

T.C.

İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİ (%30 İngilizce)

BİLİM DALI

DERİN ÖĞRENME TABANLI KENTSEL DEĞİŞİM  
TESPİTİ VE İZLEME SİSTEMİ

DOKTORA TEZİ

Sahra TILKI

İstanbul

Ekim - 2025

T.C.

İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİ (%30 İngilizce)

BİLİM DALI

DERİN ÖĞRENME TABANLI KENTSEL DEĞİŞİM TESPİTİ VE  
İZLEME SİSTEMİ

DOKTORA TEZİ

Sahra TİLKİ

Tez Danışmanı

Prof. Dr. Tarık ÖZKUL

İkinci Tez Danışmanı

Dr. Öğr. Üyesi Aydın Tarık ZENGİN

İstanbul

Ekim – 2025

Lisansüstü Eğitim Enstitüsü Müdürlüğüne,

Bu çalışma, jürimiz tarafından Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Bilimleri ve Mühendisliği (%30 İngilizce) Bilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Danışman Prof. Dr. Tarık ÖZKUL

Üye Doç. Dr. Mohammed VADİ

Üye Dr. Öğr. Üyesi Şengül BAYRAK

Üye Doç. Dr. Ülviye HACIZADE

Üye Dr. Öğr. Üyesi Muhammed DAVUD

Onay

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

Prof. Dr. Erhan İÇENER  
Enstitü Müdürü

## BİLİMSEL ETİK BİLDİRİMİ

Doktora tezi olarak hazırladığım “**Derin Öğrenme Tabanlı Kentsel Değişim Tespiti ve İzleme Sistemi**” adlı çalışmanın öneri aşamasından sonuçlandığı aşamaya kadar geçen süreçte bilimsel etiğe ve akademik kurallara özenle uyduğumu, tez içindeki tüm bilgileri bilimsel ahlak ve gelenek çerçevesinde elde ettiğimi, tez yazım kurallarına uygun olarak hazırladığımı, bu çalışmamda doğrudan veya dolaylı olarak yaptığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu beyan ederim.

Sahra TILKI

## ÖN SÖZ

Bu tez çalışmasının ortaya konulmasında katkı sunan, bilgi ve yönlendirmeleriyle süreci destekleyen tüm hocalarıma teşekkür ederim. Çalışmada kullanılan görüntü verilerini sağlayarak araştırmanın yürütülmesine olanak tanıyan Anka Coğrafi Bilgi Teknolojileri firmasına desteklerinden dolayı ayrıca teşekkür ederim.

Eğitim hayatım boyunca yanımda olan anneme ve babama, bu süreçte gösterdiği anlayış ve desteğiyle katkı sağlayan kıymetli arkadaşım Hasibe Büşra Aytekin'e içten teşekkürlerimi sunarım.

**Sahra TİLKİ**  
**İstanbul - 2025**



## ÖZET

# DERİN ÖĞRENME TABANLI KENTSEL DEĞİŞİM TESPİTİ VE İZLEME SİSTEMİ

**Sahra TİLKİ**

Doktora, Bilgisayar Bilimleri ve Mühendisliği (%30 İngilizce)

Tez Danışmanı: Prof. Dr. Tarık ÖZKUL

İkinci Tez Danışmanı: Dr. Öğr. Üyesi Aydın Tarık ZENGİN

Ekim-2025, 111 +XII Sayfa

Bu tez çalışmasında, farklı yıllarda aynı konumlardan elde edilen sokak görüntüleri üzerinden nesne düzeyinde bir değişim tespiti süreci gerçekleştirilmiştir. Çalışmanın temel hedefi, zaman içinde meydana gelen değişimlerin, farklı segmentasyon yaklaşımları kullanılarak herhangi bir eğitim sürecine gerek duyulmadan, analiz edilmesidir. Bu kapsamda, panoramik görüntülerde karşılaşılan geometrik bozulma, sahne karmaşası ve küçük nesne tespiti gibi sorunları azaltmak için eşkenar dörtgen projeksiyon yöntemiyle sokak görünümüne dönüştürülmüştür. Dönüştürülen sokak görüntülerine Segment Anything Model 2 (SAM 2) ve Panoptik segmentasyon yöntemleri uygulanmış; biri sıfır atış temelli, diğeri etiketli veriye dayanan iki farklı segmentasyon yaklaşımının karşılaştırılmıştır. Her iki modelden de elde edilen çıktılarla bina, ağaç ve trafik işareti gibi nesnelere ait segmentasyon maskeleri üretilmiştir. Aynı konumlardan elde edilen farklı yıllara ait görüntülerin segmentasyon sonuçları karşılaştırılarak, zaman içindeki değişimler nesne bazında analiz edilmiştir. Değişim yoğunluğu haritaları ve sınıflar arası değişim matrisleri gibi çeşitli metriklerle görsel ve sayısal değerlendirmeler yapılmıştır.

Elde edilen sonuçlar, sokak düzeyi görüntülerin bu alandaki analizlerde kullanılabilirliğine ve etiketli veri gerektirmeyen yaklaşımların uygulanabilirliğine dikkat çekmektedir. Tez kapsamında izlenen yöntem, hem veri ön işleme hem de değişim analizi süreçlerini birleştiren bütüncül bir yapı sunmaktadır.

**Anahtar Kelimeler:** Sokak Görünümü Görüntüleri, Panoramik Görüntü Dönüşümü, Değişim Tespiti, SAM 2, Panoptik Segmentasyon, Sıfır Atış Segmentasyon.

## ABSTRACT

# DEEP LEARNING BASED URBAN CHANGE DETECTION AND MONITORING SYSTEM

**Sahra TILKI**

Ph. D. Computer Science and Engineering (%30 English)

Supervisor: Prof. Dr. Tarık ÖZKUL

Cosupervisor: Asst. Prof. Dr. Aydın Tarık ZENGİN

October-2025, 111 + XII Pages

In this thesis, an object-level change detection process based on street-view images captured from the same locations at different years. The main objective of the study is to analyze temporal and physical changes using different segmentation approaches without requiring a training process. To overcome geometric distortion, scene complexity, and small-object detection challenges in panoramic images, the data were transformed into street-view format using the rhombic projection method.

The transformed images were processed with Segment Anything Model 2 (SAM 2) and Panoptic Segmentation, representing two distinct paradigms: SAM 2 as a zero-shot, label-free approach and Panoptic Segmentation as a labeled-data method. Segmentation masks were generated for objects such as buildings, trees, and traffic signs, and temporal changes between years were analyzed based on these results. Change density maps and class transition matrices were also produced to support visual and quantitative evaluations.

The findings show that street-view imagery can be effectively used for urban change detection, with label-free segmentation providing reliable and adaptable outcomes. The proposed framework integrates preprocessing, segmentation, and change analysis into a single pipeline, demonstrating the potential of modern segmentation models for urban monitoring and automated visual analysis.

**Keywords:** Street-View Images, Panoramic Image Transformation, Change Detection, SAM 2, Panoptic Segmentation, Zero-Shot Segmentation.

# İÇİNDEKİLER

TEZ ONAY SAYFASI.....	i
BİLİMSEL ETİK BİLDİRİMİ .....	ii
ÖN SÖZ.....	iii
ÖZET.....	iv
ABSTRACT .....	v
İÇİNDEKİLER .....	vi
TABLolar LİSTESİ.....	viii
KISALTMALAR.....	xii

<b>BİRİNCİ BÖLÜM.....</b>	<b>1</b>
<b>GİRİŞ .....</b>	<b>1</b>
1.1. Amaç .....	3
1.2. Kapsam.....	4
1.3. Katkılar.....	5
<b>İKİNCİ BÖLÜM .....</b>	<b>7</b>
<b>LİTERATÜRDEKİ ÇALIŞMALAR.....</b>	<b>7</b>

<b>ÜÇÜNCÜ BÖLÜM .....</b>	<b>14</b>
<b>PANORAMİK ve SOKAK GÖRÜNÜMÜ GÖRÜNTÜLERİ.....</b>	<b>14</b>
3.1. Panoramik Görüntülerin Elde Edilmesi .....	14
3.2. Sokak Görünümü Görüntüleri.....	17
3.2.1. SVI Analiz Yöntemleri .....	19
3.2.2. Panoramik Görüntülerden Sokak Görünümü Görüntüleri Oluşturulması	20

<b>DÖRDÜNCÜ BÖLÜM .....</b>	<b>26</b>
<b>DEĞİŞİM TESPİTİ .....</b>	<b>26</b>
4.1. Değişim Tespitinde Kullanan Görüntü Türleri.....	26
4.1.1. Optik Uzaktan Algılama Görüntüleri.....	27
4.1.2. Sentetik Açıklıklı Radar (SAR) Görüntüleri.....	28
4.1.3. Sokak Görünümü Görüntüleri .....	29
4.1.4. Panoramik Görüntüler.....	29

<b>BEŞİNCİ BÖLÜM</b> .....	<b>31</b>
<b>SEGMENTASYON VE DEĞİŞİM TESPİTİ YÖNTEMLERİ</b> .....	<b>31</b>
5.1. Semantik Segmentasyon .....	32
5.2. Örnek Segmentasyon .....	33
5.3. Panoptik Segmentasyon .....	34
5.4. Sıfır Atış Segmentasyon .....	38
5.4.1. Segment Anything Model (SAM) .....	40
5.4.2. Segment Anything Model 2 (SAM 2) .....	41
5.5. Değişim Tespiti Yöntemleri .....	42
5.5.1. Geleneksel Değişim Tespiti Yöntemleri .....	43
5.5.2. Yapay Zeka Tabanlı Değişim Tespiti Yöntemleri .....	44
<b>ALTINCI BÖLÜM</b> .....	<b>47</b>
<b>DENEYSEL ÇALIŞMA</b> .....	<b>47</b>
6.1 Veri seti ve Ön İşlem .....	47
6.2. Değişim Tespiti Yöntemi .....	54
6.2.1. Segmentasyon İşlemleri .....	55
6.2.2. Değişim Tespiti ve Senaryoların Değerlendirilmesi .....	62
<b>SONUÇ</b> .....	<b>92</b>
<b>KAYNAKÇA</b> .....	<b>96</b>
<b>ÖZGEÇMİŞ</b> .....	<b>108</b>
<b>ETİK ONAY BELGESİ</b> .....	<b>110</b>

## TABLULAR LİSTESİ

Tablo 6.1: Farklı modellerin panoramik ve sokak görüntülerinde gerçekleştirilen segmentasyon işlemlerine ait süre, segment sayısı ve performans ölçütleri.....	61
Tablo 6.2: Senaryo 1 için SAM 2 ve Panoptik segmentasyon sonuçlarına ait segment sayısı, piksel alanı ve süre değerleri.....	67
Tablo 6.3: Senaryo-1 için SAM 2 segmentasyon çıktılarından elde edilen sınıf bazlı yüzdelik alan değişimleri. ....	72
Tablo 6.4: Senaryo-1 için Panoptik segmentasyon çıktılarından elde edilen sınıf bazlı yüzdelik alan değişimleri. ....	73
Tablo 6.5: Senaryo-1 için SAM 2 segmentasyon çıktılarından hesaplanan zamansal ve konumsal örtüşme oranları. ....	73
Tablo 6.6: Senaryo-1 için Panoptik segmentasyon çıktılarından hesaplanan zamansal ve konumsal örtüşme oranları. ....	74
Tablo 6.7: Senaryo 2 için SAM 2 ve Panoptik segmentasyon sonuçlarına ait segment sayısı, piksel alanı ve süre değerleri.....	76
Tablo 6.8: Senaryo-2 için SAM 2 segmentasyon çıktılarından elde edilen sınıf bazlı yüzdelik alan değişimleri. ....	80
Tablo 6.9: Senaryo-2 için Panoptik segmentasyon çıktılarından elde edilen sınıf bazlı yüzdelik alan değişimleri. ....	80
Tablo 6.10: Senaryo-2 için SAM 2 segmentasyon çıktılarından hesaplanan zamansal ve konumsal örtüşme oranları. ....	80
Tablo 6.11: Senaryo-2 için Panoptik segmentasyon çıktılarından hesaplanan zamansal ve konumsal örtüşme oranları. ....	81
Tablo 6.12: Senaryo-3 için SAM 2 ve Panoptik segmentasyon sonuçlarına ait segment sayısı, piksel alanı ve süre değerleri. ....	83
Tablo 6.13: Senaryo-3 için SAM 2 segmentasyon çıktılarından elde edilen sınıf bazlı yüzdelik alan değişimleri. ....	88
Tablo 6.14: Senaryo-3 için Panoptik segmentasyon çıktılarından elde edilen sınıf bazlı yüzdelik alan değişimleri.....	88
Tablo 6.15: Senaryo-3 için SAM 2 segmentasyon çıktılarından hesaplanan zamansal ve konumsal örtüşme oranları. ....	89
Tablo 6.16: Senaryo-3 için Panoptik segmentasyon çıktılarından hesaplanan zamansal ve konumsal örtüşme oranları. ....	89

## ŞEKİLLER LİSTESİ

Şekil 3.1: Panoramik görüntüdeki herhangi bir $P$ noktasının, düzleştirilmiş panoramik görüntüdeki karşılık geldiği $P$ noktanın gösterimi.....	22
Şekil 4.1: Farklı kaynaklardan elde edilen görüntü türlerine ait örnekler: (a) optik uydu görüntüsü, (b) SAR görüntüsü, (c) sayısal yükseklik modeli (d) vektör tabanlı coğrafi veri, (e) LiDAR nokta bulutu verisi ve (f) sokak görünümü görüntüsü.....	30
Şekil 5.1: Temsili görüntü örnekleri: (a) Orijinal görüntü, (b) sınıflandırma, (c) sınıfkandırma ve konumlandırma, (d) nesne tabanlı segmentasyon .....	32
Şekil 5.2: Panoptik FPN ağının temel mimarisi.....	35
Şekil 5.3: Aynı sahneye ait farklı segmentasyon türlerinin çıktıları: (a) girdi görüntüsü; (b) semantik segmentasyon; (c) örnek segmentasyon; (d) panoptik segmentasyon ..	37
Şekil 5.4: SAM veri seti örnek görüntüleri .....	41
Şekil 5.5: SAM 2 veri seti örnek görüntüleri .....	42
Şekil 6.1: Veri setindeki panoramik görüntü çifti örnek-1: (a) 2020 yılına ait örnek (b) 2023 yılına ait örnek.....	48
Şekil 6.2: Veri setindeki panoramik görüntü çifti örnek-2: (a) 2020 yılına ait örnek (b) 2023 yılına ait örnek.....	49
Şekil 6.3: Perspektif projeksiyon modeli çıktıları:(a) panoramik görüntü, (b) ön sokak görüntüsü, (c) arka sokak görüntüsü, (d) sağ sokak görüntüsü, (e) sol sokak görüntüsü.....	52
Şekil 6.4: Eşkenar dörtgen projeksiyon modeli çıktıları: (a) panoramik görüntü, (b) ön sokak görüntüsü, (c) arka sokak görüntüsü, (d) sağ sokak görüntüsü, (e) sol sokak görüntüsü.....	53
Şekil 6.5: SAM 2 segmentasyon sürecine ait görsel adımları: (a) girdi görüntüsü, (b) otomatik segmentasyon sonucu, (c) kullanıcı tarafından yapılan yönlendirme, (d) yönlendirme sonucu ssegmentasyon, (e) sınıflara özel oluşturulan segmentasyon, (f) nihai segmentasyon çıktısı.....	58
Şekil 6.6: Panoramik ve sokak görüntülerinde Panoptik, SAM ve SAM 2 modellerinin segmentasyon sonuçlarının görsel karşılaştırması.....	60
Şekil 6.7: Tez kapsamında önerilen değişim tespiti yönteminin aşamaları.....	66
Şekil 6.8: Senaryo-1 için segmentasyon sonuçları: (a) 2020 yılı sokak görüntüsü, (b) 2023 yılı sokak görüntüsü, (c) 2020 yılı SAM 2 segmentasyon sonucu, (d) 2023 yılı SAM 2 segmentasyon sonucu, (e) 2020 yılı Panoptik segmentasyon sonucu, (f) 2023	

yılı Panoptik segmentasyon sonucu. her sınıfa farklı renk ataması segmentasyon sonucu.....	67
Şekil 6.9: Senaryo-1 için segmentasyon maske çıktıları: (a) 2020 yılı SAM 2 segmentasyon maskesi, (b) 2023 yılı SAM 2 segmentasyon maskesi, (c) SAM 2 modeli değişim haritası, (d) 2020 yılı Panoptik segmentasyon maskesi, (e) 2023 yılı Panoptik segmentasyon maskesi, (f) Panoptik model değişim haritası.....	69
Şekil 6.10: Senaryo-1 için yıllara göre sınıf bazlı alan oranları: (a): SAM 2 modeline ait sınıf bazlı alan oranları, (b): Panoptik segmentasyon modeline ait sınıf bazlı alan oranları.....	69
Şekil 6.11: Senaryo-1 için SAM-2 segmentasyon modelinin sınıflar arası piksel geçiş matrisi.....	70
Şekil 6.12: Senaryo-1 için Panoptik segmentasyon modelinin sınıflar arası piksel geçiş matrisi.....	71
Şekil 6.13: Senaryo-2 segmentasyon sonuçları: (a) 2020 yılı sokak görüntüsü, (b) 2023 yılı sokak görüntüsü, (c) 2020 yılı SAM 2 segmentasyon sonucu, (d) 2023 yılı SAM 2 segmentasyon sonucu, (e) 2020 yılı Panoptik segmentasyon sonucu, (f) 2023 Panoptik segmentasyon sonucu.....	75
Şekil 6.14: Senaryo- 2 için segmentasyon maske çıktıları: (a) 2020 yılı SAM 2 segmentasyon maskesi, (b) 2023 yılı SAM 2 segmentasyon maskesi, (c) SAM 2 modeli değişim haritası, (d) 2020 yılı Panoptik segmentasyon maskesi, (e) 2023 yılı Panoptik segmentasyon maskesi, (f) Panoptik model değişim haritası.....	77
Şekil 6.15: Senaryo-2 için yıllara göresınıf bazlı alan oranları: (a) SAM 2 modeline ait sınıf bazlı alan oranları, (b) Panoptik segmentasyon modeline ait sınıf bazlı alan oranları.....	77
Şekil 6.16: Senaryo-2 için SAM 2 segmentasyon modelinin sınıflar arası piksel geçiş matrisi.....	78
Şekil 6.17: Senaryo-2 için Panoptik segmentasyon modelinin sınıflar arası piksel geçiş matrisi.....	79
Şekil 6.18: Senaryo-3 segmentasyon sonuçları: (a) 2020 yılı sokak görüntüsü, (b) 2023 yılı sokak görüntüsü, (c) 2020 yılı SAM 2 segmentasyon sonucu, (d) 2023 yılı SAM 2 segmentasyon sonucu, (e) 2020 yılı Panoptik segmentasyon sonucu, (f) 2023 yılı Panoptik segmentasyon sonucu.....	82
Şekil 6.19: Senaryo- 3 için segmentasyon maske çıktıları: (a) 2020 yılı SAM 2 segmentasyon maskesi, (b) 2023 yılı SAM 2 segmentasyon maskesi, (c) SAM 2 modeli	

değişim haritası, (d) 2020 yılı Panoptik segmentasyon maskesi, (e) 2023 yılı Panoptik segmentasyon maskesi, (f) Panoptik model değişim haritası.....	84
Şekil 6.20: Senaryo-3 için yıllara göre sınıf bazlı alan oranları: (a):SAM 2 modeline ait sınıf bazlı alan oranları, (b): Panoptik segmentasyon modeline ait sınıf bazlı alan oranları.....	85
Şekil 6.21: Senaryo-3 için SAM 2 segmentasyon modelinin sınıflar arası piksel geçiş matrisi.....	86
Şekil 6.22: Senaryo-3 için Panoptik segmentasyon modelinin sınıflar arası piksel geçiş matrisi.....	87



## KISALTMALAR

- BIT:** Bitemporal Image Transformer (Çift Zamanlı Görüntü Dönüştürücü)
- CNN:** Convolutional Neural Networks (Konvolüsyonel Sinir Ağları)
- DCNN:** Deep Convolutional Neural Network (Derin Konvolüsyonel Sinir Ağı)
- FCN:** Fully Convolutional Networks (Tam Konvolüsyonel Ağ)
- FOV:** Field of View (Görüş Alanı)
- GAN:** Generative Adversarial Network (Üretici Çekişmeli Ağ)
- GIST:** Global Image Descriptor (Genelleştirilmiş Arama Ağaçları)
- HOG:** Histogram of Oriented Gradients (Yönlendirilmiş Gradyan Histogramı)
- IoU:** Intersection over Union (Birlik Üzerinden Kesişim)
- LWIR:** Long-Wave Infrared (Uzun dalga boylu kızılötesi)
- Panoptic FPN:** Panoptic Feature Pyramid Network (Panoptik Özellik Piramidi Ağı)
- PQ:** Panoptic Quality (Panoptik Kalite)
- RNN:** Recurrent Neural Network (Yinelemeli Sinir Ağı)
- RS:** Remote Sensing (Uzaktan Algılama)
- SAM 2:** Segment Anything Model 2
- SAM:** Segment Anything Model
- SAR:** Synthetic Aperture Radar (Sentetik Açıklıklı Radar)
- SCDM:** Segment Anything Model UNet Change Detection Model
- SIFT:** Scale Invariant Feature Transform (Ölçekten Bağımsız Öznitelik Dönüşümü)
- SQ:** Segmentation Quality (Segmentasyon Kalitesi)
- SURF:** Speeded-Up Robust Features (Hızlandırılmış Dayanıklı Öznitelikler)
- SVI:** Street View Imagery (Sokak Görünümü Görüntüsü)
- ViT:** Vision Transformer (Görüntü Kodlayıcısı)

# BİRİNCİ BÖLÜM

## GİRİŞ

Günümüzde insan faaliyetleri, doğal afetler ve uzun vadeli iklimsel ya da çevresel değişimler, dünya yüzeyinde sürekli dönüşümlere yol açmaktadır. Bu değişimlerin izlenmesi ve analiz edilmesi, uzaktan algılama alanının temel araştırma konularından biri haline gelmiştir. Zaman içinde meydana gelen çevresel ve yapısal değişimlerin doğru şekilde tespiti, birçok sektörde karar verme süreçlerini doğrudan etkilemektedir.

Uzaktan algılama teknolojileriyle yapılan değişim analizleri sayesinde, belirli bir bölgedeki gelişim eğilimleri hem geçmişe dönük olarak değerlendirilebilmekte hem de geleceğe yönelik öngörüler üretilebilmektedir. Bu da söz konusu teknolojiyi sadece bir izleme aracı değil, aynı zamanda stratejik planlama süreçlerinin vazgeçilmez bir parçası hâline getirmektedir. Özellikle şehir planlama alanında, yerleşim alanlarının genişleme eğilimleri, yapı yoğunluğundaki değişiklikler ya da altyapı projelerinin etkileri uzaktan algılama yöntemleriyle sistematik bir biçimde analiz edilebilmektedir. Aynı şekilde, çevresel izleme çalışmaları kapsamında; orman kaybı, su kaynaklarındaki azalma, tarımsal alanların kullanımı gibi konular düzenli aralıklarla değerlendirilerek sürdürülebilirlik politikalarının geliştirilmesine katkı sağlanmaktadır.

Tarım araştırmalarında, ekim alanlarındaki değişim, ürün verimliliği ve sulama düzeni gibi faktörler, farklı zamanlarda elde edilen görüntüler üzerinden takip edilerek üretim planlamasında önemli veriler sunmaktadır. Afet sonrası durum değerlendirmesi de değişim tespitinin kritik bir kullanım alanıdır; deprem, sel ya da yangın gibi afetlerin ardından oluşan hasarın boyutu, uzaktan algılama yoluyla hızlıca analiz edilerek müdahale süreçleri daha etkili bir şekilde yürütülebilir. Ayrıca, harita güncellemeleri ve coğrafi bilgi sistemlerinin (GIS) doğrulukla çalışabilmesi için değişen fiziksel yapının doğru şekilde modellenmesi gereklidir. Bu nedenle, değişim tespiti sadece bilimsel bir ilgi alanı değil, aynı zamanda sosyal, ekonomik ve çevresel politikaları yönlendiren güçlü bir araç konumundadır (Shi vd., 2020).

Değişim tespiti yöntemleri, genellikle aynı bölgeye ait farklı zamanlarda elde edilen görüntülerin karşılaştırılması yoluyla gerçekleştirilir. Bu karşılaştırmalar sayesinde nesnelerin şekil, konum ve boyut gibi mekânsal özelliklerindeki farklılıklar

belirlenebilir. İki görüntü arasındaki deęişimi ortaya koyan yaklaşımlar; belirli bir anda meydana gelen deęişikliklerin saptanması, uzun zaman aralıklarında meydana gelen eğilimlerin izlenmesi veya bir görüntü serisi üzerinden zaman içinde gerçekleşen dönüşümlerin takibi şeklinde sınıflandırılabilir. Örneğin bir orman yangını sonrası, etkilenen alanın sınırlarının belirlenmesi ya da yapı yoğunluğunun zamanla nasıl deęiştiğinin analiz edilmesi bu yöntemlerle mümkündür. Aynı şekilde, geçmişte sanayi tesisi olarak kullanılan bir alanın sonradan alışveriş merkezi haline gelmesi ya da konutların ticari kullanıma dönüştürülmesi gibi dönüşümler de bu tekniklerle izlenebilir.

Deęişim tespiti yaklaşımları genel olarak geleneksel ve öğrenmeye dayalı yöntemler olmak üzere iki ana grupta ele alınmaktadır. Geleneksel yöntemlerde genellikle görüntülerdeki arka plan davranışı modellenir ve belirli görüntü işleme teknikleriyle ön plandaki deęişim bölgeleri tespit edilir (Mandal, Vipparthi, 2021). Buna karşılık, öğrenmeye dayalı yaklaşımlar daha karmaşık yapılar içerir ve özellikle derin öğrenme tabanlı yöntemler sayesinde daha yüksek doğrulukta sonuçlar elde edilebilmektedir.

Son yıllarda, uydular ve insansız hava araçları (dronlar) aracılığıyla elde edilen verilerin miktarı ve kalitesi önemli ölçüde artmıştır. Bu gelişmeyle birlikte yüksek spektral ve zamansal çözünürlüğe sahip çok sayıda görüntüye erişmek mümkün hale gelmiş; optik uydu görüntüleri, radar (SAR) verileri ve hava fotoğrafları yaygın olarak kullanılmaya başlanmıştır (Shi vd., 2020). Ancak tüm bu veri türlerine rağmen, kentsel düzeyde anlık ve ayrıntılı bilgi sağlayabilecek yeni görüntü kaynaklarına duyulan ihtiyaç giderek artmaktadır. Bu noktada, sokak görünümü görüntüleri öne çıkmakta ve şehir düzeyinde gerçek zamanlı, ayrıntılı analizler yapılmasına olanak tanımaktadır. İnsan-çevre ilişkilerinin incelenmesi, yapı türlerinin sınıflandırılması, taşıt yoğunluğunun değerlendirilmesi ve trafik güvenliği gibi alanlarda önemli katkılar sunmaktadır.

Sokak düzeyinde anlık ve ayrıntılı veri sağlayabilme ihtiyacı, klasik uydu ve hava görüntülerinin ötesine geçilmesini gerektirmiştir. Bu doğrultuda, panoramik ve sokak görüntüsü tabanlı yeni veri türleri ön plana çıkmıştır. Panoramik görüntüler, genellikle 360 derecelik görüş açısına sahip sahneleri kapsar ve çevresel detayların tam olarak yakalanmasını sağlar. Google Street View, Bing Street Side ve Apple Look Around gibi platformlardan elde edilen bu görüntüler; bina cepheleri, trafik levhaları, kaldırım öğeleri ve yeşil alanlar gibi kentsel bileşenleri detaylı bir şekilde gözlemlenebilir.

sunmaktadır. Sokak görüntüleri ise sabit açılı (non-panoramik) çekimlerle genellikle bir yönde alınan, daha az bozulmaya sahip ve belirli alanlara odaklanan görsellerdir. Her iki görüntü türü de, geleneksel hava ve uydu görüntülerinin sağlayamadığı düzeyde mikro ölçekte analiz yapılmasına olanak tanır. Bu nedenle, kent planlaması, ulaşım yönetimi ve kentsel dönüşüm analizleri gibi konularda giderek daha fazla kullanılmaktadır.

Ancak özellikle panoramik görüntüler, işleme aşamasında çeşitli teknik zorlukları beraberinde getirmektedir. Özellikle panoramik yapının neden olduğu geometrik bozulmalar, görüntüdeki nesnelere biçimsel yapısını etkileyerek analiz doğruluğunu düşürebilmektedir. Ayrıca bu görüntülerin yüksek çözünürlükte olması, bellek kullanımı ve işlem süresi açısından ek yük oluşturmaktadır. Görüntüde yer alan küçük ve seyrek nesnelere sınırlı oranda temsil edilmesi ise nesne tespiti gibi görevlerde model performansını zorlaştıran bir başka faktördür. Bununla birlikte, panoramik görüntüler için yeterli ölçekte etiketlenmiş veri kümelerinin bulunmaması, bu alanda derin öğrenme tabanlı yaklaşımların uygulanmasını kısıtlamaktadır. Literatürde bu zorluklara yönelik çeşitli çözüm stratejileri önerilmekte olup, genel olarak bozulma etkilerini azaltma, görüntüleri bölerek işleme ve sınırlı veriyle öğrenmeyi mümkün kılma yönünde yöntemler geliştirilmektedir (Yang vd., 2022). Ayrıca, son yıllarda yapılan kapsamlı çalışmalar panoramik ve çevresel görüntülerle çalışan derin öğrenme yöntemlerinin karşılaştığı temel zorluklara ve bu zorluklara yönelik geliştirilen yaklaşımlara genel bir bakış sunmaktadır (Ren vd., 2022).

Tüm bu zorluklara rağmen, panoramik sokak görüntülerinin sunduğu ayrıntı düzeyi ve güncellik, onları kent ölçeğinde değişim tespiti için oldukça değerli bir kaynak haline getirmektedir. Bu tez çalışmasında, söz konusu zorlukların üstesinden gelebilecek derin öğrenme tabanlı segmentasyon ve karşılaştırma yaklaşımları geliştirilerek, bina, yeşil alan ve trafik işaretleri gibi temel kentsel unsurların zaman içindeki değişimlerinin tespit edilmesi amaçlanmaktadır. Böylece hem kentlerin dönüşüm süreci izlenebilecek hem de akıllı ulaşım sistemleri ve planlama mekanizmalarına katkı sağlanabilecektir.

### 1.1. Amaç

Bu tez çalışmasının temel amacı, farklı yıllarda elde edilen sokak görüntüleri üzerinden nesne düzeyinde bir değişim tespiti yöntemi geliştirilerek, şehirdeki fiziksel değişimlerin ortaya konulmasını sağlamaktır. Çalışma, öncelikle panoramik sokak

görüntülerinde yaygın olarak karşılaşılan geometrik bozulmalar, küçük nesnelerin seçilememesi ve karmaşık sahne yapısı gibi sorunlara odaklanmaktadır. Bu sorunları azaltmak amacıyla panoramik görüntüler, eşkenar dörtgen projeksiyon yöntemiyle daha sade ve nesnelere daha net gösteren sokak görüntülerine dönüştürülmüştür.

İkinci aşamada, bu sokak görüntüleri üzerinde SAM 2 ve Panoptik segmentasyon modelleri kullanılmıştır. SAM 2 modeli, sıfır atış (zero-shot) temelli yapısı sayesinde herhangi bir eğitim sürecine gerek duymadan bina, ağaç ve trafik işareti gibi nesnelere otomatik olarak tespit etmiş; Panoptik segmentasyon modeli ise önceden etiketlenmiş verilere dayalı olarak aynı nesnelere sınıflandırmıştır. Böylece, her iki modelin farklı öğrenme yaklaşımlarına dayanan segmentasyon performansları karşılaştırmalı olarak değerlendirilmiştir. Son olarak, aynı konumlardan elde edilen farklı yıllara ait segmentasyon sonuçları karşılaştırılarak, nesnelere varlığı, konumu veya şekli üzerindeki değişimler analiz edilmiştir.

Bu sayede şehirdeki fiziksel değişimler, belirli nesnelere üzerinden daha sistematik bir biçimde değerlendirilebilmiş ve görüntü tabanlı değişim analizine katkı sağlayacak bir uygulama gerçekleştirilmiştir. Segmentasyon temelli bu yaklaşım, şehir planlama, çevresel izleme ve görsel veri analizi gibi alanlarda kullanılabilecek bir temel sunmaktadır.

## **1.2. Kapsam**

Bu tez çalışması, panoramik sokak görüntülerinde meydana gelen değişimlerin nesne düzeyinde analiz edilmesine odaklanmaktadır. Çalışma kapsamında ilk olarak, farklı yıllarda aynı konumdan elde edilmiş panoramik görüntüler, segmentasyon verimliliğini artırmak amacıyla sokak görünümüne dönüştürülmüştür. Bu dönüşüm, eşkenar dörtgen projeksiyon modeli kullanılarak gerçekleştirilmiş ve böylece daha sade, net ve analiz edilebilir sahneler elde edilmiştir.

Dönüştürülen bu sokak görüntüleri üzerinde, SAM 2 ve Panoptik segmentasyon modelleri kullanılarak bina, ağaç ve trafik işareti gibi kentsel nesnelere maskeleri üretilmiştir. Ardından, aynı konumlara ait farklı yılların segmentasyon çıktıları karşılaştırılarak bu nesnelere görünürlüğü, konumu ve biçimi üzerindeki değişiklikler analiz edilmiştir. Bu süreçte değişim yoğunluk haritası, sınıflar arası değişim matrisi gibi çeşitli metriklerle görsel karşılaştırmalar yapılmıştır.

Tez çalışması yalnızca bina, yeşil alan, trafik işaretleri ve tabela gibi dört temel kategoriye odaklanmaktadır. Bu kategoriler, görsel sahnelerde zamanla en belirgin değişimlerin gözlemlendiği nesne türleri arasından seçilmiştir. Amaç, tüm sahnedeki değişimlerden ziyade, hangi nesne türlerinde anlamlı farklılıklar oluştuğunu gözlemleyebilmek ve bu değişimlerin hangi nesnelere arasında gerçekleştiğini daha ayrıntılı biçimde analiz edebilmektir. Bu odak sayesinde değişimin içeriği, yönü ve yoğunluğu daha açık şekilde değerlendirilebilmekte; şehirsiz mekânlardaki yapısal dönüşümlerin nesne temelli bir çerçevede incelenmesi mümkün hale gelmektedir.

Yukarıda ele alınanlara dayanarak, bu tez toplam yedi bölümden oluşmaktadır. İkinci bölümde, panoramik ve sokak düzeyi görüntüler üzerinde gerçekleştirilen segmentasyon ve değişim tespiti konularıyla ilgili literatürde yer alan çalışmalar incelenmiştir. Üçüncü bölümde, panoramik görüntülerin ve sokak görünümünün temel özellikleri, sağladıkları avantajlar ve bu görüntülerin nasıl elde edildiğine dair teorik bilgiler sunulmuştur. Dördüncü bölümde, değişim tespiti kavramı ele alınmış; bu süreçte kullanılan görüntü türleri ve genel yaklaşımlar açıklanmıştır. Beşinci bölümde, segmentasyon ve değişim tespiti yöntemleri detaylandırılmış; bu çalışmada kullanılan model ve tekniklere yer verilmiştir. Altıncı bölümde, yapılan deneysel çalışmalar aktarılmış; kullanılan veri seti, uygulanan ön işlem adımları, segmentasyon süreci ve değişim analizleri açıklanmıştır. Son olarak, yedinci bölümde çalışmanın genel bir değerlendirmesi yapılmış ve ulaşılan sonuçlar açıklanmıştır.

### **1.3. Katkılar**

Bu tez çalışması, değişim tespiti alanında kullanılan yöntem ve veri kaynaklarına yönelik bazı kısıtların aşılmasına katkı sağlamayı amaçlamaktadır. Alandaki birçok çalışmada değişim analizi genellikle uydu görüntüleri, hava fotoğrafları veya dron gibi üstten görüntüleme teknikleri kullanılarak gerçekleştirilmekte ve bu durum, yer düzeyindeki detayların izlenmesini kimi zaman sınırlayabilmektedir. Bu bağlamda, sokak görüntülerinin kullanılması, farklı bakış açıları ve nesne odaklı gözlem yapabilme imkânı sunarak mevcut yaklaşımlara alternatif bir perspektif kazandırmaktadır.

Diğer yandan, panoramik sokak görüntüleri geniş görüş açısı sunmaları açısından avantajlı olmakla birlikte; geometrik bozulmalar, küçük nesne tespiti ve karmaşık sahne yapısı gibi bazı zorluklar da barındırmaktadır. Bu çalışmada, panoramik görüntülerdeki bu sınırlamaları azaltmak amacıyla, eşkenar dörtgen projeksiyon

yöntemi kullanılarak panoramik sahnelerden sokak görünümüne sahip daha sade ve nesne odaklı görüntüler elde edilmiştir. Böylece segmentasyon kalitesi artırılmış ve görüntü analizine daha uygun bir veri formatı oluşturulmuştur.

Çalışmada kullanılan sokak görüntüleri, farklı yıllarda aynı konumlardan elde edildiği için zaman içindeki değişimlerin doğrudan karşılaştırılmasına olanak tanımakta; böylece görsel analiz açısından zengin bir veri kaynağı sunmaktadır. Segmentasyon aşamasında hem SAM 2 hem de Panoptik segmentasyon modelleri kullanılmış; SAM 2 modeli sıfır atış temelli yapısıyla etiketli veri ihtiyacını ortadan kaldırırken, Panoptik segmentasyon modeli etiketli veriye dayalı geleneksel yaklaşımıyla sonuçların karşılaştırılmasına olanak sağlamıştır. Böylece, iki farklı segmentasyon yönteminin güçlü ve zayıf yönleri aynı veri seti üzerinde incelenmiş ve karşılaştırmalı bir değerlendirme yapılmıştır.

Farklı yıllara ait aynı konumlardaki segmentasyon sonuçları karşılaştırılarak yalnızca değişimin miktarı değil, hangi nesne türlerinde ve hangi alanlarda yoğunlaştığı da analiz edilmiştir. Bu yönüyle tez, panoramik görüntülerin sokak görüntüsüne dönüştürülmesinden başlayarak segmentasyon ve değişim analizine uzanan çok aşamalı bir süreci bütüncül biçimde ele almakta; hem etiketli hem de etiketsiz veriye dayalı yaklaşımları aynı çerçevede değerlendirerek literatürde az temsil edilen sokak düzeyi görsel veriler üzerine önemli bir katkı sağlamaktadır.

## İKİNCİ BÖLÜM

### LİTERATÜRDEKİ ÇALIŞMALAR

Görüntü tabanlı değişim tespiti, uzaktan algılama ve bilgisayarla görme alanlarında uzun süredir üzerinde çalışılan önemli bir problemdir. Bu alandaki çalışmalar, kullanılan görüntü türlerine ve analiz tekniklerine bağlı olarak farklı yaklaşımlar geliştirmiştir. Literatürdeki araştırmalar genellikle uydu ve hava görüntüleri ile yapılan değişim tespiti çalışmalarından başlamaktadır; bu çalışmalar büyük alanların gözlemlenmesi ve arazi kullanımındaki değişikliklerin takibi gibi konularda geniş uygulama alanı bulmuştur. Zamanla görüntüleme teknolojilerinin gelişmesiyle, panoramik görüntüler de değişim tespiti süreçlerinde kullanılmaya başlanmıştır. Bu görüntüler geniş görüş açısı sağlamaları sayesinde daha fazla sahne bilgisi sunmakta, ancak beraberinde bazı yapısal zorluklar da getirmektedir. Panoramik görüntülerin ardından, özellikle kentsel alanlarda detaylı analiz ihtiyacının artmasıyla, sokak seviyesinden elde edilen görüntülerle yapılan değişim tespiti çalışmaları ön plana çıkmıştır. Son olarak, etiketli veriye olan ihtiyacı azaltmak amacıyla geliştirilen sıfır atışlı (zero-shot) yöntemlerin bu alana uygulanmasıyla, önceden tanımlanmamış sınıfların da başarıyla analiz edilebildiği yeni yaklaşımlar literatürde yer bulmuştur. Bu bölümde, yukarıda özetlenen görüntü türleri üzerinden yapılan değişim tespiti çalışmalarına yer verilmiş; her bir yaklaşım, kullanılan yöntemler ve karşılaşılan zorluklar açısından değerlendirilmiştir.

Chen vd. (2020) 'in sunduğu çalışmada, yüksek çözünürlüklü uzaktan algılama görüntülerinde değişim tespiti için DASNet adlı yeni bir derin öğrenme modeli geliştirilmiştir. Model, temel olarak iki farklı zaman diliminde çekilmiş görüntülerde meydana gelen değişiklikleri tespit etmeyi amaçlamaktadır. Bunun için Siyam ağı (Siamese network) yapısı kullanılmıştır; bu yapı, aynı mimariyi paylaşan iki alt ağ ile görüntü çiftleri arasında benzerlikleri veya farklılıkları öğrenmeyi sağlar. DASNet'in en önemli katkılarından biri, dikkat mekanizmasını (attention mechanism) hem uzamsal (görüntüdeki yer bilgisi) hem de kanalsal (özellik haritasındaki bilgi yoğunluğu) düzeyde entegre etmesidir. Bu sayede model, değişimin meydana geldiği bölgelere daha fazla odaklanabilir. Ayrıca, değişmeyen bölgelerin sayısal olarak çok fazla olmasından kaynaklanan dengesiz veri dağılımı sorununu azaltmak için özel bir kayıp fonksiyonu tasarlanmıştır.

Zheng vd. (2024)'in yaptığı çalışmada, çok zamanlı uzaktan algılama görüntülerindeki veri eksikliğini gidermek amacıyla "generative change modeling" (üretici değişim modelleme) adını verdikleri yenilikçi bir yaklaşım önerilmiştir. Bu yöntemde, etiketli veya etiketsiz tek zamanlı görüntülerden, zaman içinde meydana gelen değişimleri içeren görüntü dizileri ve bunlara ait semantik değişim etiketleri otomatik olarak üretilmektedir. Bu amaçla geliştirilen Changen2 modeli, kendi kendine denetimli (self-supervised) öğrenme yoluyla eğitilmekte ve herhangi bir etiketli veri gerektirmeden değişim bilgisini çıkarabilmektedir. Changen2 modeli, yalnızca sahte veri üretmekle kalmaz; aynı zamanda bu veriler üzerinden eğitilen görev-öзгü modellerin sıfır atışlı (zero-shot) değişim tespiti yapabilmesini de mümkün kılar. Yapılan deneysel çalışmalar, bu modelin bina değişimi, arazi kullanımı/örtüsü değişimi ve afet hasar analizi gibi farklı senaryolarda yüksek aktarılabilirlik sağladığını göstermektedir.

Ma vd. (2023)' in sunduğu bir diğer derin öğrenme tabanlı değişim tespiti yöntemi, mevcut yöntemlerde sıkça karşılaşılan hedefi yanlış tespit etme, sahte alarm üretme ve bulanık kenar sorunu gibi problemleri azaltmayı hedeflemiştir. Bu amaçla geliştirilen mimari, farklı zamanlara ait görüntü çiftlerini işleyen Siamese tabanlı bir kodlayıcı ağ ile başlamaktadır. Ardından, iki görüntü arasındaki farkı daha etkili şekilde çıkarmak için Fark Özellik Çıkarım Modülü (Difference Feature-Extraction Module, DFEM) kullanılmaktadır. Modelin dikkat çeken diğer bileşenleri arasında, çıkarılan fark özelliklerini dikkat mekanizmasıyla optimize eden Dikkat Düzenleme Modülü (Attention Regulation Module, ARM) ve çoklu ölçekli bilgi entegrasyonunu sağlayan Ölçekler Arası Özellik Birleştirme Modülü (Cross-Scale Feature Fusion Module, CSFM) yer almaktadır. Gerçekleştirilen deneyler, bu modelin hedef sapmaları ve daha net segmentasyon sınırları sunduğunu ortaya koymuştur.

Yüksek çözünürlüklü uzaktan algılama görüntülerinde değişim tespiti, derin öğrenme modelleri sayesinde önemli ilerlemeler kaydetmiştir. Ancak mevcut yöntemler, nesnelerin karmaşıklığı nedeniyle zaman-mekân bağlamını tam olarak yakalayamamakta ve sahte değişimlere yol açabilmektedir. Bu sorunu aşmak üzere Chen, Qi ve Shi (2019) 'in geliştirdiği Bitemporal Image Transformer (BIT) modeli, değişim kavramlarını az sayıda anlamsal gösterim (token) ile ifade ederek Transformer tabanlı yapısıyla zamansal ve mekânsal bağlamı daha etkili şekilde yakalamaktadır. Model, sade bir CNN omurgasıyla bile yüksek doğruluk sağlamış ve LEVIR-CD,

WHU-CD, DSIFN-CD veri kümelerinde dikkat tabanlı birçok güncel yöntemi hem doğruluk hem de verimlilik açısından geride bırakmıştır.

Uydu görüntülerinden bina değişim tespiti amaçlayan Cui vd. (2024)'in yaptığı çalışmada, yeni inşa edilen ya da ortadan kaybolan binaların belirlenmesi sağlanmıştır. Bina boyutlarının ve görünülerinin değişkenliği ile birlikte, arka plan karmaşasından kaynaklanan yalancı değişimlerin varlığı, doğru ve eksiksiz değişim çıkarmayı güçleştirmektedir. Bu zorluklara çözüm olarak, U-Conformer isimli bir yapı önerilmiştir. Bu yapı, konvolüsyonel sinir ağları (CNN) ile görsel dönüştürücüler (Vision Transformer - ViT) mimarilerini birleştiren hibrit bir Siamese ağ modelidir. Modelin temel avantajı, farklı ölçeklerdeki binaları tespit edebilecek güçlü ve heterojen çok ölçekli temsil yeteneği sunmasıdır. Ayrıca modele entegre edilen öğrenilebilir maske yönlendirme modülü, yalancı değişimleri bastırarak yalnızca ilgili ölçeklerdeki değişikliklere odaklanmayı sağlamıştır.

Uydu ve hava görüntülerine dayalı değişim tespiti çalışmaları literatürde önemli bir yer tutsa da, son yıllarda çevresel detayların daha yakından ve gerçekçi biçimde analiz edilmesi ihtiyacı, panoramik görüntülere olan ilgiyi artırmıştır. Bu doğrultuda, panoramik görüntüler kullanılarak gerçekleştirilen değişim tespiti çalışmaları da giderek yaygınlaşmakta ve özellikle sokak düzeyinde daha ayrıntılı değişimlerin belirlenmesine olanak sağlamaktadır.

Sakurada, Shibuya ve Wang (2020)'in yaptıkları çalışmada, zayıf denetimli verilerle çalışan yeni bir semantik sahne değişim tespiti yöntemi sunulmuştur. Çalışmada, bu görev için özel olarak etiketlenmiş büyük ölçekli veri kümeleri oluşturmanın maliyetli ve zaman alıcı olduğunu belirterek, doğrudan uçtan uca bir eğitim yerine, mevcut veri kümelerinin iki aşamalı olarak kullanıldığı bir yapı önerilmiştir. Ayrıca, araç üstü kameralar gibi farklı bakış açılarından alınan görüntüler nedeniyle ortaya çıkan görüş açısı farklarının, değişim tespiti görevinde zorluk yarattığı vurgulanmaktadır. Bu sorunu aşmak için, korelasyon katmanı içeren yeni bir Siyam ağ yapısı geliştirilmiştir. Deneysel sonuçlar, önerilen yaklaşımın hem değişim tespitindeki görüş açısı farklarına karşı dayanıklı olduğunu hem de semantik değişim tespiti açısından etkili performans sunduğunu ortaya koymuştur.

Panoramik görüntülerdeki değişim tespiti görevinde, özellikle farklı zamanlarda ve farklı kamera bakış açılarıyla elde edilen görüntüler arasında doğru eşleşme sağlamak

büyük bir zorluk oluşturmaktadır. Bu problemi ele alan çalışmada, iki zamanlı görüntü çifti arasında yoğun optik akış (dense optical flow) kullanarak sahne değişimlerini tespit etmeye yönelik yeni bir yöntem sunulmuştur. Sabit kameralardan elde edilen görüntülerde pikseller arası eşleşme kolaylıkla modellenebilirken, hareketli araçlara monte edilmiş kameralar söz konusu olduğunda bu eşleşme karmaşıklaşmaktadır. Önerilen yöntem, kamera pozlarındaki farklılıklara karşı dayanıklılığı artırmak amacıyla, giriş görüntüleri arasındaki yoğun optik akış bilgisini kullanan bir CNN modeli geliştirmiştir. Panoramik görüntülerden oluşan bir değişim tespiti veri kümesi üzerinde yapılan deneyler, önerilen yaklaşımın mevcut yöntemlere kıyasla daha yüksek doğruluk sağladığını göstermiştir (Sakurada vd., 2017).

Panoramik görüntüler üzerinde değişim tespiti yapmak, özellikle piksel düzeyinde etiketlenmiş veri gereksinimi nedeniyle zaman alıcı ve maliyetli olabilmektedir. Bu soruna çözüm olarak önerilen çalışmada, yalnızca görüntü düzeyinde etiketlenmiş veriler kullanarak hem değişim tespiti hem de konumlandırma yapabilen zayıf denetimli (weakly supervised) bir yöntem geliştirmiştir. Bu yöntemde, değişim görüntülerini öğrenmek amacıyla yönlendirilmiş derin sinir ağları kullanılmıştır. Piksel düzeyindeki etiket tahmini için kısıtlı ortalama alan (constrained mean-field) çıkarımı uygulanarak, tahmin edilen etiketler ile CNN ağı parametreleri güncellenmiştir. Bu sayede, ön plan değişimlerinin genel dağılımı üzerinde küresel kısıtlamalar uygulanabilmiştir. Yapılan deneysel analizler, önerilen yaklaşımın dört farklı veri kümesi üzerinde hem tespit hem de konumlandırma açısından güçlü temel yöntemleri geride bıraktığını göstermektedir (Khan vd., 2016).

Panoramik görüntülerle gerçekleştirilen değişim tespiti çalışmalarının ardından, son yıllarda giderek artan bir ilgiyle sokak düzeyindeki görüntüler de değişim analizlerinde kullanılmaya başlanmıştır. Özellikle araç kamerası, cep telefonu veya mobil haritalama sistemleri gibi kaynaklardan elde edilen bu görüntüler, çevresel değişikliklerin daha ayrıntılı ve yerel düzeyde incelenmesine olanak tanımaktadır. Sokak görünümü görüntüleri, kentsel dönüşüm, altyapı güncellemeleri, doğal afet sonrası değerlendirmeler gibi birçok uygulama alanında kullanılabilir detay ve perspektife sahiptir. Bu özellikleriyle, değişim tespiti araştırmalarında tamamlayıcı bir veri kaynağı haline gelen sokak görüntüleri, özellikle binalar, yol altyapısı, yeşil alanlar ve trafik işaretleri gibi nesne temelli değişimlerin belirlenmesinde önemli avantajlar sunmaktadır.

Araç üstü tek mercekli kameralarla elde edilen sokak görüntülerinden yapısal değişimleri tespit etmek amacıyla Alcantarilla vd. (2018) 'in yaptığı çalışmada, yeni bir yöntem önerilmiştir. Bu sistem, 3B yeniden yapılandırma adımlarını derin bir dekonvolüsyonel ağla birleştirerek, yaklaşık olarak hizalanmış görüntü çiftlerinden piksel düzeyinde değişim tespiti yapmaktadır. Yöntem, mevsim ve ışık değişikliklerinden etkilenmeyen sağlam sonuçlar sunmuş ve mevcut literatürdeki yöntemlerden daha yüksek doğruluk elde etmiştir. Ayrıca oluşturulan büyük sokak düzeyi değişim veri kümesiyle test edilen yöntem, panorama tabanlı bir veri kümesinde de etkili olmuştur.

Chen, Yang ve Stiefelhagen (2021)' in yapmış olduğu çalışmada, mevcut sinir ağların sınırlılıklarına çözüm olarak, geçici dikkat mekanizması (temporal attention) önerilmiştir. Dikkat kapsamının (dependency-scope) değişim tespit performansına etkisini incelemiş ve daha hafif, verimli bir yapı olan Dinamik Algılama Alanlı Geçici Dikkat Modülü ile yatay ve dikey dikkat yapısını birleştiren bir modül geliştirmiştir. GSV, TSUNAMI ve VL-CMU-CD veri kümeleri üzerinde yapılan deneylerde, önerilen yaklaşım yüksek doğruluk ve verimlilik sağlayarak otonom araçlar gibi gerçek zamanlı sistemlerde uygulanabilirliğini kanıtlamıştır.

Sokak görüntülerinden faydalanarak yol veritabanlarını güncellemek, özellikle trafik işareti gibi coğrafi nesnelere değişimlerini tespit etmede önemli bir uygulama alanıdır. Bu amaçla geliştirilen DuARUS adlı sistem, özellikle coğrafi nesnelere otomatik konumlandırılması ve değişimlerinin algılanmasına odaklanmaktadır. Çalışmada önerilen iki aşamalı konumlandırma yöntemi, görüntü eşleştirme ve tek görüntüden derinlik tahmini yaklaşımlarını entegre ederek daha hassas sonuçlar elde edilmesini sağlar. Ayrıca, sahne anlayışı ve görsel temsile dayalı öğrenme stratejileriyle oluşturulan büyük ölçekli anlamsal harita sayesinde, değişim tespiti bir sınıflandırma problemi olarak yeniden yapılandırılmıştır. Gerçek dünya sokak görüntüleri üzerinde yapılan kapsamlı deneylerle etkinliği kanıtlanan bu sistem, Baidu Maps altyapısında 2020 yılından itibaren üretim ortamında kullanılmakta ve yol veritabanı güncellemelerinin %96'sını otomatik olarak gerçekleştirmektedir. DuARUS sistemi, yıllık güncellenen yol verisini milyonlardan onlarca milyona çıkarmış ve haftalık güncellemeler yapabilir hale gelmiştir (Xia vd., 2022).

Son yıllarda, derin öğrenmenin yön verdiği görüntü işleme alanında etiketli veri ihtiyacını azaltmak amacıyla sıfır atışlı (zero-shot) öğrenme yaklaşımları dikkat

çekmeye başlamıştır. Geleneksel yöntemlerin aksine, sıfır atışlı tabanlı değişim tespiti yöntemleri önceden tanımlı örneklere ihtiyaç duymadan, genel görsel kavramları öğrenerek farklı veri kümelerinde değişimi tespit edebilme potansiyeline sahiptir.

Sıfır örnekli değişim tespiti yaklaşımlarından biri olarak önerilen ViewDelta, geleneksel yöntemlerin sınırlamalarını aşmayı hedefleyen çok modlu bir mimari sunmaktadır. Bu yöntem, birbiriyle hizalanmamış iki görüntü çifti arasında gerçekleşen değişiklikleri, kullanıcı tarafından verilen metin tabanlı yönlendirmeler doğrultusunda tespit etmektedir. Model, görsel ve metinsel gömülü temsilleri birleştirerek, yeniden eğitime ihtiyaç duymadan farklı senaryolarda genel değişiklikleri algılayabilme yeteneğine sahiptir. Gerçekleştirilen deneyler, ViewDelta'nın iç ve dış mekanlar, sokak görüntüleri, uydu verileri ve sentetik görüntüler gibi birçok farklı alanda etkili ve esnek performans sergilediğini ortaya koymuştur. Bu yönüyle çalışma, metin yönlendirmeli değişim tespiti konusunda gelecekte yapılacak araştırmalara önemli bir temel oluşturmaktadır (Varghese, Gao ve Hoskere, 2024).

Son yıllarda Segment Anything Model (SAM), güçlü görsel tanıma kabiliyeti sayesinde birçok görüntü işleme görevinde yaygın olarak kullanılmaya başlanmıştır. Ancak SAM, özellikle benzer yer nesnelere içeren yüksek çözünürlüklü uzaktan algılama görüntülerinde belirgin sınıf içi varyasyonlar ve sınıflar arası benzerlikler nedeniyle performans düşüklüğü yaşamaktadır. Bu sorunu ele almak üzere Mei vd. (2024)'in sunduğu çalışmada SCD-SAM modeli geliştirilmiştir. SAM'in genel görsel segmentasyon gücünü semantik değişim tespiti için uyarlamayı hedeflemektedir. Önerilen yöntem, MobileSAM ve konvolüsyonel sinir ağı tabanlı ikili bir kodlayıcı yapısı kullanarak hem küresel hem yerel semantik değişim özelliklerini paralel olarak çıkarmakta ve bunları derin özellik etkileşimi yoluyla bütünleştirmektedir.

Zhao vd. (2024)'in önerdiği çalışmada, SCDM (Segment Anything Model–UNet Change Detection Model) isimli yaklaşım farklı zamanlara ait uzaktan algılama görüntülerindeki yapısal değişimleri yüksek doğrulukla tespit etmeyi amaçlamaktadır. Modelde, öncelikle çevrenin küresel özellik haritası çıkarılmakta, ardından zamana bağlı farklılıkları yakalayan ölçüm özellikleri hesaplanmakta ve bu iki bileşen birleştirilerek değişim tahmini yapılmaktadır. WHU-CD, LEVIR-CD ve karmaşık sahneler içeren DTX veri kümeleri üzerinde yapılan deneylerde, önerilen yöntemin

ChangeFormer, ChangerEx, Tiny-CD, BIT, DTCDSCN ve STANet gibi gncel modellerden daha başarılı sonuçlar elde ettiđi gsterilmiřtir.

Literatrdeki alıřmalar incelendiđinde, deđiřim tespiti alanında ilk olarak yksek znrlkl uydu ve hava grntleri zerine yođunlařıldıđı grlmektedir. Ancak bu tr grntlerdeki sınırlı grř aısı ve gncel veri elde etme zorlukları, arařtırmacıları sokak ve panoramik grntler gibi daha yer dzeyine yakın ve detaylı bilgi sunan alternatif veri kaynaklarına ynlendirmiřtir. Bu yeni grnt trleriyle yapılan alıřmalarda ise, karmařık perspektif yapıları, grnt formatlarındaki farklılıklar ve zellikle manuel veri etiketleme srecinin yksek iř gc gerektirmesi gibi yeni zorluklar ortaya ıkmıřtır. Bu sorunların ařılması amacıyla, son yıllarda sıfır atıřlı yntemlerin kullanıldıđı alıřmalar ne ıkmaya bařlamıřtır. Bu tez alıřmasında da literatrde karřılařılan bu temel zorluklar gz nnde bulundurularak, panoramik grntlerden sokak grntlerinin elde edilmesi, bu grntlerdeki nesnelerin otomatik olarak bltlenmesi ve deđiřim tespitinde etiket ihtiyaını azaltacak alternatif yntemlerin arařtırılması hedeflenmiřtir. Bu dođrultuda geliřtirilen yntemler ile derin đrenme tabanlı deđiřim tespiti alanına katkı sađlanması amalanmıřtır.

## ÜÇÜNCÜ BÖLÜM

### PANORAMİK ve SOKAK GÖRÜNÜMÜ GÖRÜNTÜLERİ

Panoramik görüntüleme sistemleri, sahnenin tamamını 360 derece kapsayan geniş görüş açısıyla (görüş alanı – Field of View, FOV) çevresel algılamada önemli bir teknoloji olarak öne çıkmaktadır. 360° yatay ve 180° dikey FOV sunarak sahnede hiçbir noktanın bilgiden kopmasına izin vermez. Özellikle kentsel alanlarda, tüm çevreyi tek bir görüntüyle yakalama imkânı sunarak geleneksel dar açılı kamera sistemlerine göre daha zengin bağlamsal bilgi sağlar. Bu özellik, şehir planlaması, otonom araç navigasyonu, robotik, sanal gerçeklik, güvenlik sistemleri ve harita güncellemeleri gibi pek çok uygulama alanında panoramik görüntülerin tercih edilmesine neden olmuştur (Gao vd., 2022). Panoramik kameraların en önemli avantajlarından biri, geniş görüş açısı sayesinde sahnenin hiçbir bölümünün göz ardı edilmemesidir. Bu sayede yollar, ağaçlar, yayalar veya trafik işaretleri gibi sahneye ait tüm öğeler aynı kare içinde temsil edilebilir.

Bununla birlikte, panoramik görüntüleme sistemlerinin getirdiği bu geniş kapsamlı veri sunumu, beraberinde birtakım zorluklar da taşımaktadır. Panoramik görüntülerin sahip olduğu yüksek çözünürlük, bu görüntülerin işlenmesini hem bellek açısından hem de zaman açısından zorlaştırmaktadır. Panoramik sahnelerde özellikle küçük nesnelerin (örneğin trafik levhaları veya sokak mobilyaları gibi) görüntüde çok az yer kaplaması, bu nesnelerin doğru şekilde tespitini zorlaştırmaktadır. Bunun yanında, bu veri türüne özgü geniş ölçekli ve detaylı şekilde etiketlenmiş veri kümelerinin sınırlı olması da derin öğrenme temelli segmentasyon modellerinin bu görüntüler üzerinde eğitilmesini güçleştirmektedir (Ai vd., 2022).

Panoramik görüntüleme sistemlerinin sahip olması beklenen ideal özellikler; yüksek çözünürlük, kör alan bırakmama, kompakt optik yapı ve çok boyutlu çevresel algılamadır (Gao vd., 2022). Ancak bu hedeflere ulaşmak, mevcut teknikler açısından hâlâ çeşitli sınırlılıkları beraberinde getirmektedir.

#### 3.1. Panoramik Görüntülerin Elde Edilmesi

Panoramik ve geniş görüş açısına sahip görüntülerin elde edilmesinde yaygın olarak kullanılan yöntemlerden biri, birden fazla görüş alanının birleştirilmesidir. Bu yaklaşımda farklı açılardan elde edilen görüntüler birleştirilerek geniş görüş açısına sahip panoramik görüntüler oluşturulur (Gurrieri ve Dubois, 2013). Bu teknoloji,

temelde tek kameralı tarama ve çok kameralı birleştirme olmak üzere iki farklı yöntemle uygulanır (Gao vd., 2022).

Tek kameralı tarama yöntemi, yüksek hassasiyetli mekanik döner platformlar kullanılarak tek bir kameranın döndürülmesiyle panoramik bir görünüm elde edilmesini sağlar. Bu yöntemin temelinde, optik sistemin belirli bir merkez noktası etrafında döndürülerek geniş açılı bir görüntü oluşturulması yer alır. Örneğin, bir akıllı telefon ile yapılan panoramik çekimlerde, kamera manuel olarak çevrilerek geniş görüş açısına sahip görüntüler oluşturulabilir. Benzer bir kullanımda, Nikon 990 model bir kameranın Kaidan Kiwi 990 aparatıyla döndürülerek yaklaşık 120° görüş alanına sahip panoramik görüntüler üretildiği bilinmektedir (Gledhill vd., 2003). Bu yöntem, özellikle sahnenin statik olduğu durumlarda kullanılmaya uygundur ve döner mekanizmanın yüksek doğrulukla çalışmasını gerektirir. Ancak kameranın döndürülerek çekim yapması zaman aldığından, bu yöntemle anlık sahne takibi mümkün değildir. Alternatif olarak, görüş alanının yönünü değiştirmek amacıyla prizma kullanımı da benzer bir yöntem olarak önerilmiştir (Lin vd., 2014).

Çoklu kamera birleştirme yöntemi, aynı anda birden fazla kamerayla çekim yapılarak 360° çevresel görüntü elde edilmesini sağlar (Huang vd., 2014). Bu yöntemde, farklı yönlere bakan kameralar senkronize şekilde çalışır. Ancak her bir kameranın sahip olduğu farklı parametre ayarları ve montaj açıları, görüntü birleştirme sürecini doğrudan etkileyerek nihai görüntü kalitesinde düşüştürebilir (Yuan vd., 2010).

Uzun dalga boylu kızılötesi (LWIR) sistemler, yüksek maliyetleri nedeniyle genellikle daha az tercih edilse de, düşük maliyetli alternatifler geliştirmek adına çevresel düzende yerleştirilen küçük boyutlu LWIR kameraların kullanıldığı çözümler önerilmiştir. Bu yapı sayesinde panoramik görüntüleme mümkün hâle gelirken, birden fazla sensörün aynı sistemde senkronize edilmesi ihtiyacı beraberinde yüksek hassasiyetli kalibrasyon ve hizalama gerekliliklerini de getirmektedir (Cowan vd., 2019). Benzer şekilde, taşınabilir yapıda geliştirilen stereo panoramik sistemlerde dört adet görünür bant kamerası kullanılarak düşük maliyetli ve çok yönlü bir görüntüleme altyapısı sağlanabilmektedir. Bu tür sistemler, hacimsel olarak kompakt olmanın yanı sıra üç boyutlu sahne bilgisi de sunabilmektedir (Lin vd., 2019).

Diğer yandan, panoramik görüntüleme görüş açısını ve sensör verimliliğini en üst düzeye çıkarmayı hedefleyen optik düzen tasarımlarında, iki aynadan oluşan piramit yapılar tercih edilebilmektedir. Bu tür yapıların tasarımında, piramit geometrisinin ve görüntüleyici sensör gruplarının konumlandırılmasının optimize edilmesi, sistemin genel performansını doğrudan etkilemektedir. Söz konusu analizlerin, benzer prensiplere dayalı diğer panoramik kamera sistemlerine de uyarlanabileceği belirtilmektedir (Hua, Ahuja ve Gao, 2007).

Panoramik görüntülerin elde edilmesinde kullanılan bir diğer yöntem ise balıkgözü (fisheye) optik sistemleridir. Bu sistemler, çoklu kameraların birleştirilmesine dayalı yöntemlere kıyasla daha basit bir sistem yapısı sunar; görüntü birleştirme algoritmalarına ihtiyaç duymaz, kurulum kolaylığı sağlar ve nispeten daha düşük maliyetlidir. En yaygın kullanım biçimi, ön merceği dışa bombeli yapıda olan klasik balıkgözü lens sistemidir (Haggui vd., 2021).

Balıkgözü sistemler, genellikle 180°'nin üzerinde görüş alanı sağlayan ultra geniş açılı optik sistemlerdir (Miyamoto, 1964). Bu geniş açılar sayesinde panoramik fotoğrafçılık, gökyüzü haritalama ve robotik navigasyon gibi uygulamalarda önemli avantajlar sunar. Sistemin ön kısmında yer alan lensler, sahnedeki geniş görüş alanını sıkıştırarak görüntünün optik sistemden geçmesini sağlar; sonrasında ise aktarma (relay) lens grupları aracılığıyla çeşitli optik bozulmalar giderilir. Ancak bu optik yapıdan kaynaklı olarak görüntünün bazı bölgelerinde şekil bozulmaları meydana gelebilmektedir. Özellikle görüntü merkezinden uzaklaştıkça oluşan bu bozulmalar, merceğin yapısının geniş görüş alanını düzlemsel bir yüzeye yansıtmasından kaynaklanır ve bu tür bozulmalar literatürde sıklıkla  $f-\theta$  distorsiyonu olarak adlandırılır (Thibault vd., 2005). Temelde bu, görüntüdeki nesnelerin açısal konumları ile algılanan yerlerinin birbir örtüşmemesi durumudur. Bu nedenle balıkgözü lens tasarımlarında distorsiyon kontrolü büyük önem taşır.

Bununla birlikte, yalnızca optik sistemlere özgü sorunlar değil, panoramik görüntülerin genel yapısından kaynaklanan birtakım zorluklar da bulunmaktadır. Panoramik görüntüler, sahnenin tamamını kapsayan geniş bir görüş alanı sundukları için nesnelere, özellikle görüntü merkezinden uzaklaştıkça daha küçük boyutlarda temsil edilir. Bu durum, küçük nesnelerin algılanmasını zorlaştırmakta ve nesne temelli segmentasyon işlemlerinde başarıyı düşürmektedir. Aynı zamanda, bu geniş görüş alanı, sahnedeki derinlik algısını bozabilir; nesnelere arasındaki uzaklıkların

yorumlanması zorlaşabilir. Görüntüde yer alan eğrilikler ve perspektif sapmaları, hem görsel yorumlamada hem de model eğitimi süreçlerinde ciddi karmaşıklık yaratmaktadır (Jakab vd., 2024).

Panoramik görüntülerdeki yüksek çözünürlük, verilerin işlenmesini özellikle bellek ve zaman açısından maliyetli hâle getirmektedir. Derin öğrenme modellerinin yüksek çözünürlüklü girişlerle çalışabilmesi için GPU bellek kapasitesinin sınırları zorlanmakta, bu da işlem süresini artırmakta ve modelin verimli bir şekilde eğitilmesini engellemektedir. Buna ek olarak, panoramik görüntülere özgü, yeterli çeşitliliğe ve açıklığa sahip, etiketlenmiş büyük veri kümelerinin eksikliği de önemli bir sınırlılık olarak karşımıza çıkmaktadır (Blott vd., 2018).

Tüm bu zorluklar, panoramik görüntülerin doğrudan kullanıldığı uygulamalarda hem hesaplama yükü hem de doğruluk açısından çeşitli sınırlamaların ortaya çıkmasına neden olmuştur. Çözünürlük yönetimi, nesne boyutu ve algı karmaşıklığı gibi teknik sorunlar, araştırmacıların alternatif veri temsilleri üzerine yoğunlaşmasına yol açmıştır. Bu bağlamda, panoramik görüntülerden türetilen yeni görüntü formatları, özellikle de dar görüş açısına sahip sokak düzeyinde görüntüler, son yıllarda dikkat çeken bir araştırma alanı hâline gelmiştir. Bu tür görüntüler, sahnenin daha sınırlı ancak detaylı bir kesitini sunarak belirli analiz türlerinde daha kullanılabilir veriler sağlayabilmektedir.

### **3.2. Sokak Görünümü Görüntüleri**

Sokak görünüm görüntüleri (Street View Imagery – SVI), şehirlerin fiziksel çevresini algılamada kullanılan yenilikçi bir coğrafi veri türüdür (Tang vd., 2022). Bu görüntüler, 360 derece panoramik bilgi sunarak kullanıcıların şehir sokaklarını gerçekçi bir şekilde uzaktan keşfetmelerine olanak tanır (Ye et vd., 2019). SVI sistemleri, yaya perspektifinden doğal ve yapay çevrelerin eşzamanlı olarak gözlemlenmesini sağlar. Derin öğrenme ve görüntü işleme teknolojilerindeki hızlı gelişmelerle birlikte, bu tür verilerin daha ayrıntılı ve etkili biçimde analiz edilmesi mümkün hâle gelmiştir. Böylece, şehir ortamı ve insan faaliyetleri üzerine daha önce benzeri görülmemiş ölçekte sayısal analizlerin yapılması sağlanmıştır.

SVI, kentsel yapılı çevrenin araştırılmasında yeni ve güçlü bir veri kaynağı sunar. Bu teknoloji sayesinde, sokak düzeyinde yer alan sahne öğeleri tespit edilerek daha kapsamlı ve doğru çevre denetimleri yapılabilmektedir. Bu tür görüntüler özellikle

bina yapısı, cephe elemanları ve mimari özelliklerin değerlendirilmesinde yaygın olarak kullanılmakta; binaların tipi, durumu ve işlevi gibi mimari nitelikler uzaktan algılanabilmektedir (Li vd., 2015). Bunun yanında, kırık camlar veya duvar yazıları gibi düzensizlik unsurları, sosyoekonomik koşullar hakkında dolaylı ipuçları sunarak, suç oranları gibi kentsel göstergelerin analizinde de kullanılabilir (Zhang, Pan ve Zhang, 2022). SVI sayesinde bu değerlendirmeler, fiziksel olarak sahada bulunmaya gerek kalmaksızın, düşük maliyetli ve yaygın biçimde yapılabilmektedir.

Günümüzde SVI sistemlerinin dünya genelinde geniş ölçekte kullanılabilir hâle gelmesi, 3B bina verisi veya yapı ayak izi olmayan bölgelerde bile, yapay zekâ tabanlı yöntemlerle 3B kentsel morfolojinin çıkarılmasını mümkün kılmaktadır (Pang ve Biljecki, 2022). Ayrıca SVI kullanılarak büyük ölçekli analizlerde kent kanyonlarının etkileri, radyasyon sıcaklığı, kısa dalga ışımaya gibi çevresel parametreler değerlendirilebilmekte; güvenlik (Porzi vd., 2015), konut fiyatları (Law, Paige ve Russell, 2019) ve demografik yapı gibi mahalle düzeyinde özellikler analiz edilebilmektedir. Daha az ölçekte ise yapıların çevresel donatımı, yeşil alan durumu ve bunların insan sağlığına etkisi gibi temalar SVI verisiyle çalışılabilmektedir (Zhang vd., 2021).

Bugüne kadar yapılan araştırmalar, SVI ve yapay zekâ tekniklerinin birlikte kullanılmasıyla yapı çevreye ilişkin karmaşık mekânsal bilgilerin çıkarılabildiğini ve bu sayede kentlerin daha detaylı, nicel ve karşılaştırılabilir biçimde değerlendirilebildiğini göstermektedir. Bu yaklaşım aynı zamanda düşük karbon salımlı kentlerin planlanmasına katkı sunmakta ve yapıların yaşam döngüsü değerlendirmelerinde de önemli bir rol oynamaktadır (Wu vd., 2022).

SVI hizmetlerinin büyük ölçekte yaygınlaşmasından bu yana, araştırmacılar bu yöntemin yapı çevre özelliklerini değerlendirme konusunda büyük potansiyele sahip olduğunu kabul etmiştir (Kelly vd., 2013). Ancak şimdiye kadarki literatür taramaları çoğunlukla yalnızca Google Street View özelinde, sınırlı halk sağlığı temaları ve mikro çevresel faktörlere odaklanmıştır. Oysa önceki araştırmalar, kentlerin fiziksel ortamıyla bireylerin sağlık davranışları arasında güçlü ilişkiler bulunduğunu göstermektedir (Kang vd., 2020). Son yıllarda, epidemiyoloji, psikoloji ve coğrafya gibi disiplinlerde araştırmacılar, yapı çevrenin sağlık üzerindeki etkilerini incelemeye daha fazla önem vermeye başlamışlardır.

Bununla birlikte, kent ortamının bireylerde oluşturduğu algıların ve duyuşsal etkilerin ruh sađlıđına katkısı da bazı alıřmalarda incelenmiřtir. rneđin, evresel algıyı daha gvenli, yeřil ya da estetik aıdan hoř olarak tanımlayan grsel ierikler analiz edilmiřtir (Larkin vd., 2021). Ancak bu alıřmalar genellikle yapılı evreye dair SVI verisinin tek bir uygulama alanına odaklandıđını gstermektedir. Son dnemde artan alıřmalar, SVI verileriyle yapı evresine dair fiziksel zelliklerin llmesini ve bu yntemlerin uygulanabilirliđini arařtırmaktadır (Biljecki ve Ito, 2021).

### **3.2.1. SVI Analiz Yntemleri**

SVI analiz yntemleri, genel olarak bilgisayarlı gr ve derin đrenme olmak zere iki ana bařlık altında incelenebilir. Bilgisayarlı gr, insan gznn yerini grntleme sistemleriyle alarak nesnelere tanınması, llmesi ve yksek boyutlu verilerden anlamlı bilgilerin ıkarılması srelerini kapsayan bir teknolojidir (Lrig et al., 2021). Geleneksel bilgisayarlı gr yaklařımları, grntleri ifade etmek iin renk spektrumu, doku, řekil, lekten bađımsız zellik dnřm (SIFT) (Lowe, 1999), ynl gradyan histogramı (HOG) (Dalal ve Triggs, 2005) ve genelleřtirilmiř arama ađaları (GIST) (Oliva ve Torralba, 2001) gibi sıđ ve orta dzeyli, elle tanımlanmıř grsel znelikler kullanır. Ancak bu znelikler yksek dzeyde uzmanlık gerektirir, grnt temsili aısından sınırlamalara neden olabilmektedir.

Bu sınırlamaları ařmak amacıyla 2012 yılında geliřtirilen AlexNet modeli, yksek boyutlu verilerin derin đrenmeyle iřlenmesinde nemli bir dnm noktası olmuřtur. AlexNet, grevle iliřkili grsel znelikleri otomatik olarak đrenebilmesi sayesinde, derin đrenme tabanlı yntemlerin grnt yorumlama srelerinde etkin biimde kullanılmasını mmkn kılmıřtır (Li vd., 2022).

Derin đrenme, grev tr ve mimari yapısına gre otomatik kodlayıcılar, retici karřıt ađlar (GAN), yinelemeli sinir ađları (RNN) ve derin evriřimli sinir ađları (DCNN) gibi farklı yapılarda uygulanabilir. zellikle derin evriřimli sinir ađları, grnt verilerinin analizi iin yaygın olarak kullanılmakta olup; AlexNet, VGG, GoogLeNet, ResNet ve DenseNet gibi ncl modeller bu alanda ne ıkmaktadır. Bu yapılar, ođunlukla grnt zneliklerinin ıkarılmasında n adım olarak kullanılır; ardından greve zel ađ yapılarıyla analiz gerekleřtirilir. Bununla birlikte, modelin genelleme yetkinliđi ve ayırt edebildiđi sınıf sayısı, byk lde kullanılan eđitim veri setine bađlıdır. Gnmzde aık eriřimli veri kmeleri kullanılarak utan uca eđitilebilen yksek

doğruluklu modeller geliştirilmiştir. Bu modeller, sokak sahneleri, sosyal medya görüntüleri ve benzeri görsel içerikler üzerinde doğrudan uygulanabilmekte, böylece kentsel yapılı çevrenin görüntü tabanlı nicel analizine yönelik güçlü bir temel sunmaktadır.

Geleneksel yöntemler çoğunlukla sığ düzeyli, elle tanımlanmış özniteliklere dayandığından, görsel sahnelerdeki derin anlamsal yapıları yeterince temsil edememekte ve bu durum SVI verilerinin kent ölçekli çalışmalarda etkin kullanımını sınırlandırmaktadır. Buna karşın, güncel derin öğrenme destekli bilgisayarlı görü teknikleri, sahne içeriklerini daha doğru tanımlayarak hem anlamsal nesne tespiti hem de yapılı çevrenin nicel ve içeriksel olarak ifade edilmesi için etkili araçlar sunmaktadır (Li vd., 2022).

Sokak görünümü tanıma uygulamaları zamanla sahne sınıflandırma, nesne-arka plan ayrımı ve konum tanımadan, fiziksel çevre ve mekânsal algı gibi daha ileri düzey analizlerin yapılmasına neden olmuştur. Görüntü işleme teknolojileri başlangıçta manuel ve basit görüntü işleme adımları ile sınırlıyken, günümüzde derin öğrenme tabanlı modellerin yaygınlaşmasıyla birlikte daha karmaşık yapıların analiz edilmesi mümkün hale gelmiştir. Örneğin; PSPNet, SegNet, DeepLab v3 ve U-Net gibi mimariler yaygın olarak kullanılmaktadır (He ve Li, 2021).

Küçük örneklemlerle veri kümelerinde hâlâ manuel etiketleme yöntemleri tercih edilmekte olup bu işlemler için genellikle bazı yazılımlar kullanılmaktadır. Daha ileri düzeyde ise, piksel tabanlı görüntü işleme teknikleriyle sokak görüntüleri analiz edilmekte; farklı piksellerin eşikleme veya segmentasyon yöntemleriyle hangi kentsel unsura karşılık geldiği belirlenmektedir. Örneğin Zeng ve ark. (2018), Canny kenar algılama algoritmasını kullanarak görüntülerde gökyüzü alanlarını tespit etmişlerdir.

### **3.2.2. Panoramik Görüntülerden Sokak Görünümü Görüntüleri Oluşturulması**

Panoramik görüntüler, insan gözüne yakın bir bakış açısı sağlayarak geniş bir görüş alanı sunar. Bu yüzden hem kentsel ortamlarda hem de yapay zeka temelli modellemelerde giderek daha fazla tercih edilmektedir. Panoramik görüntüler hem daha fazla detay içerir hem de mekânsal bağlamı daha iyi tutarlar; ancak bu tür görüntüler yüksek çözünürlük ve distorsiyonlar nedeni ile analiz süreçlerinde zorluklar oluşturur. Bu zorluklar, tek başına kullanım yerine, bu görüntülerden sokak görünümü görüntüleri gibi yeni görüntü türleri türetme ihtiyacını ortaya çıkarmıştır. Bu sayede,

distorsiyonun etkileri azaltılarak, derin öğrenme temelli segmentasyon gibi görevlerde daha doğal, gerçekçi ve detaylı bir veri kaynağı elde edilmiş olur.


Panoramik görüntüler çoğunlukla çok mercekli kameralarla elde edildiğinden, görüntünün farklı yönlerinde ciddi doğrusal olmayan bozulmalar ortaya çıkmaktadır. Bu bozulmalar, perspektif görüntülere eklenmiş bir tür geometrik dönüşüm gibi düşünülebilir ve görüntü merkezinden uzaklaştıkça etkisi artar. Örneğin SIFT algoritması, döndürmeye, ölçeğe ve parlaklık değişimine karşı dayanıklı olduğundan panoramik görüntüler için hâlâ kullanılmaktadır; ancak işlem süresi uzundur (Lowe, 2004).

SIFT algoritmasındaki sorunları çözmek üzere geliştirilen SURF algoritması, SIFT'e kıyasla daha hızlı çalışmakta ve büyük veri hacmine sahip panoramik görüntüler için daha uygundur (Bay vd., 2008). SIFT üzerine inşa edilen bir diğer algoritma olan ASIFT, tam dönüşüm dayanıklılığı sağlar; bu sayede panoramik görüntülere daha iyi uyum sağlar (Wu vd., 2013). ASIFT, SIFT'ten farklı olarak dört yerine altı parametre kullanır. Çoğu algoritma, öznitelik eşleştirme için FLANN gibi uzaklık temelli yöntemler kullanır; ancak panoramik görüntülerdeki belirgin doğrusal olmayan bozulmalar, bu tür eşleştirme yöntemlerinin başarısını düşürmektedir (Muja ve Lowe, 2014). Alternatif olarak geliştirilen CSIFT algoritması, çekirdek çizgi kısıtlamaları (kernel line constraints) kullanarak eşleşme başarımını artıran, SIFT benzeri tanımlayıcılar sunmaktadır (Chen vd., 2015). Ancak bu algoritmaların çoğu, perspektif görüntüler için geliştirilmiş olan öznitelik çıkarım ve eşleme tekniklerinin doğrudan veya uyarlanmış biçimde panoramalara uygulanmasıyla sınırlıdır ve panoramaların belirgin bozulmalarına yeterince uyum sağlayamamaktadır.

Yapay zekâ tabanlı yöntemlerin gelişmesiyle birlikte, CNN üzerine kurulu öznitelik çıkarımı ve eşleme yaklaşımları ön plana çıkmıştır (Li vd., 2020). Örneğin LIFT, SuperPoint, DELF ve D2-Net gibi modeller bu alanda etkin biçimde kullanılmakta, daha hızlı ve daha doğru öznitelik çıkarımı sağlamaktadır (Yi vd., 2016). Öznitelik çıkarımı açısından, SuperPoint algoritması çok sayıda özneliği hızlıca çıkarabilmesiyle öne çıkmakta ve yaygın biçimde kullanılmaktadır (DeTone, Malisiewicz ve Rabinovich, 2018). Super Glue algoritması, grafik tabanlı mekanizması ile çalışarak geleneksel eşleştirme algoritmalarına göre çok daha iyi sonuçlar elde etmektedir (Sarlin vd., 2020).

Son olarak, panoramik görüntülerin analizini kolaylaştırmak amacıyla çeşitli projeksiyon modelleri geliştirilmiştir. Bu projeksiyon modelleri, türleri ve yapısal özelliklerine göre Küp Projeksiyon Modeli ve Eşkenar Dörtgen Projeksiyon Modeli olmak üzere iki ana grupta incelenebilir. (Gao vd., 2023).

Eşkenar dörtgen projeksiyon modeli, panoramik görüntülerin düzlem üzerinde daha dengeli ve bozulma oranı düşük şekilde temsil edilmesini amaçlayan yöntemlerden biridir. Bu modelde, sanal panoramik küre üzerindeki enlem ve boylam koordinatları, düzlem üzerindeki dikey ve yatay koordinatlara eşlenir. Panoramik görüntü düz bir düzleme açıldığında, genişliği yüksekliğinin iki katı olacak şekilde yeniden düzenlenir ve küresel panoramik görüntüdeki herhangi bir  $P$  noktasının, düzleştirilmiş panoramik görüntüdeki karşılık gelen  $P$  noktasıyla birebir eşleme ilişkisi bulunur. Bu ilişkinin görsel olarak temsili Şekil 3.1’de verilmiştir.



**Şekil 3.1: Panoramik görüntüdeki herhangi bir  $P$  noktasının, düzleştirilmiş panoramik görüntüdeki karşılık geldiği  $P$  noktanın gösterimi**

**Kaynak:** Gao vd., 2023

Kullanılan projeksiyon modelinde temel varsayım, üç boyutlu uzaydaki doğrusal yapıların, iki boyutlu düzleme projeksiyon sürecinde de doğrusal özelliklerini korumasıdır. Eşkenar dörtgen projeksiyon, panoramik görüntünün tam küresel kapsama alanını korurken, verilerin daha verimli işlenmesini sağlar. Bu yapı, özellikle görüntü işleme ve segmentasyon gibi derin öğrenme tabanlı uygulamalarda, panoramik veriyi düzenli bir matris yapısına dönüştürerek algoritmaların standart

CNN tabanlı yapılara daha kolay uygulanmasına olanak tanır. Bu modelin en büyük avantajlarından biri, panoramik görüntünün tamamını tek bir düzlem üzerinde bozulmaları minimize ederek sunabilmesidir. Böylece hem görsel analiz süreçleri kolaylaşır hem de derin öğrenme yöntemleriyle entegre çalışmalarda daha tutarlı sonuçlar elde edilebilir.

Formül (1), düzlemsel panoramik görüntüdeki bir piksel olan  $p(x, y)$  ile, küresel kutupsal koordinat sistemindeki  $P'(\alpha, \beta, R)$  noktası arasındaki ilişkiyi sunmaktadır. Formül (2) ise küresel kutupsal koordinat sistemi ile dik açılı küresel koordinat sistemi arasındaki eşleşmeyi tanımlamaktadır (Startsev ve Dorr, 2018).

Burada  $R$ , kürenin yarıçapını;  $W$ , düzlemsel görüntünün genişliğini;  $\beta$ , OP doğrultusu ile XOY düzlemi arasındaki açıyı;  $\alpha$  ise OP doğrultusu ile OY eksenini arasındaki açıyı ifade etmektedir.

Formül (1) ve Formül (2)'ye dayalı basit bir türetme ile, düzlemsel panoramik görüntüdeki piksel koordinatları  $p(x, y)$  ile, küre üzerindeki küresel panoramik görüntünün uzaydaki koordinat sistemindeki karşılığı olan  $P(X, Y, Z)$  arasındaki ilişki aşağıdaki şekilde elde edilmektedir:

$$\begin{cases} X = R \cdot \alpha \\ Y = R \cdot \beta \\ R = \frac{W}{2\pi} \end{cases} \quad (3.1)$$

$$\begin{cases} X = R \cdot \sin(\alpha) \cdot \sin(\beta) \\ Y = R \cdot \cos(\alpha) \cdot \sin(\beta) \\ Z = R \cdot \cos(\beta) \end{cases} \quad (3.2)$$

$$\begin{cases} X = R \cdot \sin\left(\frac{x}{R}\right) \cdot \sin\left(\frac{y}{R}\right) \\ Y = R \cdot \cos\left(\frac{x}{R}\right) \cdot \sin\left(\frac{y}{R}\right) \\ Z = \cos\left(\frac{y}{R}\right) \end{cases} \quad (3.3)$$

Küp Projeksiyon Modeli, sanal panoramik küreyi dıştan kesilen bir küpün altı yüzeyine yansıtarak altı farklı perspektif görüntü oluşturmayı amaçlamaktadır (Yang vd., 2018). Bu yöntemde, öncelikle sanal panoramik küre, geometrik ilişkiler kullanılarak küp yüzeyine yansıtılır. Ardından, her bir küp yüzeyi koordinat dönüşümleri aracılığıyla birer perspektif görüntüye dönüştürülür. Böylece, sanal panoramik küre ile elde edilen perspektif görüntüler arasında bir eşleme ilişkisi

kurulmuş olur. Bu eşleme işleminin temel amacı, küp üzerindeki her bir görüntü noktasının panoramik kürede karşılık geldiği konumu doğru şekilde belirlemektir. Bu noktada kritik olan, küre üzerindeki her bir görüntü noktasının, küpün hangi yüzeyine yansıtılması gerektiğinin doğru biçimde saptanmasıdır.

Bir diğer projeksiyon modeli olan perspektif projeksiyon modeli, üç boyutlu bir sahnedeki nesnelerin düzlemsel bir görüntü üzerine, gözle veya kamerayla olan uzaklıklarına bağlı olarak doğal bir biçimde küçülerek yansıtılmasını sağlayan geometrik bir dönüşüm modelidir. Bu projeksiyon türü, insan gözünün dünyayı algılayış biçimine benzer şekilde, nesnelerin uzaklaştıkça küçüldüğü bir görünüm üretir. Modelin temelinde, genellikle bir iğne deliği (pinhole camera) modeli yer alır. Bu yaklaşımda, sahnedeki her bir nokta, kamera merkezinden geçerek bir görüntü düzlemine aktarılır ve böylece derinlik etkisi oluşturulur.

Perspektif projeksiyon, özellikle panoramik görüntülerin dönüştürülmesinde önemli avantajlar sunmaktadır. Panoramik görüntüler, geniş görüş alanı sağlasa da, sahne içerisindeki nesneler arasında orantısız bozulmalara ve derinlik hissini kaybına neden olabilir. Perspektif projeksiyon ise bu görüntüleri, gerçek dünya görünümüne daha yakın bir şekilde yeniden düzenleyerek, özellikle uzak ve küçük nesnelerin daha belirgin hâle gelmesini sağlar. Bu özellik, bina, ağaç ve trafik işareti gibi nesne odaklı analizlerin daha sağlıklı yapılabilmesine zemin hazırlar.

Bilgisayarla görü alanında yapılan çalışmalarda, perspektif projeksiyon modeli birçok farklı amaçla kullanılmaktadır. Özellikle şehir sahnelerinin semantik segmentasyonu, yol ve yapı tespiti gibi görevlerde, bu modelin sahne içi ölçek farklılıklarını dengeleyici etkisi sıkça kullanılmaktadır.

Panoramik görüntülerden sokak görünümleri elde etmek amacıyla kullanılan projeksiyon yöntemleri arasında yer alan perspektif model, özellikle tek bir bakış açısına ait ve derinlik bilgisi korunan görüntüler üretmek için tercih edilmektedir (Li vd., 2017).

Bu yaklaşım sayesinde, panoramik görüntü üzerindeki karmaşık eşleme işlemleri, küpün altı ayrı yüzeyine projekte edilen perspektif kareler aracılığıyla daha yönetilebilir bir hale gelir. Her biri yaklaşık 90 derecelik görüş açısına sahip olan bu yüzeyler, farklı açılardan görüntü toplanmasına ve panoramik distorsiyonun azaltılarak daha düşük bozulma içeren perspektif görüntülerin elde edilmesine olanak

tanır. Bu sayede, görüntüler klasik öznitelik çıkarımı ve eşleme algoritmalarıyla daha kolay analiz edilebilir. Ayrıca bu model, gelişmiş öznitelik çıkarımı ve eşleme yöntemlerinin uygulanmasını kolaylaştırarak daha güvenilir ve kararlı sonuçlar elde edilmesini sağlar. Ancak, küp projeksiyonunun tüm yüzeyleri arasında her zaman tam bir süreklilik sağlanamayabilir. Özellikle bazı yüzeyler arasında geçişlerde oluşan boşluklar, örtüşme oranını düşürebilir ve eşleşme doğruluğunu olumsuz etkileyebilir.



## DÖRDÜNCÜ BÖLÜM

### DEĞİŞİM TESPİTİ

Zaman içinde kentlerde yaşanan fiziksel dönüşümleri takip edebilmek, özellikle şehir planlaması, çevresel izleme ve afet yönetimi gibi alanlarda büyük önem taşımaktadır. Bu noktada değişim tespiti, bir bölgenin farklı zamanlarda çekilmiş görüntülerini karşılaştırarak yaşanan değişiklikleri belirlemeye yönelik bir yöntem olarak öne çıkar. Binaların yapım veya yıkım süreçleri, yol düzenlemeleri, yeşil alanların azalması ya da artması gibi pek çok değişiklik bu yöntemle ortaya konabilir.

Gelişen teknolojiler sayesinde değişim tespiti yalnızca uydu görüntüleriyle sınırlı kalmamakta; daha yerel düzeyde, insan perspektifinden elde edilen verilerle de desteklenmektedir. Özellikle son yıllarda yapay zekâ ve derin öğrenme tabanlı yaklaşımlar sayesinde bu süreç daha hassas ve ölçeklenebilir hâle gelmiştir. Araştırmalarda kullanılan veri türleri çeşitlenmiş, klasik geniş açılı uydu görüntülerinin yanı sıra, daha ayrıntılı analizlere imkân tanıyan sokak görünümüleri ve panoramik görüntüler de önem kazanmaya başlamıştır (Parelius, 2023).

Panoramik ve sokak görünümü gibi insan bakış açısını yansıtan görüntüler, özellikle bina cephe yenilemeleri, trafik işaretlerinin değiştirilmesi veya peyzaj düzenlemeleri gibi küçük ölçekli değişimlerin belirlenmesinde etkili olmaktadır (Yun ve Kim, 2022). Bu tür detayların tespiti, geleneksel uzaktan algılama yöntemleriyle her zaman mümkün olmayabilir. Bu nedenle, gerçek zamanlı şehir takibi ya da sınırlı alanlarda değişim analizi yapılmak istendiğinde, daha farklı veri kaynaklarına ihtiyaç duyulmaktadır.

Sonuç olarak, değişim tespiti alanı yalnızca geçmişi belgeleyen değil, aynı zamanda şehirlerin geleceğini planlamaya yardımcı olan dinamik bir araştırma alanı hâline gelmiştir. Farklı görüntü türlerinin kullanımı, bu alanda hem çeşitliliği artırmakta hem de daha kapsamlı analizlere olanak sağlamaktadır.

#### 4.1. Değişim Tespitinde Kullanılan Görüntü Türleri

Uydu görüntüleme sistemleri, insansız hava araçları ve yer tabanlı haritalama araçları gibi veri toplama platformlarının gelişmesiyle birlikte, bu sistemlerin ürettiği çok kaynaklı uzaktan algılama verileri, arazi üzerindeki değişimlerin izlenmesine yönelik yeni uygulama ihtiyaçlarını da beraberinde getirmiştir. Özellikle yüksek mekânsal ve

zamansal çözünürlüğe sahip veriler, insan eliyle yapılan görsel analizlerin hem zaman açısından yoğun hem de uzmanlık gerektirdiği için maliyetli olması nedeniyle, daha otomatik ve dayanıklı değişim tespiti yöntemlerine duyulan ihtiyacı artırmıştır.

Değişim tespiti çalışmalarında kullanılan veri türleri incelendiğinde, mevcut yöntemlerin bu verilerle ne ölçüde uyumlu olduğu daha net şekilde değerlendirilebilmektedir. Bu bağlamda literatürde değişim tespiti amacıyla en yaygın kullanılan veri türleri, optik uzaktan algılama görüntüleri, Sentetik Açıklıklı Radar (SAR) görüntüleri ve sokak görünümüne dayalı görüntüler olarak üç ana grupta toplanmaktadır. Sokak görünümü görüntüleri doğrudan uzaktan algılama verisi olarak sınıflandırılmasa da, genellikle yardımcı veri olarak kullanılmaktadır (Ghouaiel ve Lefèvre, 2016). Özellikle sokak düzeyinde gözlem yapılabilmesine olanak tanınmaları, onları değişim tespiti açısından önemli bir veri kaynağı hâline getirmektedir (Shi vd., 2020).

Ayrıca, farklı veri türlerinin bir araya getirilerek (heterojen veri kombinasyonları) kullanıldığı değişim tespiti yaklaşımları da literatürde yer almaktadır. Örneğin, optik görüntüler genellikle pasif sensörler aracılığıyla, SAR verileri ise aktif sensörlerle elde edilmekte olup, farklı elektromanyetik spektrum aralıklarını kapsamaktadır. Bunlara ek olarak, sayısal yükseklik modelleri (DEM), coğrafi bilgi sistemi (GIS) verileri ve nokta bulutu (point cloud) gibi kaynaklar da değişim tespitine katkı sağlayacak tamamlayıcı bilgiler sunabilmektedir.

Yukarıdan yapılan uzaktan algılama, geniş alanlar üzerinde bilgi sağlayabilse de, zaman çözünürlüğü sınırlı olabilmektedir. Buna karşılık sokak görünümü görüntüleri, şehir ölçeğinde yere daha yakın bir perspektiften neredeyse gerçek zamanlı bilgi sunarak, özellikle kentsel çevredeki küçük ölçekli değişimlerin izlenmesinde önemli avantajlar sağlamaktadır. Kullanılan farklı veri türlerine ait örnek görüntüler, Şekil 4.1'de verilmiştir.

#### **4.1.1. Optik Uzaktan Algılama Görüntüleri**

Optik uzaktan algılama (RS) görüntüleri, bant sayısına göre hiperspektral, multispektral ve pankromatik olarak sınıflandırılır. Hiperspektral görüntüler (HSI), elektromanyetik spektrumun çok dar aralıklarında yüzlerce bant içererek yer yüzeyindeki en küçük spektral farkları bile tespit edebilecek kapasitededir (Li, Yuan ve Wang, 2019). Multispektral görüntüler genellikle 15'ten az bant içerirken daha

geniş spektral bant aralıklarına sahiptir ve yüzeydeki genel değişiklikleri analiz etmek için uygundur. Hiperspektral görüntüler, sağladıkları zengin spektral içerikle yüzeydeki küçük değişimleri tespit etmede güçlü bir araç sunarken, düşük mekânsal çözünürlükleri nedeniyle çevresel dokuların netliğinde azalma ve karışık piksel oranında artış gibi dezavantajlar barındırır. Bu da verinin yorumlanmasını zorlaştırmakta ve veri fazlalığına sebep olmaktadır.

Optik görüntülerin analizinde, özellikle çok zamanlı görüntüler arasında karşılaştırma yapılırken, atmosferik koşullardaki değişiklikler ve güneş ışığı açısı gibi dışsal faktörler sınıflandırma doğruluğunu etkileyebilmektedir. Bu nedenle, optik veriler üzerinde yapılan değişim tespiti çalışmalarında, ön işleme adımları büyük önem taşır. Radyometrik düzeltme, geometrik hizalama ve bulut maskeleyme gibi işlemler sayesinde görüntüler arası tutarlılık artırılarak daha sağlıklı karşılaştırmalar yapılabilmektedir. Son yıllarda, spektral özellikleri zengin olan bu veriler, makine öğrenmesi ve derin öğrenme temelli modellerle entegre edilerek arazi örtüsü değişimlerinin izlenmesinde daha etkin biçimde kullanılmaya başlanmıştır. Özellikle sınıf bazlı değişim haritalarının çıkarılmasında, optik görüntüler halen en çok tercih edilen kaynaklardan biridir.

#### **4.1.2. Sentetik Açıklıklı Radar (SAR) Görüntüleri**

SAR görüntüleri, sinyal işleme teknikleri ile fiziksel anten sınırlamalarının ötesine geçerek yüksek çözünürlüklü yüzey görüntüleri sağlar. Bu sensörler genellikle uydulara ya da hava araçlarına monte edilerek, hava koşullarından ve ışık düzeylerinden etkilenmeden görüntüleme yapılmasına olanak tanır. Bu özelliğiyle SAR, değişim tespiti açısından oldukça değerli bir bilgi kaynağı hâline gelmiştir. Günümüzde çok bantlı, çok kutuplaşmalı ve çok platformlu SAR verileri ile zengin görüntü setleri elde edilebilmekte; ancak bu görüntülerde sıklıkla görülen benek (speckle) gürültüsü, analiz süreçlerini zorlaştırmaktadır. Bu zorlukların üstesinden gelmek amacıyla, otomatik kodlayıcılar (autoencoder) ve konvolüsyonel sinir ağları (CNN) gibi yapay zekâ teknikleri, hem görüntüdeki gürültüleri bastırmak hem de anlamlı görsel özellikleri çıkarmak için yaygın biçimde kullanılmaktadır (Dong vd., 2018).

#### 4.1.3. Sokak Görünümü Görüntüleri

Sokak görünümü görüntüleri, kuşbakışı yerine yaya bakış açısıyla elde edilen görseller oldukları için daha küçük ölçekte ama yüksek detay içeren bilgi sunarlar. Bu görüntüler, özellikle binaların cephelerinde meydana gelen yenilemeler, tabelaların değişimi ya da kentsel peyzaj düzenlemeleri gibi değişiklikleri izleme açısından önemli bir kaynak olarak kullanılmaktadır (Ghouaiel & Lefèvre, 2016). Sokak görünümüne dayalı değişim tespiti, kentsel mekânlardaki görsel farklılıkları analiz ederken sıklıkla ışıklandırma değişiklikleri, kamera açılarındaki farklılıklar, nesnelere önünü kapatan unsurlar ve gölgeler gibi gürültü yaratan faktörlerle karşılaşır. Bu durum, görüntülerdeki gerçek semantik değişimleri ayırt etmeyi zorlaştırmaktadır. Bu nedenle, CNN gibi derin öğrenme modelleri kullanılarak anlamlı değişiklikleri öğrenmek mümkün hâle gelmektedir. Ancak bu yöntemlerin etkin bir şekilde çalışabilmesi için, karşılaştırılan görüntülerin mekânsal olarak eşleştirilmiş olması gerekir (Guo vd., 2018).


Sokak görünümü görüntüleri, özellikle bina cepheleri, yol kenarı donatıları, otoparklar, ağaçlık alanlar gibi ayrıntılı kentsel öğelerin analizinde büyük avantaj sağlar. Google Street View, Mapillary ve benzeri platformlar sayesinde büyük ölçekli ve çok zamanlı sokak görüntüleri veri kümelerine erişim mümkün hâle gelmiştir. Bu görüntüler, sadece görsel izleme değil, aynı zamanda kent planlama, tabela tanıma, engelli erişimi analizi ve tarihi doku takibi gibi birçok farklı alanda da kullanılmaktadır. Ancak bu verilerin sağlıklı şekilde analiz edilebilmesi için, görüntülerin hizalanması (registration), aydınlatma normalizasyonu ve obje maskeleri oluşturma gibi adımların dikkatle yürütülmesi gerekmektedir. Son dönemde geliştirilen sokak görünümüne özel semantik segmentasyon modelleri, bu alandaki analizlerin doğruluğunu önemli ölçüde artırmıştır.

#### 4.1.4. Panoramik Görüntüler

Panoramik görüntüler, çevrenin geniş açılı bir temsiline olanak tanıyarak 360 dereceye kadar yatay görüş sunar. Bu görüntüler, özellikle sokak görünümünün geniş alanları kapsayan versiyonlarıdır ve hem zamansal hem de mekânsal bağlamda karşılaştırma yapılmasına elverişli olduğu için, zaman içinde meydana gelen kentsel değişikliklerin izlenmesinde etkili bir araç hâline gelmiştir. Ancak görüntü boyutlarının büyük olması ve deformasyon içermesi, analiz aşamasında bazı teknik zorluklara neden olabilir.

Buna rağmen, doğru işleme teknikleriyle panoramik görüntüler, özellikle yapay zekâ destekli analizlerde güçlü bir veri kaynağı hâline gelmektedir.

Panoramik görüntüler, özellikle otomatik sürüş sistemleri, akıllı şehir uygulamaları ve sanal gerçeklik senaryolarında sıkça kullanılmaktadır. Bu tür görüntülerin analizi, geniş alan kapsama avantajı sağlasa da, küresel koordinat sistemine dönüştürülmeden yapılan analizlerde ciddi hata payları doğurabilmektedir. Bu nedenle, panoramik görüntüler genellikle küresel koordinatlara açılar üzerinden yeniden projeksiyon uygulanarak sokak görünümüne dönüştürülür. Bu dönüşüm, nesnelerin tanınmasını kolaylaştırmakta ve segmentasyon gibi sahne anlama işlemlerinde başarıyı artırmaktadır. Panoramik görüntülerden türetilen sokak görüntüleri, derin öğrenme modelleriyle birlikte kullanıldığında, farklı zamanlara ait sahneler arasında detaylı değişim tespiti yapılmasına olanak tanır. Ayrıca, nesne bazlı karşılaştırmalarda perspektif uyumu sağladığı için değişikliklerin daha hassas belirlenmesine katkı sunmaktadır.



**Şekil 4.1: Farklı kaynaklardan elde edilen görüntü türlerine ait örnekler: (a) optik uydu görüntüsü, (b) SAR görüntüsü, (c) sayısal yükseklik modeli (d) vektör tabanlı coğrafi veri, (e) LiDAR nokta bulutu verisi ve (f) sokak görünümü görüntüsü**

**Kaynak:** Shi vd., 2020

## BEŞİNCİ BÖLÜM

### SEGMENTASYON VE DEĞİŞİM TESPİTİ YÖNTEMLERİ


Kamera, radar ve çeşitli veri yakalama sensörlerinin kullanımı son yıllarda önemli ölçüde artış göstermiştir. Özellikle gerçek zamanlı veri toplama ihtiyacının arttığı akıllı şehir uygulamaları ile güvenlik sistemlerinde, bu tür cihazlar kamuya açık alanlarda ve konut çevrelerinde sıkça tercih edilmektedir (Yeong vd.,2021). Video ve görüntü kaydı yapabilen cihazların yaygınlaşması, bilgisayarla görme teknolojileri aracılığıyla bu verilerin analiz edilmesine ve anlamlı bilgilere dönüştürülmesine olanak tanımaktadır (Sreenu ve Durai, 2019). Bu gelişmeler, Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme gibi alanların görüntü verisiyle çalışan sistemlerde daha etkin bir şekilde kullanılmasına zemin hazırlamıştır.

Görüntü ve video verileri; güvenlik izleme, insan davranışı analizi, sağlık hizmetleri, tıbbi video analizi, otonom sürüş teknolojileri ve çeşitli akıllı şehir uygulamalarında karar destek amacıyla kullanılabilecek değerli bilgiler sunmaktadır. Bu alanlardaki uygulama çeşitliliği ve artan araştırma ilgisi, bilgisayarla görme tabanlı analizlerin daha da geliştirilmesini teşvik etmektedir. Özellikle nesne tespiti, nesne etiketleme ve segmentasyon gibi görevler, güncel çalışmalarda sıkça ele alınan temel konular arasında yer almaktadır (Elharrouss vd., 2016).

Görüntü işleme ve bilgisayarla görme alanlarında, görsellerin analizinde kullanılan temel yaklaşımlar arasında sınıflandırma, konumlandırma, nesne tespiti ve nesne tabanlı segmentasyon yer almaktadır. Bu yöntemler, görsel içerikteki nesnelerin varlığını, konumunu ve sınırlarını belirlemeye yönelik farklı seviyelerde bilgi sağlar. En temel düzey olan sınıflandırma, görüntüde hangi nesne türünün bulunduğunu belirtirken; konumlandırma, nesnenin yaklaşık yerini belirleyen sınırlayıcı kutular üretir. Nesne tespiti, birden fazla nesneyi aynı anda tanıyıp konumlandırabilirken; nesne tabanlı segmentasyon, her bir nesnenin pikseller düzeyinde ayrıştırılmasına olanak tanır.

Şekil 5.1’de, bu temel yaklaşımlar görseller üzerinden örneklendirilmiştir. İlk görselde sadece sınıflandırma işlemiyle bir kedinin tespiti yapılırken, ikinci görselde aynı kedinin konumu kutu içerisinde belirlenmiştir. Üçüncü görselde, birden fazla nesnenin tespiti ve konumlandırılması nesne tespiti yöntemiyle gerçekleştirilmiştir; dördüncü

görselde ise her bir nesne pikseller düzeyinde ayrıştırılarak nesne tabanlı segmentasyon uygulanmıştır.



**Şekil 5.1: Temsili görüntü örnekleri: (a) Orijinal görüntü, (b) sınıflandırma, (c) sınıfkandırma ve konumlandırma, (d) nesne tabanlı segmentasyon**

**Kaynak:** Rajalingappaa, 2018

Bilgisayarla görme teknikleri sayesinde, kameralar aracılığıyla elde edilen sahne içerikleri algılanabilir, sınıflandırılabilir, tanımlanabilir ve çeşitli segmentlere ayrılabilir hâle gelmiştir. Segmentasyon uygulamalarıyla birlikte, görüntüde yer alan sayılabilir nesnelere (things) ile sayılamayan ve homojen yapıya sahip alanlar (stuff) ayrıştırılarak analiz edilmektedir. Örneğin, bir sokak sahnesi değerlendirildiğinde; binalar, araçlar ve yayalar sayılabilir nesnelere olarak tanımlanırken, gökyüzü, yol yüzeyi veya çim alanlar sayılamayan bölgeler arasında yer alır (Vu vd., 2018). Bu nedenle, birçok görsel analiz algoritması hem sayılabilir hem de sayılamayan nesnelere tanımlayacak biçimde geliştirilmektedir.

Segmentasyon yöntemleri semantik segmentasyon, örnek (instance) segmentasyonu ve panoptik segmentasyon olmak üzere üç temel grupta incelenebilir. Bu yöntemler, görüntülerdeki nesnelere tespiti ve sınıflandırılmasında izlenen yaklaşımlara göre birbirinden ayrılır. Son dönemde literatürde yer bulan sıfır atış segmentasyon ise, daha önce eğitim verisiyle karşılaşmamış nesnelere tanıyabilme yeteneği sayesinde geleneksel yaklaşımlara alternatif bir çözüm sunmaktadır. Özellikle etiketli veriye ulaşmanın zor olduğu durumlarda, açıklayıcı metinlere dayalı yönlendirme ile farklı görsel içeriklerin segmentasyonu mümkün hâle gelmiştir.

### **5.1. Semantik Segmentasyon**

Semantik segmentasyon, bir görüntüyü piksel düzeyinde analiz ederek her pikseli ait olduğu nesne ya da yüzey sınıfına göre etiketlemeyi amaçlayan bir tekniktir (Hao, Zhou ve Guo, 2020). Bu yaklaşım, görüntüde yer alan tüm öğeleri anlamlandırarak sayılabilir nesnelere (örneğin insanlar, araçlar) ve sayılamayan yüzeylere (örneğin

yollar, gökyüzü) birbirinden ayırt etmeye olanak tanır. Bu yönüyle semantik segmentasyon, bir sahnenin genel yapısını tanımada ve her bir pikselin anlamsal bağlamda neyi temsil ettiğini belirlemede önemli rol oynar.

Bu teknik, ilk olarak 2007 yılında bilgisayarla görme alanında önerilmiş olsa da, derin öğrenme tabanlı yaklaşımların bu alana dâhil edilmesiyle 2014 yılında önemli bir ivme kazanmıştır. Özellikle Long ve arkadaşlarının çalışması (Long, Shelhamer ve Darrell, 2015), doğal görüntülerin uçtan uca segmentasyonu için CNN kullanarak bu alanda çığır açan bir yöntem ortaya koymuştur. Sonraki yıllarda U-Net, SegNet ve Fully Convolutional Networks (FCN) gibi CNN tabanlı mimariler, segmentasyon doğruluğunu artırmak amacıyla yaygın biçimde kullanılmıştır. Bu mimariler, görsel öğeleri sınıflandırmada başarılı sonuçlar vermekle birlikte; nesne yoğunluğunun fazla olduğu veya sahnenin karmaşık olduğu durumlarda, farklı sınıfların doğru şekilde ayrıştırılmasında sınırlı kalabilmektedir (Elharrouss et al., 2021). Bu nedenle son dönemlerde daha gelişmiş ağ yapıları ve hibrit yöntemler geliştirilmeye başlanmıştır.

## 5.2. Örnek Segmentasyon

Örnek (instance) segmentasyon, nesne algılama temelli yaklaşımların bir devamı olarak geliştirilen bir yöntemdir. Nesne algılama yalnızca görüntüdeki nesnelerin türünü tanımakla kalmaz, aynı zamanda bu nesnelerin görüntü içindeki konumlarını belirleyerek etrafına sınırlayıcı kutular çizer. Görüntü işleme süreci genellikle sırasıyla görüntü sınıflandırma, nesne algılama, semantik segmentasyon ve örnek segmentasyon adımlarını içerir.

Segmentasyon, sahnede yer alan nesnelere daha ayrıntılı şekilde bölerek her bir piksele karşılık gelen etiketi atamayı hedefler. Örnek segmentasyon ise bu süreci bir adım daha ileriye taşıyarak, aynı sınıfa ait olsa bile her bir nesne örneğini birbirinden ayırt eder. Yani, aynı kategoriye giren iki nesne için ayrı segmentasyon maskeleri oluşturulur ve pikseller, yalnızca sınıflara değil, aynı zamanda o sınıfa ait özgül nesne örneklerine göre de gruplanır.

Semantik segmentasyondan temel farkı, tüm nesnelere tek bir sınıf altında toplamak yerine her nesneyi bağımsız bir örnek olarak ele almasıdır. Bu sayede görüntüde yer alan her nesne hem ait olduğu sınıfa göre hem de bireysel örnek olarak ayrıştırılır. Bu farklılaşma, özellikle birden fazla nesnenin bulunduğu karmaşık sahnelerde detaylı

analiz yapmayı mümkün kılar. Görsel sınıflandırma, nesne tanıma, semantik ve örnek segmentasyonun uygulama örnekleri Şekil y 'de karşılaştırmalı olarak sunulmuştur.

Bir bilgisayarla görme yönteminin başarısını belirleyen en kritik unsurlardan biri, görüntüden çıkarılan özelliklerdir. Derin öğrenme öncesi dönemde yaygın olarak kullanılan SIFT (Scale Invariant Feature Transform) ve SURF (Speeded-Up Robust Features) gibi geleneksel özellik çıkarım yöntemleri, manuel olarak seçilmiş sınırlı özelliklere dayanıyordu. Ancak zamanla, bu tür elle tanımlanmış yöntemler yerini tam otomatik çalışan derin öğrenme mimarilerine bırakmıştır.

Özellikle CNN modelleri, görüntülerden anlamlı ve yüksek düzeyli özelliklerin otomatik olarak çıkarılmasında etkili bir omurga mimarisi olarak öne çıkmıştır. CNN temelli yapılar, yalnızca sınıflandırma değil, aynı zamanda segmentasyon gibi daha karmaşık görevler için de kullanılmaktadır.

Örnek segmentasyon, bu gelişmelerin bir sonucu olarak, görüntülerdeki geometrik dönüşümler, küçük nesnelerin tespiti, gürültü etkileri ve bozulmalar gibi çeşitli zorlukların üstesinden gelmeyi hedeflemektedir. Bu amaçla geliştirilen yaygın mimariler arasında Mask-RCNN, RCNN ve YOLACT gibi modeller yer almaktadır. Bu modeller, örnek segmentasyonun hem doğruluğunu hem de işlem verimliliğini artırmak üzere geliştirilmiş olup, günümüzde birçok uygulamada başarıyla kullanılmaktadır.

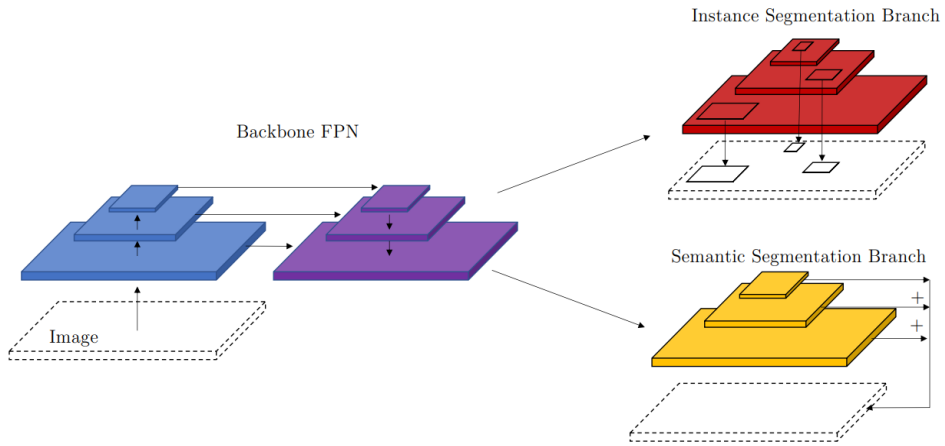
### **5.3. Panoptik Segmentasyon**

Panoptik segmentasyon, sahnelerde yer alan sayılabilen (things) ve sayılamayan (stuff) nesnelere aynı anda ayırt edebilen birleşik bir yaklaşımdır. Sayılamayan nesnelere, örneğin gökyüzü, kaldırım veya zemin gibi homojen yapılara sahip bölgeleri ifade ederken; sayılabilen nesnelere ise insanlar, arabalar gibi belirgin objeleri kapsar. Bu yaklaşım, semantik segmentasyonun piksel düzeyinde sınıflandırma yeteneğini, örnek segmentasyonun her nesneyi bireysel olarak maskeleyebilme yeteneği ile birleştirir. Böylece, sahnedeki her bölge hem sınıf bilgisine hem de nesne kimliğine sahip olur.

Panoptik segmentasyonun temel amacı, semantik ve örnek segmentasyon tekniklerinin sınırlamalarını aşarak sahneleri daha bütünsel bir şekilde analiz etmektir. Bu yöntem sayesinde, farklı türden nesnelere tek bir çıktı haritasında, onları birbirinden ayıracak şekilde farklı renklerle görselleştirilebilir. Bu da hem sahne anlaşılabilirliğini artırır hem de yapay zeka sistemlerinde segmentasyon çıktılarının daha etkili kullanılmasını

sağlar (Kirillov vd., 2019). Uygulamada, panoptik segmentasyon iki temel yöntemle gerçekleştirilebilir: Birincisi, semantik ve örnek segmentasyon çıktılarının birleştirilmesiyle oluşturulan yaklaşımdır. İkincisi ise bu iki görevi aynı ağ içinde mimari düzeyde birleştiren birleşik modellerin kullanılmasıdır (Huang vd., 2021).

Panoptik segmentasyon için geliştirilmiş popüler derin öğrenme mimarilerinden biri Panoptic Feature Pyramid Network (Panoptic FPN) modelidir. Bu model, örnek segmentasyon için kullanılan Mask R-CNN mimarisine semantik segmentasyon dalı eklenerek oluşturulmuştur. FPN bileşeni, farklı ölçeklerdeki nesnelere algılayabilmek için çok seviyeli özellik haritaları üretir. FPN, ResNet mimarisi üzerine inşa edilmiştir ve aşağıdan yukarıya (bottom-up) ile yukarıdan aşağıya (top-down) bilgi akışını birleştirerek özellik çıkarımı yapar. ResNet-50, 50 katmandan oluşan bir derin konvolüsyonel sinir ağıdır ve residual bloklar sayesinde derin ağların eğitimini kolaylaştırır (Lu vd., 2019). Panoptik FPN ağının temel mimarisi Şekil 5.2'de gösterilmiştir.



**Şekil 5.2: Panoptik FPN ağının temel mimarisi**

**Kaynak:** Allred vd., 2022

Mask R-CNN, iki aşamalı bir yapıdadır: İlk aşamada, görüntüde nesne içerebilecek bölgeler önerilir; ikinci aşamada ise bu bölgeler sınıflandırılır, sınır kutuları çizilir ve her nesne için segmentasyon maskesi oluşturulur (Lazarow vd., 2020). Panoptic FPN mimarisi, bu yapının üzerine semantik segmentasyon katmanı entegre edilerek hem sayılabilen hem de sayılamayan nesnelere tek bir panoptik haritada gösterimini mümkün kılar (Kirillov et al., 2019).

Google tarafından geliştirilen DeepLab mimarisi, özellikle semantik segmentasyon için tasarlanmıştır. Panoptic DeepLab ise, bu mimarinin panoptik segmentasyona uygun hale getirilmiş versiyonudur (Cheng vd., 2020). Bu model, semantik ve örnek segmentasyon dallarını aynı ağ içerisinde birleştirerek panoptik bir çıktı üretir. Panoptic DeepLab, farklı seviyelerdeki katman çıktılarından faydalanarak hem detaylı sınıf ayrımı hem de nesne temelli ayrım sağlar.

Panoptik segmentasyonun başarımı, genellikle Panoptic Quality (PQ) ve Segmentation Quality (SQ) metrikleri ile değerlendirilir. PQ, hem sayılabilen hem de sayılamayan nesnelere için yapılan tahminlerin doğruluğunu ölçerken; SQ yalnızca sayılamayan nesnelere semantik doğruluğunu analiz eder. Bu metrikler, modelin bir görüntüdeki nesne sınırlarını ve sınıflarını ne kadar doğru tespit ettiğini ortaya koyar (Liu vd., 2020).

Panoptik segmentasyon, çok sayıda alanda yaygın şekilde kullanılmaya başlanmıştır. Otonom sürüş sistemlerinde, sahne algılamasının daha detaylı yapılabilmesi sayesinde karar verme sistemleri daha güvenilir hale gelir. Örneğin, yol yüzeyi, yayalar, diğer araçlar ve çevresel nesnelere, ayrı ayrı sınıflandırılıp konumlandırılarak daha isabetli yönlendirme yapılabilir. Bu amaçla, LiDAR, kamera ve radar gibi sensörlerden elde edilen veriler panoptik segmentasyonla işlenir ve planlama modüllerine aktarılır (Kirillov vd., 2019).


Benzer şekilde, insansız hava araçları ile yapılan uzaktan algılama çalışmalarında da panoptik segmentasyon, yüksek çözünürlüklü görüntülerde sahne bileşenlerini ayırt etmede büyük kolaylık sağlamaktadır. Özellikle şehir planlama, tarım, biyoloji, tıbbi görüntüleme ve askeri uygulamalarda panoptik segmentasyon modelleriyle yapılan analizler giderek yaygınlaşmaktadır (Sun vd., 2020).

Bununla birlikte, panoptik segmentasyonun uygulanmasında bazı zorluklar da vardır. Küçük nesnelere algılanması, görüntüdeki bozulmalar, sahne karmaşıklığı, değişken hava koşulları gibi etkenler, model performansını olumsuz etkileyebilir. Bu nedenle, bu zorluklara yönelik çözümler geliştirilmesi ve modellerin yeni uygulama alanlarına entegre edilmesi, alanın gelişimine önemli katkı sağlayacaktır.

Sonuç olarak, panoptik segmentasyon modellerinin sağladığı bütünsel yaklaşım, farklı türdeki nesnelere aynı çatı altında sınıflandırma ve ayırt etme imkânı sunarak bilgisayarla görme alanındaki birçok uygulamaya ileri düzey katkılar sağlamaktadır.

Panoptik segmentasyon, hem semantik hem de örnek tabanlı segmentasyonun güçlü yönlerini birleştirerek, sahnedeki her pikselin hem bir kategoriye hem de bir örneğe ait olacak şekilde etiketlenmesini mümkün kılar. Bu bütünsel yapı sayesinde, görüntü analizinde daha tutarlı, detaylı ve anlamlı sonuçlar elde edilebilmektedir. Bu durum, özellikle kentsel analiz, otonom sürüş sistemleri ve akıllı şehir uygulamaları gibi yüksek doğruluk gerektiren alanlarda kritik önem taşımaktadır.

Şekil 5.3'te, bu segmentasyon türlerinin farkını görsel olarak ortaya koyan bir örnek gösterilmiştir. Aynı sahne üzerinden oluşturulan çıktılar, sırasıyla semantik segmentasyon, örnek tabanlı segmentasyon ve panoptik segmentasyonu temsil etmektedir. Semantik segmentasyonda nesnelere yalnızca ait oldukları sınıfa göre etiketlenmişken, örnek tabanlı segmentasyonda aynı sınıfa ait farklı nesnelere birbirinden ayırt edilebilmiştir. Panoptik segmentasyon ise bu iki yaklaşımı bir araya getirerek hem sınıf bilgisini hem de nesne kimliğini aynı anda sağlayarak sahne hakkında daha kapsamlı bir analiz sunmuştur. Böylelikle, nesne düzeyinde detaylandırılmış ve sahne bütünlüğü korunmuş bir çıktı elde edilmiştir. Görsel, panoptik segmentasyonun ne denli kapsamlı ve güçlü bir yapı sunduğunu somut biçimde ortaya koymaktadır.



**Şekil 5.3: Aynı sahneye ait farklı segmentasyon türlerinin çıktıları: (a) girdi görüntüsü; (b) semantik segmentasyon; (c) örnek segmentasyon; (d) panoptik segmentasyon**

**Kaynak:** Kirillov vd., 2019

#### 5.4. Sıfır Atış Segmentasyon

Geleneksel segmentasyon yöntemleri, nesnelerin doğru bir şekilde sınıflandırılabilmesi için her bir sınıfa ait çok sayıda etiketlenmiş örneğe ihtiyaç duyar. Ancak bu durum, büyük veri kümeleri oluşturma ve bu verileri elle etiketleme süreçlerinde ciddi zaman ve maliyet yükü doğurur. Sıfır atışlı segmentasyon (zero-shot segmentation) ise bu sınırlamaları aşmayı hedefleyen yenilikçi bir yaklaşımdır. Bu yöntem, modelin eğitim aşamasında hiç karşılaşmadığı nesne sınıflarını, test aşamasında yalnızca tanımsal bilgiye dayanarak doğru biçimde tanıyıp segmentleyebilmesini sağlar (Zhou vd., 2022). Temel amacı, yalnızca görsel olarak öğrenilmiş sınıflarla sınırlı kalmadan, kavramsal veya dilsel olarak tanımlanabilen "görülmemiş" nesnelere de başarılı şekilde ayrıştırabilmektir. Bu bağlamda, segmentasyon süreci yalnızca görüntü verisine değil, aynı zamanda metin açıklamaları, kategori etiketleri ve sınıflar arası semantik benzerlikler gibi ek bilgi kaynaklarına da dayanmaktadır (Xian, Schiele ve Akata, 2019).

Sıfır atış segmentasyon yöntemleri genellikle görsel ve dilsel temsilleri aynı vektör uzayına yansıtan modeller üzerine kuruludur. Görüntülerden elde edilen görsel özellikler, kelime gömme yöntemleri (word embeddings) ya da büyük ölçekli dil modelleri aracılığıyla üretilen semantik temsillerle eşleştirilir. Bu eşleştirme sayesinde model, daha önce hiç karşılaşmadığı bir sınıfı yalnızca metinsel tanımı üzerinden tanıyabilir ve bu sınıfa ait bölgeyi doğru şekilde tanımlayabilir, segmentasyon işlemi yapabilir. Sıfır atış segmentasyonu bu özelliğiyle, doğal dil işleme ve görsel analiz tekniklerini bir araya getirerek hem metin hem de görsel veriyi birlikte değerlendirebilen sistemlerin geliştirilmesine olanak tanır.

Teknik olarak sıfır atış segmentasyonu, görsel özelliklerin çıkarılması (örneğin, CNN ya da Vision Transformer gibi derin öğrenme mimarileri) ve bu özelliklerin semantik uzayla eşleştirilmesi (örneğin, CLIP, DeViSE gibi modeller aracılığıyla) olmak üzere iki temel bileşene dayanır. Böylece sistem, yalnızca sınıf tanımına dayanarak piksellerin ait olduğu kategorileri tahmin edebilir. Bu yaklaşım, sıfır atışlı öğrenmenin temelini oluşturan "görülen" ve "görülmemiş" sınıflar arasındaki ayrım üzerine kuruludur.

Sıfır atış modelleri, bir nesne sınıfının görsel özelliklerinden çok, kavramsal tanımına dayanarak segmentasyon gerçekleştirir. Bu yönüyle, açık sınıf (open-vocabulary)

segmentasyon ihtiyaçlarına güçlü bir çözüm sunar. Eğitim sırasında yalnızca belirli sınıflarla çalışsa bile, test aşamasında daha önce hiç görülmemiş kavramlara da yanıt verebilir. Böylece, sınıf çeşitliliğinin yüksek olduğu veya sık değişen ortamlarda önemli avantajlar sağlar.


Az temsil edilen ya da nadir görülen nesnelerin segmentasyonu gereken birçok alanda etkili biçimde kullanılmaktadır. Özellikle tıbbi görüntüleme gibi, her sınıf için geniş çaplı etiketli veri toplamanın zor olduğu alanlarda yaygın olarak benimsenmiştir. Ayrıca uzaktan algılama, otonom araçlar, robotik ve güvenlik sistemleri gibi gerçek zamanlı karar verme gerektiren uygulamalarda, esnek ve dinamik tanıma yeteneği nedeniyle değerli bir çözümdür. Kentleşme izleme, akıllı şehir uygulamaları ve trafik yönetimi gibi alanlarda da sıfır atış modelleri etkin bir şekilde kullanılmaktadır. Özellikle sokak görüntülerinde, daha önce görülmemiş bir trafik levhası, tabela ya da yapı gibi yeni nesnelerin yalnızca metinsel açıklamalar yardımıyla tanımlanabilmesi, modelin güncellenmeden değişen sahnelere uyum sağlamasını kolaylaştırır. Bu tür durumlarda, etiketlenmemiş veriler üzerinde sınıf tanımlı yapmadan segmentasyon ve nesne tespiti gerçekleştirebilen sıfır atış yaklaşımlar etkili bir çözüm sunar. Bu doğrultuda geliştirilen bir çalışmada, sokak görünümüne ait panoramik görüntüler üzerinde sıfır atış nesne algılama ve segmentasyon uygulamaları gerçekleştirilmiştir (Tilki, Kaplan & Zengin, 2024).

Son yıllarda yapılan araştırmalar, sıfır atış modellerin başarımını artırmak amacıyla görsel-dil temelli temel modellerin kullanımını yaygınlaştırmıştır. Özellikle CLIP ve OWL-ViT gibi modeller, görüntü ve metin arasında güçlü semantik bağlar kurarak, önceden etiketlenmemiş nesnelere yüksek doğrulukla sınıflandırma ve segmentleme kapasitesine sahiptir (Radford vd., 2021). Sıfır atış modellerinin en önemli avantajları arasında, etiketleme maliyetini azaltması, modelin esnekliğini artırması ve yeni sınıflara adaptasyon sürecini kolaylaştırması yer alır. Bununla birlikte, bu yaklaşım bazı zorlukları da beraberinde getirir. Özellikle görülmeyen sınıfların semantik olarak doğru temsil edilmesi her zaman mümkün olmayabilir. Bu da sınıflar arası ayrımın bulanıklaşmasına ve segmentasyon doğruluğunun düşmesine yol açabilir. Bu nedenle, gelecekte sıfır atış modellerinin başarımını artırmaya yönelik olarak semantik temsillerin zenginleştirilmesi ve görsel-dil eşleşmelerinin hassaslaştırılması yönünde çalışmalar yapılmaktadır (Stegmüller et al., 2024).

#### 5.4.1. Segment Anything Model (SAM)

Sıfır atırlı segmentasyon yaklaşımının uygulamada etkili biçimde kullanılabilmesini mümkün kılan modellerden biri, Meta AI tarafından geliştirilen Segment Anything Model (SAM)'dir. SAM, kullanıcıdan gelen sınırlayıcı kutular, metin girdileri veya belirli nokta seçimleri gibi farklı istem türlerine yanıt verebilen, etkileşimli ve genel amaçlı bir görüntü segmentasyon modelidir (Kirillov et al., 2023). Modelin en dikkat çekici özelliđi, herhangi bir nesneyi sınıf etiketi gerekmeden segmentleyebilmesidir. Bu özelliđi sayesinde SAM, sınıf bağımsız (class-agnostic) olarak çalışır ve sıfır atırlı segmentasyon görevlerine doğrudan uygulanabilir hale gelir. Model, yaklaşık 11 milyon görüntü ve 1 milyar segment içeren büyük ölçekli SA-1B veri kümesi üzerinde eğitilmiştir. Bu geniş veri kümesi sayesinde SAM, farklı sahne ve nesne türlerinde yüksek genelleme yeteneđi göstererek etkili segmentasyon sonuçları sunabilmektedir. Şekil 5.4'te veri kümesindeki örnek görüntüler verilmiştir.

SAM, görüntü kodlayıcı (image encoder), istem kodlayıcı (prompt encoder) ve maske tahminleyici (mask decoder) olmak üzere üç temel bileşene sahip bir mimari kullanır. Görüntü kodlayıcısı genellikle görüntü transformatörü (ViT) mimarisi üzerine kuruludur ve giriş görüntüsünden görsel öznitelikleri çıkarır (Dosovitskiy vd., 2020). ViT, CNN modellerine alternatif olarak ortaya çıkmıştır. CNN modelleri piksel dizilerini kullanırken, ViT ise görüntüleri sabit boyutlu ufak parçalara böler. İstem kodlayıcı, kullanıcı tarafından sağlanan girişleri, örneđin bir nokta veya dikdörtgen kutu gibi yönlendirmeleri anlamlandırır. Maske tahminleyici ise bu iki bileşenden gelen bilgileri birleştirerek her bir isteme karşılık gelen segmentasyon maskesini üretir. Bu birleşik yapı, SAM'in daha önce tanımlanmamış sınıflara ait nesnelere başarılı şekilde segmentasyon yapabilmesini sağlar.



**Şekil 5.4: SAM veri seti örnek görüntüleri**

**Kaynak:** Kirillov vd., 2023


SAM modeli, yalnızca geleneksel segmentasyon görevlerinde değil, aynı zamanda açık-küme segmentasyonu ve sınıf etiketi bulunmayan durumlarda da kullanılabilir. Model, farklı ölçeklerdeki nesnelere algılama, karmaşık arka planları ayırt etme ve kullanıcıdan gelen yönlendirmelere hızlı şekilde yanıt verme gibi avantajlar sunar.

#### **5.4.2. Segment Anything Model 2 (SAM 2)**

SAM modelinin geliştirilmiş bir versiyonu olan SAM 2, segmentasyon doğruluğunu artırmak ve daha karmaşık sahnelerde daha esnek çözümler sunmak amacıyla Meta AI tarafından önerilmiştir (Ravi vd., 2024). SAM 2, daha fazla sayıda kullanıcı istemini (prompt) aynı anda işleyebilme kapasitesine sahiptir. Bu sayede, bir görüntüdeki çoklu nesnelere eşzamanlı olarak daha ayrıntılı ve doğru şekilde segmentleyebilir. SAM 2'nin önemli katkılarından biri, küçük nesnelere tespit etmedeki başarısıdır. Görsel sahnelerde özellikle boyut bakımından küçük ancak semantik olarak önemli nesnelere doğru şekilde ayrıştırılması, geleneksel segmentasyon modelleri için önemli bir zorluk teşkil etmektedir. SAM 2, bu zorluğu yüksek çözünürlüklü çıktı üretimi ve iyileştirilmiş maske üretim mekanizmasıyla aşmaktadır.

Model, önceki sürümde olduğu gibi görüntü kodlayıcı, istem kodlayıcı ve maske tahminleyici bileşenlerinden oluşmakla birlikte, bu modüllerin yapısal olarak daha optimize edilmiş versiyonlarını içermektedir. SAM 2, istemlere verdiği tepkiler açısından daha tutarlı sonuçlar üretebilmekte ve kullanıcı tarafından verilen farklı

türdeki yönlendirmelere (örneğin nokta, kutu, metin açıklaması) daha duyarlı hale getirilmiştir. 2024 yılında yapılan kapsamlı bir çalışmada, SAM 2'nin büyük boyutlu görüntülerde ve karmaşık sahnelerde, özellikle de detay seviyesi yüksek olan kentsel analiz, biyomedikal görüntüleme, güvenlik sistemleri uygulamalarında SAM'e kıyasla daha yüksek doğruluk ve tutarlılık göstermiştir. Ayrıca SAM 2'nin, sıfır atışlı segmentasyon problemlerinde de güçlü performans sergileyerek önceden tanımlanmamış sınıflara ait nesnelere segmentleme becerisini artırdığı görülmektedir. SAM 2 modelinin eğitiminde kullanılan veri seti görüntüsünden örnek görseller Şekil 5.5'te gösterilmiştir.



**Şekil 5.5: SAM 2 veri seti örnek görüntüleri**

**Kaynak:** Ravi vd., 2024

### **5.5. Değişim Tespiti Yöntemleri**

Değişim tespiti, belirli bir nesne ya da olayın farklı zamanlardaki durumları arasındaki farklılıkları ortaya koymayı amaçlayan bir analiz sürecidir (Singh, 1989). Bu süreç, özellikle uzaktan algılama alanında uzun yıllardır önemli bir araştırma konusu olmuş ve özellikle son on yıllarda kapsamlı çalışmalarla ele alınmıştır. Uydu görüntüleri ve hava fotoğrafları gibi çok zamanlı uzaktan algılama verileri, belirli bir bölgedeki arazi örtüsü ve arazi kullanımı değişimlerinin belirlenmesine olanak tanıyan zengin bilgiler sunmaktadır. Bu durum, kentsel planlama, çevresel izleme, tarımsal analiz, afet değerlendirme ve harita güncelleme gibi pek çok uygulama açısından kritik öneme sahiptir.

Günümüzde, yer gözlem teknolojilerinde yaşanan ilerlemeler sayesinde spektral, mekânsal ve zamansal çözünürlüğü yüksek büyük hacimli veriler erişilebilir hale gelmiştir. Ancak bu gelişmeler, değişim tespiti tekniklerinden daha fazla hassasiyet, doğruluk ve otomasyon talep edilmesine de neden olmuştur. Özellikle daha yüksek çözünürlüklü görüntülerle çalışırken karşılaşılan analiz zorluklarını aşmak için farklı yöntemler geliştirilmiştir. Bu yöntemler, genel olarak geleneksel ve yapay zeka tabanlı yaklaşımlar olmak üzere iki ana kategori altında incelenebilir (Shi vd., 2020).

### **5.5.1. Geleneksel Değişim Tespiti Yöntemleri**

Geleneksel değişim tespiti yöntemleri, özellikle uzaktan algılama verilerinin yaygınlaşmasıyla birlikte uzun yıllardır çeşitli uygulamalarda kullanılmaktadır. Bu yöntemler, genellikle sınırlı sayıda bant içeren çok zamanlı (multi-temporal) uydu veya hava görüntüleri üzerinde basit matematiksel ve istatistiksel işlemler yapılarak sahadaki değişiklikleri belirleme esasına dayanır. Histogram temelli karşılaştırma gibi istatistiksel metotlar, özellikle tarımsal alan değişim tespiti gibi uygulamalarda yaygın olarak kullanılmaktadır (Tilki ve Zengin, 2021). Günümüzde halen birçok uygulamada ilk adım olarak tercih edilen bu yaklaşımlar, temel olarak piksel düzeyinde karşılaştırmalara dayanmakta ve çoğu zaman denetimsiz biçimde uygulanmaktadır (Cheng vd., 2024).

İlk ve en temel yaklaşımlardan biri görsel analizdir. Bu yöntemde, farklı zamanlarda elde edilen görüntüler uzman kişiler tarafından manuel olarak karşılaştırılır ve değişim haritası bu yorumlar doğrultusunda oluşturulur. Yüksek doğruluk sunması bakımından güçlü bir yöntem olsa da, zaman alıcı olması ve kullanıcıya bağlı olarak subjektiflik taşıması nedeniyle büyük ölçekli çalışmalarda sınırlı kalmaktadır.

Bir diğer yaygın yöntem grubu ise cebirsel yöntemlerdir. Bu yöntemlerde çok zamanlı görüntüler üzerinde doğrudan matematiksel işlemler uygulanarak değişim bölgeleri ortaya çıkarılır. Görüntü farkı alma (image differencing), görüntü oranlama (image ratioing), değişim vektör analizi ve temel bileşenler analizi bu gruba dahil edilebilir. Bu tür işlemler, görüntüler arasındaki spektral farklılıkları vurgulayarak değişimin yoğunluğunu ve yönünü ortaya koyabilir (Coppin vd., 2004). Ancak bu tekniklerin başarısı, görüntülerin aynı geometrik düzlemde hizalanmış olmasına ve atmosferik koşulların benzerliğine oldukça bağlıdır.

Sınıflandırma tabanlı yöntemlerde ise her bir görüntü ayrı ayrı sınıflandırılır ve bu sınıflandırma sonuçları karşılaştırılarak değişiklik bölgeleri belirlenir. Bu yaklaşımda, ya post-sınıflandırma karşılaştırması yapılır ya da çok zamanlı görüntü verileri aynı anda işlenerek doğrudan çoklu tarihli sınıflandırma gerçekleştirilir. Tematik doğruluk açısından güçlü sonuçlar sunabilse de, her iki zamanda yapılan sınıflandırmalardaki hata payı doğrudan değişim tespiti sonucuna yansiyabildiğinden dikkatli değerlendirme gerektirir (Hussain vd., 2013).

Bazı gelişmiş yöntemler ise fiziksel modellere dayalı analizler sunar. Örneğin, Li-Strahler yansıtma modeli, spektral karışım modelleri veya biyofiziksel parametre çıkarım yöntemleri kullanılarak, çok zamanlı görüntülerin yansıtma değerleri fiziksel parametrelere dönüştürülür ve bu parametreler üzerinden değişim analizi yapılır. Bu yöntemler daha sezgisel sonuçlar sağlayabilir; ancak oldukça karmaşık yapıları nedeniyle geniş veri kümelerine uygulanmaları zordur ve işlem süreleri uzundur (Chen vd., 2012).

Son olarak, bilgi tabanlı yöntemler, mekânsal istatistiklere dayalı analizler, coğra bilgi sistemleri ile entegre edilen hibrit yaklaşımlar ve nesne düzeyli değişim analizleri gibi çeşitli alternatif yöntemler de literatürde yer almaktadır. Bu tür yöntemler, özellikle piksellerden ziyade nesnelerin analiz edilmesini temel aldığından, gürültüye karşı daha dayanıklı ve sahne içeriğini daha anlamlı şekilde temsil eden değişim haritaları üretme potansiyeline sahiptir.

Ancak geleneksel yöntemlerin çoğu, görüntü çözünürlüğünün artması, sahne karmaşıklığının yükselmesi ve büyük hacimli verilerin yaygınlaşmasıyla birlikte performans açısından sınırlı kalmaya başlamıştır. Bu nedenlerle, son yıllarda yapay zekâ tabanlı yöntemlere olan ilgi artmış ve bu alanda daha esnek, öğrenebilen ve yüksek doğrulukta sonuçlar sunabilen modeller geliştirilmiştir (Cheng vd., 2024).

### **5.5.2. Yapay Zeka Tabanlı Değişim Tespiti Yöntemleri**

Son yıllarda yapay zekâ, özellikle derin öğrenme temelli yaklaşımlar, değişim tespiti alanında büyük bir dönüşüm yaratmıştır. Geleneksel yöntemlerin sınırlı doğruluk kapasitesi, manuel parametre ayarlama gereksinimi ve yüksek karmaşıklığa sahip sahnelerde yetersiz kalması gibi nedenlerle, daha otomatik ve öğrenebilen sistemlere duyulan ihtiyaç artmıştır. Bu noktada yapay zekâ tabanlı yöntemler, görüntü

verilerinden anlamlı özellikleri otomatik olarak öğrenebilme kapasiteleri sayesinde öne çıkmaktadır.

Yapay zeka ile entegre edilmiş değişim tespiti yöntemleri, doğruluk ve otomasyon düzeyini önemli ölçüde artırma potansiyeline sahiptir. Yapay zekanın güçlü modelleme ve öğrenme yetenekleri sayesinde, görüntüdeki nesnelere ile gerçek dünyadaki coğrafi karşılıkları arasındaki ilişkiler daha tutarlı biçimde öğrenilebilir hale gelmiştir (Zhang ve Lu, 2019). Bu sayede, özellikle gerçek değişikliklerin daha doğru ve etkili biçimde tespit edilmesi sağlanmaktadır. Yapay zeka tabanlı yaklaşımlar, çok zamanlı verilerdeki mekânsal bağlam bilgilerini öğrenerek, bu bağlamdan türetilmiş yüksek düzeyli özellik temsillerini kullanmakta ve bu temsiller değişim tespiti görevlerinde daha dayanıklı sonuçlar sunmaktadır. Bu alandaki mevcut literatürler çoğunlukla yapay zekâ algoritmalarının genel gelişimine ya da belirli uzaktan algılama uygulamalarına odaklanmaktadır (Ma vd., 2019).

Yapay zeka tabanlı değişim tespiti yaklaşımları, özellikle uzaktan algılama verilerinde mekânsal, zamansal ve spektral bağlamları bir arada analiz edebilme becerileriyle dikkat çekmektedir. Bu yöntemlerde, CNN, görüntü kodlayıcısı (VIT) ve RNN gibi derin öğrenme mimarileri kullanılarak görüntülerden çok katmanlı temsil özellikleri çıkarılmakta ve bu temsiller üzerinden değişiklik analizi yapılmaktadır (Zhan vd., 2017). Bu yüksek seviyeli temsiller sayesinde, sahnedeki karmaşık yapılar, gürültü ve görüntü bozulmaları gibi sorunlar daha etkili şekilde yönetilebilmektedir.

Özellikle sokak görünümü ve panoramik görüntüler gibi detaylı sahne içeriğine sahip ve çeşitli nesne türlerini barındıran görüntülerde, geleneksel yöntemlerin ayırt edici yetenekleri sınırlı kalmaktadır. Bu tür görüntülerde; bina cephelerindeki değişiklikler, yeni trafik işaretleri, yol genişletmeleri ya da yeşil alan kayıpları gibi ayrıntılı değişikliklerin tespiti oldukça önemlidir. Derin öğrenme temelli yöntemler, yüksek çözünürlüklü bu görüntülerde çok küçük ölçekli değişimleri bile yakalayarak, şehir planlama ve kentsel izleme gibi uygulamalarda değerli bilgiler sunmaktadır (Zhang vd., 2020). Ayrıca panoramik görüntüler, sahneyi geniş bir açıdan gözlemleyebilme imkânı sunduğundan, değişim tespiti görevlerinde daha bütüncül ve mekânsal olarak tutarlı analizler yapılmasına olanak tanır.

Yapay zeka tabanlı yöntemlerin öne çıkan bir diğer özelliği ise etiketli veri ihtiyacını azaltmaya yönelik yeni yaklaşımların geliştirilmesidir. Özellikle öz denetimli (self-

supervised) ve yarı denetimli (semi-supervised) öğrenme teknikleri sayesinde, az sayıda etiketli görüntüyle bile yüksek doğrulukta değişim haritaları üretilebilmektedir. Öz denetimli öğrenme, modelin dışarıdan etiketli veri gereksinimi olmadan, verinin içsel yapısından yararlanarak öğrenmesini sağlarken; yarı denetimli öğrenme, az miktarda etiketli veri ile çok miktarda etiketsiz veriyi birleştirerek daha güçlü bir öğrenme gerçekleştirmeyi amaçlar. Bu durum, etiketli veri toplamanın zor veya maliyetli olduğu şehir ölçekli uygulamalarda büyük avantaj sağlamaktadır.

Yapay zeka tabanlı değişim tespiti çalışmalarında kullanılan derin öğrenme mimarileri genellikle iki görüntü arasındaki farklılıkları yakalamaya yönelik olarak tasarlanmıştır. Bu amaçla en yaygın kullanılan yapılardan biri, aynı sahnenin farklı zamanlarda alınmış görüntülerini eş zamanlı olarak işleyen Siyam ağ (Siamese Neural Networks) yapılarıdır (Zhou vd., 2023). Bu ağlar, iki görüntüden çıkarılan öznelikleri karşılaştırarak değişiklik bölgelerini tespit etmeye çalışır. Özellikle Siyam U-Net, hem düşük hem yüksek düzeydeki özellikleri birleştirme kapasitesi sayesinde ayrıntılı değişim haritaları üretme konusunda başarılı sonuçlar vermektedir. Buna ek olarak, Tam Konvolüsyonlu Erken Birleşim (Fully Convolutional Early Fusion) modeli gibi yapılar, görüntü çiftlerini doğrudan birleştirerek tek bir ağ üzerinden değişim tespiti yapmayı hedefler.

Son yıllarda ise Mekansal-Zamansal Dikkat Ağı (Spatial–Temporal Attention Network) gibi dikkat (attention) tabanlı modeller, zamansal ve mekânsal bağlam bilgisini daha etkin şekilde kullanabilmeleri sayesinde ön plana çıkmıştır. Bu tür ağlar, değişiklikleri yalnızca pikseller düzeyinde değil, aynı zamanda bağlamsal ilişkiler üzerinden de değerlendirebildikleri için daha doğru sonuçlar elde edilmesini sağlamaktadır. Bu mimarilerin her biri, görüntü çözünürlüğüne, sahne karmaşıklığına ve uygulama alanına göre farklı avantajlar sunmakta ve değişim tespiti görevlerinin başarımını artırmaktadır (Peng, Zhang ve Guan, 2019).

## ALTINCI BÖLÜM

### DENEYSEL ÇALIŞMA

Bu bölümde, önerilen değişim tespiti yaklaşımının uygulanma süreci, kullanılan veri seti, ön işleme adımları ve deneysel analizler ayrıntılı biçimde sunulmaktadır. Çalışma kapsamında, farklı yıllarda aynı konumdan elde edilmiş panoramik sokak görüntüleri üzerinde çeşitli dönüşüm ve segmentasyon işlemleri gerçekleştirilmiş, ardından bu görüntülerden elde edilen bilgiler derin öğrenme tabanlı değişim tespiti modeline girdi olarak kullanılmıştır. Deneysel süreç boyunca hem görsel değerlendirme hem de sayısal analiz yöntemleri kullanılarak modelin başarımı farklı açılardan incelenmiştir.

#### 6.1 Veri seti ve Ön İşlem

Bu çalışmada kullanılan veri seti, AnkaGeo Coğrafi Bilgi Teknolojileri firması tarafından, araç üzerine monte edilmiş geniş açılı kameralar aracılığıyla elde edilmiştir (AnkaGeo Coğrafi Bilgi Teknolojileri, 2021). Veri seti, 2020 ve 2023 yıllarında Kahramanmaraş ilinin Elbistan ilçesinde aynı coğrafi konumlardan çekilen panoramik sokak görüntülerinden oluşmaktadır.

Her biri 8192×4096 piksel çözünürlüğünde olan bu yüksek boyutlu görüntülerden, her yıl için yaklaşık 2000 adet olmak üzere toplamda 4000 panoramik görüntü elde edilmiştir. Yüksek çözünürlükleri sayesinde, sahnelerdeki küçük nesnelerin ve detaylı kentsel yapıların analizine olanak tanımaktadır.

Veri seti, şehir dokusunu oluşturan bina, yeşil alan ve trafik işaretleri gibi temel unsurlarda zaman içinde meydana gelen değişimlerin tespitini amaçlayan derin öğrenme tabanlı yöntemlerin test edilmesi açısından büyük önem taşımaktadır.

Panoramik formatta elde edilen bu görüntüler, geniş görüş açısı sunmaları sebebiyle sahnenin tamamını kapsamlı şekilde yansıtmakta; ancak bu avantajın yanı sıra yapısal bozulmalar ve segmentasyon zorlukları gibi bazı teknik sınırlamaları da beraberinde getirmektedir. Bu nedenle, görüntüler üzerinde ön işlem adımlarının uygulanması gerekliliği doğmuştur. Veri setinde 2020 ve 2023 yılına ait örnek panoramik görüntü çiftleri Şekil 6.1’de ve Şekil 6.2’de verilmiştir.



(a)



(b)

**Şekil 6.1: Veri setindeki panoramik görüntü çifti örnek-1: (a) 2020 yılına ait örnek (b) 2023 yılına ait örnek.**



**Şekil 6.2: Veri setindeki panoramik görüntü çifti örnek-2: (a) 2020 yılına ait örnek (b) 2023 yılına ait örnek.**

Panoramik görüntüler geniş alanları tek bir karede sunabilmeleri açısından avantaj sağlasa da, görüntü işleme ve analiz süreçlerinde bazı yapısal zorluklar doğurmaktadır. Özellikle görüntü eğrilikleri, perspektif bozulmaları, uzak mesafedeki nesnelerin çözünürlük kaybı, küçük nesnelerin algılanmasındaki zorluklar ve segmentasyon hataları gibi problemler, bu tür verilerin doğrudan işlenmesini güçleştirmektedir. Ayrıca, görüntülerdeki nesnelerin belirli bir perspektiften görünmemesi ya da görüntüye olan açı farklılıkları, derin öğrenme tabanlı segmentasyon ve değişim tespiti yöntemlerinde performans kaybına neden olabilmektedir.

Bu zorlukları aşmak ve daha sağlıklı nesne ayrımı yapabilmek amacıyla, panoramik görüntüler sokak görünümüne dönüştürülmüştür. Böylece sahneler daha dar bir görüş açısıyla, doğal perspektif özellikleri korunarak yeniden elde edilmiş ve görüntü üzerindeki nesnelerin daha net biçimde analiz edilebilmesi sağlanmıştır.

Panoramik görüntülerin analizinde karşılaşılan yapısal zorlukları azaltmak amacıyla bu çalışmada, panoramik formatta elde edilen görüntüler sokak görünümüne dönüştürülmüştür. Bu dönüşüm sürecinde perspektif projeksiyon ve eşkenar dörtgen projeksiyon modelleri olmak üzere iki farklı projeksiyon modeli test edilmiştir. Perspektif projeksiyon modelinde, panoramik görüntü belirli bir görüş açısı (örneğin 90°) üzerinden yeniden örneklenerek, insan gözünün doğal bakış açısına yakın bir sokak görünümü elde edilmesi amaçlanmıştır. Bu yöntem sayesinde sahnedeki nesneler daha gerçekçi bir perspektifle sunulmuş, ancak özellikle yatay düzlemde meydana gelen görüntü kayıpları nedeniyle bazı önemli detaylar eksik kalmıştır.

Diğer bir model olan eşkenar dörtgen projeksiyon modeli ise, sahneyi küresel bir yapı üzerinden dört farklı düzleme (ön, arka, sağ, sol) yansıtarak daha dengeli bir alan kapsama sağlamıştır. Bu yöntemde elde edilen sokak görüntüleri, yalnızca belirli bir yönü değil, sahnenin tüm çevresini daha bütünlüklü şekilde temsil etmiştir. Ayrıca, eşkenar dörtgen projeksiyon yöntemiyle elde edilen görsellerde segmentasyon açısından daha tutarlı sonuçlar alınmış ve uzak nesnelerin detayları daha net bir biçimde korunmuştur.


Bu iki projeksiyon modelinin temel farkı, sahneyi sunma biçimlerindeki geometrik yaklaşımdan kaynaklanmaktadır. Perspektif projeksiyon modeli, tek bir bakış açısı üzerinden görüntü oluşturduğu için sahnenin sadece sınırlı bir bölümünü detaylı şekilde sunabilirken, eşkenar dörtgen projeksiyon modeli aynı sahneyi dört ayrı yönlü düzleme yayarak daha geniş bir kapsama alanı sunmaktadır. Bu durum, eşkenar dörtgen projeksiyonda sahne içi nesnelerin eksiksiz şekilde yer almasını sağlarken, perspektif modelde belirli nesnelerin görüntü dışında kalmasına yol açabilmektedir. Öte yandan, perspektif projeksiyonun derinlik hissini daha güçlü biçimde yansıtması, insan bakışına daha yakın ve gerçekçi bir görünüm oluşturmasını mümkün kılmaktadır. Dolayısıyla, bu iki modelin kullanımı arasında tercih yapılırken, elde edilmek istenen görsel özellikler ve analiz amaçları belirleyici olmaktadır.

Her iki projeksiyon modeline ait dönüşüm sonuçları, Şekil 6.3'te Perspektif Projeksiyon Modeli ve Şekil 6.4'te Eşkenar Dörtgen Projeksiyon Modeli olmak üzere, ön, sağ, sol ve arka sokak görünümüne ait örnek görüntüler üzerinden karşılaştırmalı olarak sunulmuştur. Bu görseller incelendiğinde, özellikle sahne içerisindeki nesnelerin netliği, geometrik tutarlılığı ve görünürlük oranı açısından iki model arasında belirgin farklar olduğu gözlemlenmektedir. Görsellerde de açıkça görülebileceği üzere, eşkenar dörtgen projeksiyon modeli hem nesne tespiti hem de sonrasında uygulanan segmentasyon işlemleri açısından daha başarılı ve tutarlı sonuçlar üretmiştir. Bu başarı, sahne içindeki nesnelerin daha geniş bir açıyla ve daha dengeli bir şekilde yansıtılmasından kaynaklanmaktadır. Bu nedenle, sonraki aşamalarda gerçekleştirilen analizlerde, daha nitelikli görsel veri sunması sebebiyle eşkenar dörtgen projeksiyon modeli tercih edilmiştir.

Bu yöntemde, panoramik görüntülerin dört farklı düzleme yansıtılmasıyla elde edilen sokak görünümü, yalnızca iki boyutlu bir izdüşümden ibaret olmayıp, sanki sahnenin fiziksel olarak içine girilmiş gibi bir derinlik ve yön hissi yaratmaktadır. Her bir düzlem (ön, arka, sağ, sol) sahnenin farklı yönlerini temsil ettiğinden, elde edilen görüntüler yalnızca belirli bir açının değil, çevresel bağlamın tamamının analiz edilmesine olanak tanımaktadır. Bu çok yönlü görselleştirme sayesinde, özellikle binalar, yeşil alanlar ve trafik işaretleri gibi kentsel yapılar daha açık biçimde tanımlanabilir hâle gelmiş; böylece nesne ayrımı daha hassas şekilde yapılabilmektedir. Segmentasyon algoritmaları açısından bu durum oldukça kritiktir, çünkü girdi olarak kullanılan görsellerin kalitesi ve içerik zenginliği doğrudan çıktılarının doğruluğunu etkilemektedir. Elde edilen sokak görünümü, yalnızca tek bir yönü değil, sahnenin çeşitli yönlerden kavranmasını sağladığı için segmentasyon modelleri açısından hem veri çeşitliliği hem de anlamlılık bakımından güçlü bir kaynak oluşturmuştur.

Bu dönüşüm sürecinin etkileri, yalnızca segmentasyon aşamasıyla sınırlı kalmamış, aynı zamanda değişim tespiti sürecinde kullanılacak maskelerin üretim kalitesine de doğrudan katkı sağlamıştır. Dört yönlü yansıtma yaklaşımı sayesinde elde edilen daha dengeli ve detaylı görseller, derin öğrenme tabanlı analizlerde ihtiyaç duyulan sağlam temeli oluşturmuştur. Başka bir deyişle, panoramik görüntülerde sıkça karşılaşılan yapısal bozulmalar, geometrik dengesizlikler ve özellikle uzak mesafedeki nesnelerin düşük görünürlüğü gibi sorunlar, eşkenar dörtgen projeksiyonun sunduğu kapsayıcı görüş sayesinde büyük ölçüde giderilmiştir. Bu da hem segmentasyon hem de değişim


tespiti süreçlerinin daha güvenilir, daha kararlı ve daha doğru çıktılar üretmesini mümkün kılmıştır. Böylece, bu tez kapsamında gerçekleştirilen değişim tespiti süreci, her aşamada daha güvenilir ve doğru sonuçlar elde edilecek şekilde adım adım iyileştirilerek yapılandırılmıştır.




**Şekil 6.3: Perspektif projeksiyon modeli çıktıları: (a) panoramik görüntü, (b) ön sokak görüntüsü, (c) arka sokak görüntüsü, (d) sağ sokak görüntüsü, (e) sol sokak görüntüsü.**




(a)




(b)



(c)



(d)



(e)

**Şekil 6.4: Eşkenar dörtgen projeksiyon modeli çıktıları: (a) panoramik görüntü, (b) ön sokak görüntüsü, (c) arka sokak görüntüsü, (d) sağ sokak görüntüsü, (e) sol sokak görüntüsü.**

## 6.2. Değişim Tespiti Yöntemi

Bu çalışmada, panoramik sokak görüntülerine uygulanan derin öğrenme tabanlı değişim tespiti yöntemlerinin değerlendirilmesi amacıyla, farklı yıllarda aynı konumlardan elde edilmiş sokak görüntülerinden oluşan eşlenik görsel çiftleri kullanılmıştır. Veri setinde, 2020 ve 2023 yılları olmak üzere iki farklı yıla ait toplamda birçok panoramik görsel bulunsa da, segmentasyon işleminin manuel müdahale gerektirmesi ve hesaplama kaynaklarının sınırlı olması nedeniyle tüm görsel çiftleri üzerinde değişim analizi yapmak yerine, çeşitli değişim türlerini temsil eden üç farklı senaryo belirlenmiştir. Bu senaryolar; yeşil alanlarda azalma, yeni bina yapısı eklenmesi, trafik işaretlerinin ortadan kalkması, belirli sınıfların konumunun sabit kalması, görselde ilk kez beliren yeni nesne sınıfları ve karmaşık dönüşüm yapıları gibi farklı durumları kapsayacak şekilde seçilmiştir. Her bir senaryo, analizlerin farklı çevresel veya yapısal değişim türleri karşısındaki performansını gözlemlemek ve yöntemin genellenebilirliğini test etmek amacıyla kullanılmıştır. Senaryoların içerikleri aşağıda detaylı bir şekilde açıklanmıştır.

Senaryo 1: Görseldeki yeşil alanlarda azalma ve tabela sınıfında değişim gözlemlenmiştir. İlk yılda mevcut olan tabelaların ikinci yılda tamamen ortadan kalktığı bu senaryo, küçük ölçekli kentsel unsurların (örneğin tabelalar) zaman içinde kaldırılması veya yer değiştirmesi gibi nesne düzeyinde çevresel değişimleri temsil etmektedir. Ayrıca yeşil alanların azalması, bölgedeki doğal dokunun kısmen yapılaşmaya veya zemin düzenlemesine maruz kaldığını göstermektedir.

Senaryo 2: Yeşil alanlarda azalma ile yeni bir bina yapısının ortaya çıktığı senaryodur. Bu durumda, ilk yılda bulunmayan bina sınıfının ikinci yılda segmentasyon sonuçlarında tespit edilmesi, yeni yapılaşmayı ve fiziksel genişlemeyi temsil etmektedir. Yeşil alanların azalması ise bu yapısal artışın çevresel etkisini destekleyici niteliktedir. Bu senaryo, kentsel büyüme ve yapılaşma süreçlerinin izlenmesine yönelik örnek bir durumu göstermektedir.

Senaryo 3: Yeşil alan ve bina sınıflarının her ikisinde de azalma gözlemlenmiş, ayrıca trafik işareti sınıfı ikinci yılda tamamen ortadan kalkmıştır. Bu durum, sahnede çok yönlü bir değişimi temsil etmekte olup, hem doğal hem yapısal hem de işlevsel unsurlarda (trafik işaretleri gibi) dönüşüm yaşandığını göstermektedir. Bu senaryo,

kentsel alanlarda eş zamanlı farklı türde değişimlerin bir arada görülebildiği karmaşık dinamikleri örneklemektedir.

Bu üç senaryo birlikte değerlendirildiğinde, çalışma alanında kentsel değişimin farklı ölçek ve biçimlerde ortaya çıkabileceği görülmektedir. Yeşil alan kayıpları çevresel dönüşümü, yeni yapıların ortaya çıkışı yapısal gelişmeyi, küçük nesnelere (tabela ve trafik işaretleri gibi) değişimler ise kentsel yenilenmeyi temsil etmektedir. Böylece, önerilen sistem yalnızca tek bir değişim türünü değil, doğal, yapısal ve işlevsel dönüşümlerin tümünü bütüncül biçimde izleyebilen bir analiz yaklaşımı ortaya koymaktadır.

### **6.2.1. Segmentasyon İşlemleri**

Segmentasyon aşamasında, Panoptik Segmentasyon (Panoptic FPN) ve Meta AI tarafından geliştirilen Segment Anything Model 2 (SAM 2) ve yöntemleri kullanılmıştır. SAM 2, kullanıcıdan gelen yönlendirmelere dayalı olarak belirli nesne sınıflarını (“yeşil alan”, “bina”, “trafik işaretleri” gibi) otomatik şekilde maskelerle ayrıştırabilen, etkileşimli bir temel segmentasyon modelidir. Bu model, veri setinde manuel etiketleme gereksinimini ortadan kaldırarak segmentasyon sürecini hem zamansal hem de operasyonel açıdan verimli hâle getirmektedir. Bu çalışmada, kullanıcı tarafından görsel üzerine çizilen kutular (bounding box) aracılığıyla hedef nesne sınıfları tanımlanmış, ardından SAM 2 modeli bu kutulara odaklanarak ilgili bölgeleri segment etmiştir. Her bir sınıf, çıktıda özgün bir renkle kodlanarak görsel maske elde edilmiştir.

Panoptik segmentasyon modeli ise, etiketli veriye dayalı olarak sahnedeki tüm nesnelere hem semantik hem de örnek düzeyinde tanımlamayı hedeflemektedir. Bu yaklaşım, sahnenin bütünsel yapısını koruyarak nesnelere sınırlarını yüksek doğrulukta belirlemekte; aynı zamanda birden fazla nesne sınıfı tek bir segmentasyon çıktısında birleştirmektedir. Her iki modelin ürettiği renkli maskeler, değişim analizlerinde temel girdi olarak kullanılmış; SAM 2'nin açık uçlu, etkileşimli yapısı ile Panoptik segmentasyonun önceden tanımlı sınıf temelli yapısı karşılaştırmalı biçimde değerlendirilmiştir.

Her iki modelde de her bir sınıf, çıktıda özgün bir renkle kodlanarak görsel maske elde edilmiştir. Bu renkli maskeler, değişim analizlerinde temel girdi olarak kullanılmış ve farklı segmentasyon yaklaşımlarının karşılaştırılmasına olanak sağlamıştır.

Segmentasyon işlemleri sonucunda, her bir yıla ait görsel üzerinde istenilen sınıfların detaylı olarak ayrıştırılması sağlanmakta ve farklı yıllardaki aynı sahnelerin karşılaştırmalı analizine uygun altyapı oluşturulmaktadır. SAM 2 sayesinde sağlanan bu otomatik segmentasyon altyapısı, kullanıcı girişine dayalı olarak istenilen nesne gruplarının dinamik olarak takibini mümkün kılmış ve tez kapsamında segmentasyon doğruluğu ve genel kapsayıcılığı açısından yeterli performans göstermiştir.

Klasik segmentasyon yöntemleri ile karşılaştırıldığında, bu yaklaşımın önemli farklılıklar ve avantajlar sunduğu görülmektedir. Geleneksel yöntemlerde, kullanıcıdan her bir nesneyi piksel seviyesinde manuel olarak çizmesi beklenirken, SAM 2 tabanlı yaklaşımda yalnızca sınıf etiketi ve nesnenin yaklaşık konumunu belirten kutuların girilmesi yeterli olmaktadır. Bu durum, zaman açısından büyük bir tasarruf sağlarken, aynı zamanda kullanıcı hatalarının önüne geçmektedir. Kullanıcı tarafından tanımlanan sınıf isimleri, interaktif arayüz aracılığıyla SAM 2 modeline yönlendirilmiş ve model tarafından bu kutular doğrultusunda yüksek doğrulukta segmentasyon maskeleri oluşturulmuştur.

Ayrıca bu etkileşimli segmentasyon yaklaşımı, açık sınıf tanımlamalarını desteklemesi bakımından da avantaj sunmaktadır. Sabit bir sınıf listesiyle sınırlı kalmaksızın, çalışmanın özel ihtiyaçlarına göre belirlenen sınıf etiketleriyle segmentasyon yapılabilmüş; böylece sadece ilgili nesne gruplarına odaklanan bir analiz gerçekleştirilmiştir. Segmentasyon süreci boyunca yalnızca belirlenen kutulara odaklanıldığından, modelin gereksiz ya da yanlış bölgelere segmentasyon uygulamasının da önüne geçilmiştir.

SAM 2 sayesinde sağlanan bu otomatik segmentasyon altyapısı, kullanıcı girişine dayalı olarak istenilen nesne gruplarının dinamik olarak takibini mümkün kılmış ve tez kapsamında segmentasyon doğruluğu ve genel kapsayıcılığı açısından yeterli performans göstermiştir.

Sonuç olarak, SAM 2 tabanlı bu yarı-otomatik segmentasyon yapısı, geleneksel etiketleme süreçlerine kıyasla daha hızlı, esnek, kullanıcı kontrollü ve hataya kapalı

bir etiketleme süreci sunarak, deęişim tespiti alıřmalarına nemli bir katkı saęlamıřtır.

Segmentasyon iřlemlerinin ilk ıktılarından biri olarak, her bir nesneye ait blgenin yalnızca varlık bilgisine dayalı olarak ayrıldıęı ikili (binary) maskeler elde edilmiřtir. Bu maskeler, siyah (arka plan) ve beyaz (nesne) piksellerden oluřmakta olup, yalnızca nesnenin konumunu ve varlıęını temsil etmektedir. Ancak bu maskelerde sınıf bilgisi bulunmadıęı iin, sınıflar arası dnüşüm, zamansal örtüşme oranı veya yüzdelik deęişim analizi gibi semantik bilgiye dayalı iřlemlerde kullanılması mümkün deęildir. Bu nedenle ikili maskeler, yalnızca segmentasyonun nesne bazlı doęruluęunu grselleřtirmek amacıyla deęerlendirilmiř; deęişim tespiti sürecinin temel analiz ařamalarında kullanılmamıřtır. Bu baęlamda, analiz sürecinin devamında her bir nesnenin sınıf bilgisiyle birlikte gsterildięi renkli segmentasyon maskeleri temel alınmıřtır.

Ařaęıda yer alan řekil 6.7 'deki (a)–(f) grselleri, SAM 2 modeli kullanılarak gerekleřtirilen segmentasyon sürecinin adımlarını temsil etmektedir. Bu ařamalar, kullanıcının ynlendirmeleriyle belirli nesne gruplarına odaklanan segmentasyon sürecinin nasıl ilerledięini grsel olarak ortaya koymaktadır:

(a): Analiz sürecinin bařlangıcında kullanılan orijinal sokak grüntüsüdür. Bu grsel herhangi bir iřleme tabi tutulmamıř ham veriyi temsil etmektedir.


(b): SAM 2 modeli tarafından sahnedeki tm grsel blgelerin otomatik olarak segmentlere ayrıldıęı genel segmentasyon sonucudur. Bu ařamada, kullanıcı ynlendirmesi olmadan model tm nesneleri ayırır; ancak bu iřleminde hangi nesnenin hangi sınıfa ait olduęu bilgisi bulunmaz, sadece grsel btnlüklerine gre ayrılmıř maskeler gsterilir.

(c): Kullanıcı tarafından analiz edilmek istenen nesnelere belirlemek zere grüntü zerine izilmiř ynlendirme kutularının (bounding box) yer aldıęı adımdır. Bu kutular, SAM 2 modelinin yalnızca bu blgelere odaklanarak segmentasyon yapmasını saęlar.

(d): Kullanıcı tarafından tanımlanan kutular doęrultusunda elde edilen hedef odaklı segmentasyon sonucudur. Bu ařamada yalnızca belirli nesne grupları maskelenmiř ve grselden ayırılmıřtır.

(e): Belirli sınıf etiketleriyle eşleştirilen nesnelere ait renkli maske görüntüsüdür. Burada her sınıfa kullanıcı tarafından atanmış bir renk uygulanarak, farklı sınıfların görseldeki konumları açık şekilde vurgulanmıştır. Bu görsel, değişim analizi için temel girdi olarak kullanılır.

(f): Sadece kullanıcı tarafından seçilen sınıflara ait bölgelerin yer aldığı renkli fark haritasıdır. Arka plan siyah bırakılırken, hedef nesnelere ait bölgeler ayırt edici renklerle kodlanmıştır. Böylece segmentasyonun yalnızca ilgili sınıflar üzerinden görsel ayırım sağladığı açıkça ortaya konmaktadır.




**Şekil 6.5: SAM 2 segmentasyon sürecine ait görsel adımları: (a) girdi görüntüsü, (b) otomatik segmentasyon sonucu, (c) kullanıcı tarafından yapılan yönlendirme, (d) yönlendirme sonucu ssegmentasyon, (e) sınıflara özel oluşturulan segmentasyon, (f) nihai segmentasyon çıktısı.**

Bu çalışmada, SAM 2'nin yanı sıra SAM ve panoptik segmentasyon modelleri de uygulanmış ve iki yaklaşımın panoramik ile sokak görüntülerindeki performansları karşılaştırılmıştır. Panoptik segmentasyon, sahnedeki tüm nesnelere hem sınıf düzeyinde hem de örnek bazında ayırt ederek sahneyi bütüncül biçimde analiz edebilen bir yöntemdir. Bu kapsamda Panoptik FPN R-50 (1x), R-50 (3x) ve R-101 (3x) modelleri kullanılmış; modellerin panoramik ve bu görüntülerden türetilen dört yönlü sokak görüntülerindeki performansları incelenmiştir.

Veri setimizde, panoramik görüntülerdeki segmentasyon problemini yansıtan örnek 207 görüntü seçilmiştir. Bu görüntüler, panoramik yapının neden olduğu eğrilik ve perspektif bozulmaları nedeniyle bazı bölgelerde nesne sınırlarının algılanmasını güçleştirmekte; dolayısıyla panoptik segmentasyon modelleri için de sınırlı performans sergilenmektedir. Bu nedenle, aynı sahnelerin sokak görüntüsüne dönüştürülmüş halleri üzerinde yapılan testlerle, segment edilemeyen bölgelerin daha ayrıntılı biçimde ayrıştırılıp ayrıştırılmadığı analiz edilmiştir.

Panoptik, SAM ve SAM 2 modellerinden elde edilen çıktılar Şekil 6.6'da karşılaştırmalı olarak sunulmuştur. Görselde, panoramik görüntülerde sınırlı kalan nesne ayrımlarının sokak görüntülerinde belirgin biçimde daha net hale geldiği görülmektedir. Özellikle bina cepheleri, yeşil alanlar ve trafik işaretleri gibi ayrıntı düzeyi yüksek nesnelere, sokak görüntülerinde daha doğru biçimde tespit edilmiştir. Bu durum, panoramik görüntülerdeki küresel distorsiyonun azaltılmasının segmentasyon performansını doğrudan iyileştirdiğini göstermektedir.

Her modelin farklı görüntü türlerindeki ortalama segment sayısı ve işleme süresi karşılaştırmalı olarak Tablo 6.1'de verilmiştir. Bu süre ölçümleri, Google Colab ortamında NVIDIA A100 GPU kullanılarak gerçekleştirilmiştir.



**Şekil 6.6: Panoramik ve sokak görüntülerinde Panoptik, SAM ve SAM 2 modellerinin segmentasyon sonuçlarının görsel karşılaştırması.**

Sonuçlara göre, Panoptic FPN modelleri oldukça hızlı (yaklaşık 0.05–0.06 saniye) çalışmakta ancak ayrıntı düzeyi bakımından SAM tabanlı yöntemlere kıyasla daha sınırlı kalmaktadır. Buna karşılık, SAM 2 modeli panoramik görüntülerde ortalama 6.26 saniyelik sürede 53 segment üretirken, sokak görüntülerinde bu süre 1.56 saniyeye düşmüş ve ortalama 13 segment tespit edilmiştir. Bu fark, sokak görüntülerinde hem işlem süresinin kısaldığını hem de modelin daha net sonuçlar verdiğini göstermektedir.

Panoptik segmentasyon modellerinde panoramik görüntülerde ortalama 38–39 segment üretilirken, sokak görüntülerinde bu değer 9–10 segment aralığında kalmıştır. Bunun nedeni, panoramik görüntülerin çok geniş bir görüş açısı içermesi ve aynı karede farklı sahneleri kapsaması; buna karşın sokak görüntülerinin belirli bir yöne odaklanarak sınıf sınırlarını daha net biçimde ayırabilmesidir.

**Tablo 6.1: Farklı modellerin panoramik ve sokak görüntülerinde gerçekleştirilen segmentasyon işlemlerine ait süre, segment sayısı ve performans ölçütleri.**

Model	Görüntü	Ortalama Süre (s)	En kısa Süre (s)	En uzun Süre (s)	Ortalama Segment Sayısı	Görüntü Sayısı
<b>Panoptik FPN R-50 (1x)</b>	Panoramik	0.056	0.050	0.065	38	207
	Sokak Görüntüsü	0.056	0.050	0.073	9	828
<b>Panoptik FPN R-50 (3x)</b>	Panoramik	0.055	0.050	0.062	39	207
	Sokak Görüntüsü	0.056	0.049	0.072	10	828
<b>Panoptik FPN R-101 (3x)</b>	Panoramik	0.062	0.060	0.070	39	207
	Sokak Görüntüsü	0.063	0.057	0.087	9	828
<b>SAM</b>	Panoramik	3.443	2.898	3.938	284	207
	Sokak Görüntüsü	3.443	2.361	4.760	71	828
<b>SAM 2</b>	Panoramik	6.263	4.810	7.732	53	207
	Sokak Görüntüsü	1.566	0.964	2.681	13	828

Elde edilen bulgular, sokak görüntülerinin panoramik görüntülere kıyasla hem segmentasyon kalitesi hem de işlem süresi açısından daha uygun bir yapıda olduğunu ortaya koymuştur. Dolayısıyla, panoramik görüntülerden türetilen sokak görüntülerinin değişim tespiti sürecinde kullanılması, bölgesel değişimlerin daha doğru ve ayrıntılı biçimde yakalanmasını sağlamaktadır.

Son aşamada, hem Panoptik FPN hem de SAM 2 modellerinden elde edilen renkli segmentasyon maskeleri, değişim tespiti sürecinde temel girdi olarak kullanılmıştır. Bu maskeler, yıllar arası karşılaştırmalarda nesne bazlı değişimlerin piksel düzeyinde analiz edilmesini mümkün kılmış ve segmentasyon aşamasının değişim tespitinin ön hazırlık basamağını oluşturmuştur.

Elde edilen sonuçlar incelendiğinde, sokak görüntülerinin panoramik görüntülere kıyasla hem segment sayısı hem de segment çeşitliliği açısından daha uygun bir yapıda olduğunu ortaya koymuştur. Yapılan testler sonucunda, panoramik görüntülerde segment edilemeyen detayların, bu görüntülerin sokak görünümüne dönüştürülmesiyle birlikte başarılı bir şekilde segment edilebildiği gözlemlenmiştir. Bu nedenle, değişim

tespitinin performansının artırılması amacıyla analizler sokak görüntüleri üzerinden yürütülmüştür.

Değişim tespiti sürecinde girdi olarak, sokak görüntülerine ait Panoptik FPN ve SAM 2 segmentasyon sonuçları kullanılmıştır. Bu iki model, farklı segmentasyon yaklaşımlarını temsil etmektedir. Panoptik segmentasyon, sahnedeki tüm pikselleri önceden tanımlanmış sınıflara göre etiketleyen, denetimli ve veriye dayalı bir yöntemdir. Her piksel yalnızca tek bir sınıfa ait olacak biçimde sınıflandırılır ve aynı sınıfa ait farklı nesnelere birbirinden ayırt edilir. Buna karşın SAM 2, önceden belirlenmiş bir sınıf listesine ihtiyaç duymayan, kullanıcı yönlendirmelerine ve görsel ipuçlarına göre çalışan sıfır atışlı (zero-shot) bir modeldir. Bu yapısal fark nedeniyle, Panoptik FPN daha kural-tabanlı ve sınıf odaklı, SAM 2 ise daha esnek ve etkileşimli bir segmentasyon yaklaşımı sunmaktadır. Çalışmada, bu iki farklı modelden elde edilen çıktılar, değişim tespiti performansına etkilerini değerlendirmek amacıyla karşılaştırmalı biçimde kullanılmıştır.

### 6.2.2. Değişim Tespiti ve Senaryoların Değerlendirilmesi

Her bir senaryo üzerinden uygulanan değişim analiz süreci, birden fazla aşamada yürütülmüştür. Bu süreç, segmentasyon çıktılarının yalnızca görsel düzeyde yorumlanmasının ötesine geçerek, sayısal ve uzamsal karşılaştırmalara dayanan kapsamlı bir değerlendirme sunmayı hedeflemiştir.

İlk olarak, piksel bazlı yüzdelerle değişim analizi gerçekleştirilmiştir. Her bir görüntüde belirli nesne sınıflarına ait piksel yoğunlukları sayılarak, sınıfların toplam alan içindeki kapladığı oran hesaplanmıştır. Böylece, yıllar arasındaki artış veya azalış eğilimleri sayısal olarak hesaplanmıştır. Bu hesaplama aşağıdaki formül ile ifade edilmektedir:

$$Yüzde_{sınıf} = \left( \frac{N_{sınıf}}{N_{toplam}} \right) \times 100 \quad (6.1)$$

Burada  $N_{sınıf}$ , ilgili sınıfa ait piksel sayısını;  $N_{toplam}$ , tüm sınıflara ait toplam piksel sayısını ifade eder. Bu analiz sonucunda, örneğin “yeşil alan: 11.2% → 5.4%” şeklinde yüzdelerle ifadelerle değişim yönü ve oranı açıkça ortaya konmuştur.

Bir sonraki aşamada, sınıflar arası dönüşümü gösteren sözde "değişim matrisi" oluşturulmuş, bir yılda belirli bir sınıf olarak işaretlenmiş piksellerin diğer yılda hangi

sınıfa dönüştüğü hesaplanmıştır. Bu matris sayesinde, örneğin bir bölgenin "yeşil alan" sınıfından "bina/yapı" sınıfına geçiş yaptığı sayısal olarak ifade edilerek, çevresel dönüşüm net bir biçimde gösterilmiştir. Bu analiz, alan değişimlerinin hem yönelim hem de miktar olarak detaylı incelenmesini sağlamıştır. İlgili hesaplama şu şekilde formüle edilmiştir:

$$M_{i,j} = |\{p \mid p \in C_i^{(t1)} \cap p \in C_j^{(t2)}\}| \quad (6.2)$$

Bu formülde,  $p$  bir piksel konumunu temsil ederken,  $C_i^{(t1)}$  ve  $C_j^{(t2)}$  ifadeleri sırasıyla ilk ve ikinci zaman dilimlerinde bu pikselin ait olduğu sınıfı göstermektedir. Matrisin her bir satır-sütun çifti, belirli bir sınıfın başka bir sınıfa dönüşümünü sayısal olarak ifade eder. Örneğin,  $M_{yeşil\ alan, bina}$  hücresi ilk yıl "yeşil alan" olarak segmentlenen kaç pikselin ikinci yıl "bina" olarak yeniden segmentlendiğini gösterir. Bu analiz sayesinde, örneğin bir bölgenin "yeşil alan" sınıfından "bina/yapı" sınıfına geçtiği hem yön hem de miktar açısından belirlenmiştir.

Analizin üçüncü aşamasında, aynı sınıfın iki yıl içindeki uzamsal konumlarının ne derece örtüştüğünü ölçmek amacıyla IoU (Intersection over Union) benzeri bir metrik olan zamansal örtüşme oranı hesaplanmıştır. Bu oran, klasik nesne tabanlı IoU'dan farklı olarak, sınıf bazında tüm görüntü alanında değerlendirme yapmaktadır.

Bu metrik sayesinde her sınıf için, iki farklı zamana ait segmentasyon maskelerinde bulunan piksellerin kesişim ve birleşim oranı hesaplanmıştır. Böylece, nesne düzeyinde olmasa da, ilgili sınıfın genel konumsal devamlılığı hakkında yorum yapılabilmektedir. Dolayısıyla bu metrik, teorik olarak IoU'nun sınıf-bazlı bir türevi olarak değerlendirilebilir ve "Zamansal Örtüşme Oranı" şeklinde adlandırılmıştır. Hesaplama aşağıdaki gibidir:

$$Zamansal\ Örtüşme\ Oranı_{sınıf} = \frac{|Maske_{t1} \cap Maske_{t2}|}{|Maske_{t1} \cup Maske_{t2}|} \quad (6.3)$$

Burada  $Maske_{t1}$  ve  $Maske_{t2}$ , ilgili sınıfa ait segmentasyon maskelerini temsil eder. Kesişim ( $\cap$ ) bölgesi, iki yılda da aynı konumda aynı sınıfın bulunduğu pikselleri ifade ederken; birleşim ( $\cup$ ) bölgesi, her iki yıldaki toplam varlığı tanımlar. Böylece bu oran, sınıfın uzamsal olarak ne derece istikrarlı kaldığını ölçmek için kullanılmıştır. Skorun 1'e yakın olması, sınıfın konumunun büyük ölçüde sabit kaldığını; 0'a yakın olması ise

sınıfın konumsal olarak büyük ölçüde değiştiğini göstermektedir. Bu metrik, tez kapsamında yalnızca temsili bir benzerlik ölçütü olarak kullanılmış, "gerçek IoU" hesaplaması amacı taşımamaktadır.

Analizin dördüncü aşamasında, iki farklı yıla ait segmentasyon maskeleri arasındaki benzerliği ölçmek amacıyla Konumsal Örtüşme Oranı, yani Dice Katsayısı (Dice Similarity Coefficient, DSC) hesaplanmıştır. Bu oran, IoU tabanlı Zamansal Örtüşme Oranı'na benzer şekilde iki maske arasındaki örtüşmeyi ölçmekle birlikte, hesaplama yöntemi itibarıyla Dice katsayısından türetilmiş bir konumsal benzerlik metriği olarak değerlendirilmektedir.

Dice katsayısı, iki maskenin kesişim alanının iki katını, her iki maskede yer alan toplam piksel sayısına oranlayarak iki küme arasındaki benzerliği hesaplar. Bu yaklaşım, IoU'ya kıyasla kesişim bölgelerine daha fazla ağırlık verir ve özellikle küçük nesnelerin bulunduğu bölgelerde konumsal tutarlılığı daha hassas biçimde yansıtır. Bu nedenle tez kapsamında, Dice katsayısından türetilen bu Konumsal Örtüşme Oranı, iki dönem arasındaki sınıf bazlı konumsal benzerliği değerlendirmek için tamamlayıcı bir ölçüt olarak kullanılmıştır.

Hesaplama aşağıdaki biçimde yapılmıştır:

$$\text{Konumsal Örtüşme Oranı} = \frac{2 \times |\text{Maske}_{t1} \cap \text{Maske}_{t2}|}{|\text{Maske}_{t1}| + |\text{Maske}_{t2}|} \quad (6.4)$$


Burada  $\text{Maske}_{t1}$  ve  $\text{Maske}_{t2}$ , aynı sınıfa ait iki farklı yıla ilişkin segmentasyon maskelerini temsil etmektedir. Kesişim (U) bölgesi, her iki yılda da aynı konumda aynı sınıfın bulunduğu pikselleri; paydadaki toplam alan ise her iki yılda o sınıfa ait tüm pikselleri ifade etmektedir. Skorun 1'e yakın olması, iki dönemdeki sınıf bölgelerinin büyük ölçüde aynı konumlarda yer aldığını; 0'a yakın olması ise sınıfın konumsal olarak belirgin bir değişim geçirdiğini göstermektedir.

Son olarak, her bir senaryoya ait renkli fark haritası ve değişim yoğunluğu haritası oluşturularak, değişimlerin mekânsal dağılımı görsel olarak sunulmuştur. Değişim haritasında sadece farklılık gösteren pikseller renkli olarak kodlanmış, diğer bölgeler gri ya da saydam bırakılarak kullanıcının dikkatini değişime çekmesi sağlanmıştır. Değişim yoğunluğu haritası ise, farklılığın hangi bölgelerde daha sık görüldüğünü

sıcaklık renkleri ile sunarak sezgisel bir değerlendirme aracı sağlamıştır. Tüm bu analiz süreçleri, SAM 2 ve Panoptik segmentasyon modelleri ile entegre biçimde yürütülmüştür. Bu modeller, farklı segmentasyon yaklaşımlarını temsil ederek aynı veri seti üzerinde birbirini tamamlayıcı çıktılar üretmiştir. SAM 2 modeli, kullanıcı yönlendirmesine dayalı sifit atış segmentasyon yeteneğiyle nesnelere esnek biçimde ayırırken; Panoptik segmentasyon modeli, önceden tanımlı sınıflar üzerinden piksel düzeyinde etiketleme yaparak sahnedeki tüm nesnelere bütüncül biçimde analiz etmiştir. Bu iki farklı modelin çıktıları, değişim tespitinin hem genel eğilimlerini hem de sınıf bazlı detaylarını daha kapsamlı biçimde inceleme olanağı sağlamıştır.

Çalışmada uygulanan yöntemsel adımlar, tez kapsamında önerilen değişim tespiti sürecinin bütününe temsil etmektedir. Süreç, panoramik görüntülerin eşkenar dörtgen projeksiyon yöntemiyle sokak görünümüne dönüştürülmesiyle başlamış; ardından bu görüntüler üzerinde SAM 2 ve Panoptik FPN modelleri ile segmentasyon işlemleri gerçekleştirilmiştir. Her iki modelin segmentasyon çıktıları üzerinden sınıf bazlı renk kodlamaları yapılarak görsel maskeler elde edilmiştir. Bu maskeler, sonraki aşamada gerçekleştirilen değişim tespiti analizlerinin girdisini oluşturmuştur. Ayrıca, segmentasyon modelleri süre ve segment sayısı açısından karşılaştırılmış; panoramik ve sokak görüntüleri arasındaki farklar değerlendirilerek, sokak görüntülerinde daha fazla detayın yakalandığı ve daha doğru segmentasyon çıktıları üretildiği gözlemlenmiştir. Bu çok aşamalı yapı, çalışmada izlenen genel yöntem akışını ortaya koymaktadır. İzlenen sürecin tamamı Şekil 6.7’de gösterilmiştir.


Bu çalışmada önerilen değişim tespiti yönteminin her bir senaryosu, belirli bir problem çerçevesinde yapılandırılmış olup, süreç adım adım ilerleyen aşamalardan oluşmaktadır. Senaryo 1 kapsamında ele alınan ilk aşama, değişim analizine temel oluşturacak görüntülerin segmentasyonudur. Aynı fiziksel konumdan iki farklı yıl içerisinde alınmış sokak görünümleri üzerinde yürütülen bu ilk adımda, SAM 2 ve Panoptik segmentasyon modelleri kullanılarak nesne düzeyinde ayrıştırma işlemi gerçekleştirilmiştir. Bu aşamada, bina, yeşil alan, trafik işareti ve tabela gibi hedef sınıflara odaklanılmış; yalnızca ilgi duyulan sınıflar seçilerek bölgesel maskeler oluşturulmuştur. Segmentasyon çıktılarında her sınıfa farklı renkler atanarak, sınıfların görselde açıkça ayırt edilebilir olması sağlanmıştır. Bu segmentasyon sonuçları, ilerleyen aşamalarda üretilecek olan değişim haritaları ve semantik düzeydeki farklılıkların değerlendirilmesi için temel veri niteliği taşımaktadır.



**Şekil 6.7: Tez kapsamında önerilen deęişim tespiti yönteminin aşamaları.**

Tüm bu işlemler, tez kapsamında tanımlanan üç senaryonun her birinde, SAM 2 ve Panoptik segmentasyon modelleri üzerinde ayrı ayrı uygulanmıştır. Böylece, farklı segmentasyon yaklaşımlarının deęişim tespiti sürecine etkisi karşılaştırmalı olarak incelenmiştir. Senaryo-1 kapsamında gerçekleştirilen SAM 2 ve Panoptik segmentasyon sonuçları Şekil 6.8’de gösterilmiştir. Sunulan görsel segmentasyon çıktılarından, her iki modele ait sayısal segmentasyon çıktıları ayrıntılı olarak değerlendirilmiş ve sınıf bazlı performans ölçütleri karşılaştırılmıştır. Bu kapsamda, her bir sınıf için segment sayısı, piksel alanı ve işlem süresi değerleri hesaplanarak modellerin performansı nicel olarak analiz edilmiştir.

Tüm değerlendirmeler Google Colab ortamında NVIDIA A100 GPU üzerinde gerçekleştirilmiştir. Böylece, görsel düzeyde gözlemlenen farklılıklar sayısal olarak da desteklenmiş ve her iki segmentasyon yönteminin işlem verimlilięi karşılaştırmalı biçimde ortaya konmuştur. Senaryo 1’e ait SAM 2 ve Panoptik segmentasyon sonuçlarının nicel değerleri Tablo 6.2’de verilmiştir.



**Şekil 6.8: Senaryo-1 için segmentasyon sonuçları: (a) 2020 yılı sokak görüntüsü, (b) 2023 yılı sokak görüntüsü, (c) 2020 yılı SAM 2 segmentasyon sonucu, (d) 2023 yılı SAM 2 segmentasyon sonucu, (e) 2020 yılı Panoptik segmentasyon sonucu, (f) 2023 yılı Panoptik segmentasyon sonucu. her sınıfa farklı renk ataması segmentasyon sonucu.**

**Tablo 6.2: Senaryo 1 için SAM 2 ve Panoptik segmentasyon sonuçlarına ait segment sayısı, piksel alanı ve süre değerleri.**


Görüntü	Model	Sınıf	Segment Sayısı	Piksel Alanı (px)	Süre (sn)
2020 Görüntüsü	SAM 2	Yeşil Alan	25	6088	1.258
		Trafik İşareti	0	0	
		Bina -Yapı	0	0	
		Tabela	1	682	
	Panoptik	Yeşil Alan	3	22119	0.017
		Trafik İşareti	0	0	
		Bina -Yapı	0	0	
Tabela		0	0		
2023 Görüntüsü	SAM 2	Yeşil Alan	10	4096	1.208
		Trafik İşareti	0	0	
		Bina -Yapı	0	0	
		Tabela	0	0	
	Panoptik	Yeşil Alan	2	6777	0.018
		Trafik İşareti	0	0	
		Bina -Yapı	0	0	
Tabela		0	0		

Tablo 6.2 incelendiğinde, iki modelin segmentasyon performansları arasında belirgin farklar olduğu görülmektedir. SAM 2, küçük ve detaylı nesnelere daha fazla segment üretirken; Panoptik model, genel sahne bütünlüğünü koruma eğilimi göstermiştir. Bununla birlikte, SAM 2'nin işlem süresi Panoptik modele kıyasla daha uzundur. Sonuç olarak, SAM 2 detay odaklı; Panoptik segmentasyon ise daha bütüncül bir yaklaşım sergilemektedir.

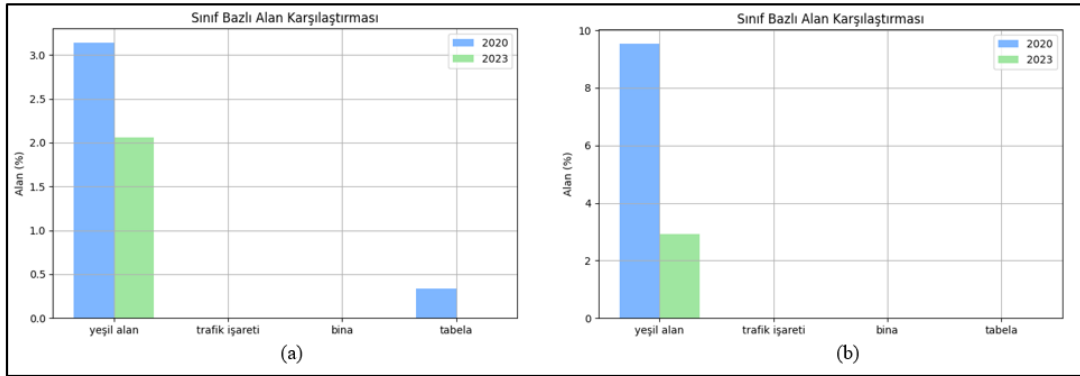
Senaryo 1 için gerçekleştirilen ikinci aşama, segmentasyon sonuçları elde edilen maskelerin kategori bazında sınıflandırılmasıdır. Bu aşamadaki amaç, her bir segmentin anlamlı bir kategoriyle eşleştirilerek sınıflandırılmasıdır. Böylece, farklı yıllara ait görüntülerdeki benzer nesne sınıflarının karşılaştırılması mümkün hâle gelmektedir. Görsellerde kullanılan renk kodları, sınıfların ayrımını kolaylaştırmak amacıyla her kategori için sabit tutulmuştur. Yeşil renk ile ağaçlar, mavi ile binalar, kırmızı ile trafik işaretleri ve tabelalar sarı renk ile temsil edilmektedir.

Şekil 6.9'da, Senaryo-1 için SAM 2 ve Panoptik segmentasyon modelleri kullanılarak 2020 ve 2023 yıllarına ait kategorik segmentasyon çıktıları ile bu çıktılardan elde edilen değişim haritaları verilmiştir. Bu haritalar, görüntü çiftleri arasındaki semantik farkları sınıflandırmaksızın genel değişim durumunu görselleştirmektedir. Kırmızı ile gösterilen alanlar, önceki zamana ait görüntüde bulunup sonradaki görüntüde yer almayan yani "silinmiş" bölgeleri; yeşil alanlar ise son görüntüde yeni olarak beliren "eklenmiş" bölgeleri temsil etmektedir. Elde edilen bu maskeler, sonraki aşamada gerçekleştirilecek olan piksel tabanlı ve nesne tabanlı karşılaştırmalarda kullanılmak üzere hazırlanan temel veriyi oluşturmaktadır.

Her iki modelin çıktıları incelendiğinde, SAM 2 modelinin tabula gibi küçük nesnelereki değişimleri daha belirgin biçimde yakalayabildiği, buna karşılık Panoptik modelin daha geniş yüzey alanlarına sahip sınıflarda (örneğin yol ve bina bölgeleri) daha tutarlı sonuçlar ürettiği gözlemlenmiştir. Bu durum, SAM 2'nin etkileşimli ve detay odaklı yapısının küçük ölçekli değişimlerde avantaj sağladığını, Panoptik segmentasyonun ise genel sahne bütünlüğünü korumada daha kararlı davrandığını göstermektedir.



**Şekil 6.9: Senaryo-1 için segmentasyon maske çıktıları: (a) 2020 yılı SAM 2 segmentasyon maskesi, (b) 2023 yılı SAM 2 segmentasyon maskesi, (c) SAM 2 modeli değişim haritası, (d) 2020 yılı Panoptik segmentasyon maskesi, (e) 2023 yılı Panoptik segmentasyon maskesi, (f) Panoptik model değişim haritası.**




**Şekil 6.10: Senaryo-1 için yıllara göre sınıf bazlı alan oranları: (a): SAM 2 modeline ait sınıf bazlı alan oranları, (b): Panoptik segmentasyon modeline ait sınıf bazlı alan oranları.**

Şekil 6.10'da, Senaryo-1 kapsamında 2020 ve 2023 yıllarına ait görüntüler üzerinden elde edilen sınıf bazlı alan karşılaştırması sunulmaktadır. Bu grafik, dört farklı sınıf

(yeşil alan, trafik işareti, bina ve tabela) için yıllar arasındaki yüzdelik alan değişimlerini görselleştirmektedir.

Grafik incelendiğinde, her iki segmentasyon modeli için de yeşil alanların toplam alan oranında azalma görülmekte; bu durum, kentsel genişleme veya yapılaşma gibi etkenlerle açıklanabilir. Tabela sınıfında ise, SAM 2 modeli grafiğinde azalış gözlemlenmiş, Panoptik model grafiğinde ise değişim görülmemiştir. Model davranışları açısından, SAM 2 küçük ve seyrek nesnelere daha dalgalanmaları daha görünür kılarken, Panoptik model geniş yüzeyli sınıflarda tutarlı oranlar üretmiştir. Bu farklılık, iki yaklaşımın çalışma prensiplerinin alan değişimi analizine tamamlayıcı katkı sunduğunu göstermektedir.

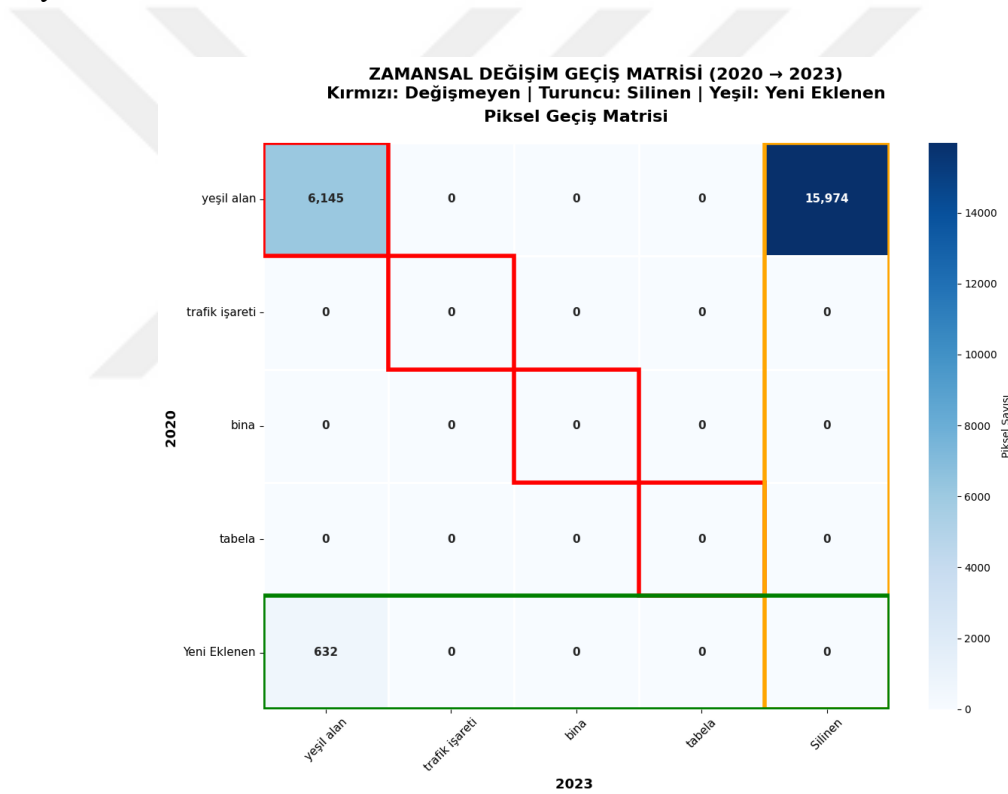


**Şekil 6.11: Senaryo-1 için SAM-2 segmentasyon modelinin sınıflar arası piksel geçiş matrisi.**

Şekil 6.11’de SAM 2 segmentasyon sonucunda sınıflar arası piksel geçişlerini gösteren bir geçiş matrisi sunulmaktadır. Bu matris, 2020 (ilk yıl) ve 2023 (ikinci yıl) görüntülerindeki sınıflar arasında gerçekleşen dönüşümleri piksel düzeyinde göstermektedir. Matrisin satırları ilk yılın sınıflarını, sütunları ise ikinci yılın sınıflarını temsil ederken, her hücredeki değer ilgili sınıf dönüşümüne ait piksel sayısını göstermektedir. Matris incelendiğinde, en belirgin değişimlerin yeşil alan sınıfında gerçekleştiği görülmektedir. 2020 yılında yeşil alan olarak etiketlenen 5.971 pikselin

2023 yılında farklı sınıflara geçtiği, yalnızca 737 pikselin aynı sınıfta kaldığı belirlenmiştir. Bu durum, yeşil alanların önemli bir bölümünün zaman içerisinde ortadan kalktığını göstermektedir.

Tabela sınıfı incelendiğinde, 2020 yılında 404 pikselin yeşil alana dönüştüğü, 315 pikselin ise silindiği görülmektedir. Bu sonuç, çalışma sahasında bazı tabelaların fiziksel olarak kaldırıldığını veya üzerlerinin bitki örtüsüyle kapandığını göstermektedir. Diğer sınıflarda (trafik işareti, bina) anlamlı bir geçiş gözlemlenmemiştir. Bu tür geçiş matrisleri, sadece toplam değişim oranlarını değil, aynı zamanda hangi sınıfların ne tür dönüşümlere uğradığını detaylı biçimde analiz etmeye olanak sağlar. Böylece, değişimlerin sınıf bazında kaynakları daha net şekilde yorumlanabilir.



**Şekil 6.12: Senaryo-1 için Panoptik segmentasyon modelinin sınıflar arası piksel geçiş matrisi.**

Şekil 6.12’de verilen Panoptik segmentasyon sonucundaki sınıflar arası geçiş matrisi, değişimlerin büyük ölçüde yeşil alan sınıfında yoğunlaştığını göstermektedir. 2020 yılında yeşil alan olarak etiketlenen 15.974 pikselin 2023 yılında farklı sınıflara geçtiği, yalnızca 6.145 pikselin aynı sınıfta kaldığı belirlenmiştir. Bu durum, yeşil alanların önemli bir kısmının zaman içinde kaybolduğunu veya başka sınıflara

dönüştüğünü göstermektedir. Ayrıca 2023 yılına ait görüntüde 632 pikselin yeni yeşil alan olarak eklendiği tespit edilmiştir. Diğer sınıflarda anlamlı bir geçiş gözlemlenmemiştir.

Senaryo 1 incelendiğinde, yeşil alan ve tabela sınıflarında değişimlerin meydana geldiği görülmektedir. SAM 2 modeli, her iki sınıfta da segmentasyon sürecinde ilgili bölgeleri doğru biçimde ayırabilmiş, dolayısıyla bu sınıflarda gerçekleşen değişimler değişim tespiti aşamasında açık biçimde ortaya konmuştur. Buna karşılık, Panoptik segmentasyon modeli özellikle tabela sınıfındaki bölgeleri yeterli doğrulukta ayıramadığı için, bu sınıfa ait değişim haritasında anlamlı bir fark gözlemlenmemiştir. Bu durum, Panoptik modelin önceden tanımlı sabit sınıf yapısı ve küçük nesnelere ayırt etmedeki sınırlı duyarlılığı ile açıklanabilir. SAM 2'nin sıfır atış tabanlı ve etkileşim temelli yapısı ise, küçük ölçekli nesnelere daha esnek ve ayrıntılı segmentasyonlar üreterek değişim tespiti aşamasına daha doğru girdi sağlamıştır.

**Tablo 6.3: Senaryo-1 için SAM 2 segmentasyon çıktılarından elde edilen sınıf bazlı yüzdeler alan değişimleri.**

Sınıf	2020 (%)	2023 (%)	Değişim Oranı (%)	Değişim Yönü
Yeşil Alan	3.14	2.06	- 1.08	Azalma
Trafik İşareti	0	0	0	Değişim yok
Bina	0	0	0	Değişim yok
Tabela	0.34	0	- 0.34	Azalma

Tablo 6.3 ve Tablo 6.4'te, Senaryo-1 için sırasıyla SAM 2 ve Panoptik segmentasyon modelleri ile elde edilen çıktıların sınıf bazlı yüzdeler alan değişimleri verilmiştir. Her iki model için 2020 ve 2023 yıllarına ait alansal yüzdeleri hesaplanmış, bu değerler arasındaki farklar, mutlak yüzde puan değeri olarak sunulmuştur. Bu farkın işareti (+/-) değişimin yönünü belirtirken, "Değişim Yönü" sütunu ise söz konusu değişimin artış mı azalış mı olduğunu yorumlamaya olanak sağlamıştır.

**Tablo 6.4: Senaryo-1 için Panoptik segmentasyon çıktılarından elde edilen sınıf bazlı yüzdelik alan değişimleri.**

Sınıf	2020 (%)	2023 (%)	Değişim Oranı (%)	Değişim Yönü
Yeşil Alan	9.54	2.92	- 6.62	Azalma
Trafik İşareti	0	0	0	Değişim yok
Bina	0	0	0	Değişim yok
Tabela	0	0	0	Değişim yok

Tablo 6.5 ve Tablo 6.6’da, sırasıyla SAM 2 ve Panoptik segmentasyon sonuçlarından hesaplanan zamansal ve konumsal örtüşme oranları verilmiştir. Bu oranlar, her bir sınıfın iki yıl arasındaki konumsal konum benzerliğini ve zamansal sürekliliğini nicel olarak değerlendirmeye olanak sağlamaktadır. Zamansal örtüşme oranı, aynı sınıfın iki farklı yıldaki piksel düzeyindeki kesişimini; konumsal örtüşme oranı ise bu sınıfın uzamsal benzerliğini göstermektedir.

**Tablo 6.5: Senaryo-1 için SAM 2 segmentasyon çıktılarından hesaplanan zamansal ve konumsal örtüşme oranları.**

Sınıf	Zamansal Örtüşme Oranı	Konumsal Örtüşme Oranı	Zamansal Örtüşme Durumu	Konumsal Benzerlik Durumu	Değişim Yorumu
Yeşil Alan	0.071	0.133	Düşük örtüşme	Düşük benzerlik	Kısmi değişim
Trafik İşareti	0	0	Örtüşme yok	Benzerlik yok	Değişim yok
Bina	0	0	Düşük örtüşme	Benzerlik yok	Kısmi değişim
Tabela	0	0	Örtüşme yok, sınıf kaybı	Benzerlik yok, sınıf kaybı	Sınıf son yılda bulunmuyor

Tablo 6.5 incelendiğinde, SAM 2 segmentasyon sonuçlarına göre en düşük zamansal ve konumsal örtüşme oranlarının yeşil alan ve tabela sınıflarında meydana geldiği görülmektedir. Yeşil alan sınıfında zamansal örtüşme oranı 0.071, konumsal örtüşme oranı ise 0.133 olarak hesaplanmış; bu değerler, sınıfın iki yıl arasında kısmi bir alan kaybı yaşadığını ve konumsal olarak yeniden şekillendiğini göstermektedir.

Tabela sınıfında her iki metrik için de 0 değeri elde edilmiştir. Bu durum, sınıfın 2020 yılında mevcut olup 2023 yılında tamamen ortadan kalktığını göstermekte ve sınıf kaybı olarak yorumlanmaktadır. Buna karşılık, trafik işareti sınıfı her iki yılda da

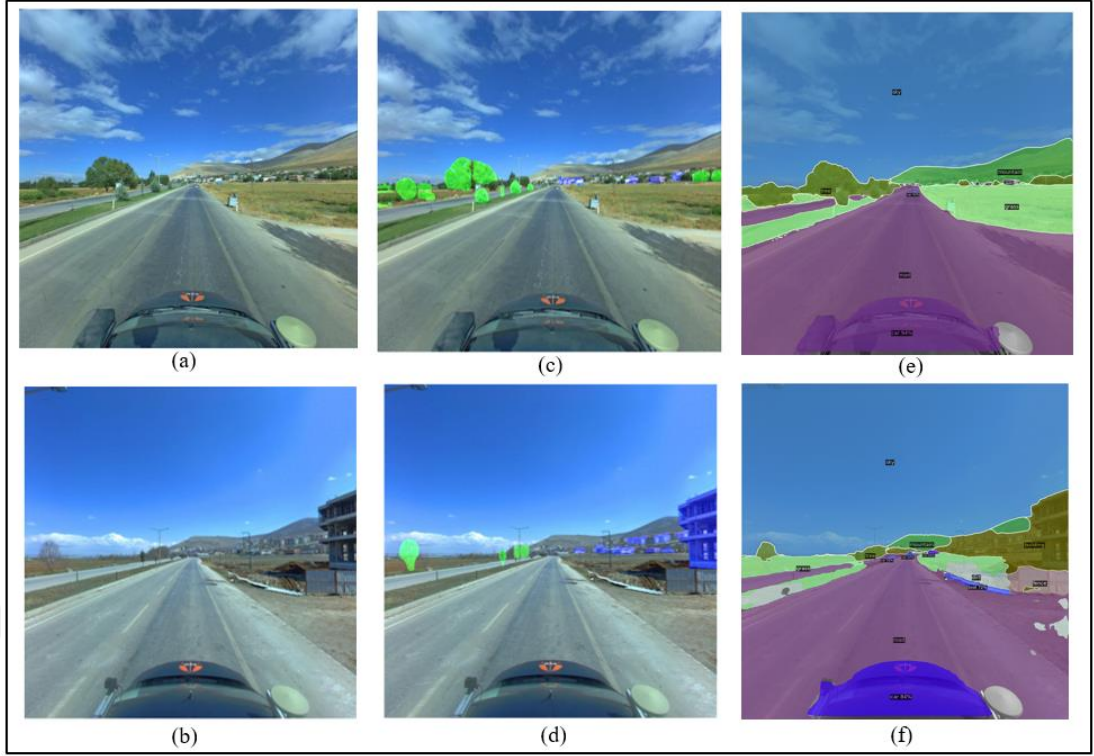
segmentasyon çıktılarında yer almamıştır; dolayısıyla bu sınıf için oranlar 0 olarak hesaplanmış ancak bu değerler ölçülebilir bir değişimi değil, sınıfın her iki dönemde de bulunmamasını ifade etmektedir.

Bu tür durumlarda, bir sınıf yalnızca bir yılda bulunduğu veya her iki yılda da yer almadığında, örtüşme oranları matematiksel olarak 0 değerini almaktadır. Ancak bu sonuç, yalnızca “benzerliğin olmaması” değil, sınıfın tamamen ortadan kalktığı veya mevcut olmadığı bir durumu temsil etmektedir. Bu nedenle çalışmada bu tür durumlar, yalnızca sayısal oranlarla değil, değişimin türü ve yönü de belirtilerek “örtüşme yok, sınıf kaybı” veya “benzerlik yok, sınıf kaybı” şeklinde değerlendirilmiştir. Böylece, modelin sayısal çıktılarının gerçek değişim olgusunu daha doğru ve anlamlı biçimde yansıtması sağlanmıştır.

**Tablo 6.6: Senaryo-1 için Panoptik segmentasyon çıktılarından hesaplanan zamansal ve konumsal örtüşme oranları.**

Sınıf	Zamansal Örtüşme Oranı	Konumsal Örtüşme Oranı	Zamansal Örtüşme Durumu	Konumsal Benzerlik Durumu	Değişim Yorumu
<b>Yeşil Alan</b>	0.270	0.425	Düşük örtüşme	Düşük benzerlik	Kısmi değişim
<b>Trafik İşareti</b>	0	0	Örtüşme yok	Benzerlik yok	Değişim yok
<b>Bina</b>	0	0	Örtüşme yok	Benzerlik yok	Değişim yok
<b>Tabela</b>	0	0	Örtüşme yok	Benzerlik yok	Değişim yok

Senaryo 2 kapsamında da, ilk senaryoda olduğu gibi, değişim analizine temel oluşturmak amacıyla sokak görünümleri üzerinde segmentasyon işlemleri gerçekleştirilmiştir. Senaryo 2 için uygulanan SAM 2 ve Panoptik segmentasyon çıktıları Şekil 6.13’te verilmiştir.



**Şekil 6.13: Senaryo-2 segmentasyon sonuçları: (a) 2020 yılı sokak görüntüsü, (b) 2023 yılı sokak görüntüsü, (c) 2020 yılı SAM 2 segmentasyon sonucu, (d) 2023 yılı SAM 2 segmentasyon sonucu, (e) 2020 yılı Panoptik segmentasyon sonucu, (f) 2023 Panoptik segmentasyon sonucu.**

Senaryo-2 kapsamında, her iki modele ait sayısal segmentasyon çıktıları analiz edilmiş; sınıf bazında segment sayısı, piksel alanı ve işlem süreleri karşılaştırılmıştır. Değerlendirmeler Google Colab ortamında NVIDIA A100 GPU üzerinde yürütülmüş ve modellerin işlem verimliliği karşılaştırmalı biçimde ortaya konmuştur. Elde edilen sonuçlar Tablo 6.7’te sunulmuştur.

**Tablo 6.7: Senaryo 2 için SAM 2 ve Panoptik segmentasyon sonuçlarına ait segment sayısı, piksel alanı ve süre değerleri.**


Görüntü	Model	Sınıf	Segment Sayısı	Piksel Alanı (px)	Süre (sn)
2020 Görüntüsü	SAM 2	Yeşil Alan	13	3721	1.309
		Trafik İşareti	0	0	
		Bina -Yapı	4	556	
		Tabela	0	0	
	Panoptik	Yeşil Alan	4	7421	0.018
		Trafik İşareti	0	0	
		Bina -Yapı	0	0	
		Tabela	0	0	
2023 Görüntüsü	SAM 2	Yeşil Alan	4	1077	1.756
		Trafik İşareti	0	0	
		Bina -Yapı	8	5666	
		Tabela	0	0	
	Panoptik	Yeşil Alan	3	1416	0.018
		Trafik İşareti	0	0	
		Bina -Yapı	5	11168	
		Tabela	0	0	

Tablo 6.7 incelendiğinde, SAM 2 modelinin segment sayısı açısından daha yüksek değerler ürettiği, buna karşılık Panoptik segmentasyonun daha kısa sürede sonuç verdiği görülmektedir. SAM 2 modeli, özellikle küçük ölçekli ve detaylı nesnelere ayırt etmede daha fazla segment oluştururken; Panoptik model sahnenin genel yapısını koruyarak daha az segment üretmiştir. Ayrıca SAM 2'nin işlem süresinin Panoptik modele göre belirgin biçimde uzun olması, modelin etkileşimli ve çok katmanlı yapısından kaynaklanmaktadır. Bu sonuçlar, her iki modelin segmentasyon yaklaşımı ve işlem verimliliği açısından birbirini tamamlayıcı nitelikte olduğunu göstermektedir.

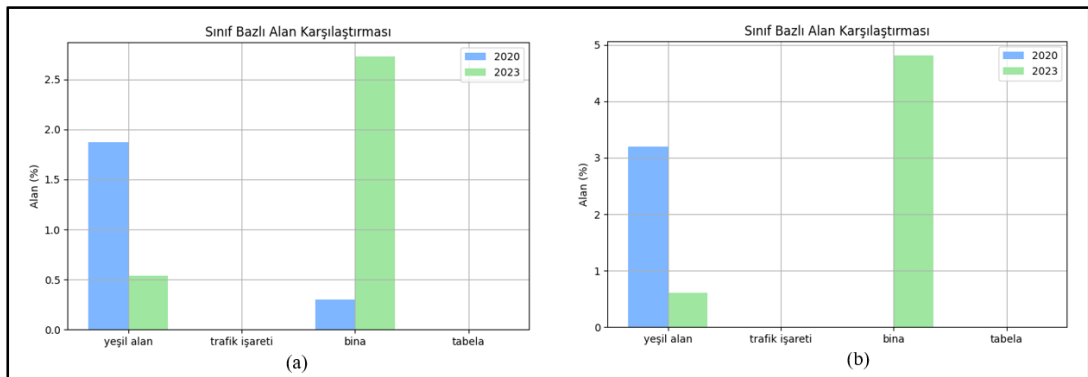
Şekil 6.14'te, Senaryo 2 kapsamında SAM 2 ve Panoptik segmentasyon modelleriyle elde edilen sınıf bazlı segmentasyon işleminin sonuçları ve değişim haritaları verilmiştir. Bu haritalar, iki dönem arasındaki sınıf temelli farkların görsel karşılaştırmasını sunmakta olup, kırmızı renk silinen nesnelere, yeşil renk yeni eklenen nesnelere, gri renk ise değişmeyen bölgeleri temsil etmektedir.

Elde edilen sonuçlara göre, SAM 2 modeli küçük ve detaylı nesne gruplarındaki değişimleri daha hassas biçimde ayırt edebilmiştir. Buna karşılık, Panoptik segmentasyon modeli daha geniş alanlara sahip sınıflarda, özellikle bina ve yol bölgelerinde, daha kararlı sonuçlar üretmiştir. Her iki modelin çıktıları birlikte

değerlendirildiğinde, SAM 2'nin ayrıştırma düzeyinde değişim yakalama kapasitesinin; Panoptik modelin ise sahne bütünlüğü içindeki yapısal değişimleri temsil etme gücünün öne çıktığı görülmektedir.




**Şekil 6.14: Senaryo- 2 için segmentasyon maske çıktıları: (a) 2020 yılı SAM 2 segmentasyon maskesi, (b) 2023 yılı SAM 2 segmentasyon maskesi, (c) SAM 2 modeli değişim haritası, (d) 2020 yılı Panoptik segmentasyon maskesi, (e) 2023 yılı Panoptik segmentasyon maskesi, (f) Panoptik model değişim haritası.**



**Şekil 6.15: Senaryo-2 için yıllara göre sınıf bazlı alan oranları: (a) SAM 2 modeline ait sınıf bazlı alan oranları, (b) Panoptik segmentasyon modeline ait sınıf bazlı alan oranları.**

Şekil 6.15'te, Senaryo 2'ye ait 2020 ve 2023 yıllarına yönelik sınıf bazlı alan karşılaştırmaları sunulmaktadır. Her iki modelde de yeşil alan sınıfında belirgin bir azalma, buna karşılık bina sınıfında anlamlı bir artış görülmektedir. Bu durum, analiz edilen bölgede bitki örtüsünün azaldığını ve yapılaşmanın arttığını göstermektedir.




**Şekil 6.16: Senaryo-2 için SAM 2 segmentasyon modelinin sınıflar arası piksel geçiş matrisi.**

Şekil 6.16'da, Senaryo-2 kapsamında SAM 2 segmentasyon sonucunda sınıflar arası piksel geçişlerini gösteren geçiş matrisi sunulmaktadır. Görsel, 2020 (ilk yıl) ve 2023 (ikinci yıl) görüntülerinde yer alan sınıflar arasında gerçekleşen dönüşümleri piksel düzeyinde ortaya koymaktadır.

Matris incelendiğinde, yeşil alan sınıfında 3.110 pikselin silindiği ve 683 pikselin yeni olarak eklendiği görülmektedir. Buna karşılık, bina sınıfında 5.117 pikselin yeni olarak oluştuğu tespit edilmiştir. Bu durum, çalışma alanında bitki örtüsünün azaldığını ve bina alanlarının genişlediğini göstermektedir. Diğer sınıflarda (trafik işareti, tabela) anlamlı bir değişim gözlenmemiştir.

**ZAMANSAL DEĞİŞİM GEÇİŞ MATRİSİ (2020 → 2023)**  
Kırmızı: Değişmeyen | Turuncu: Silinen | Yeşil: Yeni Eklenen  
Piksel Geçiş Matrisi



**Şekil 6.17: Senaryo-2 için Panoptik segmentasyon modelinin sınıflar arası piksel geçiş matrisi.**

Şekil 6.17’de, Senaryo 2 için Panoptik segmentasyon modeli kullanılarak elde edilen piksel geçiş matrisi gösterilmektedir. Matris incelendiğinde, yeşil alan sınıfında 5.338 pikselin silindiği, yalnızca 1.059 pikselin sabit kaldığı ve 357 pikselin yeni olarak eklendiği görülmektedir. Buna karşılık, bina sınıfında 10.144 pikselin yeni olarak eklendiği tespit edilmiştir.

Bu sonuçlar, çalışma bölgesinde yeşil alanların yerini yapılaşmanın aldığını ve bu dönüşümün Panoptik model tarafından net biçimde yakalandığını göstermektedir. Diğer sınıflarda herhangi bir anlamlı geçiş gözlenmemiştir. Tablo 6.8’de ve Tablo 6.9’da, Senaryo 2’ye ait SAM 2 ve Panoptik segmentasyon modellerinden elde edilen sınıf bazlı yüzdelik alan değişimleri karşılaştırmalı olarak sunulmuştur. Her iki model için 2020 ve 2023 yıllarına ait sınıf oranları hesaplanmış, bu değerler arasındaki farklar yüzde puan cinsinden gösterilmiştir.

**Tablo 6.8: Senaryo-2 için SAM 2 segmentasyon çıktılarından elde edilen sınıf bazlı yüzdeler alan değişimleri.**

Sınıf	2020 (%)	2023 (%)	Değişim Oranı (%)	Değişim Yönü
Yeşil Alan	1.87	0.54	- 1.34	Azalma
Trafik İşareti	0	0	0	Değişim yok
Bina	0.30	2.73	+ 2.43	Artış
Tabela	0	0	0	Değişim yok

**Tablo 6.9: Senaryo-2 için Panoptik segmentasyon çıktılarından elde edilen sınıf bazlı yüzdeler alan değişimleri.**

Sınıf	2020 (%)	2023 (%)	Değişim Oranı (%)	Değişim Yönü
Yeşil Alan	3.20	0.61	- 2.59	Azalma
Trafik İşareti	0	0	0	Değişim yok
Bina	0	4.82	+ 4.82	Artış
Tabela	0	0	0	Değişim yok

Senaryo-2 için Tablo 6.10'da ve Tablo 6.11'de, sırasıyla SAM 2 ve Panoptik segmentasyon sonuçlarından hesaplanan zamansal ve konumsal örtüşme oranları verilmiştir. Bu oranlar, her bir sınıfın iki yıl arasındaki konumsal konum benzerliğini ve zamansal sürekliliğini nicel olarak değerlendirmeye olanak sağlamaktadır. Zamansal örtüşme oranı, aynı sınıfın iki farklı yıldaki piksel düzeyindeki kesişimini; konumsal örtüşme oranı ise bu sınıfın uzamsal benzerliğini göstermektedir.

**Tablo 6.10: Senaryo-2 için SAM 2 segmentasyon çıktılarından hesaplanan zamansal ve konumsal örtüşme oranları.**

Sınıf	Zamansal Örtüşme Oranı	Konumsal Örtüşme Oranı	Zamansal Örtüşme Durumu	Konumsal Benzerlik Durumu	Değişim Yorumu
Yeşil Alan	0.098	0.171	Düşük örtüşme	Düşük benzerlik	Kısmi değişim
Trafik İşareti	0	0	Örtüşme yok	Benzerlik yok	Değişim yok
Bina	0.046	0.088	Düşük örtüşme	Düşük benzerlik	Kısmi değişim
Tabela	0	0	Örtüşme yok	Benzerlik yok	Değişim yok


**Tablo 6.11: Senaryo-2 için Panoptik segmentasyon çıktılarından hesaplanan zamansal ve konumsal örtüşme oranları.**

Sınıf	Zamansal Örtüşme Oranı	Konumsal Örtüşme Oranı	Zamansal Örtüşme Durumu	Konumsal Benzerlik Durumu	Değişim Yorumu
<b>Yeşil Alan</b>	0.136	0.424	Düşük örtüşme	Düşük benzerlik	Kısmi değişim
<b>Trafik İşareti</b>	0	0	Örtüşme yok	Benzerlik yok	Değişim yok
<b>Bina</b>	0	0	Örtüşme yok, sınıf oluşumu	Benzerlik yok, sınıf oluşumu	Sınıf son yılda tespit edilmiş
<b>Tabela</b>	0	0	Örtüşme yok	Benzerlik yok	Değişim yok

Tablo 6.10 incelendiğinde, SAM 2 segmentasyon sonuçlarına göre en düşük zamansal ve konumsal örtüşme oranlarının yeşil alan ve bina sınıflarında gözlemlendiği görülmektedir. Yeşil alan sınıfı için 0.098 ve 0.171 olarak hesaplanan değerler, sınıfın iki yıl arasında kısmi bir alan değişimi yaşadığını göstermektedir. Benzer biçimde bina sınıfında da düşük oranlar elde edilmiş, bu da yapısal alanların kısmen yeniden şekillendiğini ortaya koymuştur. Trafik işareti ve tabela sınıflarında ise her iki yılda da anlamlı bir değişim gözlenmemiş, dolayısıyla bu sınıflar için oranlar 0 (değişim yok) olarak belirlenmiştir.

Tablo 6.11’de yer alan Panoptik segmentasyon sonuçları, yeşil alan sınıfında düşük düzeyde örtüşme ve konumsal benzerlik (0.136 ve 0.424) göstermiştir. Bu durum, sınıfın alan olarak azaldığını ancak kısmen benzer bölgelerde varlığını sürdürdüğünü ifade etmektedir. Bina sınıfında ise örtüşme oranlarının sıfır çıkması, bu sınıfın yalnızca 2023 yılında tespit edildiğini göstermekte ve sınıf oluşumu olarak yorumlanmaktadır. Trafik işareti ve tabela sınıflarında herhangi bir değişim saptanmamıştır.

Senaryo-3 için SAM 2 ve Panoptik segmentasyon sonrası elde edilen sonuçlar Şekil 6.18’de gösterilmiştir.



**Şekil 6.18: Senaryo-3 segmentasyon sonuçları: (a) 2020 yılı sokak görüntüsü, (b) 2023 yılı sokak görüntüsü, (c) 2020 yılı SAM 2 segmentasyon sonucu, (d) 2023 yılı SAM 2 segmentasyon sonucu, (e) 2020 yılı Panoptik segmentasyon sonucu, (f) 2023 yılı Panoptik segmentasyon sonucu.**


Senaryo 3 kapsamında SAM 2 ve Panoptik segmentasyon modellerinin sayısal performans ölçütleri değerlendirilmiş; her sınıf için segment sayısı, piksel alanı ve süre değerleri incelenmiştir. Google Colab ortamında NVIDIA A100 GPU üzerinde gerçekleştirilen bu analizler, her iki modelin işlem süreleri ve segment üretim davranışlarını karşılaştırmalı olarak ortaya koymuştur. İlgili sonuçlar Tablo 6.12’de verilmiştir.

**Tablo 6.12: Senaryo-3 için SAM 2 ve Panoptik segmentasyon sonuçlarına ait segment sayısı, piksel alanı ve süre değerleri.**

Görüntü	Model	Sınıf	Segment Sayısı	Piksel Alanı (px)	Süre (sn)
2020 Görüntüsü	SAM 2	Yeşil Alan	9	13224	1.628
		Trafik İşareti	2	5375	
		Bina -Yapı	18	17065	
		Tabela	0	0	
	Panoptik	Yeşil Alan	2	26807	0.020
		Trafik İşareti	1	1814	
		Bina -Yapı	2	34659	
		Tabela	0	0	
2023 Görüntüsü	SAM 2	Yeşil Alan	13	10824	1.493
		Trafik İşareti	0	0	
		Bina -Yapı	16	10662	
		Tabela	0	0	
	Panoptik	Yeşil Alan	6	18382	0.019
		Trafik İşareti	0	0	
		Bina -Yapı	9	20961	
		Tabela	0	0	

Tablo incelendiğinde, SAM 2 modelinin segment sayısı açısından Panoptik segmentasyon modeline kıyasla daha fazla ayrıntı ürettiği görülmektedir. SAM 2, özellikle yeşil alan ve bina sınıflarında daha yüksek segment sayıları elde etmiş, bu da modelin detay odaklı yapısını yansıtmaktadır. Ancak işlem süresi bakımından SAM 2'nin ortalama süresi Panoptik modele göre belirgin biçimde daha uzundur, bu da etkileşimli yapısının hesaplama maliyetini artırdığını göstermektedir.

Panoptik segmentasyon ise daha az segment sayısı ile sahne bütünlüğünü koruyarak daha kısa sürede sonuç üretmiştir. Özellikle bina ve yeşil alan sınıflarında genel alan temsili sağlasa da, küçük ölçekli nesnelere (örneğin trafik işaretleri) sınırlı tespit yapabilmektedir. Sonuç olarak, SAM 2 ayrıntılı nesne ayrıştırma, Panoptik segmentasyon ise genel sahne yapısının korunmasında daha başarılı bir performans sergilemiştir.



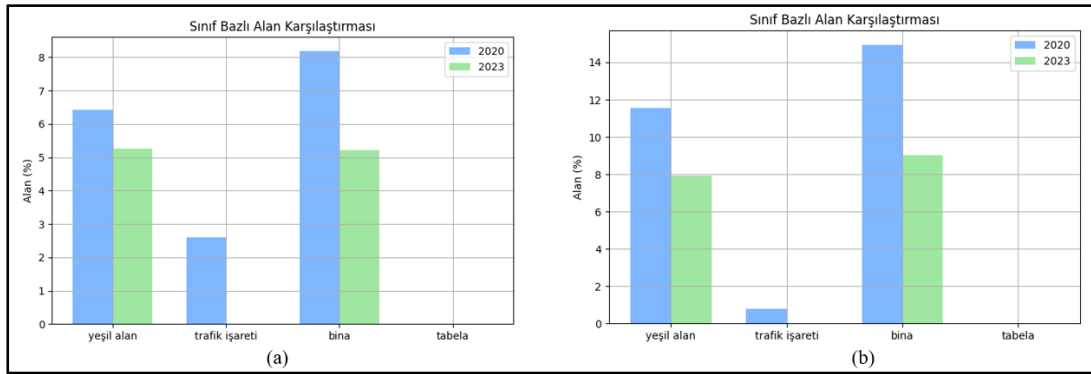
**Şekil 6.19: Senaryo- 3 için segmentasyon maske çıktıları: (a) 2020 yılı SAM 2 segmentasyon maskesi, (b) 2023 yılı SAM 2 segmentasyon maskesi, (c) SAM 2 modeli değişim haritası, (d) 2020 yılı Panoptik segmentasyon maskesi, (e) 2023 yılı Panoptik segmentasyon maskesi, (f) Panoptik model değişim haritası.**

Senaryo 3 kapsamında SAM 2 ve Panoptik segmentasyon çıktıları ile elde edilen değişim haritaları Şekil 6.17’de gösterilmiştir. Segmentasyon sonuçlarında bina alanları mavi, yeşil alanlar yeşil, trafik işaretleri kırmızı renk ile temsil edilmiştir. Değişim haritalarında ise kırmızı renk silinen alanları, yeşil renk yeni eklenen alanları, gri renk ise iki yıl arasında değişmeyen bölgeleri göstermektedir.

Elde edilen sonuçlar incelendiğinde, her iki modelde de bina ve yeşil alan sınıflarında belirgin değişimler gözlemlenmiştir. SAM 2 modeli, özellikle küçük ölçekli eklenme ve silinme bölgelerini (örneğin tabela ve duvar kenarları) daha ayrıntılı biçimde tespit ederken, Panoptik model daha geniş alanlardaki değişimleri (örneğin yapı blokları ve bitki örtüsü yoğunluğu) daha bütüncül bir biçimde yakalamıştır. Genel olarak, her iki model de kentsel dokudaki yapısal değişimleri başarıyla ortaya koymuş; ancak SAM 2’nin detay duyarlılığı ve küçük nesne hassasiyeti Panoptik modele göre daha yüksek olmuştur.

Senaryo-3 için SAM 2 ve Panoptik segmentasyon çıktılılarından elde edilen sınıf bazlı alan değişim grafiği Şekil 6.25'te gösterilmektedir. Grafikler incelendiğinde, bina sınıfında gözle görülür bir artış meydana geldiği, buna karşılık yeşil alanların oranında belirgin bir azalma yaşandığı görülmektedir. Bu durum, bölgedeki yapılaşmanın arttığını ve yeşil alanların yerini büyük oranda binaların aldığını göstermektedir.

Senaryo 3 kapsamında SAM 2 ve Panoptik segmentasyon modelleriyle elde edilen sınıf bazlı alan karşılaştırmaları Şekil 6.20'de sunulmaktadır. Grafikler, 2020 ve 2023 yıllarına ait yeşil alan, trafik işareti, bina ve tabela sınıflarının yüzdelik dağılımlarını göstermektedir. Her iki modelde de bina sınıfında alan azalması, yeşil alanlarda ise belirgin bir daralma gözlemlenmiştir. Bu durum, çalışma sahasında yapılaşmanın artmasına paralel olarak yeşil alanların azaldığını göstermektedir. Trafik işareti sınıfında ise değişimler tespit edilmiş, tabela sınıfı her iki yılda da anlamlı bir alansal varlık göstermemiştir.



**Şekil 6.20: Senaryo-3 için yıllara göre sınıf bazlı alan oranları: (a):SAM 2 modeline ait sınıf bazlı alan oranları, (b): Panoptik segmentasyon modeline ait sınıf bazlı alan oranları.**

**ZAMANSAL DEĞİŞİM GEÇİŞ MATRİSİ (2020 → 2023)**  
**Kırmızı: Değişmeyen | Turuncu: Silinen | Yeşil: Yeni Eklenen**  
**Piksel Geçiş Matrisi**



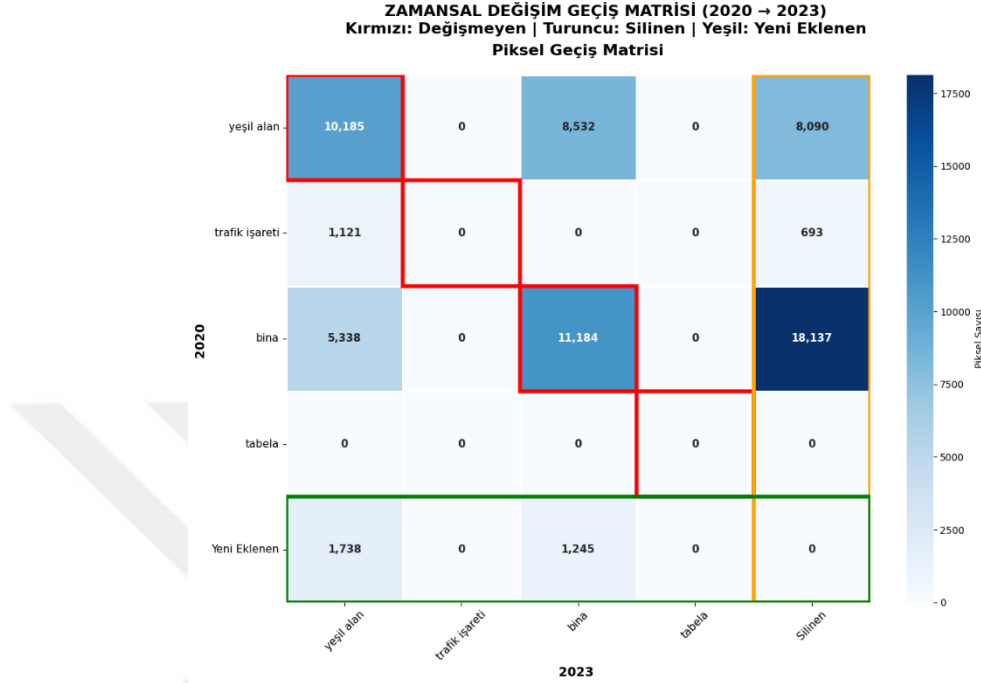
**Şekil 6.21: Senaryo-3 için SAM 2 segmentasyon modelinin sınıflar arası piksel geçiş matrisi.**

Şekil 6.21’de, SAM 2 segmentasyon modeli kullanılarak elde edilen piksel geçiş matrisi gösterilmektedir. Matris, 2020 ve 2023 yılları arasında her sınıfın piksel düzeyindeki değişimini ortaya koymaktadır. Elde edilen sonuçlara göre en belirgin geçişler bina, yeşil alan ve trafik işareti sınıflarında gözlenmiştir.

Yeşil alan sınıfında, 2020 yılındaki 4.227 pikselin yalnızca bir kısmı aynı sınıfta kalmış, 6.251 piksellik önemli bir bölümünün ortadan kalktığı, ayrıca 3.923 pikselin bu sınıfa yeni olarak eklendiği görülmektedir. Ek olarak 3.227 pikselin bina sınıfına dönüştüğü gözlemlenmiştir. Bu durum, yeşil alanların hem mekânsal konum hem de yoğunluk açısından değişkenlik gösterdiğini ortaya koymaktadır.

Bina sınıfında ise zamansal değişim çok daha belirgindir. 2020 yılında bina olarak etiketlenen 15.101 piksel silinmiş, 6.525 piksel yeni bina alanı oluşmuş, 1.444 piksel ise yeşil alana dönüşmüştür. Bu sonuç, çalışma bölgesinde yapılaşmanın dinamik bir süreç izlediğini ve bina sınıfının sürekli dönüşüm halinde olduğunu göstermektedir. Trafik işareti sınıfında ise, 1.627 pikselin 2023 yılında yeşil alana dönüştüğü, 452 pikselin bina ve yapılara dönüştüğü ve ayrıca 3.451 pikselin silindiği tespit edilmiştir.

Genel olarak, SAM 2 modeli sınıflar arası geçişleri ayrıntılı biçimde yakalayıp küçük ölçekli ekleme ve silinmeleri başarılı biçimde tespit etmiş, bu da modelin detay duyarlılığının yüksek olduğunu göstermiştir.



**Şekil 6.22: Senaryo-3 için Panoptik segmentasyon modelinin sınıflar arası piksel geçiş matrisi.**

Şekil 6.22’de, Panoptik segmentasyon modeli kullanılarak elde edilen piksel geçiş matrisi gösterilmiştir. Matris incelendiğinde, en yüksek değişim oranına sahip olan bina sınıfı öne çıkmaktadır. 2020 yılında bina olarak tanımlanan 18.137 pikselin silindiği, 11.184 pikselin konumu koruduğu, ayrıca 5.338 pikselin yeşil alana dönüştüğü ve 1.245 piksel yeni bina olarak eklendiği tespit edilmiştir. Bu durum, modelin geniş yüzeyli yapısal alanlardaki değişimleri güçlü biçimde yakalayabildiğini göstermektedir.

Yeşil alan sınıfında ise 2020 yılındaki 10.185 pikselin aynı sınıfta kaldığı, 8.532 pikselin binaya dönüştüğü, 8.090 piksel ise silindiği görülmektedir. Ayrıca 1.738 piksel yeni olarak eklenmiştir. Bu sonuçlar, yeşil alanların kısmen daraldığını ve bir bölümünün yapılaşma veya sınıf değişimi nedeniyle ortadan kalktığını göstermektedir. Trafik işareti sınıfında ise 1.121 pikselin yeşil alana dönüştüğü, 623 pikselin ise tamamen silindiği tespit edilmiştir. Panoptik segmentasyon modeli genel olarak büyük ölçekli nesne ve yüzeylerdeki değişimleri güvenilir biçimde yakalayabilmiş; ancak

küçük nesnelere (örneğin trafik işaretleri) değişimleri sınırlı biçimde tespit edebilmiştir. Bu sonuç, modelin sahne bütünlüğünü koruma eğilimi ile açıklanabilir.

Senaryo 3 kapsamında Tablo 6.13 ve Tablo 6.14'te, SAM 2 ve Panoptik segmentasyon modellerinden elde edilen sınıf bazlı yüzdelerdeki alan değişimleri karşılaştırmalı olarak verilmiştir. Her iki model için de 2020 ve 2023 yıllarına ait sınıfların alansal yüzdeleri hesaplanmış, bu değerler arasındaki farklar yüzde puan biçiminde ifade edilmiştir. Bu hesaplamalar, yıllar arasındaki sınıf bazlı artış veya azalış eğilimlerini ortaya koyarak, modellerin değişim tespit performanslarının karşılaştırmalı değerlendirilmesine olanak sağlamaktadır.

**Tablo 6.13: Senaryo-3 için SAM 2 segmentasyon çıktılarından elde edilen sınıf bazlı yüzdelerdeki alan değişimleri.**

Sınıf	2020 (%)	2023 (%)	Değişim Oranı (%)	Değişim Yönü
Yeşil Alan	6.420	5.260	-1.160	Azalma
Trafik İşareti	2.59	0	-2.59	Azalma
Bina	8.20	5.22	- 2.97	Azalma
Tabela	0	0	0	Değişim yok

**Tablo 6.14: Senaryo-3 için Panoptik segmentasyon çıktılarından elde edilen sınıf bazlı yüzdelerdeki alan değişimleri.**

Sınıf	2020 (%)	2023 (%)	Değişim Oranı (%)	Değişim Yönü
Yeşil Alan	11.56	7.93	-3.63	Azalma
Trafik İşareti	0.78	0	-0.78	Azalma
Bina	14.95	9.04	- 5.91	Azalma
Tabela	0	0	0	Değişim yok

**Tablo 6.15: Senaryo-3 için SAM 2 segmentasyon çıktılarından hesaplanan zamansal ve konumsal örtüşme oranları.**

Sınıf	Zamansal Örtüşme Oranı	Konumsal Örtüşme Oranı	Zamansal Örtüşme Durumu	Konumsal Benzerlik Durumu	Değişim Yorumu
<b>Yeşil Alan</b>	0.204	0.339	Düşük örtüşme	Düşük benzerlik	Kısmi değişim
<b>Trafik İşareti</b>	0	0	Örtüşme yok, sınıf kaybı	Benzerlik yok, sınıf kaybı	Sınıf son yılda bulunmuyor
<b>Bina</b>	0.034	0.066	Düşük örtüşme	Düşük benzerlik	Kısmi değişim
<b>Tabela</b>	0	0	Örtüşme yok	Benzerlik yok	Değişim yok

Tablo 6.15 incelendiğinde, SAM 2 segmentasyon sonuçlarına göre en düşük zamansal ve konumsal örtüşme oranlarının yeşil alan ve bina sınıflarında gözlemlendiği görülmektedir. Yeşil alan sınıfında elde edilen 0.204 ve 0.339 değerleri, sınıfın iki yıl arasında kısmi bir mekânsal değişim yaşadığını ve alan yoğunluğunda farklılık oluştuğunu göstermektedir. Bina sınıfında benzer şekilde 0.034 ve 0.066 değerleri ile düşük oranlar elde edilmiştir; bu da yapısal alanların konum veya biçim bakımından kısmen yeniden şekillendiğini ortaya koymaktadır. Trafik işareti sınıfında ise örtüşme oranları sıfır olarak hesaplanmış olup, bu durum sınıfın 2023 yılında tespit edilememesinden dolayı ilgili yılda tamamen ortadan kalktığını göstermektedir.

**Tablo 6.16: Senaryo-3 için Panoptik segmentasyon çıktılarından hesaplanan zamansal ve konumsal örtüşme oranları.**

Sınıf	Zamansal Örtüşme Oranı	Konumsal Örtüşme Oranı	Zamansal Örtüşme Durumu	Konumsal Benzerlik Durumu	Değişim Yorumu
<b>Yeşil Alan</b>	0.291	0.451	Düşük örtüşme	Düşük benzerlik	Orta düzey değişim
<b>Trafik İşareti</b>	0	0	Örtüşme yok, sınıf kaybı	Benzerlik yok, sınıf kaybı	Sınıf son yılda bulunmuyor
<b>Bina</b>	0.252	0.402	Düşük örtüşme	Düşük benzerlik	Orta düzey değişim
<b>Tabela</b>	0	0	Örtüşme yok	Benzerlik yok	Değişim yok

Tablo 6.16 incelendiğinde, Panoptik segmentasyon sonuçlarına göre yeşil alan ve bina sınıflarında düşük düzeyde zamansal ve konumsal örtüşme oranları gözlemlenmiştir. Yeşil

alan sınıfında 0.291 ve 0.451 olarak hesaplanan değerler, alanın iki yıl arasında orta düzeyde değişim göstermektedir. Benzer şekilde, bina sınıfında 0.252 ve 0.402 oranları elde edilmiş; bu da yapısal alanların yeniden düzenlendiğini veya genişlediğini ortaya koymaktadır. Trafik işareti sınıfında ise örtüşme oranları sıfır olarak hesaplanmış olup, bu durum sınıfın 2023 yılında tespit edilememesinden dolayı ilgili yılda tamamen ortadan kalktığını göstermektedir.

Panoptik model genel olarak, bina ve yeşil alan gibi geniş yüzeyli nesnelere kısmi ve orta düzeydeki değişimleri başarılı biçimde ortaya koyarken, küçük ölçekli nesnelere (örneğin trafik işaretleri) sınırlı bir duyarlılık göstermiştir.

Bu çalışmada yürütülen senaryo bazlı analizler, kentsel değişimlerin belirli nesne sınıflarında farklı yoğunluk ve biçimlerde gerçekleştiğini ortaya koymuştur. Özellikle örtüşme oranı düşük veya tamamen değişmiş nesnelere, belirli bölgelerde tekrarlayan değişim eğilimleri göstermiştir. Bu durum, elde edilen sonuçların yalnızca akademik bir analizle sınırlı kalmayıp, pratikte uygulanabilir ve karar alma süreçlerine entegre edilebilir çözümler için de önemli bir potansiyel barındırdığını göstermektedir. Literatürde, belirli bir teknolojinin veya yöntemin yaygın kabul görmesini sağlayan, yüksek etkiye sahip ve dönüştürücü potansiyeli bulunan uygulamalar “öncü uygulamalar (killer application)” olarak tanımlanmaktadır. Bu çalışmada hem SAM 2 hem de Panoptik segmentasyon modelleriyle elde edilen senaryo bazlı bulgular, kentsel çevrede kritik değişimlerin sistematik olarak izlenebilmesi için böyle bir uygulamanın zeminini oluşturmuştur. Geliştirilen sistem, sokak görünümü görüntülerinde zaman içindeki değişimleri tespit edebilmekte; yeşil alan kaybı, yeni yapıların ortaya çıkması ve trafik işaretlerinin kaybolması gibi unsurları hem görsel hem de sayısal olarak sunabilmektedir. Her iki modelin birlikte değerlendirilmesi, farklı segmentasyon yaklaşımlarının değişim tespit performansına etkisini ortaya koymuştur. Bu özellikleriyle çalışma, belediye ve şehir planlama birimleri için “Kentsel Değişim Tespit ve İzleme Sistemi” adı altında kullanılabilir, pratik ve etkili bir çözüm niteliği taşımaktadır.

Önerilen uygulamanın en önemli katkılarından biri, manuel saha incelemeleri yerine görüntü tabanlı ve otomatik bir değişim tespit altyapısı sunmasıdır. Çalışma kapsamında oluşturulan sınıf bazlı geçiş matrisleri ve zamansal örtüşme analizleri, bu sistemin temel karar mekanizmasını besleyecek şekilde kullanılabilir. Sonuç olarak,

söz konusu “Öncü Uygulama” ile hem geçmiş veriler üzerinden eğilim analizi yapılabilecek hem de güncel verilerle anlık kentsel değişim raporları üretilebilecektir.

Bu bağlamda, Panoptik modelin sahne bütünlüğünü korumadaki başarısı ile SAM 2'nin küçük ölçekli nesne değişimlerine duyarlılığı birbirini tamamlayıcı niteliktedir. Böylece iki modelin birlikte kullanımı, kentsel değişimlerin hem genel eğilimlerini hem de ayrıntı düzeyindeki farklılıklarını daha bütüncül biçimde ortaya koymuştur.



## SONUÇ

Bu tez çalışması, sokak düzeyinde kentsel değişimlerin, derin öğrenme tabanlı yöntemler kullanılarak güvenilir ve anlamlı biçimde tespit edilebileceğini göstermeyi amaçlamaktadır. Çalışmanın ilk çıkış noktası, panoramik sokak görüntülerinin doğal yapısında yer alan geometrik bozulmalar ve analiz zorlukları olmuştur. Bu tür görüntüler, geleneksel görüntü işleme ve segmentasyon teknikleri açısından analiz zorlukları barındırmakta; özellikle de nesne sınırlarının bozulması, uzak mesafedeki objelerin ayrıştırılamaması ve açısız sapmalar gibi nedenlerle doğru sınıflandırmaların önüne geçmektedir. Bu problemi ortadan kaldırmak amacıyla, panoramik görüntüler eşkenar dörtgen projeksiyon modeli aracılığıyla sokak görüntüsü biçimine dönüştürülmüş; böylece daha sağlıklı, anlamlı ve doğruluğu yüksek bir analiz zemini oluşturulmuştur. Gerçekleştirilen bu dönüşüm sayesinde, görüntü içerisindeki nesnelere sokak perspektifine daha uygun bir düzlemde yeniden yapılandırılmış ve segmentasyon işlemlerindeki problemler giderilmiştir.

Bu dönüşümün ardından gerçekleştirilen segmentasyon aşamasında, Meta AI tarafından geliştirilen SAM 2 ve Panoptik segmentasyon yöntemi tercih edilmiştir. Panoptik segmentasyon, sahne bütünlüğünü koruyarak semantik ve nesne tabanlı bilgiyi bir arada sunabilmesi bakımından çalışmaya bütüncül bir bakış kazandırmıştır. SAM 2 modeli ise kullanıcı yönlendirmesine dayalı, sıfır atış segmentasyon yapısı sayesinde küçük ölçekli ve ayrıntılı nesnelereki değişimleri daha hassas biçimde yakalayabilmiştir. Böylece her iki modelin birlikte kullanımı, hem detay hem de genel düzeyde kentsel değişimlerin daha doğru biçimde tespit edilmesini sağlamıştır.

SAM 2'nin en belirgin özelliği, kullanıcıdan gelen sınıf ve konum bilgilerine dayalı olarak istenilen nesnelere otomatik biçimde maskeyle ayrıştırabilen interaktif bir yapıya sahip olmasıdır. Bu özellik sayesinde, klasik segmentasyon yöntemlerinde karşılaşılan zaman alıcı ve hataya açık manuel etiketleme süreçleri tamamen ortadan kaldırılmış; kullanıcı yalnızca analiz edilmek istenen sınıf isimlerini ve bu sınıfların yaklaşık konumlarını belirlemiştir. Geri kalan tüm ayrıştırma işlemleri SAM 2 tarafından otomatik ve yüksek doğrulukta gerçekleştirilmiştir. Bu durum, yalnızca zamandan tasarruf sağlamamış, aynı zamanda segmentasyon sürecini ve tekrar edilebilirliğini de büyük ölçüde artırmıştır.

SAM 2'nin bu kullanıcı yönlendirmesine dayalı yapısı, çalışmanın amacına özel sınıf tanımlamaları yapılmasına imkân sağlamıştır. Sabit ve önceden tanımlanmış sınıf listeleri yerine, analiz kapsamında ihtiyaç duyulan sınıflar kullanıcı tarafından belirlenmiş; "bina-yapı", "yeşil alan", "trafik işareti" ve "tabela" gibi sınıflar çalışmanın hedef nesne kümeleri olarak seçilmiştir. Bu esneklik sayesinde, sadece belirli nesne gruplarına odaklanan ve anlamlı sonuçlar üreten segmentasyon maskeleri elde edilmiştir. Ayrıca SAM 2 çıktılarının renkli maske formatında sunulması, görsel analizlerin hem sezgisel olarak yorumlanmasını kolaylaştırmış hem de sonraki değişim tespiti adımları için sağlam ve tutarlı bir altyapı oluşturmuştur.

Buna karşılık, Panoptik segmentasyon modeli önceden etiketlenmiş veriler üzerinde eğitildiği için sınıf tanımlarında daha katı bir yapıya sahiptir. Bu nedenle, model eğitiminde yer almayan ya da görsel bağlamı farklı biçimde sunulan nesnelere karşılaştığında, SAM 2 kadar esnek ve uyarlanabilir bir performans sergileyememektedir. Özellikle sahnede ölçeği küçük olan veya görsel olarak benzer yapılarla çevrili nesnelere (örneğin trafik işaretleri ya da tabelalar) segmentasyon başarısı sınırlı kalabilmektedir. Buna rağmen, Panoptik modelin geniş yüzey alanlarına sahip sınıflarda (örneğin bina ya da yol bölgeleri) sahne bütünlüğünü koruduğu gözlemlenmiştir.

Çalışmanın değişim tespiti aşamasında ise, her biri farklı çevresel ve yapısal dönüşüm türlerini temsil eden üç senaryo geliştirilmiştir. Bu senaryolar, binlerce panoramik görüntüden anlamlı ve temsili örnekler oluşturmak amacıyla seçilmiş; her bir senaryoda farklı sınıfların yok olması, yeni yapıların inşa edilmesi, yeşil alanların daralması ya da nesnelere sabit kalması gibi durumlar modellenmiştir. Böylece hem kentsel dönüşümün farklı yönleri gözlemlenmiş, hem de geliştirilen yöntemin genellenebilirliği test edilmiştir.

Değişim analizleri kapsamında, dört ana metrik geliştirilmiştir: sınıf bazlı piksel yüzdesi değişimi, sınıf dönüşüm matrisi, zamansal örtüşme oranı ve değişim yoğunluğu haritası. Bu metriklerden ilki, iki yıl arasındaki her bir sınıfın piksel oranındaki artış ya da azalışı yüzdelik olarak hesaplamıştır. İkinci olarak oluşturulan sınıf dönüşüm matrisi, bir sınıfın başka bir sınıfa dönüşümünü göstererek çevresel veya yapısal değişimin yönünü açıkça ortaya koymuştur. Üçüncü olarak, aynı sınıfın yıllar içerisindeki konumsal örtüşmesi zamansal benzerlik ölçütü olarak sunulmuş; bu değerler, belirli nesnelere sahnede ne ölçüde sabit kaldığını ya da hareket ettiğini

ortaya koymuştur. Son olarak ise, yalnızca değişime uğrayan piksellerin vurgulandığı fark haritaları ve bu değişimlerin yoğunluklarını gösteren ısı haritaları oluşturulmuştur. Bu görselleştirmeler sayesinde, değişimlerin mekânsal olarak nerelerde yoğunlaştığı kullanıcıya açık ve sezgisel bir biçimde sunulmuştur.

Elde edilen tüm bu sonuçlar değerlendirildiğinde, SAM 2 ve Panoptik segmentasyon modelleri ayrı ayrı uygulanarak karşılaştırmalı biçimde analiz edilmiştir. Bu karşılaştırma, her iki modelin yapısal farklılıklarının değişim tespiti performansına etkisini ortaya koymuştur. Panoptik segmentasyon modeli, etiketli veriler üzerinde eğitilmiş bir yapıya sahip olduğundan, tanımlı sınıflar dışındaki nesnelere esneklik gösterememekte; bu nedenle, sahne genelinde daha bütüncül ancak sınıf çeşitliliği açısından daha kısıtlı sonuçlar üretmektedir. Buna karşılık, SAM 2 modeli kullanıcı yönlendirmesine dayalı yarı otomatik segmentasyon yapısı sayesinde, yeni veya önceden tanımlanmamış nesne türlerini de tanıyabilmekte ve küçük ölçekli değişimlere daha yüksek duyarlılıkla tepki verebilmektedir.

Bu açıdan, SAM 2'nin kullanıcı kontrollü ancak otomatikleşmiş işleyişi, klasik etiketleme ve analiz yöntemlerine kıyasla daha esnek, özelleştirilebilir ve zamandan tasarruf sağlayan bir yapı sunmuştur. Öte yandan Panoptik segmentasyonun önceden etiketlenmiş veri temelli yapısı, geniş yüzey alanına sahip sınıflarda (örneğin bina veya yol bölgelerinde) sahne bütünlüğünü koruma açısından daha tutarlı sonuçlar elde edilmesini sağlamıştır. Sonuç olarak, bu iki modelin karşılaştırmalı değerlendirmesi, etkileşimli yaklaşımların (SAM 2) küçük ve dinamik nesne değişimlerinde, etiket tabanlı yaklaşımların (Panoptik segmentasyon) ise genel sahne istikrarını ölçmede daha başarılı olduğunu göstermiştir. Böylece çalışmada, farklı segmentasyon çeşitlerinin güçlü yönleri bütüncül bir bakış açısıyla ortaya konmuştur.

Bu yönüyle tez çalışması, yalnızca akademik anlamda teorik bir katkı sunmakla kalmayıp, aynı zamanda şehir planlama, kentsel dönüşüm izleme, çevresel sürdürülebilirlik ve afet sonrası hasar tespiti gibi alanlarda uygulanabilirliği yüksek bir yöntem ortaya koymaktadır. Bunun yanı sıra geliştirilen “Kentsel Değişim Tespit ve İzleme Sistemi”, savunma ve güvenlik uygulamalarında, örneğin sınır bölgelerinde gerçekleşen yapılaşmaların veya araç hareketlerinin izlenmesinde; altyapı yönetimi süreçlerinde, kent içi yapısal değişimlerin takibinde; tarımsal alanlarda, arazi kullanımı ve yeşil alan dönüşümlerinin analizinde ve afet sonrası iyileşme

çalışmalarında, yeniden inşa edilen bölgelerin izlenmesinde etkin biçimde kullanılabilecek potansiyele sahiptir.

Sonuç olarak, bu tez çalışması, modern segmentasyon modellerinin karşılaştırmalı biçimde değerlendirildiği kapsamlı bir yapıyla hem kentsel hem de çevresel değişimlerin yüksek doğrulukla izlenebileceğini göstermiştir. Bu kapsamda geliştirilen sistem, yalnızca akademik bir model olmanın ötesinde, “Öncü Uygulama (Killer Application)” niteliği taşıyan, farklı alanlara uyarlanabilir ve karar destek süreçlerine entegre edilebilir bir çözüm olarak değerlendirilmektedir.

Gelecekte yapılacak çalışmalarda, geliştirilen sistemin uydu veya hava görüntüleriyle entegre edilmesi, daha geniş coğrafi ölçekte otomatik değişim takibini mümkün kılabilir. Ayrıca, SAM 2 ve Panoptik segmentasyonun birleşik ya da hibrit yapılarla bir araya getirilmesi hem sahne bütünlüğü hem de nesne düzeyinde hassasiyetin aynı anda sağlandığı yeni nesil değişim tespit sistemlerinin geliştirilmesine katkı sağlayacaktır.

## KAYNAKÇA

- Ai, H., Cao, Z., Zhu, J., Bai, H., Chen, Y., & Wang, L. (2022). Deep learning for omnidirectional vision: A survey and new perspectives. arXiv preprint arXiv:2205.10468.
- Alcantarilla, P. F., Stent, S., Ros, G., Arroyo, R., & Gherardi, R. (2018). Street-view change detection with deconvolutional networks. *Autonomous Robots*, 42, 1301-1322.
- Allred, A., Abbott, L. J., Doostan, A., & Maute, K. (2022). Automated processing of X-ray computed tomography images via panoptic segmentation for modeling woven composite textiles. arXiv preprint arXiv:2202.01265.
- AnkaGeo Coğrafi Bilgi Teknolojileri. (2021). *AnkaGeo Coğrafi Bilgi Teknolojileri Resmi Web Sitesi*. <https://ankageo.com/> (Erişim tarihi: 27.07.2025)
- Bay, H., Ess, A., Tuytelaars, T., & Van Gool, L. (2008). Speeded-up robust features (SURF). *Computer vision and image understanding*, 110(3), 346-359.
- Biljecki, F., & Ito, K. J. L. (2021). Street view imagery in urban analytics and GIS: A review. *Landscape and Urban Planning*, 215, 104217.
- Blott, G., Takami, M., & Heipke, C. (2018). Semantic Segmentation of Fisheye Images. In *ECCV Workshops*.
- Byun, G., & Kim, Y. (2022). A street-view-based method to detect urban growth and decline: A case study of Midtown in Detroit, Michigan, USA. *Plos one*, 17(2), e0263775.
- Chen, H., Qi, Z., & Shi, Z. (2021). Remote sensing image change detection with transformers. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-14.
- Chen, J., Gong, P., He, C., Pu, R., & Shi, P. (2012). Land-use/land-cover change detection using improved change-vector analysis. *Photogrammetric Engineering & Remote Sensing*, 69(4), 369–379.
- Chen, J., Li, Q., Peng, Q., & Wong, K. H. (2015). CSIFT based locality-constrained linear coding for image classification. *Pattern Analysis and Applications*, 18(2), 441-450.

- Chen, J., Yuan, Z., Peng, J., Chen, L., Huang, H., Zhu, J., ... & Li, H. (2020). DASNet: Dual attentive fully convolutional Siamese networks for change detection in high-resolution satellite images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 1194-1206.
- Chen, S., Yang, K., & Stiefelwagen, R. (2021, July). Dr-tanet: Dynamic receptive temporal attention network for street scene change detection. In *2021 IEEE Intelligent Vehicles Symposium (IV)* (pp. 502-509). IEEE.
- Cheng, B., Collins, M. D., Zhu, Y., Liu, T., Huang, T. S., Adam, H., & Chen, L. C. (2020). Panoptic-deeplab: A simple, strong, and fast baseline for bottom-up panoptic segmentation. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 12475-12485).
- Cheng, G., Huang, Y., Li, X., Lyu, S., Xu, Z., Zhao, H., ... & Xiang, S. (2024). Change detection methods for remote sensing in the last decade: A comprehensive review. *Remote Sensing*, 16(13), 2355.
- Coppin, P., Jonckheere, I., Nackaerts, K., Muys, B., & Lambin, E. (2004). Digital change detection methods in ecosystem monitoring: a review. *International Journal of Remote Sensing*, 25(9), 1565–1596.
- Cowan, L. V., Babington, J., Carles, G., Perciado, M. A., Wood, A. P., & Harvey, A. R. (2019). 360° snapshot imaging with a convex array of longwave infrared cameras. In *Imaging and Applied Optics 2019 (COSI, IS, MATH, pcAOP)*. Optical Society of America.
- Cui, Y., Chen, H., Dong, S., Wang, G., & Zhuang, Y. (2024). U-shaped CNN-ViT Siamese network with learnable mask guidance for remote sensing building change detection. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*.
- Dalal, N., & Triggs, B. (2005). Histograms of oriented gradients for human detection. In *Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)* (pp. 886–893). San Diego, CA, USA

- DeTone, D., Malisiewicz, T., & Rabinovich, A. (2018). Superpoint: Self-supervised interest point detection and description. In Proceedings of the IEEE conference on computer vision and pattern recognition workshops (pp. 224-236).
- Dong, H., Ma, W., Wu, Y., Gong, M., & Jiao, L. (2018). Local descriptor learning for change detection in synthetic aperture radar images via convolutional neural networks. *IEEE access*, 7, 15389-15403.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., ... & Houlsby, N. (2020). An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*.
- Elharrouss, O., Al-Maadeed, S., Subramanian, N., Ottakath, N., Almaadeed, N., & Himeur, Y. (2021). Panoptic segmentation: A review. *arXiv preprint arXiv:2111.10250*.
- Elharrouss, O., Moujahid, D., Elkah, S., & Tairi, H. (2016). Moving object detection using a background modeling based on entropy theory and quad-tree decomposition. *Journal of Electronic Imaging*, 25(6), 061615-061615.
- Gao, S., Yang, K., Shi, H., Wang, K., & Bai, J. (2022). Review on panoramic imaging and its applications in scene understanding. *IEEE Transactions on Instrumentation and Measurement*, 71, 1-34.
- Gao, T., Lan, C., Wang, L., Huang, W., Yao, F., & Wei, Z. (2023). Leveraging CNNs for panoramic image matching based on improved cube projection model. *Remote Sensing*, 15(13), 3411.
- Ghouaiel, N., & Lefèvre, S. (2016). Coupling ground-level panoramas and aerial imagery for change detection. *Geo-spatial Information Science*, 19(3), 222-232.
- Gledhill, D., Tian, G.-Y., Taylor, D., & Clarke, D. (2003). Panoramic imaging – A review. *Computers & Graphics*, 27(3), 435–445.
- Guo, E., Fu, X., Zhu, J., Deng, M., Liu, Y., Zhu, Q., & Li, H. (2018). Learning to measure change: Fully convolutional siamese metric networks for scene change detection. *arXiv preprint arXiv:1810.09111*.

- Gurrieri, L. E., & Dubois, E. (2013). Acquisition of omnidirectional stereoscopic images and videos of dynamic scenes: A review. *Journal of Electronic Imaging*, 22(1), 011003.
- Haggi, O., Bayd, H., Magnier, B., & Aberkane, A. (2021). Human detection in moving fisheye camera using an improved YOLOv3 framework. In *Proceedings of the 2021 IEEE 23rd International Workshop on Multimedia Signal Processing (MMSp)* (pp. 1–6). IEEE.
- Hao, S., Zhou, Y., & Guo, Y. (2020). A brief survey on semantic segmentation with deep learning. *Neurocomputing*, 406, 302–321.
- He, N., & Li, G. (2021). Urban neighbourhood environment assessment based on street view image processing: A review of research trends. *Environmental Challenges*, 4, 100090.
- Hua, H., Ahuja, N., & Gao, C. (2007). Design analysis of a high-resolution panoramic camera using conventional imagers and a mirror pyramid. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(2), 356–361.
- Huang, J., Guan, D., Xiao, A., & Lu, S. (2021). Cross-view regularization for domain adaptive panoptic segmentation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 10133-10144).
- Huang, K.-C., Chien, P.-Y., Chien, C.-A., Chang, H.-C., & Guo, J.-I. (2014). A 360-degree panoramic video system design. In *Proceedings of the 2014 International Symposium on VLSI Design, Automation and Test* (pp. 1–4).
- Hussain, M., Chen, D., Cheng, A., Wei, H., & Stanley, D. (2013). Change detection from remotely sensed images: From pixel-based to object-based approaches. *ISPRS Journal of Photogrammetry and Remote Sensing*, 80, 91–106.
- Jakab, D., Wolf, C., & Dufour, N. (2024). Surround-View Fisheye Optics in Computer Vision and Simulation: Survey and Challenges. arXiv preprint. <https://arxiv.org/abs/2402.12041>
- Kang, Y., Zhang, F., Gao, S., Lin, H., & Liu, Y. (2020). A review of urban physical environment sensing using street view imagery in public health studies. *Annals of GIS*, 26(3), 261–275.

- Kelly, C. M., Wilson, J. S., Baker, E. A., Miller, D. K., & Schootman, M. (2013). Using Google Street View to audit the built environment: Inter-rater reliability results. *Annals of Behavioral Medicine*, 45(Suppl 1), S108–S112.
- Khan, S. H., He, X., Porikli, F., Bennamoun, M., Sohel, F., & Togneri, R. (2016). Learning deep structured network for weakly supervised change detection. arXiv preprint arXiv:1606.02009.
- Kirillov, A., Girshick, R., He, K., & Dollár, P. (2019). Panoptic feature pyramid networks. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 6399-6408).
- Kirillov, A., He, K., Girshick, R., Rother, C., & Dollár, P. (2019). Panoptic segmentation. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 9404-9413).
- Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., ... & Girshick, R. (2023). Segment anything. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 4015-4026).
- Larkin, A., Gu, X., Chen, L., & Hystad, P. J. L. (2021). Predicting perceptions of the built environment using GIS, satellite and street view image approaches. *Landscape and Urban Planning*, 216, 104257.
- Law, S., Paige, B., & Russell, C. (2019). Take a look around: Using street view and satellite images to estimate house prices. *ACM Transactions on Intelligent Systems and Technology*, 10(5), 1–19.
- Lazarow, J., Lee, K., Shi, K., & Tu, Z. (2020). Learning instance occlusion for panoptic segmentation. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 10720-10729).
- Li, G., Wang, J., Shen, H. W., Chen, K., Shan, G., & Lu, Z. (2020). Cnnpruner: Pruning convolutional neural networks with visual analytics. *IEEE Transactions on Visualization and Computer Graphics*, 27(2), 1364-1373.
- Li, X., Jie, Z., Wang, W., Liu, C., Yang, J., Shen, X., ... & Feng, J. (2017). Foveanet: Perspective-aware urban scene parsing. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 784-792).

- Li, X., Yuan, Z., & Wang, Q. (2019). Unsupervised deep noise modeling for hyperspectral image change detection. *Remote Sensing*, 11(3), 258.
- Li, X., Zhang, C., Li, W., Ricard, R., Meng, Q., & Zhang, W. (2015). Assessing street-level urban greenery using Google Street View and a modified green view index. *Urban Forestry & Urban Greening*, 14(3), 675–685.
- Li, Y., Peng, L., Wu, C., & Zhang, J. (2022). Street View Imagery (SVI) in the built environment: A theoretical and systematic review. *Buildings*, 12(8), 1167.
- Lin, C.-H., Hsiao, L., Hsiao, J.-T., & Lin, H. Y. (2014). Front view and panoramic side view videoscope lens system design. *Applied Optics*, 53(29), H146–H152.
- Lin, H. S., Chang, C.-C., Chang, H.-Y., Chuang, Y.-Y., Lin, T., & Ouhyoung, M. (2019). A low-cost portable polycamera for stereoscopic 360° imaging. *IEEE Transactions on Circuits and Systems for Video Technology*, 29(3), 915–929.
- Liu, D., Zhang, D., Song, Y., Zhang, F., O'Donnell, L., Huang, H., ... & Cai, W. (2020). Pdam: A panoptic-level feature alignment framework for unsupervised domain adaptive instance segmentation in microscopy images. *IEEE Transactions on Medical Imaging*, 40(1), 154-165.
- Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3431-3440).
- Lowe, D. G. (1999). Object recognition from local scale-invariant features. In *Proceedings of the Seventh IEEE International Conference on Computer Vision* (pp. 1150–1157). Kerkyra, Greece.
- Lowe, D. G. (2004). Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60, 91-110.
- Lu, X., Kang, X., Nishide, S., & Ren, F. (2019, December). Object detection based on SSD-ResNet. In *2019 IEEE 6th International Conference on Cloud Computing and Intelligence Systems (CCIS)* (pp. 89-92). IEEE.
- Lürig, M. D., Donoughe, S., Svensson, E. I., Porto, A., & Tsuboi, M. (2021). Computer vision, machine learning, and the promise of phenomics in ecology and evolutionary biology. *Frontiers in Ecology and Evolution*, 9, 148.

- Ma, C., Yin, H., Weng, L., Xia, M., & Lin, H. (2023). DAFNet: A novel change-detection model for high-resolution remote-sensing imagery based on feature difference and attention mechanism. *Remote Sensing*, 15(15), 3896.
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS journal of photogrammetry and remote sensing*, 152, 166-177.
- Mandal, M., & Vipparthi, S. K. (2021). An empirical review of deep learning frameworks for change detection: Model design, experimental frameworks, challenges and research needs. *IEEE Transactions on Intelligent Transportation Systems*.
- Mei, L., Ye, Z., Xu, C., Wang, H., Wang, Y., Lei, C., ... & Li, Y. (2024). SCD-SAM: Adapting segment anything model for semantic change detection in remote sensing imagery. *IEEE Transactions on Geoscience and Remote Sensing*.
- Miyamoto, K. (1964). Fish eye lens. *Journal of the Optical Society of America*, 54(8), 1060–1061.
- Muja, M., & Lowe, D. G. (2014). Scalable nearest neighbor algorithms for high dimensional data. *IEEE transactions on pattern analysis and machine intelligence*, 36(11), 2227-2240.
- Oliva, A., & Torralba, A. (2001). Modeling the shape of the scene: A holistic representation of the spatial envelope. *International Journal of Computer Vision*, 42(3), 145–175.
- Pang, H. E., & Biljecki, F. (2022). 3D building reconstruction from single street view images using deep learning. *International Journal of Applied Earth Observation and Geoinformation*, 112, 102859.
- Parelius, E. J. (2023). A review of deep-learning methods for change detection in multispectral remote sensing images. *Remote Sensing*, 15(8), 2092.
- Peng, D., Zhang, Y., & Guan, H. (2019). End-to-end change detection for high resolution satellite images using improved UNet++. *Remote Sensing*, 11(11), 1382.
- Porzi, L., Rota Bulò, S., Lepri, B., & Ricci, E. (2015). Predicting and understanding urban perception with convolutional neural networks. In *Proceedings of the*

23rd ACM International Conference on Multimedia (pp. 139–148). Brisbane, Australia

Radford, A., Kim, J. W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., ... & Sutskever, I. (2021, July). Learning transferable visual models from natural language supervision. In International conference on machine learning (pp. 8748-8763). PmLR.

Rajalingappaa, S. (2018). *Deep learning for computer vision*. Packt Publishing. Retrieved from <https://www.oreilly.com/library/view/deep-learning-for/9781788295628/4fe36c40-7612-44b8-8846-43c0c4e64157.xhtml> (Erişim tarihi: 20.07.2024)

Ravi, N., Gabeur, V., Hu, Y. T., Hu, R., Ryali, C., Ma, T., ... & Feichtenhofer, C. (2024). Sam 2: Segment anything in images and videos. arXiv preprint arXiv:2408.00714.

Ren, C., Xi, S., Wang, G., Zhang, J., Yang, K., & Stiefelhagen, R. (2022). *Deep learning for omnidirectional vision: A survey and new perspectives*. arXiv preprint arXiv:2205.10468. <https://arxiv.org/abs/2205.10468>

Sakurada, K., Shibuya, M., & Wang, W. (2020, May). Weakly supervised silhouette-based semantic scene change detection. In 2020 IEEE International conference on robotics and automation (ICRA) (pp. 6861-6867). IEEE.

Sakurada, K., Wang, W., Kawaguchi, N., & Nakamura, R. (2017). Dense optical flow based change detection network robust to difference of camera viewpoints. arXiv preprint arXiv:1712.02941.

Sarlin, P. E., DeTone, D., Malisiewicz, T., & Rabinovich, A. (2020). SuperGlue: Learning feature matching with graph neural networks. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 4938-4947).

Shi, W., Zhang, M., Zhang, R., Chen, S., & Zhan, Z. (2020). Change detection based on artificial intelligence: State-of-the-art and challenges. *Remote Sensing*, 12(10), 1688.

- Shi, W., Zhang, M., Zhang, R., Chen, S., & Zhan, Z. (2020). Change detection based on artificial intelligence: State-of-the-art and challenges. *Remote Sensing*, 12(10), 1688.
- Singh, A. (1989). Review article digital change detection techniques using remotely-sensed data. *International journal of remote sensing*, 10(6), 989-1003.
- Sreenu, G. S. D. M. A., & Durai, S. (2019). Intelligent video surveillance: a review through deep learning techniques for crowd analysis. *Journal of Big Data*, 6(1), 1-27.
- Startsev, M., & Dorr, M. (2018). 360-aware saliency estimation with conventional image saliency predictors. *Signal Processing: Image Communication*, 69, 43-52.
- Stegmüller, T., Lebailly, T., Dukic, N., Bozorgtabar, B., Tuytelaars, T., & Thiran, J. P. (2024). A Simple Framework for Open-Vocabulary Zero-Shot Segmentation. arXiv preprint arXiv:2406.16085.
- Sun, Y., Zuo, W., Huang, H., Cai, P., & Liu, M. (2020). Pointmoseg: Sparse tensor-based end-to-end moving-obstacle segmentation in 3-d lidar point clouds for autonomous driving. *IEEE Robotics and Automation Letters*, 6(2), 510-517.
- Sun, Z., Song, H., Zhang, K., Dong, G., Liang, L., & Zhao, Y. (2024, April). Segment anything model guided semantic knowledge learning for remote sensing change detection. In *ICASSP 2024-2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 5830-5834). IEEE.
- Tang, Y., Zhang, J., Liu, R., & Li, Y. (2022). Exploring the impact of built environment attributes on social followings using social media data and deep learning. *ISPRS International Journal of Geo-Information*, 11(6), 325.
- Thibault, S., Gauvin, J. R., Doucet, M., & Wang, M. (2005). Enhanced optical design by distortion control. In *Proceedings of SPIE Optical Systems Design 2005*. SPIE.
- Tilki, S., & Zengin, A. T. (2021, November). Natural and Applied Science 2021 (ICENAS'21) November 24-26, 2021-Osmaniye, Turkey. In *Proc. ICENAS'21* (pp. 24-26).

- Tilki, S., Kaplan, A., & Zengin, A. T. (2024, April). Zero-Shot Object Detection and Segmentation: A Focus on Street View Imagery. In 2024 IEEE 3rd International Conference on Computing and Machine Intelligence (ICMI) (pp. 1-5). IEEE. <https://doi.org/10.1109/ICMI60790.2024.10585911>
- Varghese, S., Gao, J., & Hoskere, V. (2024). ViewDelta: Text-Prompted Change Detection in Unaligned Images. arXiv preprint arXiv:2412.07612.
- Vu, H., Le, T. L., Nguyen, V. G., & Dinh, T. H. (2018). Semantic regions segmentation using a spatio-temporal model from an UAV image sequence with an optimal configuration for data acquisition. *Journal of Information and Telecommunication*, 2(2), 126–146.
- Wu, C., Cenci, J., Wang, W., & Zhang, J. (2022). Resilient city: Characterization, challenges and outlooks. *Buildings*, 12(4), 516
- Wu, J., Cui, Z., Sheng, V. S., Zhao, P., Su, D., & Gong, S. (2013). A Comparative Study of SIFT and its Variants. *Measurement science review*, 13(3), 122.
- Xia, D., Huang, J., Yang, J., Liu, X., & Wang, H. (2022, October). Duarus: automatic geo-object change detection with street-view imagery for updating road database at baidu maps. In *Proceedings of the 31st ACM International Conference on Information & Knowledge Management* (pp. 3565-3574).
- Xian, Y., Schiele, B., & Akata, Z. (2019). Zero-shot learning: The good, the bad and the ugly. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 4582–4591.
- Yang, K., Gao, S., Shi, H., Wang, K., & Bai, J. (2022). *Review on panoramic imaging and its applications in scene understanding*. arXiv preprint arXiv:2205.05570. <https://arxiv.org/abs/2205.05570>
- Yang, W., Qian, Y., Kämäräinen, J. K., Cricri, F., & Fan, L. (2018, August). Object detection in equirectangular panorama. In *2018 24th international conference on pattern recognition (icpr)* (pp. 2190-2195). IEEE.
- Ye, Y., Richards, D., Lu, Y., Song, X., Zhuang, Y., Zeng, W., & Zhong, T. (2019). Measuring daily accessed street greenery: A human-scale approach for informing better urban planning practices. *Landscape and Urban Planning*, 191, 103434.

- Yeong, D. J., Velasco-Hernandez, G., Barry, J., & Walsh, J. (2021). Sensor and sensor fusion technology in autonomous vehicles: A review. *Sensors*, 21(6), 2140.
- Yi, K. M., Trulls, E., Lepetit, V., & Fua, P. (2016). Lift: Learned invariant feature transform. In *Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part VI 14* (pp. 467-483). Springer International Publishing.
- Yuan, H., Wang, B., Zhang, J. A., & Li, H. (2010). A novel method for geometric correction of multi-cameras in panoramic video system. In *Proceedings of the 2010 International Conference on Measuring Technology and Mechatronics Automation* (Vol. 1, pp. 248–251).
- Zeng, L., Lu, J., Li, W., & Li, Y. (2018). A fast approach for large-scale sky view factor estimation using street view images. *Building and Environment*, 135, 74–84.
- Zhan, Y., Fu, K., Yan, M., Sun, X., Wang, H., & Qiu, X. (2017). Change detection based on deep siamese convolutional network for optical aerial images. *IEEE Geoscience and Remote Sensing Letters*, 14(10), 1845-1849.
- Zhang, G., Pan, Y., & Zhang, L. (2022). Deep learning for detecting building façade elements from images considering prior knowledge. *Automation in Construction*, 133, 104016.
- Zhang, W., & Lu, X. (2019). The spectral-spatial joint learning for change detection in multispectral imagery. *Remote Sensing*, 11(3), 240.
- Zhang, Y., Chen, N., Du, W., Li, Y., & Zheng, X. (2021). Multi-source sensor based urban habitat and resident health sensing: A case study of Wuhan, China. *Building and Environment*, 198, 107883.
- Zhao, X., Wu, Z., Chen, Y., Zhou, W., & Wei, M. (2024). Fine-Grained High-Resolution Remote Sensing Image Change Detection by SAM-UNet Change Detection Model. *Remote Sensing*, 16(19), 3620.
- Zheng, Z., Ermon, S., Kim, D., Zhang, L., & Zhong, Y. (2024). Changen2: Multi-temporal remote sensing generative change foundation model. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- Zhou, Y., Liu, Y., Ji, W., Wu, Q., & Song, Y. (2022). A Comprehensive Survey on Zero-shot Image Segmentation. *arXiv preprint arXiv:2211.08352*.

Zhou, Y., Wang, J., Ding, J., Liu, B., Weng, N., & Xiao, H. (2023). Signet: A siamese graph convolutional network for multi-class urban change detection. *Remote Sensing*, 15(9), 2464.



## ÖZGEÇMİŞ

Sahra TİLKİ

### A. EĞİTİM

Sahra Tilki, 1994 yılında Bursa’da doğdu. İlk ve orta öğrenimini Balıkesir’de tamamladı. 2017 yılında İstanbul Sabahattin Zaim Üniversitesi Bilgisayar Mühendisliği lisans programından mezun oldu. 2018–2020 yılları arasında İstanbul Sabahattin Zaim Üniversitesi Bilgisayar Bilimi ve Mühendisliği yüksek lisans programını tamamladı. 2020 yılında aynı üniversitenin Bilgisayar Bilimleri ve Mühendisliği doktora programına başladı.

### B. MESLEKİ DENEYİM

2022 yılından bu yana İstanbul Sabahattin Zaim Üniversitesi Bilgisayar Mühendisliği Bölümü’nde araştırma görevlisi olarak çalışmaktadır.

### C. YAYINLAR

Rasheed, J., Jamil, A., Dogru, H. B., Tilki, S., & Yesiltepe, M. (2019, November). A deep learning-based method for Turkish text detection from videos. *In 2019 11th International Conference on Electrical and Electronics Engineering (ELECO)* (pp. 935-939). Ieee.

Dogru, H. B., Tilki, S., Jamil, A., & Hameed, A. A. (2021, April). Deep learning-based classification of news texts using doc2vec model. *In 2021 1st International Conference on Artificial Intelligence and Data Analytics (CAIDA)* (pp. 91-96). IEEE.

Tilki, S., Dogru, H. B., & Hameed, A. A. (2021). Gender classification using deep learning techniques. *Manchester journal of Artificial Intelligence and Applied sciences*, 2(2).

Doğru, H. B., Hameed, A. A., Tilki, S., & Jamil, A. (2021). Comparative analysis of deep learning and traditional machine learning models for Turkish text classification. *In 1st International Conference on Computing and Machine Intelligence*. İstanbul Sabahattin Zaim Üniversitesi.

Dođru, H. B., Őirin, Y., Tilki, S., YeŐiltepe, M., Rasheed, J., & Khan, M. U. S. (2021). Fruits Sorting with Instance Based Image Processing. *In 1st International Conference on Computing and Machine Intelligence*. İstanbul Sabahattin Zaim Üniversitesi.

Alimovski, E., & Rasheed, J. (2021). Automated Biometrical Fingerprint Recognition Scheme using Synthesized Images. *In 1st International Conference on Computing and Machine Intelligence*. İstanbul Sabahattin Zaim Üniversitesi.

Tilki, S., & Zengin, A. T. (2021, November). IPCA based agricultural land classification and change detection using histogram for autonomous UAVs. *In Proceedings of the International Conference on Engineering Natural and Applied Sciences (ICENAS'21)* (pp. 24–26), Osmaniye, Turkey.

Tilki, S., Kaplan, A., & Zengin, A. T. (2024, April). Zero-Shot Object Detection and Segmentation: A Focus on Street View Imagery. *In 2024 IEEE 3rd International Conference on Computing and Machine Intelligence (ICMI)* (pp. 1-5). IEEE.

#### **D. PROJELER**

**Proje Adı:** Sokak Görünümü Görüntüleriyle YeŐil Alan, Bina ve Trafik İşaretlerinde Derin Öğrenme Tabanlı Deđişim Tespiti

**Proje No:** 2024-BAP-300-001

**Destekleyen Kurum:** İstanbul Sabahattin Zaim Üniversitesi

**Proje Süresi:** 03.06.2024 – 03-12.2024

# ETİK ONAY BELGESİ



T.C.  
İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ REKTÖRLÜĞÜ  
ETİK KURULU BAŞKANLIĞI

Sayı : E-20292139-050.03-202535397  
Konu : Etik Kurul 2025/9 No'lu Toplantı (Sahra  
TİLKİ)

Sayın Sahra TİLKİ

Bilgisayar Mühendisliği Ana Bilim Dalı, Bilgisayar Bilimleri Doktora Programı Öğrencisi "Derin Öğrenme Tabanlı Kentsel Değişim Tespiti ve İzleme Sistemi" başlıklı araştırmanızla ilgili başvurunuz 02.10.2025 tarihli ve 2025/9 sayılı toplantısında değerlendirilerek araştırmanızın etik açıdan uygun bulunduğuna katılanların oy birliği ile karar verilmiştir.  
Bilgilerinize arz ederim.

Prof. Dr. Ali Haydar ŞAR  
Kurul Başkanı

Ek:14.10.2025. Etik Kurul 2025\_9 No\_lu Toplantı (Sahra TILKI) (1 Sayfa)

**Bu belge, güvenli elektronik imza ile imzalanmıştır.**

Belge Doğrulama Kodu : \*BSE3LMKBH8\* Pin Kodu : 03762

Belge Takip Adresi : [https://ebys.izu.edu.tr/enVision/Validate\\_Doc.aspx](https://ebys.izu.edu.tr/enVision/Validate_Doc.aspx)

Adres:Halkalı Caddesi No: 281 Küçükçekmece/İstanbul  
Telefon:444 97 98 Faks:+90 (212) 693 82 29  
e-Posta: bilgi@izu.edu.tr Web: www.izu.edu.tr  
Kep Adresi: izu@hs01.kep.tr

Bilgi için: Murat AKTAŞ  
Ünvanı: Yeminli Katip



 <b>Istanbul Zaimi Üniversitesi</b>	<b>ETİK ONAY BELGESİ</b>	Doküman No	ET-FR-675
		İlk Yayın Tarihi	27.11.2023
		Revizyon Tarihi	22.12.2023
		Revizyon No	01
		Sayfa	1/1

Tarih	02.10.2025
Sayı	2025/9
Araştırmanın Niteliği	Doktora Tezi
Araştırmanın Adı	<i>Derin Öğrenme Tabanlı Kentsel Değişim Tespiti ve İzleme Sistemi</i>
Sorumlu/Yürütücü Araştırmacının Adı Soyadı	Sahra TILKI
Diğer Araştırmacı/lar Adı Soyadı	Prof. Dr. Tark ÖZKUL
Karar	UYGUNDUR

(İstanbul Sabahattin Zaim Üniversitesi Etik Kurulu'nun kararı tavsiye niteliğinde olup, Üniversitemizle ilgili etik ilkelerinin belirlenmesi ve değerlendirilmesi amacını taşımaktadır.)

(Katıldı)  
Prof. Dr. Ali Haydar ŞAR  
Başkan

(Katıldı)  
Prof. Dr. Mehmet Emin KÖKTAŞ  
Başkan V.

(Katılmadı)  
Prof. Dr. Mustafa ATEŞ  
Üye

(Katıldı)  
Prof. Dr. Beytullah KAYA  
Üye

(Katıldı)  
Prof. Dr. Ayşe Nefise BAHÇECİK  
Üye

(Katılmadı)  
Prof. Dr. Tark ÖZKUL  
Üye

(Katıldı)  
Av. Bilal ŞAMAT  
Üye

Kurul Yeminli Kâtibi: Murat AKTAŞ

Dokümantasyon Onayı Prof. Dr. İbrahim GÜNEY Yönetim Sistemleri Temsilcisi

Bu belge, güvenli elektronik imza ile imzalanmıştır.  
Evrak sorgulaması <https://ebys.izu.edu.tr/enVision/Sorgula/BS43LFUAF1> adresinden yapılabilir.