

**BAŐKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**İÇERİK TABANLI GÖRÜNTÜ ERİŐİMİNDE ÖZİNİTELİK
FÜZYONU**

ÖMÜRHAN A. SOYSAL

YÜKSEK LİSANS TEZİ

2016

İÇERİK TABANLI GÖRÜNTÜ ERİŞİMİNDE ÖZNEİELİK FÜZYONU

WEIGHTED FEATURE FUSION FOR CONTENT-BASED IMAGE RETRIEVAL

ÖMÜRHAN A. SOYSAL

Başkent Üniversitesi
Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin
BİLGİSAYAR Mühendisliği Anabilim Dalı İçin Öngördüğü
YÜKSEK LİSANS TEZİ
olarak hazırlanmıştır.

2016

“İçerik Tabanlı Görüntü Erişiminde Öznitelik Füzyonu” başlıklı bu çalışma, jürimiz tarafından, 10/02/2016 tarihinde, **BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI'nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Başkan : Yrd. Doç. Dr. Hakan TORA

Danışman : Yrd. Doç. Dr. Emre SÜMER

Üye : Yrd. Doç. Dr. Mustafa SERT

ONAY

..../02/2016

Prof. Dr. Emin AKATA
Fen Bilimleri Enstitüsü Müdürü



BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ YÜKSEK LİSANS
TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 22/02/2016

Öğrencinin Adı, Soyadı : ÖMÜRHAN AVNİ SOYSAL
Öğrencinin Numarası : 201410495
Anabilim Dalı : BİLGİSAYAR MÜHENDİSLİĞİ
Programı : BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS
Danışmanın Adı, Soyadı : YRD.DOÇ.DR. EMRE SÜMER
Tez Başlığı : İÇERİK TABANLI GÖRÜNTÜ ERİŞİMİNDE ÖZİNİTELİK FÜZYONU

Yukarıda başlığı belirtilen Yüksek Lisans/Doktora tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 75 sayfalık kısmına ilişkin, 22/02/ 2016 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %12'dir.

Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimedenden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası

Onay

22 / 02/ 2016

Yrd. Doç. Dr. Emre Sümer

TEŐEKKÜR

Sayın Yrd. Doç. Dr. EMRE SÜMER'e (tez danışmanı), çalışmanın sonuca ulaştırılmasında ve karşılaşılan güçlüklerin aşılmasında her zaman yardımcı ve yol gösterici olduđu için,

Tez çalışmam boyunca destekleriyle yanımda olan sevgili eşim Ezgi Pekşen SOYSAL'a ve aileme desteklerinden dolayı teşekkürü borç bilirim.

ÖZ

İÇERİK TABANLI GÖRÜNTÜ ERİŞİMİNDE ÖZİNİTELİK FÜZYONU

Ömürhan A. SOYSAL

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışmada, içerik tabanlı görüntü erişim problemlerinin çözümünde tercih edilen tanımlayıcılardan en yaygın olarak kullanılan SIFT (Scale Invariant Feature Transform), SURF (Speeded-Up Robust Features) ve ORB'nin (Oriented FAST and Rotated BRIEF) performansları değerlendirilmiş ve probleme özgü tanımlayıcı tercih etmek yerine jenerik bir çözüm olarak "Ağırlıklandırılmış Öznelik Füzyonu" gerçekleştirilmiştir. Inria'nın 2 temel veri kümesi üzerinde testler yapılmış ve geri getirim sonuçlarının hassasiyetinin yükseltilmesi hedeflenmiştir. Önerilen yaklaşımın, tanımlayıcıların tek başlarına uygulandığı durumlarda; ORB'nin tek başına uygulandığı duruma göre %10-30, SIFT'in tek başına uygulandığı duruma göre %9-22, SURF'un tek başına uygulandığı duruma göre %12-29 daha az Yanlış Pozitif ürettiği gözlenmiştir.

ANAHTAR SÖZCÜKLER: İçerik Tabanlı Görüntü Erişimi, Öznelik Füzyonu, Tanımlayıcı Füzyonu.

Danışman: Yrd.Doç.Dr. Emre SÜMER, Başkent Üniversitesi, Bilgisayar Mühendisliği Bölümü.

ABSTRACT

WEIGHTED FEATURE FUSION FOR CONTENT-BASED IMAGE RETRIEVAL

Ömürhan A. SOYSAL

Baskent University Institute of Science and Engineering

Computer Engineering Department

The feature descriptors such as SIFT (Scale Invariant Feature Transform), SURF (Speeded-up Robust Features) and ORB (Oriented FAST and Rotated BRIEF) are known as the most commonly used solutions for the content-based image retrieval problems. In this paper, a generic approach called "Weighted Feature Fusion" is implemented as a generic solution instead of applying problem-specific descriptors alone. Experiments were performed on two basic data sets of the Inria in order to improve the precision of retrieval results. It was found that in cases where the descriptors were used alone the proposed approach yielded 10-30% more accurate results than the ORB alone. Besides, it yielded 9-22% and 12-29% less False Positives compared to the SIFT alone and SURF alone, respectively.

KEYWORDS: Content-Based Image Retrieval, Feature Fusion, Descriptor Fusion

Advisor: Asst. Prof. Dr. Emre Sümer, Baskent University, Computer Engineering Department.

İÇİNDEKİLER LİSTESİ

Sayfa

ÖZ.....	i
ABSTRACT	ii
İÇİNDEKİLER LİSTESİ.....	iii
ŞEKİLLER LİSTESİ.....	v
ÇİZELGELER LİSTESİ.....	vi
SİMGELER VE KISALTMALAR LİSTESİ.....	vii
1 GİRİŞ.....	1
1.1 Çalışmanın Konusu, Amaç ve Kapsam.....	1
1.2 Benzer Çalışmalar.....	5
1.2.1 Flann.....	7
1.2.2 K-Means.....	7
1.2.3 Hiyerarşik K-Means.....	8
1.2.4 K En Yakın Komşu.....	9
1.2.5 Öklid Mesafesi.....	9
1.3 Tezin Genel Yapısı.....	10
2 ÖNERİLEN YÖNTEM.....	12
2.1 Genel Metodoloji.....	12
2.2 Ön İşleme.....	14
2.2.1 Bi-Cubic enterpolasyon.....	15
2.3 İlgili Noktalarının Tespiti ve Öznitelik Çıkarma.....	15
2.3.1 Öznitelik detektörü.....	15
2.3.2 Öznitelik tanımlayıcı.....	15
2.3.2.1 <u>SIFT</u>	15
2.3.2.2 <u>SURF</u>	16
2.3.2.3 <u>ORB</u>	16
2.3.2.4 <u>Normalizasyon</u>	19
2.4 Öznitelik Tanımlayıcı için Eşleştirici.....	19
2.5 Ağırlıklandırma.....	20
3 VERİ KÜMESİ.....	22
3.1 Inria Holidays.....	22

3.2	Inria Copy Days.....	24
3.2.1	Scale jpeg attacked images.....	24
3.2.2	Crop.....	26
3.2.3	Strong.....	26
4	DENEYSEL SONUÇLAR.....	29
4.1	Test Ortamı ve Konfigürasyon.....	29
4.1.1	OpenCV.....	29
4.2	Değerlendirme Sonuçları ve Tartışma.....	29
5	SONUÇ VE GELECEK ÇALIŞMALAR.....	38
	KAYNAKLAR LİSTESİ.....	39
	EKLER LİSTESİ.....	42

ŞEKİLLER LİSTESİ

	<u>Sayfa</u>
Şekil 1.1	“Sunset in beach” ifadesinin Google arama motoruna göre sonuçları.....3
Şekil 1.2	İçerik Tabanlı Görüntü Erişimi'nin Temel İş Akış Diyagramı.....5
Şekil 1.3	Hiyerarşik K-Means.....9
Şekil 2.1	Önerilen yöntemin akış şeması.....14
Şekil 2.2	Öznitelik detektörlerinin veri kümesi üzerinde çalışması sonucu tespit edilen tanımlayıcılar.....18
Şekil 2.3	Şeklin sol tarafındaki parlak noktalar tespit edilmesi istenen görüntüdeki öznitelikler, sağ tarafındaki noktalar ise sorgu görüntüsündeki öznitelikler.....20
Şekil 3.1	Inria Holidays veri kümesinden örnek-1.....23
Şekil 3.2	Inria Holidays veri kümesinden örnek-2.....23
Şekil 3.3	Inria Holidays veri kümesinden örnek-3.....23
Şekil 3.4	Inria Copy Days veri kümesinden örnek-4.....25
Şekil 3.5	Inria Copy Days veri kümesinden örnek-5.....25
Şekil 3.6	Inria Copy Days veri kümesinden örnek-6.....25
Şekil 3.7	Inria Copy Days veri kümesinden örnek-7.....26
Şekil 3.8	Inria Copy Days veri kümesinden örnek-8.....27
Şekil 3.9	Inria Copy Days veri kümesinden örnek-9.....27
Şekil 3.10	Inria Copy Days veri kümesinden örnek-10.....27
Şekil 3.11	Inria Copy Days veri kümesinden örnek-11.....28
Şekil 4.1	Inria Copy Days Crop veri kümesi üzerinde ORB tanımlayıcı ve FLANN indeks, SIFT tanımlayıcı ve FLANN indeks, SURF tanımlayıcı ve FLANN indeks ile Ağırlıklandırılmış Öznitelik Füzyonu yöntemlerinin uygulanmasının karşılaştırmalı sonuçları.....32
Şekil 4.2	Inria Copy Days Scale JPEG Attacked Images veri kümesi üzerinde ORB tanımlayıcı ve FLANN indeks, SIFT tanımlayıcı ve FLANN indeks, SURF tanımlayıcı ve FLANN indeks ile Ağırlıklandırılmış Öznitelik Füzyonu yöntemlerinin uygulanmasının karşılaştırmalı sonuçları.....35

ÇİZELGELER LİSTESİ

	<u>Sayfa</u>
Çizelge 4.1 Inria Copy Days Crop veri kümesi üzerinde ORB tanımlayıcı ve FLANN indeks kullanılarak elde edilen sonuçlar.....	30
Çizelge 4.2 Inria Copy Days Crop veri kümesi üzerinde SIFT tanımlayıcı ve FLANN indeks kullanılarak elde edilen sonuçlar.....	31
Çizelge 4.3 Inria Copy Days Crop veri kümesi üzerinde SURF tanımlayıcı ve FLANN indeks kullanılarak elde edilen sonuçlar.....	31
Çizelge 4.4 Inria Copy Days Crop veri kümesi üzerinde Ağırlıklandırılmış Öznitelik Füzyonu yönteminin uygulanmasının sonuçları.....	32
Çizelge 4.5 Inria Copy Days Scale JPEG Attacked Images veri kümesi üzerinde ORB tanımlayıcı ve FLANN indeks kullanılarak elde edilen sonuçları.....	33
Çizelge 4.6 Inria Copy Days Scale JPEG Attacked Images veri kümesi üzerinde SIFT tanımlayıcı ve FLANN indeks kullanılarak elde edilen sonuçları.....	34
Çizelge 4.7 Inria Copy Days Scale JPEG Attacked Images veri kümesi üzerinde SURF tanımlayıcı ve FLANN indeks kullanılarak elde edilen sonuçları.....	34
Çizelge 4.8 Inria Copy Days Scale JPEG Attacked Images veri kümesi üzerinde Ağırlıklandırılmış Öznitelik Füzyonu yönteminin uygulanmasının sonuçları.....	35
Çizelge 4.9 Inria Copy Days Strong ve Holidays veri kümeleri üzerinde ORB tanımlayıcı ve FLANN indeks, SIFT tanımlayıcı ve FLANN indeks, SURF tanımlayıcı ve FLANN indeks ile Ağırlıklandırılmış Öznitelik Füzyonu yöntemlerinin uygulanmasının karşılaştırmalı sonuçları.....	36

SİMGELER VE KISALTMALAR LİSTESİ

SIFT	Scale-Invariant Feature Transform
SURF	Speed-Up Robust Features
FAST	Features from Accelerated Segment Test
BRIEF	Binary Robust Independent Elementary Features
ORB	Oriented FAST and Rotated BRIEF
RGB	Red Green Blue
HSV	Hue Saturation Value
BF	Brute Force
FLANN	Fast Library for Approximate Nearest Neighbors
KNN	K Nearest Neighbor
OpenCV	Open Source Computer Vision Library
GPS	Global Positioning System
PCA	Principle Component Analysis
BF Matcher	Brute Force Matcher
BSD	Berkeley Software Distribution
CUDA	Compute Unified Device Architecture
QBIC	Query By Image Content

1. GİRİŞ

1.1 Çalışmanın Konusu, Amaç ve Kapsam

Günümüz internet dünyası bilginin hızlı ve kontrolsüz bir biçimde yayılmasına olanak sağlamaktadır. Mobil cihazların kullanımının yaygınlaşmasıyla beraber görsel bilgi üretimi ve yayılımı da artmaktadır. Arama motoru devi Google'ın Arama Ürünleri Yöneticisi Ben Ling'in açıklamalarına göre Google 2001 yılında 250 milyon fotoğraf indekslemişken 2005 yılında bu sayı 1 milyarı, 2010 yılında 10 milyarı aşmıştır [1]. Resmi blogundaki açıklamalara göre 2015 yılı itibariyle Instagram'ın 400 milyon kullanıcısı günde 80 milyon fotoğraf paylaşmaktadır [2]. Facebook'un bugün dünya çapındaki 1.4 milyar kullanıcısı [3] günde yaklaşık 400 milyon fotoğrafı Facebook'a yüklemektedir [4].

Sosyal medyanın ve dolayısıyla iletişim araçlarının gelişmesiyle beraber artan görsel verilere erişim, başlı başına bir sorun olarak önümüzde durmaktadır. Gerek bireysel gerekse kurumsal ihtiyaçlara bağlı olarak, üretilen görsel verilerin internet dünyasında aranması ve tespit edilmesi kelimenin tam anlamıyla samanlıkta iğne aramaya benzemektedir. Bu aramanın manuel yapılması ise günümüz koşullarındaki görsel bilgi sığıması yüzünden pek mümkün değildir.

Yaşar Tonta bir bilim disiplini olarak yaklaşık 60 yıllık geçmişi olan bilgi erişimini "bilgi toplama, sınıflama, kataloglama, depolama, büyük miktardaki verilerden arama yapma ve bu verilerden istenen bilgiyi üretme (veya gösterme) teknik ve süreci" olarak tanımlamaktadır [5]. Bu erişimin sağlanması için arama motorları, sınıflandırma ve kataloglama yöntemleri geliştirilmiştir. Bu çalışmalar ilk başlarda metin tabanlı bilgi erişimine odaklanmış ve bu konuda sayısız yöntem geliştirilmiştir. Her ne kadar dünya genelinde Google başta olmak üzere büyük şirketler ve önemli akademik çalışmalar bu konuda önemli mesafe kat etmiş olsa da problemin tamamen çözüldüğünü söylemek imkânsızdır. Daha metin tabanlı bilgi erişimine yönelik çalışmalar devam etmekteyken bilgi erişiminin bir diğer alt başlığı olan görüntü erişimi problemi karşımıza çıkmıştır.

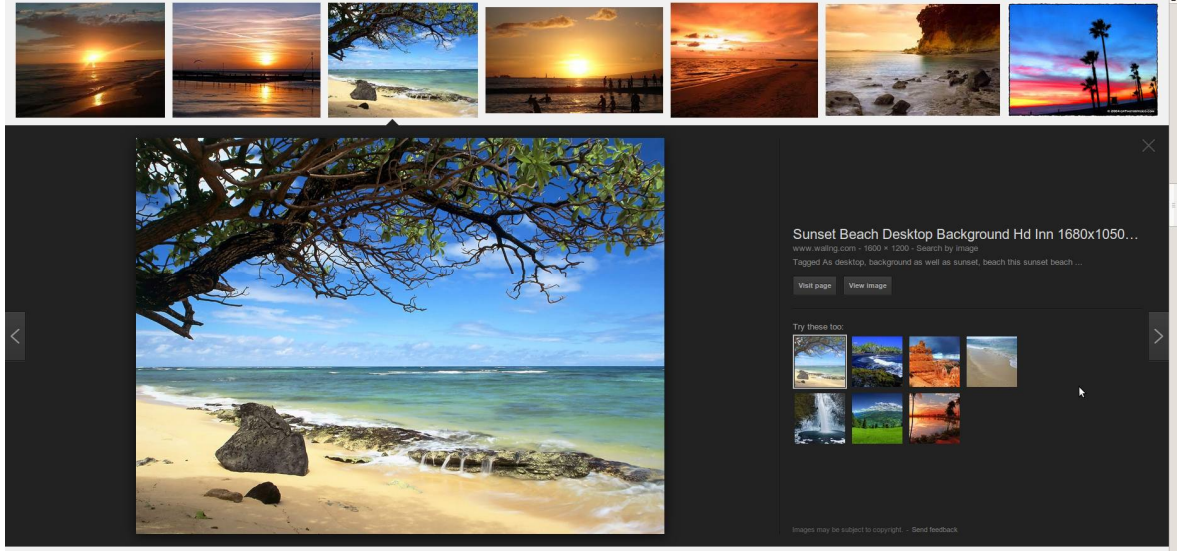
Görüntü erişimi problemine yönelik geliştirilen çözümlerde kullanılan yöntemlerin en başında metin verisi tabanlı arama gelmektedir [6]. Her görüntü sayısal görüntü bilgi alanı dışında metin tipindeki üst veri bilgi alanına da sahiptir. Görüntünün renk

kanalları, pozlama süresi, en ve boy uzunlukları, tarihi, çözünürlüğü, GPS koordinatları, kim tarafından oluşturulduğu, tanımı, etiketi bu üst veri bilgi alanlarından bazılarıdır. Bu verilerin bir kısmı kullanıcı tarafından oluşturulur. Aramada kullanılan veriler de genellikle kullanıcı tarafından oluşturulan üst veri alanlarıdır.

Bu yöntemin avantajı hızlı sonuç üretmesidir. Aramada kullanılan metin verisinin boyutu görsel bilgiye göre çok daha az olacağı için hem arama yapılan uzay hem de tespit edilmesi istenen görsel daha küçük bir boyutta temsil edilebilmektedir. Günümüzde metin içeriğine sahip büyük verinin dağıtık olarak indekslenebildiği ve çok kısa sürelerde karşılaştırma yapabildiği düşünüldüğünde bu yöntem çok hızlı bir sonuç üretebilme yeteneğine sahiptir.

Diğer yandan aramada kullanılan üst veri bilgisi çoğu zaman yanlış sonuçlar üretmektedir. Bunun nedeni de görsellerin üst veri alanlarının kullanıcılar tarafından manuel etiketlenmesi ve/veya tanımlanmasıdır. Bu işlem için kullanıcılar dâhil olmak üzere birçok kişiden destek alınması ve söz konusu süreçte insan faktörünün olması sebebiyle içerik oluşturulmasındaki hata riski yüksektir. Ayrıca, etiketleme sürecinde içeriğin öznel yorumlanma olasılığı, dolayısıyla bağlama duyarlı olmaması ve/veya içeriğin eksik/yetersiz oluşturulması veya herhangi bir etiket veya tanımlama bilgisine sahip olmaması da diğer dezavantajlar arasında değerlendirilebilir.

Şekil 1.1'de arama motoru devi Google'ın görsel aramalarında "sunset in beach" ifadesi ile yapılan aramanın sonucu görülmektedir. Metin tabanlı aramadaki başarısını görüntü erişimine de yansıtmaya çalışan Google, fotoğrafların bağlantılarını indeksleyip fotoğraf isimlerinde aratma yaptığı için böyle yanlış bir eşleşme sonucu elde edilmektedir.



Şekil 1.1 “Sunset in beach” ifadesinin Google arama motoruna göre sonuçları

Görüntü erişiminde tercih edilen bir diğer yaklaşım ise “İçerik Tabanlı Görüntü Erişimi”dir [7]. Bu alanda yapılan ilk ticari çalışma IBM tarafından geliştirilen ve QBIC [8] (Görüntü içeriği ile sorgulama) adı verilen üründür. QBIC örnek görüntü, el çizimi, seçili renk ve doku ile sorgulamayı desteklemektedir. Yüksek boyutlu öznitelik indekslemeye de olanak sağlayan ürün metin tabanlı arama desteği ile içerik tabanlı benzerlik aramasındaki sonuçları iyileştirmeyi hedeflemiştir.

İçerik Tabanlı Görüntü Erişim yönteminin evrimsel gelişimi izlendiğinde alt başlık olarak iki yöntem dikkate değerdir: Bunlardan ilki sorgu fotoğrafı ile aramadır. Bu yöntemde sorgu fotoğrafının tüm sayısal içeriği aramada kullanılır. Oysa arama yapılırken fotoğrafın tüm içeriğini kullanmak hem çalışma zamanını uzatır hem de gereksiz detayların arama kriteri olarak verilmesinden kaynaklı yanlış eşleşmelere yol açmasına neden olur. Özellikle günümüz koşullarında görüntü koleksiyonlarının sayısının ve dolayısıyla sayısal içeriğinin giderek büyüdüğü düşünüldüğünde görüntülerdeki gereksiz detayların indekslenmesi büyük donanım kaynaklarının kullanımına yol açacaktır.

İçerik Tabanlı Görüntü Erişimi'nde tercih edilen bir diğer alt başlık ise aramada görüntünün tüm sayısal içeriğinin kullanılması yerine görüntüdeki bir takım özniteliklerin tanımlayıcılar sayesinde tespit edilmesi ve aramanın bu öznitelikler aracılığı ile yapılmasıdır. Bu yöntemin geri getirimdeki performansı diğer

yöntemlere göre daha yüksektir. Bu yöntem de evrimsel olarak incelendiğinde ilk olarak karşımıza renk, doku, şekil vb bilgilerin öznitelik olarak kullanıldığı görülmektedir. Renk bilgilerinin kullanılarak arama yapılması her ne kadar bazı gereksinimleri karşılarsa da birbirine benzemeyen ama aynı renge sahip farklı içerikteki görüntülerin tespit edilmesine yol açmaktadır. Dolayısıyla bu bilginin de tek başına yeterli olmadığı süreç içerisinde gözlemlenmiştir.

Son yıllarda yukarıda ayrıntılandırdığımız yöntemlerin dezavantajlarından ötürü İçerik Tabanlı Görüntü Erişimi'nde görselin içerik bilgisindeki ilgi noktalarını kullanarak arama yapılması oldukça popüler bir çalışma alanı haline gelmiştir. Görüntü içerisindeki köşe noktalarının farklı tanımlayıcılar ile tespit edilmesi, arama yapılırken bu verilerin dikkate alınması hem çalışma zamanında hem de doğru eşleşme sayılarında gözle görülür bir iyileşme katkısı sağlamıştır. Büyük sayı ve sığadaki görüntü koleksiyonlarında arama yaparken bu görüntülerin tüm içeriğini kullanmak yerine sadece ilgi noktaları matrisleri aracılığı ile arama yapmak hızlı ve doğru sonuç üreten bir yöntem olarak değerlendirilmektedir. Bu bağlamda, literatürde farklı tanımlayıcıların ayrı ayrı ya da birleştirilerek kullanıldığı bazı çalışmalara rastlanmaktadır [9] [10] [11].

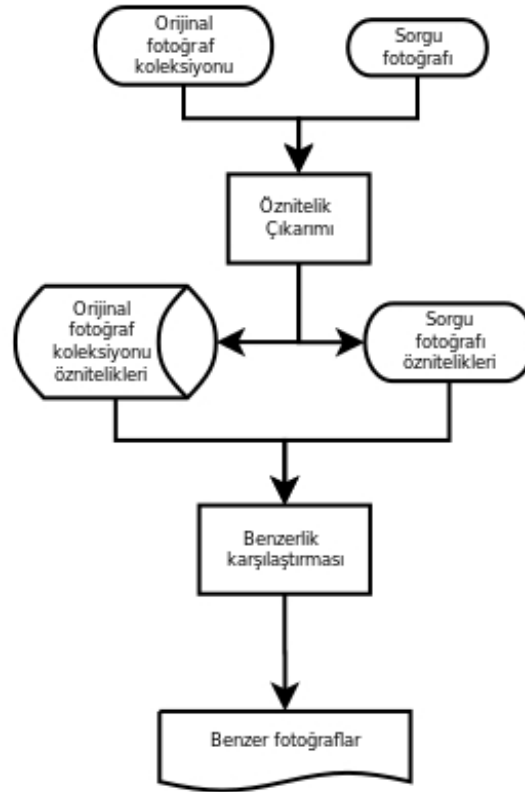
Bu tez kapsamında içerik tabanlı görüntü erişim problemlerinin çözümünde yaygın olarak kullanılan ve literatürdeki benzerlerine nazaran daha yakın zamanda ortaya çıkmış tanımlayıcılar olan SIFT, SURF ve ORB'nin performansları değerlendirilmiş ve bu tanımlayıcıların ayrı ayrı kullanımı yerine bir ağırlıklandırma dâhilinde bir arada kullanımı önerilmiştir. Füzyon işlemi kapsamında bu tanımlayıcıların seçilmesindeki amaç, birbirlerini tamamlayıcı özellikte olmalarıdır. Bu bağlamda, belli bir mantık çerçevesinde ağırlıklandırıldıklarında gözle görülür bir performans artışı olduğu yapılan testler neticesinde görülmüştür.

Tez kapsamında yapılan testlerde yalnızca hassasiyet (precision) değeri hesaplanmış olup geri-getirim (recall) değeri hesaplanmamıştır. Bunun temel nedeni üzerinde çalışılan veri kümelerinde sorgu fotoğrafı ile eşleşen yalnız 1 orijinal fotoğrafın yer almasıdır. Geri-getirim değerinin hesaplanması sorgu fotoğrafı ile eşleşen birden fazla orijinal fotoğrafın olduğu durumlarda daha anlamlıdır.

1.2 Benzer Çalışmalar

İçerik tabanlı görüntü erişimine yönelik yaklaşımların genel anlamda kullanımını gösteren akış şeması Şekil 1.2'de verilmiştir.

İçerik Tabanlı Görüntü Erişimi'nde her ne kadar görüntünün tüm sayısal içeriği kullanılsa da görüntü koleksiyonlarının büyümesi yüzünden öznitelik vektörünün de oldukça büyük boyutlara ulaşabilme olasılığı üzerine literatürde çalışmalar mevcuttur. Yapılan çalışmaların büyük bir kısmında fotoğraflardan çıkarılan öznitelik vektörünün boyutunu azaltmak için Temel Bileşenler Analizi (PCA)'nin tercih edildiği gözlemlenmiştir. Temel bileşen analizi öznitelikler arasındaki değişintiyi (variance) açıkladığı için aykırı değerlere karşı hassastır: Merkezden uzakta olan birkaç nokta değişinti üzerinde ve dolayısıyla vektörler üzerinde çok etkili olabilir. Gürbüz kestirim yöntemleri, aykırı değerlere rağmen parametre değerlerini hesaplamayı sağlar [12]. Dolayısıyla görüntü koleksiyonu genişledikçe ilgi noktaları da artmakta, birbiri ile ilgisi olmayan ilgi noktaları yüzünden PCA matrisi geri getirim sonuçlarını olumsuz yönde etkilemektedir.



Şekil 1.2 İçerik Tabanlı Görüntü Erişimi'nin Temel İş Akış Diyagramı

Öznitelik vektörünün boyutunun azaltılmasına yönelik son dönemlerdeki en dikkat çekici çalışma Hervé Jegéou ve arkadaşlarının gerçekleştirdiği çalışmadır [13]. Her bir görüntünün 20 byte'lık bir öznitelik vektörü ile temsil edilmesini sağlayan çalışma oldukça dikkat çekici olmasına rağmen PCA kullanılarak boyut azaltmanın tercih edildiği ve geri getirimdeki başarı oranının %50-60 seviyesinde kaldığı gözlemlenmiştir. Geri getirim performansı yerine görüntünün temsil edildiği vektörün boyutlarının azaltılmasının hedeflendiği bu çalışmadaki veri kümeleri bizim çalışmamızda da tercih edilmiştir.

Yue ve arkadaşlarının 2011 yılında yaptıkları çalışmada [14] insan algısına daha çok hitap etmesi nedeniyle RGB renk kanalı yerine HSV renk kanalına ve kapasite, entropi, eylemsizlik momenti ve ilgililikten oluşan doku bilgisine dayalı histogram aracılığı ile içerik tabanlı görüntü erişimi yaptıkları gözlemlenmiştir. Ancak, yöntemin sadece sınırlı veri kümesinde değerlendirilmesi, bu veri kümesinin sadece arabalardan oluşması ve erişilmek istenen görüntünün birebir aynısının veri kümesinde yer aldığı gözlemlenmiştir.

Bazı çalışmalarda ise İçerik Tabanlı Görüntü Erişimi için spesifik problemler tanımlanmış ve bu problemlere özgü çözümler önerilmiştir. Höschl ve arkadaşının gerçekleştirdiği çalışmada [15] gürültülü görüntülere erişim problemi üzerine çalışılmıştır. Bu görüntülerin gürültüleri modellenmiş ve ardından bu gürültülere dayanıklı histogramlar oluşturulmuştur. Çalışılan alanın sadece gürültülü görüntülerle sınırlandırılması, örneğin birleştirilmiş veya aynı sahnenin farklı pozlama perspektifine sahip görüntüleri gibi geniş bir problem uzayına sahip olmaması bu çalışmanın dezavantajları arasında sayılabilir. İnternet dünyasındaki problemlerin sadece Gaussian gürültüsüne sahip görüntülerden oluşmadığı düşünüldüğünde bu çalışmanın oldukça sınırlı bir alana sahip olduğunu söylemek mümkündür. Fakat bu çalışmada önerilen yöntemin bir yumuşatma adımı olarak ön işlemede kullanılabileceğini de not olarak düşmek gerekir.

Zhang ve arkadaşlarının yaptığı çalışmada [16] dönmeden bağımsız Gabor doku özniteliklerine dayalı görüntü erişim metodu önerilmiştir. Önerilen yaklaşım ile görüntülerin tüm içeriğindeki global doku bilgileri çıkarılmış ve çıkarılan bu öznitelik bilgileri benzerlik ölçümü için de kullanılmıştır. Söz konusu yöntem görüntünün tüm

içeriğinde veya ana parçasında düzenli bir doku bilgisi varsa kullanışlıdır. Gerçek dünyada ise bir görüntü farklı doku alanlarının mozaiği şeklinde olabilir. Bu durumda önerilen yaklaşımın çıkaracağı özniteliklerin nasıl bir davranışa sahip olacağı, bu özniteliklerin başarılı olup olmayacağı belirsizdir. Bu yüzden doku bölütleme üzerine ilave bir çalışma yapılması ve sonuçlarının bu bağlamda değerlendirilmesi gerekmektedir.

2013 yılında yapılan ve bu tez çalışmasına da altlık olan çalışmanın [17] ilk yarısında tespit edilmesi istenen görüntüler yeniden boyutlandırma ve renk entropisi hesaplama ön işleme adımlarından geçirilmiştir. Ardından bu görüntülerin SIFT [18] öznitelikleri tespit edilmiş ve Flann [19] ile indekslenmiştir. Bölüm 1.2.1 ile 1.2.5 arasında ayrıntıları anlatılan bu yöntemde indeksleme için Hiyerarşik K-Means [20], arama için de KNN kullanılmıştır. Sorgu fotoğrafı da aynı ön işleme adımlarından geçirilmiş ve SIFT öznitelikleri çıkarılmıştır. Sorgu fotoğrafının öznitelikleri ile tespit edilmesi istenen fotoğrafların SIFT indeksi karşılaştırılmış ve sorgu fotoğrafına en benzer 3 fotoğraf tespit edilmiştir. Fakat söz konusu çalışma herhangi bir veri kümesi üzerinde uygulanıp değerlendirilmemiş ve sadece SIFT öznitelikleri kullanılmış olup diğer tanımlayıcılar test edilmemiştir.

1.2.1 Flann

Yüksek boyutlu uzayda yaklaşık en yakın komşu aramalarını hızlı gerçekleştiren bir kütüphanedir. En yakın komşuluk aramasında veri kümesine göre optimum parametreleri ve en iyi algoritmayı otomatik olarak seçen bir dizi algoritmayı içermektedir. Kütüphane temel olarak iki yapıdan oluşmaktadır:

- İndeksleme: Lineer, KD Tree, K-Means, Composite, LSH, Autotuned
- Arama: KNN, Radius

1.2.2 K-Means

K-Means [21] kümeleme başta veri madenciliği olmak üzere birçok alanda tercih edilen bir vektör niceleme yöntemidir. Diğer sınıflandırma yöntemlerine göre en önemli avantajı hiçbir sınıf bilgisi olmadan eldeki mevcut verilerle k adet kümeye gruplama işlemidir. Gruplama işlemi için öncelikle küme sayısına (k) karar verilir. Daha sonra her bir kümenin ağırlık merkezi noktası belirlenir.


Başlangıç ağırlık noktaları olarak veri setinden rastgele k nokta seçilebilir veya veriler sıralanarak her k ve k 'nın katlarında yer alan değerler ağırlık noktaları olarak alınabilir. Daha sonra k -means algoritmasında, kümeler içerisinde yer alan nesnelere hareketsiz kalıncaya kadar üç aşamadan oluşan işlem tekrarlanır:

- Ağırlık noktalarına karar verilir.
- Her bir nesnenin ağırlık noktalarına olan uzaklıkları hesaplanır.
- Her bir nesne minimum uzaklığa sahip olduğu kümeye atanır. Her bir nesne ile küme ağırlık merkezi arasındaki mesafeyi ölçmek için Öklid mesafesi kullanılır.

Çok sayıda değişkenin olduğu durumlarda bile düşük bellek kullanımı ile hiyerarşik kümeleme yöntemlerine göre daha avantajlı olan K -Means kümelemenin en önemli dezavantajı optimum k parametresinin belirlenmesi ve bunun doğrulanmasıdır. Ayrıca farklı başlangıç bölümleri ile farklı kümeler oluşturması da bu yöntemin bir diğer dezavantajıdır.

1.2.3 Hiyerarşik K -Means

Hiyerarşik K -Means algoritması veri kümesini yinelemeli olarak kümelere ayrıştırır. Şekil 1.3'ün üst bölümünde görüldüğü üzere veri kümesine ilk olarak k -means kümelemeyi uygular, burada k parametresi için 2'yi seçer. Daha sonra ayrıştırılan her bir kümede yine k parametresi 2 olan k -means kümelemeyi uygular ve yinelemeli bir şekilde devam eder. Ne zamanki kümelere tek bir nokta kalır veya durdurma kriterine ulaşırsa algoritma durur ve kümeleme tamamlanır.



Şekil 1.3 Hiyerarşik K-Means

1.2.4 K en yakın komşu

K En Yakın Komşu yöntemi, sınıflandırma problemini çözen denetimli öğrenme yöntemleri arasında yer alır. Yöntemde; sınıflandırma yapılacak verilerin öğrenme kümesindeki normal davranış verilerine benzerlikleri hesaplanarak; en yakın olduğu düşünülen k verinin ortalamasıyla, belirlenen eşik değere göre sınıflara atamaları yapılır. Önemli olan, her bir sınıfın özelliklerinin önceden net bir şekilde belirlenmiş olmasıdır.

Yöntemin performansını k en yakın komşu sayısı, eşik değeri, benzerlik ölçümü ve öğrenme kümesindeki normal davranışların yeterli sayıda olması kriterleri etkilemektedir.

Örneğin $k = 3$ için yeni bir eleman sınıflandırılmak istensin. Bu durumda eski sınıflandırılmış elemanlardan en yakın 3 tanesi alınır. Bu elemanlar hangi sınıfa dâhilse, yeni eleman da o sınıfa dâhil edilir. Mesafe hesabında genelde öklid mesafesi kullanılır.

1.2.5 Öklid mesafesi

İki nokta arasındaki doğrusal uzaklıktır. P ve Q sırasıyla Eşitlik 1.1 ve 1.2'deki elemanlardan oluşan iki vektör olsun.

$$P=(p_1,p_2,p_3,\dots p_n) \quad (1.1)$$

$$Q=(q_1,q_2,q_3,\dots q_n) \quad (1.2)$$

Bu iki nokta arasındaki öklid uzaklığı Eşitlik 1.3'teki şekilde hesaplanır:

$$\sqrt{(p_1-q_1)^2+(p_2-q_2)^2+(p_3-q_3)^2+\dots+(p_n-q_n)^2} \quad (1.3)$$

1.3 Tezin Genel Yapısı

İçerik Tabanlı Görüntü Erişimi'nde Ağırlıklandırılmış Öznitelik Füzyonu'nun önerildiği bu tezin ilk bölümünde (Bölüm 1.1) çalışmanın konusu, amacı ve kapsamı açıklanmıştır. Önerilen yöntemle benzer çalışmalar, ilgili kaynaklar ve bu çalışmayla altlık olan çalışmadaki yöntemler ise Bölüm 1.2'de detaylı bir şekilde aktarılmıştır.

İkinci bölümde problemin nasıl çözüleceğine dair önerilen yöntemin adımlarına ve bu adımlarda kullanılan yöntemlerin ayrıntılı açıklamalarına yer verilmiştir. Öncelikle problemin çözümünde hangi adımların uygulandığı ve bu adımlar ile ilgili genel açıklamalara yer verilmiştir (Bölüm 2.1). Bölüm 2.2'de hem sorgu hem de tespit edilmesi istenen görüntüler üzerindeki ön işleme adımından ve bu adımda hangi yöntemin uygulandığından bahsedilmiştir. Ön işleme fazından geçen görüntülerdeki ilgi noktalarının tespiti ve öznitelik çıkarımında kullanılan yöntemler ayrıntılı bir şekilde aktarılmıştır (Bölüm 2.3). Bu bölümde öznitelik çıkarımında kullanılan tanımlayıcılardan da bahsedilmiştir. Tanımlayıcıların veri kümesi üzerinde uygulanması sonucunda elde edilen çıktılardan örneklerin de verildiği bu bölümde öznitelik vektörünün nasıl normalize edildiği de anlatılmıştır. Normalize edilen öznitelik vektörlerinin eşleştirilme yöntemi Bölüm 2.4'te, eşleştirme sonrasındaki ağırlıklandırma yöntemi ise Bölüm 2.5'te ifade edilmiştir.

Üçüncü bölümde tez kapsamında önerilen yöntemin değerlendirildiği veri kümeleri hakkında ayrıntılı bilgi ve bu veri kümelerinden örnekler verilmiştir. Inria Holidays veri kümesindeki sorgu ve tespit edilmesi istenen fotoğraflardan Bölüm 3.1'de bahsedilmiş, örneklere de yine aynı bölümde yer verilmiştir. Inria Copy Days ve alt

veri kümelerindeki sorgu ve tespit edilmesi istenen fotoğraflardan ise Bölüm 3.2'de bahsedilmiş, örneklere de yine aynı bölümde yer verilmiştir.

Dördüncü bölümün başında tez konusu çalışmaların yapıldığı test ortamı, konfigürasyon ve bu kapsamda kullanılan kütüphaneden (Bölüm 4.1) bahsedilmiştir. Bölüm 4.2'de önerilen yöntemin uygulanmasıyla elde edilen sonuçlar değerlendirilmiş ve bu sonuçlar bağlamındaki yorumlar ve tartışmalar aktarılmıştır.

Beşinci bölümde tez çalışmasından elde edilen sonuçlar ve bu sonuçların geliştirilmesi için planlanan çalışmalar aktarılmıştır.

Kaynaklar Listesi'nden sonraki bölümde ise çalışma kapsamında önerilen yöntemin veri kümesi üzerinde uygulanması sonucu elde edilen Doğru Pozitif ve Yanlış Pozitif eşleşmelerine yer verilmiştir.

2 ÖNERİLEN YÖNTEM

2.1 Genel Metodoloji

Bu tez çalışması kapsamında içerik tabanlı görüntü erişiminde ağırlıklandırılmış öznitelik füzyonu için aşağıdaki adımlar sırası ile uygulanmıştır:

- Ön işleme
- İlgili noktalarının tespiti ve çıkarımı
- Eşleştirme
- Ağırlıklandırma

Bu tez kapsamında literatürde sıklıkla kullanılan ve performansı kanıtlanmış olan SIFT, SURF [22] ve ORB [23] öznitelikleri tercih edilmiştir.

Sırasıyla SIFT, SURF ve ORB öznitelikleri tespit edilmiş ve çıkarılmıştır. Özniteliklerin tespiti ve çıkarılmasında, korunacak en iyi özellik sayısı olarak 500 tercih edilmiştir. Çıkarılan öznitelikler birleştirilmemiş, üçü de ayrı matrislerde saklanmıştır. Karşılaştırma aşamasında her tanımlayıcının ilgili tanımlayıcı ile karşılaştırılması için bu yöntem tercih edilmiştir.

Her üç tanımlayıcı ile elde edilen öznitelik vektörü de $[0-1]$ aralığına normalize edilmiştir. Böylece gürbüz olan özniteliklerin tespit edilip saklanmasında her üç tanımlayıcı için de ortak bir eşik değeri tercih edilmesi sağlanmıştır.

Bu aşamaya kadar yapılan tüm işlemler sorgu fotoğraflarına da uygulanmış ve böylelikle sorgu fotoğraflarının da öznitelik vektörleri elde edilmiştir.

Önerilen yöntemin çalışma hızına dair bir kısıt olmadığı için vektörlerin karşılaştırılması aşamasında kaba-kuvvet eşleştirme yöntemi tercih edilmiştir. Sorgu fotoğraflarının öznitelik vektöründeki her bir elemanın orijinal fotoğraflardan elde edilen öznitelik vektörüne olan öklid mesafesi hesaplanmıştır. Öznitelik vektörleri çıkarıldıktan sonra normalize edildiği için tüm vektör elemanları ve dolayısıyla mesafeler $[0-1]$ aralığında dağılım göstermektedir. Gürbüz olan öznitelik vektörü elemanlarını tespit edebilmek için mesafesi 0.1'den fazla olan öznitelikler elenmiştir.

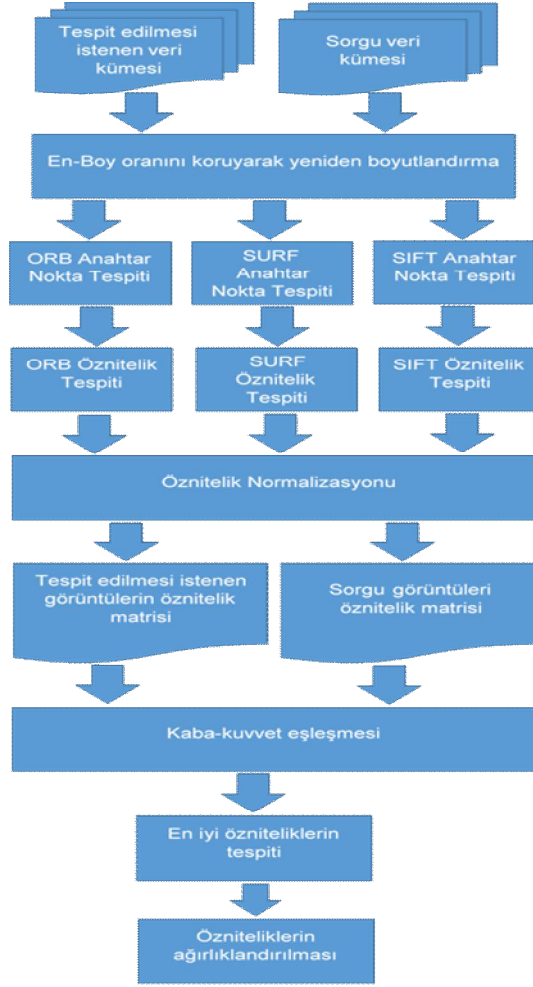
Son olarak, saklanan bu öznitelik vektöründe ağırlıklandırma ile benzerlik tespiti adımı uygulanmıştır.

Tanımlayıcıların tek başlarına uygulandığı durumlarda açık bir şekilde gözlenebileceği gibi SIFT tanımlayıcıları genellikle tüm sonuçlarda diğer tanımlayıcılara göre daha yüksek bir başarımlarına sahiptir. SIFT'in ardından SURF, en son olarak da ORB gelmektedir. Bu gözlemden hareketle ağırlıklandırma aşamasında eşit ağırlıklandırma yerine başarımları daha yüksek olan aşağıdaki sıralama dikkate alınmış olup önerilen ağırlıklandırma mantığı Bölüm 2.5'de anlatılacaktır:

- SIFT: 0.5
- SURF: 0.3
- ORB: 0.2

Önerilen yöntemin çalışmasını görselleştiren akış şeması Şekil 2.1'de gösterildiği gibidir.

Tüm bu adımlar uygulandıktan sonra sorgu görüntüsüne en benzer orijinal görüntülerin tespit edilmesi için k en yakın komşuluk arama yöntemine [24] benzer şekilde benzer orijinal görüntüler tespit edilmiştir. Burada k parametresi 3 olarak seçilmiştir.



Şekil 2.1 Önerilen yöntemin akış şeması

2.2 Ön İşleme

Veri kümesinde yer alan fotoğrafların büyük boyutlu ve yüksek çözünürlüklü olması, tespit edilecek özniteliklerin gereksiz detaylar içermesine yol açacaktır. Üstelik bu durum öznitelik matrisinin de büyümesine neden olacaktır. Dolayısıyla öznitelik matrisinin yanlış eşleşmelere yol açmaması için tüm fotoğraflar en-boy oranı korunarak en büyük kenarı 400 piksel olacak şekilde yeniden boyutlandırılmıştır. Yeniden boyutlandırma yapılırken Bi-Cubic Enterpolasyon yöntemi kullanılmıştır. Her ne kadar bu çalışmada yöntemin çalışma hızı dikkate alınmamışsa da yeniden boyutlandırma, sistemin daha hızlı çalışmasına yol açmıştır.

2.2.1 Bi-Cubic enterpolasyon

Bi-Cubic Enterpolasyon [25] yöntemi en yakın komşu enterpolasyon yöntemindeki basamak benzeri sınır görünümünün üstesinden gelir ve bilineer enterpolasyon yönteminde ortaya çıkan bulanıklaşma sorununu çözer. Bi-cubic polinom yüzeyinde 16 komşuluk noktasına yerel olarak yaklaşarak görüntüdeki parlaklık enterpolasyonunu geliştirir. Bu yöntem, bazı durumlarda görüntüdeki keskinleştirmeyi arttıran Laplacian'a çok benzerdir.

2.3 İlgi Noktalarının Tespiti ve Öznitelik Çıkarma

Öznitelik, görüntünün sayısal verisinden çıkarılan ve verinin temsil ettiği formu karakterize edebilen kısımlardır. Görüntüdeki renk, doku, şekil, köşe noktası gibi veriler görüntüde kullanılabilen özniteliklerdir. Bunlar görüntünün referans noktalarıdır.

İçerik Tabanlı Görüntü Erişimi'nde görüntünün tüm verisini kullanmak yerine o görüntüyü en iyi temsil eden öznitelikler kullanılır. İki görüntünün öznitelikleri arasındaki mesafe hesaplanarak bu görüntülerin birbirlerine benzerlikleri ölçülür.

Özniteliklerin tespit edilmesi, çıkarılması ve eşleştirilmesinde genel olarak sistem aşağıdaki üç ana kısımdan oluşur:

2.3.1 Öznitelik detektörü

Görüntü üzerinde önemli noktaların konumlarını tespit eder. Bir noktayı önemli yapan unsur detektörün kullandığı algoritmaya göre değişir. Bu noktalara referans noktaları da denir. Bugün bilgisayarlı görü alanında özniteliklerin belirlenmesi amacıyla birçok algoritma kullanılmaktadır.

2.3.2 Öznitelik tanımlayıcı

Önceden tespit edilen referans noktaları için tanımlayıcının kullandığı algoritmaya göre o noktanın ve etrafının durumuna göre öznitelik vektörleri çıkarma işlemidir.

2.3.2.1 SIFT

Görüntü ölçeğinden bağımsız öznitelik belirleme ve çıkarma algoritmasıdır. SIFT görüntü üzerinde köşe ayırt edici noktaları olan köşe noktalarını algılar ve her bir nokta için tanımlayıcılar çıkarır. Bu çıkarılan ilgi noktaları (ayırt edici noktalar)

ölçek, zıtlık ve rotasyondan bağımsızdır. SIFT öznelik algoritmasının temel adımları:

- Gaussian ölçek alanı hesaplanır.
- Gaussian farkı bulunur.
- Aday özelliğine sahip olabilecek anahtar noktalar tespit edilir.
- Kararsız olan noktalar elenir.
- Her bir anahtar noktaya yön belirlenir.
- Her bir anahtar nokta için ayırt edici tanımlayıcılar elde edilir.

2.3.2.2 SURF


Bilgisayarlı görü alanında kullanılan öznelik algoritmalarının bir diğeri SURF'tür. Gürbüz anahtar nokta bulma ve tanımlama yöntemidir. Standart hali SIFT'ten daha hızlıdır ve yazarları tarafından değişik görüntü değişimlerinde SIFT'ten daha gürbüz olduğu belirtilir. SIFT yerel öznelik tanımlayıcısının ikinci temel adımındaki Gaussian farkı yerine Hessian Piramidi tercih edilmiştir. SIFT'e göre ilgi noktası tespit işlemi daha hızlıdır ama asıl olarak eşleştirme adımındaki çalışma zamanını azaltmaya odaklanmıştır. Hessian matrisinin eşleştirme hızına olumlu katkı sağlayabilmek amacıyla düşük boyutlu tanımlayıcılarla kullanılır.

2.3.2.3 ORB

ORB, hızlı ve gürbüz bir yerel öznelik detektörüdür. Bilgisayarlı görü alanındaki nesne tanıma ve 3-boyutlu yeniden yapılandırma problemlerine yönelik olarak geliştirilen yöntem FAST [26] anahtar nokta detektörü ve görsel tanımlayıcı BRIEF [27] tabanlıdır. SIFT'e göre daha hızlı ve yüksek performanslı bir alternatif yöntem olma iddiasındadır. Ayırt edici noktaları tespit etmek için FAST, tespit edilen ayırt edici noktaların özelliklerini çıkarabilmek için ise BRIEF yerel özneliğini kullanır. BRIEF'in rotasyon ve gürültüye karşı duyarsız olmasından kaynaklı olarak böyle bir yöntem tercih edilmiştir. Bu yüzden de "Oriented FAST and Rotated BRIEF" (yönlü FAST ve döndürülmüş BRIEF) olarak adlandırılmıştır.

Öznelik detektörlerinin veri kümesi üzerinde çalışması sonucu elde edilen çıktıların örneği Şekil 2.2'de görülmektedir. Şeklin ilk sütununda SIFT, ortadaki sütununda SURF ve son sütununda ORB tanımlayıcısının sonuçları görülmektedir. Şeklin ilk iki satırında tanımlayıcıların az öznelik bulduğu, diğeri iki satırında ise

daha fazla öznitelik bulunduđu örneklerdir. Özellikle az sayıda özniteliđin bulunduđu örneklerden görülebileceđi üzere SIFT'in tespit edemediđi öznitelikler SURF ve ORB; SURF'un tespit edemediđi öznitelikler SIFT ve ORB; ORB'nin tespit edemediđi öznitelikler ise SIFT ve SURF tarafından tespit edilebilmektedir. Tez kapsamında önerilen yöntem sayesinde bir tanımlayıcı tarafından tespit edilemeyen öznitelikler diđer ikisi tarafından tespit edilebilmekte, böylelikle bir tanımlayıcının eksik kalması durumunda diđer ikisi tarafından tolere edilebilmektedir.



Şekil 2.2 Öznitelik detektörlerinin veri kümesi üzerinde çalışması sonucu tespit edilen tanımlayıcılar

2.3.2.4 Normalizasyon

Vektör normalizasyonu vektör uzunluğunun 0 ile 1 aralığına çekilmesi için kullanılır. Bunun için vektöre ait tüm bileşenler vektör uzunluğuna bölünür. Normalizasyon formülü en genel haliyle Eşitlik 2.1'de yer almaktadır.

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^m x_{ij}^2}}, i = 1, \dots, m; j = 1, \dots, n. \quad (2.1)$$

Tez kapsamında tüm tanımlayıcılardan elde edilen öznitelikler normalize edilmiştir. Bunun uygulanmasındaki temel amaç, öznitelik vektörlerinin eşleştirilmesi sonucunda elde edilen mesafelerde ortak bir eşik değeri belirlenebilmesidir. Eşleştirme sonucunda en gürbüz öznitelikleri tespit edebilmek için mesafesi 0.1 değerinden küçük ve eşit olanlar seçilmiş, diğer öznitelikler elenmiştir. Böylelikle iki görüntü arasındaki birbirine en yakın noktalar eşleşme sonuçlarına dâhil edilmiştir.

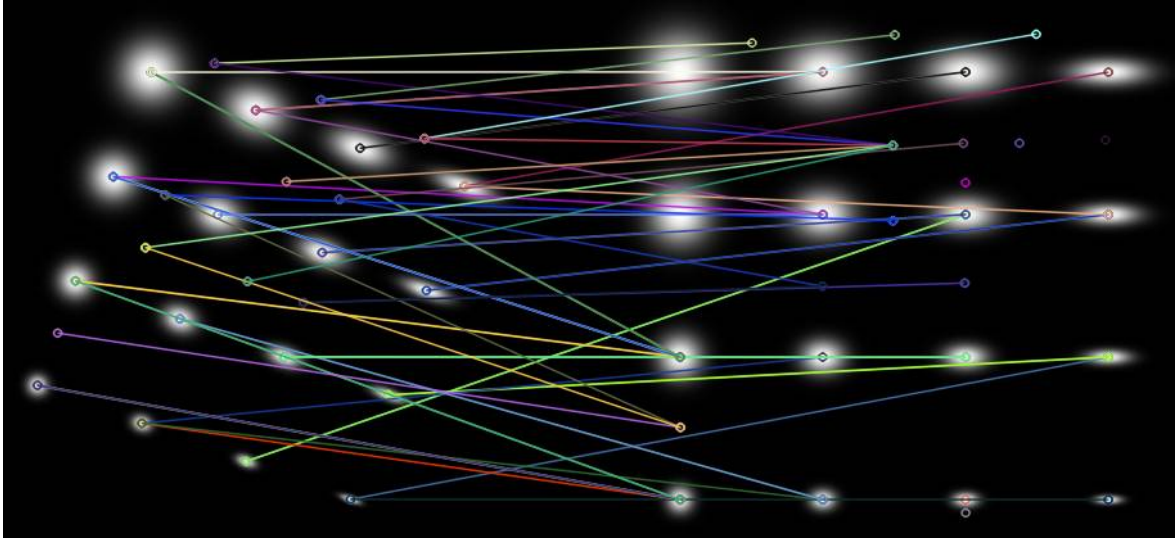
2.4 Öznitelik Tanımlayıcı için Eşleştirici

İki ayrı görüntü arasında öznitelik tanımlayıcılarının çıkardığı vektörleri eşleştirir. Bir diğer ifade ile bir görüntüdeki referans noktasının diğer görüntüdeki referans noktaları ile mesafelerini hesaplar ve en yakın hangi noktaya karşılık geldiğini tespit eder.

Kaba Kuvvet Eşleştirme [28] yöntemi bilgisayar bilimlerinde en genel problem çözme yöntemidir. Sistemik çözüm için tüm adaylar numaralandırılır ve bu her bir adayın problemi çözüp çözmediği kontrol edilir. Yöntem, lineer arama olarak da adlandırılır. Yöntemin karmaşıklığı $O(n^2)$ 'dir. Eşleştirme için Levenshtein, Hamming, Normalized Hamming, Euclidian, Manhattan, Cosine, Jaccard, Jaro gibi farklı mesafe hesaplama yöntemleri de mevcuttur.

Tez kapsamında bu yöntemin uygulanması şu şekilde olmuştur: Tespit edilmesi istenen görüntülerdeki SIFT, SURF ve ORB özniteliklerinin her biri sorgu görüntülerinin SIFT, SURF ve ORB özniteliklerinin her biri ile karşılaştırılmıştır. Mesafe hesaplamada ise öklid mesafe hesaplama yöntemi tercih edilmiştir. Şekil 2.3'te simülasyonu görüldüğü üzere tespit edilmesi istenen ilgi noktalarının her biri

sorgu fotoğrafındaki ilgi noktaları ile eşleştirilmiş ve aralarındaki mesafe hesaplanmıştır.



Şekil 2.3 Şeklin sol tarafındaki parlak noktalar tespit edilmesi istenen görüntüdeki öznitelikler, sağ tarafındaki noktalar ise sorgu görüntüsündeki öznitelikler

2.5 Ağırlıklandırma

İki veya daha fazla seçeneğin bulunduğu ve bu seçeneklerden hangisinin daha iyi olduğunun belirlenmesi gibi durumlarda ağırlıklandırma önem kazanmaktadır. Çünkü tercih edilen ağırlıklandırma yöntemi ve verilen ağırlıkların sayılması işlemi en iyiyi belirlemede etkin rol oynamaktadır. Öyle ki farklı ağırlıklandırma yöntemleri farklı en iyileri ortaya çıkarmaktadır.

Tez kapsamında Borda Sayısı Yöntemi'ne [29] benzer bir yöntem kullanılmıştır. Yaptığımız deneylerden gözlemlediğimiz üzere görüntü eşleştirmelerinde en iyi performansı sırasıyla SIFT, SURF ve ORB öznitelikleri vermiştir. Bu deneylerden elde ettiğimiz gözlemlere dayalı olarak bu 3 öznitelikten elde ettiğimiz sonuçlara aşağıdaki ağırlıklarda oy verilmiş ve en fazla oyu alan öznitelikleri sıralayarak tespit edilmesi istenen görüntüye en benzer ilk 3 görüntü elde edilmiştir.

Kaba-kuvvet eşleştirme sonucunda; sorgu görüntüsündeki özniteliklerin, tespit edilmesi istenen görüntünün özniteliklerinden hangisine en benzer olduğu sonucu elde edilmiştir. Sorgu fotoğrafının bu en benzer öznitelikleri SIFT için 0.5, SURF için 0.3 ve ORB için 0.2 olarak oylanmış ve en fazla oyu alan özniteliklerin hangi

görüntüye ait olduđu bilgisi muhafaza edilerek k en yakın komşuluk arama yöntemine benzer şekilde arama yapılmıştır. Burada k parametresi olarak 3 tercih edilmiştir. Böylelikle sorgu görüntüsüne benzer orijinal görüntülerin ilk 3 tanesi tespit edilmiştir.

3 VERİ KÜMESİ

Tez kapsamında önerilen yöntemin değerlendirme aşamasında gerçek dünyadaki problemlere en uygun olan ve aşağıda detayları verilen veri kümeleri kullanılmıştır. Hem önerilen yöntem hem de karşılaştırılan yöntem bu veri kümeleri üzerinde uygulanmış ve karşılaştırmalı sonuçlar elde edilmiştir.

3.1 Inria Holidays

1491 fotoğraftan oluşan bu veri kümesinde [30] 500 fotoğraf sorgulama amaçlı, 991 fotoğraf da tespit edilmesi istenen fotoğraf olarak kullanılmıştır. Sorgu fotoğrafları üzerinde kesme, piksel yoğunluğu değişimi, döndürme, bulanıklaştırma, perspektif değişimi, aynı perspektiften farklı zamanlarda pozlama, renk değişimi, açı değişimi ve engel (oklüzyon) ekleme problemleri uygulanmıştır.

Veri kümesindeki tespit edilmesi istenen fotoğraflar ve onlarla eşleşen benzer sorgu fotoğrafları ayrıştırılmış olarak hazırlanmıştır. Kesin referanslar (ground truth) ise benzer isimlendirme ile etiketlenmiştir. Veri kümesinde tespit edilmesi istenen fotoğrafa benzer birden fazla fotoğraf yer alabilmektedir.

Fotoğrafların isimlendirilmesinde şu şekilde bir yöntem uygulanmıştır:

- Tespit edilmesi istenen fotoğraf: 100000.jpg
- Tespit edilmesi istenen fotoğrafa benzer sorgu fotoğrafları: 100001.jpg ve 100002.jpg

Tez kapsamında önerilen yöntemin uygulanması sonucunda elde edilen sorgu fotoğrafının ismi ile onunla eşleşmiş tespit edilmesi istenen ilk 3 fotoğrafın isimleri karşılaştırılmış ve doğru pozitifler ile yanlış pozitiflerin oranı bu şekilde hesaplanmıştır. Şekil 3.1, 3.2 ve 3.3'te Inria Holidays veri kümesinden alınan 3 fotoğraf çifti görülmekte olup bu fotoğraflar; tespit edilmesi istenen (sol) ve sorgu (sağ) fotoğrafları olarak ayrılmıştır. Buna göre; Şekil 3.1'deki sorgu fotoğrafı tespit edilmesi istenen fotoğrafın farklı bir perspektiften çekilmiş versiyonudur. Benzer şekilde Şekil 3.2'de yer alan sorgu fotoğrafı tespit edilmesi istenen fotoğrafın kesilmiş versiyonudur. Şekil 3.3'teki sorgu fotoğrafı ise tespit edilmesi istenen fotoğrafın yeniden boyutlandırılmış ve sisli bir havada çekilmiş versiyonudur.



Şekil 3.1 Inria Holidays veri kümesinden örnek-1:



Şekil 3.2 Inria Holidays veri kümesinden örnek-2:



Şekil 3.3 Inria Holidays veri kümesinden örnek-3:

3.2 Inria Copy Days

Bu veri kümesi [31] yakın benzerliklerin tespit edilmesi ve değerlendirilmesi için tasarlanmıştır. Veri kümesi 157 fotoğraftan oluşmaktadır. Bu küme üzerinde farklı dönüşüm senaryoları dâhilinde 3 ayrı alt sorgu veri kümesi oluşturulmuştur.

Veri kümesindeki tespit edilmesi istenen fotoğraflar ve onlarla eşleşen benzer sorgu fotoğrafları ayrıştırılmış olarak hazırlanmıştır. Kesin referanslar (ground truth) ise aynı isimlendirme ile etiketlenmiştir. Veri kümesinde tespit edilmesi istenen fotoğrafa benzer sadece bir fotoğraf yer almaktadır.

Fotoğrafların isimlendirilmesinde şu şekilde bir yöntem uygulanmıştır:

- Tespit edilmesi istenen fotoğraf: 100000.jpg
- Tespit edilmesi istenen fotoğrafa benzer sorgu fotoğrafı: 100000.jpg

Tez kapsamında önerilen yöntemin uygulanması sonucunda elde edilen sorgu fotoğrafının ismi ile onunla eşleşmiş tespit edilmesi istenen ilk 3 fotoğrafın isimleri karşılaştırılıp doğru pozitifler ile yanlış pozitiflerin oranı bu şekilde hesaplanmıştır. Aşağıda Şekil 3.4, 3.5 ve 3.6'da verilmiş olan örneklerle göre sol taraftaki fotoğraf tespit edilmesi istenen, sağ taraftaki fotoğraf ise sorgu fotoğrafıdır. Şekil 3.4 için sorgu fotoğrafı, tespit edilmesi istenen fotoğrafın JPEG3 kalitesine sahip, eni ve boyu 1/4, toplamda 1/16'sına düşürülerek yeniden boyutlandırılmış versiyonudur. Şekil 3.5 ve 3.6 için sorgu fotoğrafları, tespit edilmesi istenen fotoğrafların sırasıyla JPEG8 ve JPEG15 kalitesine sahip, eni ve boyu 1/4, toplamda 1/16'sına düşürülerek yeniden boyutlandırılmış versiyonlarıdır.

3.2.1 Scale jpeg attacked images

Her bir görüntünün yeniden boyutlandırılması (enin ve boyun 1/4'ü olmak üzere toplam yüzeyin 1/16'sına kadar küçültülmesi), en düşük fotoğraf kalitesine sahip JPEG3'ten tipik web kalitesine sahip JPEG75'e kadar toplamda 9 farklı kaliteye sahip problemleri veri kümesidir.



Şekil 3.4 Inria Copy Days veri kümesinden örnek-4:



Şekil 3.5 Inria Copy Days veri kümesinden örnek-5



Şekil 3.6 Inria Copy Days veri kümesinden örnek-6:

3.2.2 Crop

Orijinal veri kümesinde görüntülerin her birinin en ve boyundan belli miktarlarda kesilerek toplamda 9 ayrı alt sorgu veri kümesi oluşturulmuştur. Şekil 3.7’de sol taraftaki fotoğraf tespit edilmesi istenen, diğer fotoğraflar sorgu fotoğrafları olup sorgu fotoğrafları, tespit edilmesi istenen fotoğrafın enden ve boydan sırasıyla %30 (soldan ikinci), %50 (sağdan ikinci) ve %80 (en sağdaki) kesilmiş versiyonlarıdır.



Şekil 3.7 Inria Copy Days veri kümesinden örnek-7:

3.2.3 Strong

Toplam 229 görüntüden oluşan bu kümede baskı ve tarama, engel, zıtlık (kontrast) değişimi, bulanıklaştırma, yüzey alanından kesme, perspektif efekti vb. problemler uygulanmıştır. Şekil 3.8, 3.9, 3.10 ve 3.11’de sunulan örneklerde sol taraftaki fotoğraf tespit edilmesi istenen, sağ taraftaki fotoğraf ise sorgu fotoğraftır. Şekil 3.8’deki sorgu fotoğrafı, tespit edilmesi istenen fotoğrafın taranmış, kesilmiş, döndürülmüş ve en-boy oranı sabit tutulmadan yeniden boyutlandırılmış versiyondur. Şekil 3.9’da ise sorgu fotoğrafı, tespit edilmesi istenen fotoğrafın yarısına gürültü eklenmiş ve en-boy oranı sabit tutulmadan yeniden boyutlandırılmış versiyonudur. Öte yandan, Şekil 3.10’daki sorgu fotoğrafı, tespit edilmesi istenen fotoğraftaki dokuların deforme edilmiş, kesilmiş ve yeniden boyutlandırılmış versiyonudur. Son olarak, Şekil 3.11’deki sorgu fotoğrafı, tespit edilmesi istenen fotoğrafın sündürülmüş, en-boy oranı sabit tutulmadan yeniden boyutlandırılmış, zıtlık ve aydınlatma değerlerinin değiştirilmiş versiyonudur.




Şekil 3.8 Inria Copy Days veri kümesinden örnek-8:



Şekil 3.9 Inria Copy Days veri kümesinden örnek-9:



Şekil 3.10 Inria Copy Days veri kümesinden örnek-10:



Şekil 3.11 Inria Copy Days veri kümesinden örnek-11:

4 DENEYSEL SONUÇLAR

4.1 Test Ortamı ve Konfigürasyon

Tez kapsamında önerilen yöntem Ubuntu 14.04 LTS işletim sisteminde ve C++ dili üzerinde geliştirilen OpenCV [32] kütüphanesinin 2.4.10 versiyonu ile gerçekleştirilmiştir. Bu çalışmanın yapıldığı sırada OpenCV'nin C++ kütüphanesinin en son versiyonu olan 2.4.12 versiyonu yayımlanmıştır.

4.1.1 OpenCV

Açık kaynak kodlu bir bilgisayarlı görü kütüphanesidir. Görüntü işleme ile ilgili yüzlerce temel ve ileri seviyedeki fonksiyonu, optimize edilmiş halleriyle barındırmaktadır. İlk olarak Intel'in Rusya'daki laboratuvarlarında, 1999 yılında geliştirilmeye başlanmıştır [33].

Bilindiği gibi açık kaynak kodlu projeler değişik lisanslara sahip olabilmektedir. Lisansı türüne göre kısıtlamalar içerebilmektedir. OpenCV BSD [34] lisansı altında dağıtılmaktadır. Bu lisans türünde ticari uygulamalardaki kullanımlar dâhil bir engel teşkil etmemektedir.

Başlangıçta C ile kodlanmaya başlanmış olmasına rağmen, 2.0 versiyonundan itibaren C++ temelli bir yapıya kavuşmuştur. OpenCV 3.0 [35] ile daha modern bir yapıya geçmiştir. CUDA desteğiyle birlikte performansında gözle görülür bir artış gerçekleşmiştir. C/C++ dışında pek çok dil (Python, Java, Matlab/Octave, C#) ile de kullanılabilir.

OpenCV, programlama dillerinde olduğu gibi platform ve işletim sistemi konusunda da oldukça geniş bir yelpazede çalışma imkânı sağlamaktadır. Windows, Linux, MacOSX gibi yaygın kullanılan pek çok işletim sistemi üzerinde çalışabilmektedir.

Günümüzün öne çıkan alanlarından olan mobil aygıtlar (Android, Blackbery, iPhone) ve gömülü geliştirme kartları (Beagbone, Raspberry Pi) yine OpenCV'nin kullanılabilceği platformlardandır.

4.2 Değerlendirme Sonuçları ve Tartışma

Önerilen yöntem kapsamında yapılan ağırlıklandırma sonucunda öznelik vektörleri sıralanmış, bu vektör elemanlarının ait olduğu orijinal fotoğraflardan

ağırlıklandırmada en çok oya sahip ilk 3 tanesi tespit edilmiş ve aşağıdaki çizelgelerde verilen sonuçlar elde edilmiştir.

Verilen tablolarda yer alan “Doğru Pozitif” geri-getirimde ilk 3'te yer alan fotoğraf sayılarını gösterirken, “Yanlış Pozitif” geri-getirim işleminin başarısız olduğu durumları ifade etmektedir. Hassasiyet değeri ise Eşitlik 4.1'de gösterildiği gibi Doğru Pozitif değerinin toplam fotoğraf sayısına oranını göstermektedir.

$$Hassasiyet = \left(\frac{\text{Doğru Pozitiflerin Sayısı}}{\text{Doğru Pozitiflerin Sayısı} + \text{Yanlış Pozitiflerin Sayısı}} \right) \quad (4.1)$$

Buna göre, Inria Copy Days Crop veri kümesi üzerinde yapılan testlerin sonuçları Çizelge 4.1 ile Çizelge 4.4 arasında verilmiş, dört yaklaşımın birbirleriyle kıyaslandığı performans grafiği ise Şekil 4.1'de sunulmuştur.

Çizelge 4.1 Inria Copy Days Crop veri kümesi üzerinde ORB tanımlayıcı ve FLANN indeks kullanılarak elde edilen sonuçlar

Veri Kümesi	Doğru Pozitif	Yanlış Pozitif	Hassasiyet
10	157	0	1
15	157	0	1
20	157	0	1
30	156	1	0.9936
40	156	1	0.9936
50	153	4	0.9745
60	150	7	0.9554
70	131	26	0.8343
80	94	63	0.5987

Çizelge 4.2 Inria Copy Days Crop veri kümesi üzerinde SIFT tanımlayıcı ve FLANN indeks kullanılarak elde edilen sonuçlar

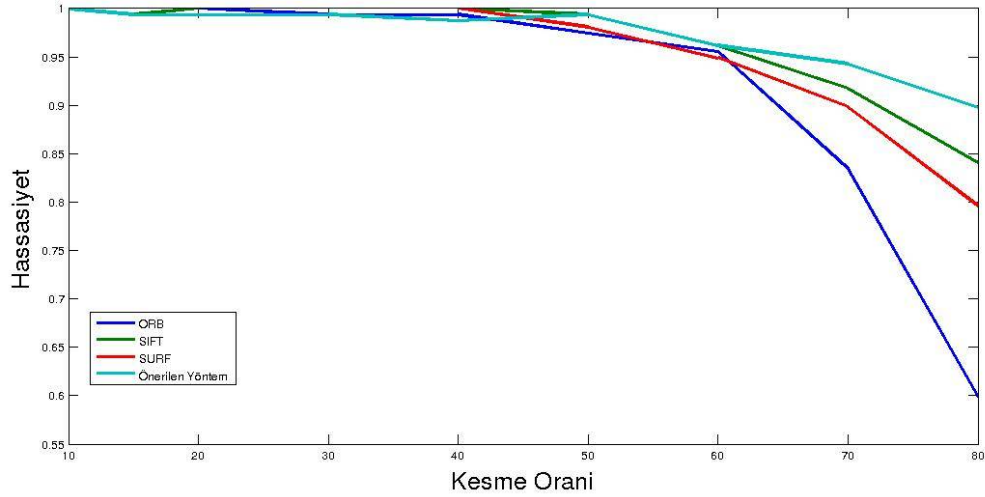
Veri Kümesi	Doğru Pozitif	Yanlış Pozitif	Hassasiyet
10	157	0	1
15	156	1	0.9936
20	157	0	1
30	157	0	1
40	157	0	1
50	156	1	0.9936
60	151	6	0.9617
70	144	13	0.9171
80	132	25	0.8407

Çizelge 4.3 Inria Copy Days Crop veri kümesi üzerinde SURF tanımlayıcı ve FLANN indeks kullanılarak elde edilen sonuçlar

Veri Kümesi	Doğru Pozitif	Yanlış Pozitif	Hassasiyet
10	157	0	1
15	157	0	1
20	157	0	1
30	157	0	1
40	157	0	1
50	154	3	0.9808
60	149	8	0.9490
70	141	16	0.8980
80	125	32	0.7961

Çizelge 4.4 Inria Copy Days Crop veri kümesi üzerinde Ağırlıklandırılmış Öznitelik Füzyonu yönteminin uygulanmasının sonuçları

Veri Kümesi	Doğru Pozitif	Yanlış Pozitif	Hassasiyet
10	157	0	1
15	156	1	0.9936
20	156	1	0.9936
30	156	1	0.9936
40	155	2	0.9872
50	156	1	0.9936
60	151	6	0.9617
70	148	9	0.9426
80	141	16	0.8980



Şekil 4.1 Inria Copy Days Crop veri kümesi üzerinde ORB tanımlayıcı ve FLANN indeks, SIFT tanımlayıcı ve FLANN indeks, SURF tanımlayıcı ve FLANN indeks ile Ağırlıklandırılmış Öznitelik Füzyonu yöntemlerinin uygulanmasının karşılaştırmalı sonuçları

Elde edilen sonuçlara göre kesme oranı %50'ye yakınsayana kadar ORB tanımlayıcının geri getirim performansı olumsuz etkilenmemektedir. Benzer şekilde kesme oranı %60'a yakınsayana kadar SIFT ve SURF tanımlayıcıların performansının da oldukça iyi olduğu gözlemlenmektedir. Ancak, kesme oranı %70 ve %80 oranına ulaştığında her 3 tanımlayıcının da ayrı ayrı çalıştığı durumda yakalayamadığı fotoğraf sayısında ciddi bir artış olduğu görülmektedir. Oysa Ağırlıklandırılmış Öznitelik Füzyonu'nda kesme oranı %70'e ulaştığında ORB'ye

göre yaklaşık %11, SURF'e göre %5, SIFT'e göre %3'lük bir oranda daha iyi geri getirim performansına sahip olduğu görülmektedir. Kesme oranı %80'e ulaştığında önerilen yöntemin ORB'ye göre yaklaşık %30, SURF'e göre %10, SIFT'e göre ise %5'lik bir oranda daha iyi geri getirim performansına sahip olduğu görülmektedir. SIFT tek başına uygulandığında 157 fotoğraftan oluşan Inria Copy Days Crop veri kümesinden 25 adet fotoğraf ilk 3 sonuç içerisinde tespit edilemezken bu sayı Ağırlıklandırılmış Öznitelik Füzyonu'nda 16'ya düşmektedir. Kesme oranı arttıkça fotoğraf içerisindeki ilgi noktalarının tespiti zorlaşmaktadır. Bir tanımlayıcının ilgi noktası olarak göremediği bir öznitelik bir başka tanımlayıcı tarafından tespit edilebilmektedir. Ağırlıklandırılmış Öznitelik Füzyonu sayesinde probleme göre zayıf karakteristiğe sahip olan bir tanımlayıcı bir başka tanımlayıcı tarafından tolere edilebilmektedir.

Inria Copy Days Scale JPEG Attacked Images veri kümesi üzerinde yapılan testlerin sonuçları Çizelge 4.5 ile Çizelge 4.8 arasında verilmiş, dört yaklaşımın birbirleriyle kıyaslandığı performans grafiği ise Şekil 4.2'de sunulmuştur.

Çizelge 4.5 Inria Copy Days Scale JPEG Attacked Images veri kümesi üzerinde ORB tanımlayıcı ve FLANN indeks kullanılarak elde edilen sonuçları

Veri Kümesi	Doğru Pozitif	Yanlış Pozitif	Hassasiyet
3	148	9	0.9426
5	153	4	0.9745
8	157	0	1
10	157	0	1
15	157	0	1
20	157	0	1
30	157	0	1
50	157	0	1
75	157	0	1

Çizelge 4.6 Inria Copy Days Scale JPEG Attacked Images veri kümesi üzerinde SIFT tanımlayıcı ve FLANN indeks kullanılarak elde edilen sonuçları

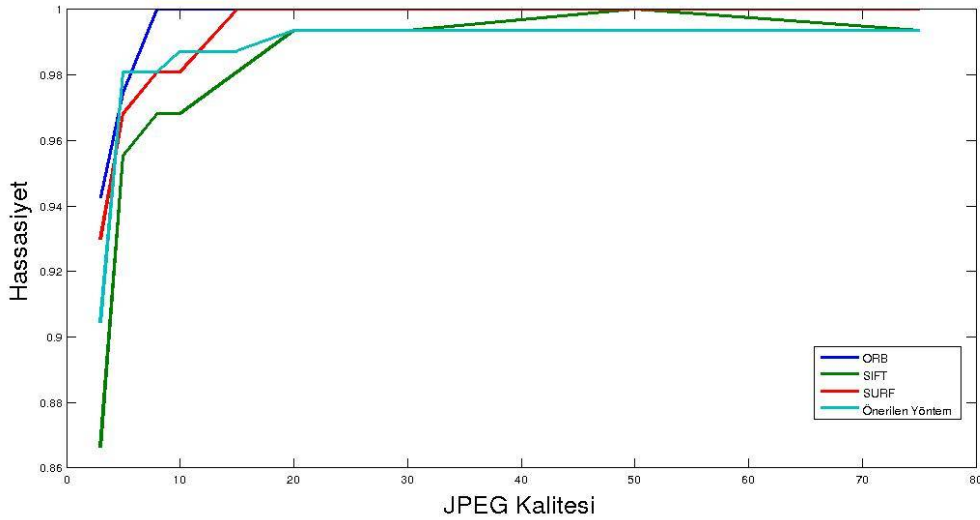
Veri Kümesi	Doğru Pozitif	Yanlış Pozitif	Hassasiyet
3	136	21	0.8662
5	150	7	0.9554
8	152	5	0.9681
10	152	5	0.9681
15	154	3	0.9808
20	156	1	0.9936
30	156	1	0.9936
50	157	0	1
75	156	1	0.9936

Çizelge 4.7 Inria Copy Days Scale JPEG Attacked Images veri kümesi üzerinde SURF tanımlayıcı ve FLANN indeks kullanılarak elde edilen sonuçları

Veri Kümesi	Doğru Pozitif	Yanlış Pozitif	Hassasiyet
3	146	11	0.9299
5	152	5	0.9681
8	154	3	0.9808
10	154	3	0.9808
15	157	0	1
20	157	0	1
30	157	0	1
50	157	0	1
75	157	0	1

Çizelge 4.8 Inria Copy Days Scale JPEG Attacked Images veri kümesi üzerinde Ağırlıklandırılmış Öznitelik Füzyonu yönteminin uygulanmasının sonuçları

Veri Kümesi	Doğru Pozitif	Yanlış Pozitif	Hassasiyet
3	142	15	0.9044
5	154	3	0.9808
8	154	3	0.9808
10	155	2	0.9872
15	155	2	0.9872
20	156	1	0.9936
30	156	1	0.9936
50	156	1	0.9936
75	156	1	0.9936



Şekil 4.2 Inria Copy Days Scale JPEG Attacked Images veri kümesi üzerinde ORB tanımlayıcı ve FLANN indeks, SIFT tanımlayıcı ve FLANN indeks, SURF tanımlayıcı ve FLANN indeks ile Ağırlıklandırılmış Öznitelik Füzyonu yöntemlerinin uygulanmasının karşılaştırmalı sonuçları

Inria Copy Days Scale JPEG veri kümesinde fotoğrafların JPEG kalitesi arttıkça tanımlayıcıların geri getirim performansı yükselmektedir. Bu kümedeki sorgu fotoğraflarının geri getiriminde ORB tanımlayıcının başarı oranı Şekil 4.2'de de görülebileceği üzere diğerlerine göre daha yüksek çıkmıştır. ORB'nin ardından SURF, sonra da SIFT gelmektedir. En düşük JPEG kalitesine sahip olan JPEG3 veri kümesinde Ağırlıklandırılmış Öznitelik Füzyonu SIFT'e göre yaklaşık %4'lük

daha iyi bir geri getirim performansına sahiptir. Aynı veri kümesinde Ağırlıklandırılmış Öznitelik Füzyonu'na göre ORB %2, SURF ise %2,5 daha iyi bir geri getirim performansına sahiptir. Fotoğrafların JPEG kalitesi yükseldikçe her 4 yöntemin sonuçları da birbirine yakınsamakta, çünkü tespit edilen ilgi noktalarının sayısı artmaktadır. JPEG3 kalitesine sahip olan fotoğraflardan oluşan veri kümesindeki fotoğrafların ORB ve SURF tanımlayıcılar kullanıldığında geri getirim başarımının yüksek olması Ağırlıklandırılmış Öznitelik Füzyonu'nda bu tanımlayıcıların ağırlıklarının düşük olması ile yorumlanabilir.

Inria Copy Days Strong ve Holidays veri kümesi üzerinde yapılan testlerin sonuçları Çizelge 4.9'da verilmiştir.

Çizelge 4.9 Inria Copy Days Strong ve Holidays veri kümeleri üzerinde ORB tanımlayıcı ve FLANN indeks, SIFT tanımlayıcı ve FLANN indeks, SURF tanımlayıcı ve FLANN indeks ile Ağırlıklandırılmış Öznitelik Füzyonu yöntemlerinin uygulanmasının karşılaştırmalı sonuçları

Yöntem	Metrik	Copy Days Strong	Inria Holidays
ORB	Doğru Pozitif	126	383
	Yanlış Pozitif	103	608
	Hassasiyet	0.5502	0.3865
SURF	Doğru Pozitif	124	537
	Yanlış Pozitif	105	454
	Hassasiyet	0.5415	0.5419
SIFT	Doğru Pozitif	153	570
	Yanlış Pozitif	76	421
	Hassasiyet	0.6681	0.5752
Önerilen Yöntem	Doğru Pozitif	180	660
	Yanlış Pozitif	49	331
	Hassasiyet	0.7860	0.6660

Çizelge 4.9'un üçüncü sütununda Inria Copy Days Strong veri kümesi üzerindeki testlerin sonuçları verilmiştir. Bu veri kümesinde yer alan fotoğraflar karışık problemlere sahip olduğu için her 3 tanımlayıcının ayrı ayrı uygulanması sonucunda en yüksek geri getirim performansı %66 ile SIFT'e aittir. Ardından ORB %55 ile gelmektedir. En son olarak da SURF %54 geri getirim performansı ile dikkat çekmektedir. Ağırlıklandırılmış Öznitelik Füzyonu ise SURF'e göre %24,

ORB'ye göre %23, SIFT'e göre ise yaklaşık %12 daha iyi geri getirim performansına sahiptir. Ağırlıklandırılmış Öznitelik Füzyonu'nun bu veri kümesi üzerindeki geri getirim performansı %78.6 olmuştur. 229 fotoğraftan oluşan bu veri kümesinde SURF ile 105, ORB ile 103, SIFT ile 76 fotoğraf tespit edilen ilk 3 fotoğraf içerisinde doğru olarak yer almamıştır. Bu sayı Ağırlıklandırılmış Öznitelik Füzyonu'nda ise 49'a kadar düşmüştür. Bu kadar fazla sayıda problem içeren bu veri kümesinde dahi Ağırlıklandırılmış Öznitelik Füzyonu'nun performansı tanımlayıcıların ayrı ayrı uygulandığı durumlara göre çok daha iyi sonuçlar vermektedir.

Çizelge 4.9'un dördüncü sütununda ise Inria Holidays veri kümesi üzerindeki test sonuçları yer almaktadır. 991 sorgu fotoğrafından oluşan bu kümedeki fotoğraflar da geniş bir problem skalasına sahiptir. Bu küme üzerinde ORB tek başına uygulandığında diğerlerine göre oldukça kötü sonuç vermiş ve sadece %38'lik bir geri getirim performansına sahip olmuştur. SURF ise Inria Copy Days Strong veri kümesindeki yakınına yakın bir sonuçla %54'lük bir performansa sahiptir. SIFT tanımlayıcının performansı da önceki veri kümesine göre bir düşüş göstererek %57'lik bir geri getirim performansına sahip olmuştur. SIFT ve ORB'deki bu düşüş Ağırlıklandırılmış Öznitelik Füzyonu'na da yansımış ve başarı oranı %66'ya gerilemiştir. Fakat yine de 3 tanımlayıcının ayrı ayrı uygulandığındaki performanslarına göre daha iyi sonuçlar vermiştir. Ağırlıklandırılmış Öznitelik Füzyonu bu veri kümesinde SIFT'e göre %9, SURF'e göre %12 ve ORB'ye göre %28 oranında daha iyi bir geri getirim performansına, bir diğer ifade ile %66.6'lık doğru pozitif oranına sahip olduğu gözlenmektedir.

5 SONUÇ VE GELECEK ÇALIŞMALAR

Bu çalışmada “İçerik Tabanlı Görüntü Erişimi”nde tercih edilen tanımlayıcıların performansları değerlendirilmiş ve fotoğraflardaki problemin içeriğine göre tanımlayıcı tercih etmek yerine jenerik bir çözüm olarak Ağırlıklandırılmış Öznitelik Füzyonu önerilmiştir. Elde edilen sonuçlara göre Ağırlıklandırılmış Öznitelik Füzyonu'nun, bu füzyonda yer alan her bir tanımlayıcıdan genelde daha başarılı sonuçlar verdiği görülmüştür. Füzyon kapsamında tanımlayıcıların birbirlerini tolere edebildiği, bir tanımlayıcının zayıf olduğu yerde bir diğer tanımlayıcının oradaki eksiği kapattığını da gözlemlemek mümkündür.

Önerilen yöntemin ilk adımında sadece yeniden boyutlandırma ön işlemi uygulanmıştır. Kullanılan veri kümesindeki fotoğraflarda öne çıkan gürültü etkisi gözlemlenmediği için gürültü temizleme ve yumuşatma filtreleri kullanılmamıştır. Gürültü olasılığına karşı ilerleyen çalışmalarda bu filtrelerden en iyi performansı veren yöntemin kullanılması planlanmaktadır.

Bu çalışmada kümeleme yöntemleri denenmemiştir. İlerleyen süreçte başta hiyerarşik k-means olmak üzere özniteliklerin kümelenmesi ve böylelikle karşılaştırma adımında öznitelik vektörünün kullanılması yerine elde edilen bu modelin kullanılması hedeflenmektedir. Bu yöntem uygulanırken hem sığa, hem de çalışma hızı performansı kriterleri dikkate alınacak ve aralarındaki ilişki yorumlanmaya çalışılacaktır.

Karşılaştırılan yöntemde kullanılan Flann Based Indexing ve Matching yönteminin bir benzeri Ağırlıklandırılmış Öznitelik Füzyonu'nda da test edilecek ve sonuçları değerlendirilecektir. Böylelikle öznitelik vektörü matrisinin indekslenmeden ve indekslendikten sonra geri getirim performansını ve çalışma hızını nasıl etkilediği değerlendirilecektir. Yine bu tez çalışmasında bahsi geçen öklid mesafe hesaplama dışındaki yöntemlerin performansı da değerlendirilecektir.

KAYNAKLAR LİSTESİ

- [1] Siegler, M.G., Google Image Search: Over 10 Billion Images, 1 Billion Pageviews A Day. Techcrunch, <http://techcrunch.com/2010/07/20/google-image-search/>. (Son erişim: 5 Ocak 2016), 20 Temmuz 2010.
- [2] Celebrating a Community of 400 Million, Instagram Blog, <http://blog.instagram.com/post/129662501137/150922-400million> (Son erişim: 5 Ocak 2016), 22 Eylül 2015.
- [3] Bullas, J., 21 Awesome Facebook Facts and Statistics You Need To Check Out, <http://www.jeffbullas.com/2015/04/17/21-awesome-facebook-facts-and-statistics-you-need-to-check-out> (Son erişim: 5 Ocak 2016), 17 Nisan 2015.
- [4] Hatmaker, T., Facebook will tag every photo ever taken of you whether you like it or not, <http://www.dailydot.com/technology/facebook-deepface-science> (Son erişim: 5 Ocak 2016), 7 Şubat 2015.
- [5] Tonta, Yaşar, Bilgi erişim sorunu, 21. Yüzyıla Girerken Enformasyon Olgusu: Ulusal Sempozyum Bildirileri, s.198-206, 19-20 Nisan 2001.
- [6] Torres, R. D. S., Falcão A. X., Content-Based Image Retrieval: Theory and Applications, *Revista de Informática Teórica e Aplicada*, vol. 13, s. 161-185, 2006.
- [7] Datta, R., Joshi, D., Li, J., Wang, J. Z., Image Retrieval: Ideas, Influences, and Trends of the New Age, *ACM Computing Surveys*, vol. 40, no. 2, article 5, s. 1-60, 2008.
- [8] Rui, Y., Huang, T. S., Chang, S., Image Retrieval: Current Techniques, Promising Directions and Open Issues, *Journal of Visual Communication and Image Representation*, Vol. 10 (1), s. 39-62, 1 Mart 1999.
- [9] Wang, L., Khan, L., Liu, L., Wu, W., Automatic Image Annotation and Retrieval Using Weighted Feature Selection, *Multimedia Software Engineering*, 2004. Proceedings. IEEE Sixth International Symposium, pp.435-442, 13-15 Dec. 2004.
- [10] Wang, J., Zhu, Z., Image Retrieval System Based on Multi-Feature Fusion and Relevance Feedback, *Machine Learning and Cybernetics (ICMLC)*, 2010 International Conference, vol.4, pp.2053-2058, 11-14 Temmuz 2010.
- [11] Yue, J., Li, Z., Liu, L., Fu, Z., Content-based Image Retrieval Using Color and Texture Fused Features, *Mathematical and Computer Modelling*, Volume 54, Issues 3-4, Pages 1121-1127, August 2011.
- [12] APAYDIN, Ethem, *Yapay Öğrenme*, Boğaziçi Üniversitesi Yayınevi, 95s., 2012.
- [13] Jégou, H., Perronnin, F., Douze, M., Sánchez, J., Pérez, P., Schmid, C., Aggregating Local Image Descriptors into Compact Codes, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 34, No. 9, s. 1704-1716, September 2012.

- [14] Yue, J., Li, Z., Liu, L., Fu, Z., Content-based image retrieval using color and texture fused features, *Mathematical and Computer Modelling*, vol. 54, s. 1121-1127, 2011.
- [15] Höschl IV, C., Jan, F., Robust Histogram-based Image Retrieval, *Pattern Recogn. Lett.*, vol. 69, s. 72-81, 2016.
- [16] Zhang, D., Wong, A., Indrawan, M., Lu, G., Content-based Image Retrieval Using Gabor Texture Features, *IEEE Transactions PAMI*, s. 13-15, 2000.
- [17] Soysal, Ö., Oral, T., Çelikkale, B., Köse, G., İçerik Tabanlı Görüntü Erişimi Yöntemi ile Fotoğraf Tespiti ve Logo Tanıma, 30. Ulusal Bilişim Kurultayı, 28-29 Kasım 2013.
- [18] Lowe, D. G., Distinctive image features from scale-invariant keypoints, *International Journal on Computer Vision*, vol. 60, no. 2, s. 91–110, 2004.
- [19] Muja, M., Lowe, D. G., Fast Approximate Nearest Neighbors with Automatic Algorithm Configuration, *International Conference on Computer Vision Theory and Application VISSAPP'09*, s. 331-340, 2009.
- [20] Jain, A. K., Murty, M. N., Flynn, P. J., Data Clustering: A Review, *ACM Comput. Surv.*, vol. 31, s. 264-323, 1999.
- [21] Lloyd, S. P., Least squares quantization in PCM, *IEEE Transactions on Information Theory* vol. 28, s. 129–137, 1982.
- [22] Bay, H., Ess, A., Tuytelaars, T., Gool L. V., Speeded-Up Robust Features (SURF)", *European Conference on Computer Vision (ECCV)*, s. 404-417, 2006.
- [23] Rublee, E., Rabaud, V., Konolige, K., Bradski, G., ORB: An Efficient Alternative to SIFT or SURF, *Computer Vision (ICCV)*, IEEE International Conference on. IEEE, 2011.
- [24] LU, Guojun, *Multimedia Database Management Systems*, Artech House Computing Libraries, 9. Bölüm, 30 Eylül 1999.
- [25] Keys, R., Cubic convolution interpolation for digital image processing, *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 29, s. 1153–1160, 1981.
- [26] Rosten, E., Porter, R., Drummond, T., Faster and better: a machine learning approach to corner detection, *CoRR*, vol. Abs/0810.2434, 2008.
- [27] Calonder, M., Lepetit, V., Strecha, C., Fua, P., BRIEF: Binary Robust Independent Elementary Features, *Computer Vision – ECCV 2010*, vol. 6314, s. 778-792, 2010.
- [28] PAAR, Christof, PELZL, Jan, PRENEEL, Bart, *Understanding Cryptography: A Textbook for Students and Practitioners*, Springer, 7s., 2010.

- [29] NABİYEV, Vasif Vagifođlu, Teoriden Uygulamalara Algoritmalar, Seçkin Yayıncılık, 794s., 2009.
- [30] Jégou, H., Douze, M., Schmid, C., Hamming Embedding and Weak Geometric Consistency for Large Scale Image Search, Proc. 10th European Conf. Computer Vision, Oct. 2008.
- [31] Douze, M., Jégou, H., Singh, H., Amsaleg, L., Schmid, C., Evaluation of GIST Descriptors for Web-Scale Image Search, Proc. ACM Int'l Conf. Image and Video Retrieval, July 2009.
- [32] <http://ww.opencv.org/> Son Erişim Tarihi: 24 Ocak 2016.
- [33] KUYUMCU, Birol, OpenCV Görüntü İşleme ve Yapay Öğrenme, Level Kitap, 13s., 2015.
- [34] McKUSICK, Marshall Kirk, Open Sources 2.0: The Continuing Evolution, O'Reilly, 401s., 2006.
- [35] <http://docs.opencv.org/3.0-beta/> Son Erişim Tarihi: 24 Ocak 2016.

EKLER LİSTESİ

Sayfa

EK-1: INRIA HOLIDAYS VERİ KÜMESİ ÜZERİNDE AĞIRLIKLANDIRILMIŞ ÖZNİTELİK FÜZYONU YÖNTEMİNİN UYGULANMASI SONUCU ELDE EDİLEN GERÇEK POZİTİF VE SAHTE POZİTİF EŞLEŞMELER	43
EK-2: INRIA COPY DAYS STRONG VERİ KÜMESİ ÜZERİNDE AĞIRLIKLANDIRILMIŞ ÖZNİTELİK FÜZYONU YÖNTEMİNİN UYGULANMASI SONUCU ELDE EDİLEN GERÇEK POZİTİF VE SAHTE POZİTİF EŞLEŞMELER.....	48
EK-3: INRIA COPY DAYS CROP VERİ KÜMESİ ÜZERİNDE AĞIRLIKLANDIRILMIŞ ÖZNİTELİK FÜZYONU YÖNTEMİNİN UYGULANMASI SONUCU ELDE EDİLEN GERÇEK POZİTİF VE SAHTE POZİTİF EŞLEŞMELER.....	54
EK-4: INRIA COPY DAYS SCALE JPEG ATTACK VERİ KÜMESİ ÜZERİNDE AĞIRLIKLANDIRILMIŞ ÖZNİTELİK FÜZYONU YÖNTEMİNİN UYGULANMASI SONUCU ELDE EDİLEN GERÇEK POZİTİF VE SAHTE POZİTİF EŞLEŞMELER.....	60

EK-1

INRIA HOLIDAYS VERİ KÜMESİ ÜZERİNDE AĞIRLIKLANDIRILMIŞ ÖZNİTELİK FÜZYONU YÖNTEMİNİN UYGULANMASI SONUCU ELDE EDİLEN DOĞRU POZİTİF VE YANLIŞ POZİTİF EŞLEŞMELER



Inria Holidays veri kümesindeki 100501.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 100000.jpg, 100500.jpg (doğru eşleşme sonucu), 103600.jpg.



Inria Holidays veri kümesindeki 101101.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 100000.jpg, 101100.jpg (doğru eşleşme sonucu), 146200.jpg.



Inria Holidays veri kümesindeki 102201.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 100000.jpg, 102200.jpg (doğru eşleşme sonucu), 142700.jpg.



Inria Holidays veri kümesindeki 137504.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 137500.jpg (doğru eşleşme sonucu), 100000.jpg, 147600.jpg.



Inria Holidays veri kümesindeki 140502.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 100000.jpg, 140500.jpg (doğru eşleşme sonucu), 105100.jpg.



Inria Holidays veri kümesindeki 140503.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 100000.jpg, 123600.jpg, 122800.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.



Inria Holidays veri kümesindeki 101001.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 100000.jpg, 144100.jpg, 110600.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.




Inria Holidays veri kümesindeki 101402.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 100000.jpg, 101600.jpg, 138900.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.



Inria Holidays veri kümesindeki 103301.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 100000.jpg, 128400.jpg, 110500.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.

EK-2

INRIA COPY DAYS STRONG VERİ KÜMESİ ÜZERİNDE AĞIRLIKLANDIRILMIŞ ÖZNİTELİK FÜZYONU YÖNTEMİNİN UYGULANMASI SONUCU ELDE EDİLEN DOĞRU POZİTİF VE YANLIŞ POZİTİF EŞLEŞMELER



Inria Copy Days Strong veri kümesindeki 200001.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg (doğru eşleşme), 208900.jpg, 200600.jpg.



Inria Copy Days Strong veri kümesindeki 200201.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 200200 (doğru eşleşme).jpg, 212900.jpg.




Inria Copy Days Strong veri kümesindeki 201201.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 201200 (doğru eşleşme).jpg, 214600.jpg.



Inria Copy Days Strong veri kümesindeki 215601.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 215600 (doğru eşleşme).jpg, 203300.jpg.



Inria Copy Days Strong veri kümesindeki 215201.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 215200 (doğru eşleşme).jpg, 211200.jpg.




Inria Copy Days Strong veri kümesindeki 200101.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 215600.jpg, 215500.jpg, 215400.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.



Inria Copy Days Strong veri kümesindeki 200301.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 215600.jpg, 215500.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.



Inria Copy Days Strong veri kümesindeki 215301.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 210900.jpg, 200600.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.



Inria Copy Days Strong veri kümesindeki 214701.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 208900.jpg, 200300.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.



Inria Copy Days Strong veri kümesindeki 214601.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 201100.jpg, 208600.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.

EK-3

INRIA COPY DAYS CROP VERİ KÜMESİ ÜZERİNDE AĞIRLIKLANDIRILMIŞ ÖZNİTELİK FÜZYONU YÖNTEMİNİN UYGULANMASI SONUCU ELDE EDİLEN DOĞRU POZİTİF VE YANLIŞ POZİTİF EŞLEŞMELER



Inria Copy Days Crop 80 veri kümesindeki 209700.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 208400.jpg, 209700.jpg (doğru eşleşme).



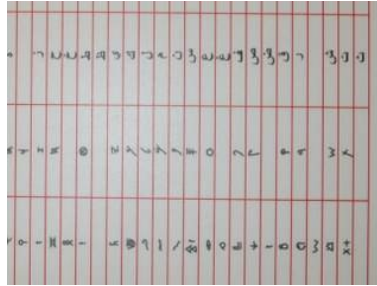
Inria Copy Days Crop 80 veri kümesindeki 209800.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 209800.jpg (doğru eşleşme), 202500.jpg.



Inria Copy Days Crop 80 veri kümesindeki 200600.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200600.jpg (doğru eşleşme), 210900.jpg, 201000.jpg.



Inria Copy Days Crop 60 veri kümesindeki 208600.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 208600.jpg (doğru eşleşme), 214600.jpg.



ALPHABET PHENICIEN
(X-IXème s. av. J.-C.)

Alphabète	Phénicien	Arabe	Hebreu	Assyrien
A	𐤀	أ	א	𐤀
B	𐤁	ب	ב	𐤁
G	𐤂	ג	ג	𐤂
D	𐤃	ד	ד	𐤃
E	𐤄	ה	ה	𐤄
F	𐤅	ו	ו	𐤅
G	𐤆	ז	ז	𐤆
H	𐤇	ח	ח	𐤇
I	𐤈	ט	ט	𐤈
J	𐤉	י	י	𐤉
K	𐤊	כ	כ	𐤊
L	𐤋	ל	ל	𐤋
M	𐤌	מ	מ	𐤌
N	𐤍	נ	נ	𐤍
O	𐤎	ס	ס	𐤎
P	𐤏	פ	פ	𐤏
Q	𐤐	ק	ק	𐤐
R	𐤑	ר	ר	𐤑
S	𐤒	ש	ש	𐤒
T	𐤓	ת	ת	𐤓
U	𐤔	י	י	𐤔
V	𐤕	ו	ו	𐤕
W	𐤖	ז	ז	𐤖
X	𐤗	ח	ח	𐤗
Y	𐤘	ט	ט	𐤘
Z	𐤙	י	י	𐤙



Inria Copy Days Crop 60 veri kümesindeki 211900.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 211900.jpg (doğru eşleşme), 200000.jpg, 207400.jpg.



Inria Copy Days Crop 80 veri kümesindeki 210200.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 215600.jpg, 215500.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.



Inria Copy Days Crop 80 veri kümesindeki 201700.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 202800.jpg, 209700.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.



Inria Copy Days Crop 80 veri kümesindeki 202300.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 201000.jpg, 210700.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.



Inria Copy Days Crop 80 veri kümesindeki 204500.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 205900.jpg, 209400.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.



Inria Copy Days Crop 80 veri kümesindeki 206800.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 212400.jpg, 208700.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.

EK-4


INRIA COPY DAYS SCALE JPEG ATTACK VERİ KÜMESİ ÜZERİNDE AĞIRLIKLANDIRILMIŞ ÖZNİTELİK FÜZYONU YÖNTEMİNİN UYGULANMASI SONUCU ELDE EDİLEN DOĞRU POZİTİF VE YANLIŞ POZİTİF EŞLEŞMELER




Inria Copy Days Scale JPEG Attack 3 veri kümesindeki 206600.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 206600.jpg (doğru eşleşme), 202100.jpg.



Inria Copy Days Scale JPEG Attack 3 veri kümesindeki 206900.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 206900.jpg (doğru eşleşme), 211800.jpg.



Inria Copy Days Scale JPEG Attack 75 veri kümesindeki 207100.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 207100.jpg (doğru eşleşme), 215600.jpg.



Inria Copy Days Scale JPEG Attack 3 veri kümesindeki 205000.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 205000.jpg (doğru eşleşme), 203000.jpg.



Inria Copy Days Scale JPEG Attack 3 veri kümesindeki 201900.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 201900.jpg (doğru eşleşme), 206000.jpg.



Inria Copy Days Scale JPEG Attack 3 veri kümesindeki 200300.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 208900.jpg, 210700.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.




Inria Copy Days Scale JPEG Attack 3 veri kümesindeki 200600.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 201000.jpg, 210700.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.



Inria Copy Days Scale JPEG Attack 3 veri kümesindeki 201000.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 209700.jpg, 203300.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.



Inria Copy Days Scale JPEG Attack 3 veri kümesindeki 200900.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 202300.jpg, 212700.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.



Inria Copy Days Scale JPEG Attack 3 veri kümesindeki 207100.jpg fotoğrafının (üstte) ilk 3 eşleşme sonuçları: Soldan sağa (sırasıyla); 200000.jpg, 201000.jpg, 210900.jpg. Bu fotoğraf için doğru eşleşme bulunamamıştır.