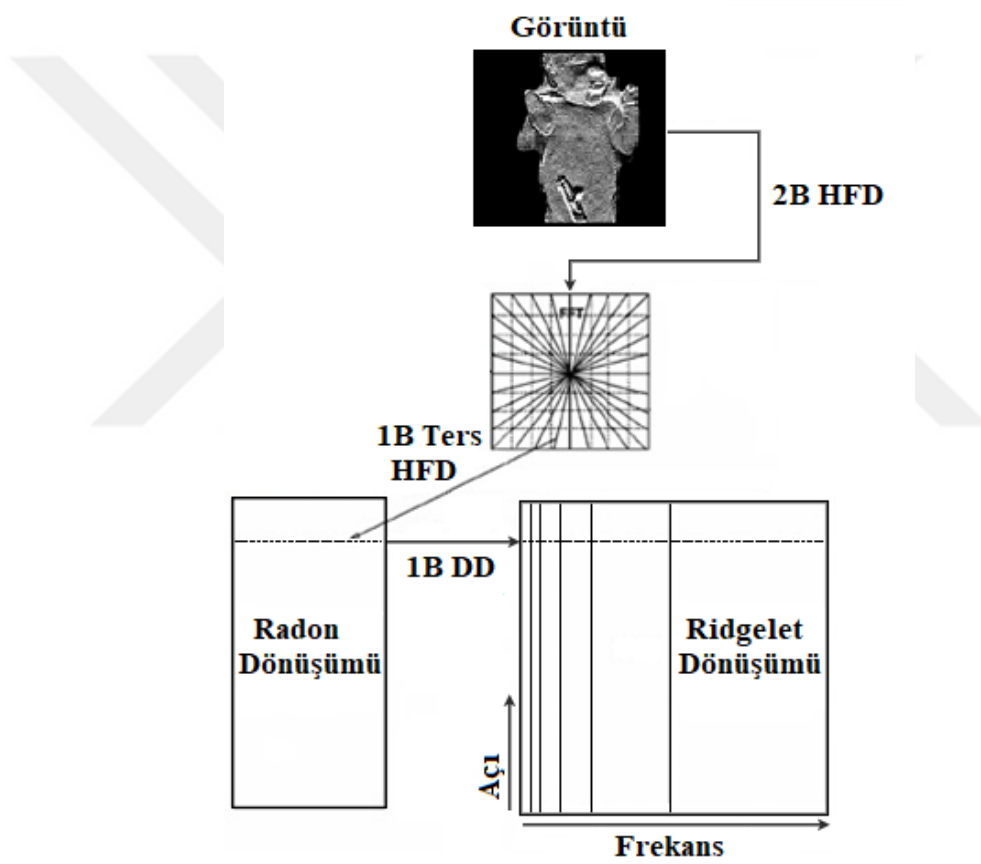
tanımlandığından, kartezyen düzlemindeki (x_1, x_2) noktaların kutupsal koordinat düzlemindeki (θ, t) iz düşümlerinin hesaplanması gerekmektedir. Kartezyen koordinattan kutupsal koordinata dönüşüm interpolasyon yoluyla elde edilebilmektedir. Kutupsal koordinattaki örnekler göz önüne alındığında ışınların sayısı, izdüşümlerin sayısına karşılık gelir ve her bir ışın üzerindeki örneklerin sayısı bu açı başına düşen kaymaların sayısına karşılık gelir. Her ışın için 1B Ters HFD uygulanması ile Radon dönüşümü dilimleri elde edilir. Bu durumda, Ridgelet Dönüşümü açısal değişkenin (θ) sabit olduğu ve t' nin değiştiği Radon Dönüşümü dilimlerine 1 Boyutlu Dalgacık Dönüşümü uygulaması ile elde edilir (Fadili ve Starck, 2009). Sürekli ridgelet katsayıları eşitlik (2.17) ile tanımlanır (Carre ve Andres, 2004).

$$RiD_f(a, b, \theta) = \int_{\mathbb{R}^2} \psi_{a,b}(t) R_f(\theta, t) dt \quad (2.17)$$

Ayrık Ridgelet Dönüşümünde (ARiD), kartezyen düzleminde-kutupsal düzlemine dönüşümünün gerçekleştirilmesi için sahte (pseudo) kutuplu bir koordinat düzleminin kullanılması önerilmiştir. Bu işlem rektopolar koordinat düzlemi olarak adlandırılmaktadır. Rektopolar koordinat düzleminin ızgara çizgileri, radyal çizgiler kümesi ile eksenlere paralel kartezyen çizgilerin arasındaki kesişim noktalarıdır. Bu koordinat düzleminin geometrisi, veri noktalarının daire ile işaretlendiği Şekil 2.12' de gösterilmiştir (Strack ve ark, 2002). Bu düzlemde, kutupsal düzlemde doğrusal olarak büyüyen yarıçapın eş merkezli çevreleri doğrusal olarak büyüyen kenarların eş merkezli kareleriyle değiştirilir. Işınlar, açısal olarak değil eğim bakımından eşit olarak yayılır. Bu iki değişiklik, kutupsal düzleme benzeyen bir ızgara verir. Bu ızgara için HFD interpolasyon olmadan uygulanır. Işınlar için 1B Ters HFD uygulanırken izdüşüm açılarının eşit aralıklarla yerleştirilmediği Radon Dönüşümünün bir başka şekli elde edilmiş olur (Fadili ve Starck, 2009). Ayrık Ridgelet Dönüşümü, Şekil 2.13' te verilen uygulama adımları kullanılarak elde edilmektedir.



Şekil 2. 12. 8×8 görüntü için frekans alanındaki rektopolar koordinat düzlemi gösterimi (Strack ve ark, 2002)



Şekil 2. 13. Ayrık ridgelet dönüşümünün uygulama adımları (Fadili ve Starck, 2009)

2.3.3. Curvelet dönüşümü

Görüntü üzerindeki kenar yapıları düz çizgilerden ziyade eğriseldir. Kenarlar ve çizgisel tekillikler içeren bölgeleri yakalamada Ridgelet Dönüşümü başarılı bir yöntem olmasına rağmen, eğrisel tekillikler içeren bölgeleri yakalamada yetersiz kalmıştır. Bu sorunu çözmek için Curvelet Dönüşümü (CuD) geliştirilmiştir (Fadili ve Starck, 2009).

Curvelet Dönüşümü ilk kez Candes ve Donoho (1999) tarafından tanıtılmış ve 2003' te revize edilmiştir. Curvelet Dönüşümü, görüntüleri farklı ölçeklerde ve yönlerde (açıda) temsil etmek için tasarlanmış Dalgacık Dönüşümünün yüksek boyutlu bir genelleştirmesidir. Konum, ölçek ve yön parametrelerine göre indekslenen çerçeve elemanları ile çok ölçekli bir piramit olarak görülmektedir. Curvelet piramidi çok yüksek yönlü hassasiyet ve anizotropi derecesine sahiptir (Alzubi ve ark, 2011).

Curvelet Dönüşümü, Birinci Nesil Curvelet Dönüşümü (1NCuD) ve İkinci Nesil Curvelet Dönüşümü (2NCuD) olmak üzere iki nesil olarak tanımlanmaktadır. Birinci Nesil Curvelet Dönüşümünün uygulaması, Ridgelet geometrisinin anlaşılması zor olmasından dolayı sınırlıdır. (Ma ve Plonka, 2010). İkinci Nesil Curvelet tanımı ile Curvelet Dönüşümünün kullanımı ve anlaşılması kolaylaşmıştır. Daha sonralarda İkinci Nesil Curvelet Dönüşümüne dayanan Hızlı Ayrık Curvelet Dönüşümü (HACuD) önerilmiştir (Candes ve ark., 2006).

3.3.3.1. Birinci Nesil Curvelet Dönüşümü

Birinci Nesil Curvelet Dönüşümü ile kavisli kenarlar ince ölçeklerde neredeyse düz çizgi olarak temsil edilebilmektedir (Fadili ve Starck, 2009). Şekil 2.14' te bu işlem anlatılmaktadır. Kavisli kenarlar boyunca bant geçiren görüntüler, genişliğin yaklaşık 2^{-2s} olduğu çizgileri göstermektedir. Bölümlenmiş bant geçiren görüntüler $2^{-s} \times 2^{-s}$ boyutlarında karelere ayrılır. Kavisli kenarlar ile kesişmeyen kareler etkili bir enerjiye sahip olmadıklarından dikkate alınmazlar. Kenarlar ile kesişen karelerin pencerelenmesiyle neredeyse düz bir çizgi alınması sağlanır. Bu düz çizgiler, Ridgelet Dönüşümü için istenen girişlerdir. Dolayısıyla önemli olan kareler, uzunluk-genişlik oranının $2^{-s} \times 2^{-2s}$ olduğu çizgileri gösterir. Çizgilerin Ridgelet Dönüşümü ile analiz edilmesi sonucu sadece birkaç önemli katsayı elde edilir. (Candes ve Donoho, 2000).

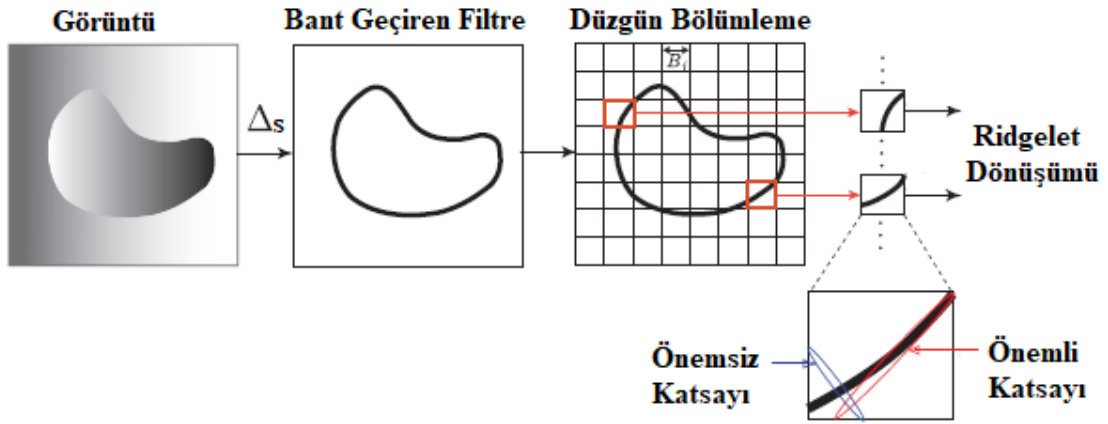
Birinci Nesil Curvelet Dönüşümünün akış şeması Şekil 2.15' te verilmiştir. Birinci Nesil Curvelet Dönüşümünün aşamaları şu şekildedir: (Candes ve Donoho, 2000; Donoho ve Duncan, 1999; Fadili ve Starck, 2009).

1. Alt Bantlara Ayırıştırma: Görüntü filtre bankaları ile farklı ölçekte alt bantlara ayrılır. Alt bantlara ayırıştırma işleminde görüntü birkaç çözünürlük seviyesine bölünmektedir. Her seviye farklı frekans detayları içermektedir.

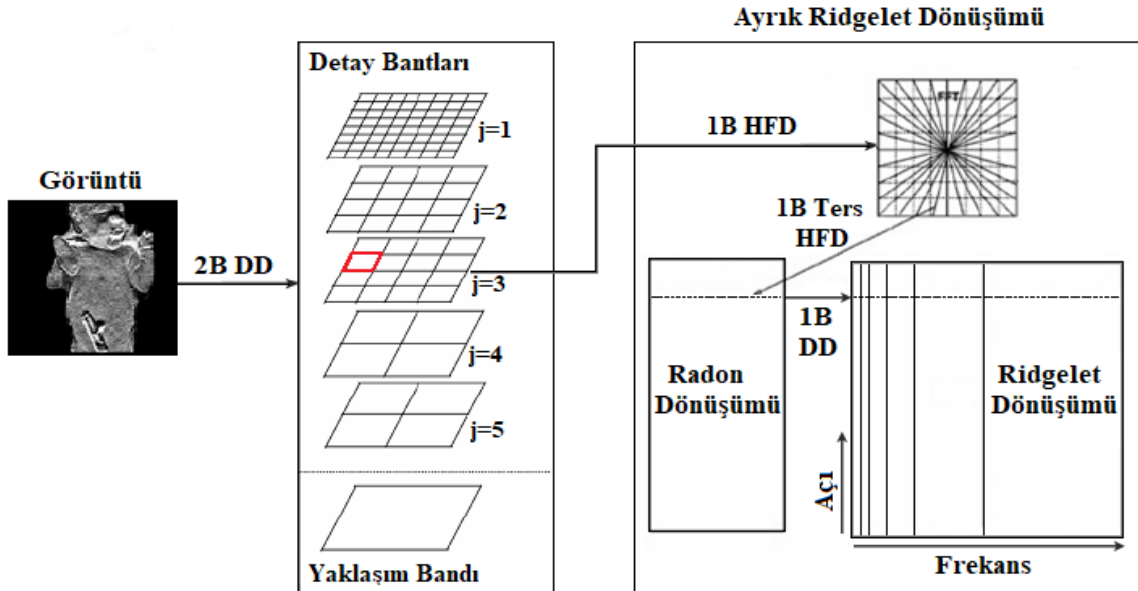
2. Düzgün bölümlenme: Her bir alt bant düzgün bölümlenme ile alt karesel pencerelere ayrılır. Her alt karesel pencerelerin büyüklüğü farklı olabilir. Her bir alt bantın pencere fonksiyonu ile çarpılmasıyla görüntü düzgün hale getirilir.

3. Renormalizasyon: Her bir karesel pencereden elde edilen sonuç renormalize edilir.

4. Ridgelet Dönüşümü: Renormalize edilmiş karesel pencerelere ortonormal Ridgelet Dönüşümü uygulanır.



Şekil 2. 14. Kavisli kenarların alt bantlarına ayrılarak düzgün bölünmesi ve ridgelet dönüşümünün uygulanması (Fadili ve Starck, 2009)



Şekil 2. 15. Birinci nesil curvelet dönüşümünün akış şeması (Fadili ve Starck, 2009)

2.3.3.2. İkinci nesil curvelet dönüşümü

Birinci Nesil Curvelet Dönüşümünün bazı dezavantajları vardır. Bunlardan birincisi, bu dönüşümün ölçek, konum ve yön parametreleri arasında karmaşık yedi- indeksli bir yapı içermesidir. Ayrıca parabolik ölçekleme oranının (*genişlik* \approx *uzunluk*²) yaklaşık bir değer olmasıdır. Gerçekte Birinci Nesil Curvelet Dönüşümünde geniş bir uzunluk oranı varsayılır. Bu durum, matematiksel ve nicel analizleri hassaslaştırmaktadır. İkincisi ise Birinci Nesil Curvelet Dönüşümünün düzgün bölünme aşamasında engelleme etkilerinden kaçınmak için üst üste binen pencereler kullanılmasıdır. Bu da Birinci Nesil Curvelet Dönüşümünün işlem yükünü artmasına yol açmaktadır (Fadili ve Starck, 2009).

İkinci Nesil Curvelet Dönüşümü ise ölçek, yön ve konum olmak üzere üç parametreye sahip daha basit ve doğal bir indeksleme yapısı sergiler. Dolayısıyla matematiksel analizi basitleştirir. Ayrıca, İkinci Nesil Curvelet Dönüşümünde sıkı bir çerçeve (tight frame) genişletme yöntemi uygulandığından daha düşük işlem yüküne sahiptir. Birinci Nesil Curvelet Dönüşümünün aksine, İkinci Nesil Curvelet Dönüşümü Ridgelet Dönüşümünü kullanmaz (Fadili ve Starck, 2009).

2.3.3.2.1. Sürekli versiyon


Sürekli Curvelet Dönüşümü \mathbb{R}^2 için x uzamsal değişkenini, w frekans uzayı değişkenini, r ve θ frekans uzayı kutupsal koordinat değişkenlerini, $W(r)$ radyal pencere fonksiyonunu ve $V(t)$ açılal pencere fonksiyonunu göstermektedir. W , $r \in (\frac{1}{2}, 2)$ aralığında V ise $t \in [-1, 1]$ aralığında tanımlıdır (Candes ve ark., 2006).

$j \geq j_0$ olmak üzere frekans uzayında, W ve V pencere fonksiyonlarını frekans uzayı filtresi oluşturacak şekilde birleştirilerek 2^{-j} ölçeğinde U_j kutupsal dilim filtresi eşitlik (2.18) ile tanımlanır.

$$U_j(r, \theta) = 2^{-3j/4} W(2^{-j}r) V\left(\frac{2^{|j/2|}\theta}{2\pi}\right) \quad (2.18)$$

Sürekli Curvelet Dönüşümü için kutupsal düzlemde frekans uzayı dilimi Şekil 2.16 ile verilmiştir. Şekil 2.16' da görülen koyu gri alan, radyal pencerenin (gri olarak

gösterilen halka) ve açısız pencerenin (açık gri) ürünü olarak elde edilen bir dilimi göstermektedir (Fadili ve Strack, 2009).



Şekil 2. 16. Sürekli curvelet dönüşümü için kutupsal düzlemde frekans uzayı dilimi (Fadili ve Strack, 2009)

Eşitlik 2.18 ile elde edilen U_j kutupsal dilim filtresinin Fourier dönüşümü ile $U_j(w) = \hat{\varphi}_j(w)$ eşitliğini sağlayarak bir curvelet fonksiyonu $\varphi_j(x)$ tanımlanır. Ana Curvelet fonksiyonu 2^{-j} ölçeğinde, θ_ℓ yönünde ve $x_k^{j,\ell} = R_{\theta_\ell}^{-1}(k_1 \cdot 2^{-j}, k_2 \cdot 2^{-j/2})$ konumunda eşitlik (2.19) ile tanımlanır.

$$\varphi_{j,\ell,k}(x) = \varphi_j(R_{\theta_\ell}(x - x_k^{j,\ell})) \quad (2.19)$$

Burada $\ell = 0,1,2 \dots$ olmak üzere $0 \leq \theta_\ell \leq 2\pi$ aralığında $\theta_\ell = 2\pi 2^{-\lfloor \frac{j}{2} \rfloor} \ell$ eşit aralıklı rotasyon açısı, $k = (k_1, k_2) \in \mathbb{Z}^2$ ise öteleme parametresidir. Eşitlik (2.20) ile gösterilen R_{θ_ℓ} , θ_ℓ açılarındaki rotasyondur. $R_{\theta_\ell}^{-1}$, R_{θ_ℓ} 'in transpozunu gösterir.

$$R_{\theta_\ell} = \begin{pmatrix} \cos\theta_\ell & \sin\theta_\ell \\ -\sin\theta_\ell & \cos\theta_\ell \end{pmatrix} \quad R_{\theta_\ell}^{-1} = R_{\theta_\ell}^T \quad (2.20)$$

$f \in L^2\mathbb{R}^2$ olmak üzere curvelet katsayıları, fonksiyon ile curveletlerin iç çarpımı olarak elde edilir. Curvelet katsayıları eşitlik (2.21) ile hesaplanır. Burada $\bar{\varphi}$ kompleks eşleniği ifade etmektedir (Candes ve ark., 2006).

$$c(j, \ell, k) = \langle f, \varphi_{j, \ell, k} \rangle = \int_{\mathbb{R}^2} f(x) \overline{\varphi_{j, \ell, k}(x)} dx \quad (2.21)$$

Curvelet katsayıları $\bar{\varphi}$ ifadesinden dolayı kompleks değerlidir. $\overline{\varphi_{j, \ell, k}(r, \theta)} + \overline{\varphi_{j, \ell, k}(r, \theta + \pi)}$ olacak şekilde orijine göre simetrik curveletler kullanılarak reel değerli curvelet katsayıları elde edilir (Fadili ve Starck, 2009).

2.3.3.2.2. Ayrık versiyon

İkinci Nesil Curvelet Dönüşümünün ayrık versiyonu, kartezyen yapıda tanımlıdır. Kartezyen yapı, eş merkezli daire yerine eş merkezli karelere ve dilimlere dayanır. Bu nedenle, kutupsal dilimler yerine ikizkenar yamuklarla pencere fonksiyonları oluşturulur (Fadili ve Starck, 2009).

h bir boyutlu alçak geçiren filtre olmak üzere $H_j(v) = \hat{h}(2^{-j} v_1) \hat{h}(2^{-j} v_2)$ alçak geçiren pencereleri ifade etmektedir. $\forall j \geq 0$ olmak üzere eşitlik (2.22) ile gösterilen radyal pencerenin kartezyen yapıdaki eşdeğeri $\hat{w}_j(v) = \hat{w}_j(2^{-j} v)$ bir bant geçiren frekans penceresini göstermektedir.

$$\hat{w}_j(v) = \sqrt{H_{j+1}(v)^2 - H_j(v)^2}, \quad \hat{w}_0(v) = \hat{h}(v_1) \hat{h}(v_2) \quad (2.22)$$

Her kartezyen yapı kuzey, güney, batı ve doğu olmak üzere 4 çeyrek düzleme sahiptir. Her çeyrek düzlem, aynı bölgelerle $2^{\lfloor j/2 \rfloor}$ dilimlere ayrılmıştır. Örneğin, doğu çeyrek düzleminde dilimleme $-\pi/4 \leq \theta_\ell \leq \pi/4$ frekans düzleminde yerleşmektedir. Diğer çeyrek düzlemlerde ise $\pm\pi/2$ radyal rotasyonu ve orijin etrafında simetriği alınarak elde edilmektedir. Doğu çeyrek düzleminde $\ell = -2^{\lfloor j/2 \rfloor}, \dots, 2^{\lfloor j/2 \rfloor} - 1$ için eşit aralıklı eğimler dizisi $\tan\theta_\ell = 2^{-\lfloor j/2 \rfloor} \ell$ olarak tanımlanır. Buna göre ℓ' inci yöndeki açısal pencere eşitlik (2.23) ile tanımlanır.

$$\hat{v}_{j, \ell}(v) = \hat{v}(2^{\lfloor j/2 \rfloor} \frac{v_2 - v_1 \tan\theta_\ell}{v_1}) \quad (2.23)$$

\hat{w} ve \hat{v} pencereleri birleştirilerek eşitlik (2.24)' te tanımlanan $\hat{u}_{j, \ell}$ frekans uzayı dilim filtreleri elde edilir.

$$\hat{u}_{j,\ell}(v) = \hat{w}_j(v)\hat{v}_{j,\ell}(v) = \hat{w}_j(v)\hat{v}_{j,0}(S_{\theta_\ell}v) \quad (2.24)$$

Bu tanımla, $\hat{u}_{j,\ell}$ ' nin ikizkenar yamuk şeklindeki dilim yakınında $v = (v_1, v_2) | 2^j \leq v_1 \leq 2^{j+1}, -2^{-j/2} \leq v_2/(v_1 - \tan\theta_\ell) \leq 2^{-j/2}$ desteklendiği görülebilmektedir. S_{θ_ℓ} , dilim matrisidir ve eşitlik (2.25) ile ifade edilir.

$$S_{\theta_\ell} = \begin{pmatrix} 1 & 0 \\ -\tan\theta_\ell & 1 \end{pmatrix} \quad (2.25)$$


Tüm çeyrek düzlemler için $\hat{u}_{j,\ell}$ ' nin birleşimi Şekil 2.17' de gösterilen frekans dilimlenmesine neden olur. Böylece $\hat{u}_{j,\ell}$ ' nin tüm 2^{-j} ölçeklerinde ve tüm ℓ ötelemelerinde Ayrık Curvelet Dönüşümü için filtre ailesi frekans uzayında elde edilmiş olur.

$\hat{u}_{j,\ell}$ ' den kartezyen curvelet fonksiyonu ($\hat{\varphi}_j$), eşitlik (2.26) ile tanımlanır. Burada $\hat{\varphi}_j^D$ ile kartezyen curvelet fonksiyonu uzamsal olarak gösterilmektedir.

$$\hat{\varphi}_j^D(v) = \hat{u}_{j,0}(v) \quad (2.26)$$

Kartezyen curvelet fonksiyonun ötelenmiş ve dilimlenmiş versiyonu ile Ayrık Curvelet Dönüşümü katsayıları eşitlik (2.27) ile ifade edilir. (Fadili ve Starck 2009).

$$\hat{\varphi}_{j,\ell,k}^D(x) = 2^{3j/4} \varphi_j^D(S_{\theta_\ell}^T x - m), \quad m = k_1 2^{-j}, k_2 2^{-j/2} \quad (2.27)$$



Şekil 2.17. Ayrık curvelet dönüşümü için kartezyen düzlemde frekans uzayı dilimi (Fadili ve Starck, 2009)

2.3.3.2.3. Hızlı ayrık (sayısal) curvelet dönüşümü

İkinci Nesil Curvelet Dönüşümünün sayısal uygulaması eşitlik (2.28)' de verilen katsayılar ile hesaplanmaktadır (Fadili ve Starck, 2009).

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

HACuD' yi gerçekleştirmek için öncelikle görüntünün 2 boyutlu Hızlı Fourier Dönüşümü alınır. Daha sonra 2 boyutlu fourier frekans düzlemi, dilimlere ayrılır. Dilimler, fourier düzleminin radyal ve açısall bölmelere ayrılması sonucunda parabolik bir şekilde sahiptir. Son olarak, curvelet katsayılarını elde etmek için her bir dilime 2 boyutlu Ters Hızlı Fourier Dönüşümü uygulanır (Gedik ve Atasoy, 2013).

HACuD, Eşit Zaman Aralıklı Hızlı Fourier Dönüşümü ve Kaydırma (Wrapping) yöntemleri adı altında iki formda uygulanabilmektedir. Bu iki yöntem farklı yollarla dönüşüm katsayılarını hesaplamasına rağmen, her ikisi de $n \times n$ görüntü için $O(n^2 \log n)$ hesaplama karmaşıklığına sahiptir. Bu iki dönüşüm de ölçek, yön ve konum parametreleriyle indekslenen curvelet katsayılarını döndürür, ancak belirli ölçek ve açıda curveletleri çevirmek için kullanılan çevirme ızgarası (translation grid) farklıdır (Candes ve ark, 2006).

Eşit Zaman Aralıklı Hızlı Fourier Dönüşümü yönteminde kullanılan çevirme ızgarası, curveletin yönü ile aynı eksene getirmek için eğilir (Candes ve ark, 2006). Bu dönüşümde kullanılan eğimli ızgara, $\hat{u}_{j, \ell}$ eksenleri ile hizalanmıştır. Bu uygulama standart olmayan bir interpolasyon kullanır. Ayrıca interpolasyon adımını tersine çevirmek için Ters Hızlı Fourier Dönüşümünde eşlenik gradyanlar iterasyonunu kullanır. Bundan dolayı Kaydırmalı yönteme kıyasla daha yüksek bir hesaplama yüküne sahiptir (Fadili ve Starck, 2009).


Kaydırma yönteminde kullanılan çevirme ızgarası her bir çeyrek düzlem içindeki her açı için aynıdır, ancak her bir curvelete uygun yön verilir (Candes ve ark., 2006). Bu dönüşümde kullanılan kartezyen ızgara giriş ile hizalanmıştır. Bundan dolayı kaydırma yönteminde dönüşümün uygulanması ve anlaşılması daha basittir (Fadili ve Starck, 2009). Bu çalışmada, Kaydırma yöntemi ile HACuD kullanılmıştır.

Kaydırma yöntemi ile HACuD' nin oluşturulması şu şekildedir:

1. $\hat{f}[n_1, n_2]$ Fourier örneklerini elde etmek için iki boyutlu Hızlı Fourier Dönüşümü uygulanır. ($-n/2 \leq n_1, n_2 < n/2$)
2. Her ölçek (j) ve açı (ℓ) çiftine interpolasyon uygulanır ve $\tilde{u}_{j,\ell}[n_1, n_2]\hat{f}[n_1, n_2]$ ürünü oluşur.
3. Bu ürünün orijin etrafında kaydırılması ile $\hat{f}_{j,\ell}[n_1, n_2] = W(\tilde{u}_{j,\ell}\hat{f})[n_1, n_2]$ elde edilir. ($-\pi/4, \pi/4$) aralığında θ için, n_1 ve n_2 sırasıyla $0 \leq n_1 < L_{1,j}$ ve $0 \leq n_2 < L_{2,j}$ aralığındadır.
4. Her bir $\hat{f}_{j,\ell}$ fonksiyonuna iki boyutlu Ters Hızlı Fourier Dönüşümü uygulanır. Böylece HACuD katsayıları ($c^D(j, \ell, k)$) elde edilir (Candes ve ark., 2006).

Kaydırma yönteminde curvelet katsayıları esas olarak eşitlik (2.28) ile aynıdır, ancak $S_{\theta_\ell}^{-T}m$ 'nin yerine dikdörtgen ızgara üzerindeki m değerleri ile değiştirilir (Eşitlik 2.29). Ama bu durum, $\hat{u}_{j,\ell}$ frekans uzayı dilim filtrelerinin Ters Hızlı Fourier Dönüşümünün uygulanacağı $2^j \times 2^{j/2}$ boyutundaki dikdörtgene uymayacağından bir zorluk çıkarmaktadır. Kaydırma yöntemi ile pencerelemiş frekans verisinin $\hat{f}\hat{u}_{j,\ell}$ periyodize edilmesi ve orijinde $a \sim 2^j \times 2^{j/2}$ dikdörtgen etrafında kaydırılarak örnek dizininin yeniden indekslenmesi sağlanır (Fadili ve Starck, 2009).

$$c^D(j, \ell, k) = \int_{\mathbb{R}^2} \hat{f}(v) \hat{\varphi}_j^D(S_{\theta_\ell}^{-1}v) e^{imv} dv, \quad m = k_1 2^{-j}, k_2 2^{-j/2} \quad (2.29)$$



Şekil 2. 18. Kaydırma yönteminde verilerin (a) Orijinal bölümü (b) Orijin etrafında kaydırılmış bölümü (Fadili ve Starck, 2009)


Kaydırma yönteminin işleyişi Şekil 2.18' de gösterilmiştir. Şekil 2.18 (a) ve (b) sırasıyla orijinal ve kaydırılmış verilerin bölümlerini göstermektedir. Başlangıçta veri paralelkenarın içindedir. Paralelkenar curveletin frekans desteğini içeren dilimi içerir. Kesik çizgi ile gösterilen ikizkenar yamuk ise dilimleri gösterir. Açık gri renkte olan paralelkenarlar, periyodize edilmeden kaynaklanan kopyaları gösterir. Başlangıçta paralelkenar içinde olan veri, periyodize edilmesi ve orijin etrafında kaydırılması ile dikdörtgene dönüştürülür. Dikdörtgen içindeki dilim orijinde merkezlenir ve kaydırılmış veri parçalara ayrılmış olarak görünür (Fadili ve Starck, 2009).

2.3.4. Contourlet dönüşümü

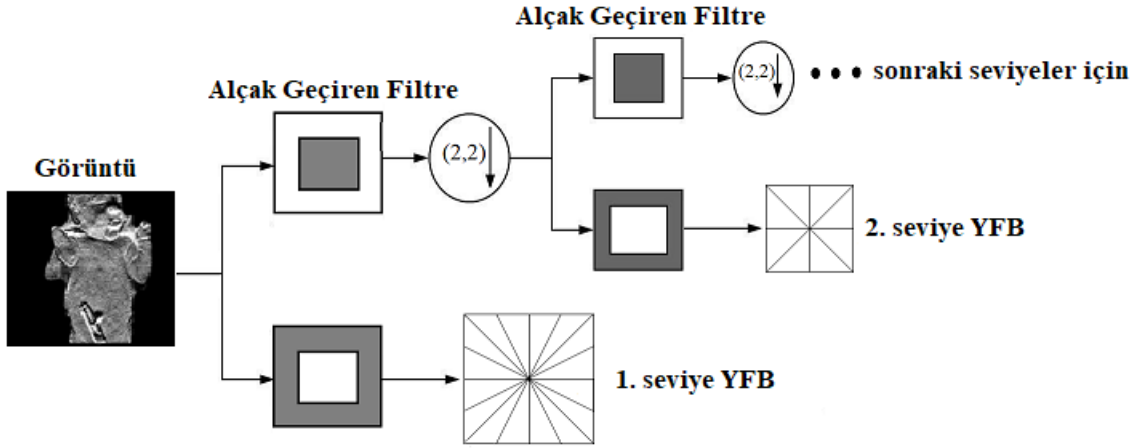
ADD' nin bilgiyi sadece belirli yönlerde yakalayabilmesi ve çizgisellikler üzerinde bilgileri yakalama konusunda belirli bir devamlılığın sağlanamaması CoD' nin doğmasına neden olmuştur. Bundan dolayı CoD, çok ölçekli ve yönsel filtre bankaları kullanılarak 2B DD' nin geliştirilmiş bir versiyonudur. Doğal görüntülerde noktasal süreksizlikler genellikle fiziksel nesnelerin düzgün sınırlarına bağlı olarak düzgün eğriler (yani konturlar) boyunca konumlandırılır. Bundan dolayı doğal görüntüler, görsel bilginin temel özelliği olan yapısal geometrik yapılar içerir. 2B ADD konturları farklı boyutlarda karesel alanlar şeklinde ifade eder. Çözünürlük arttıkça, noktasal süreksizlikleri yakalamak için birden fazla iyi noktalar kullanması gerekmektedir. Ancak kenar noktalarındaki süreksizlikleri iyi yakalanmasına rağmen konturların geometrik düzgünlüğünü elde edemezler. CoD ise konturları takip eden çeşitli yönlerde ve farklı uzatılmış şekillerle konturların düzgünlüğünü yakalamaktadır. ADD ile CoD' lerin görüntü yakalama performansları Şekil 2.19' da gösterilmiştir (Do ve Vetterli, 2005).

CoD genel olarak bir görüntü genişlemesidir. Ortaya çıkan görüntü genişlemesi, kontur bölümlerinden oluşan bir çerçevedir ve Contourlet olarak adlandırılır (Do ve Vetterli, 2005). CoD' de görüntü, bir çift filtre banka yapısı kullanılarak ayrıştırılır. Piramidal Yönsel Filtre Bankası (PYFB) olarak adlandırılan çift filtre banka yapısında, ilk olarak noktasal süreksizlikleri yakalamak için Laplas Piramidi (LP) kullanılır ve sonrasında noktasal süreksizlikleri doğrusal yapılara bağlamak için Yönsel Filtre Bankası (YFB) tarafından takip edilir. YFB, görüntülerin yüksek frekanslı bileşenlerini yakalamak için tasarlanmıştır. Böylece PYFB, her ölçekte farklı yönlere izin verdiği için görüntüler için esnek bir çoklu çözünürlük ve yönlü bir ayrıştırma sağlamaktadır. (Do ve

Vetterli, 2002). Şekil 2.20’ de Contourlet Piramidal Yönlü Filtre Bankası şeması gösterilmiştir.



Şekil 2.19. (a) ADD ve (b) CoD’ lerin görüntü yakalama performansları



Şekil 2.20. Contourlet piramidal yönlü filtre bankası şeması

2.4. İstatistikî Özellik Çıkarma Yöntemleri

Bu tez çalışması için gerçekleştirilen sınıflandırma uygulamalarının özellik çıkarma aşamasında çoklu çözünürlük analizi yöntemlerinin yanı sıra bazı istatistiksel yöntemler de kullanılmıştır. Bunlar; ortalama, ortanca, standart sapma, varyans, skewness ve kurtosis değerleridir.

Bir x sayı dizisi için; n eleman sayısını göstermek üzere ortalama, eşitlik (2.30) ile formüle edilmektedir.

$$\text{Ortalama} = \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{x_1 + x_2 + \dots + x_n}{n} \quad (2.30)$$

Ortanca değer, küçükten büyüğe doğru sıralanmış bir veri grubunun orta değerini gösterir.

Standart sapma, bir veri grubunda verilerin aritmetik ortalamadan ne kadar uzaklaştığının ölçüsüdür ve eşitlik (2.31) ile formüle edilmektedir.

$$\text{Standart sapma} = \sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (2.31)$$

Varyans, verilerin aritmetik ortalamadan sapmalarının karelerinin toplamıdır. Yani standart sapmanın karesi varyansı verir ve eşitlik (2.32) ile hesaplanır.

$$\text{Varyans} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (2.32)$$

Çarpıklık katsayısı (skewness) ve basıklık katsayısı (kurtosis), ortalama değer civarındaki asimetrinin istatistiksel birer ölçümüdür. Skewness değeri eşitlik (2.33) ve kurtosis değeri eşitlik (2.34) ile hesaplanır. Burada E(.) beklenen değeri gösterir.

$$\text{skewness} = \frac{E[(x-\bar{x})^3]}{\sigma^3} \quad (2.33)$$

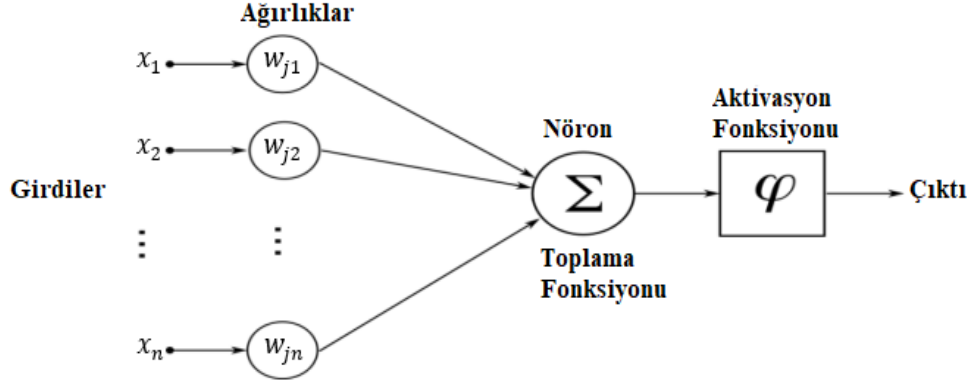
$$\text{kurtosis} = \frac{E[(x-\bar{x})^4]}{\sigma^4} \quad (2.34)$$

2.5. Yapay Sinir Ağı

Yapay sinir ağı, “öğrenme” ve “genelleme” yeteneklerini yansıtan biyolojik sinir yapısının matematiksel temsili olan bir yapay zekâ tekniğidir. YSA, değişkenler arasındaki ilişkinin bilinmediği veya çok karmaşık olduğu doğrusal olmayan sistemleri modelleyebildikleri için araştırmalarda yaygın olarak kullanılmaktadır (Amato ve ark., 2013). Görüntü ve sinyal işleme, optimizasyon, sınıflandırma, modelleme, tahmin gibi birçok uygulama alanında kullanılmaktadır.

Sinir ağları paralel olarak çalışan “nöronlar” veya “düğümler” olarak adlandırılan işlem elemanlarından oluşur (Demuth ve ark., 1998). Yapay sinir ağlarında nöronlar, bağlantılarla birbirine bağlanır. Her bir bağlantı, girdisinin gücü ile ilişkili bir sayısal ağırlığa sahiptir. Her bir nöron, bağlantılarıyla giriş sinyallerini alır ve tek bir çıkış sinyali üretir. Çıkış sinyalini üretmek için önce nöronlar giriş sinyallerinin ağırlıklı toplamını

hesaplar ve bir net girdi değeri belirler. Daha sonra net girdiye bir aktivasyon fonksiyonu uygulanarak çıkış sinyali üretilir (Negnevitsky, 2005). Şekil 2.21’ de basit bir nöron yapısı gösterilmiştir.



Şekil 2. 21. Basit bir nöron yapısı

Aktivasyon fonksiyonlarının kullanılmasının amacı, bir nöronun çıkış genliğini istenen değer aralığına sınırlamaktır. Bu değerler genellikle $[-1, 1]$ veya $[0, 1]$ arasındadır. Çeşitli aktivasyon fonksiyonları mevcuttur. En yaygın aktivasyon fonksiyonları adım (step), işaret (sign), doğrusal (linear) ve sigmoid fonksiyonlardır (Negnevitsky, 2005).

Aktivasyon fonksiyonu seçilirken öncelikle türevlenebilir olma şartı sonrasında türevinin sonlu olması şartı aranmaktadır. Sıklıkla kullanılan çok katmanlı ağ modelinde aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmaktadır (Öztemel, 2003). Sigmoid fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Sigmoid fonksiyonu $+\infty$ ve $-\infty$ arasında herhangi bir değere sahip olan nöron girişini 0 ile 1 arasında bir değere dönüştürür. Bu aktivasyon fonksiyonu, sınıflandırma sonucunda ikili (binary) çıkış elde etmek için kullanılmaktadır (Negnevitsky, 2005).


Bir yapay sinir ağı yapısı birbirleriyle bağlantılı sinir hücrelerinin yer aldığı girdi katmanı, gizli katman ve çıktı katmanı olmak üzere temelde üç katmandan oluşmaktadır. YSA’ da bilgi akışı, giriş verilerinin beslendiği giriş katmanında başlar. Girdi katmanındaki nöronlar verileri alır ve ağırlıklı bağlantılar yoluyla ilk gizli katmanda nöronlara aktarır. Girdi katmanında bulunan nöronların sayısı giriş sayısına eşittir. Gizli katmanda, veriler matematiksel olarak işlenir ve sonuç bir sonraki katmandaki nöronlara aktarılır. Gizli katmanda bulunan nöronların dış ortamla bağlantıları yoktur, sadece girdi

katmanından gelen sinyalleri alarak bir sonraki katmana sinyal gönderirler. Son olarak, çıktı katmanındaki nöronlar ile ağın çıkışı sağlanır (Amato ve ark, 2013).

Yapay sinir ağının yapısı genel olarak tek katmanlı ağ ve çok katmanlı ağ olarak ikiye ayrılmaktadır. Tek katmanlı yapay sinir ağ yapısı sadece girdi ve çıktı katmanlarından oluşur. Katmanların bir veya daha fazla nöronu bulunabilmektedir. Tek katmanlı yapay sinir ağları doğrusal problemlerin çözümünde kullanılmaktadır. Bu yüzden karmaşık işlemleri hesaplama yeteneğinden yoksundurlar (Elmas, 2003). Tek katmanlı yapay sinir ağlarının doğrusal olmayan problemlerin çözümünde başarısız olması üzerine çok katmanlı yapay sinir ağları geliştirilmiştir.

2.5.1. Çok katmanlı yapay sinir ağı

Çok katmanlı yapay sinir ağı, bilgi girişinin yapıldığı girdi katmanı, bir veya daha fazla gizli (ara) katman ve bir çıktı katmanından oluşan ileri beslemeli bir sinir ağıdır. Bir katmandaki nöron sayısı ve katmanların sayısı, çalışılan sistemin karmaşıklığına bağlı olarak değişir. Bu nedenle en uygun ağ mimarisi belirlenmelidir (Amato ve ark, 2013). Şekil 2.22’ de ileri beslemeli çok katmanlı ileri beslemeli ağ yapısı görülmektedir. İleri beslemeli ağlarda bilgi akışı, giriş katmanından çıktı katmanına doğru bağlantı yollarının bir yönde (ileri) akması ile olur. İleri beslemeli yapay sinir ağlarında tersine bir yönelme yoktur. Bir katmandaki yapay sinir hücreleri bir önceki katmanın yapay sinir hücreleri tarafından beslenir (Hakimpoor ve ark., 2011).




Şekil 2. 22. Çok katmanlı ileri beslemeli ağ yapısı

Bu tip çok katmanlı yapay sinir ağının eğitiminde genellikle geri yayılım (Backpropagation-BP) öğrenme algoritması kullanılmaktadır.

2.5.1.1. Geri yayılım öğrenme algoritması

Geriy yayılım algoritması genelleştirilmiş delta kuralı olarak da bilinmektedir. Geriy yayılım algoritması, ağıın çıktısının belirlendiği ileri besleme ve oluşan hatanın geriy yayılarak ağırlıkların güncellendiği geriy besleme aşamalarından oluşmaktadır. İleri besleme aşamasında, eğitim setinin girişleri ağıın girdi katmanına sunulur. Daha sonra çıktı katmanında bir değer üretilinceye kadar ağı giriş verilerini girdi katmanından çıktı katmanına doğru ilerletir. Ağıın çıktı katmanından elde edilen değer ile hedef değer arasındaki fark bir hata değeri olarak hesaplanır. Geriy besleme aşamasında hata değeri, istenen ve gerçek çıktı arasındaki minimum hata değeriine ulaşılana kadar geriy doğru yayılır, böylece kapalı bir döngü sistemi kurulur. Geriy yayılırken hata oranına göre ağırlıklar güncellenir. Ağırlıklar, gradyeni iniş (gradient-descent) metodu kullanılarak ayarlanır (Negnevitsky, 2005; Du ve Swamy, 2013).



Şekil 2. 23. Geriy yayımlı YSA' da j nöronundaki sinyal akışı (Haykin, 1999)

Şekil 2.23' e göre çıktı katmanında bulunan herhangi bir j nöronun ağırlıkları girişlerinin toplamı eşitlik (2.35) ile ifade edilir (Haykin, 1999).

$$net_j(n) = \sum_{i=0}^M w_{ji}(n)x_i(n) \quad (2.35)$$

x_i , j nörona uygulanan girdi değerini, w_{ji} , x_i girdisinin ağırlığını (bias dahil), M ise girişin toplam sayısını göstermektedir.

N iterasyonda çıktı katmanında bulunan j nöronun çıkış değeri (y_j) eşitlik (2.36) ile tanımlanır. φ_j , j nöronun aktivasyon fonksiyonunu gösterir.

$$y_j(n) = \varphi_j(\text{net}_j(n)) \quad (2.36)$$

Çıktı katmanında j nöronun hata değeri eşitlik (2.37) ile tanımlanır.

$$e_{j(n)} = d_j(n) - y_j(n) \quad (2.37)$$

Burada d_j ağıın üretmesi beklenen hedef değeri, y_j ise ağıın ürettiği gerçek değerdir.

Çıktı katmanında bulunan bütün nöronlar için toplam hata ise eşitlik (2.38) ile ifade edilir. C kümesi çıktı katmanındaki bütün nöronları içermektedir.

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (2.38)$$

Ağırlık değişim miktarı $\Delta w_{ij}(n)$, toplam hatanın ağırlıklara göre kısmi türevi alınarak bulunur. Delta kuralına göre ağırlık değişim miktarı, eşitlik (2.39) ile ifade edilir.

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)} \quad (2.39)$$

Burada η geri yayılım algoritmasının öğrenme oranıdır. Eksisi işareti, toplam hatayı azaltacak olan ağırlık değişimi için yönü gösterir. Böylece hata fonksiyonunun minimum olduğu yere doğru hareket edilmektedir.

Eşitlik (2.39)' da yer alan kısmi türeve zincir kuralı uygulanması ve tek tek kısmi türevlerinin açılması ile ağırlık değişim miktarı eşitlik (2.40)' deki gibi yeniden ifade edilebilir.

$$\Delta w_{ji}(n) = \eta \delta_j(n) x_i \quad (2.40)$$

Burada $\delta_j(n)$ yerel eğim değeridir. Yerel eğim değeri ise eşitlik (2.41) ile tanımlanır.

$$\delta_j(n) = e_j(n) \varphi'(net_j(n)) \quad (2.41)$$

Yerel eğim değeri, ağırlıklar için gerekli değişimleri işaret eder. Ağırlıkların güncellenmesi için gerekli eğim değerleri çıkış katmanından gizli katmana doğru hesaplanır.

Gizli katmanda bulunan herhangi bir nöronunun çıktı katmanında olduğu gibi beklenen bir hedef çıktı değeri yoktur. Bu nedenle gizli katmandaki k nöronun yerel eğim değeri ise bu gizli nöronun doğrudan bağlı olduğu tüm nöronların yerel eğim değerinden etkilenerek hesaplanmaktadır (Haykin 1999). Eşitlik (2.42) ile gizli katmanda bulunan herhangi bir k nöronun yerel eğim değeri tanımlanır.

$$\delta_k(n) = \varphi_k'(net_k(n)) \sum_j \delta_j(n) w_{kj}(n) \quad (2.42)$$

Ağırlıkların güncellenmesi eşitlik (2.43) ve eşitlik (2.44) ile ifade edilir (Haykin 1999).

$$\Delta w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (2.43)$$

$$\Delta w_{ji}(n) = w_{ji}(n) + \eta \delta_j(n) x_i(n) \quad (2.44)$$

Rumelhart ve ark. (1986) tarafından geriye yayılım algoritmasının ağırlık güncelleme denklemine momentum sabiti (α) eklenmiştir. Böylece, ağırlık yerel minimuma takılma olasılığı azaltılmıştır. Momentum terimi eklendikten sonra ağırlık güncelleme denklemi eşitlik (2.45) ile ifade edilmektedir.

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \eta \delta_j(n) x_i(n) \quad (2.45)$$

2.6. Performans Değerlendirme Yöntemleri

Bu bölümde, termal görüntülerin çoklu çözünürlük analizlerinin sınıflandırma sonuçlarını değerlendirmek için kullanılan performans değerlendirme yöntemleri sunulmaktadır. Performans değerlendirmesi için doğruluk, hassasiyet ve özgüllük değerleri, ağırlık sınıflama performansının genelleştirilmesi için ise k kat çapraz geçerlilik (k-fold cross-validation) yöntemi kullanılmıştır.

2.6.1. Doğruluk, hassasiyet ve özgüllük

Sınıflandırma uygulamalarının performansını ölçmek için genellikle doğruluk, hassasiyet ve özgüllük değerleri kullanılmaktadır (Sharma ve ark, 2009). Doğruluk, hassasiyet ve özgüllük değerleri sırasıyla eşitlik (2.46), (2.47) ve (2.48) kullanılarak hesaplanmaktadır. Bu değerler genellikle yüzde olarak ifade edilmektedir.

Doğru olarak sınıflandırılan pozitif (hasta) ve negatif (sağlıklı) durumlarının tüm durumlara oranı, doğruluk değerini ifade etmektedir (Kohavi ve Provost, 1998).

$$\text{Doğruluk (\%)} = \frac{DP + DN}{DP + DN + YP + YN} \times 100 \quad (2.46)$$

Burada DP, DN, YP ve YN sırasıyla, doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatifi ifade etmektedir. Bu terimler, veri grubunun hasta ve sağlıklı olmak üzere iki sınıfa ait olduğu düşünüldüğünde şu şekilde tanımlanır:

- Doğru Pozitif (DP): Hasta etiketli bir verinin YSA tarafından hasta olarak sınıflandırılması.
- Doğru Negatif (DN): Sağlıklı etiketli verinin YSA tarafından sağlıklı olarak sınıflandırılması.
- Yanlış Pozitif (YP): Sağlıklı etiketli verinin YSA tarafından hasta olarak sınıflandırılması.
- Yanlış Negatif (YN): Hasta etiketli verinin YSA tarafından sağlıklı olarak sınıflandırılması.

Doğru pozitif sonuçların, doğru pozitif ve yanlış negatif sonuçların toplamına oranı hassasiyet değerini göstermektedir (Sharma ve ark, 2009). Bu değer, sınıflayıcının hastalığı belirleyebilme yeteneğini gösterir.

$$\text{Hassasiyet (\%)} = \frac{DP}{DP + YN} \times 100 \quad (2.47)$$

Doğru negatif sonuçların, doğru negatif ve yanlış pozitif sonuçların toplamına oranı özgüllük değerini ifade etmektedir (Sharma ve ark, 2009). Bu değer, sınıflayıcının sağlıklıyı belirleyebilme yeteneğini gösterir.

$$\text{Özgüllük (\%)} = \frac{DN}{DN + YP} \times 100 \quad (2.48)$$

Sınıflandırıcı modelinin doğru olup olmadığını ve ne tür hatalar yaptığını daha iyi anlayabilmek için karmaşıklık matrisi kullanılmaktadır. Karmaşıklık matrisi, verilerin gerçek sınıflarının ve sınıflayıcı sonuçlarının yer aldığı bir tablo olarak ifade edilmektedir (Kohavi ve Provost, 1998). Karmaşıklık matrisinin gösterimi Çizelge 2.1’ de yer almaktadır.

Çizelge 2. 1. Karmaşıklık matrisi

		Sınıflayıcının Sonucu	
		Pozitif (Hasta)	Negatif (Sağlıklı)
Verilerin Gerçek Sınıfı	Pozitif (Hasta)	DP Doğru Pozitif	YN Yanlış Negatif
	Negatif (Sağlıklı)	YP Yanlış Pozitif	DN Doğru Negatif

2.6.2. k kat çapraz geçerlilik yöntemi

Çapraz geçerlilik yöntemi, verileri iki bölüme ayırarak öğrenme algoritmalarını karşılaştırmak ve değerlendirmek için kullanılan istatistiksel bir yöntemdir. Bölümleme sonucu veri parçalarından biri modeli öğrenmek ve eğitmek için kullanılırken, diğeri de modeli doğrulamak için kullanılmaktadır (Refaeilzadeh ve ark, 2008).

Çapraz geçerliliğin temel biçimi k kat çapraz geçerlilikdir. K kat çapraz geçerlilik yönteminde A ile temsil edilen veri seti, yaklaşık olarak her birinde aynı sayıda veri bulunan ve (A_1, A_2, \dots, A_k) şeklinde k adet parçalara ayrılır. Her işlemde, k adet parçaya bölünmüş veri setlerinin bir tanesi test verisi olarak ayrılır, geriye kalan k-1 parça eğitim verisi olarak kullanılır. Yöntem k kez tekrarlandıktan sonra her bir aşamada elde edilen değerlerin ortalaması alınarak genel sınıflandırma sonucu elde edilir (Refaeilzadeh ve ark, 2008; Kohavi, 1995).

Çizelge 2.2’ de 10 kat çapraz geçerlilik işlemi görsel olarak ifade edilmiştir. Bu işleme göre tüm veri seti 10 eşit veri setine ayrılmakta ve ağı eğitim işlemi için bu 10 setten 9’ u kullanılırken, geriye kalan 1 set ile ağı test edilmektedir. Test işlemi bittiğinde bu kez testte kullanılan set eğitim kümesine dahil edilirken eğitim kümesinden bir set de test kümesine alınmaktadır. Bu işlem 10 kez tekrarlandığında veri setinde bulunan tüm veriler ile ağı hem eğitilmesi hem de test edilmesi sağlanmaktadır.

Çizelge 2. 2. 10-kat çapraz geçerlilik işlemi

Veri	1.kat	2.kat	3.kat	4.kat	5.kat	6.kat	7.kat	8.kat	9.kat	10.kat
1.parça	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
2.parça	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
3.parça	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
4.parça	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
5.parça	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
6.parça	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim
7.parça	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim
8.parça	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim
9.parça	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim
10.parça	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test

Bu tez çalışması kapsamında 10 kat çapraz geçerlilik işlemi gerçekleştirilmiştir. K tane farklı eğitim ve test veri setiyle birlikte üzerinde işlem yapılan sistemlerde sonuç olarak k adet başarı ölçüsü elde edilmiş olmaktadır. Bu durumda üzerinde çalışılan sınıflandırmanın genel başarısını elde etmek için bu k adet ölçüm sonucunun ortalama değeri hesaplanmaktadır.

3. SINIFLANDIRMA SONUÇLARI

Bu tez çalışmasında; yenidoğan prematüre bebeklere ait termal görüntülerin sağlıklı-hasta teşhisine yönelik sınıflandırma çalışmaları yapılmıştır. Çalışmalar alt başlıklarda detaylandırılmıştır. İteratif işlemler 2.5 GHZ' lik bir işlemciye ve 6 GB RAM' e sahip bir bilgisayarda MATLAB platformunda gerçekleştirilmiştir. Önerilen sistemlerin blok diyagramı Şekil 3.1' de gösterilmektedir.



Şekil 3. 1. Önerilen sistemin blok diyagramı

3.1. Bebeklerin Sağlıklı-Hasta Olarak Belirlenmesi

Bu çalışmada, segmente edilmiş termal görüntülerden çoklu çözünürlük analizi yöntemleri ve istatistikî metotlar yardımıyla özellikler çıkarılmış ve farklı YSA modelleri ile sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma başarılarını değerlendirmek için doğruluk, hassasiyet ve özgüllük değerleri kullanılmıştır.

3.1.1. Uygulamada kullanılan görüntüler

Bu tez çalışmasında, 19 sağlıklı ve 19 hasta bebeğe ait 190 görüntü kullanılmıştır. Her bir bebek için 5 farklı görüntü kaydedilmiştir. Böylece, toplam 95 adet sağlıklı etiketli ve 95 adet hasta etiketli görüntü elde edilmiştir. Bu çalışmada kullanılan görüntülere ait detaylı bilgiler Çizelge 3.1 ve Çizelge 3.2’ de verilmiştir. Şekil 3.2’ de yenidoğan bebelere ait RGB ve sıcaklık haritalarından elde edilen termal görüntüler yer almaktadır.


Çizelge 3. 1. Sağlıklı bebeklerde kullanılan veriler ve fiziksel özellikler

Veri	Doğum Ağırlığı (gr)	Doğum Hafta + Gün
Sağlıklı_1	720	24
Sağlıklı_2	1825	34
Sağlıklı_3	1300	28
Sağlıklı_4	1100	28
Sağlıklı_5	1375	28+2
Sağlıklı_6	2200	32
Sağlıklı_7	1580	29
Sağlıklı_8	1690	30+5
Sağlıklı_9	955	27
Sağlıklı_10	1175	28+4
Sağlıklı_11	1870	31+6
Sağlıklı_12	1900	32+5
Sağlıklı_13	2300	33+5
Sağlıklı_14	1195	29+3
Sağlıklı_15	950	28+5
Sağlıklı_16	2800	35
Sağlıklı_17	1605	33+6
Sağlıklı_18	1660	32+1
Sağlıklı_19	1435	29

Çizelge 3. 2. Hasta bebeklerde kullanılan veriler ve fiziksel özellikler


Veri	Teşhis 1	Teşhis 2	Doğum Ağırlığı (gr)	Doğum Hafta + Gün
Hasta_1	İntrakraniyal kanama (IKK)	Hipotermi	2015	34
Hasta_2	Solunum Bozukluğu		1100	28
Hasta_3	Respiratuar Distres Sendromu (RDS)		3300	33+1
Hasta_4	NEC	PDA	3000	36
Hasta_5	Solunum Bozukluğu	Sızlanma	865	28
Hasta_6	Solunum Bozukluğu	DAB	1890	33+2

Hasta_7	Pulmoner Hipertansiyon		2055	34
Hasta_8	NEC		1985	32
Hasta_9	Bağırsak Tıkanıklığı		2305	34+1
Hasta_10	Hipoplastik sol kalp sendromu		2280	37
Hasta_11	Özofagus Atrezi		2200	35
Hasta_12	Solunum Bozukluğu	Yenidoğan sepsisi	1590	30
Hasta_13	NEC	Sepsis	1790	31
Hasta_14	Diyafagma Hernisi	Salgı bezi	2680	38
Hasta_15	Yenidoğanın geçici hızlı solunumu (TTN)		2700	35
Hasta_16	İntrauterin (rahim içi) gelişme geriliği (IUGR)		565	28
Hasta_17	Özofagus Atrezi		3079	37
Hasta_18	Hidrocefali	Miyelomeningosel	3300	38
Hasta_19	AORT Koarktasyon	Down Sendromu	1100	33



Şekil 3. 2. (a) Yenidoğana ait RGB termal görüntü (b) Yenidoğana ait sıcaklık haritalarından elde edilen termal görüntü

Şekil 3.3' te termal görüntünün seçilen bölgeye ait sıcaklık haritası gösterilmiştir. Bu çalışmada termal kameradan alınan görüntülerin sıcaklık haritaları kullanılmıştır.

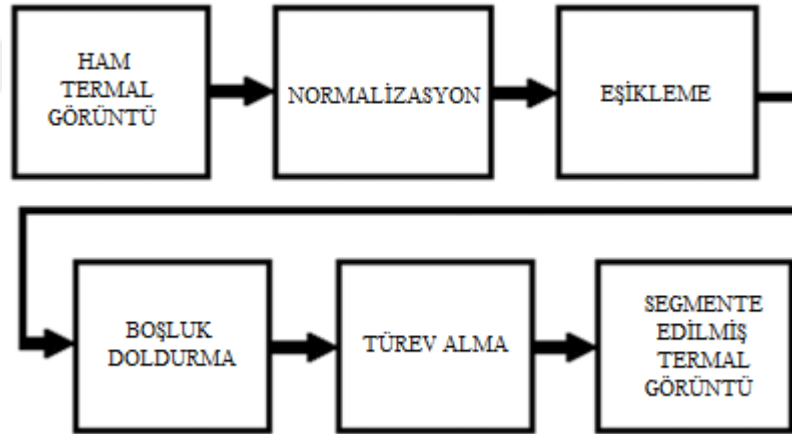


Şekil 3. 3. Sıcaklık haritalarının görselleştirilmesiyle oluşan görüntü ve seçilen bölgenin sıcaklık haritası

3.1.2. Sıcaklık haritası çıkarılmış termal görüntülerin segmentasyonu

Segmentasyon işlemi görüntü analizinin önemli bir parçasıdır. İlgilenilen nesneyi arka plandan çıkarmak amacıyla görüntünün farklı bölümlere ayrılma sürecini ifade eder. Başka bir ifadeyle görüntü segmentasyonu, görüntüdeki her piksele aynı etiketi taşıyan piksellerin belirli görsel özellikleri paylaşacağı şekilde bir etiket atama işlemidir. Segmentasyonun amacı, görüntü içeriklerinin anlamlı ve yorumlanabilir piksel bölgelerine ayrılmasını sağlar (Agrawal ve ark., 2010).

Her yenidoğan farklı vücut sıcaklıklarına sahiptir. Bazı durumlarda yenidoğanın vücut sıcaklığı, kuvöz içindeki durumuna göre de değişmektedir. Örneğin, bazı kuvözler açık durumdayken bazı kuvözler harici bir ısı kaynağı ile ısıtılmaktadır. Dolayısıyla kuvözdeki harici ısı kaynağı, termal kameradan yakalanan kızılötesi radyasyon dağılımını etkileyebilmektedir. Bu durumda yenidoğan vücut sıcaklıkları ve arka plan sıcaklıkları farklı olduğu için, sıcaklık değerlerine ve renk yoğunluğuna bağlı olarak Şekil 3.4' te gösterildiği gibi bir segmentasyon işlemi uygulanmıştır.



Şekil 3. 4. Segmentasyon işleminin adımları


Segmentasyon işleminde ilk olarak sıcaklık haritası çıkarılmış ham termal görüntüler, [0 1] arasında normalize edilmiştir (Şekil 3.5 (a)). Daha sonra yenidoğanın vücut bölgesini arka plandan ayırmak için eşikleme yöntemi kullanılmıştır.

Eşikleme yönteminde, görüntüdeki gri seviye dağılımlarını gösteren görüntü histogramından faydalanılmaktadır. Bu yöntemde, görüntü histogramından göreceli olarak belirlenen bir T eşik değeri, görüntüdeki piksel değerleri ile karşılaştırılmaktadır. Buna göre, görüntüdeki herhangi bir (i, j) pikseli için; $f(i, j) \geq T$ ise (i, j) pikseli nesneye ait bir nokta, $f(i, j) < T$ ise (i, j) pikseli arka plana ait bir nokta olarak etiketlenmektedir

(Gonzalez ve ark., 2004). Eşiklenmiş görüntü piksel değerleri $g(i, j)$, eşitlik (3.1) ile gösterilmektedir.

$$g(i, j) = \begin{cases} 1, & f(i, j) \geq T \\ 0, & f(i, j) < T \end{cases} \quad (3.1)$$

Sabit bir eşik değeri tüm görüntüler üzerinde kabul edilebilir sonuçlar üretmeyebilir. Dolayısıyla eşik değerin, resmin renk dağılımına uygun olarak belirlenmesini sağlayacak bir yöntem ihtiyacı duyulmaktadır. Eşik değeri, global eşikleme ve adaptif eşikleme olmak üzere 2 farklı yöntemle belirlenebilmektedir. Bu çalışmamızda global eşikleme yöntemi kullanılmıştır. Bu yöntem, Otsu metodunu kullanarak bir eşik değeri belirlemektedir. Eşik değeri, gri seviye görüntüler üzerinde otomatik olarak gerçekleştirilmektedir. Otsu yöntemine göre, arka plan ile ön plan arasındaki sınıf içi varyans değeri tüm eşik değerleri için hesaplanmakta ve en küçük farkı sağlayan eşik değeri optimum değer olarak seçilmektedir (Otsu, 1979). Böylece her yenidoğana özgü bir eşik değeri otomatik olarak belirlenmektedir. Şekil 3.5 (b)' de normalize edilmiş termal görüntünün eşikleme yapılmış hali gösterilmektedir.




Şekil 3. 5. a-) Normalize edilmiş termal görüntü b-) Eşikleme işleminden sonra elde edilen termal görüntü

Şekil 3.5' te görüldüğü gibi bazı yenidoğanların göbek bölgelerinde mandallar bulunmaktadır ve bu mandallar vücuda göre daha soğuk olduklarından termal görüntülerde daha düşük sıcaklık değerini göstermektedirler. Segmentasyon işleminde bu değerler, eşik değerinin altında kaldığı için siyah alanlar meydana gelmektedir. Nesne

içindeki bu siyah alanların doldurulması için boşluk doldurma yöntemi uygulanmıştır. Boşluk doldurma yöntemi, morfolojik yeniden yapılandırmaya dayalı bir algoritma kullanmaktadır. Bu yöntemde göre maske olarak kullanılan $f(i, j)$ görüntüsünün sınırları içerisindeki siyah alanın “0” piksel değerleri “1” olacak şekilde etiketlenerek siyah alan içindeki boşluklar doldurulmaktadır. Siyah alan içindeki piksel değeri $I_m(i, j)$ eşitlik (3.2) ile gösterilmektedir (Gonzalez ve ark., 2004).

$$I_m(i, j) = \begin{cases} 1-f(i, j), & \text{Eğer } (i, j) \text{ pikseli, } f(i, j) \text{ görüntüsünün sınırları içerisindeyse} \\ 0, & \text{değilse} \end{cases} \quad (3.2)$$

Böylece gri tonlamalı görüntülerde, daha aydınlık alanlarla çevrili siyah alanların yoğunluk değerleri çevre piksellerle aynı yoğunluk seviyesine getirilmektedir. Boşluk doldurma yöntemi kullanıldıktan sonra oluşan görüntü Şekil 3.6’ da gösterilmektedir.



Şekil 3. 6. Boşluk doldurma uygulandıktan sonra oluşan sıcaklık haritası görüntüsü

Eşikleme ve boşluk doldurma yöntemi uygulandıktan sonra, elde edilen sıcaklık değerlerinin türevi alınmıştır (Eşitlik 3.3). Her satırda bulunan sıcaklık değeri $f(x)$ bir önceki sıcaklık değerinden $f(x - 1)$ çıkarılarak türev alma işlemi gerçekleştirilmiştir.

$$\frac{df}{dx} = f(x) - f(x - 1) \quad (3.3)$$

Böylece sıcaklık değişimlerini içeren bir matris elde edilmiştir. Şekil 3.7’ de gösterildiği gibi bu matris pozitif ve negatif değerlere sahiptir. Bu değerleri ikili hale getirmek için sıfır veya sıfırdan küçük değerler 0’ a, 0’ dan büyük değerler ise 1’ e

eşitlenmiştir. Şekil 3.8’ de ikili hale getirilmiş matris ve bu matrisin görsel hali gösterilmiştir.

-0.08	-0.08	-0.04	-0.1	-0.09	-0.05
0.02	-0.04	0.02	0.03	0.03	0.02
-0.08	0.03	-0.02	-0.03	-0.05	-0.02
-0.01	-0.06	-0.04	-0.02	-0.02	-0.06
-0.02	0	-0.03	-0.01	0.02	0.03
-0.01	-0.07	-0.1	-0.02	0.02	0.02
0.07	0.03	-0.03	-0.05	-0.04	-0.08
-0.04	0.03	0.08	0.01	-0.04	-0.02
0.01	-0.05	-0.04	-0.01	-0.04	-0.08
-0.03	0	-0.03	-0.05	-0.01	0.01
-0.04	-0.05	0.02	0.04	0.05	0.09
0.04	-0.02	-0.02	0.01	0	-0.01
0	0.01	0.06	0.02	-0.02	-0.03
0.03	0.03	0.01	0.08	0.1	0.09
0.11	0.16	0.16	0.12	0.11	0.11

Şekil 3. 7. Sıcaklık değişimlerini temsil eden matris

0	0	0	0	0	0
1	0	1	1	1	1
0	1	0	0	0	0
0	0	0	0	0	0
0	0	0	0	1	1
0	0	0	0	1	1
1	1	0	0	0	0
0	1	1	1	0	0
1	0	0	0	0	0
0	0	0	0	0	1
0	0	1	1	1	1
1	0	0	1	0	0
0	1	1	1	0	0
1	1	1	1	1	1
1	1	1	1	1	1




Şekil 3. 8. İkili hale getirilen matris ve matrisin görselleştirilmesi

3.1.3. Termal görüntülerin çoklu çözünürlük analizi yöntemleri ile sınıflandırılması

Segmente edilmiş termal görüntülerin çoklu çözünürlük analizi yöntemleri ve istatistik özellikler kullanılarak sağlıklı-hasta olarak sınıflandırılması için önerilen sistemler Şekil 3.9 (a) ve (b)’ de verilmiştir. Şekil 3.9 (b)’ de farklı olarak, çoklu çözünürlük analizi yöntemlerinden elde edilen yaklaşım katsayıları üzerinden ortalama değer, ortanca değer, standart sapma, skewness ve kurtosis değerleri hesaplanmıştır. Bu

tez çalışmasında ilk olarak, segmente edilmiş 479×640 boyutuna sahip termal görüntüler, çoklu çözünürlük analizi yöntemlerinde kullanılmak üzere 512×512 boyutuna sabitlenmiştir.



Şekil 3.9. Termal görüntülerin sağlıklı-hasta olarak sınıflandırılması için önerilen sistem

İkinci olarak termal görüntülerden özellik çıkarımı için çoklu çözünürlük analiz yöntemleri (Ayrık Dalgacık, Ayrık Ridgelet, Hızlı Ayrık Curvelet ve Contourlet Dönüşümü) kullanılmıştır. Termal görüntüler, çoklu çözünürlük analiz yöntemleri uygulanarak yaklaşım ve detay katsayılarına ayrılmıştır. Termal görüntülerde özellik çıkarımı, yaklaşım katsayı matrisi üzerinden gerçekleştirilmiştir. Böylece termal görüntülere ADD, ARiD, CuD ve CoD uygulanarak özellik matrisleri oluşturulmuştur. Deneysel olarak, optimum ayırıştırma seviyesi ADD, CoD ve CuD için 3, ARiD için 5 olarak belirlenmiştir. Bu işlemlerde elde edilen özellik matrislerinin boyutları ADD için 64×64 , ARiD için 33×1024 , CuD için 85×85 ve CoD için 64×64 tür. Elde edilen yaklaşım katsayısı matrisleri sütun vektörü haline getirilerek özellik vektörleri oluşturulmuş ve bu özellik vektörleri $[0, 1]$ aralığında normalize edilmiştir. Şekil 3.9b’de segmente edilmiş termal görüntülere ADD, ARiD, CuD ve CoD uygulanarak elde edilen özellik matrisleri üzerinden ortalama değer, ortanca değer, standart sapma, skewness ve kurtosis değerleri hesaplanarak özellik vektörleri oluşturulmuştur.

Üçüncü olarak, elde edilen özellik vektörlerin sınıflandırılması için YSA kullanılmıştır. Sınıflandırma esnasında 190 adet özellik vektörü YSA eğitiminde kullanılmıştır. YSA' nın eğitim işlemi için sınıflandırma sonucunda ulaşılmaması hedeflenen değerler de verilmiştir. YSA' da sağlıklı etiketli görüntülerin hedefi "0", hasta etiketli görüntülerin hedefi ise "1" olarak belirlenmiştir. Çalışmada, sınıflandırma için eşik değeri 0.5 olarak tanımlanmıştır. Sınıflandırma sonucunda; YSA çıkışında 0.5 ve üzerinde elde edilen değerler hasta etiketli, 0.5' ten küçük elde edilen değerler ise sağlıklı etiketli olarak kabul edilmiştir. Sınıflandırma sonuçları 10 kat çapraz geçerlilik yöntemi ile test edilmiştir.

Çalışmada kullanılan YSA modeli ileri beslemeli ve geri yayımlıdır. Gizli katman aktivasyon fonksiyonu olarak logaritmik sigmoid fonksiyonu kullanılmıştır. YSA modelinde, momentum ile gradyan azalan eğitim algoritması (traingdx) seçilmiştir. Geri yayılım ağlarında traingdx, uyarlanabilir öğrenme oranı ve momentum ile gradyan azalmaya göre ağırlık değerlerini ve eğim yönünü güncelleyen bir ağ eğitim işlevidir. Öğrenme oranının ve momentumun birlikte kullanımı sayesinde ağırlıklar çok daha hızlı istenilen optimum değerlere ulaşmaktadır. Böylece daha az zamanda yerel minimuma yakınsamasından dolayı traingdx eğitim algoritması tercih edilmiştir.

Sınıflandırma aşamasında, kullanılan çoklu çözünürlük analizi yöntemleri ile ulaşılabilecek maksimum doğruların kıyaslanabilmesi adına, deneysel olarak optimum YSA parametreleri (gizli katman sayısı, gizli düğüm sayısı ve öğrenme oranı) belirlenmiştir.

Şekil 3.9 (a)' da önerilen sistem için YSA modelinin katman sayısına göre sınıflandırma sonuçları Çizelge 3.3 ve Çizelge 3.4' de verilmiştir. Sınıflandırma performanslarını karşılaştırmak için doğruluk, hassasiyet, özgüllük ve işlem süreleri hesaplanmıştır. Dört katmanlı YSA modeli gizli düğüm sayıları 50 ve 10, öğrenme oranı ise 0.01 iken en yüksek sınıflandırma başarısına ulaşılmıştır. Üç katmanlı YSA modeli ile en yüksek sınıflandırma başarısı ise gizli düğüm sayısı 50, öğrenme oranı 0.7 için elde edilmiştir. Bu işlemlerde hata değeri $1e-20$, maksimum iterasyon sayısı 1000 ve momentum sabiti 0.2 olarak alınmıştır.

Çizelge 3. 3. Termal görüntülerin çoklu çözünürlük analiz yöntemleri ve dört katmanlı YSA modeli ile sınıflandırma sonuçları

Yöntem	Gizli Düğüm Sayısı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Süre (Saniye)
ADD	[50 10]	100	100	100	9.3241
ARiD	[50 10]	98.95	100	97.90	149.9259
CuD	[50 10]	98.42	100	96.84	26.8880
CoD	[50 10]	93.16	97.50	88.42	11.3747

Çizelge 3. 4. Termal görüntülerin çoklu çözünürlük analiz yöntemleri ve üç katmanlı YSA modeli ile sınıflandırma sonuçları

Yöntem	Gizli Düğüm Sayısı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Süre (Saniye)
ADD	50	98.42	98.95	97.90	6.9004
ARiD	50	97.90	95.79	100	83.1666
CuD	50	93.68	90.53	96.84	11.6461
CoD	50	97.90	97.90	97.90	8.6501

Çizelgeler karşılaştırıldığında, dört katmanlı YSA modeli ile yapılan sınıflandırma sonuçlarının doğruluk, hassasiyet ve özgüllük değerlerinin üç katmanlı YSA modeli kullanılarak yapılan sınıflandırma sonuçlarına göre daha yüksek olduğu görülmüştür. Dolayısıyla önerilen sistem için en uygun yapının dört katmanlı YSA olduğu görülmüştür. Çizelge 3.3' den de görüleceği gibi termal görüntüler; ADD ile %100, ARiD ile %98.95, CuD ile %98.42, CoD ile %93.16 doğrulukla sınıflandırılmıştır. Kullanılan çoklu çözünürlük yöntemleri ile elde edilen sonuçlar ayrı ayrı değerlendirildiğinde, en yüksek başarı %100 ile ADD kullanılarak elde edilmiştir. En yüksek hassasiyet oranı %100 ile ADD, CuD ve ARiD, en yüksek özgüllük oranı ise %100 ile ADD kullanılarak sağlanmıştır.

Çizelge 3.5' de ADD, ARiD, CuD ve CoD yöntemlerinin dört katmanlı YSA kullanılarak sınıflandırılması ile elde edilen karmaşıklık matrisi yer almaktadır. Bu çizelgelerde, sağlıklı ve hasta olduğu bilinen veriler ile sınıflandırma sonucu bu etiketli verileri hangi sınıflara ayırdığı detaylı olarak görülebilmektedir. Çizelgede yer alan karmaşıklık matrisleri incelendiğinde üç yöntem için (ADD, CuD ve ARiD) hasta etiketli görüntülerin doğru sınıflandırıldığı görülmektedir. sağlıklı etiketli görüntülerin ise sadece ADD yöntemi ile doğru sınıflandırıldığı görülmektedir. Yöntemler arasından hasta ve sağlıklı görüntüleri sınıflandırmada en iyi sonuç, ADD ve YSA yapısı ile elde edilmiştir.

Çizelge 3. 5. Çoklu çözünürlük analizi yöntemlerin dört katmanlı YSA ile sınıflandırılması sonucu elde edilen karmaşık matrisi

a-) ADD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	95	0
	Sağlıklı	0	95

b-) ARiD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	95	0
	Sağlıklı	2	93

c-) CuD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	95	0
	Sağlıklı	3	92

d-) CoD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	93	2
	Sağlıklı	11	84

Şekil 3.9 (b)' de önerilen sistem için YSA modelinin katman sayısına göre sınıflandırma sonuçları Çizelge 3.6 ve Çizelge 3.7' de verilmiştir. Dört katmanlı YSA modeli gizli düğüm sayıları 50 ve 10 iken en yüksek sınıflandırma başarısına ulaşılmıştır. Her bir yöntem için optimum öğrenme oranı ADD için 0.6, ARiD için 0.7, CuD ve CoD için 0.8 olarak elde edilmiştir. Üç katmanlı YSA modeli ile en yüksek sınıflandırma başarısı ise gizli düğüm sayısı ADD için 50, CoD, CuD ve ARiD için 30 iken ulaşılmıştır. Her bir yöntem için optimum öğrenme oranı ADD için 0.02, ARiD için 1, CuD için 0.5 ve CoD için 1 olarak elde edilmiştir. Bütün işlemler için hata değeri 0.001, maksimum iterasyon sayısı 300 ve momentum sabiti 0.2 olarak alınmıştır.

Çizelge 3. 6. Termal görüntülerin istatistiki özelliklerinin dört katmanlı YSA modeli ile sınıflandırma sonuçları

Yöntem	Gizli Düğüm Sayısı	Öğrenme Oranı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Süre (Saniye)
ADD	[50 10]	0.6	69.47	56.84	82.10	0.6434
ARiD	[50 10]	0.7	73.68	72.63	74.74	0.7193
CuD	[50 10]	0.8	66.32	70.53	62.10	0.6530
CoD	[50 10]	0.8	70	69.47	70.53	0.6567

Çizelge 3. 7. Termal görüntülerin istatistiki özelliklerinin üç katmanlı YSA modeli ile sınıflandırma sonuçları

Yöntem	Gizli Düğüm Sayısı	Öğrenme Oranı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Süre (Saniye)
ADD	50	0.02	74.74	63.16	86.32	0.6990
ARiD	30	1	72.11	81.05	63.16	0.6794
CuD	30	0.5	68.42	70.53	66.32	0.5764
CoD	30	1	71.58	68.42	74.74	0.5965

Çizelgeler karşılaştırıldığında, en uygun yapının üç katmanlı YSA modeli ile elde edildiği görülmüştür. Çizelge 3.7' den de görüleceği gibi termal görüntüler; ADD ile %74.74, ARiD ile %72.11, CuD ile %68.42, CoD ile %71.58 doğrulukla sınıflandırılmıştır. Kullanılan çoklu çözünürlük yöntemleri ile elde edilen sonuçlar ayrı ayrı değerlendirildiğinde, en yüksek başarıyı %74.74 ile ADD göstermiştir. En yüksek hassasiyet oranı %81.05 ile ARiD, en yüksek özgüllük oranı ise %86.32 ile ADD kullanılarak elde edilmiştir.

Çizelge 3.8' de ADD, ARiD, CuD ve CoD yöntemlerinin üç katmanlı YSA modeli kullanılarak sınıflandırılması ile elde edilen karmaşıklık matrisi yer almaktadır. ARiD yöntemi ile YSA kullanılarak sınıflandırma işleminde hasta olarak etiketlenmiş 95 görüntünün 77'sinin hasta olarak sınıflandırıldığı görülmektedir. ADD yöntemi ile YSA kullanılarak sınıflandırma işleminde sağlıklı olarak etiketlenmiş 95 görüntünün 82'sinin sağlıklı olarak sınıflandırıldığı görülmektedir. ADD yönteminin sağlıklı görüntüleri sınıflandırmada, ARiD yönteminin ise hasta görüntüleri sınıflandırma iyi olduğu görülmüştür.

Çizelge 3. 8. Termal görüntülerin istatistikî özelliklerinin üç katmanlı YSA sınıflandırılması sonucu elde edilen karmaşıklık matrisi

a-) ADD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	60	35
	Sağlıklı	13	82

b-) ARiD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	77	18
	Sağlıklı	35	60

c-) CuD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	67	28
	Sağlıklı	32	63

d-) CoD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	65	30
	Sağlıklı	24	71

3.2. Kalp Hastalığı Olan Bebeklerin Belirlenmesi

Bu çalışmada, kalp hastalığı teşhisi konmuş yenidoğan prematüre bebeklere ait termal görüntülerin çoklu çözünürlük analizi yöntemleri uygulanarak özellikleri çıkarılmış ve farklı YSA modelleri ile sınıflandırma işlemi gerçekleştirilmiştir.

Sınıflandırma başarılarını değerlendirmek için doğruluk, hassasiyet ve özgüllük değerleri kullanılmıştır.

3.2.1. Uygulamada kullanılan görüntüler

Bu tez çalışmasında yenidoğan bakım ünitesinde kalp hastalığı (AORT Koarktasyon, Pulmoner atreti) teşhisi konulmuş 14 hasta incelenmiştir. Buna ek olarak, sağlıklı 29 PRM bebek kontrol grubu olarak değerlendirilmiştir. Çalışmada toplam 43 görüntü incelenmiştir. Bu çalışmada kullanılan görüntülere ait detaylı bilgiler Çizelge 3.9 ve Çizelge 3.10' da verilmiştir. Şekil 3.10' da sağlıklı ve hasta yenidoğanlara ait termal görüntüler gösterilmiştir.


Çizelge 3. 9. Sağlıklı bebeklerde kullanılan veriler ve fiziksel özellikler

Veri	Doğum Ağırlığı (gr)	Doğum Hafta + Gün
Sağlıklı_1	955	27
Sağlıklı_2	1375	28+2
Sağlıklı_3	1175	28+4
Sağlıklı_4	955	27
Sağlıklı_5	1375	28+2
Sağlıklı_6	955	27
Sağlıklı_7	970	27
Sağlıklı_8	950	28+5
Sağlıklı_9	1435	29
Sağlıklı_10	1690	30+5
Sağlıklı_11	535	23+5
Sağlıklı_12	1605	33+6
Sağlıklı_13	1600	28
Sağlıklı_14	2200	32
Sağlıklı_15	1765	29+4
Sağlıklı_16	1735	35+3
Sağlıklı_17	950	26+4
Sağlıklı_18	750	26+1
Sağlıklı_19	800	28
Sağlıklı_20	590	28+1
Sağlıklı_21	1760	35+3
Sağlıklı_22	830	28+1
Sağlıklı_23	1780	33+3
Sağlıklı_24	1515	31+1
Sağlıklı_25	1900	31+5
Sağlıklı_26	1465	29
Sağlıklı_27	1825	34

Sağlıklı_28	3200	32
Sağlıklı_29	2800	35+ 4

Çizelge 3. 10. Hasta yenidoğan bebeklerde kullanılan veriler ve fiziksel özellikler

Veri	Doğum Ağırlığı (gr)	Doğum Hafta + Gün	Patoloji Bulgusu
Hasta_1	1120	33+5	Aort Koarktasyonu
Hasta_2	1850	31	(Konjenital Kalp Hastalığı (KKH) + Pulmoner arter bantlama
Hasta_3	1850	31	KKH + Patent Duktus Arteriyozus (PDA) + Pulmoner Byling
Hasta_4	3200	37	Ventriküler Septal Defekt (VSD) + Atriyal Septal Defekt (ASD) + Pulmoner Hipertansiyon
Hasta_5	3600	36	Aort Koarktasyonu
Hasta_6	3460	-	KKH + Post Op 9.gün
Hasta_7	2280	37+6	Hipoplastik sol kalp sendromu
Hasta_8	3170	39	Pulmoner Atrezi + KKH
Hasta_9	2300	38	PDA +Aort Koarktasyonu
Hasta_10	3170	-	Pulmoner Hipertansiyon + KKH + Dicort Sendromu
Hasta_11	3735	42	Kalp Yetmezliği
Hasta_12	3200	40	Konjenital Kalp Yetmezliği
Hasta_13	1850	31	KKH + PDA + Pulmoner Byling + Prematüre retinopatisi (ROP)
Hasta_14	2130	32	KKH + Pulmoner arter bantlama




Şekil 3. 10. (a) Sağlıklı yenidoğana ait termal görüntü (b) Kalp hastalığı teşhisi konulmuş yenidoğana ait termal görüntü

3.2.2. RGB termal görüntülerin segmentasyonu

Termal görüntülerin bebeğin vücut bölgesi dışındaki görüntülerin etkisini azaltmak için arka plan çıkarma işlemi gerçekleştirilmiştir. Şekil 3.11 (a)' da görüldüğü gibi termal görüntüler RGB görüntü olduğu için standardize etmek amacıyla gri seviyeye

dönüştürülmüştür. Şekil 3.11 (b)' de arka plan çıkarma işlemi sonucu oluşan gri seviyeli görüntü gösterilmiştir.



Şekil 3. 11. (a) RGB termal görüntü (b) Gri seviyeli ve segmente edilmiş görüntü

Bu uygulamada segmentasyon işlemi için MATLAB' ın Image Segmentser uygulamasında bulunan Graph Cut tekniği kullanılmıştır. Graph Cut, bir görüntüyü ön plan ve arka plan öğelerine ayırmak için kullanabilen yarı otomatik bir segmentasyon tekniğidir. Graph Cut yönteminde, görüntünün ön planı ve arka planı kullanıcı tarafından çizilen çizgiler ile belirlenmektedir. Böylece, çizilen çizgilere göre görüntü otomatik olarak bölümlere ayrılmaktadır. Segmentasyon sonucunda, arka plan siyah olurken segmente edilmiş görüntü ön planı göstermektedir. İstenilen görüntü elde edilene kadar çizgiler çizerek segmentasyon işlemi gerçekleştirilebilmektedir.

3.2.3. Kalp hastalığı olan bebeklerin termal görüntülerinin sınıflandırılması

Bu tez çalışmasında; 362×482 boyutuna sahip segmente edilmiş termal görüntüler, çoklu çözünürlük analiz yöntemlerinde kullanılmak üzere 256×256 boyutuna sabitlenmiştir. Termal görüntülerden özellik çıkarımı için çoklu çözünürlük analiz yöntemleri kullanılmıştır. Deneysel olarak, optimum ayrıştırma seviyesi ADD, CoD, CuD için 3 ve ARiD için 2 olarak belirlenmiştir. Çoklu çözünürlük analizi yöntemleri ile elde edilen yaklaşım katsayısı matrislerinin boyutları ADD ve CoD için 32×32 , CuD için 85×85 ve ARiD için 129×512 ' dir. Elde edilen yaklaşım katsayısı matrisleri sütun vektörü haline getirilerek özellik vektörleri oluşturulmuş ve bu özellik vektörleri $[0, 1]$ aralığında normalize edilmiştir. Elde edilen 43 adet özellik vektörü YSA' ya giriş olarak verilmiş ve sınıflandırma işlemi gerçekleştirilmiştir.

Kullanılan 3 katmanlı ve 4 katmanlı YSA modellerinin sınıflandırma sonuçları Çizelge 3.11 ve Çizelge 3.12’ de verilmiştir. Sınıflandırma performanslarını karşılaştırmak için doğruluk, hassasiyet, özgüllük değerleri ve işlem süreleri hesaplanmıştır. Dört katmanlı YSA modeli ile sınıflandırma işleminde en yüksek sınıflandırma başarısına, gizli düğüm sayıları 50 ve 10 iken ulaşılmıştır. Her bir yöntem için optimum öğrenme oranı ADD için 0.03, ARiD için 0.2, CuD için 0.01 ve CoD için 0.04 olarak elde edilmiştir. Üç katmanlı YSA modeli ile sınıflandırma işleminde en yüksek sınıflandırma başarısına, gizli düğüm sayısı 50 iken ulaşılmıştır. Her bir yöntem için optimum öğrenme oranı ADD için 0.05, ARiD için 0.8, CuD için 0.05 ve CoD için 0.7 olarak elde edilmiştir. Bütün işlemler için durdurma kriteri $1e-20$, maksimum iterasyon sayısı 300 ve momentum sabiti 0.2 olarak belirlenmiştir.

Çizelge 3. 11. 43 termal görüntünün dört katmanlı YSA modeli ile sınıflandırma sonuçları

Yöntem	Gizli Düğüm Sayısı	Öğrenme Oranı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Süre (Saniye)
ADD	[50 10]	0.03	81.40	42.86	100	0.8955
ARiD	[50 10]	0.2	74.42	42.86	89.66	21.8935
CuD	[50 10]	0.01	72.09	57.14	79.31	3.1575
CoD	[50 10]	0.04	74.42	42.86	89.66	0.7739

Çizelge 3. 12. 43 termal görüntünün üç katmanlı YSA modeli ile sınıflandırma sonuçları

Yöntem	Gizli Düğüm Sayısı	Öğrenme Oranı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Süre (Saniye)
ADD	50	0.05	69.77	42.86	82.76	0.7850
ARiD	50	0.8	57.44	50	75.86	29.7737
CuD	50	0.05	69.77	28.57	89.66	0.8042
CoD	50	0.7	65.11	42.86	75.86	0.8749

Çizelgeler karşılaştırıldığında, dört katmanlı YSA modeli ile sınıflandırma sonuçlarının doğruluk, hassasiyet ve özgüllük değerlerinin üç katmanlı YSA modeli ile sınıflandırma sonuçlarına göre daha yüksek olduğu görülmüştür. Dolayısıyla, en uygun yapı için dört katmanlı YSA modeli seçilmiştir. Çizelge 3.11’ den de görüleceği gibi termal görüntüler; ADD ile %81.40, ARiD ile %74.42, CuD ile %72.09, CoD ile %74.42 doğrulukla sınıflandırılmıştır. Kullanılan çoklu çözünürlük yöntemleri ile elde edilen sonuçlar ayrı ayrı değerlendirildiğinde, en yüksek başarı %81.40 ile ADD kullanılarak sağlanmıştır. En yüksek hassasiyet oranını %57.14 ile CuD, en yüksek özgüllük oranını ise %100 ile ADD göstermiştir.

Çizelge 3.13’ de ADD, ARiD, CuD ve CoD yöntemlerinin dört katmanlı YSA modeli kullanılarak sınıflandırılması ile elde edilen karmaşıklık matrisi yer almaktadır. Bu çizelgelerde, sağlıklı ve hasta olduğu bilinen veriler ile sınıflayıcının bu etiketli verileri hangi sınıflara ayırdığı detaylı olarak görülebilmektedir. Çizelgede yer alan karmaşıklık matrisleri incelendiğinde bütün yapılar için pozitif etiketli görüntülerde sınıflama hatalarının olduğu ve bunun sonucu olarak da pozitif tahmin testlerinin düşük olduğu görülmektedir. Ancak negatif verileri sınıflandırmada %79 ile %100 arasında değişen bir orana ulaşılmıştır. ADD yöntemi ile YSA kullanılarak sınıflandırma işleminde sağlıklı olarak etiketlenmiş 29 görüntünün tamamının sağlıklı olarak sınıflandığı görülmektedir.

Çizelge 3. 13. 43 termal görüntünün dört katmanlı YSA modeli ile sınıflandırılması sonucu elde edilen karmaşıklık matrisi

a-) ADD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	6	8
	Sağlıklı	0	29

b-) ARiD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	6	8
	Sağlıklı	3	26

c-) CuD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	8	6
	Sağlıklı	6	23

d-) CoD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	6	8
	Sağlıklı	3	26

Sınıflandırma sonucunda elde edilen doğruluk ve hassasiyet oranları yeterli görülmemiştir. Bu durumun sebebi olarak kullanılan termal görüntülerin sayısının yetersizliği düşünülmüş; bu amaçla da ikinci bir uygulama gerçekleştirilmiştir. Bu uygulamada, veri sayısını sentetik olarak artırmak amacıyla veri artırma yöntemi (data augmentation method) kullanılmıştır. Bu yöntem ile girdi görüntüsünden rastgele olarak görüntüyü kırpma, çevirme, yeniden boyutlandırma ve döndürme gibi sentetik veri üretme teknikleri kullanılarak görüntünün farklı varyasyonları oluşturulmuş ve böylece veri sayısında artış sağlanmıştır.

3.2.4. Veri artırma yöntemi uygulanması sonucu elde edilen termal görüntülerin sınıflandırılması

Bu tez çalışmasının ikinci uygulamasında, kalp hastalığı teşhisi konmuş yenidoğanların segmente edilmiş 43 tane termal görüntüsüne veri artırma yöntemi uygulanarak her bir görüntüden farklı varyasyonda 5 görüntü daha oluşturulmuştur. Şekil 3.12’ de veri artırma yöntemi ile elde edilen görüntüler gösterilmiştir. Şekilde görülen bu görüntüler, orijinal görüntüye [-20 20] derece aralığından seçilen rasgele açılarla rotasyon işlemi ve [-5 5] aralığından rasgele seçilen mesafede yatay ve dikey yönde çevirme işlemleri uygulanarak elde edilmiştir. Sonuç olarak, bu uygulamada orijinal görüntü ve veri artırma ile elde edilen 5 farklı görüntü olmak üzere toplamda 258 termal görüntü incelenmiştir.



Şekil 3. 12. Veri artırma yöntemi ile elde edilen görüntüler

362 × 482 boyutuna sahip termal görüntüler, çoklu çözünürlük analizi yöntemlerinde kullanılmak üzere 256 × 256 boyutuna sabitlenmiştir. Çoklu çözünürlük analizi yöntemleri (Ayrık Dalgacık, Ayrık Ridgelet, Hızlı Ayrık Curvelet ve Contourlet Dönüşümü) uygulanarak görüntülerin yaklaşım katsayılarından özellikler çıkarılmış ve YSA modeli ile sınıflandırma işlemi gerçekleştirilmiştir.

Kullanılan 3 katmanlı ve 4 katmanlı YSA modellerinin sınıflandırma sonuçları Çizelge 3.14 ve Çizelge 3.15’ de verilmiştir. Sınıflandırma performanslarını karşılaştırmak için doğruluk, hassasiyet ve özgüllük değerleri ile işlem süreleri hesaplanmıştır. Dört katmanlı YSA modeli ile sınıflandırma işleminde en yüksek sınıflandırma başarısına, gizli düğüm sayısı 50 ve 10 iken ulaşılmıştır. Her bir yöntem için optimum öğrenme oranı ADD için 0.9, ARiD için 0.7, CuD için 0.8 ve CoD için 0.05 olarak elde edilmiştir. Üç katmanlı YSA modeli ile sınıflandırma işleminde en yüksek sınıflandırma başarısına, gizli düğüm sayısı 50 iken ulaşılmıştır. Her bir yöntem için

optimum öğrenme oranı ADD için 0.6, ARiD için 0.02, CuD için 0.6 ve CoD için 1 olarak elde edilmiştir.

Çizelge 3. 14. 258 termal görüntünün dört katmanlı YSA modeli ile sınıflandırma sonuçları

Yöntem	Gizli Düğüm Sayısı	Öğrenme Oranı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Süre (Saniye)
ADD	[50 10]	0.9	88.37	75	94.83	2.1019
ARiD	[50 10]	0.7	90.7	83.33	94.25	2.1758
CuD	[50 10]	0.8	89.54	72.62	97.70	2.1909
CoD	[50 10]	0.05	92.25	85.71	85.40	1.7026

Çizelge 3. 15. 258 termal görüntünün üç katmanlı YSA modeli ile sınıflandırma sonuçları

Yöntem	Gizli Düğüm Sayısı	Öğrenme Oranı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Süre (Saniye)
ADD	50	0.6	90.7	86.91	92.53	2.0786
ARiD	50	0.02	90.7	84.52	93.68	111.5660
CuD	50	0.6	91.09	84.52	94.25	3.1900
CoD	50	1	91.09	85.71	93.68	2.0397

Çizelgeler karşılaştırıldığında, üç katmanlı YSA modeli ile yapılan sınıflandırma sonuçlarının hassasiyetlik oranının, dört katmanlı YSA modeli kullanılarak yapılan sınıflandırma sonuçlarına göre daha yüksek olduğu görülmüştür. Bu sonuçlardan yola çıkarak en uygun yapının üç katmanlı YSA modeli ile elde edildiği görülmüştür. Çizelge 3.15' den de görüleceği üzere termal görüntüler; ADD ile %90.7, ARiD ile %90.7, CuD ile %91.09, CoD ile %91.09 doğrulukla sınıflandırılmıştır. Kullanılan çoklu çözünürlük yöntemleri ile elde edilen sonuçlar ayrı ayrı değerlendirildiğinde, en yüksek başarı %91.09 doğrulukla CoD ve CuD kullanılarak sağlanmıştır. En yüksek hassasiyet oranını %86.91 ile ADD, en yüksek özgüllük oranını ise %94.25 ile CuD göstermiştir.

Çizelge 3.16' da ADD, ARiD, CuD ve CoD yöntemlerinin üç katmanlı YSA modeli kullanılarak sınıflandırılması ile elde edilen karmaşıklık matrisi yer almaktadır. Çizelgede yer alan karmaşıklık matrisleri incelendiğinde, CoD yöntemi ile YSA kullanılarak sınıflandırma işleminde hasta olarak etiketlenmiş 84 görüntünün 73' ünün hasta olarak sınıflandığı görülmektedir. CuD yöntemi ile YSA kullanılarak sınıflandırma işleminde sağlıklı olarak etiketlenmiş 174 görüntünün 164' ünün sağlıklı olarak sınıflandığı görülmektedir.

Çizelge 3. 16. 258 termal görüntünün üç katmanlı YSA modeli ile sınıflandırılması sonucu elde edilen karmaşıklık matrisi

a-) ADD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	73	11
	Sağlıklı	13	161

b-) ARiD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	71	13
	Sağlıklı	11	163

c-) CuD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	71	13
	Sağlıklı	10	164

d-) CoD + YSA için sınıflandırma sonucu

		Tahmin Edilen Sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	72	12
	Sağlıklı	11	163

Veri artırma yöntemi uygulanarak gerçekleştirilen sınıflandırma sonuçlarının daha yüksek doğruluk, hassasiyet ve özgülük oranlarına ulaşılabildiği görülmüştür.

4. TARTIŞMA VE ÖNERİLER

4.1. Tartışma

Yenidoğan yoğun bakım ünitesinde bulunan bebeklerin yaşamsal parametrelerinin (solunum hızı, vücut sıcaklığı vs.) rahatsızlık vermeden veya ciltte tahriş oluşturmadan sürekli olarak izlenmesi gerekmektedir. Özellikle erken doğan ve çok düşük doğum ağırlığına sahip olan yenidoğanların vücut sıcaklığının sabit tutulması oldukça önemlidir. Dolayısıyla sıcaklık değişimlerinin hızlı bir şekilde değerlendirilmesi; acil müdahale ihtiyacı, yeni tedavi planlaması veya stabil durumun korunması gibi hayati kararların verilmesini sağlamaktadır. Yenidoğan bebeklerin farklı çevresel etkiler altında vücut sıcaklıklarının takip edilebilmesi ve sıcaklık profillerinin çıkartılabilmesi için kızılötesi termal görüntülemenin oldukça kullanışlı ve kolay uygulanabilen bir yöntem olduğu literatürde vurgulanmıştır. Termal görüntülemenin temassız, iyonize olmayan, non-invazif ve zararsız bir yöntem olması yenidoğan yoğun bakım ünitelerinde bulunan bebeklerin sürekli takibi için önemini artırmıştır.

Bu tez çalışması ile termal görüntüleme gerçekleştirilmiş ve zamana bağlı olarak elde edilen termal değişiklikler analiz edilerek bir ön tanı sistemi oluşturulmuştur. İlk kez bu tez çalışmasında yenidoğan bebeklerin termal görüntülerinin çoklu çözünürlük analiz yöntemleri ile sınıflandırma performansı değerlendirilmiştir. Elde edilen sonuçlar karşılaştırmalı olarak sunulmuştur. Çoklu çözünürlük analiz yöntemleri, segmente edilmiş görüntülerden özellik çıkarılması aşamasında görüntünün çeşitli seviyelere ayrıştırılmasında ve istatistiki özelliklerinin çıkarılmasında kullanılmıştır.

4.1.1. Bebeklerin sağlıklı-hasta olarak belirlenmesi


Bu çalışmada 95 sağlıklı ve 95 hasta bebekten alınan 190 farklı termal görüntünün sıcaklık haritaları kullanılarak sağlıklı-hasta sınıflandırma işlemi yapılmıştır. Sıcaklık haritası çıkarılmış 190 termal görüntü kullanılarak çoklu çözünürlük analizi yöntemleri ile sınıflandırma işlemi ve çoklu çözünürlük analizi yöntemleri ile istatistiki özellikler kullanılarak gerçekleştirilen sınıflandırma işleminin sonuçlarının doğruluk, hassasiyet ve özgüllük değerlerinin karşılaştırılması Şekil 4.1, Şekil 4.2 ve Şekil 4.3' te gösterilmiştir.

Sıcaklık haritası çıkarılmış 190 termal görüntünün sınıflandırılması için gerçekleştirilen uygulamalarda, %68.42 ile %100 arasında değişen doğruluk oranlarına

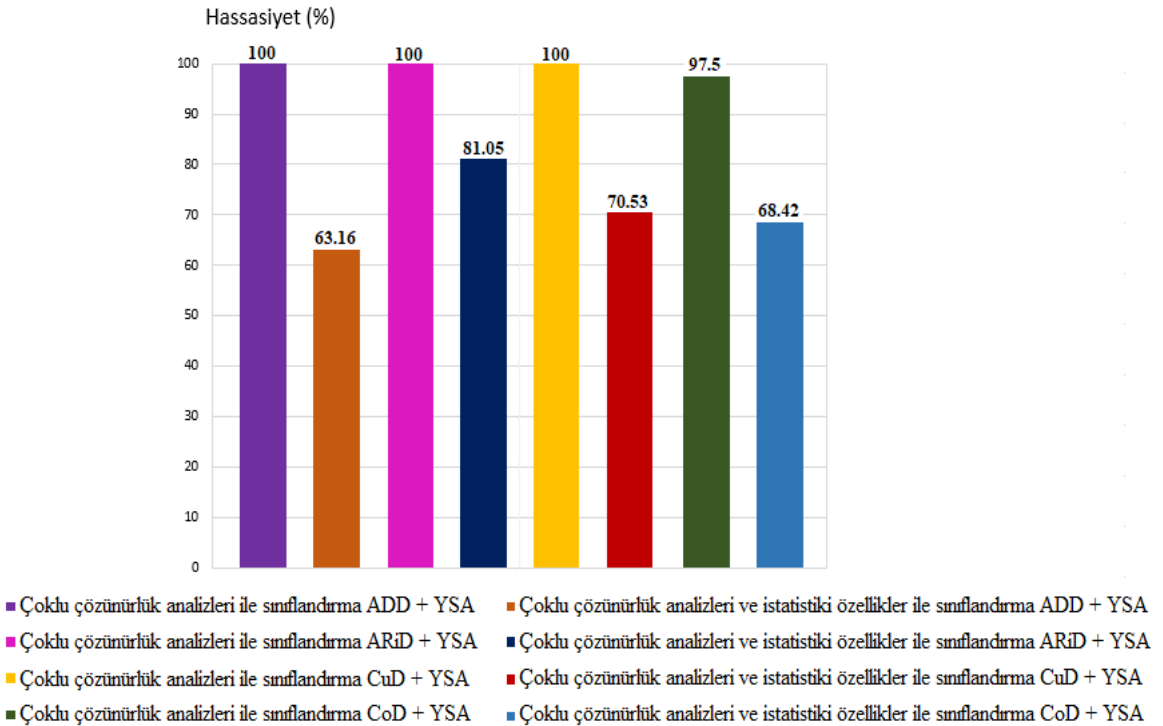
ulaşılmıştır. Şekil 4.1' de çoklu çözünürlük analizi yöntemleri kullanılarak en yüksek doğruluk oranı %100 olarak elde edilirken, çoklu çözünürlük analizi yöntemleri ve istatistiki özellikler kullanılarak elde edilen bu başarı %74.74' tür. Çoklu çözünürlük analizi yöntemlerinin yanı sıra istatistiki özelliklerin kullanılması özellik vektörlerinin boyutunun azaltılmasına neden olmuştur. Bu vektörlerin boyutunun azaltılması, sınıflandırmada kullanılan YSA' nın işlem süresini kısaltsa da görüntü içerisinde hastalığı tanımlayan özellikleri azaltmaya neden olduğu için sınıflandırma başarısını düşürmüştür. Sonuç olarak, sıcaklık haritası çıkarılmış 190 termal görüntünün çoklu çözünürlük analizi yöntemleri ile sınıflandırılmasında daha iyi sonuçlar elde edilmiştir. En yüksek doğruluk oranlarına ADD, ARiD ve CuD dönüşümü ile ulaşıldığı ve birbirine yakın değerler olduğu görülmüştür. CoD' un çoklu ölçeklemede daha esnek yönler kullanmasından dolayı çizgisellikleri daha az katsayı ile ve toplu bir şekilde ifade etmesi CoD' un diğer dönüşümlerden daha düşük doğruluk oranına (%93.16) sahip olmasına neden olmuştur.

Şekil 4.2' de çoklu çözünürlük analizi yöntemleri kullanılarak en yüksek hassasiyet oranına %100 ile ulaşılrken, çoklu çözünürlük analizi yöntemleri ve istatistiki özellikler kullanılarak elde edilen hassasiyet oranı %81.05'e düşmüştür. ADD, ARiD ve CuD yöntemlerinin %100 hassasiyet oranı göstermesi, bu yöntemlerin yenidoğan hasta bebeklere hastalık teşhisini koymadaki başarısını göstermektedir. İstatistiki özellikler çıkartılmadan çoklu çözünürlük analizi yöntemlerinden ADD, ARiD ve CuD ile 95 hasta bebeğin tamamının hasta olarak sınıflandırıldığı görülmektedir.

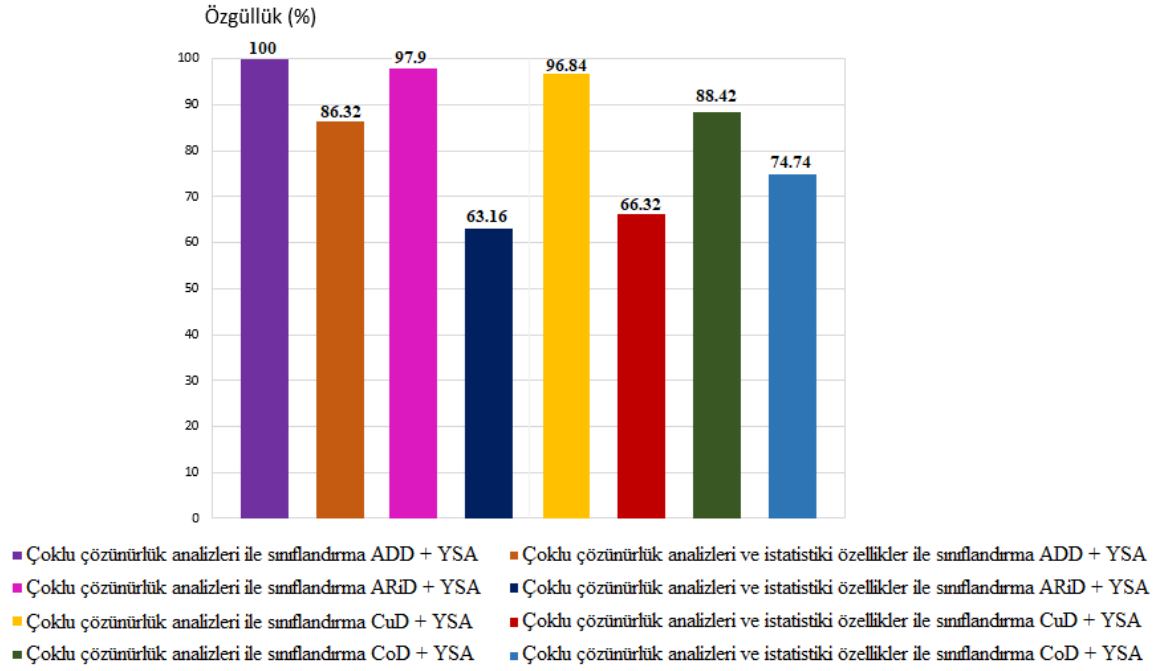
Şekil 4.3' te çoklu çözünürlük analizi yöntemleri kullanılarak en yüksek özgüllük oranına %100 olarak elde edilirken, çoklu çözünürlük analizi yöntemleri ve istatistiki özellikler kullanılarak elde edilen bu başarı %86.32' dir. ADD yönteminin %100 özgüllük oranı göstermesi yenidoğan bebeklerin sağlıklı teşhisini koymadaki başarısını göstermektedir. Çoklu çözünürlük analizi yöntemlerinden ADD ile 95 sağlıklı bebeğin tamamının sağlıklı olarak sınıflandırıldığı görülmektedir.



Şekil 4. 1. Termal görüntülerin sağlıklı-hasta sınıflandırılmasında doğruluk değerlerinin karşılaştırılması



Şekil 4. 2. Termal görüntülerin sağlıklı-hasta sınıflandırılmasında hassasiyet değerlerinin karşılaştırılması



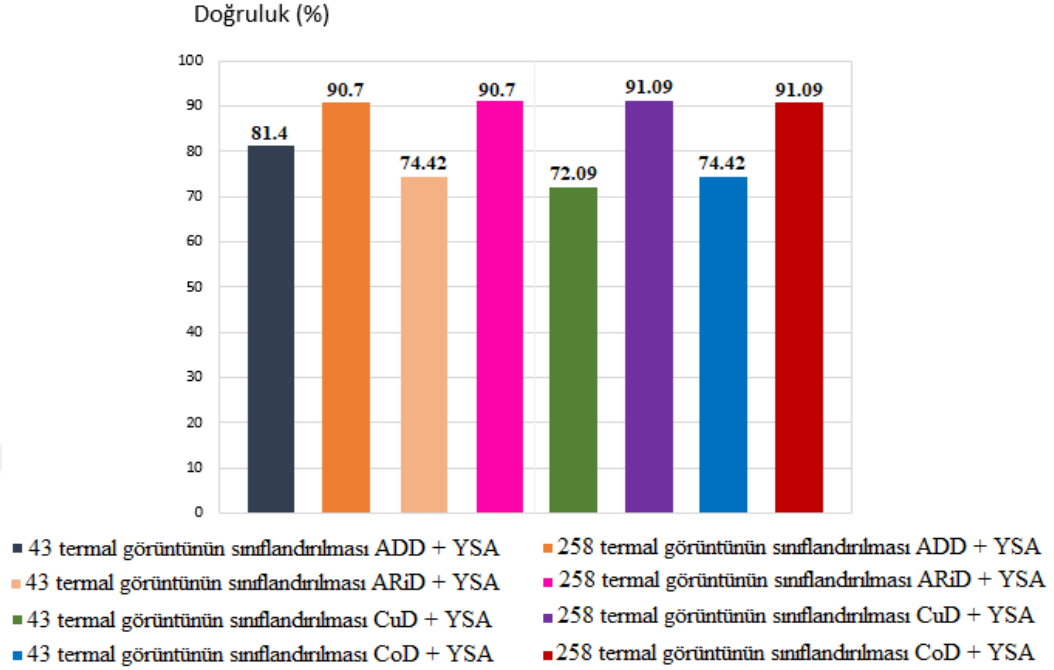
Şekil 4. 3. Termal görüntülerin sağlıklı-hasta sınıflandırılmasında özgüllük değerlerinin karşılaştırılması

4.1.2. Kalp hastalığı olan bebeklerin belirlenmesi

Bu çalışmada 29 sağlıklı ve kalp hastalığı teşhisi konmuş 14 hasta bebekten alınan 43 farklı termal görüntü kullanılarak sağlıklı-hasta sınıflandırılması yapılmıştır. Kalp hastalığı olan bebeklerin termal görüntülerinin sağlıklı-hasta sınıflandırılmasında bebeklerden alınan 43 termal görüntü ve veri artırma yöntemi kullanılarak elde edilen 258 termal görüntünün çoklu çözünürlük analizi yöntemleri ile sınıflandırma sonuçlarının doğruluk, hassasiyet, özgüllük değerlerinin karşılaştırılması Şekil 4.4, Şekil 4.5 ve Şekil 4.6' da gösterilmiştir. Çizelgelerde ulaşılan sonuçlar değerlendirildiğinde veri setindeki görüntülerin sayısını artırmak için kullanılan veri artırma yöntemi ile elde edilen 258 termal görüntünün sınıflandırılma başarısında artış görülmüştür.

Kalp hastalığı olan bebeklerin termal görüntülerinin sınıflandırılması için gerçekleştirilen uygulamalarda, %72.09 ile %91.09 arasında değişen doğruluk oranlarına ulaşılmıştır. Şekil 4.4' te 43 termal görüntü kullanılarak gerçekleştirilen sınıflandırmada en yüksek doğruluk oranı %81.4 iken, veri artırma yöntemi ile elde edilen 258 termal görüntü kullanılarak gerçekleştirilen sınıflandırmada ise doğruluk oranı %91.09' e çıkmıştır. Veri sayısının artırılması ile sınıflandırma başarısının arttığı gözlemlenmiştir. Bu uygulamada, en yüksek doğruluk oranına CuD ve CoD yöntemleri ile ulaşılmasına

rağmen ADD, ARiD, CuD ve CoD yöntemlerinin doğruluk oranları arasındaki farkın oldukça düşük (%0.39) olduğu görülmüştür.




Şekil 4. 4. Kalp hastalığı olan bebeklerin sağlıklı-hasta sınıflandırma işleminde doğruluk değerlerinin karşılaştırılması

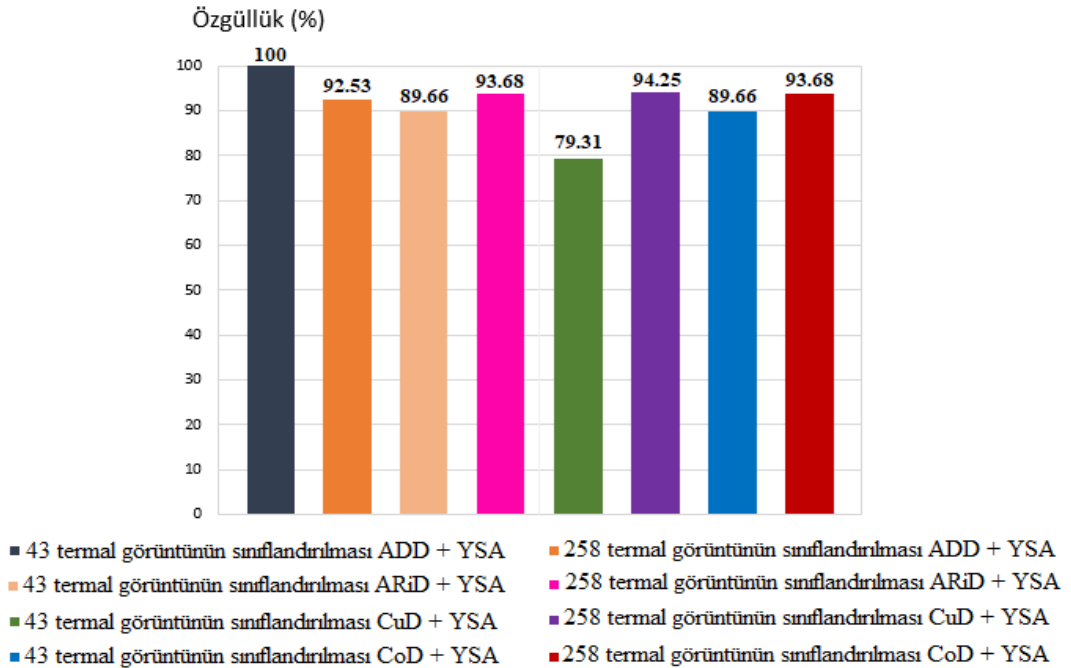
Şekil 4.5' te 43 termal görüntü kullanılarak gerçekleştirilen sınıflandırmada en yüksek hassasiyet oranı %57.14 olarak elde edilirken, veri artırma yöntemi uygulanmasıyla birlikte toplamda sahip olunan 258 termal görüntü kullanılarak gerçekleştirilen sınıflandırmada bu başarı %86.91 olmuştur. Hassasiyet oranları karşılaştırıldığında aradaki farkın oldukça fazla (%29.77) olduğu görülmektedir. 43 termal görüntü kullanılarak ulaşılan hassasiyet oranının oldukça düşük olması, bebeklere hastalık teşhisi koymadaki başarısını düşürmüştür. 258 termal görüntünün sınıflandırılmasında çoklu çözünürlük analizi yöntemlerin tamamı için %84' ün üstünde bir hassasiyet oranı elde edilmiştir. Sonuç olarak, kalp hastalığının belirlenmesinde çıkan sınıflandırma sonuçlarının %86 oranında hassasiyetlik göstermesi termal görüntüleme ile kalp hastalığının teşhisinin yapılabileceğini göstermiştir.

Şekil 4.6' da 43 termal görüntü kullanıldığında en yüksek özgüllük oranı %100 iken, 258 termal görüntü kullanıldığında bu başarı %94.25' dir. 43 termal görüntünün sınıflandırılmasında en yüksek özgüllük oranı ADD yöntemi ile elde edilirken, 258 termal görüntünün sınıflandırılmasında en yüksek özgüllük oranı CuD yöntemi ile elde edilmiştir. 43 termal görüntünün sınıflandırılmasında özgüllük oranının %100 olması

sağlıklı bebeklerinin tamamını sağlıklı olarak sınıflandırabileceğini göstermektedir. 258 termal görüntünün sınıflandırılmasında çoklu çözünürlük analizi yöntemlerin tamamı için %92' nin üstünde bir özgüllük oranına ulaşılmıştır. Bu iki uygulamanın en yüksek özgüllük oranları karşılaştırıldığında aradaki farkın % 5.75 olduğu görülmektedir.



Şekil 4. 5. Kalp hastalığı olan bebeklerin sağlıklı-hasta sınıflandırma işleminde hassasiyet değerlerinin karşılaştırılması



Şekil 4. 6. Kalp hastalığı olan bebeklerin sağlıklı-hasta sınıflandırma işleminde özgüllük değerlerinin karşılaştırılması

Şekillerden de anlaşılacağı üzere 43 termal görüntü kullanılarak gerçekleştirilen sınıflandırma sonuçlarında görüntü sayısının az olmasından dolayı düşük doğruluk ve hassasiyet oranları elde edilmiştir. Bu oranları artırmak amacıyla veri artırma yöntemi kullanılmış ve görüntü sayısı sentetik olarak artırılmıştır. Bu veri artırma yönteminde girdi görüntüye rasgele olarak seçilen oranlarda döndürme ve çevirme dönüşümleri uygulanarak görüntünün farklı varyasyonları oluşturulmuştur. Bu dönüşümler ile orijinal görüntülerden elde edilen farklı varyasyondaki görüntüler sınıflandırmada kullanılmış, böylece doğruluk ve hassasiyet oranlarında artış sağlanmıştır.

4.2. Öneriler

Tez çalışmasında termal görüntülerden özellik çıkarma işlemi için çoklu çözünürlük analizi yöntemleri (ADD, ARiD, CuD ve CoD), sınıflandırma işlemi için YSA kullanılmıştır. Elde edilen sonuçlar değerlendirildiğinde, termal görüntülerin çoklu çözünürlük analizi yöntemleri ile sınıflandırılmasında iyi sonuçlar elde edilebildiği görülmüştür. Yenidoğan yoğun bakım ünitesinde bulunan bebeklerin termal görüntülerinin çoklu çözünürlük analizi yöntemleri ile sağlıklı-hasta teşhisi ilk bu tez çalışması ile önerilmiştir. Tez çalışmasında önerilen sınıflandırma yapısında farklı ve yeni çoklu çözünürlük dönüşümleri kullanılması sınıflandırma başarısını artıracak önemli bir unsur olacaktır. Ayrıca görüntüler üzerinde incelenen hastalığa özgü ilgi alanları tanımlanarak sınıflandırma performansı değerlendirilmelidir. Bu tez çalışmalarında çoklu çözünürlük dönüşümlerinin kompleks versiyonları kullanılmamıştır. Gelecek çalışmalarda bu çoklu çözünürlük dönüşümlerinin reel versiyonlarının yanında kompleks versiyonlarının da kullanılması sınıflandırma başarısını etkileyecektir. Farklı veri setleri ile gerçekleştirilecek benzer çalışmalarda da aynı sonuçların elde edilip edilemeyeceğini test etmek üzere yeni uygulamalar yapılmalıdır.

Ayrıca sıcaklık haritası çıkarılmış termal görüntülerin çoklu çözünürlük analizi yöntemlerinin yanı sıra istatistikî özellikler kullanılarak gerçekleştirilen sınıflandırma uygulamasında daha fazla ve farklı istatistikî özelliklerin kullanılması çalışma başarısını artırabileceği düşünülmektedir. Gerçekleştirilen uygulamada özellik boyutlarının azaltılmasına veya seçilmesine yönelik herhangi bir özellik seçme yöntemi kullanılmamıştır. Çalışmada kullanılan özellik boyutlarının azaltılmasında veya seçilmesinde özellik seçme yönteminin kullanılmasının sınıflandırma sonuçlarına olumlu katkılar sağlayacağı düşünülmektedir.

KAYNAKLAR

- Abbas, A. K., Heimann, K., Jergus, K., Orlikowsky, T. and Leonhardt, S., 2011, Neonatal non-contact respiratory monitoring based on real-time infrared thermography, *Biomedical Engineering Online*, 10 (1), 93.
- Abbas, A. K., Heimann, K., Blazek, V., Orlikowsky, T. and Leonhardt, S., 2012, Neonatal infrared thermography imaging: analysis of heat flux during different clinical scenarios, *Infrared Physics & Technology*, 55 (6), 538-548.
- Abbas, A.K., Heimann K., Jergus, K., Orlikowsky, T. and Leonhardt, S., 2012, Neonatal Monitoring Technologies: Design for Integrated Solutions, *Book chapter: Neonatal Infrared Thermography Imaging*, USA: IGI Global, 84-124.
- Abbas, A. K. and Leonhardt, S., 2008, Neonatal IR-Thermography pattern clustering based on ICA Algorithm, *Color Image Processing Workshop*, Aachen University, Germany.
- Abbas, A. K. and Leonhardt, S., 2014, Intelligent neonatal monitoring based on a virtual thermal sensor, *BMC Medical Imaging*, 14 (1), 9.
- Agrawal, P., Shriwastava, S.K. and Limaye, S.S., 2010, MATLAB implementation of image segmentation algorithms. *In 2010 3rd International Conference on Computer Science and Information Technology*, IEEE, 3:427-431.
- Albert, S.M., Glickman, M. and Kallish, M., 1964, Thermography in orthopedics. *Annals of the New York Academy of Sciences*, 121 (1), 157-170.
- Al-Alwani, A. and Chahir, Y., 2014, Neonatal events recognition using LBP descriptor and wavelet thresholding technique, *2014 International Conference on Multimedia Computing and Systems (ICMCS)*, IEEE, 427-432.
- Al-Khalidi, F., Saatchi, R., Elphick, H. and Burke, D., 2011, An evaluation of thermal imaging based respiration rate monitoring in children, *American Journal of Engineering and Applied Sciences*, 4 (4), 586-597.
- AlZubi, S., İslam, N. and Abbod, M., (2011) Multiresolution Analysis Using Wavelet, Ridgelet, and Curvelet Transforms for Medical Image Segmentation, *International Journal of Biomedical Imaging*, 1-18.
- Amato, F., López, A., Peña-Méndez, E. M., Vañhara, P., Hampl, A. and Havel, J., 2013, Artificial neural networks in medical diagnosis, *Journal of Applied Biomedicine*, 11: 47–58.
- Anderson, E. S., Wailoo, M. P. and Petersen, S. A., 1990, Use of thermographic imaging to study babies sleeping at home, *Archives of Disease in Childhood*, 65 (11), 1266-1267.
- Antonini, M., Barlaud, M., Mathieu, P. and Daubechies, I., 1992, Image coding using wavelet transform, *IEEE Transactions on Image Processing*, 1 (2), 205-220.

- Boas, N.F., 1964, Thermography in rheumatoid arthritis, *Annals of the New York Academy of Sciences*, 121 (1), 223-234.
- Bouzida, N., Bendada, A. and Maldague, X. P., 2009, Visualization of body thermoregulation by infrared imaging, *Journal of Thermal Biology*, 34 (3), 120-126.
- Candes, E. J. and Donoho, D. L., 1999, Ridgelets: A key to higher-dimensional intermittency, *Philosophical Transactions of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, 357 (1760), 2495-2509.
- Candes, E. J. and Donoho, D. L., 2000, Curvelets-A surprisingly effective nonadaptive representation for objects with edges, *Vanderbilt University Press*, Nashville, 1-10.
- Candes, E. J. and Donoho, D. L., 2004, New tight frames of curvelets and optimal representations of objects with piecewise C2 singularities, *Communications on Pure and Applied Mathematics: A Journal Issued by the Courant Institute of Mathematical Sciences*, 57 (2), 219-266.
- Candes, E., Demanet, L., Donoho, D. and Ying, L., 2006, Fast discrete curvelet transforms, *Applied and Computational Mathematics, California Institute of Technology*.
- Carre, P. and Andres, E., 2004, Discrete analytical ridgelet Transform, *Signal processing, Elsevier*, 84 (11), 2165-2173.
- Catalan, L. B., 2009, Neonatal infrared thermography image processing, MSc Thesis, *Aachen University, Germany*.
- Ceylan, M., 2009, Bilgisayar tomografili akciğer görüntülerinin değerlendirilmesinde kompleks değerli yeni bir akıllı sistem tasarımı, Doktora tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya*, 21-35.
- Chan, F. H. Y., So, A. T. P., Kung, A. W. C., Lam, F. K. and Yip, H. C. L., 1995, Thyroid diagnosis by thermogram sequence analysis, *Bio-medical Materials and Engineering*, 5 (3), 169-183.
- Chein, W., Oetomo, S. B. and Feijs, L., 2012, Neonatal Monitoring Technologies: Design for Integrated Solutions, *Medical Information Science Reference, USA: IGI Global*.
- Christidis, I., Zotter, H., Rosegger, H., Engele, H., Kurz, R. and Kerbl, R., 2003, Infrared thermography in newborns: the first hour after birth, *Gynäkologisch-geburtshilfliche Rundschau*, 43 (1), 31-35.
- Clark, R. P. and Stothers, J. K., 1980, Neonatal skin temperature distribution using infrared colour thermography, *The Journal of physiology*, 302 (1), 323-333.
- Cole, R. P., Jones, S. G. and Shakespeare, P. G., 1990, Thermographic assessment of hand burns, *Burns*, 16 (1), 60-63.

- Connell, J. F., Morgan, E. and Rousselot, L.M., 1964, Thermography in trauma. *Annals of the New York Academy of Sciences*, 121 (1), 171-176.
- Demuth, H. and Beale, M., 1998, Neural network toolbox for use with MATLAB users guide, MathWorks Inc., Natick.
- Du, K. L. and Swamy, M. N., 2013, Neural networks and statistical learning, *Springer Science & Business Media*.
- Do, M. N. and Vetterli, M., 2002, Contourlets, In J. Stoeckler and G. V. Welland, editors, *Beyond Wavelets*, Academic Press.
- Do, M. N. and Vetterli, M., 2003, The finite ridgelet transform for image representation, *IEEE Transactions on Image Processing*, 12 (1), 16-28.
- 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.
- Donoho, D. L. and Duncan, M., 1999, Digital Curvelet Transform Strategy, Implementation and Experiments, Department of Statistics Stanford University.
- Elmas, Ç., 2003, Yapay Sinir Ağları, *Seçkin Yayıncılık*, Birinci Baskı, Ankara.
- Fadili, J. and Starck, J. L., 2009, Curvelets and ridgelets, R.A. Meyers, ed. *Encyclopedia of Complexity and Systems Science*, Springer New York, 1718-1738.
- Frize, M., Nur, R., Bariciak, E. and Herry, C., 2013, Infrared Imaging and Classification of Neonates with Necrotising Enterocolitis, In World Congress on Medical Physics and Biomedical Engineering May 26-31, 2012, Beijing, China (pp. 1309-1312), Springer, Berlin, Heidelberg.
- 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 (4), 1002-1014.
- Gershen-Cohen, J., Haberman, J. and Brueschke, E. E., 1965, Medical thermography: a summary of current status, *Radiology Clinics of North America*, 3 (3), 403-431.
- Gonzalez, R. C., Woods, R. E., Steven, L. E., 2004, Digital Image Processing Using Matlab, Prentice-Hall, New Jersey, 365-407.
- Gratt, B. M., Sickles, E. A., Graff-Radford, S. B. and Solberg, W. K., 1989, Electronic thermography in the diagnosis of atypical odontalgia: a pilot study. *Oral Surg Oral Med Oral Pathol*, 68:472-481.
- Haberman, J. D., 1968, The present status of mammary thermography, *CA: A Cancer Journal for Clinicians*, 18 (6), 314-321.

- Hakimpoor, H., Arshad, K. A. B., Tat, H. H., Khani, N. and Rahmandoust, M., 2011, Artificial neural networks' applications in management, *World Applied Sciences Journal*, 14 (7), 1008-1019.
- Handley, R. S., 1962, The temperature of breast tumors as a possible guide to prognosis, *Acta Unio Internationalis Contra Cancrum*, 18 (6), 822.
- Hartmann, M., Kunze, J. and Friedel, S., 1981, Telethermography in the diagnostics and management of malignant melanomas, *The Journal of Dermatologic Surgery and Oncology*, 7 (3), 213-218.
- Haykin, S., 1999, Neural Networks A Comprehensive Foundation, *Prentice Hall International*, Inc Second Edition, NJ, USA.
- Heimann, K., Jergus, K., Abbas, A. K., Heussen, N., Leonhardt, S. and Orlikowsky, T., 2013, Infrared thermography for detailed registration of thermoregulation in premature infants, *Journal of Perinatal Medicine*, 41 (5), 613-620.
- Hejazi, S. and Spangler, R., 1992, Theoretical modeling of skin emissivity, *14th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, IEEE, (1), 258-259.
- Herrick, R. T. and Herrick, S. K., 1987, Thermography in the detection of carpal tunnel syndrome and other compressive neuropathies, *The Journal of Hand Surgery*, 12 (5), 943-949.
- Hildebrandt, C., Zeilberger, K., Ring, E. F. J. and Raschner, C., 2012, The application of medical infrared thermography in sports medicine, *An International Perspective on Topics in Sports Medicine and Sports Injury*, 14:258–274.
- Jones, B. F., 1998, A reappraisal of the use of infrared thermal image analysis in medicine, *IEEE Transactions on Medical Imaging*, 17 (6), 1019-1027.
- Knobel, R. B., Guenther, B. D. and Rice, H. E., 2011, Thermoregulation and thermography in neonatal physiology and disease, *Biological Research for Nursing*, 13 (3), 274-282.
- Kohavi, R., 1995, A study of cross-validation and bootstrap for accuracy estimation and model selection, *Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence*, San Mateo, CA: Morgan Kaufmann, 2 (12), 1137–1143.
- Kohavi, R. and Provost, F., 1998, Glossary of Terms, *Editorial for the Special Issue on Applications of Machine Learning and the Knowledge Discovery Process*, 30 (2-3), 271-274.
- Kulkarni, S. M. and Shelke, A. R., 2014, Multiresolution Analysis for Medical Image Segmentation Using Wavelet Transform, *International Journal of Emerging Technology and Advanced Engineering (IJETA)*, 4 (6), 543-545.

- Lahiri, B. B., Bagavathiappan, S., Jayakumar, T. and Philip, J., 2012, Medical applications of infrared thermography: a review, *Infrared Physics & Technology*, 55 (4), 221-235.
- Lane, W. Z., 1964, Thermography in diseases of the thorax, *Annals of the New York Academy of Sciences*, 121 (1), 190-208.
- Lawson, R. N., 1956, Implications of surface temperature in the diagnosis of breast cancer, *Canadian Medical Association Journal*, 75 (4), 309–310.
- Lawson, R.N. and Chughtai, M.S., 1963, Breast cancer and body temperatures, *Canadian Medical Association Journal*, 88 (2), 68–70.
- Liddington, M. I. and Shakespeare, P. G., 1996, Timing of the thermographic assessment of burns, *Burns*, 22 (1), 26-28.
- Ma, J. and Plonka, G., 2010, The curvelet transform, *IEEE Signal Processing Magazine*, 27 (2), 118-133.
- Mallat, S. G., 1989, A theory for multiresolution signal decomposition: the wavelet representation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11 (7), 674-693.
- Mallat, S., 1999, A Wavelet Tour Of Signal Processing, *Academic Press*, 637.
- Negnevitsky, M., 2005, Artificial Intelligence, *A Guide to Intelligent Systems*, Second Edition.
- Nur, R. and Frize, M., 2013, Image processing of infrared thermal images for the detection of necrotizing Enterocolitis, *In Medical Imaging 2013: Image Processing (Vol. 8669, p. 86692M)*. International Society for Optics and Photonics, USA.
- Nur, R., 2013, Identification of Thermal Abnormalities by Analysis of Abdominal Infrared Thermal Images of Neonatal Patients, MsC Thesis, *Carleton University*.
- Otsu, N., 1979, A threshold selection method from gray-level histograms, *IEEE Transactions on Systems, Man and Cybernetics*, 9: 62-66.
- Örnek, A.H., Savaşçı, D., Ervural, S., Ceylan, M. ve Soylu, H., 2018, Termogramların Değerlendirilmesinde Doğru Yaklaşımların Belirlenmesi, *URSI-TÜRKİYE 2018 IX. Bilimsel Kongresi*, KTO Karatay Üniversitesi, Konya.
- Öztemel, E., 2003, Yapay Sinir Ağları, *Papatya Yayıncılık*, 1. Baskı, İstanbul.
- Öztürk, A.E., 2015, Ripplet, Tetrolet ve Ridgelet Dönüşümleri Kullanılarak Karaciğer Fokal Lezyonlarının Belirlenmesi, Yüksek Lisans tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 13-20.

- Öztürk, A.E., Ceylan, M. and Kırarak, A.S., 2014, A new approach for liver classification using ridgelet/ripplelet-II transforms, feature groups and ANN, *6th European Conference of the International Federation for Medical and Biological Engineering-MBEC 2014*, Dubrovnik-Croatia, 130-133.
- Polikar, R., 1996, The Wavelet Tutorial, <http://users.rowan.edu/~polikar/WTPart3.html> [Ziyaret Tarihi: 10 Ocak 2019].
- Polikar, R., 1999, The story of wavelets, *Physics and Modern Topics in Mechanical and Electrical Engineering*, 192-197.
- Quinn, J., 2007, Bayesian condition monitoring in neonatal intensive care, PhD, *Dissertation, University of Edinburgh*.
- Refaeilzadeh, P., Tang, L. and Li, H., 2008, Cross-Validation, Arizona State University.
- Rice, H. E., Hollingsworth, C. L., Bradsher, E., Danko, M. E., Crosby, S., Goldberg, R. N., Tanaka, D.T. and Knobel, R. B., 2010, Infrared thermal imaging (thermography) of the abdomen in extremely low birthweight infants, *The Journal of Surgical Radiology*, 1 (2), 82-89.
- Ring, E. F. J., 2004, The historical development of thermal imaging in medicine, *Rheumatology*, 43 (6), 800-802.
- Ring, E. F. J. and Ammer, K., 2012, Infrared thermal imaging in medicine, *Physiological measurement*, 33 (3), 33-46.
- Ring, E. F. J. and Bacon, P. A., 1977, Quantitative thermographic assessment of inositol nicotinate therapy in Raynaud's phenomena, *Journal of International Medical Research*, 5 (4), 217-222.
- Rogalski, A. and Chrzanowski, K., 2002, Infrared devices and techniques, *Optoelectronics Review*, 10 (2), 111-136.
- Rumelhart, D. E., Hinton, G. E. and Williams, R. J., 1986, Learning internal representation by error propagation, In: *Rumelhart D.E., McClelland, J.L. (Eds.). Parallel Distributed Processing: Exploration in the Microstructure of Cognition*, MIT Press, Cambridge, MA, Chapter 8.
- Sandrow, R. E., Torg, J. S., Lapayowker, M. S. and Resnick, E. J., 1972, The use of thermography in the early diagnosis of neuropathic arthropathy in the feet of diabetics, *Clinical Orthopaedics and Related Research*®, 88:31-33.
- 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.
- Shatsova, E. N. and Popov, V. A., 1989, The possibilities of infrared thermography in the diagnosis of thyroid pathology, *Problemy Endokrinologii*, 35 (2), 34-37.

- Shukla, P. D., 2003, Complex wavelet transforms and their applications, MSc Thesis, *The University of Strathclyde*, Glasgow (United Kingdom), 5-30.
- Silva, C. T., Naveed, N., Bokhari, S., Baker, K. E., Staib, L. H., Ibrahim, S. M., Muchantef, K. and Goodman, T. R., 2012, Early assessment of the efficacy of digital infrared thermal imaging in pediatric extremity trauma, *Emergency Radiology*, 19 (3), 203-209.
- Skversky, N. J., Herring, A. B. and Baron, R. C., 1964, Thermography in peripheral vascular diseases, *Annals of the New York Academy of Sciences*, 121 (1), 118-134.
- Soffin, C.B., Morse, D.R., Seltzer, S., Lapayowker, M.S., 1983, Thermography and oral inflammatory conditions, *Oral Surg Oral Med Oral Pathol*, 56:256–262.
- Sruthi, S. and Sasikala, M., 2015, A low cost thermal imaging system for medical diagnostic applications, *International Conference on Smart Technologies and Management for Computing, Communication, Controls, Energy and Materials (ICSTM)*, IEEE, 621-623.
- Steketee, J., 1973, Spectral emissivity of skin and pericardium, *Physics in Medicine & Biology*, 18 (5), 686-694.
- Steed, P. A., 1991, The utilization of contact liquid crystal thermography in the evaluation of temporomandibular dysfunction. *CRANIO®*, 9 (2), 120-128.
- Starck, J.L., Candès, E.J. and Donoho, D.L., 2002, The curvelet transform for image denoising, *IEEE Transactions on Image Processing*, 11 (6), 670-684.
- Yaşar, H., 2015, Medikal Görüntülerin Çoklu Çözünürlük Metotları ile Analizi, Yüksek Lisans tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 16-28.
- Vetterli, M. and Kovacevic, J., 1995, Wavelets and Subband Coding, *Prentice Hall Inc.*, Englewood Cliffs, NJ.
- Villarroel, M., Guazzi, A., Jorge, J., Davis, S., Watkinson, P., Green, G., Shenvi, A., McCormick, K. and Tarassenko, L., 2014, Continuous non-contact vital sign monitoring in neonatal intensive care unit, *Healthcare Technology Letters*, 1 (3), 87-91.
- Williams, K. L., Williams, F. L. and Handley, R. S., 1961, Infra-red thermometry in the diagnosis of breast disease, *The Lancet*, 278 (7217), 1378-1381.
- Winsor, T. and Bendezu, J., 1964, Thermography and the peripheral circulation, *Annals of the New York Academy of Sciences*, 121 (1), 135-156.

EKLER**EK-1 Etik Kurul Kararı**

T.C.
SELÇUK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞI

GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU KARARLARI

Toplantı Sayısı: 2015/1

Toplantı Tarihi : 06.01.2015

Karar Sayısı 2015/16 S.Ü. Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Anabilim Dalı Öğretim Üyesi Yrd.Doç.Dr. Murat CEYLAN'ın, "Termal Görüntüleme Tabanlı Yeni Doğan Destek Ünitesi" başlıklı araştırmasının değerlendirilme talebi ile ilgili 25.12.2014 tarihli dilekçesi ve ekleri görüşüldü.

Yapılan inceleme ve görüşmelerden sonra: Yrd.Doç.Dr. Murat CEYLAN'ın, "Termal Görüntüleme Tabanlı Yeni Doğan Destek Ünitesi" adlı araştırmanın kabultüne, TÜBİTAK desteği alındıktan sonra protokolün dosyaya ilave edilmek üzere Etik Kurul sekretaryasına teslim edilmesine oy birliği ile karar verildi.

ASLI GİBİDİR

06/01/2015


Mehmet KESİK
Sekretarya

EK-2 Yenidoğan Termal Görüntülerinin Sağlıklı-Hasta Olarak Sınıflandırılmasında Kullanılan Ayırık Dalgacık Dönüşümünün Matlab Kodu

```
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
% OUPUT:
%   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 Yenidoğan Termal Görüntülerinin Sağlıklı-Hasta Olarak Sınıflandırılmasında Kullanılan Ridgelet Dönüşümünün Matlab Kodu

```

% RT = RIDGELET( X, L, md )

% Computes ridgelet transform as given in reference [1]. Suitable for
% denoising applications.
%
% 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(1,1);
    rt{1} = fft_iso_dwt( yp(1,:), L, md );

end

```



```
for jj = 2:1
    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
```



EK-4 Yenidoğan Termal Görüntülerinin Sağlıklı-Hasta Olarak Sınıflandırılmasında Kullanılan Hızlı Ayırık Curvelet Dönüşümünün Matlab Kodu

```

function C = fdct_wrapping(x, is_real, finest, nbscales,
nangles_coarse)

% fdct_wrapping.m - Fast Discrete Curvelet Transform via wedge
wrapping - Version 1.0
%
% Inputs
%   x           M-by-N matrix
%
% Optional Inputs
%   is_real     Type of the transform
%               0: complex-valued curvelets
%               1: real-valued curvelets
%               [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
%               [default set to ceil(log2(min(M,N)) - 3)]
%   nangles_coarse
%               number of angles at the 2nd coarsest level, minimum 8,
%               must be a multiple of 4. [default set to 16]
%
% Outputs
%   C           Cell array of curvelet 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.
%               If is_real is 1, there are two types of curvelets,
%               'cosine' and 'sine'. For a given scale j, the 'cosine'
%               coefficients are stored in the first two quadrants
(low
%               values of l), the 'sine' coefficients in the last two
%               quadrants (high values of l).
%
% See also ifdct_wrapping.m, fdct_wrapping_param.m
%
% By Laurent Demanet, 2004

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, nangles_coarse = 16; end

% Initialization: data structure
nangles = [1, nangles_coarse .* 2.^(ceil((nbscales-(nbscales:-
1:2))/2))];

```

```

if finest == 2
    nbangles(nbscales) = 1;
end

C = cell(1,nbscales);

for j = 1:nbscales
    C{j} = cell(1,nbangles(j));
end

% Loop: pyramidal scale decomposition
M1 = N1/3;
M2 = N2/3;

if finest == 1

    % Initialization: smooth periodic extension of high frequencies
    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);

    % Invariant: equiv_index_1(floor(2*M1)+1) == (N1 + 2 -
mod(N1,2))/2
    % is the center in frequency. Same for M2, N2.
    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);

    % Invariant: floor(M1) + floor(2*M1) == N1 - (mod(M1,3)~=0)
    % Same for M2, N2.
    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; % size is 2*floor(4*M1)+1 - by -
2*floor(4*M2)+1
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; % size is 2*floor(2*M1)+1 - by -
2*floor(2*M2)+1

% Loop: angular decomposition
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));           % integers
        wedge_midpoints = (wedge_endpoints(1:(end-1)) +
wedge_endpoints(2:end))/2;
        % integers or half-integers

        % Left corner wedge
        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));

        % integers
        [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));
        % Coordinates of the top-left corner of the wedge wrapped
        % around the origin. Some subtleties when the wedge is
        % even-sized because of the forthcoming 90 degrees rotation

        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);
        % not integers in general

```

```

        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

% Regular wedges
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);
    end
end

```

```

        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}{l} =
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}{l} = sqrt(2)*real(x);
        C{j}{l+nbangles(j)/2} = sqrt(2)*imag(x);
    end
end

% Right corner wedge
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
    end
    if quadrant < nbquadrants
        Xhi = rot90(Xhi);
    end
end
end

% Coarsest wavelet level
C{1}{1} = fftshift(iff2(iff2shift(Xlow)))*sqrt(prod(size(Xlow)));
if is_real == 1
    C{1}{1} = real(C{1}{1});
end
end

```


EK-5 Yenidoğan Termal Görüntülerinin Sağlıklı-Hasta Olarak Sınıflandırılmasında Kullanılan Contourlet Dönüşümünün Matlab Kodu

```

function y = pdfbdec(x, pfilter, dfilter, nlevs)

% PDFBDEC Pyramidal Directional Filter Bank (or Contourlet)
Decomposition
%
% y = pdfbdec(x, pfilter, dfilter, nlevs)
%
% Input:
% x: input image
% pfilter: filter name for the pyramidal decomposition step
% dfilter: 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(pfilter);

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

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

```

```

        case {'pkva6', 'pkva8', 'pkva12', 'pkva'}
            % Use the ladder structure (which 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

```

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Duygu SAVAŞCI
Uyruğu : TC
Doğum Yeri ve Tarihi : KONYA, 01.01.1991
Telefon : (+90) 534 932 22 72
E-Posta : duyguzn8559@gmail.com

EĞİTİM

Derece	Adı	İlçe	İl	Bitirme Yılı
Lise	: Atatürk Lisesi, Ereğli, KONYA (91/100)			2009
Üniversite	: Erciyes Üniversitesi, Talas, KAYSERİ			2015
		Elektrik-Elektronik Mühendisliği (3.53/4)		
		Bilgisayar Mühendisliği (Çift Anadal) (2.99/4)		
Yüksek Lisans	: Selçuk Üniversitesi, Selçuklu, KONYA			2019
		Elektrik – Elektronik Mühendisliği A.B.D (90.77)		

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2016		Tübitak 1001 proje bursiyerliği

UZMANLIK ALANI

Görüntü İşleme, Makine Öğrenmesi, Çoklu Çözünürlük Analizi

YABANCI DİLLER

İngilizce (İyi derecede)

YAYINLAR

1. **Savaşçı, D.**, Ceylan, M., 2018, Thermal image analysis for neonatal intensive care units (First evaluation results), *SIU 2018*, İzmir, Türkiye.
2. Örnek, A.H., **Savaşçı, D.**, Ervural, S., Ceylan, M., Soylu, H., 2018, Termogramların Değerlendirilmesinde Doğru Yaklaşımların Belirlenmesi, *URSI-TÜRKİYE 2018 IX. Bilimsel Kongresi*, KTO Karatay Üniversitesi, Konya.

3. **Savaşçı, D.**, Örnek, A.H., Ervural, S., Ceylan, M., Konak, M., Soylu, H., 2019, Classification of Unhealthy And Healthy Neonates in Neonatal Intensive Care Units Using Medical Thermography Processing and Artificial Neural Network (Accepted), *Classification Techniques for Medical Image Analysis and Computer Aided Diagnosis, Elsevier Book Chapter*, Scheduled publish date 23rd August 2019.

