



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



DERİN ÖĞRENME TABANLI KENTSEL
GELİŞİM ANALİZİ

Gizem EYİ

YÜKSEK LİSANS TEZİ

Harita Mühendisliği Anabilim Dalı

Nisan-2026
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Gizem EYİ tarafından hazırlanan “DERİN ÖĞRENME TABANLI KENTSEL GELİŞİM ANALİZİ” adlı tez çalışması .../.../... tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Anabilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. İbrahim Öztuğ BİLDİRİCİ

.....

Danışman

Doç. Dr. İlkey BUĞDAYCI

.....

Üye

Dr. Öğr. Üyesi Abdullah VARLIK

.....

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun/.../20.. gün ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Havvanur UÇBEYİAY
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Gizem EYİ

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME TABANLI KENTSEL GELİŞİM ANALİZİ

Gizem EYİ

NECMETTİN ERBAKAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Danışman: Doç. Dr. İlkey BUĞDAYCI

2026, 76 Sayfa

Jüri

Doç. Dr. İlkey BUĞDAYCI
Prof. Dr. İbrahim Öztuğ BİLDİRİCİ
Dr. Öğr. Üyesi Abdullah VARLIK

Hızlı nüfus artışı ve kontrolsüz kentleşme, doğal kaynakların sürdürülebilirliği üzerinde ciddi baskılar oluşturmaktadır. Kentsel gelişimin ve arazi örtüsü değişimlerinin zamanında ve doğru bir şekilde izlenmesi, şehir planlama süreçleri için kritik öneme sahiptir. Bu tez çalışmasında, yüksek maliyetli ticari uydu görüntülerine ve yoğun işgücü gerektiren piksel tabanlı etiketleme yöntemlerine alternatif olarak; orta çözünürlüklü Sentinel-2 uydu görüntüleri üzerinde çalışan, süperpiksel tabanlı ve zayıf denetimli bir derin öğrenme yaklaşımı geliştirilmiştir.

Çalışma kapsamında geliştirilen ve FERİHA olarak adlandırılan bu özgün sistem, Bursa ilinden elde edilen verilerle eğitilmiştir. FERİHA, özelleştirilmiş bir Konvolüsyonel Sinir Ağı (CNN) mimarisi ile Basit Doğrusal Yinelemeli Kümeleme (SLIC) algoritmasını entegre ederek mekânsal bütünlüğü korumaktadır. Eğitilen modelin büyük ölçekli uydu sahnelerini işleyebilmesi için parçalı işlem (tiling) ve küresel maskelama (global masking) tekniklerini içeren otomatik bir "Çıkarım Motoru" (Inference Engine) tasarlanmıştır. Ayrıca, farklı tarihlere ait görüntüleri karşılaştırarak ormansızlaşma, tarım arazisi kaybı ve yapılaşma oranlarını nicel olarak hesaplayan bir "Değişim Analizi Modülü" geliştirilmiştir.

Elde edilen sonuçlar, FERİHA modelinin kentsel büyüme dinamiklerini yüksek doğrulukla tespit edebildiğini göstermiştir. Yapılan doğruluk analizlerinde model, temel arazi örtüsü sınıflarında %97'nin üzerinde sınıflandırma başarısı göstermiş ve kentsel yapıların tespitinde 0.99 AUC (Eğri Altında Kalan Alan) değeri ile yüksek bir ayırt edicilik performansı sergilemiştir. Modelin saha uygulamalarında ise Bursa-Görükle pilot bölgesinde 2020-2025 yılları arasında %13.16 oranında yapılaşma artışı ve buna bağlı %14.72'lik tarım arazisi kaybı somut olarak hesaplanmıştır. Ayrıca modelin, Marmara Bölgesi verisiyle eğitilmesine rağmen Konya gibi farklı iklim ve bozkır dokusuna sahip alanlarda da yüksek genelleştirme yeteneği sunduğu kanıtlanmıştır. Geliştirilen model ve analiz araçları, son kullanıcıların kolay erişimi için Streamlit tabanlı interaktif bir web arayüzüne dönüştürülmüştür. Bu çalışma, açık kaynaklı veriler ve derin öğrenme teknikleri kullanılarak kentsel izleme süreçlerinin otomatikleştirilmesi adına maliyet etkin ve uygulanabilir bir çözüm sunmaktadır.

Anahtar Kelimeler: Arazi Örtüsü Sınıflandırması, Değişim Analizi, Derin Öğrenme, Kentsel Gelişim, Sentinel-2, Süperpiksel Segmentasyonu, Zayıf Denetimli Öğrenme

ABSTRACT

MS THESIS

DEEP LEARNING-BASED URBAN DEVELOPMENT ANALYSIS

Gizem EYİ

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES OF
NECMETTİN ERBAKAN UNIVERSITY THE DEGREE OF MASTER OF
SCIENCE
IN GEOMATICS ENGINEERING**

Advisor: Assoc. Prof. Dr. İlkey BUĞDAYCI

2026, 76 Pages

Jury

**Assoc. Prof. Dr. İlkey BUĞDAYCI
Prof. Dr. İbrahim Öztuğ BİLDİRİCİ
Asst. Prof. Dr. Abdullah VARLIK**

Rapid population growth and uncontrolled urbanization pose significant pressures on the sustainability of natural resources. Timely and accurate monitoring of urban development and land cover changes is of critical importance for urban planning processes. In this thesis, a superpixel-based and weakly supervised deep learning approach utilizing medium-resolution Sentinel-2 satellite imagery has been developed as an alternative to high-cost commercial satellite imagery and labor-intensive pixel-based labeling methods.

The unique system developed within the scope of this study is named FERİHA. Trained with data obtained from Bursa province, FERİHA integrates a customized Convolutional Neural Network (CNN) architecture with the Simple Linear Iterative Clustering (SLIC) algorithm to preserve spatial integrity. An automated "Inference Engine" incorporating tiling and global masking techniques was designed to enable the model to process large-scale satellite scenes. Furthermore, a "Change Detection Module" was developed to quantitatively calculate deforestation, cropland loss, and urbanization rates by comparing images from different dates.

The obtained results demonstrated that the FERİHA model could detect urban growth dynamics with high accuracy. In the accuracy analyses, the model demonstrated over 97% classification success in fundamental land cover classes and exhibited a high discriminative performance with an AUC (Area Under Curve) value of 0.99 in the detection of urban structures. In the field applications of the model, a 13.16% increase in urbanization and a corresponding 14.72% loss of agricultural land between 2020 and 2025 in the Bursa-Görükle pilot region were concretely calculated. Furthermore, the model proved its high generalization capability in areas with different climates and steppe textures, such as Konya, despite being trained on the data of the Marmara Region. The developed model and analysis tools were transformed into an interactive web interface based on Streamlit for easy access by end-users. This study presents a cost-effective solution for automating urban monitoring processes using open-source data and deep learning techniques.

Keywords: Change Detection, Deep Learning, Land Cover Classification, Sentinel-2, Superpixel Segmentation, Urban Development, Weakly Supervised Learning

ÖNSÖZ

Bu tez çalışması, zayıf denetimli süperpiksel tabanlı derin öğrenme yaklaşımlarıyla çok zamanlı uydu görüntülerinden kentsel gelişimin semantik düzeyde analizine yönelik olarak gerçekleştirilmiştir. Hızla değişen kent yapılarının doğru biçimde izlenmesi ve sınırlı etiketli verilerle yüksek doğrulukta analizlerin yapılabilmesi, sürdürülebilir şehir planlaması açısından büyük önem taşımaktadır. Bu doğrultuda geliştirilen modelin, uzaktan algılama ve yapay zekâ tabanlı yöntemlerin kentsel planlamaya entegrasyonuna katkı sunması hedeflenmiştir.

Bu yolculukta her aşamada yanımda olan ve akademik gelişime kıymetli katkılar sağlayan değerli danışmanım Sayın Doç. Dr. İlkey Buğdaycı'ya en içten teşekkürlerimi sunarım. Bilimsel rehberliği, sabrı ve yol gösterici yaklaşımı, çalışmamın şekillenmesinde büyük rol oynamıştır.

Hayatım boyunca bana koşulsuz sevgi ve destek veren sevgili annem ve babama sonsuz teşekkür ederim. İnançları, sabırları ve verdikleri emek, bugün bu çalışmanın ortaya çıkmasındaki en güçlü temeli oluşturmuştur. Varlıkları, her zaman en büyük ilham kaynağım olmuştur.

Ayrıca, bu süreçte bilgi, moral ve motivasyon desteğini esirgemeyen değerli arkadaşlarıma da teşekkür ederim. Zorlandığım anlarda yanımda olan dostlukları benim için çok kıymetlidir.

Ve en büyük teşekkürü, Cumhuriyetimizin kurucusu Gazi Mustafa Kemal Atatürk'e, bir Türk kadını olarak, bugün bu akademik noktaya gelebilmemin yolunu açtığı için derin bir minnet ve saygıyla sunmak isterim. Kadınların eğitimde, bilimde ve toplumda hak ettiği yeri alabilmesi yönündeki vizyonu, bu çalışmanın temel ilham kaynaklarından biridir.

Bu tezi, bana inanan, destek olan ve bu süreci anlamlı kılan herkese bir teşekkür nişanesi olarak sunuyorum.

Gizem EYİ
KONYA-2026

İÇİNDEKİLER

1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	5
2.1. Uzaktan Algılama ve Kentsel Analizin Temelleri	5
2.1.1. Uzaktan algılama temelleri ve çözünürlük kavramları	6
2.1.2. Uydu veri kaynakları ve Sentinel-2 misyonu	9
2.1.3. Kentsel gelişim analizinde metodolojik yaklaşımlar	11
2.1.3.1. Piksel tabanlı yaklaşımlar	13
2.1.3.2. Nesne ve süperpiksel tabanlı yaklaşımlar	14
2.1.4. Çok zamanlı uydu görüntülerinde değişim analizi	15
2.2. Derin Öğrenme ve Zayıf Denetimli Modelleme	16
2.2.1. Yapay sinir ağları ve derin öğrenme kavramı	16
2.2.2. Evrişimsel sinir ağları (cnn) mimarileri	17
2.2.2.1. Evrişimsel sinir ağlarının temel bileşenleri	18
2.2.3. Derin Öğrenme Modellerinin Eğitim Süreci: Optimizasyon ve Kayıp Fonksiyonları	18
2.2.3.1. Kayıp fonksiyonları ve Focall Loss (Odaklanmış Kayıp)	19
2.2.3.2. Adam (Adaptive Moment Estimation) optimizasyonu	19
2.2.3. Zayıf Denetimli Öğrenme (Weakly Supervised Learning)	20
2.2.3.1. Süperpiksel bölütleme ve SLIC algoritması	22
2.3. Doğruluk analizi ve performans metrikleri	23
2.3.1. Sınıflandırma performansının değerlendirilmesi	23
2.3.2. Hata Matrisi (Confusion Matrix) ve Temel Metrikler	23
2.3.3. ROC eğrisi (Receiver Operating Characteristic) ve AUC analizi	24
3. MATERYAL VE YÖNTEM	26
3.1. Çalışma Alanı	26
3.2. Kullanılan Veri Setleri	27
3.3. Ön İşleme Adımları	27
3.4. Süperpiksel Tabanlı Bölütleme	28
3.5. Zayıf Denetimli Süperpiksel Tabanlı Derin Öğrenme Modeli	29
3.5.1. Süperpiksel bölütleme ve SLIC algoritması	29
3.5.2. CNN mimarisi	31
3.5.3. Eğitim süreci	32
3.5.4. Model performans değerlendirmesi	33
3.6. Büyük Ölçekli Görüntü İşleme ve Otomatik Çıkarım Matrisi	35
3.6.1. Parçalı işleme (tiling) stratejisi	35
3.6.2. Küresel maskeleye (global masking) ve gürültü giderme	35
3.7. Zamansal Kentsel Gelişim ve Değişim Analizi	36
3.7.1. Piksel tabanlı değişim matrisi	36
3.7.2. Alan bazlı yüzdesel değişim hesaplamaları	36
3.8. Model Çıktılarının Görselleştirilmesi ve Web Arayüzü	36
3.9. Veri ve Yazılım Erişilebilirliği	37
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	38

4.1. Model Performansı ve Doğruluk Analizi.....	38
4.1.1. Nitel ve görsel değerlendirme.....	40
4.2. Ana Çalışma Sahası: Bursa İli Değişim Analizi (2020-2025).....	42
4.2.1. Vaka analizi 1: Hızlı kentleşme örneği (Görükle bölgesi)	42
4.2.2. Vaka analizi 2: Kıyı şeridi ve mevsimsel dayanıklılık (Gemlik bölgesi)	46
4.3. Farklı Coğrafi Bölgelerde Model Genelleştirme Testleri.....	50
4.3.1. Marmara bölgesi: 3. Köprü ve İstanbul Boğazı.....	50
4.3.2. Güney Marmara: Çanakkale ve tarımsal spektral karışıklık analizi	53
4.3.3. Akdeniz Bölgesi: Antalya ve örtü altı tarım (sera) etkisi	56
4.3.4. İç Anadolu Bölgesi: Konya (kurak iklim ve bozkır analizi).....	60
4.4. Sonuçların Literatür ile Karşılaştırılması.....	64
5. SONUÇLAR VE ÖNERİLER.....	66
5.1. Sonuçlar	66
5.2. Öneriler	67
KAYNAKLAR	68
EKLER	76

ŞEKİLLER LİSTESİ

Şekil 2.1. Uzaktan algılamada kullanılan elektromanyetik spektrum aralıkları.....	5
Şekil 2.2. Farklı piksel boyutlarının (GSD) görüntü detayı üzerindeki etkisi.....	7
Şekil 2.3. Spektral bant sayısı ve bant genişliğinin nesne ayırt ediciliğine etkisi.....	8
Şekil 2.5. Multispektral ve hiperspektral veri küplerinin karşılaştırılması.....	9
Şekil 2.6. Atatürk Kent Ormanı örneği üzerinden arazi kullanımı ve arazi örtüsü ayrımı	12
Şekil 2.7. Semantik segmentasyon için kullanılan U-Net kodlayıcı-kod çözücü mimarisi	17
Şekil 2.8. Zayıf denetimli öğrenme paradigması genel iş akışı.....	20
Şekil 2.9. Yoğun piksel etiketleme (A) ve nokta tabanlı zayıf etiketleme (B) yöntemlerinin karşılaştırılması	21
Şekil 2.10. Geleneksel piksel tabanlı ızgara ile SLIC süperpiksel bölütleme sınırı doğruluğunun Google Earth üzerinde karşılaştırılması	22
Şekil 2.11. Sınıflandırma başarısını ölçen örnek bir hata matrisi yapısı	24
Şekil 3.1. Tez çalışmasının ana uygulama sahası olan Bursa ilinin Türkiye üzerindeki konumu	25
Şekil 3.2. Görükle Merkez bölgesine ait 2025 tarihli görüntü üzerinde uygulanan SLIC süperpiksel bölütleme sonucu.....	28
Şekil 3.3. Veri seti oluşturma sürecinde geliştirilen yarı-otomatik etiketleme arayüzü.	29
Şekil 3.4. Modelin eğitim ve doğrulama kümeleri üzerindeki kayıp (loss) ve doğruluk (accuracy) eğrileri	31
Şekil 3.5. FERİHA modelinin İstanbul tesy veri seti üzerindeki gerçek performansını gösteren karmaşıklık matrisi.....	32
Şekil 3.6. FERİHA modelinin test veri seti üzerindeki çok sınıflı ROC eğrileri ve AUC değerleri	33
Şekil 3.7. Geliştirilen değişim analizi sisteminin web tabanlı kullanıcı arayüzü.....	36
Şekil 4.1. FERİHA modelinin test veri seti üzerindeki çok sınıflı ROC eğrileri ve AUC değerleri	38
Şekil 4.2. Önerilen FERİHA modelinin nesne tabanlı karar verme sürecini gösteren çıktı	39
Şekil 4.3. Geleneksel yöntem (ArcGIS Maximum Likelihood) kullanılarak, manuel örnek toplama süreci sonunda üretilen İstanbul sınıflandırma haritası	40
Şekil 4.4. 28.07.2020 tarihli Görükle bölgesine ait doğal renkli uydu görüntüsü.....	42
Şekil 4.5. 29.07.2025 tarihli Görükle bölgesine ait doğal renkli uydu görüntüsü.....	42
Şekil 4.6. 28.07.2020 tarihli geleneksel yöntem (ArcGIS Maximum Likelihood) ile üretilen sınıflandırma haritası	43
Şekil 4.7. 29.07.2025 tarihli geleneksel yöntem (ArcGIS Maximum Likelihood) ile üretilen sınıflandırma haritası	43
Şekil 4.8. FERİHA modeli tarafından Görükle bölgesi için üretilen 2020-2025 karşılaştırma haritası.....	44
Şekil 4.9. FERİHA modeli tarafından Görükle bölgesi için üretilen 2020-2025 karşılaştırma raporu	44
Şekil 4.10. 30.12.2020 tarihli Gemlik ilçesine ait kış dönemi doğal renkli uydu görüntüsü	45
Şekil 4.11. 19.12.2025 tarihli Gemlik ilçesine ait kış dönemi doğal renkli uydu görüntüsü	46
Şekil 4.12. 30.12.2020 tarihli mevsimsel etkiler altındaki görüntünün geleneksel yöntem (ArcGIS) sınıflandırma haritası	47
Şekil 4.13. 19.12.2025 tarihli mevsimsel etkiler altındaki görüntünün geleneksel yöntem	

(ArcGIS) sınıflandırma haritası	47
Şekil 4.14. FERİHA modelinin Gemlik bölgesi için 2020-2025 kış görüntüleri üzerinden üretilen karşılaştırma haritası	48
Şekil 4.15. FERİHA modelinin Gemlik bölgesi için 2020-2025 kış görüntüleri üzerinden üretilen karşılaştırma raporu	48
Şekil 4.16. 28.07.2021 tarihli İstanbul Boğazı kuzey kesimi ve Yavuz Sultan Selim Köprüsü'ne ait doğal renkli uydu görüntüsü	49
Şekil 4.17. 29.07.2025 tarihli İstanbul Boğazı kuzey kesimi ve Yavuz Sultan Selim Köprüsü'ne ait doğal renkli uydu görüntüsü	50
Şekil 4.18. 28.07.2021 tarihli geleneksel yöntem (ArcGIS) sınıflandırma haritası	50
Şekil 4.19. 29.07.2025 tarihli geleneksel yöntem (ArcGIS) sınıflandırma haritası	51
Şekil 4.20. FERİHA modeli tarafından İstanbul Boğazı kuzey kesimi ve Yavuz Sultan Selim Köprüsü için üretilen 2021-2025 karşılaştırma haritası	51
Şekil 4.21. FERİHA modeli tarafından İstanbul Boğazı kuzey kesimi ve Yavuz Sultan Selim Köprüsü için üretilen 2021-2025 karşılaştırma raporu.....	52
Şekil 4.22. 29.07.2020 tarihli Çanakkale test bölgesine ait doğal renkli uydu görüntüsü	53
Şekil 4.23. 28.07.2025 tarihli Çanakkale test bölgesine ait doğal renkli uydu görüntüsü	53
Şekil 4.24. 29.07.2020 tarihli geleneksel yöntem (ArcGIS) sınıflandırma haritası	54
Şekil 4.25. 28.07.2025 tarihli geleneksel yöntem (ArcGIS) sınıflandırma haritası	54
Şekil 4.26. FERİHA modeli tarafından Çanakkale bölgesi için üretilen 2020-2025 karşılaştırma haritası	55
Şekil 4.27. FERİHA modeli tarafından Çanakkale bölgesi için üretilen 2020-2025 karşılaştırma raporu	55
Şekil 4.28. 25.07.2020 tarihli Antalya test bölgesine ait doğal renkli uydu görüntüsü..	56
Şekil 4.29. 24.07.2025 tarihli Antalya test bölgesine ait doğal renkli uydu görüntüsü..	57
Şekil 4.30. 25.07.2020 tarihli geleneksel yöntem (ArcGIS) sınıflandırma haritası	57
Şekil 4.31. 24.07.2025 tarihli (ArcGIS) sınıflandırma haritası	58
Şekil 4.32. FERİHA modeli tarafından Antalya bölgesi için üretilen 2020-2025 karşılaştırma haritası	59
Şekil 4.33. FERİHA modeli tarafından Antalya bölgesi için üretilen 2020-2025 karşılaştırma raporu	59
Şekil 4.34. 30.07.2020 tarihli Konya test bölgesine ait doğal renkli uydu görüntüsü....	60
Şekil 4.35. 29.07.2025 tarihli Konya test bölgesine ait doğal renkli uydu görüntüsü....	60
Şekil 4.36. 30.07.2020 tarihli geleneksel yöntem (ArcGIS ISO Cluster) sınıflandırma haritası.....	61
Şekil 4.37. 29.07.2025 tarihli (ArcGIS ISO Cluster) sınıflandırma haritası	61
Şekil 4.38. FERİHA modeli tarafından Konya bölgesi için üretilen 2020-2025 karşılaştırma haritası	62
Şekil 4.39. FERİHA modeli tarafından Konya bölgesi için üretilen 2020-2025 karşılaştırma raporu	62

ÇİZELGELER/TABLolar LİSTESİ

Çizelge 2.1. Sentinel-2 uydu misyonuna ait spektral bantlar ve çözünürlük özellikleri	10
Çizelge 3.1. Çalışmada kullanılan Sentinel-2A uydu görüntülerinin temel özellikleri..	26
Çizelge 3.2. Etiketleme sürecinde kullanılan arazi örtüsü sınıfları ve güncel kodları ...	29
Çizelge 3.3. Orijinal veri setindeki sınıflara ait örneklem dağılımı	29
Çizelge 3.4. Önerilen CNN modelinin katman mimarisi ve çıktı boyutları	31
Çizelge 3.5. Model eğitim sürecinde kullanılan hiperparametreler.....	31
Çizelge 4.1. Modelin test veri seti üzerindeki sınıf bazlı doğruluk oranları	37
Çizelge 4.2. Test setindeki sınıflara göre doğru ve yanlış tahmin dağılımları	38
Çizelge 4.3. Görükle bölgesi arazi örtüsü değişim matrisi özeti (2020-2025)	44
Çizelge 4.4. Gemlik bölgesi değişim istatistikleri (2020-2025).....	48



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

SİMGELER

Δ	Değişim miktarı / Fark
μm	Mikrometre
1	Gösterge Fonksiyonu
M	Sınıflandırma Maskesi
m	Metre
m ²	Metrekare
N	Piksel Sayısı
R _c	Sınıfsal Alan Oranı
T	Zaman / Tarih

KISALTMALAR

ABD	Amerika Birleşik Devletleri
CAM	Sınıf Aktivasyon Haritaları (Class Activation Maps)
CBS	Coğrafi Bilgi Sistemleri
CNN	Evrişimsel Sinir Ağları (Convolutional Neural Networks)
ESA	Avrupa Uzay Ajansı (European Space Agency)
FCN	Tam Konvolüsyonel Ağlar (Fully Convolutional Networks)
GDAL	Geospatial Data Abstraction Library
L1C	Seviye-1C (Level-1C / Atmosferik düzeltme yapılmamış)
L2A	Seviye-2A (Level-2A / Atmosferik düzeltme yapılmış)
LULC	Arazi Örtüsü ve Arazi Kullanımı (Land Use / Land Cover)
NASA	Ulusal Havacılık ve Uzay Dairesi
OBIA	Nesne Tabanlı Görüntü Analizi (Object-Based Image Analysis)
PCC	Sınıflandırma Sonrası Karşılaştırma
ReLU	Doğrultulmuş Doğrusal Birim (Rectified Linear Unit)
RGB	Kırmızı, Yeşil, Mavi (Red, Green, Blue)
SLIC	Basit Doğrusal Yinelemeli Kümeleme
SVM	Destek Vektör Makineleri (Support Vector Machines)
TÜİK	Türkiye İstatistik Kurumu
ViT	Görüntü Transformatörleri (Vision Transformers)

1. GİRİŞ

Küresel ölçekte gözlemlenen demografik hareketlilik, endüstriyel dönüşüm ve sosyo-ekonomik tabakalaşma süreçleri, günümüzde kentleşmeyi modern dünyanın en dinamik, çok katmanlı ve yönetilmesi en zor yeryüzü süreçlerinden biri haline getirmiştir (Ozgur, 2009). Kentleşme olgusu, sadece fiziksel bir yapılaşma veya nüfusun belirli bir alanda yoğunlaşması değil; ekosistem hizmetleri, enerji tüketimi ve mekânsal planlama disiplinlerinin kesişim noktasında yer alan, geri dönüşümsüz bir arazi kullanım değişim sürecidir. Özellikle 21. yüzyılın başından itibaren gelişmekte olan ülkelerde gözlenen kontrolsüz kentsel yayılma (urban sprawl) hareketleri; biyolojik çeşitliliğin azalması, verimli tarım arazilerinin yapılaşma baskısı altında kalması, hidrolojik dengelerin bozulması ve kentsel ısı adası etkisi gibi mikro-klimatik değişimleri tetikleyerek çevresel sürdürülebilirliği tehdit eder boyuta ulaşmıştır (Maktav vd., 2010). Bu karmaşık ve dinamik sürecin rasyonel bir çerçevede yönetilebilmesi, kentsel büyüme eğilimlerinin hem mekânsal hem de zamansal boyutta, yüksek hassasiyetli ve güncel verilerle izlenmesini zorunlu kılmaktadır. Bu noktada uzaktan algılama teknolojileri; yeryüzünü geniş ölçekte, düzenli aralıklarla ve farklı elektromanyetik spektrum bantlarında gözlemleyebilme yeteneği sayesinde, kentsel morfolojinin değişimini izlemek için en temel ve stratejik bilgi kaynağı olarak kabul edilmektedir (Chen vd., 2024; Maktav vd., 2010; Ozgur, 2009).

Geleneksel uzaktan algılama yöntemleri ve istatistiksel sınıflandırıcılar, arazi örtüsünün belirlenmesinde uzun yıllar boyunca standart olarak kullanılmış olsa da, modern kent dokusunun heterojen yapısı bu yöntemlerin performansını ciddi ölçüde sınırlamaktadır. Kentsel alanlar; beton, asfalt, bitki örtüsü, su yüzeyleri ve çıplak toprak gibi spektral açıdan birbirine çok yakın veya bir piksel içerisinde harmanlanmış materyallerin dar alanlarda iç içe geçtiği oldukça karmaşık sahnelerden oluşmaktadır. Bu spektral karmaşıklık, piksellerin sahip olduğu dijital sayıların (DN) tekil bir sınıfı temsil etmekten uzak olduğu "karışık piksel" (mixed pixel) sorununu doğurmakta, özellikle geçirimsiz yüzeylerin gölge veya su kütleleriyle spektral olarak karıştığı durumlarda geleneksel modeller çaresiz kalmaktadır (Hu, 2022). Son on yılda, bilgisayarlı görü (computer vision) ve yapay zeka alanındaki devrim niteliğindeki algoritmik ilerlemelerle birlikte, Derin Öğrenme (Deep Learning) tabanlı yaklaşımlar bu zorlukların aşılmasında yeni bir dönemi başlatmıştır. Evrişimli Sinir Ağları (CNN), görüntüdeki nesneleri yalnızca renk veya yansıtım değerlerine göre değil; doku, şekil, bağlam ve hiyerarşik

öznitelik örüntülerini otomatik olarak öğrenerek sınıflandırabilmektedir. Bu yetenek, derin öğrenme modellerinin uydu görüntülerinden kentsel nesne çıkarımı (urban object extraction) ve semantik bölütleme çalışmalarında geleneksel makine öğrenmesi yöntemlerinin çok ötesinde bir başarı sergilemesini sağlamıştır (J. Liu vd., 2024).

Ancak, literatürde yüksek doğruluk oranlarıyla sunulan bu modern mimarilerin operasyonel kullanımı önünde, aşılması zor iki temel yapısal engel bulunmaktadır: veri maliyeti ve etiketleme. Mevcut çalışmaların büyük bir kısmı, WorldView, Pleiades veya IKONOS gibi santimetre seviyesinde çözünürlük sunan ancak erişimi oldukça maliyetli olan ticari uydu verilerine bağımlıdır (Z. Liu vd., 2017; Scarpetta vd., 2022). Bu durum, özellikle geniş coğrafi alanları kapsayan bölgesel analizlerde veya sismik afetler sonrası yıkım ve yeniden yapılanma süreçlerinin izlenmesi gibi zamana karşı yarışılan durumlarda, ekonomik sürdürülebilirliği ve operasyonel hızı dramatik şekilde düşürmektedir. Diğer taraftan, derin öğrenme modellerinin başarısı, "veri açlığı" (data hunger) olarak literatürde yer eden devasa miktardaki eğitim verisine bağlıdır. Bir modelin kentsel alanları doğru yorumlayabilmesi için on binlerce binanın, yolun veya yeşil alanın piksel hassasiyetinde manuel olarak çizildiği veri setlerine ihtiyaç duyulmaktadır (Reichstein vd., 2019). Karmaşık kentsel alanlarda bu tür bir "yer gerçeği" (ground truth) verisi hazırlamak, aylar süren yoğun uzman emeği gerektirmekte ve projenin termin sürelerini uzatan en büyük metodolojik kısıt haline gelmektedir. Çalışma kapsamında tasarlanan FERİHA sistemi, sunduğu yarı otomatik etiketleme altyapısı ile aylar süren bu yorucu piksel tabanlı çizim sürecini asgari düzeye indirmekte; böylece veri hazırlık aşamasındaki zaman ve iş gücü kayıplarını radikal bir şekilde düşürerek araştırmacılara operasyonel hız kazandırmaktadır.

Avrupa Uzay Ajansı (ESA) tarafından Copernicus programı kapsamında sağlanan Sentinel-2 uydu misyonu, ücretsiz açık erişim politikası, 13 farklı spektral bandı ve 5 günlük yüksek yeniden ziyaret süresi ile literatürdeki veri erişim sorununa devrim niteliğinde bir alternatif sunmaktadır. Ancak Sentinel-2'nin sunduğu 10 metrelik mekânsal çözünürlük, ticari uydularla kıyaslandığında kentsel detayların net bir şekilde ayrıştırılmasında "mekânsal belirsizlik" yaratmaktadır. Literatürde Sentinel-2 verileriyle yapılan kentsel LULC (Land Use Land Cover) sınıflandırmalarının laboratuvar testlerinde (benchmark) yüksek başarılar sergilese de, gerçek dünyadaki büyük ölçekli operasyonel dağıtımlarda (operational deployment) aynı stabiliteyi koruyamadığı ve görsel kirlilik (biber-tuz etkisi) yarattığı kanıtlanmıştır (Jocea vd., 2025). Literatürdeki bu metodolojik boşluk; açık kaynaklı verinin ekonomik avantajından ödün vermeden,

veri etiketleme maliyetini minimize eden ve düşük çözünürlüklü veride bile yüksek geometrik doğruluk sunabilen hibrit yaklaşımlara duyulan ihtiyacı açıkça ortaya koymaktadır.

Bu metodolojik gereksinimlerden hareketle, bu tez çalışması kapsamında, kentsel büyüme ve mekânsal değişimlerin Sentinel-2 görüntüleri üzerinden analiz edilmesini sağlayan, düşük maliyetli ve yüksek verimli bir çözüm geliştirilmiştir. Çalışmanın özgün metodolojisini oluşturan süperpiksel tabanlı zayıf denetimli derin öğrenme yaklaşımı, literatürdeki "yoğun etiketleme" zorunluluğunu "nokta tabanlı zayıf etiketler" (weak labels) ile aşmaktadır. Geliştirilen ve FERİHA olarak isimlendirilen bu özgün sistem, nokta etiketler üzerinden nesnelerin semantik varlığını öğrenmekte, ardından bu öğrenilen bilgiyi görüntünün doğal sınırlarını (edge) ve doku bütünlüğünü koruyan süperpiksel segmentasyonu ile entegre etmektedir. Bu sayede, Sentinel-2 verisinin 10 metrelik fiziksel kısıtına rağmen, kentsel nesne sınırlarının geometrik hassasiyeti korunmakta ve piksellerin semantik anlamlandırılması çok daha stabil bir zemine oturtulmaktadır.

Literatürdeki benzer kentsel analiz çalışmaları incelendiğinde, araştırmacıların bu engelleri aşmak için temelde iki farklı gruba ayrıldığı görülmektedir. İlk gruptaki çalışmalar, Sentinel-2 verilerini tam denetimli (fully-supervised) U-Net ve türevi mimarilerle eğiterek yüksek doğruluk hedeflemiş (Wang vd., 2025), ancak bu yöntemler bölgesel ölçekte devasa manuel etiketleme maliyetleri yarattığı için genellenebilirlik sorunu yaşamıştır. İkinci gruptaki çalışmalar ise etiketleme maliyetini düşürmek amacıyla zayıf denetimli (weakly-supervised) öğrenme stratejilerine yönelmiş; ancak bu modeller sadece görüntü seviyesinde veya seyrek (sparse) etiketler kullandığı için, özellikle kentsel heterojenliğin yüksek olduğu sahalarda nesne sınırlarını (boundary delineation) belirlemede yetersiz kalarak geometrik sapmalara neden olmuştur (Hua vd., 2022).

Bu tez çalışması, literatürdeki tam denetimli modellerin yüksek etiketleme iş yükü ile zayıf denetimli modellerin düşük sınır hassasiyeti problemlerini eşzamanlı olarak çözerek mevcut çalışmalardan metodolojik olarak ayrılmaktadır. Geliştirilen ve FERİHA olarak isimlendirilen özgün çözüm; etiketleme zorluğunu "nokta tabanlı zayıf etiketler" (weak labels) ile çözerken, literatürdeki klasik zayıf denetimli modellerin aksine sınır kaybı yaşamamak için derin öğrenme aktivasyonlarını süperpiksel bölütleme (SLIC) ile entegre etmektedir. Bu hibrit strateji sayesinde, Sentinel-2'nin 10 metrelik fiziksel kısıtına rağmen kentsel nesne sınırlarının geometrik hassasiyeti korunmakta ve piksellerin semantik anlamlandırılması çok daha stabil bir zemine oturtulmaktadır.

FERİHA sistemi, sadece bir sınıflandırma algoritması olmanın ötesinde, büyük ölçekli uydu görüntülerini bellek kısıtlarına takılmadan işleyebilen parçalı çıkarım (tiled inference) mimarisine ve zamansal değişimleri otomatik olarak raporlayan uçtan uca bir analiz motoruna sahiptir. Bu motor, farklı yıllara ait analiz çıktılarını zamansal bir değişim matrisi üzerinden karşılaştırarak; kentsel genişleme hızlarını, yeşil alanlardaki daralmaları ve tarım arazilerinin yapılaşmaya dönüşüm süreçlerini, modern literatürdeki "sınıflandırma sonrası karşılaştırma" (PCC) prensipleriyle nicel olarak hesaplamaktadır (Trabelsi vd., 2023a). Sistemin bir diğer özgün yönü ise, karmaşık mühendislik çıktılarını karar vericiler ve şehir plancıları için yorumlanabilir, semantik açıklamalar içeren "Yönetici Özeti" formatında bir rapora dönüştürebilmesidir. Sonuç olarak bu çalışma; yüksek maliyetli ticari veri setlerine ve yoğun manuel etiketleme süreçlerine olan bağımlılığı ortadan kaldırarak, açık kaynaklı uydu verileriyle kentsel gelişimin izlenmesine yönelik sürdürülebilir, ekonomik ve yüksek doğruluklu bir metodoloji literatüre kazandırmıştır. Geliştirilen yaklaşım, özellikle afet sonrası yeniden yapılanma süreçlerinin izlenmesi veya hızlı büyüyen metropollerin denetlenmesi gibi operasyonel süreklilik gerektiren alanlarda, yüksek teknolojili uzaktan algılama verilerinin karar destek mekanizmalarına entegrasyonu açısından kritik bir boşluğu doldurmaktadır.

FERİHA'yı literatürdeki karmaşık mühendislik algoritmalarından ayıran ve sahadaki uygulanabilirliğini en üst düzeye çıkaran asıl özgünlüğü ise, kullanıcı deneyimini merkeze alan erişilebilir yapısıdır. Geliştirilen sistem, ileri düzey derin öğrenme mimarilerini ve Python tabanlı analiz süreçlerini arka planda çalıştırarak, son kullanıcı için özel olarak tasarlanmış interaktif bir web arayüzü üzerinden hizmet vermektedir. Bu yenilikçi arayüz sayesinde, herhangi bir yazılım veya kodlama bilgisine sahip olmayan yerel yönetim personelleri, şehir plancıları veya araştırmacılar bile, sadece ilgilendikleri bölgeyi ve tarihleri seçerek saniyeler içinde yüksek doğruluklu kentsel değişim haritaları ve yönetici özeti formatında analiz raporları üretebilmektedir.


Sonuç olarak bu çalışma; yüksek maliyetli ticari veri setlerine ve yoğun manuel etiketleme süreçlerine olan bağımlılığı ortadan kaldırarak, ücretsiz uydu verileriyle kentsel gelişimin izlenmesine yönelik sürdürülebilir, ekonomik, hızlı ve yüksek doğruluklu bir metodoloji literatüre kazandırmıştır. Geliştirilen yaklaşım, özellikle afet sonrası yeniden yapılanma süreçlerinin izlenmesi veya hızlı büyüyen metropollerin denetlenmesi gibi operasyonel süreklilik gerektiren alanlarda, ileri GeoAI teknolojilerinin kodlama engeline takılmadan doğrudan karar destek mekanizmalarına entegre edilebilmesi açısından kritik bir boşluğu doldurmaktadır.

2. KAYNAK ARAŞTIRMASI

Bu bölümde, çalışmanın metodolojik ve kuramsal altyapısını oluşturan temel kavramsal çerçeve ile literatürdeki güncel yaklaşımlar sunulmaktadır. Çalışmanın odak noktasını oluşturan kentsel büyüme ve arazi örtüsü değişimlerinin uzaktan algılama teknolojileriyle izlenme süreçleri, geleneksel piksel tabanlı yöntemlerden modern yapay zeka mimarilerine uzanan geniş bir perspektifte incelenmektedir. Bu bağlamda, ilk olarak uzaktan algılama sistemlerinin kapasiteleri, çözünürlük kavramları ve kentsel analiz dinamikleri ele alınmış; ardından derin öğrenme, evrimsel sinir ağları (CNN), süperpiksel bölütleme ve zayıf denetimli öğrenme gibi ileri düzey bilgisayarlı görü tekniklerinin literatürdeki yeri tartışılmıştır. Bölümün son kısmında ise, geliştirilen uzamsal modellerin güvenilirliğini ve sınır hassasiyetini ölçmek amacıyla kullanılan doğruluk analizi ile temel performans metriklerinin teorik arka planı detaylandırılmıştır.

2.1. Uzaktan Algılama ve Kentsel Analizin Temelleri

Uzaktan algılama, yeryüzü nesnelerinin fiziksel temas olmaksızın, nesnelerden yansıyan veya yayılan elektromanyetik enerjinin kaydedilmesi ve anlamlandırılması prensibine dayanmaktadır (Jensen, 2015). Şekil 2.1'de sunulan elektromanyetik spektrum, uzaktan algılama sistemlerinin veri toplama kapasitesini belirleyen temel fiziksel çerçeveyi oluşturmaktadır. Spektrumun görünür ışık (RGB), yakın kızılötesi (NIR) ve kısa dalga kızılötesi (SWIR) gibi farklı bant aralıkları, kentsel dokuyu oluşturan materyallerin (beton, bitki örtüsü, asfalt vb.) karakteristik spektral yansıtım değerlerini ayırt etmek için stratejik öneme sahiptir (Schowengerdt, 2007).



Şekil 2.1. Uzaktan algılamada kullanılan elektromanyetik spektrum aralıkları

Uzaktan algılama verilerinin analiz edilebilirliği ve elde edilecek bilginin niteliği, görüntünün sahip olduğu çözünürlük özellikleri ile doğrudan ilişkilidir. Kentsel çevrenin çoklu sensörlerle (multi-sensor) incelendiği güncel çalışmalarda, uzamsal ve spektral çözünürlük arasındaki dengenin, kentsel alanlardaki çevresel değişimlerin izlenmesinde kritik bir rol oynadığı vurgulanmaktadır (Chen vd., 2024). Bu bağlamda, bölümün ilk aşamasında uzamsal, zamansal, spektral ve radyometrik çözünürlük kavramları irdelenerek, bu parametrelerin kentsel nesne çıkarımı (urban object extraction) üzerindeki etkileri tartışılmıştır. Ardından, çalışmada temel veri kaynağı olarak kullanılan Avrupa Uzay Ajansı (ESA) bünyesindeki Sentinel-2 misyonunun teknik kapasitesi ve spektral bant konfigürasyonu detaylandırılmıştır. Literatürde, Sentinel-2 verilerinin kentsel arazi örtüsü ve arazi kullanımı (LULC) sınıflandırmasında sunduğu ücretsiz ve yüksek zamansal çözünürlük avantajları geniş çapta kabul görse de (Phiri vd., 2020) ; operasyonel uygulamalarda bu verilerin performansı, akademik karşılaştırma (benchmark) testlerinin sıklıkla gerisinde kalabilmektedir (Jocea vd., 2025).

2.1.1. Uzaktan algılama temelleri ve çözünürlük kavramları

Uzaktan algılama teknolojileri; yeryüzünün geniş alanlarının kısa sürede izlenebilmesi, periyodik veri üretimi ve farklı spektral bantlarda zengin bilgi sağlaması gibi avantajları nedeniyle kentsel analizler, çevresel izleme ve afet yönetimi gibi birçok alanda modern veri bilimi mimarileriyle bütünleşik olarak kullanılmaktadır (Chen vd.,

2024; Jocea vd., 2025). Özellikle uydu tabanlı uzaktan algılama sistemleri, sundukları zamansal süreklilik (time-series) ve yüksek mekânsal kapsayıcılık sayesinde, dinamik kentsel büyüme süreçlerinin ve uzun dönemli arazi örtüsü değişimlerinin izlenmesinde günümüzde en kritik veri kaynağını oluşturmaktadır (J. Liu vd., 2024; Trabelsi vd., 2023a).

Uzaktan algılama verilerinin analiz edilebilirliği ve elde edilecek bilginin niteliği ise, görüntülerin sahip olduğu çözünürlük özellikleri ile doğrudan ilişkilidir. Uzaktan algılamada çözünürlük kavramı; uzamsal, zamansal, spektral ve radyometrik çözünürlük olmak üzere dört temel başlık altında incelenmektedir (Jensen, 2015; Schowengerdt, 2007).

Uzamsal çözünürlük, bir uydu görüntüsünde yer yüzeyinde temsil edilen en küçük birimin boyutunu ifade etmektedir. Başka bir deyişle, bir pikselin yeryüzünde kapladığı alan uzamsal çözünürlüğü belirlemektedir. Şekil 2.2'de de görüleceği üzere, yüksek uzamsal çözünürlüğe sahip görüntüler, daha küçük nesnelerin ayırt edilebilmesine olanak sağlarken, düşük uzamsal çözünürlüklü görüntüler daha geniş alanları daha az detayla temsil etmektedir (Woodcock ve Strahler, 1987).



Şekil 2.2. Farklı piksel boyutlarının (GSD) görüntü detayı üzerindeki etkisi (“Mekânsal Çözünürlük Nedir?”, 2023)


Kentsel alanların analizi söz konusu olduğunda, uzamsal çözünürlük önemli bir faktör olmakla birlikte, yüksek çözünürlüklü verilerin maliyeti ve erişilebilirliği önemli

kısıtlar oluşturmaktadır. Bu nedenle, orta çözünürlüklü uydu görüntülerinin uygun yöntemlerle analiz edilmesi, maliyet etkin çözümler sunabilmektedir (Weng, 2012).

Zamansal çözünürlük, aynı bölgenin uydu tarafından ne sıklıkla görüntülenebildiğini ifade etmektedir. Yüksek zamansal çözünürlüğe sahip uydu sistemleri, belirli bir alanı kısa zaman aralıklarıyla tekrar görüntüleyebilmekte ve bu durum zamansal değişimlerin izlenmesine olanak tanımaktadır (Jensen, 2015; Schowengerdt, 2007).

Kentsel gelişim gibi dinamik süreçlerin analizinde, zamansal çözünürlük büyük önem taşımaktadır. Uzun dönemli ve düzenli veri sağlayan uydu sistemleri, kentsel büyüme eğilimlerinin ve arazi örtüsü değişimlerinin izlenmesine katkı sağlamaktadır (Jensen, 2007; Seto vd., 2011).

Spektral çözünürlük, bir algılayıcının elektromanyetik spektrumun kaç farklı bant aralığında veri topladığını ve bu bantların genişliğini ifade etmektedir (Şekil 2.3). Çok bantlı (multispektral) ve çok dar bantlı (hiperspektral) görüntüler, yüzey özelliklerinin ayırt edilmesinde önemli avantajlar sunmaktadır (Goetz vd., 1985; Schowengerdt, 2007).




Şekil 2.3. Spektral bant sayısı ve bant genişliğinin nesne ayırt ediciliğine etkisi (“Mekânsal Çözünürlük Nedir?”, 2023)

Spektral çözünürlüğün artması, farklı arazi örtüsü türlerinin ayırt edilmesini kolaylaştırmakta ve sınıflandırma doğruluğunu artırmaktadır. Özellikle bitki örtüsü, yapılaşmış alanlar ve tarım alanları gibi sınıfların ayrımında spektral bilgi önemli bir rol oynamaktadır (Landgrebe, 2003; Thenkabail vd., 2000).

Radyometrik çözünürlük ise, algılayıcının yüzeyden yansıyan enerjiyi hangi hassasiyetle kaydedebildiğini ifade etmektedir. Bu çözünürlük, bir pikselin alabileceği parlaklık değerlerinin sayısı ile ilişkilidir (Şekil 2.4). Yüksek radyometrik çözünürlük,

yüzey özellikleri arasındaki küçük farkların algılanabilmesine olanak tanımaktadır (Elachi ve van Zyl, 2006; Jensen, 2015).



Şekil 2.4. Bit derinliğine (8-bit vs 12-bit) bağlı radyometrik hassasiyet değişimi (Heffels ve Vanschoren, 2020).

Görüntülerin sahip olduğu bu dört temel çözünürlük kapasitesi, uydu sensörlerinin tasarımına ve kullanım amacına göre farklı veri türlerinin ortaya çıkmasına zemin hazırlamıştır. Bu bağlamda, spektral ve uzamsal özelliklerine göre ayrılan uydu görüntüleri, çalışmanın metodolojik çerçevesini belirleyen temel unsurlardır.


2.1.2. Uydu veri kaynakları ve Sentinel-2 misyonu

Uzaktan algılama çalışmalarında kullanılan uydu görüntüleri, sahip oldukları bant sayısı ve algılama yöntemlerine göre farklı türlere ayrılmaktadır (Kramer, 2002). Bu görüntü türleri, çalışma amacına bağlı olarak farklı avantajlar ve sınırlılıklar sunmaktadır (Chuvieco, 2020; Jensen, 2015).

Tek bantlı (pankromatik) görüntüler, geniş bir spektral aralıkta toplanan veriyi tek bir bantta sunmakta ve genellikle yüksek uzamsal çözünürlük sağlamaktadır. Ancak spektral bilgi sınırlı olduğu için arazi örtüsü sınıflandırmalarında tek başına yeterli olmayabilmektedir.

Çok bantlı (multispektral) görüntüler, elektromanyetik spektrumun farklı bantlarında veri toplayarak yüzey özelliklerinin daha ayrıntılı analiz edilmesine olanak tanımaktadır. Sentinel-2 gibi uydu sistemleri, multispektral yapıları sayesinde kentsel, tarımsal ve doğal alanların analizinde yaygın olarak kullanılmaktadır (Drusch vd., 2012).

Hiperspektral görüntüler ise çok sayıda dar spektral bant içermekte ve ayrıntılı spektral analizlere imkan tanımaktadır. Ancak veri boyutlarının büyük olması ve işleme maliyetleri nedeniyle kullanım alanları daha sınırlıdır (Goetz vd., 1985; Plaza vd., 2009). Şekil 2.5'te multispektral ve hiperspektral görüntülerinin karşılaştırılması verilmiştir.



Şekil 2.5. Multispektral ve hiperspektral veri küplerinin karşılaştırılması (Reichstein vd., 2019)

Görüntü türleri içerisinde, çalışmanın odağını oluşturan Sentinel-2 uydusu, multispektral yapısı ve 13 bandı ile öne çıkmaktadır (Çizelge 2.1). Avrupa Uzay Ajansı (ESA) tarafından Copernicus programı kapsamında geliştirilen Sentinel-2 misyonu, sunduğu teknik kapasite ile kentsel izleme çalışmalarında yeni bir dönem başlatmıştır. 10 metre mekânsal çözünürlük, 13 farklı spektral bant ve 5 günlük yüksek yeniden ziyaret süresi (revisit time) gibi özellikleri; Sentinel-2 verilerini özellikle sürdürülebilir izleme projeleri ve zaman serisi analizleri için Landsat gibi öncüllerine kıyasla daha avantajlı konuma getirmektedir (Drusch vd., 2012). Ayrıca verilerin ücretsiz ve açık erişim politikasıyla sunulması, kentsel büyüme dinamiklerinin küresel ölçekte izlenebilirliğini artırmıştır (Phiri vd., 2020). Bununla birlikte, Sentinel-2 verilerinin kentsel analizlerde bazı sınırlılıkları da bulunmaktadır. Özellikle WorldView veya Pleiades gibi çok yüksek çözünürlüklü (VHR - Very High Resolution) ticari uydularla kıyaslandığında, Sentinel-2'nin sunduğu 10 metrelik piksel boyutu, dar sokak dokularının, tekil binaların veya küçük ölçekli kentsel detayların ayırt edilmesinde yetersiz kalabilmektedir. Bu durum, "karışık piksel" probleminin yoğun olduğu heterojen kent dokularında sınıflandırma doğruluğunu etkileyen bir faktör olarak literatürde tartışılmaktadır (Phiri vd., 2020; Small, 2001). Sentinel-2 verilerinin sunduğu bu teknik kapasite ve beraberinde getirdiği karışık piksel gibi kısıtlar, verinin hangi alanlarda ve hangi yöntemlerle işleneceği konusunu kritik hale getirmektedir.

Çizelge 2.1. Sentinel-2 uydu misyonuna ait spektral bantlar ve çözünürlük özellikleri (*Copernicus Browser*, t.y.; Drusch vd., 2012)

Bant No	Spektral Bölge	Dalga Boyu (μm)	Çözünürlük
Bant 1	Kıyasal Aerosol	0.443	60 m
Bant 2	Mavi	0.490	10 m
Bant 3	Yeşil	0.560	10 m
Bant 4	Kırmızı	0.665	10 m
Bant 5	Kırmızı Kenar 1	0.705	20 m
Bant 6	Kırmızı Kenar 2	0.740	20 m
Bant 7	Kırmızı Kenar 3	0.783	20 m
Bant 8	Yakın Kızılötesi	0.842	10 m
Bant 8A	Dar Kızılötesi	0.865	20 m
Bant 9	Su Buharı	0.945	60 m
Bant 10	Sirüs	1.375	60 m
Bant 11	SWIR 1	1.610	20 m
Bant 12	SWIR 2	2.190	20 m

2.1.3. Kentsel gelişim analizinde metodolojik yaklaşımlar

Uzaktan algılama teknolojileri, yeryüzü kaynaklarının yönetimi ve izlenmesi süreçlerinde önemli bir bilgi kaynağı olarak konumlanmıştır. Elde edilen veriler; tarımsal üretim tahminlerinden orman yangınlarının izlenmesine, su kalitesi analizlerinden afet sonrası hasar tespitine kadar geniş bir uygulama alanında kullanılmaktadır. Bu teknolojiler, sağladıkları zamansal süreklilik sayesinde, yeryüzündeki dinamik değişimlerin anlaşılmasında geleneksel yöntemlere kıyasla maliyet ve zaman avantajı sunmaktadır (Kavzoğlu ve Çölkesen, 2010; Maktav, 2016).

Özellikle kentsel alanlarda uzaktan algılama uygulamaları, nüfus artışı ve hızlı kentleşmenin yarattığı baskıyı izlemek adına büyük önem taşımaktadır. Ancak kentsel yüzeyler; beton, asfalt, yeşil alan ve su yüzeyleri gibi farklı materyallerin dar bir alanda bir arada bulunduğu oldukça heterojen bir yapıya sahiptir (Ridd, 1995).

Uzaktan algılama sistemlerinde bir pikselin sayısal değeri (yansıtım/reflektans), algılayıcının anlık görüş alanı (IFOV – Instantaneous Field of View) içerisinde yer alan tüm yüzey bileşenlerinin spektral tepkilerinin entegre bir sonucunu temsil eder. Kentsel alanlardaki yüksek mekânsal karmaşıklık nedeniyle, tek bir mekânsal çözünürlük hücresi (örneğin Sentinel-2 verilerinde yaklaşık 10x10 m) birden fazla arazi örtüsü sınıfını aynı anda içerebilmektedir. Bu durum, örneğin tek bir piksel içerisinde bina çatısı, kaldırım yüzeyi ve ağaç örtüsünün birlikte bulunmasına yol açabilmektedir. Literatürde “karışık piksel” (mixed pixel) problemi olarak tanımlanan bu olgu, piksele atanan spektral imzanın homojen (saf) bir materyale değil, farklı yüzey bileşenlerinin yansıtım

değerlerinin matematiksel bir kombinasyonuna karşılık gelmesi prensibine dayanmaktadır (Fisher, 1997). Dolayısıyla piksel değeri, tekil bir sınıfın temsilcisi olmaktan ziyade, alt piksel ölçekteki bileşenlerin ağırlıklı ortalamasını yansıtmaktadır.

Karışık piksellerin içerdiği bu spektral belirsizlik, geleneksel piksel tabanlı sınıflandırma algoritmalarının ayırt edicilik kapasitesini sınırlamakta ve özellikle kentsel alanlarda sınıflandırma doğruluğunu doğrudan düşürmektedir. Bu nedenle, kentsel uzaktan algılama çalışmaları doğal ve daha homojen yüzeylere kıyasla hem kuramsal hem de yöntemsel açıdan daha karmaşık bir problem alanı oluşturmaktadır.

Kentsel alanlar, demografik hareketlilik ve ekonomik faaliyetlerin merkezi olmaları nedeniyle yeryüzünün en dinamik bölgeleridir. Bu dinamizmin izlenmesi, sürdürülebilir şehir planlaması açısından hayati önem taşımaktadır.

Literatürde kentsel büyüme, kentsel fonksiyonların kırsal alanlara doğru yayılması ve doğal yüzeylerin geçirimsiz yüzeylere (beton, asfalt vb.) dönüşmesi süreci olarak tanımlanmaktadır (Bhatta, 2010). Bu noktada iki temel kavram olan, yeryüzündeki fiziksel metaryeli ifade eden arazi örtüsü (Land Cover) ve insanların arazi üzerindeki sosyo-ekonomik fonksiyonunu belirten arazi kullanım (Land Use) arasındaki ayrımı bilmek önemlidir (Anderson vd., 1976) (Şekil 2.6).



Şekil 2.6. Atatürk Kent Ormanı örneği üzerinden arazi kullanımı ve arazi örtüsü ayrımı

Kentleşme anlık bir olay değil, kümülatif bir süreçtir. Bu nedenle tek bir tarihe ait uydu görüntüsü, mevcut durumu gösterse de değişim yönünü ve hızını ifade etmekte yetersiz kalır (Lu vd., 2004). Farklı tarihlerde elde edilen görüntülerin kullanıldığı çok zamanlı (multi-temporal) analizler, tarım arazilerinin kentsel alana dönüşüm hızını veya

yeşil alan kayıplarını nicel olarak ortaya koymaktadır (Maktav ve Erbek, 2005; Yuan vd., 2005).

Kentleşme sürecinin bu çok zamanlı izlenebilirliği, ham uydu verisinden anlamlı tematik haritalar üretecek algoritmaların başarısına doğrudan bağlıdır. Literatürde bu çıkarım süreci, teknolojik gelişmelere paralel olarak piksel tabanlı yaklaşımlardan daha gelişmiş yapay zeka yöntemlerine doğru bir evrim sergilemiştir (Blaschke, 2010; Lu ve Weng, 2007; Ma vd., 2019).

2.1.3.1. Piksel tabanlı yaklaşımlar

Geleneksel uzaktan algılama literatürünün temelini oluşturan piksel tabanlı sınıflandırma yaklaşımında, görüntüdeki her bir piksel komşu piksellerden ve mekânsal bağlamdan bağımsız olarak, yalnızca sahip olduğu spektral yansıma değerlerine göre değerlendirilmektedir. Bu yaklaşımın kuramsal temeli, her pikselin tek ve homojen bir arazi örtüsü sınıfını temsil ettiği varsayımına dayanmaktadır. Başka bir ifadeyle, sınıflandırma süreci pikseli en küçük analiz birimi olarak kabul etmekte ve karar mekanizmasını yalnızca çok bantlı spektral özellikler üzerinden yürütmektedir. Aynı sınıfa (örneğin su veya orman) ait piksellerin benzer spektral imzalara sahip olacağı varsayımı, bu yöntemin temel istatistiksel öncülünü oluşturmaktadır (Jensen, 2015; Richards, 2013).

Uygulama sürecinde uzun yıllar standart olarak kabul gören parametrik yöntemler, verinin istatistiksel dağılımını temel almaktadır. Örneğin, yaygın olarak kullanılan Maksimum Olabilirlik (Maximum Likelihood) algoritması, her bir arazi sınıfının spektral yansıtım değerlerinin çok değişkenli normal (Gauss) dağılıma uyduğunu varsayarak, Bayes kuralı yardımıyla bir pikselin ilgili sınıfa ait olma olasılığını hesaplar. Ancak son yıllarda veri boyutlarının (bant sayılarının) artmasıyla birlikte, spektral dağılımların her zaman normal dağılıma uymaması, parametrik olmayan makine öğrenmesi tekniklerini ön plana çıkarmıştır. Bu bağlamda; sınıfları n-boyutlu öznelik uzayında ayıran en uygun hiper-düzlemi (hyperplane) bularak sınıflar arası ayırma mesafesini maksimize eden Destek Vektör Makineleri (SVM) ve çok sayıda bağımsız karar ağacının (decision tree) eşzamanlı çalıştırılmasıyla topluluk (ensemble) öğrenmesi gerçekleştiren Rastgele Orman (Random Forest) algoritmaları, karmaşık kentsel spektral dağılımları modellemede yüksek doğruluk oranları sunmaktadır (Belgiu ve Drăguț, 2016; Mountrakis vd., 2011).

Bununla birlikte, piksel tabanlı yöntemler özellikle kentsel alanlar gibi heterojen yüzeylerde önemli kuramsal ve pratik kısıtlılıklar içermektedir. Sentinel-2 gibi orta çözünürlüklü (10 m) görüntülerde tek bir piksel içerisinde birden fazla arazi örtüsü bileşeninin girmesiyle oluşan "Karışık Piksel (Mixed Pixel)" problemi, pikselin tek sınıf temsilcisi olduğu varsayımını doğrudan zayıflatmaktadır (Fisher, 1997; Small, 2001). Ayrıca piksellerin mekânsal bütünlüğünün ve komşuluk ilişkilerinin göz ardı edilmesi, literatürde "Biber-Tuz (Salt-and-Pepper)" etkisi olarak adlandırılan mekânsal tutarsızlıklara yol açmaktadır (Blaschke, 2010). Bu durum, piksel tabanlı yaklaşımın mekânsal bağlamı modelleyememe sınırlılığının doğrudan bir sonucudur.

2.1.3.2. Nesne ve süperpiksel tabanlı yaklaşımlar

Piksel tabanlı yöntemlerin mekânsal bağlamı ihmal etmesi ve mekânsal tutarsızlık (tuz-biber etkisi) sorunu, görüntü analizinde daha üst düzey temsil birimlerinin geliştirilmesine zemin hazırlamıştır. Bu dönüşüm, görüntünün yalnızca spektral bir matris olarak değil, aynı zamanda mekânsal olarak örgütlenmiş bir yapı olarak ele alınması gerektiği anlayışına dayanmaktadır.

Bu bağlamda geliştirilen Nesne Tabanlı Görüntü Analizi (Object-Based Image Analysis - OBIA), görüntüyü yalnızca spektral değerlerine göre değil; doku, şekil, ölçek ve komşuluk ilişkilerine göre de analiz ederek homojen segmentler üretmektedir. OBIA yaklaşımında temel analiz birimi piksel değil, segmentasyon sonucunda elde edilen nesnelerdir. Bu yaklaşım, Gestalt algı prensiplerinden esinlenen bir kuramsal çerçeveye dayanmakta ve mekânsal bütünlüğü koruyan analizler üretmeyi hedeflemektedir. Bununla birlikte segmentasyon ölçeğinin (scale parameter) belirlenmesi büyük ölçüde kullanıcı deneyimine bağlıdır ve farklı ölçek parametreleri farklı mekânsal temsiller üretebilmektedir (Blaschke, 2010). Bu durum yöntemin tekrarlanabilirliği ve genellenebilirliği açısından bir sınırlılık olarak değerlendirilmektedir.

Nesne tabanlı yaklaşımın daha algoritmik ve optimize edilmiş bir uzantısı olarak geliştirilen Süperpiksel kavramı, görüntüdeki çok sayıdaki pikseli algısal olarak anlamlı, küçük ve homojen bölgelere ayırmayı amaçlamaktadır. Süperpiksel üretiminin temel amacı, görüntüdeki yerel homojenliği korurken veri boyutunu azaltmak ve sınıflandırma sürecine daha istikrarlı bir başlangıç birimi sağlamaktır. İlk kez Ren vd. (2023) tarafından önerilen bu yaklaşım, görüntüdeki fazlalık bilgiyi (redundancy) azaltarak hem hesaplama maliyetini düşürmekte hem de mekânsal bütünlüğü artırmaktadır (Ren vd., 2023).

Günümüzde süperpiksel üretiminde en yaygın kullanılan yöntemlerden biri Basit Doğrusal Yinelemeli Kümeleme (Simple Linear Iterative Clustering - SLIC) algoritmasıdır (Achanta vd., 2012). Achanta vd. (2012) tarafından geliştirilen bu yöntem, k-means kümeleme prensibinin uzamsal olarak kısıtlanmış bir uyarlaması olup pikselleri hem spektral benzerliğe hem de mekânsal yakınlığa göre gruplandırmaktadır. SLIC algoritmasında mesafe ölçütü, renk (veya spektral) uzaklık ile mekânsal uzaklığın normalize edilmiş birleşiminden oluşmaktadır. Bu sayede üretilen süperpikseller kompakt, sınırları belirgin ve mekânsal olarak tutarlı bölgeler oluşturmaktadır. Özellikle kentsel alanlarda bina ve yol kenarları gibi keskin sınırların korunması (boundary adherence) açısından standart piksel tabanlı yöntemlere kıyasla daha başarılı sonuçlar vermektedir.

Her ne kadar süperpiksel tabanlı yaklaşımlar mekânsal bütünlüğü sağlamada önemli bir ilerleme sunmuş olsa da, üretilen segmentlerin semantik anlamlandırılması hâlâ harici bir sınıflandırma mekanizmasına ihtiyaç duymaktadır. Başka bir ifadeyle, süperpikseller düşük seviyeli görsel özelliklere dayalı homojen bölgeler üretmekte; ancak bu bölgelerin yüksek seviyeli semantik temsillerinin çıkarılması için daha gelişmiş öğrenme modellerine gereksinim duyulmaktadır. Bu noktada, öz nitelikleri ham veriden otomatik olarak öğrenen derin öğrenme mimarileri, kentsel sınıflandırma çalışmalarında yeni bir standart oluşturmuştur.

2.1.4. Çok zamanlı uydu görüntülerinde değişim analizi

Kentsel alanların izlenmesinde kullanılan yöntemler, teknolojinin gelişimine ve uydu görüntülerinin çözünürlük kapasitesine paralel olarak evrilmiştir. Literatürde kentsel objelerin (bina, yol, yeşil alan vb.) ham veriden tematik bir haritaya dönüştürülmesi süreci; temel analiz birimi olarak tekil pikselleri alan yaklaşımlardan, pikselleri anlamlı gruplar haline getiren nesne tabanlı yöntemlere doğru bir geçiş sergilemiştir. Aşağıdaki alt bölümlerde bu yaklaşımların kuramsal temelleri ve kentsel alanlardaki uygulanabilirliği ele alınmaktadır.

Kentsel değişimin tespitinde literatürde en yaygın kabul gören ve güncel makine öğrenmesi modelleriyle entegre edildiğinde dahi en stabil sonuçları sunan yaklaşım, Sınıflandırma Sonrası Karşılaştırma (Post-Classification Comparison - PCC) yöntemidir (J. Liu vd., 2024; Trabelsi vd., 2023b). Literatürdeki kuramsal temelleri ilk olarak Singh (1989) tarafından detaylandırılan bu yöntemde, farklı tarihlere ait uydu görüntüleri birbirinden bağımsız olarak sınıflandırılmakta ve elde edilen tematik haritalar piksel

tabanlı olarak karşılaştırılmaktadır (Singh, 1989). Yöntemin en büyük avantajı, farklı tarihlerdeki görüntüler arasında atmosferik düzeltme ve radyometrik normalizasyon hatalarını minimize etmesidir, çünkü her görüntü kendi spektral uzayı içinde bağımsız olarak değerlendirilmektedir.

Analiz sonucunda elde edilen "değişim matrisi", sadece toplam değişim miktarını değil, değişimin yönünü de (örneğin; "Tarım alanından Kentsel alana" veya "Ormandan Çıplak alana" geçişleri) alan (hektar veya m^2 bazında ortaya koymaktadır. Ancak bu yöntemde, her iki tarihteki sınıflandırma hatalarının toplanarak sonuç haritasına yansması riski bulunduğundan, sınıflandırma doğruluğunun yüksek olması kritik önem taşımaktadır (Congalton, 1991).

2.2. Derin Öğrenme ve Zayıf Denetimli Modelleme

Bu bölümde, tezin teorik altyapısını oluşturan yapay zeka ve bilgisayarlı görü yaklaşımları kuramsal bir perspektifle ele alınmaktadır. Geleneksel makine öğrenmesi yöntemlerinden derin öğrenmeye geçiş süreci, Evrişimli Sinir Ağlarının (CNN) mimari yapısı, veri etiketleme maliyetini düşüren zayıf denetimli öğrenme paradigması ve görüntü segmentasyonunun temelini oluşturan süperpiksel teorisi bu bölümün kapsamını oluşturmaktadır.

2.2.1. Yapay sinir ağları ve derin öğrenme kavramı

Son yıllarda bilgisayarlı görü (computer vision) alanındaki algoritmik gelişmeler, uzaktan algılama problemlerine de uyarlanmış ve özellikle yeryüzü nesnelerinin otomatik sınıflandırılması aşamasında doğruluğu önemli ölçüde artırmıştır. Geleneksel makine öğrenmesi yöntemlerinde (SVM, Random Forest vb.) sınıflandırma başarısı büyük ölçüde uzman tarafından tasarlanan özniteliklere (feature engineering) bağlıdır. Başka bir ifadeyle, modelin hangi spektral bant kombinasyonlarını, hangi doku ölçütlerini veya hangi indeksleri kullanacağı önceden araştırmacı tarafından belirlenmektedir.


Derin öğrenme algoritmaları ise bu süreci otomatikleştirmektedir. Bu yaklaşımın temel farkı, öznitelik çıkarımı ile sınıflandırma adımlarının tek bir bütünleşik model içerisinde birlikte öğrenilmesidir. Model, ham piksel değerlerinden başlayarak kenar, köşe, doku ve daha soyut mekânsal örüntüleri çok katmanlı yapılar aracılığıyla hiyerarşik olarak öğrenmektedir (LeCun vd., 2015). Böylece insan müdahalesine dayalı öznitelik tasarımına olan bağımlılık önemli ölçüde azalmaktadır.

2.2.2. Evrişimsel sinir ağları (cnn) mimarileri

Evrişimsel Sinir Ağları (Convolutional Neural Network - CNN), görüntü verisinin iki boyutlu yapısını dikkate alan bir derin öğrenme mimarisidir. CNN'in temel prensibi, görüntü üzerinde kayan küçük filtreler (kernel) aracılığıyla yerel komşuluk ilişkilerini analiz etmek ve mekânsal örüntüleri tespit etmektir. Bu işlem, klasik tam bağlantılı yapılar yerine parametre paylaşımı (weight sharing) prensibine dayandığı için hesaplama maliyetini düşürmekte ve mekânsal bağımlılıkları korumaktadır.

Uzaktan algılamada temel problemlerden biri yalnızca “bu görüntüde bina var mı?” sorusuna cevap vermek değil, “bina hangi pikselde?” sorusunu yanıtlamaktır. Bu problem literatürde semantik segmentasyon (semantic segmentation) olarak adlandırılmaktadır. Bu amaçla geliştirilen Tam Evrişimsel Ağlar (Fully Convolutional Networks - FCN), klasik sınıflandırma ağlarından farklı olarak tam bağlantılı katmanları kaldırarak çıktı üretimini piksel düzeyine taşımıştır (Long vd., 2015).

Bu alandaki en önemli mimarilerden biri olan U-Net, simetrik bir "kodlayıcı–kod çözücü" (encoder–decoder) yapıya sahiptir (Ronneberger vd., 2015) (Şekil 2.7). Kodlayıcı bölümünde görüntüden hiyerarşik öznitelikler çıkarılırken; kod çözücü bölümünde bu öznitelikler tekrar yüksek çözünürlüğe taşınarak piksel hassasiyetinde çıktı üretilmektedir. Ara katmanlar arasındaki atlama bağlantıları (skip connections), düşük seviyeli mekânsal bilgilerin kaybolmasını engelleyerek sınır doğruluğunu artırmaktadır.



Şekil 2.7. Semantik segmentasyon için kullanılan U-Net kodlayıcı-kod çözücü mimarisi (Ronneberger vd., 2015)

2.2.1.1. Evrişimsel sinir ağlarının temel bileşenleri

Derin öğrenme modellerinin uzaktan algılama görüntülerinden anlamlı mekânsal öznitelikler çıkarabilmesi, CNN içerisinde yer alan çeşitli matematiksel operasyonların ardışık olarak uygulanmasına dayanmaktadır. Literatürde standartlaşmış olan bu temel katmanlar ve fonksiyonları aşağıda açıklanmıştır:

Evrişim Katmanı (Convolutional Layer): Görüntü işleme literatüründeki uzamsal filtreleme (spatial filtering) mantığıyla çalışan bu katman, uydu görüntüsü üzerinde belirli boyutlardaki (örneğin 3x3) ağırlık matrislerini (kernel/filtre) gezdirerek matematiksel bir evrişim işlemi gerçekleştirir. Bu işlem sayesinde piksellerin tekil spektral değerleri yerine; bina köşeleri, yol sınırları veya doku gibi mekânsal ve topolojik özellikler (feature maps) tespit edilir.

Havuzlama Katmanı (Pooling): Evrişim katmanlarından elde edilen öznitelik haritalarının mekânsal boyutlarını (piksel sayısını) küçültmek ve hesaplama maliyetini düşürmek amacıyla kullanılan boyut indirgeme (dimensionality reduction) tekniğidir. En yaygın kullanılan En Büyük Değer Havuzlama (Max-Pooling) yönteminde, belirli bir pencere (örneğin 2x2) içerisindeki en yüksek piksel değeri seçilerek bir sonraki katmana aktarılır. Bu işlem, modelin görüntüdeki küçük ötelemelere ve konumsal gürültülere karşı dirençli (translation invariant) olmasını sağlar.

Seyreltme (Dropout) Mekanizması: Derin öğrenme modelleri, milyonlarca parametreye sahip olmaları nedeniyle eğitim verisini ezberleme (overfitting) eğilimindedir. Bu problemi baskılamak amacıyla literatürde Dropout (Seyreltme) adı verilen bir düzenleme (regularization) tekniği kullanılmaktadır (Srivastava vd., 2014). Seyreltme işlemi, ağı eğitim aşamasında her bir iterasyonda rastgele seçilen nöronların belirli bir oranını (örneğin %20) geçici olarak devre dışı bırakır. Böylece ağıdaki nöronların birbirine aşırı bağımlı hale gelmesi engellenir ve modelin daha önce hiç görmediği yeni uydu görüntülerindeki (test verisi) genelleştirme performansı artırılır.

2.2.3. Derin Öğrenme Modellerinin Eğitim Süreci: Optimizasyon ve Kayıp Fonksiyonları

Derin öğrenme modellerinin eğitimi, ağı ürettiği tahminler ile gerçek etiketler arasındaki hatanın (kaybın) matematiksel olarak hesaplanması ve bu hatayı minimize edecek şekilde ağıdaki ağırlıkların (weights) güncellenmesi sürecine dayanmaktadır. Bu

iteratif süreç, kayıp fonksiyonları (loss functions) ve optimizasyon algoritmaları aracılığıyla gerçekleştirilir.

2.2.3.1. Kayıp fonksiyonları ve Focal Loss (Odaklanmış Kayıp)

Sınıflandırma problemlerinde geleneksel olarak en yaygın kullanılan hata ölçüm yöntemi Çapraz Entropi (Cross-Entropy) fonksiyonudur. Ancak, kentsel uzaktan algılama çalışmalarında arazi sınıfları genellikle dengesiz bir dağılım sergiler. Örneğin; bir uydu görüntüsünde "Tarım Alanı" veya "Yeşil Alan" pikselleri milyonlarca adetken, "Su Yüzeyi" veya "Bina" pikselleri çok daha az sayıda olabilir. Standart Çapraz Entropi fonksiyonu, sayıca üstün olan (kolay öğrenilen) sınıfların toplam kayıp üzerindeki etkisini baskın hale getirerek, modelin azınlık sınıflarını öğrenmesini engeller. Bu sınıf dengesizliği (class imbalance) problemini aşmak amacıyla Lin (2017) tarafından Focal Loss (Odaklanmış Kayıp) fonksiyonu geliştirilmiştir. Focal Loss, standart çapraz entropi formülüne dinamik bir ölçeklendirme faktörü $(1 - p_t)^\gamma$ ekleyerek, modelin kolay sınıflandırılan örneklerden ziyade, yanlış sınıflandırılan ve öğrenilmesi zor olan (hard examples) örneklerle odaklanmasını sağlar (Lin vd., 2018).

Focal Loss fonksiyonunun matematiksel ifadesi Eşitlik (2.1)'de verilmiştir:

$$FLp_t = -\alpha_t(1 - p_t)^\gamma \log(p_t) \quad (2.1)$$

Burada p_t , modelin ilgili sınıf için ürettiği olasılık değeridir. α_t parametresi sınıflar arası frekans dengesizliğini kontrol ederken, γ (odaklanma parametresi) kolay örneklerin kayıp fonksiyonuna katkısını ne kadar azaltacağını belirler. $\gamma > 0$ olduğunda, model yüksek güvenle doğru tahmin ettiği piksellerin ağırlığını düşürür ve nadir görülen kentsel sınıflardaki (örn. su veya çıplak arazi) hataları cezalandırarak başarı oranını artırır.

2.2.3.2. Adam (Adaptive Moment Estimation) optimizasyonu

Ağın ürettiği hatayı minimize etmek için ağırlıkların hangi yönde ve ne büyüklükte güncelleneceğini belirleyen matematiksel kurallara optimizasyon algoritması denir. Derin öğrenme literatüründe en yaygın kullanılan yöntemlerden biri olan Adam (Adaptive Moment Estimation), geleneksel Gradyan İniş (Stochastic Gradient Descent - SGD) yönteminin geliştirilmiş bir versiyonudur (Kingma ve Ba, 2017).

Adam algoritması, her bir ağı parametresi için öğrenme oranını (learning rate) dinamik ve bağımsız olarak uyarlar. Algoritma, gradyanların birinci momenti (ortalama, m_t) ve ikinci momenti (dallanma/varyans, v_t) olmak üzere iki farklı hareketli ortalama hesaplar. Bu matematiksel yaklaşım, ağırlık güncellemelerinin gürültülü uydu görüntülerinde bile daha stabil ve hızlı yakınsamasını (convergence) sağlar.


Adam optimizasyonunun parametre güncelleme denklemi Eşitlik (2.2)'de verilmiştir:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v_t} + \epsilon} m_t \quad (2.2)$$


Burada θ_t mevcut ağırlıkları, η öğrenme oranını, m_t ve v_t sırasıyla birinci ve ikinci momentlerin sapma düzeltmeli tahminlerini (bias-corrected estimates), ϵ ise sıfıra bölme hatasını engellemek için eklenen çok küçük bir sabiti ifade eder. Yüksek çözünürlüklü ve karmaşık kentsel özelliklere sahip Sentinel-2 verilerinin işlenmesinde Adam algoritması, modelin yerel minimumlara (local minima) takılmadan global optimum noktasına hızlıca ulaşmasını sağlamaktadır.

2.2.3. Zayıf Denetimli Öğrenme (Weakly Supervised Learning)

Derin öğrenme modellerinin yüksek miktarda etiketli veri gereksinimi, özellikle uydu görüntülerinde her bir nesnenin piksel düzeyinde etiketlenmesinin maliyetli olması nedeniyle önemli bir kısıttır (veri açlığı). Bu problemi aşmak amacıyla geliştirilen Zayıf Denetimli Öğrenme paradigması, modelin tam hassasiyetli etiketler yerine; nokta, kutu (bounding box) veya sadece görüntü etiketi gibi üretilmesi kolay etiketlerle eğitilmesini sağlamaktadır (Z.-H. Zhou, 2018) (Şekil 2.8 ve Şekil 2.9).



Şekil 2.8. Zayıf denetimli öğrenme paradigmasının genel iş akışı (Ren vd., 2023)



Şekil 2.9. Yoğun piksel etiketleme (A) ve nokta tabanlı zayıf etiketleme (B) yöntemlerinin karşılaştırılması

Bu bağlamda kullanılan Sınıf Aktivasyon Haritaları (Class Activation Maps - CAM), modelin karar verirken görüntünün hangi bölgelerine odaklandığını görselleştirmektedir (B. Zhou vd., 2016). Bu haritalar, yalnızca görüntü düzeyindeki etiketlerden piksel tabanlı yaklaşık segmentasyon maskeleri türetilmesine olanak sağlayarak, yüksek doğruluk ile operasyonel uygulanabilirlik arasında bir denge kurmaktadır.

2.2.3.1. Süperpiksel bölütleme ve SLIC algoritması

Geleneksel piksel tabanlı görüntü işleme yaklaşımları, özellikle heterojen kentsel alanlarda piksellerin sahip olduğu anlamsal (semantik) bütünlüğü korumakta yetersiz kalmaktadır. Bu sorunu aşmak için literatürde sıklıkla başvurulanan "süperpiksel" kavramı, görüntüyü tekil pikseller yerine; renk, doku ve mekânsal yakınlık açısından benzerlik gösteren, sınırları belirgin ve anlamlı piksel gruplarına (bölütlere) ayırma işlemidir (Şekil 2.10).



Şekil 2.10. Geleneksel piksel tabanlı ızgara ile SLIC süperpiksel bölütleme sınır doğruluğunun Google Earth üzerinde karşılaştırılması

Bu tez kapsamında temel bölütleme mimarisi olarak Basit Doğrusal Yinelemeli Kümeleme (Simple Linear Iterative Clustering - SLIC) algoritması benimsenmiştir. SLIC, temelde k-ortalama (k-means) makine öğrenmesi algoritmasının piksel uzayına uyarlanmış halidir. Algoritma, pikselleri yalnızca spektral yansıtım değerlerine göre değil, aynı zamanda L , a , b renk uzayı ve x, y koordinat düzlemi üzerinde normalize edilmiş bir mesafe ölçütüyle (D) 5 boyutlu bir uzayda kümelemektedir. Bir piksel (i) ile küme merkezi (k) arasındaki spektral (d_{Lab}) ve mekânsal (d_{xy}) mesafe formülasyonu Eşitlikler (2.3), (2.4) ve (2.5)'de verilmiştir:

$$d_{Lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \quad (2.3)$$

$$d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2} \quad (2.4)$$

$$D = \sqrt{D_{Lab}^2 + \left(\frac{m^2}{S}\right)d_{xy}^2} \quad (2.5)$$

Burada m parametresi süperpikselin kompaktlığını, S ise merkezler arası uzaklığı kontrol eder. Spektral ve mekânsal mesafelerin bu şekilde ağırlıklandırılması, derin öğrenme modellerinden gelen düşük çözünürlüklü aktivasyon haritalarının kentsel nesne sınırlarına (bina kenarları, yol hatları, tarım parselleri) tam olarak oturmasını sağlayarak tezin metodolojik omurgasını tamamlamaktadır.

2.3. Doğruluk analizi ve performans metrikleri

Uzaktan algılama ve derin öğrenme tabanlı sınıflandırma çalışmalarında, üretilen tematik haritaların güvenilirliği ancak sistematik bir doğruluk analizi ile ortaya konulabilmektedir. Bu bölüm, modelin eğitim ve test aşamalarındaki başarısını ölçmek için kullanılan istatistiksel yöntemleri ve mekânsal doğruluk kriterlerini kapsamaktadır.

2.3.1. Sınıflandırma performansının değerlendirilmesi

Sınıflandırma doğruluğu, model tarafından üretilen etiketler ile yer gerçeği (ground truth) verileri arasındaki uyumun derecesini ifade eder. Bu değerlendirme, modelin genelleme yeteneğini ölçmek ve aşırı öğrenme (overfitting) gibi problemlerin önüne geçmek adına kritik bir adımdır. Değerlendirme sürecinde nicel veriler sunan hata matrisi ve bu matristen türetilen metrikler temel alınmaktadır.

2.3.2. Hata Matrisi (Confusion Matrix) ve Temel Metrikler

Hata matrisi, modelin sınıflandırma performansını sınıf bazında detaylandıran $N \times N$ boyutunda bir tablodur (Şekil 2.11). Matrisin temel bileşenleri; Doğru Pozitif (TP), Doğru Negatif (TN), Yanlış Pozitif (FP) ve Yanlış Negatif (FN) değerlerinden oluşmaktadır. Bu değerler kullanılarak hesaplanan temel performans metrikleri şu şekildedir:

Genel Doğruluk (Overall Accuracy - OA): Doğru sınıflandırılan piksellerin toplam piksel sayısına oranıdır (Eşitlik (2.6)).

$$OA = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.6)$$

Kesinlik (Precision / User's Accuracy): Belirli bir sınıfa atanan piksellerin gerçekte ne kadarının o sınıfa ait olduğunu gösterir (Eşitlik (2.7)).

$$Precision = \frac{TP}{TP+FP} \quad (2.7)$$

Duyarlılık (Recall / Producer's Accuracy): Yer gerçeğinde bulunan bir sınıfın ne kadarının model tarafından doğru yakalandığını ifade eder (Eşitlik (2.8)).

$$Recall = \frac{TP}{TP+FN} \quad (2.8)$$

F1-Skoru: Kesinlik ve duyarlılık değerlerinin harmonik ortalaması olup, özellikle kentsel alanlar gibi dengesiz veri setlerinde performansın daha sağlıklı yorumlanmasını sağlar (Eşitlik (2.9)).

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.9)$$

Confussion Matrix		Gerçek (Actual) Sonuçlar	
		Pozitif (1)	Negatif (0)
Tahminlenen (Predicted) Sonuçlar	Pozitif (1)	TP [1, 1] True Pozitif	FP [1, 0] False Pozitif
	Negatif (0)	FN [0, 1] False Negatif	TN [0, 0] True Negatif

Şekil 2.11. Sınıflandırma başarısını ölçen örnek bir hata matrisi yapısı

2.3.3. ROC eğrisi (Receiver Operating Characteristic) ve AUC analizi

ROC eğrisi, modelin farklı karar eşiklerinde (threshold) sergilediği performansın görsel bir temsilidir. Eğri, Doğru Pozitif Oranı (TPR) ile Yanlış Pozitif Oranı (FPR) arasındaki ilişkiyi grafikize eder.

$$\text{Doğru Pozitif Oranı (Sensitivite): } TPR = \frac{TP}{TP+FN}$$

$$\text{Yanlış Pozitif Oranı (1-Spesifite): } FPR = \frac{FP}{FP+TN}$$

AUC (Area Under the Curve), ROC eğrisi altında kalan alanı ifade eder. 1.0 değerine yaklaşan bir AUC değeri, modelin kentsel alanı kentsel olmayan alandan ayırt etme yeteneğinin mükemmel olduğunu kanıtlar.



3. MATERYAL VE YÖNTEM

Bu bölümde, tez çalışması kapsamında geliştirilen FERİHA modelinin eğitim ve test süreçlerinde kullanılan veri setleri, çalışma alanının özellikleri ve metodolojik altyapı detaylandırılmıştır. Çalışmada izlenen yöntem; veri ön işleme, süperpiksel tabanlı bölütleme, derin öğrenme modelinin tasarımı ve değişim analizi motorunun geliştirilmesi olmak üzere dört ana aşamadan oluşmaktadır. Aşağıdaki alt başlıklarda bu aşamalar sırasıyla sunulmuştur.

3.1. Çalışma Alanı

Bu tez çalışması kapsamında, kentsel gelişim ve arazi örtüsü değişimlerinin belirgin biçimde gözlemlenebildiği ve heterojen arazi yapısına sahip olan Bursa ili, modelin eğitimi için ana çalışma sahası olarak seçilmiştir. Şekil 3.1'de coğrafi konumu gösterilen Bursa; hızlı sanayileşme ve kentleşme baskısı altında olması, aynı zamanda tarım arazileri ve yeşil alanlarla iç içe geçmiş bir kentsel dokuya sahip olması nedeniyle önerilen yöntemin zorlu koşullarda test edilmesi için ideal bir ortam sunmaktadır.



Şekil 3.1. Tez çalışmasının ana uygulama sahası olan Bursa ilinin Türkiye üzerindeki konumu

Ayrıca, geliştirilen sistemin farklı coğrafi bölgelerdeki genelleştirme yeteneğini test etmek amacıyla, eğitim veri setinden tamamen bağımsız olarak İstanbul ilinden de test bölgeleri belirlenmiştir. Seçilen çalışma alanları içerisinde kentsel alanlar, sanayi bölgeleri, ormanlık alanlar, tarım arazileri ve su yüzeyleri bir arada bulunmakta olup, bu

çeşitlilik geliştirilen modelin ve analiz motorunun başarısının kapsamlı şekilde değerlendirilmesine olanak sağlamaktadır.

3.2. Kullanılan Veri Setleri

Bu çalışmada kullanılan temel veri kaynağı, Avrupa Uzay Ajansı (ESA) Copernicus programı kapsamında sağlanan Sentinel-2A uydu görüntüleridir. Sentinel-2, sunduğu 13 spektral bant, yüksek uzamsal çözünürlük (10m, 20m, 60m) ve 5 günlük yeniden ziyaret süresi ile kentsel izleme çalışmaları için optimum bir veri kaynağıdır.

Çalışma kapsamında, atmosferik düzeltmeleri yapılmış ve analize hazır yüzey yansıtım değerlerini içeren Seviye-2A (Level-2A) ürünleri tercih edilmiştir. Modelin eğitimi için Bursa iline ait, bulutluluk oranı düşük olan ve 10 yıllık bir değişimi temsil eden iki farklı tarihe ait görüntüler kullanılmıştır. Modelin bağımsız bir veri seti üzerindeki genelleştirme başarımını ölçmek amacıyla gerçekleştirilen test aşamasında ise İstanbul iline ait 20 Kasım 2015 tarihli görüntüden faydalanılmıştır. Eğitim sürecinde kullanılan Bursa bölgesine ait ana görüntülerin temel özellikleri Çizelge 3.1'de özetlenmiştir.

Çizelge 3.1. Çalışmada kullanılan Sentinel-2A uydu görüntülerinin temel özellikleri (*Copernicus Browser*, t.y.)

Özellik	T1 Görüntüsü	T2 Görüntüsü
Uydu	Sentinel-2A	Sentinel-2A
İşlem Seviyesi	Level-2A	Level-2A
Alım Tarihi	30 Temmuz 2015	29 Temmuz 2025
Bulutluluk Oranı	%3.36	%0.08

3.3. Ön İşleme Adımları

Uydu görüntülerinin analize ve derin öğrenme modeline uygun hale getirilmesi amacıyla Python tabanlı kütüphaneler (GDAL, Rasterio, NumPy) ve ArcGIS yazılımı kullanılarak aşağıdaki ön işleme adımları uygulanmıştır:

1. **Bant Seçimi:** Modelin eğitimi ve sınıflandırma işlemleri için Sentinel-2 uydu görüntülerinden 10 metre mekânsal çözünürlüğe sahip görünür bölge bantları olan RGB (B4: Kırmızı, B3: Yeşil, B2: Mavi) seçilmiştir.
2. **Görüntü Kırpma (Tiling):** Büyük boyutlu uydu sahneleri, bellek yönetimi ve işlem kolaylığı sağlamak amacıyla 696x810 piksel boyutlarında daha küçük parçalara (tiles) ayrılmıştır.

3. **Veri Yapısı:** Her bir görüntü parçası, Python ortamında (3, 696, 810) boyutlarında NumPy dizilerine dönüştürülmüştür. Burada ilk boyut spektral bant sayısını temsil etmektedir.


3.4. Süperpiksel Tabanlı Bölütleme

Tezin teorik altyapısında matematiksel temelleri detaylandırılan süperpiksel tabanlı bölütleme yaklaşımı, bu aşamada çalışma alanının kentsel dokusuna ve Sentinel-2 verilerinin 10 metrelik mekânsal çözünürlüğüne optimize edilerek uygulanmıştır. Görüntüler üzerindeki sınıf karışmalarını (biber-tuz etkisi) minimize etmek ve modelin eğitim birimlerini oluşturmak amacıyla Python *Scikit-Image* kütüphanesinde yer alan SLIC algoritması tercih edilmiştir.

Çalışma sahası olan Bursa ilinin yoğun yapılaşma, parçalı tarım arazileri ve sanayi bölgelerinden oluşan heterojen yapısı göz önüne alınarak çok sayıda deneysel test gerçekleştirilmiştir. Kentsel nesnelerin (bina blokları, yol hatları ve tarla sınırları) geometrik bütünlüğünü en yüksek hassasiyetle koruyan optimum bölütleme parametreleri şu şekilde belirlenmiştir:

Segment Sayısı (n_segments) - 2000: Uydu görüntüsü yamasının (696x810 piksel) mekânsal büyüklüğü dikkate alınarak, çok büyük (sınıfları birbirine karıştıran) veya çok küçük (aşırı parçalanmış) süperpiksellerin oluşmasını engellemek amacıyla segment sayısı 2000 olarak sabitlenmiştir.

Kompaktlık (compactness) - 1.0: Süperpiksellerin şekilsel esnekliğini belirleyen bu parametre, algorithmada düşük bir değere (1.0) ayarlanmıştır. Bu stratejik tercih sayesinde, algoritmik kare/kutu şekiller yerine, kentsel dokunun doğal sınırlarına (köşeli binalar, kıvrımlı yollar) tam uyum sağlayan amorf bölgeler elde edilmiştir.



Şekil 3.2. Görükle Merkez bölgesine ait 2025 tarihli görüntü üzerinde uygulanan SLIC süperpiksel bölütleme sonucu

Belirlenen bu spesifik parametreler ile elde edilen süperpikseller, tez kapsamında gerçekleştirilen zayıf etiketleme ve derin öğrenme ile sınıflandırma aşamalarının temel girdi birimini (instance) oluşturmuştur (Şekil 3.2).

3.5. Zayıf Denetimli Süperpiksel Tabanlı Derin Öğrenme Modeli

Bu bölümde, çalışma kapsamında geliştirilen ve sistemin temelini oluşturan CNN modelinin teknik detayları sunulmaktadır.

3.5.1. Süperpiksel bölütleme ve SLIC algoritması

Modelin eğitimi için süperpiksel tabanlı bir veri seti oluşturulmuştur. Etiketleme süreci, geliştirilen Python tabanlı yarı-otomatik bir arayüz üzerinden gerçekleştirilmiştir (Şekil 3.3). Bu arayüzde kullanıcılar, SLIC ile üretilen süperpiksel segmentlerine tıklayarak ilgili arazi sınıfını atamıştır.



Şekil 3.3. Veri seti oluşturma sürecinde geliştirilen yarı-otomatik etiketleme arayüzü

Çizelge 3.2. Etiketleme sürecinde kullanılan arazi örtüsü sınıfları ve güncel kodları

Sınıf ID	Sınıf Adı
0	Tarım Alanı
1	Su Yüzeyi
2	Yeşil Alan
3	Atanamayan
4	Yol
5	Çıplak Arazi
6	Bina

Orijinal veri setinde toplam 10.924 adet etiketli süperpiksel elde edilmiştir. Ancak sınıflar arasında dengesizlik (örneğin Tarım sınıfı 4470 örnek iken, Su sınıfı 146 örnek) gözlemlenmiştir (Çizelge 3.3). Modelin yanlı (bias) öğrenmesini engellemek amacıyla azınlık sınıflar için örneklem artırma (oversampling) tekniği uygulanmış ve toplam veri sayısı 31.290'a çıkarılarak dengeli bir eğitim seti oluşturulmuştur. Veri seti %90 eğitim ve %10 doğrulama (validation) olarak ayrılmıştır.

Çizelge 3.3. Orijinal veri setindeki sınıflara ait örneklem dağılımı

Sınıf	Örnek Sayısı
Tarım Alanı	4470
Su Yüzeyi	146
Yeşil Alan	2839
Atanamayan	351
Yol	959
Çıplak Arazi	1077
Bina	1082

3.5.2. CNN mimarisi

Süperpiksel bölgelerinin sınıflandırılması amacıyla "SegmentClassifierModel" adı verilen özelleştirilmiş bir Evrişimsel Sinir Ağı (CNN) mimarisi tasarlanmıştır. Model, her bir süperpikseli temsil eden $3 \times 22 \times 22$ boyutundaki görüntü parçalarını (RGB) girdi olarak almaktadır.

Model mimarisi (Çizelge 3.4), görüntü işleme ve örüntü tanıma adımlarını gerçekleştiren şu temel bileşenlerden oluşmaktadır:

Öznitelik Çıkarımı (Evrişim Katmanları): Görüntü üzerindeki kenar, doku ve yapısal şekiller gibi mekânsal özellikleri tespit etmek amacıyla artan filtre sayılarına (32, 64, 128) sahip 6 adet evrişim (convolution) bloğu kullanılmıştır. Ağın daha kararlı ve hızlı öğrenmesini sağlamak için her blokta Grup Normalizasyonu (Batch Normalization) uygulanmış; modelin karmaşık sınırları öğrenebilmesi için ise doğrusal olmayan ReLU aktivasyon fonksiyonu kullanılmıştır.

Mekânsal Boyut İndirgeme (Max-Pooling): Görüntüden elde edilen öznitelik haritalarının çözünürlüğünü küçültmek ve hesaplama yükünü hafifletmek amacıyla En Büyük Değer Havuzlama (Max-Pooling) katmanları kullanılmıştır. Bu işlem, görüntüdeki en belirgin özellikleri korurken veri boyutunu yarı yarıya düşürerek modelin görüş alanını genişletir.

Sınıflandırma Kararı (Tam Bağlantılı Katmanlar): Çıkarılan tüm mekânsal öznitelikler tek boyutlu bir vektör haline getirilmiş (düzleştirilmiş) ve Tam Bağlantılı (Fully Connected) katmanlara iletilmiştir. Bu katmanlar, elde edilen tüm piksellerin özelliklerini sentezleyerek arazinin hangi sınıfa (Bina, Yol, Su vb.) ait olduğuna dair nihai kararı (Softmax fonksiyonu ile) üretir.

Düzenleştirme ve Genelleştirme (Dropout): Modelin eğitim verisi üzerindeki gürültüleri ezberlemesini (overfitting) baskılamak ve farklı coğrafi bölgelerdeki genelleştirme kapasitesini maksimize etmek amacıyla, ağ mimarisinin kritik düğümlerine %15 ve %30 oranlarında seyreltme (dropout) mekanizması entegre edilmiştir. Bu algoritmik tercih, modelin yalnızca belirli baskın özniteliklere bağımlı kalmasını engelleyerek sınıflandırma kararlılığını artırmıştır.

Çizelge 3.4. Önerilen CNN modelinin katman mimarisi ve çıktı boyutları


Katman	Çıktı Boyutu	Açıklama
Giriş (input)	3x22x22	RGB Süperpiksel yaması
Conv1+BN+ReLU	32x22x22	3x3 kernel, padding=1
Conv2+BN+ReLU	32x22x22	3x3 kernel, padding=1
MaxPool1+Dropout	32x11x11	2x2 pooling, p = 0.15
Conv3+BN+ReLU	64x11x11	3x3 kernel, padding=1
Conv4+BN+ReLU	64x11x11	3x3 kernel, padding=1
MaxPool2+Dropout	64x5x5	2x2 pooling, p = 0.15
Conv5+BN+ReLU	128x5x5	3x3 kernel, padding=1
Conv6+BN+ReLU	128x5x5	3x3 kernel, padding=1
Global AvgPool+Drop.	128x1x1	Adaptive AvgPool, p = 0.3
FC1+ReLU+Dropout	256	Tam bağlantılı katman
FC2+ReLU+Dropout	128	Tam bağlantılı katman
Çıktı Katmanı	7	Softmax aktivasyonu

3.5.3. Eğitim süreci

Modelin eğitimi PyTorch kütüphanesi kullanılarak gerçekleştirilmiştir (Çizelge 3.5 ve Şekil 3.4). Sınıf dengesizliğinin etkilerini minimize etmek için kayıp fonksiyonu olarak Focal Loss tercih edilmiştir. Optimizasyon algoritması olarak Adam kullanılmış olup, başlangıç öğrenme oranı (learning rate) 1×10^{-3} olarak belirlenmiştir.

Çizelge 3.5. Model eğitim sürecinde kullanılan hiperparametreler

Parametre	Değer
Mini-Batch Boyutu	32
Maximum Epoch	50
Erken Durdurma (Early Stopping)	15 ardışık epoch iyileşmezse
Optimizasyon Algoritması	Adam
Öğrenme Oranı (Learning Rate)	1×10^{-3}
Ağırlık Azaltma (Weight Decay)	1×10^{-4}

**Şekil 3.4.** Modelin eğitim ve doğrulama kümeleri üzerindeki kayıp (loss) ve doğruluk (accuracy) eğrileri


3.5.4. Model performans deęerlendirmesi

Eęitilen FERİHA modelinin genelleřtirme yeteneęini ölçmek ve önerilen süperpiksel tabanlı sınıflandırma yaklaşımının etkinlięini doęrulamak amacıyla, eęitim sürecinde hiç kullanılmamıř (unseen) verilerle kapsamlı bir performans testi gerekleřtirilmiřtir.

Modelin bařarısı, sınıflandırma problemlerinde literatürde standart kabul edilen Karmařıklık Matrisi (Confusion Matrix) yöntemiyle analiz edilmiřtir. Harita mühendislięi ve uzaktan algılama uygulamalarında doęruluęun sadece genel yüzdeyle ifade edilmesi yanıltıcı olabileceęinden, sınıflar arası karıřıklıkların detaylı incelenmesi büyük önem taşımaktadır.

alıřma kapsamında, modelin hiç görmedięi İstanbul iline ait test veri seti kullanılarak FERİHA modeline özgü gerek karmařıklık matrisi oluřturulmuřtur (řekil 3.5).

Matris incelendięinde, köřegen üzerindeki koyu renkli hücrelerin (Doęru Tahminler) yoğunluęu, modelin yüksek bařarısını göstermektedir. Özellikle "Su" ve "Atanamayan" sınıflarında hata sıfırdır. Hataların (aık renkli hücreler) genellikle spektral özellikleri birbirine ok yakın olan "ıplak Arazi" ve "Tarım Alanı" ile geometrik benzerlik gösteren "Bina" ve "Yol" sınıfları arasında yoğunlařtıęı görölmektedir.




řekil 3.5. FERİHA modelinin İstanbul test veri seti üzerindeki gerek performansını gösteren Karmařıklık Matrisi

Bu analiz, modelin sadece genel doğrulukta değil, sınıf bazlı ayırmada da dengeli bir performans sergilediğini ve kentsel dönüşüm analizleri için güvenilir sonuçlar ürettiğini kanıtlamaktadır.

Karmaşıklık matrisine ek olarak, modelin sınıfları birbirinden ayırt etme yeteneğini (discriminative power) istatistiksel olarak ölçmek amacıyla Çok Sınıflı ROC Analizi kullanılmıştır. ROC eğrisi, farklı sınıflandırma eşik değerleri için Doğru Pozitif Oranı (TPR) ile Yanlış Pozitif Oranı (FPR) arasındaki ilişkiyi grafiksel olarak ifade etmektedir.

Tez kapsamında yedi sınıflı bir analiz gerçekleştirildiği için, değerlendirme literatürde yaygın olarak kabul gören "Bire-Karşı-Diğerleri" (One-vs-Rest) yaklaşımı ile yapılmıştır. Bu yöntemde, her bir arazi örtüsü sınıfı sırasıyla "pozitif sınıf" kabul edilirken, geri kalan tüm sınıflar birleştirilerek "negatif sınıf" olarak değerlendirilmekte ve her sınıf için bağımsız bir ROC eğrisi çizilmektedir.

Modelin başarısının tek bir sayısal değer ile ifade edilebilmesi ve karşılaştırılabilir olması için Eğri Altında Kalan Alan (AUC - Area Under Curve) metriği hesaplanmıştır. AUC değeri 0.0 ile 1.0 arasında değişmekte olup; 0.50 değeri modelin rastgele tahmin yaptığını (öğrenemediğini), 1.00 değeri ise sınıfları kusursuz bir şekilde birbirinden ayırabildiğini göstermektedir (Şekil 3.6).



Şekil 3.6. FERİHA modelinin test veri seti üzerindeki çok sınıflı ROC eğrileri ve AUC değerleri

3.6. Büyük Ölçekli Görüntü İşleme ve Otomatik Çıkarım Matrisi

Tez çalışmasının uygulama aşamasında, eğitilen derin öğrenme modelinin tüm bir uydu sahnesi üzerinde (örneğin 10000x10000 piksel) çalışabilmesi için özel bir "Çıkarım Motoru" (Inference Engine) geliştirilmiştir. Standart CNN modelleri, bellek (RAM/VRAM) kısıtlamaları nedeniyle büyük uydu görüntülerini tek seferde işleyememektedir. Bu problemi aşmak için "Böl-Yönet-Birleştir" (Divide-and-Conquer) stratejisine dayalı bir algoritma tasarlanmıştır.

3.6.1. Parçalı işleme (tiling) stratejisi

Büyük boyutlu Sentinel-2 görüntüleri, modelin eğitim veri setiyle uyumlu olacak şekilde, sanal bir ızgara sistemi kullanılarak parçalara ayrılmıştır. Bu süreçte mekânsal tutarlılığı korumak adına aşağıdaki yöntem izlenmiştir:

Dinamik Pencereleme: Görüntü üzerinde 696x810 piksellik kayan pencereler (sliding windows) gezdirilmiştir.

Kenar Yönetimi: Görüntünün kenar kısımlarında kalan ve standart boyuttan küçük olan parçalar için, SLIC segmentasyon algoritmasının "*n_segments*" parametresi, parça alanıyla orantılı olarak dinamik şekilde yeniden hesaplanmıştır. Bu sayede kenar bölgelerindeki segment yoğunluğunun merkezle aynı kalması sağlanmıştır.

3.6.2. Küresel maskeleme (global masking) ve gürültü giderme

Uydu görüntülerinin projeksiyon dönüşümleri sırasında kenar bölgelerinde oluşan ve veri içermeyen siyah pikseller (NoData), model tarafından hatalı bir şekilde "Tarım" veya "Bina" olarak sınıflandırılabilir. Bu hatayı önlemek için geliştirilen sistemde iki aşamalı bir maskeleme uygulanmıştır:

Adım 1 (Veri Tespiti): Analiz öncesinde görüntünün tamamı taranarak, piksel parlaklık değerinin 0.001 eşik değerinin altında olduğu alanlar için bir "Geçersiz Veri Maskesi" oluşturulmuştur.

Adım 2 (Son İşlem): Model tahminleri oluşturulduktan sonra, bu maske kullanılarak ilgili alanlar zorunlu olarak "Tanımsız (Sınıf 0)" etiketine dönüştürülmüş ve kenar gürültüleri temizlenmiştir.

3.7. Zamansal Kentsel Gelişim ve Değişim Analizi

Çalışmanın nihai amacı olan kentsel yayılımın ve arazi örtüsü değişiminin tespiti için, farklı tarihlere (T_1 ve T_2) ait sınıflandırma sonuçlarını karşılaştıran bir "Analiz Motoru" (Analysis Engine) geliştirilmiştir.

3.7.1. Piksel tabanlı değişim matrisi

İki farklı tarihe ait sınıflandırma maskeleri (M_{t1} ve M_{t2}) piksel tabanlı olarak üst üste çakıştırılmış ve bir geçiş matrisi (Transition Matrix) oluşturulmuştur. Bu matris, T_1 zamanındaki bir arazi sınıfının T_2 zamanında hangi sınıfa dönüştüğünü nicel olarak ifade etmektedir.

Özellikle kentsel gelişim baskısını ortaya koymak amacıyla Eşitlik (3.1) ve Eşitlik (3.2)'deki dönüşümler izlenmiştir:

$$\Delta_{Orman \rightarrow Kent} = \sum_{i,j} \mathbb{1}(M_{t1}(i,j) = \text{Yeşil Alan} \wedge M_{t2}(i,j) \in \{\text{Bina, Yol}\}) \quad (3.1)$$

$$\Delta_{Tarim \rightarrow Kent} = \sum_{i,j} \mathbb{1}(M_{t1}(i,j) = \text{Tarım} \wedge M_{t2}(i,j) \in \{\text{Bina, Yol}\}) \quad (3.2)$$

Burada $\mathbb{1}$ gösterge fonksiyonunu temsil etmektedir. Bu formülasyon ile orman ve tarım arazilerinin ne kadarının yapılaşmaya dönüştüğü tam sayısal doğrulukla hesaplanmıştır.

3.7.2. Alan bazlı yüzdesel değişim hesaplamaları

Model çıktılarının yorumlanabilirliğini artırmak için, her bir sınıfın kapladığı alanın toplam geçerli alana oranı (R_c) aşağıdaki formül ile hesaplanmıştır. Hesaplamalarda "Tanımsız" (Sınıf 3) pikseller toplama dahil edilmeyerek istatistiksel sapmalar önlenmiştir.

$$R_c = \frac{N_c}{N_{\text{total}} - N_{\text{undefined}}} \times 100 \quad (3.3)$$

Eşitlik 3.3'de N_c , ilgili sınıfın piksel sayısını; N_{total} ise görüntüdeki toplam piksel sayısını ifade eder.

3.8. Model Çıktılarının Görselleştirilmesi ve Web Arayüzü


Geliştirilen sistemin son kullanıcılar ve karar vericiler tarafından kolayca kullanılabilmesi amacıyla, Python tabanlı Streamlit kütüphanesi kullanılarak interaktif bir web arayüzü tasarlanmıştır (Şekil 3.7).

Bu arayüz sayesinde:

Kullanıcılar T_1 ve T_2 tarihlerine ait Sentinel-2 görüntülerine (.tiff formatında) sisteme yükleyebilmektedir.

Sistem, arka planda geliştirilen çıkarım motorunu çalıştırarak sınıflandırma haritalarını anlık olarak üretmektedir.

Değişim analizi sonuçları, otomatik olarak oluşturulan bir "Yönetici Özeti" (Executive Summary) formatında ve grafiklerle desteklenerek sunulmaktadır.



Şekil 3.7. Geliştirilen değişim analizi sisteminin web tabanlı kullanıcı arayüzü

3.9. Veri ve Yazılım Erişilebilirliği

Bu tez çalışması kapsamında oluşturulan veri setleri, geliştirilen kaynak kodlar ve eğitilen modeller, "Açık Bilim" ilkeleri doğrultusunda araştırmacıların erişimine sunulmuştur.

Veri Seti (DOI): Çalışmada kullanılan ve etiketlenen süperpiksel veri seti, Zenodo platformunda [10.5281/zenodo.14660370](https://doi.org/10.5281/zenodo.14660370) DOI numarası ile arşivlenmiştir ve erişime açıktır (Eyi vd., 2025).

Kaynak Kodlar: FERİHA modelinin mimarisi, eğitim betikleri ve çıkarım motoruna ait tüm Python kodları GitHub üzerinde paylaşılmıştır (*Pienrium/Sentinel2-LandCover-Inference*).

Canlı Demo: Geliştirilen modelin son kullanıcılar tarafından test edilebilmesi için Hugging Face Spaces üzerinde çalışan interaktif bir web demosu hazırlanmıştır (*Feriha - a Hugging Face Space by pienrium*).

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde, tez çalışması kapsamında geliştirilen FERİHA sisteminin performansına ilişkin nicel ve nitel değerlendirmeler ile modelin entegre edildiği otomatik analiz sistemi aracılığıyla elde edilen kentsel değişim bulguları sunulmaktadır. Çalışma kapsamında öncelikle modelin hiç görmediği İstanbul test veri seti üzerindeki doğruluğu test edilmiş, ardından Bursa ana çalışma sahası ve Türkiye'nin farklı coğrafi bölgelerinde (Konya, Antalya, Çanakkale vb.) gerçekleştirilen vaka analizleri ile sistemin genelleştirme yeteneği tartışılmıştır.

4.1. Model Performansı ve Doğruluk Analizi

Eğitilen FERİHA modelinin İstanbul test veri seti üzerindeki performansı incelendiğinde oldukça yüksek bir başarı oranı elde edildiği görülmüştür. Sınıf bazlı doğruluk oranları Çizelge 4.1'te özetlenmiştir. Çizelge incelendiğinde, modelin yedi sınıfın beşinde %97'nin üzerinde doğruluk sergilediği görülmektedir.

Çizelge 4.1. Modelin test veri seti üzerindeki sınıf bazlı doğruluk oranları

Sınıf	Doğruluk (%)
Su Yüzeyi	100.0
Atanamayan	100.0
Bina	98.7
Yeşil Alan	98.2
Yol	97.1
Tarım Alanı	95.1
Çıplak Arazi	94.9


Sonuçlar detaylandırıldığında, "Su Yüzeyi" ve "Atanamayan" sınıflarının %100 doğrulukla kusursuz bir şekilde sınıflandırıldığı görülmektedir. Bu başarının temel nedeni, su yüzeylerinin spektral imzasının diğer sınıflardan çok belirgin şekilde ayrışmasıdır. Ayrıca "Bina", "Yeşil Alan" ve "Yol" gibi temel arazi örtüsü sınıflarında elde edilen %97 üzeri başarı, FERİHA modelinin kentsel ve doğal unsurları ayırt etmede oldukça yetkin olduğunu kanıtlamaktadır.

En düşük doğruluk oranı %94.9 ile "Çıplak Arazi" sınıfında elde edilmiştir. Bunun nedeninin, çıplak arazi spektral karakteristiğinin zaman zaman hasat edilmiş "Tarım Alanları" veya stabilize "Yollar" ile karışmasından kaynaklandığı değerlendirilmektedir. Model hatalarının detaylı analizi Çizelge 4.2'de sunulmuştur.

Çizelge 4.2. Test setindeki sınıflara göre doğru ve yanlış tahmin dağılımları

Sınıf	Doğru Tahmin	Yanlış Tahmin	Toplam Örnek
Su Yüzeyi	447	0	447
Atanamayan	447	0	447
Bina	441	6	447
Yeşil Alan	439	8	447
Yol	434	13	447
Tarım Alanı	425	22	447
Çıplak Arazi	424	23	447

Geliştirilen FERİHA modelinin sınıflandırma başarısını salt doğruluk (accuracy) metriklerinin ötesinde, her bir sınıfın diğer sınıflardan ne kadar iyi ayrıştırılabildiğini (discriminative power) ölçmek amacıyla "Bire-Karşı-Diğerleri" (One-vs-Rest) stratejisi kullanılarak Çok Sınıflı Alıcı İşletim Karakteristiği (ROC - Receiver Operating Characteristic) analizi gerçekleştirilmiştir. Elde edilen ROC eğrileri ve Eğri Altında Kalan Alan (AUC - Area Under Curve) değerleri Şekil 4.1'de sunulmuştur.



Şekil 4.1. FERİHA modelinin test veri seti üzerindeki çok sınıflı ROC eğrileri ve AUC değerleri


Modelin sınıflandırma performansı incelendiğinde, kentsel gelişim tespitindeki temel hedef olan "Bina" sınıfının 0.99 AUC değeri ile yüksek bir ayırt ediciliğe sahip olduğu görülmektedir. Bu sonuç, 10 m mekânsal çözünürlüklü Sentinel-2 uydu görüntülerinde, önerilen CNN mimarisinin kentsel yapıları (çatı, beton vb.) diğer arazi örtülerinden (tarım, orman, çıplak toprak) başarılı bir şekilde ayırabildiğini göstermektedir.

Benzer şekilde, "Su Yüzeyi" sınıfı, spektral karakteristiklerinin belirginliği ve görünür/kızılötesi bölgelerdeki düşük yansımaya değerleri sayesinde 1.00 AUC değeri ile sınıflandırılmıştır. Öte yandan, "Tarım Alanı" ve "Yeşil Alan" sınıfları, benzer fotosentetik yansımaya özelliklerine ve dokusal yapıya sahip olmaları nedeniyle birbirleriyle kısmi bir spektral karışma yaşasa da 0.93 AUC değeri ile yeterli bir ayırıcılık performansı sergilemiştir. Rastgele sınıflandırma eşiği olan 0.50 değeri (kesikli siyah çizgi) ile kıyaslandığında, modelin tüm sınıflar için mekânsal ve spektral özellikleri öğrenme kapasitesinin uygun düzeyde olduğu değerlendirilmektedir.

4.1.1. Nitel ve görsel değerlendirme


Geliştirilen FERİHA modelinin başarısını ve operasyonel verimliliğini ortaya koymak amacıyla, modelin yaklaşımı ile literatürde ve harita mühendisliği uygulamalarında yaygın olarak kullanılan geleneksel yöntemler karşılaştırmalı olarak görselleştirilmiştir.

Geliştirilen model, pikselleri tekil olarak değil, mekânsal komşulukları ve renk benzerliklerine göre gruplandırılmış "süperpiksel" segmentleri üzerinden analiz etmektedir. Şekil 4.2'de, modelin İstanbul test görüntüsü üzerindeki çalışma mantığı görülmektedir. Sarı sınırlar ile belirlenen her bir segment, model tarafından bir bütün olarak değerlendirilmekte ve tek bir sınıf etiketi (renkli noktalar) atanmaktadır.



Şekil 4.2. Önerilen FERİHA modelinin nesne tabanlı karar verme sürecini gösteren çıktı

Karşılaştırma amacıyla, aynı İstanbul test görüntüsü üzerinde, herhangi bir derin öğrenme desteği olmaksızın, ArcGIS yazılımı kullanılarak geleneksel En Çok Olabilirlik (Maximum Likelihood - MLC) sınıflandırması gerçekleştirilmiştir. Bu işlem için operatör tarafından her bir sınıf (Su, Bina, Yeşil Alan vb.) için manuel olarak çok sayıda eğitim örneği (training sample) toplanmıştır. Elde edilen sonuç haritası Şekil 4.3'de sunulmuştur.



Şekil 4.3. Geleneksel yöntem (ArcGIS Maximum Likelihood) kullanılarak, manuel örnek toplama süreci sonunda üretilen İstanbul sınıflandırma haritası

Şekil 4.2 (Önerilen Yöntem) ve Şekil 4.3 (Geleneksel Yöntem) birlikte değerlendirildiğinde şu temel farklar ortaya çıkmaktadır:

Gürültü ve Nesne Bütünlüğü: Geleneksel yöntemler (Şekil 4.3) piksel tabanlı çalıştığı için, bina çatılarındaki gölgeler veya parlak yüzeyler gibi spektral yansıma farklılıklarında hatalı sınıflandırmalar yaparak mekansal tutarsızlıklar (Tuz-Biber Etkisi) oluşturmaya yatkındır. Buna karşın FERİHA modeli (Şekil 4.2), süperpiksel yaklaşımı sayesinde bu tür gürültüleri kaynağında engellemekte ve nesne bütünlüğünü korumaktadır.

Operasyonel İş Yüğü ve Zaman: Şekil 4.3'deki haritanın üretilmesi için her yeni görüntüde operatörün manuel olarak saatlerce eğitim verisi toplaması gerekmektedir. Bu durum büyük alanların haritalanmasında ciddi bir zaman ve maliyet kaybıdır. FERİHA modeli ise eğitildikten sonra, insan müdahalesine gerek duymadan yeni görüntüleri saniyeler içerisinde otomatik olarak sınıflandırabilmektedir.

Sonuç olarak; görsel analizler, FERİHA modelinin geleneksel yöntemlere kıyasla hem daha temiz (gürültüsüz) veri ürettiğini hem de manuel harita üretim süreçlerindeki ağır iş yükünü ortadan kaldırdığını göstermektedir.

4.2. Ana Çalışma Sahası: Bursa İli Değişim Analizi (2020-2025)


Modelin eğitim sahası olan Bursa ili, farklı kentsel gelişim dinamiklerine sahip alt bölgeler (Merkez ilçe, kıyı şeridi vb.) barındırmaktadır. Sistemin başarısını detaylandırmak amacıyla, hızlı kentleşme baskısı altındaki Görükle bölgesi ve coğrafi sınırları nedeniyle daha stabil bir yapı sergileyen Gemlik ilçesi iki ayrı vaka analizi olarak incelenmiştir.

4.2.1. Vaka analizi 1: Hızlı kentleşme örneği (Görükle bölgesi)

Bursa Uludağ Üniversitesi kampüsünü ve yeni yerleşim bölgelerini kapsayan Görükle, son 5 yıl içerisinde en yoğun yapılaşma faaliyetlerinin görüldüğü alanlardan biridir. Bölgedeki değişimi çok boyutlu olarak değerlendirmek için analiz sürecinde bölgeye ait doğal görüntüler, geleneksel yöntem analizi ve önerilen model (FERİHA) analizi gerçekleştirilmektedir.

Analize başlamadan önce, bölgedeki değişimin çıplak gözle doğrulanması amacıyla Sentinel-2 uydusuna ait 2020 (T_1) ve 2025 (T_{12}) tarihli gerçek renkli (RGB) kompozitler incelenmiştir (Şekiller 4.4 ve 4.5).

Görseller karşılaştırıldığında, özellikle görüntünün merkez ve doğu kısımlarındaki tarım arazilerinin (kahverengi/krem tonları) yerini betonarme yapılaşmaya (beyaz/gri parlak dokular) bıraktığı net bir şekilde görülmektedir. Bu doğal görüntüler, modelin başarısını ölçmek için referans (Ground Truth) olarak kabul edilmiştir.




Şekil 4.4. 28.07.2020 Tarihli Görükle bölgesine ait doğal renkli uydu görüntüsü




Şekil 4.5. 29.07.2025 Tarihli Görükle bölgesine ait doğal renkli uydu görüntüsü

Modelin performansını kıyaslamak amacıyla, aynı görüntüler üzerinde operatör destekli En Çok Olabilirlik (Maximum Likelihood) sınıflandırması uygulanmıştır (Şekiller 4.6 ve 4.7).

Sonuçlar incelendiğinde, geleneksel yöntemin piksel tabanlı yapısı nedeniyle bina içlerinde ve tarla kenarlarında yoğun mekansal tutarsızlıklar (Tuz-Biber Etkisi) oluşturduğu görülmektedir. Özellikle 2025 görüntüsünde (Sağ), yeni yapılan binaların parlak çatıları "Çorak Arazi" veya "Yol" ile karışmış, yapısal bütünlük sağlanamamıştır. Ayrıca bu haritaların üretilmesi için her iki tarih için ayrı ayrı eğitim verisi (training samples) toplanması gerekmiş, bu da ciddi bir zaman maliyeti oluşturmuştur.



Şekil 4.6. 28.07.2020 Tarihli Geleneksel yöntem (ArcGIS Maximum Likelihood) ile üretilen sınıflandırma haritası




Şekil 4.7. 29.07.2025 Tarihli Geleneksel yöntem (ArcGIS Maximum Likelihood) ile üretilen sınıflandırma haritası

Geliştirilen Derin Öğrenme modeli ile yapılan analizde ise süperpiksel tabanlı yaklaşım sayesinde çok daha temiz, gürültüden arınmış ve nesne bütünlüğü korunan sonuçlar elde edilmiştir (Şekil 4.8).

Şekil 4.8 dikkatle incelendiğinde, modelin "Koyu Pembe" (Bina) olarak sınıflandırdığı alanların, Şekil 4.4 ve Şekil 4.5'deki doğal görüntüdeki yeni yapılaşma alanlarıyla birebir örtüştüğü görülmektedir. ArcGIS çıktısındaki karmaşa yerine, FERİHA net sınırlara sahip bloklar üretmiştir.



Şekil 4.8. FERİHA modeli tarafından Görükle bölgesi için üretilen 2020-2025 karşılaştırma haritası



Şekil 4.9. FERİHA modeli tarafından Görükle bölgesi için üretilen 2020-2025 karşılaştırma raporu

Çizelge 4.3'de ve Şekil 4.9'da gösterilen otomatik analiz motoru tarafından üretilen istatistikler, bölgedeki tarım arazilerinin yapılaşma baskısı altında kaldığını sayısal olarak doğrulamaktadır.

Çizelge 4.3. Görükle bölgesi arazi örtüsü değişim matrisi özeti (2020-2025)

Sınıf	2020 Oranı (%)	2025 Oranı (%)	Değişim
Yapılaşma	%54.11	%67.27	+%13.16(artış)
Doğal Alanlar	%38.58	%21.51	-%17.07(azalış)

Elde edilen sonuçlara göre, sadece 5 yıllık bir periyotta bölgedeki yapılaşma yoğunluğu %13.16 oranında artış göstermiştir. Daha da önemlisi, sistem "Tarım Arazisi Kaybı" uyarısı vererek, tarım alanlarının %14.72'lik kısmının imara açıldığını veya

yapılaşmaya dönüştüğünü tespit etmiştir. Bu bulgu, önerilen FERİHA modelinin kentsel yayılımı (urban sprawl) izlemedeki hassasiyetini kanıtlamaktadır.

4.2.2. Vaka analizi 2: Kıyı şeridi ve mevsimsel dayanıklılık (Gemlik bölgesi)

Modelin sadece ideal yaz koşullarında değil, zorlu atmosferik ve mevsimsel şartlarda da kararlı çalışıp çalışmadığını (robustness) test etmek amacıyla Gemlik ilçesi pilot bölge seçilmiştir. Analiz için güneş açısının düşük olduğu ve gölge etkilerinin yoğun hissedildiği kış mevsimine ait görüntüler (30.12.2020 ve 19.12.2025) kullanılmıştır. Analiz süreci yine üç aşamalı (Doğal, Klasik, Önerilen) karşılaştırma yöntemiyle gerçekleştirilmiştir.

İncelenen bölge, Gemlik Körfezi (Deniz) ile dik yamaçlı dağlar arasına sıkışmış dar bir kıyı şerididir. Şekil 4.10 ve 4.11 'deki doğal renkli görüntüler incelendiğinde, kış mevsimi olması nedeniyle dağlık alanlarda koyu gölgelerin oluştuğu ve bitki örtüsünün (zeytinlikler) spektral yansımalarının düştüğü görülmektedir.

Ayrıca Görükle örneğinin aksine, Gemlik'te 2020-2025 yılları arasında doğal görüntülerde çıplak gözle belirgin bir "yeni yapılaşma patlaması" görülmemektedir. Bu durum, ilçenin coğrafi olarak büyüme sınırlarına ulaştığını işaret etmektedir.



Şekil 4.10. 30.12.2020 tarihli Gemlik ilçesine ait kış dönemi doğal renkli uydu görüntüsü




Şekil 4.11. 19.12.2025 tarihli Gemlik ilçesine ait kış dönemi doğal renkli uydu görüntüsü

Aynı kış görüntüleri üzerinde ArcGIS ile uygulanan \textbf{Maximum Likelihood} sınıflandırması, mevsimsel zorluklardan ciddi oranda etkilenmiştir (Şekiller 4.12 ve 4.13).


Piksel tabanlı çalışan klasik yöntem, özellikle şu iki noktada hatalı sonuçlar üretmiştir:

Gölge Karışıklığı: Dağların kuzeye bakan yamaçlarındaki koyu gölgeler, spektral olarak su yüzeyine benzediği için yer yer "Su" veya "Atanamayan" olarak hatalı sınıflandırılmıştır.

Kıyı Hattı Bozulması: Deniz ile kentsel alanın birleştiği kıyı şeridinde yoğun mekansal tutarsızlıklar (Tuz-Biber gürültüsü) oluşmuş, liman yapıları ve iskeleler net olarak ayırt edilememiştir.



Şekil 4.12. 30.12.2020 tarihli mevsimsel etkiler altındaki görüntünün geleneksel yöntem (ArcGIS) sınıflandırma haritası




Şekil 4.13. 19.12.2025 tarihli mevsimsel etkiler altındaki görüntünün geleneksel yöntem (ArcGIS) sınıflandırma haritası

Geliştirilen FERİHA modeli ise süperpiksel tabanlı yaklaşımı sayesinde kış koşullarının getirdiği piksel bazlı gürültüleri elimine etmeyi başarmıştır (Şekil 4.14).

Model, dağ gölgelerini su yüzeyinden başarıyla ayırmış ve Gemlik Körfezi'nin sınırlarını net bir şekilde çizmiştir. "Mavi" (Su) ve "Koyu Pembe" (Yapılaşma) alanlar arasındaki geçişler, ArcGIS çıktısına kıyasla çok daha keskin ve doğrudur. Modelin ürettiği istatistikler (Çizelge 4.4 ve Şekil 4.15), bölgedeki yapılaşmanın doygunluk noktasına ulaştığını doğrulamaktadır.



Şekil 4.14. FERİHA modelinin Gemlik bölgesi için 2020-2025 kış görüntüleri üzerinden üretilen karşılaştırma haritası



Şekil 4.15. FERİHA modelinin Gemlik bölgesi için 2020-2025 kış görüntüleri üzerinden üretilen karşılaştırma raporu

Çizelge 4.4. Gemlik bölgesi değişim istatistikleri (2020-2025)

Sınıf	2020 Oranı (%)	2025 Oranı (%)	Değişim
Yapılaşma	%54.11	%67.27	+%13.16(artış)
Doğal Alanlar	%38.58	%21.51	-%17.07(azalış)

İstatistiksel sonuçlar incelendiğinde, 5 yıllık süreçte yapılaşma oranında sadece %0.92'lik marjinal bir artış olduğu görülmüştür. Bu durum, Gemlik'in coğrafi yapısı gereği kentsel gelişim alanlarının kısıtlı olmasıyla örtüşmektedir. Ayrıca, kış aylarındaki zorlu radyometrik koşullara rağmen modelin "Su Varlığı"nı %21 bandında tutarlı (sadece

%0.91 farkla) tespit etmesi, sistemin mevsimsel deęişikliklere karşı dayanıklılıęının en güçlü kanıtıdır.


4.3. Farklı Coęrafi Bölgelerde Model Genelleştirme Testleri

Geliştirilen FERİHA} sisteminin, eğitim verisi olarak kullanılan Bursa ili dışındaki farklı coęrafi bölgelerde nasıl performans gösterdiğini (genelleştirme yeteneğini) test etmek amacıyla; İstanbul, Çanakkale, Antalya ve Konya illerinden seçilen test bölgeleri üzerinde analizler gerçekleştirilmiştir.


4.3.1. Marmara bölgesi: 3. Köprü ve İstanbul Boęazı

Modelin ince ve doğrusal yapıları (altyapı projeleri) tespit etme yeteneğini ölçmek için İstanbul Boęazı'nın kuzey kesimi ve Yavuz Sultan Selim Köprüsü analiz edilmiştir. Analiz, önceki bölümlerde olduęu gibi üç aşamalı (Doęal, Klasik, Önerilen) karşılaştırma yöntemiyle gerçekleştirilmiştir.

Referans olarak kullanılan doğa renkli (RGB) Sentinel-2 görüntülerinde (Şekiller 4.16 ve 4.17, İstanbul Boęazı'nı birbirine bağlayan Yavuz Sultan Selim Köprüsü net bir şekilde görölmektedir. Ancak köprü genişliğinin yaklaşık 59 metre olması ve Sentinel-2'nin 10 metrelik mekânsal çözünürlüğü göz önüne alındığında, bu yapı uzaktan algılama algoritmaları için tespit edilmesi zor "ince lineer öznetelik" (thin linear feature) sınıfına girmektedir.




Şekil 4.16. 28.07.2021 tarihli İstanbul Boęazı Kuzey Kesimi ve Yavuz Sultan Selim Köprüsü'ne ait doğa renkli görüntü




Şekil 4.17. 29.07.2025 tarihli İstanbul Boğazı Kuzey Kesimi ve Yavuz Sultan Selim Köprüsü'ne ait doğal renkli görüntü

Aynı görüntüler üzerinde operatör destekli En Çok Olabilirlik (Maximum Likelihood) sınıflandırması uygulandığında, piksel tabanlı yaklaşımın sınırları ortaya çıkmıştır (Şekiller 4.18 ve 4.19).

Klasik yöntem, köprü piksellerini su pikselleriyle karıştırmış ve köprü bütünlüğünü sağlayamamıştır. Harita incelendiğinde, köprünün yer yer koptuğu, bazı kısımlarının "Su" olarak sınıflandırıldığı ve kıyı şeridinde yoğun gürültü olduğu görülmektedir. Ayrıca bu sonucu elde etmek için yine manuel eğitim verisi toplama işlemi gerekmiştir.




Şekil 4.18. 28.07.2021 tarihli geleneksel yöntem (ArcGIS) sınıflandırma haritası




Şekil 4.19. 29.07.2025 tarihli geleneksel yöntem (ArcGIS) sınıflandırma haritası

FERİHA modeli ile gerçekleştirilen analizde ise, SLIC süperpiksel algoritmasının kenar koruma (boundary adherence) yeteneği sayesinde çarpıcı bir sonuç elde edilmiştir (Şekil 4.20).

Model, köprüyü oluşturan pikselleri bir segment grubu olarak algılamış ve su yüzeyinden başarıyla ayırarak kesintisiz bir "Koyu Pembe" (Yol/Yapı) hat olarak tanımlamıştır. Şekil 4.20'de görüldüğü üzere, köprü ayakları ve bağlantı yolları net bir şekilde haritalanmıştır. Ayrıca şekil 4.21'de modelin karşılaştırma raporu eklenmiştir. Bu sonuç, FERİHA'nın sadece geniş alanları değil, stratejik öneme sahip ince altyapı unsurlarını da başarıyla tespit edebildiğini kanıtlamaktadır.



Şekil 4.20. FERİHA modeli tarafından İstanbul Boğazı Kuzey Kesimi ve Yavuz Sultan Selim Köprüsü için üretilen 2021-2025 karşılaştırma haritası



Şekil 4.21. FERİHA modeli tarafından İstanbul Boğazı Kuzey Kesimi ve Yavuz Sultan Selim Köprüsü için üretilen 2021-2025 karşılaştırma raporu

4.3.2. Güney Marmara: Çanakkale ve tarımsal spektral karışıklık analizi

Modelin yoğun tarımsal faaliyetlerin olduğu bölgelerdeki davranışını ve spektral ayırt etme yeteneğini test etmek amacıyla Çanakkale ilinde seçilen bir endüstriyel tarım bölgesi analiz edilmiştir. Bu vaka analizi, uzaktan algılama çalışmalarında sıkça karşılaşılan "Hasat Edilmiş Tarla" ile "Çorak Arazi/Yapılaşma" karışıklığını (spectral confusion) irdelemek açısından kritik öneme sahiptir.

Analiz edilen bölgeye ait doğal renkli görüntüler (Şekiller 4.22 ve 4.23) incelendiğinde, 2020 (T_1) yılında tarlaların büyük kısmının hasat edildiği veya nadasa bırakıldığı, bu nedenle toprak yüzeyinin oldukça parlak ve açık renkli olduğu görülmektedir. 2025 (T_2) yılında ise fenolojik döngünün farklı olması nedeniyle bazı tarlaların daha koyu tonlarda olduğu izlenmektedir.

Bu durum, optik uydu görüntülerinde kurumuş toprak ile beton/asfalt yüzeylerin birbirine çok yakın yansıma değerleri (reflectance) vermesine neden olmaktadır.




Şekil 4.22. 29.07.2020 tarihli Çanakkale test bölgesine ait doğal renkli görüntü




Şekil 4.23. 28.07.2025 tarihli Çanakkale test bölgesine ait doğal renkli görüntü

ArcGIS üzerinde uygulanan En Çok Olabilirlik (Maximum Likelihood) sınıflandırması, bu spektral benzerlikten en çok etkilenen yöntem olmuştur (Şekiller 4.24 ve 4.25).

Yöntem piksel tabanlı çalıştığı için, parlak görünen tarla piksellerini rastgele bir şekilde "Bina" (Pembe) veya "Çorak Arazi" (Bej) olarak sınıflandırmıştır. Sonuç haritasında tarlaların içi homojen değil, adeta bir mozaik gibi farklı sınıflarla kirlenmiş (gürültülü) bir yapıdadır. Bu durum, tarım arazilerinin sınırlarının tespiti imkansız hale getirmiştir.



Şekil 4.24. 29.07.2020 tarihli geleneksel yöntem (ArcGIS) sınıflandırma haritası



Şekil 4.25. 28.07.2025 tarihli geleneksel yöntem (ArcGIS) sınıflandırma haritası

FERİHA modeli ile yapılan analizde (Şekiller 4.26 ve 4.27), süperpiksel yaklaşımı sayesinde tarlalar ve yapılar geometrik olarak (bloklar halinde) düzgün ayrıştırılmıştır. Ancak, modelin sayısal çıktılarında yapılaşma oranında %11.7'lik sanal bir düşüş (azalma) gözlemlenmiştir.


Bir kentin yapılaşma oranının azalması (binaların yıkılıp tarlaya dönüşmesi) olağan bir durum değildir. Bu anomali detaylı incelendiğinde şu sonuç ortaya çıkmıştır:

Yanlış Pozitif (False Positive): Model, 2020 (T_1) görüntüsündeki parlak nadas alanlarını, şekilsel bütünlüğü korusa da sınıf etiketi olarak "Yapılaşma/Çıplak Arazi" (Koyu Pembe/Gri) olarak etiketlemiştir.

Düzelme: 2025 (T_2) yılında ise aynı alanlar ekili olduğu veya nem oranı arttığı için doğru bir şekilde "Tarım" (Sarı) olarak sınıflandırılmıştır.



Şekil 4.26. FERİHA modeli tarafından Çanakkale bölgesi için üretilen 2020-2025 karşılaştırma haritası



Şekil 4.27. FERİHA modeli tarafından Çanakkale bölgesi için üretilen 2020-2025 karşılaştırma raporu

Bu bulgu, önerilen modelin geometrik başarısının (sınır koruma) yüksek olduğunu, ancak radyometrik ayırt etme yeteneğinin (sınıflandırma) mevsimsel koşullara bağımlı olduğunu göstermektedir. Bu durum, tarımsal alanlarda analiz yapılırken çok zamanlı (multi-temporal) görüntülerin kullanılmasının önemini ortaya koymaktadır.

4.3.3. Akdeniz Bölgesi: Antalya ve örtü altı tarım (sera) etkisi

Türkiye'nin örtü altı tarım (seracılık) merkezi olan Antalya, uzaktan algılama modelleri için oldukça zorlu bir test ortamı sunmaktadır. Seraların hem geometrik

yapısının (dikdörtgen bloklar) binalara benzemesi hem de kaplama malzemelerinin (plastik/cam) yüksek yansıma değerine sahip olması, sınıflandırma algoritmalarını yanıltabilmektedir. Bu bölümde, modelin bu zorlu "Sera-Bina Ayrımı" problemindeki davranışı analiz edilmiştir.

Test bölgesine ait doğal renkli görüntüler (Şekiller 4.28 ve 4.29) incelendiğinde, tarım alanlarının büyük kısmının klasik açık tarla değil, plastik veya cam örtülü seralar olduğu görülmektedir.

2020 (T_1) ve 2025 (T_2) görüntüleri karşılaştırıldığında, seraların parlak beyaz/gri renk tonlarına sahip olduğu ve bu yönüyle betonarme yapılarla neredeyse aynı spektral imzayı taşıdığı dikkat çekmektedir. Bu durum, optik uydu görüntülerinde sadece renk bilgisine dayanarak ayırım yapmayı zorlaştırmaktadır.




Şekil 4.28. 25.07.2020 tarihli Antalya test bölgesine ait doğal renkli görüntü




Şekil 4.29. 24.07.2025 tarihli Antalya test bölgesine ait doğal renkli görüntü

ArcGIS üzerinde uygulanan En Çok Olabilirlik (Maximum Likelihood) yöntemi, seraların yarattığı bu spektral benzerlik nedeniyle tutarlı bir sonuç üretememiştir (Şekiller 4.30 ve 4.31).

Piksel tabanlı analizde, seraların üzerindeki yansıma farkları (örneğin plastik örtünün eskimesi veya güneş açısı) nedeniyle aynı sera bloğu içinde hem "Bina", hem "Çorak Arazi" hem de "Tarım" pikselleri karışık halde çıkmıştır. Sonuç haritasında seraların sınırları kaybolmuş ve bölge genelinde yoğun bir gürültü (noise) oluşmuştur.



Şekil 4.30. 25.07.2020 tarihli geleneksel yöntem (ArcGIS) sınıflandırma haritası



Şekil 4.31. 24.07.2025 tarihli geleneksel yöntem (ArcGIS) sınıflandırma haritası

FERİHA modeli ile yapılan analizde (Şekiller 4.32 ve 4.33), modelin Antalya'ya özgü bu zorluk karşısında geometrik olarak başarılı ancak semantik olarak hatalı bir çıkarım yaptığı gözlemlenmiştir.


İstatistiksel sonuçlarda, bölgedeki yapılaşma oranında %10.68'lik bir düşüş tespit edilmiştir. Kentsel gelişimin devam ettiği bir bölgede yapılaşmanın azalması beklenen bir durum değildir. Bu anomalinin nedeni incelendiğinde:

Şekilsel Yanılgı: Modelin, seraların keskin dikdörtgen sınırlarını ve parlak yüzeylerini, eğitim verisindeki (Bursa) sanayi yapılarına veya büyük binalara benzeterek "Bina" (Koyu Pembe) sınıfına atadığı görülmüştür (Yanlış Pozitif).

Dönemsel Fark: 2025 yılında (T_2), sera örtülerinin değişmesi veya kirlenmesi sonucu yansımanın azalmasıyla, model bu alanların bir kısmını bu kez doğruya daha yakın şekilde "Tarım" veya "Çorak Arazi" olarak sınıflandırmış, bu da istatistiklere "bina yıkıldı/azaldı" şeklinde yansımıştır.



Şekil 4.32. FERİHA modeli tarafından Antalya bölgesi için üretilen 2020-2025 karşılaştırma haritası



Şekil 4.33. FERİHA modeli tarafından Antalya bölgesi için üretilen 2020-2025 karşılaştırma raporu

Bu vaka analizi, derin öğrenme modellerinin sadece renk bilgisine değil, nesne geometrisine de (dikdörtgen form) güçlü bir şekilde odaklandığını kanıtlamaktadır. Sera gibi yapısal olarak binaya benzeyen tarım unsurlarının ayrıştırılması için, modelin eğitim setine "Sera" sınıfının ayrıca eklenmesi gerektiği, bu çalışmanın önemli bir çıkarımı olarak kaydedilmiştir.


4.3.4. İç Anadolu Bölgesi: Konya (kurak iklim ve bozkır analizi)

Modelin eğitim veri setinde bulunmayan (unseen) bir iklim kuşağında ve arazi yapısında nasıl performans gösterdiğini test etmek amacıyla, İç Anadolu Bölgesi'nin kurak ve bozkır (step) örtüsüne sahip Konya ili analiz edilmiştir. Bu vaka analizi, modelin

farklı coğrafyalara "Genelleştirme Yeteneğini" (Generalization Capability) ölçmek açısından kritik öneme sahiptir.

Şekil 4.34 ve şekil 4.35'deki doğal renkli görüntüler incelendiğinde, bölgenin tipik sanayi ve kentsel gelişim alanlarını barındırdığı görülmektedir. Ancak bölgenin en büyük zorluğu, kurak toprak yapısının (açık bej/sarı tonlar) yüksek yansıma değerine sahip olması ve betonarme yapıların çatılarıyla neredeyse aynı spektral imzayı taşımasıdır.

Nem ve bitki örtüsünün azlığı, zemin ve bina ayrımını optik görüntülerde en zorlu seviyeye taşımaktadır.




Şekil 4.34. 30.07.2020 tarihli Konya test bölgesine ait doğal renkli görüntü




Şekil 4.35. 29.07.2025 tarihli Konya test bölgesine ait doğal renkli görüntü

Bu bölgede gerçekleştirilen karşılaştırmalı analizlerde, önceki vaka analizlerinde kullanılan En Çok Olabilirlik (Maximum Likelihood) yöntemi başarısız olmuştur. Toprak ve bina arasındaki spektral benzerlik nedeniyle algoritma sınıfları ayırtıramamış ve tek bir sınıf ataması yapmıştır.

Bu nedenle, alternatif bir geleneksel yöntem olan ve piksel değerlerini istatistiksel olarak gruplayan ISO Cluster (Denetimsiz Sınıflandırma) algoritması kullanılmıştır (Şekiller 4.36 ve 4.37). Ancak bu yöntemle elde edilen sonuçlarda da (özellikle 2025 görüntüsünde), sanayi yapılarının çatıları ile yollar ve boş araziler arasında yoğun karışıklıklar yaşandığı, bina sınırlarının net olarak çizilemediği görülmüştür.



Şekil 4.36. 30.07.2020 tarihli geleneksel yöntem (ArcGIS ISO Cluster) sınıflandırma haritası




Şekil 4.37. 29.07.2025 tarihli geleneksel yöntem (ArcGIS ISO Cluster) sınıflandırma haritası

FERİHA modeli ile gerçekleştirilen analizde ise (Şekiller 4.38 ve 4.39), modelin sadece renk bilgisine değil, nesnelerin doku ve geometrisine (süperpiksel) odaklanması sayesinde zemin-bina ayrımını başarıyla yaptığı görülmüştür.

Model, Marmara Bölgesi'nin yeşil bitki örtüsü üzerinde eğitilmiş olmasına rağmen, İç Anadolu'nun sarı/bozkır zeminini doğru bir şekilde "Çorak/Doğal Alan" olarak tanımlamış ve üzerindeki koyu pembe (Bina) blokları net bir şekilde ayırmıştır. İstatistiksel olarak bölgedeki yapılaşma yoğunluğunun %4.28 oranında arttığı tespit edilmiştir.



Şekil 4.38. FERİHA modeli tarafından Konya bölgesi için üretilen 2020-2025 karşılaştırma haritası



Şekil 4.39. FERİHA modeli tarafından Konya bölgesi için üretilen 2020-2025 karşılaştırma raporu

Bu sonuç, geliştirilen derin öğrenme mimarisinin sadece belirli bir bölgeye (overfitting) özgü kalmadığını, farklı coğrafi ve iklimsel koşullarda da kentsel gelişimi izleyebilecek esnekliğe sahip olduğunu kanıtlamaktadır.

4.4. Sonuçların Literatür ile Karşılaştırılması

Bu tez çalışması kapsamında geliştirilen FERİHA modeli ile elde edilen deneysel bulgular, kentsel uzaktan algılama literatüründeki güncel tartışmalar, mevcut problemler ve çözüm önerileri ışığında kapsamlı olarak değerlendirilmiştir. Çalışmanın sonuçları dört ana başlık altında literatürle ilişkilendirilmiştir.

Nesne Tabanlı Yaklaşımın "Karışık Piksel" Sorununa Çözümü: Orta çözünürlüklü uydu görüntülerinde (Örn: Sentinel-2, 10m) karşılaşılan en temel problemlerden biri, tek bir pikselin birden fazla arazi sınıfını (hem su hem kara gibi) barındırmasından kaynaklanan "karışık piksel" (mixed pixel) sorunudur. Geleneksel piksel tabanlı yöntemler (Maximum Likelihood vb.), mekânsal komşuluğu dikkate almadığı için bu piksellerde yoğun mekansal tutarsızlıklar (tuz-biber gürültüsü) üretmektedir.

Bu çalışmada uygulanan Süperpiksel (SLIC) entegrasyonu, literatürdeki Nesne Tabanlı Görüntü Analizi (OBIA) prensiplerini Derin Öğrenme ile birleştirmiştir. Özellikle İstanbul Boğazı Köprüsü vaka analizinde görüldüğü üzere model, köprüyü oluşturan pikselleri su yüzeyinden bağımsız tek bir segment olarak algılayarak, piksel tabanlı yöntemlerin yaşadığı sınır bozulması (boundary distortion) sorununu minimize etmiştir. Bu durum, süperpiksel tabanlı öznitelik çıkarımının, kentsel detayların korunmasında piksel tabanlı CNN modellerine göre daha kararlı olduğunu göstermektedir.

Farklı Coğrafyalara Genelleştirme (Domain Adaptation): Derin öğrenme modellerinin eğitim verisinin ait olduğu coğrafyaya aşırı uyum (overfitting) sağlayarak, farklı iklim kuşaklarında başarısız olması literatürde sıkça raporlanan bir "Alan Kayması" (Domain Shift) problemidir.

Ancak bu çalışmada, Marmara Bölgesi'nin ılıman ve yeşil bitki örtüsü üzerinde eğitilen modelin, Konya gibi kurak, bozkır ve farklı toprak yapısına sahip bir bölgede (unseen domain) yeniden eğitime ihtiyaç duymadan başarılı sonuçlar vermesi dikkat çekicidir. Bu bulgu, önerilen modelin sadece spektral renk bilgisine (RGB) odaklanmadığını; aynı zamanda binaların geometrik şekli, dokusu ve süperpiksel

komşulukları gibi yapısal öznitelikleri de öğrendiğini kanıtlamaktadır. Bu yönüyle çalışma, literatürdeki "Transfer Öğrenme" (Transfer Learning) çalışmalarına pozitif bir örnek teşkil etmektedir.

Spektral Karışıklık ve Optik Veri Sınırları: Uzaktan algılama literatüründe "Semantic Gap" (Semantik Açık) olarak tanımlanan; nesnelerin fiziksel yansıma değerleri ile semantik etiketleri arasındaki uyumsuzluk sorunu, bu çalışmanın limitlerini belirlemiştir.

Antalya örneğinde seraların, Çanakkale örneğinde ise hasat edilmiş parlak tarlaların model tarafından "Bina/Yapılaşma" olarak algılanması, optik uydu görüntülerinin bilinen bir sınırıdır. Literatürde de sıkça vurgulandığı üzere, plastik sera örtülerinin ve beton çatıların spektral imzalarının birbirine çok yakın olması, sadece RGB bantları kullanan modellerde kaçınılmaz olarak "Yanlış Pozitif" (False Positive) hatalarına yol açmaktadır. Bu durum, modelin geometrik başarısı yüksek olsa bile, materyal ayrımı konusunda çok zamanlı (multi-temporal) veya radar (SAR) verileriyle desteklenmesi gerekliliğini ortaya koymuştur.

Etiketleme Maliyeti ve Operasyonel Verimlilik: Derin öğrenme tabanlı haritalama çalışmalarının önündeki en büyük engel, piksel seviyesinde hassas etiketlenmiş büyük veri setlerine duyulan ihtiyaçtır \citep{ma2019deep}. Geleneksel yöntemlerde (ArcGIS vb.) her yeni görüntü için operatörün manuel örnek toplaması ciddi bir zaman maliyetidir.

Bu tezde önerilen Zayıf Denetimli (Weakly Supervised) yaklaşım ve geliştirilen süperpiksel etiketleme arayüzü sayesinde, veri seti oluşturma süreci "piksel boyama" yerine "segment seçme" işlemine indirgenmiştir. Elde edilen sonuçlar, daha az insan müdahalesi ve daha düşük etiketleme maliyetiyle, tam denetimli (fully supervised) yöntemlere yakın doğrulukta haritalar üretilebileceğini kanıtlamıştır.

5. SONUÇLAR VE ÖNERİLER

Bu bölümde, tez çalışması kapsamında tasarlanan derin öğrenme tabanlı FERİHA modelinin sınıflandırma performansı, kentsel gelişim analizlerindeki kullanılabilirliği ve mevcut sınırları bütüncül bir yaklaşımla değerlendirilmiştir. Gerçekleştirilen çalışma ile, Harita Mühendisliği uygulamalarında sıklıkla ihtiyaç duyulan arazi örtüsü değişimlerinin tespitine yönelik, yüksek çözünürlüklü uydu görüntülerinden beslenen yarı-otomatik bir analiz metodolojisi ortaya konmuştur.

5.1. Sonuçlar

Tez kapsamında, Sentinel-2 uydu görüntülerini temel alan ve "Süperpiksel Tabanlı Zayıf Denetimli Öğrenme" yaklaşımını kullanan özgün bir mimari geliştirilmiştir. Elde edilen deneysel bulgular ve karşılaştırmalı analizlerle şu temel sonuçlara ulaşılmıştır:

Geleneksel Yöntemlere Göre Üstünlük: Çalışmada geliştirilen FERİHA modeli, Harita Mühendisliği uygulamalarında yaygın olarak kullanılan piksel tabanlı sınıflandırma yöntemlerine (Örn: Maximum Likelihood) kıyasla belirgin bir başarımla sergilemiştir. Özellikle İstanbul Boğazı Köprüsü örneğinde görüldüğü üzere; SLIC süperpiksel entegrasyonu sayesinde piksel tabanlı yöntemlerin kronik sorunu olan mekânsal tutarsızlıklar (Tuz-Biber etkisi) minimize edilmiş ve nesne bütünlüğü (Object Integrity) korunmuştur.

Coğrafi Genelleştirme Başarısı (Domain Adaptation): Modelin sadece eğitim verisinin toplandığı ılıman iklim kuşağında (Bursa) değil, tamamen farklı spektral karakteristiğe sahip kurak/bozkır iklimindeki Konya ilinde de yüksek doğrulukla çalıştığı kanıtlanmıştır. Bu durum, sistemin renklere ezbere dayalı (overfitting) bir öğrenme gerçekleştirmediğini; doku ve geometrik öznitelikleri de kavrayarak yüksek genelleştirme yeteneğine ulaştığını göstermektedir.

Otomasyon ve Operasyonel Verimlilik: Geleneksel yöntemlerde her yeni görüntü için operatörün manuel olarak saatlerce eğitim verisi (training sample) toplama zorunluluğu, bu çalışmada önerilen Zayıf Denetimli yaklaşım ile ortadan kaldırılmıştır. Tasarlanan "Parçalı Çıkarım Motoru" ve Web Arayüzü sayesinde, ham uydu görüntüsünden nihai değişim raporuna giden süreç tam otomatik hale getirilmiştir.

Kentsel Baskının Nicel Tespiti: Görükle pilot bölgesinde yapılan analizlerde, son 5 yıl içerisinde yapılaşma yoğunluğunun %13.16 oranında arttığı ve bu büyümenin

doğrudan tarım arazileri aleyhine geliştiği somut verilerle ortaya konmuştur. Sistem, şehir plancıları ve yerel yönetimler için karar destek mekanizması oluşturacak nitelikte üretilebilir veriler sağlamıştır.

5.2. Öneriler

Tez çalışması sırasında elde edilen deneyimler ve Antalya/Çanakkale vaka analizlerinde karşılaşılan "spektral karışıklık" (spectral confusion) problemleri doğrultusunda, sistemin geliştirilmesi için aşağıdaki teknik öneriler sunulmaktadır:

Çoklu Sensör Entegrasyonu (Data Fusion): Antalya örneğinde seraların, Çanakkale örneğinde ise hasat edilmiş tarlaların "Bina" ile karıştırılması, optik uydu görüntülerinin fiziksel bir limitidir. Gelecek çalışmalarda, Sentinel-2 optik verilerinin Sentinel-1 (SAR/Radar) verileri ile füzyonunun yapılması önerilmektedir. Radar verilerinin yüzey pürüzlülüğü ve doku bilgisi (backscatter), parlak sera örtülerinin beton yapılardan ayrılmasında kesin çözüm sunacaktır.

Çok Zamanlı (Multi-Temporal) Analiz: Tarımsal alanların mevsimsel döngüsünden kaynaklanan hataları gidermek için modelin tek bir tarihe değil, yılın farklı dönemlerine ait görüntü serilerine (Time-Series) bakarak karar vermesi sağlanmalıdır. Bir alanın yılın sadece belli bir döneminde parlak görünmesi (hasat), onun bina olmadığını en güçlü kanıttır.

Kitle Kaynaklı (Crowdsourced) Veri Zenginleştirme: Modelin "Sera", "Güneş Enerji Santrali" veya "Şantiye Alanı" gibi spesifik sınıfları öğrenebilmesi için eğitim setinin çeşitlendirilmesi gerekmektedir. Bunun için, geliştirilen web arayüzüne "Kullanıcı Geri Bildirimi" modülü eklenerek, hatalı sınıfların kullanıcılar tarafından düzeltilmesi ve bu verilerin sisteme geri beslenmesi (Active Learning) önerilmektedir.

KAYNAKLAR

- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., & Süsstrunk, S. (2012). SLIC Superpixels Compared to State-of-the-Art Superpixel Methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(11), 2274-2282.
<https://doi.org/10.1109/TPAMI.2012.120>
- Anderson, J. R., Hardy, E. E., Roach, J. T., & Witmer, R. E. (1976). *A Land Use and Land Cover Classification System for Use with Remote Sensor Data* (Professional Paper Sy. 964). U.S. Geological Survey.
- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of the literature and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31.
- Bhatta, B. (2010). *Analysis of Urban Growth and Sprawl from Remote Sensing Data*. Springer.
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2-16.
- Chen, G., Zhou, Y., Voogt, J. A., & Stokes, E. C. (2024). Remote sensing of diverse urban environments: From the single city to multiple cities. *Remote Sensing of Environment*, 305, 114108. <https://doi.org/10.1016/j.rse.2024.114108>
- Chuvieco, E. (2020). *Fundamentals of Satellite Remote Sensing: An Environmental Approach* (3rd bs.). CRC Press.
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35-46.
- Copernicus Browser. (t.y.). Copernicus Browser. Geliş tarihi 01 Mayıs 2026, gönderen <https://browser.dataspace.copernicus.eu/>

- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., & others. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 25-36.
- Elachi, C., & van Zyl, J. (2006). *Introduction to the Physics and Techniques of Remote Sensing* (2nd bs.). John Wiley & Sons.
- Eyi, G., Bayram, M. A., & Bugdayci, I. (2025). *Superpixel Sentinel-2 Dataset of Türkiye* [Veri kümesi]. Zenodo. <https://doi.org/10.5281/zenodo.17514638>
- Feriha—A Hugging Face Space by pienrium. (t.y.). Geliş tarihi 01 Mayıs 2026, gönderen <https://huggingface.co/spaces/pienrium/feriha>
- Fisher, P. (1997). The pixel: A snare and a delusion. *International Journal of Remote Sensing*, 18(3), 679-685.
- Goetz, A. F. H., Vane, G., Solomon, J. E., & Rock, B. N. (1985). Imaging spectrometry for earth remote sensing. *Science*, 228(4704), 1147-1153.
- Heffels, M., & Vanschoren, J. (2020). *Aerial Imagery Pixel-level Segmentation*.
- Hu, C. (2022). Sea Snots in the Marmara Sea as Observed From Medium-Resolution Satellites. *IEEE Geoscience and Remote Sensing Letters*, 19, 1-5. <https://doi.org/10.1109/LGRS.2022.3173997>
- Hua, Y., Marcos, D., Mou, L., Zhu, X. X., & Tuia, D. (2022). Semantic Segmentation of Remote Sensing Images with Sparse Annotations. *IEEE Geoscience and Remote Sensing Letters*, 19, 1-5. <https://doi.org/10.1109/LGRS.2021.3051053>
- Jensen, J. R. (2007). *Remote Sensing of the Environment: An Earth Resource Perspective* (2nd bs.). Pearson Prentice Hall.
- Jensen, J. R. (2015). *Introductory Digital Image Processing: A Remote Sensing Perspective* (4th bs.). Pearson.

- Jocea, A. F., Porumb, L., Necula, L., & Raducanu, D. (2025). Sentinel-2 Land Cover Classification: State-of-the-Art Methods and the Reality of Operational Deployment—A Systematic Review. *Sustainability*, 17(22).
<https://doi.org/10.3390/su172210324>
- Kavzoğlu, T., & Çölkesen, \.Ismail. (2010). Karar ağaçları ile uydu görüntülerinin sınıflandırılması ve performans analizi. *Harita Teknolojileri Elektronik Dergisi*, 2(1), 36-49.
- Kingma, D. P., & Ba, J. (2017). *Adam: A Method for Stochastic Optimization* (arXiv:1412.6980). arXiv. <https://doi.org/10.48550/arXiv.1412.6980>
- Kramer, H. J. (2002). *Observation of the Earth and Its Environment: Survey of Missions and Sensors* (4th bs.). Springer.
- Landgrebe, D. A. (2003). *Signal Theory Methods in Multispectral Remote Sensing*. John Wiley & Sons.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Lin, T.-Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2018). *Focal Loss for Dense Object Detection* (arXiv:1708.02002). arXiv.
<https://doi.org/10.48550/arXiv.1708.02002>
- Liu, J., Wu, J., Xie, H., Xiao, D., & Ran, M. (2024). Semantic Segmentation of Urban Remote Sensing Images Based on Deep Learning. *Applied Sciences*, 14(17).
<https://doi.org/10.3390/app14177499>
- Liu, Z., Yuan, L., Weng, L., & Yang, Y. (2017). A High Resolution Optical Satellite Image Dataset for Ship Recognition and Some New Baselines: *Proceedings of the 6th International Conference on Pattern Recognition Applications and Methods*, 324-331. <https://doi.org/10.5220/0006120603240331>

- Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 3431-3440.
- Lu, D., Mausel, P., Brondizio, E., & Moran, E. (2004). Change detection techniques. *International Journal of Remote Sensing*, 25(12), 2365-2401.
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5), 823-870. <https://doi.org/10.1080/01431160600746456>
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, 166-177. <https://doi.org/10.1016/j.isprsjprs.2019.04.015>
- Maktav, D. (2016). *Uzaktan Algılama: Temel Esaslar ve Uygulama Örnekleri*. Nobel Akademik Yayıncılık.
- Maktav, D., & Erbek, F. S. (2005). Analysis of urban growth using multi-temporal satellite data in Istanbul, Turkey. *International Journal of Remote Sensing*, 26(4), 797-810.
- Maktav, D., Siegmund, A., Jürgens, C., Naumann, S., Sunar, F., Eşbah, H., Levent, T. B., Akar, \I, Uysal, C., Kalkan, K., Mercan, Y. O., Wolf, N., & Thunig, H. (2010). *KENTSEL GELİŞİM İÇİN POTANSİYEL ALANLARIN UZAKTAN ALGILAMA VE CBS İLE BELİRLENMESİ VE DEĞERLEMESİ*.
- Mekânsal Çözünürlük Nedir? (2023, Ağustos 22). *Uydu Shop*. <https://uydushop.com.tr/mekansal-cozunurluk-nedir/>

- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247-259.
- Ozgur, E. M. (2009). ANKARA’NIN KENTSEL GELİŞİMİNİN UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİYLE ÖLÇÜLMESİ. *Nature Sciences*, 4(4), Makale 4.
- Phiri, D., Simbizi, M., Salekin, S., Nyirenda, V., Mwansa, Y., Paudel, R., & others. (2020). Sentinel-2 data for land cover/use mapping: A review. *Remote Sensing*, 12(14), 2291.
- Pienrium/Sentinel2-LandCover-Inference. (t.y.). GitHub. Geliş tarihi 01 Mayıs 2026, gönderen <https://github.com/pienrium/Sentinel2-LandCover-Inference>
- Plaza, A., Benediktsson, J. A., Boardman, J. W., Brazile, J., Bruzzone, L., Camps-Valls, G., Chanussot, J., Fauvel, M., Gamba, P., Gualtieri, A., & others. (2009). Recent advances in techniques for hyperspectral image processing. *Remote Sensing of Environment*, 113, S110-S122.
- Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N., & Prabhat. (2019). Deep learning and process understanding for data-driven Earth system science. *Nature*, 566(7743), 195-204.
- Ren, Z., Wang, S., & Zhang, Y. (2023). Weakly supervised machine learning. *CAAI Transactions on Intelligence Technology*, 8, 1-32.
- <https://doi.org/10.1049/cit2.12216>
- Richards, J. A. (2013). *Remote Sensing Digital Image Analysis: An Introduction* (5th bs.). Springer.

- Ridd, M. K. (1995). Exploring a V-I-S (vegetation-impervious surface-soil) model for urban ecosystem analysis through remote sensing: Comparative anatomy of cities. *International Journal of Remote Sensing*, 16(12), 2165-2185.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015*, 234-241.
- Scarpetta, M., Spadavecchia, M., D'Alessandro, V. I., Palma, L. D., & Giaquinto, N. (2022). A new dataset of satellite images for deep learning-based coastline measurement. *2022 IEEE International Conference on Metrology for Extended Reality, Artificial Intelligence and Neural Engineering (MetroXRINE)*, 635-640. <https://doi.org/10.1109/MetroXRINE54828.2022.9967574>
- Schowengerdt, R. A. (2007). *Remote Sensing: Models and Methods for Image Processing* (3rd bs.). Academic Press.
- Seto, K. C., Fragkias, M., Güneralp, B., & Reilly, M. K. (2011). A meta-analysis of global urban land expansion. *PLOS ONE*, 6(8), e23777.
- Singh, A. (1989). Digital change detection techniques using remotely-sensed data. *International Journal of Remote Sensing*, 10(6), 989-1003.
- Small, C. (2001). Estimation of urban vegetation abundance by spectral mixture analysis. *International Journal of Remote Sensing*, 22(7), 1305-1334.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). *Dropout: A Simple Way to Prevent Neural Networks from Overfitting*.
- Thenkabail, P. S., Smith, R. B., & De Pauw, E. (2000). Hyperspectral remote sensing of vegetation and agricultural crops. *Remote Sensing of Environment*, 71(2), 158-182.

- Trabelsi, N., Triki, I., Hentati, I., & Rachdi, N. (2023a). Classification and Spatio-Temporal Change Detection of Land Use/Land Cover Using Remote Sensing and Geographic Information System in the Manouba Region, NE Tunisia. *Journal of Geographic Information System*, 15(6), 652-668.
<https://doi.org/10.4236/jgis.2023.156033>
- Trabelsi, N., Triki, I., Hentati, I., & Rachdi, N. (2023b). Classification and Spatio-Temporal Change Detection of Land Use/Land Cover Using Remote Sensing and Geographic Information System in the Manouba Region, NE Tunisia. *Journal of Geographic Information System*.
<https://doi.org/10.4236/jgis.2023.156033>
- Wang, Z., Wu, W., & Liu, H. (2025). Comparing Soil pH Mapping from Multi-Temporal PlanetScope and Sentinel-2 Data Across Land Use Types. *Remote Sensing*, 17(2), 189. <https://doi.org/10.3390/rs17020189>
- Weng, Q. (2012). *An Introduction to Contemporary Remote Sensing*. McGraw-Hill Education.
- Woodcock, C. E., & Strahler, A. H. (1987). The factor of scale in remote sensing. *Remote Sensing of Environment*, 21(3), 311-332.
- Yuan, F., Sawaya, K. E., Loeffelholz, B. C., & Bauer, M. E. (2005). Land cover classification and change analysis of the Twin Cities (Minnesota) Metropolitan Area by multitemporal Landsat remote sensing. *Remote Sensing of Environment*, 98(2-3), 317-328.
- Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). Learning deep features for discriminative localization. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2921-2929.

Zhou, Z.-H. (2018). A brief introduction to weakly supervised learning. *National Science Review*, 5(1), 44-53.



EKLER

EK-1 FERİHA Model Mimarisi ve Eğitim Kodları

Bu bölümde, tez kapsamında geliştirilen ve PyTorch kütüphanesi kullanılarak oluşturulan CNN modelinin temel mimari kodları sunulmuştur \citep{feriha_github}.

```
# FERİHA Model Mimarisi (Temel Yapı)
import torch.nn as nn

class SegmentClassifierModel(nn.Module):
    def __init__(self, num_classes=7):
        super(SegmentClassifierModel, self).__init__()

        # Oznitelik Cikarici Katmanlar
        self.features = nn.Sequential(
            nn.Conv2d(3, 32, kernel_size=3, padding=1),
            nn.BatchNorm2d(32),
            nn.ReLU(inplace=True),
            nn.MaxPool2d(kernel_size=2, stride=2),
            # ... (diger katmanlar)
        )

        # Siniflandirici
        self.classifier = nn.Sequential(
            nn.Linear(128 * 5 * 5, 256),
            nn.ReLU(inplace=True),
            nn.Dropout(0.5),
            nn.Linear(256, num_classes)
        )

    def forward(self, x):
        x = self.features(x)
        x = x.view(x.size(0), -1)
        x = self.classifier(x)
        return x
```


EK-2 Web Arayüzü Kullanım Kılavuzu

Geliştirilen Streamlit tabanlı otomatik analiz sisteminin (FERİHA) temel kullanım adımları ve arayüz ekranları aşağıda sunulmuştur \citep{feriha_huggingface}:

1. **Giriş ve Görüntü Yükleme:** Kullanıcı, sol panelden analiz modunu (Tek Görüntü veya Değişim Analizi) seçer ve ilgili Sentinel-2 görüntülerini (.tiff formatında) sisteme yükler.




Şekil 1. Uygulama başlangıç ekranı ve veri yükleme paneli

2. **Analiz ve Görsel Karşılaştırma:** Sistem görüntüleri işledikten sonra sonuçları harita üzerinde gösterir. Değişim analizi modunda, iki farklı tarih arasındaki farklar yan yana bir arayüz ile interaktif olarak incelenebilir.



Şekil 2. İki tarih arası değişim analizinin görsel karşılaştırma ekranı

3. **Raporlama ve İstatistikler:** Analiz sonuçları, nicel verilere dökülerek grafikler ve "Yönetici Özeti" formatında sunulur. Aşağıda hem tekil analiz hem de değişim analizi için üretilen rapor örnekleri görülmektedir.



Şekil 3. İki tarih arası değişim analizi için üretilen detaylı yönetici özeti ve tespitler

EK-3 Kullanılan Uydu Görüntüleri Envanteri

Tez çalışmasının eğitim, test ve vaka analizi aşamalarında kullanılan Sentinel-2 uydu görüntülerinin teknik detayları Çizelge E.1'de sunulmuştur. Çalışmada toplamda farklı tarihlere ve bölgelere ait 12 adet Sentinel-2 sahnesi kullanılmıştır.

Çizelge 1. Tez kapsamında kullanılan Sentinel-2 görüntü envanteri

Bölge	Tarih	Kullanım Amacı
Bursa (Genel)	30.07.2015	Model Eğitimi (T_1)
Bursa (Genel)	29.07.2025	Model Eğitimi (T_2)
İstanbul	20.11.2015	Model Testi (Bağımsız Veri)
Bursa (Görükle)	29.07.2020	Vaka Analizi 1 (T_1)
Bursa (Görükle)	30.07.2025	Vaka Analizi 1 (T_2)
Bursa (Gemlik)	30.12.2020	Vaka Analizi 2 (T_1)
Bursa (Gemlik)	19.12.2025	Vaka Analizi 2 (T_2)
Çanakkale	15.08.2020	Genelleştirme Testi (T_1)
Çanakkale	20.08.2025	Genelleştirme Testi (T_2)
Antalya	25.07.2020	Genelleştirme Testi (T_1)
Antalya	30.07.2025	Genelleştirme Testi (T_2)
Konya	10.08.2020	Genelleştirme Testi (T_1)
Konya	15.08.2025	Genelleştirme Testi (T_2)

EK-4 Veri Seti Teknik Dokümantasyonu ve Yapısı

Bu ekte, tez kapsamında oluşturulan ve Zenodo üzerinde yayınlanan "Superpixel Dataset for Sentinel-2 Turkey Classification" veri setinin teknik detayları, klasör yapısı ve kullanım özellikleri sunulmuştur \citep{feriha_dataset_2026}.

Veri Seti Özeti

Veri seti, Türkiye'nin Marmara Bölgesi'nden (Bursa ve İstanbul) alınan Sentinel-2 uydu görüntülerinin SLIC (Basit Doğrusal Yinelemeli Kümeleme) algoritması ile bölütlenmesi ve derin öğrenme modelleri için etiketlenmesiyle oluşturulmuştur.

Coğrafi Kapsam: Bursa (Görükle, Karacabey, Kestel - 2015 & 2025) ve İstanbul (Çeşitli lokasyonlar - 2025). Toplam 23 adet yüksek çözünürlüklü görüntü.

Sınıf Sayısı: 7 Sınıf (Tarla, Su Alanı, Yeşil Alan, Atanamaz, Yol, Çorak Toprak, Bina).

Veri Seti Klasör Yapısı

Veri seti aşağıdaki hiyerarşik dosya yapısına sahiptir:

```
data/
+-- images/          # Uydu görüntüleri (.tif formatında)
|   +-- bursa_1.tif  # Bursa/Görükle 2015
|   +-- bursa_2.tif  # Bursa/Görükle 2025
|   +-- ...          # Diğer görüntüler
|   \-- istanbul_*.tif
+-- labels/          # Yer gerçeği etiketleri (.json formatında)
|   +-- bursa_1.json # bursa_1.tif için segment etiketleri
|   \-- ...
```

Etiketleme Şeması

Veri setinde kullanılan sınıf kodları ve karşılıkları Çizelge E.2'de verilmiştir.

Çizelge 2. Veri Seti Sınıflandırma Şeması

ID	Sınıf Adı (TR)	Açıklama
0	Tarla	Ekili veya hasat edilmiş tarım arazileri
1	Su Alanı	Deniz, göl, baraj ve nehir yüzeyleri
2	Yeşil Alan	Orman, park, makilik alanlar
3	Atanamaz	Görüntü kenar boşlukları veya bozuk pikseller
4	Yol	Otoyol, asfalt ve tali yollar
5	Çorak Toprak	İnşaat sahası, kayalık veya bitkisiz toprak
6	Bina	Konut, sanayi yapıları ve kentsel doku

Kurulum ve Kullanım

Veri setini ve FERİHA modelini kullanmak için gerekli temel Python kütüphaneleri şunlardır:

matplotlib, numpy, osgeo (GDAL), scikit-image, torch, torchvision