

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



YAPAY ZEKÂ İLE AKILLI ŞEHİRLERDE ÇEVRESEL
GÖRÜNTÜ VE VIDEO ANALİZİ

Kudret DİNÇ

Yüksek Lisans Tezi

ADLI BİLİŞİM MÜHENDİSLİĞİ ANABİLİM DALI

TEMMUZ 2025

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Adli Bilişim Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

YAPAY ZEKÂ İLE AKILLI ŞEHİRLERDE ÇEVRESEL GÖRÜNTÜ VE VIDEO ANALİZİ

Tez Yazarı
Kudret DİNÇ

Danışman
Doç.Dr.Orhan YAMAN

TEMMUZ 2025
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Adli Bilişim Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	Yapay Zekâ ile Akıllı Şehirlerde Çevresel Görüntü ve Video Analizi
Yazarı:	Kudret DİNÇ
İlk Teslim Tarihi:	17.06.2025
Savunma Tarihi:	17.07.2025

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç.Dr.Orhan YAMAN Fırat Üniversitesi, Teknoloji Fakültesi	<i>İmza</i> Onayladım
Başkan:	Dr.Öğr.Üyesi İrfan KILIÇ Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Dr.Öğr.Üyesi Furkan ÖZTEMİZ İnönü Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza
Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Yapay Zekâ ile Akıllı Şehirlerde Çevresel Görüntü ve Video Analizi” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

17.07.2025

Kudret DİNÇ



ÖNSÖZ

Bu tez çalışmasında, yüksek lisans eğitimim boyunca kazandığım bilgi ve becerilerimin pratiğe dökülmesi açısından önemli bir yer tutmaktadır. Özellikle yapay zekâ ile görüntü ve video işleme alanlarında yapılan teorik ve pratik çalışmalar, şehir yaşamına günümüz teknolojisinin entegrasyonunda büyük rol almaktadır. Akıllı şehirler bağlamında gerçekleştirilen bu tezde, video tabanlı analiz sistemlerinin yangın algılama, anomali tespiti ve kalabalık analizi gibi kritik konularda uygulamaları detaylı bir şekilde incelenmiştir.

Bu çalışmada bana yol gösteren, fikir ve önerileriyle katkı sunan danışman hocama sonsuz teşekkürlerimi sunuyorum. Aynı zamanda projeler sırasında karşılaştığım teknik sorunlarda yardımcı olan arkadaşlarıma ve veri kaynaklarına ulaşımında bana destek olan tüm akademik camiaya minnettarım. Sabırla, anlayışla her aşamada yanımda olan aileme şükran borçluyum.

Bu çalışma, 5220154 numaralı TÜBİTAK projesi kapsamında desteklenmiştir. İlgili alanlarda araştırma yapacak bilim insanları için yol gösterici ve ilham verici bir kaynak olmasını temenni ederim.

Kudret DİNÇ
ELAZIĞ, 2025

İÇİNDEKİLER

	Sayfa
ÖNSÖZ	iv
İÇİNDEKİLER	v
ÖZET.....	vi
ABSTRACT	vii
ŞEKİLLER LİSTESİ	viii
TABLOLAR LİSTESİ	ix
KISALTMALAR	x
1. GİRİŞ	1
1.1. Video İşleme Uygulamalarında Yapay Zekânın Önemi	1
1.2. Literatür Özeti	2
1.3. Çalışmanın Önemi	5
1.4. Tezin Amacı ve Kapsamı	5
1.5. Tezin Yapısı.....	5
2. GÖRÜNTÜ VE VIDEO İŞLEME ANALİZ UYGULAMALARI.....	7
2.1. Görüntü ve Video İşleme Temel Kavramları.....	7
2.2. Video Segmentasyonu	8
2.3. Video Özetleme	12
2.4. Anahtar Kare Tespiti	13
2.5. Anomali Tespit Yöntemleri ve Uygulama Alanları	18
2.6. Kalabalık Analiz Yöntemleri ve Uygulama Alanları.....	18
3. AKILLI ŞEHİRLERDE YANGIN ALGILAMA İÇİN HSV HİSTOGRAM	
TABANLI YÖNTEM.....	20
3.1. Giriş	20
3.2. Flame Veri Seti	21
3.3. Önerilen HSV Histogram Yöntemi	21
3.4. Deneysel Sonuçlar	25
3.5. Bölüm Değerlendirmesi.....	27
4. AKILLI ŞEHİRLERDE KALABALIK ANALİZİ İÇİN CSRNET VE MCNN	
TABANLI BİR YÖNTEM	28
4.1. Giriş	288
4.2. Kalabalık Veri Seti	28
4.3. Önerilen Yöntem	29
4.4. Deneysel Sonuçlar	30
4.5. Bölüm Değerlendirmesi.....	32
5. SONUÇLAR.....	34
5.1. Yangın Tespitinde HSV Histogram Yöntemi Üzerine Değerlendirme.....	34
5.2. Kalabalık Analizi Üzerine Değerlendirme	34
5.3. Genel Değerlendirme ve Katkıları	35
5.4. Gelecek Çalışmalar İçin Öneriler	35
KAYNAKLAR	36
ÖZGEÇMİŞ	

ÖZET

Yapay Zekâ ile Akıllı Şehirlerde Çevresel Görüntü ve Video Analizi

Kudret DİNÇ

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Adli Bilişim Mühendisliği Anabilim Dalı

Temmuz 2025, Sayfa: x + 38

Bu tez çalışması, akıllı şehirlerde yaşam kalitesini yükseltmek ve güvenlik sistemlerini güçlendirmek amacıyla, yapay zeka temelli gelişmiş görüntü ve video analiz yöntemleri geliştirmeyi hedeflemiştir. Çalışma, üç temel problem üzerinde yoğunlaşarak, yangın algılama, anomali tespiti ve kalabalık analizine yönelik özgün çözümler sunmaktadır. Yangın algılama alanında, görüntülerin renk bilgilerini insan görsel algısına daha uygun şekilde temsil eden HSV (Hue, Saturation, Value) renk uzayına dayalı yenilikçi bir histogram tabanlı yöntem geliştirilmiştir. FLAME veri seti üzerinde gerçekleştirilen kapsamlı deneyler, önerilen yöntemin yangın ve yangın dışı sahneler arasındaki farkları başarıyla tespit ettiğini ve yüksek doğruluk oranlarıyla sınıflandırma performansı sergilediğini göstermiştir. Bu süreçte SVM, Karar Ağacı ve K-Nearest Neighbors gibi farklı makine öğrenmesi algoritmaları kullanılarak elde edilen sonuçlar karşılaştırılmıştır. Anomali tespiti çalışmasında, video akışlarından elde edilen görüntülerdeki hareket ve renk özellikleri, Histogram of Oriented Gradients (HOG) ve renk histogramları gibi etkili öznitelik çıkarım teknikleriyle analiz edilmiştir. Çeşitli makine öğrenmesi modelleriyle gerçekleştirilen sınıflandırmalar sayesinde, güvenlik kameralarından alınan görüntülerde meydana gelen anormal durumların yüksek hassasiyetle tespit edilmesi sağlanmıştır. Kalabalık analizi kısmında ise, derin öğrenme temelli CSRNet ve MCNN modelleri kullanılarak, ShanghaiTech ve Mall veri setleri üzerinde yoğunluk haritaları oluşturulmuş ve kişi sayımı yapılmıştır. Elde edilen deneysel sonuçlar, CSRNet modelinin yüksek yoğunluklu ve karmaşık sahnelerde daha doğru ve detaylı tahminler sunduğunu ortaya koyarken, MCNN modeli ise hesaplama verimliliği ve hızlı tahmin kabiliyetiyle özellikle sınırlı kaynaklara sahip uygulamalarda tercih edilebilir bir alternatif olduğunu göstermiştir. Gerçekleştirilen deneyler ve analizler, önerilen yöntemlerin farklı gerçek dünya senaryolarında güvenilirlik, yüksek doğruluk ve uygulama pratikliği sağladığını ortaya koymuştur. Böylece, bu tez çalışması, akıllı şehirlerde güvenlik, acil durum yönetimi ve toplumsal düzenin izlenmesine yönelik yapay zekâ destekli görüntü işleme tekniklerinin geliştirilmesi ve uygulanmasına önemli katkılar sunmaktadır.

Sonuç olarak, elde edilen bulgular ve geliştirilen modeller, akıllı şehir teknolojilerinin gelişimine yön veren kritik adımlardan biri olarak değerlendirilebilir ve gelecekteki araştırmalar için sağlam bir temel teşkil etmektedir.

Anahtar Kelimeler: Görüntü işleme, akıllı şehirler, yangın tespiti, anomali tespiti, kalabalık analizi.

ABSTRACT

Environmental Image and Video Analysis in Smart Cities with Artificial Intelligence

Kudret DİNÇ

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Digital Forensic Engineering

July 2025, Pages: x + 38

This thesis aims to develop advanced artificial intelligence (AI)-based image and video analysis methods to enhance the quality of life and strengthen smart city security systems. The study focuses on three core problems: fire detection, anomaly detection, and crowd analysis, offering original solutions for each. In the fire detection domain, an innovative histogram-based method grounded in the hue, saturation, value (HSV) color space — which better represents human visual perception of color — has been developed. Extensive experiments on the FLAME dataset demonstrate that the proposed method effectively distinguishes between fire and non-fire scenes, achieving high classification accuracy. Various ML algorithms, including SVM, Decision Tree, and K-Nearest Neighbors, were employed, and their results were compared. We analyzed the motion and color features extracted from the video streams using effective feature extraction techniques, such as the histogram of oriented gradients and color histograms for anomaly detection. Classification using multiple ML models enabled the precise identification of high-sensitivity abnormal events captured by security cameras. Two DL architectures, CSRNet and MCNN, were used to generate density maps and perform crowd counting on the ShanghaiTech and Mall datasets. The experimental results reveal that the CSRNet model provides more accurate and detailed predictions, especially in highly congested and complex scenes, whereas the MCNN model offers computational efficiency and faster inference, making it a viable option for resource-constrained applications. Experiments and analyses demonstrate the reliability, high accuracy, and practical applicability of the proposed methods across various real-world scenarios. This thesis makes significant contributions to the development and implementation of artificial intelligence (AI)-driven image processing techniques to improve security, emergency management, and public monitoring within smart city frameworks. The findings and developed models presented here represent a crucial advancement in smart city technologies and provide a solid foundation for future research in this field.

Keywords: Image processing, smart cities, fire detection, anomaly detection, crowd analysis.

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Hareket vektörleri örn.	9
Şekil 2.2. Renk tabanlı segmentasyon örn.	10
Şekil 2.3. Eşikleme Tabanlı Segmentasyon örn.	11
Şekil 2.4. Accident Footages From CCTV veri seti üzerinde anahtar kare çıkarılması	15
Şekil 2.5. Frame Difference kullanım örn.	16
Şekil 2.6. Histogram Comparisons (Histogram Karşılaştırmaları) örnek veri seti için elde edilen sonuç....	18
Şekil 3.1. Veri kümesindeki tüm depolar	21
Şekil 3.2. Önerilen yöntemin akış diyagramı	22
Şekil 3.3. Yangın sınıfı RGB, gri ve HSV görünümü	23
Şekil 3.4. Yangın ve yangın dışı sınıf için histogramlar.....	23
Şekil 3.5. Yangın sınıfı ve yangın sınıfı olmayan örnek görüntülerin R, G, B ve H, S, V katmanlarının histogram grafikleri.....	24
Şekil 3.6. Confusion Matris a) Fine Decision Tree Model b) Cubic SVM Model c) Fine KNN Model	25
Şekil 3.7. Confusion Matris a) Fine Decision Tree Model b) Cubic SVM Model c) Fine KNN Model	26
Şekil 4.1. CSRNet ve MCNN kullanarak kalabalık sayma hattı	29
Şekil 4.2. ShanghaiTech Bölüm A veri setinden alınan yüksek yoğunluklu bir görüntü için CSRNet tarafından tahmin edilen yoğunluk haritası.....	31
Şekil 4.3. Yoğun kalabalıkların modellenmesinde sınırlamaları gösteren ikinci MCNN tahmini.....	31
Şekil 4.4. CSRNet tarafından Alışveriş Merkezi veri kümesi üzerinde oluşturulan örnek yoğunluk haritası, kalabalık alanlardaki doğru konsantrasyonu göstermektedir.	32

TABLÖLAR LİSTESİ

	Sayfa
Tablo 1.1. Literatürde FLAME veri setini kullanan bazı çalışmalar.....	3
Tablo 1.2. Anomali tespit yöntemlerine ilişkin literatür özeti.....	4
Tablo 1.3. Kalabalık sayımına ilişkin literatüre özeti	4
Tablo 2.1. Video üzerinde hareket tabanlı segmentasyon algoritmasının sözde kodu	9
Tablo 2.2. Frame Difference yöntemiyle anahtar kare tespit adımları	14
Tablo 2.3. Optik akış yöntemiyle anahtar kare tespit adımları	15
Tablo 2.4. Histogram Comparisons (Histogram Karşılaştırmaları) yöntemiyle anahtar kare tespit adımları	17
Tablo 3.1. Önerilen yöntem 100 yineleme performans değerleri.....	25
Tablo 3.2. RGB, gri tonlamalı ve HSV görünümünün histogramları kullanılarak elde edilen yangın tahmin doğruluğu değerlerinin karşılaştırılması	26
Tablo 3.3. Önerilen yöntem 100 yineleme performans değerleri.....	26
Tablo 3.4. RGB, gri tonlamalı ve HSV görünümünün histogramları kullanılarak elde edilen yangın tahmin doğruluğu değerlerinin karşılaştırılması.	27
Tablo 4.1. ShanghaiTech Part A Sonuçları	30
Tablo 4.2. Mall Veri Seti Sonuçları	32

KISALTMALAR

HSV	: Ton, Doygunluk, Değer (Hue, Saturation, Value)
RGB	: Kırmızı, Yeşil, Mavi (Red, Green, Blue)
CNN	: Evrimsel Sinir Ağı (Convolutional Neural Network)
LSTM	: Uzun Kısa Süreli Hafıza (Long Short-Term Memory)
MCNN	: Çok Sütunlu Konvolüsyonel Sinir Ağı (Multi-Column Convolutional Neural Network)
CSRNet	: Yoğun Kalabalık Tanıma Ağı (Congested Scene Recognition Network)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
RMSE	: Kök Ortalama Kare Hata (Root Mean Squared Error)
FLAME	: Yangın Bölgeleme ve Analiz Modeli Değerlendirme (Fire Localization and Analysis Model Evaluation)
ConvLSTM	: Konvolüsyonel Uzun Kısa Süreli Hafıza (Convolutional Long Short-Term Memory)
VGG-16	: Görsel Geometri Grubu Modeli 16 (Visual Geometry Group Model-16)
SVM	: Destek Vektör Makinesi (Support Vector Machine)
KNN	: K-En Yakın Komşu Algoritması (K-Nearest Neighbors)
DT	: Karar Ağacı Algoritması (Decision Tree)
IoT	: Nesnelerin İnterneti (Internet of Things)
MATLAB	: Matris Laboratuvarı (Matrix Laboratory)

1. GİRİŞ

Günümüzde şehirlerdeki hızlı nüfus artışı, ulaşım ve güvenlik gibi birçok alanda yeni çözümleri zorunlu hâle getirmiştir. Artık kentlerde yaşanan kalabalıklaşma, olaylara hızlı müdahale edilebilmesi için sistemlerin daha akıllı olmasını gerektirmektedir. Bu da görüntülerin ve videoların anlık olarak işlenmesini sağlayan teknolojilerin daha önemli hâle gelmesine neden olmuştur [1].

Geleneksel yöntemlerle elde edilen sonuçlar, çoğu zaman yetersiz kalmakta ya da geç tepki vermektedir. Bu durum, örneğin bir yangının geç fark edilmesine veya anormal bir olayın gözden kaçmasına neden olabilmektedir [2]. İşte bu noktada yapay zekâ destekli sistemler devreye girmekte ve olaylara karşı daha hızlı ve etkili sonuçlar üretmektedir.

Bu tezde ele alınan üç ana konu şunlardır: yangın tespiti, anomali algılama ve kalabalık analizi. Yangın tespiti için HSV renk uzayı kullanılarak bir histogram yöntemi geliştirilmiştir [3]. Anomali tespiti ise çeşitli görsel özniteliklerin çıkarılması [4] [5] ve bu verilerin farklı makine öğrenmesi algoritmalarıyla sınıflandırılmasıyla gerçekleştirilmiştir [6] [7]. Kalabalık analizi alanında ise CSRNet ve MCNN gibi derin öğrenme modelleri kullanılmıştır [8].

Yapılan uygulamalarla, sistemlerin gerçek dünyadaki çeşitli senaryolara ne kadar başarılı yanıt verebildiği ölçülmüş ve doğruluk oranları ile yorumlanmıştır. Bu çalışma, özellikle akıllı şehir altyapıları için önemli katkılar sunmayı hedeflemektedir. Gerçek zamanlı analiz kabiliyeti, sistemlerin hem güvenlik hem de yönetim açısından daha işlevsel hâle gelmesini sağlayabilir.

1.1. Video İşleme Uygulamalarında Yapay Zekânın Önemi

Nüfus yoğunluğunun artmasıyla kentleşme ile beraber akıllı şehirler konsepti de hayatımıza girmiştir. Bununla beraber ulaşım altyapısı, kamu güvenliği gibi bir çok alan kent yaşamını karmaşık hale getirmiştir [9]. Akıllı şehirler sadece altyapı geliştirme sürecini içermemektedir aynı zamanda bu yapılardan elde edilen verilerin anlamlandırılmasıdır [10]. Bu noktada video ve görüntü işleme teknolojileri, çok sayıda video verilerini işleyerek analiz edilmesi ve tahmin edilmesine bağlı olarak önlem alma konusunda devreye girmektedir [11].

Sıradan video işleme yöntemlerinin ışık değişimleri ,kamera açısı farklılıkları ve çevresel faktörler gibi sebeplerle doğruluk açısından yetersiz kalırken yapay zeka temelli görüntü ve video işleme derin öğrenme sayesinde yorumlama ,nesne tanıma, hareket analizi, anomali tespiti, kalabalık tahmini gibi zor problemlerde, bu sistemlerin doğruluğunu ,hızını ve uyumunu önemli ölçüde arttırmıştır [12] [13].

Görüntü ve video işlemenin de dahil olmasıyla sadece akademik araştırma konusu değil, aynı zamanda güvenlik, afet yönetimi, trafik kontrolü, olay tespitine kadar önemli alanlarda gerçek zamanlı karar destek sisteminin temelini oluşturmuştur [3] [14]. Yangın algılama ve kalabalık analizi,

bu amaçta deęerlendirilecek iki önemli uygulama alanıdır [15].Her iki problemde hızlı karar almayı gerektiren insani açıdan oldukça önemli konulardır.

Bu çalışmada, video işleme ile yapay zekanın kesişiminde yer alan iki ana problem olan yangın algılama ve kalabalık analizi ele alınmıştır. Bu problemlerin çözümünde HSV histogram temelli görüntü analiz yöntemleri ve derin öğrenme tabanlı kalabalık sayımı algoritmaları CSRNet ve MCNN kullanılmıştır [16] [8] .

1.2. Literatür Özeti

Yapay zeka temelli video ve görüntü analizi alanlarında son zamanlarda yapılan çalışmalarda önemli bir artış kaydedilmiştir [13] [12].Bu alanda yapılan akademik çalışmalar önem kazanmaya başlamıştır. Başlıca ele alınan konular anomali tespiti ve kalabalık analizi gibi alanlar olmuştur [17] [18].Yangın tespiti alanında gerçekleştirilen çalışmalarda renk tabanlı modeller tercih edilmiştir [19]. Görüntülerde duman ve ateş gibi renk tonu ve parlaklık değışikliklerinden bağımsız çalışmalar yapabilmek için HSV renk uzayının sıklıkla tercih edildiğı gözlemlenmiştir [5] [20].

Açık kaynaklı veri setleri kullanılarak yürütölen görüntü ve video işleme çalışmalarında genel olarak başarılı sonuçlar elde edilmiştir [3] [14]. Ancak, farklı ışık koşullarında bu sistemlerin yanıltıcı sonuçlar üretebildiğı de gözlemlenmiştir. Bu durum, özellikle yangın gibi kritik ve erken müdahale gerektiren senaryolarda, daha güvenilir renk histogramı yöntemlerinin geliştirilmesini önemli bir araştırma ve tartışma konusu haline getirmiştir [15].

Kalabalık analizi hususunda literatür araştırıldığında, özellikle CSRNet (Convolutional Neural Networks for Crowd Counting) [21] ve MCNN (Multi-Column Convolutional Neural Network) [16] gibi derin öğrenme temelli yapıların öne çıktığı gözlemlenmektedir. ShanghaiTech ve MALL gibi veri setlerinde yapılan çalışmalar, bu yapıların yüksek doğruluk oranına sahip olduklarını göstermektedir [22]. CSRNet, yoğunluk haritaları oluşturma konusunda yüksek performans sergilerken, MCNN ise çok ölçekli yapısı sayesinde farklı açılardan gelen görüntülere karşı daha esnek çözümler sunmuştur.

Bu tezde gerçekleştirilen deneyler literatürle aynı doğrultuda ;önerilen yöntemlerin, geleneksel yöntemlerle kıyaslandığında daha başarılı sonuçlar vermiştir [1].

Tablo 1.1’de göröldüğü üzere, yangın tespiti için derin öğrenme tabanlı modeller yaygın olarak kullanılmakta ve performansları giderek artmaktadır. Özellikle transfer öğrenme ve ince ayar yöntemleriyle mevcut modellerin başarı oranları yükseltilmiştir. MaskSU R-CNN gibi segmentasyon temelli yaklaşımlar ise yangın sahnelerinin hem algılanması hem de konumlandırılması açısından önemli avantajlar sağlamaktadır.

Bununla birlikte, yüksek doğruluk oranlarına rağmen bazı çalışmalarda özgüllük ve yanlış pozitif oranları gibi metriklerde iyileştirmeye ihtiyaç duyulmaktadır. Bu durum, gelecekte hibrit yöntemler ve farklı öznitelik çıkarım tekniklerinin kombinasyonu ile aşılmaya çalışılmaktadır. Genel olarak

literatür, yangın tespiti alanında yapay zekâ temelli çözümlerin hızla geliştiğini ve etkinliğinin arttığını göstermektedir.

Tablo 1.1. Literatürde FLAME veri setini kullanan bazı çalışmalar

Yıl	Yazar(lar)	Model/Yöntem	Katkı / Temel Özellikler
2021	Dutta ve Ghosh [31]	Separable CNN + Görüntü İşleme	Eşikleme ve segmentasyonla birleşik mimari; %98.10 hassasiyet, %87.09 özgüllük
2022	Zhang ve ark. [11]	FT-ResNet50 (Transfer Öğrenme)	VGG16'dan %6.22 daha başarılı; %79.48 doğruluk elde edildi
2021	Treneska ve Stojkoska [32]	ResNet50 (İnce Ayarlı)	Modelin ince ayarlanmasıyla doğruluk %88'e çıkarıldı (%11 iyileşme)
2022	Guan ve ark. [33]	MaskSU R-CNN (Segmentasyon Tabanlı)	%91.85 doğruluk, %88.81 geri çağırma, F1-puanı %90.30, mIoU %82.31

Aşağıda Tablo 1.2' de görüldüğü üzere, anomali tespiti alanında hem klasik makine öğrenmesi yöntemleri hem de derin öğrenme temelli yaklaşımlar başarıyla uygulanmaktadır. Özellikle zamanla gelişen veri kümesi çeşitliliği ve hesaplama gücündeki artış, modellerin uzamsal-zamansal örüntüleri daha iyi yakalamasını sağlamıştır. Sabokrou ve Ionescu gibi araştırmacılar, derin öğrenme ile özellikle karmaşık sahnelerde başarılı sonuçlar elde ederken; Hasan ve Xu'nun denetimsiz ya da tek-sınıf sınıflandırma temelli yaklaşımları, etiketli veri gereksinimi olmadan etkili çözümler sunmuştur. Bu çalışmalar, gözetim sistemlerinde gerçek zamanlı ve doğru anomali tespitinin mümkün olabileceğini göstermektedir.

Tablo 1.2. Anomali tespit yöntemlerine ilişkin literatür özeti

Yıl	Yazar(lar)	Yöntem	Veri Kümesi	Performans	Açıklama
2009	Chandola ve ark. [34]	Anomali Tespit Tekniklerinin İncelemesi	Yok	Yok	Farklı alanlardaki anomali tespit kapsamlı değerlendirmesi
2017	Sabokrou ve ark. [35]	Tam Konvolüsyonel Sinir Ağları	Avenue, UCSD Pedestrian	Avenue: %91.7, UCSD: %92.5 (AUC)	Zamansal ve mekânsal anomalileri tespit etmede etkili
2017	Xu ve ark. [36]	One-Class SVM + Elle Belirlenen Özellikler	UMN	%96.1 (Doğruluk)	Hareket ve iz özelliklerini kullanarak yüksek doğruluk
2016	Hasan ve ark. [37]	Otoenkoder Tabanlı Öğrenme (Unsupervised)	UCSD Pedestrian	%88 (AUC)	Denetimsiz öğrenmenin etkinliği vurgulanmıştır
2019	Ionescu ve ark. [38]	Derin Tek-Sınıf Sınıflandırma	Avenue, ShanghaiTech	Avenue: %88.7, Shanghai: %84.3 (AUC)	Normal davranış skoru kullanılarak anomali tespiti
2009	Mehran ve ark. [39]	Sosyal Kuvvet Modeli (SFM)	UCSD Pedestrian	%89 (Doğruluk)	Kalabalık davranış anomalilerinde erken ve temel bir yaklaşım

Aşağıdaki Tablo 1.3 incelendiğinde, kalabalık sayımında doğruluğu artırmak için model mimarilerinde önemli yeniliklere gidildiği görülmektedir. MCNN modeli, farklı ölçekteki bireyleri algılayabilmek için çok sütunlu bir yapı kullanırken; CSRNet modeli, geniş receptive field sunan genişletilmiş evrişim katmanlarıyla yüksek doğruluk sağlamıştır. Daha yeni çalışmalarda dikkat mekanizması (CAN), çok yollu çözücü (TEDNet) ve yoğunluk yerine doğrudan kişi koordinatı tahmini (P2PNet) gibi yöntemlerle model başarımı ve uygulama esnekliği artırılmıştır. Bu çalışmalar, kalabalık analizine yönelik modellerin hem karmaşık sahnelerde hem de gerçek zamanlı uygulamalarda başarılı şekilde kullanılabileceğini ortaya koymaktadır.

Tablo 1.3. Kalabalık sayımına ilişkin literatüre özeti

Yıl	Yazar(lar)	Model	Katkı / Temel Özellikler
2016	Zhang ve ark. [16]	MCNN	Çok ölçekli özellik çıkarımı için çok kolonlu konvolüsyonel sinir ağı
2018	Li ve ark. [8]	CSRNet	Geniş alıcı alan sağlayan genişletilmiş (dilated) konvolüsyonlarla yüksek doğruluk
2018	Cao ve ark. [40]	SANet	Farklı çözünürlüklerden elde edilen özelliklerin birleştirilmesi
2019	Liu ve ark. [22]	CAN	Yoğunluk tahmini için bağlam farkındalığına sahip dikkat mekanizması
2020	Jiang ve ark. [17]	TEDNet	Çok yollu çözücü (decoder) mimarisi ile regresyon doğruluğunun artırılması
2021	Song ve ark. [18]	P2PNet	Yoğunluk haritası yerine doğrudan kişi konumlarının (koordinatlarının) tahmin edilmesi

1.3. Çalışmanın Önemi

Günümüzde yangın can ve mal kaybına sebep olan en tehlikeli afetlerden bir tanesidir [23].Çoğunlukla nüfus yoğunluğu fazla olan kamu alanlarında erken yangın tespiti, itfaiyenin hızlı müdahalesini ve daha büyük faciaların önlenmesini sağlar [11].Bu tezde video işleme ve yapay zeka entegrasyon konusunun sadece teorik bir problem olmadığını aynı zamanda yaşam kalitesini doğrudan etkileyen pratiklere sahip olduğunu göstermektedir [10].Önerilen HSV histogram temelli yangın tespiti, sahnelerdeki alev oluşumlarını yüksek başarı ile tanımlayarak oldukça önemli bir ihtiyaca çözüm sunar [19].

İnsan yoğunluğunun çok olduğu yerlerde olay tespiti ve kontrolü de güvenlik açısından önemlidir. AVM’lerde, istasyonlarda, toplu gösteri ve miting alanlarında, şehir merkezlerinde oluşan anomali durumlarının izlenmesi ve tespiti hem güvenlik güçlerinin iş yükünü azaltır hem de hızlı müdahale sağlar [3]. Kalabalık analizinde kullanılan CSRNet ve MCNN tabanlı modeller, gerçek zamanlı izleme sistemleri için yüksek doğruluklu çözümler sunar [8] [16].

Çalışmanın önemi, klasik yöntemlerin yetersizliklerini aşmakta ve yapay zekâ ile güçlendirilmiş

1.4. Tezin Amacı ve Kapsamı

Bu tezin başlıca amacı, akıllı şehirlerde maruz kalınan iki ana sorun olan kalabalık analizi ve yangın algılama için yaratıcı ve etkili yöntemler geliştirmektir [15].Bu alanlardaki mevcut çözümlere katkıda bulunmaktır [24].

Kalabalık analizi bağlamında CSRNet ve MCNN yapıları kullanılarak ShanghaiTech ve Mall veri setleri eğitilerek yoğunluk tahmini yapılmıştır. MAE,RMSE gibi metriklerle başarıları kıyaslanmıştır [16] [17]. Görüntü işleme alanında temel amaç, özellikle alev içeren sahnelerin arka plan ve ışık değişimlerinden etkilenmeden HSV histogram tabanlı yöntemlerle yüksek başarı ile yangın tespitini yapmaktır [5] [20].

Tez içeriği sadece algoritma uygulama ile sınıtlı değil; aynı zamanda veri ön işleme, model eğitimi, doğrulama, görselleştirme ve kıyaslamalı analizler barındırmaktadır [3] [23].

1.5. Tezin Yapısı

Bu tez, beş ana bölümden oluşmaktadır. Birinci bölümde giriş kısmında çalışmanın arka planı, hedefi, önemi ve literatürdeki yeri ele alınmıştır.

İkinci bölümünde, görüntü ve video işleme uygulamaları hakkında temel bilgiler bulunmaktadır. Video segmentasyonu, video özetleme, anahtar kare tespiti, anomali tespiti ve kalabalık analizi yöntemleri gibi konular işlenmiştir.

Üçüncü bölümde, HSV histogram temelli yangın tespiti tanıtılmıştır. Flame veri seti kullanılarak yapılan uygulamalı çalışmalar, yöntemsel açıklamalar ve sonuç değerlendirmeleri sunulmuştur.

Dördüncü bölümde, kalabalık analizi kapsamında CSRNet ve MCNN tabanlı mimariler açıklanmıştır. Mall ve ShangaiTech veri setleri üzerinde yapılan uygulamalara yer verilmiştir. Beşinci bölümde, algoritmaların karşılaştırılmış başarı tabloları ve grafiklerle destelenmiştir ve son bölümde ise genel sonuçlar, çıkarımlar ve gelecekte yapılabilecek çalışmalar ele alınmıştır.



2. GÖRÜNTÜ VE VIDEO İŞLEME ANALİZ UYGULAMALARI

Yapay zeka ile görüntü ve video işleme , sanal ortamdan elde edilen görsel verilerin otomatik olarak işlenmesi, analiz edilmesi ve yorumlanması sürecini ifade eder [13][12]. Özellikle video tabanlı sistemlerde veriler , zamana bağlı olarak değişen karelerden oluştuğundan, klasik görüntü işlemenin sınırlarını aşan çok katmanlı çözümlmeleri gerektirir [16][8].Bu durumda, görüntü ve video işleme çalışmaları ; güvenlikten trafik izlemeye, medya özetlemelerinden endüstriyel otomasyona kadar birçok alanda kullanılmaktadır[3]. Bu bölümde, görüntü ve video işleme süreçlerinin temel yapı taşları olan çeşitli analiz uygulamaları incelenecektir.

2.1. Görüntü ve Video İşleme Temel Kavramları

Görüntü ve video işleme, dijital görsel verilerin analiz edilmesi, yorumlanması ve dönüştürülmesi amacıyla matematiksel ve algoritmik yöntemlerin uygulandığı bir disiplindir. Bu alan, bilgisayarla görü, yapay zeka ve makine öğrenmesi gibi teknolojilerle yakın ilişkilidir ve çok sayıda endüstriyel ve akademik uygulama alanına sahiptir [25].

Dijital görüntüler, iki boyutlu piksel matrislerinden oluşur. Her piksel, bir konum bilgisi ile birlikte renk ya da parlaklık değerlerini taşır. Görüntünün boyutu, bu matrisin satır ve sütun sayısı ile tanımlanır (örneğin, 1920x1080 piksel). Çözünürlük, görüntüdeki ayrıntı seviyesini belirler; çözünürlük arttıkça, birim alandaki piksel sayısı artar ve bu da daha net görüntüler elde edilmesini sağlar [26].

Renk bilgisi, görüntü işlemede önemli bir parametredir. Renkler genellikle bir renk uzayı içerisinde tanımlanır. En yaygın renk uzayı RGB (Red, Green, Blue) olup, her pikselin kırmızı, yeşil ve mavi bileşenlerle temsil edildiği bir modeldir. Ancak görüntü işleme uygulamalarında sıklıkla RGB yerine HSV (Hue, Saturation, Value) ya da YCbCr gibi renk uzayları tercih edilir. Örneğin, HSV uzayı insan algısına daha yakındır ve özellikle nesne takibi veya segmentasyon gibi görevlerde daha başarılı sonuçlar verebilir [27][28].

Video işleme ise ardışık görüntü karelerinin (frame) zaman içerisinde analiz edilmesiyle gerçekleştirilir. Videolarda zaman boyutu da önemli bir parametre olduğundan, hareket tespiti, optik akış ve nesne izleme gibi konular öne çıkar. Video verisi genellikle saniyede belirli sayıda kareden (fps – frames per second) oluşur ve bu karelerin her biri bağımsız bir görüntü gibi işlenebilir.

Modern görüntü işleme uygulamaları, genellikle derin öğrenme tabanlı yöntemlerle desteklenmektedir. Özellikle Convolutional Neural Network (CNN) gibi yapılar, görüntülerdeki

özelliklerin otomatik olarak çıkarılmasını sağlar. Ancak bu yöntemlerin başarılı olabilmesi için verilerin uygun biçimde ön işlenmesi, yani normalize edilmesi, yeniden boyutlandırılması veya renk uzayı dönüşümüne tabi tutulması gerekir [29].

Bu bağlamda, temel görüntü işleme kavramlarının anlaşılması, yüksek düzeyli analizlerin doğruluğu açısından kritik öneme sahiptir. Özellikle görüntü çözünürlüğü, renk uzayı seçimi ve boyutlandırma gibi temel adımlar, algoritmaların performansını doğrudan etkileyen faktörlerdendir.

2.2. Video Segmentasyonu

Video segmentasyonu, bir video içerisindeki farklı nesneleri veya hareketli bölgeleri tanımlamak ve bu nesneleri veya bölgeleri izole etmek için kullanılan bir dizi algoritma ve teknikten oluşan bir alandır. Video segmentasyonu, video analizi, nesne tanıma, hareket algılama ve bilgisayarla görme gibi birçok uygulama alanında kullanılır. İşte yaygın olarak kullanılan bazı video segmentasyon algoritmaları:

1. Hareket Vektörü Tabanlı Segmentasyon
2. Renk Tabanlı Segmentasyon
3. Eşikleme Tabanlı Segmentasyon
4. Kesin Kenar Tabanlı Segmentasyon
5. Nesne Takibi ve Bölge Büyütme Tabanlı Segmentasyon
6. Derin Öğrenme Tabanlı Segmentasyon

Bu, video segmentasyonunda kullanılan yaygın algoritmaların sadece birkaç örneğidir. Her bir yöntemin avantajları ve dezavantajları vardır ve kullanım senaryolarına bağlı olarak farklı durumlarda tercih edilebilirler.

Hareket Vektörü Tabanlı Segmentasyon: Bu yöntemde, ardışık kareler arasındaki piksel farklarına dayanarak hareket eden nesnelerin belirlenmesi sağlanır. Optik akış algoritmaları gibi teknikler kullanılabilir. Video üzerinde hareket tabanlı segmentasyon algoritmasının sözde kodu Tablo 2.1’de verilmiştir.

Tablo 2.1. Video üzerinde hareket tabanlı segmentasyon algoritmasının sözde kodu

1	Önceki kareyi oku ve ilk kare olarak ata.
2	Döngü başlar:
	• Mevcut kareyi oku. • Önceki kare ve mevcut kare arasındaki hareket vektörlerini hesapla. • Hareket vektörlerini kullanarak hareketli bölgeleri segmente et. • Segmente edilmiş hareketli bölgeleri görselleştir. • Önceki kareyi güncelle. • Süreci artır
3	Eğer video sona ulaşırsa, döngüyü bitir

Optik akış tabanlı hareket vektörleri kullanılarak elde edilen ve video sahnesinde hareketli nesneleri temsil eden bölgelerin görselleştirilmiş hali Şekil 2.1. 'de gösterilmiştir.




Şekil 2.1. Hareket vektörleri örn.

Renk Tabanlı Segmentasyon: Bir nesnenin rengini belirleyerek, o rengi içeren pikselleri tanımlamak için kullanılan bir yöntemdir. Renk histogramları, renk eşikleme ve renk uzayı dönüşümleri gibi teknikler kullanılabilir.

Bu sözde kod, renk tabanlı segmentasyonun temel adımlarını içerir:

- Renk uzayını belirle: İşlem için kullanılacak renk uzayını belirle. Örneğin, RGB, HSV, LAB gibi.
- Örnek görüntüyü oku: Segmentasyon işlemi için bir örnek görüntüyü oku.
- Hedef renk aralığını belirle: Segmentasyon için hedeflenen renk aralığını belirle. Örneğin, mavi renk aralığı.
- Renk tabanlı segmentasyonu uygula: Örnek görüntü üzerinde belirlenen renk aralığına sahip pikselleri segmente et.
- Sonuçları görselleştir: Orijinal görüntüyü ve segmente edilmiş görüntüyü görselleştir.

Bu kod örneği, renk tabanlı segmentasyonun temel adımlarını anlatır. Gerçek uygulamada, renk uzayı seçimi, hedef renk aralığının belirlenmesi ve segmentasyon algoritmasının seçimi gibi adımlar daha ayrıntılı olabilir. HSV renk uzayında belirlenen hedef renk aralığı kullanılarak gerçekleştirilen renk tabanlı segmentasyon süreci ve bu süreç sonucunda elde edilen segmente görüntü Şekil 2.2.'de gösterilmiştir.



Şekil 2.2. Renk tabanlı segmentasyon örn.

Eşikleme Tabanlı Segmentasyon: Bir veya birden fazla eşik değeri kullanılarak piksellerin belirli bir eşik değerinden büyük veya küçük olup olmadığına bakılarak nesnelerin ayrılması sağlanır. Tek bir eşik değeri ile yapılan ikili eşikleme işlemi sonucunda, görüntüdeki nesnelerin parlaklık farkına göre segmente edilerek ikili (binary) biçimde Şekil 2.3.'de sunulmuştur.



Şekil 2.3. Eşikleme Tabanlı Segmentasyon örn.

Bu sözde kod, eşikleme tabanlı segmentasyon algoritmasının temel adımlarını göstermektedir:

- Örnek görüntüyü oku: İşlem için bir örnek görüntüyü oku.
- Görüntüyü gri seviyeye dönüştür: Renkli görüntüyü gri seviyeye dönüştür.
- Eşik değerini belirle: Eşikleme işlemi için bir eşik değeri belirle.
- Eşikleme uygula: Belirlenen eşik değeri kullanılarak eşikleme işlemi uygula. Bu işlem, her bir pikselin eşik değerine göre siyah (0) veya beyaz (1) olmasını belirler.
- Sonuçları görselleştir: Elde edilen segmente edilmiş görüntüyü görselleştir.

Gerçek uygulamada, eşik değeri belirlenmesi, eşikleme işleminin nasıl yapılacağı ve sonuçların nasıl görselleştirileceği gibi adımlar daha ayrıntılı olarak ele alınır. Bu adımlar, uygulamanın gereksinimlerine ve kullanılan programlama diline göre değişebilir.

1. **Kesin Kenar Tabanlı Segmentasyon:** Kenar belirleme algoritmalarıyla (örneğin, Canny kenar algılama) kenarları belirlemek ve ardından bu kenarları kullanarak nesneleri ayırmak için kullanılır.
2. **Nesne Takibi ve Bölge Büyütme Tabanlı Segmentasyon:** Bir başlangıç noktasından hareket ederek, bir nesneyi veya bölgeyi tanımlamak ve takip etmek için kullanılan yöntemlerdir. Örneğin, hareketli nesneleri takip etmek için takip edici (tracker) algoritmaları kullanılabilir.
3. **Derin Öğrenme Tabanlı Segmentasyon:** Derin öğrenme teknikleri, özellikle derin sinir ağları ve evrişimli sinir ağları (CNN) kullanılarak nesnelerin veya bölgelerin doğrudan piksel seviyesinde segmentasyonunu gerçekleştirebilir.

2.3. Video Özetleme

Video özetleme, güvenlik kameraları gibi devamlı video üreten sistemlerde, bu kayıtların içinden yalnızca önemli kısımlarının çekilip öne çıkarılması işlemidir [1]. Kısacası uzun süreli video kayıtlarının kısa, anlamlı, kompakt bir şekilde sunan tekniktir [23]. İki ana başlıkta incelenmektedir: temsili (keyframe-based) özetleme ve zaman sıkıştırımlı (temporal compression) özetleme. Temsili özetleme, videodaki olayların en iyi şekilde yansıtan anahtar kareler tercih edilir [13]. Zaman sıkıştırımlı özetlemenin amacı ise sahnelerin hızlandırılarak gösterilmesidir [14].

Bu tezde, kalabalık analizi ve yangın tespiti gibi olay odaklı video işleme sorunlarında, olayın yaşandığı anları yalıtılmış bir şekilde aktarmak için kullanılması önerilmiştir [3].

Video özetleme, bir video akışının önemli özelliklerini daha kısa bir video veya video özetinde temsil etmek için kullanılan bir dizi algoritmadır. Video özetleme algoritmaları, bir videoyu daha yönetilebilir hale getirmek, video içeriğini anlamak ve öne çıkan kısımları belirlemek için kullanılır. İşte video özetleme algoritmalarından bazıları:

1. Anahtar Kare Çıkarma (Keyframe Extraction)
2. Video İçeriğine Dayalı Özetleme (Summarization based on Video Content)
3. Harekete Dayalı Özetleme (Motion-based Summarization)
4. Kümeleme Tabanlı Özetleme (Clustering-based Summarization)
5. Derin Öğrenme Tabanlı Özetleme (Deep Learning-based Summarization)
6. Çoklu Modlu Özetleme(Multi-modal Summarization)

Bu algoritmalar, farklı özetleme amaçlarına ve gereksinimlerine göre kullanılabilir. Örneğin, bir video izleme platformunda kullanıcıların ilgi alanlarına göre özetleme yapmak için kişiselleştirilmiş algoritmalar kullanılabilir.

1. **Anahtar Kare Çıkarma (Keyframe Extraction):** Video özetleme için en temel yaklaşımlardan biridir. Video akışındaki anahtar kareler belirlenir ve bu anahtar kareler özetlemenin temelini oluşturur.
2. **Video İçeriğine Dayalı Özetleme (Summarization based on Video Content):** Video içeriğini analiz eden algoritmalar kullanılarak, önemli veya ilgi çekici bölümler belirlenir ve bu bölümler özette yer alır.
3. **Harekete Dayalı Özetleme (Motion-based Summarization):** Video içindeki hareketli bölümler, hareketin yoğunluğu veya süresine göre belirlenir ve özetleme için kullanılır.
4. **Kümeleme Tabanlı Özetleme (Clustering-based Summarization):** Video içindeki benzer veya yakın bölümlerin bir araya getirilmesi ve bu kümelerin özetlemeyi oluşturmasıdır.
5. **Derin Öğrenme Tabanlı Özetleme (Deep Learning-based Summarization):** Derin öğrenme teknikleri kullanılarak, video içeriğinin daha karmaşık ve anlamlı özellikleri belirlenir ve bu özellikler özetleme için kullanılır.
6. **Çoklu Modlu Özetleme (Multi-modal Summarization):** Birden fazla veri türünün (görüntü, ses, metin vb.) bir araya getirilerek, kapsamlı bir video özeti oluşturulmasıdır.

2.4. Anahtar Kare Tespiti

Video özetleme ve segmentasyon işlemlerinin temelini oluşturan bu teknik video içerisinden en anlamlı veya tanımlayıcı karelerin seçilme işlemidir [16]. Anahtar kare işlemi, video içeriğini hızlı bir şekilde anlamlandırmaya yarar ve olay tespiti, görsel etiketleme gibi alanlarda kullanılır [13] [12].

Genellikle içerik değişimlerinin yoğun olduğu noktalarda anahtar kareler seçilir. Bu seçimişde yaparken, piksel farkından, nesne tespitinden, histogram yapısından yararlanabilir [4]. Kalabalık tespitinde insan yoğunluğunun en fazla olduğu anlar, yangın tespitinde alevin ortaya çıktığı anlar anahtar kare olarak ele alınabilir [3].

Bu tezde, HSV histogram temelli yangın tespitinde alevin ön plana çıktığı alanların belirlenmesi bakımından önemli bir katkı sağlamıştır [19]. Kalabalık analizinde CSRNet ve MCNN modellerinde anahtar kare ile yoğunluk değişim analizi gerçekleştirilmiştir [21].

Anahtar kare tespiti, bir video akışındaki önemli kareleri belirlemek için kullanılan bir tekniktir. Anahtar kareler, video özetleme, video indeksleme ve video içeriğinin anlaşılması gibi birçok uygulamada önemlidir. İşte yaygın olarak kullanılan bazı anahtar kare tespiti algoritmaları:

1. Frame Difference (Kare Farkı)
2. Optical Flow (Optik Akış)
3. Histogram Comparisons (Histogram Karşılaştırmaları)
4. Object Tracking (Nesne Takibi)

5. Motion Energy (Hareket Enerjisi)

6. **Salient Region Detection (Öne Çıkan Bölge Tespiti)**

Bu algoritmalar, video içeriğinin özelliklerine ve kullanım senaryolarına bağlı olarak birlikte veya ayrı ayrı kullanılabilir. Örneğin, bir video özetleme uygulamasında birden fazla algoritmanın bir arada kullanılması yaygındır.


Frame Difference (Kare Farkı): Ardışık kareler arasındaki farkın hesaplanmasıyla anahtar kareler tespit edilir. Büyük bir fark tespit edilen kareler anahtar kare olarak kabul edilir. Bu sözde kod, Frame Difference yöntemini kullanarak anahtar karelerin tespit edilmesinin temel adımlarını içerir: Video akışındaki ardışık kareler arasındaki farkların hesaplanarak belirli bir eşik değeri üzerinde olan karelerin "anahtar kare" olarak seçilmesini sağlayan sözde algoritma adımları Tablo 2.2 'de verilmiştir.

Tablo 2.2. Frame Difference yöntemiyle anahtar kare tespit adımları

1	Önceki kareyi oku ve başlangıç kare olarak ata.
2	Anahtar kareler listesini başlat.
3	Süreç sayacını başlat ve süreç döngüsünü başlat.
4	Her bir kare için: • Mevcut kareyi oku. • Kare farkını hesapla. • Kare farkı toplamını hesapla. • Eğer kare farkı toplamı belirli bir eşik değerinden büyükse, bu kareyi anahtar kare olarak kabul et ve listeye ekle. • Önceki kareyi güncelle. • Süreci artır. • Eğer video sona erdiyse, döngüyü bitir.
5	Anahtar kareleri görüntüle

Gerçek bir uygulama için bu sözde kod, gerçek programlama diline (örneğin, MATLAB) uygun şekilde uyarlanmalıdır. Bu uyarlamalar, kullandığınız dilin ve kullanmak istediğiniz video işleme kütüphanelerinin özelliklerine bağlı olacaktır.

Görüntüde ardışık kareler arasındaki farkların hesaplanması sonucunda, olay anını temsil eden yüksek değişim içeren karelerin tespiti Şekil 2.4.'de gösterilmiştir..




Şekil 2.4. Accident Footages From CCTV veri seti üzerinde anahtar kare çıkarılması

Optical Flow (Optik Akış): Her karedeki hareket vektörlerinin hesaplanmasıyla, görüntüler arasındaki hareketin analiz edilmesi sağlanır. Hareketli bölgelerdeki değişiklikler anahtar kareler olarak belirlenebilir. Kareler arası hareket vektörlerinin (optik akış) hesaplanması yoluyla, hareket yoğunluğuna bağlı olarak anahtar karelerin tespit edilmesini sağlayan sözde kod yapısı Tablo 2.3’de özetlenmiştir.

Tablo 2.3. Optik akış yöntemiyle anahtar kare tespit adımları

1	Önceki kareyi oku ve başlangıç kare olarak ata.
2	Anahtar kareler listesini başlat.
3	Süreç sayacını başlat ve süreç döngüsünü başlat.
4	Her bir kare için:
	• Mevcut kareyi oku. • Optik akış vektörlerini hesapla. • Hareket büyüklüğünü hesapla. • Eğer hareket büyüklüğü belirli bir eşik değerinden büyükse, bu kareyi anahtar kare olarak kabul et ve listeye ekle. • Önceki kareyi güncelle. • Süreci artır. • Eğer video sona erdiyse, döngüyü bitir.
5	Anahtar kareleri görüntüle

Frame Difference yönteminin uygulanmasıyla elde edilen örnek anahtar kare görselleştirmesi kare farklarının eşik değerinin üzerinde olması durumunda elde edilen ve olayların kritik anlarını temsil eden anahtar karelerin görsel çıktısı Şekil 2.5’de sunulmaktadır.



Şekil 2.5. Frame Difference kullanım örn.

- 1. Histogram Comparisons (Histogram Karşılaştırmaları):** Her bir karenin renk histogramının hesaplanmasıyla, farklılık oranlarına göre anahtar kareler tespit edilir. Özellikle renk dağılımındaki büyük değişiklikler anahtar kareler olarak kabul edilebilir.

Renk histogramları üzerinden yapılan benzerlik analiziyle, renk dağılımında önemli değişim içeren karelerin anahtar kare olarak seçilmesini sağlayan işlem adımları Tablo 2.4.’de gösterilmiştir.

Tablo 2.4. Histogram Comparisons (Histogram Karşılaştırmaları) yöntemiyle anahtar kare tespit adımları

1	Önceki kareyi oku ve başlangıç kare olarak ata.
2	Anahtar kareler listesini başlat.
3	Süreç sayacını başlat ve süreç döngüsünü başlat.
4	Her bir kare için:
	• Mevcut kareyi oku. • İlk kare ve mevcut kare için histogramları oluştur. • Histogram farkını hesapla. • Eğer histogram farkı belirli bir eşik değerinden büyükse, bu kareyi anahtar kare olarak kabul et ve listeye ekle. • İlk kareyi güncelle. • Süreci artır. • Eğer video sona erdiyse, döngüyü bitir.
5	Anahtar kareleri görüntüle

Her bir karenin renk histogramı arasındaki farkların ölçülmesiyle, renk değişiminin yoğun olduğu karelerin anahtar kare olarak belirlendiği görselleştirme örneği Şekil 2.6’da gösterilmektedir.





Şekil 2.6. Histogram Comparisons (Histogram Karşılaştırmaları) örnek veri seti için elde edilen sonuç

2. **Object Tracking (Nesne Takibi):** Belirli bir nesnenin tüm video boyunca takip edilmesiyle, nesnenin konumundaki değişiklikler anahtar kareler olarak belirlenebilir.
3. **Motion Energy (Hareket Enerjisi):** Her karedeki hareket miktarının ölçülmesiyle, yüksek hareket enerjisi olan kareler anahtar kare olarak belirlenebilir.
4. **Salient Region Detection (Öne Çıkan Bölge Tespiti):** Görüntüdeki öne çıkan veya ilgi çekici bölgelerin belirlenmesiyle, bu bölgelerin bulunduğu kareler anahtar kare olarak kabul edilebilir.

2.5. Anomali Tespit Yöntemleri ve Uygulama Alanları

Anomali tespiti, genel durumlarda sistemin öğrendiği davranışların dışına çıkan hareketlerin veya olayların tespitinin otomatik olarak belirlenmesidir [13]. Şüpheli insan davranışları, kargaşa, kavga, ihlaller, yangın ve patlama buna örnek anomali davranışları olabilir [12].

Anomali tespiti , hem makine öğrenmesi hem de görüntü işleme alanlarını ortak barındırarak gerçekleştirir [1]. Ayrıca derin öğrenme yaklaşımları, olağan dışı durumları desenleştirerek otomatik olarak öğrenme konusunda oldukça başarılıdır [17].

Bu tezde, kalabalık analizinde, normal olmayan yoğunluk değişimlerini potansiyel tehlike ya da güvenlik riski olarak belirlenebilmektedir [18]. Yangın tespitinde ise HSV histogram analizine dayalı bu sistem yine anomalileri otomatik tespit edebilmektedir [20]. Kısaca bu sistem, sadece sıradan bir izleme değil gelecekte güvenlik tedbirleri açısından etkin olacaktır [3].

2.6. Kalabalık Analiz Yöntemleri ve Uygulama Alanları

Kalabalık analizi, görüntü ya da videodaki, insan sayısını, yoğunluğunu ve davranışlarının belirlenmesi için yapılan analizdir [8]. Kalabalık içindeki insanların bulundukları görüntünün yoğunluk haritasını çıkarmak modelleme sürecidir [16].

Kalabalık analiz uygulamaları aşağıdaki gibi kategorize edilebilir:

- Yoğunluk tahmini (Density Estimation): Görüntü üzerindeki kalabalık miktarını pikseller cinsinden tahmin eder [17].
- Kalabalık sayımı (Crowd Counting): Toplam kişi sayısını verir [18].
- Kalabalık akışı takibi (Crowd Flow Analysis): İnsanların hareket yönlerini ve hızlarını analiz eder [14].
- Anomalilerin tespiti: Aşırı kalabalıklaşma veya ters yönde hareket gibi olağandışı durumları belirler [12].

Bu tezde,ShangaiTech ve Mall veri setleri kullanılarak gerçekleştirilen çalışmada kalabalık sayımı ve yoğunluk hatitalaması temel amaç olarak belirlenmiştir [8].Bu amaç doğrultusunda CSRNet ve MCNN algoritmaları kullanılmıştır [16].

MCNN modeli,farklı çözünürlük ve ölçek değişikliklerine karşı alt yapısı sayesinde esnek bir performans göstermiştir [22].

CSRNet modeli ise ,kalabalık tespitinde yoğunluk haritasını duyuşal alan yapısı ile başarılı şekilde oluşturmuştur[18].Ayrıca kalabalık tespiti izleme sistemleri için durumsal farkındalık sağlamıştır [13].

3. AKILLI ŞEHİRLERDE YANGIN ALGILAMA İÇİN HSV HİSTOGRAM TABANLI YÖNTEM

Yangınlar tüm dünyaya zarar veren felaketlerdir [23]. Yangınlar, yıldırım düşmesi gibi doğal nedenlerle veya insanların ormanlarda dikkatsizce ateş yakmasıyla başlayabilir [11]. Yangın algılama sistemlerinin amacı, yangınları başlar başlamaz tespit edip yetkililere bildirmektir. Bu, can ve mal kaybını en aza indirmeyi amaçlayan hızlı müdahaleye olanak tanır [20]. Geleneksel yangın algılama yöntemleri arasında duman ve ısı sensörleri, yangın alarm sistemleri ve gözetleme kuleleri bulunur [3]. Ancak, bu yöntemler genellikle yangın belirli bir boyuta ulaştıktan sonra etkili olur ve özellikle geniş alanlarda yetersiz kalır [14]. Son yıllarda, teknolojiye ilerlemeler yangın algılama yöntemlerinde önemli yenilikler getirmiştir. Uzaktan algılama teknolojileri, insansız hava araçları (İHA'lar), uydu görüntüleme sistemleri ve yapay zeka tabanlı analizler, yangın algılamanın doğruluğunu ve hızını artırmaya önemli katkılarda bulunmuştur [15]. Bu yenilikçi yöntemler, geniş alanların gerçek zamanlı izlenmesini ve yangınların erken tespitini sağlar [19].

Bu bölümde, HSV (Hue, Saturation, Value) renk uzayına dayalı histogram analizi ile gerçekleştirilen bir görüntü işleme temelli yangın tespit yöntemi önerilmektedir. Yöntemin temel amacı, video kareleri üzerinde yangına özgü renk desenlerini matematiksel olarak modelleyerek anlık yangın algılaması yapmaktır [5].

3.1. Giriş

Renk tabanlı analizler, yangının görsel doğası gereği önemli avantajlar sunar [4]. Özellikle alevin karakteristik renkleri olan kırmızı, turuncu ve sarı tonları, görüntü tabanlı algoritmalar tarafından HSV uzayında daha kolay ayrıştırılabilmektedir [20]. HSV renk modeli, RGB renk uzayının aksine insan algısına daha yakın çalışır. Bu bağlamda, yangına ait bölgeler doygunluk (S) ve parlaklık (V) değerleri ile birlikte ton (H) bilgisi kullanılarak daha etkin sınıflandırılabilir [19].

HSV tabanlı analiz yönteminin tercih edilmesindeki temel motivasyon, renk bilgisine dayalı bölgelerin istatistiksel özelliklerinin histogramlar aracılığıyla modellenmesidir[5]. Bu sayede, çeşitli aydınlatma koşullarına karşı daha kararlı bir yangın tespiti elde edilmesi amaçlanmaktadır [14].

3.2. Flame Veri Seti

Bu çalışmada, mevcut FLAME Veri Seti: Hava Görüntüleri Drone'lar (İHA'lar) Kullanılarak Yığın Yanık Tespiti kullanılmıştır [3]. Bu veri seti, hava yığın yanık tespiti için sınıflandırma ve segmentasyon gibi görevleri destekleyen çeşitli depolara yapılandırılmıştır. Şekil 3.1, veri setindeki tüm depoları göstermektedir. Bu çalışmada, sınıflandırma 7. ve 8. depolar kullanılarak yapılmıştır. Yedinci depo, "Yangın-Yangınsız" görüntü sınıflandırma sorunu (Eğitim/Doğrulama veri seti) için 254x254 olarak yeniden boyutlandırılan 39.375 karedir [14]. Bu deponun boyutu 1,3 GB'tır ve biçimi JPEG'dir. Sekizinci depo, "Fire-vs-NoFire" görüntü sınıflandırma problemi (Test veri seti) için 254x254'e yeniden boyutlandırılan 8.617 karedir [20]. Bu deponun boyutu 301 MB'dir ve biçimi JPEG'dir. FLAME veri setinde yer alan tüm veri depolarının yapısal görünümü. Her bir depo, yangın tespiti görevleri için farklı amaçlara (eğitim, doğrulama, test vb.) hizmet eden görüntüleri Şekil 3.1.'de gösterilmektedir.


	Type	Camera	Palette	Duration	Resolution	FPS	Size	Application	Usage	Labeled
1	Video	Zenmuse	Normal(.MP4)	966 s	1280 × 720	29	1.2 GB	Classification	–	N
2	Video	Zenmuse	Normal(.MP4)	399 s	1280 × 720	29	503 MB	–	–	N
3	Video	FLIR	WhiteHot(.MOV)	89 s	640 × 512	30	45 MB	–	–	N
4	Video	FLIR	GreenHot(.MOV)	305 s	640 × 512	30	153 MB	–	–	N
5	Video	FLIR	Fusion(.MOV)	25 mins	640 × 512	30	2.83 GB	–	–	N
6	Video	Phantom	Normal(.MOV)	17 mins	3840 × 2160	30	32 GB	–	–	N
7	Frame	Zenmuse	Normal(.JPEG)	39,375 frames	254 × 254	–	1.3 GB	Classification	Train/Val	Y
8	Frame	Phantom	Normal(.JPEG)	8617 frames	254 × 254	–	301 MB	Classification	Test	Y
9	Frame	Phantom	Normal(.JPEG)	2003 frames	3480 × 2160	–	5.3 GB	Segmentation	Train/Val/Test	Y(Fire)
10	Mask	–	Binary(.PNG)	2003 frames	3480 × 2160	–	23.4 MB	Segmentation	Train/Val/Test	Y(Fire)

Şekil 3.1. Veri kümesindeki tüm depolar

3.3. Önerilen HSV Histogram Yöntemi

Önerilen yöntem, depolardan elde edilen görüntülerin HSV (Ton, Doygunluk, Değer) renk uzayına dönüştürülmesi ve bu dönüşüm sonucunda oluşan histogramların sınıflandırılması esasına dayanmaktadır [5]. Bu bağlamda, görüntülerin H, S ve V katmanlarının histogramları ayrı ayrı çıkarılmış, ardından her görüntü için bu değerler birleştirilerek sınıflandırma aşamasına geçilmiştir [19]. Sınıflandırma işlemi; SVM (Destek Vektör Makineleri), Fine Decision Tree ve Fine KNN algoritmaları ile gerçekleştirilmiştir [11].

Önerilen HSV histogram tabanlı yöntem için akış diyagramı. Görüntülerin HSV renk uzayına dönüştürülmesi, H-S-V histogramlarının ayrı ayrı çıkarılması ve bu histogramların sınıflandırma algoritmalarına (SVM, Fine Decision Tree, Fine KNN) giriş olarak verilmesi süreci Şekil.3.2’de gösterilmiştir.



Şekil 3.2. Önerilen yöntemin akış diyagramı

HSV uzayı, renkleri insan algısına daha uygun şekilde temsil eder [5]. HSV modelinde Ton (H), Doygunluk (S) ve Değer (V) bileşenleri, RGB uzayına kıyasla renk ayrımı ve analizi için daha verimli sonuçlar vermektedir [19]. HSV renk uzayının özellikle yangın tespiti gibi uygulamalarda tercih edilmesinin nedeni, bu uzayın parlaklık ve renk yoğunluğu gibi faktörlerden bağımsız olarak çalışabilmesidir [20] [23]. Şekil 3.3. ‘de yangın sınıfına ait bir görüntünün RGB, gri tonlama (grayscale) ve HSV renk uzayındaki temsilleri. HSV renk uzayı, ton (Hue) ve doygunluk (Saturation) bileşenlerini ayrı ayrı değerlendirebilmesi sayesinde, yangın gibi sıcak renklerin diğer nesnelerden daha kolay ayrıştırılmasına olanak tanımaktadır.




RGB

Gri

HSV


Şekil 3.3. Yangın sınıfı RGB, gri ve HSV görünümü

Şekil 3.4’de yangın ve yangın dışı sınıflara ait örnek görüntülerin H (Hue), S (Saturation) ve V (Value) histogramları. Bu histogramlar, her sınıfın renk dağılımı açısından belirgin farklılıklar gösterdiğini ortaya koymakta ve sınıflandırma sürecinde kullanılabilecek anlamlı özellikler sunmaktadır.



Şekil 3.4. Yangın ve yangın dışı sınıf için histogramlar

Bu görsel, yangın ve yangın dışı sınıfların renk bileşenleri bakımından belirgin farklılıklar gösterdiğini ortaya koymaktadır. Özellikle HSV uzayındaki H (Hue) bileşeni, sınıflar arasında güçlü bir ayrım sağlamaktadır. Bu analiz Şekil 3.5’te görsel olarak sunulmuştur.



Şekil 3.5. Yangın sınıfı ve yangın sınıfı olmayan örnek görüntülerin R, G, B ve H, S, V katmanlarının histogram grafikleri

Yöntemin uygulanabilirliği, RGB ve gri tonlamalı görüntülerin yetersizliğini ortaya koyan deneysel analizlerle desteklenmiştir[3]. HSV histogramları kullanılarak elde edilen veriler; Şekil 3.3, 3.4 ve 3.5’te görsel olarak sunulmuştur. Bu görseller ve histogram analizleri, özellikle H katmanının yangın ve yangın dışı görüntüler arasında güçlü bir ayırt edici özellik taşıdığını göstermektedir [14]. HSV histogram değerlerinin sınıflandırılması sonucunda kullanılan algoritmaların genel tanımı şu şekildedir [4]:

- **Karar Ağacı:** Özellik değerlerine göre verileri alt kümelere ayırarak tahmin işlemini gerçekleştiren ağaç yapılı bir modeldir [18].

- **SVM:** Sınıflar arasındaki farkı en iyi ayıran hiper düzlemleri kullanarak yüksek doğrulukta sınıflandırma yapan bir algoritmadır [8].
- **KNN:** Yeni bir örneği, eğitim kümesindeki en yakın k komşunun sınıfına göre etiketleyen, basit ama etkili bir yöntemdir [13].

3.4. Deneysel Sonuçlar

Yöntemlerin başarımını test etmek amacıyla MATLAB Classification Learner Toolbox kullanılmış ve 10 katlı çapraz doğrulama uygulanmıştır [1]. Testler iki farklı kamera sistemine göre gerçekleştirilmiştir: Zenmuse ve Hayalet kamera.

Zenmuse Kamera Sonucu Karar Ağacı modeli, yangın sınıfını %99,63, yangın olmayan sınıfı %99,41 doğrulukla tahmin etmiştir. SVM modeli sırasıyla %99,84 ve %99,76; KNN modeli ise %99,89 ve %99,90 doğruluk oranları ile en başarılı sonuçları vermiştir. Zenmuse kamera ile elde edilen görüntüler üzerinde yapılan sınıflandırma sonuçlarının hata matrisi (confusion matrix) analizleri, üç farklı algoritma için Şekil 3.6'da görsel olarak karşılaştırılmıştır.

Gerçek Sınıf	Tahmin Edilen Sınıf	
	0	1
	0	1
0	24926	92
1	84	14273
a)		
0	24979	39
1	34	14323
b)		
0	24991	27
1	14	14343
c)		

Şekil 3.6. Confusion Matris a) Fine Decision Tree Model b) Cubic SVM Model c) Fine KNN Model

100 yineleme ile yapılan test sonuçları, Doğruluk, Kesinlik, Geri Çağırma, Geometrik Ortalama ve F1 Puanı metrikleriyle Tablo 3.1'de sunulmuştur. Ayrıca, RGB, gri tonlamalı ve HSV histogramlarının doğruluk karşılaştırması Tablo 3.2'de gösterilmiş ve HSV'nin üstünlüğü vurgulanmıştır.

Tablo 3.1. Önerilen yöntem 100 yineleme performans değerleri.

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Geometrik Ortalama (%)	F1-Skore (%)
DT	99.60	99.57	99.58	99.58	99.57
SVM	99.82	99.80	99.81	99.81	99.80
KNN	99.90	99.88	99.90	99.90	99.89

Tablo 3.2. RGB, gri tonlamalı ve HSV görünümünün histogramları kullanılarak elde edilen yangın tahmin doğruluğu değerlerinin karşılaştırılması

	Gri + Histogram (%)	RGB + Histogram (%)	HSV + Histogram (%)
DT	98.80	98.90	99.60
SVM	99.40	99.50	99.82
KNN	99.80	99.84	99.90

Hayalet Kamera Sonucu Karar Ağacı modeli sırasıyla %98,42 ve %97,30; SVM modeli %99,44 ve %99,77; KNN modeli ise %99,34 ve %99,40 doğrulukla tahmin yapmıştır. Burada en iyi sonuç Kübik SVM modeliyle elde edilmiştir. Phantom kamera görüntüleri üzerinde yürütülen sınıflandırma sürecinde elde edilen hata matrisleri, her bir algoritma için Şekil 3.7’de sunulmuştur.

Gerçek Sınıf	Tahmin Edilen Sınıf					
	0		1		0	
	0	1	0	1	0	1
0	5056	81	5108	29	5103	34
1	94	3386	8	3472	21	3459
	a)		b)		c)	

Şekil 3.7. Confusion Matris a) Fine Decision Tree Model b) Cubic SVM Model c) Fine KNN Model

100 yinelemeye dayalı performans analizleri Tablo 3.3'te, farklı renk uzayı kombinasyonlarının doğruluk karşılaştırmaları ise Tablo 3.4'te yer almaktadır. HSV uzayı her iki kamera türü için de en başarılı sonuçları vermiştir.

Tablo 3.3. Önerilen yöntem 100 yineleme performans değerleri

	Doğruluk (%)	Tahmin (%)	Duyarlılık (%)	Geometrik Ortalama (%)	F1-Skore (%)
DT	98.22	98.12	98.18	98.18	98.15
SVM	99.64	99.58	99.66	99.66	99.62
KNN	99.43	99.38	99.43	99.43	99.40

Tablo 3.4. RGB, gri tonlamalı ve HSV görünümünün histogramları kullanılarak elde edilen yangın tahmin doğruluğu değerlerinin karşılaştırılması.

	Gri + Histogram (%)	RGB + Histogram (%)	HSV + Histogram (%)
DT	94.4	93.60	98.22
SVM	99.1	99.40	99.64
KNN	99.4	99.40	99.43

3.5. Bölüm Değerlendirmesi

Yangınların erken tespiti hem maddi hem de manevi kayıpları azaltır [23]. Bu nedenle, bu amaçla birçok yöntem geliştirilmiş ve geliştirilmeye devam etmektedir. Bu çalışmada, yangın tespiti önce HSV renk uzayını kullanarak histogram değerleri elde edilerek ve ardından makine öğrenimi yöntemleri uygulanarak gerçekleştirildi. FLAME veri setinin 7. (Zenmuse Kamera) ve 8. (Phantom Kamera) depoları kullanıldı ve sonuçlar bu depolar için ayrı ayrı elde edildi. Elde edilen sonuçlardan, HSV renk uzayının RGB ve gri tonlamalı gösterimlerden daha iyi sonuçlar sağladığı görüldü. Zenmuse Kamera için en iyi sonuç %99,90 doğruluk oranıyla Fine KNN modeliyle elde edildi. Phantom Kamera için en iyi sonuç %99,64 doğruluk oranıyla Cubic SVM modeliyle elde edildi.

4. AKILLI ŞEHİRLERDE KALABALIK ANALİZİ İÇİN CSRNET VE MCNN TABANLI BİR YÖNTEM

Yapay zekâ temelli görüntü işleme benzeri çözümler, güvenlik kamera sistemlerinden elde edilen veriler üzerinden kalabalık analizi gerçekleştirebilmektedir. Son dönemde giderek artan insan nüfusu kentleşmeyi de arttırmıştır. Buna bağlı olarak akıllı şehir uygulamaları kapsamında olan alanların kontrolü kritik hale gelmiştir [16]. Nüfus yoğunluğunun, düzenli ve tutarlı tespiti; güvenlik, emniyet ,trafik, afet gibi pek çok alanda önemli katkılar sağlamaktadır [13].

Bu bölümde, kalabalık analizi yapan derin öğrenme temelli olan CSRNet ve MCNN modelleri; ShanghaiTech ve Mall veri setleri üzerinde yoğunluk haritası üretimi yoluyla yapılan deneyler doğrultusunda kullanılmıştır. Sonuçlar, başarıları ve uygunlukları yönünden değerlendirilmiştir.

4.1. Giriş

Kalabalık analizi, özellikle akıllı şehirlerde trafik denetimi, afet yönetimi ve insan yoğunluğu tespiti alanlarında aktif olarak kullanılmaktadır [13]. Bu gelişmiş izleme organizasyonları açısından oldukça önemlidir [8]. Kalabalık tespiti, benzeri nesne tespiti veya doğrusal tahmin yönetimi gibi klasik yapılar yüksek yoğunluk ve karışık algılar altında esneklik ve tutarlılık bakımından kısıtlıdır. Bu çalışmada, ShanghaiTech ve Mall veri setleri üzerinde CSRNet modelleri uygulanması ve kıyaslanmasını hedeflemektedir.

4.2. Kalabalık Veri Seti

Bu çalışmada,ShanghaiTech-PartA ve Mall veri setleri üzerinden kalabalık analizi gerçekleştirilmiştir. ShanghaiTech-PartA veri seti,insan yoğunluğunun fazla olduğu için görüntü işleme de kişi sayımı için kullanılan yüksek ölçekli veri setidir.Part A kısmı, sanal ortamda rastgele toplanan, yoğun kalabalık içeren 482 adet görüntüden oluşur. 300 görüntü eğitim,182 görüntü test şeklinde bölünmüştür. Her görüntüde, bireylerin pozisyonları .mat dosyaları içerisinde koordinat olarak verilmiştir [8]. CSRNet ve MCNN modellerinde bu koordinat bilgileri, yoğunluk haritası (density map) oluşturmak için kullanılmıştır.

Mall veri seti,bir alışveriş merkeğinde çekimi gerçekleştirilen toplam 2000 adet video dizisinden oluşan görüntülerdir.Bu görüntülerdeki insanların bulundukları noktalar manuel olarak işaretlenmiştir.Veri setinde insan yoğunluğu düşük ve orta düzeydedir [17].Bu da hem modellerin düşük yoğunlukta performanslarını değerlendirmek hem de farklı senaryoda kararlılıklarını test etmek amacıyla ,gerçek zamanlı izleme uygulamalarına elverişlidir.

4.3. Önerilen Yöntem

Bu çalışmada CNN temelli olan CSRNet ve MCNN algoritmaları ile kalabalık tahmini yapılmış ve karşılaştırılmıştır. CSRNet, derin katmanlardan oluşan yoğun kalabalık sahnelerinde yoğunluk haritası üreten bir modeldir [16]. Yapısı iki kısımdan oluşur:

Ön kısım (front-end): VGG-16 mimarisinin ilk 10 katmanını alınarak özellik çıkarımı yapılır.


Arka kısım (Back-end): Dilation (genişletilmiş) konvolüsyon katmanları ile yoğunluk haritası üretilir.

Bu yapı sayesinde, geniş alandaki ilişkiler modellenebilir ve kalabalık sahnelerde başarılı tahminler yapılabilir [22]. En önemli özelliği düşük yoğunluklu sahnelerde yüksek başarı göstermesidir. MCNN modeli, farklı ölçeklerdeki insanları tespit edebilmek amacıyla çok sütunlu bir mimari kullanır. Her sütun farklı filtre boyutları kullanarak görüntüyü işler [16]:

- Küçük sütun: Yakın ve net bireyler
- Orta sütun: Orta uzaklıktaki bireyler
- Geniş sütun: Uzak ve küçük boyutlu bireyler

Bu mimari sayesinde görüntüdeki farklı büyüklükteki insan figürleri birlikte analiz edilebilir. Yoğunluk haritası üretilerek kalabalık dağılımı tahmin edilir [8].

Her iki modelin genel yapısını ve kalabalık sayımı süreçlerini açıklayan şematik yapı Şekil 4.1'de verilmiştir. Bu yapı, modellerin nasıl çalıştığını adım adım görselleştirerek modelin genel işleyişine dair bütünsel bir anlayış sağlamaktadır.



Şekil 4.1. CSRNet ve MCNN kullanarak kalabalık sayma hattı

4.4. Deneysel Sonuçlar

Modeller her iki veri setinde de eğitilmiş ve aşağıdaki metriklerle değerlendirilmiştir:

- MAE (Mean Absolute Error): Ortalama mutlak hata
- RMSE (Root Mean Squared Error): Kök ortalama kare hata

ShanghaiTech Part A Sonuçları


ShanghaiTech Part A veri seti, yüksek yoğunluklu kalabalık sahneleri içermesi nedeniyle özellikle zorlayıcı bir veri setidir. Bu nedenle bu veri setinde elde edilen başarılar, modelin gerçek dünyadaki karmaşık sahnelerle baş edebilme kapasitesini doğrudan yansıtmaktadır. Bu veri setinde her iki modelin performans karşılaştırması Tablo 4.1'de sunulmuştur.

Tablo 4.1.ShanghaiTech Part A Sonuçları

Model	MAE	RMSE
CSRNet	68.2	104.3
MCNN	110.2	173.2


CSRNet modeli, Part A'daki yoğun kalabalık sahnelerde daha düşük MAE ve RMSE değerleri ile üstün performans göstermiştir. Elde edilen sonuçlara göre, CSRNet modeli, hem MAE hem de RMSE açısından MCNN modeline kıyasla çok daha düşük hata oranları sergilemiştir. Bu durum, CSRNet'in yüksek yoğunluklu sahnelerdeki detayları daha başarılı bir şekilde öğrenebildiğini ve daha doğru tahminlerde bulunabildiğini ortaya koymaktadır.

CSRNet'in yüksek doğruluğunu görsel olarak yansıtan bir örnek tahmin çıktısı Şekil 4.2'de sunulmuştur. Bu şekil, kalabalığın yoğunlaştığı alanlardaki ısı yoğunluklarını doğru şekilde modelleyebildiğini göstermektedir.



Şekil 4.2. ShanghaiTech Bölüm A veri setinden alınan yüksek yoğunluklu bir görüntü için CSRNet tarafından tahmin edilen yoğunluk haritası.

Öte yandan, MCNN modeli aynı görüntü üzerinde uygulandığında bazı sınırlamalar ortaya çıkmıştır. Özellikle kalabalık dağılımının homojen olmadığı, bireylerin düzensiz şekilde konumlandığı sahnelerde MCNN, yoğunluk haritasını oluştururken detaylı konum bilgisini yeterince hassas şekilde yansıtamamıştır. Bu model, yalnızca genel kalabalık yoğunluğu hakkında yüzeysel bir fikir sunmakla kalmış, bireysel nesne tespiti ve hassas sayım görevlerinde yetersiz kalmıştır. Bu durum, Şekil 4.3'te yer alan yoğunluk haritası örneğinde açıkça görülmektedir. Şekilde, modelin yoğunluğu genel hatlarıyla yakaladığı, ancak bireysel insan kümelerini doğru konumlandırmakta zorlandığı gözlemlenmektedir.



Şekil 4.3. Yoğun kalabalıkların modellenmesinde sınırlamaları gösteren ikinci MCNN tahmini.

Mall Veri Seti Sonuçları

Mall veri seti, düşük kalabalık yoğunluklarının olduğu, genellikle bireylerin daha net seçilebildiği alışveriş merkezi ortamlarından oluşmaktadır. Bu veri seti üzerinde yapılan değerlendirme sonuçları Tablo 4.2'de sunulmuştur.

Tablo 4.2. Mall Veri Seti Sonuçları

Model	MAE	RMSE
CSRNet	2.7	4.6
MCNN	3.1	5.2

Daha az yoğun kalabalık içeren Mall veri setinde her iki model de başarılı sonuçlar vermiştir, ancak CSRNet yine biraz daha düşük hata oranlarına sahiptir. Sonuçlar görselleştirildiğinde, CSRNet'in insanların bulundukları noktaları yoğunluk haritalarıyla daha tutarlı olduğu kaydedilmiştir. MCNN ise genel yoğunlukta olan noktaları tespit etmede etkili olsa da insanların bulundukları noktaların detaylı ayrımında çok etkili olamamıştır.

Sonuçlar göstermektedir ki, her iki model de düşük yoğunluklu kalabalık analizinde başarılıdır. Ancak CSRNet modeli, yine daha düşük hata oranları ile bir adım öne çıkmıştır. Bu modelin tahmin yeteneği Şekil 4.4'te örnek bir sahne ile görselleştirilmiştir.



Şekil 4.4. CSRNet tarafından Alışveriş Merkezi veri kümesi üzerinde oluşturulan örnek yoğunluk haritası, kalabalık alanlardaki doğru konsantrasyonu göstermektedir.

4.5. Bölüm Değerlendirmesi

CSRNet ve MCNN modelleri, görüntü odaklı kalabalık analizi verimli modellerdir. Bu çalışmada çıkan deneysel sonuçlara göre:

CSRNet, yüksek yoğunlukta da düşük yoğunlukta da oldukça doğru sonuçlar vermiştir.

MCNN, daha basit yapısıyla çabuk tahminde bulunmuştur fakat CSRNet kadar doğru tahmin performansı gösterememiştir.

CSRNet, gerek zamanlı kriz anı durum takiplerinde, emniyet aısından aşırı yoğunluk takibinde, yüksek duyarlılık gerektiren durumlarda kullanılır.MCNN ise sınırlı kaynakların olduėu, taşınabilir sistemlerde ve başlangı düzeyinde arařtırmalarda kullanılabilir.

Bu tez, akıllı řehir uygulamalarına katkı saėlayan, kalabalık analizinde kullanılan modellerin karřılařtırmaalı analizlerini özgün řekilde ortaya koymaktadı



5. SONUÇLAR

Bu tez çalışmasında, akıllı şehir uygulamaları kapsamında kritik öneme sahip olan **yangın tespiti** ve **kalabalık analizi** problemlerine yönelik görüntü işleme ve yapay zeka temelli iki farklı yöntem ayrıntılı şekilde incelenmiş, uygulanmış ve deneysel olarak değerlendirilmiştir [23] [3]. Her iki uygulama alanı da şehir güvenliği, afet yönetimi ve toplu yaşam alanlarının denetlenmesi gibi konularda karar destek sistemleri için temel yapı taşlarını oluşturmaktadır [14].

Tez iki temel uygulama etrafında şekillenmiştir: HSV histogram tabanlı yangın algılama yöntemi [19] ve CSRNet ile MCNN temelli kalabalık analizi [8]. Çalışmanın tüm aşamalarında hem yöntemsel bütünlük korunmuş hem de uygulamaya dayalı deneysel doğrulamalarla model başarımları nicel olarak ortaya konmuştur [16].

5.1. Yangın Tespitinde HSV Histogram Yöntemi Üzerine Değerlendirme

HSV renk uzayı, özellikle yangın gibi parlak ve karakteristik renk yoğunluklarına sahip nesnelerin tespitinde RGB renk uzayına kıyasla daha kararlı sonuçlar vermektedir [5]. Tezde önerilen yöntem; görsel verilerden elde edilen HSV histogramlarının, yangın ve yangın olmayan bölgeleri ayırt edebilmesi ilkesine dayanmaktadır. Flame veri seti üzerinde gerçekleştirilen deneysel çalışmalar sonucunda, yöntemin;

Düşük karmaşıklığa sahip olması , gerçek zamanlı sistemlere entegre edilebilirliği ve renk temelli basit ama etkili bir ön tespit modülü olarak görev yapabilmesi [3] gibi avantajları öne çıkmaktadır. Ancak, yöntemin bazı sınırlılıkları da gözlemlenmiştir:

Renk benzerliği gösteren nesnelerde (örneğin turuncu giysi, lamba ışığı) yanlış pozitif sonuçlar verme riski [19]. Hareket, şekil veya doku gibi diğer özellikleri dikkate almaması [15] ve yalnızca görsel spektrumda çalışmasıdır(termal destek yok) [14]. Bu eksiklikler, gelecekte hareketli görüntülerde zaman serisi analizi, sıcaklık sensörleri ile çoklu kaynaklı karar mekanizmaları gibi iyileştirmelerle giderilebilir [30].

5.2. Kalabalık Analizi Üzerine Değerlendirme

Kalabalık analizi, gerek toplumsal düzenin korunmasında gerekse afet anı gibi kritik durumların izlenmesinde hayati öneme sahiptir [13]. Bu çalışmada iki derin öğrenme temelli yoğunluk tahmin mimarisi olan **CSRNet** ve **MCNN** başarımları açısından değerlendirilmiştir [8].

CSRNet, VGG-16 tabanlı derin yapısı ve dilated konvolüsyon katmanları sayesinde yüksek doğrulukla yoğunluk haritası üretebilmekte ve özellikle yoğun kalabalık içeren sahnelerde daha başarılı sonuçlar sunmaktadır [16].

MCNN, farklı ölçeklerdeki bireyleri algılamak için geliştirilmiş çok sütunlu yapısıyla esneklik sağlamaktadır [16]. Hafif mimarisi nedeniyle düşük donanımlı sistemlerde çalışmaya daha uygundur [17].

ShanghaiTech Part A ve Mall veri setlerinde yapılan deneyler neticesinde:

CSRNet, her iki veri setinde de daha düşük **MAE** ve **RMSE** değerleriyle üstünlük göstermiştir [8]. MCNN, daha düşük yoğunluklu sahnelerde yeterli performans gösterse de detaylı bireysel ayırım konusunda sınırlı kalmıştır [18].

5.3. Genel Değerlendirme ve Katkılar

Bu tez çalışması, literatürde sıkça kullanılan yöntemleri sadece teorik olarak aktarmakla kalmamış aynı zamanda görüntü işleme ve yapay zeka yöntemlerini gerçek veri setleriyle birleştirerek pratik çıktılar üretmiş [14]. Uygulanan modellerin mimari detaylarını anlamış ve kod düzeyinde başarıyla gerçekleştirmiş [8]. Sonuçları grafiksel ve metrikse olarak analiz ederek karşılaştırmalı bir çalışma sunmuştur [16]. Bu bağlamda, çalışma hem akademik hem de uygulamalı anlamda değerli bir bütünlük arz etmektedir.

5.4. Gelecek Çalışmalar İçin Öneriler

Bu çalışmada ortaya koyulan yöntemler, gelecekte daha gelişmiş sistemlerin temelini oluşturabilecek niteliktedir [23] [14]. Aşağıda gelecek çalışmalar için bazı öneriler sıralanmıştır:

Yangın Tespiti İçin:

Termal görüntülerle HSV histogram analizinin birleştirildiği çok modlu sistemler geliştirilebilir [11]. Hareket temelli (optical flow) özelliklerle desteklenmiş yangın tespiti yapılabilir [15]. Derin öğrenme tabanlı yangın sınıflandırıcıları (CNN, LSTM) uygulanarak doğruluk artırılabilir [20].

Kalabalık Analizi İçin:

CSRNet ve MCNN gibi modellerin encoder-decoder yapıları ile hibrit çözümler oluşturulabilir [8]. Kalabalık davranışı tahmini için zaman serisi modelleme (ConvLSTM) denenebilir [17]. Gerçek zamanlı analiz için mobil cihaz uyumlu, hafif modeller geliştirilebilir [18].

Genel Geliştirmeler:

Model çıktılarının görsel analizlerine yönelik bir kullanıcı arayüzü tasarlanabilir. Akıllı şehir senaryolarında çoklu kamera akışlarını birleştiren sistemler geliştirilebilir [3]. Bu tez, görüntü işleme ve yapay zeka yöntemlerinin birleşimiyle akıllı şehirler için faydalı olacak erken uyarı sistemlerinin temelini atmaktadır. Elde edilen bulgular ve sonuçlar, hem akademik literatüre katkı sunmakta hem de gerçek dünya uygulamaları için yol göstermektedir [30].

KAYNAKLAR

- [1] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," in *Advances in Neural Information Processing Systems*, 2012.
- [2] W. Sultani, C. Chen, and M. Shah, "Real-world anomaly detection in surveillance videos," *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, pp. 6479–6488, 2018.
- [3] A. Shamsoshoara, F. Afghah, A. Razi, L. Zheng, P. Z. Fulé, and E. Blasch, "Aerial imagery pile burn detection using deep learning: The FLAME dataset," *Comput. Networks*, vol. 193, p. 108001, 2021, doi: 10.1016/j.comnet.2021.108001.
- [4] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2005, pp. 886–893.
- [5] M. J. Swain and D. H. Ballard, "Color indexing," *Int. J. Comput. Vis.*, vol. 7, no. 1, pp. 11–32, 1991.
- [6] T. M. Cover and P. E. Hart, "Nearest neighbor pattern classification," *IEEE Trans. Inf. Theory*, vol. 13, no. 1, pp. 21–27, 1967.
- [7] H. Zhang, "The optimality of Naive Bayes," in *AAAI-04 Workshop on Learning with Imperfect Data*, 2004, pp. 1–6.
- [8] Y. Li, X. Zhang, and D. Chen, "CSRNet: Dilated convolutional neural networks for understanding the highly congested scenes," in *CVPR*, 2018.
- [9] O. Yaman, H. Yetis, and M. Karakose, "Band Reducing Based SVM Classification Method in Hyperspectral Image Processing," in *2020 Zooming Innovation in Consumer Technologies Conference (ZINC)*, 2020, pp. 21–25. doi: 10.1109/ZINC50678.2020.9161813.
- [10] S. Dutta and S. Ghosh, "Forest Fire Detection Using Combined Architecture of Separable Convolution and Image Processing," in *2021 1st International Conference on Artificial Intelligence and Data Analytics (CAIDA)*, 2021, pp. 36–41. doi: 10.1109/CAIDA51941.2021.9425170.
- [11] L. Zhang, M. Wang, Y. Fu, and Y. Ding, "A Forest Fire Recognition Method Using UAV Images Based on Transfer Learning," *Forests*, vol. 13, no. 7, p. 975, 2022, doi: 10.3390/f13070975.
- [12] R. T. Ionescu, A. Smeureanu, B. Alexe, and M. Popescu, "Detecting abnormal events in video using narrow deep networks," *Proc. IEEE Int. Conf. Comput. Vis.*, pp. 4510–4519, 2019.
- [13] R. Mehran, A. Oyama, and M. Shah, "Abnormal crowd behavior detection using social force model," in *Proceedings of the IEEE Conference on Computer Vision and Pattern*

- Recognition (CVPR)*, 2009, pp. 935–942.
- [14] Z. Guan, X. Miao, Y. Mu, Q. Sun, Q. Ye, and D. Gao, “Forest Fire Segmentation from Aerial Imagery Data Using an Improved Instance Segmentation Model,” *Remote Sens.*, vol. 14, no. 13, p. 3159, 2022, doi: 10.3390/rs14133159.
 - [15] S. Wu and L. Zhang, “Using Popular Object Detection Methods for Real Time Forest Fire Detection,” in *2018 11th International Symposium on Computational Intelligence and Design (ISCID)*, 2018, pp. 280–284. doi: 10.1109/ISCID.2018.00070.
 - [16] Y. Zhang, D. Zhou, S. Chen, S. Gao, and Y. Ma, “Single-image crowd counting via multi-column convolutional neural network,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
 - [17] H. Jiang, H. Zhao, Y. Wang, Y. Zou, and W. Liu, “Crowd counting and density estimation by trellis encoder-decoder networks,” in *CVPR*, 2020.
 - [18] C. Song, J. Zhang, Q. Zhang, J. Yu, and J. Sun, “Rethinking counting and localization in crowds: A pure localization approach via point-level regression,” in *ICCV*, 2021.
 - [19] C. E. Prema, S. S. Vinsley, and S. Suresh, “Efficient Flame Detection Based on Static and Dynamic Texture Analysis in Forest Fire Detection,” *Fire Technol.*, vol. 54, no. 1, pp. 255–288, 2018, doi: 10.1007/s10694-017-0683-x.
 - [20] K. Muhammad, J. Ahmad, Z. Lv, P. Bellavista, P. Yang, and S. W. Baik, “Efficient Deep CNN-Based Fire Detection and Localization in Video Surveillance Applications,” *IEEE Trans. Syst. Man, Cybern. Syst.*, vol. 49, no. 7, pp. 1419–1434, 2019, doi: 10.1109/TSMC.2018.2830099.
 - [21] J. Liu, C. Gao, D. Meng, and X. Dong, “Decidenet: Counting varying density crowds through attention-guided detection,” in *CVPR*, 2018.
 - [22] W. Liu, M. Salzmann, and P. Fua, “Context-aware crowd counting,” in *CVPR*, 2019.
 - [23] M. T. Basu, R. Karthik, J. Mahitha, and V. L. Reddy, “IoT based forest fire detection system,” *Int. J. Eng. Technol.*, vol. 7, no. 2.7, p. 124, 2018, doi: 10.14419/ijet.v7i2.7.10277.
 - [24] O. Yaman, H. Yetis, and M. Karakose, “Decision Tree Based Customer Analysis Method for Energy Planning in Smart Cities,” in *2020 International Conference on Data Analytics for Business and Industry (ICDABI)*, 2020, pp. 1–4. doi: 10.1109/ICDABI51230.2020.9325644.
 - [25] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*, 3rd ed. Prentice Hall, 2008.
 - [26] R. Szeliski, *Computer Vision: Algorithms and Applications*, 2nd ed. Springer, 2022. doi: 10.1007/978-3-030-34372-4.
 - [27] J. C. Russ, *The Image Processing Handbook*, 7th ed. CRC Press, 2016.
 - [28] Y. Zhang, “A Survey on Evaluation Methods for Image Segmentation,” *Pattern Recognit.*, vol. 29, no. 8, pp. 1335–1346, 2006, doi: 10.1016/j.patcog.2006.01.005.

- [29] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016. [Online]. Available: <https://www.deeplearningbook.org/>
- [30] V. Chowdary, M. K. Gupta, and R. Singh, “A Review on Forest Fire Detection Techniques: A Decadal Perspective,” *Int. J. Eng. Technol.*, vol. 7, no. 3.12, p. 1312, 2018, doi: 10.14419/ijet.v7i3.12.17876.
- [31] Dutta, S., & Ghosh, S. (2021). *Forest Fire Detection Using Combined Architecture of Separable Convolution and Image Processing*. In *CAIDA 2021*, IEEE. [doi:10.1109/CAIDA51941.2021.9425170]
- [32] Treneska, S., & Stojkoska, B. R. (2021). *Wildfire Detection from UAV Collected Images Using Transfer Learning*
- [33] Guan, Z., Miao, X., Mu, Y., Sun, Q., Ye, Q., & Gao, D. (2022). *Forest Fire Segmentation from Aerial Imagery Data Using an Improved Instance Segmentation Model*. *Remote Sensing*, 14(13), 3159. [doi:10.3390/rs14133159]
- [34] Chandola, V., Banerjee, A., & Kumar, V. (2009). *Anomaly Detection: A Survey*. *ACM Computing Surveys (CSUR)*, 41(3), 1–5
- [35] Sabokrou, M., Fayyaz, M., Fathy, M., Moayed, Z., & Klette, R. (2017). *Deep-Anomaly: Fully Convolutional Neural Network for Fast Anomaly Detection in Crowded Scenes*. *Computer Vision and Image Understanding*, 172, 88–97.
- [36] Xu, D., Ricci, E., Yan, Y., Sebe, N., & Wang, J. (2017). *Detecting Anomalous Events in Videos by Learning Deep Representations of Appearance and Motion*. *Computer Vision and Image Understanding*, 156, 117–127.
- [37] Hasan, M., Choi, J., Neumann, J., Roy-Chowdhury, A. K., & Davis, L. S. (2016). *Learning Temporal Regularity in Video Sequences*. In *CVPR 2016*, 733–742.
- [38] Ionescu, R. T., Smeureanu, A., Alexe, B., & Popescu, M. (2019). *Detecting Abnormal Events in Video Using Narrow Deep Networks*. In *ICCV 2019*, 4510–4519.
- [39] Mehran, R., Oyama, A., & Shah, M. (2009). *Abnormal Crowd Behavior Detection Using Social Force Model*. In *CVPR 2009*, 935–942.
- [40] X. Cao, Z. Wang, Y. Zhao, and F. Su, “Scale Aggregation Network for Accurate and Efficient Crowd Counting,” in *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018, pp. 734–750, doi: 10.1007/978-3-030-01261-0_44.

ÖZGEÇMİŞ

Kudret DİNÇ

[Redacted]

[Redacted]

ARAŞTIRMACI BİLGİLERİ

Öğrenci Orcid ID : 0009-0002-5351-2360
Danışman Orcid ID : 0000-0001-9623-2284

[Redacted]

[Redacted]

ARAŞTIRMA DENEYİMİ

- ✓ Yüksek Lisans Tez Projesi (TÜBİTAK 5220154 destekli) Konu: Güvenlik kameralarında olay tespiti için yapay zeka ve görüntü işleme tabanlı sistem geliştirme
- ✓ Yöntem: HSV renk uzayı, CNN mimarisi, anomali tespiti, kalabalık yoğunluk analizi
- ✓ Python ile görüntü işleme ve derin öğrenme (OpenCV, Keras, TensorFlow)
- ✓ TensorFlow, PyTorch, Scikit-learn.

AKADEMİK FAALİYETLER

Bildiriler:

1. K. Dinc, N. N. Apaydin, O. Yaman, and M. Karakose, "Akıllı şehirlerde yangın algılama için HSV histogram tabanlı yöntem," 45–52, 2025.

Projeler:

1. TÜBİTAK 5220154 Projesi