

**KARADENİZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**İSTATİSTİKSEL VE DOKUSAL ÖZELLİKLERİ KULLANAN HİBRİT  
GÖRÜNTÜ BİRLEŞTİRME SAHTECİLİĞİ TESPİT YÖNTEMİ**

**DOKTORA TEZİ**

**Bil. Yük. Müh. Esra ODABAŞ YILDIRIM**

**KASIM 2019**  
**TRABZON**



**KARADENİZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**İSTATİSTİKSEL VE DOKUSAL ÖZELLİKLERİ KULLANAN HİBRİT  
GÖRÜNTÜ BİRLEŞTİRME SAHTECİLİĞİ TESPİT YÖNTEMİ**

**Bil. Yük. Müh. Esra ODABAŞ YILDIRIM**

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde  
“DOKTOR (BİLGİSAYAR MÜHENDİSLİĞİ)”  
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih : 21.10.2019  
Tezin Savunma Tarihi : 08.11.2019**

**Tez Danışmanı : Doç. Dr. Güzin ULUTAŞ**

**Trabzon 2019**

**KARADENİZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**Bilgisayar Mühendisliği Anabilim Dalında  
Esra ODABAŞ YILDIRIM Tarafından Hazırlanan**

**İSTATİSTİKSEL VE DOKUSAL ÖZELLİKLERİ KULLANAN HİBRİT  
GÖRÜNTÜ BİRLEŞTİRME SAHTECİLİĞİ TESPİT YÖNTEMİ**

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 22/10/2019 gün ve 1824 sayılı  
kararıyla oluşturulan jüri tarafından yapılan sınavda  
DOKTORA TEZİ  
olarak kabul edilmiştir.**

**Jüri Üyeleri**

**Başkan : Prof. Dr. Suat ÖZDEMİR**

**Üye : Prof. Dr. Cemal KÖSE**

**Üye : Prof. Dr. Erdal KILIÇ**

**Üye : Doç. Dr. Güzin ULUTAŞ**

**Üye : Doç. Dr. Önder AYDEMİR**

  
.....  
.....  
.....  
.....  
.....

**Prof. Dr. Asim KADIOĞLU  
Enstitü Müdürü**

## ÖNSÖZ

Günümüzde sayısal görüntülerin kullanımının yaygınlaşması ve bu görüntüler üzerinde değişiklik yapmaya yarayan açık kaynak kodlu yazılımların varlığı, görüntü sahteciliğini kolaylaştırmış ve yaygınlaştırmıştır. Kullanılan görüntülerin adli nitelik taşıyabilmesi ve kötü niyetli kullanımların şahıs kurum ve kuruluşları zor durumda bırakacak sonuçlara yol açabilmesi nedeniyle görüntülerin sahte veya orijinal olduğunun tespiti (doğrulanması) kaçınılmaz bir gereksinim olmuştur. Bu tez çalışmasında yeni yaklaşımlar ortaya konularak görüntü birleştirme sahteciliğini tespit eden pasif görüntü doğrulamasını gerçekleyen bir sistem tasarlanmıştır.

Çalışmalarında danışmanlığımı üstlenen, her türlü destek ve katkılarıyla çalışmamı yönlendiren çok değerli danışman hocam Sayın Doç. Dr. Güzin ULUTAŞ'a sonsuz teşekkürlerimi bir borç bilirim.

Çalışma sürecinde değerli görüş ve katkılarını esirgemeyen hocalarım Sayın Prof. Dr. Cemal KÖSE ve Doç. Dr. Önder AYDEMİR'e ayrıca teşekkür ederim.

Doktora eğitimimin her aşamasında yanımda olan eşim Mustafa YILDIRIM'a ve sevgili oğlum Eymen'e, bana her türlü desteği sunan annem, babam ve kardeşlerime teşekkür ederim.

Esra ODABAŞ YILDIRIM  
Trabzon, 2019

## TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduđum “İstatistiksel ve Dokusal Özellikleri Kullanan Hibrit Görüntü Birleřtirme Sahteciliđi Tespit Yöntemi” bařlıklı bu alıřmayı bařtan sona kadar danıřmanım Do. Dr. Güzin ULUTAŐ’ın sorumluluđunda tamamladıđımı, verileri/örnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, bařka kaynaklardan aldıđım bilgileri metinde ve kaynakada eksiksiz olarak gösterdiđimi, alıřma sürecinde bilimsel arařtırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya ıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 21/10/2019

Esra ODABAŐ YILDIRIM

## İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET .....	VIII
SUMMARY .....	IX
ŞEKİLLER DİZİNİ .....	X
TABLolar DİZİNİ.....	XIII
SEMBOLLER DİZİNİ .....	XIV
1. GENEL BİLGİLER.....	1
1.1. Giriş .....	1
1.2. Görüntü Üzerinde Yapılan Sahtecilik Yöntemleri .....	2
1.3. Tezin Kapsamı .....	4
1.4. Görüntü Birleştirme Sahteciliği Tespiti.....	5
1.4.1. Ön işleme .....	5
1.4.2. Öznitelik Çıkarma.....	6
1.4.3. Öznitelik Seçme.....	16
1.4.4. Görüntüleri Sınıflandırma.....	17
2. YAPILAN ÇALIŞMALAR.....	19
2.1. Sahtecilik Tespitinde Görüntü Ön İşleme ile İlgili Yapılan Çalışmalar.....	24
2.1.1. Renk Uzaylarının Değerlendirilmesi .....	24
2.1.2. Frekans Domenlerinin İncelenmesi .....	26
2.2. Görüntüdeki İstatistiksel Bozulmaların Değerlendirilmesi .....	30
2.2.1. Durum Geçiş Modeli ve Geçiş Olasılık Matrislerinin Elde Edilmesi .....	31
2.2.2. Ayrık Dalgacık Dönüşüm Domeni Düşük Frekans Bileşenlerinde Durum Geçiş Modeli Tabanlı Sahtecilik Tespiti .....	32
2.2.3. DCT Yüksek Frekans Bölgesinde Durum Geçiş Modeli ile Sahtecilik Tespiti .....	34
2.3. Görüntüdeki Dokusal Bozulmaların Değerlendirilmesi .....	36
2.3.1. Görüntüden GLCM'lerin Elde Edilmesi .....	37
2.3.2. Hilbert Domende LBP ve Entropi Tabanlı Birleştirme Sahteciliğinin Tespiti .....	39

2.4.	Görüntüdeki Dokusal ve İstatistiksel Bozulmaların Hibrit Bir Yaklaşımla Değerlendirilmesi .....	45
2.4.1.	SWT Domende Durum Geçiş Modeli ve GLCM Tabanlı Dokusal Özniteliklerin Hibrit Kullanımı ile Birleştirme Sahteciliği Tespiti .....	45
2.5.	Görüntüleri Sınıflandırmada Farklı Sınıflandırıcıların Performans Değerlendirmesi.....	50
2.5.1.	Destek Vektör Makineleri (SVM) .....	50
2.5.2.	K-En Yakın Komşu Sınıflandırması (KNN) .....	54
3.	BULGULAR VE İRDELEME .....	55
3.1.	Veri Setleri.....	55
3.2.	Kullanılan Ölçütler .....	57
3.3.	İstatistiksel Özniteliklere Dayalı Birleştirme Sahteciliğinin Tespiti ve Elde Edilen Deneysel Sonuçlar .....	60
3.3.1.	DWT Domende Markov Tabanlı Görüntü Birleştirme Sahteciliği Tespitinin Değerlendirilmesi ve Elde Edilen Deneysel Sonuçlar.....	60
3.3.1.1.	Yöntemi Oluşturan En Uygun Alt Senaryonun Belirlenmesi İçin Yapılan Performans Testleri .....	61
3.3.1.2.	Önerilen Yöntemin Literatürdeki Benzer Yöntemlerle Kıyaslanması .....	64
3.3.2.	DCT Dömen Yüksek Frekans Bölgesinde Markov Tabanlı Görüntü Birleştirme Sahteciliğinin Tespiti ve İrdelenmesi .....	66
3.3.2.1.	Yöntemi Oluşturan En Uygun Alt Senaryonun Belirlenmesi İçin Yapılan Performans Testleri .....	67
3.3.2.2.	Önerilen Yöntemin Literatürdeki Benzer Yöntemlerle Kıyaslanması .....	70
3.4.	Dokusal Özniteliklere Dayalı Birleştirme Sahteciliği Tespiti ve Elde Edilen Deneysel Sonuçlar.....	71
3.4.1.	Hilbert Domende Dokusal Bozulmaları Kullanarak Görüntülerin Doğrulanması ve Elde Edilen Deneysel Sonuçlar .....	71
3.4.1.1.	Yöntemi Oluşturan En Uygun Alt Senaryonun Belirlenmesi İçin Yapılan Performans Testleri .....	72
3.4.1.2.	Önerilen Yöntemin Performans Analizi .....	78
3.5.	Dokusal ve İstatistiksel Bozulmalara Dayalı Hibrit Bir Birleştirme Sahteciliği Tespiti ve Elde Edilen Deneysel Sonuçlar .....	83
3.5.1.	SWT Domende Durum Geçiş Modeli ve GLCM Tabanlı Dokusal Özniteliklerin Hibrit Kullanımı ile Birleştirme Sahtecilik Tespiti ve Elde Edilen Deneysel Sonuçlar .....	83
3.5.1.1.	Yöntemi Oluşturan En Uygun Alt Senaryonun Belirlenmesi İçin Yapılan Performans Testleri .....	84
3.5.1.2.	Önerilen Yöntemin Performans Analizi .....	97

3.6.	Farklı Sınıflandırıcıların Kullanılması ile Sahte Görüntülerin Tespiti ve Elde Edilen Deneysel Sonuçlar .....	102
4.	SONUÇLAR.....	108
5.	ÖNERİLER.....	112
6.	KAYNAKLAR .....	114
7.	EKLER .....	122
ÖZGEÇMİŞ		





Doktora Tezi

ÖZET

İSTATİSTİKSEL VE DOKUSAL ÖZELLİKLERİ KULLANAN HİBRİT GÖRÜNTÜ  
BİRLEŞTİRME SAHTECİLİĞİ TESPİT YÖNTEMİ

Esra ODABAŞ YILDIRIM

Karadeniz Teknik Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı  
Danışman: Doç. Dr. Güzin ULUTAŞ  
2019, 121 Sayfa, 4 Sayfa Ek

Sayısal görüntüler üzerinde en sık karşılaşılan sahtecilik türleri kopyala taşı ve görüntü birleştirme sahteciliğidir. Bu tez çalışmasında görüntü birleştirme sahteciliği alanındaki problemler irdelenmiş ve bu problemlere çözüm getirecek şekilde birleştirilmiş sahte görüntüleri tespit edecek yeni yöntemler önerilmiştir. Yapılan çalışmalarla literatürde ilk kez kenar görüntüleri üzerinden Hilbert Dönüşüm Uzayından elde edilen dokusal öznitelikler değerlendirilmiş ve bu öznitelikler ile birleştirilmiş sahte görüntüler yüksek doğrulukla tespit edilmiştir. Önerilen bir başka yöntemde literatürde ilk kez görüntüdeki dokusal ve istatistiksel öznitelikler hibrit bir şekilde SWT domende sahtecilik tespiti için kullanılarak, yüksek doğruluk oranına ulaşılmıştır. Bu yaklaşımlarla farklı atak tiplerine karşı (döndürme, ölçekleme, deformasyon gibi) dayanıklılık sağlanmıştır. Yapılan çalışmalarda algılama performansını artırmak için öznitelik seçme algoritmaları gibi herhangi ek bir işleme ihtiyaç duyulmamıştır. Önerilen yöntemler sayesinde uzman bir sistemden beklenir şekilde %99'un üzerinde doğruluk oranı ile sahte görüntüler tespit edilmiştir. Önerilen birleştirilmiş sahte görüntüleri tespit etme yöntemlerinden elde edilen sonuçların literatürdeki benzer çalışmalarla kıyaslaması gerçekleştirilerek üstünlükleri ortaya konmuştur.

**Anahtar Kelimeler:** Görüntü Birleştirme Sahteciliği Tespiti, Pasif Yöntemler, Görüntü Sahteciliği, İstatistiksel Öznitelikler, Dokusal Öznitelikler.

PhD. Thesis

SUMMARY

A HYBRID IMAGE SPLICING DETECTION METHOD BASED ON STATISTICAL AND  
TEXTURAL FEATURES

Esra ODABAŞ YILDIRIM

Karadeniz Technical University  
The Graduate School of Natural and Applied Sciences  
Computer Engineering Graduate Program  
Supervisor: Assoc. Prof. Güzin ULUTAŞ  
2019, 121 Pages, 4 Pages Appendix

Copy move and image splicing forgery are the most common types of forgery on digital images. In the scope of the study, problems in the field of image splicing forgery were examined and new methods to detect spliced images, were proposed. For the first time in the literature, textural properties were evaluated on the edge images on Hilbert Transform Domain and spliced images are detected with those properties. Another proposed method is utilized the textural and statistical features on a hybrid manner on SWT domain with a high accuracy rate, also the first time in the literature. Robustness to different attack types (rotation, scaling, deformation etc.) with these approaches is provided. In order to improve the detection performance, no additional processes such as feature selection algorithms were needed. With the proposed methods, forged images were detected with an accuracy rate of over 99%, as expected from an expert system. Results are compared with similar studies reported in the literature to reveal the strengths of proposed detecting image splicing methods.

**Key Words:** Image Splicing Forgery Detection, Passive Methods, Image Forgery, Statistical Features, Textural Features.

## ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1.	Görüntü doğrulamada kullanılan yöntemlerin gruplanması..... 2
Şekil 1.2.	Kopyala-taşı sahteciliği ile oluşturulan sahte görüntü ..... 3
Şekil 1.3.	Görüntü birleştirme sahteciliği ile oluşturulan sahte görüntü ..... 3
Şekil 1.4.	(a) Gürültü ilavesi ile başka bir görüntüden gelen kuş eklenmesi. (b) Başka bir görüntüden alınan oyuncak ördeğin herhangi bir işleme tabi tutulmadan eklenmiş hali ..... 12
Şekil 1.5.	Sınıflandırma akış şeması..... 18
Şekil 2.1.	Sahte görüntünün YCbCr renk uzayı dönüşümü..... 24
Şekil 2.2.	Sahte görüntünün YCbCr renk uzayındaki kanallara ayrıştırılması..... 25
Şekil 2.3.	Sahte görüntünün Lab renk uzayına dönüşümü ..... 25
Şekil 2.4.	Tek seviyeli ayrık dalgacık dönüşümü..... 27
Şekil 2.5.	a)DWT, b)SWT ile dalgacık dönüşümü prosedürü..... 28
Şekil 2.6.	Kaldırılmalı dalgacık dönüşümü şeması ..... 30
Şekil 2.7.	Önerilen yöntem-1'in [56] akış diyagramı..... 33
Şekil 2.8.	Önerilen yöntem-2'nin akış şeması..... 35
Şekil 2.9.	DCT katsayılarının zigzag sıralaması ..... 36
Şekil 2.10.	GLCM'de $d=1$ ve $\theta= 0^0, 45^0, 90^0, 135^0$ döndürme açısı ile kullanılan pikseller ..... 38
Şekil 2.11.	GLCM'nin oluşturulması. a) $4 \times 4$ 'lük dört gri seviyeli görüntü b) $d=1$ ve $\theta=0$ parametreleri ile GLCM oluşturulması ..... 39
Şekil 2.12.	Önerilen yöntem-3'ün akış şeması..... 40
Şekil 2.13.	a) Orijinal görüntüler ve kenar görüntüleri, b) Sahte görüntüler ve kenar görüntüleri ..... 42
Şekil 2.14.	LBP operatörünün işleyişi..... 44
Şekil 2.15.	Önerilen yöntem-4'ün [58] akış şeması ..... 47
Şekil 2.16.	Doğrusal ayrılan veriler için SVM ile karar düzlem seçimi..... 51
Şekil 2.17.	İki sınıflı bir problem için (a) Hiper düzlemler (b) Optimum hiper düzlem ve destek vektörleri..... 51
Şekil 2.18.	Hiper düzlemlerin gösterimi..... 52
Şekil 2.19.	Doğrusal olarak ayrılamayan veriler ve hiper düzlemin belirlenmesi ..... 53
Şekil 2.20.	KNN algoritması ile yeni gelen örneğin sınıfının belirlenmesi ..... 54
Şekil 3.1.	CASIA v1.0 veri setinden örnek görüntüler..... 56
Şekil 3.2.	CASIA v2.0 veri setinden örnek görüntüler..... 57

Şekil 3.3.	Columbia Üniversitesi veri setinden örnek görüntüler .....	57
Şekil 3.4.	10 katlı çapraz doğrulama şeması .....	59
Şekil 3.5.	Rastgele alt örnekleme çapraz doğrulama şeması .....	59
Şekil 3.6.	(a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-1 [56] ile elde edilen öznelik vektörleri, (e) b ve c görüntülerinden önerilen yöntem-1 [56] ile elde edilen öznelik vektörleri.....	63
Şekil 3.7.	(a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-1 [56] ile elde edilen öznelik vektörleri, (e) b ve c görüntülerinden önerilen yöntem-1 [56] ile elde edilen öznelik vektörleri.....	64
Şekil 3.8.	Farklı kuantalama değerinin sistem performansına etkisi (CASIA v1.0).....	67
Şekil 3.9.	Renk kanallarına göre elde edilen doğruluk oranları (CASIA v1.0).....	68
Şekil 3.10.	(a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-2 [57] ile elde edilen öznelik vektörleri, (e) b ve c görüntülerinden önerilen yöntem-2 [57] ile elde edilen öznelik vektörleri.....	69
Şekil 3.11.	(a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-2 [57] ile elde edilen öznelik vektörleri, (e) b ve c görüntülerinden önerilen yöntem-2 [57] ile elde edilen öznelik vektörleri.....	70
Şekil 3.12.	Önerilen yöntem-3 ile CASIA v1.0 üzerinde farklı renk kanallarının doğruluk oranları .....	75
Şekil 3.13.	(a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-3 ile elde edilen entropiye dayalı öznelik vektörü, (e) a ve c görüntülerinden önerilen yöntem-3 ile elde edilen varyans bilgisine dayalı öznelik vektörleri .....	76
Şekil 3.14.	(a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-3 ile elde edilen entropiye dayalı öznelik vektörü, (e) a ve c görüntülerinden önerilen yöntem-3 ile elde edilen varyans bilgisine dayalı öznelik vektörleri .....	78
Şekil 3.15.	Önerilen yöntem-3'ün farklı veri setleri üzerindeki deneysel sonuçları .....	79
Şekil 3.16.	CASIA v2.0 veri seti üzerinde farklı atak tiplerinin analizi.....	80
Şekil 3.17.	CASIA v1.0 veri seti üzerinde farklı atak tiplerinin analizi.....	81
Şekil 3.18.	Önerilen yöntemin [15, 21] ile CASIA v2.0 veri setinde farklı atak tiplerindeki performans değerlendirmesi .....	82
Şekil 3.19.	Önerilen yöntemin [21]'deki yöntem ile CASIA v1.0 veri setinde farklı atak tiplerindeki performans değerlendirmesi .....	83
Şekil 3.20.	[58]'deki yöntemde farklı eşik değeri (T)'nin sistem performansına etkisi .....	85

Şekil 3.21.	(a) CASIA v1.0, (b) CASIA v2.0, (c) Columbia (renkli) veri setleri üzerinde renk kanallarının önerilen yöntemin [58] performansına etkisinin değerlendirilmesi. ....	86
Şekil 3.22.	(a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-4 ile elde edilen dokusal tabanlı öznelik vektörü, (e) a ve c görüntülerinden önerilen yöntem-4 ile elde edilen istatistiksel tabanlı öznelik vektörleri .....	89
Şekil 3.23.	(a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-4 ile elde edilen dokusal tabanlı öznelik vektörü, (e) a ve c görüntülerinden önerilen yöntem-4 ile elde edilen istatistiksel tabanlı öznelik vektörleri .....	90
Şekil 3.24.	Örnek bir GOM matrisi .....	91
Şekil 3.25.	a) Sahte görüntü, b) Orijinal görüntü, c) Sahte görüntüden elde edilen SWT alt bantları, d) Orijinal görüntüden elde edilen SWT alt bantları .....	92
Şekil 3.26.	Önerilen yöntemde [58] SWT domen LH bandında a) yatay fark matrisinden b) dikey fark matrisinden c) köşegenel fark matrisinden elde edilen GOM'ler.....	94
Şekil 3.27.	(a) eklemli sahte görüntü, (b) orijinal görüntü .....	95
Şekil 3.28.	Önerilen yöntemde [58] SWT domen LH bandında a) yatay fark matrisinden b) dikey fark matrisinden c) köşegenel fark matrisinden elde edilen GOM'ler.....	96
Şekil 3.29.	[58] ile önerilen yöntemin farklı atak tiplerine karşı CASIA v2.0'da gösterdiği performans.....	97
Şekil 3.30.	Önerilen yöntemde [58] farklı kalite faktörüne sahip JPEG görüntülerden elde edilen doğruluk oranları .....	98
Şekil 3.31.	Literatürdeki benzer yöntemlerle CASIA v1.0 ve CASIA v2.0 veri seti üzerinde elde edilen ortalama TNR, TPR ve doğruluk oranlarının karşılaştırılması .....	99
Şekil 3.32.	Öznelik vektör boyutunun literatürdeki diğer yöntemlerle kıyaslanması .....	101
Şekil 3.33.	[58]'te önerilen yöntemin çalışma [15] ve [21] ile CASIA v2.0 veri seti üzerinde farklı atak tipleri için performans analizi.....	102

## TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 2.1. Görüntü birleştirme sahteciliği tespitinde literatürde var olan çalışmalar ve özellikleri .....	20
Tablo 3.1. Veri setlerinde renk kanallarına göre elde edilen doğruluk oranları .....	62
Tablo 3.2. [56] önerilen yöntemin farklı filtreler kullanılması ile CASIA v1.0 veri setinde elde ettiği doğruluk oranları.....	62
Tablo 3.3. Önerilen yöntemin [56] DWT domen farklı alt bantlarda CASIA v1.0 veri setinde elde ettiği doğruluk oranları.....	62
Tablo 3.4. Önerilen yöntem-1'in [56] literatürdeki diğer yöntemlerle karşılaştırılması .....	65
Tablo 3.5. Önerilen yöntem-2'nin [57] literatürdeki diğer yöntemlerle karşılaştırılması .....	71
Tablo 3.6. Önerilen yöntemin farklı kenar algoritmaları ile CASIA v1.0 üzerinde test edilmesi .....	72
Tablo 3.7. Önerilen yöntemin farklı frekans domenlerinde CASIA v1.0 üzerinde test edilmesi.....	73
Tablo 3.8. Farklı renk kanallarının performans değerlendirilmesinin CASIA v1.0 veri seti üzerinde değerlendirilmesi .....	74
Tablo 3.9. Dokusal bozulmalara dayalı önerilen yöntemin literatürdeki benzer yöntemlerle performans karşılaştırması .....	81
Tablo 3.10. Sahte ve Orijinal görüntülerin sınıflandırılmasında kullanılan karmaşıklık matrisi .....	87
Tablo 3.11. Farklı veri setlerinin ((a) CASIA v1.0, (b) CASIA v2.0, (c) Columbia) sınıflandırılmasındaki karmaşıklık matrisleri .....	87
Tablo 3.12. [58] ile önerilen yöntemin farklı veri setleri üzerinde diğer yöntemlerle birlikte performans analizi .....	100
Tablo 3.13. [58] ile önerilen yöntemin sınıflandırmasında CASIA v1.0 veri seti üzerinde uygun sigma değerinin belirlenmesi.....	103
Tablo 3.14. [58] ile önerilen yöntemin KNN ile sınıflandırmasında CASIA v1.0 veri seti üzerinde uygun K değerinin belirlenmesi.....	104
Tablo 3.15. [58]'deki yöntemin üç farklı veri seti üzerinde farklı sınıflandırıcılarda elde ettiği performans değerlendirmesi.....	106
Tablo 4.1. Tez kapsamında önerilen yöntemlerin literatürdeki yöntemlerle kıyaslanması .....	110

## SEMBOLLER DİZİNİ

<b>DWT</b>	: Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform)
<b>SPT</b>	: Yönlendirilebilir Piramit Dönüşümü (Steerable Pyramid Transform)
<b>IQMs</b>	: Görüntü Kalite Ölçütleri (Image Quality Metrics)
<b>ANN</b>	: Yapay Sinir Ağları (Artificial Neural Networks)
<b>HHT</b>	: Hilbert Hough Dönüşümü (Hilbert Hough Transform)
<b>LBP</b>	: Yerel İkili Örüntü (Local Binary Pattern)
<b>DCT</b>	: Ayırık Kosinüs Dönüşümü (Discrete Cosine Transform)
<b>LPQ</b>	: Yerel Faz Kuantalaması (Local Phas Quantization)
<b>WLD</b>	: Weber Yerel Tanımlayıcı (Weber Local Descriptor)
<b>QDCT</b>	: Kuaternion Ayırık Kosinüs Dönüşümü ()
<b>VAM</b>	: Görsel Dikkat Modeli (Visual Attention Model)
<b>PRNU</b>	: Foto Tepki Düzensizliği (Photo Response non-uniformity)
<b>SVM</b>	: Destek Vektör Makineleri (Support Vector Machines)
<b>CRF</b>	: Kamera Tepki Fonksiyonu (Camera Response Function)
<b>SVM-RFE</b>	: Destek Vektör Makineleri Özyinelemeli Özellik Seçme (Support Vector Machines-Recursive Feature Elimination)
<b>KNN</b>	: K En Yakın Komşu (k Nearest Neighbour)
<b>GLCM</b>	: Gri Seviye Eş Oluşum Matrisi (Gray Level Co-occurrence Matrice)
<b>SWT</b>	: Sabit Dalgacık Dönüşümü (Stationary Wavelet Transform)
<b>LWT</b>	: Kaldırılmalı Dalgacık Dönüşümü (Lifting Wavelet transform)
<b>BEMD</b>	: İki boyutlu Mod Ayırıştırma (Bi-empirical Mode Decomposition)
<b>EMD</b>	: Deneysel Mod Ayırıştırma (Empirical Mode Decomposition)
<b>GOM</b>	: Geçiş Olasılık Matrisi
<b>TPR</b>	: Doğru Pozitif Oranı (True Positive Rate)
<b>TNR</b>	: Doğru Negatif Oranı (True NEgative Rate)

# 1. GENEL BİLGİLER

## 1.1. Giriş


Son yıllarda teknolojinin hızla ilerlemesi ile birlikte sayısal görüntülerin kullanımı birçok alanda (sosyal medya görüntüleri, tıbbi bilgilerin tutulması, adli vakalar vb.) yaygınlaşmıştır. Kötü niyetli olarak görüntülerin kullanılması kurum ve şahısları zor durumda bırakacak sonuçlara yol açabilir. Günümüzde görüntüler ve videolar adli delil olarak kullanılabilir. Buna bağlı olarak bu delillerin orijinalliğinin doğrulanması önemli bir konu haline gelmiştir.

Fotoğraf makinesi, kamera ve günlük hayatta yaygın olarak kullanılan cep telefonları ile hayatın her anında görüntü alınabilmesi kolay ve erişilebilir bir hal almıştır. Görüntüler üzerinde değişiklik yapmayı kolaylaştıran ticari ve açık kaynak yazılımların varlığı (Photoshop, GIMP) görüntü üzerinde değişiklik yapmayı kolaylaştırmıştır. Görüntü üzerinde kontrastı iyileştirme, titreşimin etkisini azaltma gibi değişikliklerin yanı sıra kötü niyetli kullanıma bağlı olarak bir nesneyi gizleme ya da çoğullama, başka görüntüden alınan görüntüleri birleştirerek olmamış bir olayı olmuş gibi gösterme gibi birçok değişiklik yapılabilir. Bu nedenle günümüzde görüntü doğrulama önemli ve gerekli bir konudur.

Şekil 1.1.'de görüleceği üzere literatürde görüntü doğrulama teknikleri aktif ve pasif olmak üzere gruplanabilir. Aktif görüntü doğrulama teknikleri sayısal imza ve damgalama olarak ikiye ayrılmaktadır. Bu yöntemlerde görüntünün doğrulanması için ön bilgiye (imzanın veya damganın ne olduğu bilgisi gibi) ihtiyaç duyulmaktadır. Sayısal imza yönteminde görüntü elde edilen bir imza aracılığı ile doğrulanırken, sayısal damga yönteminde ise doğrulama görüntü içine gizlenen bir damga ile sağlanır. Görüntü üzerinde yapılan bir değişiklik damganın elde edilememesi ile sonuçlanacağından görüntü doğrulanamayacaktır.

Pasif görüntü doğrulama tekniklerinde görüntünün doğrulanması için bir ön bilgiye ihtiyaç duyulmamaktadır. Pasif yöntemlerde görüntüden elde edilecek özellikler/öznitelikler yardımı ile görüntü doğrulaması gerçekleştirilir. Dolayısıyla özellikle sayısal görüntülerin adli delil olarak kullanılacağı ortamlarda görüntü doğrulama tekniği olarak pasif yöntemlerin kullanılması tercih edilecektir.





Şekil 1.1. Görüntü doğrulamada kullanılan yöntemlerin gruplanması

## 1.2. Görüntü Üzerinde Yapılan Sahtecilik Yöntemleri

Şekil 1.1.'de verilen gruplandırma işlemi görüntü üzerinde yapılan sahtecilik türlerini esas almıştır. Görüntü üzerinde yapılan sahtecilikler, sahtecilik türünden bağımsız ve sahtecilik türüne bağımlı olarak iki gruba ayrılmaktadır. Sahtecilik türünden bağımsız yöntemler, görüntüyle oynandıktan sonra uygulanan JPEG sıkıştırma, görüntüyü yeniden boyutlandırma gibi işlemlere ait izleri kullanarak görüntüyü doğrulamaktadır. Sahtecilik tipine bağlı yöntemler kopyala-taşı sahteciliği ve görüntü birleştirme sahteciliği olarak iki sınıfa ayrılır.

Kopyala-taşı sahteciliğinde Şekil 1.2.'de görüleceği üzere bir görüntü üzerindeki bölgenin yine aynı görüntü üzerine yapıştırılması ile sahte görüntü elde edilmektedir [1-6]. Örnek görüntüde yapılan bir protesto görüntüsünü daha kalabalık göstermek amacıyla insan topluluğundan alınan yuvarlak ile gösterilen bölümün görüntünün farklı yerlerine yapıştırılması ile elde edilen sahte görüntü verilmiştir. Bu sahtecilik türünde görüntüdeki

bir bölümün çoğul görüntüsünün oluşturulacağı gibi görüntüde var olan bir nesneyi kapatma işlemi de yapılabilmektedir. Kopyala-taşı sahteciliğinde de yapılan işlemi gizlemek ve sahtecilik tespitini zorlaştırmak için kötü niyetli kişi tarafından döndürme, bulanıklaştırma, ölçekleme gibi operasyonlar görüntü üzerine uygulanabilmektedir [7-10].



Şekil 1.2. Kopyala-taşı sahteciliği ile oluşturulan sahte görüntü

Görüntü birleştirme sahteciliği en az iki görüntüden alınan bölgelerin birleştirilmesi ile tek bir görüntü oluşturulması işlemidir. Farklı görüntülerden alınan yamaların öznitelikleri eklendiği orijinal görüntüye göre değişiklik göstererek belli tutarsızlıklara (kenar, gürültü, aydınlatma vs.) neden olacaktır. Bu tutarsızlıklar sahte görüntü tespitinde kullanılmaktadır. Şekil 1.3.'te görüleceği üzere balık tutan insan görüntüsünün olduğu orijinal görüntüye, sandaldaki karakter görüntüsünün birleştirilmesi ile sahte görüntü elde edilmiştir.



Şekil 1.3. Görüntü birleştirme sahteciliği ile oluşturulan sahte görüntü

Literatürde görüntü birleştirme sahteciliği tespiti için yapılan çalışmalar, görüntüleri sahte ve orijinal olarak sınıflandıran ve görüntüdeki birleştirilmiş bölgenin lokalizasyonunu sağlayan yöntemler olarak iki sınıfta toplanmaktadır. Görüntüleri sahte ve orijinal olarak sınıflandıran yöntemler, görüntü üzerinden elde edilen öznitelikler ile sınıflandırma yaparak, sınıflandırmanın doğruluk oranını yükseltmeyi amaçlar. Birleştirilmiş bölgenin yer tespiti üzerinde çalışan yöntemler ise görüntüdeki parlaklık ve gürültü tutarsızlıklarından yola çıkarak eklemli bölgenin yerini tespit etmeyi amaçlar. Tez kapsamında görüntülerin sahte ve orijinal olarak sınıflandırılması üzerinde çalışılmıştır. Bu alanda gerçekleşmesi amaçlanan hedefler aşağıdaki şekilde özetlenebilir.

1. Görüntülerin doğrulama performansının iyileştirilmesi
2. Elde edilecek doğrulama performansı için görüntüden çıkarılacak öznitelik vektörlerinde hesaplama karmaşıklığının azaltılması, öznitelik seçme algoritmalarına gerek duyulmaması
3. Önerilen yöntemin sahte görüntüler üzerinde uygulanan farklı atak tiplerine dayanıklılık göstermesi.

Yapılan çalışmalarda, verilen hedefler doğrultusunda görüntülerin doğrulanmasını %99'un üzerinde bir performansla gerçekleştiren, literatürde ilk kez kenar görüntüleri üzerinden dokusal özniteliklerin değerlendirmesini yapan, görüntüden öznitelik elde etme aşamasında yine literatürde ilk kez hibrit bir yaklaşımla görüntünün istatistiksel ve dokusal özelliklerini kullanan yöntemler önerilmiştir.

### **1.3. Tezin Kapsamı**

Tez kapsamında pasif görüntü doğrulama yöntemine dayalı görüntü doğrulaması gerçekleştiren ve görüntü sahteciliğini tespit eden bir sistemin tasarımı gerçekleştirilmiştir. Sistem sahte görüntülerde görüntü birleştirme sahteciliğini tespit etmektedir. Görüntü birleştirme sahteciliği alanında literatürde yapılan çalışmaların kısaca tanımlamaları ve literatür taraması tezin genel bilgiler bölümünde verilecektir. Yapılan çalışmalar kısmında görüntü birleştirme sahteciliğinin tespiti için gerçekleştirdiğimiz çalışmalar deney ve sonuçlardan bağımsız olarak özetlenecektir. Bulgular ve irdeleme bölümünde de elde edilen sayısal ve görsel sonuçlar irdelenip yorumlanacak literatürde bu sahtecilik türüne ait yapılmış olan çalışmalarla karşılaştırılacaktır.

#### 1.4. Görüntü Birleştirme Sahteciliği Tespiti

Görüntü birleştirme sahteciliği tespitinde ana hedef tasarlanan sisteme verilen görüntülerin yüksek doğruluk oranı ile sahte veya orijinal olarak sınıflandırılmasıdır. Bu nedenle görüntüleri sınıflandırabilmek için görüntüyü temsil edebilecek en iyi öznitelik vektörlerinin elde edilmesi gerekir. Görüntüyü sahte mi orijinal mi diye tespit eden yöntemlerde görüntülerden genel olarak ayırt edici öznitelik çıkarılır [12-30]. Çıkarılan bu öznitelikler kullanılarak, bir sınıflandırma algoritması yardımı ile sistem eğitilir. Daha sonraki aşamalar verilen test görüntüsü üzerinde sahte mi orijinal mi olduğunun tespiti, doğruluk oranının iyileştirilmesi, hesaplama karmaşıklığının azaltılması, çıkarılan öznitelik vektörlerinin boyutunun indirgenmesi şeklinde verilebilir. Öznitelik vektörünün elde edilme aşamasının öncesinde ve sonrasında ihtiyaç duyulan başka adımlar da varsa uygulanabilmektedir. Özetle görüntü birleştirme sahteciliği tespitinin temel adımlarını aşağıdaki gibi sıralayabiliriz;

- Ön işleme,
- Öznitelik çıkarma,
- Öznitelik seçme
- Görüntülerin sahte ve orijinal olarak sınıflandırılması.

İlerleyen bölümlerde görüntü birleştirme sahteciliği tespiti için yukarıda verilen adımlar detaylandırılacak ve bu adımlar içerisinde literatürde yapılan çalışmalar incelenecektir. Ardından tez kapsamında hedeflenen iyileştirmelerle birlikte yapılan çalışmalar ve önerilen yöntemler ilgili bölümlerde detaylarıyla yer alacaktır.

##### 1.4.1. Ön işleme

Görüntü birleştirme sahteciliği tespitinde literatürde yapılan çalışmalarda ön işleme kısmı genel olarak renk uzayı dönüşümü olarak görülmektedir ve yaygın olarak YCbCr renk uzayı kullanılmıştır [12-30].

Ön işleme adımında renk uzayı dönüşümünün yanı sıra frekans dönüşümü yapan çalışmalar da mevcuttur. Görüntüyü alt bantlara ayırarak daha ayrıntılı öznitelik elde etmeyi amaçlayan çalışmalarda ön işlem olarak DWT (Discrete Wavelet Transform-Ayrık Dalgacık Dönüşümü) [26,30] ve SPT (Steerable Pyramid Transform-Yönlendirilebilir Piramit Dönüşümü) [15,21] kullanan çalışmalar mevcuttur. Görüntüyü farklı yönlendirme

ve farklı ölçeklerde alt bantlara ayırtırmayı sağlayan Gabor filtresi [16] ve Entropi filtresi [18]'de ön işleme adımında kullanılan yöntemlerdendir.

### 1.4.2. Öznitelik Çıkarma

Öznitelik çıkarımının amacı, görüntüyü vurgulayan asıl verilerin temsili bir özetinin çıkarılmasıdır. Kullanılan yöntemlere göre elde edilen öznitelik kümesinin boyutu çok büyük olabilir, gereğinden fazla bilgi içerebilir ve bunlar sınıflandırıcının verimliliğini düşürebilir. Bunun için öznitelik çıkarma işleminin öncesinde görüntü ön işleme ve çıkarılan özniteliklerin boyutunu azaltmak için öznitelik seçme yöntemleri de kullanılabilir.

1999 yılında Farid'in insan-konuşma eklemesi tespiti için yaptığı çalışmada ikili tutarlılık öznitelikleri kullanılmıştır [11]. Bu çalışmadan yola çıkarak ikili tutarlılık özniteliklerini görüntüler üzerinde genişleten ilk çalışma Ng vd. tarafından yapılmıştır [12]. Bu çalışma görüntü birleştirme sahteciliği alanında yapılan çalışmalara orijin teşkil etmiştir.

Görüntü sahteciliğini tespit etmek için yapılan çalışmaları görüntüden öznitelik vektörü elde etme aşamasında kullandıkları yöntemlere göre görüntüdeki dokusal ve istatistiksel öznitelikleri değerlendiren çalışmalar, kamera tepki fonksiyonu tutarsızlığını kullanan çalışmalar ve gürültü tutarsızlığından yola çıkan çalışmalar olarak üç ana başlık altında toplayabiliriz.

Öznitelik çıkarmada görüntüden elde edilen istatistiksel ve dokusal öznitelikleri kullanan yöntemler: Literatürde bu alanda yapılan çalışmalarda görüntüyü yüksek doğruluk oranı ile sınıflandırmak hedeflenmiştir [12-22]. Ng vd. [12] ortalama genlik ve negatif faz entropi değerleri ile elde ettiği ikili tutarlılık (bicoherence) özniteliklerini görüntü doğrulamada kullanmıştır. Yöntemi farklı doku tiplerine sahip görüntüler üzerinde uygulayarak performans değerlendirmesi yapmıştır. Bu çalışma görüntü birleştirme sahteciliğini tespit eden çalışmalara orijin teşkil etmiştir. Birleştirilmiş görüntüdeki eklemeli bölgeleri saptamada ikili tutarlılık özniteliklerinin kapasitesini geliştirmek için kenar piksel yoğunluğu gibi görüntünün içeriğine olan bağımlılıktan yararlanır.

Zhang vd. [13] çalışmalarında moment ve görüntü kalite ölçümlerini (Image Quality Metrics-IQMs) (mutlak hata, ortalama karesel hata, istatistiksel farklara dayanan korelasyon ölçümleri gibi) kullanarak sahteciliği tespit etmeyi hedeflemiştir. Sınıflandırma

işlemi için ANN (Artificial Neural Networks-Yapay Sinir Ağları) kullanmışlardır. Yapılan çalışmada oluşturulan model, orijinal resim ile birleştirilmiş resim arasındaki istatistiksel farklılıkları ölçmektedir. Veri seti olarak Coloumbia Üniversitesi'nin sağladığı Columbia Görüntü Ekleme Tespiti Veri Kümesi kullanılmıştır. Yöntem ANN kullanımına bağlı olarak yüksek hesaplama karmaşıklığı dezavantajına sahiptir. Li vd. çalışmalarında görüntüden öznitelik elde etmek için birleştirilen neden olduğu lineer olmayan ve durağan durumu tespit için Hilbert-Huang dönüşümünü kullanmıştır [14]. Bu çalışmada karakteristik fonksiyonların momentlerine dayanan istatistiksel bir yöntem önerilmiştir.

Literatürde yapılan çalışmalarda görüntüleri farklı frekans bantlarına veya farklı ölçek ve yönlendirmelerle alt bantlara ayırdıktan sonra öznitelik elde eden çalışmalar yapılmıştır. Muhammed vd. [15] çalışmalarında SPT ve LBP (Local Binary Pattern-Yerel İkili Örüntü)'ye dayanan renkli görüntülerde kullanılan bir sahtecilik yöntemi önermiştir. SPT farklı ölçeklerde filtrelemeyi içerdiğinden tercih edilmiştir. Çalışmada SPT renkli görüntünün renk kanalına uygulanmış ve alt bantlardan LBP öznitelikleri çıkarılmıştır. Tüm alt bantlardan çıkarılan LBP histogramları birleştirilerek öznitelik vektörü oluşturulmuştur. Sistem karmaşıklığını azaltmak için öznitelik seçme algoritması kullanılarak öznitelik vektör boyutu indigenmiştir. Elde edilen bu öznitelikler, SVM (Support Vector Machines- Destek Vektör Makineleri) kullanılarak sistem eğitilmiş ve test edilmiştir. Muhammad vd. [16] de görüntüye çok ölçekli Gabor filtresi uygulamıştır. Daha sonra her bir alt banttan DCT (Discrete Cosine Transform- Ayrık Kosinüs Dönüşümü) dönüşümü sonrası elde edilen katsayıların zigzag tarama ile ilk 20 tanesi alınarak, öznitelik olarak kullanmıştır.

Doku tanımlayıcısı olarak LBP, LPQ (Local Phase Quantization-Lokal Faz Kuantalaması) ve WLD (Weber Local Descriptor- Weber Yerel Tanımlayıcı) öznitelik çıkarma aşamasında farklı frekans uzaylarında kullanılmıştır [17-20]. Hussain vd. [17] YCbCr uzayının renk kanallarında çok ölçekli WLD kullanmış ve bunu LBP ile karşılaştırmıştır. Çalışmasında WLD'nin LBP'den daha iyi sonuç verdiğini raporlamıştır. Agarwal ve Chand [18] sahtecilik tespitinde çok ölçekli entropi filtresi ve doku tanımlayıcısı olarak LPQ yöntemlerini kullanmıştır. Görüntüye farklı ölçeklerde (3x3, 3x5, 5x5, 5x3, 5x7) entropi filtresi uygulandıktan sonra her bir ölçekten LPQ ile elde edilen histogramlar öznitelik olarak kullanılmıştır.

Görüntüden öznitelik çıkarma aşamasında görüntüdeki dokusal öznitelikleri değerlendiren bir başka çalışma Alahmadi vd. [19] tarafından yapılmıştır. Yöntemde

görüntü bloklara ayrılmış daha sonra her bloğun LBP dönüşümü gerçekleştirilmiştir. LBP görüntünün yerel frekans dağılımındaki değişikliklerini izlemek için blok tabanlı DCT kullanılarak frekans alanına dönüştürülmüş ve daha sonra tüm bloklardaki DCT katsayılarının istatistiksel ölçümlerinin hesaplanması ile öznelik vektörü elde edilmiştir. Yine Shen vd. [20] çalışmasında dokusal öznelikleri kullanmıştır. Öznelik vektörünün oluşturulmasında görüntüye önce DCT uygulanmıştır. Daha sonra DCT kat sayı fark matrisleri oluşturulmuş, bu matrisler üzerinden gri seviyeli eş oluşum matrisleri elde edilmiştir. Yöntemde eş oluşum matrislerinden 6 tane dokusal öznelik çıkarılmış ve bunların ortalama değeri ve standart sapması öznelik olarak kullanılmıştır. Yöntemin avantajı öznelik vektör boyutunun küçük olmasıdır. Vidyardharan ve Thampi [21] çoklu doku tanımlayıcısı (LBP, LPQ, İkili istatistiksel görüntü öznelikleri ve ikili gabor paterni) kullanarak görüntüden öznelik çıkarmıştır. Yöntem SPT'nin farklı ölçekli alt bantlarından elde ettiği çoklu dokusal öznelikleri kullanarak bir öznelik vektörü oluşturmaktadır. Dokusal özellikleri kullanan bir diğer çalışma da [22] frekans domeninden öznelik çıkararak sahtecilik tespiti yapmayı amaçlamıştır. Görüntüye sabit dalgalık dönüşümü uygulandıktan sonra elde edilen alt bantlar üzerinde döndürmeden bağımsız LBP (RICLBP) öznelikleri elde edilmiş, her bir alt banttan elde edilen öznelikler birleştirilerek sonuç öznelik vektörü oluşturulmuştur.

Görüntüdeki dokusal özneliklerin yanısıra istatistiksel özneliklerden faydalanan çalışmalar da yapılmıştır. Bir görüntünün istatistiksel öznelikleri görüntünün karakteristik kabiliyetini yansıtabildiği için görüntü bölütleme, görüntüyü yeniden yapılandırma gibi alanlarda kullanılmaktadır. He vd. [23] çalışmalarında öznelik çıkarmada Markov modelini kullanarak bir yöntem önermişlerdir. Yöntem görüntüden DCT ve DWT domenlerinde Markov özneliklerini elde eder. Görüntüdeki pikseller arasındaki istatistiksel bağımlılığa bakarken 1-piksel adımlı (inter blok) bağımlılıkların yanı sıra 8-piksel adımlı (intra blok) bağımlılıklar da hesaplanır. DCT katsayılarından fark matrisleri elde edilir ve bu fark matrisindeki her bir değer bir durum olarak ele alınır. Bu matrislerden geçiş olasılık matrisleri hesaplanır ve bu matrisler öznelik olarak kullanılır. Her iki frekans domeninden elde edilen özneliklerin birleştirilmesi ile yöntemin öznelik vektörü elde edilmiş olur. Yöntem öznelik vektörünün boyutu yüksek olduğundan ekstra bir işlem olarak öznelik seçme algoritmasına ihtiyaç duymuştur. Su vd. [24] çalışmasında genişletilmiş bir Markov durum seçme yöntemi ile öznelik vektörünün boyutunu indirgediğini raporlamıştır. Yöntem fark matrisindeki DCT katsayılarını T eşik değeri ile

eşiklemek yerine, önceden belirlenmiş çeşitli fonksiyon modellerine göre çok sayıda katsayıya eşlemiştir. He vd.'nin [23] yönteminde DCT katsayılarını yuvarlama ve eşikleme işleminden dolayı aradaki birçok sayısal değerin aynı değere karşılık geleceği düşüncesi ile belirlenen bir durum sayısına göre katsayı fark matrisindeki değerleri seçilen fonksiyonlar yardımıyla o aralığa haritalamıştır. Yöntem elde edilen öznitelik sayısını indirgemiş ancak sınıflandırma performansında bir artış gösterememiştir.

El-Alfy ve Qureshi [25] de Markov tabanlı çalışmalarında, görüntü özniteliklerini uzaysal ve frekans domende oluşturarak birleştirme sahteciliği tespiti önermiş ve PCA (Principle Component Analysis-Temel Bileşen Analizi) kullanarak en anlamlı öznitelikleri seçmiştir. Zhao vd. [26] önerdiği yöntemde DCT frekans domeninde ve Ayırık Meyer dalgacık dönüşümü domeninde Markov özniteliklerini çıkararak daha ayırt edici öznitelik vektörüne ulaştığını belirtmiştir. Li vd. [27] çalışmasında, He vd.'nin [23] önerdiği yöntemden yola çıkarak QDCT (Quaternion Discrete Cosine Transform-Kuaternion Ayırık Kosinüs Dönüşümü) domende Markov özniteliklerini kullanmıştır. 2008'de Feng ve Hu [28] tarafından renk şablonu eşleştirmesinde QDCT domeni kullanılmıştır. Li vd. bu çalışmadan [28] yola çıkarak görüntü sahteciliğinde de QDCT domende çalışmıştır. Markov tabanlı bir başka çalışma Han vd. [29] tarafından geçiş olasılık matrislerini elde etmeden önce DCT katsayılarını kuantalayarak geçiş olasılık dağılımlarının ayırt ediciliğini artırmak üzerine yapılmıştır.

Zhang vd. [30] görüntüye blok DCT ve counturlet domen dönüşümü ile Markov özniteliklerinin elde edildiği bir yöntem önerdi. Counturlet alt bant katsayıları arasındaki bağımlılık elde ettiği yatay ve dikey kat sayı fark matrisleri üzerinden modellenmiştir. Görüntüye blok DCT uygulandıktan sonra, her bir blok zigzag sıralamasına göre 3 alt banda ayrılarak bu alt bantlar üzerinden geçiş olasılık matrisleri elde edilmiştir. Daha sonra her bir geçiş matrisinin ortalaması ile öznitelikler elde edilmiştir. Her iki domenden elde edilen öznitelikler birleştirilerek sahtecilik tespiti için öznitelik vektörleri oluşturulmuştur. Zhang vd. [31] bir diğer çalışmada görüntünün tümüne DWT uygulamak yerine, görüntü bloklara ayrıldıktan sonra her bir bloğa DWT uygulamıştır. Elde edilen dalgacık katsayılarından yatay ve dikey fark matrisleri elde edildikten sonra iki yönde geçiş olasılık matrisleri hesaplanarak, bu matrislerin her bir elemanı öznitelik vektörü olarak kullanılmıştır. Yöntem, [23] ile önerilen DCT tabanlı Markov ile kıyaslanarak daha iyi doğrulama performansı sunduğunu raporlamıştır.



Phan vd. [32] Markov modeli ile önerdikleri yöntemde ardışık katsayılar arasındaki ilişkiyi modellemenin yanısıra blok DCT ile elde ettiği düşük frekans bileşenleri üzerinden yine bir bağımlılık analizi ile sahtecilik tespit etmeyi amaçlamıştır. Katsayılar ve bloklar arasındaki ilişki için iki farklı eşikleme değeri kullanmıştır. Önerilen yöntem özellikle hesaplama karmaşıklığının azaltılması ve hesaplama süresinin düşürülmesi üzerine vurgu yapmıştır.


He vd. [33] eklemlenmiş bölgeden dolayı oluşan yapıyı tespit etmek için yaklaşık koşma zamanı (approximation run length) temelli bir yöntem önermiştir. İlk olarak, görüntünün kenar gradyan matrisi hesaplanır ve yaklaşık koşma uzunluğu, kenar gradyan yönü boyunca hesaplanır. Yaklaşık koşma uzunluğu belirli bir yön boyunca aynı gri piksel değerine sahip ardışık piksel dizisi olarak tanımlanır. Koşma uzunluğu, işlemdeki yinelenen piksel sayısıdır. Görüntüden elde edilen öznelik vektörü yaklaşık çalışma uzunluğunun histogramından oluşturulmuştur. Bir görüntünün yapısındaki süreksizlik/tutarsızlık yani eklemlenmiş bölgenin meydana getirdiği pikseller arasındaki korelasyon, bir görüntünün bütününden yaklaşık koşma uzunluğunun hesaplanmasıyla tespit edilemeyecek kadar sınırlıdır bu nedenle görüntüdeki kenarlar üzerinden yaklaşık koşma zamanı hesaplamıştır. Eklemlenmiş bölgeden dolayı görüntüdeki kenar yapısı değişeceğinden kenar piksellerinden koşma uzunluğu hesaplama işlemi daha mantıklı olacaktır. Eklemlenmiş bölgeden gelen ekstra kenarlar, orijinal bir görüntüdekinden daha keskindir ve bu nedenle, eklemlenmiş sahte görüntülerin doğal olanlardan ayırt edilmesinde avantaj sağlanabilir düşüncesi ile mevcut çalışma gerçekleştirilmiştir. Son olarak, elde edilen öznelikler ile görüntüleri sınıflandırmak için SVM'den yararlanılmaktadır.

Görüntü birleştirme sahteciliği tespitinde öznelik çıkarmada istatistik filtrelerini kullanan bir yöntem önerilmiştir. Zhenhua vd. [34] görsel belirginlik ve sabitlemenin kullanıldığı, insan görsel sistemi tabanlı, sıralı istatistik filtrelerini kullanan bir ekleme algılama yöntemi önermiştir. Yöntem algılama penceresi diye adlandırdığı pencereler yardımıyla görüntüyü parçalara ayırmaktadır. Her bir alt bloğa görsel dikkat modeli (visual attention model-VAM) uygulamakta, bu model ile parlaklık-kenar gibi özneliklerin düşük seviye özellik piramidinden dikkat çekme (saliency map) haritası üretmektedir. Bu görsel dikkat modeli kenar keskinlik ipuçlarını kullanmaktadır. Her alt bloktan Normalized Edilmiş Keskinlik Haritası ve Keskinlik esaslı harita çıkarılmaktadır. Çalışma hiyerarşik bir sınıflandırıcının eğitilebileceğini göstermektedir. Hiyerarşik sınıflandırıcı ayrıca ekleme sınırlarını belirlemek için uygun bir yol sağlar. Yöntemde lokalizasyon vardır ama

eklenmiş alanların hepsini bulup çıkaramamaktadır, şüpheli kenarları işaretlemektedir. Bu da daha fazla bölgeye dayalı analiz ve insan incelemesi gerektirdiğinden çok efektif bulunmamaktadır. Önerilen yöntem, birleştirme sahteciliği yapılan görüntüde eklemli bölgenin sınırlarını gizlemek için görüntüye bulanıklaştırma işlemi uygulandığında kenar keskinliği azalacağı için başarısız olacaktır.

Mevcut çalışmalarda birleştirilen bölge ve orijinal görüntü arasında bir sınır olduğunu kabul eden yöntemler vardır. Dolayısıyla birleştirilen bölgeyi bulma işlemini yerel özel operasyonlarla bulmayı hedefler. Örneğin Bahrami vd. [35] çalışmalarında birleştirilmiş bölgenin bulanıklaştırıldığını, Bianchi vd. [36] median filtrelendiğini, Lin vd. [37] kontrast genişletilme yapıldığını kabul eder.

Öznelik çıkarmada görüntüdeki gürültü ve aydınlatma tutarsızlığını kullanan yöntemler: Bölge/blok tabanlı yöntemler genellikle görüntüdeki sahteciliği belirlemek için birleştirilen ve orijinal bölgelerden tahmin edilen tutarsız sistem parametrelerini kullanır. Johnson ve Farid [38] 2006 yılındaki çalışmalarında görüntüdeki renk sapmaları ve aydınlatma tutarsızlığından faydalanmıştır. Hemen hemen bütün optik görüntüleme sistemleri, bir görüntüye çeşitli sapmalar getirir. Örneğin renk sapmaları, bir optik sistemin, farklı dalga boylarındaki ışığa odaklanmadaki başarısızlığından kaynaklanmaktadır. Yanal renk sapmaları renk kanallarının birbirine göre genişlemesi / daralması olarak ifade edilebilir. Bir görüntüyle oynandığı zaman, bu sapma genellikle bozulur ve görüntüde tutarlı olmaz. Bu renk sapmalarını tahmin etmek için Johnson ve Farid [38] yeni bir yöntem önermiştir. Gürültü tabanlı yöntemler, bir görüntüdeki genel gürültü seviyesinin orijinal bir görüntü boyunca genellikle tutarlı olması ve farklı görüntülerden gelen bölgelerin genellikle farklı gürültü seviyelerine sahip olması esasına dayanarak sahtecilik tespiti yapmayı amaçlar. Bu farklılıklar, ya görüntü yakalama işlemi sırasında ya da görüntü birleştirme sonrasında kalan izlerin gizlenmesi için kasıtlı gürültü eklenmesinden kaynaklanıyor olabilir. Şekil 1.4'te iki görüntü birleştirme örneği gösterilmektedir. Şekil 1.4 (a)'daki örnek için, başka bir görüntüye ait bir kuş orijinal resme eklenir. Sahtecilik sırasında, eklemli bölgeyi gizlemek için kuş görüntüsü hafif Gauss gürültüsü ile eklenir [40]. Şekil 1.4 (b)'de başka bir görüntüden alınan oyuncak herhangi bir ön işleme yapılmadan hedef resme eklenir.



Şekil 1.4. (a) Gürültü ilavesi ile başka bir görüntüden gelen kuş eklenmesi. (b) Başka bir görüntüden alınan oyuncak ördeğin herhangi bir işleme tabi tutulmadan eklenmiş hali [40].

Gürültü seviyesi farklılığından yola çıkılarak önerilen yöntemlerin gürültü farkı belli bir eşik değerinden küçük ise yöntem çalışmamaktadır. Bu yöntemlerin temeli yapıştırılan bölgenin gürültüsünün orijinal görüntüdeki farklı olacağı düşüncesine dayanmaktadır. Görüntü bloklarından elde edilen gürültü seviyeleri öznel olarak kullanılır ve bir sınıflandırıcı yardımı ile iki sınıfa ayrılır. Yapıştırılan bölgedeki blok sayısının orijinal blok sayısından az olacağı düşünülerek, az blok sayısına sahip olan sınıftaki bloklar sahte kabul edilir ve görüntüde işaretlenir, böylece yapıştırılan bölgenin yeri tespit edilmiş olur. Gürültü tutarsızlığını temel alan literatürdeki çalışmalarda görüntünün kurtuz değerinin kullanıldığı görülmektedir [39-44]. Bu yöntem gürültü tutarsızlıklarını saptamada etkili bir yöntemdir ama dokusal ve düşük gürültü seviyesine sahip görüntülerde etkili değildir. Bununla birlikte, bu yöndeki birçok çalışma [39-44] orijinal görüntünün kurtuzunu bilmekte ve bu da onları uygulamalar için pratik yapmamaktadır.

Popescu ve Farid [39] 2004'teki çalışmalarında her yerel görüntü bloğu için ikinci ve dördüncü moment değerlerini hesaplayarak gürültü varyansını hesaplamışlardır. Bununla birlikte, yöntem orijinal sinyalin kurtuzunun bilinmesini gerektirir. Zoran ve Weiss'in [41] algoritması kurtuz değerlerini bilmeyi gerektirmeyen ilk kurtuz temelli yöntemdir. Zoran ve Weiss [41], gürültünün varyansını tahmin etmek için istatistiksel bir model önermiş ve düşük seviyeli gürültüye sahip görüntülerdeki etkinliğini göstermiştir. Yöntem farklı filtre ve ölçeklerdeki kurtuz değerinin ölçeklemeye bağlı olarak değişmeyeceğini, bu değerlerdeki herhangi bir değişikliğin ek gürültüden kaynaklanacağı varsayımına dayanmaktadır. Çalışmada görüntüye önce DCT dönüşümü yapılır ve daha

sonra gürültü tahmin etme adımına geçilir. Gürültü tahmin etme adımının temelinde orijinal, üzerinde değişiklik yapılmamış görüntünün değişmez istatistiklere sahip olduğu varsayımı yer almaktadır. Yani orijinal görüntülerin farklı filtrelere yanıtlarının kurtozunun bilinmeyen bir sabit değer olduğunu ve görüntüye eklemli bölge ile dışardan eklenen gürültünün ölçekler boyunca kurtoz değerlerini değiştireceğini varsaymaktadır. Pan vd. [42] çalışmalarında farklı gürültü varyanslarına göre gruplandırma yapmış, gürültü seviyesi tahmin yöntemi için Zoran ve Weiss (2009) 'in yöntemini [41], yerel görüntü bloklarına uygulamış ve birleştirilmiş bölgeyi bloklara kabadan-inceye bir gruplama yoluyla orijinal görüntüden ayırt etmiştir. Lyu vd. [42,43] çalışmalarında Zoran ve Weiss'in [41] çalışmasındaki gürültü seviyesi tahmin yöntemini genişletmiş, görüntü birleştirme sahteciliğinde lokalizasyon tespiti için uygulamış ve piksel seviyesinde algılama hassaslığı elde etmiştir.

Zeng vd. [40] çalışmasında Lyu vd.nin [43] yaptığı çalışmaları incelemiş, böyle bir yöntemin yaptıkları ön testler sonucu görüntü dokusuna duyarlı olduğu ve yer tespiti sonuçlarında yanlış pozitiflik oluşturabileceği gözlemlenmiştir. Mevcut gürültü tabanlı yöntemler orijinal ve birleştirilmiş bölgeler arasındaki gürültü farkı yeterince büyük olduğunda çalışmaktadır. Ancak, pratikte sahte görüntülerde bu fark oldukça küçüktür ve mevcut gürültü tabanlı yöntemler bu durumda daha az doğruluk performansı sağlar. Zeng vd. [40] bu performans açığını giderebilmek, gürültü farkının küçük olduğu sahte görüntüleri de tespit edebilmek için yeni bir yöntem önermişlerdir. Çalışmalarında yer tespiti de mevcuttur. Gürültü seviyesi tahmini için 64x64'lük görüntü blokları üzerinden gürültü tahmini yapılmış, yapılan bu tahmine göre bloklar K-ortalama algoritması ile iki gruba (sahte veya orijinal) ayrılmıştır. Daha sonra sahte diye tespit edilen bloklar üzerinden ikinci bir gruplama işlemine giderek yer tespitinde bulunulmuştur. Yer tespiti için 32x32'lik bloklar ile gürültü tutarsızlıklarına bakarak, lokalizasyon yapmışlardır. Gürültü tahmini için büyük bloklar, lokalizasyon için küçük bloklar tercih edildiğinden bu çalışmada da iki farklı ölçekle değerlendirme yapılmıştır.

Mahdian ve Saic'in çalışması [44] görüntü bloklarından gürültü tahmin etmeye dayanmaktadır. Görüntünün dalgacık dönüşümünü yaptıktan sonra yüksek frekanslı alt banttaki her görüntü bloğundan (birbiri ile örtüşmeyen) medyan tabanlı gürültü varyans tahmincisi ile her bloktaki gürültü seviyesini tahmin etmiştir. Daha sonra bu bloklar homojen bölge oluşturmak için komşu bloklar arasında gürültü farkını inceleyerek

birleştirilmiştir. Fakat bu yöntemde eşik değerinin seçilmesi zafiyeti vardır. Eşik değeri dikkatli seçilmezse birleştirilmiş alan, görüntüden ayırt edilemez.

Gürültü tahmini tabanlı görüntü birleştirme sahteciliği tespiti yöntemlerinin birçoğunda gürültü sadece Gaussian gürültüsü olarak alınır ve homojen olduğu kabul edilir. Fakat Poisson bileşeni bu varsayımı bozar. Jullian vd. [45] çalışmasında Poisson bileşenini de dikkate almıştır ancak yöntem lokalizasyon konusunda eksiktir. Aynı zamanda blok tabanlı olan yöntem, gürültünün Gauss ve Poisson kısımlarının parametrelerini iyi tahmin etmeyi amaçlamaktadır. Alt bloklardaki bu parametrelerin tutarsızlıkları ve dolayısıyla olası eklemeleri izole etmeyi sağlar. Çalışma temel olarak ham görüntülere odaklanmaktadır. Birleştirilmiş alanın büyüklüğü gibi yöntemin zayıf noktaları vardır. Çok küçük bir eklenmiş bölge, onu içeren bloğun gürültü özniteliklerini fazla değiştirmeyeceğinden saptanamayacaktır. Ayrıca bu yöntemle hedef görüntüye benzer gürültü öznitelikler taşıyan bir görüntü ile birleştirildiğinde eklemeli bölge saptanamayacaktır. Jullian vd. [46] sonraki çalışmalarında gürültünün Gaussian ve Poisson bileşenleri ile gürültü yoğunluğu kazanım tablosu kullanmıştır. Bu tablo bir görüntünün herhangi bir alt bloğunun, görüntünün tamamının gürültü yoğunluk tablosuna katkı yüzdesini ifade eder. Bu yöntem, görüntü eklenmiş bir bölge içerdiğinde, görüntünün gürültü yoğunluğundaki katkılarının farklılığına dayanır. Gürültüye farklı katkının olduğu yerlere bakarak bir görüntüye eklenmiş bir alanın tespit edilmesinin mümkün olduğunu göstermişlerdir. Yöntemin dayanıklılığı, resmin tüm kanallarına çoğaltılarak artırılmıştır.

Öznitelik çıkarmada görüntüdeki kamera tepki fonksiyonlarını kullanan yöntemler: Görüntüdeki gürültü seviyesinin tutarsızlığı, birleştirilmiş eklemeli bölgenin tespiti için kullanılabilir. Gürültü tutarsızlığını kullanan çalışmaların bir kısmı, gürültüyü kamera modelinin tanımlanması için bir öznitelik olarak kullanılır. Lukas vd. [47] görüntüleme sensörlerinin bir karakteristiği olan PRNU'yu (Photo Response non-uniformity- Foto Tepki Düzensizliği), belirli bir görüntü için kaynak kamerayı tanımlamada bir parmak izi gibi kullanmıştır. Chen vd. [48] çalışmalarında, Lukas vd.'nin [47] kullandığı metodu daha az eğitim görüntüsü ile PRNU tahmini için geliştirmiş ve daha sonra görüntü değiştirme tespiti için kullanmıştır.

Chen vd. [48] çalışmalarında fotoğrafın çekildiği kameranın tespit edilmesi ve görüntü bütünlüğünün doğrulaması için bir yöntem önermiştir. Her iki amaç için fotoğrafın çekildiği dijital kameranın görüntüleme sensörlerinin bir nevi parmak izi olan PRNU tespit edilmiştir. PRNU ilk önce sensör çıkışının basitleştirilmiş bir modelinden maksimum

olabilirlik prensibini kullanarak tahmin edilir. Hem kamera kimliği hem de bütünlük doğrulaması için uygun optimum algılama istatistikleri elde edilir. Her iki hipotez altında test istatistiklerinin dağılımı deneysel olarak diğer kameralardan alınan çok sayıda görüntüden elde edilir ve bir korelasyon tahmincisi kullanılır. İncelenen görüntünün belirli bölgelerinde PRNU varlığının tespit edilmesiyle görüntünün bütünlüğünün bozulup bozulmadığı algılanır. Bu tür yöntemlerin başlıca kısıtlılığı, belirli kamera modellerinin bilgisine bağlı olmalarıdır.

Bazı yöntemlerde öznitelik olarak CRF (Camera Response Function-Kamera Tepki Fonksiyonu) [49-51] kullanılmıştır. Lin vd. [49] kameranın tepki işlevlerini, farklı şekillerde uygun yamaları seçerek hesaplayan bir yaklaşım önermiştir. Tepki işlevleri anormalse veya birbiriyle tutarsız ise görüntü sahte olabilir. Yanıt fonksiyonlarının normallığı SVM tarafından sınıflandırılır. Deneysel sonuçlar, pek çok dokusuz, kenarlı, yüksek kontrastlı görüntüler için etkili olduğunu göstermektedir. Bununla birlikte CMOS uyarlanabilir sensörleri kullanan kameralar gibi bazı kamera türlerinde, yüksek kontrastlı sahnelerde daha hoş fotoğraflar çekmek için uyarlamalı yanıt işlevleri ile çekilen görüntüleri yanlış olarak sınıflandırılacağı yazar tarafından söylenmiştir. Hsu ve Chang [50,51] çalışmalarında görüntüdeki farklı alanlar arasında kamera özniteliklerinin tutarlılık kontrolüne dayanan tam otomatik bir birleştirilmiş sahte görüntüyü algılama yöntemi önermiştir. Girişten gelen test görüntüsü ilk önce farklı-ayrık alanlara bölünmüştür. CRF, lokal düzleme ait parlaklık noktalarından geometrik değişmezler kullanarak her alandan tahmin edilir. Orijinal ve eklenmiş bölge arasındaki bir sınır segmenti oluşturmak için, CRF çapraz yerleştirme skorları ve alan yoğunluğu öznitelikleri hesaplanır ve SVM ile sınıflandırılır. Bu segment seviyesindeki sınıflandırma skorları daha sonra görüntü seviyesinde sınıflandırma kararı oluşturmak için birleştirilir [51].

Johnson ve Farid [52] kameranın optik sistemindeki kusurlarını kullanan yeni bir görüntü sahteciliği tespit yöntemi tasarlamıştır. Çalışmadaki mevcut yaklaşım sadece yanal renk sapmalarını dikkate almaktadır. Bu sapmalar, düşük parametrelili bir model ile iyi bir şekilde yaklaştırılmıştır. Renk kanalları arasındaki karşılıklı bilgiyi maksimize etmeye dayanan bu model parametrelerini tahmin etmek için otomatik bir teknik geliştirilmiştir.

### 1.4.3. Öznitelik Seçme

Öznitelik seçme orijinal öznitelik kümesini temsil edecek en iyi öznitelik alt kümesinin belirlenmesi diye tanımlanabilir. Kullanılan öznitelik seçme algoritmasına göre öznitelik kümesindeki öznitelikler değerlendirilerek en iyi “n” adet öznitelik seçilir. Öznitelik seçmenin amacı ele alınan öznitelik kümesi içinde, ilgili problem için en nitelikli özniteliklerin seçilerek öznitelik sayısının indirgenmesidir. Öznitelik seçme algoritmasının avantajları aşağıda verilmiştir [53];

- Hesaplama karmaşıklığı azaltılmış olur,
- Veri depolamada bellek tasarrufu sağlar,
- Elde edilen öznitelik kalitesini artırır,
- Sınıflandırmanın doğruluk performansında iyileştirme yapabilir.

Literatürdeki görüntü birleştirme sahteciliği tespiti alanında yapılan bazı çalışmalarda da sistem performansını artırmak için öznitelik seçme algoritmalarına ihtiyaç duyulmuştur [15, 23, 25, 30, 54]. Muhammad vd. [15] çalışmasında SPT alt bantlarından elde edilen özniteliklerin birleştirilmesi ile öznitelik vektörünü oluşturmuştur. Alt bant sayısının fazla olmasından dolayı oluşturulan öznitelik vektörünün boyutu  $1 \times 3584$ 'tür. Çalışmada LLB (Local Learning Based-Yerel Öğrenme Tabanlı) öznitelik seçme algoritması kullanılarak öznitelik vektör boyutunu  $1 \times 480$ 'e indirmişdir. Bu işlem neticesinde sistemin performansı %91.67 iken öznitelik seçiminden sonra %96.39'a yükselmiştir. He vd. [23] istatistiksel tabanlı önerdiği yöntemde özellik vektör boyutunu SVM-RFE (Support Vector Machine Recursive Feature Elimination-Destek Vektör Makinesi Yinelemeli Öznitelik Seçimi) kullanarak deneysel olarak belirlemiştir. Çalışma [23] sistem performansını öznitelik seçimi sonucu elde edilen ( $1 \times 50, 1 \times 100, 1 \times 150, 1 \times 200$ ) büyüklüğündeki vektörlerle değerlendirmiş ve sistemin öznitelik vektör boyutu %93.55 doğruluk oranıyla  $1 \times 100$  olarak seçilmiştir. El-Alfy vd. [25] önerilen yöntemde elde edilen öznitelik vektör boyutunu indirmek için PCA kullanmıştır. Bu işlem sonucunda elde edilen farklı büyüklükte ( $1 \times 30, 1 \times 50, 1 \times 100, 1 \times 150,$ ) öznitelik alt kümeleriyle sistem performansı test edilerek,  $1 \times 50$  büyüklüğündeki öznitelik vektör boyutuyla en yüksek doğrulama oranına (%98.82) ulaşılmıştır. Zhang vd. [30] birleştirme sahteciliği için önerdikleri yöntemde özellik seçme algoritması olarak SVM-RFE kullanmış, öznitelik sayısı 5508'den 200'e indirgenerek sistem %94.10 oranında doğruluk performansına ulaştığını raporlamıştır. Yöntem [30],

(1x50, 1x100, 1x150, 1x200) büyüklüğündeki öznitelik vektörleriyle elde edilen doğruluk oranlarını raporlamış, öznitelik seçme algoritması kullanılmadan önceki sistemin performansını değerlendirmemiştir. Öznitelik seçme algoritmasını kullanan bir diğer çalışma Wang vd. [54] tarafından ortaya konmuştur. Çalışma BFS (Boosting Feature Selection- Hızlandırıcı Öznitelik Seçimi) kullanarak sistem performansını %89.9'dan %90.5'e yükseltmiştir. Görüntü sahteciliği tespitinde öznitelik seçme algoritmasını kullanan yöntemler kullanılan algoritmaların (öznitelik seçme) zaman açısından performans üzerine etkisini incelememiştir. Aşağıda literatürde yaygın olarak kullanılan SVM-RFE algoritmasından kısaca bahsedilecektir.

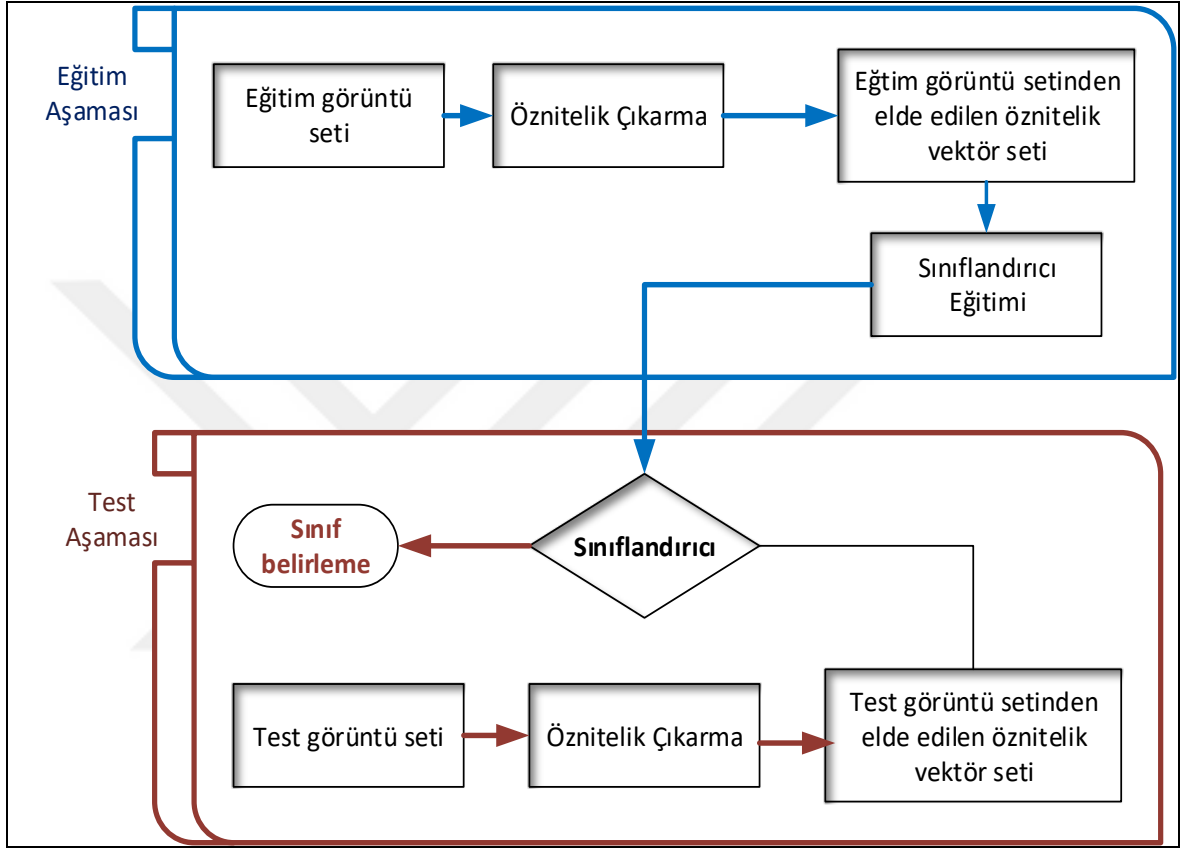
Destek vektör makinesi yinelemeli öznitelik seçimi (SVM-RFE): Özellik (öznitelik) seçiminde elde edilecek olan K adet en iyi öznitelik için bir öznitelik alt kümesi oluşturulur ve bu öznitelikler için farklı formüllerle değerlendirmeler yapılarak öznitelikliğin seçilip seçilmeyeceğine karar verilir. Mevcut veri setinden alt küme üretimi için ardışık arama, rastgele arama gibi yaklaşımlar kullanılmaktadır. SVM-RFE metodu öznitelik alt kümesini oluşturmak için tüm özellikleri bir fonksiyona bağlı olarak derecelendirmekte daha sonra en düşük dereceye sahip öznitelikliği elemektedir. Bu işlem sınıflandırma performansı maksimumuna ulaşana kadar tekrarlanır. Özetle, metod SVM ile eğitim işlemi yaptıktan sonra elde edilen sonuçlarla öznitelik ağırlıklarını tekrar güncelleyerek en düşük ağırlıklara göre öznitelikleri elemektedir [55].

#### 1.4.4. Görüntüleri Sınıflandırma

Görüntü birleştirme sahteciliğinin tespitinde son aşama görüntüleri doğrulanmış (orijinal) veya sahte görüntü olarak sınıflandırmaktır. Sınıflandırıcının amacı, verilen görüntüleri ayırt etmek, bunları orijinal ve sahte görüntü diye iki kategoriye ayırmaktır. Sınıflandırma aşamasında sahte görüntüler 0 ve orijinal görüntüler 1 ile etiketlendiğinde sınıflandırma işlemi ikili sınıflandırma halini alır. Bu aşamadan sonra görüntülerin sınıflandırılması için k-En Yakın Komşu (k-Nearest Neighbour- KNN) veya SVM gibi ikili sınıflandırmada yüksek performans gösteren algoritmalar kullanılabilir. Literatürde yapılan çalışmalarda yaygın olarak SVM [13-37] kullanılmıştır. Şekil 1.5'te genel olarak sınıflandırma şeması verilmektedir. Eğitim aşamasında sınıflandırmada kullanılacak eğitim setindeki her bir görüntüden, görüntüyü temsil edecek öznitelik vektörü çıkarılır ve bu vektörler ile öznitelik vektör seti oluşturulur. Elde edilen bu eğitim öznitelik vektör seti ile



sınıflandırıcı eğitilir. Test aşamasında test için sisteme verilecek olan görüntü setinden eğitim aşamasında kullanılan yöntemle öznelik vektörleri oluşturulur ve bu öznelikler önceden eğitilmiş sınıflandırıcıya verilir. Sınıflandırıcı sisteme verilen görüntülerin hangi sınıfa ait olduğuna karar verir.



Şekil 1.5. Sınıflandırma akış şeması

## 2. YAPILAN ÇALIŞMALAR

Günümüzde internet kullanımının yaygınlaşması avantajlarının yanı sıra beraberinde birçok problemi de getirmiştir. Gerek cep telefonlarının gerekse dijital fotoğraf makinelerinin yaygın kullanımı sayısal görüntülerin hayatın her alanında kullanılmasını kolaylaştırmış ve yaygınlaştırmıştır. Kullanılan bu sayısal görüntüler sosyal medya ağlarında ya da herhangi bir konuyla alakalı yapılan TV, dergi ve gazete haberlerinde kurum kişi ve şahısları zan altında bırakır nitelikte veya delil niteliğinde kullanılabilir. Dolayısıyla her alanda kullanılabilen, özellikle adli vakalarda sayısal delil niteliği taşıyabilen sayısal görüntülerin üzerinde değişiklik yapılıp yapılmadığının tespiti, görüntülerin doğrulanması literatürde önem gören bir konu olmuştur.

Tez kapsamında görüntü sahtecilik türlerinden olan görüntü birleştirme sahteciliğinin tespiti üzerinde durulmuştur. Tablo 2.1'den görüleceği üzere, literatürde görüntü birleştirme sahteciliği tespiti alanındaki çalışmaların büyük çoğunluğu görüntüyü sahte veya orijinal olarak sınıflandırma üzerine yapılmıştır. Bu çalışmalarda ana hedef görüntüyü yüksek doğruluk oranı ile sınıflandırabilmektir. Bunun için bazı çalışmalar sınıflandırma performansını arttırmak için özellik seçme algoritmasına ihtiyaç duymuştur. Görüntüdeki eklemlenmiş bölgenin lokalizasyonunu tespit etmek için yapılan çalışmalar [37-46, 51,52], eklemlenmiş bölgeden kaynaklanan gürültü ve aydınlatma tutarsızlığını kullanmaktadır. Ayrıca görüntünün çekildiği makinenin bir nevi parmak izi olarak değerlendirilen kamera tepki fonksiyonundaki tutarsızlıklar üzerine yapılan çalışmalar [46-49] da mevcuttur. Yapılan bu çalışmaların mevcut veri setleri üzerindeki sahte görüntülerde lokalizasyon değerlendirmesi yapmaması, seçilen birkaç örnek görüntü üzerinde performans değerlendirmesi vermesi yöntemlerin kısıtlılığını düşündürmektedir.

Tablo 2.1. Görüntü birleştirme sahteciliği tespitinde literatürde var olan çalışmalar ve özellikleri

	Kullanılan yöntem	Sınıflandırma algoritması	Öznitelik seçme	Eklemli bölgenin tespiti	Kullanılan veri setleri			
					CASIA v1.0	CASIA v2.0	Columbia	Diğer veri setleri
[12]	Dokusal (ortalama genlik+ikili tutarlılık)	SVM 10-katlı çapraz doğr.	-	-	-	-	✓	-
[13]	İstatistiksel (görüntü kalite ölçümleri)	YSA (%80e-20t)	-	-	-	-	✓	-
[14]	İstatistiksel (moment)	SVM (2/3 e-1/3t)	-	-	-	-	✓	-
[15]	Dokusal (SPT+LBP)	SVM 10 katlı çapraz doğr.	✓	-	✓	✓	✓	-
[16]	Dokusal (Gabor+dct)	SVM 10 katlı çapraz doğr.	-	-	✓	✓	-	-
[17]	Dokusal (Entropi,WLD)	SVM 10 katlı çapraz doğr.	-	-	✓	-	-	-
[18]	Dokusal (Entropi+LPQ)	SVM 10 katlı çapraz doğr.	-	-	✓	✓	✓	-
[19]	Dokusal (LBP+DCT)	SVM 10 katlı çapraz doğr.	-	-	✓	✓	✓	-
[20]	Dokusal (DCT+GLCM)	SVM (5/6 e-1/6-t) 10 kez	-	-	✓	✓	-	-
[21]	Dokusal (SPT,LBP,LPQ,BSIF, BGP)	RFC (random forest classifier) 10 katlı çapraz doğr.	-	-	✓	✓	✓	-
[22]	Dokusal (RICLBP)	SVM (%50t-50e) 30 kez	-	-	✓	-	✓	-
[23]	İstatistiksel (DCT,Markov,DWT)	SVM (5/6 e-1/6-t) 50 kez	✓	-	-	✓	✓	-
[24]	İstatistiksel (Markov)	SVM (%50t-50e) 50 kez	-	-	-	-	✓ <sub>g</sub>	-
[25]	İstatistiksel (Markov, uzaysal+DCT)	SVM 10 katlı çapraz doğr.	✓	-	-	-	✓ <sub>g</sub>	-
[26]	İstatistiksel (DMWT,DWT)	SVM (5/6 e-1/6-t) 50 kez	-	-	-	-	✓ <sub>g</sub>	-
[27]	İstatistiksel (QDCT,Markov)	SVM (5/6 e-1/6-t) 50 kez	-	-	✓	✓	✓	-

Tablo 2.1'in devam

	Kullanılan yöntem	Sınıflandırma algoritması	Öznitelik seçme	Eklemler bölgenin tespiti	Kullanılan veri setleri			
					CASIA v1.0	CASIA v2.0	Columbia	Diğer veri setleri
[29]	İstatistiksel (Markov,kuantalama)	SVM 6-katlı çapraz doğrulama	-	-	✓	✓	✓ <sub>r</sub>	-
[30]	İstatistiksel (Conturlet,Markov)	SVM (5/6 e-1/6-t) 50 kez	✓	-	-	-	✓	✓
[31]	İstatistiksel (3.seviye DWT,Markov)	SVM (5/6 e-1/6-t) 50 kez	-	-	-	-	✓ <sub>g</sub>	-
[32]	İstatistiksel (Markov, DCT LF)	SVM 10 katlı çapraz doğr.	✓	-	✓	✓	✓	-
[33]	Dokusal (kenar gradyan takibi)	SVM (5/6 e-1/6-t) 50 kez	-	-	-	-	✓ <sub>g</sub>	-
[34]	İstatistiksel (Sıralı istatistik filtreleri)	SVM (%50t-50e)	-	✓	-	-	-	-
[38]	Aydınlatma tutarsızlığı	-	-	✓	-	-	-	✓
[39]	Gürültü tutarsızlığı	-	-	✓	-	-	-	✓
[40]	Gürültü tutarsızlığı	-	-	✓	-	-	✓ <sub>g</sub>	-
[42]	Gürültü tutarsızlığı	-	-	✓	-	-	-	✓
[43]	Gürültü tutarsızlığı	-	-	✓	-	-	✓	-
[44]	Gürültü tutarsızlığı	-	-	✓	-	-	-	✓
[45]	Gürültü tutarsızlığı	-	-	✓	-	-	-	✓
[46]	Gürültü tutarsızlığı	-	-	✓	-	-	-	✓
[47]	Kamera tepki fonksiyonu	-	-	-	-	-	-	✓
[48]	Kamera tepki fonksiyonu	-	-	-	-	-	-	✓
[49]	Kamera tepki fonksiyonu	-	-	✓	-	-	-	✓
[50]	Kamera tepki fonksiyonu	-	-	✓	-	-	-	✓
[52]	Aydınlatma tutarsızlığı	-	-	✓	-	-	-	✓
[54]	Renk bilgisi	-	✓	-	-	-	✓ <sub>g</sub>	-

g:gri renkli veri seti, r: renkli veri seti, e:eğitim, t: test

Literatürde [12-33] ile yapılan çalışmalarda görüntülerin doğrulanmasında elde edilen doğruluk oranı yaygın olarak %98'in altındadır. Görüntüyü yüksek doğrulukla sınıflandırmayı amaçlayan tez süresince yapılan çalışmalarla;

- Uzman bir sistemden beklenir şekilde görüntülerin %100'e yakın bir oranla doğrulanması

- Elde edilecek sistem performansı için ekstra bir sürece (öznitelik seçme algoritması gibi) ihtiyaç duyulmaması
- Yöntemin farklı atak tiplerine karşı dayanıklı olması

sağlanmıştır. Görüntüleri sınıflandırmada kullanılan öznitelik vektörlerinin oluşturulmasında, eklemli bölgenin görüntünün yapısında neden olduğu bozuklukları tespit edebilecek yöntemler araştırılmıştır. Yapılan çalışmalarda görüntünün yapısındaki istatistiksel bozulmaları değerlendiren iki yöntem, dokusal bozulmaları değerlendiren ve her iki kategorideki bozulmaları literatürde ilk kez hibrit olarak değerlendiren toplamda dört yeni yöntem önerilmiştir.

1. Görüntüdeki istatistiksel bozulmaların değerlendirilmesi: İstatistiksel bozulmaların değerlendirilmesinde görüntünün farklı frekans bantlarındaki özniteliklerinden yararlanılmıştır. Görüntüdeki her bir pikseli bir düğüm/durum olarak değerlendirilerek Markov Zincir modelinin görüntüler üzerinde uygulanması sağlanmıştır. Görüntüdeki istatistiksel bozulmaları farklı frekans domen ve bileşenlerinde değerlendiren iki farklı yöntem önerilmiştir.

Birinci önerilen yöntemde görüntü birleştirme sahteciliğinin tespitinde yapılandırılan bölgenin istatistiksel bozulmaları DWT domen düşük frekans bandında değerlendirilmiştir [56]. [23]'te önerilen yöntemde görüntü üzerindeki yatay ve dikey piksel geçişlerine bakılmıştır ancak bir görüntüdeki piksel etrafındaki tüm komşuları ile ilişkilidir. Yöntem ele alınan pikselin tüm geçişlerini yansıtmama zafiyetinden dolayı çok yüksek bir performans sergilememiştir. [23] ile önerilen yöntem üzerinde iyileştirme yapılarak, Durum Geçiş modeli dört yönlü olarak genişletilmiştir. Yapılan çalışmada birleştirilmiş görüntü sahteciliğinin tespitinde öznitelik vektörlerinin oluşturulması için Ayrık Dalgacık Dönüşümü ve Markov tabanlı bir yöntem kullanılmıştır [56]. İlk olarak görüntüye Ayrık Dalgacık Dönüşümü uygulanarak düşük frekans bileşenli görüntü elde edilmiş, daha sonra düşük frekanslı görüntü üzerinden durum geçişleri modellenmiştir. Öznitelik çıkarma işleminden sonra destek vektör makineleri yardımı ile görüntüler sahte ve orijinal olarak sınıflandırılmıştır. Önerilen yöntem elde edilen öznitelik vektörünün küçük olmasından dolayı düşük hesaplama karmaşıklığına sahiptir. Yöntem yüksek doğruluk performansı göstermiştir.

İstatistiksel bozulmaların değerlendirildiği diğer çalışmada DCT domen yüksek frekans bileşenlerindeki durum geçişlerinin modellenmesi önerilmiştir [57]. Görüntüye eklenen bölgenin yüksek frekans bileşenlerinde de farklılık oluşturabileceği fikri ile

görüntüye DCT uygulandıktan sonra zigzag tarama ile 16 YF (yüksek frekans) katsayısı alınmış ve 4x4'lük alt bloklara dönüştürülmüştür. Bu alt bloklardaki katsayı geçişlerinin dört yönlü bağımlılığı modellenerek öznitelik matrisi oluşturulmuş ve elde edilen öznitelikler destek vektör makineleri ile sınıflandırılmıştır. Önerilen yöntem yüksek doğruluk oranı ile görüntüleri sınıflandırabilmektedir.

2. Görüntüdeki dokusal bozulmaların değerlendirilmesi: Görüntü birleştirme sahteciliği ile elde edilen görüntüde eklemli bölge görüntünün dokusal yapısında da bozulmalar meydana getirecektir. Önerilen bir diğer yöntem görüntü birleştirme sahteciliğinin tespiti için görüntünün dokusal yapısının istatistiklerinden yararlanır. Görüntüdeki dokusal bozulmaların frekans alanında daha iyi görülebileceği düşüncesi ile yöntem için uygun frekans domeni aranmış, DWT, SWT (Stationary Wavelet Transform-Sabit Dalgacık Dönüşümü), LWT (Lifting Wavelet Transform-Kaldırmalı Dalgacık Dönüşümü) ve Hilbert Dönüşüm uzaylarından elde edilen öznitelikler ile sistemin performansı değerlendirilmiştir. Elde edilen sonuçlar doğrultusunda Hilbert dönüşüm uzayında çalışılmıştır. Eklenen bölge görüntünün kenar bölgelerinde bozukluk meydana getireceği düşüncesi ile literatürde ilk kez kenar görüntülerinden dokusal özellikler çıkarılmıştır. Dokusal özniteliklerin elde edilmesi için dört yönlü GLCM (Gray Level Co-occurrence Matrice-Gri Seviye Eş Oluşum Matrisi)'nin her bir yönlendirmedeki ortalama parlaklık değerinin standart sapması, her yöndeki GLCM'nin entropi değeri ve yerel ikili örüntü (LBP) histogramları kullanılmıştır. Önerilen yöntem sisteme verilen görüntüleri yüksek doğruluk oranı ile sınıflandırmakta ve farklı atak tiplerine dayanıklılık göstermektedir.

3. Görüntüdeki istatistiksel ve dokusal özniteliklerin birlikte değerlendirilmesi: Literatürde yapılan çalışmalarda görüntüdeki eklemli bölgenin oluşturduğu bozukluklar istatistiksel ve dokusal olarak ayrı ayrı değerlendirilmiştir. Önerilen bu yöntemde görüntünün istatistiksel ve dokusal özniteliklerini literatürde ilk kez birlikte değerlendiren hibrit bir yöntem önerilmiştir [58]. Yöntem SWT'den elde ettiği yüksek frekanslı alt bantlardan görüntünün durum geçiş modeli ile istatistiksel özniteliklerini elde etmiş, yine yüksek frekanslı alt bantlardan GLCM tabanlı Haralic'in dokusal özelliklerini kullanarak dokusal öznitelikleri elde etmiştir. Elde edilen bu iki tür öznitelik (istatistiksel ve dokusal) birleştirilerek elde edilen öznitelikler SVM yardımı ile görüntüleri sınıflandırmada kullanılmıştır.


Bu tez süresince yapılan çalışmalar Matlab simülasyon ortamı kullanılarak denenmiş ve önerilen yöntemler kodlanması hazır paketler olmaksızın tarafımızca yapılmıştır. Tez süresince yapılan çalışmalar öncelikle ön işleme adımı yapılan çalışmalardan bahsedilmiş daha sonra görüntüden öznelik çıkarmak için yapılan çalışmalar dokusal, istatistiksel ve hibrit öznelikler olmak üzere üç alt başlık halinde verilmiştir.

## 2.1. Sahtecilik Tespitinde Görüntü Ön İşleme ile İlgili Yapılan Çalışmalar


Bu bölümde görüntüden öznelik çıkarmadan önce görüntüye uygulanan ön işleme adımlarından bahsedilecektir. Kullanılan ön işleme adımları; görüntünün farklı renk uzayı dönüşümü ve farklı frekans dönüşümlerinin incelenmesi olmuştur. Farklı renk uzayı ve farklı frekans domeni dönüşümlerinde görüntünün ayrıntılarının elde edilmesi irdelenmiştir.

### 2.1.1. Renk Uzaylarının Değerlendirilmesi

Literatürde yaygın olarak kullanılan YCbCr renk uzayının yanı sıra Lab uzayı dönüşümü de tez çalışması kapsamında uygulanmıştır. YCbCr renk uzayında Y kanalı görüntünün parlaklık kanalını, Cb ve Cr kanalı da görüntünün renk kanallarını temsil etmektedir. İnsan göz, parlaklık kanalına daha hassas olmasına rağmen Cb ve Cr renk kanallarında görüntünün daha ayrıntılı bilgilerine ulaşılabilir.




Şekil 2.1. Sahte görüntünün YCbCr renk uzayı dönüşümü



Şekil 2.2. Sahte görüntünün YCbCr renk uzayındaki kanallara ayrıştırılması

Şekil 2.1’de başka bir görüntüden alınan tilki görüntüsünün manzara görüntüsü üzerine yapıştırılması ile elde edilen sahte görüntü gösterilmektedir. Bu görüntünün her bir renk kanalında ayrı ayrı temsili Şekil 2.2’de görülmektedir. Cb ve Cr renk kanallarında elde edilen görüntüde yapıştırılan bölge ön plana çıkmaktadır. Dolayısıyla görüntüyü YCbCr renk kanalında temsil ederek özellikle renk kanalları olan Cb ve Cr kanalından elde edilen özniteliklerin sınıflandırmada kullanılması sahtecilik algılama performansını artırmıştır. YCbCr renk uzayı dönüşümüne alternatif olarak kullanılması planlanan renk uzayı Lab uzayı olmuştur. YCbCr renk uzayına benzer şekilde L kanalı parlaklık kanalını a ve b kanalları da renk kanallarını temsil etmektedir. Tilki görüntüsü ile elde edilen sahte görüntünün Şekil 2.3’teki dönüşümünden görüleceği gibi yine renk kanallarında (a ve b) yapıştırılan bölge vurgulanmaktadır. Bu nedenle görüntü birleştirme sahteciliğinin tespit edilmesinde bu renk uzayının da kullanılması, görüntüden daha ayrıntılı bilgi edinimini sağlamıştır. “Bulgular ve İrdeleme” bölümünde önerilen yöntemlerin her birinin farklı renk kanallarında temsil edildikten sonra elde ettikleri algılama performans değerlendirmesi ayrıntılı olarak verilmiştir.



Şekil 2.3. Sahte görüntünün Lab renk uzayına dönüşümü

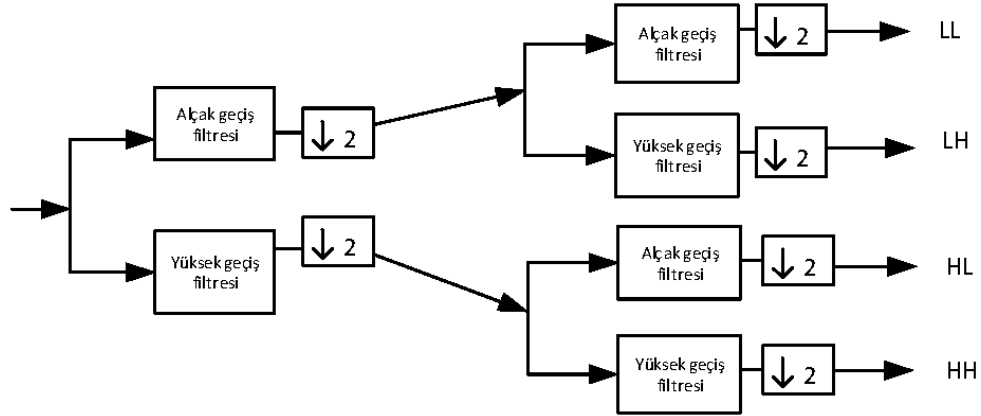


### 2.1.2. Frekans Domenlerinin İncelenmesi

Yapılan çalışmalarda görüntüyü farklı renk uzayında temsil ettikten sonra görüntüdeki ayrıntıları elde edebilmek adına görüntü farklı frekans domenlerinde değerlendirilmiştir. Aşağıda incelenen frekans dönüşüm domenleri verilmiştir bu frekans dönüşümlerinin sistem performansına etkisi yapılan çalışmalarla incelenmiştir.

- Ayrık Dalgacık dönüşümü (DWT)
- Sabit dalgacık dönüşümü (SWT)
- Kaldırmalı Dalgacık Dönüşümü (LWT)
- Hilbert transform dönüşümü
- Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform-DWT)


Macar matematikçi Alfred Haar [59] tarafından önerilen Ayrık Dalgacık Dönüşümü görüntüleri sıkıştırma, ayrıştırma için kullanılan bir dönüşüm tekniğidir. Dönüştürme işlemi dalgacık olarak nitelendirilen ana sinyalin zaman ve frekans bandında farklı dalgalara bölünmesi ile gerçekleştirilir ve bu bantlarda işlemler yapılır. Ayrık dalgacık dönüşümü sinyallerin alt bant ayrıştırması için oldukça etkili ve esnek bir yöntem olarak sunulmuştur. İki boyutlu Ayrık Dalgacık Dönüşümü günümüzde görüntü işlemede önemli bir dönüşümdür. Görüntü üzerinde çok çözünürlüklü bir analiz sağlar ve görüntüyü dalgacık katsayıları ve ölçekleme fonksiyonu ile alt bantlara ayrıştırır. Dalgacık dönüşümü, görüntüyü piksel bloklarından daha verimli şekilde depolanabilen bir dizi dalgacığa dönüştürür. İki boyutlu ayrık dalgacık dönüşümü, önce satırlar boyunca bir boyutlu dalgacık dönüşümü sonra sütunlar boyunca dalgacık dönüşümünün yapılması olarak görülebilir. Dizinin satırlarında öncelikle tek seviyeli ayrıştırma yapılır ve dizi temelde dikey olarak ikiye bölünmüş olur. İlk yarı ortalama katsayıları depolar ikinci dikey yarı ise ayrıntı katsayılarını depolar. Bu işlem daha sonra filtre çıkışı tarafından her ayrıştırma seviyesi için dört alt banda ayıracak şekilde sütunlarda tekrarlanır [60-63]. Şekil 2.4.'te tek seviyeli ayrık dalgacık dönüşümü gösterilmiştir.



Şekil 2.4. Tek seviyeli ayrık dalgacık dönüşümü

- Sabit Dalgacık Dönüşümü (Stationary Wavelet Transform-SWT)

Dalgacık dönüşümü frekans domeninde görüntü ayrıntılarını çok ölçekli bir şekilde ayrıştırmayı sağlar [64]. Yaygın olarak kullanılan Ayrık Dalgacık Dönüşümünde filtrelemeden sonra katsayıların aşağı örnekleme (boyut indirgenmesi) ile gereksiz fazlalık önlenir ve farklı seviyelerde aynı filtre çiftinin (düşük-yüksek) kullanılmasına izin verilir. Bu giriş sinyalindeki küçük kaymaların, farklı seviyelerdeki katsayılar arasındaki enerji dağılımında büyük değişikliklere neden olabileceği ve yeniden yapılanmada bazı hatalara neden olabileceği anlamına gelecektir. Bu problem, sabit dalgacık dönüşümünde her seviyede filtreleme işleminden sonra aşağı örnekleme (boyut indirgeme) adımlarının ortadan kaldırılmasıyla aşılmıştır [65]. Şekil 2.5 (b) 'de görüleceği üzere SWT, DWT'den farklı olarak filtreleri her bir ayrıştırma seviyesinde değiştirir ve alt gruptaki giriş görüntüsünün boyutunu değiştirmez. DWT, her bir ayrıştırma seviyesinde aynı filtreleri kullanmasına karşın SWT her bir ayrıştırma seviyesinde farklı filtreler kullanmaktadır. DWT'de alt bantlarda boyut 2 kat indirgenmiştir. SWT dönüşüm sırasında boyut indirgeme ile ayrıntıların kaybolmasına neden olmaz [65]. Tüm bu özellikler göz önüne alındığında, görüntü birleştirme sahteciliğinin tespitinde frekans domenine dönüşümde SWT'nin kullanılmasının, boyut indirgemeyle bilgi kaybını ortadan kaldıracağı düşüncesi ile bu çalışmada kullanılması tercih edilmiştir.



Şekil 2.5. a)DWT, b)SWT ile dalgacık dönüşümü prosedürü

- Kaldırmalı Dalgacık Dönüşümü (Lifting wavelet transform-LWT)

1998 yılında Sweldens kaldırma yöntemi olarak adlandırılan yeni bir dalgacık dönüşüm yöntemi önermiştir [66]. İkinci nesil dalgacık dönüşümü olarak bilinir. Dalgacık dönüşümlerinin temel fikri, seyrek bir yaklaşım oluşturmak için çoğu gerçek hayat sinyalinde mevcut olan korelasyon yapısından yararlanmaktır. Korelasyon yapısı tipik olarak uzay (zaman) ve frekansta yereldir; komşu örnekler ve frekanslar birbirinden uzak olanlardan daha fazla ilişkilidir. Geleneksel dalgacık yapıları, uzay-frekans lokalizasyonunu oluşturmak için Fourier dönüşümünü kullanır. LWT dalgacık dönüşümünün temeli olan Fourier dönüşümünü kullanmaz ve dönüşüm katsayıları tamsayıdır, bu nedenle kuantalama hatalarının zayıflığı giderilmiş olur. LWT hızlı bir dalgacık dönüşümü algoritmasıdır. Filtre bankası konvolüsyon ve alt örnekleme işlemlerini çift ve tek bileşenlerde gerçekleştirir bu da işlem sayısını yaklaşık iki kat azaltır. Böylece hesaplama hızı ve daha az bellek gereksinimi gibi çeşitli avantajlar da sunar. Kaldırma dönüşümü dalgacık dönüşümü işlemini uzaysal domende yapmaktadır. Bunun için ayrıştırma, tahmin etme ve güncelleme olarak üç adım uygulanır.

Ayrıştırma; girişten gelen sinyal tek ve çift bileşenlerine ayrılır ve bu iki set tipik olarak birbiri ile yakından ilişkilidir [67]. Bu nedenle tek veya çift bileşen setinden biri verildiğinde, bir setin diğer bir set için iyi bir tahminde (P) bulunabilmesi doğaldır. Tahminin kesin olması gerekmediğinden, aradaki farkı ve ayrıntıyı (d) kaydetmemiz gerekir.

$$d = X_c - P(X_t) \quad (1)$$

Verilen ifadede  $X_c$ ,  $X$  sinyalindeki çift bileşenleri,  $X_t$  tek bileşenleri,  $P$  tahmin operatörünü temsil etmektedir.  $d$  ile tahmin edilen ve gerçek değer arasındaki fark hesaplanmıştır. Burada  $d$  ve tek bileşenler göz önüne alındığında çift bileşen (2) ile yeniden inşa edilebilecektir. Eğer  $P$  iyi bir tahmin ise,  $d$  yaklaşık olarak seyrek bir küme olacaktır.

$$X_c = P(X_t) + d \quad (2)$$


Bir tahminin hesaplanması ve detayların kaydedilmesi işlemine bir kaldırma adımı denmektedir. Tahmin adımı uzaysal korelasyonun bazılarıyla ilgilenmektedir ama dalgacıklar için frekans domeninde de bazı ayrıştırmalar istenmektedir. Yukarıdaki ifadelerle  $(X_c, X_t)$ 'dan  $(X_c, d)$ 'ye bir dönüşüm elde edilmiştir. Frekans ayrıştırması zayıftır çünkü  $X_c$  basit bir alt örneklemeyle elde edilmektedir. Bu da sinyalde kısmi bozulma meydana getirir. Özellikle  $X_c$ 'nin ortalaması orijinal sinyaldeki örneklerle aynı değildir. Bunu düzeltmek için ayrıntılara ( $d$ ) uygulanan bir düzeltme operatörü ( $U$ ) kullanılarak, çift bileşenleri düzeltilmiş değerle değiştiren ikinci bir kaldırma adımı uygulanmaktadır [65];

$$s = X_c + U(d) \quad (3)$$

Aynı şekilde bu adım tersine çevrilebilir.  $(s, d)$  verildiğinde  $X_c$ 'yi ifade (4)'deki gibi elde edebiliriz.

$$X_c = s - U(d) \quad (4)$$

Daha sonra  $X_e$  yukarıda anlatıldığı gibi elde edilebilir. Bu kaldırmanın yerleşik özniteliklerinden birini gösterir.  $P$  ve  $U$  nasıl seçilirse seçilsin şema her zaman ters çevrilebilir ve böylece iyi örneklenmiş yeniden yapılandırılabilir bir filtre bankaları ortaya çıkar. Şekil 2.6.'da iki kaldırma adımının (tahmin ve güncelleme) şeması verilmiştir.



Şekil 2.6. Kaldırılmalı dalgacık dönüşümü şeması

- Hilbert Dönüşümü

Sinyal teorisindeki Hilbert Dönüşümü [68,69] gerçek bir sinyal olan  $r(t)$ 'nin karmaşık düzlemde bir uzantısı olarak (5) ifadesi ile sunulmuştur [70].

$$X(t) = r(t) + jh(t) \quad (5)$$

denklemden  $h(t)$ ,  $r(t)$ 'nin Hilbert dönüşümüdür ve (6) tarafından verilen ifadeyle  $H\{r(t)\}$  olarak verilmiştir.

$$h(t) = H\{r(t)\} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{r(t')}{t-t'} dt' = r(t) * \frac{1}{\pi t} \quad (6)$$

Hilbert dönüşümü Fourier domende daha kolay uygulanabilir.  $R(t)$  sinyali ve onun  $90^\circ$  kaydırılmış versiyonu olan  $h(t)$ 'nin Fourier dönüşümünde negatif bileşenlerinin baskılanarak elde edilmesiyle analitik sinyal elde edilir.  $r(t)$ ,  $X(t)$ 'nin reel bileşeni,  $h(t)$  sanal bileşenidir.  $r(t)$  ve  $h(t)$  ortogonal sinyallerdir. Kısaca Hilbert dönüşümü girişindeki tüm sinyallerin fazlarını  $\pm\pi/2$  radyan değiştiren bir filtredir denebilir.

## 2.2. Görüntüdeki İstatistiksel Bozulmaların Değerlendirilmesi

Birleştirme sahteciliği ile elde edilen sahteciliğin tespitinde, görüntüyü verilen sistemde sahte veya orijinal olarak sınıflandırabilmek için ilgili ön işlemler uygulandıktan sonra görüntüden öznelik elde etme adımına geçilmiştir. Bu bölümde birleştirilmiş bölgenin görüntü üzerinde oluşturacağı istatistiksel bozulmaların değerlendirilmesi için

elde edilen istatistiksel öznitelikler anlatılacaktır. Öncelikle istatistiksel öznitelikleri elde etmede kullanılan yöntemlerden (durum geçiş modeli ve geçiş olasılık matrisleri) bahsedilecek daha sonra sahtecilik tespitinde istatistiksel bozulmaları değerlendirmede önerilen iki yöntemin ayrıntıları verilecektir.

### 2.2.1. Durum Geçiş Modeli ve Geçiş Olasılık Matrislerinin Elde Edilmesi

Görüntüdeki bozulmaların istatistiksel olarak değerlendirilmesi aşamasında Markov zincir modelinden yararlanılmıştır. Markov zinciri birbiri ile bağımlı düğümler arasında tek boyutlu olarak bağımlılığı saptar. Model, mevcut bir düğümün (durumun) kendinden sonraki düğüm ile peş peşe gelme olasılığını hesaplar. Bu olasılık, geçiş olasılığı diye adlandırılır. Görüntüdeki istatistiksel bozulmaların değerlendirilmesi başlığı altında yapılan çalışmalarda, bu mantıktan yola çıkarak görüntüdeki her piksel bir durum olarak değerlendirilerek, görüntü içinde kendinden sonraki pikselle tekrar bir araya gelme olasılığı hesaplanmıştır. Durum geçiş modelinin hesaplanması 3 adımdan oluşmaktadır.

- Pikseller arasındaki renk geçişlerini modelleyebilmek için her bir pikselin, dört yöndeki komşularıyla fark matrisleri (7) ile verilen ifadedeki gibi hesaplanır.

$$F_h(u, v) = F(u, v) - F(u + 1, v)$$

$$F_v(u, v) = F(u, v) - F(u, v + 1)$$

$$F_{mad}(u, v) = F(u, v) - F(u + 1, v + 1)$$

$$F_{mid}(u, v) = F(u + 1, v) - F(u, v + 1) \quad (7)$$

- Geçiş olasılık matrislerinin boyutunu yani öznitelik vektörlerinin boyutunu azaltmak için bir eşikleme tekniği geliştirilmiştir, böylece hesaplama karmaşıklığı azaltılmıştır. İkinci aşamada belirlenen bir eşik değerine göre (T), katsayı fark matrisindeki değerler (8) ile verilen ifadede gösterildiği gibi kuantalanır.

$$e_{yeni} = \begin{cases} T, & e \geq T \\ -T, & e \leq -T \\ e, & diğ\text{er} \end{cases} \quad (8)$$

Buradaki  $e$  fark matrisindeki mevcut değeri göstermektedir.

- Durum geçiş modeli için son aşamada Geçiş Olasılık Matrisleri (GOM) hesaplanır.  $i, j \in \{-T, -T + 1, \dots, 0, \dots, T - 1, T\}$ ,  $S_u$  ve  $S_v$  orijinal kaynak görüntünün boyutunu temsil etmektedir.  $\delta(\cdot)$  sadece koşullar sağlandığında 1, aksi halde daima 0 değerini vermektedir. (9) ile verilen ifadeler ile toplamda 6 tane GOM üretilmiş olur.

$$\begin{aligned}
P_{hh}(i, j) &= \frac{\sum_{u=1}^{S_u-2} \sum_{v=1}^{S_v} \delta(F_h(u, v) = i, F_h(u + 1, v) = j)}{\sum_{u=1}^{S_u-2} \sum_{v=1}^{S_v} \delta(F_h(u, v) = i)} \\
P_{hv}(i, j) &= \frac{\sum_{u=1}^{S_u-1} \sum_{v=1}^{S_v-1} \delta(F_h(u, v) = i, F_h(u, v + 1) = j)}{\sum_{u=1}^{S_u-1} \sum_{v=1}^{S_v-1} \delta(F_h(u, v) = i)} \\
P_{vh}(i, j) &= \frac{\sum_{u=1}^{S_u-1} \sum_{v=1}^{S_v-1} \delta(F_v(u, v) = i, F_v(u + 1, v) = j)}{\sum_{u=1}^{S_u-1} \sum_{v=1}^{S_v-1} \delta(F_v(u, v) = i)} \\
P_{vv}(i, j) &= \frac{\sum_{u=1}^{S_u} \sum_{v=1}^{S_v-2} \delta(F_v(u, v) = i, F_v(u, v + 1) = j)}{\sum_{u=1}^{S_u-1} \sum_{v=1}^{S_v-2} \delta(F_v(u, v) = i)} \\
P_{mad}(i, j) &= \frac{\sum_{u=1}^{S_u-2} \sum_{v=1}^{S_v-2} \delta(F_d(u, v) = i, F_d(u + 1, v + 1) = j)}{\sum_{u=1}^{S_u-2} \sum_{v=1}^{S_v-2} \delta(F_d(u, v) = i)} \\
P_{mid}(i, j) &= \frac{\sum_{u=1}^{S_u} \sum_{v=1}^{S_v-2} \delta(F_{-d}(u+1, v)=i, F_{-d}(u, v+1)=j)}{\sum_{u=1}^{S_u-2} \sum_{v=1}^{S_v-2} \delta(F_{-d}(u, v)=i)} \tag{9}
\end{aligned}$$

Elde edilen geçiş olasılık matrislerinin bütün elemanları öznitelik vektörünü oluşturmaktadır. Bu öznitelikler görüntüdeki pikseller arasındaki bağımlılığı istatistiksel olarak yansıtmaktadır.


Durum geçiş modelini kullanarak sahtecilik tespiti için iki yöntem önerilmiştir. Bunlardan bir tanesi DWT domen düşük frekans bandında, diğeri ise DCT domen yüksek frekans bandında sahteciliği tespit etmektedir. Aşağıda önerilen yöntemlerin detayları verilmektedir.

### 2.2.2. Ayrık Dalgacık Dönüşüm Domeni Düşük Frekans Bileşenlerinde Durum Geçiş Modeli Tabanlı Sahtecilik Tespiti

Görüntü birleştirme sahteciliğinin tespitinde yapılan çalışmalarda temel hedef görüntüyü yüksek doğruluk ile doğrulamaktır. Bunun için görüntüyü en iyi temsil edecek öznitelik vektörleri araştırılmış ve bu öznitelik vektörler bir sınıflandırıcı yardımı ile

görüntüyü sahte ve orijinal olarak iki sınıfa ayırmak için kullanılmıştır. He vd. [23] görüntüden istatistiksel öznitelik çıkarmak için görüntü pikselleri arasındaki yatay ve dikey bağımlılığa bağlı olarak geçiş olasılık matrislerinin hesaplanması ile sahteciliği tespit eden bir çalışma yapmıştır. Çalışmadan elde edilen algılama performansı, adli delil oluşturabilecek görüntülerin doğrulanmasında kullanılabilir kadar yüksek değildir. [23]'teki çalışmanın iyileştirilmesi için pikseller arasındaki korelasyonu, düşük frekans bileşenlerinde dört yönlü olarak ele alan yeni bir yöntem önerilmiştir [56].

Önerilen yöntemde sahte ve orijinal görüntülerin yüksek doğruluk oranı ile tespit edilmesi amaçlanmıştır. Görüntüdeki piksel geçişlerinin modellenmesini kullanan yöntemin şeması Şekil 2.7'de verilmiştir. Yapılan çalışmada [56] girişten gelen renkli görüntünün öncelikle kullanılacak renk uzayına dönüşümü yapılır ve performans testleri sonucu ilgili renk kanalı seçilir. Daha sonra görüntüye DWT uygulanarak görüntü yüksek ve düşük frekanslı alt bantlara ayrılır. Bu alt bantlardan düşük frekanslı alt bant alınarak öznitelik çıkarma adımına geçilir. DWT ayrıştırma sonucu elde edilen düşük frekanslı alt bantın boyutu görüntünün  $1/4$ 'ü kadar olduğundan öznitelik çıkarma adımında hesaplama karmaşıklığı azaltılmış olur. Elde edilen düşük frekanslı görüntü üzerine DCT uygulandıktan sonra, katsayı fark matrisleri çıkarılıp (7), bu matrisler üzerine dört yönlü Markov modeli uygulanır.



Şekil 2.7. Önerilen yöntem-1'in [56] akış diyagramı

Önerilen yönteminin adımları aşağıdaki gibidir.

Adım 1: Görüntünün kullanılacak olan renk uzayına dönüşümü yapılarak renk kanalı seçilir.

Adım 2: Seçilen kanal görüntüsüne 1.seviye DWT uygulanarak görüntünün düşük frekanslı bileşeni elde edilir ve bundan sonraki adımlar bu bileşen üzerinde uygulanır.



Adım 3: Görüntü  $8 \times 8$  büyüklüğündeki karesel bloklara ayrılır ve her bir bloğa DCT dönüşümü uygulanarak DCT katsayıları elde edilir. Katsayılar en yakın değere yuvarlanıp, mutlak değerleri alınır.

Adım 4: DCT katsayı matrisleri üzerinden (7)'deki ifade yardımıyla yatay ( $F_h$ ), dikey ( $F_v$ ), ana köşegen ( $F_{mad}$ ) ve minor köşegen ( $F_{mid}$ ) katsayı fark matrisleri elde edilir.

Adım 5: Belirlenen bir eşik değerine göre ( $T$ ), katsayı fark matrisindeki değerler (8)'deki ifadenin kullanımı ile kuantalanır.

Çalışmada kullanılan  $T$  eşik değeri deneysel olarak belirlenmiştir. Yuvarlama ve eşik işlemi sonrasında, katsayı fark matrisinin elemanlarının her biri bir durum olarak değerlendirilir ve bu durumlardan GOM'ler üretilir.

Adım 6: Yatay ( $P_{hh}, P_{vh}$ ), Dikey ( $P_{hv}, P_{vv}$ ) ve Köşegenel ( $P_{mad}, P_{mid}$ ) GOM'ler (9)'de gösterilen şekilde hesaplanır.

Adım 7: GOM'nin tüm elemanları görüntü birleştirme sahteciliğini tespit etmek için öznitelik olarak kullanılır. Elde edilen öznitelik vektörünün boyutu seçilen  $T$  eşik değerine bağlı olarak  $(2T+1) \times (2T+1) \times 6$  olmaktadır.

Adım 8: Elde edilen öznitelik vektörleri ile görüntüler bir sınıflayıcı yardımıyla sınıflandırılır.

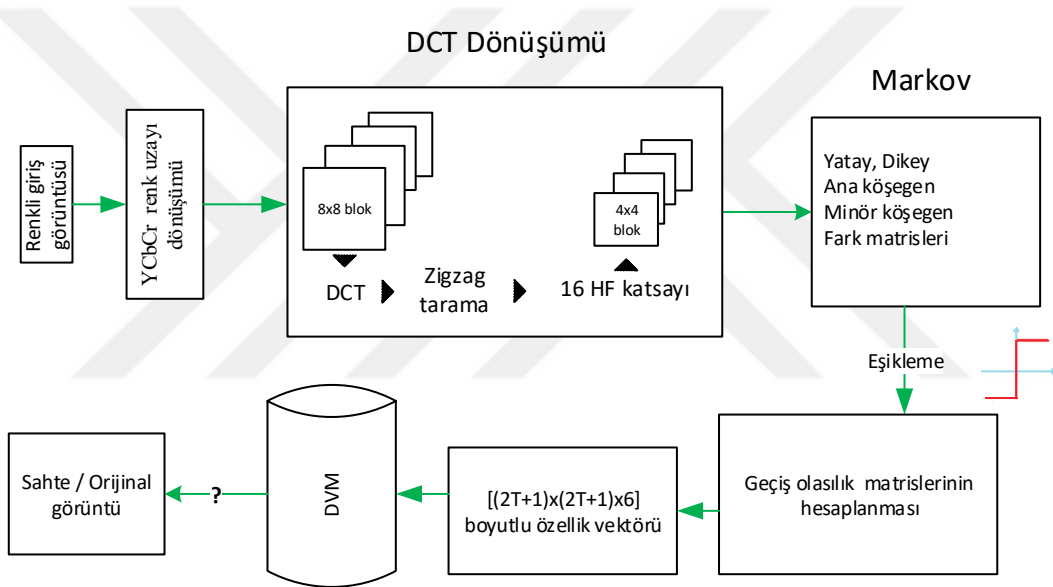
Çalışma, görüntünün dokusal ve istatistiksel özniteliklerini kullanan literatürdeki diğer yöntemlerle kıyaslanmıştır ve yüksek doğruluk oranı ile sahte görüntülerin tespit edildiği görülmüştür. Yukarıda detayları verilen yöntemin performans değerlendirmesi bulgular ve irdeleme kısmında verilmiştir.

### **2.2.3. DCT Yüksek Frekans Bölgesinde Durum Geçiş Modeli ile Sahtecilik Tespiti**

Görüntüye başka bir görüntüden eklenen bölgenin ana görüntüdeki yüksek frekans bileşenlerinde de farklılık oluşturabileceği düşüncesi ile önerilen yöntemde DCT domen yüksek frekans bölgesinde çalışılmıştır. Yapılan çalışmanın [57] esas hedefi girişten gelen test görüntüsünün sınıflamasında (orijinal ve sahte olmak üzere iki sınıf mevcuttur) doğruluk oranı yüksek bir yöntem önerebilmektir.

YCbCr uzayı çalışma kapsamında test görüntüsünün temsilinde kullanılmış, tüm kanallar üzerinde yapılan testler ile hangi kanalın seçiminin daha anlamlı olacağına karar verilmiştir. Daha sonra görüntüye  $8 \times 8$ 'lik bloklar halinde DCT uygulanarak görüntü

frekans boyutuna taşınmıştır. Bu dönüşümle görüntünün toplam enerjisi dönüşüm katsayılarında toplanır. Elde edilen DCT katsayıları üzerinde zigzag tarama ile alınan 16 yüksek frekanslı katsayıdan 4x4'lük bloklar oluşturularak temsili DCT görüntüsü elde edilir. DCT dönüşümden sonra 16 yüksek frekans katsayısının seçilmesi ile  $\frac{1}{4}$  oranında görüntü boyu indirgenmiş olur böylelikle hesaplama karmaşıklığı da azaltılmış olmaktadır. Yüksek frekanslı DCT katsayılarının ifade ettiği anlamı daha belirgin hale getirmek için, kuantalama işlemi yapılmış, kuantalama değeri de deneysel olarak belirlenmiştir. DCT dönüşümü sonrası katsayı fark matrisleri çıkarılıp bu matrisler üzerinden dört yönlü Markov modeli uygulanmıştır. Şekil 2.8'de önerilen yöntemin akış şeması verilmiştir.



Şekil 2.8. Önerilen yöntem-2'nin akış şeması

Aşağıda yapılan çalışmanın ayrıntıları adımlar halinde verilmiştir.

Adım 1: Renkli görüntünün YCbCr renk uzayına dönüşümü yapılarak görüntü kanallara ayrılır, yöntemin geri kalan kısmı bu kanallara uygulanır.

Adım 2: Görüntü 8x8'lik karesel bloklara ayrılıp her bir bloğa DCT dönüşümü uygulanır. Şekil 2.9'da gösterilen zigzag tarama ile yüksek frekans bölgesinden son 16 DCT katsayısı seçilir.

1	2	6	7	15	16	28	29
3	5	8	14	17	27	30	43
4	9	13	18	26	31	42	44
10	12	19	25	32	41	45	54
11	20	24	33	40	46	53	55
21	23	34	39	47	52	56	61
22	35	38	48	51	57	60	62
36	37	49	50	58	59	63	64

Şekil 2.9. DCT katsayılarının zigzag sıralaması

Adım 3: Katsayıların ifade ettiği alanı netleştirmek için seçilen yüksek frekans katsayıları kuantalanır. Kuantalama işlemi için kullanılacak olan  $q$  değeri deneysel sonuçlar kısmında irdelenmiştir. Kuantalama işleminden sonra katsayılar en yakın değere yuvarlanıp mutlak değeri alınır.

Adım 4: DCT yüksek frekans bölgesinden elde edilen katsayılar ile Markov öznitelikleri hesaplanır, Markov öznitelikleri genel olarak üç adımda gerçekleştirilir. Öncelikle katsayı fark matrisleri (7)'de verilen ifade ile hesaplanır.

Katsayı fark matrisindeki elemanlar belirlenen bir  $T$  eşik değeri ile (8)'de verilen ifadeye göre kuantalanır. Bu kuantalama işleminden sonra durumlar arasındaki geçişler  $[-T, T]$  aralığında hesaplanacağından elde edilecek GOM'lerin boyutu sınırlandırılmış olur.

Markov öznitelikleri için son aşamada Geçiş Olasılık Matrisleri (GOM) (9)'daki ifadenin kullanımı ile hesaplanır. Toplamda 6 tane GOM üretilmiş olur.

Adım 5: GOM'nin tüm elemanları öznitelik olarak kullanılır.  $T$ 'ye bağlı olarak öznitelik vektörü  $(2T + 1) \times (2T + 1) \times 6$  boyutludur.

Adım 6: Elde edilen öznitelik vektörleri ile görüntüler bir sınıflayıcı yardımıyla sınıflandırılır.

Bu bölümde görüntü birleştirme sahteciliği tespiti için önerilen yöntemin [56] detayları verilmiştir. Yöntemin performans değerlendirmesi Bulgular ve İrdeleme bölümünde verilecektir.

### 2.3. Görüntüdeki Dokusal Bozulmaların Değerlendirilmesi

Görüntü birleştirme sahteciliğini tespit etmek için yapılan bir diğer çalışmada eklemlenmiş bölgenin hedef görüntüde meydana getireceği dokusal bozulmaların kullanılması düşünülmüştür. Literatürde görüntüdeki dokusal öznitelikleri kullanarak sahtecilik tespiti

yapan çalışmalar görüntüyü farklı filtrelerden geçirdikten sonra (Gabor, Entropi) veya DCT domende doku operatörlerini kullanarak öznitelik vektörlerini oluşturmuştur. Sahte görüntüdeki eklemli bölge yapıştırıldığı orijinal görüntüde ekstra bir kenar oluşturacağından görüntünün dokusal yapısında bir değişiklik meydana getireceği düşüncesi ile literatürdeki yöntemlerden [12-22] farklı olarak önerilen yöntem kenar görüntüleri üzerinden öznitelik çıkarmaktadır. Yapıştırılan bölgenin sınır bölgelerindeki piksellerin, orijinal görüntüyle arasında farklı bir geçişe sahip olacağından, görüntüdeki değişimi algılamak için varyans bilgisinden faydalanılması düşünülmüştür. Kenar görüntülerindeki dokusal öznitelikler GLCM üzerinden elde edilmiştir. Bu bölümde görüntüden GLCM'lerin elde edilmesinden bahsedildikten sonra, Hilbert domende sahtecilik tespiti için dokusal öznitelikleri kullanarak yapılan çalışmanın detayları verilecektir.


### 2.3.1. Görüntüden GLCM'lerin Elde Edilmesi

Literatürde görüntü bölütleme, yüz algılama, video kesimi algılanması, video sahteciliği, hareketli nesnelerin algılanması gibi birçok farklı çalışma alanlarında görüntünün dokusal karakteristiğini yansıtabilmesi nedeni ile aşağıda detayları verilecek olan GLCM yaygın olarak kullanılmıştır [71-80]. Birleştirilmiş sahte görüntünün dokusal yapısında meydana gelecek olan bozulmalar GLCM üzerinden varyans, entropi bilgisi ve yerel ikili örüntü özellikleri kullanılarak elde edilmiştir. Bu bölümde sırasıyla görüntüden GLCM matrislerinin elde edilmesi ve önerilen yöntemin detayları verilecektir.

GLCM, ilk olarak Haralick tarafından önerilmiştir [81]. GLCM görüntü dokusunu iyi analiz edebilmesi sebebiyle görüntü işleme alanında sıklıkla tercih edilen, piksellerin mekânsal ilişkisini dikkate alan istatistiksel bir yöntemdir ve aynı zamanda gri-düzy mekânsal bağımlılık matrisi olarak da bilinir. GLCM,  $i$  değerine sahip gri seviye piksel parlaklığının  $j$  değerindeki bir piksel ile belirli bir uzamsal ilişkisinin frekansını bularak (10)'da verilen ifade ile hesaplanır.


$$P(i, j, d, \theta) = \sum_{p=1}^m \sum_{q=1}^n \begin{cases} 1, & I(p, q) = i \text{ ve } I(p + d\theta_0, q + d\theta_1) = j \\ 0, & \text{diğer} \end{cases} \quad (10)$$

$d$  uzaklık ve  $(\theta)$  açı  $I(p,q)$  görüntüyü temsil etmektedir. GLCM'de, görüntüde  $(i,j)$ 'deki her bir eleman  $i$  parlaklık değerine sahip pikselin belirlenen mekansal ilişkideki  $j$  değerine sahip pikselle ilişkili olduğu toplam sayı hesaplanır. GLCM, gri tonlamalı bir görüntüdeki parlaklık değerlerinin sayısını 256'dan 8'e düşürmek için ölçekleme kullanır. Gri seviyelerin sayısı GLCM'nin boyutunu belirler. GLCM iki parametre ile hesaplanır. Birincisi arasındaki ilişkiye bakılacak olan pikselin uzaklığı ( $d$ ) ve diğeri bu uzaklıkta hangi yöndeki pikselin seçileceğini belirten döndürme açısı ( $\theta$ )'dır.  $\theta$ , Şekil 2.10'da gösterildiği gibi genellikle 0,45,135,180 derece açılarla kullanılır. Bu açılarla doku özneliklerinin döndürme ile değişmediği ispatlanmış olur.



Şekil 2.10. GLCM'de  $d=1$  ve  $\theta= 0^{\circ}, 45^{\circ}, 90^{\circ}, 135^{\circ}$  döndürme açısı ile kullanılan pikseller


Şekil 2.11'de örnek bir görüntü üzerinde GLCM hesaplaması verilmiştir. Örnek görüntü 4 seviyeli gri değere sahiptir dolayısıyla elde edilecek GLCM'nin boyutu da  $4 \times 4$ 'tür. Her bir renk seviyesindeki geçişlerin toplam sayısının hesaplanması ile GLCM matrisi elde edilir. Örneğin şekilde yeşil ile gösterilen 2-2 geçişine baktığımızda görüntüde toplamda 1 tane geçiş mevcuttur dolayısıyla GLCM matrisinde (2,2) indisli hücreye 1 yazılmıştır.



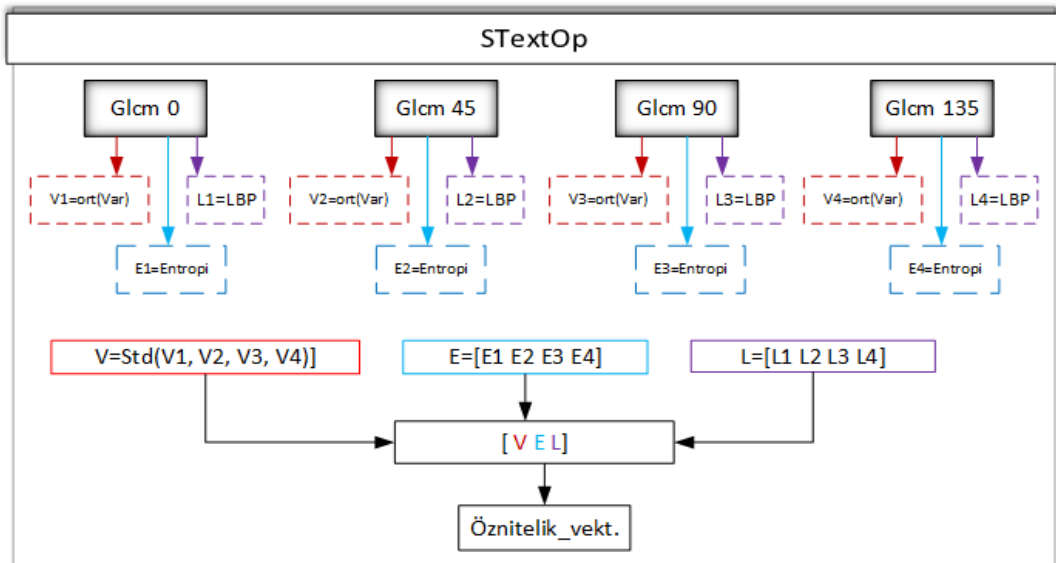
Şekil 2.11. GLCM'nin oluşturulması. a) 4x4'lük dört gri seviyeli görüntü b)  $d=1$  ve  $\theta=0$  parametreleri ile GLCM oluşturulması

### 2.3.2. Hilbert Domende LBP ve Entropi Tabanlı Birleştirme Sahteciliğinin Tespiti

Önerilen yöntemde sahte ve orijinal görüntüleri birbirinden ayırabilmek için elde edilecek öznitelik vektörünün oluşumunda görüntünün dokusal özniteliklerinin istatistiklerinin değerlendirilmesi amaçlanmıştır. Görüntü birleştirme sahteciliği ile oluşturulan sahte görüntüde yapıştırılan bölgenin kenar bölgelerinin sistemin dokusal özniteliklerinin istatistiğinde farklılık yaratacağı düşüncesi ile öznitelik vektörü kenar görüntüsü üzerinden çıkarılmıştır. Kenar görüntüsü için Sobel, Prewitt ve Canny algoritmaları kullanılmış ve en iyi sonuç veren algoritma seçilmiştir. Öznitelik vektörü görüntünün ilgili renk kanalından GLCM matrisleri üzerinden ortalama varyansın standart sapması, LBP ve entropi değerlerinden oluşmaktadır. Frekans domeninin görüntüdeki ayrıntıları daha iyi yansıtacağı düşüncesi ile yöntem DWT, SWT, LWT ve Hilbert dönüşüm uzayında test edilmiştir. Önerilen yöntemin akış şeması Şekil 2.12'de verilmiştir.



(a)



(b)

Şekil 2.12. Önerilen yöntem-3'ün akış şeması

Sisteme giriş görüntüsü olarak gelen renkli görüntü ön işleme tabi tutularak YCbCr ve Lab renk uzaylarını dönüşümü gerçekleştirilir. Yöntem her bir renk kanalı üzerinde uygulanmaktadır. Seçilen renk kanalına Canny kenar bulma algoritması uygulanarak kenar görüntüsü elde edilir ve bu görüntünün Hilbert uzayına dönüşümü yapılır. Frekans domenindeki görüntüye DCT uygulandıktan sonra yatay ( $F_h$ ), dikey ( $F_v$ ), ana köşegenel ( $F_{mad}$ ) ve minor köşegenel ( $F_{mid}$ ) yönlerdeki katsayı fark matrisleri (7) ile verilen ifadenin kullanımı ile elde edilir. Elde edilen bu fark matrislerinin her birinden dört yönlü GLCM'ler hesaplanır ve bu GLCM'ler STextOp diye isimlendirilen (Statistics of Texture Operator) dokusal özniteliklerin istatistiklerini elde etmek için kullanılır. Dokusal özniteliklerin istatistiklerini elde etmek için GLCM'nin dört yönlü ortalama varyansının standart sapması, entropi bilgisi ve LBP histogramları kullanılmıştır. Görüntü işlemede entropi dokuları sınıflandırmak için kullanılabilir, belirli desenler yaklaşık olarak belirli şekillerde kendilerini tekrar ettiği için belirli bir doku belirli bir entropiye sahip olabilir. Düşük entropi düşük düzensizlik yani düşük varyans anlamına gelir. Düşük entropiye sahip bir bileşen, yüksek entropiye sahip bir bileşenden daha homojendir.


Önerilen yöntem aşağıda adımlar halinde verilmiştir.

Adım 1. Renkli giriş görüntüsü YCbCr ve Lab renk uzaylarına dönüşümü yapılır ve tüm alt kanalları öznitelik çıkarmada kullanılır.

Adım 2. Seçilen renk kanalına Canny operatörü uygulanarak kenar görüntüsü elde edilir, sonraki adımların hepsi (3-9) bu kenar görüntüsü üzerinde uygulanır.

Kenar bulma, görüntü analizinde ve sınıflandırmada önemli bilgiler içerdiğinden görüntü işleminin temel adımlarından biri olmuştur. Kenar çıkarmanın amacı görüntü içindeki önemli bilgileri koruyarak gereksiz bilgileri filtrelemektir. Kenar görüntüdeki bir nevi yoğunluktaki zıtlıktır, yoğunluk noktasında bir seviyeden diğerine sıçrama noktasıdır da denebilir. Kenar algılama, görüntülerdeki nesnelerin sınırlarını bulmak için bir görüntü işleme tekniğidir. Parlaklıktaki süreksizlikleri tespit ederek çalışır. Kenar algılama, görüntü segmentasyonu, görüntü işleme, bilgisayarla görme ve makine görme gibi alanlarda görüntüden veri çıkarma için kullanılır [82-86]. Görüntü birleştirme sahteciliğinde yapılandırılan bölge görüntünün kenarlarında tutarsızlıklara yol açacaktır. Şekil 2.13'te orijinal ve eklemli bir görüntüden elde edilen 3 farklı kenar görüntüsü verilmiştir. Şekilde soldaki kolonda orijinal görüntüler sağdaki kolonda birleştirilmiş sahte görüntüye ait görüntülerin Y parlaklık kanalından elde edilen Sobel, Prewitt ve Canny operatörleri ile elde edilen kenar görüntüleri verilmektedir.





Şekil 2.13. a) Orjinal görüntüler ve kenar görüntüleri, b) Sahte görüntüler ve kenar görüntüleri

Şekil 2.13'te ikinci satır görüntülerinden görüleceği üzere en iyi kenar görüntüsü Canny algoritması ile elde edilmiştir. Sobel [87] ve Prewitt [88] kenar bulma algoritmaları görüntünün 1.türevine dayalı kenar bulma algoritmalarıdır. Sobel (11) ile verilen, prewitt (12) ile verilen konvolasyon matrisleriyle görüntünün x ve y yönünde türevini alarak görüntüdeki kenarları bulur.

$$\begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (11)$$

$$\begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}, \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix} \quad (12)$$

Canny algoritmasında ise zayıf ve güçlü kenarları belirleyebilmek için 2 farklı eşik değeri kullanılmaktadır. Canny kenar dedektörü ilk önce gürültüyü ortadan kaldırmak için görüntüyü düzeltir (yumuşatır). Daha sonra, yüksek uzaysal türevleri olan bölgeleri vurgulamak için görüntü gradyanını bulur. Algoritma daha sonra bu bölgeler boyunca izler ve maksimumda olmayan pikselleri bastırır. Gradyan dizisindeki kesiklik böylece azalır. Geri kalan pikseller için iki eşik kullanılır. Eğer gradyanın genliği (büyüklük) ilk eşik altında ise sıfırlanarak kenar olarak algılanmaktan çıkarılır şayet büyüklüğü yüksek eşik üzerinde ise, kenar olarak algılanır. Eğer büyüklük iki eşik arasında ise, o zaman bu pikselden T2'nin üzerinde bir gradyanı olan bir piksele bir yol olmadıkça sıfıra ayarlanır [89-90].

Literatürde yaygın kullanılan kenar bulma algoritmaları Sobel, Prewit ve Canny algoritmaları önerilen yöntem için yüksek performans sağlaması açısından değerlendirilmiş ve sonuçları “Bulgular ve İrdeleme” başlığı altında verilmiştir. Önerilen yöntemde Canny algoritması ile elde edilen kenar görüntülerinde sistemin performansı artmıştır.

Adım 3. Kenar görüntüsünün Hilbert uzayına dönüşümü yapılır. (Hilbert uzayının ayrıntıları 2.1.2’de verilmiştir)

Adım 4. Görüntüye 8x8’lik bloklar halinde DCT uygulandıktan sonra (7) ile dört yönlü katsayı fark matrisleri hesaplanır ( $F_h, F_v, F_{mad}, F_{mid}$ ). Bundan sonraki adımlar her bir fark matrisi için uygulanacaktır.

Adım 5. Mevcut katsayı fark matrisinden (10)’deki ifadede  $d=1, \mathbf{P}=0^0, 45^0, 90^0, 135^0$  parametreleri ile dört yönlü GLCM üretilir.

Adım 6. GLCM’lerin her bir yönlendirmeye sahip matris üzerinden ortalama varyans değerlerinin standart sapması hesaplanır ve bu elde edilen ilk özelliği oluşturur ( $V=[1 \times 1]$ ).


Adım 7. GLCM’lerin her bir yönlendirmeye sahip matris üzerinden entropi değeri (13) ifadesi ile hesaplanır. Bu ifadede  $G(x, y)$  GLCM’nin  $(x, y)$ . elemanını,  $N_g$  gri seviye

sayısını göstermektedir. Önerilen yöntemde  $N_g = 8$  seçilmiştir. Bu adım sonunda görüntüden ikinci öznelik vektörü elde edilmiş olur ( $E=[1 \times 4]$ ).

$$E = \sum_{x=1}^{N_g} \sum_{y=1}^{N_g} p(x, y) \log(G(x, y)) \quad (13)$$

Adım 8. Sekiz gri seviyeli GLCM'nin her bir yönlendirmeye sahip matris üzerinden LBP histogramı hesaplanır ( $L=[1 \times 32]$ ).

Doku tanımlamada etkin olarak kullanılan yerel ikili örüntü 2002 yılında Ojala tarafından önerilmiştir [91]. Yerel ikili örüntü görüntüdeki piksel komşulukları bazındaki dokusal farklılıkları yakalayabilmesi nedeniyle, görüntüden dokusal öznelik çıkaran birçok çalışmada kullanılmıştır [92-95]. LBP operatörü bir pikseli etrafındaki komşu piksellerle birlikte değerlendirerek ikili bir öznelik çıkarır. Ekleme/birleştirme sahteciliği ile oluşturulan sahte görüntüde yapıştırılan kısım görüntünün orijinal dokusunu bozar ve LBP operatörünün bu farklılığı karakterize edebileceği düşünülmektedir. Şekil 2.14'te LBP operatörü ile örnek bir öznelik bulma gösterilmiştir.



Şekil 2.14. LBP operatörünün işleyişi

LBP operatörü görüntüyü 3x3'lük bloklara bölerek bu bloğun merkezindeki piksel ile komşu piksellerini eşikler ve böylece 8 ikili bir kod oluşturur. Bu kod 10'luk sisteme dönüştürülerek LBP kod elde edilmiş olur.

Adım 9. Yukarıdaki adımlarda elde edilen V, E, L öznelikleri birleştirilerek mevcut fark matrisinden elde edilen öznelik vektörü oluşturulur. Tüm fark matrisleri için (5-8)

adımları tekrarlanarak seçilen renk kanalı için öznitelik vektörü oluşturulur. Tüm fark matrislerinden öznitelikler çıkarıldıktan sonra adım 10'a geçilir

Adım 10. Her bir renk kanalı için adım 2 -8 uygulanır.

Adım 11. Renk kanallarından elde edilen tüm öznitelik vektörleri birleştirilerek giriş görüntüsü için öznitelik vektörü elde edilir.

Adım 12. Elde edilen öznitelik vektörleri ile görüntüler bir sınıflayıcı yardımıyla sınıflandırılır.

Bu bölümde görüntü birleştirme sahteciliği tespiti için doku tabanlı önerilen yöntemin ayrıntıları verilmiştir. Yöntemin literatürdeki veri setleri üzerindeki performans değerlendirmesi "Bulgular ve İrdeleme" kısmında verilecektir

## **2.4. Görüntüdeki Dokusal ve İstatistiksel Bozulmaların Hibrit Bir Yaklaşımla Değerlendirilmesi**

Görüntü sahteciliğinin tespiti için tez kapsamında yapılan çalışmalarda bir diğer önerilen yöntem, görüntüden elde edilen dokusal ve istatistiksel öznitelikleri birlikte kullanan, hibrit bir yaklaşım sunmaktadır. Aşağıda önerilen yöntemin detayları verilecektir.


### **2.4.1. SWT Domende Durum Geçiş Modeli ve GLCM Tabanlı Dokusal Özniteliklerin Hibrit Kullanımı ile Birleştirme Sahteciliği Tespiti**

Görüntü birleştirme sahteciliği ile oluşturulan eklemli bir görüntüdeki istatistiksel özniteliklerin ve dokusal yapının birlikte bozulacağı düşüncesi ile görüntü üzerinde daha önce çalışılan bu iki bozulmanın hibrit bir yaklaşımla değerlendirilmesi hedeflenmiştir. Literatürdeki yöntemler görüntüyü doğrulamak için dokusal ve istatistiksel öznitelikleri ayrı ayrı değerlendirmiştir ve elde edilen görüntü doğrulama oranları genel olarak % 98'in altındadır. Ayrıca bazı çalışmalarda bu doğruluk oranını elde etmek için öznitelik seçme algoritmalarının kullanılması gibi ekstra bir sürece ihtiyaç duyulmuştur. Eklemli bölgeden kaynaklanan bozulmaları literatürde ilk kez hibrit olarak değerlendiren yöntem [59], öznitelik seçme algoritmasının kullanılmasına ihtiyaç duymadan sahte ve orijinal görüntüleri sınıflandırmada yüksek doğruluk oranı sunmaktadır.

Önerilen yöntemde görüntüyü frekans domenine taşımak için dalgacık dönüşümü kullanılmıştır. Görüntü işleme alanında dalgacık dönüşümü olarak DWT yaygın olarak kullanılmaktadır. DWT görüntüyü, alt bantlara ayırırken görüntü boyutunu da indirgediğinden dolayı bazı ayrıntılar kaybolabilir. SWT'nin ayrıştırdığı alt bant görüntülerinde boyut indirgemesi olmamaktadır. Görüntüdeki ayrıntıları daha iyi yakalayabileceğim düşüncesi ile yapılan çalışmada SWT kullanılması tercih edilmiştir. Yöntem ayrıca farklı frekans domenlerinin de sistem performansına etkisinin incelenebilmesi için DWT, LWT, SWT ve Hilbert dönüşüm uzaylarında değerlendirilmiştir. Görüntünün dokusal öznitelikleri için Haralic'in önerdiği [64] gri seviyeli eş oluşum matrisleri üzerinden elde edilen dokusal öznitelikler kullanılmıştır. İstatistiksel öznitelikler için de Markov modeli üzerinden elde edilen durum geçiş modeli kullanılmıştır. Elde edilen hibrit öznitelik vektörü ile görüntüler sahte ve orijinal olarak sınıflandırılmıştır. Önerilen yöntem kopyala-taşı, yapıştırma ve deforme etme gibi farklı sahtecilik saldırılarına karşı dayanıklılık göstermektedir. Yöntemde kullanılan kullanılan SWT'ye ilişkin detaylar 1.4.1'de, İstatistiksel öznitelikler için kullanılan Markov tabanlı öznitelik çıkarma işleminin ayrıntıları 2.2.1'de ve dokusal özniteliklerin elde edilmesinde kullanılan GLCM'ye ilişkin detaylar 2.3.1'de verilmiştir.

Görüntü birleştirme sahteciliğini tespit için önerilen yöntemde bir giriş görüntüsü alınır ve seçilen renk uzayına dönüşümü yapılır. Mevcut test görüntüsü için daha fazla ayrıntı elde etmek amacıyla renk kanallarına birinci seviye SWT uygulanır. SWT'den elde edilen yüksek frekanslı her bir alt-bant için yatay ( $F_h$ ), düşey ( $F_v$ ), ana diyagonal ( $F_{mad}$ ) ve minör diyagonal ( $F_{mid}$ ) ile gösterilen dört fark matrisi oluşturulmuştur. Bu fark matrisleri üzerinden elde edilen GLCM matrisleri dört yönde hesaplanmıştır. Yine aynı fark matrisleri, eşikleme işleminden sonra elde edilecek olan geçiş olasılık matrislerinin oluşturulmasında da kullanılmaktadır. Elde edilen geçiş olasılık matrisleri önerilen yöntemin istatistiksel özelliğini yansıtır. Markov tabanlı istatistiksel özniteliklerin elde edilmesinden sonra görüntüden dokusal öznitelikler elde edilecektir. Her bir GLCM matrisi için beş Haralic dokusal özelliği elde edilecektir (her bir alt kanal için dört yön kullanılarak dört GLCM matrisi oluşturulmuştur). Dört yönlü GLCM matrisinden elde edilen her bir Haralic özelliği için standart sapma ve ortalama değerler hesaplanmıştır. Sonuç olarak, her bir fark matrisi için beş Haralic özelliği için beş standart sapma ve ortalama değer çiftlerinden oluşan  $1 \times 10$  büyüklüğünde bir vektör oluşturulacaktır. Böylece, mevcut alt banttaki  $1 \times 40$  boyutundaki dokusal öznitelik vektörü elde edilecektir.

Daha sonra mevcut test görüntüsünü temsil etmek için dokusal ve istatistiksel öznitelikler birleştirilecektir. Hibrit yaklaşımlı önerilen yöntemin akış şeması Şekil 2.15'te verilmiştir.



Şekil 2.15. Önerilen yöntem-4'ün [58] akış şeması

Yukarıda detayları verilen yöntem aşağıda adımlar şeklinde verilmiştir.

Adım 1: Görüntünün YCbCr renk uzayına dönüşümü yapılarak renk kanalları (Cb ve Cr) seçilir.

Adım 2: Seçilen kanal görüntüsüne 1.seviye SWT uygulanarak görüntünün yüksek frekanslı bileşenleri seçilir ve bundan sonraki adımlar bu bileşenler üzerinde uygulanır.

Adım 3: Seçilen alt banttan ( $F$ ), yatay ( $F_h$ ), dikey ( $F_v$ ), köşegen ( $F_{mad}$ ) ve ters köşegen ( $F_{mid}$ ) katsayı fark matrisleri elde edilir (7).

Adım 4: Belirlenen bir eşik değerine göre (T), katsayı fark matrisindeki değerler (8)'deki ifadenin kullanımı ile kuantalanır. Çalışmada kullanılan T eşik değeri deneysel olarak belirlenmiştir.

Adım 5: Yuvarlama ve eşik işlemi sonrasında, katsayı fark matrisinin elemanları Markov durumları olarak değerlendirilir ve bu durumlardan GOM'ler üretilir. Yatay ( $P_{hh}$ ,  $P_{vh}$ ), Dikey ( $P_{hv}$ ,  $P_{vv}$ ) ve Köşegenel ( $P_{mad}$ ,  $P_{mid}$ ) GOM'ler (9)'de verilen ifade ile hesaplanır.

GOM'nin tüm elemanları birinci öznitelik vektörünü olarak görüntü birleştirme sahteciliğini tespit etmek için öznitelik olarak kullanılır. Elde edilen öznitelik vektörünün boyutu seçilen T eşik değerine bağlı olarak  $(2T + 1) \times (2T + 1) \times 6$  olmaktadır.

Adım 6: Adım 3'te elde edilen fark matrislerinden dört yönde ( $0^0$ ,  $45^0$ ,  $90^0$ ,  $135^0$  'lik açılarla) GLCM'ler elde edilir.

Adım 7: Her bir fark matrisinden elde edilen dört yönlü GLCM'den Haralic'in sunduğu 5 dokusal öznitelik (14-18)'de verilen ifadelerle çıkarılarak, öznitelik vektörünün boyutunu azaltmak için dört yönde elde edilen bu özniteliklerin ortalama değeri ve standart sapması öznitelik olarak alınır.

GLCM üzerinden elde edilen dokusal öznitelikler ilk olarak Haralic tarafından 1973 yılında kullanılmıştır [81]. Haralic, GLCM'lerden açısız ikinci moment, kontrast, korelasyon, varyans, ters fark momenti, toplam ortalama, toplam entropi, entropi, fark varyansı, fark entropisi, korelasyonun bilgi ölçüleri ve maksimum korelasyon katsayısı olmak üzere 14 tane dokusal öznitelik önermiştir. Daha sonra bu özniteliklerden hangilerinin görüntüyü daha iyi temsil ettiğini bulmak için bir çok çalışma yapılmıştır [20,96,97]. Bu çalışmalardan yola çıkılarak önerilen yöntemde Haralic özniteliklerinden aşağıda detayları verilen 5 tanesi kullanılmıştır ( $H_1 \dots H_5$ ).

- Enerji: Açısız ikinci moment ve tek düzelik diye adlandırılan bu parametre GLCM'deki elemanların karesel toplamıdır. Görüntü ne kadar homojen ise enerji değeri o kadar büyük olacaktır.

$$H_1 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} G^2(i, j) \quad (14)$$

- Kontrast: Kontrast bir görüntünün yerel varyansının ölçüsüdür.

$$H_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{\substack{j=1 \\ |i-j|=n}}^{N_g} G(i,j) \right\} \quad (15)$$

- Korelasyon: GLCM'deki gri seviye değerlerin lineer bağımlılığını hesaplar, referans pikselin komşularıyla nasıl bağlı olduğu hakkında bir fikir verir.

$$H_3 = \frac{\sum_i \sum_j (i,j) G(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y}, \quad (16)$$

$\mu_x, \mu_y$  ortalama,  $\sigma_x \sigma_y$  standart sapma değeridir.

- Homojenlik: GLCM'deki elemanların GLCM diyagonaline olan dağılımının yakınlığını ölçer. Ters fark momenti olarak da adlandırılır.

$$H_4 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{|i-j|^2} G(i,j), \quad (17)$$

$G(i,j)$  GLCM'deki  $(i,j)$ . eleman,  $N_g$  gri seviye sayısıdır.

- Entropi: Bir görüntünün karmaşıklığı ve düzensizliğinin ölçüsüdür.

$$H_5 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j) \log(G(i,j)) \quad (18)$$

Adım 8: Elde edilen birinci (Adım 5) ve ikinci (Adım 7) öznitelik vektörleri mevcut alt banttandır elde edilen öznitelik vektörünün temsili için birleştirilir.

Adım 9: Her bir alt bant için Adım 3- Adım 8 tekrarlanarak öznitelikler elde edilir.

Adım 10: Üç alt banttandır gelen öznitelik vektörleri toplam özellik vektörünü elde etmek için birleştirilir.

Adım 11: Elde edilen öznitelik vektörleri ile görüntüler bir sınıflayıcı yardımıyla sınıflandırılır.



Yukarıda istatistiksel ve dokusal öznitelikleri birlikte kullanarak sahtecilik tespiti için önerilen yöntemin ayrıntıları verilmiştir. Önerilen yöntem ile ilgili deneysel sonuçlar “Bulgular ve İrdeleme” kısmında verilecektir


## **2.5. Görüntüleri Sınıflandırmada Farklı Sınıflandırıcıların Performans Değerlendirmesi**

Görüntüyü en iyi temsil edecek öznitelik vektörlerinin elde edilmesinden sonra, sahte ve orijinal görüntüleri birbirinden ayırt edebilmek için, bu özniteliklerin sınırlarını birbirinden ayırt edebilecek sınıflandırıcılara ihtiyaç duyulmaktadır. Tez kapsamında birleştirilmiş eklemli görüntüleri ve orijinal görüntüleri birbirinden ayırt edebilme-sınıflandırma problemi üzerinde durulmuştur. Görüntüler sahte ve orijinal olarak iki sınıfa ayrılmaktadır, yani sınıflandırma problemi iki sınıflı bir problem halini almıştır. Destek vektör makineleri ikili sınıflandırma için literatürde yaygın olarak tercih edilmiş bir sınıflandırıcıdır. Birleştirme sahteciliğinin tespiti için önerilen yöntemlerin literatürdeki yöntemlerle kıyaslamasının aynı ortamda gerçekleştirilebilmesi için performans değerlendirmesi SVM ile yapılmıştır. Sınıflandırma problemlerinde bir sınıflandırıcının tüm problemler için en iyi sınıflandırıcı olduğu söylenemez. Farklı problemler farklı sınıflandırıcılarda daha yüksek performans gösterebilir. Bunun için yapılan çalışmalarda ikinci bir sınıflandırıcı performansına da başvurulmuştur. Bu kapsamda KNN de performans değerlendirmesi açısından test edilmiştir. Bu bölümde kullanılan sınıflandırıcıların ayrıntıları verilecektir.

### **2.5.1. Destek Vektör Makineleri (SVM)**

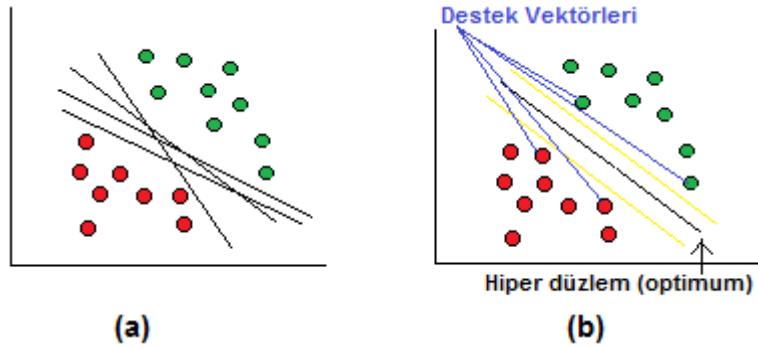
İlk olarak Vapnik vd. tarafından geliştirilen destek vektör makineleri [98] farklı sınıf üyeliğine sahip nesnelere birbirinden ayıran karar düzlemi kavramına dayanır. Başka bir deyişle SVM lineer bir fonksiyon uzayı hipotezini yüksek boyutlu bir öznitelik uzayında kullanan ve optimizasyon teorisinden gelen bir öğrenme algoritması ile eğitilen sistemler olarak tanımlanabilir [99]. Şekil 2.16’da şematik bir örnek gösterilmektedir. Bu örnekte nesnelere ya Yeşil ya da Kırmızı sınıfa aittir ve doğrusal bir düzlemlerle birbirinden ayrılabilir. Ayırma çizgisi, sağdaki tüm nesnelere Yeşil ve solundaki tüm

nesnelerin Kırmızı olduğu bir sınırı tanımlar. Sağa düşen her yeni nesne (Yeşil daire) Yeşil olarak, ayırma çizgisinin soluna düşerse Kırmızı olarak sınıflandırılmıştır.



Şekil 2.16. Doğrusal ayrılan veriler için SVM ile karar düzlem seçimi

Şekil 2.17 (a)'daki gibi doğrusal ayrılabilen düzlemlerde iki bölgeyi birbirinden ayıran birçok sayıda doğru çizilebilir. Buradaki amaç çizilebilecek sınır doğruları arasında en büyük marjine sahip olanı belirlemektir. Marjin, ayırma düzleminin iki tarafında en yakın örneklere paralel geçen ayırma düzlemine olan dik uzaklıktır [99]. Şekil 2.17 (b)'de görüleceği üzere sınırı maksimuma çıkararak en uygun ayrımı yapan hiper düzleme optimum hiper düzlem, sınıf genişliğini sınırlandıran noktalar ise destek vektörleri olarak adlandırılır [100].



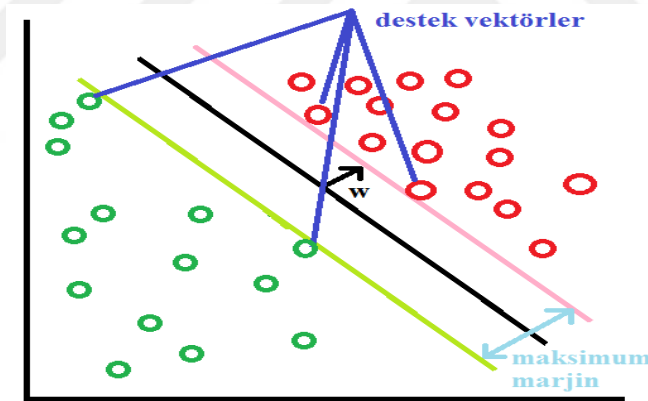
Şekil 2.17. İki sınıflı bir problem için (a) Hiper düzlemler (b) Optimum hiper düzlem ve destek vektörleri [100].

SVM ile sınıflandırmada iki senaryo mevcuttur. Birincisi eğitim verilerinin doğrusal olarak birbirinden ayrıldığı, ikincisi verilerin doğrusal olarak birbirinden ayrılamadığı senaryodur.

İki sınıflı, doğrusal olarak ayrılabilen sınıflandırma senaryosunda, n sayıda örnekten oluşan eğitim verisi olsun. Bu durumda optimum hiper düzlem için (19) eşitsizliği ile verilen senaryo söz konusu olacaktır.

$$y_i(wx_i + b) \geq 1, i = 1, 2 \dots n \quad (19)$$

Verilen ifadede x, M-boyutlu bir uzayı, y sınıf etiketini (+1 veya -1), w hiper düzlemin normalini göstermektedir. Şekil 2.18’de görüleceği üzere, hiper düzlemin merkez noktasına en yakın noktanın mesafesi x’in hiper düzlemde olduğu gibi maksimize edilmesiyle bulunabilir. Benzer durum diğer yan durumlar için de geçerlidir. Böylece bu iki mesafeyi çözerek ayırma düzlemine en yakın noktalara kadar olan toplam mesafeyi elde ederiz. Bu durumda maksimum marjın  $2/|w|$  uzunluğundadır. Böylelikle w ve b değeri ile çözmemiz gereken ikinci dereceden bir optimizasyon problemi elde edilmektedir.



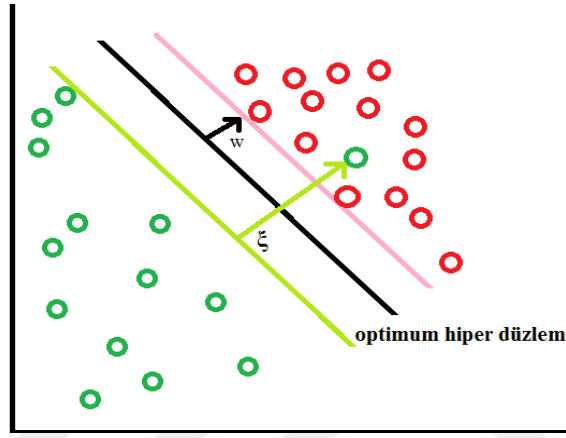
Şekil 2.18. Hiper düzlemlerin gösterimi [101].

Bunu çözmek için fonksiyonu doğrusal kısıtlamalarla optimize etmek gerekir. Çözüm Lagrange’in  $\alpha_i$  çarpanının ilişkili olduğu denklemi içerir. Bütün  $\{x_i, y_i\}$  ‘ler için (19) ile verilen ifade geçerlidir. Yukarıda bahsedilen problemin çözümü (20) ifadesinin yardımı ile sonuç karar fonksiyonu (21) ile verilen şeklini alır [100].

$$w = \sum \alpha_i * x_i; b = y_k - w * x_k, \alpha_k \neq 0 \quad (20)$$

$$F(x) = \sum \alpha_i y_i x_i * x + b \quad (21)$$

SVM ile sınıflandırmada ikinci senaryo eğitim verilerinin doğrusal olarak birbirinden ayrılamadığı durumdur. Günümüzde gerçek uygulamaların büyük çoğunluğunda veriler Şekil 2.19’da gösterildiği gibi birbirinden doğrusal olarak ayrılamaz. Bu senaryoda kernel (çekirdek) fonksiyonları kullanılarak veri yüksek boyutlu başka bir uzaya taşınır ve bu uzayda doğrusal hiper düzlem aranır. Şekil 2.19’da görüleceği üzere hiper düzlemin üst tarafında kalan eğitim verileri vardır. Bu durumun çözülmesi için pozitif bir yatay değişken ( $\xi$ ) eklenir (22) [100-102].



Şekil 2.19. Doğrusal olarak ayrılamayan veriler ve hiper düzlemin belirlenmesi

$$\min\left(\frac{1}{2} \|w\|^2 + c \sum_{i=1}^r \xi_i\right) \quad (22)$$

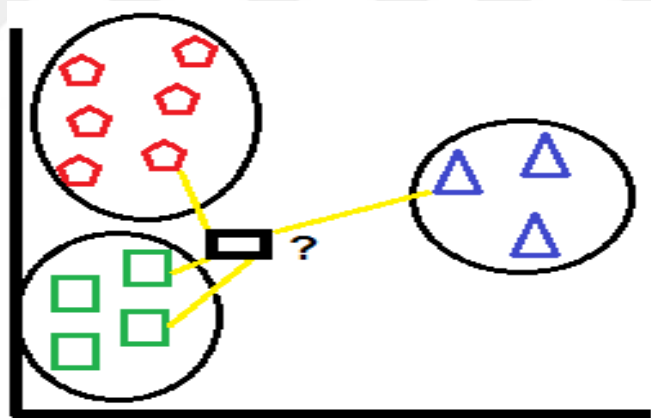
Verilen ifadeye düzenleme parametresi  $c$ 'nin değiştirilmesinin sınıflandırıcı performansı üzerindeki etkisi gözlemlenerek belirlenebilir[99-100].

SVM uygun kernel fonksiyonu seçimi ile doğrusal olmayan dönüşümler yaparak verilerin yüksek boyutta lineer olarak ayrılabilmesini sağlar. Kernel fonksiyonu kullanılarak iki sınıflı ve doğrusal olarak ayrılamayan problemin çözümü (23) ile verilmiştir[100-101].

$$f(x) = \text{sign}\left(\sum \alpha_i y_i \varphi(x) \cdot \varphi(x_i) + b\right) \quad (23)$$

### 2.5.2. K-En Yakın Komşu Sınıflandırması (KNN)

k-en yakın komşu kümelemesi (k-nearest neighbour KNN) algoritması eğitilmiş bir öğrenme algoritmasıdır. Şekil 2.20’de görüleceği gibi, eğitim verileri sınıflara ayrıldıktan sonra sisteme gelen veri kendisine en yakın k-komşuluğuna bakılarak hangi sınıfa dahil olacağına karar verilir. En yakın komşu uzaklıkları Öklid, Manhattan veya Minkowski uzaklığı gibi bir mesafe ölçüsü ile hesaplanabilmektedir. Sınıflandırmada seçilecek “k” (komşu sayısı), sınıflandırıcının performansına etki edecektir. “k” değerinin çok küçük seçilmesi yanlış sınıflandırma oranının artmasına neden olabileceği gibi, çok büyük seçilmesi de gereksiz hesaplama karmaşıklığına yol açabilmektedir. Yapılan çalışmada en yakın komşu uzaklığı olarak öklid uzaklığı kullanılmış, komşu sayısı “k” değeri de 1 ve 15 komşuya kadar olan bütün değerlendirmeler yapılarak sınıflandırma doğruluk oranına göre en uygun “k” değeri belirlenmiştir. “Bulgular ve İrdeleme” bölümünde “k” değerinin değerlendirilmesi ayrıca verilecektir.



Şekil 2.20. KNN algoritması ile yeni gelen örneğin sınıfının belirlenmesi

### 3. BULGULAR VE İRDELEME

Bu bölümde görüntü birleştirme sahteciliği kapsamında yapılan çalışmalara ait bulguların literatürde var olan çalışmalara ait sonuçlarla kıyaslaması gerçekleştirilecek ve önerilen yöntemlerin avantaj ve dezavantajları irdelenecektir. Önerilen yöntemlerin performans değerlendirilmesinin öncesinde kullanılan veri setleri ve yapılan çalışmaların performansını değerlendirmek için kullanılan ölçütler verilecektir.

#### 3.1. Veri Setleri

Bu bölümde, görüntü birleştirme sahteciliği alanında yapılan çalışmalarda yaygın olarak kullanılan ve halka açık olan üç farklı veri seti CASIA ITDE veri seti (v1.0 ve v2.0) [103] ve Columbia ISDE [104] incelenmiştir.


CASIA ITDE veri seti: CASIA görüntü kurcalama tespit veri seti diye adlandırılan bu veri seti, Adobe Photoshop CS3 versiyon 10.0.1 kullanılarak oluşturulmuştur. Veri seti tamamen renkli görüntülerden oluşmaktadır. CASIA v1.0 1725 renkli görüntüden oluşmaktadır, CASIA v2.0 ise 12323 görüntüden oluşan daha kapsamlı bir veri setidir. CASIA v1.0 sahte görüntü olarak JPG biçiminde 384x256 ve 256x384 piksel boyutlarında sadece birleştirilmiş eklemli sahte görüntülerden oluşmaktadır. CASIA v1.0 ile CASIA v2.0 karşılaştırıldığında CASIA v2.0'da daha kapsamlı değiştirilmiş sahte görüntülerin varlığı dikkat çeker.

CASIA IDTE v1.0 veri setinde 800 orijinal 921 sahte görüntü mevcuttur ve bu görüntüler sahte-kurcalanmış ve orijinal-doğrulanmış olarak adlandırılmıştır. Doğrulanmış gruptaki görüntüler kabaca sahne, hayvan, mimari, karakter, bitki, sanat, doğa ve doku olmak üzere 8 kategoriye sahiptir. Kurcalanmış sahte görüntüler de bu orijinal görüntülere Adobe Photoshop ile sadece kırpma ve yapıştırma işlemleri uygulanarak elde edilmiştir. Eklenen bölgeler aynı görüntüden veya iki farklı görüntüden alınmıştır. Aslında aynı görüntüden kopyala-yapıştır ile eklenen görüntülere kopyala-taşı sahteciliği ile elde edilen görüntüler denmesine rağmen bu veri setinde iki tür görüntüde eklemli-birleştirilmiş görüntü kategorisinde değerlendirilmiştir.

CASIA IDTE v2.0 veri setinin yapısı v2.0 ile benzerdir. 7200 tane orijinal görüntünün yanında 5123 değiştirilmiş sahte görüntü içermektedir. Bu veri seti v2.0'a göre daha zorlu ve kapsamlıdır. Sahte görüntü elde ederken birleştirmenin yanı sıra bulanıklaştırma da uygulanmıştır. V1.0'dan farklı olarak 320x240 ile 800x600 arasında değişen farklı boyutlarda görüntüler mevcuttur. V1.0 sadece JPEG formatlarında görüntü içerirken v2.0 BMP ve TIFF gibi sıkıştırılmamış görüntüler de içermektedir. Orijinal görüntü kümesinde sahne, hayvan, mimari, karakter, bitki, makale, doğa, iç mekan ve doku olmak üzere sınıflandırılan 9 kategori vardır. Her iki veri setinde yapıştırılan bölgelerde ölçekleme, döndürme veya diğer bozma işlemleri yapıştırılan bölgeye uygulanmaktadır.

Columbia Görüntü Ekleme Algılama Değerlendirme Veri seti: Columbia görüntü veri seti iki bölümden oluşur; birinci bölüm, 128 x 128 piksel boyutunda 933 orijinal ve 912 eklenmiş gri görüntü veri kümesidir. Diğer bölüm, 183 orijinal ve 180 birleştirilmiş renkli görüntüden oluşan Sıkıştırılmamış Görüntü Ekleme Algılama Değerlendirme Veri Kümesi olarak adlandırılan veri setidir.  $757 \times 568$  -  $1152 \times 768$  arasında değişen boyutlara sahip renkli görüntü blokları ve tümü TIFF veya BMP formatında sıkıştırılmamış resimlerdir. Columbia veri seti yalnızca basit kurcalanmış görüntü blokları içerir ve yeterli sayıda renkli görüntü örneklerine sahip değildir.

Şekil 3.1-3.3'te bu üç veri setinden örnek görüntüler verilmiştir. İlk satırdaki görüntüler orijinal, ikinci satırdaki görüntüler sahte görüntülerdir.



Şekil 3.1. CASIA v1.0 veri setinden örnek görüntüler



Şekil 3.2. CASIA v2.0 veri setinden örnek görüntüler



Şekil 3.3. Columbia Üniversitesi veri setinden örnek görüntüler

### 3.2. Kullanılan Ölçütler

Yapılan çalışmalarda orijinal görüntüler “1” sahte görüntüler “0” ile etiketlenmektedir. Böylece sınıflandırma ikili sınıflandırma halini alır. Destek vektör makinaları ikili sınıflandırma için kullanılmıştır. Literatürdeki yöntemlerle performans kıyaslaması yapılacağından, sistemin eşit şartlarda değerlendirilmiş olması için yaygın olarak kullanılan sınıflandırıcılardan SVM’nin kullanılması tercih edilmiştir. Yöntem performansı ayrıca KNN ile de değerlendirilmiş olup, sonuçlar “Bulgular ve İrdeleme” bölümünde verilmiştir.

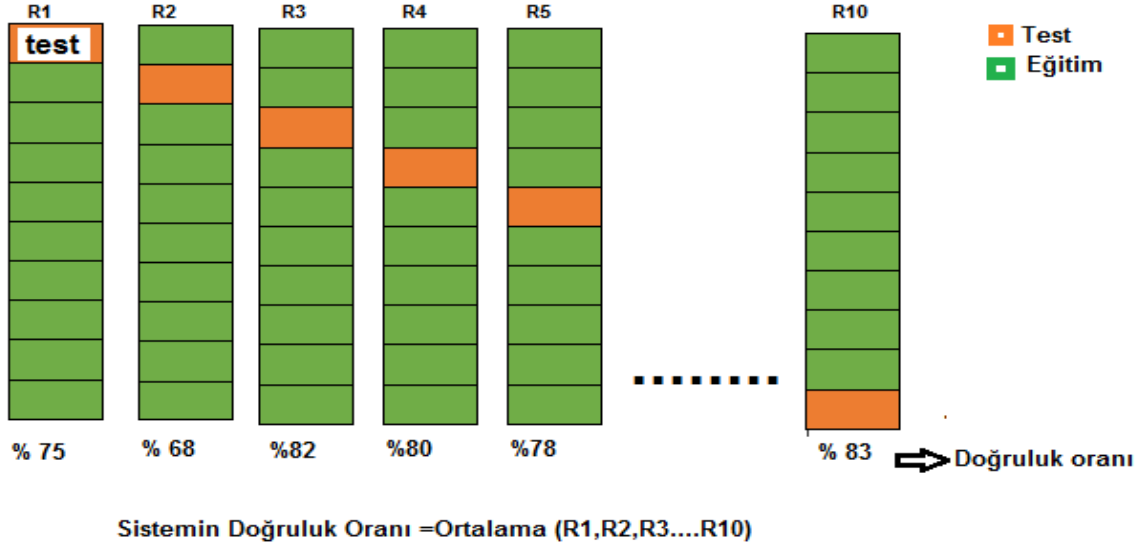


Sınıflandırıcı performansı verilirken çeşitli yaklaşımlar mevcuttur. Bunlardan yaygın olarak kullanılanlar K-katlı Çapraz Doğrulama (K-fold cross-validation), Rastgele Alt Örnekleme Çapraz Doğrulama (random subsampling cross validation) ve Birini Dışarda Bırakarak Çapraz Doğrulama (leave one out cross validation)'dır. K-katlı çapraz doğrulamada veri seti K adet alt parçaya bölünür. Bu parçalardan K-1 tanesi eğitimde 1 tanesi test aşamasında kullanılır ve bu döngüde en uygun sınıflandırıcı parametresi aranır. Bu parametre KNN için komşuluk sayısı, SVM için ayırıcı düzlemin rbf çekirdeğindeki sigma parametresidir. Her bir kat 1 kere test aşamasında kullanılana kadar döngü devam eder. Yöntemin avantajı verinin nasıl bölündüğünün fazla önemli olmamasıdır çünkü her bir veri tam olarak bir kez test ve K-1 kez eğitim setine girer. Yöntemin dezavantajı ise eğitim algoritmasının her seferinde sıfırdan K kere tekrarlama, K kat daha fazla işlem yapmasıdır.

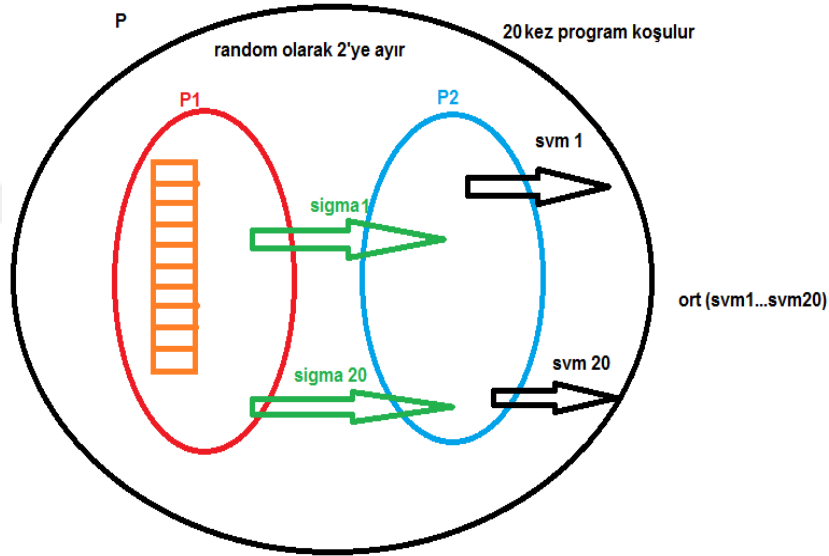
“Rastgele Alt Örnekleme Çapraz Doğrulama” prosedüründe veri seti random olarak istenilen büyüklükte iki parçaya ayrılır. Bunlardan biri ile sınıflandırıcı eğitilirken diğeri ile test gerçekleştirilir.

“Birini Dışarda Bırak Çapraz Doğrulama” yaklaşımında veri setindeki bir örnek dışındaki veriler eğitim, 1 örnek ise test için kullanılır. N boyutlu bir veri seti için sınıflandırma işlemi N kez tekrarlanır. Veri seti boyutu büyük olan verilerde bu çaprazlama yöntemini kullanmak, tekrarlama sayısının yüksekliğinden dolayı dezavantaj sağlayacaktır. Veri sayısının az olduğu durumlarda kullanımı tercih edilebilir.

Tez kapsamında çalışılan veri setlerinde değerlendirilecek görüntü sayısı yüksek olduğundan birini dışarda bırak çapraz doğrulama yöntemi tercih edilmemiştir. K-katlı Çapraz Doğrulamada K değeri 10 olarak seçilmiş ve Şekil 3.4'te gösterilen 10 katlı çapraz doğrulama şeması gerçekleştirilmiştir. Rastgele Alt Örnekleme Çapraz Doğrulama yönteminde ise veri seti Şekil 3.5'te görüleceği gibi rastgele 2 parçaya bölünmüştür. Bu parçalardan biri ile (Şekil 3.5'teki P1) 10 katlı çapraz doğrulama kullanılarak sınıflandırıcı için optimum parametreler elde edilmiştir ve en başta ayrılan ve eğitim sürecine hiç katılmamış olan ikinci kısım (P2) bu parametreler ile sınıflandırılmıştır. Program N sayıda koşulduktan sonra ortalama doğruluk oranı ile sistemin test doğruluk oranı elde edilmiştir.



Şekil 3.4. 10 katlı çapraz doğrulama şeması



Şekil 3.5. Rastgele alt örnekleme çapraz doğrulama şeması

Görüntü birleştirme sahteciliği tespiti için önerilen yöntemlerin başarısını değerlendirebilmek için literatürde var olan yöntemlerin performans değerlendirmesinde kullandıkları doğruluk (accuracy), hassaslık-duyarlılık (sensitivity-TPR) ve özgüllük (specificity-TNR) ölçütleri kullanılmıştır. Doğruluk oranı sisteme verilen sahte ve orijinal görüntülerden doğru olarak sınıflandırma oranını verir. Hassaslık sistemin orijinal görüntüleri hangi oranda tespit ettiğini, özgüllük ise sahte görüntülerin hangi oranda tespit edildiği bilgisi için kullanılmıştır.

$$\text{Hassaslık (TPR)} = \frac{TP}{TP+FN},$$

$$\text{Özgüllük (TNR)} = \frac{TN}{TN+FP},$$

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (24)$$

Verilen ifadede TP (True Positive) doğrulanmış görüntülerin doğru sınıflandırma oranını, TN (True Negative) sahte görüntülerin doğru sınıflandırma oranını, FP (False Positive) orijinal görüntüleri yanlış sınıflandırılma oranını, FN (False Negative) sahte görüntülerin yanlış sınıflandırma oranını göstermektedir.

### 3.3. İstatistiksel Özniteliklere Dayalı Birleştirme Sahteciliğinin Tespiti ve Elde Edilen Deneysel Sonuçlar

Görüntü birleştirme sahteciliğinin tespiti için görüntüdeki istatistiksel öznitelikleri farklı domenlerde, yüksek ve düşük frekanslarda değerlendiren iki farklı yöntem önerilmiştir. 2.2.'de ayrıntıları verilen yapılan çalışmalardan biri DWT domen düşük frekanslı alt bantta dört yönlü durum geçiş modeli ile istatistiksel öznitelikler elde ederken, bir diğer yöntem DCT tabanlı yüksek frekans bölgesinde durum geçişini modelleyerek görüntü birleştirme sahteciliğini tespit etmeyi hedeflemiştir. Aşağıda önerilen yöntemlerle ilgili deneysel bulgulara yer verilecektir

#### 3.3.1. DWT Domende Markov Tabanlı Görüntü Birleştirme Sahteciliği Tespitinin Değerlendirilmesi ve Elde Edilen Deneysel Sonuçlar

Görüntü birleştirme sahteciliğinin tespiti için önerilen yöntemin akış şeması Şekil 2.12'de verilmiştir. Çalışmada öznitelik vektörü çıkarma aşamasına geçmeden önce, renk uzayına dönüşüm ve ilgili kanal seçimi yapılacaktır ve bu seçim deneysel olarak belirlenecektir. Öznitelik vektörünün oluşturulması aşamasında, görüntünün bütünü kullanmak yerine, görüntüye DWT uygulanmıştır. Elde edilen düşük frekanslı görüntü üzerinde dört yönlü durum geçişleri modellenmiştir. DWT LL bandındaki görüntüye renk uzayı dönüşümü uygulandıktan sonra seçilen kanala blok DCT uygulanmıştır. DCT

katsayıları üzerinden elde edilen fark matrislerindeki geçişler dört yönlü olarak modellenmiştir. Yapılan çalışmanın [56] temel hedefi görüntüleri yüksek doğrulukla sahte ve orijinal olarak ayırt edebilmektir. Önerilen yöntemin performans analizi en uygun alt senaryonun belirlenmesi için yapılan deneyler ve performans analizi olarak iki aşamada incelenecektir

### 3.3.1.1. Yöntemi Oluşturan En Uygun Alt Senaryonun Belirlenmesi İçin Yapılan Performans Testleri

Önerilen yöntemde en yüksek verimlilikle öznitelik vektörlerinin elde edilmesi için yöntem, farklı renk uzayında ve frekans domenlerde performans testleri yapılmıştır. Yöntem için en uygun senaryo belirlendikten sonra diğer veri setleri üzerinde ve literatürdeki benzer yöntemlerle performans analizi yapılmıştır

- Yöntemde kullanılacak olan renk uzayı ve renk kanalının belirlenmesi: Görüntü sahteciliği tespitinde, renkli görüntüler üzerinde kullanılan renk uzayı dönüşümlerinde YCbCr ve Lab uzayları kullanılmıştır. İnsan gözünün parlaklık kanallarına daha duyarlı olmasına rağmen renk kanalları görüntünün zayıf sinyal içeriğini vurguladığından, görüntü sahteciliği tespiti için daha uygundur. Görüntüde sahtecilik sonucu meydana gelen düzensizlik renk kanallarında fark edilebilir. Bu nedenle yapılan çalışmada kullanılan renk uzaylarında Cb ve Cr kanalları üzerinde işlem yapılmıştır. YCbCr uzayında Cb ve Cr, Lab uzayında ise a ve b kanalının daha iyi sonuç verdiği Tablo 3.1'de elde edilen değerlerle gözlemlenmiştir. Yöntem YCbCr dönüşümünde renk kanalları üzerine uygulandığında Cb kanalında %98.46, Cr kanalında %98.13 doğruluk oranı elde etmiştir. Sistemin performansını artırması açısından her iki kanaldan çıkarılan öznitelikler ile performans değerlendirmesi yapıldığında, %98.48 doğruluk oranı ile doğruluk oranının arttığı gözlemlenmiştir. Görüntü sahteciliğinde kullanılan bir diğer renk uzayı olan Lab uzayında da sistem test edildiğinde YCbCr uzayına göre daha iyi sonuçların elde edildiği gözlemlenmiştir. Yöntem, a kanalında %98.77, b kanalında %98.43 doğruluk oranına sahiptir. Bu iki kanaldan (a,b) elde edilen özniteliklerin birleştirilmesi ile sistem %98.93 doğruluk oranı elde etmiştir. Yapılan deneylerde önerilen yöntemin Lab uzayında kullanılmasının sistemin doğruluk oranı açısından daha iyi bir performans sergilediği gözlemlenmiştir.

Tablo 3.1. Veri setlerinde renk kanallarına göre elde edilen doğruluk oranları

RENK KANALI	ÖZNİTELİK VEKTÖR BOYUTU	DOĞRULUK ORANI %		
		CASIA v1.0	CASIA v2.0	Columbia (Renkli)
<b>CB</b>	294	98.46	99.38	91.74
<b>CR</b>	294	98.13	99.34	92.55
<b>CB,CR</b>	588	98.48	99.63	92.83
<b>A</b>	294	98.77	98.98	95.87
<b>B</b>	294	98.43	98.90	92.84
<b>A, B</b>	588	<b>98.93</b>	<b>99.77</b>	<b>97.24</b>

- Yöntemde kullanılacak olan frekans domeninin belirlenmesi: Önerilen yöntemde [56] seçilen dönüşüm domeninin etkinliğinin araştırılması için yöntem SWT, LWT ve Hilbert dönüşümlerinde de uygulanmış ve en yüksek doğruluk oranının DWT domende elde edildiği görülmüştür.

Tablo 3.2. [56] önerilen yöntemin farklı filtreler kullanılması ile CASIA v1.0 veri setinde elde ettiği doğruluk oranları

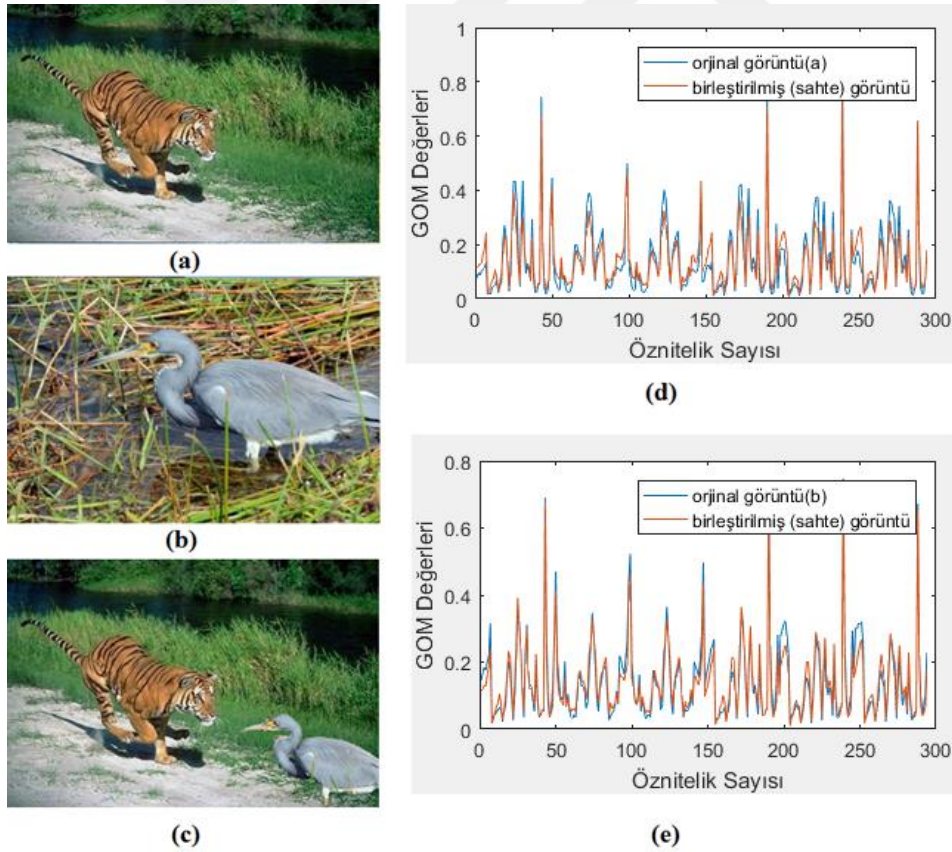
UYGULANAN ÖN İŞLEME ADIMI	KULLANILAN RENK KANALI	DOĞRULUK ORANLARI (%)
<b>SWT</b>	Cb	98.37
<b>LWT</b>	Cb	95.11
<b>HILBERT</b>	Cb	91.51
<b>DWT</b>	Cb	<b>98.46</b>

Seçilen DWT domeninin farklı alt bantlarının da sistem performansına etkisi araştırılmış ve Tablo 3.3'te görüleceği üzere en iyi algılama performansı, düşük frekanslı LL alt bandında elde edilmiştir.

Tablo 3.3. Önerilen yöntemin [56] DWT domen farklı alt bantlarda CASIA v1.0 veri setinde elde ettiği doğruluk oranları

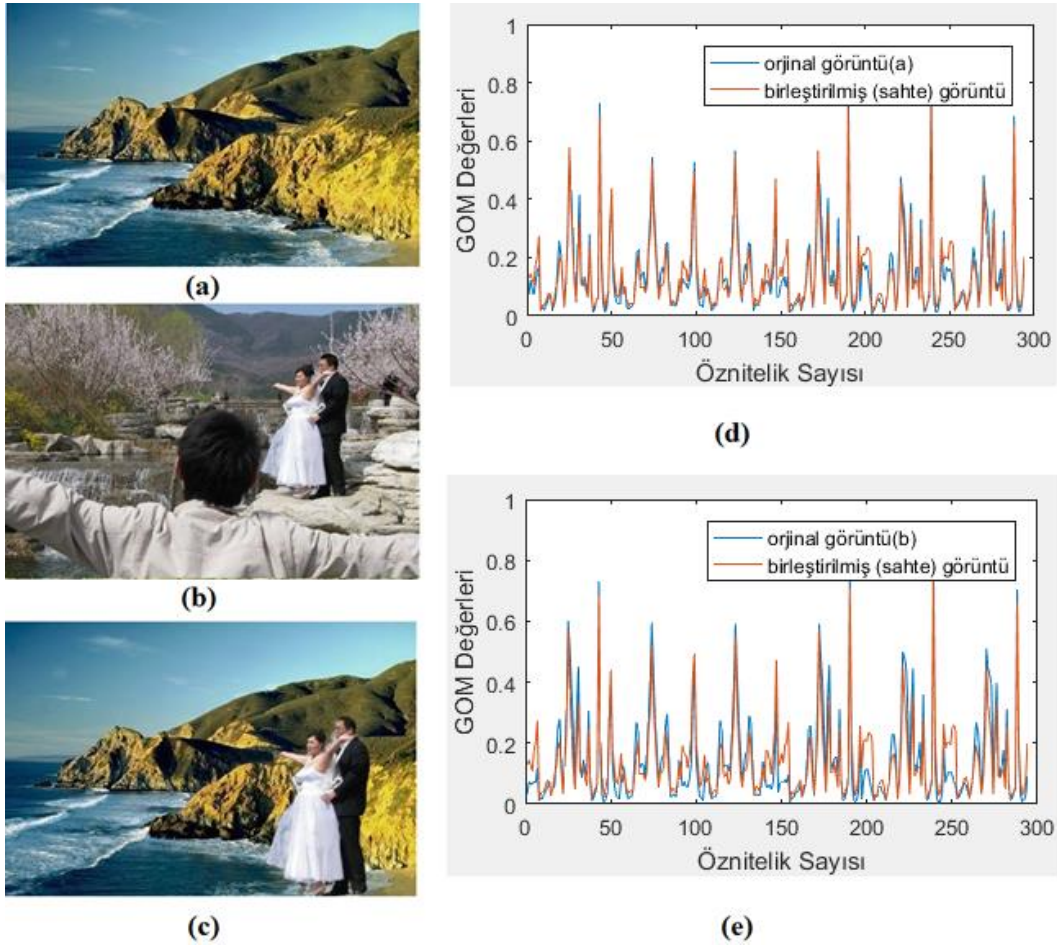
UYGULANAN ÖN İŞLEME ADIMI	KULLANILAN RENK KANALI	DOĞRULUK ORANLARI (%)
<b>DWT LL</b>	Cb	98.46
<b>DWT LH</b>	Cb	93.84
<b>DWT HL</b>	Cb	97.80
<b>DWTHH</b>	Cb	87.79

Yapılan deneylerle istatistiksel özellikleri kullanan yöntemde öznelik çıkarılacak domen DWT ve kullanılacak renk uzayı Lab olarak belirlenmiştir. Şekil 3.6'da örnek sahte ve orijinal görüntüden tek bir renk kanalının kullanımı (Cr) ile elde edilen öznelik vektörleri grafiksel olarak gösterilmiştir. Şekil 3.6 (a)'da kaplan görüntüsünün olduğu görüntüye, (b) ile verilen orijinal görüntüdeki balıkçıl kuşunun yapıştırılması ile elde edilen sahte görüntü (c) ile verilmiştir. (d)'deki grafikte (a)'daki orijinal görüntü ve (c)'deki sahte görüntünün öznelik vektörlerinin karşılaştırılması gösterilmiştir. Görüntüden elde edilen özneliklerin SVM sınıflandırıcıda kullanılması ile görüntüler sahte ve orijinal olarak sınıflandırılmakta olduğundan, elde edilen özneliklerin sahte ve orijinal görüntüde birbirinden farklılık göstermesi beklenmektedir. Grafikten (Şekil 3.6 (d)) görüleceği üzere, orijinal ve sahte görüntüden elde edilen öznelikler birbirinden farklılık göstermektedir. Aynı şekilde (b) orijinal görüntüsü ve (c) sahte görüntüsünden elde edilen özellik vektörleri de (e)'de görüldüğü üzere farklıdır.



Şekil 3.6. (a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-1 [56] ile elde edilen öznelik vektörleri, (e) b ve c görüntülerinden önerilen yöntem-1 [56] ile elde edilen öznelik vektörleri

Yine önerilen yöntemde, elde edilen öznelik vektörlerinin farklılıklarını göstermek için Şekil 3.7’de sahte ve orijinal görüntüler verilmiştir. Şekil 3.7’de mevcut doğa görüntüsü (a) üzerine, gelin ve damat görüntüsünün (b) yapıştırılması ile sahte görüntü (c) elde edilmiştir. (a) görüntüsü ve bu görüntüden elde edilen eklemli görüntü (c)’den elde edilen öznelik vektöründeki sapmalar, (d) ile verilen grafikten ayırt edici bir şekilde görülebilmektedir.



Şekil 3.7. (a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-1 [56] ile elde edilen öznelik vektörleri, (e) b ve c görüntülerinden önerilen yöntem-1 [56] ile elde edilen öznelik vektörleri

### 3.3.1.2. Önerilen Yöntemin Literatürdeki Benzer Yöntemlerle Kıyaslanması

Görüntü birleştirme sahteciliğinde yapılan bazı çalışmalarda [23,25,31,54] öznelik seçme algoritması kullanılarak sistemin performansında artış sağlanmıştır. Önerilen

yöntemde öznelik seçme algoritmasına gerek kalmadan Tablo 3.4'te görüleceği üzere, sistem performansı karşılaştırılan yöntemlerden daha yüksek doğruluk oranları elde edilmiştir. Tablo 3.4'te yöntemler tarafından test edilmemiş veri setleri “-“ ile gösterilmiştir. Önerilen yöntem CASIA v1.0 veri setinde %98.93 ile diğer yöntemlere kıyasla en yüksek doğruluk oranını elde etmiştir. CASIA v2.0 veri setinde % 99.74, Columbia veri setinde %97.24 doğruluk oranı elde edilmiştir. Önerilen yöntemle benzer bir çalışma [31]'de yapılmıştır. Zhang vd. yaptıkları bu çalışmada DWT domenin DCT'den daha iyi performans sağlayacağı düşüncesi ile direk DWT katsayıları üzerinden Markov modelini çıkarmıştır. Yöntemlerinde özneliklerini gri seviye ve R bileşeni üzerinden, görüntüye 3 seviyeli DWT uygulayarak elde ettiği 12 alt bant ve dönüşüm yapılmayan görüntüyle birlikte 13 görüntü bandından iki yönlü olarak durum geçişlerini modellemiştir. [31]'deki çalışmada eklemli bölgenin bıraktığı izler farklı renk kanallarında farklı kalıntılara neden olacağından görüntüyü sadece gri seviyede değerlendirmek yeteri kadar bilgi edinilmesinde birinci zafiyettir. Görüntüdeki geçişleri sadece yatay ve dikeyde değerlendirmesi de çalışmanın ikinci zayıflığı olarak değerlendirilebilir. Ayrıca görüntüye uygulanan 3 seviyeli DWT dönüşüm sonrası öznelik çıkarılacak görüntü boyutu  $1/16$  oranında azalacağından, eklemli bölgenin neden olduğu değişikliklerin kaçırılması olasıdır. Nitekim performans değerlendirmesi verdiği Columbi veri seti (gri)'nde %89.93 ile beklenen doğruluk performansını elde edememiştir.

Tablo 3.4. Önerilen yöntem-1'in [56] literatürdeki diğer yöntemlerle karşılaştırılması

YÖNTEM	ÖZNETELİKLER	CASIA V1.0	CASIA V2.0	COLUMBIA (R/G)
[23]	Markov (DCT+DWT)	-	89.76	-
[26]	Markov(DMWT)			93.36 (gri)
[27]	Markov (QDCT)	96.43	92.38	-
[25]	Markov(spatial+DCT)			98.82 (gri)
[30]	Markov Countourlet + DCT			94.10
[31]	Markov 3seviye DWT			89.93
[29]	Markov+Kuantalama	98.95	97.28	95.24
[32]	Markov (DCT-LF)		96.90	
<b>Önerilen Yöntem-1 [56]</b>	<b>Markov (DWT LL)</b>	<b>98.93</b>	<b>99.77</b>	<b>97.24</b>



Yapılan çalışmada görüntü birleştirme sahteciliğini tespit etmek için görüntünün düşük frekanslı bileşeni üzerinden dört yönlü istatistiksel Markov özniteliklerinin kullanımı gerçekleştirilmiştir. Farklı renk kanalları üzerinde yöntemin performansı test edilmiş, öznitelik vektörü oluşturulması esnasında ayrı ayrı kanallardan çıkarılan öznitelikler değerlendirilmiş, bu kanallardan elde edilen özniteliklerin kombinsayonlarının sistem performansına etkisi irdelenmiştir. Önerilen yöntemin en yüksek performansı a ve b kanallarında verdiği görülmüştür. Önerilen yöntemin literatürdeki yöntemler arasında sistemin doğruluk performansını artırdığı gözlemlenmiştir.

### **3.3.2. DCT Dömen Yüksek Frekans Bölgesinde Markov Tabanlı Görüntü Birleştirme Sahteciliğinin Tespiti ve İrdelenmesi**


Önerilen yöntemin esas hedefi girişten gelen test görüntüsünün sınıflamasında (orijinal ve sahte olmak üzere iki sınıf mevcuttur) doğruluk oranı yüksek bir yöntem önerebilmektir. YCbCr uzayı çalışma kapsamında test görüntüsünün temsilinde kullanılmış, tüm kanallar üzerinde yapılan testler ile hangi kanalın seçiminin daha anlamlı olacağına karar verilmiştir. Renk kanalının belirlenmesine yönelik yapılan çalışmalar ve elde edilen sonuçlar aşağıda irdelenmiştir.

Önerilen yöntemde öznitelik vektörünün oluşturulması aşamasında öncelikle seçilen kanal görüntüsüne 8x8'lik bloklar halinde DCT uygulanmıştır, birleştirme işleminin yüksek frekansta daha ayırt edici izler bırakacağı düşüncesi ile her bloktan zigzag tarama ile 16 tane yüksek frekanslı katsayı seçilmiştir. Yüksek frekanslı bu 16 tane DCT katsayısının birbiri ile istatistiksel bağımlılığının modellenmesi için Markov modeli kullanılmıştır. Önerilen yöntem [57], literatürdeki benzer çalışmalar ile kıyaslanmış ve elde edilen sonuçlarda yöntemin doğruluk oranı açısından daha başarılı olduğu görülmüştür.

Yapılan deneylerde öncelikle DCT katsayılarını kuantalamada kullanılacak q kuantalama değeri CASIA v1.0 veri seti üzerinde, her üç renk kanalı (Y, Cb, Cr) için test edilmiştir. Bu testler sonucu belirlenen q değeri ve seçilen renk kanalı ile sistem CASIA v2.0 ve Columbia (renkli) veri seti üzerinde test edilmiş, sistemin sahte ve orijinal görüntüleri sınıflandırmadaki doğruluk sonuçları, literatürdeki diğer yöntemlerle kıyaslanmıştır. Önerilen yöntemin performans analizi en uygun alt senaryonun belirlenmesi için yapılan testler ve performans analizi olarak iki aşamada incelenecektir

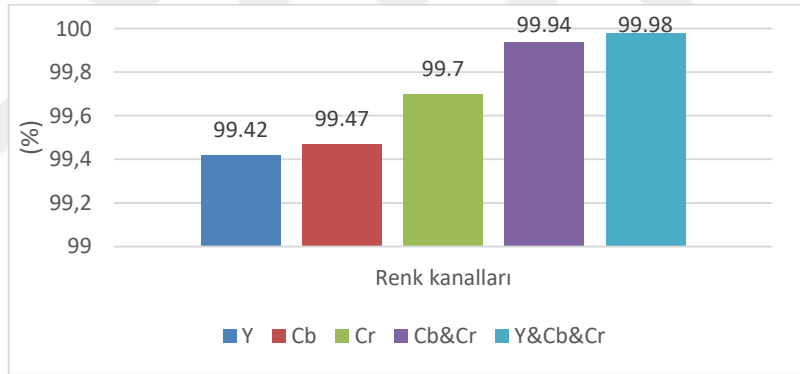
### 3.3.2.1. Yöntemi Oluşturan En Uygun Alt Senaryonun Belirlenmesi İçin Yapılan Performans Testleri

- DCT yüksek frekans katsayılarının kuantalama değerinin belirlenmesi: Önerilen yöntem ilgili renk uzayı dönüşümü ve renk kanalı seçimi yapıldıktan sonra DCT uygulanmış ve bu DCT katsayıları en yakın değere yuvarlanmıştır. Ancak bu katsayılardan (1)'de verilen ifade ile fark matrisleri elde edildiğinde yuvarlama işleminden dolayı birçok DCT katsayısının aynı değere karşılık düştüğü ve aslında her biri birbirinden bağımsız bir durum olarak nitelendirilmesi gerekirken büyük çoğunluğunun aynı duruma karşı geldiği görülmüştür. Bu DCT katsayılarının ifade ettiği anlamı genişletebilmek düşüncesi ile kuantalama işleminden sonra yuvarlama işleminin yapılması düşünülmüştür. Bu amaçla DCT katsayıları 7 farklı q katsayı değeri ile kuantalandıktan sonra öznel vektörleri elde edilmiş ve CASIA v1.0 veri seti üzerinde YCbCr renk uzayının her bir kanalında q katsayısının etkisi irdelenmiştir. Şekil 3.8'de görüleceği üzere, üç renk kanalında da q=25 değerinden sonra artırıldığında sistem performansına önemli bir katkısı olmamıştır. DCT yüksek frekans bileşenleri 25 değeri ile kuantalandığında yeteri kadar net bir alanda frekans bileşenleri irdelenebilmektedir. Bu nedenle bundan sonraki testlerde q=25 olarak seçilmiştir.



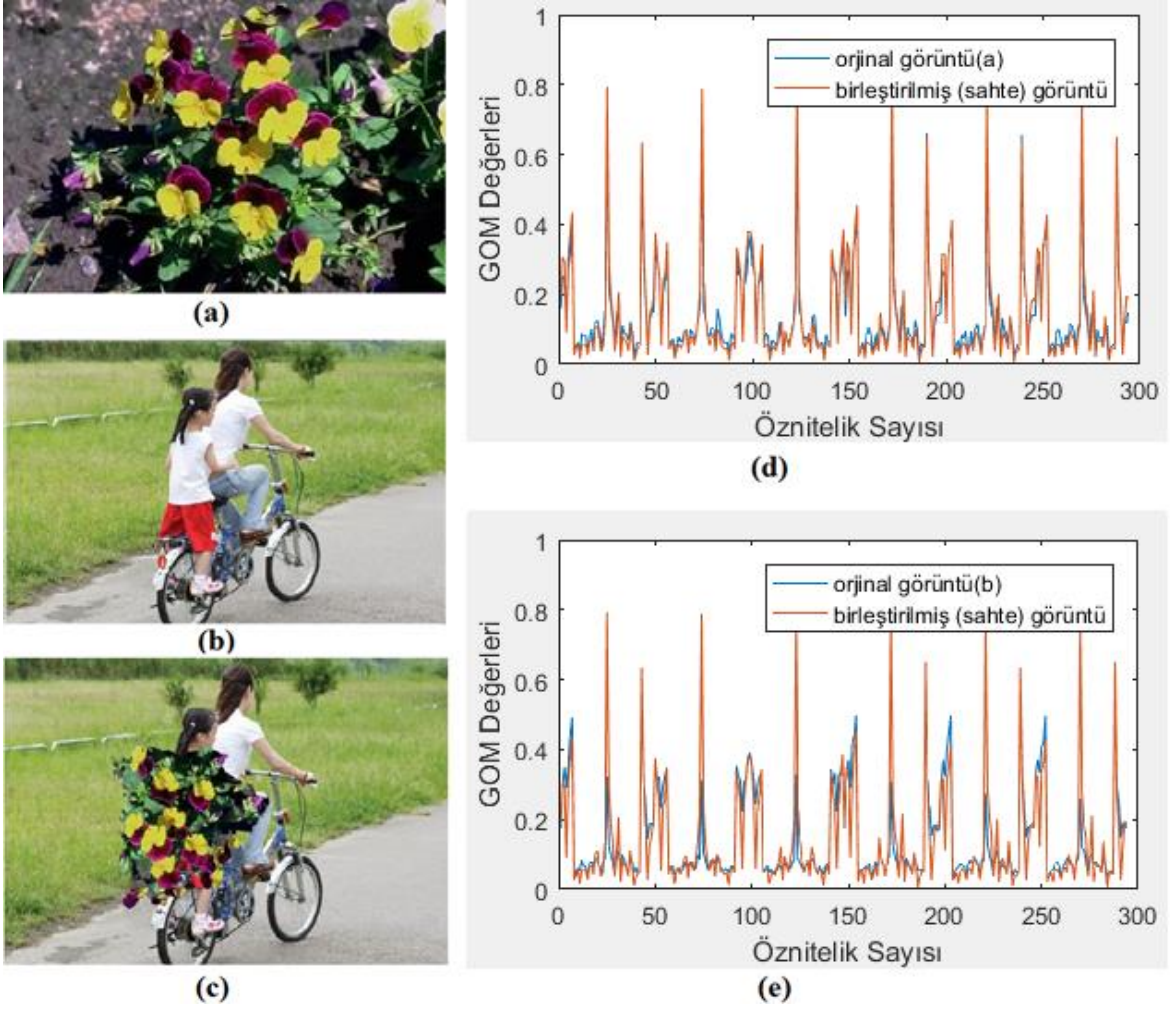
Şekil 3.8. Farklı kuantalama değerinin sistem performansına etkisi (CASIA v1.0).

- Yöntemde kullanılacak olan renk kanalının seçilmesi: Şekil 3.9’da  $q=25$  değeri ile CASIA v1.0 veri seti üzerinde YCbCr renk uzayının tüm kanalları üzerinde yöntem performansı değerlendirilmiş ve bu kanalların çeşitli kombinasyonlarının sistem performansına katkısı araştırılmıştır. Önerilen yöntem, belirlenen kuantalama değeri ile Y kanalında en yüksek %99.42 doğruluk oranını elde etmiştir. Cb kanalında %99.47, Cr kanalında %99.98 doğruluk oranı elde edilmiştir. Sistemin performansını artırması açısından her iki kanaldan (Cb,Cr) çıkarılan öznitelikler ve üç kanaldan (Y,Cb,Cr) çıkarılan özniteliklerin birleştirilmesi düşünülerek sistemin performansı araştırıldığında %99.98 doğruluk oranıyla Y,Cb,Cr kanalının en yüksek performansı sergilediği görülmüştür. Bu nedenle yöntemin diğer veri setleri üzerindeki (CASIA v2.0 ve Columbia (renkli)) performans değerlendirmesinde Y, Cb ve Cr kanallarının hepsinden çıkarılan özniteliklerin kullanılmasına karar verilmiştir.



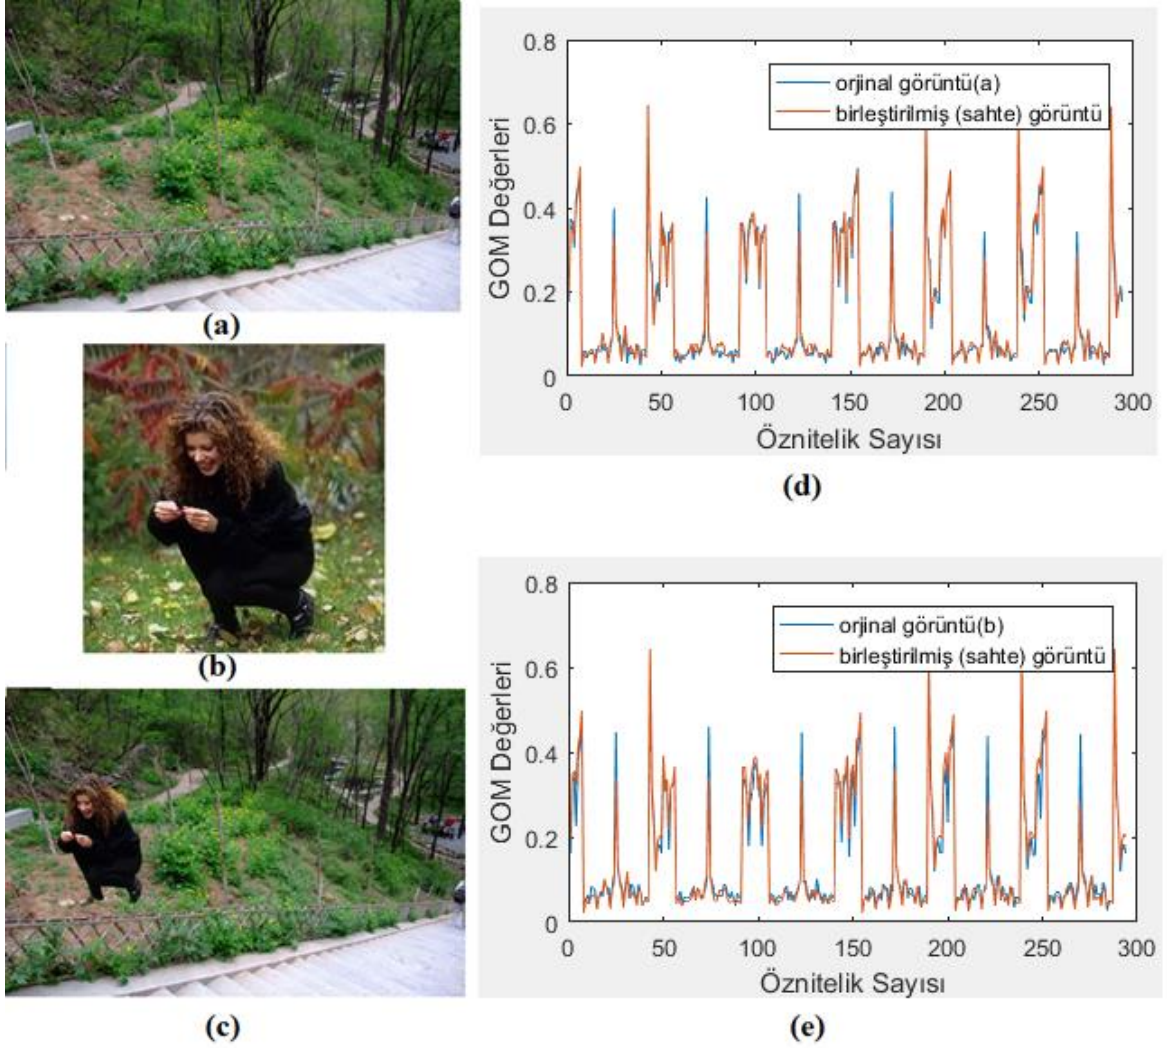
Şekil 3.9. Renk kanallarına göre elde edilen doğruluk oranları (CASIA v1.0).

Şekil 3.10’da önerilen yöntem ile tek bir renk kanalından (Cr) elde edilen öznitelik vektörleri gösterilmiştir. Orijinal (b) görüntüsüne, yine orijinal görüntü (a)’dan alınan bir bölgenin yapılandırılması ile elde edilen sahte görüntü (c)’de verilmektedir. Kıyaslama yapabilmek için, orijinal ve sahte görüntüden elde edilen öznitelik vektörleri (d-e)’de birlikte verilmiştir. Özellikle (b) görüntüsünün üzerine (a)’daki görüntüden bir bölgenin yapılandırıldığı düşünülürse (b) ve (c)’nin öznitelik vektörlerinin ne kadar birbirine yakınsayacağı merak edilir. (e) ile verilen grafikte (b) ve (c)’den elde edilen öznitelik vektörleri görülmektedir. Elde edilen istatistiksel özniteliklerin iki görüntü arasında yüksek bir farklılık oluşturduğu görülebilmektedir.



Şekil 3.10. (a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-2 [57] ile elde edilen öznitelik vektörleri, (e) b ve c görüntülerinden önerilen yöntem-2 [57] ile elde edilen öznitelik vektörleri

Şekil 3.11’de orijinal doğa görüntüsü (a) üzerine, (b)’deki kadın görüntüsünün ölçeklenerek yapıştırılması ile elde edilen sahte görüntü (c) verilmiştir. (d) ile verilen grafikte (a)’daki orijinal görüntü ve eklemlili sahte görüntü (c)’den yapılan çalışmayla edilen öznitelik vektörleri verilmiştir. (e) ile verilen grafikte (b)’deki orijinal görüntü ve sahte görüntü (c)’den elde edilen öznitelik vektörleri gösterilmektedir. Grafiklerden (d-e) görüleceği üzere elde edilen öznitelik vektörlerinin birbirinden farklılık gösterdiği açıktır. Öznitelik vektörlerindeki bu farklılıklar sınıflandırıcı tarafından görüntüyü sahte ve orijinal diye iki gruba ayırırken, sınıflandırmanın performansını da belirlemektedir. Orijinal ve sahte görüntülerden elde edilen öznitelik vektörleri ne kadar birbirinden farklı karakter sergilerse, sınıflandırıcının performansı o kadar yüksek olur.



Şekil 3.11. (a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-2 [57] ile elde edilen öznitelik vektörleri, (e) b ve c görüntülerinden önerilen yöntem-2 [57] ile elde edilen öznitelik vektörleri

### 3.3.2.2. Önerilen Yöntemin Literatürdeki Benzer Yöntemlerle Kıyaslanması

Önerilen yöntem sahte ve orijinal görüntüleri yaklaşık %98-99 arasında doğruluk değerleriyle tespit edebildiğinden, öznitelik seçme algoritmalarına gerek duyulmamıştır. Tablo 3.5'te görüleceği üzere önerilen yöntem yüksek doğruluk oranı ile sahte ve orijinal görüntüleri tespit etmektedir.

CASIA v1.0 veri seti üzerinde test edilen yöntemlere kıyasla önerilen yöntem %99.98 ile en yüksek doğruluk oranını elde etmiştir. Literatürde CASIA v2.0 veri setinde Han vd. [29] yaptığı çalışma %97.28'lik bir başarıya sahipken önerilen yöntem %99.89

oranıyla daha yüksek bir başarı elde etmiştir. Yöntem Columbia veri setinde de %98.92 doğruluk oranıyla yüksek bir performans göstermektedir. Pham vd. [32] renkli görüntüleri gri seviyeye çevirdikten sonra DCT domen düşük frekans bileşenleri ve blok çiftleri arasındaki DCT katsayıları arasından iki yönlü olarak Markov modeli ile yaptığı çalışmada CASIA v2.0 veri setinde %96.90 başarı oranı elde etmiştir. Giriş görüntülerin renk kanal bilgilerinin kullanılmaması ve DCT katsayıları arasındaki ilişkinin iki yönlü olarak ele alınması [32]'deki yöntemin algılama performansını sınırlandırmıştır.

Tablo 3.5. Önerilen yöntem-2'nin [57] literatürdeki diğer yöntemlerle karşılaştırılması

YÖNTEM	ÖZİNİTELİKLER	CASIA V1.0	CASIA V2.0	COLUMBIA (R/G)
[23]	Markov (DCT+DWT)	-	89.76	-
[26]	Markov(DMWT)	-	-	93.36 (gri)
[27]	Markov (QDCT)	96.43	92.38	-
[25]	Markov(spatial+DCT)	-	-	98.82 (gri)
[30]	Markov Countourlet + DCT	-	-	94.10
[31]	Markov 3seviye DWT	-	-	89.93
[29]	Markov+Kuantalama	98.95	97.28	95.24
[32]	Markov (DCT-LF)	-	96.90	-
<b>Önerilen Yöntem-2 [57]</b>	<b>Markov (DCT-HF)</b>	<b>99.98</b>	<b>99.89</b>	<b>98.92</b>

#### 3.4. Dokusal Özniteliklere Dayalı Birleştirme Sahteciliği Tespiti ve Elde Edilen Deneysel Sonuçlar

Bu bölümde eklemli bölgenin görüntü üzerinde oluşturacağı dokusal bozulmaları sahtecilik tespitinde kullanmak için önerilen dokusal tabanlı yöntemin deneysel sonuçları verilmiştir.

##### 3.4.1. Hilbert Domende Dokusal Bozulmaları Kullanarak Görüntülerin Doğrulanması ve Elde Edilen Deneysel Sonuçlar

Görüntü birleştirme sahteciliği ile elde edilen sahte görüntülerin dokusal yapısının bozulacağı düşüncesi ile önerilen yöntemde GLCM tabanlı LBP, entropi ve varyans bilgilerinin değerlendirildiği başka bir yöntem önerilmiştir. Eklemli bölge yapıştırıldığı

hedef görüntüde ekstra kenarlar oluşturacağından, yapılan çalışma görüntüdeki bozulmaları literatürdeki doku tabanlı yöntemlerden farklı olarak kenar görüntüleri üzerinden, Hilbert domende elde etmiştir. Görüntüde GLCM'ler üzerinden dokusal özellikler elde edilmiştir. Sahte görüntüdeki düzensizliği yansıtaacağı düşüncesi ile görüntünün entropi ve varyans bilgilerinden faydalanılmıştır. Ayrıca LBP ile de yine dokusal özellikler çıkarılmıştır. Yöntemin performans analizi en uygun alt senaryonun belirlenmesi için yapılan deneyler ve performans analizi olarak iki aşamada incelenecektir.

#### 3.4.1.1. Yöntemi Oluşturan En Uygun Alt Senaryonun Belirlenmesi İçin Yapılan Performans Testleri

Yapılan çalışmada elde edilen performansı en üst düzeye çekmek için kullanılacak olan kenar algoritmaları, frekans domen dönüşümleri ve renk uzayları yapılan testlerle belirlenmiştir.

- Yöntemde kullanılacak olan kenar operatörünün belirlenmesi: Önerilen yöntemde giriş görüntüsü YCbCr ve Lab renk dönüşüm uzaylarında temsil edildikten sonra kenar görüntüsü elde edilmiştir. Yapılan testlerde kenar görüntüsü elde etmek için hangi kenar belirleme operatörünün kullanılacağı belirlenmiştir. Bunun için CASIA v1.0 veri seti üzerinde YCbCr renk uzayında (bütün kanallardan elde edilen öznitelikler dahil edilmiştir) 3 farklı kenar belirleme operatörü kullanılarak sistem performansı değerlendirilmiştir. Tablo 3.6'da görüleceği üzere yöntem Canny algoritması ile elde edilen kenar görüntüsünden %99.11 ile en yüksek doğruluk oranı elde etmiştir.

Tablo 3.6. Önerilen yöntemin farklı kenar algoritmaları ile CASIA v1.0 üzerinde test edilmesi

<b>KENAR BELİRLEME OPERATÖRÜ</b>	<b>DOĞRULUK ORANI (%)</b>
<b>SOBEL</b>	99.02
<b>PREWITT</b>	98.96
<b>CANNY</b>	99.11

- Yöntemde kullanılacak olan frekans domeninin belirlenmesi: Kenar görüntüsü elde edildikten sonra önerilen yöntemdeki bir sonraki adım özniteliklerin

çıkarılacağı frekans domeninin belirlenmesidir. Bir önceki adımda kullanılan YCbCr renk uzayı ve Canny ile elde edilen kenar görüntüsü ile farklı frekans domenlerinde performans testi uygulanmıştır. Tablo 3.7’de görüleceği üzere deneysel olarak uygun frekans domenini seçmek için SWT, LWT, DWT ve Hilbert dönüşüm uzaylarında test edilmiş ve sistemin en yüksek doğruluk oranı %99.11 ile Hilbert dönüşüm uzayında elde edilmiştir.

Tablo 3.7. Önerilen yöntemin farklı frekans domenlerinde CASIA v1.0 üzerinde test edilmesi

FREKANS DOMENİ	DOĞRULUK ORANI (%)
SWT	95.76
LWT	97.2
HILBERT	99.11
DWT	95.35


- YCbCr ve Lab renk uzayı kanallarının katkısının irdelenmesi: Bu bölümde YCbCr ve Lab renk uzayının kanallarının katkısı CASIA v1.0 üzerinde irdelenmiştir. Elde edilen sonuçlarda tüm renk kanallarından elde edilen özneliklerin birleştirilmesinin sistem performansını artırdığı gözlemlenmiştir. Önerilen yöntem Y, Cb ve Cr renk kanalları üzerinde sırası ile %97.58, %98.02, %98.58 doğruluk oranı elde edilmiştir. YCbCr uzayındaki renk kanallarından elde edilen özneliklerin birleştirildiğinde %99.01 oranında, parlaklık kanalı da katıldığında yani üç kanaldan elde edilen özneliklerin tümü kullanıldığında %99.11 doğruluk oranı elde edilmiştir. Lab renk kanalı biraz daha düşük performans göstermiştir. L parlaklık kanalında % 94.02, a renk kanalında %97.12 ve b renk kanalında %97.28 doğruluk oranları ile sistem performans sergilemiştir. Lab uzayındaki renk kanalından elde edilen özneliklerin birleştirilmesi ile %98.52 oranında doğruluk oranı elde edilirken, her üç kanalın öznelikleri birleştirildiğinde %98.81 oranında doğruluk elde edilmiştir. Her iki renk uzayında da renk kanallarından elde edilen özneliklerinin birleştirilmesinin sistem performansına pozitif etkisi görülmüştür. Şekil 3.12’de deneysel sonuçlar gösterilmiştir. Tablo 3.8’de görüleceği üzere TPR değeri YCbCr renk uzayında daha yüksektir. TNR değeri de Lab uzayında yüksektir. TNR değeri eklemli sahte görüntülerin doğru



sınıflandırma oranını verdiği için Lab uzayı sahte görüntüleri sınıflandırmada daha yüksek sonuç vermiştir, YCbCr uzayı da orijinal görüntüleri sınıflandırmada daha başarılıdır. Bu nedenle bu iki renk uzayının da sahte ve orijinal görüntüleri sınıflandırmada kullanılmasının sistemin performansını artıracak görülmüştür. Şekil 3.12’de de görüleceği gibi bu iki renk uzayından elde edilen özneliklerin birlikte kullanılması sistemin görüntü doğrulamadaki performansını artırmıştır. Bundan sonraki performans karşılaştırmalarında YCbCr ve Lab uzayının ikisi birlikte kullanılacaktır. Renk uzayının belirlenmesinden sonra önerilen yöntem farklı veri seti üzerinde test edilmiştir.

Tablo 3.8. Farklı renk kanallarının performans değerlendirilmesinin CASIA v1.0 veri seti üzerinde değerlendirilmesi

VERİ SETİ	RENK KANALI	TPR (%)	TNR (%)	DOĞRULUK (%)
CASIA V1.0	Y	94.16	97.90	<b>97.58</b>
	Cb	96.60	98.83	<b>98.02</b>
	Cr	98.77	97.65	<b>98.58</b>
	Cb-Cr	99.17	92.50	<b>99.01</b>
	YCbCr	99.21	97.98	<b>99.11</b>
	L	81.50	97.72	<b>94.02</b>
	a	88.88	99.02	<b>97.12</b>
	b	93.60	99.41	<b>97.28</b>
	a-b	96.75	98.93	<b>98.52</b>
	Lab	96.62	98.96	<b>98.81</b>
	<b>YCbCr-Lab</b>	<b>97.62</b>	<b>99.87</b>	<b>99.15</b>




Şekil 3.12. Önerilen yöntem-3 ile CASIA v1.0 üzerinde farklı renk kanallarının doğruluk oranları

Aşağıda sahte ve orijinal görüntülerden önerilen yöntemle elde edilen öznelik vektörleri verilmiştir. Şekil 3.13-(b)'deki karakterin (a)'daki orijinal görüntü üzerine yapılandırılması ile elde edilen sahte görüntü (c)'de verilmiştir. Önerilen yöntemde öznelik vektörünü oluşturan her bir GLCM'den elde edilen entropi değeri [0-1] aralığında olmasına karşın, tüm yönlerdeki GLCM'lerin ortalama varyansının standart sapması değeri çok büyük sayılara denk gelmektedir. İki özellik aynı grafikte gösterildiğinde standart


sapma değerleri entropi değerlerini baskılamakta ve ayrıntılı bir şekilde grafikte görülememektedir. Bu nedenle öznitelik vektöründeki bu değerler ayrı grafiklerde gösterilmiştir.

Şekil 3.13'te, (a)'da verilen orijinal görüntü ve onun eklemli hali olan (c)'de verilen sahte görüntüden elde edilen entropi değerleri (d) ile, her bir GLCM'nin dört yönünden elde edilen ortalama varyansın standart sapma değeri de (e)'deki grafiklerle gösterilmiştir. Her iki grafikten de görüleceği üzere orijinal ve sahte görüntü üzerinden elde edilen bu öznitelikler birbirinden farklılık göstermektedir.



Şekil 3.13. (a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-3 ile elde edilen entropiye dayalı öznitelik vektörü, (e) a ve c görüntülerinden önerilen yöntem-3 ile elde edilen varyans bilgisine dayalı öznitelik vektörleri


Şekil 3.14'te, (a)'da verilen orijinal sahne görüntüsü üzerine, (b)'de verilen orijinal sahne görüntüsündeki kitap okuyan kadın figürünün yapıştırılması ile oluşturulan sahte görüntü (c)'de verilmiştir. (d) ile verilen grafikte önerilen yöntem ile (a) ve (c) görüntüsünden elde edilen entropi değerleri verilmiştir. Entropi değerinin orijinal ve sahte görüntülerde farklı karakteristiğe sahip olduğu görülmektedir. Entropi değeri düzensizliği ifade etmektedir, dolayısıyla eklemli görüntüdeki düzensizliğin daha fazla olması beklenmektedir. Şekil 3.13 ve Şekil 3.14'de (d) ile verilen entropi değerlerine bakıldığında orijinal görüntülerin entropi değerlerinin sahte görüntüdeki değerlerden daha düşük olduğu izlenmektedir. Şekil 3.14'te (e) ile verilen grafikte de (a)'daki orijinal görüntü ve onun eklemli versiyonu olan (c)'deki sahte görüntüden yöntemin önerdiği gri seviyeli eş oluşturma matrislerinin ortalama varyansının standart sapma değerleri gösterilmekte olup her iki görüntüden elde edilen bu öznelikler de birbirinden farklı davranış sergilemektedir. Öznelik vektörlerindeki bu farklılıklar SVM sınıflandırıcı yardımı ile sahte ve orijinal görüntüleri birbirinden ayırt etmek için kullanılmaktadır.



Şekil 3.14. (a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-3 ile elde edilen entropiye dayalı öznitelik vektörü, (e) a ve c görüntülerinden önerilen yöntem-3 ile elde edilen varyans bilgisine dayalı öznitelik vektörleri


### 3.4.1.2. Önerilen Yöntemin Performans Analizi

Yukarıdaki testlerle yöntemde kullanılacak olan parametreler belirlendikten sonra, yöntem literatürde yaygın kullanılan diğer veri setlerinde (CASIA v2.0 ve Columbia) de test edilmiştir. Şekil 3.15'te de görüleceği üzere yöntem her üç veri setinde de ortalama %99 oranında başarıya sahiptir. Sahte görüntüleri sınıflandırmada ortalama %99.8 doğruluk oranına sahipken orijinal görüntüleri sınıflandırmada ortalama %98.3 doğruluk oranı vermektedir. TPR ve TNR değerleri ile yorumlanan bu iki sonuç, görüntü sahteciliği tespiti için yeterli sayılabilecek performans oranlarıdır.




Şekil 3.15. Önerilen yöntem-3'ün farklı veri setleri üzerindeki deneysel sonuçları

- CASIA v2.0 veri seti üzerindeki farklı atak tiplerine karşı performans analizi: CASIA v2.0 veri seti eklemli sahte görüntülerin yanısıra, bu eklemli görüntüleri ön işleme ile "döndürme", "ölçekleme", "deformasyon" gibi atak tipleri uygulanmış sahte görüntüler de mevcuttur. Önerilen yöntem YCbCr ve Lab renk uzayları kullanılarak bu atak tipleri üzerinde de irdelenmiştir. Şekil 3.16 önerilen yöntemin CASIA v2.0 veri setindeki her bir atak tipi üzerindeki TNR, TPR ve doğruluk oranları verilmiştir. Yöntem "dönüşüm yok" ve "birleştime" etiketi ile hiçbir ön işlem uygulanmayan ve eklemli sahte görüntülerde %100 doğruluk oranı verirken, diğer atak tipleri için %99-100 arasında bir performans göstermiştir. TNR sonuçları, önerilen yöntemin sahte görüntüleri "ölçekleme", "deformasyon" ve "dönüşüm yok" atak tiplerinde yüksek doğruluk oranı elde ettiğini göstermektedir.



Şekil 3.16. CASIA v2.0 veri seti üzerinde farklı atak tiplerinin analizi

- CASIA v1.0 veri seti üzerindeki farklı atak tiplerine karşı performans analizi: CASIA v1.0 veri seti üzerinde farklı atak tiplerine göre performans değerlendirmesi TPR, TNR ve doğruluk oranları ile birlikte verilmektedir. Mevcut veri setinde kopyala-taşı sahteciliği ile oluşturulmuş sahte görüntüler de mevcuttur ve yöntem eklemli sahte görüntülerde kopyala-taşı sahteciliğiyle üretilmiş görüntülere kıyasla daha yüksek doğruluk oranına sahiptir. Şekil 3.17’de görüleceği üzere önerilen yöntem “dönüşüm yok, ölçekleme ve birleştirme” etiketleri ile herhangi bir ön işleme tabi tutulmayan, ölçeklendirilmiş ve eklemli sahte görüntülerde %100 doğruluk oranına sahiptir ve yöntemin diğer atak tiplerine karşı da ortalama %99 oranında doğruluk oranı vardır. Görüntülerin doğrulanması için önerilen yöntemde elde edilen değerler ideale yakındır.



Şekil 3.17. CASIA v1.0 veri seti üzerinde farklı atak tiplerinin analizi

- Literatürdeki diğer yöntemlerle performans analizi: Bu bölümde, önerilen yöntemin orijinal ve sahte görüntüleri doğru sınıflandırmadaki performansı literatürdeki benzer yöntemlerle literatürde yaygın olarak kullanılan üç veri seti üzerinde karşılaştırılmıştır. Tablo 3.9’da görüleceği üzere yöntem CASIA v1.0 veri seti üzerinde %99.15 doğruluk oranına sahiptir. Diğer yöntemlerin doğruluk oranları önerilen yönteminkinden daha düşüktür. CASIA v2.0 veri seti üzerinde önerilen yöntem %99.60 doğruluk performansı elde ederken diğer yöntemlerde CASIA v2.0 veri setinde elde edilen doğruluk oranları çok da yüksek değildir. Yöntem renkli Columbia veri setinde %99.29 oranında doğruluk oranı elde ederken, bu veri setinde literatürdeki çalışmalarda elde edilen ikinci en yüksek doğruluk oranı %97.77’dir.

Tablo 3.9. Dokusal bozulmalara dayalı önerilen yöntemin literatürdeki benzer yöntemlerle performans karşılaştırması


YÖNTEM	ÖZNETELİKLER	CASIA V1.0	CASIA V2.0	COLUMBİA (RENKLİ)
[15]	SPT+LBP	94.89	97.33	96.39
[16]	Gabor+DCT	96.21	97.9	-
[17]	Entropi+WLD	93.33	-	-
[20]	TF-GLCM	98.54	97.73	-
[18]	Entropi + LPQ	95.41	98.33	91.14
[19]	LBP+DCT	97.0	97.50	97.77




Tablo 3.9'un devamı

YÖNTEM	ÖZİNİTELİKLER	CASIA V1.0	CASIA V2.0	COLUMBIA (RENKLİ)
[21]	SPT+LBP, LPQ, BSIF, BGP	94.13	97.03	92.01
[22]	SWT+ RICLBP	96.81	-	92.31
<b>Önerilen Yöntem-3</b>	STextOp (Glc, var, ent., lbp)	<b>99.15</b>	<b>99.60</b>	<b>99.29</b>

Bir diğer karşılaştırma atak tiplerine karşı olan dayanıklılık üzerinden literatürdeki çalışmalarla yapılmıştır. CASIA v2.0 veri seti üzerindeki atak tiplerine göre sonuç veren çalışmalar [15,21] ve CASIA v1.0 üzerinde atak tiplerine göre sonuç veren çalışmalarla [21] yöntem kıyaslanmıştır. Şekil 3.18, CASIA v2.0 veri seti üzerinde diğer yöntemlerle performans değerlendirmesini göstermektedir. Önerilen yöntem splicing, copy move, “döndürme”, ölçekleme and deforming ataklarında diğer yöntemlerden yüksek performans göstermektedir. Şekil 3.19 da CASIA v1.0 üzerindeki atak tiplerine göre performans değerlendirmesini vermektedir. Yöntem [21]’deki çalışmaya göre bütün atak tiplerinde yüksek performans elde etmektedir ve her iki veri setinde de “döndürme” atak tipinde diğerlerine oranla biraz daha düşük performansa sahiptir.



Şekil 3.18. Önerilen yöntemin [15, 21] ile CASIA v2.0 veri setinde farklı atak tiplerindeki performans değerlendirmesi



Şekil 3.19. Önerilen yöntemin [21]'deki yöntem ile CASIA v1.0 veri setinde farklı atak tiplerindeki performans değerlendirilmesi

Görüntü birleştirme sahteciliği ile elde edilen görüntülerde eklemli bölge görüntüdeki dokusal yapıyı değiştireceğinden, sahte görüntüleri sınıflandırmada eklemli bölgenin bıraktığı izlerden yola çıkma düşüncesi ile önerilen yöntemde, görüntüler sahte ve orijinal olarak yüksek doğruluk oranı ile sınıflandırılmıştır. Önerilen yöntemde öznelilikler Hilbert dönüşüm uzayında kenar görüntüsü üzerinden elde edilmiş, gri seviyeli eş oluşum matrislerinden ortalama varyansın standart sapması, LBP ve entropi öznelilikleri çıkarılmıştır. Önerilen yöntem farklı atak tiplerine karşı dayanıklıdır.

### 3.5. Dokusal ve İstatistiksel Bozulmalara Dayalı Hibrit Bir Birleştirme Sahteciliği Tespiti ve Elde Edilen Deneysel Sonuçlar

Bu bölümde birleştirme sahteciliği ile üretilen görüntüde oluşan dokusal ve istatistiksel bozulmaların literatürde ilk kez birlikte değerlendirildiği hibrit tabanlı çalışmada elde edilen deneysel sonuçlar verilecektir.

#### 3.5.1. SWT Domende Durum Geçiş Modeli ve GLCM Tabanlı Dokusal Özneliliklerin Hibrit Kullanımı ile Birleştirme Sahtecilik Tespiti ve Elde Edilen Deneysel Sonuçlar


Görüntü birleştirme sahteciliği ile elde edilen sahte görüntüler üzerinde daha önceki yapılan çalışmalarda dokusal öznelilikler ve istatistiksel öznelilikler ayrı ayrı değerlendirilmiştir. Elde edilen sonuçlarda her iki bozulmadan yola çıkarak elde edilen

doğruluk performanslarının yüksek olduğu görülmüştür. Bu sonuç görüntüdeki istatistiksel bozulmaların da, dokusal yapının bozulmasının da görüntü doğrulamada göz ardı edilemeyeceği kanaatini oluşturmuştur. Bu nedenle [58] ile önerilen yöntemde literatürde ilk kez istatistiksel ve dokusal özniteliklerin birlikte kullanıldığı hibrit bir yaklaşım sunulmuştur. Önerilen yöntem görüntünün pikseller arasındaki geçişlerin istatistiksel bir modelini çıkarmada Markov özniteliklerinden faydalanırken, görüntünün dokusal öznitelikleri için Haralick'in önerdiği [81] gri seviyeli eş-oluşum matrislerinden çıkarılan dokusal özniteliklerden faydalanılmıştır. Önerilen yöntemin performans analizi en uygun alt senaryonun belirlenmesi için yapılan deneyler ve performans analizi olarak iki aşamada incelenecektir

### **3.5.1.1. Yöntemi Oluşturan En Uygun Alt Senaryonun Belirlenmesi İçin Yapılan Performans Testleri**


Önerilen yöntemde sistemin performansına etki edecek istatistiksel özellikleri elde etmede kullanılan T eşik değeri ve renk kanalı seçimi yapılan testlerle belirlenmiştir.

- Eşik değeri T'nin yöntemin performansına etkisinin araştırılması: Önerilen yöntemde Markov modeli oluşturulurken fark matrisleri elde edildikten sonra bu fark matrisleri seçilen bir T eşik değeri (2) ile gösterildiği gibi kuantalanır (2). Elde edilen öznitelik matrisinin boyutu  $(2T+1)^2$  ile doğru orantılıdır. T'nin çok büyük seçilmesi öznitelik vektörünün boyutunu artıracak, çok küçük seçilmesi ise geçiş olasılık matrislerinde (GOM) birleştirme sahteciliğinin izleri hakkında bilgi edinmeyi zorlaştıracaktır. Bu nedenle uygun eşik değeri deneysel olarak belirlenmiştir. Önerilen yöntem CASIA v1.0 veri seti üzerinde farklı T değeri için test edilmiştir. Şekil 3.20'de görüleceği üzere en iyi performans T=3 değeri için elde edilmiştir. Bundan sonraki tüm performans değerlendirmelerinde T=3 olarak seçilmiştir.



Şekil 3.20. [58]'deki yöntemde farklı eşik değeri (T)'nin sistem performansına etkisi

- Cb ve Cr kanallarının sistem performansına etkisinin irdelenmesi: Bu bölümde önerilen yöntemde renk kanallarından elde edilen özneliklerinin sistem performansına etkisi incelenmiştir. Şekil 3.20'de de görüleceği gibi Cb ve Cr renk kanallarından elde edilen özneliklerin birleştirilmesinin tüm eşik değerlerinde sistem performansını artırdığı gözlemlenmiştir. Ayrıca bu bölümde renk kanallarının sistem performansına etkisi üç veri seti üzerinde (CASIA v1.0, CASIA v2.0, Columbia renkli) test edilmiştir. Şekil 3.21'de görüleceği üzere Cb ve Cr renk kanallarının birlikte kullanılması her üç veri setinde performansı artırdığı görülmüştür. Bu nedenle bundan sonraki performans değerlendirmelerinde öznelik çıkarımında her iki kanal birlikte kullanılmıştır.



Şekil 3.21. (a) CASIA v1.0, (b) CASIA v2.0, (c) Columbia (renkli) veri setleri üzerinde renk kanallarının önerilen yöntemin [58] performansına etkisinin değerlendirilmesi.

Aşağıda her bir veri setinin elde ettiği doğruluk performanslarının bağlı olduğu Karmaşıklık Matrisleri verilmektedir (Tablo 3.11). Karmaşıklık Matrisleri tahminlerin doğruluğu hakkında bilgi veren bir matristir. 4 hücresi mevcuttur. Ele alınan problemin sınıflandırma sonuçlarının karmaşıklık matrisindeki karşılığı Tablo 3.10'da verilmiştir.

Tablo 3.10. Sahte ve Orijinal görüntülerin sınıflandırılmasında kullanılan karmaşıklık matrisi

	<b>Sahte olarak tahmin edilen görüntü sayısı</b>	<b>Orijinal olarak tahmin edilen görüntü sayısı</b>
<b>Gerçekte Sahte olan görüntü sayısı</b>	Doğru Negatif (TN)	Yanlış Pozitif (FP)
<b>Gerçekte Orijinal olan görüntü sayısı</b>	Yanlış Negatif (FN)	Doğru Pozitif (TP)

Tablo 3.11. Farklı veri setlerinin ((a) CASIA v1.0, (b) CASIA v2.0, (c) Columbia) sınıflandırılmasındaki karmaşıklık matrisleri

CASIA v1.0 (Cr - Cb Kanah)		Tahmin Edilen Sınıflar		CASIA v2.0 (Cr - Cb Kanah)		Tahmin Edilen Sınıflar	
		Sahte	Orijinal			Sahte	Orijinal
Gerçek Sınıflar	Sahte	92	0.1	Gerçek Sınıflar	Sahte	510.6	1.6
	Orijinal	1.2	77.8		Orijinal	3	746.4

(a)

(b)

Columbia (renkli) (Cr & Cb Kanah)		Tahmin Edilen Sınıflar	
		Sahte	Orijinal
Gerçek Sınıflar	Sahte	17.5	0.2
	Orijinal	0.3	17

(c)

Yapılan performans değerlendirmelerinde ayrıntıları 3.2’de verilen 10-Katlı Çapraz doğrulama kullanıldığından, verilen karmaşıklık matrisleri de 10-Katlı sınıflandırma sonucu elde edilen karmaşıklık matrislerinin ortalamaları alınarak verilmiştir. Ortalama alma işleminden dolayı karmaşıklık matrisindeki değerler ondalıklı sayı çıkmıştır. Tablo 3.11 (a)’da CASIA v1.0 veri seti üzerinde elde edilen sınıflandırmanın sahte ve orijinal görüntülerdeki başarı oranı verilmektedir. İlk satırda gerçekte sahte olan görüntü sayısı ikinci satırda da gerçekte orijinal olan görüntü sayısı verilmektedir. Bu veri setinde 921 sahte, 780 orijinal görüntü sınıflandırma işlemine girmiştir. 10-katlı çapraz doğrulama için veri seti 19’a bölünüp, test aşamasında her bir iterasyonda bu parçalardan biri kullanıldığı için 92 sahte görüntü 78 orijinal görüntü test edilmiştir. 10-katlı sınıflandırmada sadece 1 kere 1 görüntü sahte olduğu halde orijinal olarak sınıflandırılmıştır. Bu bilgi karmaşıklık matrisinin 1 satır 2.sütun hücresinden (FP=0.1) elde edilmektedir. Aynı şekilde 10-katlı sınıflandırmada toplam 12 orijinal görüntünün sahte olarak sınıflandırıldığını, matrisin 2.satır 1.sütun hücresinden görülmektedir (FN=1.2).

Tablo 3.11 (b)’de CASIA v2.0 veri seti kullanılarak elde edilen karmaşıklık matrisi verilmiştir. Karmaşıklık matrisinin 1. satır elemanları toplamı, 10 kere sınıflandırmanın ortalaması alındığından dolayı 512.6’dır, yani toplamda 5126 tane sahte görüntü sınıflandırılmıştır.

Yukarıda yapılan deneylerle önerilen yöntemin SWT domende Cb ve Cr renk kanallarının ikisinin birlikte kullanılması ile elde edilen özneliklerin kullanılması belirlenmiştir. Şekil 3.22-23’te önerilen yöntemden [58] elde edilen öznelik vektörlerinin sahte ve orijinal görüntüler açısından karşılaştırılması verilmiştir. Elde edilen öznelik vektörü dokusal ve istatistiksel öznelikler içermektedir. Bu özneliklerin sayısal değerleri aralık olarak birbirinden farklı olduğundan, istatistiksel öznelikler 0-1 aralığında, dokusal öznelikler 0-40 arasında değişen değerler aldığından, öznelik vektörünün bütünü tek bir grafikte gösterildiğinde eksen skalasında istatistiksel öznelikler ayırt edici bir şekilde görülememektedir. Bu nedenle önerilen yöntemden elde edilen öznelikler, dokusal ve istatistiksel öznelikler olarak ayrı ayrı gösterilmiştir. Önerilen yöntemde Haralic’in dokusal özneliklerinden 5 tanesinin ortalama ve standart sapma değeri dokusal öznelik olarak kullanılmıştır. Her bir GLCM’den  $5 \times 2 \times 4 = 40$  tane dokusal öznelik elde edilmiştir. 3 SWT yüksek frekans bandından elde edilen öznelikler birleştirildiğinde  $40 \times 3 = 120$  tane dokusal öznelik elde edilir. T=3 için  $((2T+1)^2 \times 6) \times 3$  uzunluğunda da istatistiksel öznelik mevcuttur.

Şekil 3.22’de (a)’daki orijinal görüntünün üzerine (b) görüntüsünden kesilen kaplan görüntüsünün yapıştırılması ile oluşturulan sahte görüntü (c)’ verilmiştir. Orijinal ve sahte görüntülerden (a, c) önerilen yöntem ile elde edilen dokusal ve istatistiksel özniteliklerin grafiksel gösterimi sırası ile (d) ve (e)’de verilmiştir. Her iki öznitelik vektöründe de orijinal ve sahte görüntüden elde edilen özelliklerin sahte ve orijinal görüntüde birbirinden farklılık gösterdiği görülmektedir.




(a)




(b)



(c)



(d)



(e)

Şekil 3.22. (a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-4 ile elde edilen dokusal tabanlı öznitelik vektörü, (e) a ve c görüntülerinden önerilen yöntem-4 ile elde edilen istatistiksel tabanlı öznitelik vektörleri



Şekil 3.23'te doğa görüntüsü üzerine yapıştırılan karakter görüntülerinde elde edilen sahte görüntü (c) verilmiştir. (d) ile a ve c görüntüsünden elde edilen dokusal öznitelikler, (e) ile a ve c görüntüsü üzerinden elde edilen istatistiksel özniteliklerin grafiksel gösterimi verilmiştir. Her iki grafikten de görüleceği üzere orijinal ve sahte görüntüden elde edilen öznitelikler Şekil 3.23'te verilen örnek görüntüler için de farklılık göstermiştir.




(a)




(b)



(c)



(d)



(e)

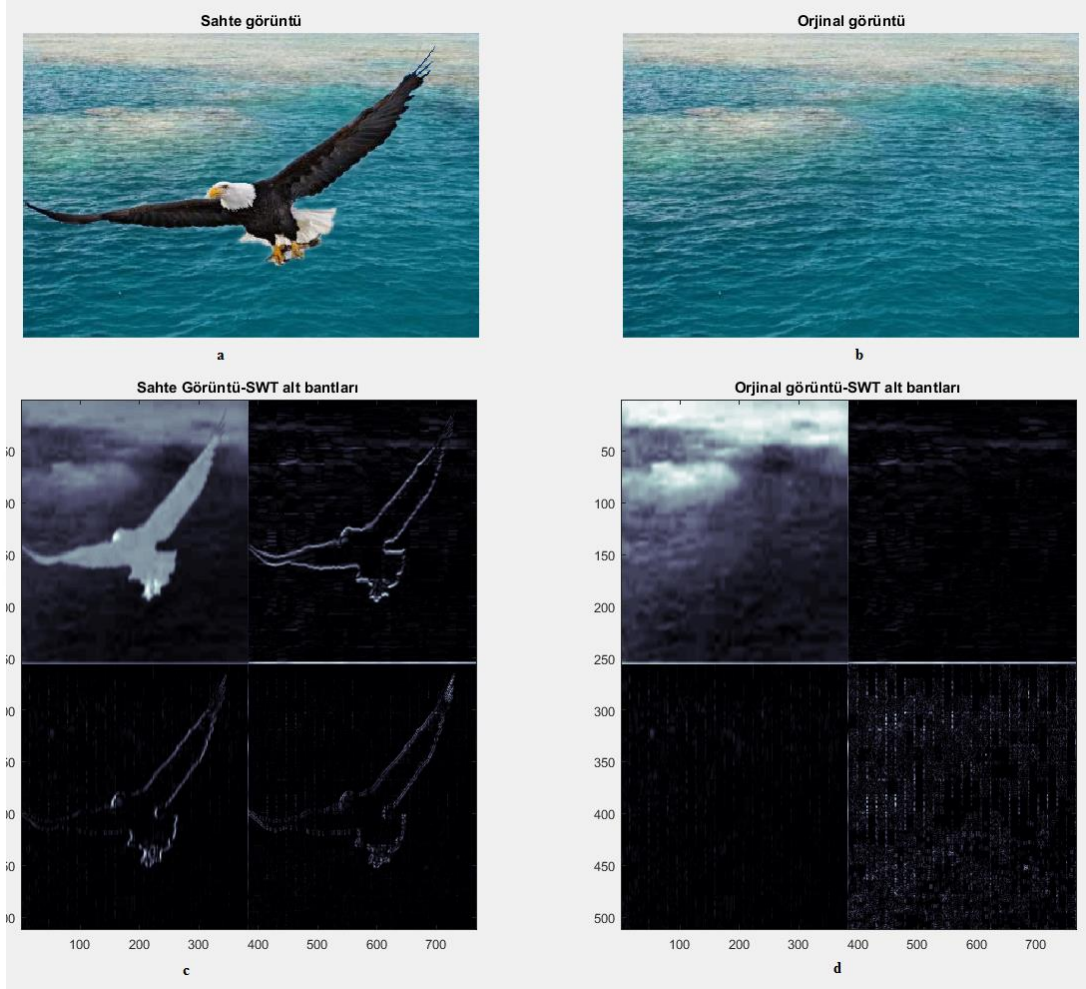
Şekil 3.23. (a) Orijinal görüntü, (b) Orijinal görüntü, (c) Sahte görüntü, (d) a ve c görüntülerinden önerilen yöntem-4 ile elde edilen dokusal tabanlı öznitelik vektörü, (e) a ve c görüntülerinden önerilen yöntem-4 ile elde edilen istatistiksel tabanlı öznitelik vektörleri

Görüntüdeki bozulmaları hibrit bir yaklaşımla değerlendiren çalışmada Markov modeli üzerinden elde edilen geçiş olasılık matrisleri, ele alınan görüntüdeki piksel

bağımlılıklarını yansıtmaktadır. Yöntemde SWT alt bantlarından elde edilen fark matrisleri, görüntüdeki ani değişimleri yansıtacaktır. Sahte görüntüye yapıştırılan eklemli bölge bir kenar oluşturacağından fark matrislerinde daha büyük değerlere karşılık gelmesi beklenir. GOM'ler (9)'da verilen ifade ile seçilen eşik değerine göre (-T,+T) arasındaki geçişlerin bir istatistiğini çıkarır. Matris elemanlarının Şekil 3.24'deki gibi olacağını düşündüğümüzde, matrisin (1,7) ve (7,1) indislerinde hesaplanacak olan geçiş, sırasıyla -3'ten +3'e ve +3'ten -3'e karşılık gelecektir. Bu da GOM'deki aradaki farkın en yüksek olduğu katsayılar arasındaki geçişin değerlendirilmesi anlamına gelmektedir. Dolayısıyla sahte görüntülerden elde edilen GOM'lerde matrisin sağ üst ve sol alt köşelerinde farklı bir karakter sergilemesi beklenmektedir. Şekil 3.25 (a,b)'de sırası ile sahte ve orijinal görüntüler görülmektedir. Bu görüntülerin SWT domen dönüşümünden elde edilen alt bantları Şekil 3.25 (c,d)'de verilmiştir. Şekil 3.25 (c)'de sahte görüntüden elde edilen alt bantlarda eklemli bölgenin kenarlarının vurgulandığı görülebilmektedir. Aşağıda Şekil 3.25 ve 3.27'de verilen örnek sahte ve orijinal görüntülerden elde edilen GOM'ler incelenecektir.

	-3	-2	-1	0	1	2	3
-3	(1,1)	.	.	.	.	.	(1,7)
-2	.						
-1	.						
0	.						
1	.						
2	.						
3	(7,1)	.	.	.	.	.	.

Şekil 3.24. Örnek bir GOM matrisi




Şekil 3.25. a) Sahte görüntü, b) Orijinal görüntü, c) Sahte görüntüden elde edilen SWT alt bantları, d) Orijinal görüntüden elde edilen SWT alt bantları

Önerilen yöntemde pikseller arasındaki durum geçişini modellemek için her bir SWT alt bandından yatay ( $F_h$ ) dikey ( $F_v$ ), ana köşegen ( $F_{mad}$ ) ve minör köşegende ( $F_{mid}$ ) fark matrisleri hesaplanmıştır. Yataydaki fark matrisinden yatay ve dikey geçiş olasılık matrisler ( $P_{hh}$ ,  $P_{hv}$ ), dikey fark matrisinden yatay ve dikey geçiş olasılık matrisi ( $P_{vh}$ ,  $P_{vv}$ ) ve köşegenel fark matrislerinden ( $P_{mad}$ ,  $P_{mid}$ ) GOM'ler elde edilmiştir. Şekil 3.26'te SWT domen LH bandından elde edilen GOM'lerin üç boyutlu gösterimi verilmiştir. Şekil 3.26-(a)'da yatay fark matrisinden elde edilen yatay ve dikey geçişlerin durum modeli verilmiştir. Sahte görüntüye ait GOM'lerin her ikisinde de (1,7) noktasında bariz bir kırılma olduğu görülmektedir. Orijinal görüntüden elde edilen  $P_{hh}$  modelinde bu indise karşılık gelen değer 0'a yakınsama gösterirken sahte görüntüden elde edilen  $P_{hh}$  modeli yukarı doğru bir kırılma göstererek 0.1 değerine yakınsamaktadır. Şekil 3.25-a'da verilen sahte görüntüde, yapıştırılan kartal görüntüsünün kenarlarının alt bantlarda oluşturduğu

kenarlar, yatayda elde edilen fark matrislerinde sınırlarda piksel deęerleri arasında bir fark oluřturmaktadır. Bu fark geiř olasılık matrisinde orijinal grntdekinden farklı bir karakter sergileyecektir.


Őekil 3.26-(b)'de rnek grntlerden elde edilen dikey fark matrisi zerinden (bir nevi dikey kenar grnts) hesaplanan durum geiř modelleri verilmiřtir. Orijinal grntde dikey fark matrisinden elde edilen yatay geiřler  $P_{hv}$  genel olarak matrisin orta kısmında yığılma yapmıřtır. GOM'nin orta blgesindeki indisler matris deęerlerine bakıldıęında (Őekil 3.24) piksel arasındaki fark deęerlerinin kk olduęu bunun da dřk frekans geiřlerine karřılık geldięi grlmektedir. Őekil 3.25-(b)'den de grleceęi zere deęerlendirilen orijinal grnt yksek frekans geiřlerine sahip deęildir. Őekil 3.25-(a)'da eklenen kartal grntsnn grntdeki dikey geiřler dikkate alındıęında da bir sapma meydana getirdięi Őekil 3.26-(b)'de grlmektedir.

Aynı Őekilde grntdeki dikey geiřlerin modellenmesine bakıldıęında orijinal deniz grntsnden elde edilen SWT LH alt bandında gze arpan bir geiř grlmemektedir. Bu grntye kartal grntsnn eklenmesi ile elde edilen sahte grntde ise grntye yeni eklenen kenarlara křegenel bakıldıęında da rastlanacaęından pikseller arasındaki geiřin křegenel olarak modellenmesi de orijinal grntden bir farklılık meydana getirmiřtir. nerilen yntemde SWT domen dięer alt bantlardan elde edilen GOM'lerin modellenmesi Ek Őekil.1-2'de verilmiřtir.




Şekil 3.26. Önerilen yöntemde [58] SWT domen LH bandında a) yatay fark matrisinden b) dikey fark matrisinden c) köşegenel fark matrisinden elde edilen GOM'ler

Şekil 3.26’da sahte görüntülerden elde edilen GOM’lerde izlenen katlanmalar, görüntüye eklenen bölgenin büyüklüğüne göre değişim gösterecektir. Eklenen bölgenin küçük olması durumunda GOM’lerdeki kırılmalar daha küçük, eklemli bölgenin büyük olması durumunda ise GOM’lerin kırılması daha büyük olacaktır. Şekil 3.27-(a)’da küçük bir eklemli bölgeye sahip sahte bir görüntü ve orijinal hali (b)’de verilmiştir. Şekil 3.28’de bu orijinal ve sahte görüntülerden elde edilen GOM’lerin modellenmesi görülmektedir.



Şekil 3.27. (a) eklemli sahte görüntü, (b) orijinal görüntü

Şekil 3.27 (a)’da verilen sahte görüntüde sol en altta futbol topu görüntüsü eklenmiştir. Eklenen top görüntüsü orijinal görüntüdeki GOM’de farklılık yaratacağından, görüntüden elde edilen GOM’lerde belirli sapmalar, GOM’lerin yüzeysel gösteriminde kırılmalar oluşturacaktır. Şekil 3.28 (a)’da görüntülerden yatay fark matrisinden elde edilen yatay ve dikey geçişler modellenmiştir.  $P_{hh}$  ile verilen yüzeysel gösterimden görüleceği üzere, sahte görüntüde (1,7) ve (7,1) indislerinde sahte görüntüde kırılmalar vardır. Aynı kırılmalar (sapmalar) Şekil 3.28 (c)’de köşegenel yönlerdeki geçişleri modelleyen  $P_{mad}$  ve  $P_{mid}$  geçiş olasılık matrislerinden de görülmektedir. Yöntemde diğer SWT alt bantlarından elde edilen GOM’lerde farklı ayrıntılar elde edileceğinden, farklı karakterler sergileyen GOM’ler gösterilmiştir (Ek Şekil 3.-4.).




Şekil 3.28. Önerilen yöntemde [58] SWT domen LH bandında a) yatay fark matrisinden b) dikey fark matrisinden c) köşegenel fark matrisinden elde edilen GOM'ler

### 3.5.1.2. Önerilen Yöntemin Performans Analizi

Birleştirme sahteciliğini hibrit bir yaklaşımla değerlendiren çalışmanın performans analizi CASIA v1.0, CASIA v2.0 ve Columbia veri setleri üzerinde değerlendirilmiştir. CASIA veri setlerinde farklı atak tipleriyle oluşturulmuş sahte görüntüler mevcuttur. Yöntemin bu görüntüler üzerinden farklı atak tiplerine karşı dayanıklılığı da test edilmiştir.

- CASIA v2.0 veri seti üzerinde farklı atak tiplerine karşı performans analizi: Önerilen yöntemin [58] CASIA v2.0 veri setindeki farklı atak tiplerine karşı olan görüntüler üzerinde performans analizi gerçekleştirilmiştir. Şekil 3.29’da gösterildiği üzere yöntem en yüksek doğruluk oranını %99.94 ile “dönüşüm yok” etiketi ile herhangi bir ön işlemeye tabi tutulmamış sahte görüntülerde elde etmiştir. Yöntem eklemli sahte görüntülerde %99.46 oranında doğruluğa sahiptir. Tüm atak tipleri için doğruluk oranları %98’in üstündedir.




Şekil 3.29. [58] ile önerilen yöntemin farklı atak tiplerine karşı CASIA v2.0’da gösterdiği performans

- Önerilen yöntemin JPEG sıkıştırma atağına karşı performans analizi: Farklı kalite faktörleri ile sıkıştırılmış sahte görüntüler üzerindeki sınıflandırma performansı yöntem üzerinde test edilmiştir. CASIA v1.0 veri setindeki sahte görüntüler, 5 ile 90 arasında kalite faktörüne kadar sıkıştırılıp tekrar kaydedilmesi ile farklı kalite faktöründe sahte görüntüler elde edilmiştir. Aynı işlem orijinal görüntüler için de uygulanmıştır. Sahte görüntülerin aynı veri setindeki orijinal görüntülerle birlikte



sınıflandırılarak önerilen yöntemin performans sonuçları Şekil 3.30'da verilmektedir. Şekil 3.30'da görüleceği üzere sıkıştırılma yapılmamış JPEG görüntülerde önerilen yöntemin doğruluk oranı %99.29 iken görüntüdeki sıkıştırma oranına bağlı olarak sınıflandırma performansında bir düşüş gözlemlenmektedir. Kalite faktörü düştükçe görüntüdeki sıkıştırma oranı artar. Bu, görüntüdeki yüksek frekans bileşenlerini sifıra yakınsamaya karşılık gelir. Yüksek frekans bileşenleri 0'a yakınsadıkça, görüntüden elde edilen bilgi oranı azalacaktır. Bu durumda elde edilen özelliklerin sınıflandırıcı tarafından ayırt ediciliği düşecektir.




Şekil 3.30. Önerilen yöntemde [58] farklı kalite faktörüne sahip JPEG görüntülerden elde edilen doğruluk oranları

- [58]'de önerilen yöntemin literatürdeki diğer yöntemlerle kıyaslanması: Bu deneylerde performans değerlendirmesi TPR, TNR ve doğruluk ölçütleri ile yapılmıştır. Tablo 3.10 benzer çalışmaların sınırlamalarına ek olarak, üç veri seti üzerinde doğruluk sonuçlarını göstermektedir. Şekil 3.31 CASIA v1.0 ve CASIA v2.0'ın ortalama hassasiyet, özgüllük ve doğruluk oranlarının performans karşılaştırmasını göstermektedir.

TPR terimi, bu çalışmalardaki orijinal görüntülerin doğru sınıflandırma oranını, yani doğru pozitif oranını göstermektedir. Şekil 3.31’de görüleceği üzere Agarwal ve Chand [18] %98.47’lik bir ortalamayla CASIA veri setlerinde en yüksek ortalama doğruluk oranına, Alahmadi vd. [19] %97.67 ile ikinci en yüksek doğruluk oranına sahiptir. Önerilen yöntem CASIA veri setinin ikisinde ortalama % 99.04 TPR oranı elde etmiş, bu da önerilen yöntemin sahte olmayan (orijinal) görüntüleri tespit etmede biraz daha düşük bir performansa sahip olduğu anlamına gelmektedir.

TNR terimi, sahte görüntülerin doğru sınıflandırılma oranı yani doğru negatif oranı için kullanılır. Önerilen yöntem CASIA veri setlerinde en yüksek ortalama TNR oranına (%99.79), Shen vd. [20] ikinci yüksek ortalama TNR oranına (%97.6) sahiptir. Önerilen yöntem, sahte görüntülerin tespit etmede daha başarılıdır.



Şekil 3.31. Literatürdeki benzer yöntemlerle CASIA v1.0 ve CASIA v2.0 veri seti üzerinde elde edilen ortalama TNR, TPR ve doğruluk oranlarının karşılaştırılması

Tablo 3.12. [58] ile önerilen yöntemin farklı veri setleri üzerinde diğer yöntemlerle birlikte performans analizi


	Yöntem	Öznitelik Seçme	İstatistiksel Öznitelikler	Dokusal Öznitelikler	Öznitelik Vektör Uzunluğu	Veri Setleri			Farklı atak tiplerine karşı dayanıklılık testi
						CASI A v1.0	CASI A v2.0	Columbia (renkli)	
[15]	SPT+LBP	✓	-	✓	3584 (475)	94.89	97.33	96.39	✓
[18]	Entropi + LPQ	-	-	✓	2048	95.41	98.33	91.14	-
[23]	DCT+DWT+ Markov	✓	✓	-	6642 (100)	-	89.76	-	-
[27]	QDCT+ Markov	-	✓	-	972	96.43	92.38	-	-
[20]	TF-GLCM	-	-	✓	96	98.54	97.73	-	-
[22]	SWT+ RICLBP	-	-	✓	408	96.81	-	92.31	-
[19]	LBP+DCT	-	-	✓	-	97.0	97.50	97.77	-
[21]	SPT+LBP, LPQ,BSIF, BGP	-	-	✓	19680 (700)	94.13	97.03	92.01	✓
<b>Önerilen Yöntem-4</b>	SWT+Markov SWT+ TF.	-	✓	✓	1004	<b>99.24</b>	<b>99.64</b>	<b>98.55</b>	✓

Önerilen yöntem doğrulama performansı açısından da literatürdeki benzer çalışmalarla karşılaştırılmıştır ve sonuçları Tablo 3.12'de gösterilen üç veri seti için değerlendirilmiştir. En iyi doğruluk oranı CASIA v1.0'da önerilen yöntemde % 99.29 ile elde edilirken, Shen vd. [20] aynı veri setinde % 98.54 doğruluk oranına sahiptir. Tablo 3.12'de görüleceği üzere sadece dokusal özniteliklerin kullanıldığı çalışmalarda CASIA v1.0'da % 94 ile % 98 arasında bir doğruluk oranı elde edilirken, hibrit özniteliklerin (istatistiksel ve dokusal) kullanılması sistemin performansını yaklaşık olarak % 99'a yükseltmiştir. Benzer bir sonuç, sadece istatistiksel öznitelikleri kullanan yöntemlerde de elde edilmiştir. Örneğin, Li vd. [27] yaptıkları çalışmada % 96.43 doğruluk oranı elde ederken hibrit bir yaklaşım sunan önerilen yöntem % 99.29 doğruluk oranı elde etmiştir.

CASIA v2.0 veri setinde, önerilen yöntem Tablo 3.12'de gösterildiği gibi % 99.58 ile en yüksek doğruluk oranına sahiptir. Aynı veri seti üzerinde Agarwal ve Chand [18] (yalnızca dokusal öznitelikleri kullanan) % 98.33 doğruluk oranıyla ikinci en yüksek doğruluk oranını elde etmiştir. CASIA v2.0 veri seti üzerinde, dokusal veya istatistiksel özniteliklerin ayrı ayrı kullanıldığı yöntemler, hibrit özniteliklerin kullanılmasından (istatistiksel ve dokusal) daha düşük bir doğruluk oranı elde etmiştir. Hibrit yöntem,


Columbia veri setinde %98.55 doğruluk oranına ulaşmaktadır. Alahmadi vd. [19], Columbia veri seti için ikinci en yüksek doğruluk oranı % 97.77'yi elde etmiştir.

Başka bir değerlendirme kriteri öznelik vektörü boyutu olarak düşünülebilir. Daha yüksek vektör boyutu daha yüksek hesaplama karmaşıklığı anlamına gelse de, bu en iyi vektör boyutunun en küçük olduğu anlamına gelmez. İstatistiksel ve dokusal öznelikleri bir arada kullanmak, önerilen yöntemin öznelik vektörünü artırmıştır. Yapılan çalışma, Şekil 3.32'de görülebileceği gibi en küçük vektör boyutuna sahip değildir, ancak en yüksek doğruluk oranına ulaşmıştır. Shen vd. [20] en küçük öznelik vektör boyutuna ve % 99'un altında bir doğruluk oranına sahiptir. Şekil 3.32'deki diğer yöntemler önerilen yöntemden [58] daha küçük öznelik vektör boyutlarına sahip olmalarına rağmen, daha düşük doğruluk oranlarına sahiptirler.



Şekil 3.32. Öznelik vektör boyutunun literatürdeki diğer yöntemlerle kıyaslanması

Bir başka değerlendirme, yöntemlerin farklı atak tiplerine karşı elde ettiği doğruluk oranları üzerinden yapılmıştır. Şekil 3.33'de görüleceği üzere önerilen yöntem literatürdeki iki farklı çalışmayla ([15,21]) karşılaştırılmıştır. Önerilen yöntem “birleştirme”, “kopyala taşı”, “döndürme”, “ölçeklendirme” ve “deformasyon” atak tiplerine karşı benzer yöntemlere kıyasla daha yüksek doğruluk oranına sahiptir.



Şekil 3.33. [58]'te önerilen yöntemin çalışma [15] ve [21] ile CASIA v2.0 veri seti üzerinde farklı atak tipleri için performans analizi

### 3.6. Farklı Sınıflandırıcıların Kullanılması ile Sahte Görüntülerin Tespiti ve Elde Edilen Deneysel Sonuçlar

Önerilen yöntemleri literatürdeki yöntemlerle aynı zeminde kıyaslayabilmek için, SVM sınıflandırıcı kullanılmıştır. Tez kapsamında yapılan çalışmada önerilen yöntemlerin sınıflandırma performansları farklı sınıflandırıcı olarak KNN ile de değerlendirilmiş ve raporlanmıştır.

Seçilen çekirdek fonksiyonu ile sınıfları ayıracak hiper düzlem belirleneceği için, sigma parametresinin en uygun değeri 10 katlı çapraz doğrulama ile belirlenmiştir. Tablo 3.13'de görüntü sahteciliğini hibrit yaklaşımla tespit eden yöntem [58] için uygun 0.125-128 arasında değişen sigma parametreleri ile yöntemin sınıflandırma performansı verilmiştir.

SVM ile sistemin performansını belirlemek için 10 katlı çapraz doğrulama kullanılmıştır. SVM'de kullanılan ve ifade (15)'de verilen çekirdek fonksiyondaki sigma parametresinin en uygun değerini belirlemek için, bu parametre  $2^{-3}$ - $2^7$  arasında değiştirilerek 10 katlı sınıflandırmada elde edilen doğruluk oranlarının ortalaması alınarak her bir sigma parametresi için ortalama doğruluk oranı hesaplanmıştır. Maksimum ortalama doğruluk oranını veren sigma değeri bu problem için sınıflandırıcıda kullanılacak olan değer olarak belirlenmiş olur.

Kullanılan her iki sınıflandırıcıda ilgili yöntem performansının değerlendirilmesi için 10 katlı çapraz doğrulama yapılmıştır. Tablo 3.14'de görüleceği üzere KNN için her bir katta komşu sayısı 1'den başlayarak 15'e kadar artırılmıştır. 10 katlı doğrulamada, KNN'deki her bir komşu sayısı için her bir katta elde edilen doğruluk oranının ortalaması alınmış ve maksimum doğruluk oranına sahip komşu sayısı ile sistemin kaç k komşuluğu seçilerek sınıflandırılacağı belirlenmiştir.

Yapılan çalışmalarda SVM sınıflandırıcıda kullanılan çekirdek fonksiyonu radyan temel fonksiyonudur (Radial basis function-rbf). SVM'nin temelde (14)'deki ifade ile verilebilir.

$$f(x) = \sum_{i=1}^n \alpha_i k(x, x_i) + b \quad (25)$$

Buradaki k, çekirdek fonksiyondur ve yöntemde SVM'de kullanılan rbf fonksiyonu için (15) ile verilen şekilde ifade edilir.

$$k(x, x') = \exp\left(-\frac{\|x-x'\|^2}{2\sigma^2}\right) \quad (15)$$

Burada verilen sigma ( $\sigma$ ) genellikle Gauss dağılımında tanımlandığı gibi standart sapmadır ve Gauss dağılımının genişliğini belirler. Seçilen çekirdek fonksiyonu ile sınıfları ayıracak hiper düzlem oluşturulacağı için,  $\sigma$  parametresinin en uygun değeri 10 katlı çapraz doğrulama ile belirlenmiştir. Tablo 3.13'de [58] ile önerilen yöntem için uygun 0.125-128 arasında değişen  $\sigma$  parametreleri ile yöntemin sınıflandırma performansı verilmiştir.

Tablo 3.13. [58] ile önerilen yöntemin sınıflandırmasında CASIA v1.0 veri seti üzerinde uygun sigma değerinin belirlenmesi

Rbf çekirdeği için ( $\sigma$ ) parametresi	10 katlı çapraz doğrulama										Ortalama doğruluk (%)
	Kat 1	Kat 2	Kat 3	Kat 4	Kat 5	Kat 6	Kat 7	Kat 8	Kat 9	Kat 10	
0.125	53.80	54.07	53.48	53.80	53.48	54.43	53.48	53.48	53.80	54.12	53.79
0.25	53.80	54.07	53.48	53.80	53.48	54.43	53.48	53.48	53.80	54.12	53.79
0.50	53.80	54.07	53.48	53.80	53.48	54.43	53.48	53.48	53.80	54.12	53.79
1	53.80	54.07	53.48	53.80	53.48	54.43	53.48	53.48	53.80	54.12	53.79

Tablo 3.13'ün devamı

Rbf çekirdeği için ( $\sigma$ ) parametresi	10 katlı çapraz doğrulama										
	Kat 1	Kat 2	Kat 3	Kat 4	Kat 5	Kat 6	Kat 7	Kat 8	Kat 9	Kat 10	Ortalama doğruluk oranı (%)
2	53.80	54.07	53.48	53.80	53.48	54.43	53.48	53.48	53.80	54.12	53.79
4	60.23	61.05	63.37	59.06	61.04	58.72	58.72	59.30	59.65	61.17	60.23
8	84.79	88.30	88.37	86.55	87.79	83.72	83.72	87.21	86.55	85.29	86.23
16	96.49	98.83	100	96.49	97.67	97.09	98.25	98.25	97.66	96.47	97.72
32	<b>98.24</b>	<b>100</b>	<b>100</b>	<b>98.93</b>	<b>99.58</b>	<b>98.83</b>	<b>99.56</b>	<b>100</b>	<b>99.68</b>	<b>98.62</b>	<b>99.24</b>
64	97.66	98.24	100	98.24	98.83	97.09	99.41	100	99.42	97.64	98.65
128	97.66	97.07	98.83	96.49	98.25	95.93	97.67	98.25	97.66	96.47	97.43

Tablo 3.13'de görüldüğü üzere SVM sınıflandırıcıda kullanılan parametreye ( $\sigma$ ) bağlı olarak ayırma düzlemi değişikçe sınıflandırma doğruluk oranı da değişmektedir. 10 katlı çapraz doğrulama ile her bir  $\sigma$  değeri için elde edilen performans neticesinde [58] ile önerilen yöntem için sigma ( $\sigma$ ) parametresi 32 olarak belirlenmiştir.

Önerilen yöntemde elde edilen öznitelik vektörlerinin başka bir sınıflandırıcıda performansını değerlendirmek için KNN sınıflandırıcı seçilmiştir. KNN algoritması ile sınıflandırma yaparken en yakın k-komşu dikkate alınır. KNN ile sınıflandırmada seçilecek olan komşuluk sayısının iyi belirlenmesi gerekir, çünkü seçilen komşu sayısı sınıflandırıcının performansını değiştirecektir. Tablo 3.14'de [58] ile önerilen yöntemde elde edilen öznitelikler farklı bir sınıflandırıcı olarak KNN sınıflandırıcısına verilmiştir.

Tablo 3.14. [58] ile önerilen yöntemin KNN ile sınıflandırmasında CASIA v1.0 veri seti üzerinde uygun K değerinin belirlenmesi

Komşu sayısı	10 Katlı Çapraz Doğrulama										
	Kat 1	Kat 2	Kat 3	Kat 4	Kat 5	Kat 6	Kat 7	Kat 8	Kat 9	Kat 10	Ortalama doğruluk oranı (%)
1	93.02	95.38	94.76	97.09	93.60	94.76	91.86	91.86	94.76	94.76	94.18
2	91.86	92.48	94.76	96.51	92.44	94.18	90.11	90.11	93.02	93.02	92.84
3	92.44	95.37	97.09	97.09	94.76	95.93	92.44	91.86	95.93	95.93	85.13
4	92.44	94.21	95.93	97.67	94.76	93.60	90.11	91.27	96.51	96.51	94.30
5	<b>92.44</b>	<b>96.53</b>	<b>94.76</b>	<b>97.67</b>	<b>96.51</b>	<b>94.76</b>	<b>93.02</b>	<b>95.34</b>	<b>95.34</b>	<b>95.34</b>	<b>95.17</b>
6	93.60	94.79	94.18	98.25	94.76	93.02	93.06	93.60	95.34	95.34	94.59
7	93.02	96.53	94.76	97.09	95.93	94.18	93.02	95.34	94.76	94.76	94.94
8	94.18	95.37	95.34	98.25	94.18	93.60	93.02	95.34	95.93	95.93	95.11

Tablo 3.14'ün devamı

Komşu sayısı	10 Katlı Çapraz Doğrulama										Ortalama doğruluk oranı (%)
	Kat 1	Kat 2	Kat 3	Kat 4	Kat 5	Kat 6	Kat 7	Kat 8	Kat 9	Kat 10	
9	93.02	96.53	95.34	97.09	94.18	94.76	94.18	94.76	95.34	95.34	95.05
10	92.44	95.95	93.60	97.09	94.76	94.76	93.60	95.34	95.34	95.34	94.82
11	92.44	96.53	94.18	97.09	95.34	93.02	94.18	95.93	94.76	94.76	94.82
12	93.02	95.37	93.02	95.93	94.76	94.76	94.18	96.51	95.34	95.34	94.82
13	92.44	96.53	93.02	95.93	93.60	94.18	93.02	97.67	94.76	94.76	94.59
14	92.44	95.37	93.60	95.34	94.76	94.18	92.44	95.93	94.18	94.18	94.24
15	93.02	93.02	95.95	95.93	95.93	94.18	91.86	95.93	94.18	94.18	94.41

KNN ile sınıflandırma performansında seçilen komşu sayısının etkisinin araştırılmasında 10 katlı çapraz doğrulamanın her bir iterasyonunda  $k=1$  ile 15 arasındaki her bir değer için sınıflandırma doğruluk oranı alınmıştır. 10 iterasyonun sonucunda her bir  $k$  değeri için elde edilen doğruluk oranının ortalama değeri hesaplanarak 15 farklı  $k$  değeri için 10 iterasyondan elde edilen ortalama doğruluk oranları hesaplanmıştır. Bu doğruluk oranları arasındaki maksimum doğruluk oranını veren  $k$  değeri sistemin KNN'deki komşu sayısı olarak belirlenmiştir. [58] ile önerilen yöntem CASIA v1.0 veri seti üzerinde  $k=5$  seçilerek %95.17 doğruluk oranı elde etmiştir.

Bundan sonraki sınıflandırıcıların performans değerlendirmesinde SVM ile sınıflandırmada ( $\sigma$ )=32 ve KNN ile sınıflandırmada  $k=5$  olarak seçilmiştir. Yöntemin farklı sınıflandırıcılara ait diğer veri setleri üzerindeki performans değerlendirmesi Tablo 3.15'te verilmiştir. Tablo 3.15'te görüleceği gibi, sınıflandırma işleminde aynı öznelik vektörleri kullanılmasına rağmen farklı sınıflandırıcılar farklı performans sergilemektedir. CASIA v2.0 veri seti üzerinde SVM ile sınıflandırmada 0.16'lık bir standart sapma ile %99.58 doğruluk oranı elde edilmiştir. Burada verilen standart sapma değeri, sistemin 10 katlı çapraz doğrulama ile elde ettiği 10 farklı doğruluk oranının ortalamasını alırken, bu 10 farklı sınıflandırma sonucunun standart sapmasını vermektedir. Yani standart sapma değeri ne kadar küçük olursa sistemin o kadar kararlı olduğu görülür. Aynı veri seti üzerinde KNN ile sınıflandırmada elde edilen doğruluk oranı ise %0.31'lik bir sapma ile %99.08'dir. Columbia veri seti üzerinde yapılan sınıflandırıcıların performans değerlendirmesinde SVM ve KNN sınıflandırıcıları karşılaştırdığımızda SVM



sınıflandırıcısının yaklaşık %2 daha yüksek doğruluk oranı ile %97.99'luk bir oran elde ettiğini görülmektedir.

Tablo 3.15. [58]'deki yöntemin üç farklı veri seti üzerinde farklı sınıflandırıcılarda elde ettiği performans değerlendirmesi

	SVM		KNN	
	Doğruluk Oranı (%)	Standart Sapma	Doğruluk Oranı (%)	Standart Sapma
CASIA v1.0	99.24	±0.58	95.17	±1.58
CASIA v2.0	99.64	±0.27	99.08	±0.31
Columbia	98.55	±2.13	95.78	±3.15

Sınıflandırma performans karşılaştırmasında literatürdeki yöntemlerle karşılaştırmada ortak zemin oluşturmak için önerilen yöntemlerin sonuçları da 10 katlı çapraz doğrulama ile verilmiştir. Yapılan çalışmalarla tez kapsamında önerilen dört yöntemin “10-katlı Çapraz Doğrulama” ve “Rastgele Alt Örnekleme Çapraz Doğrulama” sonuçları her üç veri seti için Tablo 3.16’da verilmiştir. “Rastgele Alt Örnekleme İle Çapraz Doğrulama” sonuçlarının elde edilmesi için Şekil 3.5’te gösterildiği gibi veri seti 2 alt kümeye bölünmüş ve ilk alt küme üzerinden sınıflandırıcı parametreleri belirlenmiştir. Bu parametreler ile ikinci alt küme test edilerek sınıflandırıcıdan bir doğruluk oranı elde edilmiştir. Bu işlem 20 kez tekrarlandıktan sonra, ortalama doğruluk oranı hesaplanarak yöntemin performansı belirlenmiştir.

Tablo 3.16. Sınıflandırmada farklı yaklaşımların sınıflandırma performansına etkisinin araştırılması

		Önerilen Yöntem-1	Önerilen Yöntem-2	Önerilen Yöntem-3	Önerilen Yöntem-4
<b>CASIA v1.0</b>	10 katlı çapraz doğrulama	98.93	99.98	99.15	99.24
	Rastgele alt örnekleme çapraz doğrulama	98.19	99.43	99.03	98.28
<b>CASIA v2.0</b>	10 katlı çapraz doğrulama	99.77	99.89	99.60	99.64
	Rastgele alt örnekleme çapraz doğrulama	98.81	99.41	99.13	98.84

Tablo 3.16'nın devamı

		<b>Önerilen Yöntem-1</b>	<b>Önerilen Yöntem-2</b>	<b>Önerilen Yöntem-3</b>	<b>Önerilen Yöntem-4</b>
<b>Columbia</b>	10 katlı çapraz doğrulama	97.24	98.92	99.29	98.55
	Rastgele alt örnekleme çapraz doğrulama	96.11	98.11	99.09	96.37



#### 4. SONUÇLAR

Son yıllardaki cep telefonu, dijital fotoğraf makineleri ve kamera teknolojisindeki gelişim ve kullanımının yaygınlaşması, sayısal görüntülerin her alanda kullanımını ve erişim kolaylığını desteklemiştir. Aynı zamanda sayısal görüntüler üzerinde değişiklik yapmayı sağlayan ve kolaylaştıran açık kaynak kodlu yazılımların da yaygınlaşması bu sayısal görüntüler üzerinde değişiklik yapılabilmesini kolaylaştırmıştır. Görüntü üzerinde değişikliğe olanak sağlayan bu yazılımlar, kullanım niyetine bağlı olarak iyi ya da kötü amaçla kullanılabilir. Masum bir şekilde sayısal bir görüntünün netliğini artırmak, gürültüsünün etkisini azaltmak gibi değişiklikler yapılacağı gibi, kötü niyetli olarak, olmayan bir olayı olmuş gibi gösterme amaçlı görüntüye sonradan bir parça ekleme, ya da var olan bir nesneyi kapatma veya var olan nesnelere çoğullama gibi sahteciliklerin yapılması da olasıdır. Dolayısıyla sayısal görüntülerin içeriğinin değişmediğinin ve doğruluğunun ispatlanması için araştırmacılar tarafından önerilen çeşitli yöntemler bulunmaktadır. Bu yöntemler aktif ve pasif yöntemler olmak üzere ikiye ayrılmaktadır. Aktif yöntemler görüntünün doğrulanması için önceden bilinen bir bilgiye ihtiyaç duyarken (sayısal imza ve damgalama gibi), pasif yöntemler mevcut görüntü üzerinden elde edilen bilgileri kullanarak görüntüyü doğrulamayı hedefler. Bu özelliğinden dolayı özellikle adli delil olarak kullanılacak sayısal görüntülerin doğrulanması pasif yöntemlerin kullanılmasını zorunlu kılmış ve söz konusu yöntemler bu alanda tek çözüm yolu haline gelmiştir.

Literatürde görüntü sahteciliği tespiti alanında yapılan çalışmalar yaygın olarak kopyala-taşı sahteciliği tespiti ve görüntü birleştirme/ekleme sahteciliği tespiti başlığı altında toplanmaktadır. Tez süresince görüntü birleştirme sahteciliği tespiti üzerinde çalışmalar yapılmış olup, sayısal görüntülerin adli delil teşkil etme özelliğinden dolayı temel hedef olarak görüntü doğrulama oranının %100' e yakın bir oranda sağlanması üzerinde durulmuştur. Görüntü birleştirme sahteciliği tespiti üzerinde diğer hedeflenen iyileştirmeler; hesaplama karmaşıklığının azaltılması, farklı ön işlemeyle dayalı sahtecilik ataklarına karşı (döndürme, ölçekleme, deformasyon gibi) dayanıklılığının artırılması ve önerilen yöntemlerle bu hedeflere ulaşılmıştır. Bu hedefler doğrultusunda önerilen birleştirme sahteciliği tespit yöntemleri ve elde edilen sonuçlar kısaca aşağıdaki şekilde özetlenebilir:

1. Görüntüdeki piksellerin her birini bir durum olarak değerlendirerek bu durumlar arasındaki geçişin modellenmesinin sağlanması ve aynı zamanda hesaplama karmaşıklığının da azaltılması için DWT domen düşük frekanslı alt bant üzerinde dört yönlü Markov modeli kullanılarak sahtecilik tespiti amaçlanmıştır. Yöntem literatürde durum geçiş modelini kullanan diğer yöntemlere göre [23-29] daha yüksek doğruluk oranı elde etmektedir. Bu çalışmalar arasında [23,25] kendi çalışmasında belirttiği doğruluk oranını elde edebilmek için ekstra bir işlem olarak öznitelik seçme algoritmasına gerek duymuştur. Önerilen yöntemde [56] elde edilen sınıflandırma performansı için başka ek bir işleme gerek duyulmamıştır. Ayrıca Yöntem DWT domen LL bantta öznitelik çıkarımı yaptığı için hesaplama karmaşıklığını da azaltmıştır.
2. Görüntüdeki sahteciliği tespit etmek için görüntüdeki istatistiksel özniteliklerdeki sapmaları dikkate alan bir diğer yöntem DCT domen HF katsayıları üzerinden bir durum modellemesi önermiş, HF katsayılarının ifade ettiği anlamı daha geniş bir perspektifte değerlendirebilmek adına seçilen HF katsayıları belirlenmiş bir değerle kuantalanmıştır. Önerilen yöntem her bir 8x8'lik bloğa DCT uyguladıktan sonra zigzag tarama ile aldığı 16 HF katsayısını 4x4'lük bir matrise dönüştürerek elde ettiği temsili HF görüntü üzerinden bir durum modellemesi yapmış, bu da yine görüntü boyutunu  $1/4$  oranında azalttığı için hesaplama karmaşıklığını azaltmıştır. Yöntem literatürde görüntüdeki istatistiksel öznitelikleri durum geçiş modellemesi ile değerlendiren diğer yöntemler [23-29] arasında doğruluk oranını iyileştirilmiştir. Yöntemin bir diğer avantajlarından biri elde edilen yüksek sınıflandırma performansı için ekstra bir öznitelik seçme algoritmasına ihtiyaç duyulmamasıdır.
3. Görüntü birleştirme sahteciliği tespitinde görüntüdeki yapıştırılan bölgenin görüntünün dokusal yapısında deformasyona sebep olacağı düşüncesi ile görüntünün dokusal özniteliklerinin değerlendirildiği bir diğer yöntem, görüntü üzerinde gri seviyeli eş-oluşum matrislerinden elde edilen dokusal istatistikleri değerlendirmiştir. Yöntem birçok frekans domeni üzerinde uygulanmış ve en yüksek performans elde eden frekans domeni (Hilbert) seçilmiştir. Yapıştırılan bölgedeki değişimi dokusal olarak değerlendirirken değişikliğin bir yansıtıcısı olarak gri seviyeli eş oluşum matrislerinin dört yönlü varyansının standart sapması hesaplanmıştır. Bu matrislerin her birinin entropi değeri ve yerel ikili örüntü

histogramı da kullanılan dokusal özniteliklerdir. Literatürde yapılan çalışmaların hemen hemen hepsinde renk uzayı olarak YCbCr uzayı kullanılırken, önerilen yöntem Lab renk uzayından elde edilen öznitelikleri de değerlendirmiştir. Literatürde dokusal öznitelikleri kullanarak birleştirme sahteciliği yapılan çalışmalara bakıldığında [14-22] ortalama elde edilen doğruluk oranı %98'in altındadır. Önerilen yöntem dokusal öznitelik tabanlı bu yöntemlerin doğruluk oranında iyileştirme yapmıştır. Yöntem CASIA v1.0 ve CASIA v2.0 üzerinde farklı atak tipleri üzerinde test edilmiş ve %100'e yakın bir performans göstererek farklı atak tiplerine karşı dayanıklılığını göstermiştir.

4. Görüntü birleştirme sahteciliği tespitinde uzaysal ve frekans domeninde görüntünün dokusal ve istatistiksel öznitelikleri değerlendirilmiştir. Literatürde ilk kez dokusal ve istatistiksel özniteliklerin hibrit bir yaklaşımla sunulduğu bir yöntem önerilmiştir. Yöntemde SWT domende çalışılmıştır ve yöntem literatürde dokusal öznitelikleri [14-22] veya istatistiksel öznitelikleri [23-32] ayrı kullanan yöntemlerin tümünden daha yüksek doğruluk oranına sahiptir. Yöntem elde ettiği yüksek doğruluk performansı için herhangi bir öznitelik seçme algoritmasına ihtiyaç duymamıştır. Yöntemin avantajlarından biri de farklı atak tiplerine karşı dayanıklı olmasıdır.

Tablo 4.1. Tez kapsamında önerilen yöntemlerin literatürdeki yöntemlerle kıyaslanması

Yöntem	Öznitelikler	CASIA v1.0	CASIA v2.0	COLUMBIA (renkli/gri)
[15]	SPT+LBP	94.89	97.33	96.39
[16]	Gabor+DCT	96.21	97.9	-
[17]	Entropi+WLD	93.33	-	-
[20]	TF-GLCM	98.54	97.73	-
[18]	Entropi + LPQ	95.41	98.33	91.14
[19]	LBP+DCT	97.0	97.50	97.77
[21]	SPT+LBP, LPQ,BSIF,BGP	94.13	97.03	92.01
[22]	SWT+ RICLBP	96.81	-	92.31
[23]	Markov (DCT+DWT)	-	89.76	-
[26]	Markov(DMWT)	-	-	93.36 (gri)
[27]	Markov (QDCT)	96.43	92.38	-
[25]	Markov (uzaysal+DCT)	-	-	98.82 (gri)
[30]	Markov (Countourlet + DCT)	-	-	94.10
[31]	Markov (3. seviye DWT)	-	-	89.93
[29]	Markov (Kuantalama)	98.95	97.28	95.24

Tablo 4.1'in devamı

Yöntem	Öznitelikler	CASIA v1.0	CASIA v2.0	COLUMBIA (renkli/gri)
[32]	Markov (DCT-LF)	-	96.90	-
Önerilen Yöntem 1	Markov (DWT-LL)	<b>99.98</b>	<b>99.89</b>	<b>98.92</b>
Önerilen Yöntem 2	Markov (DCT-HF)	<b>99.29</b>	<b>99.58</b>	<b>97.99</b>
Önerilen Yöntem 3	GlcM, var., entropy, lbp	<b>99.15</b>	<b>99.60</b>	<b>99.29</b>
Önerilen Yöntem 4	SWT( Hibrit)	<b>99.24</b>	<b>99.64</b>	<b>98.55</b>

Tez çalışmasında görüntü birleştirme sahteciliği tespitinde, gelen bir test görüntüsünün doğrulanması aşamasında görüntünün doğru olarak sınıflandırma performansının yükseltilmesi, hesaplama karmaşıklığının azaltılması ve yöntemin farklı atak tiplerine karşı dayanıklılık göstermesi problemlerinin giderilmesini hedefleyen yeni yöntemler önerilmiştir. Literatürdeki yöntemlerde elde edilen doğruluk oranlarına bakıldığında sahte ve orijinal görüntüleri sınıflandırmada en yüksek doğruluk oranının CASIA v1.0 veri seti üzerinde %98.95 ile [29]'daki çalışmada elde edildiği görülmektedir ancak bu çalışma CASIA v2.0 veri setinde yaklaşık olarak %97 oranında bir performansa sahiptir. Tablo 4.1'deki veri setleri içinde en güçlü veri seti CASIA v2.0'dır ve bu çalışma bu veri seti üzerinde yeterince etkili olamamaktadır. Tablodaki diğer yöntemlere bakıldığında çalışmaların birçoğu CASIA v2.0 veri setini performans değerlendirmesi için tercih etmemiştir. Bu durum ise önerilen yöntemlerin performans değerlendirmesini eksik bırakmaktadır. Tez çalışmasında önerilen yöntemler ile literatürde kullanılan veri setleri arasında en kapsamlı sayılan ve ön işleme tabi tutulmuş verilerin de olduğu CASIA v2.0 veri seti üzerinde % 99.50'nin üzerinde doğrulama performansı elde edilmiştir. Bu oran neredeyse bütün görüntülerde doğrulamayı sağlayacak bir performans anlamına gelmektedir. Aynı sonuç diğer veri setleri için de geçerlidir. Sayısal görüntülerin doğrulanmasının adli açıdan da önem teşkil ettiği göz önünde bulundurulduğunda, önerilen yöntemlerle elde edilen doğrulama oranlarının adli delil olarak kullanılan/kullanılacak görüntülerin doğrulanması için yeterli sayılabilecek bir performans olarak değerlendirilmesi mümkündür.

## 5. ÖNERİLER

Sayısal görüntülerin doğrulanması, literatürde bir çalışma konusu olarak önemli bir yere sahiptir. Özellikle 2004 yılından sonra görüntü sahteciliği alanında birçok çalışma yapılmış, bu çalışmalar arasında görüntü birleştirme sahteciliğini tespit eden çalışmalar 2009 yılından sonra artış göstermiştir. Son yıllara doğru da görüntü birleştirme sahteciliği tespitinde yapılan çalışma sayısında büyük bir artış gözlenmektedir. Bu alandaki çalışmaların ivmelenmesi ayrıca konunun önemini ve araştırma potansiyelinin yüksekliğini göstermektedir.

Görüntü birleştirme sahteciliğinin tespitinde yapılan çalışmalar genel olarak görüntüyü sahte veya orijinal olarak sınıflandıran yöntemler ve görüntüdeki eklemli bölgenin lokalizasyonunu sağlayan çalışmalar olarak iki gruba ayrılabilir. Tez kapsamında yapılan çalışma ilk gruptaki çalışmalar arasında değerlendirilmektedir. Görüntüden elde ettiği öznitelikler ve bir sınıflandırıcı yardımı ile görüntüleri sahte ve orijinal olarak sınıflandıran bu çalışmalarda elde edilen sınıflandırma performansı genel olarak %98'in altındadır, hatta bu orana ulaşan çalışma sayısı da azdır. Sınıflandırma performansını artırmak için görüntüdeki istatistiksel ve dokusal bozulmaları birlikte değerlendiren hibrit yaklaşımlar doğruluk performansını artıracaktır. Görüntüden daha fazla ayrıntı elde edebilmek için görüntüyü farklı frekans bantları veya farklı ölçek ve yönlendirmelerle alt bantlara ayırmak avantaj sağlayacaktır. Bu alt bantlardan elde edilen öznitelik kombinasyonlarının ayrı ayrı değerlendirilmesi, yöntem için en alt iyi senaryoyu belirlemeye yardımcı olacaktır. Önerilen yöntemde belirli bir renk uzayında çalışmak yerine farklı renk uzaylarından öznitelikler elde ederek bu renk uzayı ve kanallarının değerlendirilmesi de yöntemdeki görüntüyü en iyi temsil edebilecek öznitelik vektörlerinin elde edilmesini sağlayacak, görüntünün karakteristiğini en iyi şekilde yansıtmaya yardımcı olacaktır.

Görüntüden öznitelik çıkarma aşamasında görüntünün boyutundan bağımsız olarak öznitelik elde edilmesi sağlanmalıdır. Bazı çalışmalarda blok tabanlı öznitelikler elde edilmektedir. Görüntünün boyutu değişikçe elde edilecek blok sayısı değişeceğinden, aynı boyutta öznitelik vektörleri elde edilemeyecektir. Bu problemin çözümü için her görüntüyü aynı boyuta ölçekleme gibi bir çözüm önerilebilir ancak görüntüyü yeniden boyutlandırma görüntüdeki eklemli bölgenin kalıntılarında ayrıntıların kaybolmasına neden olabilir. Bu

nedenle bu çözüm efektif olmayacaktır. Bu bağlamda görüntünün bütününden öznelik çıkarmayı sağlayan anahtar noktası tabanlı yöntemler bu alanda denenebilir.

İkinci grupta yapılan çalışmaların sayısının azlığı dikkat çekmektedir. Bu çalışmalar alınan örnek birkaç görüntü üzerinde eklemli bölgeyi tespit etmektedir. Bu da yapılan çalışmayı efektif kılmamaktadır. Görüntü birleştirme sahteciliği tespiti için kullanılan veri setindeki bütün görüntüler üzerinde lokalizasyon için önerilen yöntem denenip, yöntemin performansı bu şekilde verilebilir. Ayrıca bu yöntemler genel olarak görüntüdeki aydınlatma veya gürültü tutarsızlığına dayanmaktadır. Bu tutarsızlıklar için bloklar arasındaki fark (gürültü veya aydınlatma) belirli bir eşik değerinin altında olduğunda yöntem çalışmamaktadır. Ayrıca bu gruptaki çalışmalarda önerilen yöntemlerin farklı atak tiplerine karşı dayanıklılığı test edilmemiştir. Görüntüdeki eklemli yerin lokalizasyonu için gürültü tutarsızlığı için seçilen eşik değerinin gelen test görüntüsünün bütününden elde edilecek otomatik bir eşik değerine göre belirlenmesi önerilen yöntemi farklı görüntüler üzerinde çalışılır hale getirecektir.

Birleştirme sahteciliği tespitinde iki katmanlı olarak görüntü sahteciliği tespiti ve sahte görüntüler üzerinde eklemli bölgenin yer tespiti yapılması şeklinde bir sistem tasarlanabilir. Sisteme gelen test görüntüsü sahte veya orijinal olarak etiketlendikten sonra, eğer görüntü sahte olarak etiketlenmiş ise eklemli bölgenin tespiti için ikinci katmana sokulabilir. Burada lokalizasyon için görüntüden hem gürültü tutarsızlığına bakılarak blok işaretlemesi yapıp, daha sonra da aydınlık tutarsızlığı olan bloklar işaretlenerek, her iki yöntemde işaretlenmiş bloklardan kesişen bloklar sonuç olarak alınıp, eklemli bölgenin işaretlenmesi sağlanabilir.



## 6. KAYNAKLAR

1. Huang, Y., Lu, W., Sun, W. ve Long, D., Improved DCT-based detection of copy-move forgery in images, Forensic science international, 206,1-3 (2011) 178-184.
2. Zhao, J. ve Guo, J., Passive forensics for copy-move image forgery using a method based on DCT and SVD, Forensic science international 233,1-3 (2013) 158-166.
3. Popescu, A.C. ve Farid, H., Exposing digital forgeries by detecting traces of resampling, IEEE Transactions on signal processing, 53,2 (2005) 758-767.
4. Wang, X., Zhang, X., Li, Z. ve Wang, S., A DWT-DCT based passive forensics method for copy-move attacks, Third International Conference on Multimedia Information Networking and Security, November 2011, IEEE, 304-308.
5. Cao, Y., Gao, T., Fan, L. ve Yang, Q., A robust detection algorithm for copy-move forgery in digital images, Forensic science international, 214,1-3 (2012) 33-43.
6. Bin, Y., Xingming, S., Xianyi, C., Zhang, J. ve Xu, L., An Efficient Forensic Method for Copy--move Forgery Detection Based on DWT-FWHT, Radioengineering 22,4 (2013).
7. Wu, Q., Wang, S. ve Zhang, X., Detection of image region-duplication with rotation and scaling tolerance, International Conference on Computational Collective Intelligence, November 2010, Springer,100-108.
8. Ryu, S.-J., Lee, M.-J. ve Lee, H.-K., Detection of copy-rotate-move forgery using Zernike moments, International workshop on information hiding, June 2010, Springer,51-65.
9. Ulutas, G. ve Muzaffer, G., A new copy move forgery detection method resistant to object removal with uniform background forgery, Mathematical Problems in Engineering, 2016, (2016).
10. Wang, T., Tang, J. ve Luo, B., Blind detection of region duplication forgery by merging blur and affine moment invariants, Seventh International Conference on Image and Graphics (ICIG), April 2013, IEEE,258-264.
11. Farid, H., Detecting digital forgeries using bispectral analysis, Technical Report AIM-1657, (1999).
12. Ng, T.-T., Chang, S.-F. ve Sun, Q., Blind detection of photomontage using higher order statistics, International Symposium on Circuits and Systems (IEEE Cat. No. 04CH37512), May 2004, IEEE,V-V.

13. Zhang, Z., Wang, G., Bian, Y. ve Yu, Z., A novel model for splicing detection, Fifth International Conference on Bio-Inspired Computing: Theories and Applications (BIC-TA), September 2010, IEEE, 962-965.
14. Li, X., Jing, T. ve Li, X., Image splicing detection based on moment features and Hilbert-Huang Transform, International Conference on Information Theory and Information Security (ICITIS), December 2010, IEEE, 1127-1130.
15. Muhammad, G., Al-Hammadi, M.H., Hussain, M. ve Bebis, G., Image forgery detection using steerable pyramid transform and local binary pattern, Machine Vision Applications, 25,4 (2014) 985-995.
16. Muhammad, G., Dewan, M.S., Moniruzzaman, M., Hussain, M. ve Huda, M.N., Image forgery detection using Gabor filters and DCT, International Conference on Electrical Engineering and Information & Communication Technology (ICEEICT), April 2014, IEEE, 1-5.
17. Hussain, M., Muhammad, G., Saleh, S.Q., Mirza, A.M. ve Bebis, G., Image forgery detection using multi-resolution Weber local descriptors, Eurocon, July 2013, IEEE, 1570-1577.
18. Agarwal, S. ve Chand, S., Image Forgery Detection using Multi Scale Entropy Filter and Local Phase Quantization, International Journal of Image, Graphics, 7,10 (2015) 78-85.
19. Alahmadi, A., Hussain, M., Aboalsamh, H., Muhammad, G., Bebis, G. ve Mathkour, H., Passive detection of image forgery using DCT and local binary pattern, Signal, Image Video Processing, 11,1 (2017) 81-88.
20. Shen, X., Shi, Z. ve Chen, H., Splicing image forgery detection using textural features based on the grey level co-occurrence matrices, IET Image Processing, 11,1 (2016) 44-53.
21. Vidyadharan, D.S. ve Thampi, S.M., Digital image forgery detection using compact multi-texture representation, Journal of Intelligent Fuzzy Systems, 32,4 (2017) 3177-3188.
22. Agarwal, S. ve Chand, S., Image forgery detection using co-occurrence-based texture operator in frequency domain, Progress in Intelligent Computing Techniques: Theory, Practice and Applications, January 2018, Singapore Springer, 117-122.
23. He, Z., Lu, W., Sun, W. ve Huang, J., Digital image splicing detection based on Markov features in DCT and DWT domain, Pattern Recognition, 45,12 (2012) 4292-4299.
24. Su, B., Yuan, Q., Wang, S., Zhao, C. ve Li, S., Enhanced state selection Markov model for image splicing detection, EURASIP Journal on wireless communications networking, 2014,1 (2014) 7.

25. El-Alfy, E.-S.M. ve Qureshi, M.A., Combining spatial and DCT based Markov features for enhanced blind detection of image splicing, Pattern Analysis Applications, 18,3 (2015) 713-723.
26. Zhao, X., Wang, S., Li, S. ve Li, J., Passive image-splicing detection by a 2-D noncausal Markov model, IEEE Transactions on Circuits Systems for Video Technology, 25,2 (2014) 185-199.
27. Li, C., Ma, Q., Xiao, L., Li, M. ve Zhang, A., Image splicing detection based on Markov features in QDCT domain, Neurocomputing, 228 (2017) 29-36.
28. Feng, W. ve Hu, B., Quaternion discrete cosine transform and its application in color template matching, Congress on Image and Signal Processing, May 2008, IEEE,252-256.
29. Han, J.G., Park, T.H., Moon, Y.H. ve Eom, I.K., Quantization-based Markov feature extraction method for image splicing detection, Machine Vision Applications 29,3 (2018) 543-552.
30. Zhang, Q., Lu, W. ve Weng, J., Joint image splicing detection in DCT and Contourlet transform domain, Journal of Visual Communication Image Representation, 40, (2016) 449-458.
31. Zhang, Q., Lu, W., Wang, R. ve Li, G., Digital image splicing detection based on Markov features in block DWT domain, Multimedia Tools Applications, 77,23 (2018) 31239-31260.
32. Pham, N.T., Lee, J.-W., Kwon, G.-R. ve Park, C.-S., Efficient image splicing detection algorithm based on markov features, Multimedia Tools and Applications, 78,9 (2019) 12405-12419.
33. He, Z., Sun, W., Lu, W. ve Lu, H., Digital image splicing detection based on approximate run length, Pattern Recognition Letters, 32,12 (2011) 1591-1597.
34. Qu, Z., Qiu, G. ve Huang, J., Detect digital image splicing with visual cues, International workshop on information hiding, June 2009, Springer,247-261.
35. Bahrami, K., Kot, A.C., Li, L. ve Li, H., Blurred image splicing localization by exposing blur type inconsistency, IEEE Transactions on Information Forensics Security, 10,5 (2015) 999-1009.
36. Bianchi, T. ve Piva, A., Image forgery localization via block-grained analysis of JPEG artifacts, IEEE Transactions on Information Forensics Security, 7,3 (2012) 1003-1017.
37. Lin, X., Li, C.-T. ve Hu, Y., Exposing image forgery through the detection of contrast enhancement, IEEE international conference on image processing, September 2013, IEEE,4467-4471.

38. Johnson, M.K. ve Farid, H., Exposing digital forgeries through chromatic aberration, 8th workshop on Multimedia and security, September 2006, ACM,48-55.
39. Popescu, A.C. ve Farid, H., Statistical tools for digital forensics, International workshop on information hiding, May 2004, Springer,128-147.
40. Zeng, H., Zhan, Y., Kang, X. ve Lin, X., Image splicing localization using PCA-based noise level estimation, Multimedia Tools Applications, 76,4 (2017) 4783-4799.
41. Zoran, D. ve Weiss, Y., Scale invariance and noise in natural images, IEEE 12th International Conference on Computer Vision., September 2009, IEEE,2209-2216.
42. Pan, X., Zhang, X. ve Lyu, S., Exposing image forgery with blind noise estimation, Thirteenth ACM multimedia workshop on Multimedia and security, September 2011, ACM,15-20.
43. Lyu, S., Pan, X. ve Zhang, X., Exposing region splicing forgeries with blind local noise estimation, International journal of computer vision, 110,2 (2014) 202-221.
44. Mahdian, B. ve Saic, S., Using noise inconsistencies for blind image forensics, Image Vision Computing, 27,10 (2009) 1497-1503.
45. Julliand, T., Nozick, V. ve Talbot, H., Automated image splicing detection from noise estimation in raw images, Imaging for Crime Prevention and Detection, (2015) 1-6.
46. Julliand, T., Nozick, V. ve Talbot, H., Automatic image splicing detection based on noise density analysis in raw images, International Conference on Advanced Concepts for Intelligent Vision Systems, October 2016, Springer,126-134.
47. Lukáš, J., Fridrich, J. ve Goljan, M., Digital camera identification from sensor pattern noise, IEEE Transactions on Information Forensics and Security, 1,2 (2006) 205-214.
48. Chen, M., Fridrich, J., Goljan, M. ve Lukás, J., Determining image origin and integrity using sensor noise, IEEE Transactions on information forensics and security, 3,1 (2008) 74-90.
49. Lin, Z., Wang, R., Tang, X. ve Shum, H.-Y., Detecting doctored images using camera response normality and consistency, IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), June 2005, IEEE,1087-1092.
50. Hsu, Y.-F. ve Chang, S.-F., Image splicing detection using camera response function consistency and automatic segmentation, IEEE International Conference on Multimedia and Expo (ICME), July 2007, IEEE,28-31.

51. Hsu, Y.-F. ve Chang, S.-F., Camera response functions for image forensics: an automatic algorithm for splicing detection, IEEE Transactions on Information Forensics and Security, 5,4 (2010) 816-825.
52. Johnson, M.K. ve Farid, H., Exposing digital forgeries in complex lighting environments, IEEE Transactions on Information Forensics and Security, 2,3 (2007) 450-461.
53. Ladha, L. ve Deepa, T., Feature selection methods and algorithms, International journal on computer science and engineering, 3,5 (2011) 1787-1797.
54. Wang, W., Dong, J. ve Tan, T., Effective image splicing detection based on image chroma, 16th IEEE International Conference on Image Processing (ICIP), November 2009, IEEE,1257-1260.
55. Budak, H., Özellik Seçim Yöntemleri ve Yeni Bir Yaklaşım, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 22, (2018) 21-31.
56. Yildirim, E.O. ve Ulutaş, G., Image splicing detection with dwt domain extended Markov features, 26th Signal Processing and Communications Applications Conference (SIU), May 2018, IEEE,1-4.
57. Yildirim, E.O. ve Ulutaş, G., Markov-Based Image Splicing Detection in the DCT High Frequency Region, International Conference on Artificial Intelligence and Data Processing (IDAP), September 2018, IEEE,1-4.
58. Yıldırım, E.O. ve Ulutaş, G., Augmented features to detect image splicing on SWT domain, Expert Systems with Applications, 131, (2019) 81-93.
59. Haar, A., Zur theorie der orthogonalen funktionensysteme, Mathematische Annalen, 69,3 (1910) 331-371.
60. Vetterli, M. ve Kovacevic, J., Wavelets and Subband Coding Prentice Hall PTR, Englewood Cliffs, NJ, (1995).
61. Lin, Y.-P. ve Vaidyanathan, P., Theory and design of two-dimensional filter banks: A review, Multidimensional Systems and Signal Processing, 7,3-4 (1996) 263-330.
62. Stanhill, D. ve Zeevi, Y.Y., Two-dimensional orthogonal filter banks and wavelets with linear phase, IEEE transactions on signal processing, 46,1 (1998) 183-190.
63. Shukla, P.D., Complex wavelet transforms and their applications, Glasgow (United Kingdom)), M. Phil. Thesis, Dept. of Electronic and Electrical Engineering, University of Strathclyde, (2003).
64. Fowler, J.E., The redundant discrete wavelet transform and additive noise, IEEE Signal Processing Letters, 12,9 (2005) 629-632.

65. Srinivas, P.B. ve Venkatesh, B., Comparative Analysis of DWT SWT DWT & SWT and DT-CWT-Based Satellite Image Resolution Enhancement, International Journal of Electronics & Communication Technology (IJECT), 5,4 (2014) 137-141.
66. Sweldens, W., The lifting scheme: A construction of second generation wavelets, SIAM journal on mathematical analysis, 29,2 (1998) 511-546.
67. Blessie, A.A., Nalini, J. ve Ramesh, S., Image compression using wavelet transform based on the lifting scheme and its implementation, International Journal of Computer Science Issues (IJCSI), 8,3 (2011) 449.
68. Cizek, V., Discrete hilbert transform, IEEE Transactions on Audio and Electroacoustics, 18,4 (1970) 340-343.
69. Oppenheim, A.V., Buck, J.R. ve Schafer, R.W., Discrete-time signal processing. Vol. 22001: Upper Saddle River, NJ: Prentice Hall.
70. Priya, G. ve Domnic, S., Transition detection using Hilbert transform and texture features, American J. of Signal Proc. 10, (2012) 35-40.
71. Lian, M.-J. ve Huang, C.-L., Texture feature extraction of gray-level co-occurrence matrix for metastatic cancer cells using scanned laser pico-projection images, Lasers in medical science, 34,7 (2019) 1503-1508.
72. Suresh, A. ve Shunmuganathan, K., Feature fusion technique for colour texture classification system based on gray level co-occurrence matrix, Journal of Computer Science, 8,12 (2012) 2106.
73. Reddy, D.J., Prasath, T.A., Rajasekaran, M.P. ve Vishnuvarthanan, G., Brain and Pancreatic Tumor Classification Based on GLCM—k-NN Approaches, International Conference on Intelligent Computing and Applications, January 2019, Springer,293-302.
74. Arabi, P.M., Joshi, G. ve Deepa, N.V., Performance evaluation of GLCM and pixel intensity matrix for skin texture analysis, Perspectives in Science, 8, (2016) 203-206.
75. Luo, J., Song, D., Xiu, C., Geng, S. ve Dong, T., Fingerprint classification combining curvelet transform and gray-level cooccurrence matrix, Mathematical Problems in Engineering, 2014, (2014).
76. Oghaz, M.M., Maarof, M.A., Rohani, M.F., Zainal, A. ve Shaid, S.Z.M., An optimized skin texture model using gray-level co-occurrence matrix, Neural Computing and Applications, (2019) 1-19.
77. Mohanaiah, P., Sathyanarayana, P. ve GuruKumar, L., Image texture feature extraction using GLCM approach, International Journal of Scientific And Research Publications, 3,5 (2013) 1.


78. Reni, M.B., Iris Recognition based Age Estimation in Security Systems using Canny Edge Detection, Research Journal of Pharmaceutical Biological and Chemical Sciences, 6,5 (2015) 349-357.
79. Priya, G.L. ve Domnic, S., Video cut detection using Hilbert transform and GLCM, International Conference on Recent Trends in Information Technology (ICRTIT), June 2011, IEEE,749-753.
80. Dhruv, B., Mittal, N. ve Modi, M., Study of Haralick's and GLCM texture analysis on 3D medical images, International Journal of Neuroscience, 129,4 (2019) 350-362.
81. Haralick, R.M., Shanmugam, K. ve Dinstein, I.H., Textural features for image classification, IEEE Transactions on systems, man, and cybernetics,6 (1973) 610-621.
82. Ahmed, M. ve Laskar, R.H., Eye center localization in a facial image based on geometric shapes of iris and eyelid under natural variability, Image and Vision Computing, 88, (2019) 52-66.
83. Xiang, L. ve Xiaoqing, W., Motion segmentation based on edge detection, Procedia Engineering, 29, (2012) 74-78.
84. Ahmed, K.T., Ummesafi, S. ve Iqbal, A., Content based image retrieval using image features information fusion, Information Fusion, 51, (2019) 76-99.
85. Subrahmanyam, M., Maheshwari, R. ve Balasubramanian, R., Local maximum edge binary patterns: a new descriptor for image retrieval and object tracking, Signal Processing, 92,6 (2012) 1467-1479.
86. Rathore, H., Sharma, V.K., Chaturvedi, S. ve Sharma, K.D., Overlapped Sunflower Weighted Crop Yield Estimation Based on Edge Detection, International Conference on Advanced Informatics for Computing Research, July 2018, Springer,13-22.
87. Sobel, I., Camera models and machine perception, Computer Science Department, Technion, (1972).
88. Prewitt, J.M., Object enhancement and extraction, Picture processing and Psychopictorics, 10,1 (1970) 15-19.
89. Canny, J., A computational approach to edge detection, IEEE Transactions on pattern analysis and machine intelligence,6 (1986) 679-698.
90. Maini, R. ve Aggarwal, H., Study and comparison of various image edge detection techniques, International journal of image processing (IJIP), 3,1 (2008).
91. Ojala, T., Pietikäinen, M. ve Mäenpää, T., Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, IEEE Transactions on Pattern Analysis & Machine Intelligence,7 (2002) 971-987.

92. Ahonen, T., Hadid, A. ve Pietikainen, M., Face description with local binary patterns: Application to face recognition, IEEE Transactions on Pattern Analysis & Machine Intelligence,12 (2006) 2037-2041.
93. Rosdi, B.A., Shing, C.W. ve Suandi, S.A., Finger vein recognition using local line binary pattern, Sensors, 11,12 (2011) 11357-11371.
94. Wang, Y., Zhao, Y. ve Chen, Y., Texture classification using rotation invariant models on integrated local binary pattern and Zernike moments, EURASIP Journal on Advances in Signal Processing, 2014,1 (2014) 182.
95. Jagtap, J. ve Kokare, M., Human age classification using facial skin aging features and artificial neural network, Cognitive Systems Research, 40, (2016) 116-128.
96. Ulaby, F.T., Kouyate, F., Brisco, B. ve Williams, T.L., Textural information in SAR images, IEEE Transactions on Geoscience and Remote Sensing,2 (1986) 235-245.
97. Baraldi, A. ve Parmiggiani, F., An Investigation of the Textural Characteristics Associated with Gray Level Cooccurrence Matrix Statistical Parameters, IEEE Transactions on Geoscience and Remote Sensing, 33,2 (1995).
98. Vapnik, V.N., The nature of statistical learning, Theory, (1995).
99. Aykut, M., Esnek Kullanımlı Avuç İzi Bölgesine Dayalı Doğrulama Sistemlerinin Tasarım Çalışması, Doktora Tezi, Fen Bilimleri Enstitüsü, Trabzon, 2013.
100. Kavzoğlu, T. ve Çölkesen, İ., Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi, Harita Dergisi, 144,7 (2010) 73-82.
101. Jakkula, V., Tutorial on support vector machine (svm), School of EECS, Washington State University, 37, (2006).
102. Osuna, E.E., Support vector machines: Training and applications, 1998.
103. Dong, J., Wang, W. ve Tan, T., Casia image tampering detection evaluation database, IEEE China Summit and International Conference on Signal and Information Processing, July 2013, IEEE,422-426.
104. Ng, T.-T., Chang, S.-F. ve Sun, Q., A data set of authentic and spliced image blocks, Columbia University, ADVENT Technical Report, (2004) 203-2004.




## 7. EKLER

### Ek 1. Önerilen Yöntemde [58] Farklı Frekans Bantlarından Elde Edilen Geçiş Olasılık Matrislerinin Yüzeysel Gösterimi




Ek Şekil 1. Önerilen yöntemde [58] SWT domen HL bandında a) yatay fark matrisinden b) dikey fark matrisinden c) köşegenel fark matrisinden elde edilen GOM'ler

## Ek 1'in devamı




Ek Şekil 2. Önerilen yöntemde [58] SWT domen HH bandında a) yatay fark matrisinden b) dikey fark matrisinden c) köşegenel fark matrisinden elde edilen GOM'ler

Ek 1'in devamı



Ek Şekil 3. Önerilen yöntemde [58] SWT domen HL bandında a) yatay fark matrisinden b) dikey fark matrisinden c) köşegenel fark matrisinden elde edilen GOM'ler

## Ek 1'in devamı



Ek Şekil 4. Önerilen yöntemde [58] SWT domen HH bandında a) yatay fark matrisinden b) dikey fark matrisinden c) köşegenel fark matrisinden elde edilen GOM'ler

## ÖZGEÇMİŞ

Esra ODABAŞ YILDIRIM; 1985 yılında Erzurum'da doğdu. İlk ve Orta öğrenimini Erzurum'da tamamladı. 2003 yılında Nevzat Karabağ Anadolu Öğretmen Lisesi'nden mezun oldu. 2004 yılında Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü'nde lisans programına başladı ve 2010 yılı Ocak ayında mezun oldu. Yine aynı yıl bahar döneminde başladığı Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans çalışmalarını 2014 yılında tamamladı. Yüksek Lisans Eğitimini yaparken 2013 yılı Temmuz-Eylül ayları arasında tez ile ilgili araştırma-inceleme yapmak için Amerika'da UTSA (University Texas of San Antonio) üniversitesine görevli olarak gitti. Karadeniz Teknik Üniversitesi'nde başladığı yüksek lisans eğitimini 2014'te tamamladı ve aynı yıl doktor çalışmalarına başladı. 2010 yılında Atatürk Üniversitesi Bilgisayar Mühendisliği Bölümünde Dekanlığa bağlı Araştırma Görevlisi olarak başladığı görevine halen devam etmektedir. Yabancı dil olarak İngilizce bilmektedir. Başlıca yayınları aşağıda verilmiştir.

SCI/SCI-E indekslerine giren dergilerde yayınlanan makaleler

1. **Yıldırım, E.O.** ve Ulutaş, G., Augmented features to detect image splicing on SWT domain, Expert Systems with Applications, 131, (2019) 81-93.

Uluslararası Dergi ve Konferanslar kapsamında yapılan yayınlar

1. **Yıldırım, E.O.** ve Ulutaş, G., Image splicing detection with dwt domain extended Markov features, in 2018 26th Signal Processing and Communications Applications Conference (SIU). 2018, IEEE,1-4.
2. **Yıldırım, E.O.** ve Ulutaş, G., Markov-Based Image Splicing Detection in the DCT High Frequency Region, in 2018 International Conference on Artificial Intelligence and Data Processing (IDAP). 2018, IEEE,1-4.