İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

2-B DİKGEN KAFES SÜZGEÇ YAPILARIYLA GÖRÜNTÜ BÖLÜTLEME

YÜKSEK LİSANS TEZİ

Müh. Saide Zeynep AYKUT

Anabilim Dalı : ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ

Programı : TELEKOMÜNİKASYON MÜHENDİSLİĞİ

MAYIS 2004

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

2-B DİKGEN KAFES SÜZGEÇ YAPILARIYLA GÖRÜNTÜ BÖLÜTLEME

YÜKSEK LİSANS TEZİ
Müh. Saide Zeynep AYKUT
504021319

Tezin Enstitüye Verildiği Tarih : 26 Nisan 2004
Tezin Savunulduğu Tarih : 21 Mayıs 2004

Tez Danışmanı : Yrd.Doç.Dr. Işın ERER

Diğer Jüri Üyeleri : Prof.Dr. Ahmet H. KAYRAN

Prof.Dr. Serhat ŞEKER

MAYIS 2004

ÖNSÖZ

Tezimin hazırlanması sırasındaki her aşamada desteğini, yardımlarını ve güleryüzünü esirgemeyen tez danışmanım Yrd. Doç. Dr. Işın Erer'e teşekkürlerimi bir borç bilirim.

Çalışmam boyunca, gösterdikleri sevgi, sabır ve yardımları için aileme ve de tüm dostlarıma çok teşekkür ederim.

Nisan, 2004 Saide Zeynep AYKUT

İÇİNDEKİLER

KISALTMALAR **v**
TABLO LİSTESİ **vi**
ŞEKİL LİSTESİ **vii**
ÖZET **ix**

SUMMARY **xi**

1. GİRİŞ **1**

2. GÖRÜNTÜ BÖLÜTLEMEDE DÖNÜŞÜM TABANLI ÖZNİTELİK ÇIKARIM YÖNTEMLERİ **6**

2.1. Öznitelik Çıkartma İşlemi 6
2.2. Kafes Süzgeç Yapıları 8
2.2.1. 1-B kafes yapıları 9
2.2.1.1. Sonlu geçmişe dayalı doğrusal öngörü: Levinson-Durbin özyinelemesi 9
2.2.1.2. Kafes öngörücüler 12
2.2.2. 2-B kafes yapıları 15
2.2.2.1. Üç parametreli kafes süzgeç yapısı 16
2.2.2.2. 2-B dikgen kafes süzgeç yapıları 18
2.3. Dalgacık Dönüşümü 26
2.3.1. Fourier dönüşümü 26
2.3.2. Sürekli dalgacık dönüşümü 28
2.3.3. Ayrık dalgacık dönüşümü 28

3. GÖRÜNTÜ BÖLÜTLEME **33**

3.1. Çalışmada İncelenen Görüntüler 33
3.1.1. Doku görüntüsü 33
3.1.1.1. Doku tanımı 34
3.1.2. Optik görüntü 35
3.2. Görüntülerin Bölütlenmesi 36
3.2.1. 2-B kafes yapılar ile görüntü bölütleme 36
3.2.2. Ayrık dalgacık dönüşümü ile görüntü bölütleme 37
3.3. Eğitim Aşaması 37
3.3.1. 2-B dikgen kafes süzgeç yapılarında eğitim 38

3.3.2. Üç parametreli kafes süzgeçlerde eğitim 40
3.3.3 Ayrık dalgacık dönüşümünde eğitim 41
3.4. Test Aşaması 42
3.4.1. Doku görüntülerinin bölütlenmesi 45
3.4.2. Optik görüntülerin bölütlenmesi 56

4. SONUÇLAR 61

KAYNAKLAR 63

ÖZGEÇMİŞ 68

KISALTMALAR

2-D	: Two-Dimensional
MRF	: Markov Random Fields
MSRF	: Multiscale Random Field
MAP	: Maximum a Posteriori
SMAP	: Sequential Maximum a Posteriori
GMRF	: Gauss-Markov Random Fields
SAR	: Synthetic Aperture Radar
DWF	: Discrete Wavelet Frame
TPLF	: Three-Parameter Lattice Filters
EDLF	: Extended Lattice Filters of Diagonal Form
FILF	: Further Improved Lattice Filters
FD	: Fourier Dönüşümü
KZFD	: Kısa Zamanlı Fourier Dönüşümü
DD	: Dalgacık Dönüşümü
ADD	: Ayrık Dalgacık Dönüşümü
SDD	: Sürekli Dalgacık Dönüşümü

TABLO LİSTESİ

Sayfa No

Tablo 3.1. Çeyrek düzlem modelinde 1.,2. ve 3. dereceler için oluşturulan yansıma katsayıları 39

ŞEKİL LİSTESİ **Sayfa No**

Şekil 2.1 :Karar verme mekanizması..... 6
Şekil 2.2 :1-B kafes süzgecin m. aşaması 15
Şekil 2.3 : n aşamalı üç parametreli kafes süzgeç yapısı..... 17
Şekil 2.4 : Çeyrek ve simetrik olmayan yarı düzlem modelleri için N. derecede olası bazı dizilimler
(a)çeyrek düzlem modeli
(b)simetrik olmayan yarı düzlem modeli..... 19
Şekil 2.5 :2-B dikgen kafes süzgecin n.aşamasında $\Pi^{(n)}_{p-n,p}$ bloğu 23
Şekil 2.6 : 2-B dikgen kafes yapı algoritması..... 24
Şekil 2.7 : Ayrık dalgacık dönüşümünde bir seviyeli ayrıştırma..... 30
Şekil 2.8 : (a) 2-B görüntü için iki seviyeli ayrık dalgacık ayrıştırması
(b) İki seviyeli dalgacık ayrıştırması ile oluşan kanallar..... 32
Şekil 3.1 : Düzenli ve istatistiksel doku görüntüleri..... 34
Şekil 3.2 : 2-B dikgen kafes yapılar için eğitim aşaması..... 38
Şekil 3.3 :Üç parametreli yapı için eğitim aşaması..... 40
Şekil 3.4 : ADD için eğitim aşaması..... 41
Şekil 3.5 : Görüntü bölütleme ve sınıflandırma işlemleri..... 44
Şekil 3.6 : Brodatz albümünden seçilen görüntüler..... 45
Şekil 3.7 : (a) Bölütleme ve sınıflama işlemlerinde kullanılan 4 sınıflı görüntü
(b) Bölütleme ve sınıflama işlemlerinin ideal sonucu..... 46
Şekil 3.8 : 8x8'lik pencerelerle yatay yönde 8 piksellik kaydırma sonuçları
(a)2-B dikgen kafes , 1.derece, çeyrek düzlem, Öklid uzak.
(b) 2-B dikgen kafes , 2.derece, çeyrek düzlem, Öklid uzak.
(c) 2-B dikgen kafes , 3.derece, çeyrek düzlem, Öklid uzak.
(d) 5 aşamalı 3 parametreli kafes, Öklid uzaklığı
(e) 2 seviyeli ayrık dalgacık dönüşümü, Öklid uzaklığı..... 47
Şekil 3.9 : 8x8'lik pencerelerle 8 piksellik kaydırma sonuçları
(a)2-B dikgen kafes , 2.der., çeyrek d., Öklid uzak.
(b)2-B dikgen kafes , 2.der., çeyrek d., Mahalonibis uzak.
(c) 5 aşamalı 3 parametreli kafes, Öklid uzak.
(d) 5 aşamalı 3 parametreli kafes, Mahalonibis uzak..... 48
Şekil 3.10 : 16x16'lık pencerelerle 16 piksellik kaydırma sonuçları
(a) 2-B dikgen kafes , 1.der., çeyrek d.
(b) 2-B dikgen kafes , 2.der., çeyrek d.
(c) 2-B dikgen kafes , 3.der., çeyrek d.
(d) 5 aşamalı 3 parametreli kafes
(e) 2 seviyeli ayrık dalgacık dönüşümü 49

Şekil 3.11 : 32x32'lik pencerelerle 32 piksellik kaydırma sonuçları
(a) 2-B dikgen kafes , 2.der., çeyrek d.
(b) 2-B dikgen kafes , 3.der., çeyrek d.
(c) 5 aşamalı 3 parametreli kafes
(d) 2 seviyeli ayrık dalgacık dönüşümü..... 50

Şekil 3.12 : 16x16'lık pencerelerle 8 piksellik kaydırma sonuçları
(a) 2-B dikgen kafes , 2.der., çeyrek d.
(b) 2-B dikgen kafes , 3.der., çeyrek d.
(c) 5 aşamalı 3 parametreli kafes
(d) 2 seviyeli ayrık dalgacık dönüşümü..... 51

Şekil 3.13 : 32x32'lik pencerelerle 16 piksellik kaydırma sonuçları
(a) 2-B dikgen kafes , 2.der., çeyrek d.
(b) 2-B dikgen kafes , 3.der., çeyrek d.
(c) 5 aşamalı 3 parametreli kafes
(d) 2 seviyeli ayrık dalgacık dönüşümü..... 52

Şekil 3.14 : 11x11'lik pencerelerle yatay yönde tek piksel kaydırma sonuçları
(a) 2-B dikgen kafes , 2.der., çeyrek d.
(b) 2-B dikgen kafes , 3.der., çeyrek d.
(c) 5 aşamalı 3 parametreli kafes..... 53

Şekil 3.15 : 21x21'lik pencerelerle tek piksel kaydırma sonuçları
(a) 2-B dikgen kafes , 2.der., çeyrek d.
(b) 2-B dikgen kafes , 3.der., çeyrek d.
(c) 5 aşamalı 3 parametreli kafes..... 54

Şekil 3.16 : Ayrık dalgacık dönüşümü için tek piksel kaydırma sonucu
(a) 8x8'lik pencerelerle
(b) 16x16'lık pencerelerle
(c) 32x32'lik pencerelerle..... 55

Şekil 3.17 : Optik görüntü için 7x7 lik pencereyle piksel-piksel kaydırma sonuçları
(a) İncelenen optik görüntü
(b) 2-B dikgen kafes , 2.der., çeyrek d.
(c) 2-B dikgen kafes , 3.der., çeyrek d.
(d) 5 aşamalı 3 parametreli kafes
(e) 2 seviyeli ayrık dalgacık dönüşümü, 8x8'lik pencereyle..... 58

Şekil 3.18 : Optik görüntü için kafes yapılarda 9x9' luk pencereyle piksel-piksel kaydırma sonuçları
(a) 2-B dikgen kafes , 2.der., çeyrek d.
(b)5 aşamalı 3 parametreli kafes..... 59

2-B DİKGEN KAFES SÜZGEÇ YAPILARIYLA GÖRÜNTÜ BÖLÜTLEME

ÖZET

Görüntü sınıflandırmanın ilk adımı genellikle görüntünün bölütlenmesidir. Bölütleme ile, görüntünün kendi içinde benzer özellik gösteren bölgeleri birbirinden ayrılır. Bölütlemenin en temel adımlarından biri, görüntünün içindeki homojen bölgeleri temsil eden özelliklerin, yani özniteliklerin elde edilmesidir. Doğru özniteliklerin tespiti, sınıflandırma başarımını da artırır.

Öznitelik çıkartmada pek çok yöntem bulunmaktadır. Bu yöntemler, istatistiksel ve dönüşüm tabanlı yöntemler olmak üzere ikiye ayrılır. Ayrık dalgacık dönüşümü, bölütleme uygulamalarında sıkça kullanılan dönüşüm tabanlı bir yöntemdir. 2-B kafes yapılar da dönüşüm işlemine dayanır ancak daha önce bu yapılardan sadece üç parametreli kafes yapısı doku görüntülerinin bölütlenmesinde kullanılmıştır. Üç parametreli kafes yapı, ilk 2-B kafes süzgeç uygulamasıdır ve çok basit bir yapıdır. Daha sonra pek çok 2-B kafes yapı geliştirilmiştir. Bu tezde, bölütlemede kullanılan öznitelikleri çıkartmak için 2-B dikgen kafes süzgeç yapılar önerilmiştir. Bu yapıların seçilme nedeni, çok gelişmiş ve dikgenlik özelliği sayesinde de çok sağlam yapılar olmalarıdır. Üç parametreli kafes yapı uygulamasında olduğu gibi, öznitelik vektörünün elemanları 2-B dikgen kafes yapıların yansıma katsayılarıdır.

Bu tezde, görüntü olarak, görüntü analizinde kullanılan başlıca görüntü çeşidi olan Brodatz doku görüntüleri ile tek spektral bantlı, siyah-beyaz bir optik görüntü kullanılmıştır. Optik görüntüler, 2-B kafes yapı uygulamalarında daha önce hiç denenmemiştir.

Önerilen yöntemde, öngörü destek bölgesi olarak çeyrek düzlem modeli kullanılmış ve 1., 2. ve 3. dereceler için elde edilen sonuçlar, üç parametreli beş aşamalı kafes süzgeçler ve 2 seviyeli ayrık dalgacık dönüşümü ile elde edilen sonuçlarla karşılaştırılmıştır.

Yapılan çalışmada, belirli boyutlardaki pencereler görüntü üzerinde kaydırılarak pencerenin her konumunda , tezde uygulanan üç yöntem kullanılarak o pencereye ait öznitelik vektörleri bulunmuştur. Sonra bu öznitelik vektörleri daha önce eğitim aşamasında hesaplanmış olan öznitelik vektörleriyle karşılaştırılarak sınıf kararı verilmiştir. Karar verme adımında minimum uzaklık sınıflayıcısı kullanılmıştır.

Önerilen yöntem, doku görüntülerinde diğer yöntemlerden çok daha iyi performans göstermiştir. Ayrıca eğitim aşaması, ayrık dalgacık dönüşümüne göre önemli derecede kısadır. Oluşan hatalar pencerelemeden dolayı özellikle sınıfların sınırlarında gerçekleşmiştir. Optik görüntüde ise, önerilen yöntem diğer 2-B kafes yapısı olan, üç parametreli kafes yapısından daha üstündür. Ancak bazı yönlerden ayrık dalgacık dönüşümünden daha düşük performans göstermiştir. Bunun sebepleri, görüntünün tek spektral bantlı olması ve sınıflar hakkındaki kesin bilgilerin eksik olmasıdır. Bu yüzden, doğru öznitelikler elde edilememiştir.

Sonuç olarak, tezde önerilen 2-B dikgen kafes yapının görüntü bölütleme için kullanılabileceği görülmüştür. Önerilen yöntemin doku görüntülerinde daha iyi performans gösterebilmesi için pencerelemeden dolayı oluşan sınır hatalarını ortadan kaldıracak bir ön işlem yapılması doğru olacaktır. Optik görüntülerde daha doğru özniteliklerin elde edilebilmesi için ise çok bantlı ve kesin sınıf bilgilerine sahip olunan görüntülerle çalışılmalıdır.

IMAGE SEGMENTATION USING 2-D ORTHOGONAL LATTICE FILTER STRUCTURES

SUMMARY

Usually, the first step in image classification is to segment the image. Through segmentation, an image is partitioned into uniform regions. One of the primary steps of segmentation is to determine the characteristics of the homogeneous regions in the image. These are the features. True features increase the performance of the classification procedure.

There are several methods for feature extraction. These methods are divided into statistical and transform-based methods. Discrete wavelet transform is a transform-based method which is often used in segmentation applications. Although 2-D lattice structures are also transform-based methods, only the three-parameter lattice filter structure had been used for texture segmentation before. The three-parameter lattice filter structure is the first 2-D lattice structure to be developed and has a very simple structure. Many other 2-D lattice structures are developed afterwards. In this thesis, 2-D orthogonal lattice filter structures are proposed to extract the features used in segmentation. The reason, why these structures are chosen is their improved structure and their robustness which they owe to their property of orthogonality. The elements of the feature vector are the reflection coefficients of the 2-D orthogonal lattice filter structures as it was in the three-parameter lattice filter structure case.

Images used in this thesis are Brodatz texture images which belong to the main image type used in image analysis and a monospectral, black-and-white optical image. Optical images have never been used in 2-D lattice structure applications before.

In the proposed method, the quarter-plane model is applied as the prediction support region and results obtained for the 1^{st}, 2^{nd} and 3^{rd} orders are compared with the results of the three-parameter five stages lattice filters and the two-level discrete wavelet transform.

In this work, windows of certain sizes are run on the image and at each position of the window feature vectors are extracted with the three methods applied in the thesis. Then, these feature vectors are compared with those which had been calculated at the learning stage and the class decision is made. At the decision step, the minimum distance classifier is used.

The proposed method has a much better performance than the other methods on texture images. Besides, it has a much shorter learning stage than the discrete wavelet transform. Errors occur especially on the borders of classes because of windowing. In the case of optical image, the proposed image is superior to the three-parameter lattice structure. However, it has a lower performance than the discrete

wavelet transform in some respects. The reasons for that are the monospectral behavior of the image and the lack of exact information about the classes. Therefore, true features could not be obtained.

As a result, it is realized that the proposed 2-D orthogonal lattice filter structure can be used for image segmentation. In order to get a better performance on texture images in the proposed method, a preprocessing method can be applied to remove the errors on borders which appear because of the windowing. In order to obtain true features in the optical image case, one has to work with images which are multispectral and allow getting exact information about their classes.

1. GİRİŞ

Bölütleme, görüntü analizindeki başlıca adımlardan biridir. Bölütlemenin amacı,birden fazla kendi içinde benzer özellik gösteren kısma sahip olan bir görüntüyü bu alt

kısımlarına ayırmaktır.

Literatürde, yüzlerce bölütleme tekniği bulunmaktadır. Ancak ne tüm görüntüler için iyi sonuç verdiğine inanılan tek bir yöntem vardır, ne de tüm yöntemler belirli bir tür görüntü için eşit derecede iyi sonuç vermektedir. Ayrıca, bir tip görüntü için geliştirilen bir algoritma, her zaman diğer tipte görüntülere uygulanamamaktadır. Hatta, belirli türde bir görüntü için uygun bir yöntemin seçilmesi bile sorun yaratmaktadır[1].

Görüntüdeki farklı nesneleri ayırabilmek için kullanılan yöntemler, kabaca ikiye ayrılabilir:

1. İstatistiksel yöntemler
2. Dönüşüm tabanlı yöntemler

İstatistiksel yöntemler, görüntüyü bazı sayısal özellik ve özniteliklerine göre karakterize ederler[2]. Görüntünün pikselleri arasındaki ilişki, bir matris yardımıyla ifade edilir ve bu matristen oluşturulan istatistiksel öznitelikler ile de istatistiksel analiz gerçekleştirilir. Aşağıda istatistiksel yöntemlere örnekler verilmiştir:

[3]'te, Bayes tekniğiyle görüntü bölütlemek için, Markov rasgele alanları(Markov random fields-MRF) ile birlikte kullanılan MAP(maximum a posteriori) kestiriminin hesaplanmasında karşılaşılan işlem yoğunluğunun azaltılabilmesi için yeni bir yöntem sunulmuştur. Bu yöntemde, yeni bir, çok kademeli rastgele alan(multiscale random field-MSRF) ve yeni bir kestirim kriteriyle elde edilen bir dizisel MAP(sequential MAP-SMAP) kullanılmıştır. SMAP kestirimcisinin kullanılmasıyla işlem yükü hafiflemiştir. Ayrıca, Markov zincir yapısını kullanan MSRF modeli sayesinde de model parametreleri, bölütleme işlemi sırasında görüntüden verimli bir

şekilde elde edilebilmiştir. Böylece, görüntüdeki farklı büyüklüklere sahip bölgeler, önceden özel bir bilgiye gerek duyulmadan doğru bir şekilde bölütlenebilmiştir[3].

[4]'te, doku görüntüsünün bölütlenmesi için ilişki katsayıları kullanılmıştır. Bu çalışmada, görüntü önce kare şeklinde bölgelere ayrılarak her bir bölgenin ilişki katsayıları hesaplanmış ve bu katsayılar bölgeleri niteleyen parametreler olarak kabul edilmiştir. Eğer bu bölgelerin parametreleri arasında bir benzerlik varsa, bu benzerlik gösteren bölgelerin birleşimleri tek cinsten(homojen) kabul edilmiştir[4]. Bölütleme için bir ön adım niteliğinde olan bu adımdan sonra, ilişki katsayılarını ve bölgelerin birbirlerine yakınlıklarını gösteren grafiği kullanan bir algoritma ile küçük bölgelerin elenmesini sağlayan bazı adımlar uygulanarak bölütleme işlemi tamamlanmıştır.

[5]'te, görüntü, birbirleriyle örtüşmeyen küçük bölgelere ayrılarak her bir bölge için Gauss-Markov rastgele alan(GMRF) parametreleri hesaplandıktan sonra, bu bölgelere, uzaklık ölçümüne dayalı basit bir gruplama yöntemi uygulanmıştır. Daha sonra, gruplanmış kısımlardan kestirilen model parametreleri iki ayrı amaç için kullanılmıştır. Bunların biri, etiketlerin MAP(maximum a posteriori) kestirimlerinin yaklaşıklığının(approximation) bulunması, diğeri ise, yanlış sınıflandırmadan doğan hatanın minimize edilmesidir[5].

[6]'da görüntü verisi için, iki misli stokastik ya da hiyerarşik olan bir model kullanılmıştır. İlk olarak, görüntü piksellerini benzer özniteliklere sahip bölgeler şeklinde gruplandırıp karakterize etmek için Gibbs dağılımı kullanılmıştır. Daha sonraki aşamada da, öznitelikler ya da bölgelerin dokusal özellikleri, her bir sınıf tipi için ikinci bir Gibbs dağılımı kümesiyle modellenmiştir. Bölütleme algoritması, MAP(maximum a posteriori) olasılık kriteri ile oluşturulmaktadır. MAP kestirimi sırasında karşılaşılan hesap yükünü azaltmak için modelde bazı kabuller yapılmıştır.

Dönüşüm tabanlı yöntemler, özellikle Gabor süzgeçleri ve dalgacık dönüşümü sonucunda elde edilen parametreleri, bölütleme işlemi için öznitelikler olarak kullanan yöntemlerdir.

Aşağıda, dönüşüm tabanlı yöntemleri kullanan bazı çalışmalara yer verilmiştir:

Gabor temel fonksiyonlarından yararlanılarak oluşturulan Gabor süzgeç bankaları, pek çok doku bölütleme uygulamasında kullanılmıştır. Gabor süzgeçleriyle yapılan bölütleme işleminin başarımı, Gabor süzgeç parametrelerinin uygun seçilmesine bağlıdır. [7], uygun süzgeç parametrelerinin sistematik bir şekilde seçilmesini

sağlayan bir yöntem geliştirmiştir. Bu çalışmada, görüntüdeki farklı dokular için kullanılacak örneklerin daha önceden verildiği varsayılmaktadır. Gabor süzgeç çıkışlarının Rician rastgele değişkeni olarak modellenebileceği ve Gauss rastgele değişkeni ile iyi bir yaklaşıklık sağlanabileceği öne sürülmüş ve bölütleme performansının artırılması için de yine Rician modeline dayanan çoklu-süzgeç bölütlemesi uygulanmıştır.

[8]'de bir yapay açıklıklı radar(synthetic aperture radar-SAR) görüntüsü, klasik piramit yapılı dalgacık dönüşümü kullanılarak sınıflandırılmıştır. Piramit yapılı dalgacık dönüşümünde, ilk seviye dalgacık dönüşümünden sonra sadece alçak frekans bileşenlerini içeren alt görüntüler ayrıştırılarak işlem devam etmektedir. Bu çalışmada, birinci seviye ayrıştırma sonucunda oluşan dört alt bant arka arkaya konularak, her bir bantta aynı yerde bulunan dört pikselin oluşturduğu vektörler, öznitelik vektörleri olarak seçilip bölütleme ve sınıflandırmada kullanılmıştır.

[9]'da da, klasik piramit yapılı ayrık dalgacık dönüşümü kullanılmıştır. Bu dönüşümle, eldeki görüntünün ya da pencerenin yaklaşıklık katsayılarını veren alçak frekanslı alt görüntüler ayrıştırılmış, oluşan her kanal için l_1-norm ile öznitelikler oluşturulmuş ve ardından bu öznitelikler ağırlıklandırılarak bölütlemede kullanılmıştır.

[10]'da doku analizi ve sınıflandırması için 'ağaç yapılı dalgacık dönüşümü' ya da 'dalgacık paketleri' adı verilen bir dalgacık dönüşümü çeşidi geliştirilmiştir. Klasik piramit yapılı dalgacık dönüşümü sadece alçak frekanslı alt işaretleri ayrık dalgacık dönüşümüyle ayrıştırmaktadır. Ancak bu çalışmada, doku görüntülerindeki en önemli bilgilerin daha çok orta frekanslarda ortaya çıktığı ve yalnızca alçak frekans kanallarını ayrıştırmakla yeterince iyi bir sınıflandırma yapılamayacağı, diğer frekans kanallarıyla da işlem yapılması gerektiği savunulmuştur. Çalışmada, l_1-norm kullanılarak daha sonraki aşamalarda ayrıştırılacak olan dominant kanallar belirlenmektedir. Bu dominant kanallar ayrıştırılarak elde edilen alt görüntülerin enerjileri öznitelik olarak kabul edilip bölütleme işlemi gerçekleştirilmiştir.

[11]'de, doku özelliklerinin karakterize edilebilmesi için değişik bir ayrık dalgacık dönüşümü kullanılmıştır. Uygulanan yöntemde, görüntüden pencerelemeler ile elde edilen giriş işareti bir süzgeç bankasından geçirilmekte, ancak çıkışlar, klasik dalgacık dönüşümünden farklı olarak, alt-örneklenmemektedir. Kullanılan bu yapıya 'ayrık dalgacık çerçevesi(discrete wavelet frame-DWF)' adı verilmiştir. Süzgeç

çıkışlarının enerji ölçümleri öznitelik olarak kabul edilip bölütleme işlemini kolaylaştırmak için Karhunen-Loeve dönüşümüyle boyut indirgemesi yapıldıktan sonra K-ortalamalar gruplama algoritmasıyla bölütleme gerçekleştirilmiştir.

[12], doku görüntüsünden elde edilen bazı parametrelerin dokuyu karakterize etmek için kullanıldığı, modele dayalı bir çalışmadır. Model parametreleri, daha önce görüntü bölütlemede hiç uygulanmamış bir yöntem olan iki boyutlu(2-B) kafes yapılarının yansıma katsayılarıdır. Çalışmada, basitliğinden dolayı üç parametreli kafes yapısı kullanılmıştır. Yansıma katsayıları, öznitelik vektörleri olarak seçilerek bölütleme gerçekleştirilmiştir.

Bu tezde, yenilik, öznitelik çıkartma aşamasındadır. Bölütlemede kullanılan öznitelik vektörlerini oluşturmak için, daha önce denenmemiş bir yapı olan 2-B dikgen kafes yapının yansıma katsayıları kullanılmıştır. Bu 2-B kafes yapı, üç parametreli kafes yapıdan çok daha gelişmiş bir yapıdır. Dikgenlik özelliği sayesinde daha sağlamdır ve üç parametreli kafes yapıya göre çok daha fazla sayıda yansıma katsayısı oluşturur. Böylece görüntüyü daha iyi karakterize eden özniteliklerin elde edilmesi ve bölütleme performansının artması sağlanır.

2-B özbağlanımlı kafes modelleme, şimdiye dek çeşitli alanlarda pek çok uygulama alanı bulmuştur. Bu alanlardan bazıları, çok boyutlu spektral kestirim[13-17], görüntü verilerinin sıkıştırılması[18–20], zamanla değişen görüntülerin uyarlamalı olarak kodlanması[21], gürültünün ortadan kaldırılması ve görüntü onarımı için 2-B birleşik süreçlerle kestirimdir[22-23]. Diğer potansiyel uygulama alanları ise yüksek çözünürlüklü radar görüntüleme[24], 2-B veri genişletme[25] ve görüntülerdeki küçük nesnelerin bulunmasını kolaylaştırmak için birbirleriyle ilişkili saçıcıların temizlenmesidir[26].

Bu tezde, 2-B dikgen kafes süzgeç yapılarının görüntü bölütleme uygulamalarında kullanılabilecek algoritmalar olduğu görülmüştür.

Çalışmanın bundan sonraki kısmı şu şekilde düzenlenmiştir:

II.Bölüm'de, bölütlemenin en önemli bölümü olan öznitelik çıkartma işlemi açıklanmış ve çalışmada karşılaştırma amacıyla kullanılan üç öznitelik çıkartma yöntemi, üç parametreli kafes yapı, önerilen 2-B dikgen kafes yapı ve dalgacık dönüşümü tanıtılmıştır. III.Bölüm'de, bölütleme işleminde kullanılan görüntü

çeşitleri anlatılmış, tüm işlemler boyunca izlenen yollar adım adım açıklanıp elde edilen benzetim sonuçları verilmiştir. IV.Bölüm ise çalışmada varılan sonuçları içermektedir.

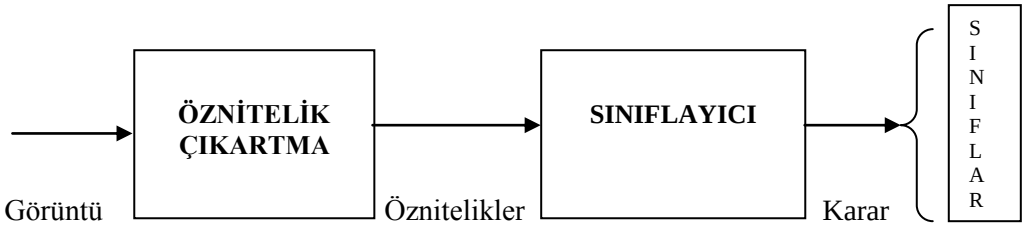
2. GÖRÜNTÜ BÖLÜTLEMEDE DÖNÜŞÜM TABANLI ÖZNİTELİK ÇIKARIM YÖNTEMLERİ

Görüntü sınıflandırmada ilk adım genellikle görüntünün bölütlenmesidir. Bölütleme ile görüntü, homojen(tek cinsten) bölgelere ayrılır. Bu uygulamada, ilgilenilen nesne çevresinden izole edildiğinde bölütleme işlemi sona ermelidir[27]. Bölütleme işleminden sonra da, elde edilen sınıflara ayrı ayrı etiketler atanarak son görüntü oluşturulur.

'GİRİŞ' bölümünde bölütleme için istatistiksel ve dönüşüm tabanlı yöntemler olmak üzere iki yaklaşımdan söz edilmiştir. Bu çalışmada önerilen yöntem ve karşılaştırma amacıyla kullanılacak yöntemler ikinci sınıfa girmektedir. O yüzden bu bölümde, önce bölütlemenin ana amacı olan 'öznitelik elde etme işlemi', ardından da tezde yer verilen ve öznitelik çıkartma amacıyla başvurulan dönüşüm tabanlı yöntemler, 'kafes yapıları' ve 'dalgacık dönüşümü' incelenecektir.

2.1. Öznitelik Çıkartma İşlemi

Görüntü analizinde, orijinal görüntüden içinde barındırdığı sınıfların elde edilmesine kadar geçen süreç aşağıda gösterilmektedir.



Şekil 2.1 Karar verme mekanizması

Dönüşüm işlemi, kategorileri birbirinden ayırt eden özelliklerin, yani özniteliklerin bulunmasıdır. Bu çalışmada getirilen yenilik de 'öznitelik çıkartma' aşamasındadır.

Bir görüntünün özniteliği, az önce de belirtildiği gibi, onu diğer görüntülerden ayıran temel bir özelliği ya da karakteristiğidir. Özniteliklerin çıkartılması da sadece bir

kategoriye ait olan, diğer kategorilerde bulunmayan bu karakteristik bilgilerin tespit edilmesidir. Bu yolla, parlaklık, kontrast vb. görüntü karateristiklerine olan bağımlılık azalır ve çok daha küçük bir veri takımı oluşturulur[28]. Kategorileri birbirinden ayıran doğru özelliklerin tespit edilmesi, sınıflama başarımını artırdığı için öznitelik çıkartma, görüntü bölütleme ve sınıflandırmanın en temel adımlarından biridir.

Bölütleme için kullanılan dönüşüm tabanlı yöntemler ile görüntüyü karakterize eden parametreler elde edilir ve bunlar görüntünün öznitelikleri olarak sınıflandırma algoritmasına sokulur.

Görüntü bölütleme için kullanılan en yaygın yöntemlerden biri dalgacık dönüşümüdür. Dalgacık dönüşümü, hem zamanda hem de frekansta iyi lokalizasyon sağladığı için görüntü bölütleme konusunda literatürde yer bulmuştur. Ayrık dalgacık dönüşümü, Fourier serisi katsayılarına benzer şekilde elde edilen katsayılarının oluşturduğu matrislerle çoklu çözüm analizi yapılmasına olanak sağlar[28]. Ayrık dalgacık dönüşümünde öznitelik olarak kullanılacak dalgacık katsayıları, kimi zaman piramit yapılı ayrık dalgacık dönüşümünden[8-9], kimi zaman dalgacık paketlerinden[10], kimi zamansa dalgacık çerçevelerinden elde edilir[11].

Kafes süzgeçleri, dikgen yapıları ve modülerlik özelliklerinin VLSI uygulamalarına izin vermeleri nedeniyle son yıllarda üstünde çok çalışılan, başarılı bir dönüşüm yöntemidir. Ancak görüntü bölütleme ve sınıflandırma alanlarında son derece sınırlı sayıda uygulamaları mevcuttur. [12]'de, üç parametreli kafes yapısından elde edilen yansıma katsayıları öznitelik olarak kullanılarak doku görüntüleri bölütlenmiş ve sınıflandırılmıştır. Ancak üç parametreli kafes yapısı iki boyut için ilk geliştirilen, en basit yapılardandır. Her aşamada üç parametre üretmektedir. Bu yüzden görüntüyü yeterince iyi modelleyebilecek sayıda öznitelik kullanamamaktadır. Çalışmada, üç parametreli kafes yapısının görüntü bölütlemede kullanılan özniteliklerin çıkarılmasında başvurulabilecek alternatif bir yöntem olduğu kanıtlanmış olmasına rağmen bu alanın yeniliklere açık olduğu da vurgulanmıştır.

Gerçekten de, üç parametreli kafes süzgeç yapısı, çok basit bir yapı olması ve dikgenlik özelliği bulunmaması yüzünden, daha karmaşık ama sağlam bir kafes yapısının daha iyi sonuçlar verebileceği rahatlıkla düşünülebilir. Bu tezde, öznitelik çıkartma yöntemi olarak önerilen 2-B dikgen kafes yapı ise daha geliştirilmiş bir yapıdır. Üç parametreli kafes yapısına oranla çok daha fazla öznitelik oluşturmakta,

böylece de görüntünün daha iyi karakterize edilmesini sağlamaktadır. Görüntüyü daha iyi karakterize eden özniteliklerin kullanılması, sınıflama başarımını da arttırmaktadır.

Bu bölümün geri kalan kısmında, yukarıda kısaca değinilen ve çalışmada karşılaştırması verilen üç dönüşüm yöntemi etraflıca anlatılacaktır.

2.2. Kafes Süzgeç Yapıları

Kafes süzgeçler ve benzeri yapılar son 30 yıldır önemli bir araştırma alanı oluşturmaktadır. Bir boyutlu(1-B) kafes süzgeçler, doğrusal modellerin oluşturduğu geniş bir sınıfın katsayılarının kestirildiği yinelemeli bir tekniktir[29]. 1-B kafes modelleri iyi şekilde geliştirilmiş ve pek çok uygulama alanı bulmuşlardır. Kafes yapılar, kolayca oluşturulabilen, modüler yapılardır.

1-B kafes yapıların başarısı, 2-B yapıların geliştirilmesi için çalışmaları da beraberinde getirmiştir. Literatürde, 2-B'a temel oluşturan yaklaşım Marzetta'ya[30] aittir. Bu yaklaşım, 1-B lineer öngörünün bazı sonuçlarını 2-B'a genişletmekte ve yansıma katsayılarını tanıtmaktadır.

Daha sonra, Parker ve Kayran üç parametreli kafes süzgeçlerini(Three-parameter lattice filters-TPLF) geliştirmişlerdir[31]. Bu süzgeç yapısı, destek bölgesi olarak çeyrek düzlemi kullanmakta ve her aşamada dört öngörü hata alanı yardımıyla üç tane yansıma katsayısı oluşturmaktadır.

[32]'de, çeyrek düzlem modeli, simetrik olmayan yarı düzlem modeline genişletilmiş ve beş öngörü hata alanı yardımıyla altı tane yansıma katsayısı elde edilmiştir.

Ertüzün[33], TPLF yapısını[31] genişleterek iki yeni ve geliştirilmiş yapı elde etmiştir.Bu iki yapının adları şu şekildedir: Çapraz biçimli genişletilmiş kafes süzgeçler- Extended lattice filters of diagonal form(ELDF) ve dikgen biçimli genişletilmiş kafes süzgeçler- Extended lattice filters of perpendicular form(ELPF). Her iki yapı da çeyrek düzlem süzgeçleridir. Bu yapılardaki yenilik, TPLF yapısının ilk aşamasından sonra eklenen geri-yönde öngörü hata alanlarıdır. İlk aşamadan sonraki her aşamada beş tane yansıma katsayısı elde edilmektedir.

[34]'te bütün bu yapılara ek olarak sunulan kafes süzgeç yapısında(Daha geliştirilmiş kafes süzgeçler-Further improved lattice filters(FILF) ise yansıma katsayılarının sayısı aşamadan aşamaya değişmektedir.

2-B kafes yapıları için tam bir çözüm, [35]'te verilen 1-B kafes süzgeç teorisinin doğal bir genişletmesi olan ve [29]'da sunulan yapıda(2-B dikgen kafes süzçgeçler) görülmektedir. Bu yöntem, 2-B genişletilmiş normal denklemlerden elde edilen kafes parametrelerini kullanarak öngörü hata süzgecinin katsayılarını hesaplayan, Levinson algoritmasına dayalı bir yöntemdir. Levinson özyinelemesi, Burg matris formülasyonu kullanılarak oluşturulmaktadır. Yöntem, dikgendir ve hem çeyrek düzlem, hem de simetrik olmayan yarı düzleme uygulanabilmektedir.

Bu çalışmada, önce 1-B kafes süzgeç yapıları anlatılacaktır. Ardından, çalışmada bölütleme performansları karşılaştırılacak olan iki 2-B kafes öngörücü yapıları([31] ve [29]) açıklanacaktır.

2.2.1. 1-B kafes yapıları

Kafes süzgeçler, Levinson-Durbin özyinelemesini kullanan yapılardır.

2.2.1.1. Sonlu geçmişe dayalı doğrusal öngörü: Levinson-Durbin özyinelemesi

Levinson(1947) ve bağımsız olarak da Durbin(1960) tarafında geliştilirilmiş özyinelemeli yapıdaki bu algoritma, özilişki matrisi $R_{(0,N)}$'in Toeplitz yapıda olma özelliğinden faydalanır. Temel olarak, bu süreçte, (n-1). dereceden genişletilmiş normal denklemlerin çözümlerinden n. dereceden öngörücü katsayıları hesaplanır. Süzgeç derecesi n=1,2,…,m olmak üzere, m ulaşılmak istenen en son dereceyi belirtir. m büyüdükçe, yararlanılan geçmişe ait bilgi miktarı da arttığından, ortalama karesel hatanın küçülerek, $y(n)$ için yapılan öngörünün daha iyi olması beklenir.

Özilişki fonksiyonu $R(k)=E[y(k)\ y(n+k)]$ olan durağan bir $y(n)$ zaman serisi göz önüne alınsın. Verilen herhangi bir m değeri için, $y(n)$ için aşağıda görülen biçimde en iyi çözümü verecek m. dereceden doğrusal bir öngörücü araştırılmalıdır.

$$\hat{y}(n) = -\left[a_1 y(n-1) + a_2 y(n-2) + ... + a_m y(n-m)\right] \tag{2.1}$$

$a_1,\ a_2,\ldots,\ a_m$ öngörü katsayıları, ortalama karesel öngörü hatasını en aza indirecek şekilde seçilir:

$$\varepsilon = E\left[e(n)^2\right] = \min \tag{2.2}$$

Burada $e(n)$ öngörü hatasıdır ve gerçek değerle öngörülen değer arasındaki farka eşittir:

$$e(n) = y(n) - \hat{y}(n) = y(n) + a_1 y(n-1) + a_2 y(n-2) + ... + a_m y(n-m) \tag{2.3}$$

(2.2) denkleminde her bir a_i, i=1,2,…,m katsayısına göre türev alınırsa, aşağıda ifadesi verilen diklik denklemleri elde edilir:

$$E\left[e(n)y(n-i)\right] = 0 \qquad , \qquad \text{i=1,2,…,m} \tag{2.4}$$

(2.3) ifadesindeki $e(n)$, (2.4)'te yerine yerleştirilirse, hesaplanacak olan öngörü katsayıları için m tane doğrusal denklem elde edilir:

$$\sum_{j=0}^{m} a_j E\left[y(n-j)y(n-i)\right] = \sum_{j=0}^{m} R(i-j)a_j = 0 \qquad , \qquad \text{i=1,2,…,m} \tag{2.5}$$

(2.4)'te verilen diklik koşulu kullanılarak,

$$\sigma_e^2 = \varepsilon = E\left[e(n)^2\right] = E\left[e(n)y(n)\right] = \sum_{i=0}^{m} R(i)a_i \tag{2.6}$$

minimum değeri de hesaplanır.

(2.5) ve (2.6) denklemleri aşağıdaki gibi (m+1)x(m+1) boyutlu bir matris denklemi şeklinde ifade edilebilir:

$$\begin{bmatrix} R(0) & R(1) & R(2) & \dots & R(m) \\ R(1) & R(0) & R(1) & \dots & R(m-1) \\ R(2) & R(1) & R(0) & \dots & R(m-2) \\ . & . & . & \dots & . \\ R(m) & R(m-1) & R(m-2) & \dots & R(0) \end{bmatrix} \begin{bmatrix} 1 \\ a_1 \\ a_2 \\ . \\ a_m \end{bmatrix} = \begin{bmatrix} \sigma_e^2 \\ 0 \\ 0 \\ . \\ 0 \end{bmatrix} \tag{2.7}$$

(2.7)'deki normal denklemleri doğrudan çözmek yerine, m=1, m=2, … derecelerden en iyi doğrusal öngörücüleri belirlemek yoluna gidilir.

İşte bu yaklaşımla, Levinson algoritması, ya da diğer bir isimle, doğrusal öngörü süzgeçlerinin kafes yapısı ile gerçeklenmesi elde edilir. Yöntem aşama aşama incelenirse,

$$
\begin{aligned}
e^{(1)}(n) &= y(n) + a_{11}y(n-1) \\
e^{(2)}(n) &= y(n) + a_{21}y(n-1) + a_{22}y(n-2) \\
e^{(3)}(n) &= y(n) + a_{31}y(n-1) + a_{32}y(n-2) + a_{33}y(n-3) \\
&. \\
&. \\
&. \\
e^{(m)}(n) &= y(n) + a_{m1}y(n-1) + a_{m2}y(n-2) + \ldots + a_{mm}(n-m)
\end{aligned}
\tag{2.8}
$$

Burada (1, a_{11}), (1, a_{21}, a_{22}), (1, a_{31}, a_{32}, a_{33}), …. katsayıları sırasıyla m=1,2,3,… dereceleri için en iyi öngörücüleri göstermektedir. Levinson algoritması, bir sonraki öngörücüyü, bir önceki öngörücüden yararlanarak oluşturan iteratif bir algoritmadır. Bu algoritmada, istenilen dereceye ulaşılıncaya kadar, daha düşük derecelerdeki bütün optimal öngörücüler hesaplanır.

İlk kez Burg tarafından kullanılan Levinson algoritmasının matris formu ile ileri ve geri yöndeki öngörücüler daha biçimsel bir şekilde gösterilmiştir. Levinson-Durbin özyinelemesi, aşağıda gösterilen iki biçimden biri şeklinde ifade edilebilir:

1. İleri yönde bir öngörü hata süzgecinin katsayı ağırlık vektörüne ilişkin derece güncellemesi şu şekilde yapılabilir:

$$
\boldsymbol{a}_{\boldsymbol{m}} = \begin{bmatrix} \boldsymbol{a}_{m-1} \\ 0 \end{bmatrix} + \Gamma_m \begin{bmatrix} 0 \\ \boldsymbol{a}_{m-1}^{B*} \end{bmatrix}
\tag{2.9}
$$

Burada Γ_m bir sabittir. Bu derece güncelleme işleminin skaler gösterimi ise şu şekildedir:

$$
a_{m,k} = a_{m-1,k} + \Gamma_m a^{*}_{m-1,m-k} \qquad \text{k=0,1,…,m} \tag{2.10}
$$

$a_{m,k}$, m. dereceden ileri yönde bir öngörü hata süzgecinin k. katsayı ağırlığıdır. $a^{*}_{m-1,m-k}$ ise (m-1). dereceden geri yönde bir öngörü hata süzgecinin k. katsayı ağırlığıdır. (2.10) bağıntısında, $a_{m-1,0} = 1$ ve $a_{m-1,m} = 0$ dır.

2. Geri yönde bir öngörü hata süzgecinin katsayı ağırlık vektörüne ilişkin derece güncellemesi şu şekilde yapılabilir:

$$\boldsymbol{a}_m^{B*} = \begin{bmatrix} 0 \\ \boldsymbol{a}_{m-1}^{B*} \end{bmatrix} + \Gamma_m^* \begin{bmatrix} \boldsymbol{a}_{m-1} \\ 0 \end{bmatrix} \tag{2.11}$$

Bu derece güncelleme işleminin skaler gösterimi ise şu şekildedir:

$$a^*_{m,m-k} = a^*_{m-1,m-k} + \Gamma^*_m a_{m-1,k} \quad , \quad k=0,1,\ldots,m \tag{2.12}$$

$a^*_{m,m-k}$, m. dereceden geri yönde bir öngörü hata süzgecinin katsayı ağırlığıdır.

2.2.1.2. Kafes öngörücüler

Bir boyutlu işaretlerin kafes parametre modeli, doğrusal öngörü probleminin çözümüne bir alternatif oluşturur. $y(n)$, skaler, ayrık zamanlı, sıfır ortalamalı durağan bir süreç olsun. $\{y(n-i)$, i=1,2,...,m$\}$, bu sürecin geçmiş değerlerini oluşturan uzaydır ve $y(n)$ değerini doğrusal olarak öngörmek için kullanılır. $y(n)$'in öngörü değeri aşağıda ifade edildiği gibi, $y(n-i)$'lerin doğrusal bir kombinasyonudur.

$$\hat{y}(n) = \sum_{i=1}^{m} a^{(m)}(i)\, y(n-i) \tag{2.13}$$

$\{a^{(m)}(i)$, i=1,2,...,m$\}$ ler ileri yönde öngörü katsayılarıdır. Gerçek değer ile öngörülen değer arasındaki fark ileri yönde öngörü hatasıdır ve şu şekilde ifade edilir:

$$f^{(m)}(n) = y(n) - \hat{y}(n) = y(n) + \sum_{i=1}^{m} a^{(m)}(i)\, y(n-i) \tag{2.14}$$

Eğer $y(n-m)$, $y(n)$, $y(n-1)$,…., $y(n-m+1)$ değerlerinden öngörülmek istenirse bu da geri yönde öngörü ismini alır. $y(n-m)$'in öngörü değeri aşağıdaki gibi ifade edilebilir:

$$\hat{y}'(n) = \sum_{i=1}^{m} a^{B*(m)}(i)\, y(n-i+1) \tag{2.15}$$

$\{a^{B*(m)}(i)$, i=1,2,...,m$\}$ ler geri yönde öngörü katsayılarıdır. Gerçek değer ile kestirilen değer arasındaki fark geri yönde öngörü hatasıdır ve şu şekilde ifade edilir:

$$b^{(m)}(n) = y(n-m) - \hat{y}'(n) = y(n-m) + \sum_{i=1}^{m} a^{B*(m)}(i)\, y(n-i+1) \tag{2.16}$$

Üst indis m, süzgeç derecesini, * işareti karmaşık eşleniği belirtmektedir.

Bir kafes öngörücüyü karakterize eden giriş-çıkış bağıntıları çeşitli şekillerde ifade edilebilir. Burada yapılacak türetme için ileri ve geri yönde öngörü hata süzgeçlerine ait olan ve (2.9) ve (2.11) bağıntılarıyla verilen aşağıdaki matris formülasyonu ile başlanabilir:

$$\boldsymbol{a}_m = \begin{bmatrix} \boldsymbol{a}_{m-1} \\ 0 \end{bmatrix} + \Gamma_m \begin{bmatrix} 0 \\ \boldsymbol{a}^{B*}_{m-1} \end{bmatrix} \tag{2.17}$$

$$\boldsymbol{a}^{B*}_m = \begin{bmatrix} 0 \\ \boldsymbol{a}^{B*}_{m-1} \end{bmatrix} + \Gamma_m^* \begin{bmatrix} \boldsymbol{a}_{m-1} \\ 0 \end{bmatrix} \tag{2.18}$$

(m+1)x1 boyutlu $\boldsymbol{a}_m$ ve mx1 boyutlu $\boldsymbol{a}_{m-1}$ vektörleri, sırasıyla m. ve (m-1). derecelerden ileri yönde öngörü hata süzgeçlerine karşılık düşerler. (m+1)x1 boyutlu $\boldsymbol{a}^{B*}_m$ ve mx1 boyutlu $\boldsymbol{a}^{B*}_{m-1}$ vektörleri ise sırasıyla m. ve (m-1). derecelerden geri yönde öngörü hata süzgeçlerine karşılık düşerler. Γ_m sabiti ise yansıma katsayısıdır. İlk olarak, katsayı girişleri $y(n-m)$, $y(n-m+1)$, ..., $y(n-1)$, $y(n)$ şeklinde gösterilen m.dereceden ileri yönde öngörü hata süzgecini göz önüne alalım. Bu süzgecin (m+1)x1 boyutlu katsayı giriş vektörü olan $\boldsymbol{y}_{m+1}(n)$ vektörünü aşağıdaki gibi ikiye ayırabiliriz:

$$\boldsymbol{y}_{m+1}(n) = \begin{bmatrix} \boldsymbol{y}_m(n) \\ \Lambda \\ y(n-m) \end{bmatrix} \tag{2.19}$$

ya da

$$\boldsymbol{y}_{m+1}(n) = \begin{bmatrix} y(n) \\ \Lambda \\ \boldsymbol{y}_m(n-1) \end{bmatrix} \tag{2.20}$$

I) (2.17) bağıntısının sol tarafı için, $\boldsymbol{y}_{m+1}(n)$ 'in $\boldsymbol{a}^{H}_m$ ile soldan çarpılması aşağıdaki sonucu verir:

$$f^{(m)}(n) = \boldsymbol{a}^{H}_m \boldsymbol{y}_{m+1}(n) \tag{2.21}$$

Burada, $f^{(m)}(n)$, m. dereceden ileri yönde öngörü hata süzgecinin çıkışındaki ileri yönde öngörü hatasıdır.

II) (2.17) bağıntısının sağ tarafındaki ilk terim için, $\boldsymbol{y}_{m+1}(n)$ 'in (2.19) eşitliği ile verilen şekli kullanılırsa aşağıdaki bağıntı yazılabilir:

$$\begin{aligned}\left[\boldsymbol{a}_{m-1}^{\boldsymbol{H}} \quad \mathrm{M} \ 0\right]\cdot \boldsymbol{y}_{m+1}(n) &= \left[\boldsymbol{a}_{m-1}^{\boldsymbol{H}} \quad \mathrm{M} \ 0\right]\cdot\begin{bmatrix} \boldsymbol{y}_m(n) \\ \Lambda \\ y(n-m)\end{bmatrix} \\ &= \boldsymbol{a}_{m-1}^{\boldsymbol{H}}\cdot \boldsymbol{y}_m(n) \\ &= f_{m-1}(n)\end{aligned} \tag{2.22}$$

Burada, $f_{m-1}(n)$, (m-1). dereceden ileri yönde öngörü hata süzgecinin çıkışındaki ileri yönde öngörü hatasıdır.

III) (2.17) bağıntısının sağ tarafındaki ikinci terim için, $\boldsymbol{y}_{m+1}(n)$ 'in (2.20) eşitliği ile verilen şekli kullanılırsa aşağıdaki bağıntı yazılabilir:

$$\begin{aligned}\left[\boldsymbol{0} \quad \mathrm{M} \ \boldsymbol{a}_{m-1}^{\boldsymbol{BT}}\right]\cdot \boldsymbol{y}_{m+1}(n) &= \left[\boldsymbol{0} \quad \mathrm{M} \ \boldsymbol{a}_{m-1}^{\boldsymbol{BT}}\right]\cdot\begin{bmatrix} y(n) \\ \Lambda \\ \boldsymbol{y}_m(n-1)\end{bmatrix} \\ &= \boldsymbol{a}_{m-1}^{\boldsymbol{BT}}\cdot \boldsymbol{y}_m(n-1) \\ &= b_{m-1}(n-1)\end{aligned} \tag{2.23}$$

Burada, $b_{m-1}(n-1)$, (m-1). dereceden geri yönde öngörü hata süzgecinin çıkışındaki geri yönde öngörü hatasıdır. (2.21), (2.22) ve (2.23) eşitliklerinden elde edilen sonuçları birleştirerek aşağıda görülen bağıntı yazılabilir:

$$f^{(m)}(n) = f^{(m-1)}(n) + \Gamma^{(m)*} b^{(m-1)}(n-1) \tag{2.24}$$

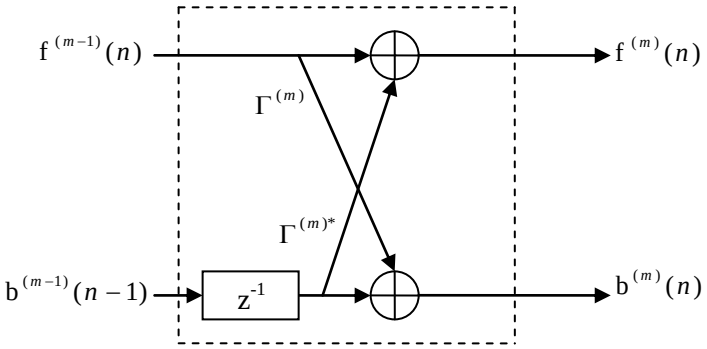
Aynı işlemler geri yönde öngörü hata süzgeci için tekrarlanırsa şu bağıntı elde edilir:

$$b^{(m)}(n) = b^{(m-1)}(n-1) + \Gamma^{(m)} f^{(m-1)}(n) \tag{2.25}$$

(2.24) ve (2.25) eşitlikleri, kafes öngörücünün m. aşamasındaki derece güncelleme işlemini karakterize eden ileri ve geri yönde öngörü hata çiftidir. Bu iki eşitlik matris formunda ifade edilmek istenirse aşağıdaki bağıntı elde edilir:

$$\begin{bmatrix} f^{(m)}(n) \\ b^{(m)}(n) \end{bmatrix} = \begin{bmatrix} 1 & \Gamma^{(m)} \\ \Gamma^{(m)} & 1 \end{bmatrix} \begin{bmatrix} f^{(m-1)}(n) \\ b^{(m-1)}(n-1) \end{bmatrix} \tag{2.26}$$

(2.26) eşitliği ile matematiksel olarak tanımlanan 1-B kafes süzgecin m. aşaması, Şekil 2.2'deki gibi gösterilebilir:



Şekil 2.2 1-B kafes süzgecin m. aşaması

2.2.2. 2-B kafes yapıları

Bu bölümde Parker ve Kayran[31] tarafından geliştirilmiş olan üç parametreli kafes süzgeç yapısı ile Kayran[29] tarafından geliştirilmiş olan 2-B dikgen kafes süzgeç yapıları anlatılacaktır.

2-B doğrusal modellemede, durağan rasgele veri alanı $y(k_1, k_2)$, komşu örnek noktaların doğrusal kombinasyonu ile öngörülür. Öngörü bölgesine bağlı olarak çeşitli nedensel modeller bulunmaktadır. Çeyrek düzlem ve simetrik olmayan yarı düzlem modelleri en çok kullanılan modellerdir. Kafes süzgeçlerde işlem, bu modellerin yardımıyla öngörü destek bölgesinin oluşturulmasıyla başlar. Dizinleme işleminin kolaylığı açısından, öngörü bölgesi içindeki elemanlar 1-B diziler halinde sıralanabilir. Önerilen sıralamada, 1-B diziler yardımıyla elemanların sıralanmasında sadece yatay ve dikey yönler kullanılmaktadır. Dizinin elemanları 0'dan N'e kadar numaralanmaktadır. N. dereceden ileri yönde öngörü hatası, N adet geçmiş örnekten yapılan öngörü ile bulunur. Benzer olarak, son örneğin N. dereceden geri yönde öngörü hatası da, kendinden önceki N geçmiş değerden öngörülür.

Üç parametreli kafes yapısı çeyrek düzlem modelini kullanırken, dikgen kafes yapıları hem çeyrek düzlem hem de simetrik olmayan yarı düzlem modeliyle çalışabilmektedirler.

2.2.2.1. Üç parametreli kafes süzgeç yapısı

Üç parametreli kafes süzgeçler, 2-B'ta geliştirilen ilk kafes yapısıdır. Daha sonra bu yapıyı geliştirmek için pek çok çalışma yapılmıştır.

Tüm 2-B kafes yapıları, yansıma katsayılarına göre tanımlanan çoklu giriş/çoklu çıkışlı aşamaların birleştirilmesiyle oluşturulur[34]. Bu aşamaların giriş ve çıkışları, eş zamanlı olarak oluşturulan ileri ve geri yönde öngörü hata alanlarıdır.

Üç parametreli kafes yapısında, m=0 dereceli süzgeç ile başlamak üzere, giriş veri alanı $u(n_1,n_2)$'den bir adet ileri yönde, üç adet de geri yönde olmak üzere dört adet öngörü hata alanı üretilir:

$$u(n_1,n_2) = f(0;n_1,n_2) = b_{ij}(0;n_1,n_2) \qquad (i,j) = \{(01),(11),(10)\} \tag{2.27}$$

Bu hata alanlarının doğrusal bir kombinasyonu ile ilk aşamanın çıkışları oluşturulur. Bu hata alanları da bir sonraki aşamanın girişleridir[34].

2-B bir kafes süzgecin m. aşamasının giriş-çıkış bağıntısı genel olarak şu şekilde ifade edilebilir:

$$e(m;n_1,n_2) = \Gamma(m)\cdot e^*(m-1;n_1,n_2) \tag{2.28}$$

Bu bağıntıda, $e^*(m-1;n_1,n_2)$ ve $e(m;n_1,n_2)$ giriş ve çıkış öngörü hata alanlarını ifade eden vektörlerdir. Üç parametreli kafes yapısında, ileri yönde öngörü hata alanları her vektörün ilk elemanını oluştururken, vektörün geri kalanı geri yönde öngörü hata alanları tarafından oluşturulur. * işareti, hata alanlarının, her aşamanın girişinde geciktirildiğini gösterir. $\Gamma(m)$ matrisi, yansıma katsayılarının oluşturduğu matristir. Yansıma katsayıları, kafes süzgecin her aşamasında hesaplanır. Üç parametreli kafes süzgecin aşamaları simetriktir ve hepsi aynı yapıdadır.

Üç parametreli bir kafes süzgecin m. aşamasının giriş-çıkış bağıntısı genel olarak şu şekilde ifade edilebilir:

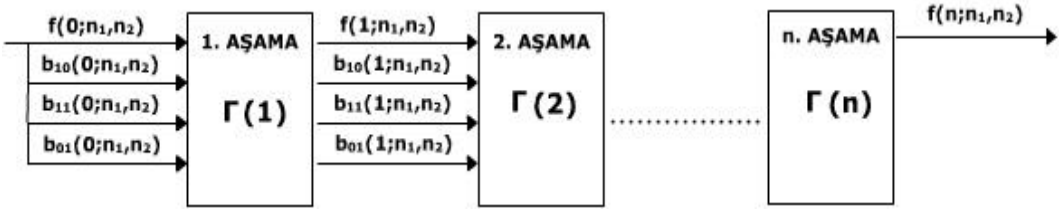
$$\begin{bmatrix} f(m;n_1,n_2) \\ b_{10}(m;n_1,n_2) \\ b_{11}(m;n_1,n_2) \\ b_{01}(m;n_1,n_2) \end{bmatrix} = \Gamma(m) \begin{bmatrix} f(m-1;n_1,n_2) \\ b_{10}(m-1;n_1-1,n_2) \\ b_{11}(m-1;n_1-1,n_2-1) \\ b_{01}(m-1;n_1,n_2-1) \end{bmatrix} \tag{2.29}$$

Bu bağıntıda, $\Gamma(m)$, m. aşamanın yansıma katsayıları tarafından oluşturulan 4x4 boyutunda bir matristir ve aşağıdaki gibi ifade edilir:

$$\Gamma(m) = \begin{bmatrix} 1 & -k_{10}(m) & -k_{11}(m) & -k_{01}(m) \\ -k_{10}(m) & 1 & -k_{01}(m) & -k_{11}(m) \\ -k_{11}(m) & -k_{01}(m) & 1 & -k_{10}(m) \\ -k_{01}(m) & -k_{11}(m) & -k_{10}(m) & 1 \end{bmatrix} \tag{2.30}$$

Burada, $k_{ij}(m)$ m. aşamanın yansıma katsayılarını gösterir. $f(m-1;n_1,n_2)$ ve $f(m;n_1,n_2)$ sırasıyla m. aşama kafes süzgecinin giriş ve çıkış ileri yönde hata alanlarıdır. $b_{ij}(m-1;n_1,n_2)$ ve $b_{ij}(m;n_1,n_2)$ ise sırasıyla m. aşama kafes süzgecinin giriş ve çıkış geri yönde hata alanlarıdır.

n aşamalı üç parametreli kafes süzgeç yapısı aşağıdaki şekilde görülmektedir.



Şekil 2.3 n aşamalı üç parametreli kafes süzgeç yapısı

Her aşamadaki kafes parametrelerinin hesaplanabilmesi için öngörü hataları ortalama karesel hata bakımından minimize edilmelidir. Minimizasyon işlemi sadece bir tek hata alanında yapılabildiği gibi, tüm hata alanlarında birden eş zamanlı olarak gerçekleştirilebilir. Bu minimizasyon işlemi ile normal denklemler oluşturulur. Normal denklemler çözülerek de yansıma katsayıları hesaplanır. Normal denklemler aşağıdaki gibi ifade edilebilirler:

$$R(m-1)\begin{bmatrix} k_{10}(m) \\ k_{11}(m) \\ k_{01}(m) \end{bmatrix} = r(m-1) \tag{2.31}$$

Burada, $R(m-1)$, (m-1). aşamanın özilişki matrisidir, simetriktir ve üç parametreli kafes yapısı için 3x3 boyutundadır. $r(m-1)$, (m-1). aşamanın çapraz ilişki vektörüdür ve üç parametreli kafes yapısı için 3x1 boyutundadır.

2-B üç parametreli süzgeç yapı algortimasının adımları aşağıda verilmiştir.

Adım1: Pencere boyutu belirlenir,öngörü seviyesi(M) seçilir.

Adım2: Pencerelenmiş veri alanı,0.aşama için(m=0) ileri ve geri yönde hata alanları olarak kabul edilir.

Adım3: Normal denklemler çözülerek yansıma katsayıları hesaplanır.

Adım4: İleri ve geri yönde öngörü hata alanları güncellenir.

Adım5: Aşama seviyesi bir arttırılır.(m=m+1)

Adım6: 3.adıma dönülür.

Algoritma, M seviyesine ulaşılıncaya kadar devam eder.

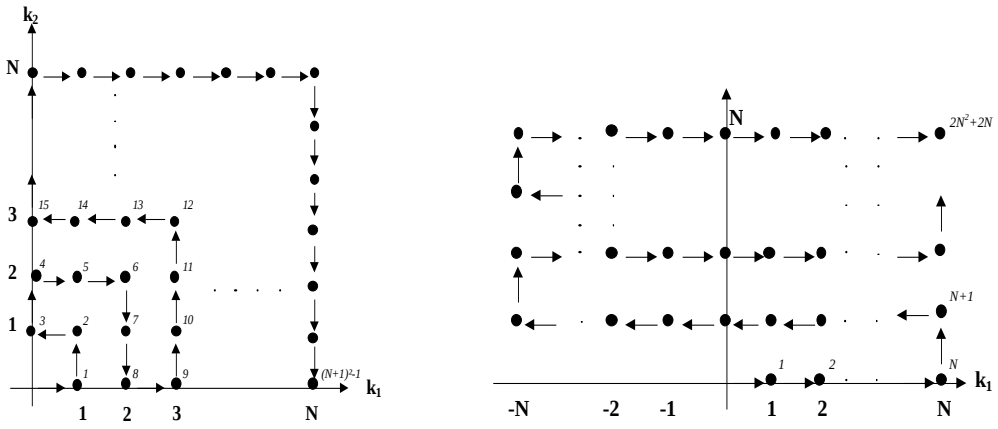
Üç parametreli kafes yapısı, uygulanması basit bir yapıdır ve elemanları arasında belirli bir ilişki bulunan verilerde başarılı sonuçlar verir. Ancak, bu şekilde oluşturulan bir kafes yapı, AR veri alanının tüm sınıflarını temsil edecek yeterli sayıda parametreden yoksundur[36]. Daha da önemlisi, bu yapı diklik özelliği taşımamaktadır ve bu yüzden de aşamaların art arda eklenmesi ile optimum bir süzgeç oluşturulamaz[37]. Ancak bu yapı basitliğinden dolayı pek çok uygulama alanı bulmuştur.

2.2.2.2. 2-B dikgen kafes süzgeç yapıları

Geçmişe ait değerlerin uygun tanımlanmasıyla, nedensel modeller özyinelemeli bir yapı oluşturur. 2-B doğrusal öngörü aşağıdaki gibi ifade edilebilir:

$$\hat{y}(k_1,k_2) = \sum_{(n_1,n_2)\in S} a(n_1,n_2)\,y(k_1-n_1,k_2-n_2) \tag{2.32}$$

Burada $a(n_1,n_2)$, katsayı ağırlıklarını, S ise (0,0) noktasının içerilmediği öngörü destek bölgesini göstermektedir. Öngörü destek bölgesi için kullanılan modellerde, N. derecede olası bazı dizilimler Şekil 2.4'te görülmektedir.



(a) (b)

Şekil 2.4 Çeyrek ve simetrik olmayan yarı düzlem modelleri için N. derecede olası bazı dizilimler
(a)çeyrek düzlem modeli
(b)simetrik olmayan yarı düzlem modeli

Öngörü hatası, 1-B'takine benzer şekilde aşağıdaki gibi tanımlanır:

$$e^{(N)}(k_1,k_2) = y(k_1,k_2) - \hat{y}(k_1,k_2) \tag{2.33}$$

$\boldsymbol{a}_0^{(m)}$ ve $\boldsymbol{g}_m^{(m)}$ vektörleri, kendilerine karşılık gelen (m+1)x1 boyutlu sırasıyla ileri ve geri yönde öngörü ağırlık vektörlerini göstermek üzere, 0. örneğin, öngörü destek bölgesindeki m geçmiş değerden öngörülmesiyle oluşacak ileri yönde öngörü hatası aşağıdaki şekilde gösterilir:

$$f_0^{(m)}(k_1,k_2) = \boldsymbol{a}_0^{(m)^T}\boldsymbol{y}_{0,m}(k_1,k_2) \tag{2.34}$$

Burada

$$\boldsymbol{a}_0^{(m)} = \left[1 \quad a_0^{(m)}(1) \quad \ldots \quad a_0^{(m)}(m)\right]^T \tag{2.35}$$

ve

$$\boldsymbol{y}_{0,m}(k_1,k_2) = \left[y((k_1,k_2)-0) \quad y((k_1,k_2)-1) \quad \ldots \quad y((k_1,k_2)-m)\right]^T \tag{2.36}$$

olarak tanımlıdır.

$y((k_1,k_2)-i)$ gösterimi, $y(k_1,k_2)$'den önceki i. elemanı göstermektedir. $y((k_1,k_2)-0)=y(k_1,k_2)$, (2.34) eşitliğindeki $\boldsymbol{y}_{0,m}(k_1,k_2)$ vektörünün ilk elemanıdır.

$f_0^{(m)}(k_1,k_2)$'ın z dönüşümü alınırsa

$$F_0^{\,m}(z_1,z_2)=\boldsymbol{a}_0^{(m)\,T}\boldsymbol{O}_{0,m}(z_1,z_2)Y(z_1,z_2) \tag{2.37}$$

elde edilir. $\boldsymbol{O}_{0,m}(z_1,z_2)$, öngörü destek bölgesinin dizilim vektörüdür:

$$\boldsymbol{O}_{0,m}(z_1,z_2)=\begin{bmatrix}1 & \delta_1(z_1,z_2) & .... & \delta_m(z_1,z_2)\end{bmatrix} \tag{2.38}$$

Burada

$$\delta_p(z_1,z_2)=\frac{Z\left[y((k_1,k_2)-p)\right]}{Y(z_1,z_2)} \quad , \quad p=0,1,\ldots,m \tag{2.39}$$

(2.38) eşitliğindeki $\delta_i(z_1,z_2)$'ler, öngörü destek bölgesindeki örnek noktaların yerlerini göstermektedir.

m. örneğin, öngörü destek bölgesindeki m geçmiş değerden öngörülmesiyle oluşacak geri yönde öngörü hatası aşağıdaki şekilde gösterilir:

$$b_m^{(m)}(k_1,k_2)=\boldsymbol{g}_m^{(m)^T}\boldsymbol{y}_{0,m}(k_1,k_2) \tag{2.40}$$

Burada

$$\boldsymbol{g}_m^{(m)}=\begin{bmatrix}g_m^{(m)}(m) & g_m^{(m)}(m-1) & \ldots & g_m^{(m)}(1) & 1\end{bmatrix} \tag{2.41}$$

olarak tanımlıdır.

$b_m^{(m)}(k_1,k_2)$'ın z dönüşümü alınırsa

$$B_m^{(m)}(z_1,z_2)=\boldsymbol{g}_m^{(m)^T}\mathbf{O}_{0,m}(z_1,z_2)\mathbf{Y}(z_1,z_2) \tag{2.42}$$

bağıntısı elde edilir.

Yukarıdaki denklemlerde alt indis, öngörülen elemanın numarasını, üst indis ise öngörü hata süzgecinin derecesini, yani öngörü için kullanılan nokta sayısını göstermektedir.

$f_0^{(m)}(k_1,k_2)$, $y((k_1,k_2)-0)=y(k_1,k_2)$'nin önceki m tane örnekten, yani $y((k_1,k_2)-1), y((k_1,k_2)-2),..., y((k_1,k_2)-m)$ örneklerinden yapılan ileri yönde öngörünün hatasıdır. $b_m^{(m)}(k_1,k_2)$ ise, $y((k_1,k_2)-m)$'in önceki m tane örnekten, yani $y((k_1,k_2)-m+1), y((k_1,k_2)-m+2),..., y((k_1,k_2)-1), y(k_1,k_2)$ örneklerinden yapılan geri yönde öngörünün hatasıdır.

(m-1).derece ileri ve geri yönde öngörü süzgeçlerine ilişkin katsayı ağırlık vektörleri sırasıyla $\boldsymbol{a}_0^{(m-1)}$ ve $\boldsymbol{g}_m^{(m-1)}$ olarak verilmiş olsun. m.aşama için derece güncellemesi aşağıdaki gibi yapılır:

$$\boldsymbol{a}_0^{(m)} = \begin{bmatrix} \boldsymbol{a}_0^{(m-1)} \\ 0 \end{bmatrix} + \Gamma_{b_m}^{(m)} \begin{bmatrix} 0 \\ \boldsymbol{g}_m^{(m-1)} \end{bmatrix} \tag{2.43a}$$

ve

$$\boldsymbol{g}_m^{(m)} = \begin{bmatrix} 0 \\ \boldsymbol{g}_m^{(m-1)} \end{bmatrix} + \Gamma_{f_0}^{(m)} \begin{bmatrix} \boldsymbol{a}_0^{(m-1)} \\ 0 \end{bmatrix} \tag{2.43b}$$

Burada $\Gamma_{f_0}^{(m)}$ ve $\Gamma_{b_m}^{(m)}$ sırasıyla m.dereceden ileri ve geri yönde öngörücülerin yansıma katsayılarıdır.

İleri ve geri yönde yansıma katsayıları ve minimum ortalama karesel hatalar şu şekilde elde edilebilir:

$$\Gamma_{fo}^{(m)} = -\frac{\Delta_{b_m}^{(m-1)}}{E_{fo}^{(m-1)}} \quad \text{ve} \quad \Gamma_{bm}^{(m)} = -\frac{\Delta_{fo}^{(m-1)}}{E_{bm}^{(m-1)}} \tag{2.44a}$$

$$E_{f_o}^{(m-1)} = E\left[{f_o^{(m-1)}}^2(k_1,k_2)\right] \quad \text{ve} \quad E_{b_m}^{(m-1)} = E\left[{b_m}^{(m-1)^2}(k_1,k_2)\right] \tag{2.44b}$$

$$E_{f_o}^{(m)} = E_{f_o}^{(m-1)}(1-\Gamma_{fo}^{(m)}\Gamma_{bm}^{(m)}) \quad \text{ve} \quad E_{b_m}^{(m)} = E_{b_m}^{(m-1)}(1-\Gamma_{fo}^{(m)}\Gamma_{bm}^{(m)}) \tag{2.44c}$$

$\Delta_{fo}^{(m-1)}$ ve $\Delta_{b_m}^{(m-1)}$ skalerleri ileri ve geri yönde öngörü hataları arasındaki çapraz ilişki olarak yorumlanabilirler. Bu skalerler birbirlerine eşit olup, aşağıdaki bağıntıyla ifade edilebilirler:

$$\Delta_{fo}^{(m-1)} = \Delta_{b_m}^{(m-1)} = \Delta_{f_o b_m}^{(m-1)}$$

$$= E\left[f_o^{(m-1)}(k_1,k_2) b_m^{(m-1)}(k_1,k_2)\right] \tag{2.45}$$

(2.34), (2.40) ve (2.43) ifadeleri kullanılarak ileri ve geri yönde süzgeçleme işlemleri tek bir yapıda birleştirilebilir:

$$\begin{bmatrix} f_0^{(m)}(k_1,k_2) \\ b_m^{(m)}(k_1,k_2) \end{bmatrix} = \begin{bmatrix} 1 & \Gamma_{b_m}^{(m)} \\ \Gamma_{f_0}^{(m)} & 1 \end{bmatrix} \begin{bmatrix} f_0^{(m-1)}(k_1,k_2) \\ b_m^{(m-1)}(k_1,k_2) \end{bmatrix} \tag{2.46}$$

N.dereceden hata yayılım denklemleri şöyle ifade edilebilir:

$$\begin{bmatrix} f_{p-n}^{(n)}(k_1,k_2) \\ b_p^{(n)}(k_1,k_2) \end{bmatrix} = \begin{bmatrix} 1 & \Gamma_{b_p}^{(n)} \\ \Gamma_{f_{p-n}}^{(n)} & 1 \end{bmatrix} \begin{bmatrix} f_{p-n}^{(n-1)}(k_1,k_2) \\ b_p^{(n-1)}(k_1,k_2) \end{bmatrix}$$

$$p = 1,2,\cdots,N \quad \text{ve} \quad n = 1,2,\ldots,\ p \tag{2.47}$$

N.derece için katsayı ağırlık vektörleri için derece güncellemesi şu şekildedir:

$$\boldsymbol{a}_{p-n}^{(n)} = \begin{bmatrix} \boldsymbol{a}_{p-n}^{(n-1)} \\ 0 \end{bmatrix} + \Gamma_{b_p}^{(n)} \begin{bmatrix} 0 \\ \boldsymbol{g}_p^{(n-1)} \end{bmatrix} \quad \text{ve} \quad \boldsymbol{g}_p^{(n)} = \begin{bmatrix} 0 \\ \boldsymbol{g}_p^{(n-1)} \end{bmatrix} + \Gamma_{f_{p-n}}^{(n)} \begin{bmatrix} \boldsymbol{a}_{p-n}^{(n-1)} \\ 0 \end{bmatrix} \tag{2.48}$$

İlk koşullar

$$f_p^{(0)}(k_1,k_2) = b_p^{(0)}(k_1,k_2) = y((k_1,k_2) - p) \quad , \ p = 0,1,2,\cdots,N \tag{2.49a}$$

$$\mathbf{a}_p^{(0)} = \mathbf{g}_p^{(0)} = [1] \tag{2.49b}$$

ifadeleriyle ile belirlidir.

Algoritma 0.dereceden başlar ve N.dereceye kadar devam eder. Yansıma katsayıları $\Gamma_{f_{p-n}}^{(n)}$ ve $\Gamma_{b_p}^{(n)}$ öngörü hata alanları minimize edilerek hesaplanır:

$$\Gamma_{f_{p-n}}^{(n)} = -\frac{\Delta_{b_p}^{(n-1)}}{E_{f_{p-n}}^{(n-1)}} \quad \text{ve} \quad \Gamma_{b_p}^{(n)} = -\frac{\Delta_{f_{p-n}}^{(n-1)}}{E_{b_p}^{(n-1)}} \tag{2.50}$$

Çapraz ilişki ifadesi şu şekildedir:

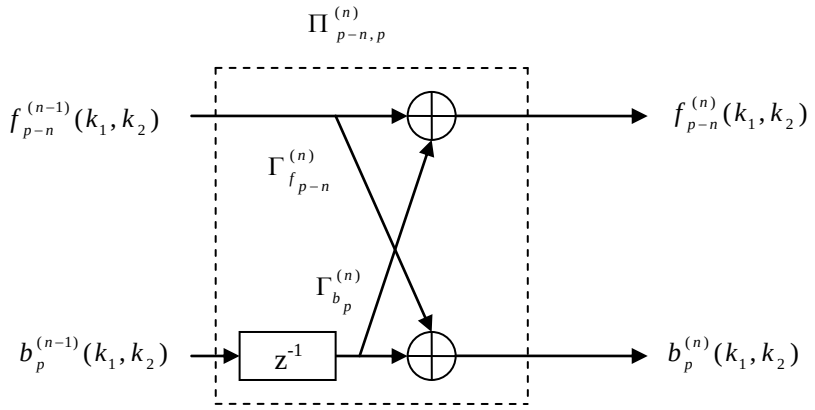
$$\Delta_{f_{p-n}}^{(n-1)} = \Delta_{b_p}^{(n-1)} = E\left[f_{p-n}^{(n-1)}(k_1,k_2) b_p^{(n-1)}(k_1,k_2)\right] \tag{2.51}$$

Öngörü hata güçleri için ise

$$E_{f_{p-n}}^{(n)} = E_{f_{p-n}}^{(n-1)}(1-\Gamma_{f_{p-n}}^{(n-1)}\Gamma_{bp}^{(n-1)}) \qquad \text{ve} \qquad E_{b_p}^{(n)} = E_{b_p}^{(n-1)}(1-\Gamma_{f_{p-n}}^{(n-1)}\Gamma_{bp}^{(n-1)}) \tag{2.52}$$

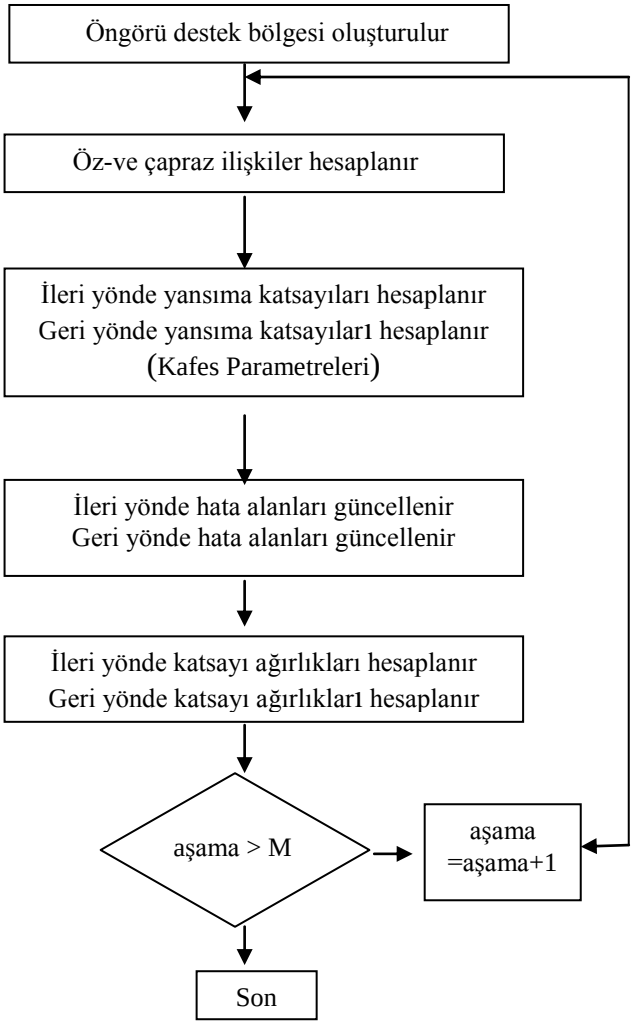
yazılır.

(2.47) eşitliği ile matematiksel olarak tanımlanan 2-B dikgen kafes süzgecin n. aşamasının $\Pi_{p-n,p}^{(n)}$ bloğu Şekil 2.5'teki gibi gösterilebilir:



Şekil 2.5 2-B dikgen kafes süzgecin n.aşamasında $\Pi_{p-n,p}^{(n)}$ bloğu

2-B dikgen kafes yapı algoritması Şekil 2.6'da verilmiştir. M, 2-B öngörü destek bölgesindeki eleman sayısını göstermektedir.



Şekil 2.6 2-B dikgen kafes yapı algoritması

2-B dikgen kafes yapılarda, hem çeyrek, hem de simetrik olmayan yarı düzlem modeliyle oluşturulan destek bölgesi modeli için de, uygulanan derecede, destek bölgesinde toplam kaç noktadan öngörü yapılıyorsa o kadar aşama vardır. Bu nokta sayıları, N dereceyi belirtmek üzere, çeyrek düzlem modeli için $(N+1)^2-1$, simetrik olmayan yarı düzlem modeli için ise $2N(N+1)$ tanedir. Aşamalar ise basamaklardan oluşur. İlk aşamada, toplam aşama sayısı kadar basamak varken aşamalar arttıkça basamak sayısı da birer birer azalır. Son aşamada tek bir basamak vardır. Uygulanan her basamakta, bir ileri, bir de geri yönde yansıma katsayısı elde edilir.

Çeyrek düzlem modeli için 1.derecede yansıma katsayılarının oluşturulması aşağıda adım adım gösterilmiştir:

Çeyrek düzlem modeli:

1.aşama:

1.basamak:

$$\begin{bmatrix} f_0^{(1)}(k_1,k_2) \\ b_1^{(1)}(k_1,k_2) \end{bmatrix} = \begin{bmatrix} 1 & \Gamma_{b_1}^{(1)} \\ \Gamma_{f_0}^{(1)} & 1 \end{bmatrix} \begin{bmatrix} f_0^{(0)}(k_1,k_2) \\ b_1^{(0)}(k_1,k_2) \end{bmatrix} \tag{2.53}$$

2.basamak:

$$\begin{bmatrix} f_1^{(1)}(k_1,k_2) \\ b_2^{(1)}(k_1,k_2) \end{bmatrix} = \begin{bmatrix} 1 & \Gamma_{b_2}^{(1)} \\ \Gamma_{f_1}^{(1)} & 1 \end{bmatrix} \begin{bmatrix} f_1^{(0)}(k_1,k_2) \\ b_2^{(0)}(k_1,k_2) \end{bmatrix} \tag{2.54}$$

3.basamak:

$$\begin{bmatrix} f_2^{(1)}(k_1,k_2) \\ b_3^{(1)}(k_1,k_2) \end{bmatrix} = \begin{bmatrix} 1 & \Gamma_{b_3}^{(1)} \\ \Gamma_{f_2}^{(1)} & 1 \end{bmatrix} \begin{bmatrix} f_2^{(0)}(k_1,k_2) \\ b_3^{(0)}(k_1,k_2) \end{bmatrix} \tag{2.55}$$

2.aşama:

1.basamak:

$$\begin{bmatrix} f_0^{(2)}(k_1,k_2) \\ b_2^{(2)}(k_1,k_2) \end{bmatrix} = \begin{bmatrix} 1 & \Gamma_{b_2}^{(2)} \\ \Gamma_{f_0}^{(2)} & 1 \end{bmatrix} \begin{bmatrix} f_0^{(1)}(k_1,k_2) \\ b_2^{(1)}(k_1,k_2) \end{bmatrix} \tag{2.56}$$

2.basamak:

$$\begin{bmatrix} f_1^{(2)}(k_1,k_2) \\ b_3^{(2)}(k_1,k_2) \end{bmatrix} = \begin{bmatrix} 1 & \Gamma_{b_3}^{(2)} \\ \Gamma_{f_1}^{(2)} & 1 \end{bmatrix} \begin{bmatrix} f_1^{(1)}(k_1,k_2) \\ b_3^{(1)}(k_1,k_2) \end{bmatrix} \tag{2.57}$$

3.aşama:

1.basamak

$$\begin{bmatrix} f_0^{(3)}(k_1,k_2) \\ b_3^{(3)}(k_1,k_2) \end{bmatrix} = \begin{bmatrix} 1 & \Gamma_{b_3}^{(3)} \\ \Gamma_{f_0}^{(3)} & 1 \end{bmatrix} \begin{bmatrix} f_0^{(2)}(k_1,k_2) \\ b_3^{(2)}(k_1,k_2) \end{bmatrix} \tag{2.58}$$

Çeyrek düzlem modelinde 1.derecede toplam 12 tane yansıma katsayısı elde edilir. Simetrik olmayan yarı düzlem modelinde de yansıma katsayıları aynı yapı kullanılarak hesaplanır. Ancak bu modelde 1.derecede 4 aşama vardır ve sonuçta toplam 20 tane yansıma katsayısı oluşturulur.

İlk aşamadaki $f_k^{(0)}(k_1,k_2)$ ve $b_k^{(0)}(k_1,k_2)$ ile gösterilen hatalar başlangıç koşullarından bulunur. Daha sonraki aşamalarda hep bir önceki aşamada hesaplanan hata alanları kullanılmaktadır. Algoritmanın iteratif yapısı buna olanak sağlamaktadır.

2.3. Dalgacık Dönüşümü

Dönüşüm, bir işaretin, bir domende belirgin olmayan özelliklerini ortaya çıkarmak için başka bir domene taşınması işlemidir.

İşaretler frekans davranışlarına göre durağan ve durağan olmayan işaretler olmak üzere ikiye ayrılabilirler. Durağan işaretler, frekans bileşenleri zamanla değişmeyen işaretlerdir. Durağan olmayan işaretlerin ise frekans bileşenleri zamanla değişir. Durağan işaretler, en bilinen dönüşüm yöntemi olan Fourier Dönüşümü(FD) ile incelenebilmektedirler. Ancak Fourier Dönüşümü, işaretin zamanla nasıl değiştiği hakkında bir bilgi vermediği için durağan olmayan işaretlerin incelenmesinde kullanılamamaktadır. Kısa Zamanlı Fourier Dönüşümü(KZFD-Short Time Fourier Transform) ve Dalgacık Dönüşümü(DD-Wavelet Transform) bu tür işaretlerin incelenmesine olanak sağlamaktadır.

2.3.1. Fourier dönüşümü

FD ile bir işaret farklı frekanslara ait üstel fonksiyonlara ayrıştırılmaktadır. Bu ayrıştırma işlemi aşağıda verilen Fourier dönüşümü ve Ters Fourier dönüşümü ifadeleri ile yapılmaktadır:

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-2\Pi ft}\, dt \tag{2.59a}$$

$$x(t) = \frac{1}{2\Pi} \int_{-\infty}^{\infty} X(f) e^{2\Pi ft}\, df \tag{2.59b}$$

Bu denklemlerden de görüldüğü gibi frekans bileşeni f, zamanın hangi anında ortaya çıkarsa çıksın integrasyona etkisi aynı olacaktır. f'in t_1 ya da t_2 zamanlarında ortaya çıkması integrasyon sonucunu değiştirmeyecektir. FD, bu özelliğinden dolayı durağan olmayan işaretlerin incelenmesine olanak vermemektedir. FD sadece belli bir f frekans bileşeninin yerini belirleyebilmektedir. Bu bilgi bileşeninin hangi zamanda ortaya çıktığından bağımsızdır.

KZFD, FD'nin bu eksikliğini gidermiştir. KZFD'de durağan olmayan işaret, durağan kabul edilebilecek kadar küçük pencerelere ayrılır ve bu parçalardan her birine FD uygulanır. Aşağıda KZFD'nin ifadesi görülmektedir:

$$KZFD\ (\tau, f) = \int_{-\infty}^{\infty} \left[x(t) \cdot w^*(t-\tau)\right] \quad e^{-2\Pi ft}\, dt \tag{2.60}$$

Burada, τ zamanda öteleme miktarını, f frekans bileşenini, $x(t)$ orijinal işareti, $w^*(t-\tau)$ zamanda ötelenmiş pencere fonksiyonunu ve * işareti de kompleks eşleniği göstermektedir.

FD, sadece frekansın bir fonksiyonu iken, KZFD hem frekansın hem de zamanın bir fonksiyonudur. Ancak KZFD'de, seçilen pencere genişliğiyle ilgili bir çözünürlük sorunu bulunmaktadır. Pencere genişliği, durağanlık varsayımını geçerli kılacak kadar dar olmalıdır. Fakat, dar bir pencere zamanda çözünürlüğü artırırken düşük frekans çözünürlüğüne sebep olacaktır. Geniş bir pencere seçildiğinde frekans çözünürlüğü artacak ancak bu sefer de zamanda çözünürlük azalacaktır. Sorun, tek bir pencere fonksiyonu seçilip bütün inceleme boyunca kullanılmasından, yani pencere boyutunun tüm inceleme boyunca sabit kalmasından kaynaklanmaktadır. Bu yüzden FD'ye göre üstünlükleri bulunan KZFD, çok geniş frekans bantları içeren işaretlerin incelenmesinde yetersiz kalmaktadır. Günlük hayatta daha sık karşımıza çıkan bu tür işaretlerin global davranışlarını görmek için, düşük frekanslarda yüksek frekans ve düşük zaman çözünürlüğüne sahip, lokal davranışlarını görmek için de yüksek frekanslarda düşük frekans ve yüksek zaman çözünürlüğüne sahip pencere fonksiyonları gerekmektedir. Yani, değişken uzunluklu bir pencere fonksiyonu kullanılmalıdır. Dalgacık dönüşümü, bu tip bir incelemeye olanak vermektedir.

2.3.2. Sürekli dalgacık dönüşümü

DD'de, KZFD'den farklı olarak, farklı frekanslar farklı çözünürlüklerde incelenmektedir. DD, KZFD'ye benzer şekilde yapılır: İşaret, KZFD'de bir pencere fonksiyonu ile çarpılırken, DD'de 'dalgacık' olarak adlandırılan bir fonksiyonla çarpılır. Ancak, KZFD ile sürekli dalgacık dönüşümü(SDD) arasında iki belirgin fark vardır: SDD'de i) Pencerelenen işaretin Fourier dönüşümü alınmaz ve böylece bir sinüzoide karşılık olarak bir tepe görülür. ii) Her bir spektral bileşen için dönüşüm hesaplanırken pencerenin genişliği değiştirilir. Son şık, dalgacık dönüşümünün en önemli özelliğidir. SDD aşağıdaki gibi ifade edilir:

$$SDD\ (\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) \cdot \psi^{*}(\frac{t-\tau}{s}) \qquad dt \tag{2.61}$$

Temel fonksiyon olan $\psi(t)$ "ana dalgacık" olarak bilinir. τ zamanda öteleme, s ise ölçek parametresidir(Ölçeği 1/frekans olarak tanımlayabiliriz). Ölçeklendirilen ana dalgacık, bir pencere fonksiyonu gibi ele alınarak işaret üzerinde ötelenir ve her pozisyon için ölçek-zaman değerleri hesaplanır. Arzu edilen tüm ölçek parametreleri için işlemler tekrarlandığında işaretin SDD'si hesaplanmış olur.

Ölçek değeri büyük ise(düşük frekanslar), işaret hakkında global bir bilgi elde edilir. Ölçek değeri küçük ise(yüksek frekanslar) işaretteki ayrıntılar(kısa süren değişimler) yakalanır.

DD'de temel fonksiyonlar açıkça belirtilmemektedir. Dalgacık dönüşümü teorisi, dalgacıkların genel özellikleri ve dalgacık dönüşümü ile ilgilidir. Ancak, $\psi(t)$ fonksiyonu kısa ve salınımlı olmalıdır. Fonksiyonun ortalaması sıfır olmalı ve her iki uçta hızlı sönümlenmelidir. Bu kısıtlama, Eşitlik 2.61 ile verilen integralin sonlu olmasını garanti eder[38]. Ölçek parametresinin değeri değiştirilerek, ana dalgacığın sıkştırılması ya da genişletilmesiyle SDD'de kullanılan ana dalgacık fonksiyonları elde edilir. Morlet, Meyer, Meksika şapkası, Daubechies dalgacıkları vb., ana dalgacık fonksiyonu olarak kulanılan fonksiyonlara örnektir.

2.3.3. Ayrık dalgacık dönüşümü

SDD etkili bir dönüşümdür fakat hesap yükü de fazladır. Ayrık dalgacık dönüşümü(ADD), hesap yükünü azaltmasının yanısıra işaretin analiz ve sentezi için

yeterli bilgiyi de sağlamaktadır. ADD, örneklenmiş sürekli zamanlı işaretlere uygulanabilmektedir. ADD' de sayısal süzgeçleme teknikleri kullanılarak sayısal işaretin zaman-ölçek temsili elde edilmektedir.

SDD, incelenen pencerenin ölçeği değiştirilerek, bu pencere zamanda kaydırılarak, işaretle pencere çarpılarak ve tüm zaman üzerinden integrali alınarak hesaplanır. ADD'de ise, farklı ölçeklerde analiz yapabilmek için farklı kesim frekansına sahip süzgeçler kullanılmaktadır.

İşaretteki ayrıntı bilgisinin ölçütü olan işaret çözünürlüğü, süzgeçleme ile değiştirilmektedir. Ölçek ise alt-örnekleme ve üst-örnekleme ile değiştirilir. Alt-örnekleme ile işaretten bazı örnekler atılarak örnekleme oranı düşürülür. Üst-örnekleme ile de işarete yeni örnekler eklenerek işaretleme oranı artırılır.
ADD'de işlem, ayrık işaret $x(n)$, $h(n)$ darbe cevabına sahip yarım bantlı alçak geçiren süzgeçten geçirilerek başlatılır:

$$x(k) * h(k) = \sum_{n=-\infty}^{\infty} x(n) \cdot h(k-n) \tag{2.62}$$

Yarım bantlı alçak geçiren süzgeç, işaretteki en yüksek frekansın yarısından büyük olan tüm frekansları yok eder. Frekans bileşenlerinin yarısının ortadan kalkması, bilginin de yarısının kaybolmasına neden olur. Yani çözünürlük yarıya iner. Frekans bileşenleri yarıya düştüğünden, örneklerin de yarısı gereksiz hale gelir ve atılabilir. Bu yüzden işaret 2 ile alt-örneklenir. Böylece ölçek de iki katına çıkar. Süzgeçleme ve alt-örnekleme işlemlerinden sonra elde edilen işaret matematiksel olarak aşağıdaki gibi ifade edilebilir:

$$y(k) = \sum_{n=-\infty}^{\infty} h(n) \cdot x(2 \cdot k - n) \tag{2.63}$$

ADD,işareti

1- Kaba bir yaklaşık işarete
2- Detay işaretine

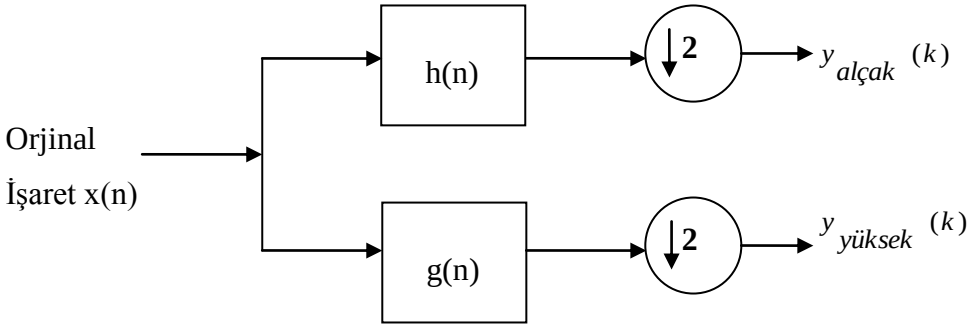
ayrıştırarak işareti farklı frekans bantlarında farklı çözünürlüklerde analiz eder. ADD, alçak geçiren ve yüksek geçiren süzgeçlere karşılık gelen ölçek fonksiyonu ve dalgacık fonksiyonu olmak üzere iki fonksiyon kümesi kullanır.

İşaretin farklı frekans bantlarına ayrıştırılması, zaman domeni işaretinin art arda yüksek ve alçak geçiren süzgeçlerden geçirilmesiyle sağlanır.

Orjinal $x(n)$ işareti önce yarım bantlı yüksek geçiren g(n) süzgecinden ve alçak geçiren $h(n)$ süzgecinden geçirilir. Süzgeçlemeden sonra en yüksek frekans yarıya indiğinden işaretteki örneklerin yarısı atılabilir. Bu nedenle işaret 2 ile alt-örneklenir. Bu, bir seviyeli bir ayrıştırma işlemidir ve 'altbant kodlama' olarak adlandırılır. Şekil 2.7'de bu bir seviyeli ayrıştırma işlemi görülmektedir. 2 ile alt-örneklemenin ardından süzgeç çıkışları aşağıdaki gibi gösterilebilir:

$$y_{yüksek}(k) = \sum_n x(n)g(2k-n) \tag{2.64a}$$

$$y_{alçak}(k) = \sum_n x(n)h(2k-n) \tag{2.64b}$$



Şekil 2.7 Ayrık dalgacık dönüşümünde bir seviyeli ayrıştırma

Bir seviyeli ayrıştırma işlemi sonrasında tüm işaret yarı sayıda örnek ile temsil edildiğinden zamanda çözünürlük yarıya iner. Buna rağmen frekansta çözünürlük artar, çünkü elde edilen işaretin kapsadığı frekans bandı bir üst seviyedeki işaretin frekans bandının yarısıdır. Böylece frekanstaki belirsizlik yarı yarıya azalmış olur. Yüksek frekanslarda iyi zaman çözünürlüğü elde edilmiş olur. Bu işlemler istendiğinde art arda uygulanarak işaretin istenen seviyede ADD'si hesaplanabilir.

Alçak geçiren süzgeç çıkışındaki işaretin alt-örneklenmesiyle elde edilen işaret 'yaklaşıklık katsayıları' olarak adlandırılır. Yüksek geçiren süzgeç çıkışındaki işaretin alt-örneklenmesiyle elde edilen işaret 'detay katsayıları' olarak adlandırılır.

Aynı ayrıştırma seviyesindeki iki süzgeç çıkışı üst-örneklenip sentez süzgeçlerden geçirildikten sonra toplanırsa orjinal işaret elde edilir. Yani geri çatma mümkündür.

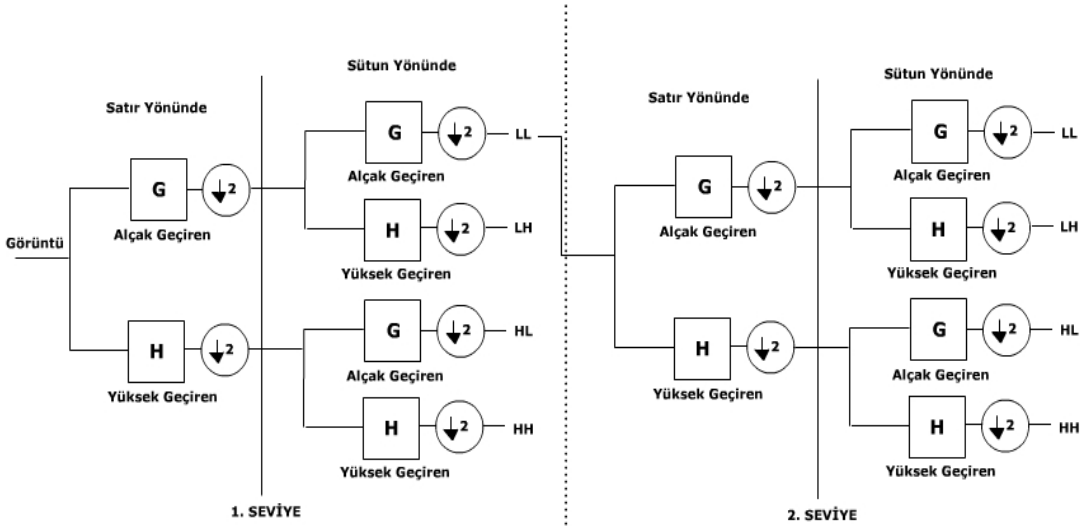
Yüksek ve alçak geçiren süzgeçler birbirlerinden bağımsız olmayıp aralarında aşağıdaki gibi bir ilişki söz konusudur:

$$g(L-1-n) = (-1)^n \cdot h(n) \tag{2.65}$$

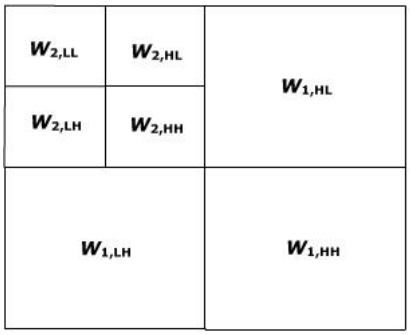
Burada $g(n)$ ve $h(n)$ sırasıyla yüksek geçiren süzgeçler, L süzgeç uzunluğudur(çift sayı olmalıdır).

Bu çalışmada, orjinal işaret 2-B görüntü olduğu için işlemler önce satırlara sonra sütunlara uygulanmıştır[8]. 2 seviyeli piramit yapılı ADD(Her seviyede sadece alçak frekanslı görüntü ayrıştırılmaktadır) ve dalgacık fonksiyonu olarak Daubechies dalgacık fonksiyonu kullanılmıştır. Oluşan her frekans kanalı için l_1-norm'u hesaplanarak öznitelikler elde edilmiştir.

Çalışmada kullanılan 2 seviyeli ayrık dalgacık dönüşümü ve incelenen görüntünün iki seviyeli dalgacık ayrıştırması sonucu oluşan kanallar Şekil 2.8'de görülmektedir. Burada LL, art arda iki kez alçak geçiren süzgeçten geçirilip alt örneklenmiş işareti, LH, önce alçak, ardından yüksek geçiren süzgeçten geçirilip alt örneklenmiş işareti, HL, önce yüksek, sonra alçak geçiren süzgeçten geçirilip alt örneklenmiş işareti ve HH, art arda iki kez yüksek geçiren süzgeçten geçirilip alt örneklenmiş işareti göstermektedir. $W_{1,x}$, 1. seviye, $W_{2,x}$, 2.seviye sonunda oluşan kanalları temsil etmektedir.



(a)



(b)

Şekil 2.8 (a) 2-B görüntü için iki seviyeli ayrık dalgacık ayrıştırması
(b) İki seviyeli dalgacık ayrıştırması ile oluşan kanallar

3. GÖRÜNTÜ BÖLÜTLEME

Bu bölümde, çalışmada incelenen görüntülerin özellikleri anlatılacak, ardından bölütleme ve sınıflama işlemlerinin nasıl gerçekleştirildikleri açıklanacaktadır. Bölümün sonunda, benzetim sonuçları ve bu sonuçlar konusundaki yorumlar verilecektir.

3.1. Çalışmada İncelenen Görüntüler

Bu tezde, iki tür görüntü üzerinde çalışılmıştır. Bunlar, doku ve optik görüntülerdir.

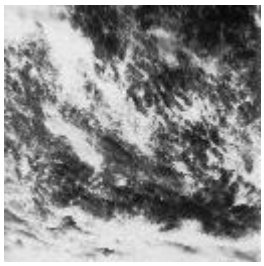
3.1.1. Doku görüntüsü

Genel olarak, doku analizinde ilk adım, birden fazla birbirinden farklı özellik gösteren bölgeden oluşan bir görüntüyü homojen(tek cinsten) alt görüntülere ayırmaktır. Bölgelerin homojenliği, gri seviye yoğunluğu, bölgenin rengi ve doku gibi pek çok özelliğe göre belirlenir. Ancak, çoğu durumda, doku doğal görüntülerin analizinde kullanılabilecek tek bilgidir. Bu yüzden de, doku analizi, görüntü analizi ve örüntü tanıma(pattern recognition) alanlarında ciddi anlamda ilgi uyandırmıştır[39].

3.1.1.1 Doku tanımı

Dokunun kesin bir tanımı bulunmamasına rağmen, bu tarif, düzgünlük(smoothness), irilik(coarseness) ve düzenlilik(regularity) gibi özelliklerin ölçütlerini sağlamaktadır[27].

Genel olarak, dokunun, bir nesnenin yüzey özelliklerini tasvir ettiği söylenebilir. Doku, ‘düzenli’ ve ‘istatistiksel’ doku olmak üzere ikiye ayrılabilir[40]. Düzenli doku, piksel çözünürlüğüne oranla büyük olan, tekrarlanan doku yapıtaşlarının birleşmesiyle oluşur. İstatistiksel dokuda ise rasgele bir dağılım görülür. Aşağıda her iki tür için örnekler görülmektedir.



(a) Gökyüzünde bulutlar (istatistiksel)



(b) Tuğlalardan örülmüş duvar (düzenli)

Şekil 3.1 Düzenli ve istatistiksel doku görüntüleri

Çoğunlukla, doku görüntüleri bu iki türün hiyerarşik bir birleşimiyle oluşmaktadır. Ana hatlar düzenli doku tarafından belirlenirken, mikro ölçekte istatistiksel dokuya rastlanmaktadır.

Doku, 'yapay' ve 'doğal' olarak da gruplanabilir. Yapay doku görüntüleri, çizgi, nokta, yıldız vb. şekillerin nötr bir arka plana yerleştirilmesiyle oluşturulur. Doğal doku görüntüleri ise, doğal manzaralardan elde edilir. Bu tip doku için tuğlalardan örülmüş bir duvar, kum ve çimen fotoğrafları örnek verilebilir. Brodatz, doğal doku fotoğraflarından oluşan bir albüm hazırlamıştır[41]. Bu çalışma için de Brodatz'ın albümünden 16 fotoğraf seçilmiştir.

Dokular, havadan ya da uydudan çekilmiş fotoğrafların, biyomedikal görüntülerin ve daha pek çok tipte görüntünün yüzey ve nesne tanımlanmasında kullanılabilecek önemli karakteristikler sunar. Bu görüntülerin analizi, endüstride, doğal kaynakların uzaktan algılanmasında ve bilgisayarlı tomografi ile tıbbi teşhiste temel oluşturur[10]. O yüzden, doku analizi, bölütlenmesi ve sınıflandırılması konularında pek çok araştırma yapılmıştır.

Bölütleme işleminin tasarımı, dokunun öznitelikleriyle yakından ilgilidir[39]. Doku özniteliklerini çıkarmak için pek çok yöntem bulunmaktadır. Bu yöntemleri kullanan çalışmaların bazılarına 'GİRİŞ' bölümünde kısaca değinilmiştir.

Bu tezde, görüntülerin özniteliklerinin çıkarılması için önerilen yöntem, 2-B dikgen kafes yapılardır. Bu yöntem, daha önce denenmiş tek 2-B kafes yapı olan üç parametreli kafes yapı ve öznitelik çıkarmada çok sık uygulanan ayrık dalgacık dönüşümüyle karşılaştırılmıştır. 2-B dikgen kafes yapılar, doku görüntülerini, uygulanan diğer iki yöntemden çok daha iyi bölütleyebilmektedirler.

3.1.2. Optik görüntü

Tezde, bölütleme için kullanılan ikinci görüntü türü, uzaktan algılama ile elde edilmiş bir optik görüntüdür.

Uzaktan algılama verisiyle yapılan çalışmaların asıl amacı, bilgi toplamaktır[42]. Toplanan bilgiler, ormancılık, tarım, kartografya, jeoloji, şehir planlama ve çevre bilimi gibi çeşitli alanlarda yapılan araştırmalarda kullanılmaktadır.

Uzaktan algılama amacıyla kullanılan uydulardan biri de SPOT uydusudur. SPOT, Fransız Uzay Ajansı(Centre National d'Etudes Spatiales-CNES) tarafından işletilen ticari amaçlı bir görüntüleme uydusudur. SPOT uydusu, hem çok spektrumlu(multispectral), hem tek spektrumlu(monospectral) hem de pankromatik(panchromatic) görüntüler için yüksek çözünürlüklü görüntüleme imkanı verir. Yüksek çözünürlükler, görüntülerdeki küçük ayrıntıları büyütür ve toprak örtüsü üzerindeki farklılıkların mükemmel bir şekilde gözlemlenmesini sağlar[43].

SPOT ürünleri, piksel büyüklükleri(2.5 m, 5 m, 10 m veya 20 m'lik çözünürlük) ve spektral kazanç biçimleri(siyah-beyaz ve renkli) yönünden farklılıklar gösterirler. Bu ürünler

- yeryüzünün verilen uzaysal çözünürlükte, bir veya daha fazla spektral bantta alınmış görünüşlerine

veya

- biri siyah-beyaz, diğeri renkli olmak üzere aynı anda elde edilmiş iki ayrı görüntünün birleştirilmesine

karşılık gelirler[44].

Beş tane SPOT uydusu bulunmaktadır. Tezde incelenmek üzere seçilen görüntü, SPOT 4 tarafından çekilmiş, İstanbul'u kapsayan bir görüntüden alınmış, 256x256 boyutunda tek spektral bantlı(monospectral), siyah-beyaz bir görüntüdür. Çözünürlüğü 10 m'dir ve dalgaboyu 0.61-0.68 μm arasındadır. Ana görüntü, 25 Ağustos 2003'te çekilmiş ve 18 Şubat 2004'te İstanbul Teknik Üniversitesi'nin Maslak kampüsünde bulunan yer istasyonu tarafından işlenmiştir.

Optik görüntü ile yapılan çalışmalar genelde pankromatik ya da çok spektrumlu uzaktan algılama görüntüleri üzerinedir. Birden fazla spektrum içeren görüntülerle çalışıldığında daha iyi sonuçlar elde edilmektedir, çünkü bu görüntülerde oluşturulan

öznitelikler, görüntünün özelliklerini daha iyi temsil etmektedirler. Bu çalışmada incelenen görüntü gibi tek bir spektral bant içeren görüntülerde elde edilen bölütleme sonuçları yeterince tatmin edici olmayabilir. 2-B kafes yapılar daha önce bu tür görüntülerde hiç kullanılmamıştır. Ayrık dalgacık dönüşümünün ise bazı uygulamaları mevcuttur[45].

Üç parametreli kafes yapısı, incelenen optik görüntüde başarı sağlayamazken, 2-B dikgen kafes yapı ile ayrık dalgacık dönüşümünün birbirlerine üstünlük sağladıkları yönler bulunmaktadır.

3.2. Görüntülerin Bölütlenmesi

Bu çalışmada, önerilen yöntem olan 2-B dikgen kafes süzgeç yapıları dışında karşılaştırma amacıyla iki ayrı dönüşüm yöntemi daha(üç parametreli kafes süzgeçler ve ayrık dalgacık dönüşümü) uygulanmıştır.

3.2.1. 2-B kafes yapılar ile görüntü bölütleme

Kafes yapıları, modele dayalı yöntemlerdir. Modele dayalı yöntemlerde, görüntüden elde edilen bazı parametreler tüm görüntüyü modellerler. Burada da model parametreleri, kafes süzgeçlerin yansıma katsayılarıdır.

Tezde, 2-B dikgen kafes süzgeç yapısı ile bölütleme yapılırken öngörü destek bölgesi için çeyrek düzlem modeli kullanılmıştır. Kullanılan model, Şekil 2.4(a)'da N.derece için gösterilen çeyrek düzlem modelidir. Tezde bu kafes yapısı sadece 1., 2. ve 3. dereceler için denenmiştir çünkü kullanılan pencere boyutları için 3.dereceden yukarısı işlem yükünü artırırken performansta önemli bir artış sağlamayacaktır.

Üç parametreli kafes süzgeçleri, görüntü üzerinde öngörü hata süzgeçlemesi işlemini gerçekleştirirler. Yöntemde, karesel hatalar minimize edilerek, her aşamadaki kafes süzgeçleri için normal denklemler elde edilir(Eşitlik 2.31). Bu normal denklemler çözülerek kafes süzgecin yansıma katsayıları hesaplanır.

Çalışmada, karşılaştırma amacıyla kullanılan ve Şekil 2.3'te n aşama için gösterilmiş üç parametreli kafes yapısında beş aşama uygulanmıştır. Çalışılan görüntülerin bölütlenmesinde beş aşama yeterli olmaktadır. Aşama arttıkça, işlem yükü de artmakta ancak çok belirgin bir performans artışı görülmemektedir[12]. Aşamalar sonucunda 15 tane yansıma katsayısı oluşturulur.

3.2.2. Ayrık dalgacık dönüşümü ile görüntü bölütleme

Bu tezde, karşılaştırma amacıyla kullanılan ayrık dalgacık dönüşümü için [9]'daki 2 seviyeli, piramit yapılı dalgacık dönüşümü kullanılmıştır. Ana dalgacık fonksiyonu, dikgen Daubechies-4 dalgacığıdır. [9]'da önerilenin aksine özniteliklere ağırlıklandırma yapılmamıştır.

Dalgacık dönüşümü sonucunda elde edilen kanalların l_1-normu alınarak bölütleme işleminde kullanılan öznitelikler hesaplanmıştır. Bir kanalın l_1-normu şu şekilde ifade edilir:

$$e = \frac{1}{M^2} \sum_{m,n=1}^{M} \left| x(m,n) \right| \tag{3.1}$$

Burada, kanal, yani alt görüntü, MxM boyutundadır. m ve n, kanalın satır ve sütunları, x ise kanalın dalgacık katsayısıdır. K seviyeli piramit yapılı dalgacık dönüşümünde, elde edilen öznitelik vektörünün boyutu 1x(3K+1)'dir[9]. 2 seviyeli ayrıştırma sonucunda 1x7 boyutlu bir öznitelik vektörü oluşturulur.

Görüntülerin bölütlenmesi ve sınıflandırılması işlemleri, eğitim ve test aşaması olmak üzere iki ana bölüme ayrılabilir. Eğitim aşamasında, dönüşüm teknikleri kullanılarak, mevcut bütün sınıfları karakterize eden öznitelik vektörleri hesaplanır ve bir veri tabanında tutulur. Test aşamasında ise, bölütlenip sınıflandırılacak görüntüden bir pencereyle kaydırma yoluyla her adımda elde edilen öznitelik vektörleri, veri tabanındaki öznitelik vektörleriyle karşılaştırılarak pencerenin içinde kalan bölge için sınıf kararı verilir.

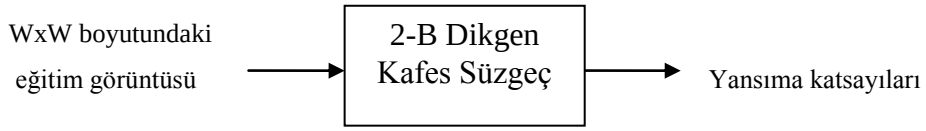
3.3. Eğitim Aşaması

Bu çalışmada, önerilen yöntem olan 2-B dikgen yapılar gibi, karşılaştırma amacıyla uygulanan diğer yöntemler de pencereleme tabanlı yöntemlerdir. Bu tip yöntemlerde işlemler, bir pencere görüntü üzerinde kaydırılarak pencere içinde kalan bölgeden gerekli parametreler hesaplanarak gerçekleştirilir. Bu yaklaşımın temel sakıncası, pencere boyutunun seçilmesi ile ilgilidir. İyi bir kestirim için büyük bir pencereye ihtiyaç duyulur, ancak pencere boyutu büyüdükçe, pencere içinde homojen olmayan bölgelere rastlama ihtimali de yükselir ki bu da kestirimi güvenilir olmaktan çıkarır[46]. Pencere boyutu genellikle deneysel olarak bulunur. İncelenen her iki

görüntü tipi için pencere boyutları ve performansları, bölümün ilerleyen sayfalarında tartışılacaktır.

3.3.1. 2-B dikgen kafes süzgeç yapılarında eğitim

2-B dikgen kafes süzgecin girişi mevcut görüntü sınıflarından seçilen bir pencere, çıkışı ise görüntüyü modellemek için kullanılan kafes yapının yansıma katsayılarıdır(Şekil 3.2).



Şekil 3.2 2-B dikgen kafes yapılar için eğitim aşaması

Çalışmada, 1., 2. ve 3.derece kafes süzgeçler kullanılmış ve öngörü destek bölgesi için sadece çeyrek düzlem modeli yaklaşımı yapılmıştır. Simetrik olmayan yarı düzlem modelinde öngörü destek bölgesi, çeyrek düzlem modeline oranla daha büyük boyutta olmalıdır. Bu durum, bölütleme uygulamalarında kullanılan pencerelerin boyutlarının da büyük tutulmasını gerekli kılmaktadır. Büyük pencere boyutları, farklı homojen bölgelere ait piksellerle karşılaşarak pencere içindeki bölgenin yanlış modellenmesine ve dolayısıyla bölütleme performansının düşmesine sebep olabilmektedir. Uygulanan çeyrek düzlem modelinde, elemanların dizilimi sayesinde her aşamada elde edilen ileri yönde yansıma katsayıları, 1.çeyrek düzleme, geri yönde yansıma katsayıları da 2.çeyrek düzleme karşılık gelmektedir. Dolayısıyla görüntü yeterince iyi bir şekilde modellenebilmektedir. Bu nedenlerden dolayı, çalışmada çeyrek düzlem modeli yeterli görülmüştür. Çeyrek düzlem modelinde, kullanılan her derece için oluşturulan yansıma katsayıları Tablo 3.1'de gösterilmiştir.

Tablo 3.1 Çeyrek düzlem modelinde 1.,2. ve 3. dereceler için oluşturulan yansıma katsayıları

Çeyrek Düzlem Modeli				
	Aşama	Basamak	Yansıma Katsayısı	Toplam Yansıma Katsayısı
1. derece	1.	3	6	12
	2.	2	4	
	3.	1	2	
2. derece	1.	8	16	72
	2.	7	14	
	…….	……	……	
	8.	1	2	
3. derece	1.	15	30	240
	2.	14	28	
	3.	13	26	
	…….	……	…….	
	14.	2	4	
	15.	1	2	

Elde edilen bu yansıma katsayılarından öznitelik vektörleri oluşturulur.

Çeyrek düzlem modeliyle yapılan bölütleme işlemlerinde öznitelik vektörlerini oluşturmak için hem ileri, hem de geri yönde yansıma katsayıları kullanılır. Görüntüden elde edilen öznitelik matrisi $F_{görüntü}$ ile öznitelik vektörü $f_{görüntü}$ aşağıdaki gibidir.

$$F_{görüntü} = \begin{bmatrix} \Gamma_{f_0}^{m-(m-1)} & \Gamma_{f_1}^{m-(m-1)} & \dots & \Gamma_{f_{m-2}}^{m-(m-1)} & \Gamma_{f_{m-1}}^{m-(m-1)} \\ \Gamma_{f_0}^{m-(m-2)} & \Gamma_{f_1}^{m-(m-2)} & \dots & \Gamma_{f_{m-2}}^{m-(m-2)} & \Gamma_{b_1}^{m-(m-2)} \\ . & . & . & . & . \\ . & . & . & . & . \\ . & . & . & . & . \\ \Gamma_{f_0}^{m} & \Gamma_{b_m}^{m} & 0 & 0 & 0 \end{bmatrix}$$

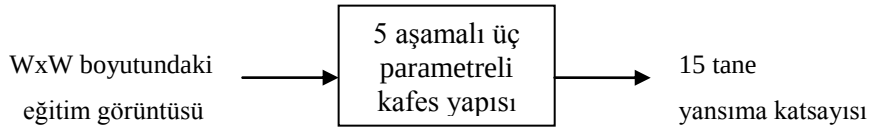
$$\begin{bmatrix} \dots & \dots & \Gamma_{b_{m-2}}^{m-(m-1)} & \Gamma_{b_{m-1}}^{m-(m-1)} & \Gamma_{b_m}^{m-(m-1)} \\ \dots & \Gamma_{b_{m-1}}^{m-(m-2)} & \Gamma_{b_m}^{m-(m-2)} & 0 & 0 \\ \dots & 0 & 0 & 0 & 0 \\ . & . & . & . & . \\ . & . & . & . & . \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}_{mx\,2m} \tag{3.2}$$

Burada m, aşama sayısını göstermektedir.

$$f_{görüntü} = \left[\Gamma_{f_0}^{m-(m-1)} \quad \Gamma_{f_1}^{m-(m-1)} \quad \dots \quad \Gamma_{f_{m-1}}^{m-(m-1)} \quad \Gamma_{b_{1_1}}^{m-(m-1)} \quad \Gamma_{b_2}^{m-(m-1)} \quad \dots \quad \Gamma_{b_m}^{m-(m-1)} \quad \Gamma_{f_0}^{m-(m-2)}\right.$$
$$\left. \dots \quad \Gamma_{f_{m-2}}^{m-(m-2)} \quad \Gamma_{b_1}^{m-(m-2)} \quad \dots \Gamma_{b_m}^{m-(m-2)} \quad \dots \quad \Gamma_{f_0}^{m} \quad \Gamma_{b_m}^{m} \right]^T_{1xm(m+1)} \tag{3.3}$$

3.3.2. Üç parametreli kafes süzgeçlerde eğitim

Üç parametreli kafes süzgeçlerde, her aşamada üç tane yansıma katsayısı üretilir. 5 aşama için ise 15 yansıma katsayısı oluşturulur. Kafes süzgecin girişi mevcut görüntü sınıflarından seçilen bir pencere, çıkışı ise görüntüyü modellemek için kullanılan 15 tane yansıma katsayısıdır(Şekil 3.3).



Şekil 3.3 Üç parametreli yapı için eğitim aşaması

Görüntüden elde edilen öznitelik matrisi $F_{görüntü}$ ve öznitelik vektörü $f_{görüntü}$ aşağıdaki gibidir:

$$F_{görüntü} = \begin{bmatrix} \Gamma_{10}(1) & \Gamma_{10}(2) & \Gamma_{10}(3) & \Gamma_{10}(4) & \Gamma_{10}(5) \\ \Gamma_{11}(1) & \Gamma_{11}(2) & \Gamma_{11}(3) & \Gamma_{11}(4) & \Gamma_{11}(5) \\ \Gamma_{01}(1) & \Gamma_{01}(2) & \Gamma_{01}(3) & \Gamma_{01}(4) & \Gamma_{01}(5) \end{bmatrix} \tag{3.4}$$

Burada i. kolon, üç parametreli kafes süzgecin i. aşamasında üretilen yansıma katsayılarını göstermektedir.

$$f_{görüntü} = \left[F_{görüntü}(:,1)^T \quad F_{görüntü}(:,2)^T \quad F_{görüntü}(:,3)^T \quad F_{görüntü}(:,4)^T \quad F_{görüntü}(:,5)^T\right] \tag{3.5}$$

Burada, $F_{görüntü}(:,n)^T$, $F_{görüntü}$ matrisinin n. kolonunun transpozunu göstermektedir.

3.3.3. Ayrık dalgacık dönüşümünde eğitim

Eldeki tüm görüntü sınıflarında, ilerde test aşamasında hangi boyuttaki pencereyle ne tür bir kaydırma(pencere pencere veya piksel piksel) yapılacaksa, o şekilde bir kaydırma uygulanarak alt görüntüler elde edilir. Bu alt görüntülerin yarısının, 2 seviyeli ADD ile 1x7 boyutunda öznitelik vektörleri bulunur:

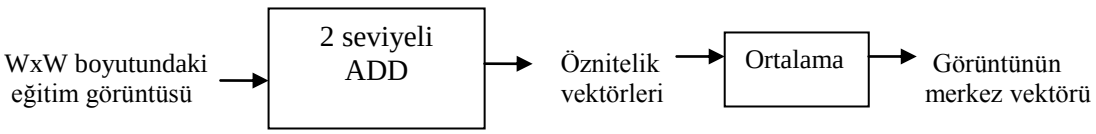
$$f_{alt} = \left[e_{1,HL} \quad e_{1,LH} \quad e_{1,HH} \quad e_{2,LL} \quad e_{2,HL} \quad e_{2,LH} \quad e_{2,HH}\right] \tag{3.6}$$

Burada, e_x, Şekil 2.8(a) da gösterilen kanallardan x kanalının l_1-normu(Eşitlik 3.1) ile hesaplanan enerjisidir.

Bu öznitelik vektörlerinin ortalaması alınarak, o görüntüyü karakterize eden bir merkez vektör bulunur:

$$M_k = \frac{1}{N}\sum_{i=1}^{N} f_{alt_k,i} \tag{3.7}$$

Burada, k, merkez vektörü hesaplanan sınıf görüntüsünün numarası, N, k.sınıf görüntüsündeki alt görüntü sayısıdır. Şekil 3.4'te merkez vektörünün bulunuşuna kadar geçen süreç görülmektedir.



Şekil 3.4 ADD için eğitim aşaması

Doku görüntülerinde bölütleme için ayrık dalgacık dönüşümü uygulandığında, eğitim aşaması, özellikle pencereler hem yatay, hem de düşey yönde piksel piksel kaydırılacaksa, kafes yapılara oranla çok uzun sürmektedir. Çünkü 16 Brodatz görüntüsünün her birinde bu piksel piksel kaydırma uygulanarak tüm görüntü

taranmakta ve oluşan alt görüntüler kullanılarak tüm doku görüntüleri için bir merkez vektör bulunmaya çalışılmaktadır. Diğer yöntemlerde ise, doku görüntüsünün tümü kullanılarak görüntünün öznitelikleri bir seferde bulunduğundan, her bir görüntü için bir adımda eğitim tamamlanmaktadır.

Bu tezde, doku görüntüleriyle çalışırken eğitim aşamasında özniteliklerin çıkarılması için küçük birer pencere seçmek yerine, görüntünün tamamı kullanılmıştır. Çünkü, incelemede kullanılan doku görüntülerinin tümü düzenli bir yapıya sahip değildir. Böyle rasgele dağılım gösteren görüntülerin herhangi bir yerinden seçilen küçük bir pencereden elde edilen özniteliklerle görüntü iyi modellenemeyecektir.

Tezde, optik görüntüler, doku görüntülerinden çok daha karmaşık yapıda olduklarından, bu görüntüyle çalışırken daha küçük pencerelerle eğitim yapılmıştır. Küçük pencerelerle, hızlı değişimler daha kolay yakalanır, başka bir homojen bölgenin elemanlarına rastlayıp yanlış karar verme olasılığı düşer. Bu görüntüde, eğitim aşamasında, kafes yapılar için 7x7'lik ve 9x9'luk, ayrık dalgacık dönüşümü için ise 9x9'luk alt görüntüler(pencereler) kullanılmıştır.

3.4. Test Aşaması

Bu tezde incelenen görüntüler, doku görüntüsü ve uzaktan algılama görüntüsü(optik görüntü) olmak üzere iki çeşittir.

Elimizde 128x128 boyutunda Brodatz albümünden seçilmiş 16 adet doku görüntüsü bulunmaktadır. Bu 16 görüntünün 4'ü seçilerek birleştirilmiş ve bölütleme ve sınıflandırma işlemlerinde kullanılan 256x256 boyutunda bir görüntü oluşturulmuştur.
İncelenen diğer görüntü, SPOT 4M uydusuyla çekilmiş İstanbul'u kapsayan tek bantlı siyah-beyaz görüntüden seçilmiş 256x256 boyutunda bir görüntüdür.

Test aşamasında, seçilen boyuttaki pencere tüm görüntü üzerinde kaydırılarak her adım için uygulanan yönteme göre, Eşitlik (3.3), (3.5) veya (3.6) şeklindeki pencerenin öznitelik vektörü bulunur. Pencerenin öznitelik vektörü $f_{pencere}$ ile daha önceden hesaplanıp bir veritabanına aktarılmış olan, sınıf görüntülerini karakterize eden öznitelik vektörü $f_{görüntü}$ arasındaki uzaklık hesaplanır. Her pencere için, doku görüntüsünde 16, optik görüntüde ise 3 tane farklı uzaklık değeri bulunur. $f_{pencere}$,

hangi görüntü sınıfına daha yakınsa o pencerenin merkezindeki piksele ya da tüm pencerenin elemanlarına, o görüntü sınıfına atanmış olan etiket verilir. Kaydırma işlemi tüm görüntü taranmış olana dek devam eder.

Çalışmada iki çeşit uzaklık ölçüsü kullanılmıştır:

a) Öklid uzaklığı
b) Mahalonibis uzaklığı

Öklid uzaklığı, şu şekilde tanımlıdır:

$$d_E = \left[(j_1 - j_2)^2 + (k_1 + k_2)^2 \right]^{1/2} \tag{3.8}$$

d_E , (j_1 , j_2) ve (k_1 , k_2) noktaları arasındaki Öklid uzaklığıdır.

Eğitim aşamasında elde edilmiş gerçek öznitelik vektörleri ile test aşamasında kullanılan pencerenin öznitelik vektörü arasındaki Öklid uzaklığı aşağıdaki gibi bulunur:

$$d_E(n) = (f_{görüntü}(n) - f_{pencere}) * (f_{görüntü}(n) - f_{pencere})^T \tag{3.9}$$

*, vektör çarpımını, T, vektörün transpozunu, $d_E(n)$ ise, seçilen n. Brodatz görüntüsü ya da optik görüntüdeki n.sınıf görüntüsünün öznitelik vektörü ile kaydırılan pencerenin öznitelik vektörü arasındaki Öklid uzaklığını göstermektedir.

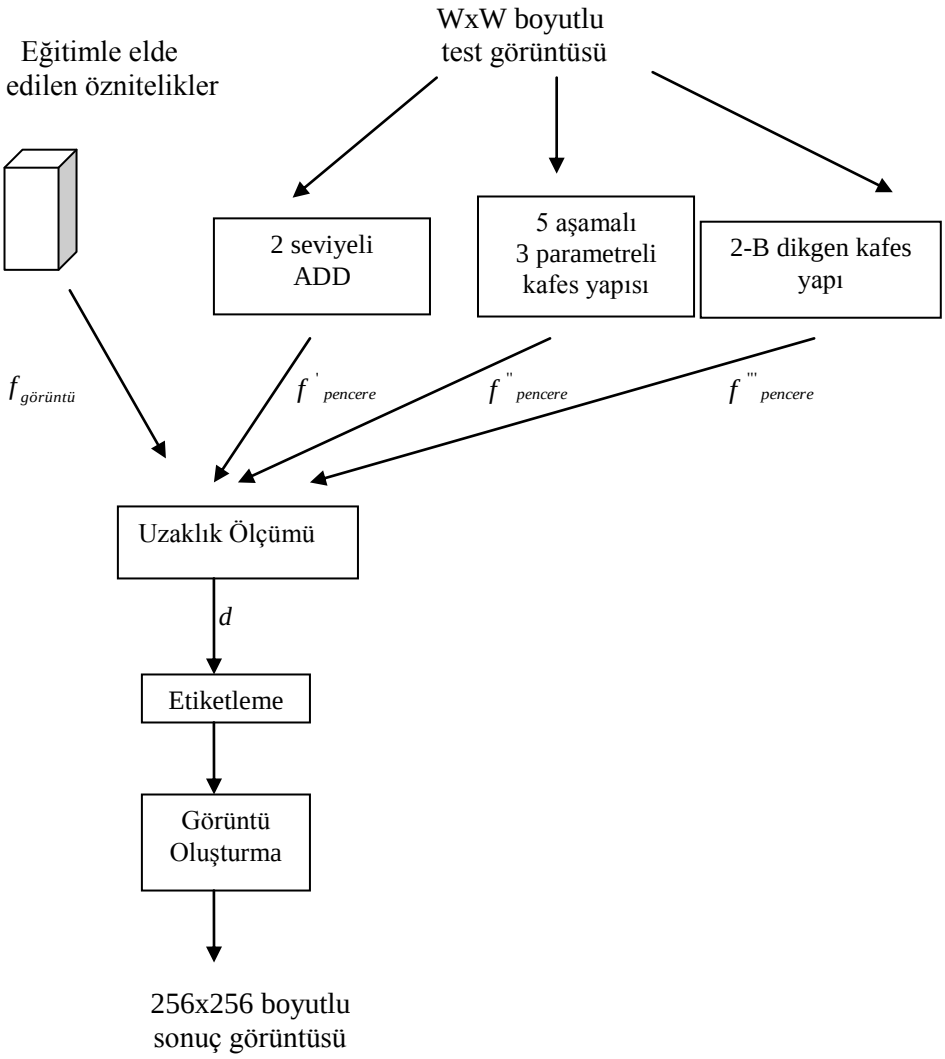
Diğer uzaklık ölçüsü çeşidi Mahalonibis uzaklığı ise şu şekilde hesaplanır:

$$d_M(n) = (f_{görüntü}(n) - f_{pencere}) * C^{-1} * (f_{görüntü}(n) - f_{pencere})^T \tag{3.10}$$

Burada $d_M(n)$, seçilen n. Brodatz görüntüsü ya da optik görüntüdeki n.sınıf görüntüsünün öznitelik vektörü ile test aşamasında kullanılan pencerenin öznitelik vektörü arasındaki Mahalonibis uzaklığını göstermektedir. *C*, öznitelik vektörlerinin kovaryans matrisidir ve şu şekilde hesaplanır:

$$C = (f_{görüntü}(n) - f_{pencere})^T * (f_{görüntü}(n) - f_{pencere}) \tag{3.11}$$

Çalışmada uygulanan eğitim ve test aşamaları aşağıdaki akış şemasıyla özetlenebilir:



Şekil 3.5 Görüntü bölütleme ve sınıflandırma işlemleri

Bu çalışmada, test aşamasında seçilen pencereler için iki farklı karar verme durumu söz konusudur. Birinde pencerenin tüm elemanları etiketlenirken, diğerinde ise sadece pencerenin merkezindeki piksel için karar verilir. Bu iki durum için farklı büyüklüklerde pencereler kullanılmıştır. Doku görüntüsünde her iki durum da incelenirken, optik görüntüde sadece ikinci durum incelenmiştir.

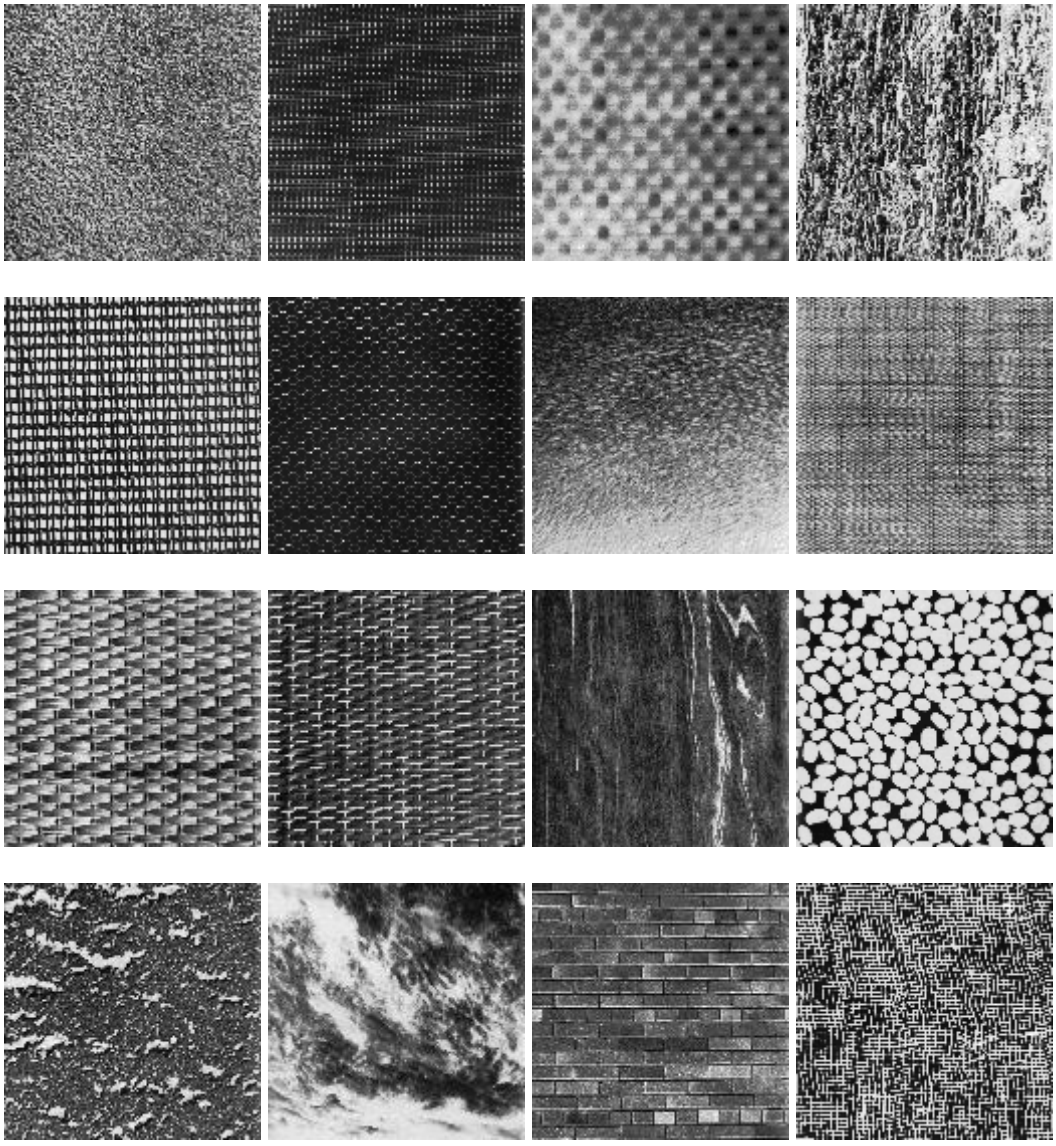
Doku görüntüsünde, tüm pencere için karar verilirken kaydırmada kullanılan pencere boyutları 8x8, 16x16 ve 32x32'dir. Sadece pencerenin merkezindeki piksel için karar verilirken kullanılan pencere boyutları, kafes yapılar için 11x11 ve 21x21, ayrık dalgacık dönüşümü için de 8x8, 16x16 ve 32x32'dir.

Optik görüntüde, test aşamasında, kafes yapıları için 7x7'lik ve 9x9'luk, ayrık dalgacık dönüşümü içinse 8x8'lik pencereler kullanılarak, pencerenin merkezindeki

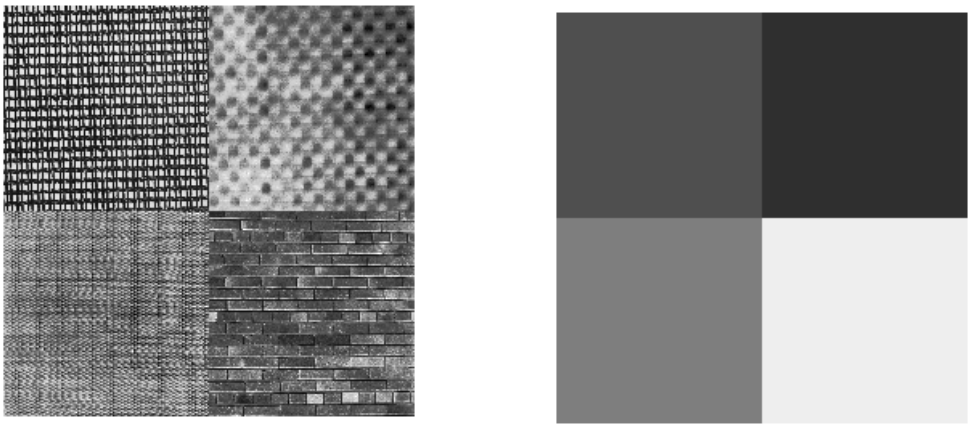
piksel için karar verilmiştir. Bu tip görüntülerde çok hızlı değişimler görüldüğü için çalışılan pencere boyutları mümkün olduğunca küçük tutulmalı ve piksel piksel çalışılmalıdır.

3.4.1. Doku görüntülerinin bölütlenmesi

Çalışmada kullanılan üç öznitelik yöntemi, Brodatz albümünden seçilen 16 adet doku görüntüsüne uygulanmıştır. Bu görüntülerin gerçek boyutları 640x640'tır. Ancak bu çalışmada 128x128'lik boyuta küçültülmüşlerdir. Uygulamada kullanılmak üzere seçilen doku görüntüleri Şekil 3.6'da görülmektedir.



Şekil 3.6 Brodatz albümünden seçilen görüntüler



(a) (b)

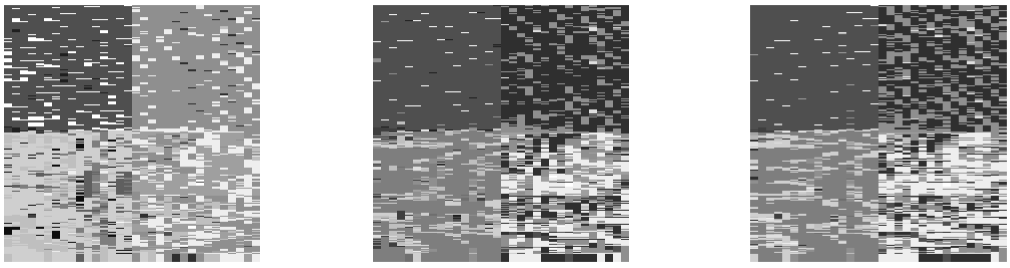
Şekil 3.7 (a) Bölütleme ve sınıflama işlemlerinde kullanılan 4 sınıflı görüntü
(b) Bölütleme ve sınıflama işlemlerinin ideal sonucu

Test aşamasında, kaydırma dikey yönde piksel piksel yapılırken, yatay yönde, ya tam bir pencere boyutu kadar, ya yarım pencere boyutu kadar ya da piksel piksel olmaktadır. Bir yönde piksel piksel kaydırma yapıldığında sınırlarda oluşan hatalar en aza inmektedir. Pencere pencere kaydırma yapıldığında ise sınırlarda hatalar oluşmaktadır. Bu çalışmada dikey yönde piksel piksel kaydırma yapılarak, dikey yönde sınır hatalarının oluşması önlemiştir. Sınır hataları sadece yatay yönde görülecektir. Hem yatay hem de dikey yönlerde kaydırma yapıldığında ise sınır hatalarıyla karşılaşılmamaktadır. Ancak görüntünün bu şekilde taranarak işlem yapılması benzetim zamanını uzatmaktadır.

Yatay yönde tam ya da yarım pencere boyutu kadar kaydırma yapıldığında, karar tüm pencere elemanları için verilmektedir. Yani, tüm pencere elemanlarına aynı etiket atanmaktadır.

Yatay yönde piksel piksel kaydırma yapıldığında ise, pencerenin merkezindeki piksel için karar verilmektedir.

Öncelikle, örtüşmeyen pencerelerle kaydırma yapılması durumu incelenecektir.



(a) (b) (c)

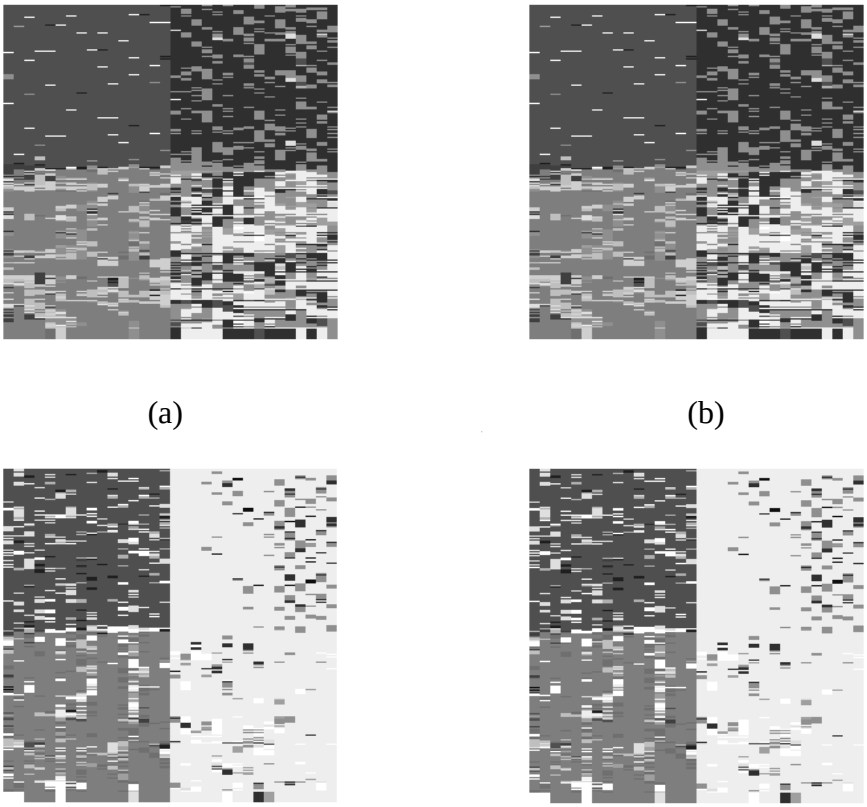


(d) (e)

Şekil 3.8 8x8'lik pencerelerle yatay yönde 8 piksellik kaydırma sonuçları
(a) 2-B dikgen kafes , 1.derece, çeyrek düzlem, Öklid uzak.
(b) 2-B dikgen kafes , 2.derece, çeyrek düzlem, Öklid uzak.
(c) 2-B dikgen kafes , 3.derece, çeyrek düzlem, Öklid uzak.
(d) 5 aşamalı 3 parametreli kafes, Öklid uzaklığı
(e) 2 seviyeli ayrık dalgacık dönüşümü, Öklid uzaklığı

Şekil 3.8'de görüldüğü gibi 2-B dikgen kafes yapılarında 1. derece hiç iyi sonuç vermemektedir. 2.derece ve 3.derece sonuçlarında sınıflar biraz gözükse de pencere boyutu iyi bir bölütleme için yeterli gelmemektedir.

Diğer bir uzaklık ölçüsü Mahalonibis uzaklığının 8x8'lik pencere için sonuçları aşağıda görülmektedir.



(a) (b)

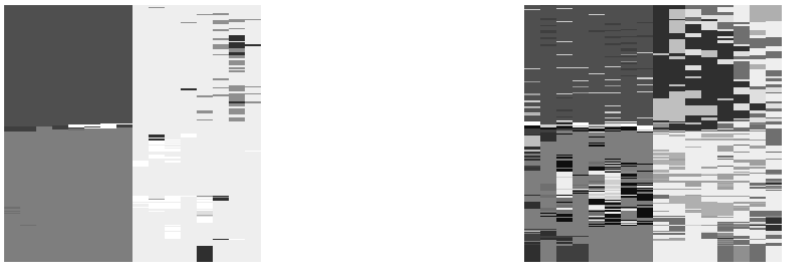
(c) (d)

Şekil 3.9 8x8'lik pencerelerle 8 piksellik kaydırma sonuçları
(a) 2-B dikgen kafes , 2.der., çeyrek d., Öklid uzak.
(b) 2-B dikgen kafes , 2.der., çeyrek d., Mahalonibis uzak.
(c) 5 aşamalı 3 parametreli kafes, Öklid uzak.
(d) 5 aşamalı 3 parametreli kafes, Mahalonibis uzak.

Şekil 3.9'da görüldüğü gibi, kafes yapılarda Mahalonibis uzaklığı, Öklid uzaklığı ile hemen hemen aynı sonucu vermektedir. Ancak Öklid uzaklığı çalışmanın geri kalan kısmındaki hesaplamalarda basitliği yüzünden tercih edilmiştir.



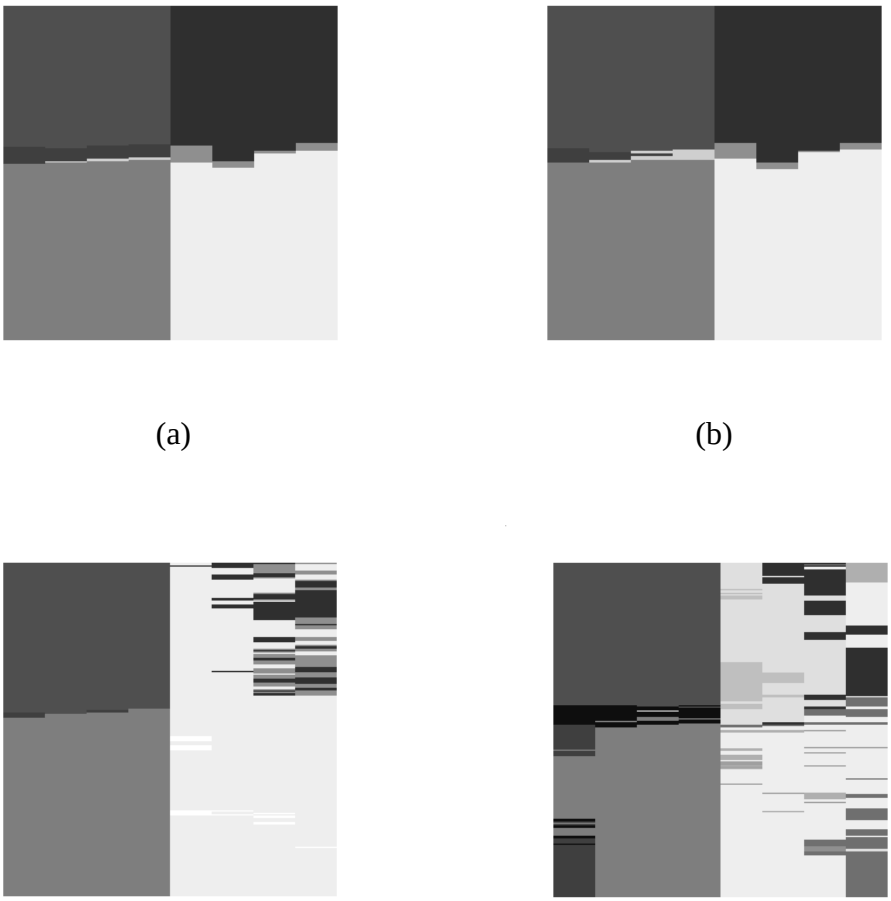
(a) (b) (c)



(d) (e)

Şekil 3.10 16x16'lık pencerelerle 16 piksellik kaydırma sonuçları
(a) 2-B dikgen kafes , 1.der., çeyrek d.
(b) 2-B dikgen kafes , 2.der., çeyrek d.
(c) 2-B dikgen kafes , 3.der., çeyrek d.
(d) 5 aşamalı 3 parametreli kafes
(e) 2 seviyeli ayrık dalgacık dönüşümü

Şekil 3.8 ve 3.10 incelendiğinde, 2-B dikgen kafes yapısının, bölütleme performansı açısından, üç parametreli kafes yapısı ve ayrık dalgacık dönüşümüne belirgin bir üstünlük sağladığı ve 2-B dikgen kafes süzgeçlerde, süzgeç derecesi arttıkça performansın da arttığı görülmektedir. 2.derece ile 3.derece arasında çok belirgin bir fark görülmemekle birlikte 3.derecede bazı piksellerde bozulmalar, bazılarında ise iyileşmeler gözükmektedir. Bu değişimin sebebi, 2.derecenin bu pencere boyutunu modellemek için yeterli olması bu yüzden de burada dereceyi artırmanın performans açısından bir artı sağlamamasıdır. 16x16'lık pencere boyutunda hala bölütleme ve sınıflandırma işlemi tam olarak gerçekleşememektedir. Bu yüzden bir de 32x32'lik pencere ile kaydırma yapıldığında alınan performansa bakılmalıdır.



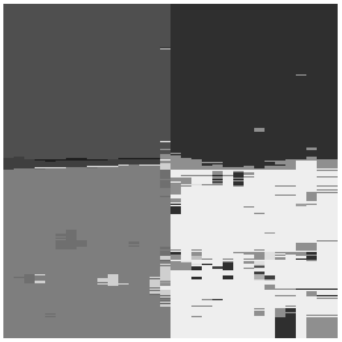
(a) (b)

(c) (d)

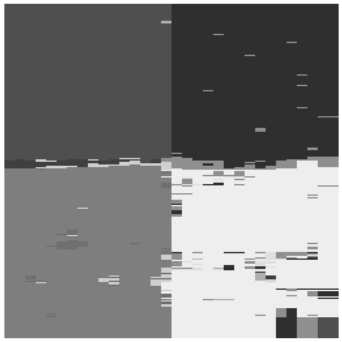
Şekil 3.11 32x32'lik pencerelerle 32 piksellik kaydırma sonuçları
(a) 2-B dikgen kafes , 2.der., çeyrek d.
(b) 2-B dikgen kafes , 3.der., çeyrek d.
(c) 5 aşamalı 3 parametreli kafes
(d) 2 seviyeli ayrık dalgacık dönüşümü

Şekil 3.11 daha önceki benzetim sonuçlarıyla karşılaştırıldığında 32x32'lik pencere boyutu ile yapılan kaydırmanın en iyi sonucu verdiği görülmektedir. Genel olarak, pencere boyutu büyüdükçe algoritmanın doğruluğu da artmaktadır. 2.derece ile 3.derece arasında neredeyse hiç fark yoktur. 32x32'lik pencerelerde 3. dereceye kadar çıkılabilir. 2-B dikgen kafeslerle yapılan bölütlemede, yatay sınırlar dışında hiç hata görülmemektedir. Ancak diğer yöntemlerde sağ üst ve sağ alttaki iki ayrı doku görüntüsünün hala birbirlerinden ayrılamadığı görülmektedir.

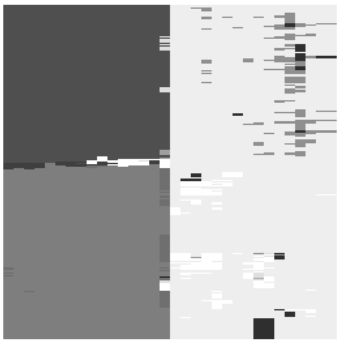
Uygulamalarda, pencereler, birbiriyle örtüşmeyecek biçimde kaydırılarak da yöntemlerin bölütleme performansları karşılaştırılmıştır.



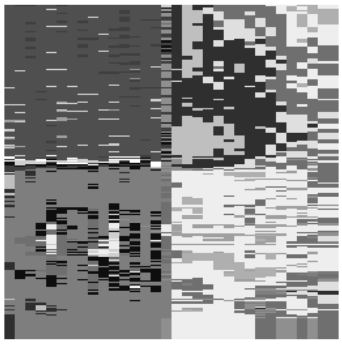
(a)



(b)

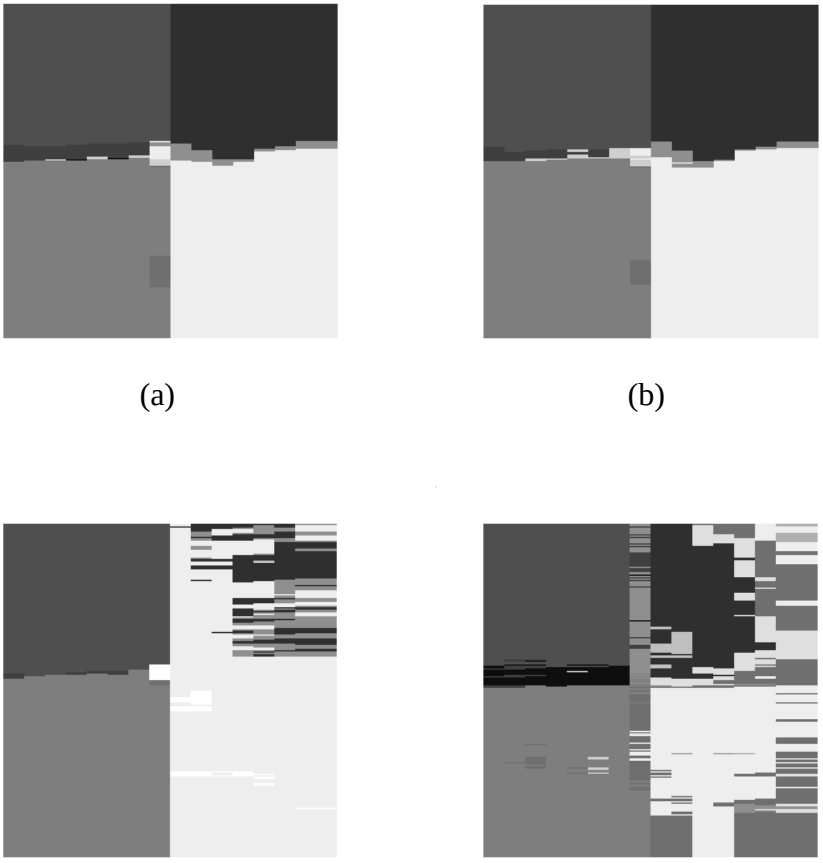


(c)



(d)

Şekil 3.12 16x16'lık pencerelerle 8 piksellik kaydırma sonuçları
(a) 2-B dikgen kafes , 2.der., çeyrek d.
(b) 2-B dikgen kafes , 3.der., çeyrek d.
(c) 5 aşamalı 3 parametreli kafes
(d) 2 seviyeli ayrık dalgacık dönüşümü



(a) (b)

(c) (d)

Şekil 3.13 32x32'lik pencerelerle 16 piksellik kaydırma sonuçları
(a) 2-B dikgen kafes , 2.der., çeyrek d.
(b) 2-B dikgen kafes , 3.der., çeyrek d.
(c) 5 aşamalı 3 parametreli kafes
(d) 2 seviyeli ayrık dalgacık dönüşümü

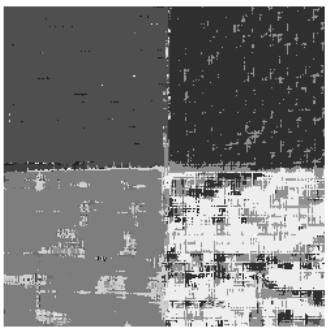
8x8'lik pencereler bu görüntü sınıflarını modelleyebilecek öznitelikleri sağlayabilecek kadar büyük değillerdir. Bu yüzden son iki uygulamadaki sonuçları verilmemiştir.

Şekil 3.10 ve 3.11 ile karşılaştırıldığında, Şekil 3.12 ve 3.13'ten de gözlenebildiği gibi, yatay yönde örtüşen pencerelerle kaydırma yapıldığında, örtüşmeyen pencerelerle kaydırma yapılması durumuna göre daha fazla sınır hatası oluşmaktadır.

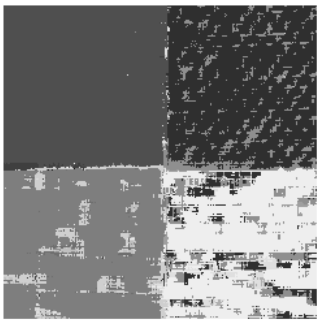
Yatay yönde piksel piksel kaydırma yolu da denenmiştir. Doku görüntüsü yatay yönde piksel piksel kaydırılırken kullanılan pencere boyutları 5x5, 11x11 ve 21x21'dir. Ancak beş aşamalı üç parametreli kafes yapısında 5x5'lik pencere boyutu, öngörü yapabilmek için yeterince büyük değildir, o yüzden bu pencere boyutunun

sonucu verilmeyecektir. 2-B kafes yapıları için sadece 11x11 ve 21x21'lik pencerelerin performansları karşılaştırılacaktır.

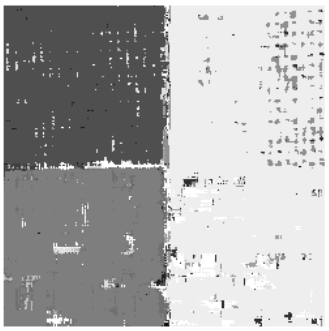
Ayrık dalgacık dönüşümü, dönüşümün yapısı gereği ancak 2'nin üslerini pencere boyutu olarak kabul etmektedir. Bu yüzden bu yöntemde 8x8, 16x16 ve 32x32'lik pencere boyutları denenmiştir.



(a)

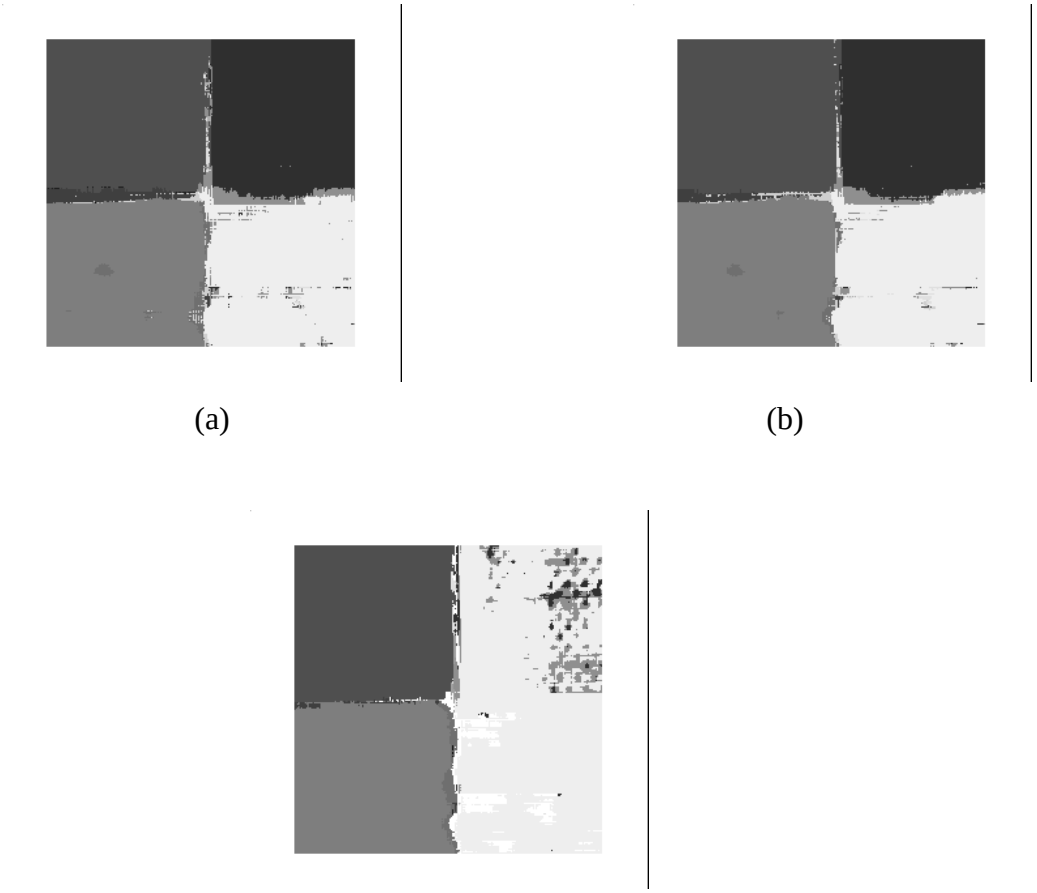


(b)



(c)

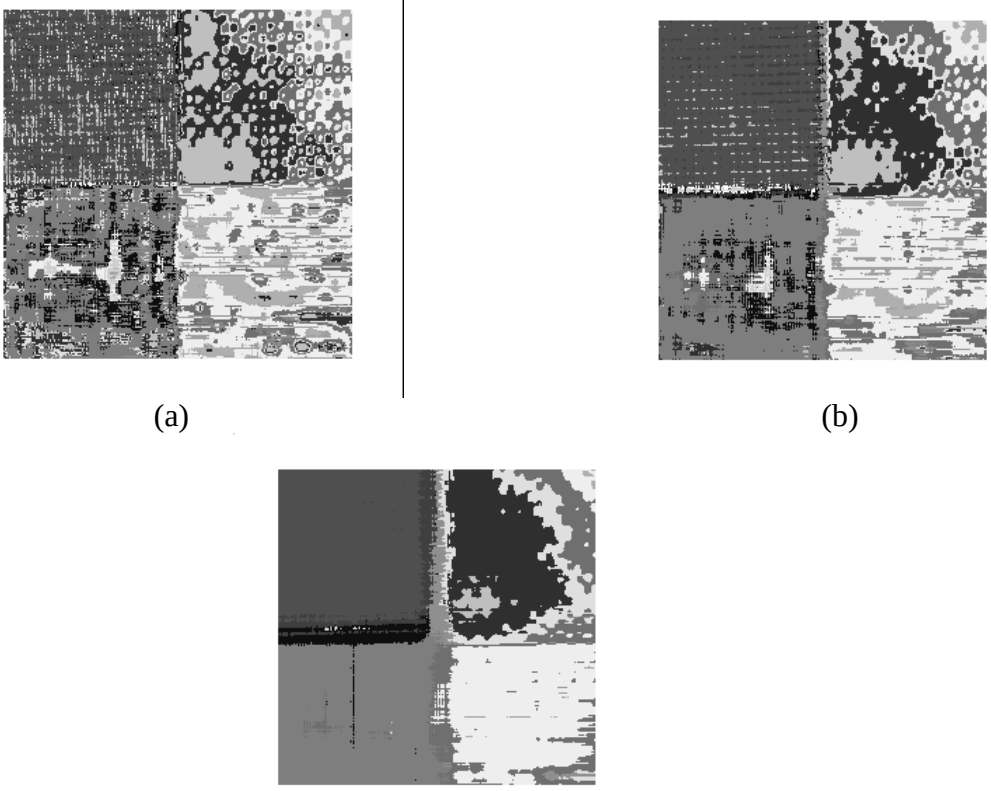
Şekil 3.14 11x11'lik pencerelerle yatay yönde tek piksel kaydırma sonuçları
(a) 2-B dikgen kafes , 2.der., çeyrek d.
(b) 2-B dikgen kafes , 3.der., çeyrek d.
(c) 5 aşamalı 3 parametreli kafes



Şekil 3.15 21x21'lik pencerelerle tek piksel kaydırma sonuçları
(a) 2-B dikgen kafes , 2.der., çeyrek d.
(b) 2-B dikgen kafes , 3.der., çeyrek d.
(c) 5 aşamalı 3 parametreli kafes

Şekil 3.14 ve Şekil 3.15 incelenirse, piksel piksel yapılan işlemlerde pencere pencere çalışmaya göre daha az hata oluştuğu görülmektedir. Sınırlardaki hatalar daha yumuşak geçişlidir. Bunlar beklenen sonuçlardır, çünkü her adımda bir piksele yapılan etiketleme daha yerinde bir inceleme sağlar. Piksel piksel yapılan işlemlerde de, pencerelerle yapılan işlemlerde olduğu gibi kaydırılan pencerelerin boyutu büyüdükçe algoritmaların başarısının da arttığı gözlenmektedir. Bunun nedeni, daha büyük pencerelerden çıkarılan özniteliklerin o bölgeyi daha iyi temsil edebilmesidir.

Farklı pencere boyutlarıyla çalışılan ayrık dalgacık dönüşümü için piksel piksel kaydırma sonucu elde edilen görüntüler Şekil 3.16'da verilmiştir.



(a) (b)

(c)

Şekil 3.16 Ayrık dalgacık dönüşümü için tek piksel kaydırma sonuçları
(a) 8x8'lik pencerelerle
(b) 16x16'lık pencerelerle
(c) 32x32'lik pencerelerle

Şekil 3.16, ayrık dalgacık dönüşümü için yapılan önceki uygulamalarla karşılaştırılırsa, bu yöntemde de, piksel piksel çalışılınca, pencere pencere çalışıldığı duruma göre daha iyi sonuçlar alındığı görülür. Ayrıca büyüyen pencere boyutu performansı da arttırmaktadır. Piksel piksel çalışıldığında ayrık dalgacık dönüşümü üç parametreli kafes yapıdan daha başarılıdır. Ama yine de 2-B dikgen kafes yapı hala en iyi bölütleme sonucunu vermektedir.

Öznitelik çıkarma amacıyla doku görüntüsüne uygulanan dönüşüm yöntemlerinden elde edilen benzetim sonuçlarına bakılarak şunlar söylenebilir:

- Tüm yöntemlerde, işlemler pencerelemeye dayandığı için sınıf sınırlarında sorun yaşanmaktadır.
- Kaydırılan pencerelerin boyutu büyüdükçe algoritmaların performansları da artmaktadır.

- Yatay yönde örtüşen pencerelerle kaydırma yapıldığında, örtüşmeyen pencerelerle kaydırma yapılması durumuna göre daha fazla sınır hatası gözlemlenmektedir.
- 2-B dikgen kafes yapı, bölütleme işlemi yönünden, üç parametreli kafes yapı ve ayrık dalgacık dönüşümüne belirgin bir üstünlük sağlamaktadır.
- 2-B dikgen kafes süzgeçlerde, süzgeç derecesi arttıkça performans da artmaktadır. Ancak kullanılan pencere boyutu yeterince büyük değilse, derecenin artması ek bir iyileştirme getirmemektedir.
- Yatay yönde piksel-piksel kaydırma yapıldığında, pencere-pencere kaydırma yapılması durumuna göre daha az sınır hatası oluşmaktadır. Sınırlardaki hatalarda daha yumuşak geçişler görülmektedir. Burada 21x21'lik pencere 2.derecede bile 16x16'lık pencereden daha iyi sonuç vermiştir.
- En iyi performans 2-B dikgen kafes süzgeçlerde, 32x32'lik pencerede, 3. derece için elde edilmektedir. 16x16 ve daha düşük boyutlu pencerelerle görüntüyü yeterli düzeyde modelleyecek katsayılar elde edilememiştir.

Önerilen yöntem 2-B dikgen kafes süzgeç yapıları, doku görüntüsünü bölütlemede diğer yöntemlerden çok daha yüksek performans göstermiştir. Sınır problemi, yöntemin başarısını gölgelemektedir. Ancak buna rağmen yöntemin görüntü bölütlemede kullanılabilecek özellikte olduğu söylenebilir. Genel olarak tüm görüntülerde iyi sonuç veren tek bir yöntemin bulunamadığı düşünülürse, sınır hatalarını azaltacak başka işlemlerle birleştirildiğinde önerilen yöntemin çok daha başarılı olacağı açıktır.

3.4.2. Optik görüntülerin bölütlenmesi

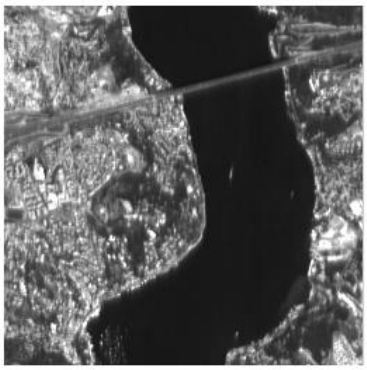
Çalışmada incelenen görüntü monospektral bir görüntüdür ve 256x256 boyutundadır. Mevcut sınıflarla ilgili kesin bir bilgi yoktur, kaç sınıfın olduğuna, bakarak tahmin yoluyla karar verilmiştir. Görüntüde deniz, yerleşim yeri ve yeşillik alan olmak üzere üç sınıf olduğu kabul edilmektedir.

Eğitim aşamasında, sınıflar için seçilen tek bir örnek matristen öznitelik çıkarmak yerine, her sınıf için 10 ayrı noktadan örnek alınmıştır. Her örneğin öznitelik vektörü bulunduktan sonra, bu 10 vektörün ortalaması alınarak o sınıfı karakterize eden asıl öznitelik vektörü bulunmuştur. Öznitelik çıkarma için böyle bir yöntemin seçilmesinin nedeni, bölütleme işleminin doğruluğunu artırmaktır. Uzaktan algılama

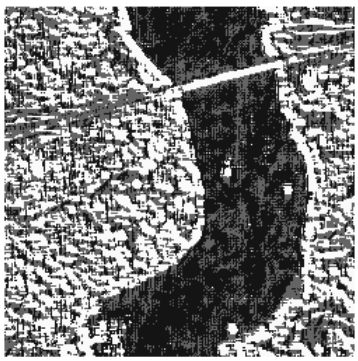
görüntüleri, doku görüntüsünden çok daha karmaşık görüntülerdir, çok hızlı değişimler içermektedirler. O yüzden, tek bir noktadan değil de birden fazla noktadan örnek alınması, bölütleme ve sınıflandırma performansını arttıracaktır.

Böyle bir görüntüde bölütleme ve sınıflandırma performansını arttırmak için bir başka yol da küçük pencerelerle çalışmaktır. Test aşamasında, hem yatay, hem de düşey yönde piksel-piksel kaydırılan pencerenin boyutları, kafes yapılar için 7x7 ve 9x9, ayrık dalgacık dönüşümü için ise 8x8'dir. 2-B dikgen kafes yapı için 2. ve 3. derecelerde işlem yapılmıştır. Kaydırılan pencerenin merkezindeki piksel için karar verilmiştir.

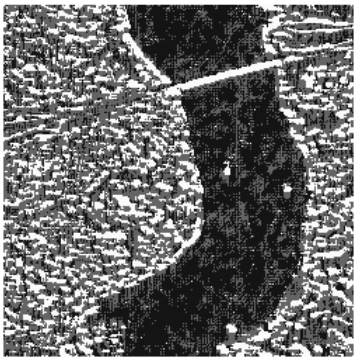
Bu görüntünün 7x7'lik pencereler kullanılarak bölütlenmesiyle elde edilen sonuçlar Şekil 3.17'de gösterilmiştir. Benzetim sonuçlarında siyah renk denizi, gri renk yeşillik alanı, beyaz renk yerleşim yerlerini göstermektedir.



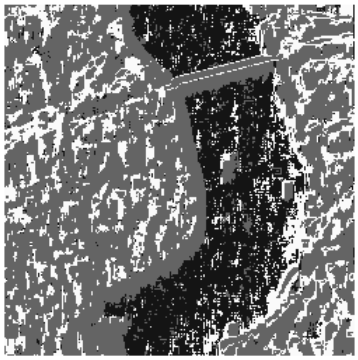
(a)



(b)



(c)



(d)



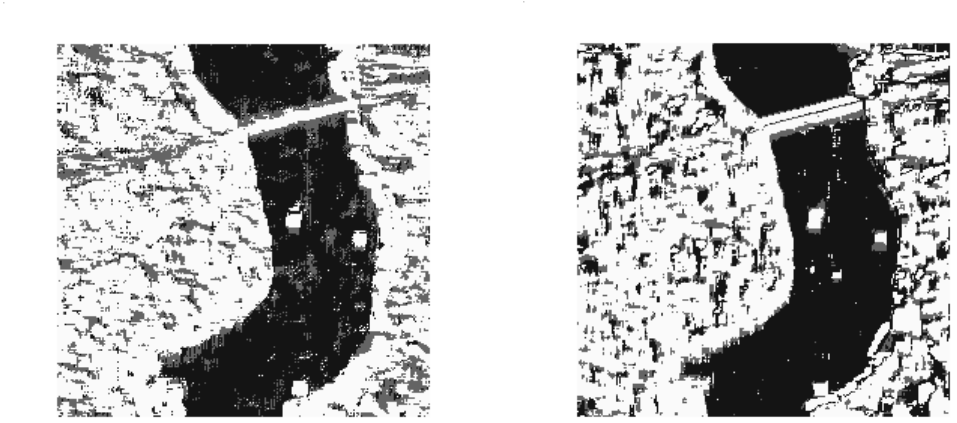
(e)

Şekil 3.17 Optik görüntü için 7x7 lik pencereyle piksel-piksel kaydırma sonuçları
(a) İncelenen optik görüntü
(b) 2-B dikgen kafes , 2.der., çeyrek d.
(c) 2-B dikgen kafes , 3.der., çeyrek d.
(d) 5 aşamalı 3 parametreli kafes
(e) 2 seviyeli ayrık dalgacık dönüşümü, 8x8'lik pencereyle

Şekil 3.17'nin sonuçlarına bakılınca, önerilen yöntem de dahil olmak üzere, uygulanan yöntemlerin hiç birinin optik görüntü için yeterince iyi sonuç

sağlayamadığı görülmektedir. Üç parametreli kafes yapısı, neredeyse tamamen yanlış sonuçlar vermiş, ayrık dalgacık dönüşümü, yeşil alanları genel olarak saptayabilirken, yerleşim yeri ile aynı özelliği gösterdiği düşünülerek sınıf örnekleri de buna göre seçilmiş olan köprüyü ve bağlantı yollarını da yeşil alan olarak sınıflamıştır. 2-B dikgen kafes yapısı ise, köprüyü ve kıyı şeridini doğru şekilde bölütleyip sınıflamış olsa da, deniz ve yeşil alanı birbirinden yeterli derecede ayıramamıştır. 2-B dikgen kafes yapıda derecenin arttırılması denizdeki hatalı pikselleri biraz azaltmış ancak bunun dışında ek bir performans sağlamamıştır. 2. derecenin üstündeki dereceler 7x7'lik pencerenin modellenmesi için fazladır.

Bir de kafes yapılarda hem eğitim, hem de test aşamasında, ayrık dalgacık dönüşümünde kullanılmış olan pencere boyutlarına yakın olması açısından, 9x9'luk pencereler denenmiş ve karşılaştırmalı sonucu Şekil 3.18'de verilmiştir.



(a) (b)

Şekil 3.18 Optik görüntü için kafes yapılarda 9x9' luk pencereyle piksel piksel kaydırma sonuçları
(a) 2-B dikgen kafes , 2.der., çeyrek d**.**
(b) 5 aşamalı 3 parametreli kafes

Şekil 3.18'de, pencere boyutları büyüdükçe, bölütleme başarımının da arttığı bir kez daha kanıtlanmıştır. Özellikle üç parametreli kafes yapıda olmak üzere her iki kafes yapıda, pencere boyutu arttırıldıkça, çok daha doğru sonuçlar elde edilmiştir. Ancak, yine de üç parametreli kafes yapıda kıyı şeridi önerilen yöntem kadar net bulunamamıştır. Ayrıca denizde olması gerekenden daha fazla kara parçası saptanmış, yerleşim yeri ve yeşillik alan olan bazı yerler de deniz olarak etiketlenmiştir. Önerilen yöntemde ise hala yeşillik alanların bulunmasında sorunlar

yaşanmaktadır. Şekil 3.17'de görülen ayrık dalgacık dönüşümünün sonucu ile karşılaştırıldığında, her iki kafes yapı da köprüyü daha doğru tespit etmişlerdir.

Bu görüntüde yeterli bir bölütleme performansı elde edilememiştir. Ancak bu karar verilirken, incelenen görüntünün tek bantlı olduğu ve sınıfların kesin bir bilgi olmadan, tahmini olarak tayin edildiği unutulmamalıdır. Çok bantlı(multispectral) görüntülerde, bazı bantlarda kimi sınıflar çok net olarak ayırt edilebilmektedir. Birden fazla spektral bandın bulunduğu durumlarda, elde edilen öznitelikler görüntüleri daha doğru niteleyebilmektedirler. Bizim durumumuzda olduğu gibi, tek bir bandın olduğu durumlarda, elde edilen özniteliklerin yeterli bilgiyi taşıyamaması doğal karşılanabilir. Görüntüden arazi bilgisi olmadan gözle sınıf tayini yapılarak örnekler alınıp, özniteliklerin bu örneklerden hesaplanması da bölütleme performansını düşürecektir. Sınıfları hakkında daha doğru bilgilere sahip olunan bir optik görüntüyle çalışılırsa daha başarılı sonuçlar elde edilebilir. Bunlar, ilerde yapılacak çalışmalar için bir araştırma alanı oluşturabilir.

4. SONUÇLAR

Bu tezde, 2-B dikgen kafes süzgeç yapılarına dayanan yeni bir görüntü bölütleme yöntemi sunulmuştur. Bu yöntem, görüntüden elde edilen bazı parametrelerle görüntünün modellenebildiği bir yöntemdir. Elde edilen model parametreleri, görüntünün bölütlenmesi ve sınıflandırılmasında kullanılmaktadır.

Önerilen yöntemin model parametreleri, görüntüden her aşamada elde edilen yansıma katsayılarıdır. Tezde, 2-B dikgen kafes yapılarında, öngörü destek bölgesinin oluşturulması için çeyrek düzlem modeli kullanılmıştır. Ayrıca, bu yapıların 1., 2. ve 3. dereceler için sonuçları da ayrı ayrı incelenmiştir.

Pek çok 2-B kafes süzgeç yapısı mevcuttur. Üç parametreli kafes süzgeçler bu yapıların en basitidir ve daha önce doku görüntülerinin bölütlenmesi ve sınıflandırılması için denenmiştir. Tezde, her aşamasında üç adet yansıma katsayısı oluşturulan bu yapı, beş aşama için uygulanmış ve sonuçları önerilen yöntemin sonuçları ile karşılaştırılmıştır.

Tezde, önerilen yöntemle karşılaştırılması için uygulanmış olan diğer bir yöntem ise ayrık dalgacık dönüşümüdür. 2 seviyeli, piramit-yapılı ayrık dalgacık dönüşümü ile görüntülerin öznitelik vektörleri elde edilmiş ve bölütleme işleminde kullanılmıştır.

Bu çalışmada, doku görüntüsü ve optik görüntü olmak üzere iki tip görüntü incelenmiştir. Doku görüntüleri, Brodatz albümünden seçilmiştir. Optik görüntü ise SPOT 4 uydusundan alınmış tek bantlı, siyah-beyaz bir uzaktan algılama görüntüsüdür.

Yapılan çalışmada, belli boyutlarda seçilen pencereler görüntü üzerinde kaydırılarak, her kaydırma için tezde sunulan yöntem ve bu yöntemle karşılaştırılan diğer yöntemlerle, o pencereye ait öznitelik vektörleri bulunmuştur. Ardından, bu öznitelik vektörleri daha

önce eğitim aşamasında hesaplanmış olan öznitelik vektörleriyle minimum uzaklık ölçümü kullanılarak karşılaştırılmış ve sınıf kararı verilmiştir. Tüm görüntü tarandığında da işlem sona ermiştir.

Diğer yöntemlerde olduğu gibi önerilen yöntemde de, uygulanan pencerelemeden dolayı, sınırlarda bölütleme ve sınıflandırma hataları görülmektedir. Pencereleme yöntemini kullanan algoritmalarda, bir piksel, etrafını çeviren bölgeye göre tanımlanır. Bu bölge, seçilen penceredir. Bu yüzden, farklı sınıfları ayıran sınırlarda bulunan piksellerde yapılan etiketlemeler yanlış sonuçlara yol açmaktadır.

Tezde önerilen yöntem, doku görüntülerinin bölütlenmesinde karşılaştırılan diğer iki yönteme göre beklendiği gibi çok daha iyi bir performans göstermiştir.

Ayrıca, doku görüntülerinde ayrık dalgacık dönüşümünün eğitim aşaması çok uzun sürmektedir. Optik görüntüde ise eğitim için sınıflar içinden seçilen pencereler küçük olduğundan böyle bir sorun yaşanmamıştır.

Optik görüntüde, önerilen yöntem, üç parametreli kafes süzgeç yapılardan daha iyi bölütleme yaparken, bazı yönlerden ayrık dalgacık dönüşümünün gerisine düşmektedir. Bunun nedeni, görüntünün tek bir spektral bandının bulunması ve sınıflar hakkında elde kesin bir bilgi olmamasından dolayı, sınıfları karakterize eden doğru özniteliklere ulaşılamamış olması olabilir.

Sonuç olarak, 2-B dikgen kafes yapıları, görüntü bölütleme işlemlerinde kullanılabilecek yapılardır. Görüntünün, sınır hatalarını ortadan kaldıracak bazı işlemlerden geçirildikten sonra kafes yapılarla bölütlenmesi daha iyi sonuç verecektir. Optik görüntülerde, daha başarılı sonuçlara ulaşılabilmesi için de çok bantlı ve kesin sınıf bilgileri olan görüntülerle çalışılması yerinde olacaktır. Ayrıca etiketleme, yani sınıflandırma adımında, minimum uzaklık ölçümü yerine yapay sinir ağlarının kullanılması denenebilir. Tüm bunlar ileride araştırma alanı yaratabilecek konulardır.

KAYNAKLAR

[1] **Pal, N.R. and Pal, S.K.,** 1993. A review on image segmentation techniques, *Pattern Recognition*, **26(9)**, 1277-1294.

[2] **Mao, J. and Jain, A.K.,** 1992. Texture classification and segmentation using multiresolution simultaneous autoregressive models, *Pattern Recognition*, **25(2)**, 173-188.

[3] **Bouman, C.A. and Shapiro, M.,** 1994. A multiscale random field model for Bayesian image segmentation, *IEEE Trans. on Image Processing*, **3**, 162-177.

[4] **Chen, P.C. and Pavlidis, T.,** 1983. Segmentation by texture using correlation, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, **5**, 64-69.

[5] **Manjunath, B. and Chellappa, R.,** 1991. Unsupervised texture segmentation using Markov random field models, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, **13**, 478-482

[6] **Derin, H. and Elliot, H.,** 1987. Modeling and segmentation of noisy and textured images using Gibbs random fields, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, **9(1)**, 39-55.

[7] **Dunn, D. and Higgins, W.E.,** 1995. Optimal Gabor filters for texture segmentation, *IEEE Trans. on Image Processing*, **4(7)**, 947-964.

[8] **Chumsamrong, W., Thitimajshina,P. and Rangsanseri, Y.,** 1999. Wavelet-based texture analysis for SAR image classification, *International Geoscience and Remote Sensing Symposium*, *3*, 1564-1566.

[9] **Gaohang, W., Yujin, Z. and Xinggang, L.,** 1999. Wavelet transform-based texture classification with feature weighting, *Proceedings of International Conference on Image Processing*, 24-28 September, **4** , 435 – 439.

[10] **Chang, T. and Kuo, C.C.J.,** 1993. Texture analysis and classification with tree-structured wavelet transform, *IEEE Trans. on Image Processing*, **2(4)**, 429-441.

[11] **Unser, M.,** 1995. Texture classification and segmentation using wavelet frames, *IEEE Trans. on Image Processing*, **4(11)**, 1549-1560.

[12] **Serdaş, B.,** 2000. Texture image segmentation and classification by using 2-D lattice filters, *MSc Thesis*, Boğaziçi University, İstanbul

[13] **Kayran, A.H.,** 1989. Design of 2-D recursive filters with asymmetric half-plane lattice modeling, *Proc. Inst. Elect. Eng. G.*, **137**, 427-438.

[14] **Therrien, C.W. and El-Shaer, H.T.,** 1989. Multichannel 2-D AR spectrum estimates, *IEEE Trans. Acoust., Speech, Signal Processing*, **37**, 1798-1800

[15] **Therrien, C.W. and El-Shaer, H.T.,** 1989. A direct algorithm for computing 2-D power spectrum estimates, *IEEE Trans. Acoust., Speech, Signal Processing*, **37**, 1795-1798.

[16] **Nakachi,T., Yamashita, K. and Hamada, N.,** 1996. A two-dimensional adaptive joint-process estimator using new lattice form, *Proc. IEEE Int. Symp. Circuits .Syst.*, Atlanta, GA, May 1996, 33-36.

[17] **Kayran, A.H.,** 1996. 2-D maximum likelihood spectrum estimation using orthogonal 2-D lattice filters, *Electron. Lett.* , **32**, 1339-1340.

[18] **Kwan, H.K. and Lui, Y.C.,** 1989. Lattice predictive modeling of 3-D random fields with application to interframe predictive coding of picture sequences, *Int. J. Electron.*, **66**, 489-505

[19] **Kwan, H.K.,** 1985. 2-D lattice modeling for image data compression, *Proc. IEEE Int. Symp. Circuits .Syst.*, Kyoto, Japan, 1105-1106.

[20] **Kwan, H.K. and Lui,Y.C.,** Image data compression using lattice modeling method, *Symp. Dig. Fifth Kobe Int. Elect. Inform. Sciences*, Kobe, Japan

[21] **Nam, M.N. and O'Neill, W.D.,** 1987. Adaptive linear predictive coding of time-varying images using multidimensional recursive least squares ladder filters, *IEEE J. Select. Areas Commun.*, **5**, 1115-1126

[22] **Youlal, H., Janati-1, M. and Najim, M.,** 1992. Two-dimensional joint process lattice adaptive restoration of images, *IEEE Trans. on Image Processing*, **1**, 366-378.

[23] **Hendekli, C.M. and Ertüzün, A.,** 2001. Design of multichannel two-dimensional delta-domain lattice filter for noise removal, *IEEE Trans. on Signal Processing*, **49**, 1581-1593.

[24] **Erer, I., Kartal, M. and Kayran, A.H.,** 2001. 2-D data extrapolation for high resolution radar imaging using autoregressive lattice modeling, P*roc. Inst. Elect. Eng. Radar, Sonar, Navigation*, **148(5)**, 277-283.

[25] **Erer, I. and Kayran, A.H.,** 2002. Superresolution ISAR imaging using 2-D autoregressive lattice filters, *Microwave Opt. Technol. Lett.*, **32(1)**, 81-85.

[26] **French, P.A., Zeidler, J.R. and Ku, W.H.,** 1997. Enhanced detectability of small objects in correlated clutter using an improved 2-D adaptive lattice algorithm, *IEEE Trans. on Image Processing*, **6**, 383-397.

[27] **Gonzalez, R.C. and Woods, R.E.,** 1993. Digital Image Processing, Addison-Wesley.

[28] **Schumacher, P. and Zhang, J.,** 1994. Texture classification using neural networks and discrete wavelet transform, *Proceedings IEEE International Conference on Image Processing*, 3 , 13-16 November , 903 – 907.

[29] **Kayran, A.H.**, 1996. Two dimensional orthogonal lattice structures for autoregressive modeling of random fields, *IEEE Trans. on Signal Processing*, **44(4)**, 963-978.

[30] **Marzetta, T.L.,** 1980. Two-dimensional linear prediction: Autocorrelation arrays, minimum phase prediction error filters, and reflection coefficient arrays, *IEEE Trans. on Acoust., Speech, Signal Processing*, **32**, 725-733.

[31] **Parker, S.R. and Kayran, A.H.,** 1984. Lattice parameter autoregressive modeling of 2-D fields, Part I: The quarter - plane case, *IEEE Trans. on Acoust., Speech, Signal Processing*, **32**, 872-885.

[32] **Parker, S.R., Kayran, A.H. and Dokanakolu, E.,** 1985. Asymmetric half plane autoregressive modeling of 2-d fields using lattice structures, *Proc. Int. Symp. on Circuits and Systems*, **85**, 1101-1104.

[33] **Ertüzün, A.,** 1989. Modelling of autoregressive fields by two-dimensional lattice filters and their entropy properties, *PhD Thesis*, Boğaziçi University, İstanbul

[34] **Ertüzün, A.,** 1995. A survey of 2-D lattice filter structures, *TÜBİTAK Elektrik Dergisi*, **3(1)**

[35] **Haykin, S.,** 1986. Adaptive Filter Theory, Englewood Cliffs: New Jersey, Prentice-Hall.

[36] **Ertüzün, A., Kayran, A.H. and Panayırcı, E.,** l990. A new 2d causal lattice filter and its entropy relations to model AR fields, *Bulletin of Technical University of İstanbul*, **43(1)**, 23-56.

[37] **Bose, N.K.,** 1990. Multidimensional digital signal processing: Problem, progress, and future scopes, Proc. IEEE, **78**, 590-597.

[38] **Ayaz, E.,** 1997. Dalgacıklar ve elektrik mühendisliğindeki uygulamaları, *Yüksek Lisans Tezi*, İTÜ Fen Bilimleri Enst., İstanbul

[39] **Lu, S.W. and Xu, H.,** 1995. Textured image segmentation using autoregressive model and artificial neural network, *Pattern Recognition*, **28(12)**, 1807-1817.

[40] **Stolpmann, A. and Dooley, L.S.,** 1998. Genetic algorithms for automised feature selection in a texture classification system, *Proceedings of International Conference on Signal Processing*, **2**, 12-16 September, 1229-1232

[41] **Brodatz, P.,** 1966. Textures-a Photographic Album for Artists and Designers, Dover, New York.

[42] **Cubero-Castan, E., Pons, J. and Zerubia, J.,** 1995. Evaluation on SPOT data of classification algorithms based on Markovian modelization, *International Geoscience and Remote Sensing Symposium*, 'Quantitative Remote Sensing for Science and Applications', **1** , 10-14 July
115 – 117.

[43] **Demin Wang, Dong-Chen He and Morin, D.,** 1994. Classification of remotely sensed images using mathematical morphology, *International Geoscience and Remote Sensing Symposium*, 'Surface and Atmospheric Remote Sensing: Technologies, Data Analysis and Interpretation'., **3** , 8-12 August, 1615 – 1617.

[44] http:// www.spot.com

[45] **Cakir, H.J., Khorram, S., Dai, X.L. and de Fraipont, P.,** 1999. Merging SPOT XS and SAR imagery using the wavelet transform method to improve classification accuracy, *Proceedings IEEE International Geoscience and Remote Sensing Symposium*, **1**, 28 June-2 July, 71 – 73.

[46] **Barbarossa, S. and Parodi, L.,** 1995. SAR Image Classification by Wavelets , *Record of the IEEE 1995 International Radar Conference*, 8-11 May, 462-467.

ÖZGEÇMİŞ

Saide Zeynep Aykut, 1979 yılında İstanbul'da doğmuştur. İlk, orta ve lise öğrenimlerini İstanbul'da sırasıyla, Hamdi Akverdi İlkokulu ve Özel Sankt Georg Avusturya Lisesi'nde tamamlamıştır. Lisans eğitimini 1998-2002 yılları arasında Yıldız Teknik Üniversitesi, Elektronik ve Haberleşme Mühendisliği bölümünde yapmış, 2002 yılında İstanbul Teknik Üniversitesi Telekomünikasyon Mühendisliği programında yüksek lisansına başlamıştır.