



TOBB ETÜ

Ekonomi ve Teknoloji Üniversitesi

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ

Bilgisayar / Yapay Zekâ Mühendisliği

BİL 495 — YAP 495

Project Proposal

Proje Önerisi

Kapsamlı proje teklifi — onaylanmış konu üzerine kurulan dönem sözleşmesi

Proje Adı	Öz-Gözetimli Uydu Görüntü Segmentasyonu ve Zaman Serisi Modelleri ile Uzun Vadeli Kentsel Yayılma Tahmini
Takım Üyeleri	Mehmet Ali USLU Kaan ARSLAN Ömer Talha AKBULUT Mete OKTAR Efe Arda UZUNOVA
Danışman	-
Akademik Dönem	2026 Yaz Dönemi
Teslim Tarihi	21 Haziran 2026

1. Problem Tanımı ve Motivasyon

Bu proje, bir şehrin uzun vadede ne kadar yayılacağını; bu yayılma sırasında yeşil alan ile yapılaşma arasındaki dengenin (yeşil-bina oranının) nasıl değişeceğini, çok-zamanlı uydu görüntüleri üzerinde arazi-örtüsü segmentasyonu kullanarak tahmin etmeyi amaçlar. Girdi olarak bir şehrin tarihsel Sentinel-2 zaman serisi verildiğinde, sistem her zaman adımı için arazi-örtüsü haritaları üretir ve bu haritaların evrimini modelleyerek gelecekteki kompozisyonu öngörür.

Problem. Kentsel yayılmanın ne kadar yayılacağını ve hangi arazi-örtüsü dengesiyle gerçekleşeceğini öngörmek; planlama, yeşil alan koruması ve altyapı yatırımı için kritik fakat zordur. Bu öngörü elle yapıldığında yavaş ve plancı sezgisine bağlıdır; mevcut hazır arazi-örtüsü ürünleri ise yalnızca güncel durumu verir, geleceği tahmin etmez.

Önem ve güncellik. Hızlı kentleşme ve sürdürülebilirlik gündemi yeşil-yapılaşma dengesinin izlenmesini öne çıkarır; Sentinel-2 gibi ücretsiz, 10 m çözünürlüklü, sık tekrarlı verinin erişilebilirliği ve öz-gözetimli öğrenme (SSL) ile temel modellerin yükselişi, veri-yoğun ve etiket-verimli yaklaşımları hem mümkün hem güncel kılar.

Hedef kullanıcı ve etki alanı. Birincil kullanıcılar kent plancıları ve belediyelerin imar/planlama birimleri ve emlak işleri ile ilgilenenlerdir. Sistem, erken aşama fizibilite ve senaryo karşılaştırması için bir karar destek aracı olarak konumlanır.

Mevcut durum ve eksiklikler. Klasik kentsel büyüme modelleri (örn. hücresel otomata) mekanik kurallara dayanır; hazır arazi-örtüsü ürünleri tahmin yapmaz; segmentasyon için etiketli uydu verisi kıttır ve segmentasyon ile zamansal tahminin tek bir uçtan uca hatta birleştirilmesi az çalışılmıştır. Bu proje bu boşluğu, SSL ile güçlendirilmiş segmentasyon ve zaman serisi modellerini (Mamba, TimesFM, LSTM, RNN) birleştirerek doldurmayı hedefler.

2. Önceki Çalışmalar / Literatür

Bu çalışma; uzaktan algılamada arazi-örtüsü segmentasyonu, öz-gözetimli ön-eğitim ve uydu zaman serisiyle kentsel değişim modellemesi literatürünün kesişiminde yer alır. Aşağıda ana referanslar ve bu projeden farkları özetlenmiştir.

Çalışma / Yaklaşım	Ne yapar	Bu projeden farkı
DynamicEarthNet [1]	Günlük çok-spektral veriyle semantik değişim segmentasyonu sunar.	Yalnızca 2 yıllık kapsam; tahmin/öngörü modeli değildir. Biz uzun zamansal tahmine odaklanıyoruz.
SpaceNet 7 [4]	Aylık görüntülerle bina ayak izi takibi yapar.	Bina-düzeyi izleme; süresi kısa, gelecek tahmini yok. Biz arazi-örtüsü kompozisyonunu tahmin ederiz.
GHSL [5]	1975-2030 küresel yapılaşma/yerleşim serisi sağlar.	Ara dönemler interpolasyondur ve yeşil sınıfı yoktur. Biz yeşil-bina oranını doğrudan ele alırız.
Dynamic World [3]	10 m, 9 sınıflı, gerçek-zamana yakın küresel arazi-örtüsü üretir.	Yalnızca güncel durumu üretir, tahmin yapmaz. Biz onu etiket olarak alıp tahmin katmanı ekleriz.
SSL4EO-S12 [2]	Büyük ölçekli, etiketsiz, çok-mevsimli SSL ön-eğitim veri seti.	Tek başına bir görev çözmez. Biz onu segmentasyon omurgamızın ön-eğitimi için kullanıyoruz.

Çalışma / Yaklaşım	Ne yapar	Bu projeden farkı
(U-TAE) [11]	Zamansal dikkat ile uydu görüntü dizilerinde panoptik/semantik segmentasyon yapar.	Kısa diziler üzerinde kare-bazlı segmentasyona odaklanır; gelecekteki kompozisyonu uzun-vadeli tahmin etmez. Biz segmentasyon dizisini ileriye dönük tahmine bağlarız.
Klasik büyüme modelleri (CA/SLEUTH) [12]	Hücrel otomata kurallarıyla kentsel yayılmayı modeller.	Mekanik ve yorum kurallıdır; derin temsil öğrenmez. Biz veri-odaklı öğrenme kullanırız.
Mamba / TimesFM / LSTM [7],[13],[14]	Uzun dizilerde verimli zaman serisi modellerini sağlarlar.	Genel amaçlıdır. Biz onu segmentasyon zaman serisi üzerinde kentsel tahmine uyarlarız.

Ayrışma. Bu projenin özgün yanı; SSL4EO-S12 ile ön-eğitilmiş etiket-verimli bir segmentasyon omurgası, bu omurgayla bir şehrin uydu zaman serisinin otomatik etiketlenmesi ve elde edilen segmentasyon dizisinin Mamba, TimesFM, LSTM veya RNN gibi modellerle modellenerek uzun vadeli yayılma yönü ve yeşil-bina kompozisyonunun tahmin edilmesini tek bir uçtan uca hatta birleştirmesidir.

3. Çözüm Yaklaşımı ve Yöntem

Ana fikir. Çözüm üç aşamalı uçtan uca bir hattır: (1) öz-gözetimli ön-eğitimle güçlendirilmiş mevsimsel segmentasyon, (2) bu segmentasyonla şehir zaman serisinin otomatik etiketlenmesi, (3) Zaman Serisi Modelleri ile zamansal tahmin.

Aşama 1 — Ön-eğitim ve segmentasyon. SSL4EO-S12 üzerinde MoCo/DINO/MAE[8][9][10] gibi bir yöntemle bir görüntü kodlayıcı ön-eğitilir; ardından Dynamic World'ün 9 sınıflı etiketleriyle ince-ayrılarak bir segmentasyon modeline (Multi-Class Certainty Mapped Network - MCCM-Net veya Attention U-Net) dönüştürülür. Sentinel-2 mevsimsel olarak belirgin değiştiğinden her mevsim için ayrı model eğitilir. Hedef: Macro-F1 $\geq$ 85.

Aşama 2 — Otomatik etiketleme. Eğitilen modeller, hedef şehrin Google Earth Engine üzerinden çekilen Sentinel-2 zaman serisine uygulanır; bulut örtüsü dikkate alınarak mümkün olan en yüksek frekansta arazi-örtüsü haritası dizisi üretilir.


Aşama 3 — Zaman Serisi Modelleri ile tahmin. Segmentasyon dizisi bir tahmin modeline (Mamba, TimesFM, LSTM veya RNN) verilir; model mekânsal-zamansal dinamiği öğrenerek gelecekteki arazi-örtüsü dağılımını ve dolayısıyla yayılma yönü/miktarını tahmin eder.

Seçim gerekçesi. SSL ön-eğitimi sınırlı/gürültülü etiketle dahi yüksek başarımlar sağlar. Tahmin modellerine gelince; Mamba, uzun dizilerde doğrusal hesaplama karmaşıklığıyla verimlidir [7]. TimesFM [14], zaman serisi tahmini için güçlü bir temel oluştururken; LSTM ve RNN ise literatürde kendini kanıtlamış olgun mimarilerdir. Segmentasyon tarafında MCCM-Net ve Attention U-Net, detayları daha iyi yakalayabilme yetenekleriyle öne çıkmaktadır.

Teknolojiler. Python; Google Earth Engine (veri); PyTorch; segmentasyon için MCCM-Net / Attention U-Net; ön-eğitim için MoCo/DINO/MAE; zamansal model için Mamba, TimesFM, LSTM veya RNN; rasterio/geopandas (mekânsal işleme); Sentinel-2'nin ~10 yıllık verisinin zaman serisi tahmininde yetersiz kalması ve istenen doğruluğa ulaşılamaması durumunda ise B Planı (yedek veri seti) olarak GHSL ve GISD30[6] kullanılacaktır.

4. Mimari Taslağı

Sistem, soldan sağa akan bir hat olarak tasarlanmıştır. Veri kaynakları ön işlemden geçer; segmentasyon modülü mevsimsel arazi-örtüsü haritaları üretir; etiketleme modülü bu modelleri şehir zaman serisine uygular; Tahmin modülü diziyi modelleyip gelecek tahminini üretir; değerlendirme modülü metrikleri hesaplar. Çıktı, yayılma miktarı ve yeşil/bina oranı tahminleridir.



Şekil 1. Yüksek seviye sistem mimarisi ve veri akışı.

Modüller arası sorumluluk.

- **Veri modülü:** SSL4EO-S12, Dynamic World etiketleri ve Sentinel-2 verisinin çekilmesi, hizalanması, ön-işlenmesi.
- **Segmentasyon modülü:** SSL ön-eğitimi ve mevsimsel segmentasyon modellerinin (MCCM-Net/Attention U-Net) eğitimi/değerlendirilmesi.
- **Etiketleme modülü:** Eğitilmiş modellerin şehir zaman serisine uygulanarak segmentasyon yığınının üretilmesi.
- **Zamansal modül:** Tahmin modellerinin (Mamba, TimesFM, LSTM, RNN vb.) eğitimi ve gelecek tahminlerinin üretilmesi.
- **Değerlendirme/görselleştirme:** Metrik hesabı ve harita/radar çıktıları.

5. Hedef Kullanıcı, Kapsam ve Başarı Kriterleri

Kullanıcılar. Birincil: kent plancıları ve belediye imar birimleri (erken aşama fizibilite ve senaryo karşılaştırması). İkincil: bu alanda çalışan araştırmacılar ve öğrenciler.

Kapsam içi (in-scope).

- Bir veya birkaç hedef şehir için, Sentinel-2 dönemi (≈2015 sonrası) üzerinde çalışma.
- 9 arazi-örtüsü sınıfı temelinde yeşil-bina odaklı segmentasyon.
- Alan bazlı yayılma ve gelecek yeşil-bina oranı tahmini.
- Sonuçların harita ile görselleştirilmesi.

Kapsam dışı (out-of-scope).

- Küresel ölçekte çalıştırma ve bina-düzeyi (tekil yapı) tahmini.
- Sosyoekonomik nedensellik analizi ve nüfus projeksiyon modellemesi.
- Gerçek-zamanlı operasyonel servis ve resmi imar planı yerine geçme iddiası.

Ölçülebilir başarı kriterleri.

Kriter	Ölçüm	Hedef (ayarlanabilir)
Segmentasyon doğruluğu	Test kümesinde Macro-F1	≥ 85
Zamansal tahmin başarımları	"Yapı" sınıfında IoU/F1	Baseline'a göre belirgin iyileşme

Kriter	Ölçüm	Hedef (ayarlanabilir)
Baseline üstünlüğü	"Değişim yok" / "doğrusal devam" ile kıyas	Naif referansları geçmek
Çalışabilirlik	Tek şehir için uçtan uca çalışma	Tek makinede pratik sürede çalışma

6. Çalışma Planı ve İş Bölümü

Plan, 495 ders takvimindeki teslim aşamalarıyla hizalanmıştır. 495 analiz ve tasarım dönemidir; ana uygulama (model eğitimi) 496'da yapılır, bu dönemde yalnızca küçük kavram-doğrulama (PoC) denemeleri yürütülür.

Faz	Tarih	Çıktı
Faz 1 – Spesifikasyon ve gereksinimler	22–28 Haz	Specifications Report (28 Haz)
Faz 2 – Analiz: veri, etiket, segmentasyon ve Zaman Serisi Modeli tasarımı	29 Haz–12 Tem	Analysis Report (12 Tem)
Faz 3 – Kısıt ve etki analizi (veri/hesaplama/fizibilite)	13–31 Tem	PKE-Plan (31 Tem)
Faz 4 – Yüksek seviye tasarım + PoC (küçük segmentasyon denemesi) + web sitesi	1–6 Ağu	High-Level Design + Web Sitesi (6 Ağu)
Faz 5 (496) – Uygulama: SSL ön-eğitim/ince-ayar, segmentasyon, otomatik etiketleme, zaman serisi modelleri	496 dönemi	Çalışan prototip

İş Bölümü (modül bazında).

Üye	Rol & Sorumlu Modül	Ana Görevler
Mehmet Ali Uslu	Proje Koordinasyonu + Veri Modülü	SSL4EO-S12 ve Sentinel-2 / Google Earth Engine veri hattının kurulması, ön-işleme ve hizalama; modüller arası entegrasyon ve genel proje koordinasyonu.
Mete Oktar	Aşama 1 — Segmentasyon	SSL ön-eğitim (MoCo/DINO/MAE) ve 4 mevsim için ayrı segmentasyon modellerinin eğitimi; Macro-F1 $\geq$ 85 hedefinin sağlanması ve değerlendirilmesi.
Ömer Talha Akbulut	Aşama 3 — Zaman Serisi Tahmini	Mamba / TimesFM / LSTM / RNN tabanlı zamansal modellerin tasarımı, eğitimi ve karşılaştırılması; girdi/çıkış formatının ve tahmin ufkunun belirlenmesi.
Kaan Arslan	Aşama 2 — Etiketleme	Eğitilmiş segmentasyon modellerinin şehir Sentinel-2 zaman serisine uygulanması; bulut maskeleyme / kompozit ile otomatik etiketleme hattının kurulması.
Efe Arda Uzunova	Değerlendirme & Çıktı	Metrikler; yayılma miktarı ve yeşil-bina oranı haritaları, radar/gül görselleştirme; proje web sitesi.
Tüm ekip (ortak): Raporlar (Spesifikasyon, Analiz, PKE-Plan, Yüksek Seviye Tasarım), haftalık ekip toplantıları ve Git deposu yönetimi tüm üyelerin ortak sorumluluğundadır.		

7. Riskler ve Önlemler

Risk	Olasılık	Etki	Önlem / B planı
Sentinel-2'nin ~10 yıllık geçmişi uzun-vadeli tahmin için yetersiz kalır	Yüksek	Yüksek	Tahmin ufkunu kısaltmak veya B Planı olarak GHSL (1975+) ve GISD30 (1985+) veri setlerini modele entegre ederek zaman serisi geçmişini geriye dönük genişletmek.
Dynamic World etiketleri gürültülüdür (segmentasyon tavanı)	Yüksek	Orta	Uzman-etiketli alt küme; gürültü-dayanımlı eğitim; F1'i etiket gürültüsüne göre yorumlamak.
Mamba ve TimesFM uzaktan algılamada görece yeni/risklidir	Orta	Orta	Klasik ve kendini kanıtlamış LSTM / RNN modellerine geçiş yapılması.
Bulut örtüsü nedeniyle eksik/gürültülü kareler	Yüksek	Orta	Bulut maskeleyme ve aylık/mevsimsel kompozitler.
SSL ön-eğitimin hesaplama maliyeti yüksek	Orta	Orta	Hazır SSL4EO-S12 ağırlıkları; küçük alt kümeyle eğitim (PoC).
Otomatik etiketlerden Tahmin Modeline hata yayılımı	Orta	Orta	Modelin kendi içindeki eğitim/test setleriyle validasyon yapılması; belirsizlik raporlama.
Kapsam genişlemesi (scope creep)	Orta	Orta	Mahalle/şehir ölçeği ve kapsam dışı listesine bağlı kalma; ek özellikleri 496'ya erteleme.

8. Beklenen Çıktılar

- Çalışan prototip (496): uydu zaman serisinden yayılma ve yeşil-bina oranı tahmini üreten uçtan uca sistem.
- 495 raporları: Proje Önerisi, Spesifikasyon, Analiz, PKE-Plan ve Yüksek Seviye Tasarım raporları.
- Eğitilmiş modeller: mevsimsel segmentasyon ağırlıkları ve zaman serisi tahmin (Mamba/TimesFM/LSTM/RNN) modelleri.
- Sunum ve demo: final sunumu ve sistemin çalışmasını gösteren demo videosu.
- Açık kaynak depo: kod, belge ve kurulum talimatlarını içeren Git deposu.
- Proje web sitesi: projeyi tanıtan ve teslimatları barındıran site (6 Ağu teslimi).

9. Kaynaklar

- [1] A. Toker et al., "DynamicEarthNet: Daily Multi-Spectral Satellite Dataset for Semantic Change Segmentation," in Proc. IEEE/CVF CVPR, 2022.
- [2] Y. Wang, N. A. A. Braham, Z. Xiong, C. Liu, C. M. Albrecht, and X. X. Zhu, "SSL4EO-S12: A Large-Scale Multi-Modal, Multi-Temporal Dataset for Self-Supervised Learning in Earth Observation," IEEE Geosci. Remote Sens. Mag., vol. 11, no. 3, pp. 98-106, 2023.
- [3] C. F. Brown et al., "Dynamic World, Near real-time global 10 m land use land cover mapping," Sci. Data, vol. 9, art. 251, 2022.
- [4] A. Van Etten et al., "The Multi-Temporal Urban Development SpaceNet Dataset," in Proc. IEEE/CVF CVPR, 2021.

- [5] M. Pesaresi et al., "Advances on the Global Human Settlement Layer by joint assessment of Earth Observation and population survey data," *Int. J. Digit. Earth*, vol. 17, no. 1, 2024.
- [6] X. Zhang et al., "GISD30: global 30 m impervious-surface dynamic dataset from 1985 to 2020 using time-series Landsat imagery on the Google Earth Engine platform," *Earth Syst. Sci. Data*, vol. 14, pp. 1831-1856, 2022.
- [7] A. Gu and T. Dao, "Mamba: Linear-Time Sequence Modeling with Selective State Spaces," *arXiv:2312.00752*, 2023.
- [8] K. He, H. Fan, Y. Wu, S. Xie, and R. Girshick, "Momentum Contrast for Unsupervised Visual Representation Learning," in *Proc. IEEE/CVF CVPR*, 2020.
- [9] M. Caron et al., "Emerging Properties in Self-Supervised Vision Transformers," in *Proc. IEEE/CVF ICCV*, 2021.
- [10] K. He, X. Chen, S. Xie, Y. Li, P. Dollar, and R. Girshick, "Masked Autoencoders Are Scalable Vision Learners," in *Proc. IEEE/CVF CVPR*, 2022.
- [11] V. S. F. Garnot and L. Landrieu, "Panoptic Segmentation of Satellite Image Time Series with Convolutional Temporal Attention Networks," in *Proc. IEEE/CVF ICCV*, 2021.
- [12] K. C. Clarke, S. Hoppen, and L. Gaydos, "A self-modifying cellular automaton model of historical urbanization in the San Francisco Bay area," *Environ. Plann. B*, vol. 24, no. 2, pp. 247-261, 1997.
- [13] L. Zhu, B. Liao, Q. Zhang, X. Wang, W. Liu, and X. Wang, "Vision Mamba: Efficient Visual Representation Learning with Bidirectional State Space Model," *arXiv:2401.09417*, 2024.
- [14] Google Research, "A decoder-only foundation model for time-series forecasting" 2024.