

**BAŐKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DALGACIK TABANLI DÖNÜŐÜMLER KULLANARAK
SAYISAL İMGELERDE ADLİ KANIT TOPLAMA**

LEVENT ÖZPARLAK

DOKTORA TEZİ

2011

**DALGACIK TABANLI DÖNÜŞÜMLER KULLANARAK
SAYISAL İMGELERDE ADLİ KANIT TOPLAMA**

**DIGITAL IMAGE FORENSICS BY USING WAVELET
BASED TRANSFORMS**

LEVENT ÖZPARLAK

Başkent Üniversitesi
Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin
ELEKTRİK-ELEKTRONİK Mühendisliği Anabilim Dalı İçin Öngördüğü
DOKTORA TEZİ
olarak hazırlanmıştır.

2011

“Dalgacık Tabanlı Dönüşümler Kullanarak Sayısal İmgelerde Adli Kanıt Toplama” başlıklı bu çalışma, jürimiz tarafından, 30/12/2011 tarihinde, **ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI 'nda DOKTORA TEZİ** olarak kabul edilmiştir.

Başkan :
Prof. Dr. M. Emin AKATA

Üye (Danışman) :
Doç. Dr. İsmail AVCIBAŞ

Üye :
Doç. Dr. Hasan OĞUL

Üye :
Yrd. Doç. Dr. Mustafa DOĞAN

Üye :
Yrd. Doç. Dr. Hüsrev Taha SENCAR

ONAY

...../...../.....

Prof. Dr. Emin AKATA
Fen Bilimleri Enstitüsü Müdürü

TEŐEKKÜR

Yazar, bu alıőmanın gerekleőmesinde katkılarından dolayı, aőađıda adı geen kiői ve kuruluőlara itenlikle teőekkür eder.

Sayın Do. Dr. İsmail AVCIBAŐ'a (tez danıőmanı), alıőmanın sonuca ulaőtırılmasında ve karőtılaőtılan glklerin aőtılmasında her zaman yardımcı ve yol gsterici olduđu iin...

Sayın Prof. Dr. Emin AKATA ve Do. Dr. Hasan OĐUL'a, tez izleme srecindeki ynlendirmeleri ve destekleri iin...

Sayın Evren F. EMEKDAŐ, Kerem YILDIZ, Kadir Nuri TEKİN, Ayten ERYILMAZ ve Okan ÖZLER'e, tez alıőmasının yapıldıđı sre ierisindeki moral destekleri iin...

ÖZ

**DALGACIK TABANLI DÖNÜŞÜMLER KULLANARAK
SAYISAL İMGELERDE ADLİ KANIT TOPLAMA**

Levent ÖZPARLAK

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Bu tezde, dalgacık tabanlı dönüşümler için istatistiksel modeller önerilmiş, sayısal imgelerde adli kanıt toplama açısından göreceli faydaları ve kullanımları incelenmiştir. İlgilendiğimiz problemler: 1) bilgisayar grafiği tabanlı imgeler ile fotoğraflık imgelerin ayrıştırılması, 2) kaynak kamera ve kaynak tarayıcı belirleme, 3) sayısal tablo örneklerinden kaynak ressam belirleme, 4) stego-imgeler ve 5) farklı çözünürlükteki imgelerin ayrıştırılmasıdır. Eldeki problemler düşünüldüğünde, ridgelet ve contourlet dönüşümü tabanlı imge modellerinden elde edilen öznitelikler, dalgacık tabanlı imge modelinden elde edilen özniteliklerden neredeyse her zaman daha başarılı olmaktadır. Etkin bir imge gösteriminin özelliklerinin anahatlarını çizerek bu özellikleri dalgacık tabanlı dönüşümlerle ilişkilendiriyoruz ve deneysel sonuçları model özellikleri ile ilişkilendirerek tartışıyoruz.

ANAHTAR SÖZCÜKLER: sınıflandırma, adli kanıt toplama, dalgacık tabanlı dönüşüm, istatistiksel modelleme.

Danışman: Doç.Dr. İsmail AVCIBAŞ, Turgut Özal Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü.

ABSTRACT

DIGITAL IMAGE FORENSICS BY USING WAVELET BASED TRANSFORMS

Levent ÖZPARLAK

Başkent University Institute of Science

Department of Electrical-Electronics Engineering

We propose statistical image models for wavelet based transforms, investigate their use, and compare their relative merits within the context of digital image forensics. We consider the problems of 1) differentiating computer graphics images from photographic images, 2) source camera and source scanner identification, 3) source artist identification from digital painting samples, 4) stego-images, and 5) differentiation by different resolution images. The features obtained from ridgelet and contourlet transform-based image models almost always perform better than the features obtained from wavelet-based image models for the problems at hand. We outline properties of efficient image representation, relate these properties to wavelet-based transforms, and discuss the experimental results in relation to the model properties.

KEYWORDS: classification, digital forensics, wavelet based transforms, statistical modelling.

Supervisor: Assoc. Prof. İsmail AVCIBAŞ, Turgut Özal University, Dept. Of Electrical-Electronics Engineering.

İÇİNDEKİLER LİSTESİ

	<u>Sayfa</u>
ÖZ	i
ABSTRACT	ii
İÇİNDEKİLER LİSTESİ	iii
ŞEKİLLER LİSTESİ	v
ÇİZELGELER LİSTESİ	vii
ALGORİTMALAR LİSTESİ	ix
SİMGELER VE KISALTMALAR LİSTESİ	x
1 GİRİŞ	1
1.1 Çalışmanın Konusu	1
1.2 Çalışmanın Amacı ve Önemi	4
1.3 Çalışmanın İçeriği	4
1.4 Daha Önce Yapılan Çalışmalar	5
1.5 Tezin Organizasyonu	12
2 DALGACIK TABANLI DÖNÜŞÜMLER	13
2.1 Ridgelet Dönüşümü	13
2.1.1 Sürekli ridgelet dönüşümü	14
2.1.2 Sonlu radon dönüşümü	16
2.2 Contourlet Dönüşümü	17
2.2.1 Temel tanımlar	19
2.2.2 Yapı	21
3 İSTATİSTİKSEL MODEL	24
3.1 Dalgacık Dönüşümü	27
3.2 Contourlet Dönüşümü	29
3.2.1 Contourlet katsayıları arası ilintilerin belirlenmesi	32
3.3 Ridgelet Dönüşümü	38
3.3.1 Ridgelet katsayıları için ilintilerin belirlenmesi	40
3.4 Öznitelik Çıkarımı	43
4 DENEYSEL SONUÇLAR	45
4.1 Veri Kümeleri	45
4.1.1 Fotogerçekçi ve fotoğrafik imge veri kümesi (CG-N)	45
4.1.2 İçine veri gizlenmiş imgeler veri kümesi (Stego)	45

	<u>Sayfa</u>
4.1.3 Farklı dijital kameralar için imge veri kümesi (Cam)	46
4.1.4 Farklı tarayıcılar için imge veri kümesi (Scanner).....	46
4.1.5 Ünlü ressamlar için imge veri kümesi (Paint1).....	47
4.1.6 Ressamlar için imge veri kümesi (Paint2).....	47
4.1.7 Farklı çözünürlüklü imgeler için imge veri kümesi (Resolution)	47
4.2 Dalgacık Tabanlı Dönüşümlerin Kullanımı.....	47
4.3 Bilgisayar Grafiği İmgelere Karşı Doğal İmgeler	48
4.4 Steganaliz.....	50
4.5 İmge Hangi Kaynaktan Gelmiştir?	54
4.6 Ressam Kim?	58
4.7 Çözünürlük Ne Fark Ettirir?	64
5 SONUÇ VE TARTIŞMA	66
KAYNAKLAR LİSTESİ	69
EK A TEMEL BİLGİLER.....	80
A.a Yüksek Dereceli İstatistikler (YDİ).....	81
A.b Destek Vektör Makineleri (DVM).....	83
A.b.i Matematiksel temeller	83
A.c Ardışık İleri Seyyar Arama (AİSA).....	84
A.d Kaynak Olarak Belirlenecek Cihazların ve Programların Çalışma	
Prensipileri	88
A.d.i Dijital kameralar nasıl çalışır	88
A.d.ii Tarayıcılar nasıl çalışır	98
A.d.iii Bilgisayar grafiği imgeler nasıl elde edilir.....	99
A.d.iii.1 <u>Statik imgeler ve yeryüzü görüntüleri</u>	99
A.d.iii.2 <u>Mimari görüntüler</u>	100
A.d.iii.3 <u>Anatomik modeller</u>	101
A.d.iii.4 <u>Kaplama</u>	101
A.d.iii.5 <u>Işın izleme</u>	102
A.d.iii.6 <u>Gölgelendirme</u>	102
A.d.iii.7 <u>Doku haritalama</u>	103
A.d.iii.8 <u>Örtüşme önleyici (Anti-aliasing)</u>	103
A.d.iii.9 <u>Hacim kaplama</u>	104

ŞEKİLLER LİSTESİ

	<u>Sayfa</u>
Şekil 2.1 – Dönüşümler arası ilişkiler.....	15
Şekil 2.2 – (a) Dalgacık dönüşümü modeli (b) Yeni model.....	19
Şekil 2.3 – Contourlet filtre bankası.....	20
Şekil 2.4 –Laplacian piramidi.....	22
Şekil 2.5 –Yönlü filtre bankası.....	22
Şekil 3.1 – (a) Boat imgesi, (b) Barbara imgesi, (c) Lena imgesi için Dalgacık, Ridgelet ve Contourlet dönüşümlerindeki normalize edilmiş ... katsayıların histogramı	25
Şekil 3.2 – (a) Noktasal imge, (b) Çapraz imge, (c) Daire imge.....	26
Şekil 3.3 – (a) Noktasal imge, (b) Çapraz imge, (c) Daire imge için dalgacık..... dönüşümü katsayıları	26
Şekil 3.4 – (a) Noktasal imge, (b) Çapraz imge, (c) Daire imge için ridgelet..... dönüşümü katsayıları(log uzayında).....	27
Şekil 3.5 – (a) Noktasal imge, (b) Çapraz imge, (c) Daire imge için contourlet..... dönüşümü katsayıları	28
Şekil 3.6 – Şekil 4.2(a)'daki noktasal kaynak için en iyi banttaki yatay..... contourlet altbantları	29
Şekil 3.7 – Dalgacık dönüşümü veri yapısı.....	29
Şekil 3.8 – Contourlet dönüşümü veri yapısı	30
Şekil 3.9 – Bir bant seviyesi farkı için indisleme	30
Şekil 3.10 – En iyi banttaki birinci kırmızı alt-bant kırmızı renk kanalı için..... özilinti katsayıları	33
Şekil 3.11 – İlinti verisine yakından bir bakış.....	33
Şekil 3.12 – Contourlet dönüşümüne dayalı yöntem için alt-bant içi arama	34
Şekil 3.13 – Contourlet dönüşümüne dayalı yöntem için bütün 9x9	35
komşular eklendiğinde ilinti gelişimi.....	35
Şekil 3.14 – Arama sonuçlarına bağlı ilişki haritası	36
Şekil 3.15 – Arama sonuçları boyunca elde edilen katsayılar için ilinti	37
katsayısı gelişimi	37
Şekil 3.16 – Ridgelet dönüşümü veri yapısı	39
Şekil 3.17 – En iyi bant kırmızı kanal için, iki boyutlu özilinti fonksiyonu	41

	<u>Sayfa</u>
Şekil 3.18 – En iyi bant kırmızı renk kanalı için bant ilişki haritası	41
Şekil 3.19 – En iyi bant kırmızı renk kanalı için ilintideki gelişim.....	42
Şekil 4.1 – CG-N veri kümesinde kullanılan imgelere örnekler	46
Şekil 4.2 – Fotogerçekçi ve fotoğrafik imgeler için bütün öznitelikler üzerinden	
ROC eğrileri.....	51
Şekil 4.3 – Fotogerçekçi ve fotoğrafik imgeler için en iyi 20 öznitelik üzerinden.....	
ROC eğrileri.....	51
Şekil A.1 – Çalışmanın algoritmik şeması	80
Şekil A.2 – İki gruba ait öznitelik kümeleri ve iki sınıflandırma çözümü	82
Şekil A.3 – Doğrusal olmayan DVM için bir durum gösterimi	85
Şekil A.4 – Uzaysal örnekleme ve pikseller	90
Şekil A.5 – Bayer renk süzgeç dizisi.....	93
Şekil A.6 – Çeşitli RSD türleri	93
Şekil A.7 – Koma	94
Şekil A.8 – Kavisli alan	94
Şekil A.9 – Boylamsal kromatik aberasyon	94
Şekil A.10 – Yanal kromatik aberasyon.....	95
Şekil A.11 – Küresel aberasyon	95
Şekil A.12 – Çarpıtma	96
Şekil A.13 – Parlama	97
Şekil A.14 – Hayalet imgeler	97
Şekil A.15 – Fraktal olarak elde edilmiş bir yeryüzü görüntüsü	100
Şekil A.16 – Sierpinski üçgenleri	100
Şekil A.17 – Bir binanın BG ile elde edilmiş çevre görüntüsü	101
Şekil A.18 – Gölgelelendirmeye bir örnek	103
Şekil A.19 – Hacim kaplamaya bir örnek.....	103

ÇİZELGELER LİSTESİ

Sayfa

Çizelge 3.1 – Bir contourlet katsayısı ile komşuları arasındaki ilinti katsayıları	31
Çizelge 3.2 – Renk kanalları arasındaki ilinti değerleri	36
Çizelge 3.3 – Renk kanalları arasındaki ilinti değerleri (Contourlet dönüşümü).....	40
Çizelge 4.1 – Fotogerçekçi ve fotoğrafik imgeler için ASA kullanmadan Dalgacık, .. Ridgelet ve Contourlet dönüşümleri kullanılarak yapılan	49
Çizelge 4.2 – Fotogerçekçi ve fotoğrafik imgeler için ASA kullanılarak Dalgacık, Ridgelet ve Contourlet dönüşümleri kullanılarak yapılan	49
Çizelge 4.3 – <i>CG-N</i> veri kümesi için her üç dönüşüm için seçilen en iyi ilk	52
Çizelge 4.4 – <i>Stego</i> veri kümesi için Outguess-, Outguess+, F5 ve LSB veri	53
Çizelge 4.5 – <i>Stego</i> veri kümesi için Outguess-, Outguess+, F5 ve LSB veri	53
Çizelge 4.6 – <i>Stego</i> veri kümesi için PQ veri gizleme algoritmasındaki Dalgacık, Ridgelet ve Contourlet dönüşümlerinin sınıflandırma sonuçları (Tüm . öznitelikler)	53
Çizelge 4.7 – <i>Stego</i> veri kümesi için PQ veri gizleme algoritmasındaki Dalgacık, Ridgelet ve Contourlet dönüşümlerinin sınıflandırma sonuçları (En iyi 20 öznitelik)	55
Çizelge 4.8 – <i>Cam</i> veri kümesi için dalgacık tabanlı sınıflandırma sonuçları	55
Çizelge 4.9 – <i>Cam</i> veri kümesi için dalgacık tabanlı sınıflandırma sonuçları	55
Çizelge 4.10 – <i>Cam</i> veri kümesi için her üç dönüşüm için seçilen en iyi ilk.....	56
Çizelge 4.11 – <i>Scanner</i> veri kümesi için Dalgacık, Ridgelet ve Contourlet	57

Çizelge 4.12 – <i>Scanner</i> veri kümesi için Dalgacık, Ridgelet ve Contourlet	
dönüşümlerinin sınıflandırma sonuçları (En iyi 20 öznitelik)	58
Çizelge 4.13 – <i>Scanner</i> veri kümesi için her üç dönüşüm için seçilen en iyi ilk	
20 öznitelikler.....	59
Çizelge 4.14 – <i>Paint1</i> veri kümesi için Dalgacık, Ridgelet ve Contourlet.....	
dönüşümlerinin sınıflandırma sonuçları (Tüm öznitelikler).....	60
Çizelge 4.15 – <i>Paint1</i> veri kümesi için Dalgacık, Ridgelet ve Contourlet.....	
dönüşümlerinin sınıflandırma sonuçları (En iyi 20 öznitelik)	60
Çizelge 4.16 – <i>Paint1</i> veri kümesi için her üç dönüşüm için seçilen en iyi ilk	
20 öznitelikler.....	61
Çizelge 4.17 – <i>Paint2</i> veri kümesi için Dalgacık, Ridgelet ve Contourlet.....	
dönüşümlerinin sınıflandırma sonuçları (Tüm öznitelikler).....	62
Çizelge 4.18 – <i>Paint2</i> veri kümesi için Dalgacık, Ridgelet ve Contourlet.....	
dönüşümlerinin sınıflandırma sonuçları (En iyi 20 öznitelik)	62
Çizelge 4.19 – <i>Paint2</i> veri kümesi için her üç dönüşüm için seçilen en iyi ilk	
20 öznitelikler.....	63
Çizelge 4.20 – <i>Resolution</i> veri kümesi için Dalgacık, Ridgelet ve Contourlet.....	
dönüşümlerinin sınıflandırma sonuçları (En iyi 20 öznitelik)	64
Çizelge 5.1 – Hem ressam hem de kaynak belirleme için ASA kullanılarak elde	
edilen sınıflandırma sonuçları.....	68

ALGORİTMALAR LİSTESİ

Sayfa

Algoritma 1 – AİSA Algoritması87

SİMGELER VE KISALTMALAR LİSTESİ

CSI:NY	Crime Scene Investigation (Suç Mahalli Araştırma):New York
NCIS	Deniz Kuvvetleri Suç İnceleme Birimi
BG	Bilgisayar Grafiği
JPEG	Birleşik Fotoğraf Uzmanları Grubu
DCT	Ayrık Kosinüs Dönüşümü
DVM	Destek Vektör Makineleri
CCD	Yüklenme İliştirilmiş Araç
CMOS	Bütünleyici Metal Oksit Yarıiletken
CFA	Renk Süzgeç Dizisi
YDİ	Yüksek Dereceli İstatistikler
AİA	Ardışık İleri Arama
AGA	Ardışık Geri Arama
AİSA	Ardışık İleri Seyyar Arama
AGSA	Ardışık Geri Seyyar Arama
DSLR	Dijital Tek Mercek Yansımali Kamera
ASB	Analogdan-Sayısala Birim
DS	Dijital Sayı
RGB	Kırmızı-Yeşil-Mavi Renk Kanalları
CIS	Kontakt İmge Sensörü
GPU	Grafik İşleme Ünitesi
BT	Bilgisayarlı Tomografi
MRG	Manyetik Rezonans Görüntüleme
SRD	Sürekli Ridgelet Dönüşümü
SDD	Sürekli Dalgacık Dönüşümü
SRAD	Sonlu Radon Dönüşümü
YFB	Yönlü Filtre Bankası
LP	Laplacian Piramidi
MP	Mega Piksel
PQ	Değişikliğe Uğratılmış Nicemleme
QMF	Dördül Ayna Süzgeçleri
ROC	Alıcı İşletim Karakteristiği
ASA	Ardışık Seyyar Arama ya da Ardışık İleri Seyyar Arama

1. GİRİŞ

Suç insanlığın varoluşundan beri süregetirdiği bir eylemdir. Suçun gelişimi binlerce yıla yayılırken buna karşı olarak da suçun kanıtlanması süreci kendi içinde bir gelişime uğramıştır. Başlangıçta adi suçlar (cinayet, hırsızlık, v.b.) şeklinde kendini gösteren suç tarihi teknolojinin gelişmesiyle, özellikle de Endüstri Devrimi sonrası, daha incelikli suçlar olarak tezahür etmiştir. Ayrıca, adi suçların işlenme şekilleri de daha dikkatli planlanmış ve suçluyu suçtan temiz çıkarmaya yönelik bir hal almıştır. Cinayet gibi adi suçların işlenme şekillerindeki bu gelişmeler ve sanat sahteciliği, dolandırıcılık gibi daha incelikli suçların faillerinin kendilerini daha ustaca saklayabiliyor hale gelmeleri sivil güçlerin bu tür suçlarda aralara gizlenmiş kanıtları bulmaları için timler oluşturmalarına neden olmuştur. Günümüzde Kriminoloji (suç bilimi) altında gelişen yöntemler zamanla olgunlaşarak Adli Kanıt Toplama adını verdiğimiz yöntemlere dönüşmüştür.

Bu yöntemlerin popülerliği günümüzde televizyon ekranlarında gördüğümüz ünlü dizilerle de (CSI:NY, CSI:Miami, NCIS v.b.) kendisini göstermektedir. Bu dizilerde ortaya konulan teknolojilerle çözülen suç sahnelerinin pek çoğu birer kurgu olmaktan ileri gidememektedir. Gerçekte, bu tür çok ince kanıtlara dayalı suç davalarının çoğu sonuçsuz kalmakta ve bu tür yüksek teknolojilere her suç davasında daha çok ihtiyaç duyulmaktadır. Günümüzde, suç sadece suç mahalinde incelenmemekte, laboratuvar ortamında da pek çok verinin elde edilmesi mümkün olmaktadır (örn. Cinayet davalarında otopsi verilerinin elde edilmesi, silahlı yaralama ve öldürme davalarında balistik sonuçlarının incelenmesi).

1.1. Çalışmanın Konusu

Bilgisayar ve görüntüleme teknolojilerindeki gelişmeler sayısal ortamdaki verilerin incelenmesini de zorunlu kılmıştır. 1800'lerin sonlarında fotoğraf teknolojisinin ilk ortaya çıkışı ile görsel medya insan hayatına girmiştir. Özellikle, gazetecilik alanında büyük ilgi uyandıran fotoğrafçılık birçok getirisinin yanında pek çok sahteciliğe de neden olmuştur. Fotoğraflar üzerinde değişiklikler yapılması, fotoğrafın çekildiği sahnede olmayan nesnelere fotoğraf içine eklenmesi

(fotomontaj) gibi yöntemler gelişmiş ve bu yöntemler hem iyi hem de kötü amaçlar için kullanılmıştır. Günümüzde bile hala paparazzilerin çektikleri resimlerde insanların kafalarını başka vücutlara monte etmesi sonucu elde ettikleri sansasyonel resimler dergilerin kapak sayfalarını doldurmaktadır.

1960'larda gelişmeye başlayan bilgisayar teknolojilerinin 1990'ların ilk yarısında ivmelenmesi ile pek çok yeni sahtecilik yöntemi ortaya çıkmıştır. Özellikle, bilgisayar kaplama yazılımlarının gelişmesi gerçekte var olmayan imgelerin fotoğrafların içine eklenmesini sağlamış, dijital kayıt ortamları (video kameralar, dijital kameralar, tarayıcılar, v.b.) fotoğrafların bilgisayar ortamına taşınmasını mümkün kılmış ve fotoğrafların rahatlıkla değiştirilmesi daha da kolay bir hal almıştır.

İnternetin gelişimi ile sayısal veriler kolayca bir yerden bir yere taşınmaya başlamış ve bu da pek çok suç eyleminin göz önünde olmadan yapılmasını sağlamıştır (örn. terörist eylem planlarının iletilmesi, casusluk verilerinin elde edilmesi ve iletilmesi). Bu tür suçlarla mücadele edebilmek için, emniyet kurumları sayısal veriler üzerinde adli kanıt toplayabilecek birimler oluşturmuştur. Bu birimlere yardımcı olabilecek teknolojilere ve bu teknolojileri üretmek için yapılan araştırmalara Sayısal Adli Kanıt Toplama adı verilmektedir. Sayısal Adli Kanıt Toplama tekniklerinin uygulanmasının bazı nedenleri şu şekilde sıralanabilir:

- Adli dosyalarda, Sayısal Adli Kanıt Toplama teknikleri sıkça davalıya veya davacıya ait olan bilgisayar sistemlerini analiz etmekte,
- Yazılım veya donanım hatalarının olduğu durumlarda verinin kurtarılmasında,
- Bir bilgisayar sistemine bir giriş olduktan sonra, örneğin, saldırganın nasıl giriş yolu bulduğu ve saldırganın içeride ne yaptığını bulmakta,
- Bir kuruluşun içerisinde kendisine zarar verdiği şüphelendiği bir çalışanı hakkında delil toplamasında,
- Tersine mühendislik ve performans en iyilemesi gibi amaçlara yönelik bir bilgisayar sisteminin nasıl çalıştığı hakkında bilgi edinmekte kullanılır.

Bu çalışmada Sayısal Adli Kanıt Toplama'nın özel bir kolu olan Sayısal İmgelerde Adli Kanıt Toplama yöntemleri üzerinde çalışılmıştır. Sayısal imgeler üzerinde

yapılan adli kanıt toplama çalışmaları içinden aşağıdaki problemler üzerinde çalışılmıştır:

1. Kaynak Belirleme: Farklı sayısal kaynaklardan gelen imgelerin kaynaklarının belirlenmesi, ya da bir suç mahalinde bulunan dijital kayıtlar içerisindeki imgelerin elde edilen bir dijital fotoğraf makinasından elde edilip edilmediğini doğrulanması kimi suç davaları için önemli kanıtlar sunabilmektedir. Bu nedenle, imgenin kaynağının belirlenmesi önemli bir kanıt yerine geçmektedir.
2. Bilgisayar Tabanlı İmgelerin Ayırıştırılması: Günümüzde, bilgisayar ortamında türetilmiş imgeler, özellikle bilgisayar tabanlı kaplama yazılımlarının gelişimi ile, neredeyse gerçek imgelerden ayrılamaz hale gelmiştir. Bir imgenin veya imgenin bir parçasının bilgisayar tabanlı olarak elde edilip edilmediğinin belirlenmesi ilgilenilmesi gereken bir başka önemli problemdir.
3. Steganaliz: Gizli haberleşme amacı ile bilginin bir imge içerisinde gizlenmesi günümüzde sıkça rastlanır bir durum haline gelmiştir. Bu tür durumlarda imge içerisinde gizlenmiş ve imgeyle ilintisiz verinin belirlenmesi sadece adli kanıt alanında değil şirketlerin kendi içlerindeki gizliliklerini korumalarında da önemli bir uygulamadır.
4. Ressam belirleme: Sanat alanında çok tartışılan konulardan birisi de gerçek olarak değerlendirilen ve altında onu yaptığı düşünülen ressamın imzalarının bulunduğu tabloların gerçekten de ressama ait olup olmadığıdır. Leonardo Da Vinci gibi bazı ressamın çıraklarına yaptırdıkları ve kendi tarzlarına çok yakın bazı tabloların altına imza attıkları bilinmektedir. Bu durumun belirlenmesi konusunda bugüne kadar bilinen hiç bir metodik çalışma yoktur. Bu tür durumların belirlenmesinde daha çok uzmanların fikirlerine başvurulmaktadır. Fakat, bir ressamın çırağı da ressamın tarzına çok yakın ürünler verdiği için, bazen uzmanlar bile bu konuda emin olamamakta ve yanlış kararlar verebilmektedir.
5. İmge üzerinde yapılan değişiklikleri belirleme: Günümüzde karşılaşılan en büyük sorunlardan birisi imgenin kaynağından çıktığı gibi tam olup olmadığı sorusudur. Photoshop gibi imge değiştirme programları ile gözle ayrılamayan değişikliklerin imge üzerine uygulanması sıkça karşılaşılan bir durumdur. Bu tür değişikliklerin imge üzerinde yapılıp yapılmadığının bulunması ve hatta imge içerisinde nerede yapıldığının bulunması ilgilenilmesi gereken bir başka çalışmadır.

6. Sanat sahteciliğini belirleme: Ressam belirlemeye benzer bir şekilde ressamlar arasında ayırım yapmak yerine bir ressamın eserlerinin arasından ressama ait olmayan sahte eserleri belirlemek de önem verilmesi gereken bir çalışmadır.

1.2. Çalışmanın Amacı ve Önemi

Bu çalışmanın amacı, Sayısal İmgelerde Adli Kanıt Toplama alanında yeni yöntemler geliştirmektir. Bu amaçla, Contourlet ve Ridgelet gibi dalgacık tabanlı dönüşümler üzerinde istatistiksel modeller önerilmiş ve bu modeller aracılığıyla öznitelikler çıkartılmıştır. Bu çalışmada ortaya konulan yeniliklerden bir diğeri ressam belirleme üzerine yapılan çalışmadır.

1.3. Çalışmanın İçeriği

Bu çalışmada, fotoğrafik imgeler için sonlu ridgelet ve contourlet dönüşümleri üzerine kurulu birer istatistiksel model önerilmiş ve dalgacık dönüşümü üzerine kurulu olan daha önceki yöntemle karşılaştırılmıştır [1]. Dalgacık dönüşümü yatay, düşey ve köşegen yönlerden bilgiler içerir. Her bir yön için, ilk ve yüksek dereceli istatistikler analiz için kullanılır. Sonlu ridgelet ve contourlet dönüşümleri yönlü dönüşümler oldukları için, daha az katsayı ile daha çok bilgi elde etmek mümkün olmaktadır.

Sayısal imgelerden adli kanıt toplama kapsamında aşağıdaki problemler üzerinde çalışılmış ve belirtilen başarılar elde edilmiştir:

1. Kaynak Belirleme: Dalgacık tabanlı dönüşümlerden elde edilen bazı özniteliklerin kullanımı ile çok yüksek başarı oranları elde etmek mümkündür. Bu dönüşümlerden elde edilen özniteliklerin bir karmasının kullanılması başarıyı daha da arttırmaktadır.
2. Bilgisayar Tabanlı İmgelerin Ayırıştırılması: Kaynak belirleme çalışmalarına paralel olarak Bilgisayar Grafiği (BG) imgelerin doğal imgelerden ayırıştırılması aşamasında dalgacık tabanlı özniteliklerin kullanılması ve bu özniteliklerin bir karmasının kullanılması başarıyı oldukça arttırmaktadır.
3. Steganaliz: Bu alanda daha önce de yapılan çalışmalar dalgacık dönüşümünün steganaliz amacı ile kullanımının çok da başarılı olmadığını göstermiştir.

Bununla birlikte, karşılaştırma amaçlı olarak yapılan çalışmalar dalgacık tabanlı diğer dönüşümlerin bu alanda dalgacık dönüşümünün kendisinden daha başarılı olduğunu göstermiştir.

4. Ressam belirleme: Bu alanda daha önce yapılmış belirgin bir çalışma olmaması bu konudaki çalışmaları ilgi çekici bir hale getirmektedir. İlk defa bu çalışmada yer verilen bu uygulamada oldukça yüksek başarı oranları sağlanmıştır.

1.4. Daha Önce Yapılan Çalışmalar

Bu tezde, farklı dalgacık tabanlı dönüşümler için istatistiksel modeller önerilmiş ve bu modellerin Adli Kanıt Toplama açısından kullanımları incelenmiştir. Sayısal imgelerden Adli Kanıt Toplama alanında geçmişte yapılmış bazı çalışmalara aşağıda özetlenmiştir.

Önceden belirlenmiş veya önceden eklenmiş fazladan bir bilgi kullanmadan, sayısal imgelerin doğruluğunu belirlemek ve üzerinde oynamaların izlerini takip etmek imge işleminin önemli araştırma alanlarından birisi olmuştur. İmge sahteciliğinin belirlenmesinde körleme yöntemlerin geçtiğimiz yıllarda popülerliği artmış ve bu alanda yayınlanan makale sayısı hızlı bir artış göstermiştir. Burada körleme teriminden kastedilen şey sahteciliği belirlemek için sadece imgenin kendisinin kullanılmasını öngören yöntemlerdir.

Fotoğrafların güvenilirliği pek çok alanda önemli bir rol oynamaktadır. Bu alanların bazıları adli kanıt araştırmaları, suç araştırmaları, gözetim sistemleri, akıllı hizmetler, medikal görüntüleme ve gazeteciliktir. İmgeyi sahte olarak türetme sanatı uzun bir geçmişe sahiptir. Günümüz teknolojileri ile bir imge tarafından ifade edilen bilginin geride hiç bir iz bırakmadan değiştirilmesi çok kolay bir işlem haline gelmiştir.

Çoklu ortam (Multimedia) güvenliği ile birlikte ortaya konulan sayısal bilgi devrimi de değişikliklerin belirlenmesi yönünde pek çok yaklaşımın türetilmesine neden olmuştur. Genellikle, bu yaklaşımlar aktif ve pasif körleme yaklaşımları olarak ikiye

ayrılır. Aktif yöntemler basitçe veri gizleme yaklaşımları [2,3,4] ve sayısal imza yöntemleri [5,6,7,8] olarak ikiye ayrılabilir.

Veri gizleme yöntemleri imgenin içine ikincil bir verinin eklenmesi üzerine kuruludur. Bu alanın en popüler grubu sayısal ıslak imzalara [9,10,11,12] dayanmaktadır. Sayısal ıslak imzalama, kaynak tarafında bir sayısal ıslak imzanın eklenmesi ve alıcı tarafta (örn. dijital kamera) bu işaretin doğrulanması şeklinde kabul edilir. Islak imzalar içine eklendikleri imgelerden çoğunlukla ayırtılamaz olur ve imgenin son halini alması sürecindeki işlemlere imgeyle beraber maruz kalır. Islak imzaların bir kötü yanı imge kaydedildiği zamanda veya daha sonraki bir zamanda yetkisi olan bir kişi tarafından eklenmek zorunda olmasıdır. Bu kısıtlama özel olarak üretilmiş kameraların kullanılmasını veya orjinal imgenin sonradan işlenmesini gerektirir. Ek olarak, bazı ıslak imzalar imgenin kalitesini düşürebilmektedir.

Sayısal imza yaklaşımı imgenin kaynak tarafından eşsiz özniteliklerinin çıkartılıp bu özniteliklerin sayısal imzayı oluşturmak için kullanılmasını içerir. Daha sonra imgenin doğruluğunun ispatlanması için bu imzalar kullanılır. Sayısal imzalar ıslak imzalar gibi veri gizleme yöntemleriyle benzer dezavantajlar içerir.

Aktif yöntemlerin tersine körleme yöntemler daha önceden belirlenen bir bilginin yokluğunda imgenin doğruluğunu belirlemeye çalıştığı için pasiftirler. Körleme yöntemler sahteciliğin imge üzerinde belirlenebilir değişiklikler (örn. istatistiksel değişiklikler) içereceği gerçeğine dayanır. Yüksek kalite imgeler üzerinde yapılan sahteciliklerde, bu tür değişiklikler gözle ayırt edilemez olur. Varolan yöntemler tahrifin (tampering) pek çok izini tanımlamaya ve her birini ayrı olarak bulmaya çalışır. İmgenin durumuna ait son karar ise genellikle farklı belirleyicilerin sonuçlarının bir ağırlıklı ortalaması üzerinden verilir.

Adli imge kanıt toplama üzerine yayınlanmış pek çok konuyu irdeleyen makale bulunmaktadır. Bunlar arasında başlıcaları şu şekilde sıralanabilir: Farid v.d. [13], Lanh v.d. [14], Luo v.d. [15] Ng ve Chang [16], Sencar ve Memon [17], Wu v.d. [18]. Bu çalışmalar farklı yöntemler kullanarak pek çok adli kanıt toplama problemine çözümler önermektedir. Bu makaleler ilk bakışta göze çarpan yayınlar

olmasına rağmen, her adli kanıt toplama problemine çözüm önerileri sunan yayınlar da bulunmaktadır.

Tekrarlanan imge bölgeleri kopyala-yapıştır sahteciliğini ifade eder. Bu tür sahtecilikte, imgenin bir bölgesi kopyalanarak aynı imgenin bir başka bölgesine yapıştırılır. Örneğin küçük bir topluluğun yaptığı bir mitingi on binlerce insandan oluşan bir toplantı görünümüne sokmak ya da imgedeki bir nesneyi gizlemek için bu tür bir işlem gerçekleştirilmesi asıl amaçlardan biri olabilmektedir.

Bayram v.d. [19] imgenin bloklarının Fourier-Mellin dönüşümünü alarak bir klon belirleyici tasarlamıştır. Fourier-Mellin dönüşümü ölçek ve yönden bağımsızdır. Bu durum yeniden ölçeklendirilmiş ve hafifçe çevrilmiş bölgelerin belirlenmesine kolaylıklar getirmektedir. Dybala v.d. [20] bir süzgeçleme işlevi ve en yakın komşu aramasına dayalı bir klonlama belirleyicisi önermiştir. Fridrich v.d. [21] ayrık kosinüs dönüşümünü üst üste gelen bloklar üzerine uygulayıp sözlüksel gösterimlerini kullanarak kopyala-taşı sahteciliğini belirleyen bir yöntem önermiştir. Huang v.d. [22] imgede taşınmış bölgeleri belirlemek için SIFT (Scale Invariant Feature Transform) algoritmasını kullanmıştır. SIFT öznelikleri aydınlatma, çevirme ve ölçeklendirmedeki değişikliklere karşı duranıdır. Langille ve Gong [23] bir k boyutlu ağaç kullanarak benzer parlaklık dokularının olduğu blokları belirlemeye dayalı bir yöntem önermiştir. Li v.d. [24] JPEG imgeler üzerindeki bloklama artıklarını belirleyerek bir kopyala-taşı belirleyicisi kullanmıştır. Lin v.d. [25] radiks sıralamaya dayalı bir yöntem önermiştir. Luo v.d. [26] yedi adet parlaklığa dayalı karakteristik öznelik kullanarak bir belirleyici geliştirmiştir. Mahdian ve Saic [27] k boyutlu ağacı, birincil bileşen analizi ve moment farklılıklarına dayalı bir yöntemi tekrarlanan bölgeleri belirlemek için kullanmıştır. Myna [28] log-polar koordinatları ve dalgacık dönüşümünü kullanma fikrini ortaya atarak bir yöntem geliştirmiştir. Popescu ve Farid [29] birincil bileşen analizi ile imge bloklarını göstermeye dayalı bir yöntem önermiştir. Sergio ve Nandi [30] log-polar koordinatları kullanarak yeni bir yöntem önermiştir. Yöntem yansıma, ölçeklendirme ve çevirmeden bağımsız olmaktadır. Zhang v.d. [31] dalgacık dönüşümü ve faz ilintilerine dayalı bir kopyala-taşı belirleme yöntemi önermiştir.

Yüksek kalite ve tutarlı imge sahtecilikleri yaratmak için, iki veya daha fazla imge bir araya getirildiğinde, geometrik dönüşümlere neredeyse her zaman ihtiyaç duyulur. Bu dönüşümler, bir imgenin bir kısmının yeni bir örnekleme kafesi üzerine yeniden örneklenmesine dayanır. Bu durum sinyal üzerinde istatistiksel değişikliklere neden olan bir aradeğerleme aşamasına ihtiyaç duyar. Bu özel istatistiksel değişimlerin belirlenmesi tahrifin ortaya çıkarılmasında kullanılabilir.

Fillion ve Sharma [32] içeriğe kendisini uyarlamaya dayalı yeniden ölçeklendirmenin belirlenmesini incelemiştir. Gallagher [33] sayısal olarak büyütülmüş imgelerin belirlenmesi üzerine bir yöntem önermiştir. Yöntem ara değerlenmiş imgenin ikinci türevinden gelen sinyalin periyodikliği üzerine kurulmuştur. [34]'de, Kirchner doğrusal süzgeçleme ve kümülatif periyodogramlara dayalı bir yeniden örnekleme belirleme yöntemi önermiştir. Kirchner ve Gloe [35] yeniden sıkıştırılmış JPEG imgelerinde yeniden örnekleme belirleyen bir yöntem önermiştir. Liu ve Sung [36] yeniden ölçeklendirilmiş JPEG imgelerinin bulunması üzerine bir çalışma yapmıştır. Çalışmaları ayırık kosinüs dönüşümü (DCT) katsayılarının birleşik yoğunluk özniteliklerinin Destek Vektör Makinaları (DVM) ile sınıflandırılmasına dayanmaktadır. Makale JPEG sıkıştırılmış imgelerde yeniden örnekleme belirleme performansını arttırmakta blokla artıklarının yardımcı olacağını göstermiştir. Mahdian ve Saic [37,38] radon dönüşümü ve bir türev işlevi kullanarak ara değerlemenin izlerinin belirlenmesi üzerine bir yöntem önermiştir. Ara değerlemenin belirlenmesi üzerine yöntemler genelde JPEG imgeler üzerinde zayıf sonuçlar vermiştir. Bu nedenle, Nataraj v.d. [39] JPEG yeniden ölçeklendirilmiş imgelerin belirlenmesine yönelik bir yöntem önermiştir. Yöntem imgeye uygun miktarda Gaussian gürültünün eklenmesi üzerine kurulmuş ve JPEG sıkıştırmadan dolayı olan periyodiklik bastırılırken yeniden ölçeklendirmeden dolayı olanların değişmeden kaldığını göstermiştir. Yeniden örnekleme izlerini belirlemek için, Popescu ve Farid [40] ara değerlendirme aşamasında yeniden örneklenen imgenin gözlemlenemeyen özel ilintilerini araştırmış ve bir beklenti en büyükleme algoritması kullanarak bir yöntem geliştirmiştir. Prasad ve Ramakrishnan [41] çeşitli uzay ve frekans bölgesi yöntemleri yeniden örnekleme izlerini belirlemek için incelemiştir. [42]'de bir sınıflandırıcı ile üzerinde temel değişiklikler yapılmış imgeler ile orijinal imgeler arasında ayırım yapılmaya çalışılmaktadır. [43]'te ise belirli yöntemlerle elde edilen

bir öznitelik kümesi içerisinde seçilen özniteliklerle imge üzerindeki değişiklikleri belirleyen bir yöntem önerilmiştir.

Fotomontaj belirleme problemiyle uğraşıldığında, yapılması gereken en temel işlerden birisi imge eklemenin belirlenmesidir. Burada imge eklemekten kastedilen şey bir imgenin bazı bölgelerinin başka bir imge üzerine eklenmesidir.

İmge eklemeyi belirlemek için, Dong v.d. [44] DVM tabanlı bir yöntem geliştirmiştir. Kullanılan öznitelikler, imge ekleme yoluyla ortaya çıkan imge piksel ilintileri ve benzerliklerindeki süreksizliklerin analizinden elde edilmiştir. [45]'te, Farid tahrif işlemi sırasında ortaya çıkan ve doğal olmayan yüksek dereceli ilintilerin belirlenmesi üzerine bir yöntem önermiştir. Hsu ve Chang [46,47] geometri benzeşikliklerinden tahmin edilen kamera cevap fonksiyonuna dayalı bir yöntem geliştirmiştir. Gopi v.d. [48,49] bir yapay sinir ağı, bağımsız bileşen analizi ve öz bağlantım katsayıları kullanarak sahteciliği belirlemeye yönelik bir yöntem önermiştir. Jing ve Hongbin [50] Sobel köşe belirleyici, bir türev işlevi ve Hough dönüşümü kullanarak bir yöntem önermiştir. Ng ve Chang [51] bir çift kutuplu sinyal karışıklığı üzerine kurulu bir imge ekleme modeli ortaya atmıştır. Shi, [52,53,54,55]'te imge eklemeyi analiz etmiştir. Önerilen yöntemler Hilbert-Huang dönüşümüne [52], iki boyutlu faz uygunluğu istatistiklerine [53] ve doğruluğu onaylanmış eklenmiş imgeleri sınıflandırmak için bir doğal imge modeline [54] dayanmaktadır.

Gelişmiş bilgisayar grafiği kaplama yazılımları (3DSMAX, Lightwave, vb.) ile çok başarılı fotogerçekçi imgeler oluşturulabilmektedir. Bu nedenle, doğal imgelerle bu imgeleri ayırt etmek çok zor olabilmektedir.

Bilgisayar grafiklerini belirlemek için Chen v.d. [56] doğal imgelerin dalgacık dönüşümü katsayılarını kullanmıştır. Çalışmalarında, imge dalgacık bölgesinin bölümlenmiş düşük dereceli momentleri çıkarılmış ve DVM kullanılarak sınıflandırılmıştır. Dehnie v.d. [57] görüntüleme sensöründeki doku gürültüsü üzerine eğilen bir yaklaşım kullanarak bir yöntem geliştirmiştir. Chang v.d. [58] fotoğrafik imgeleri ve fotogerçekçi bilgisayar grafiklerini sınıflandırmak için fiziksel imge oluşturma süreçlerinden esinlenen geometri tabanlı bir imge modeli

oluşturmuştur. Aynı yazarlar fotoğrafik imgeler ve fotogerçekçi bilgisayar grafikleri arasında sınıflandırma yapmak için bir çevrimiçi sistem tasarlamıştır [59,60]. [61]'de, Dirik v.d. renk süzgeç dizisinin mozaik yapısının bozulmasını ve kromatik sapmasını belirlemeye yönelik öznelikleri ortaya çıkarmak için fotoğrafik ve fotogerçekçi imgeleri incelemiştir. Khanna v.d. [62], kalıntı doku gürültüsüne dayalı bir yöntem önermiştir. Leykin v.d. [63] fotoğrafları tablolardan etkin bir şekilde ayırmak için köşe özelliklerindeki öznelikleri kullanmayı önermiştir. Leykin v.d., [64]'teki çalışmasında, fotoğrafların tablolardan renk, köşe ve doku özellikleri bakımından ayrıldığını bulmuştur. Lyu ve Farid [1] fotoğrafik imgeler için birinci ve daha yüksek dereceli istatistiklerini içeren bir istatistiksel model önermiştir. Rocha v.d. [65] aşamalı rastgeleleştirmeye dayalı bir yöntem önermiştir. Sankar v.d. [66] varolan öznelikleri ve bir öznelik seçim algoritması kullanarak bilgisayar grafikleri ve gerçek imgeler arasında ayırım yapmaya yönelik bir yöntem önermiştir. Shi v.d. [67] dalgacık alt-bantlarının ve onların tahmin hatalarının karakteristik fonksiyonlarının istatistiksel momentlerini kullanarak öznelikler oluşturmuş ve bu öznelikleri kullanan bir yöntem önermiştir. Sutthiwan v.d. [68] bir boyutlu ve iki boyutlu karakteristik fonksiyonların istatistiksel momentlerini bilgisayar grafikleri ve fotoğrafik imgeleri ayırt eden imge özneliklerini türetmek için kullanmıştır. Wu v.d. [69] ise sıfır bağıntılılık ve bulanık üyelikler kullanarak boyanmış imgeler üzerindeki sahte bölgeleri belirlemeye çalışmıştır.

Bir imgeyi değiştirmek için, genel olarak imgenin bir imge editörüne yüklenmesi ve değişiklikler yapıldıktan sonra elde edilen yeni sayısal imgenin kaydedilmesi gerekir. İmgenin sıkıştırılma geçmişi hakkında fikir yürütebilen gelişmiş yöntemler sahtecilik belirlemede faydalı olabilmektedir.

Battiato ve Messina [70] DCT ve JPEG özelliklerine dayalı varolan çözümlerin zayıf ve güçlü noktalarının bazılarını deneysel olarak analiz etmiştir. Chen ve Hsu [71] bir kere ve iki kere sıkıştırılmış imgeleri ifade etmek için bir kuantalama hatası modeli oluşturmuştur. Fan ve Queiroz [72] bir imgenin daha önce JPEG ile sıkıştırılıp sıkıştırılmadığına karar veren bir yöntem önermiştir. Sıkıştırma olması durumunda, yöntem, sıkıştırma parametrelerine karar vermektedir. Özellikle, JPEG kuantalama basamaklarının en büyük benzerlik tahminin yapan bir yöntem geliştirilmiştir. [73]'te, Farid farklı kalitede JPEG imgelerden yaratılan karışımların

belirlenmesine yönelik bir çalışma yapmıştır. Yöntem imgenin bir kısmının daha önce imgenin geri kalanından daha düşük bir kalitede sıkıştırılıp sıkıştırılmadığını belirlemektedir. Lukáš ve Fridrich [74] iki kere JPEG sıkıştırılmış bir imgede kuantalama matrisinin tahmini için bir yöntem önermiştir. Pevný ve Fridrich [75] düşük frekans DCT katsayılarının histogramlarından elde edilen özniteliklerle bir DVM sınıflandırıcı tasarlamıştır. Li [76] imge bloklarının özelliklerini analiz eden bir yöntem önermiştir. Zhang [77] JPEG 2000 imgeleri belirlemek için bir yöntem önermiştir.

Pek çok dijital kamera bir CCD (Charge Coupled Device) veya CMOS (Complementary Metal Oxide Semiconductor) sensör ile donatılmıştır. Renkli imgeler genellikle bir renk süzgeç dizisi aracılığıyla elde edilir. Her piksel konumunda sadece bir renk örneği yakalanır. Kayıp renkler ise renk süzgeç dizisi (CFA) ara değerlemesi adı verilen bir ara değerlendirme süreci ile elde edilir. Tahrif işlemleri CFA ara değerlemesi tarafından oluşturulan ve imge piksellerine taşınan bazı özel ilintileri yok edebilmektedir.

Dirik ve Memon [78] CFA'nın izlerini çözümleyen iki öznitelik önermiştir. Makale tahrif belirleme ve bilgisayar grafiği ile gerçek imgeleri birbirinden ayırt etme için özniteliklerin başarılı uygulamalarını göstermektedir. Fan [79] CFA'nın izlerini bulmak için bir yapay sinir ağı önermiştir. Poilpré [80] Bayer CFA ara değerlemenin izlerini belirlemek için bir yöntem tanımlamıştır. Popescu ve Farid [81] imgeye CFA ara değerlemenin getirdiği bazı özel ilintileri tanımlamış ve bu ilintilerin otomatik olarak belirlenmesi için bir yöntem önermiştir.

Farklı fotoğraflar farklı aydınlatma koşullarında çekilmektedir. Bu nedenle, imge sahteciliği yapmak için iki ya da daha fazla imge birbirine eklendiğinde, her bir fotoğraftaki aydınlatma koşullarını birbirine uydurmak zor olmaktadır. Bundan dolayı aydınlatma uyumsuzluklarının belirlenmesi tahrifin izlerinin bulunması için bir başka uygun yol olabilmektedir.

Bazı belirli basitleştirici varsayımlar altında, herhangi bir aydınlatma ortamı küresel harmoniklerin bir doğrusal kombinasyonu olarak 9-boyutlu bir model ile ifade edilebilmektedir. Johnson ve Farid [82] çalışmalarında daha düşük dereceli olan 5-

boyutlu bir modelin nasıl oluşturulacağını ve bir imgeden bu model için parametrelerin nasıl elde edileceğini göstermiştir. Aynı yazarların bir başka çalışmasında ise farklı insanların fotoğraflarını ekleyerek yaratılan imge sahteciliklerine dikkat çekilmektedir [83]. Farid ve Bravo [84] gölge ve yansımalarındaki aydınlatma uyumsuzluklarını belirlemek için farklı hesaplamalı yöntemler tanımlamıştır.

Ayrıca, tahrifin belirlenmesi ve izlerinin bulunması için, önerilen pek çok farklı yöntem de bulunmaktadır. Bunlar arasında bölgesel gürültünün üzerindeki uyumsuzlukların belirlenmesi [85,86], optik sistemlerin açıklarından oluşan kromatik sapmalar üzerindeki uyumsuzlukların bulunması [61,87], imge işleme süreçlerinin varlığının tespiti [88,89] ve imge içinde farklı oranda bulanıklık içeren bölgelerin bulunması [90,91] sayılabilir.

Bu tezde, doğal ve fotogerçekçi imgeleri ayırmak, imgenin kaynağını belirlemek, imge üzerinde gizlenen veriyi belirlemek ve sanat sahteciliğinin belirlenmesine bir ön adım olarak imgelerin hangi ressamalara ait olduğunu bulmak için ridgelet ve contourlet dönüşümlerinden elde edilen istatistiklerin kullanılması önerilmektedir. Deneysel sonuçlar ridgelet ve contourlet dönüşümünden elde edilen özniteliklerin, dalgacık tabanlı özniteliklerden görece daha az karmaşık ve sınıflandırma açısından daha başarılı olduğunu göstermektedir.

1.5. Tezin Organizasyonu

Bu tezin 2. Bölümünde Dalgacık tabanlı dönüşümler hakkında bilgi verilmekte, 3. Bölümünde kullanılan istatistiksel modelin nasıl elde edildiği belirlenmekte, 4. Bölümde deneysel sonuçlar gösterilmekte ve 5. Bölümünde sonuçlar tartışılmaktadır. Ek olarak, Ek Bölümünde tezde konu edilen bazı kavramların açıklanması amacıyla temel bilgiler verilmektedir.

2. Dalgacık Tabanlı Dönüşümler

2.1. Ridgelet Dönüşümü

Dalgacıkların başarısı esas olarak bir boyuttaki parçalı pürüzsüz (smooth) işlevlerin getirdiği iyi performanslara dayanır. Ne yazık ki, bu başarı iki boyutlu durumda geçerli değildir. Temelde, dalgacıklar sıfır boyutlu veya noktasal kesikleri yakalamakta iyidir. Bununla birlikte, iki boyutlu işaretler genellikle bir boyutlu kesikler içerir. Yumuşak geçişli bölgeler köşelerle ayrılır ve bu köşeler de kendi içlerinde yumuşak geçişleri taşırlar. İki boyutlu dalgacık dönüşümleri genelde iki adet bir boyutlu dalgacık dönüşümünün tensör çarpımından oluşur ve bu durum iki boyutlu dalgacık dönüşümünün bir boyutta bir köşeyi yakalarken bir başka boyutta yumuşak geçiş nedeniyle köşeyi kaçırmasına neden olur.

Dalgacık dönüşümünün yüksek boyutlardaki bu zayıflığının üstesinden gelmek için Candès ve Donoho [92] “ridgelet” adını verdikleri iki boyutta var olan çizgi kesikleri etkin bir şekilde göze alan yeni bir gösterimsel sistem ortaya çıkardılar. Yöntemin altında yatan fikir Radon dönüşümü kullanarak çizgi kesiklerini nokta kesiklerine dönüştürmektedir.

Daha sonra, bu çalışmayı geliştirmek amacıyla curvelet [93] ve contourlet [94] dönüşümleri ortaya atılmıştır. Bu dönüşümler daha sonraki bölümlerde incelenecektir.

Bu çalışmada, Farid v.d.. [1] tarafından yapılan çalışma temel alınarak dalgacık dönüşümü yerine ridgelet ve contourlet dönüşümü kullanılmıştır. [95]'teki çalışmaya paralel olarak her iki dönüşüm için de birer istatistiksel model ortaya konmuştur. Her iki dönüşümün de getirdiği avantajlar nedeniyle sonuçlarda belirgin iyileştirmeler gözlenmiştir.

2.1.1. Sürekli Ridgelet Dönüşümü

Ayrık Ridgelet dönüşümünü incelemeden önce sürekli Ridgelet dönüşümünü ve sürekli uzaydaki diğer dönüşümlerle bağlantılarını göstermekle başlayalım. Verilen bir tümlevleşebilir (integrable) iki değişkenli işlev $f(x)$ için, \mathbb{R}^2 'de Sürekli Ridgelet Dönüşümü (SRD) aşağıdaki gibi tanımlanır [98,102]:

$$SRD_f(a, b, \theta) = \int_{\mathbb{R}^2} \psi_{a,b,\theta}(\bar{x}) \cdot f(\bar{x}) \cdot d\bar{x}. \quad (2.1)$$

Burada ridgeletler, $\psi_{a,b,\theta}(\bar{x})$, 2 boyutlu uzayda bir boyutlu dalgacık tipi işlevlerle, $\psi(x)$, tanımlanır:

$$\psi_{a,b,\theta}(\bar{x}) = a^{-1/2} \psi((x_1 \cos \theta + x_2 \sin \theta + b)/a). \quad (2.2)$$

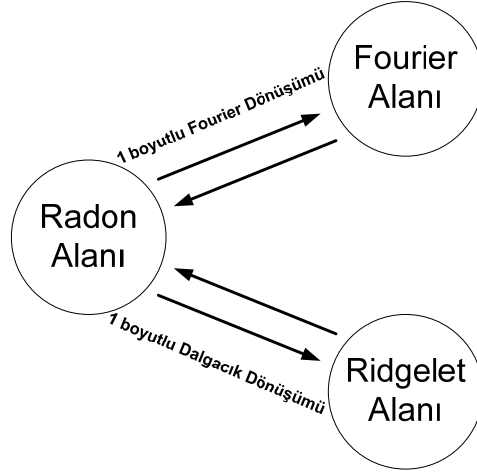
Karşılaştırmak için \mathbb{R}^2 'de ayrılabilir sürekli dalgacık dönüşümü (SDD) şu şekilde yazılabilir:

$$SDD_f(a_1, b_1, a_2, b_2) = \int_{\mathbb{R}^2} \psi_{a_1, b_1, a_2, b_2}(\bar{x}) \cdot f(\bar{x}) \cdot d\bar{x}. \quad (2.3)$$

Burada iki boyutlu dalgacıklar, $\psi_{a,b}(t) = a^{-1/2} \psi((t-b)/a)$ gibi bir boyutlu dalgacıkların tensör çarpımlarından elde edilir:

$$\psi_{a_1, b_1, a_2, b_2}(\bar{x}) = \psi_{a_1, b_1}(x_1) \cdot \psi_{a_2, b_2}(x_2). \quad (2.4)$$

Görüleceği üzere, SRD iki boyutlu SDD'ye benzemektedir. Eşitlik 2.2 ve 2.4 arasındaki fark nokta parametreleri (b_1, b_2) kullanılması yerine çizgi parametreleri (b, θ) kullanılmasıdır. Başka bir deyişle, çok ölçekli iki boyutlu dönüşümlerden dalgacık dönüşümü nokta konumlarıyla ilgiliyken, ridgelet dönüşümü çizgi konumlarıyla ilgilidir [97].



Şekil 2.1 – Dönüşümler arası ilişkiler

Sonuç olarak, ridgeletler çizgiler boyunca olan tekilliklere sahip nesnelere göstermekte oldukça etkinken, dalgacıklar izole edilmiş nokta tekillikleri olan nesnelere göstermekte etkindir. Aslında, ridgeletler bir boyutlu dalgacıkların çizgiler üzerinde birleştirilmesi için bir yöntem olarak düşünülebilir. Bundan dolayı ridgeletleri görüntü işleme süreçlerinde kullanmak, tekilliklerin imgeler üzerinde köşelerde ve düzey çizgilerinde birleşmesinden dolayı çekici bir hal almaktadır [97].

İki boyutta, noktalar ve çizgiler Radon dönüşümü aracılığıyla ilişkilendirildiğinden, dalgacıklar ve ridgeletler de Radon dönüşümü aracılığıyla ilişkilendirilebilirler. Daha kesin olarak, Radon dönüşümünü gösterecek olursak:

$$R_f(\theta, t) = \int_{\mathbb{R}^2} f(\bar{x}) \cdot \delta(x_1 \cos \theta + x_2 \sin \theta - t) \cdot d\bar{x} \quad (2.5)$$

olur. Bu durumda ridgelet dönüşümü de Radon dönüşümünün dilimlerine (izdüşümlerine) bir boyutlu dalgacık dönüşümünün uygulanmasına denk düşer [97]:

$$SRD_f(a, b, \theta) = \int_{\mathbb{R}} \psi_{a,b}(t) \cdot R_f(\theta, t) \cdot dt. \quad (2.6)$$

Bu ünlü izdüşüm-dilim teorisidir ve izdüşüm yöntemlerinde görüntü geriçatmak için kullanılır [104,105]. Farklı dönüşümler arasındaki ilişki Şekil 2.1’de verilmiştir.

2.1.2. Sonlu Radon Dönüşümü

Önceki bölümde belirtildiği gibi, ridgelet dönüşümü, Radon dönüşümünün dilimlerine bir boyutlu dalgacık dönüşümünün uygulanmasıdır. Bu durumda, ayrık bir ridgelet dönüşümü elde etmek için ayrık bir Radon dönüşümünün elde edilmesi gerekir. Radon dönüşümünü ayrıklaştırmak için birçok çalışma yapılmıştır [98,99,100,101,102,103]. Bununla birlikte, bu çalışmalar sayısal imgelerde geri dönüşüm yapmak için tasarlanmamışlardır. Alternatif olarak, kombinatorikten türetilen sonlu Radon dönüşümü teorisi de ilginç bir çözüm önermiştir [104,105,106,107].

Sonlu Radon dönüşümü (SRAD) belirli bir çizgi kümesi üzerindeki imge piksellerinin toplanması olarak tanımlanır. Bu çizgiler sürekli Radon dönüşümünün Öklid geometrisinde belirlenen çizgilerine benzer bir yolla elde edilirler. p bir asal sayıyken bir $Z_p = \{0,1,\dots,p-1\}$ tanımlayalım. Z_p 'nin p 'ye göre mod alınan bir sınırlı alan olduğuna dikkat ediniz. Ayrıca, daha sonraki işlemlerde kolaylık olması için bir de $Z_p^* = \{0,1,\dots,p\}$ tanımlayalım.

Z_p^2 sonlu alanında bir gerçek işlev f 'in SRAD'ı şu şekilde tanımlanır:

$$r_k[l] = SRAD_f(k,l) = \frac{1}{\sqrt{p}} \sum_{(i,j) \in L_{k,l}} f[i,j]. \quad (2.7)$$

Burada, $L_{k,l}$ Z_p^2 kafesinde bir çizgi oluşturan noktalar kümesini belirtir veya daha açık olarak:

$$\begin{aligned} L_{k,l} &= \{(i,j) : j = ki + l(\text{mod } p), i \in Z_p\}, 0 \leq k < p, \\ L_{p,l} &= \{(l,j) : j \in Z_p\}. \end{aligned} \quad (2.8)$$

Yapılan çalışmalar göstermiştir ki, dönüşüm sırasında enerjinin en iyi şekilde sıkışması için imgenin ortalamasının çıkarılması gerekmektedir. Bu nedenle ridgelet dönüşümü alınırken önce imgenin ortalaması imgeden çıkarılmaktadır.

2.2. Contourlet Dönüşümü

Sıkıştırma, gürültü ayıklama, öznitelik çıkarımı ve ters problemler gibi pek çok imge işleme sürecinin kalbinde görsel bilginin etkin gösterimi yatar. Bir gösterimin etkinliği, küçük bir tanımlayıcı kullanarak ilgilenilen nesne hakkında önemli bilgilerin yakalanabilmesi yetisi olarak ifade edilebilir. Pratik uygulamalarda, bu tür bir gösterim yapısal dönüşümler ve hızlı algoritmalarla elde edilebilir olmak zorundadır.

Bir boyutlu parçalı yumuşak sinyaller için (örn. bir imgenin tarama hatları gibi), dalgacıklar doğru bir seçim olur. Çünkü dalgacıklar bu tür sinyaller için en uygun türde bir gösterim sağlarlar. Ayrıca, dalgacık gösterimi hızlı dönüşümler ve uygun ağaç veri yapılarını sağladığı için etkin algoritmalarla çalışmaya uygundur.

Bununla birlikte, doğal imgeler bir boyutlu parçalı yumuşak tarama hatları kümelerinden oluşmaz ve köşeler gibi süreksiz noktalar tipik olarak fiziksel nesnelerin yumuşak sınırlarına bağlı olarak çevre çizgileri (contour) gibi yumuşak eğriler arasına yerleşmiştir. Bu nedenle, doğal imgeler görsel bilgideki anahtar özellikler olan içsel geometrik yapıları barındırır. Bir boyutlu bazların ayrılabilir bir uzantısı olması sonucunda iki boyutta dalgacıklar köşe noktalarındaki süreksizlikleri çevre çizgileri arasındaki yumuşaklığı göremeyerek izole etmekte başarılıdır. Ek olarak, ayrıştırılabilir dalgacıklar sadece sınırlı yönsel bilgi içerebilir. Bu hayal kırıcı özellikler dalgacık dönüşümü yerine daha yüksek boyutlar için daha güçlü gösterimlere ihtiyaç olduğunu gösterir.

Bu ihtiyacı basit bir örnekle ifade edebiliriz. Diyelim ki iki ressamımız olsun. Birincisi dalgacık tipi bir örüntü ile boyama yapsın, diğeri ise yeni bir yöntem denesin. Şekil 2.2(a)'da birinci ressamın noktaları nasıl koymasına gerektiği gösterilmiştir. İki boyutlu dalgacıklar bir boyutlu olanların tensör çarpımlarından elde edildikleri için birinci ressam kare şekilli fırça darbeleriyle sınırlanır. Burada farklı büyüklükte kareler dalgacıkların çoklu çözünürlük yapısına denk düşmektedir. Çözünürlük arttıkça ressamın koymasına gereken nokta sayısı da artmaktadır ki bu dalgacıkların zayıf noktasıdır. İkinci ressam ise (Şekil 2.2(b)) çok az fırça darbesiyle eğriyi başarılı bir şekilde çizebilmektedir. Farklı şekil ve


yönlerdeki fırça darbeleri sayesinde eğriyi başarılı bir şekilde takip edebilmektedir. Bu yeni yöntem Candès ve Donoho tarafından “curvelet” adıyla gerçekleştirilmiştir [99,114].

İnsan görsel sistemi için, görsel korteksteki algılayıcı bölgeler bölgesel, yönlü ve bant geçiren olarak karakterize edilir [109]. Ayrıca, doğal imgelerin seyrek elemanlarını aramaya dayalı deneyler görsel korteksin benzeri özelliklerde baz imgeler üretmiştir [110]. Bu sonuç insan görsel sisteminin en az sayıda görsel aktif hücre kullanarak doğal bir görünümdeki esas bilgiyi yakalamaya ayarlandığı hipotezini destekler. Daha da önemlisi, bu sonuç bir imge gösteriminin etkin olabilmesi için bölgesel, yönlü ve çoklu çözünürlüklü olması gerektiğini de gösterir.

Yeni bir imge gösterimi için bir “olması gerekenler” listesi yapacak olursak, bu liste beş temel maddeden oluşacaktır:

- 1) Çoklu çözünürlük: Hem düşük çözünürlükte hem de yüksek çözünürlükte gösterim imgeye başarılı bir yaklaşım getirebilmelidir.
- 2) Bölgesellik: Başarılı bir gösterimde baz elemanlar hem uzamsal hem de frekans uzayında bölgesel olmalıdır.
- 3) Kritik örnekleme: Bazı uygulamalar için, gösterimin oluşturduğu baz veya çerçeve için gereksizlikler küçük olmalıdır.
- 4) Yönlülük: İyi bir gösterim farklı yönlere çevrilmiş baz elemanları içermelidir.
- 5) Anizotropi: İmgelerdeki yumuşak çevre çizgilerini yakalamak için, gösterim pek çok farklı en-boy oranlarında uzun şekiller kullanan baz elemanları içermelidir.

Dalgacık dönüşümü ilk üç maddeyi başarılı bir şekilde sağlarken ridgelet dönüşümü dördüncü maddeyi de sağlar. Bununla birlikte, curvelet ve benzeri bir dönüşüm olan contourlet dönüşümleri bu beş maddeyi de sağlamaktadır.



Şekil 2.2 – (a) Dalgacık dönüşümü modeli (b) Yeni model

2.2.1. Temel Tanımlar

Verilen bir f sinyali için bir genel seri açılımı $\{\phi_n\}_{n=1}^{\infty}$ düşünelim:

$$f = \sum_{n=1}^{\infty} c_n \phi_n . \quad (2.9)$$

Bir açılımın etkinliğini ölçmek için kullanılan ölçeklerden birisi en iyi M terim açılımından gelen hatanın düşüşüdür. En iyi M terim açılımı:


$$\hat{f}_M = \sum_{n \in I_M} c_n \phi_n \quad (2.10)$$

olur. Burada, I_M $|c_n|$ 'nin M en büyük terimlerinin indisleridir. Bu formdaki curvelet dönüşümü için hata düşüşü (L_2 -norm kare $\|f - \hat{f}_M\|_2^2$) $O((\log M)^3 M^{-2})$ olurken, dalgacıklarda bu düşüş $O(M^{-1})$ seviyesinde ve Fourier dönüşümü için $O(M^{-1/2})$ olmaktadır [110]. Bu nedenle, yumuşak çevre çizgileri olan tipik bir imge için, dalgacıkların Fourier bazlarına göre yaptığı gelişme göz önüne alınarak curvelet

benzeri bir yöntemle dalgacıklara göre çok daha iyi sonuçlar almamız beklenebilir. Curvelet dönüşümünün ortaya koyduğu en önemli gerçek, *sabit* bir dönüşüm aracılığıyla yumuşak çevre çizgileri olan imgeler için uygun bir gösterim geliştirmenin mümkün olduğunu göstermesidir.

Curvelet dönüşümü ilk olarak her bir bant geçiren imge için çoklu ölçekli bir süzgeç ve ardından blok ridgelet dönüşümü [111] uygulanarak sürekli uzayda geliştirilmiştir [93]. Daha sonraları, yöntem geliştirilerek ikinci bir nesil ridgelet dönüşümü kullanılmadan frekans bölütleme kullanılarak yeniden tanımlanmıştır [108]. Her iki nesil de bir çevirme işlemine ihtiyaç duyar ve polar koordinatlarda frekans bölütlemeye dayanır. Sürekli uzayda bu yöntem curvelet gösterimini kolay kılarsa da ayrık uzaya geçiş aşamasında problem oldukça zorlayıcı bir hal alır. Özellikle, kritik örnekleme yaklaşmak bu tür ayrıklaştırılmış yapılarda oldukça zor olmaktadır [107].

Bu nedenle, curveletlere benzer şekilde yönlü ve çoklu çözünürlüklü bir dönüşüm olan contourlet dönüşümü doğrudan ayrık uzayda geliştirilmiştir [94]. Fakat dikkat edilmesi gereken şey contourlet dönüşümünün curvelet dönüşümünün ayrık versiyonu olmadığıdır.



Şekil 2.3 – Contourlet filtre bankası

2.2.2. Yapı


Şekil 2.2(b)'de verilen yeni yapıyla dalgacık yapısını (Şekil 2.2(a)) karşılaştırdığımızda, yeni yapının getirdiği gelişme yakın dalgacık katsayılarının gruplandırılmasına yüklenebilir. Çünkü bu katsayılar çevre çizgilerinin yumuşaklıkları nedeniyle bölgesel olarak ilintilidir. Bu nedenle, çok ölçekli bir dönüşümün ardından bir bölgesel yönlü dönüşümü, aynı ölçekteki yakın baz fonksiyonlarını doğrusal yapılara bütünleştirmek için kullanarak doğal imgeler için seyrek bir gösterim elde edilebilir. Contourlet dönüşümünde aslında ilk olarak kenar belirleme amaçlı dalgacık benzeri bir dönüşüm uygulanır. Daha sonra da çevre çizgisi parçalarını belirleme amaçlı bir bölgesel yönlü dönüşüm uygulanır. Bu dönüşüm ilginç bir şekilde görüntü işleme uygulamalarında çizgi belirleme amaçlı kullanılan Hough dönüşümüne benzemektedir [97].

Şekil 2.3'te verilen benzer filtre bankası yapısı, Laplacian piramidi [112] kullanılarak elde edilmiş ve daha sonra Bamberger ve Smith'in [113] önerdiği iki boyutlu yönlü filtre bankasının yeni bir versiyonu [114] kullanılmıştır. İlk filtre bankası nokta süreksizliklerini bulurken ikincisi ise bu nokta süreksizliklerini doğrusal yapılara bağlamaktadır. Elde edilen sonuç contourlet adı verilen baz elemanları kullanılarak ortaya konulan bir imge gösterimidir.


Laplacian piramidi (LP), Burt ve Adelson [112] tarafından ortaya atılmıştır. LP ayrışımı her seviyede orijinal imgenin bir alçak geçirgen filtrelenmiş ve altörneklenmiş sürümünü üretir ve bu sürüm ile orijinal arasındaki fark da bant geçirgen olur. Şekil 2.4(a)'da ayrışma süreci, Şekil 2.4(b)'de ise geriçatma süreci gösterilmektedir. Burada H ve G (alçak geçirgen) analiz ve sentez filtreleri ve M örnekleme matrisidir. Süreç daha kötü çözünürlükteki alçak geçirgen $a[n]$ sinyali üzerinden yinelemeli olarak sürdürülebilir.

Bamberger ve Smith [113] mükemmel geriçatmayı başarırken maksimum veri kırımını (decimation) gerçekleştiren iki boyutlu yönlü bir filtre bankası (YFB) inşa etmiştir. YFB, Şekil 2.5(a)'da gösterildiği gibi köşe-şekilli frekans parçalama ile 2^l alt-bant oluşturan l seviyeli ikili ağaç ayrışımı aracılığıyla etkin bir şekilde gerçekleştirilir. YFB'nin [113]'teki orijinal gerçekleştirilmesi girdi imgesinin modüle

edilmesi (Şekil 2.5(b)) ve elmas-şekilli filtreler kullanılarak oluşturulan quincunx filtre bankalarının kullanılmasını içerir [114].

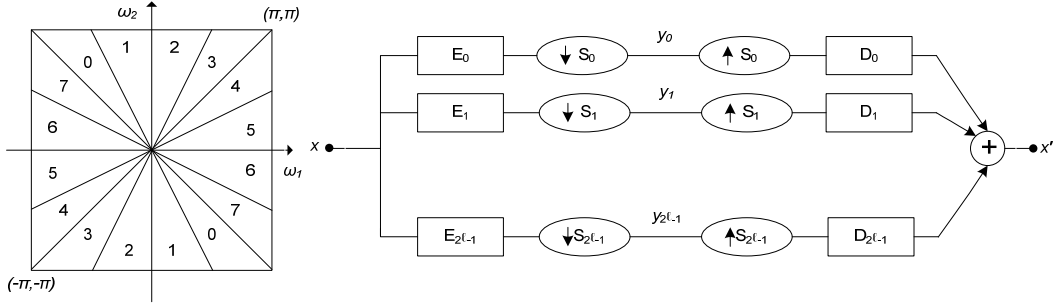


(a)



(b)

Şekil 2.4 – Laplacian Piramidi (a) Ayrışmanın bir seviyesi. Çıktılar daha kötü bir yaklaşım olan $a[n]$ ve orijinal sinyal ile tahmin arasındaki fark olan $b[n]$ 'dir. (b) Geriçatmanın bir seviyesi.



(a)

(b)

Şekil 2.5 – Yönlü filtre bankası (a) Frekans uzayını bölme biçimi (b) Yapısal model.

[114]'te bu yöntemle bir düzeltme getirilerek karmaşık ağaç yapısı basitleştirilmiştir. Bu yeni basitleştirilmiş YFB iki bloktan oluşur. İlk blok fan filtreleriyle kurulmuş quincunx filtre bankalarını kullanarak spektrumu yatay ve dikey parçalara ayırır (Şekil 2.3). İkinci blok ise bir kırpma operatörüdür ve imge piksellerinin yeniden düzenlenmesine yarar.

LP ve YFB'yi elde ettikten sonra bunları birleřtirerek Őekil 2.3'teki yapıda bir alt-bant dizisi oluřturulur ve bu dizinin bant geęirgen paręaları contourlet d6n6ř6m6n6n ęıktıları olur.

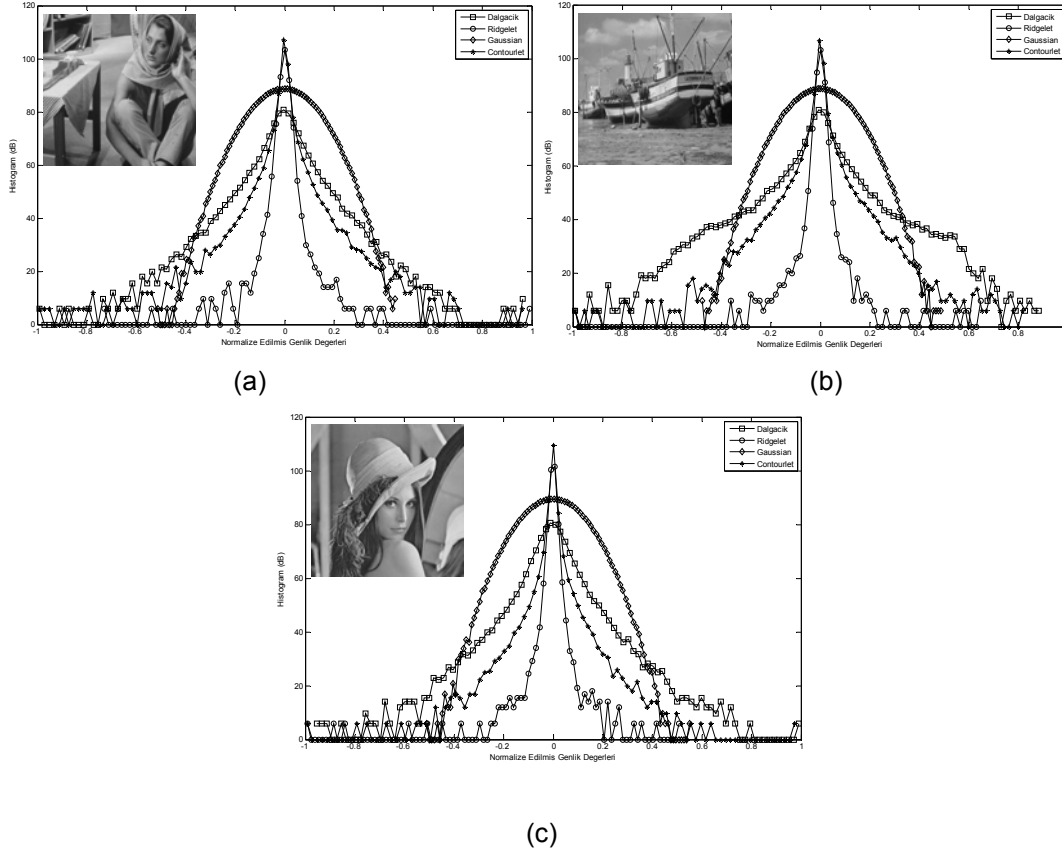
3. İstatistiksel Model

İmgeleri çözümlmek, sıkıştırmak ve kodlamak, imgedeki gürültüyü ayırmak ve imgedeki doku bilgisini sentezlemek gibi işlemler için uzaysal konum, yönelim ve ölçekle sabitlenmiş kaynak işlevlerini (örn. dalgacık, ridgelet veya contourlet dönüşümleri) kullanmak çok sıklıkla karşılaşılan bir yöntem haline gelmektedir. Bu tür çözümlmeler istatistiksel düzenlilikler getirmektedir ve bu düzenlilikler yukarıdaki yöntemlerin özellikle aradıkları niteliklerdir.

Dalgacık alt bant katsayıları, doğal imgeler için genelleştirilmiş Laplacian dağılımına benzer karakteristikler (Şekil 3.1(a), (b) ve (c)) gösterir [123]. Ridgelet dönüşümü radon bölgesinde bir imgeye dalgacık dönüşümü uygulanmasıyla elde edilir. Bu nedenle, aynı özniteliklerin ridgelet bölgesinde de korunacağı söylenebilir (Şekil 3.1(a), (b) ve (c)). Aynı şekilde Contourlet dönüşümü de dalgacık dönüşümü kullanılarak hesaplanmaktadır. Şekil 3.2(a), (b) ve (c)'de verilen imgelerin sırasıyla dalgacık (Şekil 3.3(a), (b) ve (c)), ridgelet (Şekil 3.4(a), (b) ve (c)) ve contourlet dönüşümleri ((Şekil 3.5(a), (b) ve (c))) alındığında her bir alt-bantın aslında birbiriyle ilişkisi belirgin bir şekilde gözükmemektedir. Şekil 3.2(a)'da verilen noktasal bölge dönüşümün nokta dağılım fonksiyonunu (Şekil 3.6) göstermekte başarılı olabilecek bir kaynaktır. Şekil 3.2(b) de verilen çarpı şekli ise köşelerin çakışması durumundaki özellikleri ortaya çıkaracaktır. Şekil 3.2(c)'de ise tam dairesel bir yapı kullanılarak bir eğrinin dönüşüm uzayındaki karakteristiğini göstermesi beklenmektedir. Elde edilen görsel sonuçlardan da gözlemlenebileceği gibi, belirli katsayıların birbirleriyle ilintili olduğu aşıkardır. İlk bakışta göze çarpan her bir bandın bir kaba bantla ilişkisidir. Her bir bantta bir önceki bandı tekrar eden bir yapı mevcuttur. Aynı şekilde Şekil 3.5(b)'den gözlemlenebileceği gibi her bir alt-bant da birbiriyle ilintili gözükmemektedir. Fakat, bu ilintilerin ne kadar kuvvetli olduğu, istatistiksel model için eklenmesi düşünülen iki katsayının ne kadar birbirine bağımlı olduğu konusu incelenmesi gereken bir başlıktır.

İmge işlemede sıklıkla kullanılan Boat, Barbara ve Lena imgeleri üzerinde dönüşümler alınıp katsayılar üzerinde histogramlarını hesapladığımızda Şekil 3.1'da görülebileceği gibi her dönüşümün de benzer şekilde genelleştirilmiş Laplacian özellikleri gösterdiği gözlemlenmektedir. Dalgacık dönüşümüne benzer

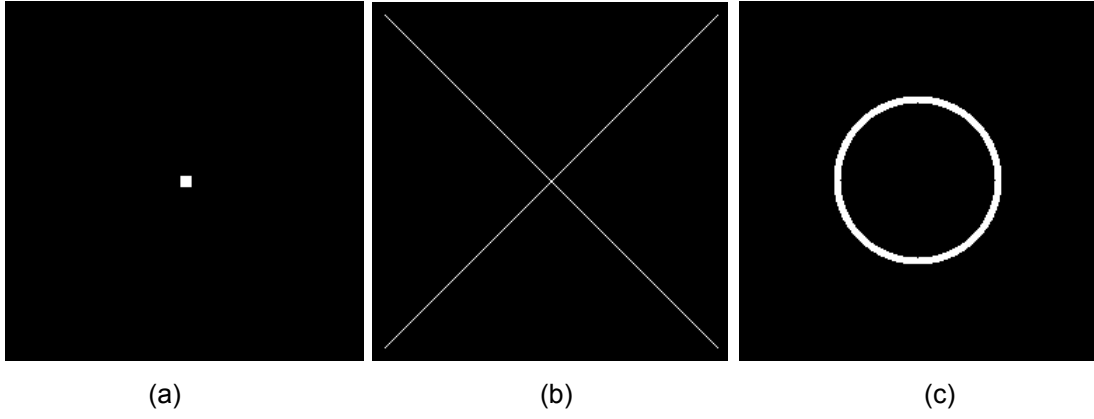
olarak Ridgelet ve Contourlet dönüşümleri için daha belirgin bir şekilde genelleştirilmiş Laplacian'a benzedikleri söylenebilir. Ridgeletler Laplacian yapıya daha yakın bir yapı gösterse de yine de genelleştirilmiş Laplacian yapıda kalmaktadır.




Şekil 3.1 – (a) Boat imgesi, (b) Barbara imgesi, (c) Lena imgesi için Dalgacık, Ridgelet ve Contourlet dönüşümlerindeki normalize edilmiş katsayıların histogramı.

Bu tür dağılımlar, sıfırda keskin tepeleri ve büyük simetrik kuyrukları olması gibi genel bir karakteristiğe sahiptir. Bu karakteristiği sezgisel olarak doğal imgelerin tipik olarak büyük yumuşak geçişli bölgeleri ve hızlı geçiş bölgeleri (örn. köşeler, kenarlar) içermesiyle açıklayabiliriz. Hızlı geçişlerle alakalı olan katsayılar büyük değerler verecektir (Şekil 3.3 ve 3.5). Diğer taraftan, yumuşak geçişli bölgelerle ilgili katsayılar sıfıra yakın çıkacaktır. Dönüşümler arasındaki istatistiksel benzerlikler, dalgacık dönüşümü ile elde edilen sonuçlardaki başarımlarla bir arada düşünüldüğünde, contourlet dönüşümü için de modelin başarılı olacağını düşündürmektedir. Ridgelet dönüşümü katsayıları doğrudan imgenin görsel bir imzasını taşımasa da bazı istatistiksel benzerlikleri beraberinde taşımaktadır. Bu


çalışmada, genelleştirilmiş Laplacian karakteristiklere dikkati yöneltmek yerine, imge istatistiği için basit bir ölçü olarak ilk dört dereceli istatistikler (ortalama, sapma, kurtosis, çarpıklık) hesaplanmıştır. Bu istatistikler her renk kanalı ve alt bant için ayrı ayrı bulunmuştur. İstatistiksel modelimizin ilk yarısını bu istatistikler oluşturmaktadır.



Şekil 3.2 –(a) Noktasal imge, (b) Çapraz imge, (c) Daire imge.



Şekil 3.3 –(a) Noktasal imge, (b) Çapraz imge, (c) Daire imge için dalgacık dönüşümü katsayıları.



Şekil 3.4 – (a) Noktasal imge, (b) Çapraz imge, (c) Daire imge için ridgelet dönüşümü katsayıları (log uzayında).


3.1. Dalgacık Dönüşümü

Dalgacık dönüşümü için [95] ve [1]'de oluşturulan istatistiksel model (*i*'inci yeşil kanal katsayılarının her üç yön için tüm mümkün uzamsal, ölçek ve renk komşularından oluşan alt kümedeki genlik tahmini) aşağıdaki gibidir (Şekil 3.7):

$$\begin{aligned}
 |H_i^g(x, y)| = & w_1 |H_i^g(x-1, y)| + w_2 |H_i^g(x+1, y)| \\
 & + w_3 |H_i^g(x, y-1)| + w_4 |H_i^g(x, y+1)| \\
 & + w_5 |D_i^g(x/2, y/2)| + w_6 |D_i^g(x, y)| \\
 & + w_7 |H_{i+1}^g(x/2, y/2)| + w_8 |H_i^r(x, y)| \\
 & + w_9 |H_i^b(x, y)|
 \end{aligned} \tag{3.1a}$$

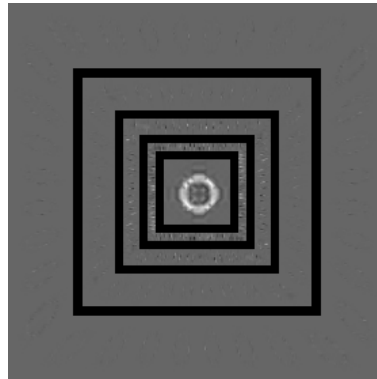
$$\begin{aligned}
|V_i^g(x, y)| &= w_1 |V_i^g(x-1, y)| + w_2 |V_i^g(x+1, y)| \\
&+ w_3 |V_i^g(x, y-1)| + w_4 |V_i^g(x, y+1)| \\
&+ w_5 |D_i^g(x/2, y/2)| + w_6 |D_i^g(x, y)| \\
&+ w_7 |V_{i+1}^g(x/2, y/2)| + w_8 |V_i^r(x, y)| \\
&+ w_9 |V_i^b(x, y)|
\end{aligned} \tag{3.1b}$$

$$\begin{aligned}
|D_i^g(x, y)| &= w_1 |D_i^g(x-1, y)| + w_2 |D_i^g(x+1, y)| \\
&+ w_3 |D_i^g(x, y-1)| + w_4 |D_i^g(x, y+1)| \\
&+ w_5 |H_i^g(x, y)| + w_6 |V_i^g(x, y)| \\
&+ w_7 |D_{i+1}^g(x/2, y/2)| + w_8 |D_i^r(x, y)| \\
&+ w_9 |D_i^b(x, y)|
\end{aligned} \tag{3.1c}$$




(a)

(b)




(c)

Şekil 3.5 – (a) Noktasal imge, (b) Çapraz imge, (c) Daire imge için contourlet dönüşümü katsayıları.



Şekil 3.6 –Şekil 3.2(a)'daki noktasal kaynak için en iyi banttaki yatay contourlet altbantları.


	Horizontal	Horizontal	$\square C_k$ Horizontal
Vertical	Diagonal	$\square P$ Diagonal	
Vertical			$\square N_{i,j}$ Diagonal
Vertical			

Şekil 3.7 –Dalgacık dönüşümü veri yapısı

Burada, H , V ve D yatay, dikey ve diyagonal yönelimleri ifade ederken, i alt-bant numarasını, r , g ve b değerleri sırasıyla kırmızı, yeşil ve mavi renk kanalları ifade etmek için kullanılmıştır. w_k değerleri ise skaler ağırlıkları ifade eder.

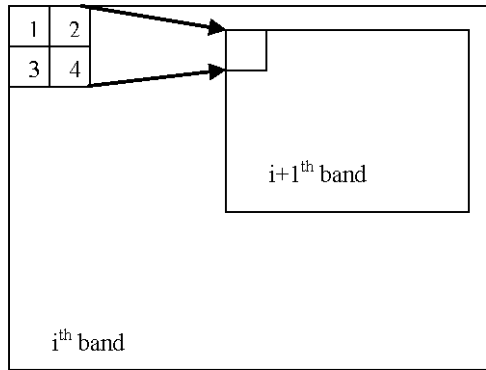
3.2. Contourlet Dönüşümü

Bu çalışmada, contourlet katsayısının genlik değeri X_c için aşağıdaki gibi bir terminoloji kullanacağız (Şekil 3.8):



Şekil 3.8 –Contourlet dönüşümü veri yapısı

- $i, j \in \{-4, -3, \dots, 3, 4\}$ olmak üzere, $N_{i,j}^c$ X_c 'nin aynı bant, aynı renk kanalı ve aynı alt-banttaki komşularının genlik değerlerini ifade etmekte ve $N_{0,0}^c$ X_c 'nin kendisine denk düşmektedir. Burada, i ve j X_c katsayısından x veya y yönündeki uzaklığı ifade eder. Çalışmalar göstermiştir ki, contourlet katsayıları için seçilecek komşu katsayılar katsayının etrafındaki 9x9 bölgeden belirlenmektedir.
- C_k^c X_c 'nin aynı bant, aynı renk kanalı fakat farklı alt-banttaki kuzenlerinin genlik değerlerini ifade etmekte ve k alt-bant numarasını göstermektedir.
- P^c X_c 'nin aynı renk kanalı, aynı alt-bant fakat farklı banttaki atalarının genlik değerlerini ifade etmektedir.



Şekil 3.9 – Bir bant seviyesi farkı için indisleme

Çizelge 3.1 - Bir contourlet katsayısı ile komşuları arasındaki ilinti katsayıları

$\times 10^{-2}$	$N_{x,-4}^c$	$N_{x,-3}^c$	$N_{x,-2}^c$	$N_{x,-1}^c$	$N_{x,0}^c$	$N_{x,1}^c$	$N_{x,2}^c$	$N_{x,3}^c$	$N_{x,4}^c$
$N_{-4,x}^c$	64.54	65.36	66.10	66.81	67.59	66.95	66.28	65.44	64.66
$N_{-3,x}^c$	65.88	66.34	67.27	67.80	68.68	67.89	67.26	66.42	65.67
$N_{-2,x}^c$	67.36	68.83	68.87	69.80	70.19	69.55	68.55	67.75	66.83
$N_{-1,x}^c$	65.84	73.60	72.85	71.37	73.98	71.27	71.30	69.31	68.89
$N_{0,x}^c$	79.50	79.92	85.25	78.98		78.98	85.25	79.92	79.50
$N_{1,x}^c$	68.89	69.31	71.30	71.27	73.98	71.37	72.85	73.60	65.84
$N_{2,x}^c$	66.83	67.75	68.55	69.55	70.19	69.80	68.87	68.83	67.36
$N_{3,x}^c$	65.67	66.42	67.26	67.89	68.68	67.80	67.27	66.34	65.88
$N_{4,x}^c$	64.66	65.44	66.28	66.95	67.59	66.81	66.10	65.36	64.54

Bu çalışmada, katsayılar arasındaki ilişki ilinti katsayıları aracılığıyla elde edilmektedir. İlk aşamada, bütün renk kanalları, bütün bantlar ve bütün alt-bantlar arasındaki çapraz-ilintiler hesaplanmış ve bu hesaplamalar şu şekilde yapılmıştır:

Aynı bant içerisindeki her alt-bant eşit sayıda katsayı içermektedir. Bir kaba banttaki katsayı miktarı varolan banttaki katsayı miktarının dörtte biri kadar (her iki yönde de katsayılar yarısı kadar) olur (Şekil 3.9). Bu nedenle, $x[n_1, n_2]$ ve $y[n_1, n_2]$ alt-bant katsayılarını göstermek üzere, herhangi iki banttan seçilmiş iki alt-bant arasındaki normalize edilmiş ilinti katsayılarını hesaplamak için aşağıdaki gibi bir normalizasyon ve alt-örnekleme uygulanır:

$$x_n^c[n_1, n_2] = \frac{x[n_1, n_2]}{|x[n_1, n_2]|} \quad (3.2)$$

$$y_n^c[n_1, n_2] = \frac{y \left[\left[\frac{n_1}{2^{l_x - l_y}} \right], \left[\frac{n_2}{2^{l_x - l_y}} \right] \right]}{\left| y \left[\left[\frac{n_1}{2^{l_x - l_y}} \right], \left[\frac{n_2}{2^{l_x - l_y}} \right] \right] \right|}. \quad (3.3)$$

Burada, l_x ve l_y , x ve y sinyallerinin seviye numaralarıdır.

Elde edilen $x_n^c[n_1, n_2]$ ve $y_n^c[n_1, n_2]$ katsayıları bir boyutlu diziler haline getirilecek olursa ($x_p^c[n]$ ve $y_p^c[n]$), aşağıdaki gibi bir ilinti dizisi tanımlanabilir:

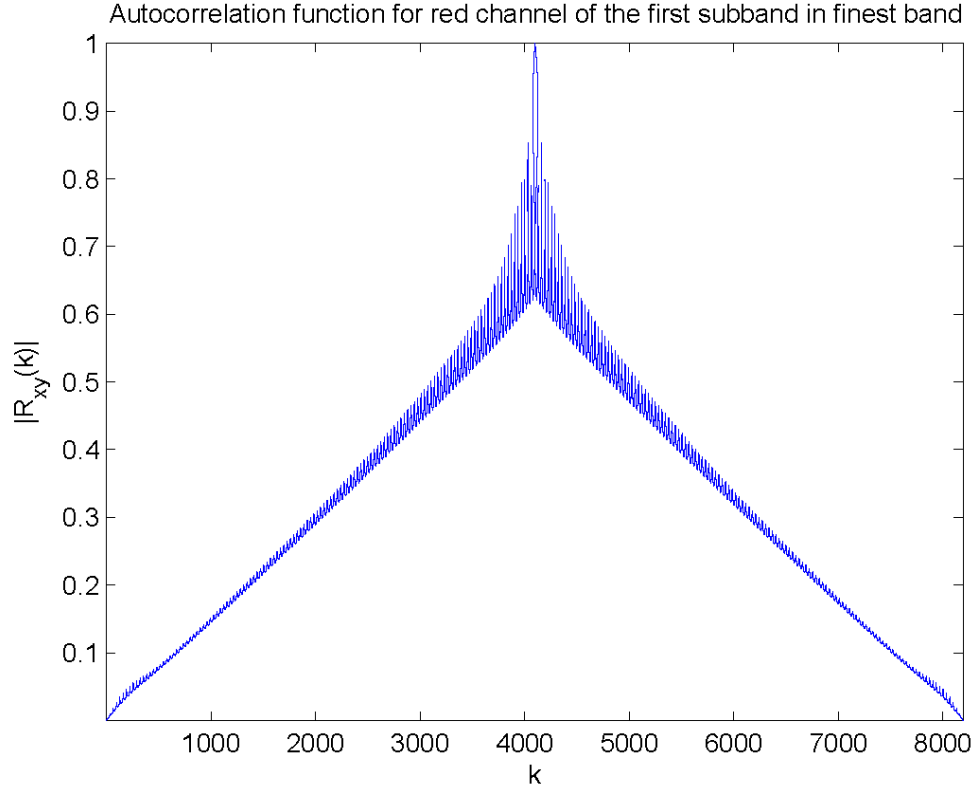
$$R_{xy}^c(k) = \sum_{n=-M \cdot N}^{M \cdot N} x_p^c[n] \cdot y_p^c[n+k]. \quad (3.4)$$

En iyi banttaki birinci alt-bant ve kırmızı renk kanalı için, bir contourlet katsayısı X_c (merkez katsayısı $N_{0,0}^c$) ile komşuları $N_{i,j}^c$ arasındaki 9×9 komşuluklar Çizelge 3.1'de verilmiştir. Kullanılan ilinti katsayıları, 1000 imge üzerinde hesaplanan değerlerin ortalamasından elde edilmiştir. Sonuçlar göstermektedir ki X_c ile en ilintili katsayılar belirtilen alt bant için $N_{-2,0}^c$ ve $N_{2,0}^c$ olmaktadır. İmgelerin enerjileri eşit olmadığından, daha önce belirtilen normalizasyon süreci işletilmiştir. Böylelikle, ilinti katsayıları $[-1, 1]$ aralığında olur. Şekil 3.10'da en iyi banttaki birinci alt-bant kırmızı renk kanalı için öz-ilinti katsayıları gösterilmiştir. İlinti verisi ile katsayı konumları arasındaki ilişkiyi göstermek amacıyla, Şekil 3.11'de daha yakın bir görünüm verilmiştir.

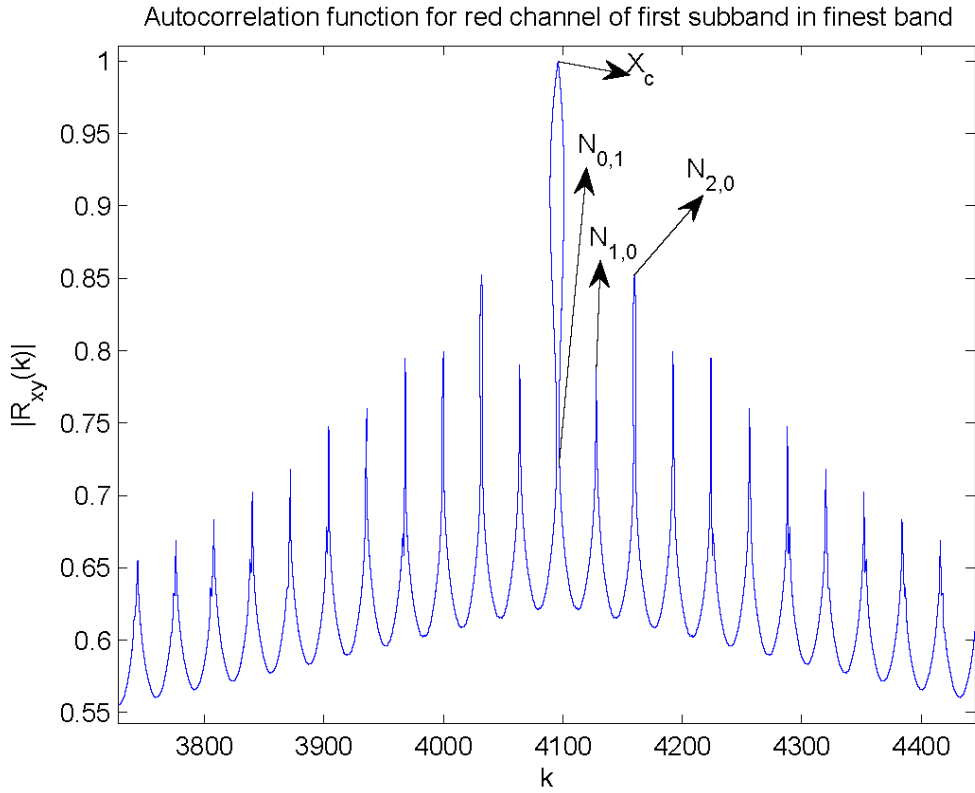
3.2.1. Contourlet katsayıları arası ilintilerin belirlenmesi

Hesaplanan ilintiler azalan sırada sıralanmıştır. Bu sıralanmış değerler eldeki katsayı ile hangi katsayının en çok ilintili olduğunu belirlemede kullanılmıştır. En ilintili katsayıdan başlayarak, en çok ilintili katsayılar kullanılarak i'inci basamakta X_c değerleri aşağıdaki formül ile kestirilmiştir:


$$x_{est,i}^c = G_{c,i} \left(G_{c,i}^T \cdot G_{c,i} \right)^{-1} G_{c,i}^T x \quad (3.5)$$



Şekil 3.10 – En iyi banttaki birinci alt-bant kırmızı renk kanalı için özilinti katsayıları



Şekil 3.11 – İlinti verisine yakından bir bakış



Şekil 3.12 – Contourlet dönüşümüne dayalı yöntem için alt-bant içi arama sonucu ilinti gelişimi


Burada, x varolan katsayıların genlikleri dizisini, $G_{c,i}$ ise ilişkili ilinti katsayısından seçilen contourlet katsayılarının genliklerinin bir dizi haline getirilmiş halini ifade etmektedir. Kestirim ile orijinal katsayı arasındaki ilinti katsayısı şu şekilde hesaplanmaktadır:

$$R_i^c = \sum_{k=1}^P x_{est,i}^c(k) \cdot x(k). \quad (3.6)$$

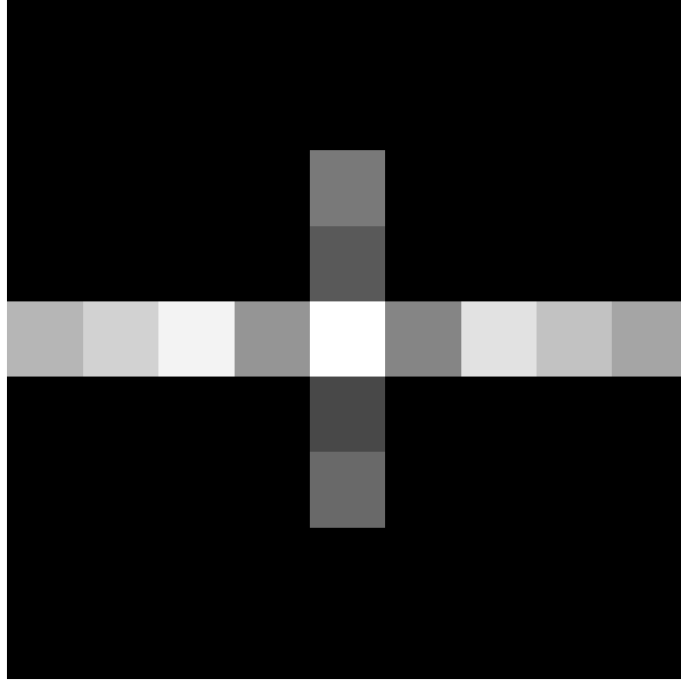
Eğer, tahmin edilen katsayı ile orijinal katsayı arasındaki ilinti %0.5'ten büyük ($R_i^c - R_{i-1}^c > 0.005$) ise, yeni katsayı orijinal katsayıyı tahmin etmekte kullanılabilir demektir. Aksi takdirde, katsayı kümeye eklenmeden yeni bir katsayı ilinti katsayıları aracılığıyla seçilir ve işleme devam edilir. Süreç $R_i^c - R_{i-1}^c < 0.0001$ olana kadar alt-bant içerisinde devam ettirilir. Bu süreç ilk olarak bütün alt-bantlarda (katsayının kendi alt-bandından başlayarak) daha sonra bir kaba banttaki alt-bantlarda ve son olarak diğer renk kanalları için tekrarlanır. Sonuçların değişkenliğini azaltmak için 100 imge üzerinden bu süreç işletilmiştir. Şekil 3.12'de en iyi bandın ilk alt-bandının kırmızı renk kanalı için alt-bant içi arama sonuçları

verilmiştir. Sonuçlara bakarak contourlet katsayıları yatay alt-bantlar için -4 ve +4 yatay komşuluklarla ilintili çıkarken, düşey alt-bantlar için aynı ilişki düşey komşuluklarda olmaktadır.

Alt-bant içi ilintilerin gelişimini daha iyi gösterebilmek için, hem düşey hem de yatay -4 ve +4 komşulukların hepsi hesaplama katılarak merkez katsayısının tahmini yapılmıştır. Çizelge 3.2'de verilen ve en iyi bantta ilk alt-bant kırmızı renk kanalı için olan katsayılar azalan sırada sıralanmış ve ilgili katsayılar herhangi bir kurala bağlı olmadan sırasıyla $G_{c,i}$ matrisine yeni bir kolon olarak eklenmiştir. Sonra, merkez katsayısı ile tahmin arasındaki ilinti katsayısı hesaplanmıştır. 9x9 komşuluk içinde kalan katsayıların eklenmesiyle oluşan ilinti gelişimi Şekil 3.13'te verilmiştir. Derinlemesine bir aramadan sonra, X_c ile X_c 'nin tahmini arasındaki ilintiyi istenilen koşullarda en iyi yapan katsayılar bulunmuştur. Şekil 3.14'te, bulunan katsayılar arama sırasında bulunma sırasına göre aydınlıktan karanlığa doğru işaretlenmiştir. Beyaz renk merkez katsayıyı ifade ederken siyah ise tamamen ilintisiz olarak işaretlenen katsayıları göstermektedir.



Şekil 3.13 – Contourlet dönüşümüne dayalı yöntem için bütün 9x9 komşular eklendiğinde ilinti gelişimi




Şekil 3.14 – Arama sonuçlarına bağlı ilişki haritası

Çizelge 3.2 – Renk kanalları arasındaki ilinti değerleri

	$\times 10^{-2}$	Kırmızı	Yeşil	Mavi
Bant 1 Alt-Bant 1	Kırmızı	100	97.40	94.38
	Yeşil	97.40	100	95.67
	Mavi	94.38	95.67	100
Bant 1 Alt-Bant 2	Kırmızı	100	97.58	94.95
	Yeşil	97.58	100	96.52
	Mavi	94.95	96.52	100
Bant 2 Alt-Bant 1	Kırmızı	100	98.52	96.57
	Yeşil	98.52	100	98.20
	Mavi	96.57	98.20	100

İkinci olarak, alt-bantlar arası ilintilerin etkileri bir bant içerisinde araştırılmıştır. Aynı kesim değeri (0.005) kullanılarak, kesim değerini aşan tahmin-oriijinal değer arası ilintilere bakılmıştır. Bununla birlikte, farklı alt-bantlardaki hiç bir katsayının ilintiyi yeterince geliştirmedeği gözlemlenmiştir. Burada, alt-bant içi katsayıların eklenmesi sonucunda, diğer alt-bantların ekleyebileceği bir katkı bırakmadığı söylenebilir.



Şekil 3.15 – Arama sonuçları boyunca elde edilen katsayılar için ilinti katsayısı gelişimi

Daha sonra, renk kanalları arası ilintiler incelenmiştir. Eşitlik 3.2 ve 3.3'ten elde edilen veri üzerinde dikkatimizi topladığımızda, belirli bir contourlet katsayısı ile en çok ilintili olan katsayılar aynı konumdaki ve diğer renk kanallarında olan katsayılardır. Çizelge 3.2'de farklı bantlardaki bazı alt-bantların renk kanalları arasındaki ilinti katsayısı değerleri gösterilmiştir.

Son aşamada, bantlar arası ilintiler incelenmiştir. Bir kaba bant ilinti gelişimi için incelenmiştir. Bu arama sırasında, renk kanalları arası ilintiler göz önüne alınmamış ve bu arama sonucu çıkan katsayılar işleme katılmamıştır. Renk kanalları arası ilintiler aracılığıyla elde edilen katsayılar, sonuçları çok hızlı bir şekilde geliştirirken diğer pek çok katsayının etkisini de azaltmaktadır. Buna ek olarak, gri-ölçekli bir imgede renk kanallarından bahsedilemeyeceği için renk kanalları olmadan da başarımın önemini görmek gerekmektedir. Son olarak, elde edilen katsayılar tekrar sırasıyla eklenerek son durumdaki ilinti gelişimleri çıkarılmıştır. Şekil 3.15'te bu gelişim en iyi banttaki ilk alt-bantın kırmızı renk kanalı için verilmiştir.

Yapılan tahmin ile hedeflenen katsayı arasındaki ilinti katsayısının hesaplanmasında bir önceki basamağa göre bir gelişme görülmemesi durumunda bu yeni eklenen katsayının daha önce belirlenen katsayılar ile doğrusal bağımlı olduğu söylenebilir. Q boyutlu bir uzaydaki bir vektörü Q boyutlu R adet vektör ile ifade etmeye çalıştığımızda o vektörün içinde bulunduğu alt-uzayı ne kadar kapsayabildiğimiz elimizdeki R adet vektörün birbirinden ne kadar doğrusal bağımsız olduğuna bağlıdır. Eklenecek R+1'inci vektör eğer öncekilerle doğrusal bağımlı ise, kapsayacağımız alt uzay yine R boyutlu olacaktır.

3.3. Ridgelet Dönüşümü


Bu çalışmada, ridgelet katsayısının genliği X_r için aşağıdaki gibi bir terminoloji kullanacağız (Şekil 3.16):

- $i, j \in \{\dots, -2, -1, 1, 2, \dots\}$ olmak üzere, N_i^r X_r 'nin aynı bant, aynı renk kanalı ve aynı alt-banttaki komşularının genliklerini ifade etmektedir. Burada, i X_r katsayısından uzaklığı ifade eder.
- $C_{k,i}^r$ X_r 'nin aynı bant, aynı renk kanalı fakat farklı alt-banttaki kuzenlerinin genliklerini ifade etmekte ve k alt-bant numarasını göstermektedir.
- P^r X_r 'nin aynı renk kanalı, aynı alt-bant fakat farklı banttaki atalarının genliklerini ifade etmektedir.

Bu çalışmada, katsayılar arasındaki ilişki ilinti katsayıları aracılığıyla elde edilmektedir. İlk aşamada, bütün renk kanalları, bütün bantlar ve bütün alt-bantlar arasındaki çapraz-ilintiler hesaplanmış ve bu hesaplamalar şu şekilde yapılmıştır:

Aynı bant içerisindeki her alt-bant eşit sayıda katsayı içermektedir. Bir kötü banttaki katsayı miktarı varolan banttaki katsayı miktarının yarısı kadar (yön sayısı sabit) olur (Şekil 3.16). Bu nedenle, $x[n_1, k]$ ve $y[n_1, k]$ bant katsayılarını göstermek üzere, herhangi iki bant arasındaki normalize edilmiş iki boyutlu ilinti katsayılarını hesaplamak için aşağıdaki gibi bir normalizasyon ve alt-örnekleme uygulanır:

$$x_n^r[n_1, k] = \frac{x[n_1, k]}{|x[n_1, k]|} \quad (3.7)$$



Şekil 3.16 – Ridgelet dönüşümü veri yapısı

$$y_n^r [n_1, k] = \frac{y \left[\left[\frac{n_1}{2^{l_x - l_y}} \right], k \right]}{\left| y \left[\left[\frac{n_1}{2^{l_x - l_y}} \right], k \right] \right|}. \quad (3.8)$$

Burada, l_x ve l_y , x ve y sinyallerinin seviye numaraları, n_1 bir alt-bant içindeki katsayının indisi ve k ise daha önce de belirtildiği gibi alt-bant numarasıdır. Ridgelet dönüşümünde alt-bantlar bir boyutlu sinyaller oldukları için her alt-bant arasındaki bir boyutlu ilintileri hesaplamak yerine, bantlar arasındaki iki boyutlu ilintileri hesaplamayı seçtik. İki boyutlu ilintiler şu şekilde hesaplanmıştır:

$$R_{xy}^r(k_1, k_2) = \sum_{n_1=0}^{P+1} \sum_{k=0}^K x_n^r [n_1, k] y_n^r [n_1 + k_1, k + k_2]. \quad (3.9)$$

En iyi banttaki kırmızı renk kanalı için, bir ridgelet katsayısı X_r ile komşuları N_i^r ve kuzenleri $C_{k,i}^r$ arasındaki 13x5 komşuluklar Çizelge 3.3'te verilmiştir. İlinti katsayıları 1000 imge üzerinden ortalama olarak hesaplanmıştır. Sonuçlar göstermektedir ki X_r ile en ilintili katsayılar belirtilen alt bant için N_{-6}^r ve N_6^r olmaktadır. İmgelerin enerjileri eşit olmadığından, daha önce belirtilen

normalizasyon süreci işletilmiştir. Böylelikle, ilinti katsayıları [-1,1] aralığında olur. Şekil 3.17’de en iyi bant kırmızı renk kanalı için öz-ilinti katsayıları gösterilmiştir.


Çizelge 3.3 – Renk kanalları arasındaki ilinti değerleri (Contourlet dönüşümü)

$\times 10^{-2}$	$C_{k-2,i}^r$	$C_{k-1,i}^r$		$C_{k+1,i}^r$	$C_{k+2,i}^r$
N_{-6}^r	0.3266	0.0781	16.8964	0.1364	0.0925
N_{-5}^r	0.0236	0.0327	2.0105	0.1192	0.1306
N_{-4}^r	0.0241	0.0155	4.3019	0.0464	0.1758
N_{-3}^r	0.2603	0.0139	10.8350	0.0207	0.0644
N_{-2}^r	0.1729	0.0233	2.1825	0.0113	0.0918
N_{-1}^r	0.1981	0.0713	6.2106	0.0724	0.0071
	0.1127	0.0351		0.0351	0.1127
N_1^r	0.0071	0.0724	6.2106	0.0713	0.1981
N_2^r	0.0918	0.0113	2.1825	0.0233	0.1729
N_3^r	0.0644	0.0207	10.8350	0.0139	0.2603
N_4^r	0.1758	0.0464	4.3019	0.0155	0.0241
N_5^r	0.1306	0.1192	2.0105	0.0327	0.0236
N_6^r	0.0925	0.1364	16.8964	0.0781	0.3266


3.3.1. Ridgelet katsayıları için ilintilerin belirlenmesi

Hesaplanan ilintiler azalan sırada sıralanmıştır. Bu sıralanmış değerler eldeki katsayı ile hangi katsayının en çok ilintili olduğunu belirlemede kullanılmıştır. En ilintili katsayıdan başlayarak, en çok ilintili katsayılar kullanılarak i’inci basamakta X_r değerleri aşağıdaki formül ile kestirilmiştir:


$$x_{est,i}^r = G_{r,i} \left(G_{r,i}^T \cdot G_{r,i} \right)^{-1} G_{r,i}^T x \quad (3.10)$$



Şekil 3.17 – En iyi bant kırmızı kanal için, iki boyutlu öz ilinti fonksiyonu (etkilerin daha iyi gözükmesi için çok daha büyük olan merkez değeri sıfırlanmıştır)



Şekil 3.18 – En iyi bant kırmızı renk kanalı için bant ilişki haritası



Şekil 3.19 – En iyi bant kırmızı renk kanalı için ilintideki gelişim

Burada, x varolan katsayılar dizisini, $G_{r,i}$ ise ilişkili ilinti katsayısından seçilen contourlet katsayılarının bir dizi haline getirilmiş halini ifade etmektedir. Tahmin ile orijinal katsayı arasındaki ilinti katsayısı şu şekilde hesaplanmaktadır:

$$R_i^r = \sum_{k=1}^P x_{est,i}^r(k) \cdot x(k). \quad (3.11)$$

Eğer, tahmin edilen katsayı ile orijinal katsayı arasındaki ilinti %0.5'ten büyük ($R_i^r - R_{i-1}^r > 0.005$) ise, yeni katsayı orijinal katsayıyı tahmin etmekte kullanılabilir demektir. Aksi takdirde, katsayı boş verilerek yeni bir katsayı ilinti katsayıları aracılığıyla seçilir ve işleme devam edilir. Süreç $R_i^r - R_{i-1}^r < 0.0001$ olana kadar alt-bant içerisinde devam ettirilir. Bu süreç ilk olarak bütün alt-bantlarda (katsayının kendi alt-bandından başlayarak) daha sonra bir kötü banttaki alt-bantlarda ve son olarak diğer renk kanalları için tekrarlanır. Sonuçların değişkenliğini azaltmak için 100 imge üzerinden bu süreç işletilmiştir. Sonuçlara bakarak ridgelet katsayıları alt-bant içinde -6 ve +6 komşuluklarla ilintili çıkarken, aynı zamanda bant içinde de kendisine 90° derece uzaklıkta olan kuzeni ile ilintili çıkmaktadır (Şekil 3.18).

Daha sonra, renk kanalları arası ilintiler incelenmiştir. Eşitlik 3.7 ve 3.8'den elde edilen veri üzerinde dikkatimizi topladığımızda, belirli bir ridgelet katsayısı ile en çok ilintili olan katsayılar aynı konumdaki ve diğer renk kanallarında olan katsayılardır.

Son aşamada, bantlar arası ilintiler incelenmiştir. Bir kaba bant ilinti gelişimi için incelenmiştir. Bu arama sırasında, renk kanalları arası ilintiler göz önüne alınmamış ve bu arama sonucu çıkan katsayılar işleme katılmamıştır. Renk kanalları arası ilintiler aracılığıyla elde edilen katsayılar, sonuçları çok hızlı bir şekilde geliştirirken diğer pek çok katsayının etkisini de azaltmaktadır. Buna ek olarak, gri-ölçekli bir imgede renk kanallarından bahsedilemeyeceği için renk kanalları olmadan da başarımın önemini görmek gerekmektedir. Son olarak, elde edilen katsayılar tekrar sırasıyla eklenerek son durumdaki ilinti gelişimleri çıkarılmıştır. Şekil 3.19'da bu gelişim en iyi banttaki ilk alt-bantın kırmızı renk kanalı için verilmiştir.

3.4.Öznitelik Çıkarımı

Ridgelet ve contourlet katsayıları için birer istatistiksel modele karar verdikten sonra, Farid v.d..'ın [1] kullandığı yöntemeye uygun bir şekilde bir öznitelik çıkarma metodolojisi uygulanmıştır. Contourlet dönüşümü için her bir alt-bantta ve ridgelet dönüşümü için her bir bantta 8 istatistiksel öznitelik iki grupta hesaplanmıştır. İlk grup, katsayıların doğrudan kendilerinden elde edilirken, ikinci grup katsayılar ise modeller ile yapılan kestirimleri arasındaki hata üzerinden elde edilmektedir.

İlk grupta, katsayıların ilk ve daha yüksek dereceli istatistikleri (ortalama, varyans, skewness ve kurtosis) hesaplanmıştır. İkinci grupta ise, benzer bir şekilde, bu istatistikler elde edilen hata üzerinden hesaplanmıştır. Kestirimler aşağıdaki formüle bağlı kalınarak hesaplanmıştır:

$$x_{est}^m = G_m \left(G_m^T \cdot G_m \right)^{-1} G_m^T x \quad (3.12)$$

Burada, x katsayıların genliklerinin sütun halinde dizilmiş halleri, G_m istatistiksel modelden elde edilen ilişkili katsayı konumlarına denk düşen değerlerin sütun

halinde dizilmiş halleri ve x_{est}^m ise yapılan kestirim deęerlerini gstermektedir. Simoncelli *v.d.* [95] gstermiřtir ki dalgacık ddnüřümü katsayılarının genlikleri 1'den küçük olduęunda dięer katsayılarla iliřkileri bulanıklařmaya bařlamaktadır. Bu nedenle, Farid *v.d.* [1] alıřmasında 1'den küçük deęerleri göz ardı etmeyi semiřtir. Ridgelet ve contourletler için de benzer bir durum söz konusudur. Bu nedenle, aynı kesim deęeri bu alıřmada da korunmuřtur. İstatistiklerin üzerinden hesaplandıęı tahminle orijinal katsayı arasındaki log- genlik hatası řu řekilde hesaplanır:

$$E_{est} = \log_2(x) - \log_2(x_{est}) \quad (3.13)$$

4. Deneysel Sonular

4.1. Veri Kümeleri

4.1.1. Fotogereki ve Fotoğrafik İmge Veri Kumesi (CG-N)

Bu imge veri kumesinde 5000 adet fotogereki ve 5000 adet fotografik imge bulunmaktadır (Şekil 4.1). İmgeler üç kanallı (Kırmızı, Yeşil, Mavi) imgelerdir. Fotogereki imgeler, çeşitli websiteleri (örn. <http://www.cgw.com>, Stanford CG Group-<http://www-graphics.stanford.edu>, MIT Computer Graphics Group-<http://groups.csail.mit.edu/>, <http://artworks.avalonweb.net/>) üzerinden elde edilmiş olup gerçek imgelerle gözle ayırdedilmesi zor imgeler olmasına dikkat edilmiştir. İmgeler farklı çözünürlüklerde olmalarına rağmen genellikle 1 MP'den daha büyük seçilmiştir. Fotografik imgeler ise 4 farklı kişinin kişisel fotoğraflarından bir araya getirilmiştir. İmgeler 2MP ile 4 MP arası imgelerden oluşmaktadır. Her iki türe ait imgelerde doğa görüntülerinin yanında insan figürleri ve çeşitli nesne figürleri (örn. araba, meyve, v.b) de bulunmaktadır. Yapılan çalışmalarda bu imgelerin merkez 257x257x3 kesitleri kullanılmıştır.


4.1.2. İine Veri Gizlenmiş İmgeler Veri Kumesi (Stego)

Bu imge veri kumesinde iki tür orijinal veri gizlenmemiş imge kumesi bulunmaktadır. İlk orijinal veri kumesi 1000 ve ikinci orijinal veri kumesi 800 256x256 gri seviyeli imgeden oluşmaktadır. İlk imge veri kumesi kullanılarak Outguess-, Outguess+, F5, LSB algoritmaları ile içine veri gizlenmiş imgeler bulunan 4 farklı veri kumesi elde edilmiştir. Elde edilen her bir veri kumesi orijinaline eş olarak 1000'er imgeden oluşmaktadır.

İkinci orijinal veri kumesi Columbia imge veritabanından elde edilmiş JPEG imgelerdir. Bu imgelerin Perturbed Quantization (PQ) algoritması [115] kullanılarak içlerine veri saklanmış ve farklı kalite oranlarında (%70, %80, %90 ve %100) ikinci defa JPEG sıkıştırılmışlardır. Bu şekilde her bir kalite oranı için 800'er adet imge elde edilmiştir.



(a)



(b)

Şekil 4.1 – CG-N veri kümesinde kullanılan imgelere örnekler (a) Fotogerçekçi imgeler, (b) Fotoğrafik imgeler

4.1.3. Farklı Dijital Kameralar İçin İmge Veri Kümesi (Cam)

Bu imge veri kümesinde her bir kamera için üç kanallı $257 \times 257 \times 3$ imgeler kullanılmıştır. Kümedeki imgeler, üç farklı dijital kamera (Panasonic Lumix DMC-FZ8 (Lumix), Canon EOS 20D (EOS) ve Canon Powershot S1 IS (Powershot)) ile elde edilmiş yüksek çözünürlüklü imgeler parçalanarak elde edilmiştir. Lumix ve Powershot 7.2 MP imgeler çekerken, EOS 8 MP imgeler çekmektedir. Sonuçta her bir kamera için 2000'er adet imge elde edilmiştir.

4.1.4. Farklı Tarayıcılar İçin İmge Veri Kümesi (Scanner)

Bu imge veri kümesinde farklı tarayıcılar tarafından yüksek çözünürlüklü imgelerin parçalanmasından elde edilmiş üç kanallı $257 \times 257 \times 3$ imgeler bulunmaktadır. Kullanılan tarayıcılar sırasıyla iki adet HP1510, bir adet HP 1410, bir adet HP3030 ve bir adet HP3010'dur. Aynı model tarayıcılar için de birbirleri arasında ayırım yapılabildiğini göstermek amacıyla HP1510 modeli iki adet tarayıcı kullanılmıştır. Her bir tarayıcıdan elde edilen imgeler parçalandığında elde edilen imgelerden 50000 tanesi veri kümesinde kullanılmak üzere seçilmiştir. Böylelikle bu imge veri

kümesinde 5 tarayıcının her biri için 50000'er adet 257x257x3 imge bulunmaktadır.

4.1.5. Ünlü Ressamlar İçin İmge Veri Kümesi (Paint1)

Bu imge veri kümesinde 4 farklı ressam için yüksek çözünürlüklü imgelerden parçalanmış üç kanallı 257x257x3 imgeler kullanılmıştır. Bu kümede, tablolarının dijital imgeleri kullanılan ressamlar sırasıyla Leonardo DaVinci, Francisco Goya, Pierre Auguste Renoir ve Vincent VanGogh'tur. Her bir ressam için elde edilen 2MP ile 12 MP arası imgelerden parçalanan 257x257x3 imgelerden 1000'er adet bulunmaktadır. İmgeler Google İmge Arama Motoru üzerinden bulunmuştur.

4.1.6. Ressamlar İçin İmge Veri Kümesi (Paint2)

Bu imge veri kümesinde 4 farklı ressam için yüksek çözünürlüklü imgelerden parçalanmış üç kanallı 257x257x3 imgeler kullanılmıştır. Bu kümede, tablolarının dijital imgeleri kullanılan ressamlar sırasıyla Mustafa Ayaz, Gültekin Serbest, Nurhan Arca ve B. Taner Çoruh'tur. Her bir ressam için elde edilen 7.2MP ile 8 MP arası imgelerden parçalanan 257x257x3 imgelerden 1000'er adet bulunmaktadır. İmgeler sanat galerileri aracılığıyla özel ışıklandırma koşullarında benzer şekilde çekilmişlerdir.

4.1.7. Farklı Çözünürlüklü İmgeler İçin İmge Veri Kümesi (Resolution)

Bu imge veri kümesinde Vincent VanGogh'un tablolarının farklı çözünürlüklerdeki dijital kopyaları kullanılmıştır. İmgeler 257x257x3 parçalara bölünerek her bir çözünürlük için 1000'er adet imge oluşturulmuştur. Kullanılan çözünürlükler 0.3MP±0.01MP , 0.7MP±0.01MP, 1MP±0.01MP, 2MP±0.01MP, 4MP±0.01MP olarak seçilmiştir. İmgeler Google İmge Arama Motoru üzerinden bulunmuştur.

4.2. Dalgacık Tabanlı Dönüşümlerin Kullanımı

Bu çalışmada, dalgacık dönüşümleri için Dördül Ayna Filtre Bankaları (Quadrature Mirror Filterbanks-QMF) kullanılmıştır. Daha önceki yapılan çalışmalarda, QMF

filtrelerin başarımlarının diğerlerinden daha yüksek olduğu gözlemlendiğinden dolayı, dalgacık dönüşümüyle uygulanan yöntemin daha yüksek değerler verdiği yerlerdeki ridgelet dönüşümü ile uygulanan yöntemin sonuçlarını görmek amacıyla QMF üzerinde çalışılmaya devam edilmiştir [1]. Contourlet dönüşümü için tanımlanmış filtrelerin sınırlı sayıda olması nedeniyle, tanımlı filtreler içinden PKVA (Quincunx/Fan) filtreleri seçilmiştir. Bu filtrelerin tanımlanan filtreler arasında sıkıştırma yetisi açısından en başarılı olan olması [94] bu filtrenin kullanılmasındaki motivasyonun temel noktasıdır.

Dalgacık ve contourlet dönüşümleri uygulanan imgeler 256x256 olarak verilmiş, ridgeletler için 257x257 imgeler kullanılmıştır (257 bir asal sayıdır). Bu nedenle imge kümeleri oluşturulurken 257x257 imgeler oluşturulmuş ve bunların ilk 256x256 pikselleri dalgacık ve contourletler için kullanılırken imgelerin bütünü de ridgeletler için kullanılmıştır.

Bu çalışmalar dahilinde yapılması anlam ifade edecek bir başka benzetim de her üç dönüşümden elde edilen öznitelikleri birleştirerek aralarından en iyi öznitelikleri seçmektir. Böylelikle, hangi dönüşümün diğerlerine göre daha başarılı olduğu da bir noktaya kadar ortaya çıkacaktır. Bu amaçla, fotogerçekçi ve fotoğrafik imgelerden elde edilen öznitelikler birleştirilmiş ve ASA aracılığıyla aralarındaki en iyi 20 öznitelik seçilmiştir. Tablolarda *Karma* ile ifade edilen sonuçlar bu şekilde elde edilmiş sonuçlardır.

4.3. Bilgisayar Grafiği İmgelere Karşı Doğal İmgeler

Benzetimlerin yapılabilmesi için, **CG-N** kümesindeki 5.000 fotoğrafik ve 5.000 fotogerçekçi imge iki kümeye ayrılmıştır: 2.500 fotoğrafik ve 2.500 fotogerçekçi imge eğitim amaçlı ve geri kalan imgeler de test amaçlı olarak belirlenmiştir. Her iki küme için de öznitelikler elde edilmiş ve Destek Vektör Makineleri (DVM) kullanılarak her iki kümede de fotoğrafik ve fotogerçekçi imgeler sınıflandırılmıştır.

DVM, özniteliklerin sınıf içinde saçılımın en küçüklendiği ve sınıflar arasındaki saçılımın en çoklandığı bir alt uzayda izdüşümünü alır. Bu izdüşümü alırken kullandığı altuzayı seçerken Doğrusal Ayrıştırma Analizi'nden farklı olarak sınıflar

arasındaki ayrımı da en büyük tutmaya çalışır. Çizelge 4.1'de özetlenen sonuçlardan görülebileceği gibi, ridgelet ve contourlet dönüşümleri elde edilen istatistiksel model kullanılarak, dalgacık dönüşümünden daha az sayıda istatistiksel özniteliğe sahip olmasına rağmen daha iyi sonuçlar vermektedir. Burada, yanlış alarm oranı BG bir imgenin BG olarak belirlenememesi, hata oranı da doğal bir imgenin doğal bir imge olarak belirlenememesi durumundaki oranları ifade eder. Öngörüsül olarak, contourlet dönüşümünün en iyi sonucu vermesi beklenmektedir. Elde ettiğimiz sonuçlar da bunu destekler yapıdadır.

Özniteliklerin birbirinden doğrusal bağımsız olmaması durumu bu tür problemlerde sıkça karşılaşılan bir durumdur. Bu nedenle, belirli sayıda en iyi özniteliklerin seçilmesi çok daha doğru sonuçlar elde edilmesine yol açar. Ardışık Seyyar Arama (ASA) yöntemi [121] en iyi özniteliklerin bulunması için kullanılan yöntemlerden birisidir. Bu çalışmada DVM ve ASA bir araya getirilerek en iyi 20 öznitelik her bir dönüşümden elde edilen istatistiksel özniteliklerden ayrı ayrı elde edilmiştir. Çizelge 4.2'de DVM ve ASA'nın bir arada kullanılması ile elde edilen sonuçlar verilmiştir.

Çizelge 4.1 - Fotogerçekçi ve fotoğrafik imgeler için ASA kullanılmadan Dalgacık, Ridgelet ve Contourlet dönüşümleri kullanılarak yapılan sınıflandırma sonuçları. Gösterilenler eğitim ve test amaçlı olarak iki eşit parçaya ayrılmış 5.000 fotoğrafik ve 5.000 fotogerçekçi imge üzerindeki doğruluklardır.

Tüm Öznitelikler	Dalgacık	Ridgelet	Contourlet
Yanlış Alarm Oranı	5.48% (137)	5.12% (128)	3.68% (92)
Kayıp Oranı	4.44% (111)	3.96% (99)	3.56% (89)

Çizelge 4.2 - Fotogerçekçi ve fotoğrafik imgeler için ASA kullanılarak Dalgacık, Ridgelet ve Dalgacık dönüşümleri kullanılarak yapılan sınıflandırma sonuçları. Gösterilenler eğitim ve test amaçlı olarak iki eşit parçaya ayrılmış 5.000 fotoğrafik ve 5.000 fotogerçekçi imge üzerindeki doğruluklardır.

En İyi 20 Öznitelik	Dalgacık	Ridgelet	Contourlet	Karma
Yanlış Alarm Oranı	5.08% (127)	4.72% (118)	3.44% (86)	1.60% (40)
Kayıp Oranı	4.20% (105)	3.76% (94)	3.24% (81)	0.60% (15)

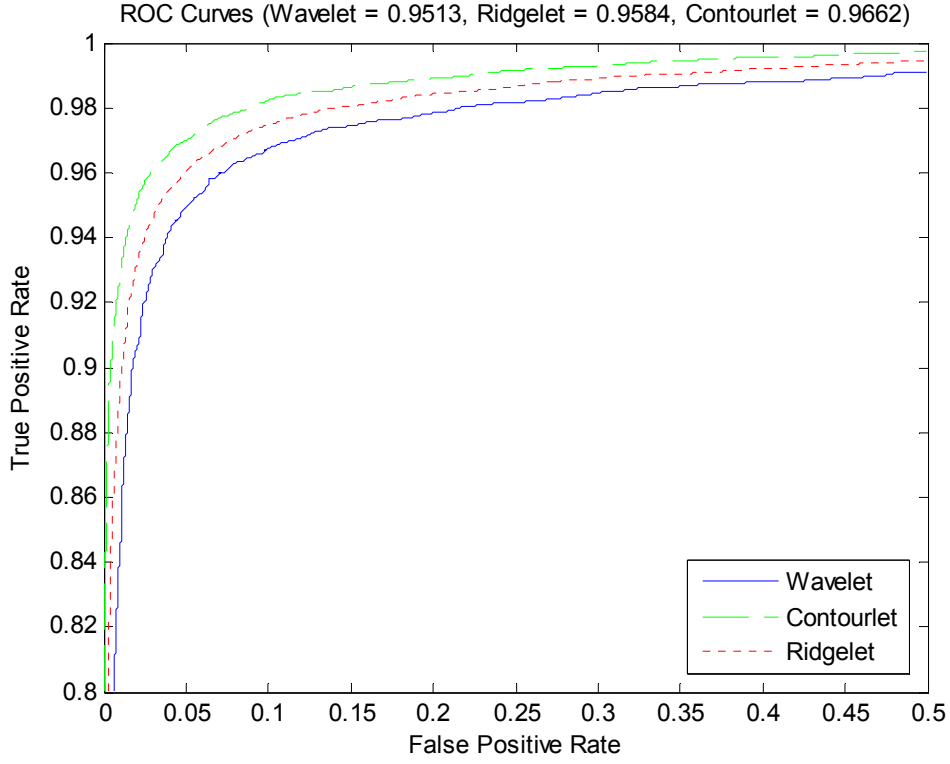
Çizelge 4.1 ve 4.2'deki değerlerin doğruluğunu desteklemek amacıyla elde edilen öznitelikler kullanılarak ROC (Receiver Operating Characteristics) eğrileri çıkarılmıştır. Şekil 4.2 ve 4.3'te tüm özniteliklerin kullanılması ve en iyi 20 özniteliğin seçilmesi durumlarındaki eğriler verilmiştir.

Çizelge 4.3'de, her üç dönüşüm için de seçilmiş ilk 20 öznitelik verilmiştir. Burada, X için, μ, σ, κ ve χ sırasıyla ortalama, varyans, kurtosis ve skewness olarak ifade edilir. Renk için R,G ve B değerleri kırmızı, yeşil ve mavi kanalları ifade eder. Yön için dalgacıklarda V, H ve D değerleri düşey, yatay ve diyagonal yönleri belirtirken, ridgeletlerde yön bilgisi bulunmaz ve contourletlerde 16 adet yön bilgisi bulunmaktadır. Orijin için O ve P değerleri özniteliğin orijinal veriden mi yoksa tahmin hatasından mı elde edildiğini belirtir. Dalgacık dönüşümü için seçilen özniteliklerin çoğunlukla orijinal verinin ya da tahmin hatasının ortalama değerlerinden oluştuğu gözlemlenmiştir. Ridgeletler için, bu durum farklıdır. Çünkü, elde edilen özniteliklerin çoğunu zaten seçmiş oluruz. Buna rağmen, özniteliklerin hala çoğunlukla ortalama ve varyans özniteliklerinden seçildiği gözlemlenmiştir. Contourlet dönüşümü için, ridgeletlere benzer bir durum oluştuğu gözlemlenmiştir. Seçilen özniteliklerin çoğu ortalama ve varyanstan oluşmuştur.

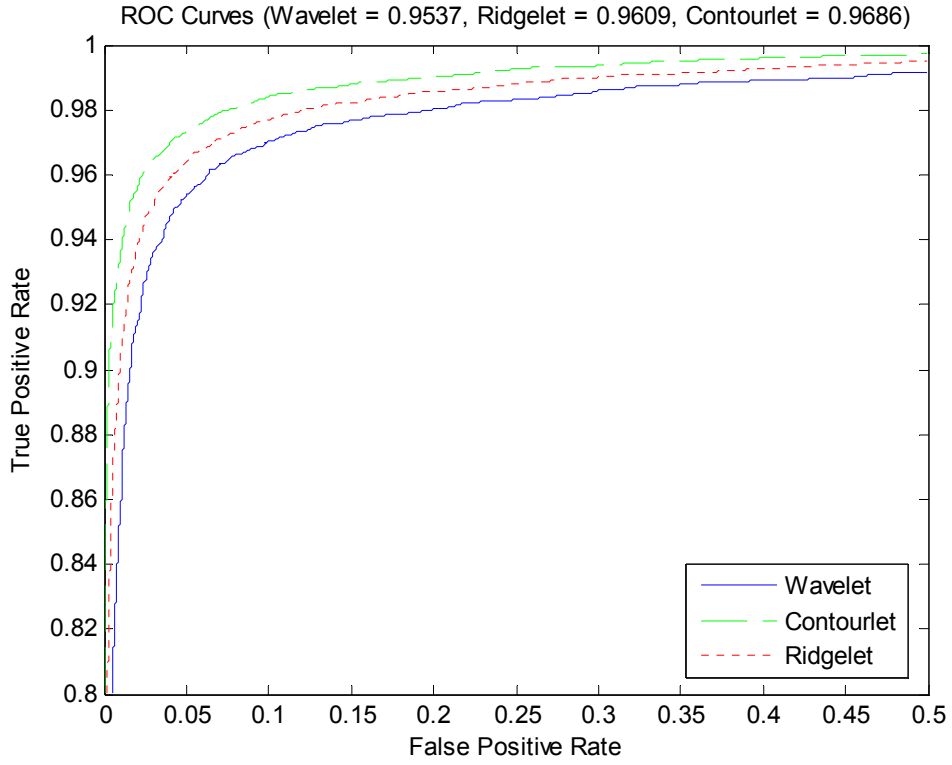
4.4. Steganaliz

Oluşturulan modelin **Stego** veri tabanı üzerinde denenmesi de bir başka önemli çalışmadır. Dalgacık tabanlı öznitelikler stego imgeler üzerinde daha denendiğinde çok da başarılı sonuçlar vermediği gözlemlenmiştir. Böyle bir sonucun çıkmasının, steganografinin veriyi görsel olarak ayırt edilemeyecek şekilde gizlemeye çalıştığı düşünülecek olursa doğal karşılanabileceği söylenebilir. Bu durumun dalgacık tabanlı diğer dönüşümlerde de aynı çıkması beklenebilir. Fakat, sonuçların nasıl çıkacağı tam olarak kestirilemediğinden böyle bir çalışmanın yapılması ve sonuçların uygun bir şekilde yorumlanması gerekmektedir.

Stego veri tabanında daha önce de açıklandığı gibi iki adet orijinal imge veri kümesi bulunmaktadır. Bunlardan birincisini kullanarak elde edilen stego imgeler ve bu kümeye ait orijinal imgeler bir sınıflandırma problemi olarak DVM'ye uygulandığında Çizelge 4.4'deki gibi sonuçlar elde edilmiştir.



Şekil 4.2 – Fotoğerçekçi ve fotoğrafik imgeler için bütün öznelilikler üzerinden ROC eğrileri



Şekil 4.3 – Fotoğerçekçi ve fotoğrafik imgeler için en iyi 20 öznelilik üzerinden ROC eğrileri

Çizelge 4.3 - CG-N veri kümesi için her üç dönüşüm için seçilen en iyi ilk 20 öznelikler,

$X_{BantiNo,Orijin}^{Renk,Yön}$. X için, μ, σ, κ ve χ sırasıyla ortalama, varyans, kurtosis ve skewness olarak ifade edilir. Renk için R,G ve B değerleri kırmızı, yeşil ve mavi kanalları ifade eder. Yön için dalgacıklarda V, H ve D değerleri düşey, yatay ve diyagonal yönleri belirtirken, ridgeletlerde yön bilgisi bulunmaz ve contourletlerde 16 adet yön bilgisi bulunmaktadır. Orijin için O ve P değerleri özneliğin orijinal veriden mi yoksa tahmin hatasından mı elde edildiğini belirtir.

Öznelik No.	Dalgacık	Ridgelet	Contourlet	Karma
1	$\mu_{1,O}^{B,H}$	$\mu_{1,O}^B$	$\chi_{1,O}^{R,6}$	$\chi_{1,O}^{R,6}$
2	$\mu_{1,O}^{G,H}$	$\mu_{1,O}^R$	$\sigma_{1,O}^{R,1}$	$\sigma_{1,O}^{R,1}$
3	$\sigma_{2,P}^{B,H}$	$\sigma_{1,O}^B$	$\sigma_{1,P}^{R,6}$	$\sigma_{1,P}^{R,6}$
4	$\kappa_{1,P}^{R,D}$	$\mu_{1,O}^G$	$\sigma_{1,P}^{R,3}$	$\sigma_{1,P}^{R,3}$
5	$\chi_{3,P}^{B,V}$	$\chi_{2,P}^R$	$\mu_{1,O}^{B,7}$	$\mu_{1,O}^{B,7}$
6	$\mu_{1,O}^{R,H}$	$\kappa_{2,O}^B$	$\mu_{1,O}^{B,6}$	$\mu_{1,O}^{G,H}$
7	$\mu_{2,O}^{B,D}$	$\sigma_{1,P}^G$	$\mu_{1,P}^{B,3}$	$\sigma_{2,P}^{B,H}$
8	$\sigma_{1,O}^{B,D}$	$\sigma_{1,O}^R$	$\kappa_{1,P}^{R,12}$	$\mu_{1,O}^{B,6}$
9	$\sigma_{1,P}^{B,D}$	$\sigma_{1,P}^B$	$\sigma_{1,P}^{G,7}$	$\mu_{1,P}^{B,3}$
10	$\mu_{1,O}^{G,V}$	$\mu_{1,P}^R$	$\sigma_{1,P}^{B,6}$	$\mu_{2,O}^{B,D}$
11	$\mu_{1,O}^{G,D}$	$\kappa_{1,O}^B$	$\sigma_{1,P}^{G,11}$	$\kappa_{1,P}^{R,12}$
12	$\kappa_{1,P}^{B,D}$	$\chi_{1,P}^G$	$\mu_{1,O}^{B,14}$	$\sigma_{1,P}^{G,7}$
13	$\mu_{1,P}^{R,H}$	$\mu_{2,O}^G$	$\mu_{1,P}^{R,15}$	$\kappa_{2,O}^B$
14	$\mu_{2,P}^{G,V}$	$\mu_{2,P}^G$	$\chi_{1,P}^{G,11}$	$\sigma_{1,P}^{G,11}$
15	$\sigma_{1,O}^{G,D}$	$\sigma_{1,P}^R$	$\sigma_{1,P}^{G,4}$	$\mu_{1,O}^{G,V}$
16	$\mu_{1,O}^{R,D}$	$\chi_{1,O}^G$	$\mu_{1,P}^{G,8}$	$\mu_{1,O}^{B,14}$
17	$\kappa_{1,P}^{B,H}$	$\mu_{2,P}^B$	$\mu_{2,O}^{B,4}$	$\sigma_{1,O}^{G,D}$
18	$\mu_{2,O}^{G,D}$	$\sigma_{1,P}^B$	$\sigma_{1,P}^{R,1}$	$\mu_{1,O}^{R,D}$
19	$\mu_{3,O}^{B,V}$	$\kappa_{2,O}^R$	$\mu_{2,P}^{R,3}$	$\mu_{3,O}^{B,V}$
20	$\mu_{3,O}^{G,H}$	$\sigma_{2,P}^R$	$\sigma_{2,P}^{B,3}$	$\mu_{2,O}^{G,D}$

Çizelge 4.4 - Stego veri kümesi için Outguess-, Outguess+, F5 ve LSB veri gizleme algoritmalarındaki Dalgacık, Ridgelet ve Contourlet dönüşümlerinin sınıflandırma sonuçları (Tüm öznitelikler).

Orijinal-F5	Dalgacık	Ridgelet	Contourlet
Yanlış Alarm Oranı	41.4%	36.6%	28.8%
Kayıp Oranı	40.8%	36.2%	33.0%
Orijinal-Outguess-	Dalgacık	Ridgelet	Contourlet
Yanlış Alarm Oranı	35.4%	33.8%	33.2%
Kayıp Oranı	36.2%	33.4%	32.8%
Orijinal-Outguess+	Dalgacık	Ridgelet	Contourlet
Yanlış Alarm Oranı	36.8%	34.4%	33.6%
Kayıp Oranı	36.6%	34.0%	33.6%
Orijinal-LSB	Dalgacık	Ridgelet	Contourlet
Yanlış Alarm Oranı	30.2%	26.4%	23.2%
Kayıp Oranı	30.8%	27.0%	23.0%

Çizelge 4.5 - Stego veri kümesi için Outguess-, Outguess+, F5 ve LSB veri gizleme algoritmalarındaki Dalgacık, Ridgelet ve Contourlet dönüşümlerinin sınıflandırma sonuçları (En iyi 20 öznitelik).

Orijinal-F5	Dalgacık	Ridgelet	Contourlet	Karma
Yanlış Alarm Oranı	29.4%	24.6%	18.8%	18.4%
Kayıp Oranı	28.8%	23.8%	21.2%	20.8%
Orijinal-Outguess-	Dalgacık	Ridgelet	Contourlet	Karma
Yanlış Alarm Oranı	26.2%	25.8%	25.4%	24.6%
Kayıp Oranı	26.8%	25.8%	25.2%	24.8%
Orijinal-Outguess+	Dalgacık	Ridgelet	Contourlet	Karma
Yanlış Alarm Oranı	27.4%	26.4%	26.0%	25.2%
Kayıp Oranı	27.0%	25.8%	25.6%	25.0%
Orijinal-LSB	Dalgacık	Ridgelet	Contourlet	Karma
Yanlış Alarm Oranı	24.4%	22.0%	18.0%	17.4%
Kayıp Oranı	25.2%	22.4%	18.0%	17.6%

Çizelge 4.6 - Stego veri kümesi için PQ veri gizleme algoritmasındaki Dalgacık, Ridgelet ve Contourlet dönüşümlerinin sınıflandırma sonuçları (Tüm öznitelikler).

Orijinal-PQ	Dalgacık	Ridgelet	Contourlet
Yanlış Alarm Oranı	40.88%	41.00%	40.00%
Kayıp Oranı	41.38%	41.00%	41.00%

İmgeler yine iki gruba ayrılmış ve her sınıftan imgelerin ilk yarısı eğitim ve geri kalan yarısı da test amaçlı olarak kullanılmıştır. Burada yanlış alarm oranı orijinal imge olarak bulunması gerekirken veri gizlenmiş imge olarak bulunan imgelerin oranını ve hata oranı da veri gizlenmiş imgeler içinden orijinal imge olarak bulunanların oranını göstermektedir. Çizelge 4.5'te ise DVM ile birlikte ASA algoritmasının kullanılması ile elde edilen en iyi 20 öznitelik için sonuçlar verilmiştir.

Görülebileceği üzere, her üç dönüşüm için elde edilen sonuçlar ve bunların karmalarından elde edilen sonuç birbirine yakın çıkmaktadır. Özellikle, PQ algoritması ile elde edilen imgelerde sonuçların neredeyse hiç farketmemesi dikkate değer bir sonuçtur. Bu tür dönüşümlerden elde edilecek özniteliklerin steganaliz alanında başarılı sonuçlar vermeyeceği bu sonuçlar ışığında açıkça ortaya çıkmaktadır.

4.5. İmge Hangi Kaynaktan Gelmiştir?

Kaynak belirlemeye dayalı çalışmalar günümüzde adli kanıt toplama biliminin önemli kısımlarından birisi haline gelmiştir. İmgenin kaynağının doğru olarak belirlenmesi için pek çok çalışma da literatürde yer almıştır. Bu amaçla elde edilen modellerin kaynak belirleme alanındaki başarılarını ölçmek için bu çalışmada iki farklı imge veri tabanı kullanılmıştır. **Cam** veri kümesi farklı dijital kameralar üzerinden elde edilmiş pek çok farklı imgeyi içermektedir. **Scanner** veri kümesi ise farklı tarayıcılardan elde edilmiş imgeleri içeren bir veri kümesidir.

Cam veri kümesi eğitim ve test amaçlı olarak ikiye ayrılmıştır. Her sınıftan (fotoğraf makinası) imgelerin yarısı eğitim amaçlı olarak, geri kalanları ise test kümesinde kullanılmıştır. Çizelge 4.8 ve 4.9'da DVM'ye tüm özniteliklerin verildiği ve ASA algoritması ile seçilen en iyi 20 özniteliğin verildiği durumlar için şaşıрма matrisleri verilmiştir. Şaşıрма matrisi ikiden fazla sınıfın olması durumunda başarı oranlarını göstermek için kullanılan bir yöntemdir. Bu matrisin her sütunu toplandığında 100 değerini verir ve o sütundaki elemanlar o sütuna ait sınıf imgelerinin her 100 tanesinden kaç tanesinin kendi ve diğer sınıflarda olarak sınıflandırıldığını gösterir. Burada amaç matrisin diyagonal elemanlarını 100

Çizelge 4.7 - Stego veri kümesi için PQ veri gizleme algoritmasındaki Dalgacık, Ridgelet ve Contourlet dönüşümlerinin sınıflandırma sonuçları (En iyi 20 öznitelik).

Orijinal-PQ	Dalgacık	Ridgelet	Contourlet	Karma
Yanlış Alarm Oranı	27.75%	27.88%	27.38%	27.00%
Kayıp Oranı	28.75%	28.5%	27.88%	27.25%

Çizelge 4.8 - Cam veri kümesi için dalgacık tabanlı sınıflandırma sonuçları (Tüm öznitelikler).

Dalgacık	Lumix	EOS	Powershot
Lumix	90.1%	5.5%	4.2%
EOS	5.2%	89.9%	4.6%
Powershot	4.7%	5.6%	91.2%
Ridgelet	Lumix	EOS	Powershot
Lumix	94.1%	3.2%	2.9%
EOS	2.8%	94.0%	2.9%
Powershot	3.1%	2.8%	94.2%
Contourlet	Lumix	EOS	Powershot
Lumix	96.3%	1.4%	1.5%
EOS	2.0%	96.5%	2.2%
Powershot	1.7%	2.1%	96.1%

Çizelge 4.9 - Cam veri kümesi için dalgacık tabanlı sınıflandırma sonuçları (En iyi 20 öznitelik).

Dalgacık	Lumix	EOS	Powershot
Lumix	92.5%	4.4%	2.7%
EOS	4.5%	93.0%	2.8%
Powershot	3.0%	2.6%	94.5%
Ridgelet	Lumix	EOS	Powershot
Lumix	97.1%	2.0%	1.4%
EOS	1.6%	96.5%	1.9%
Powershot	1.3%	1.5%	96.7%
Contourlet	Lumix	EOS	Powershot
Lumix	99.7%	0.1%	0.3%
EOS	0.1%	99.8%	0.1%
Powershot	0.2%	0.1%	99.6%
Karma	Lumix	EOS	Powershot
Lumix	99.8%	0.0%	0.1%
EOS	0.1%	99.9%	0.1%
Powershot	0.1%	0.1%	99.8%

Çizelge 4.10 - Cam veri kümesi için her üç dönüşüm için seçilen en iyi ilk 20 öznitelikler.

Öznitelik No.	Dalgacık	Ridgelet	Contourlet	Karma
1	$\mu_{1,O}^{B,H}$	$\mu_{1,O}^B$	$\chi_{1,O}^{R,6}$	$\chi_{1,O}^{R,6}$ C
2	$\mu_{1,O}^{G,H}$	$\mu_{1,O}^R$	$\sigma_{1,O}^{R,1}$	$\sigma_{1,O}^{R,1}$ C
3	$\sigma_{2,P}^{B,H}$	$\sigma_{1,O}^B$	$\sigma_{1,P}^{R,6}$	$\sigma_{1,P}^{R,6}$ C
4	$\kappa_{1,P}^{R,D}$	$\mu_{1,O}^G$	$\sigma_{1,P}^{R,3}$	$\sigma_{1,P}^{R,3}$ C
5	$\chi_{3,P}^{B,V}$	$\chi_{2,P}^R$	$\mu_{1,O}^{B,7}$	$\mu_{1,O}^{B,7}$ C
6	$\mu_{1,O}^{R,H}$	$\kappa_{2,O}^B$	$\mu_{1,O}^{B,6}$	$\mu_{1,O}^{R,H}$
7	$\mu_{2,O}^{B,D}$	$\sigma_{1,P}^G$	$\mu_{1,P}^{B,3}$	$\sigma_{1,O}^{B,D}$
8	$\sigma_{1,O}^{B,D}$	$\sigma_{1,O}^R$	$\kappa_{1,P}^{R,12}$	$\mu_{1,O}^{B,6}$ C
9	$\sigma_{1,P}^{B,D}$	$\sigma_{1,P}^B$	$\sigma_{1,P}^{G,7}$	$\sigma_{1,O}^R$ Γ
10	$\mu_{1,O}^{G,V}$	$\mu_{1,P}^R$	$\sigma_{1,P}^{B,6}$	$\mu_{1,O}^{G,V}$
11	$\mu_{1,O}^{R,D}$	$\kappa_{1,O}^B$	$\sigma_{1,P}^{G,11}$	$\mu_{1,P}^{B,3}$ C
12	$\mu_{1,O}^{G,D}$	$\mu_{1,P}^G$	$\kappa_{1,P}^{G,4}$	$\kappa_{1,P}^{R,12}$ C
13	$\kappa_{1,P}^{B,D}$	$\mu_{2,O}^G$	$\mu_{1,O}^{B,14}$	$\sigma_{1,P}^{G,7}$ C
14	$\mu_{1,P}^{R,H}$	$\mu_{2,P}^G$	$\kappa_{1,P}^{G,6}$	$\kappa_{1,P}^{B,D}$
15	$\mu_{2,P}^{G,V}$	$\sigma_{1,P}^R$	$\mu_{1,P}^{R,15}$	$\sigma_{1,O}^{G,V}$
16	$\sigma_{1,O}^{G,V}$	$\chi_{1,O}^G$	$\chi_{1,P}^{G,11}$	$\sigma_{1,P}^{B,6}$ C
17	$\sigma_{1,O}^{G,D}$	$\mu_{2,P}^B$	$\sigma_{1,P}^{G,4}$	$\sigma_{1,P}^{G,11}$ C
18	$\sigma_{1,O}^{R,D}$	$\sigma_{1,P}^B$	$\mu_{1,P}^{G,8}$	$\sigma_{1,O}^{G,D}$
19	$\kappa_{1,P}^{B,H}$	$\chi_{1,O}^R$	$\mu_{2,O}^{B,4}$	$\kappa_{1,P}^{B,H}$
20	$\mu_{2,O}^{G,D}$	$\sigma_{2,P}^R$	$\sigma_{1,P}^{R,1}$	$\kappa_{1,P}^{G,4}$ C

değerine getirmektedir ki, bu durum bütün imgelerin doğru şekilde sınıflandırıldığını gösterir.

Çizelge 4.10'da, her üç dönüşüm için de seçilmiş ilk 20 öznitelik verilmiştir. Her üç dönüşüm için seçilen özniteliklerin CG-N veri kümesinde olduğuna benzer şekilde

oluştugu gözlemlenmiştir. Her üç dönüşüm için de sadece 2'şer öznitelik değişmiştir.

Scanner veri kümesi eğitim ve test amaçlı olarak ikiye ayrılmıştır. Her sınıftan (fotoğraf makinası) imgelerin yarısı eğitim amaçlı olarak, geri kalanları ise test kümesinde kullanılmıştır. Çizelge 4.11 ve 4.12'de DVM'ye tüm özniteliklerin verildiği ve ASA algoritması ile seçilen en iyi 20 özniteliğin verildiği durumlar için şaşırtma matrisleri verilmiştir.

Çizelge 4.13'te, her üç dönüşüm için de seçilmiş ilk 20 öznitelik verilmiştir. Her üç dönüşüm için seçilen özniteliklerin **Cam** veri kümesinin aynısı olduğu gözlemlenmiştir.

Çizelge 4.11 - *Scanner* veri kümesi için Dalgacık, Ridgelet ve Contourlet dönüşümlerinin sınıflandırma sonuçları (Tüm öznitelikler).

Dalgacık	HP1510-1	HP1510-2	HP1410	HP3030	HP3010
HP1510-1	%77.01	%11.21	%4.56	%4.78	%5.00
HP1510-2	%11.54	%77.18	%4.68	%4.67	%4.12
HP1410	%4.03	%3.77	%81.75	%4.24	%4.68
HP3030	%3.71	%4.21	%4.23	%81.32	%4.50
HP3010	%3.71	%3.63	%4.78	%4.99	%81.70
Ridgelet	HP1510-1	HP1510-2	HP1410	HP3030	HP3010
HP1510-1	%85.15	%3.45	%3.99	%3.50	%3.44
HP1510-2	%3.77	%85.77	%3.26	%3.28	%3.62
HP1410	%3.65	%3.69	%85.00	%3.87	%3.16
HP3030	%3.72	%3.73	%3.75	%86.02	%3.79
HP3010	%3.71	%3.36	%4.00	%3.33	%85.99
Contourlet	HP1510-1	HP1510-2	HP1410	HP3030	HP3010
HP1510-1	%89.17	%2.85	%2.39	%2.99	%2.15
HP1510-2	%2.73	%89.07	%2.92	%2.64	%2.57
HP1410	%2.94	%2.84	%88.45	%2.80	%2.86
HP3030	%2.76	%2.43	%3.02	%88.41	%2.41
HP3010	%2.40	%2.81	%3.22	%3.16	%90.01

Çizelge 4.12 - *Scanner* veri kümesi için Dalgacık, Ridgelet ve Contourlet dönüşümlerinin sınıflandırma sonuçları (En iyi 20 öznitelik).

Dalgacık	HP1510-1	HP1510-2	HP1410	HP3030	HP3010
HP1510-1	%85.49	%8.55	%1.93	%1.98	%2.00
HP1510-2	%8.88	%85.08	%1.82	%2.27	%2.12
HP1410	%1.83	%2.10	%92.25	%1.62	%1.91
HP3030	%1.85	%2.13	%1.97	%92.15	%1.80
HP3010	%1.95	%2.14	%2.02	%1.98	%92.17
Ridgelet	HP1510-1	HP1510-2	HP1410	HP3030	HP3010
HP1510-1	%96.45	%1.45	%1.11	%1.10	%1.14
HP1510-2	%1.42	%97.04	%0.59	%0.87	%0.52
HP1410	%0.65	%0.04	%96.98	%0.14	%1.06
HP3030	%0.78	%0.73	%0.26	%96.30	%0.56
HP3010	%0.70	%0.73	%1.06	%1.58	%96.72
Contourlet	HP1510-1	HP1510-2	HP1410	HP3030	HP3010
HP1510-1	%99.32	%0.31	%0.13	%0.13	%0.03
HP1510-2	%0.33	%99.38	%0.12	%0.05	%0.06
HP1410	%0.14	%0.10	%99.63	%0.08	%0.08
HP3030	%0.06	%0.13	%0.02	%99.63	%0.11
HP3010	%0.15	%0.08	%0.10	%0.10	%99.72
Karma	HP1510-1	HP1510-2	HP1410	HP3030	HP3010
HP1510-1	%99.86	%0.06	%0.00	%0.02	%0.02
HP1510-2	%0.06	%99.88	%0.04	%0.00	%0.04
HP1410	%0.02	%0.02	%99.90	%0.04	%0.02
HP3030	%0.04	%0.02	%0.02	%99.92	%0.02
HP3010	%0.02	%0.02	%0.04	%0.02	%99.90

4.6. Ressam Kim?

Contourletler imgeden kontur bilgisini yakalamakta çok başarılıdır. Bu başarı, bir yağlıboya tablonun konturlarını bulmak için bu dönüşümün kullanılmasına uygun bir zemin hazırlar. Her ressam tablolarında kendine özgü kontur stiline sahiptir. Bu nedenle, bir tablonun konturlarını doğru şekilde belirlemek bize o tablonun ressamını bulmak konusunda yardımcı olabilir. Bu fikrin başarısını gözlemlemek için, *Paint1* ve *Paint2* imge veri kümeleri üzerinde çalışmalar yapılmıştır. *Paint1* veri kümesinde herkesin bildiği ünlü ressamların internet üzerinden toplanmış farklı çözünürlüklerdeki imgeleri bulunmaktadır. Bu imgeler iki eşit parçaya ayrılarak eğitim ve test amaçlı olarak kullanılmıştır.

Çizelge 4.13 - Scanner veri kümesi için her üç dönüşüm için seçilen en iyi ilk 20 öznitelikler.

Öznitelik No.	Dalgacık	Ridgelet	Contourlet	Karma
1	$\mu_{1,O}^{B,H}$	$\mu_{1,O}^B$	$\chi_{1,O}^{R,6}$	$\chi_{1,O}^{R,6}$ C
2	$\mu_{1,O}^{G,H}$	$\mu_{1,O}^R$	$\sigma_{1,O}^{R,1}$	$\sigma_{1,O}^{R,1}$ C
3	$\sigma_{2,P}^{B,H}$	$\sigma_{1,O}^B$	$\sigma_{1,P}^{R,6}$	$\sigma_{1,P}^{R,6}$ C
4	$\kappa_{1,P}^{R,D}$	$\mu_{1,O}^G$	$\sigma_{1,P}^{R,3}$	$\sigma_{1,P}^{R,3}$ C
5	$\chi_{3,P}^{B,V}$	$\chi_{2,P}^R$	$\mu_{1,O}^{B,7}$	$\mu_{1,O}^{B,7}$ C
6	$\mu_{1,O}^{R,H}$	$\kappa_{2,O}^B$	$\mu_{1,O}^{B,6}$	$\mu_{1,O}^{B,6}$ C
7	$\mu_{2,O}^{B,D}$	$\sigma_{1,P}^G$	$\mu_{1,P}^{B,3}$	$\sigma_{1,P}^G$ r
8	$\sigma_{1,O}^{B,D}$	$\sigma_{1,O}^R$	$\kappa_{1,P}^{R,12}$	$\mu_{1,P}^R$ r
9	$\sigma_{1,P}^{B,D}$	$\sigma_{1,P}^B$	$\sigma_{1,P}^{G,7}$	$\mu_{1,P}^{B,3}$ C
10	$\mu_{1,O}^{G,V}$	$\mu_{1,P}^R$	$\sigma_{1,P}^{B,6}$	$\mu_{1,O}^{R,D}$
11	$\mu_{1,O}^{R,D}$	$\kappa_{1,O}^B$	$\sigma_{1,P}^{G,11}$	$\kappa_{1,P}^{R,12}$ C
12	$\mu_{1,O}^{G,D}$	$\mu_{1,P}^G$	$\kappa_{1,P}^{G,4}$	$\kappa_{1,P}^{B,D}$
13	$\kappa_{1,P}^{B,D}$	$\mu_{2,O}^G$	$\mu_{1,O}^{B,14}$	$\mu_{1,P}^{R,H}$
14	$\mu_{1,P}^{R,H}$	$\mu_{2,P}^G$	$\kappa_{1,P}^{G,6}$	$\sigma_{1,P}^{G,7}$ C
15	$\mu_{2,P}^{G,V}$	$\sigma_{1,P}^R$	$\mu_{1,P}^{R,15}$	$\sigma_{1,P}^{B,6}$ C
16	$\sigma_{1,O}^{G,V}$	$\chi_{1,O}^G$	$\chi_{1,P}^{G,11}$	$\sigma_{1,P}^{G,11}$ C
17	$\sigma_{1,O}^{G,D}$	$\mu_{2,P}^B$	$\sigma_{1,P}^{G,4}$	$\sigma_{1,O}^{R,D}$
18	$\sigma_{1,O}^{R,D}$	$\sigma_{1,P}^B$	$\mu_{1,P}^{G,8}$	$\mu_{1,P}^{R,H}$
19	$\kappa_{1,P}^{B,H}$	$\chi_{1,O}^R$	$\mu_{2,O}^{B,4}$	$\kappa_{1,P}^{G,4}$ C
20	$\mu_{2,O}^{G,D}$	$\sigma_{2,P}^R$	$\sigma_{1,P}^{R,1}$	$\mu_{2,O}^{G,D}$

Çizelge 4.14 – *Paint1* veri kümesi için Dalgacık, Ridgelet ve Contourlet dönüşümlerinin sınıflandırma sonuçları (Tüm öznelilikler).

Dalgacık	DaVinci	Goya	Renoir	VanGogh
DaVinci	76.2%	9.2%	8.0%	10.0%
Goya	8.0%	75.8%	5.8%	9.4%
Renoir	7.8%	7.2%	80.2%	7.8%
VanGogh	8.0%	7.8%	6.0%	72.8%
Ridgelet	DaVinci	Goya	Renoir	VanGogh
DaVinci	79.4%	6.4%	5.4%	4.8%
Goya	7.0%	80.2%	6.6%	5.0%
Renoir	6.0%	7.6%	82.6%	6.2%
VanGogh	7.6%	5.8%	5.4%	84.0%
Contourlet	DaVinci	Goya	Renoir	VanGogh
DaVinci	86.6%	4.2%	2.0%	4.4%
Goya	5.0%	87.8%	4.8%	3.6%
Renoir	4.2%	3.6%	89.0%	3.6%
VanGogh	4.2%	4.4%	4.2%	88.4%

Çizelge 4.15 – *Paint1* veri kümesi için Dalgacık, Ridgelet ve Contourlet dönüşümlerinin sınıflandırma sonuçları (En iyi 20 öznelilik).

Dalgacık	DaVinci	Goya	Renoir	VanGogh
DaVinci	76.2%	9.2%	8.0%	10.0%
Goya	8.0%	75.8%	5.8%	9.4%
Renoir	7.8%	7.2%	80.2%	7.8%
VanGogh	8.0%	7.8%	6.0%	72.8%
Ridgelet	DaVinci	Goya	Renoir	VanGogh
DaVinci	79.4%	6.4%	5.4%	4.8%
Goya	7.0%	80.2%	6.6%	5.0%
Renoir	6.0%	7.6%	82.6%	6.2%
VanGogh	7.6%	5.8%	5.4%	84.0%
Contourlet	DaVinci	Goya	Renoir	VanGogh
DaVinci	86.6%	4.2%	2.0%	4.4%
Goya	5.0%	87.8%	4.8%	3.6%
Renoir	4.2%	3.6%	89.0%	3.6%
VanGogh	4.2%	4.4%	4.2%	88.4%
Karma	DaVinci	Goya	Renoir	VanGogh
DaVinci	92.8%	2.0%	2.0%	2.4%
Goya	2.8%	94.4%	3.6%	2.4%
Renoir	2.0%	1.4%	91.0%	2.2%
VanGogh	2.4%	2.2%	3.4%	93.0%

Çizelge 4.16 – *Paint1* veri kümesi için her üç dönüşüm için seçilen en iyi ilk 20 öznitelikler.

Öznitelik No.	Dalgacık	Ridgelet	Contourlet	Karma
1	$\mu_{1,O}^{B,H}$	$\mu_{1,O}^B$	$\chi_{1,O}^{R,6}$	$\chi_{1,O}^{R,6}$ C
2	$\mu_{1,O}^{G,H}$	$\mu_{1,O}^R$	$\sigma_{1,O}^{R,1}$	$\sigma_{1,O}^{R,1}$ C
3	$\sigma_{2,P}^{B,H}$	$\sigma_{1,O}^B$	$\sigma_{1,P}^{R,6}$	$\sigma_{1,P}^{R,6}$ C
4	$\kappa_{1,P}^{R,D}$	$\mu_{1,O}^G$	$\sigma_{1,P}^{R,3}$	$\sigma_{1,P}^{R,3}$ C
5	$\chi_{3,P}^{B,V}$	$\chi_{2,P}^R$	$\mu_{1,O}^{B,7}$	$\mu_{1,O}^{B,7}$ C
6	$\mu_{1,O}^{R,H}$	$\kappa_{2,O}^B$	$\mu_{1,O}^{B,6}$	$\sigma_{2,P}^{B,H}$
7	$\mu_{2,O}^{B,D}$	$\sigma_{1,P}^G$	$\mu_{1,P}^{B,3}$	$\mu_{1,O}^{B,6}$ C
8	$\sigma_{1,O}^{B,D}$	$\sigma_{1,O}^R$	$\kappa_{1,P}^{R,12}$	$\chi_{3,P}^{B,V}$
9	$\sigma_{1,P}^{B,D}$	$\sigma_{1,P}^B$	$\sigma_{1,P}^{G,7}$	$\mu_{1,O}^{R,H}$
10	$\mu_{1,O}^{G,V}$	$\mu_{1,P}^R$	$\sigma_{1,P}^{B,6}$	$\sigma_{1,P}^{B,D}$
11	$\mu_{1,O}^{R,D}$	$\kappa_{1,O}^B$	$\sigma_{1,P}^{G,11}$	$\sigma_{1,P}^{G,7}$ C
12	$\mu_{1,O}^{G,D}$	$\mu_{1,P}^G$	$\kappa_{1,P}^{G,4}$	$\kappa_{1,P}^{B,D}$
13	$\kappa_{1,P}^{B,D}$	$\mu_{2,O}^G$	$\mu_{1,O}^{B,14}$	$\sigma_{1,P}^{G,11}$ C
14	$\mu_{1,P}^{R,H}$	$\mu_{2,P}^G$	$\kappa_{1,P}^{G,6}$	$\mu_{1,P}^{R,H}$
15	$\mu_{2,P}^{G,V}$	$\sigma_{1,P}^R$	$\mu_{1,P}^{R,15}$	$\kappa_{1,P}^{G,4}$ C
16	$\sigma_{1,O}^{G,V}$	$\chi_{1,O}^G$	$\chi_{1,P}^{G,11}$	$\mu_{1,O}^{B,14}$ C
17	$\sigma_{1,O}^{G,D}$	$\mu_{2,P}^B$	$\sigma_{1,P}^{G,4}$	$\sigma_{1,O}^{G,D}$
18	$\sigma_{1,O}^{R,D}$	$\sigma_{1,P}^B$	$\mu_{1,P}^{G,8}$	$\mu_{2,O}^{G,D}$
19	$\kappa_{1,P}^{B,H}$	$\chi_{1,O}^R$	$\mu_{2,O}^{B,4}$	$\kappa_{1,P}^{G,6}$ C
20	$\mu_{2,O}^{G,D}$	$\sigma_{2,P}^R$	$\sigma_{1,P}^{R,1}$	$\mu_{1,P}^{R,15}$ C

Çizelge 4.14 ve 4.15'te DVM'ye tüm özniteliklerin verildiği ve ASA algoritması ile seçilen en iyi 20 özneliğin verildiği durumlar için şaşırma matrisleri verilmiştir. Çizelge 4.16'da, her üç dönüşüm için de seçilmiş en iyi ilk 20 öznelik verilmiştir. **CG-N**, **Cam** ve **Scanner** veri kümelerine benzer olarak seçilen özneliklerin çok değişmediği gözlemlenmiştir.

Çizelge 4.17 – *Paint2* veri kümesi için Dalgacık, Ridgelet ve Contourlet dönüşümlerinin sınıflandırma sonuçları (Tüm öznelilikler).

Dalgacık	Ayaz	Serbest	Arca	Coruh
Ayaz	82.1%	6.9%	8.0%	6.5%
Serbest	7.9%	84.2%	5.2%	5.5%
Arca	4.9%	4.4%	80.9%	4.5%
Coruh	5.1%	4.5%	5.9%	83.5%
Ridgelet	Ayaz	Serbest	Arca	Coruh
Ayaz	90.1%	4.2%	3.0%	4.2%
Serbest	4.0%	89.6%	2.6%	4.3%
Arca	2.9%	3.1%	92.5%	3.0%
Coruh	3.0%	3.1%	2.9%	88.5%
Contourlet	Ayaz	Serbest	Arca	Coruh
Ayaz	95.0%	1.0%	2.0%	1.9%
Serbest	2.2%	96.3%	2.0%	2.0%
Arca	1.2%	1.5%	93.9%	1.3%
Coruh	1.6%	1.2%	2.1%	94.8%

Çizelge 4.18 – *Paint2* veri kümesi için Dalgacık, Ridgelet ve Contourlet dönüşümlerinin sınıflandırma sonuçları (En iyi 20 öznelilik).

Dalgacık	Ayaz	Serbest	Arca	Coruh
Ayaz	82.1%	6.9%	8.0%	6.5%
Serbest	7.9%	84.2%	5.2%	5.5%
Arca	4.9%	4.4%	80.9%	4.5%
Coruh	5.1%	4.5%	5.9%	83.5%
Ridgelet	Ayaz	Serbest	Arca	Coruh
Ayaz	90.1%	4.2%	3.0%	4.2%
Serbest	4.0%	89.6%	2.6%	4.3%
Arca	2.9%	3.1%	92.5%	3.0%
Coruh	3.0%	3.1%	2.9%	88.5%
Contourlet	Ayaz	Serbest	Arca	Coruh
Ayaz	95.0%	1.0%	2.0%	1.9%
Serbest	2.2%	96.3%	2.0%	2.0%
Arca	1.2%	1.5%	93.9%	1.3%
Coruh	1.6%	1.2%	2.1%	94.8%
Karma	Ayaz	Serbest	Arca	Coruh
Ayaz	97.2%	0.3%	1.1%	0.9%
Serbest	1.0%	98.0%	1.0%	1.0%
Arca	0.6%	1.0%	96.9%	0.8%
Coruh	1.2%	0.7%	1.0%	97.3%

Paint2 veri kümesinde ressamaların sanat galerilerinden elde edilmiş ve benzer ışıklandırma koşulları altında çekilmiş çok yakın çözünürlüklerdeki imgeleri bulunmaktadır. Bu imgeler iki eşit parçaya ayrılarak eğitim ve test amaçlı olarak kullanılmıştır.

Çizelge 4.19 – *Paint2* veri kümesi için her üç dönüşüm için seçilen en iyi ilk 20 öznitelikler.

Öznitelik No.	Dalgacık	Ridgelet	Contourlet	Karma
1	$\mu_{1,O}^{B,H}$	$\mu_{1,O}^B$	$\chi_{1,O}^{R,6}$	$\chi_{1,O}^{R,6}$ C
2	$\mu_{1,O}^{G,H}$	$\mu_{1,O}^R$	$\sigma_{1,O}^{R,1}$	$\sigma_{1,O}^{R,1}$ C
3	$\sigma_{2,P}^{B,H}$	$\sigma_{1,O}^B$	$\sigma_{1,P}^{R,6}$	$\sigma_{1,P}^{R,6}$ C
4	$\kappa_{1,P}^{R,D}$	$\mu_{1,O}^G$	$\sigma_{1,P}^{R,3}$	$\sigma_{1,P}^{R,3}$ C
5	$\chi_{3,P}^{B,V}$	$\chi_{2,P}^R$	$\mu_{1,O}^{B,7}$	$\mu_{1,O}^{B,7}$ C
6	$\mu_{1,O}^{R,H}$	$\kappa_{2,O}^B$	$\mu_{1,O}^{B,6}$	$\sigma_{2,P}^{B,H}$
7	$\mu_{2,O}^{B,D}$	$\sigma_{1,P}^G$	$\mu_{1,P}^{B,3}$	$\mu_{1,O}^{B,6}$ C
8	$\sigma_{1,O}^{B,D}$	$\sigma_{1,O}^R$	$\kappa_{1,P}^{R,12}$	$\chi_{3,P}^{B,V}$
9	$\sigma_{1,P}^{B,D}$	$\sigma_{1,P}^B$	$\sigma_{1,P}^{G,7}$	$\mu_{1,O}^{R,H}$
10	$\mu_{1,O}^{G,V}$	$\mu_{1,P}^R$	$\sigma_{1,P}^{B,6}$	$\sigma_{1,P}^{B,D}$
11	$\mu_{1,O}^{R,D}$	$\kappa_{1,O}^B$	$\sigma_{1,P}^{G,11}$	$\sigma_{1,P}^{G,7}$ C
12	$\mu_{1,O}^{G,D}$	$\mu_{1,P}^G$	$\kappa_{1,P}^{G,4}$	$\kappa_{1,P}^{B,D}$
13	$\kappa_{1,P}^{B,D}$	$\mu_{2,O}^G$	$\mu_{1,O}^{B,14}$	$\sigma_{1,P}^{G,11}$ C
14	$\mu_{1,P}^{R,H}$	$\mu_{2,P}^G$	$\kappa_{1,P}^{G,6}$	$\mu_{1,P}^{R,H}$
15	$\mu_{2,P}^{G,V}$	$\sigma_{1,P}^R$	$\mu_{1,P}^{R,15}$	$\kappa_{1,P}^{G,4}$ C
16	$\sigma_{1,O}^{G,V}$	$\chi_{1,O}^G$	$\chi_{1,P}^{G,11}$	$\mu_{1,O}^{B,14}$ C
17	$\sigma_{1,O}^{G,D}$	$\mu_{2,P}^B$	$\sigma_{1,P}^{G,4}$	$\sigma_{1,O}^{G,D}$
18	$\sigma_{1,O}^{R,D}$	$\sigma_{1,P}^B$	$\mu_{1,P}^{G,8}$	$\mu_{2,O}^{G,D}$
19	$\kappa_{1,P}^{B,H}$	$\chi_{1,O}^R$	$\mu_{2,O}^{B,4}$	$\kappa_{1,P}^{G,6}$ C
20	$\mu_{2,O}^{G,D}$	$\sigma_{2,P}^R$	$\sigma_{1,P}^{R,1}$	$\mu_{1,P}^{R,15}$ C

Çizelge 4.20 – Resolution veri kümesi için Dalgacık, Ridgelet ve Contourlet dönüşümlerinin sınıflandırma sonuçları (En iyi 20 öznitelik)

Dalgacık	0.3MP	0.7MP	1MP	2MP	4MP
0.3MP	80.1%	11.9%	1.5%	0.8%	1.2%
0.7MP	14.3%	72.8%	13.2%	2.5%	2.8%
1MP	4.3%	12.8%	74.2%	9.3%	7.2%
2MP	1.1%	1.9%	10.0%	76.9%	15.2%
4MP	0.3%	0.6%	1.1%	10.5%	73.6%
Ridgelet	0.3MP	0.7MP	1MP	2MP	4MP
0.3MP	83.6%	10.5%	1.3%	0.7%	0.8%
0.7MP	12.2%	76.0%	11.5%	2.2%	2.0%
1MP	3.2%	11.3%	77.6%	8.4%	5.2%
2MP	0.8%	1.7%	8.7%	79.9%	12.3%
4MP	0.2%	0.5%	0.9%	8.8%	79.7%
Contourlet	0.3MP	0.7MP	1MP	2MP	4MP
0.3MP	87.0%	9.0%	1.0%	0.7%	0.5%
0.7MP	10.0%	79.3%	9.8%	1.9%	1.1%
1MP	2.3%	9.7%	81.1%	7.3%	3.2%
2MP	0.5%	1.6%	7.3%	83.0%	9.5%
4MP	0.2%	0.4%	0.8%	7.1%	85.7%
Karma	0.3MP	0.7MP	1MP	2MP	4MP
0.3MP	90.5%	7.6%	0.9%	0.6%	0.1%
0.7MP	7.9%	82.5%	8.1%	1.6%	0.3%
1MP	1.3%	8.2%	84.5%	6.3%	1.2%
2MP	0.2%	1.4%	5.9%	86.0%	6.6%
4MP	0.1%	0.3%	0.6%	5.5%	91.8%

Çizelge 4.17 ve 4.18’de DVM’ye tüm özniteliklerin verildiği ve ASA algoritması ile seçilen en iyi 20 özniteliklerin verildiği durumlar için şaşırtma matrisleri verilmiştir. Çizelge 4.19’da, her üç dönüşüm için de seçilmiş en iyi ilk 20 öznitelik verilmiştir. **Paint1** veri kümesi ile aynı sonuçların çıkması yöntemin tutarlı olduğu sonucunu da ortaya koymaktadır.

4.7.Çözünürlük Ne Fark Ettirir?

İngede adli kanıt arama çalışmaları dahilinde farklı çözünürlüklerde imgelerin kullanılması söz konusu olacaktır. Bu durum, farklı çözünürlüklerdeki imgeler için elde edilecek sonuçların ne kadar değişeceğini gözlemlemek gerektiğini ortaya

koyar. Bu nedenle, **Resolution** veritabanı kullanılarak 5 çözümlülük seviyesinde elde edilen özniteliklerin birbirinden ne kadar ayırt edilebildiği incelenmiştir.

Çizelge 4.20'de DVM'ye tüm özniteliklerin verildiği ve ASA algoritması ile seçilen en iyi 20 özniteliğin verildiği durumlar için şaşırma matrisleri verilmiştir.

5. Tartışma

İstatistikleri üç yönelimden daha fazla yönelimde elde ettiğimiz için ridgelet ve contourlet dönüşümlerini kullanarak daha başarılı sonuçlar elde etmemiz mantıklıdır. Contourlet ve ridgelet dönüşümleri için uygulanan yeni istatistiksel model sonuçları olumlu yönde etkilemiştir. Çizelge 4.1 ve 4.2'de de görülebileceği gibi fotogerçekçi ve fotoğrafik imgelerin ayrılmasında en iyi sonuçlar yeni modele sahip contourlet dönüşümü ile elde edilmektedir. Kullanılan katsayı miktarı ridgelet ve dalgacık yöntemlerinden fazla olmasına rağmen, kullanılan yöntem 3 alt-bant yerine 2 alt-bantta gerçekleştirilmiş ve bu durumda bile daha başarılı sonuçlar alınmıştır.

Çizelge 4.2'de özniteliklerin birleşiminden elde edilen başarımlar oranları fotogerçekçi ve fotoğrafik imgelerin ayrılması durumu için verilmiştir. Görülebileceği gibi Çizelge 4.3'te verilen öznitelikler kullanıldığında başarımlar oranları oldukça yüksek çıkmakta ve 5000 imgede sadece 55 imge yanlış olarak sınıflandırılmaktadır. Bu seviyede bir başarımların elde edilmesi bu yapıda bir öznitelik kümesinin bu alanda neredeyse başka türde özniteliklerin kullanılmasına gerek kalmadan başarılı sonuçlar vereceğini müjdelemektedir [116,117,118,119].

Bununla birlikte, Çizelge 4.4, 4.5, 4.6 ve 4.7'ye göz attığımızda, çeşitli steganografi uygulamalarından elde edilmiş imgeler üzerinde sadece dalgacık dönüşümünün değil, diğer dalgacık tabanlı dönüşümlerin de başarısız olduğunu göstermiştir. Özellikle bazı steganografi uygulamalarında belirgin gelişmeler gözlemlenmesine ve contourlet yönteminin her steganografi uygulamasında daha iyi başarımlar oranları vermesine rağmen hata oranları kabul edilebilirin çok üstünde olmaktadır. Bu durum, Contourlet dönüşümünün bir sihirli değnek gibi her alanda başarılı olan bir dönüşüm olmadığını gözler önüne sermektedir. Fakat, yine de karşılaştırma noktasında dalgacıktan daha iyi sonuçlar çıkardığını gözardı etmemek gerekmektedir.

Kaynak belirleme çalışmalarına yönelik olarak yapılan kamera belirleme çalışmaları da Contourlet dönüşümünün başarısını ortaya koymaktadır (Çizelge 4.8 ve 4.9). Elde edilen sonuçlar Contourlet dönüşümünden elde edilen özniteliklerin çok iyi başarı oranları ortaya koyduğunu göstermiştir. Bu veri kümesi için elde edilen sonuçlar **CG-N** veri kümesi için elde edilen sonuçlardan bile daha iyi çıkmıştır. Bu nedenle, **CG-N** veri kümesi için yapılan çıkarım benzer şekilde burada da yapılabilir ve bu yapıda bir öznitelik kümesinin bu alanda neredeyse başka türde özniteliklerin kullanılmasına gerek kalmadan başarılı sonuçlar vereceği söylenebilir [119].

Benzer sonuçlar **Scanner** veri kümesi için de elde edilmiştir. Bu kümede kullanılan imge sayısının 50000 imge seviyesinde olması elde edilen sonuçların güvenilirliğini de arttırmaktadır. Gelecekte imgelerin kaynağını belirlemeye yönelik yapılacak çalışmalarda bu çalışmada elde edilen öznitelik kümelerinin kullanılması çok başarılı sonuçların elde edilmesinde rol oynayacaktır [119].

Contourlet dönüşümünün yapısı gereği bu dönüşümün sanat eserlerinin incelenmesinde başarılı sonuçlar vereceği düşünülmüştür. Dönüşümün konturları modellemekteki başarısı, ressamın kendisine özgü konturları kullanarak oluşturduğu resimleri doğru şekilde modellenmesinde diğer dönüşümlere göre daha başarılı sonuçlar vermesi gerektiğini düşündürmektedir. Bu durumu doğrular nitelikte sonuçlar yapılan benzetimler sonucunda iki farklı veri kümesi için (Çizelge 4.14, 4.15, 4.17 ve 4.18) elde edilmiştir [119].

Kaynak belirleme çalışmalarında elde edilen başarılar göz önüne alındığında, hem ressam hem de kamera belirleme çalışmalarını bir araya getirerek iki durumu bir arada sınıflandırmak için bir çalışma yapılmıştır. Çizelge 5.1'de bu benzetimin sonuçları verilmektedir. Sonuçlardan görülebileceği gibi, dört sınıflı bir sınıflandırıcı kullanıldığında bile Contourlet dönüşümü başarısını korumaktadır. Karma özniteliklerle elde edilen sonuçlar ise elde edilen bu yüksek başarı oranlarını bir adım daha ileriye taşımaktadır.

Yapılan bir başka deneysel çalışma da çözünürlük farklılıklarının belirlenmesi üzerine olmuştur (Çizelge 4.20). Bu çalışmada elde edilen sonuçlar göstermektedir ki, farklı çözünürlüklerde imgelerin birbirinden ayrılması için de dalgacık tabanlı dönüşümlerden elde edilen özneliliklerin kullanılması mümkündür.

İleride yapılacak çalışmalarda, imgelerin üzerinde yapılan değişikliklerin de araştırılması mümkün olacaktır. Çözünürlük farklılıklarının belirlenmesi de bu bağlamda altyapı oluşturabilecek bir çalışmadır.

Gelecekte yapılması düşünülen ve bu çalışmayı baz alan çalışmalar arasında imge üzerindeki değişikliklerin belirlenmesi, elde edilen istatistiksel modeller kullanılarak imgeler üzerinde sıkıştırma algoritmalarının geliştirilmesi, medikal imgeler üzerinde yapılan değişikliklerin ve sahteciliğin belirlenmesi gibi çalışmalar sayılabilir.

Çizelge 5.1 – Hem ressam hem de kaynak belirleme için ASA kullanılarak elde edilen sınıflandırma sonuçları.

Dalgacık		Ayaz		Serbest	
		Lumix	EOS	Lumix	EOS
Ayaz	Lumix	88.2%	0.8%	11.8%	0.2%
	EOS	1.0%	87.8%	0.4%	9.8%
Serbest	Lumix	10.6%	0.4%	86.6%	0.6%
	EOS	0.2%	11.0%	1.2%	89.4%
Ridgelet		Ayaz		Serbest	
		Lumix	EOS	Lumix	EOS
Ayaz	Lumix	93.2%	0.8%	5.0%	0.4%
	EOS	1.0%	93.4%	0.6%	7.0%
Serbest	Lumix	5.6%	0.4%	93.8%	0.8%
	EOS	0.2%	5.4%	0.6%	91.8%
Contourlet		Ayaz		Serbest	
		Lumix	EOS	Lumix	EOS
Ayaz	Lumix	96.8%	0.6%	3.0%	0.2%
	EOS	0.4%	96.8%	0.0%	1.8%
Serbest	Lumix	2.8%	0.2%	96.8%	0.4%
	EOS	0.0%	2.4%	0.2%	97.6%

KAYNAKLAR

- [1] LYU, S. ve FARID, H., How realistic is photorealistic?, IEEE Transactions on Signal Processing, vol. 53, no. 2, s. 845-850, 2005.
- [2] SENCAR, H. T., RAMKUMAR, M. ve AKARSU, A.N., Data Hiding Fundamentals and Applications: Content Security in Digital Media, Academic Press, Inc., Orlando, FL, USA, 2004.
- [3] WU, M., Multimedia Data Hiding, PhD Thesis, Princeton University, June 2001.
- [4] WU, M. ve LIU, B., Multimedia Data Hiding. Springer Verlag New York, Inc., Secaucus, NJ, USA, 2002.
- [5] SCHNEIDER, M. ve CHANG, S., A robust content based digital signature for image authentication, Proceedings of the IEEE International Conference on Image Processing, Lausanne, Switzerland, September 1996, s. 227-230.
- [6] TZENG, C.-H. ve TSAI, W.-H., A new technique for authentication of image/video for multimedia applications, MM&Sec 2001: 23-26.
- [7] LU, C.-S. ve LIAO, H. Y. M.. Structural digital signature for image authentication: An incidental distortion resistant scheme, IEEE Trans. Multimedia, June 2003, s.161–173.
- [8] LIN, C.-Y. ve CHANG, S.-F., Generating Robust Digital Signature for Image/Video Authentication, Proc. ACM Multimedia 1999, Proc. Multimedia and Security Workshop at ACM Multimedia '98, U.K., September 1998.
- [9] ARNOLD, M., WOLTHUSEN, S. ve SCHMUCKER, M., Techniques and Applications of Digital Watermarking and Content Protection, Artech House, Norwood, MA, 2003.
- [10] NIKOLAIDIS, N. ve I. PITAS, Robust image watermarking in the spatial domain, Signal Processing, Elsevier, vol. 66, no. 3, s. 385-403, 1998.
- [11] MOULIN, P., The Role of Information Theory in Watermarking and Its Application to Image Watermarking, invited paper, Signal Processing , Vol. 81, No. 6, s. 1121-1139, June 2001.
- [12] REY, C. ve DUGELAY, J.-L., A survey of watermarking algorithms for image authentication, EURASIP Journal on Applied Signal Processing, v.2002 n.1, s. 613-621, January 2002.
- [13] FARID, H., A Survey of Image Forgery Detection, IEEE Signal Processing Magazine, vol. 26, no. 2, s.16-25, 2009.

- [14] LANH, T.V., CHONG, K.-S., EMMANUEL, S. ve KANKANHALLI, M.S., A Survey on Digital Camera Image Forensic Methods, ICME 2007, s.16-19, 2007.
- [15] SAIC, S. ve MAHDIAN, B., Blinds Methods for Detecting Image Fakery, Proceedings 42th Annual 2008 IEEE International Carnahan conference on Security Technology , Eds: Sanson Larry D., Fliegel Karel, 42th Annual 2008 IEEE International Carnahan conference on Security Technology, Praha, Czech Republic, 2008.
- [16] NG, T.T., CHANG, S.F., LIN, C.Y. ve SUN, Q., Passive-blind Image Forensics, in Multimedia. Security Technologies for Digital Rights, Elsevier, 2006.
- [17] SENCAR, H. T. ve MEMON, N., Overview of State-of-the-art in Digital Image Forensics, Part of Indian Statistical Institute Platinum Jubilee Monograph series titled 'Statistical Science and Interdisciplinary Research,' World Scientific Press, 2008.
- [18] WU, Q., LI, G.-H., TU, D. ve SUN, S.-J., State of the art and prospects on blind digital image forensics technology based on authenticity detection, Acta Automatica Sinica, ISSN=0254-4156, 2008.
- [19] BAYRAM, S., SENCAR, H. T. ve MEMON, N., A Survey of Copy-Move Forgery Detection Techniques, IEEE Western New York Image Processing Workshop, September 2008, NY.
- [20] DYBALA, B., JENNINGS, B. ve LETSCHER, D., Detecting filtered cloning in digital images, Proceedings of the 9th workshop on Multimedia & security, September 20-21, 2007, Dallas, Texas, USA.
- [21] FRIDRICH, J., SOUKAL, D. ve LUK, J., Detection of copy-move forgery in digital images, Proc. Digital Forensic Research Workshop, Cleveland, OH, August 2003.
- [22] HUANG, H., GUO, W. ve ZHANG, Y., Detection of Copy-Move Forgery in Digital Images Using SIFT Algorithm, Proceedings of the 2008 IEEE Pacific-Asia Workshop on Computational Intelligence and Industrial Application, s. 272-276, December 19-20, 2008.
- [23] LANGILLE, A. ve GONG, M., An Efficient Match-based Duplication Detection Algorithm, CRV 2006, s. 64-68, 2006.

- [24] LI, W., YUAN, Y. ve YU, N., Detecting copy-paster forgery of JPEG image via block artifact grid extraction, Int. Workshop on Local and Non-Local Approx. In Image Proc., 2008.
- [25] LIN, H.-J., WANG, C.-W. ve KAO, Y.-T., Fast copy-move forgery detection, WSEAS Transactions on Signal Processing, vol. 5, no. 5, s. 188-197, May 2009
- [26] LUO, W., HUANG, J. ve QIU, G., Robust Detection of Region-Duplication Forgery in Digital Image, Proceedings of the 18th International Conference on Pattern Recognition, s. 746-749, August 20-24, 2006.
- [27] MAHDIAN, B. ve SAIC, S., Detection of copy move forgery using a method based on blur movement invariants, Forensic Sci. Int., vol. 171, s. 180–189, 2007.
- [28] MYNA, A.N., VENKATESHMURTHY, M.G. ve PATIL, C.G., Detection of Region Duplication Forgery in Digital Images Using Wavelets and Log-Polar Mapping, International Conference on Computational Intelligence and Multimedia Applications (ICCIMA 2007), vol. 3, s.371-377, 2007.
- [29] POPESCU, A. C. ve FARID, H., Exposing digital forgeries by detecting duplicated image regions, Univ. of Dartmouth, Tech. Report, 2004.
- [30] BRAVO-SOLORIO, S. ve NANDI, A. K., Passive Forensic Method for Detecting Duplicated Regions Affected by Reflection, Rotation and Scaling, Proceedings of the 17th European Signal Processing Conference (EUSIPCO), UK, Glasgow, 2009.
- [31] ZHANG, J., FENG, Z. Ve SU, Y., A new approach for detecting Copy-Move forgery in digital images, International Conference on Communication Systems (ICCS 2008), 2008.
- [32] FILLION, C. ve SHARMA, G., Detecting content adaptive scaling of images for forensic applications, in Proc. SPIE: Media Forensics and Security XII, Jan. 2010, vol. 7541, Jan. 2010, San Jose, CA, s. 33–36.
- [33] GALLAGHER, A. ve CHEN, T., Image Authentication by Detecting Traces of Demosaicing, IEEE Conference on Computer Vision and Pattern Recognition, Workitorial on Vision of the Unseen 2008.
- [34] KIRCHNER, M., Fast and reliable resampling detection by spectral analysis of fixed linear predictor residue, Proceedings of the 10th ACM workshop on Multimedia and security, September 22-23, 2008, Oxford, United Kingdom.

- [35] KIRCHNER, M. ve GLOE, T., On resampling detection in re-compressed images, In First IEEE International Workshop on Information Forensics and Security (WIFS '09), 2009.
- [36] LIU, Q. ve SUNG, A. H., A new approach for JPEG resize and image splicing detection, In Proceedings of the First ACM Workshop on Multimedia in Forensics MiFor '09, ACM, s. 43-48, Beijing, China, October 23 - 23, 2009
- [37] MAHDIAN, B. ve SAIC, S., Blind authentication using periodic properties of interpolation, IEEE Transactions on Information Forensics and Security, vol. 3, no. 3, s. 529-538, 2008.
- [38] MAHDIAN, B. ve SAIC, S., Detection and description of geometrically transformed digital images, In Proc. SPIE, Electronic Imaging, Security and Forensics of Multimedia Contents XI, San Jose, CA, January 18-22, 2009.
- [39] NATARAJ, L., SARKAR, A. ve MANJUNATH, B. S., Adding Gaussian Noise to “Denoise” JPEG for detecting Image Resizing, in Proc. of IEEE International Conference on Image Processing (ICIP09), Cairo, Egypt, November 2009.
- [40] POPESCU, A. ve FARID, H., Exposing digital forgeries by detecting traces of re-sampling, IEEE Transactions on Signal Processing, vol. 53, no. 2, s. 758-767, 2005.
- [41] PRASAD, S. ve RAMAKRISHNAN, K., On resampling detection and its application to detect image tampering, In Proceedings of the 2006 IEEE International Conference on Multimedia and EXPO, s. 1325-1328, 2006.
- [42] BAYRAM, S., AVCIBAŞ, İ., SANKUR, B. ve MEMON, N. D., Image manipulation detection, J. Electronic Imaging, vol. 15, no. 4, 041102, 2006.
- [43] AVCIBAŞ, İ., BAYRAM, S., MEMON, N.D., RAMKUMAR, M. ve SANKUR, B., A classifier design for detecting image manipulations, IEEE Int. Conf. on Image Processing, s. 2645-2648, 2004.
- [44] DONG, J., WANG, W., TAN, T. ve SHI, Y. Q., Run-Length and Edge Statistics Based Approach for Image Splicing Detection, IWDW 2008, s. 76-87, 2008.
- [45] FARID, H., Detecting Digital Forgeries Using Bispectral Analysis, MIT AI Memo 1657, June 1999.
- [46] HSU, Y.-F. ve CHANG, S.-F., Image splicing detection using camera response function consistency and automatic segmentation, Proc. IEEE International Conference on Multimedia and Expo, s. 28-31, 2007.

- [47] HSU, Y.-F. ve CHANG, S.-F., Detecting Image Splicing Using Geometry Invariants and Camera Characteristics Consistency, International Conference on Multimedia and Expo, Toronto, Canada, 2006.
- [48] GOPI, E. S., Digital image forgery detection using artificial neural network and independent component analysis, Applied Mathematics and Computation, vol. 194, no. 2, s. 540-543, 15 December 2007.
- [49] GOPI, E. S., LAKSHMANAN, N., GOKUL, T., GANESH, S. K. ve SHAH, P.R., Digital Image Forgery Detection using Artificial Neural Networks and Auto Regressive Coefficients, Proc. of IEEE Canadian Conference on Electrical and Computer Engineering (CCECE),(4th-7th)May 2006, Ottawa, Canada.
- [50] JING, Z. ve HONGBIN, W., Exposing digital forgeries by detecting traces of image splicing, The 8th International Conference on Signal Processing, vol. 2, s. 15–20, 16-20 2006.
- [51] NG, T.-T. ve CHANG, S.-F., A Model for Image Splicing, IEEE International Conference on Image Processing (ICIP), Oct. 2004.
- [52] FU, D., SHI, Y. Q. ve SU, W., Detection of image splicing based on Hilbert-Huang transform and moments of characteristic functions with wavelet decomposition, International Workshop on Digital Watermarking (IWDW06), Jeju, Korea, November 2006.
- [53] CHEN, W., SHI, Y. Q. ve SU, W., Image splicing detection using 2-D phase congruency and statistical moments of characteristic function, Proceedings of SPIE, Volume 6505, Security, Steganography and Watermarking of Multimedia Contents IX ,San Jose,California, January 28 - February 1, 2007.
- [54] SHI, Y. Q., CHEN, C. ve CHEN, W., A natural image model approach to splicing detection, ACM Multimedia and Security Workshop, Dallas, Texas, September 20-21, 2007.
- [55] SHI, Y. Q., CHEN, C., XUAN, G. ve SU, W., Steganalysis versus splicing detection, The 6th International Workshop on Digital Watermarking (IWDW07), Guangzhou, Guangdong, China, December 2007.
- [56] CHEN, D., LI, J., WANG, S. ve LI, S., Identifying computer generated and digital camera images using fractional lower order moments, 4th IEEE Conference on Industrial Electronics and Applications, 2009.

- [57] DEHNIE, S., SENCAR, H. T. ve MEMON, N., Identification of computer generated and digital camera images for digital image forensics, Proc. of IEEE ICIP, 2006.
- [58] KIRCHNER, M. ve FRIDRICH, J., On Detection of Median Filtering in Digital Images, in N.D. Memon (eds.): Media Forensics and Security II, Proceedings of SPIE-IS&T Electronic Imaging, SPIE Vol. 7541, 754110, 2010.
- [59] NG, T.-T. ve CHANG, S.-F., An Online System for Classifying Computer Graphics Images from Natural Photographs, In SPIE Electronic Imaging, San Jose, CA, January 2006.
- [60] NG, T.-T., CHANG, S.-F. ve TSUI, M.-P., Lessons Learned from Online Classification of Photo-Realistic Computer Graphics and Photographs, IEEE Workshop on Signal Processing Applications for Public Security and Forensics (SAFE), Washington DC, April 2007.
- [61] DİRİK, A. E., BAYRAM, S., SENCAR, H. T. ve MEMON, N., New features to identify computer generated images, Proc. of IEEE ICIP, 2007.
- [62] KHANNA, N., CHIU, G. T.-C., ALLEBACH, J. P. ve DELP, E. J., Forensic techniques for classifying scanner, computer generated and digital camera images, ICASSP 2008, s. 1653-1656, 2008.
- [63] LEYKIN, A. ve CUTZU, F., Differences of Edge Properties in Photographs and Paintings, in proc. of ICIP, 2003.
- [64] CUTZU, F., HAMMOUD, R. ve LEYKIN, A., Distinguishing paintings from photographs. Computer Vision and Image Understanding, 2005.
- [65] ROCHA, A. ve GOLDENSTEIN, S., Is it fake or real?, in Brazilian Symposium of Computer Graphics and Image Processing (SIBGRAPI), 2006.
- [66] SANKAR, G., ZHAO, V. ve YANG, Y.H., Feature based classification of computer graphics and real images, Int. Conf. on Acoustics, Speech, and Signal Processing, Taipei, Taiwan, April 19-24, 2009.
- [67] CHEN, W., SHI, Y. Q. ve XUAN, G., Identifying computer graphics using HSV color model and statistical moments of characteristic functions, IEEE International Conference on Multimedia and Expo (ICME07), Beijing, China, July 2-5, 2007.

- [68] SUTTHIWAN, P., YE, J. ve SHI, Y. Q., An enhanced statistical approach to identifying photorealistic images, 8th International Workshop on Digital Watermarking, Guildford, UK, Springer Verlag, August 24-26, 2009.
- [69] WU, Q., SUN, S.-J., ZHU, W., LI, G.-H. ve TU, D., Detection of digital doctoring in exemplar-based inpainted images, International Conference on Machine Learning and Cybernetics, 2008.
- [70] BATTIATO, S. ve MESSINA, G., Digital Forgery Estimation into DCT Domain - A Critical Analysis In Proceedings of ACM Multimedia 2009 Workshop Multimedia in Forensics Beijing (China), October 2009
- [71] CHEN, Y.-L. ve HSU, C.-T., Detecting Doubly Compressed Images Based on Quantization Noise Model and Image Restoration, Proc. MMSP 2009, Rio de Janeiro, Brazil, Oct. 2009.
- [72] FAN, Z. ve DE QUEIROZ, R. L., Identification of bitmap compression history: JPEG detection and quantizer estimation, IEEE Transactions on Image Processing vol. 12, no. 2, s. 230-235, 2003.
- [73] FARID, H., Exposing Digital Forgeries from JPEG Ghosts, IEEE Transactions on Information Forensics and Security, vol. 4, no. 1, s.154-160, 2009.
- [74] LUKAS, J. ve FRIDRICH, J., Estimation of Primary Quantization Matrix in Double Compressed JPEG Images, Proc. of DFRWS 2003, Cleveland, OH, USA, August 5-8 2003.
- [75] FRIDRICH, J. ve PEVNY, T., Detection of Double-Compression for Applications in Steganography, IEEE Transactions on Information Security and Forensics, vol. 3, no. 2, s. 247-258, 2008.
- [76] LI, C.-T., Detection of Block Artifacts for Digital Forensic Analysis, in Proc. International Conference on Forensic Applications and Techniques in Telecommunications, Information and Multimedia (e-Forensics 09), Adelaide, Australia, 19 - 21 January, 2009.
- [77] ZHANG, J., WANG, H. ve SU, Y., Detection of Double-Compression in JPEG2000 Images for Application in Image Forensics, Journal of Multimedia 4 vol. 6, s. 379-388, 2009.
- [78] DİRİK, A. E. ve MEMON, N., Image Tamper Detection Based on Demosaicing Artifacts, IEEE ICIP 09, November 2009, Cairo Egypt.
- [79] FAN, N., JIN, C. ve HUANG, Y, A pixel-based digital photo authentication framework via demosaicking inter-pixel correlation, In Proceedings of the

- 11th ACM Workshop on Multimedia and Security (Princeton, New Jersey, USA, September 07 - 08, 2009), MM&Sec '09, ACM, s. 125-130, 2009.
- [80] POILPRÉ, M.C., PERROT, P. ve HUGUES, T., Image Tampering Detection Using Bayer Interpolation and JPEG Compression, 1st International conference on Forensic applications and techniques in telecommunications, information, and multimedia (eForensics'08), no.17, 2008.
- [81] POPESCU, A.C. ve FARID, H., Exposing Digital Forgeries in Color Filter Array Interpolated Images, IEEE Transactions on Signal Processing, vol. 53, no. 10, s. 3948-3959, 2005.
- [82] JOHNSON, M.K. ve FARID, H., Exposing Digital Forgeries in Complex Lighting Environments, IEEE Transactions on Information Forensics and Security, vol. 2, no. 3, s. 450-461, 2007.
- [83] JOHNSON, M.K. ve FARID, H., Exposing Digital Forgeries Through Specular Highlights on the Eye, 9th International Workshop on Information Hiding, Saint Malo, France, 2007.
- [84] FARID, H. ve BRAVO, M.J., Image Forensic Analyses that Elude the Human Visual System, SPIE Symposium on Electronic Imaging, San Jose, CA, 2010.
- [85] GOU, H., SWAMINATHAN, A. ve WU, M., Noise features for image tampering detection and steganalysis, in IEEE Int. Conf. Image Processing (ICIP), vol. 6, s. 97-100, San Antonio, TX, Sep. 2007.
- [86] MAHDIAN, B. ve SAIC, S., Detection of resampling supplemented with noise inconsistencies analysis for image forensics, In International Conference on Computational Sciences and Its Applications, s. 546–556, Perugia, Italy, July 2008.
- [87] JOHNSON, M.K. ve FARID, H., Exposing Digital Forgeries Through Chromatic Aberration, ACM Multimedia and Security Workshop, Geneva, Switzerland, 2006.
- [88] AVCIBAŞ, İ., BAYRAM, S., MEMON, N., RAMKUMAR, M. ve SANKUR, B., A classifier design for detecting image manipulation, Proc. of IEEE ICIP, 2004.
- [89] BAYRAM, S., AVCIBAŞ, İ., SANKUR, B. ve MEMON, N., Image Manipulation Detection with Binary Similarity Measures, 13th European Signal Processing Conference, Vol. I, s. 752-755, Antalya-TURKEY, 2005.

- [90] QU, Z., QIU, G. ve HUANG, J., Detect Digital Image Splicing with Visual Cues. *Information Hiding 2009*, s. 247-261, 2009.
- [91] STAMM, M. ve LIU, K. J. R., Blind Forensics of Contrast Enhancement in Digital Images, *Proc. IEEE Int'l Conf. Image Processing (ICIP)*, San Diego, USA, October 2008.
- [92] CANDÈS, E. J. ve DONOHO, D. L., Ridgelets: a key to higher-dimensional intermittency?, *Phil. Trans. R. Soc. Lond. A.*, s. 2495-2509, 1999.
- [93] CANDÈS, E. J. ve DONOHO, D. L., Curvelets – a surprisingly effective nonadaptive representation for objects with edges, in *Curve and Surface Fitting*, A. Cohen, C. Rabut, and L. L. Schumaker, Eds. Saint-Malo: Vanderbilt University Press, 1999.
- [94] DO, M.N. ve VETTERLI, M., The Contourlet Transform : An Efficient Directional Multiresolution Image Representation, *IEEE Trans. On Image Proc.* , vol. 14, no. 12, s. 2091-2106, 2005.
- [95] BUCCIGROSSI, R.W. ve SIMONCELLI, E.P., Image compression via joint statistical characterization in the wavelet domain. *IEEE Transactions on Image Processing*, vol. 8, no. 12, s. 1688–1701, 1999.
- [96] CANDÈS, E. J., Ridgelets: Theory and Applications, Ph.D. thesis, Department of Statistics, Stanford University, 1998.
- [97] DO, M. N. ve VETTERLI, M., The Finite Ridgelet Transform for Image Representation. *IEEE Transactions on Image Processing*, vol. 12, no. 1, s. 16-28, Jan 2003.
- [98] HERMAN, G. T., *Image Reconstruction from Projections: The Fundamentals of Computerized Tomography*, Academic Press, 1980.
- [99] ROSENFELD, A. ve KAK, A. C., *Digital Picture Processing*, Academic Press, 2nd edition, 1982.
- [100] MERSEREAU, R. M. ve OPPENHEIM, A. V., Digital reconstruction of multidimensional signals from projections, *Proc. of IEEE*, vol. 62, no. 10, s. 1319-1338, Oct 1974.
- [101] BEYLKIN, G., Discrete Radon transform, *IEEE Trans. Acoust. Speech Sig. Proc.*, vol. 35, s. 162-172, 1987.
- [102] SANZ, J. L. C., HINKLE, E. B. ve JAIN, A. K., *Radon and Projection Transform-Based Computer Vision*, Springer Verlag, 1988.

- [103] KELLEY, B. T. ve MADISETTI, V. K., The fast discrete Radon transform - I: Theory, IEEE Trans. on Image Proc., vol. 2, s. 382-400, Jul 1993.
- [104] BOLKER, E. D., The finite Radon transform, Integral Geometry (Contemporary Mathematics, Vol. 63), S. Helgason, R. L. Bryant, V. Guillemin and R. O. Wells Jr., Eds., s. 27-50.1987.
- [105] GERTNER, I., A new efficient algorithm to compute the two-dimensional discrete Fourier transform, IEEE Trans. Acoust. Speech Sig. Proc., vol. 36, s. 1036-1050, Jul 1988.
- [106] MATÚŠ, F. ve FLUSSER, J., Image representation via a finite Radon transform, IEEE Trans. Pattern Anal. Machine Intell., vol. 15, no. 10, s. 996-1006, Oct 1993.
- [107] SALZBERG, P. M. ve FIGUEROA, R., Tomography on the 3D-torus and crystals, Discrete Tomography: Foundations, Algorithms and Applications, G. T. Herman and A. Kuba, Eds., s. 417-434. Birkhauser, 1999.
- [108] CANDÈS, E. J. ve DONOHO, D. L., New tight frames of curvelets and optimal representations of objects with piecewise C² singularities, Commun. on Pure and Appl. Math., s. 219–266, Feb. 2004.
- [109] HUBEL, D. H. ve WIESEL, T. N., Receptive fields, binocular interaction and functional architecture in the cat's visual cortex, Journal of Physiology, no. 160, s. 106–154, 1962.
- [110] OLSHAUSEN, B. A. ve FIELD, D. J., Emergence of simple-cell receptive field properties by learning a sparse code for natural images, Nature, s. 607–609, 1996.
- [111] VETTERLI, M., Multidimensional subband coding: Some theory and algorithms, Signal Proc., vol. 6, no. 2, s. 97–112, February 1984.
- [112] BURT, P. J. ve ADELSON, E. H., The Laplacian pyramid as a compact image code, IEEE Trans. Commun., vol. 31, no. 4, s. 532–540, April 1983.
- [113] BAMBERGER, R. H. ve SMITH, M. J. T., A filter bank for the directional decomposition of images: Theory and design, IEEE Trans. Signal Proc., vol. 40, no. 4, s. 882–893, April 1992.
- [114] DO, M. N., Directional multiresolution image representations, Ph.D. dissertation, Swiss Federal Institute of Technology, Lausanne, Switzerland, December 2001.

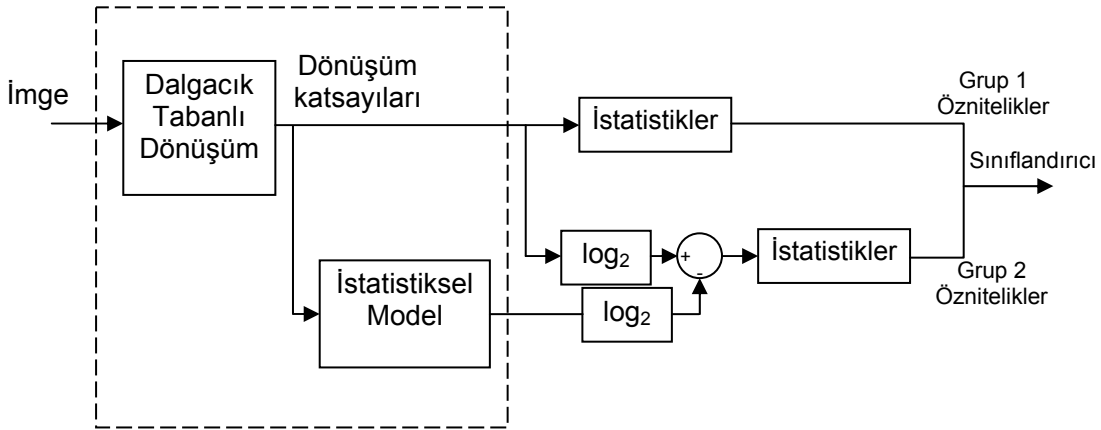
- [115] FRIDRICH, J., GOLJAN, M. ve SOUKAL, D., Perturbed Quantization Steganography, ACM Multimedia System Journal, vol. 11, no. 2, s. 98-107, 2005.
- [116] ÖZPARLAK, L. ve AVCIBAŞ, İ., Sonlu Ridgelet Dönüşümü ile Sayısal İmgelerde Adli Kanıt Toplama, SİU'09, 2009.
- [117] ÖZPARLAK, L. ve AVCIBAŞ, İ., Differentiating Between Computer Generated And Natural Images Using Wavelet Based Transforms, ICASSP'11, s. 1868-1871, 22-27 Mayıs 2011.
- [118] ÖZPARLAK, L. ve AVCIBAŞ, İ., Dalgacık Tabanlı İmge Modelleri ile Sayısal İmgelerde Adli Kanıt Toplama, SİU'11, s. 335-338, Nisan 2011
- [119] ÖZPARLAK, L. ve AVCIBAŞ, İ., Differentiating Between Images Using Wavelet Based Transforms: A Comparative Study, IEEE Transactions on Information Forensics And Security, s. 1-14, December 2011.
- [120] POULI, T., CUNNINGHAM, D. W. ve REINHARD, E., Image Statistics and their Applications in Computer Graphics, 2010, DOI=10.1.1.182.1444.
- [121] PUDIL, P., NOVOVICOVA, J. ve KITTLER, J.V., Floating Search Methods in Feature-Selection, PRL, vol. 15, no. 11, s. 1119-1125, 1994.
- [122] PUDIL, P., FERRI, F. J., NOVOVICOVA, J. ve KITTLER, J., Floating Search Methods for Feature Selection with Nonmonotonic Criterion Functions, In Proceedings of the Twelveth International Conference on Pattern Recognition, IAPR, s. 279-283, 1994.
- [123] How Digital Cameras Work, http://www.astropix.com/HTML/I_ASTROP/HOW.HTM, 2011.
- [124] ADAMS, J., PARULSKI, K. ve SPAULDING, K., Color Processing in Digital Cameras, IEEE Micro, vol. 18, no. 6, s. 20-30, Nov./Dec. 1998.
- [125] Lens Defects, <http://www.dvinfo.net/articles/optics/lensdefects.php>, 2011

EKLER

A. Temel Bilgiler

Bu bölümde yapılan çalışma içerisinde kullanılan araçların tanıtılması amaçlanmaktadır. Bu nedenle, yapılan çalışmanın algoritmik yapısının gösterilmesi araçların kullanım amaçlarının ve yerlerinin anlaşılması açısından gereklidir. Şekil A.1'de yapılan çalışmada kullanılan öznitelik çıkarma algoritmasının basit bir akış şeması verilmiştir. Temel olarak;

1. Bir imgenin dalgacık tabanlı dönüşümü alınmakta,
2. Bölüm 4'te anlatılacak olan istatistiksel modeller kullanılarak bir dalgacık tabanlı katsayı etrafındaki belirli katsayılardan öngörülmekte,
3. Elde edilen katsayılar kullanılarak logaritmik hata hesaplanmakta,
4. Dalgacık tabanlı dönüşüm katsayıları ve logaritmik hata katsayıları üzerinden yüksek dereceli istatistikler hesaplanmaktadır.



Şekil A.1 – Çalışmanın algoritmik şeması

Elde edilen bu istatistikler birer öznitelik olarak kullanılmaktadır. Bu öznitelikler bir sınıflandırma probleminin girdileri olarak ele alınmaktadır. Sınıflandırma süreci Destek Vektör Makineleri (DVM) adı verilen ve başarısı kanıtlanmış sınıflandırıcılarla yürütülmüştür. Bununla birlikte, elimizde oldukça bol miktarda öznitelik bulunduğundan, bu öznitelikler içerisinde en gerekli olanlarını seçmek için öznitelik seçimi yapılmıştır. Bu seçimi yapabilmek için kullanılan öznitelik seçim algoritması ise Ardışık İleri Seyyar Arama (AİSA) adı verilen yöntemdir. Bu

bölümde, bütün bu yöntemlerin teker teker açıklanması amaçlanmıştır. Ayrıca, bu bölüm dahilinde elde ettiğimiz sonuçların neden başarılı olduğunu açıklayabilmek amacıyla, üzerinde durduğumuz problemlerde kullanılan imgelerin hangi süreçlerden geçtiğini ve nasıl elde edildiğini açıklamaya çalışacağız.

a. Yüksek Dereceli İstatistikler (YDİ)

Geniş bir tanımlama ile, bir rassal değişken, değerleri rassal olan ve bu değerler için bir olasılık dağılımı saptamak imkânı olan bir sayıdır. Daha matematiksel biçimde, bir rassal değişken bir örneklem uzayından değişkenin mümkün değerlerinden oluşan ölçülebilir uzaya değişimi gösterir. Rassal değişkenlerin bu formel tanımlanması reel değerli sonuçlar veren deneyleri çok sıkı bir surette matematiksel ölçüm kuramı çerçevesi içine sokmakta ve reel değerli rassal değişkenler için dağılım fonksiyonu kurulmasına imkân sağlamaktadır. İstatistiksel analiz yöntemleri bize bir rassal değişken hakkında gereken bütün bilgiye sahip olmadan o rassal değişkenin önemli özelliklerini anlamamızda yardımcı olur. Yani, biz bir sonraki ölçümün ne olacağını bilmesek de nasıl bir yapıda ve hangi aralıklarda geleceğini söylememizi sağlar.

Bildiğimiz en temel iki istatistik ortalama ve değişinti bilgisidir. Ortalama bir ölçümün hangi değer etrafında saçılacağını, değişinti ise ölçümün ortalama etrafında ne kadar saçılacağını anlamamızı sağlar. Yüksek dereceli istatistiklerden kasıt üçüncü (skewness) ve dördüncü (kurtosis) dereceli istatistiklerin de öznelik kümesine eklenmesidir. Sürekli bir fonksiyon için ilk dört dereceli istatistikler şu şekilde ifade edilebilir [120]:

$$M_n(x) = \int x^n \cdot f(x) \cdot dx. \quad (\text{A.1})$$

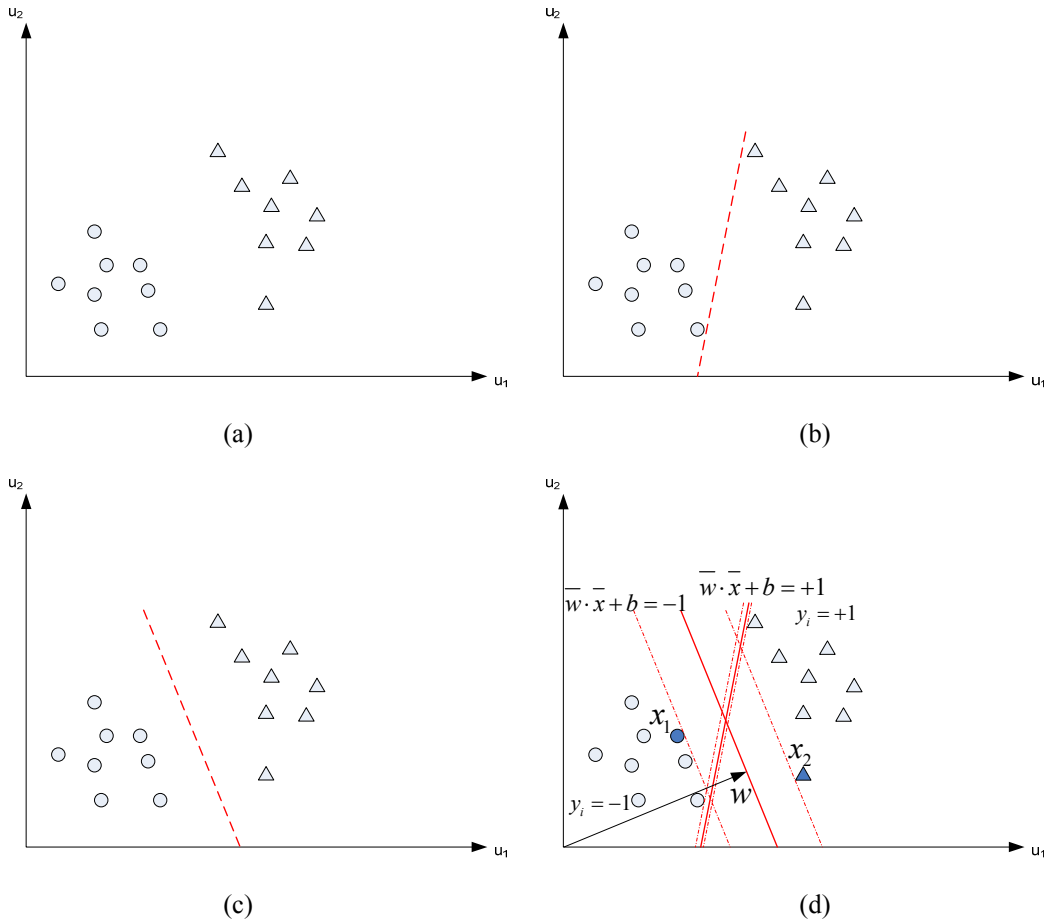
Burada, $f(x)$ x rassal değişkeninin olasılık yoğunluk fonksiyonudur. Fakat, elimizde sürekli bir fonksiyon yerine örnekler bulunduğundan örnek ortalama, örnek varyans, örnek skewness ve örnek kurtosis hesapları bu integraller yerine kullanılmaktadır:

$$\text{Örnek Ortalama: } \bar{x} = \frac{1}{N} \sum_{n=1}^N x_n . \quad (\text{A.2a})$$

$$\text{Örnek Varyans: } \sigma^2 = \frac{1}{N-1} \sum_{n=1}^N (x_n - \bar{x})^2 . \quad (\text{A.2b})$$

$$\text{Örnek Saçılma: } s = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^3}{(\sigma^2)^{3/2}} \quad (\text{A.2c})$$

$$\text{Örnek Kurtosis: } k = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^4}{(\sigma^2)^2} - 3 \quad (\text{A.2d})$$



Şekil A.2 – İki gruba ait öznitelik kümeleri ve iki sınıflandırma çözümü

b. Destek Vektör Makineleri (DVM)

İki örnek grubunu bir aşırıdüzlem (hyperplane) ayırıyor olsun. Bu aşırıdüzlem üzerindeki noktalar

$$\bar{w} \cdot \bar{x} + b = 0. \quad (\text{A.3})$$

düzlem denklemini sağlar. Burada, \bar{w} aşırı düzleme olan normali, \bar{x} aşırıdüzlem üzerindeki bir noktayı ve b düzlemin orijinden uzaklığını ifade eder. DVM yöntemi her iki gruptaki aşırıdüzleme en yakın noktalar arasındaki uzaklığın en büyük olduğu aşırıdüzlemi bulmaya çalışır. Her iki gruptan da seçilen ve aşırıdüzleme en yakın olan noktalara destek vektörleri adı verilir.

Bunu bir örnekle anlatacak olursak, Şekil A.2(a)'da verildiği gibi iki boyutlu bir uzayda varolan iki gruba ait noktalar kümesi bulunsun. İki grubun noktaları arasında bir ayırım yapmak istediğimizde Şekil A.2(b) ve A.2(c) gibi iki çözüm bulmak mümkündür. Fakat, Grup 1'e ait yeni bir örneğin eklenmesi durumunda Şekil A.2(b)'de yeni örneğin düzlemin sol tarafında kalması olasılığı Şekil A.2(c)'de kalması olasılığından düşük olacaktır. Bu nedenle, örnekler arasında seçilecek aşırıdüzlemin en yakın örneklerden mümkün olduğunca uzak olması, örnek kümesine eklenecek yeni bir örneğin gerçekten ait olduğu grup içerisinde kalma olasılığını en büyük yapacaktır.

DVM yöntemi içinde bulunulan uzayda bir düzlemin elde edilememesi durumunda ayrıca uzayın izdüşümlerini alarak bu tür bir düzlem elde edebildiği bir altuzay bulma yetisine de sahiptir. Bunun dışında kullandığı uzayı doğrusal olmayan izdüşüm alma yöntemleri ile bükerek doğrusal olmayan aşırıdüzlemler de kullanabilmektedir. Fakat, burada problemin anlaşılabilirliğini arttırmak için doğrusal olan durum üzerinde durulmaktadır.

i. Matematiksel Temeller

DVM yöntemi, seçilen destek vektörlerinden bir veya birkaçını (Şekil A.2(d))

$$\bar{w} \cdot \bar{x} + b = +1(y_i = +1) \text{ veya } \bar{w} \cdot \bar{x} + b = -1(y_i = -1) \quad (\text{A.4})$$

düzlemlerine yerleştirerek ayrımı en çoklamayı amaçlar. Bu durumda, birinci gruptan seçilen bir destek vektörü x_1 ve ikinci gruptan seçilen bir destek vektörü x_2 olmak üzere:

$$\bar{w} \cdot (\bar{x}_1 - \bar{x}_2) = 2 \text{ veya } \frac{\bar{w}}{\|\bar{w}\|} \cdot (\bar{x}_1 - \bar{x}_2) = \frac{2}{\|\bar{w}\|} \quad (\text{A.5})$$

problemini ele alır ve $2/\|\bar{w}\|^2$ 'yi en çoklamaya çalışır. Bir başka deyişle, $\|\bar{w}\|^2/2$ en küçük yapılmalıdır. Kısıtlı en iyileme yöntemi kullanılacak olursa

$$L_p = \frac{1}{2} \|\bar{w}\|^2 - \sum_{i=1}^N a_i (y_i \cdot (\bar{w} \cdot \bar{x} - b) - 1) \quad (\text{A.6})$$

denklemini en iyilemek istenilen en küçüklemeyi sağlar.

Bu denklemin çözümündeki kısıtlar ise aşağıdaki gibi olacaktır:

$$(I) \sum_{i=1}^N a_i y_i = 0$$

$$(II) a_i \geq 0 \quad \forall a_i$$


Bu noktaya kadar, grupların doğrusal olarak ayrılabilirdiği kabul edilmiştir. Doğrusal olarak ayrılamayan grupların varolması durumunda problem biraz daha geliştirilerek denkleme bir de ξ_i değişkenleri eklenir (Şekil A.3). Bu durumda eniyileme fonksiyonumuz:

$$L_p = \frac{1}{2} \|\bar{w}\|^2 - C \left(\sum_{i=1}^N \xi_i \right)^k \quad (\text{A.7})$$

olmaktadır. (II) numaralı kıstas ise $C \geq a_i \geq 0 \quad \forall a_i$ ile yer değiştirmektedir.

c. Ardışık İleri Seyyar Arama (AİSA)

Öznitelik seçim algoritmaları çeşitli gruplara ayrılmaktadır. Bu gruplar içerisinde en başarılı olanların ardışık arama yöntemleri olduğu pek çok çalışmada gösterilmiştir. Burada, ardışık arama yöntemleri kısaca anlatılmakta ve neden ardışık ileri seyyar arama yöntemini benimsediğimiz anlatılmaktadır.



Şekil A.3 – Doğrusal olmayan DVM için bir durum gösterimi

Geleneksel bir öznitelik seçimi için giriş olarak verilen öznitelik kümesi C adet sınıftan oluşan, her bir sınıfta G adet örnek verinin bulunduğu, her örnek için F sayısal özniteliğin bulunduğu bir yapıdadır. Ek olarak, elimizde genellikle anlamlı öznitelik alt küme değerlendirme kriterinin bulunmaktadır. Bu nedenle, karışık öz nitelik türleri (sayısal, text, vb.), sınıf büyüklükleri arasında büyük farklar ve eksik veri gibi sorunlarla karşılaşmayız. Gerçek hayattaki problemler genellikle bu kadar güzel yapıda olmazlar, fakat burada arama stratejilerini karşılaştırdığımız için daha geleneksel bir yapı üzerinde karşılaştırma yapmak daha doğru olacaktır.

Bu tür yöntemlerin en basidi bireysel en iyi öznitelik seçimidir. Öznitelikler, bir ölçüt fonksiyonuna bağlı olarak sıralanır ve istenilen sayıda öznitelik bir alt küme oluşturacak şekilde sıralananlar arasında en önemlisinden en önemsizine doğru seçilir. Gerçek verilerin çok azı bu yöntemin başarılı olmasını sağlayacak kadar basit yapıdadır. Bu nedenle, öznitelikler arasındaki ilişkilerin en azından bazılarını ortaya çıkaracak yöntemlere ihtiyaç duyarız.

Bir sonraki basit seçenek ardışık ileri arama (AİA) veya ardışık geri arama (AGA) olmaktadır. Bu yöntemler her seferinde kümeye yeni bir özniteliğin eklenmesi ile uygulanır. Bu yöntemlerin pek çok uygulayıcı tarafından seçilmesine neden olan belli özellikleri vardır:

1. Gerçekleştirilmeleri çok kolaydır,
2. Sadece F adımda (her adım ayrıca en çok F kriter testi içermesine rağmen) sonuç elde edildiği için hızlıdır,
3. Tek bir çalışma süresinde bütün alt küme büyüklükleri için sonuçları verebilirler.

AİA genellikle AGA'dan daha hızlıdır. AGA büyük alt küme gruplarında öznitelik özelliklerini yansıtabilir.

AİA'da boş bir öznitelik kümesi ile başlanır ve her adımda elde bulunan öznitelik alt kümesini en iyileyen öznitelik alt kümeye eklenir. AİA yönteminde her seferinde tek bir öznitelik alt kümeye eklenir. Tek öznitelik eklemek yerine n tane öznitelik ekleme yapıldığı yonteme Genelliştirilmiş Ardışık İleri Arama (GAİA) adı verilir.

AGA, AİA'ya zıt olarak tüm öznitelikleri alt kümede olarak kabul ederek başlar ve her adımda öznitelik kümesini en iyileyen bir öznitelik kümeden çıkarılır. Tek öznitelik çıkarmak yerine n tane öznitelik çıkarma yapıldığı yonteme Genelliştirilmiş Ardışık Geri Arama (GAGA) adı verilir.

AİA ve AGA'nın sorunu tek yönlü arama yapmasıdır. Arama uzayında en yakın yerel optimuma doğru yaklaşma eğilimi gösterirler. Çoğu gerçek veri kümesinde AİA ve AGA daha karmaşık yöntemler tarafından kolaylıkla yenilirler.

AİA ve AGA'nın sağlayamadığı çok yönlü aramayı Artı l - Eksi r seçim yöntemi sağlamaktadır. Bu yöntem alt küme ister boş olarak alınıp doldurularak ya da dolu olarak belirlenip öznitelik çıkarma yapılarak yürütülebilmektedir. Yöntemde her seferinde l adet öznitelik eklenmekte ve r adet öznitelik çıkarılmaktadır. Böylelikle yanlışlıkla eklenen yarasız özniteliklerin altküme dışında bırakılması kolaylaşmaktadır. Bununla birlikte, l ve r sayılarının ne olması gerektiği problemde problemde değiştiği gibi alt kümeden alt kümeye

için optimal bir çözümün elde edilmesi yine kullanıcıya kalmaktadır. l ve r sayılarının belirlenmesi ayrı bir optimizasyon problemidir [121].

Gözle görülür şekilde daha iyi sonuçların elde edilebileceği yöntemler seyyar arama yöntemleri olarak adlandırılır. Ardışık ileri seyyar arama (AİSA) ve ardışık geri seyyar arama (AGSA) seçtiği bir özniteliği yanlış bir şekilde eklediğinde/çıkarttığında geri dönerek bu özniteliği tekrar kümeden çıkartabilmekte/kümeye ekleyebilmektedir. Seyyar arama yöntemleri sahip olduğu iyi performans/hız oranından dolayı oldukça popüler olmuştur.

Algoritma 1

AİSA Algoritması

Girdi:

$$Y = \{y_j \mid j = 1, \dots, D\} // \text{elde bulunan ölçümler} //$$

Çıktı:

$$X_k = \{x_j \mid j = 1, \dots, k, x_j \in Y\}, k = 0, 1, \dots, D$$

Başlangıç:

$$X_0 := \emptyset; k := 0$$

(pratikte ASA iki kere kullanılarak $k = 2$ 'den başlanabilir)

Bitiş:

k ihtiyaç duyulan öznitelik sayısına ulaşıldığında dur

Adım 1 (İçe ekleme)

$$x^+ := \arg \max_{x \in Y - X_k} J(X_k + x) \begin{cases} X_k \text{ 'ya göre} \\ \text{en belirgin öznitelik} \end{cases}$$

$$X_{k+1} := X_k + x^+; k := k + 1$$

Adım 2 (Koşullu Çıkarma)

$$x^- := \arg \max_{x \in X_k} J(X_k - x) \begin{cases} X_k \text{ 'ya göre} \\ \text{en değersiz öznitelik} \end{cases}$$

$$\text{Eğer } J(X_k - \{x^-\}) > J(X_{k-1})$$

$$X_{k-1} := X_k - x^-; k := k - 1$$

Adım 2'ye git

Değilse

Adım 1'e git

Artı l – Eksi r seçim yöntemi'nde l ve r değerleri bir kere belirlenip o şekilde kullanılmaktadır. AİSA ve AGSA yöntemleri ise her adımda değişken bir l ve r değeri seçer. Böylelikle, hem süreci hızlandırabilir, hem de her adımda oluşan tek düzeliğin neden olabileceği hata riski azalır. Seçimin herhangi bir adımında ölçüt fonksiyonu mevcut değerinden daha iyi bir noktaya ulaşana kadar devam edildiği için, çok zor olmayan veri kümelerinde başarı oranı çok yükselebilmektedir. Algoritma 1'de AİSA algortiması için bir sözde kod verilmiştir [122]. Burada, $J(.)$ fonksiyonu bir maliyet fonksiyonudur ve maliyet olarak toplam başarı oranı seçilmiştir.

Bu çalışmada, AİSA yöntemi seçilmiştir. Daha önce bahsedilen gerekçelerden dolayı en uygun yöntemin bu olduğuna karar verilmiştir. AGSA'nın kullanılmama sebebi elde çok fazla miktarda öznelik bulunması ve bizim bunlar arasından çok azını seçecek olmamızdır.

d. Kaynak Olarak Belirlenecek Cihazların ve Programların Çalışma Prensipleri

i. Dijital Kameralar Nasıl Çalışır?

Bir dijital kamera ışığı alıp bir lens aracılığıyla silikon bazlı bir sensörün üzerine odaklar. Sensör, ışığa duyarlı fotobölgelerden oluşan bir ızgara yapısındadır. Bir fotobölge genellikle piksel olarak adlandırılır. Bir DSLR (Digital Single-Lens Reflex) kamera sensöründe bu piksellerden milyonlarca vardır.

Dijital kameralar ışığı uzaysal, parlaklığa dayalı ve zamana bağlı olarak örnekler. Uzaysal örnekleme kameranın gördüğü bakış açısının piksellerden oluşan dikdörtgensel bir ızgaraya bölünmesi anlamına gelir (Şekil A.4). Parlaklığa dayalı örnekleme doğadaki sürekli yapıda bir değişkenliğe sahip parlaklık tonlarının ayırık ton seviyelerine ayrıştırılmasıdır. Eğer her iki örnekleme türünde de yeterince örnek alınacak olunursa, orijinal sahnenin güvenilir bir gösterimi elde edilebilir. Örnek sayısının az olması orijinal sahne ile farkın ve buna bağlı olarak hatanın fazla olmasına neden olmaktadır. Zamanda örnekleme ise belirli bir süre boyunca pozlama yapılmasıdır [123].

İnsan gözü de zamanda pozlamaya denk düşen bir örnekleme yapar. Genellikle, yüksek ışık seviyelerinde insan gözü saniyede onlarca kez bu tür bir örnekleme yapar. Fakat, düşük parlaklık seviyelerinde göz örnekleme süresini birkaç saniyede bire kadar düşürür. Böylelikle, aynı sahne üzerinde daha çok ışığı gözde toplamış olur ve daha anlamlı bir görüntü elde eder. Teleskopa ilk baktığımızda göremediğimiz detayları bir süre sonra ayırıştırabilmemiz bu sayede olmaktadır [123].


Göz göreceli olarak duyarlı bir dedektördür. Tek bir fotonu belirleyebildiği halde, görsel sistemdeki gürültü süzgeç yapısının gereksinim duyduğu işaret-gürültü oranını sağlayan eşiği geçmediği için bu bilgiyi beyne göndermez. Bir görüntü bilgisinin beyne gönderilebilmesi için pek çok fotonun algılayıcı yüzeye düşmesi gerekir. Bir dijital kamera, neredeyse bir göz kadar duyarlıdır.

Bir CCD veya CMOS çip üzerindeki her fotobölge fotoelektrik etki ile fotonları soğurup elektron yayan bir fotodiyot içerisindeki kristal silikondan yapılmış bir ışığa duyarlı bölgeden oluşturulmuştur. Elektronlar pozlamanın yapıldığı süre boyunca bir havuzun içinde elektrik yükü olarak toplanır. Oluşturulan yük sensöre çarpan foton sayısı ile ilişkilidir [123].

Bu elektrik yükü daha sonra bir analog voltaja dönüştürülür ve sayısallaştırılmak üzere bir Analog/Dijital (A/D) çeviriciye gönderilir.

CCD ve CMOS sensörler benzer şekilde fotonları soğurur, elektronları oluşturur ve saklar. Fakat, yükün aktarılması ve bir voltaja dönüştürülmesi aşamasında farklılık gösterirler. Her iki durumda da sonuç sayısal bir çıktı olarak karşımıza çıkar. Sonuçta, Sayısal imge dosyası dizi üzerindeki her bir karenin (piksel) konumu ve parlaklık değerlerini içeren bir sayılar kümesidir [122].

Fotobölgenin bütünü ışığa duyarlı değildir. Sadece fotodiyot ışığa duyarlıdır. Fotobölgenin ışığa duyarlı bölgesinin bütüne oranına doluluk oranı (fill factor) adı verilir. CMOS çipler gibi bazı sensörler için, doluluk oranı bütün fotobölgenin kapladığı alanın sadece yüzde 30 ya da 40'ıdır. Bir CMOS sensörün geri kalan alanı yükseltici ya da gürültü azaltan süzgeçler gibi elektronik devrelerden oluşur [123].



Şekil A.4 – Uzaysal örnekleme ve pikseller

Fotobölgenin küçük bir kısmı ışığa duyarlı olduğu için, çipin toplam duyarlılığı azalmış olur. Bu nedenle, doluluk oranını arttırmak için üreticiler ışığı kırarak fotodiyodun üzerine yansıtacak mikro-lensler kullanırlar.

Fotonların fotodiyoda yansıtılması ile oluşturulan elektronlar pozlama süresince bir havuz içerisinde toplanmaktadır. Bu havuzun büyüklüğüne tüm-havuz kapasitesi (full-well capacity) adı verilir ve yazmaçlar dolana kadar havuzda ne kadar elektronun toplanabileceğini ifade eder. Bazı sensörlerde havuz dolduğunda, elektronlar etraflarındaki komşu havuzları da doldurabilmektedir. Bu duruma çiçeklenme (blooming) adı verilir. Bu durumun en etkin şekilde gözlemlenebileceği örnek çok parlak yıldızların fotoğraflarını çekerken oluşan dikey kabarmalar olmasıdır. Çoğu DSLR kamera çiçeklenme durumunu karşı-çiçeklenme özellikleri sayesinde kolaylıkla ortadan kaldırırlar [123].

Dinamik bölge kameranın sahnedeki soluk ve parlak bölgelerindeki detayları yakalayabildiği parlaklık aralığına demektedir. Bir havuzun toplayabileceği elektron sayısı sensör'ün aynı zamanda dinamik bölgesini de belirler. Gürültü göz önüne alındığında, tüm-havuz kapasitesi büyük olan sensörlerin dinamik bölgeleri de büyük olacaktır denilebilir. Düşük gürültü oranına sahip bir sensör dinamik bölgenin ve soluk bölgelerdeki detayların geliştirilmesine yardımcı olur.

Bir dedektöre çarpan her foton havuza eklenen bir elektron olarak ortaya çıkmamaktadır. Sensörün kuantum etkinliği dedektörden çıkan elektron sayısı ile

dedektöre çarpan foton sayısının oranı olarak ifade edilebilir. Kuantum etkinliği genellikle yüzde oranı ile ifade edilir. Eğer bir sensörün kuantum etkinliği yüzde kırk ile ifade ediliyorsa, sensöre çarpan her on fotondan dördünün elektron olarak havuza ulaşacağı söylenebilir. Modern DSLR kameraların CCD ve CMOS sensörlerinin kuantum etkinlikleri dalgaboyuna bağlı olmak üzere yüzde yirmi ile elli arasında değişmektedir [123].

Havuzda toplanan elektron sayısı sensöre çarpan foton sayısı ile orantılıdır. Havuzdaki elektronlar pozlama bittikten sonra bir voltaja çevrilmektedir. Bu voltaj yükü analogdur ve genellikle çok küçük genliktir. Bu nedenle, sayısallaştırılmadan önce bu voltajın yükseltilmesi gerekmektedir. Okuyucu (Read-out) amfisi sensörün çıkış voltaj bölgesini A/D çeviricinin giriş voltaj bölgesine uyarlayacak şekilde bu görevi yerine getirir. A/D çeviricisi elde edilen voltaj değerini ikili bir sayıya dönüştürür.

A/D çevirici dinamik bölgeyi ayrı basamaklara ayırarak sayısallaştırır. Toplam basamak sayısı çeviricinin bit derinliği ile ilişkilidir. Çoğu DSLR kamera 12 bit (4096 basamak) parlaklığa dayalı derinlikle çalışır.

Sensörün çıktısı teknik olarak analogdan-sayısala-birim (ASB) veya dijital sayı (DS) olarak çağrılır. ASB başına düşen elektron sayısı sistemin kazancını verir. Kazancın 4 olması, A/D çeviricinin her ASB 4 elektrona denk gelecek şekilde sinyali sayısallaştırdığı anlamına gelir [123].

Bir pozlamanın ISO oranı bir fotoğraf filminin hız oranı ile ifade edilmektedir. Işığa duyarlılığı ifade eden genel bir orandır. Dijital kamera sensörleri gerçekte tek bir duyarlılığa sahiptir. Fakat, kameranın kazancını değiştirerek farklı ISO seçenekleri sunmaktadır. Kazanç iki katına çıktığında ASB başına düşen elektron sayısı yarısına inmektedir [123].

Bir dijital kamerada ISO değeri arttırıldığında, daha az elektron bir ASB için dönüştürülmektedir. ISO değerini arttırmak aynı bit derinliğine daha dar bir dinamik bölgeyi sığdırmak demektir ve dinamik bölgeyi küçültür. 1600 ISO değerinde,

sensörün tüm-havuz kapasitesinin 1/16'sı gibi bir miktarını kullanabiliyoruz anlamına gelmektedir.


12 bit bir A/D çeviriciye sahip bir sensördeki her bir piksel için, parlaklık bilgisi 0 ile 4095 arası sayılarla gösterilmektedir. Bir imge dosyasının içinde bu sayısal değerler ve pikselin konum bilgisi tutulur. Bazı DSLR kameralarda, imge dosyası sürekli olarak hafıza kartına yazılmadan önce kameranın dahili arabelleğine yazılabilmektedir [123].

Bu noktaya kadar anlatılanlar renk bilgisinden bağımsız sisteme bağlı üyeler ile ilgiliydi. Renk ögesinin işin içine katılabilmesi için Renk Süzgeç Dizilerinin (RSD) irdelenmesi gerekmektedir.


Renk süzgeç dizileri, her bir fotosensörün üzerine birer renk süzgecinin dizilmesi ile oluşturulmuş yapılardır (Şekil A.5). Böylelikle her bir sensörden bir renk bilgisi elde edilir ve her bir süzgeç bir rengi taşıdığı için komşu piksellerden ortak bir renk bilgisi elde edilir. Ortak renk bilgisinin elde edilmesi aşamasında pikseller arasında ilintililik oluşmaktadır. Kullanılan aradeğerleme algoritmaları oldukça gizlilikle saklanan yöntemlerdir ve her dijital kamerada kendine özgüdür [124].

Renk süzgeç dizilerinin kendileri de farklı yapılarda olabilmektedir (Şekil A.6). Böylelikle elde edilen veriden aradeğerlenecek renk bilgisi de farklı olmaktadır.

Her elektronik sistem gibi dijital kameraların sensör kısımlarında da çevre koşullarından dolayı ortaya çıkan gürültü bulunur. Termal gürültü dışında kırınım yoluyla gelen istenmeyen fotonlar da bu tür gürültülere neden olabilir. Her bir üretici firmanın sensör tasarımı farklı olduğu için ortaya çıkacak gürültünün de yapısı farklı olmaktadır. Bu tür gürültüler özellikle bazı ışıklandırma koşullarında elde edilen imgenin piksel değerlerinde küçüklü büyüklü hatalara neden olabilmektedir ve bu gürültü imgenin pikselleri arasında bir ilintiye neden olur [124].



Şekil A.5 – Bayer Renk Süzgeç Dizisi




Şekil A.6 – Çeşitli RSD türleri


Kameralarda kullanılan optik ekipman, üretim aşamasında pek çok süreçten geçmektedir. Bu süreçler sonucunda yüzeyleri mükemmel yakın düzgünlükte elde edilir. Fakat, mikron boyutunda incelendiğinde bu düz görünümün gerçekte çok da düz olmadığı anlaşılır. Bu mikron boyutundaki bozukluklar ışığın optik ekipmanın bazı yerlerinde ufak farklılıklarla kırılmasına neden olur. Bu ufak farklılıklar ışığın bir sensör üzerine düşmesi yerine yanındakine düşmesine neden olabilir. Optik yüzey sabit olduğu için bu tür bir hata aynı dijital kameraya ait bütün imgelerde gözlemlenir ve pikseller arasında belirli bir ilintiye neden olur [124].

Bu tür durumlarda on farklı optik bozukluk oluşabilmektedir [125]. Bu optik bozukluklar ve hangilerinin nasıl düzeltilebilecekleri şu şekilde ifade edilebilir:

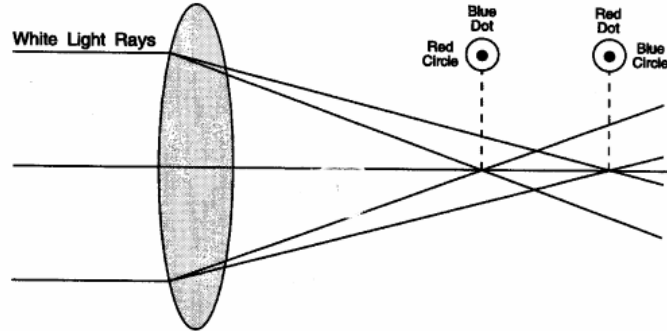
- **Astigmatizm:** Lensin yatay ve dikey odak noktasını aynı düzlem üzerine düşürememe durumudur. Astigmatizme lens eksenine paralel olmayan ışınlar neden olur. Eşit yoğunluktaki (karanlıktaki) çizgiler yatay ve dikey olarak farklı yoğunlukta görünürler. Astigmatizm lens açıklığını az tutarak azaltılabilir.



Şekil A.7 – Koma



Şekil A.8 – Kavisli alan

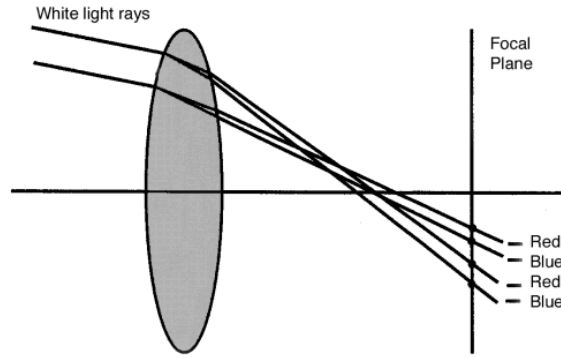


Şekil A.9 – Boylamsal kromatik aberasyon


- **Koma (Coma):** Koma paralel eğik ışınların bir nokta olarak değil de kuyruklu yıldız benzeri oval bir imge olarak oluşmasına neden olur (Şekil A.7). Koma lens açıklığını az tutarak azaltılabilir.
- **Kavisli Alan:** En keskin odak durumunun düzlemi düz değildir ve eğimli bir hal alır (Şekil A.8). Nesne düzlemi üzerindeki dış sınırlardan gelen ışınların neden

olduğu bu durum imgenin sensör üzerinde değil de daha önce odaklanmasına neden olur ve bilinen bir çözüm yolu yoktur.


- **Boylamsal Kromatik Aberasyon:** Bir lensin tüm renkleri lens ekseninde aynı düzleme düşürememesidir (Şekil A.9). Düşük dalgaboylu ışınlar sensörün önüne, yüksek dalgaboylu ışınlar ise arkasında odaklanır. Bu durum genellikle sadece uzun tele-foto lenslerde fark edilebilir. ED, ID, LD ve Flourite adı verilen bazı özel cam ekipmanlar ile azaltılır.
- **Yanal Kromatik Aberasyon:** Odak düzleminde renkli imgelerin yanal olarak birbirinden uzaklaşmasıdır (Şekil A.10). Renkte mavileşmeye ya da kırmızılaşmaya neden olur. Bilinen bir önlem alınmaz.



Şekil A.10 – Yanal kromatik aberasyon




Şekil A.11 – Küresel aberasyon



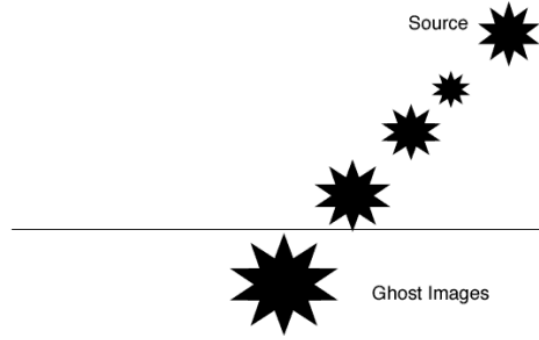
Şekil A.12 – Çarpıtma

- **Küresel Aberasyon:** Bütün ışınların aynı noktaya odaklanamamasıdır (Şekil A.11). Köşelere yakın ışınlar, paraksiyel (merkeze paralel) ışıklardan daha yakına odaklanır.
- **Çarpıtma:** Çarpıtma, düz bir çizgiye ait bir imgenin köşelerinde içe veya dışa eğilmesine neden olur (Şekil A.12). İçe doğru eğilmeye içneleşme (pincushion), dışa doğru eğilmeye varilleşme (barrel) denir.
- **Parlama:** Parlama imge formu almayan ışıktır (Şekil A.13). Zıtlığı ve renk saçılımını azaltır. Parlama çok parlak nesnelere dolaylı olarak olur ve lenste dahili yansımalara neden olur. Kaplamalı lenslerin kullanılması parlamayı en aza indirir.
- **Hayalet İmgeler:** Tam olarak gerçek bir bozukluk değildir ama yine de imgelerde sıklıkla gözlenir (Şekil A.14). Çok parlak ışığa sahip bölgelerin olduğu imgelerde sıklıkla görülür ve aynı imgenin farklı kopyaları imge üzerinde varmış gibi gözlemlenir. Uygun bir lens başlığının kullanılması görülmesini azaltır.
- **Dağılma:** Işığın bir özelliğidir. Dağılma ışığın küçük aralıklardan geçerken bükülerek açılmasıdır. Küçük diyaframlı kameralarda gözlemlenir.

Yukarıda belirtilen on farklı optik bozukluktan bazılarının çözülmesi için farklı yapıda lens katmanları, süzgeçler ve ışık kutuplayıcılar (polarizer) sensör katmanı öncesine yerleştirilir. Bu optik çözümlerin tamamına ön işleme (pre-processing) adı verilir. İmgenin elde edilmesi aşamasında açıklığın, pencereleme süresinin belirlenmesi gibi manüel olarak yapılan ayarlar da bu işleme dahildir.



Şekil A.13 – Parlama



Şekil A.14 – Hayalet imgeler

Bazı sorunlar ise sensörde elde edilen imge üzerinde çeşitli sayısal süzgeçlerin ve operatörlerin yardımı ile ortadan kaldırılır. Çok profesyonel olmayan dijital kameralardan elde edilen imgeler ise bilgisayar ortamında işlenir. Bu süreç de sonradan işleme olarak adlandırılır. Sonradan işleme yöntemlerinden en bilineni kırmızı göz etkisinin ortadan kaldırılmasıdır.

Sensörden elde edilmiş imgenin saklanacak imgeye dönüştürülmesi aşamasında uygulanan bir katman da foto işhattıdır (photo pipeline). Bu katmanda şu işlemler gerçekleştirilir:

- **Ters-mozayikleme:** Renk süzgeç dizisi dolayısıyla oluşturulan uzaysal örnekleme ters-mozayikleme işlemi ile neredeyse tamamen geri çevrilir. Böylelikle, tüm pikseller için üç renk bilgisi de elde edilmiş olur.

- **Renk Uzayı Çevrimi:** Renk süzgeçlerinden elde edilen renk bilgileri RGB uzayını tam olarak ifade etmiyor olabilir. Bu durumda renkleri daha doğru şekilde ifade etmek için elde edilen renk bilgileri yeniden uyarlanır.
- **Doğrusal Beyaz-Dengesiz Düzeltimi:** İnsan görme sistemleri ortam ve aydınlık miktarına bağlı olarak kendisini ayarlar. Doğrusal beyaz dengesi düzeltimi kamera çıktısı ile olması gereken renk arasında bir dengeleme yapmak için gereklidir.
- **Gamma Düzeltimi:** Nokta bazlı doğrusal olmayan bir ters gamma işlevi renk düzeltimi yapılmış imgeye uygulanır ve imgenin ekrana yansıtılacak formunu alması sağlanır.

Bu aşamalarda oluşan hatalar da dijital kameraya özel bazı ilintilerin oluşmasına neden olur ve bu tür durumların analizleri adli kanıt alanında sıklıkla kullanılır.

ii. Tarayıcılar Nasıl Çalışır?

Bir tarayıcı basılı bir metni, bir el yazısını ya da bir nesneyi optik olarak görüntüleyip bilgisayardaki bir sayısal görüntü verisine dönüştürür. Pek çok türü olan tarayıcılar pek çok farklı amaç için de kullanılırlar. Masaüstü uygulamalardan oyun, görüntüleme, modelleme amaçlı 3 boyutlu uygulamalara hemen her yerde kullanılan tarayıcılar türlerine göre farklı yapılarda tasarımlar da içerir. Tarayıcılar türlerine göre altı gruba ayrılabilirler:

- Drum tipi tarayıcılar: Resmi bir hat üzerinde hareket ettirerek sabit bir panelin üzerindeki sensörler aracılığıyla görüntüleme yapar,
- Masaüstü tarayıcılar: Resmi sabit tutarak, cam bir yüzeyin ardından hareket ettirilen sensör dizisi aracılığıyla görüntüleme yapar,
- Film tarayıcıları: Film negatiflerini tarayan bir teknolojidir,
- El tarayıcıları: Masaüstü tarayıcılar gibi çalışır ve sadece el yüzeyindeki çizgilerin siyah beyaz görüntüsünü alır,
- Masaüstü dijital kamera tipi (Reprografik) tarayıcılar: Dijital kameraların çalışma prensiplerine dayanır ve düz yüzeye konan nesnenin fotoğrafını çeker,
- Smartphone tarayıcılar ve barkod okuyucular: Barkod imgeleri ve benzeri tasarımları okumak için tasarlanmış özel tasarımlardır.

Modern tarayıcılar genellikle CCD (charge coupled device) veya CIS (contact image sensor) kullanırken, daha eski teknoloji olan drum tipi tarayıcılar fotoçarpıcı (photomultiplier) tüp sensörleri kullanır.

iii. Bilgisayar Grafiği İmgeler Nasıl Elde Edilir?


Bilgisayar tarafından oluşturulan imgelere genel olarak bilgisayar grafiği (BG) imgeler denir ve sanat, video oyunları, filmler, televizyon programları, reklamlar, simülatörler ve yazılı medyada sıklıkla karşımıza çıkarlar. Elde edilen görsel sahneler statik veya dinamik olabilir. Dinamik (hareketli) BG imgeleri bilgisayar animasyonu olarak adlandırılır.

Üç boyutlu grafik yazılımları dinamik ya da statik BG imgeler üretmek için kullanılan yazılımlardır. Günümüzde, büyüklü küçüklü pek çok firma bazen genelleşmiş yazılımları kullanarak, bazen de kendi özel yazılımlarını yazarak film ve reklam endüstrisinde BG imgeler üretmektedir. Hatta bu sektördeki bazı firmalar markalaşmış ve çalışanları pek çok Hollywood ünlüsü gibi bilinen insanlar haline gelmiştir.


1. Statik İmgeler ve Yeryüzü Görüntüleri

Sadece animasyon görüntüleri BG imgelemenin bir parçası değildir. Doğal görünümlü yeryüzü görüntüleri (örn. fraktal görüntüler) de bilgisayar algoritmaları aracılığıyla türetilir (Şekil A.15). Fraktal yüzeyler türetmenin kolay bir yolu üçgensel ağ yönteminin bir benzerini kullanmaktır. Sierpinski üçgenleri (Şekil A.16) denen bir yöntemle yüksekliği değişen topoğrafik bir haritanın fraktal bir benzerini türetmek oldukça kolay olmaktadır.

Yüksek oranda gerçekçiliğe sahip bilgisayar tabanlı efektlerin oluşturulması için pek çok özel teknik (örn. Taşların kimyasal yaşlanması için bir modelleme yaparak erozyonu bilgisayar ortamında göstermek) araştırılmış ve geliştirilmiştir. Fakat, bu tür bir modelleme o kadar yumuşak geçişli imgeler elde edilmesine neden olmaktadır ki doğal imgelerde karşılaştığımız gürültülerden iz olmaz.



Şekil A.15 – Fraktal olarak elde edilmiş bir yeryüzü görüntüsü



Şekil A.16 – Sierpinski üçgenleri

2. Mimari Görüntüler

Modern mimarlar müşteriler ve inşa edeceklere gösterebilmek için binaların 3 boyutlu modellerini üretmek için bilgisayar grafiği türeten firmaların hizmetlerinden faydalanmaktadır. Bu tür BG modeller geleneksel çizimlerden çok daha başarılı olmaktadır (Şekil A.17). Binanın etrafındaki binalarla ilişkisini, çevre koşullarını göstermek için üç boyutlu animasyonların yapılması da yaygın hale gelmiştir.

Mimari alanların kaplanması günümüzde birkaç bilgisayar yardımı mimari tasarım sistemi tarafından gerçekleştirilmektedir. Bu tür imgeler ve animasyonlar özellikle müşterilerin ilgisini çekmek için aşırı gerçekçi yapılmamakta ve daha yumuşak geçişli görünümle müşterinin ilgisi çekilmektedir.



Şekil A.17 – Bir binanın BG ile elde edilmiş çevre görüntüsü

3. Anatomik Modeller

Bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) gibi kimi görüntüleme sistemleri üç boyutlu kemik ve organ görüntüleme gibi kimi amaçlar için bilgisayar grafiği imgeler üretmektedir.

4. Kaplama

Kaplama bilgisayar programları kullanarak bir modelin/modellerin bir imge haline dönüştürülmesi sürecidir. Modellerden oluşan dosyaya *sahne dosyası* denir. Bir *sahne dosyası*'nda, sahne içerisindeki tüm geometriler, bakış açıları, dokular, ışıklandırma ve gölgelendirme bilgisi bulunur. Bu bilgi katı bir şekilde belirlenmiş bir dilde ya da bir veri yapısında tutulur ve daha sonra kaplama yazılımına aktarılır.

Kaplama yazılımlarının teknik detayları yazılımdan yazılıma değişmektedir. Sonuçta elde edilen veri üç boyutlu bir görünümün iki boyutlu bir gösterimidir. Elde edilen bilgi daha sonra Grafik İşleme Ünitesi (GPU) denen yapıya yollarır.


Bir GPU karmaşık kaplama denklemlerini çözebilen amaca yönelik bir cihazdır. Kaplama denklemleri ise bir sahneyi ifade etmek için kullanılan denklemlerdir. Kaplama denklemleri bütüm ışıklandırma koşullarını ifade edemezler. Bu nedenle bazı durumlarda belirgin hatalara neden olabilirler. Elde edilen sonuç bir imge dosyası içerisinde saklandığında bu tür küçük hatalar da imgenin içinde saklanmış olur.

5. Işın İzleme

Işın izleme bir imge düzleminde ışığın pikseller üzerinde geçtiği yolları izleme üzerine kurulu bir yöntemdir. Bu şekilde yüksek fotogerçekçilikte BG imgelerin elde edilmesi mümkün olmaktadır. Yöntemin kötü yanı yüksek bir hesaplama maliyeti ile başarılı sonuçlar almasıdır. Gerçek hayatta karşılaşılan yüzeyden kırınım durumu genelde bu tür yöntemlerde göz önüne alınmadığından bazen pikseller üzerindeki ışık miktarları gerçek hayattaki olması gerekenden biraz farklı bir şekilde hesaplanabilmektedir.

6. Gölgeleme

Gölgeleme üç boyutlu modellerde derinliği farklı karanlık seviyeleri ile ifade etmeye denir (Şekil A.18). Yöntem karanlık bölgeleri daha yoğun veya daha karanlık gölgelemek ve aydınlık bölgeleri daha az yoğun ya da daha az karanlık gölgelemek şeklinde uygulanır. Gölgelemenin eğik tarama (cross hatching) gibi pek çok uygulama yöntemi vardır. Eğik taramada bir bölgedeki doğru parçalarının sayısını arttırarak ya da azaltarak daha karanlık ya da daha parlak bölgeler elde edilmektedir. Eğik tarama terimi yakın zamanda gölgelemicileri tanımlamak için kullanılmaya başlamıştır. Doğal imgelerde var olmayan bu tür doğru parçacıklarının varlığı iki boyutlu imgeler üzerinde bazı farklılara neden olabilmektedir.



Şekil A.18 – Gölgelemeye bir örnek



Şekil A.19 – Hacim kaplamaya bir örnek

7. Doku Haritalama

Doku haritalama üç boyutlu bir modele veya bir bilgisayar tabanlı grafiğe detay, yüzey dokusu veya renk vermek için kullanılan yöntemdir. Burada, yapay olarak oluşturulmuş ya da gerçek hayattan alınmış bir doku görüntüsü bir yüzey üzerine haritalanmaktadır. Daha gelişmiş bir yöntem olan çoklu doku haritalama yüzeye aynı anda birden fazla dokunun haritalanması ile oluşturulur. Bazen yüzeyin şekline bazı ayrıntıları vermek yerine dokuya bu ayrıntıları işleyerek yüzeyi olduğundan farklı göstermek sıkça kullanılan bir yöntem haline gelmiştir. Bu durumda ise bazı hataların ortaya çıkması doğaldır.

8. Örtüşme Önleyici (Anti-aliasing)

Çözünürlükten bağımsız kaplanmış objelerin bir piksel tabanlı imgeye dönüştürülmesi sırasında örtüşme durumunun oluşması kaçınılmazdır. Özellikle geometrik şekillerin bağlantı noktalarında veya nesnelerin detay kısımlarında karşılaştığımız bu sorun örtüşme önleyici filtreler aracılığıyla göze daha hoş görünen ve bozuklukların yokmuş gibi gözükteği bir hale sokulur. Bu durumda, imgenin örtüşme yaşanan bölgelerinde doğal olmayan artıklar kalır.

9. Hacim Kaplama

Hacim kaplama üç boyutlu ayrık bir veri kümesinin iki boyutlu izdüşümünün görüntülenmesi üzerine kurulu bir tekniktir (Şekil A.19). BT ve MRG imgelerinde sıkça karşımıza çıkabilen bu teknikler elde edilen verinin ayrık olması nedeniyle izdüşüm alma aşamasında belirgin izlere sahip olabilmektedir.