

**MİMAR SİNAN GÜZEL SANATLAR ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ**

**UZAKTAN ALGILAMA VE DERİN ÖĞRENME TEKNİKLERİ İLE KENTSEL  
BÜYÜME TAHMİNİ**

**YÜKSEK LİSANS TEZİ**

**Said Abdurrahman KOYUNOĞLU**

**Enformatik Anabilim Dalı**

**Mimari ve Kentsel Enformatik Programı**

**Tez Danışmanı: Doç. Dr. Seher BAŞLIK**

**EYLÜL 2025**



**MİMAR SİNAN GÜZEL SANATLAR ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ**

**UZAKTAN ALGILAMA VE DERİN ÖĞRENME TEKNİKLERİ İLE KENTSEL  
BÜYÜME TAHMİNİ**

**YÜKSEK LİSANS TEZİ**

**Said Abdurrahman KOYUNOĞLU**

**Enformatik Anabilim Dalı**

**Mimari ve Kentsel Enformatik Programı**

**Tez Danışmanı: Doç Dr. Seher BAŞLIK**

**EYLÜL 2025**



Said Abdurrahman Koyunođlu tarafından hazırlanan Uzaktan Algılama Ve Derin Öğrenme Teknikleri İle Kentsel Büyüme Tahmini adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.

.....  
Tez Yöneticisi

Bu çalışma, jürimiz tarafından Mimari ve Kentsel Enformatik Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan: \_\_\_\_\_

Üye : \_\_\_\_\_

Üye : \_\_\_\_\_

Üye : \_\_\_\_\_

Üye : \_\_\_\_\_

Bu tez, Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygundur.



Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel etik kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ücret karşılığı başka kişilere yazdırmadığımı (dikte etme dışında), uygulamalarımı yaptırmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.



*Eşime ve oğluma,*





## UZAKTAN ALGILAMA VE DERİN ÖĞRENME TEKNİKLERİ İLE KENTSEL BÜYÜME TAHMİNİ

### ÖZET

Kentleşmenin hızlanmasıyla birlikte ortaya çıkan karmaşık büyüme süreçlerini anlamak amacıyla bu araştırma, kentsel büyüme modellerinin kuramsal ve yöntemsel evrimini mercek altına almaktadır. 1900’lerde Burgess ve Hoyt’un geliştirdiği geleneksel çerçevelerden başlayarak; 1950–1980 arasında regresyon, yer çekimi, Markov zinciri ve sistem dinamikleri gibi matematiksel/sibernetik tekniklere; 1980–2000 döneminde kaos teorisi, fraktal kentler ve Hücresele Otomat (HO) tabanlı simülasyonlara; 2000’ler sonrasında ise gelişmiş modelleme, hibrit yaklaşımlar ve ileri düzey yapay zekâ algoritmalarını kullanan sistemlere uzanan geniş bir yelpaze sistematik biçimde tartışılmıştır. Bu tarihsel anlatım “yeni paradigmlar” arayışıyla ilişkilendirilerek, yöntemsel çeşitliliğin zorunluluğu ortaya konmuştur.

Çalışmada, kentlerin gelecekteki büyüme dinamiklerini öngörmeye yönelik hesaplamalı bir yöntem önerilmektedir. Literatürde yaygın biçimde kullanılan Hücresele Otamata tabanlı kent gelişim modellerinin kentsel makroformun dinamik yapısını açıklamadaki sınırlılıkları ele alınmış; kentsel dokuyu simüle etmeye yönelik alternatif bir yaklaşım olarak Evrişimsel Sinir Ağı (CNN) temelli bir modelin uygulanabilirliği test edilmiştir.

Model geliştirme ve genellenebilirlik sınamaları için, geniş yüzölçümü ve heterojen arazi özellikleri nedeniyle Konya ili seçilmiştir. Çalışmada kullanılan yöntem, mekânsal istatistik, uzaktan algılama ve makine öğrenmesini birleştirip; geçmiş yıllara ait uydu görüntülerinden türetilen çok katmanlı verilerin zamansal değişimini izleyen

zaman serisi yöntemini kullanır. Veri setleri büyük ölçüde çevrimiçi platformlardan elde edilen raster ve vektör verilerden oluşturulmuştur.

Önerilen hibrit derin öğrenme mimarisi “ConvEncoder > TemporalTransformer > ConvDecoder + CBAM Spatial Attention” akışına dayanmaktadır. Bu yapı, çok kanallı mekânsal temsillerden özellik çıkarımını, uzun dönemli zamansal ilişkilerin modellenmesini ve piksel düzeyinde yapılaşma olasılığı çıkartılmasını gerçekleştirmektedir.

Sonuç olarak tez, kapsamlı bir literatür sentezini derin öğrenme temelli ampirik bir uygulamayla birleştirerek, kentsel büyüme sınırlarının belirlenmesinde veri odaklı, zamansal duyarlılığa sahip ve metodolojik açıdan yenilikçi bir çerçeve önermektedir.

**Anahtar Kelimeler:** Kentsel Büyüme Modelleri, Kentsel Sınır Tahmini, Uzaktan Algılama, Derin Öğrenme, Temporal Transformer, Mekânsal Dikkat.

# **URBAN GROWTH PREDICTION USING REMOTE SENSING AND DEEP LEARNING TECHNIQUES**

## **ABSTRACT**

In order to understand the complex growth processes emerging with the acceleration of urbanization, this research examines the theoretical and methodological evolution of urban growth models. Beginning with the traditional frameworks developed by Burgess and Hoyt in the 1900s; extending to the mathematical/cybernetic techniques of the 1950–1980 period such as regression, gravity, Markov chains, and system dynamics; followed by chaos theory, fractal cities, and Cellular Automata (CA)–based simulations between 1980 and 2000; and finally, advanced modeling, hybrid approaches, and systems employing state-of-the-art artificial intelligence algorithms after the 2000s, a broad spectrum is systematically discussed. This historical narrative is associated with the quest for “new paradigms,” highlighting the necessity of methodological diversity.

The study proposes a computational approach aimed at forecasting the future growth dynamics of cities. It addresses the limitations of CA-based urban development models, which are widely used in the literature but inadequate in explaining the dynamic structure of urban macroform, and tests the applicability of a Convolutional Neural Network (CNN)–based model as an alternative for simulating the urban fabric.

For model development and generalizability tests, Konya province was selected due to its large surface area and heterogeneous land characteristics. The employed method integrates spatial statistics, remote sensing, and machine learning, utilizing a time-series approach to track temporal changes of multi-layered datasets derived from

historical satellite imagery. The datasets were largely constructed from raster and vector data obtained through online platforms.

The proposed hybrid deep learning architecture is based on the flow “ConvEncoder > TemporalTransformer > ConvDecoder + CBAM Spatial Attention.” This structure performs feature extraction from multi-channel spatial representations, models long-range temporal dependencies, and estimates pixel-level probabilities of built-up areas.

In conclusion, the thesis combines a comprehensive synthesis of the literature with a deep learning-based empirical application, proposing a data-driven, temporally sensitive, and methodologically innovative framework for delineating urban growth boundaries.

**Keywords:** Urban Growth Models, Urban Boundary Prediction, Remote Sensing, Deep Learning, Temporal Transformer, Spatial Attention.

## İÇİNDEKİLER

<b>ÖZET</b> .....	<b>xi</b>
<b>ABSTRACT</b> .....	<b>xiii</b>
<b>İÇİNDEKİLER</b> .....	<b>xv</b>
<b>ÇİZELGE LİSTESİ</b> .....	<b>xvii</b>
<b>ŞEKİL LİSTESİ</b> .....	<b>xix</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1 Çalışmanın Amacı .....	3
1.2 Çalışmanın Kapsamı .....	4
1.3 Çalışmanın Yöntemi .....	5
<b>2. KENTSEL BÜYÜME MODELLERİ</b> .....	<b>8</b>
2.1 20. Yüzyılın ilk yarısı: Geleneksel kentsel büyüme modelleri .....	9
2.1.1 Eş merkezli çember modeli (Burgess) .....	9
2.1.2 Sektör modeli (Hoyt) .....	9
2.1.3 Çok çekirdekli model (Harris & Ullman) .....	10
2.2 1950–1980: Matematiksel ve Sibernetik Yaklaşımlar .....	11
2.2.1 Matematiksel/İstatistiksel Modeller .....	11
2.2.2 Markov Zincirleri ve Dinamik Sistem Modelleri .....	12
2.2.3 Sibernetik ve Sistem Teorisi'nin Girişi .....	14
2.3 1980–2000: Karmaşık Sistemler ve Bilgisayar Tabanlı Teknikler .....	14
2.4 2000'ler-Günümüz: Hibrit Model Dönemi .....	16
2.4.1 CLUE Ailesi ve Arazi Dönüşüm Regresyonu .....	17
2.4.2 DINAMICA EGO ve Land Change Modeller .....	17
2.4.3 METRONAMICA ve Belirsizlik Haritaları .....	17
2.4.4 FLUS: Sistem Dinamiği Entegrasyonu .....	18
2.4.5 SLEUTH-GA ve Evrimsel Kalibrasyon .....	18
2.4.6 ABM-CA Hibritleri .....	18
2.4.7 İleri Düzey Yapay Zekâ Algoritmaları .....	19

2.5 Yeni Paradigmalar .....	19
2.6 Literetürde Yer Alan Çalışmalar .....	21
<b>3. KENTSEL BÜYÜME MODELİ.....</b>	<b>31</b>
3.1 Çalışma Alanı .....	32
3.2 Veri Kaynakları .....	35
3.3 Veri Hazırlığı.....	38
3.3.1 Uydu verilerinden indekslerin oluşturulması .....	40
3.3.2 Arazi Kullanım/Örtüsü sınıf azaltma .....	41
3.3.3 Arazi/Yükselik varyansı.....	46
3.3.4 Uzaklık katmanları .....	46
3.3.5 Model girdi katmanları.....	47
3.3.6 Eksik veri işlemleri.....	48
3.3.7 Ölçeklendirme ve yama oluşturma.....	48
3.4 Derin Öğrenme Modeli ve Eğitim.....	49
3.4.1 Model mimarisi .....	49
3.4.2 Model eğitim süreci.....	51
3.5 Model Değerlendirme ve Mekânsal Dikkat .....	52
3.5.1 Modelin değerlendirilmesi .....	52
3.5.2 Mekânsal dikkat analizi.....	60
<b>4. SONUÇ VE DEĞERLENDİRME .....</b>	<b>65</b>
<b>5. KAYNAKLAR.....</b>	<b>69</b>

## ÇİZELGE LİSTESİ

Çizelge 3.1: Yapılaşmış Alan'a dönüşme olasılığına göre ilk 10 arazi sınıfı. ....	43
Çizelge 3.2: Arazi sınıfları ve yeniden sınıflandırma sonucu oluşan sınıflar. ....	44
Çizelge 3.3: Model eğitiminde girdi olarak kullanılan katmanlar. ....	47
Çizelge 3.4: Yapılaşma eşik değerlerinin yorumlanması.....	55
Çizelge 3.5: Girdi Katmanları ile Mekânsal Dikkat arasındaki korelasyon.....	60



## ŞEKİL LİSTESİ

Şekil 1.1: Tez çalışması araştırma yöntemi şematik gösterimi .....	7
Şekil 3.2: Çalışma Alan Konumu .....	33
Şekil 3.3: Konya 1990 (t <sub>0</sub> ), 2010(t <sub>1</sub> ) ve 2020 (t <sub>2</sub> ) yıllarındaki kentsel büyüme sınırları ve büyüme mesafeleri .....	34
Şekil 3.4: 2000 yılından 2020'ye sınıf geçiş matrisi ısı haritası .....	42
Şekil 3.5: Arazi kullanım sınıf azaltma sonucu oluşan yeni sınıf katmanları. ....	45
Şekil 3.6: Modelin test edildiği yamalar: Gerçek (sol) ve Tahmin (sağ).....	53
Şekil 3.7: Sigmoid aktivasyon fonksiyonu çıkış dağılımı. ....	54
Şekil 3.8: Farklı eşik değerlerinde ikili segmentasyon sonuçlarının karşılaştırması.56	
Şekil 3.9: Maske eşik değeri ile tahmin skoru karşılaştırılması. ....	57
Şekil 3.10: Optimum eşik değeri ile 2020 yılına ait tahmin ve gerçek maske. ....	57
Şekil 3.11: Rastgele seçilen 20 yama örneğinin gerçek ve tahmin yapılaşması.....	58
Şekil 3.12: Precision-Recall eğrisi (sol), ROC eğrisi (sağ). ....	59
Şekil 3.13: Ortalama Mekânsal Dikkat (Attention) Haritası. ....	63



## 1. GİRİŞ

Dünya nüfusunun hızla kentleşmesi, kentsel büyüme modellerine olan ihtiyacı her geçen gün artırmaktadır. 2021’de %56,2 olan kentsel nüfus oranının, 2050’ye dek %68’e yükselmesi beklenmektedir. Bu süreçte kentsel nüfusta 2050’ye kadar yaklaşık 2,4 milyar kişilik bir artış yaşanacağı öngörülmüştür. (UN-Habitat, 2022, s. 15).

Kentleşme sürecinin bu denli hızlanması; sanayinin merkezden taşınması, hizmetlere dijital erişimin yaygınlaşması gibi çok sayıda faktörle yayılma süreçleri karmaşıklaşmıştır. Bu bağlamda, kentlerdeki büyüme ve değişim süreçlerini izlemek, etkenlerini analiz etmek ve geleceğe dönük senaryolar geliştirmek, planlama ve kent yönetimi için zorlu ve zorunlu bir uğraş hâline gelmiştir.

Kentsel büyüme modelleri literatüründe, Ernest W. Burgess’in 1920’lerde kaleme aldığı “Chicago Modeli” ilk olarak karşımıza çıkar. Burgess, kentin yalnızca binalar, sokak ve altyapıdan ibaret olmayan; tutumlar, gelenekler ve bireylerin duygularıyla sürekli yeniden şekillenen bir sistem olarak tanımlamıştır. Modern anlamda ilk kentsel büyüme modeli olmasına karşın “Organizma” benzetmesinin (Başlık, 2008) işaret ettiği lineer olmayan ilişkiler, basit korelasyonlarla açıklanamayacak karmaşıklığı vurgular. Dolayısıyla lineer olmayan ilişkileri anlamlandırmak ve tahmin etmek için klasik yöntemlerin dışında yöntemler geliştirilmesi gerekliliği bu çalışmanın yöntem tercihine yön vermiştir.

Günümüzde ise kentsel büyüme modelleri; hücreli otomat tabanlı yöntemlerden yapay zekâ destekli sistemlere kadar geniş bir yelpazeye yayılmıştır. Ancak hâlâ veri eksiklikleri, model ölçeklendirme sorunları ve yöntemsel tekdüzelik gibi kısıtlar, kentsel büyüme süreçlerinin tam anlamıyla kavranmasını güçleştirmektedir. Bu sebeple zaman-serili ve çok kaynaklı veriyi sentezleyebilen ve çıktılarını kent planlamasına girdi verecek yaklaşımlar önemli hale gelmiştir.

Bu çalışmada, Burgess’ten Batty ve Longley’nin fraktal anlatısına, oradan günümüz hücreli otomata ve hibrit modellere alternatif vektörel yöntemlerine uzanan evrimi ele alarak, literatürde baskın hâle gelen Hücreli Otomat (HO) temelli kentsel gelişim

modellerinin; veri çözümlülüğü, parametre bağımlılığı ve ölçeklendirme gibi sınırlılıkları tartışılarak, kentsel makroformun dinamik yapısını daha esnek biçimde temsil edebilecek alternatif bir yöntem önerilmektedir. Bu alternatif, Evrişimsel Sınır Ağı (CNN) tabanlı ve zamansal ilişkileri kavrayabilen hibrit bir derin öğrenme mimarisine dayanmaktadır.

Kentsel büyüme modelleri son yirmi yıldır büyük ölçüde hüresel otomat (HO) tabanlı simülasyonlara dayanmaktadır; oysa uzaktan algılama gibi çeşitli kaynaklardan elde edilen verilerden doğrudan büyüme öğrenip simüle edebilen gelişmiş derin öğrenme (DL) modellerinin bu alanda yeterince kullanılmadığı görülmektedir. Buna karşın, Transformer mimarileri ve hibrit CNN gibi modern derin öğrenme yaklaşımları Arazi Kullanım/Örtüsü (LULC) değişim tahminleri ve uzaktan algılama verileriyle yapılan meteorolojik tahminlerde yoğun olarak kullanılmaktadır. Bu tezde benimsenen yöntemde, kentsel büyüme ve LULC değişim probleminin kentsel alan tahmininde ortak bir uğraşı paylaştığını savunarak, önceden tanımlı HO kurallarına başvurmadan bir DL mimarisi ile çözmeyi hedefleyen özgün bir yaklaşım sunmaktadır.

Araştırma kapsamında kentsel büyüme tahmini için çok katmanlı uzaktan algılama verileri mekânsal yapay zekâ algoritmaları kullanılarak modellenmiştir. Çalışma alanı olarak, geniş yüzölçümü, heterojen arazi yapısı ve hızlı büyüme dinamikleri nedeniyle Konya kenti seçilmiştir. Çeşitli yıllara ait uydu görüntülerinden türetilen NDVI, NDBI, NDWI gibi dizinler ve gece ışıkları, yapılaşma yoğunluğu gibi veri katmanları “dinamik”; eğim, bakı ve yol/merkez uzaklığı gibi bileşenler ise “statik” girdiler olarak kullanılmıştır. Veriler çevrimiçi platformlardan elde edilmiş, eksik değerlerin giderilmesi, minimum-maksimum normalizasyonu uygulanmıştır. Ayrıca 30 metre çözümlülüğe sahip 32×32 piksel boyutlarında yama (patch) model eğitimi için tutarlı bir veri kümesi oluşturulmuştur.

Önerilen yaklaşım, karmaşık (lineer olmayan) etkileşimleri modern derin öğrenme algoritmaları ile yakalamayı hedefler: CNN tabanlı mekânsal özellik çıkarımını, zamansal bağımlılıkları yakalayan bir TemporalTransformer bileşenini ve CBAM tabanlı mekânsal dikkat (attention) modülüyle hibrit bir mimari sunulmuştur. Bu yapı sayesinde;

- çok kanallı mekânsal emsillerden etkin özellik çıkarımı yapılmakta,

- yıllar arası uzun dönemli ilişkiler TemporalTransformer bileşeniyle yakalanmakta,
- CBAM tabanlı mekânsal dikkat modülü ile yerel örüntüler güçlendirilmekte ve
- son aşamada çıktı ikili segmentasyon maskesine dönüştürülerek kentsel gelişim alanı tahmin edilmektedir.

Modelin başarımı doğruluk, Intersection over Union (IoU) ve F1 skoru gibi metriklerle değerlendirilmiştir. Veri kümesi eğitim/doğrulama/test için sırasıyla %80/%10/%10 oranlarında ayrılmış ve yaklaşık binin üzerinde bağımsız yama üzerinde test edilmiştir. Böylece hem aşırı uyum (overfitting) riski azaltılmış hem de modelin genellenabilirliği sağlanmıştır.

Sonuç olarak bu çalışma, kapsamlı bir literatür sentezini derin öğrenme temelli bir uygulama ile birleştirerek, kentsel büyümenin tahmin edilmesine yönelik veri odaklı, zamansal duyarlılığa sahip ve yöntemsel açıdan yenilikçi bir çerçeve ortaya koymaktadır. Tez, bu bağlamda yalnızca bir model önerisi sunmakla kalmayıp, kentsel büyüme modellemesine ilişkin yöntemsel çeşitliliğin artırılmasına katkıda bulunmayı hedeflemektedir. Çalışmanın geri kalanında sırasıyla: kentsel büyüme kuramsal incelemesi, modele girdi olacak veriler, bu verilerin ön-işleme aşaması, model mimarisi ve tasarımı, model değerlendirme ve mekânsal dikkat ile yorumlanması ile sonuç ve değerlendirme yer almaktadır.

## 1.1 Çalışmanın Amacı

Bu çalışmanın temel amacı, kentsel büyüme modellemesinde yaygın bir araç olan Hücresel Otomat (HO) yaklaşımlarının ötesine geçebilecek, derin öğrenme (DL) tabanlı alternatif bir modelleme hattı önermek ve bu modelin performansını değerlendirmektir. HO yöntemlerinin ölçek, parametre bağımlılığı ve kural karmaşıklığı gibi bilinen sınırlılıkları, daha esnek ve veri odaklı çerçevelere olan ihtiyacı ortaya koymaktadır.

Bu ihtiyaçtan hareketle, bu çalışma, özellikle son yıllarda LULC ve meteorolojik tahmin alanlarında başarıyla uygulanan ileri düzey derin öğrenme algoritmalarının kentsel büyüme problemine neden henüz sistematik bir şekilde uyarlanmadığı sorusundan yola çıkmaktadır. Kentsel büyüme tahmini ile arazi örtüsü değişim tahmininin ortak dinamiklere sahip olduğu iddiasıyla, bu alanlardaki başarılı

mimarileri kentsel büyüme tahmini için uyarlamak çalışmanın özgün çıkış noktasını oluşturmaktadır.

Bu doğrultuda, Evrişimli Sinir Ağları (CNN), Transformer ve mekânsal dikkat (CBAM) mekanizmalarını bütünleşik olarak kullanan bir mimari tasarlanmıştır. Çalışmanın nihai hedefi, yalnızca yüksek doğruluk değerlerine ulaşmak değil, aynı zamanda kentsel makroformun karmaşık yapısını veriden doğrudan öğrenebilen, yorumlanabilir çıktılar üretebilen ve planlama pratiğine katkı sunacak veri temelli bir çerçeve sunmaktır.

## 1.2 Çalışmanın Kapsamı

Çalışmanın kapsamı, kuramsal inceleme ile ampirik uygulamayı birbirine bağlayan bütünleşik bir çerçeve olarak kurgulanmıştır. İlk olarak, 2. bölümde kentsel büyüme modellerinin tarihsel ve yönetsel evrimi ayrıntılı biçimde ele alınır: Burgess ve Hoyt'un klasik halkasal/ sektörel modellerinden başlayarak, 1950–1980 arasında ortaya çıkan regresyon temelli, yer çekimi modelleri, Markov zincirleri ve sistem dinamikleri gibi matematiksel/sibernetik yaklaşımlar; 1980–2000 döneminde kaos ve fraktal kuramlarıyla beslenen Hücresel Otomat tabanlı simülasyonlar; 2000 sonrası hibrit ve yapay zekâ destekli modellere kadar uzanan geniş bir literatür dizisi, yönetsel boşluklar ve eleştirilerle birlikte tartışılır. Böylece çalışmanın teorik arka planı ve “neden yeni bir yaklaşım gerekli?” sorusunun yanıtı ortaya konur.

İkinci olarak, 3. bölümde uygulamanın kapsamı belirlenir. Konya kenti, heterojen arazi yapısı ve son yıllardaki hızlı mekânsal büyümesi nedeniyle örnek alan olarak seçilmiştir. Bu seçim, modelin farklı morfolojik özellikler karşısındaki dayanıklılığını test etmeyi mümkün kılar. Veri seti; uydu görüntülerinden türetilen indeksler (NDVI, NDBI, NDWI vb.), gece ışıkları ve yapılaşma yoğunluğu gibi dinamik katmanlar ile eğim, bakı, yol/merkez uzaklığı gibi statik katmanları içerir. Veriler çevrimiçi platformlardan toplanmış, eksik değer giderme, minimum–maksimum normalizasyonu ve 32×32 piksel yamalarla örnekleme gibi ön işlemlerden geçirilmiştir.

Üçüncü bileşen, model tasarımına ve eğitim sürecine ilişkindir. ConvEncoder → TemporalTransformer → ConvDecoder ardışıklığına eklenen CBAM mekânsal dikkat modülü ile hem mekânsal hem zamansal örüntüler yakalanır. Eğitim/doğrulama/test

ayrımı, erken durdurma stratejileri ve hiperparametre ayarları kapsam dâhilindedir. Model çıktıları ikili segmentasyon maskeleri biçiminde üretilerek kentsel büyüme alanları tahmin edilir.

Dördüncü olarak, performans değerlendirmesi ve tartışma süreci kapsamın önemli bir parçasıdır. Doğruluk, IoU, F1 gibi metriklerin yanı sıra görsel yorumlama, hata haritaları ve duyarlılık analizleri yapılır; sonuçlar literatürdeki diğer yaklaşımlarla karşılaştırılarak güçlü ve zayıf yönler tartışılır. Kapsam dışı bırakılan konular (örneğin sosyo-ekonomik politika senaryolarının ayrıntılı simülasyonu) da bu bölümde gerekçelendirilir.

Son aşamada, elde edilen bulgular ışığında yöntemsel öneriler, gelecekteki araştırma gündemi ve planlama pratiğine yönelik çıkarımlar ortaya konur. Böylece çalışma, kuramsal bir sentez ile uygulamalı bir test alanını kapsayan bütüncül bir yapı içinde tamamlanır.

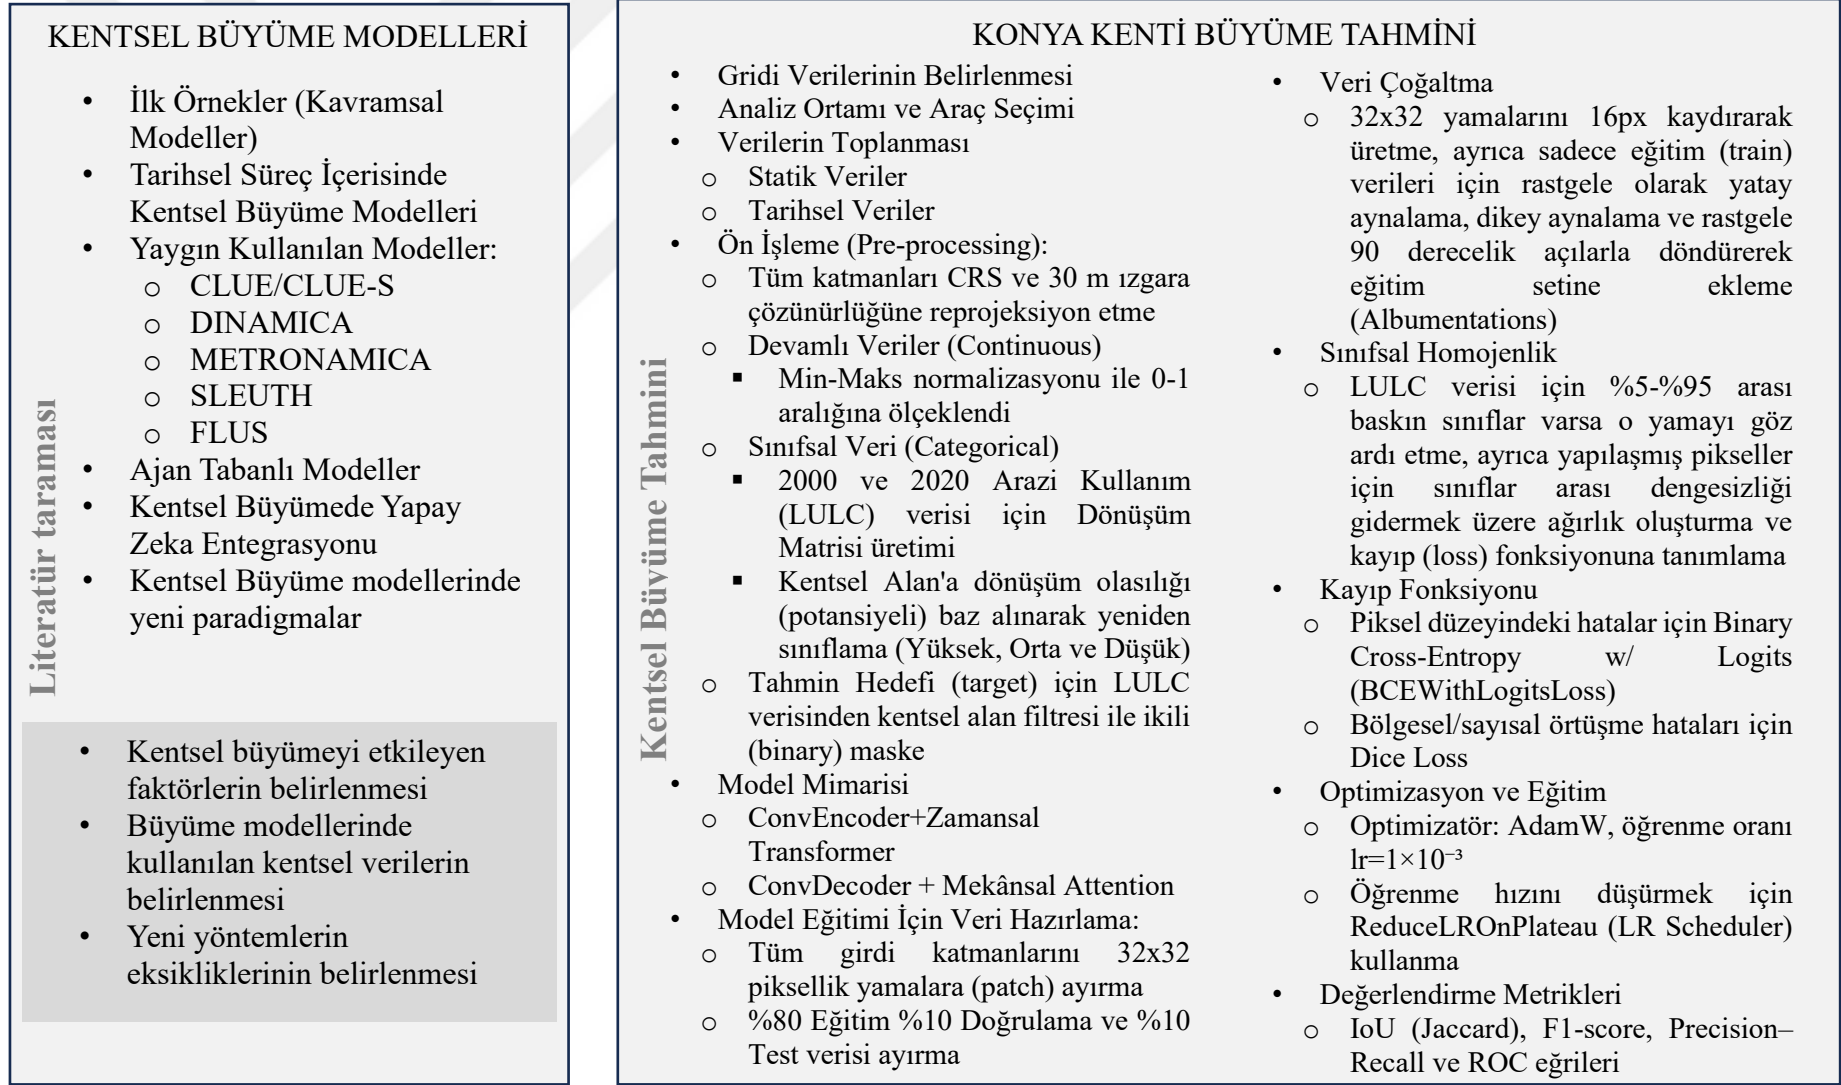
### 1.3 Çalışmanın Yöntemi

Çalışmada kullanılan yöntem aşağıdaki adımlardan oluşmaktadır:

1. **Literatür İncelemesi:** Kentsel büyüme modellerinin kuramsal temelleri dönemsel bakış açısıyla incelenir; yöntemsel boşluklar belirlenir.
2. **Veri Toplama ve Ön İşleme:**
  - Çevrimiçi platformlardan raster ve vektör veriler temin edilir.
  - Eksik/veri hatalarının giderilmesi, minimum–maksimum normalizasyonu ve 32×32 piksel yamalarla örnekleme yapılır.
3. **Model Mimarisinin Kurulması:**
  - Evrimsel katmanlarla mekânsal özellik çıkarımı,
  - Temporal Transformer ile uzun dönemli zamansal bağıntıların yakalanması,
  - CBAM mekânsal dikkat modülüyle yerel örüntülerin vurgulanması,
  - Çıktının ikili segmentasyon maskesine dönüştürülmesi aşamaları gerçekleştirilir.

4. **Eđitim ve Dođrulama:** Veri seti %80 eđitim, %10 dođrulama, %10 test olarak ayrılır; erken durdurma ve en iyi ađırlık seęimi stratejileri kullanılır.
5. **Performans Deđerlendirmesi:** eřitli metriklerle bařarı lölür, grsel/istatistiksel analizlerle modelin glü ve zayıf ynleri tartıřılır.
6. **Sonu ve Deđerlendirme:** Bulgular literatürle iliřkilendirilir; nerilen yaklařımın katkıları, sınırlılıkları ve geleceęe dnük geliřtirme nerileri ortaya konur.





Şekil 1.1: Tez çalışması araştırma yöntemi şematik gösterimi

## 2. KENTSEL BÜYÜME MODELLERİ

Bu bölümde, kentlerin mekânsal yayılımını açıklamaya yönelik teorik ve nicel modellerin tarihsel evrimi incelenmiştir. Kent planlama literatüründe, 20. yüzyılın ilk yarısında geliştirilen Eş Merkezli Çember Modeli (Burgess), Sektör Modeli (Hoyt) ve Çok Çekirdekli Model (Harris & Ullman) gibi geleneksel yaklaşımlar kentsel formun temel yapı taşlarını oluşturur. Bu modeller, tek merkezli yayılım, ulaşım koridorlarına bağlı sektörel genişleme veya fonksiyonel ihtiyaçlara göre birden çok çekirdeğin ortaya çıkışı gibi farklı mekânsal dinamikleri tanımlar.

1950–1980 döneminde, bilgisayar kapasitelerinin artışı ve operasyonel araştırma tekniklerinin yaygınlaşmasıyla kent dinamikleri deterministik ve istatistiksel çerçevelerle ele alınmaya başlanmıştır. Bu dönemin öne çıkan yöntemleri arasında regresyon analizi, yer çekimi (gravity) modelleri, Markov zincirleri ve sistem dinamikleri yer alır. Özellikle Coğrafi Bilgi Sistemleri'nin (CBS) prototiplerinin geliştirilmesi, model kalibrasyonlarında piksel/hücre tabanlı Hücresel Otomata (HO) ve Monte Carlo (MC) temelli yaklaşımların kullanılmasına imkân tanımıştır.

1980–2000 arası, kentlerin “karmaşık adaptif sistemler” olarak görülmesine zemin hazırlayan kaos teorisi, fraktal şehirler ve bu kapsamda simülasyon için kullanılan HO modelleri ile bağlantılı olarak gelişmiştir. Bu dönemde, mikro-ölçekli geri beslemeler ve çok ölçekli etkileşimler simülasyon ortamına taşınarak -görece- gerçekçi kent formu ve yayılım senaryoları üretilmiştir.

2000 sonrasında ise 19. yüzyılın istatistiksel modellerinden makine öğrenmesine, oradan da derin öğrenme ve hibrit ABM-CA (Ajan Tabanlı Model + Hücresel Otomata) yaklaşımlarına geçiş yaşanmıştır. CLUE, METRONAMICA, SLEUTH-GA ve güncel CNN/LSTM/GAN tabanlı simülasyon çerçeveleri, kentsel büyüme süreçlerini hem mekânsal hem de zamansal belirsizlikleri dikkate alarak yüksek doğrulukla modellemek için kullanılmıştır.

## **2.1 20. Yüzyılın ilk yarısı: Geleneksel kentsel büyüme modelleri**

Bu başlık altında 20. Yüzyılın ilk yarısına ait kavramsal planlama yaklaşımları ve temel terminolojiyi ele alacağız. Aşağıda, kentsel büyüme literatüründe planlama paradigması çerçevesinde öne çıkan teoriler ve modeller incelenmektedir.

### **2.1.1 Eş merkezli çember modeli (Burgess)**

Kentlerin biçimlenişi ve büyüme dinamiklerine dair temel çerçeve, Burgess'in 1920'deki Chicago incelemesinde şekillendi. Bu yaklaşımda, kentlerin düz bir alana kurulduğu, coğrafi engellerin hesaba katılmadığı kabul edilir. Ayrıca, yerleşimin tek bir çekirdek bölge etrafında örgütlendiği, her yerden bu merkeze erişimin kolay olduğu ve mekansal ilişkilerde tam rekabet koşullarının geçerli olduğu varsayılır. Yerleşim, geometrik düzlemdeki ana ticari bölgeden başlayıp dışa doğru açılan eş merkezli kuşaklardan meydana gelir. Çekirdek bölge; ekonomik, kültürel ve yönetsel faaliyetlerin kesiştiği, tüm grupların ulaşmak istediği bir odak noktasıdır.

Yerleşimin dış kesimlerinde, bilhassa merkeze yakın olan ara bölgede gecekonduların yoğunluğu artan farklı katmanlar sıralanır. Büyüme süreci, suya düşen bir taşın oluşturduğu halkalara benzetilir: içteki kuşak genişleyerek dışa doğru ilerler ve onun dışındaki katmanın konumunu alır. Bu sürekli yer değiştirme durumu, kente yönelik yoğun göç hareketiyle beslenir. Burgess, kentsel büyümenin sadece fiziksel yayılım ve ekonomik faaliyet alanlarının genişlemesiyle açıklanamayacağını; toplumsal yapıdaki evrimlerin de bu gelişmenin ayrılmaz bir bileşeni olduğunu öne sürer.

Bu bakış açısına göre, nüfus yapısındaki değişimler; yeni gelenlerin konut seçimleri, iş eğilimleri ve kent içindeki toplumsal-ekonomik gruplar arasındaki kademelenme, yerleşimde devamlı bir çeşitlenme ve yeni düzenlemeler doğurur. Bu sayıda kentsel gelişim, toplumsal organizasyonun dinamik bir izdüşümü halini alır.

### **2.1.2 Sektör modeli (Hoyt)**

Kentsel büyümeye dair önemli modellerden biri, ekonomist Homer Hoyt (1939) tarafından Burgess'in konsantrik bölge modelinin sınırlılıklarını aşmak amacıyla geliştirilmiştir. Hoyt'un modeli, kentsel gelişimin sektörler halinde ve ulaşım koridorlarına bağlı olarak şekillendiğini öne sürmektedir. Burgess'in aksine, Hoyt'un varsayımlarında topografya ve ulaşım ağları önemli rol oynamaktadır. Model, kent merkezinden dışa doğru yayılan ancak belirli yönlerde uzanan sektörlerin, sosyo-

ekonomik grupların mekânsal dağılımını belirlediğini savunur. Örneğin, sanayi alanları demiryolu veya nehir kenarlarında şeritler halinde uzanırken, yüksek gelirlili konut alanları temiz hava ve yeşil alan imkânı sunan bölgelere (örneğin yamaçlar veya ana caddeler boyunca) doğru genişler. Her sektör, başlangıçta olduğu yönde büyümeye devam eder ve zaman içinde aynı sosyo-ekonomik özellikleri korur. Bu durum, kent içinde homojen ancak birbirinden keskin çizgilerle ayrılmış alanlar yaratır. Hoyt, kentsel büyümenin sadece merkezden dışa değil, aynı zamanda çekim alanlarına (örneğin limanlar, ticaret merkezleri) bağlı olarak kama şeklinde ilerlediğini vurgular. Modelin dinamik yapısı, ulaşım teknolojisindeki gelişmelerin (tramvay, otoyol) ve arazi rantının sektörel dağılımı nasıl etkilediğini açıklamaktadır. Burgess'ten farklı olarak, sosyal statü ve ekonomik gücün mekânsal ayrışmada belirleyici olduğunu öne sürer.

### **2.1.3 Çok çekirdekli model (Harris & Ullman)**

Harris ve Ullman (1945) tarafından ortaya konan bu model, kentlerin tek bir merkez yerine birbirinden bağımsız çok sayıda çekirdek etrafında geliştiğini savunur. Model, özellikle sanayileşme sonrası dönemde büyüyen metropollerini (örneğin Los Angeles) açıklamak üzere tasarlanmıştır. Temel varsayımına göre, kentsel fonksiyonların dağılımını dört faktörle şekillenir: (1) bazı faaliyetlerin özelleşmiş altyapı gereksinimleri (limanların su kenarında olması), (2) benzer faaliyetlerin bir arada gruplanma eğilimi (finans kurumlarının merkezî iş alanında yoğunlaşması), (3) birbirine zarar veren faaliyetlerin ayrışması (sanayi ve konut alanlarının uzaklaştırılması), (4) yüksek kirali alanlara erişemeyen faaliyetlerin çevreye yayılması. Bu faktörler, kent içinde üniversite kampüsleri, havalimanı çevresindeki lojistik merkezler veya alışveriş kompleksleri gibi özerk çekirdeklerin oluşumunu tetikler.

Her çekirdek, kendi etki alanında konut, ticaret ve sosyal donatıları barındırarak kentin mozaik benzeri bir yapıya bürünmesine neden olur. Model, Burgess ve Hoyt'un aksine kentleri statik bir merkez-periferi ilişkisi yerine esnek ve parçalı bir sistem olarak ele alır. Örneğin, bir kentteki yeni bir teknoloji parkının, çevresinde yeni konut alanları ve hizmet sektörünü çekerek ikincil bir merkez yaratması bu modele tipik bir örnektir. Harris & Ullman, kentsel büyümenin doğrusal veya dairesel değil, işlevsel ihtiyaçlara göre şekillendiğini ve bu süreçte ulaşım ağlarının çoklu çekirdekleri birbirine bağladığını vurgular

Eş Merkezli Bölgeleme Teorisi Modeli, Merkez Alan Teorisi Modeli, Sektör Alan Teorisi Modeli gibi yukarıda bahsedilen modeller ilk kentsel büyüme modelleri olarak kabul edilmektedir. İlk kentsel büyüme modellerinden sonra 1940'lı yıllarda kentsel modellerin matematiksel formüllerle ifade edildiği ileriye yönelik kestirim çalışmaları başlamıştır.

## **2.2 1950–1980: Matematiksel ve Sibernetik Yaklaşımlar**

Kavramsal planlama yaklaşımları, kentsel büyüme modellerinin teorik temelini oluştururken; bu başlık altında ise kentsel sistemlerin akılcı planlama ve bilimsel yönetim prensipleri doğrultusunda ele alınmasına yönelik yeni yaklaşım benimsenen bir dönemi inceleyeceğiz.

Soğuk Savaş döneminin teknolojik ilerlemeleri, bilgisayar kapasitelerinin artması ve operasyonel araştırma tekniklerinin yaygınlaşması, kentsel dinamiklerin deterministik ve niceliksel yaklaşımlarla ele alınmasını teşvik etmiştir. Kentlerin klasik “kapalı sistem” analizlerinin ötesine geçen mekânsal istatistik, lineer regresyon ve sistem dinamiği teknikleri, çoklu etkileşimlerin sayısal modellerle tanımlanmasında tercih edilmiştir. 1960'larda Coğrafi Bilgi Sistemleri (CBS) teknolojisinin ilk prototiplerinin (ör. ESRI'nin ArcInfo'yu temel alan çalışmaları) ortaya çıkışı, mekânsal veri tabanlarının oluşturulmasına ve grid tabanlı modellemelere olanak tanımıştır. Mühendislik alanından ödünç alınan yöntemlerle dönüşen şehir planlamasında, sibernetiğin “geri besleme” kavramı, kentsel büyüme süreçlerinin çok boyutlu doğasını açıklamada merkezi bir işlev üstlenmiştir.

Bu dönemde geliştirilen matematiksel yöntemler, günümüzün yapay zekâ odaklı simülasyonlarının dayanak noktası haline gelmiştir. Özellikle sistem dinamikleri, karmaşık adaptif sistemler (CAS) teorisiyle evrilerek kentsel dirençlilik çalışmalarında hâlen kullanılmaktadır.

### **2.2.1 Matematiksel/İstatistiksel Modeller**

Önceki başlıkta anılan kavramsal planlama yaklaşımları, kentsel büyüme modellerinin teorik temelini oluştururken; bu başlık altında ise geleneksel kuramsal modellerin pratik uygulamalarını ve sınırlamalarını inceleyeceğiz. Aşağıda, kentsel büyüme literatüründe erken planlama kuramları ve kapsamı ele alınmaktadır.

## **Regresyon Analizi**

Kentsel büyümenin doğrusal ilişkilerle açıklanabileceği varsayımına dayanan bu modeller, özellikle Chicago Ekolü'nün sosyo-mekânsal hiyerarşi teorileriyle uyumlu bir şekilde kullanılmıştır. Mesela Jan Gehl'in insan ölçeğindeki kentsel araştırmalarında, yayaların erişim olanakları ile ticari merkezi yoğunluk arasındaki ilişki, çok değişkenli regresyon yöntemleriyle çözümlenmiştir. Bağımsız değişkenler arasında altyapı yatırımları (örn. metro hatları) ve istihdam merkezlerinin konumu, bağımlı değişken olarak ise arazi fiyatlarındaki artış sıklıkla analiz edilmiştir. Yine de heteroskedastisite ve multikolineerlik problemleri, 1970'lerde logit ve probit gibi doğrusal olmayan regresyon yaklaşımlarının ön plana çıkmasına neden olmuştur (... , 1975).

## **Yer Çekimi (Gravity) Modeli**

Yer çekimi (gravitasyon) modelleri de 1950–1980 döneminin matematiksel/istatistiksel modelleri arasında önemli bir yere sahiptir; Newton'un kütleçekim yasasından ilham alan bu yaklaşım, iki yerleşim birimi arasındaki etkileşimi, nüfus veya ekonomik hacim gibi “kütle” değerlerinin çarpımı ile aralarındaki mesafenin belirli bir üssüyle ters orantılı olarak tanımlar.

Walter Isard'ın bölgesel iş gücü hareketliliği modellerinden John Q. Stewart'ın demografik kütle kavramıyla hava trafiği analizlerine kadar pek çok uygulamada kullanılan yer çekimi modelleri, kentlerarası akışların niceliksel çözümlemesini mümkün kılarak matematiksel/istatistiksel çerçeveyi zenginleştirmiştir.

### **2.2.2 Markov Zincirleri ve Dinamik Sistem Modelleri**

Bu başlık altında; Markov Zincirleri ve Sistem Dinamik Modelleri gibi nicel modelleme yaklaşımları kavramsal düzeyde incelenmiştir. Aşağıda, bu iki yöntemin kentsel büyüme literatüründeki temelleri ve sağladıkları bakış açıları ele alınmaktadır.

#### **Markov Zincirleri**

Markov Zincirleri, arazi kullanım sınıfları arasındaki değişim olasılıklarını geçmiş gözlemlerden elde edilen frekanslara dayandırarak tahmin eden bellekten bağımsız bir yaklaşımdır. Modelin temel vurguları şunlardır:

Durum Tanımı: Arazi sınıfları (ör. konut, tarım, orman) birbirini izleyen dönemler için ayrı durumlara ele alınır.

Bellekten Bağımsızlık: Bir sonraki dönem olasılıkları sadece mevcut durumdan etkilenir; önceki aşamaların detaylı geçmişine ihtiyaç duyulmaz.

Olasılık Tabloları: Geçiş olasılıkları, belirli bir dönem içindeki sınıf değişim sıklıklarına dayalı olarak oluşturulur.

Projeksiyon Kapasitesi: Mevcut durum ve olasılık tabloları temel alınarak, bir veya birden çok dönem sonrası arazi kullanım dağılımı kavramsal olarak öngörülür.

1980'lerde, CBS'den elde edilen arazi sınıflandırma verileriyle oluşturulan geçiş olasılıkları, Minneapolis–St. Paul bölgesindeki kentsel yayılımı yüksek doğrulukla (%78) tahmin etmiştir (... , 1982).

Sonraki dönemlerde, Mekânsal komşuluğu dikkate almak amacıyla, Hücresel Otomat (CA) çerçevesiyle birleştirilen Markov–CA modelleri geliştirilmiştir (ör. SLEUTH) (Clarke ve diğ., 1997).

### **Sistem Dinamik Modelleri**

Sistem Dinamik (SD) Modelleri, kentsel sistemleri stok ve akış kavramlarıyla modelleyerek geri besleme döngülerinin uzun dönemli etkilerini analiz eder. İlkeleri şunlardır:

Stok ve Akış Ayrımı: Kentsel alan gibi birikimli büyüklükler (stok), bunları değiştiren süreçler (akış) ile anlatılır.

Geri Besleme Döngüleri: Politika kararları, altyapı yatırımları ve sosyo-ekonomik etkenler arasında pozitif ve negatif döngüler kurularak sistem davranışı keşfedilir.

Senaryo Analizi: Farklı karar ve yatırım senaryolarının uzun vadeli sonuçları kavramsal olarak simüle edilir.

Urban Dynamics (1969): Forrester, düşük gelirli konut politikalarının beklenmedik gettolaşma etkilerini ortaya koyarak şehir planlamasında geri besleme önemini vurgulamıştır (Forrester, 1969).

### **2.2.3 Sibermetik ve Sistem Teorisi'nin Giriş**

Bir önceki başlıkta ele alınan Markov ve SD yöntemleri, sistemin dönüşümlerini belli sınırlar ve olasılıklar içinde ele alırken; bu başlık altında kentleri bir bütün olarak kavrayan genel sistem ve sibermetik teorilere bakacağız. Aşağıda, kentsel büyüme literatüründe Sibermetik ve Genel Sistem Teorisi yaklaşımlarının temel ve sağladıkları bakış açıları ele alınmaktadır.

#### **Von Bertalanffy'nin Genel Sistem Teorisi**

Bertalanffy, kentleri çevreleriyle sürekli enerji ve materyal takası gerçekleştiren ve entropiye direnç gösteren açık sistemler olarak tanımlamıştır. Bu teori, Kevin Lynch'in kent imgeleri çalışmalarında, kentsel algının bilişsel haritalama ile nasıl şekillendiğini açıklamak için kullanılmıştır (Bertalanffy, 1960).

#### **Alonso'nun Ekonomik Teori Modeli**

Alonso, arazinin merkezden uzaklaştıkça değerinin düşüşünü matematiksel olarak formüle ederek, arazi kullanım tercihlerini mikroekonomik denge prensipleriyle açıklamıştır. Modelde, bir ticari işletmenin merkeze olan uzaklık ile ödemeye razı olduğu rant arasındaki ilişkiyi formüle etmiştir. Bu formülde taşıma giderlerinin fiyatlandırmaya olan etkisinin derecesini belirleyen parametredir. Alonso'nun çalışması, merkezi iş alanı kavramının modern planlamada temel alınmasını sağlamıştır (Alonso,1964).

#### **Forrester'ın Kentsel Dinamikleri ve Sibermetik Yaklaşımları**

Forrester'ın yaklaşımı, kentsel çürüme döngülerini tanımlamak için geri besleme halkalarını temel alan sibermetik prensipleri uygulamıştır. Örneğin, altyapı yatırımlarının artması, kısa vadede istihdamı artırsa da, uzun vadede göç dalgalarını tetikleyerek konut kıtlığına yol açabileceği öngörülmüştür. Bu simülasyon, karmaşıklık teorisinin şehir planlaması alanına aktarılmasında ön açıcı bir çalışma olarak kabul edilmiştir (Forrester, 1975).

### **2.3 1980–2000: Karmaşık Sistemler ve Bilgisayar Tabanlı Teknikler**

Bu dönem, kentlerin yalnızca makroskopik eğilimlerle değil, bileşenler arasındaki geri besleme döngüleri ve mikro-düzye etkileşimlerle de şekillendiğini gösteren “karmaşık

sistemler” paradigmasının yükseldiği; aynı zamanda artan bilgisayar gücü sayesinde artık benzetim tekniklerinin pratikte uygulanabildiği bir çağ olmuştur. Aşağıda bu çerçevede dört ana yaklaşım ele alınacaktır.

### **Kaos Teorisi / Fraktal Şehirler**

1980’lerin sonu ile 1990’ların başında Mandelbrot’un “doğanın fraktal geometrisi” kuramı, kent dokusunun kendine benzer (self-similar) bir yapıya sahip olabileceğini ortaya koydu. Batty ve Longley (1994) yayımladıkları Fractal Cities çalışmasında, şehir sınırlarının ve yoğunluk desenlerinin madde boyut analizleriyle ölçülebileceğini ve bu sayede planlı-plansız parçaların karmaşık bütününi nicel yöntemlerle incelemenin mümkün olduğunu gösterdiler. Kutu sayma (box-counting) algoritmaları, kent silueti üzerindeki “boşluk ve doluluk” örüntülerinin fraktal boyutunu hesaplama imkânı verdi; böylece form–işlev ilişkisine, klasik geometri yaklaşımlarının ötesinde bir bakış açısı kazandırıldı. Bu çalışma organizma temelli bir yaklaşım olarak kentsel büyüme çalışmalarında paradigma değişimine yol açan en önemli kilometre taşlarından biridir.

### **Hücreli Otomata (CA)**

Hücreli otomata, von Neumann ve Ulam’ın 1940’lardaki öncü çalışmalarıyla tanımlanan ızgara tabanlı hesaplama kuramına dayanmaktadır; Conway’in Game of Life (1970) adlı sıfır-oyunculu “oyunda” basit kuralların nasıl beklenmedik derecede zengin örüntülere yol açtığını gösterdi.

Bu konsept, White ve Engelen (1993) “Cellular Automata and Fractal Urban Form” makalesiyle gerçek şehir verilerine uygulandı: Gerçek uydu görüntülerinden çıkarılan arazi kullanımı haritaları, hücre komşuluk kuralları (Moore ya da von Neumann) üzerinden güncellenerek, gelecekteki büyüme örüntülerinin fraktal karakterde simülasyonu gerçekleştirildi.

Bu çalışma, hem kentsel formun mikro-ölçekli dinamiklerini modellemede yüksek mekânsal ayrıntı sağladı, hem de CA tabanlı simülasyonların teori ve uygulama arasında köprü kurmasına öncülük etti.

1980–2000 dönemi kent simülasyonlarında, hücreli otomata kurallarının en uygun parametrelerle çalışması için brute-force Monte Carlo denemeleri yaygınlaşmıştır. Clarke, Hoppen ve Gaydos’un 1997 tarihli SLEUTH uygulaması, dört yayılma kuralı

(spread, breed, slope, road) ve “self-modifying” mekanizmasını, rastgele üretilen parametre setleri üzerinden Monte Carlo tabanlı brute-force kalibrasyon ile en uygun hale getirmiştir. Bu yaklaşım, her bir parametre kombinasyonunun simülasyon doğruluğunu istatistiksel olarak sınyarak hem model güvenilirliğini arttırmış hem de parametre belirsizliklerini nicel olarak ortaya koymuştur. Daha sonraki yıllarda bu brute-force denemelerin yerini genetik algoritma optimizasyonları olarak hesap süresini %80’e varan oranda kısaltmıştır.

### **Ajan Tabanlı Modeller**

1990’larda, şehir içindeki bireysel aktörleri (haneler, yatırımcılar, yöneticiler) temsil eden “ajan”ların yerel karar kurallarıyla etkileşimini simüle eden ABM’ler, kentsel dinamikleri mikro-düzeyde açıklamayı hedefledi. Joshua M. Epstein ve Robert Axtell’in 1996’daki *Growing Artificial Societies: Social Science from the Bottom Up* adlı yapıtında tanıtılan “Sugarscape” platformu, heterojen ajanların kaynak toplama, göç, üreme, hastalık yayılımı gibi süreçleri kuramsal bir “kaynak çayrağı” üzerinde canlandırdı MIT Pressjasss.soc.surrey.ac.uk. ABM’ler, bu sayede toplumsal karar süreçleri ile arazi kullanımı, trafik talebi ve altyapı ihtiyacı arasındaki karmaşık geri beslemeleri hem nicel hem görsel biçimde inceleme imkânı sundu.

### **2.4 2000’ler-Günümüz: Hibrit Model Dönemi**

2000 sonrasında kentsel dinamiği daha iyi modellemek için 19. yüzyılın ileri düzey istatistiksel modellerinden makine öğrenimine, daha sonra da yapay zekâ modelleri geliştikçe yapay zekâ algoritmalarına geçiş yapıldığı gözükmektedir. Yapay zekâ algoritmalarını kentsel dinamiği en iyi şekilde simüle ettiği düşünülen hücresel otomata ile hibritleyen modeller bu dönemde modelleme çalışmalarının temelini oluşturmuştur.

2000–2020 arası, kentsel büyüme simülasyonlarının hücresel otomata (CA) yanında birbirinden farklı yöntemleri bir arada kullanarak zengin, çok ölçekli yaklaşımlar geliştirdiği bir dönem olmuştur. Mikro-düzeyde hücre komşuluk kuralları hâlâ çekirdek rol oynarken, makro-düzey girdiler, makine öğrenmesi teknikleri, sistem dinamiği, çok amaçlı optimizasyon ve gerçek zamanlı veri akışları da küresel simülasyon çerçevesine entegre edilmiştir. Aşağıda bu dönemin öne çıkan model aileleri ve bileşenleri ayrıntılı şekilde incelenmektedir.

#### **2.4.1 CLUE Ailesi ve Arazi Dönüşüm Regresyonu**

*CLUE (Conversion of Land Use and its Effects)* modeli, 2002 yılında Veldkamp ve Fresco tarafından geliştirilmiş olup, hücresel otomata mantığını çok değişkenli regresyon ve kullanıcı tanımlı tercih/kısıt fonksiyonlarıyla birleştirir. Modelin temel işleyişinde, geçmişe dönük arazi kullanımı verilerinden elde edilen istatistiksel dönüşüm potansiyeli matrisleri her bir hücre için hesaplanır; bu matrisler, koruma bölgeleri veya altyapı yakınlığı gibi kısıt ve tercih katmanları ile zenginleştirilir. Böylece CLUE, hem geriye dönük “hindcasting” çalışmalarıyla kalibrasyon yapabilmekte hem de nüfus artışı, altyapı yatırımları veya koruma politikaları gibi senaryolar altında gelecek projeksiyonları sunabilmektedir. Tropikal orman kaybı, tarım alanı dönüşümleri ve kentsel yayılma analizleri gibi uygulama alanlarında sıkça tercih edilen CLUE-S ve CLUE-Scanner gibi türevleri, uzaktan algılama verilerinin düzenli güncellenmesiyle modelin esnekliğini artırır.

#### **2.4.2 DINAMICA EGO ve Land Change Modeller**

DINAMICA EGO, Soares-Filho ve ekibi tarafından 2002’de sunulmuş; Monte Carlo tabanlı hücresel otomata çekirdeğini Çok Amaçlı Karar Değerlendirme (MCE), lojistik regresyon ve yapay sinir ağları (ANN) katmanlarıyla zenginleştirerek, Amazon yağmur ormanlarından kentsel etkileşim ağlarına kadar geniş bir uygulama yelpazesi oluşturmuştur. Model, raster veri katmanlarından dönüşüm potansiyeli haritalarını otomatik olarak üretiyor; MCE ile önceliklendirme yapıyor, ANN ile doğruluk artışı sağlıyor ve CA kurallarıyla mekânsal yayılımı simüle ediyor. ESRI ArcGIS ortamına entegre edilen Land Change Modeller (LCM) eklentisi ise DINAMICA’nın kullanıcı dostu arayüzünü yaygınlaştırarak, saha uzmanlarının karmaşık ayarlarla uğraşmadan simülasyon çalıştırmasını mümkün kılmıştır.

#### **2.4.3 METRONAMICA ve Belirsizlik Haritaları**

METRONAMICA, 2003 yılında Veldkamp ve Lambin tarafından tanıtılan bir diğer hibrit çerçeve olup, hücresel otomata ile Monte Carlo örnekleme tekniklerini birleştirir. Burada her hücrenin uçtan uca dönüşüm olasılığı, önceden belirlenen istatistiksel dağılımlardan rastgele seçilen değerlerle güncellenir. Sonuçta elde edilen “olasılık haritaları”, belirsizlik bilgisiyle birlikte karar vericilere sunulur; böylece kesin bir “tek bir gelecek” yerine farklı risk seviyeleri içeren çoklu senaryolar değerlendirilebilir. Kentsel planlama, ekosistem koruma ve altyapı yatırım

kararlarında METRONAMICA, belirsizlik yönetimi perspektifini model çıktısına doğrudan dahil etmesiyle öne çıkar.

#### **2.4.4 FLUS: Sistem Dinamiği Entegrasyonu**

FLUS (Future Land Use Simulation), 2014'te Guo ve arkadaşları tarafından geliştirilen bir modeldir ve mikro-ölçekli CA katmanını sistem dinamiği modülüyle birleştirir. Bu yapı, nüfus artışı, ekonomik büyüme, ulaştırma yatırımları veya çevresel kısıtlar gibi makro düzey faktörlerin “stok–akış” blokları olarak tanımlanıp, her simülasyon adımında hücresele otomata beslendiği dinamik bir döngü sunar. FLUS, özellikle hızlı kentleşen Çin metropollerinde uygulanan projelerde, altyapı devreye alma kararlarının yerleşim desenine etkisini gerçek zamanlı senaryo analizleriyle göstermiştir.

#### **2.4.5 SLEUTH-GA ve Evrimsel Kalibrasyon**

SLEUTH-GA, Clarke ve Lauer'in 2011'de yayımladığı bir sürüm olup, orijinal 1997 tarihli SLEUTH modelinin Monte Carlo-brute-force kalibrasyonunu genetik algoritmalarla (GA) değiştirir. Burada beş temel parametre (“spread, breed, slope, road, unlikely-urban”) birer kromozom olarak kodlanır ve evrimsel döngülerle optimize edilir. Bu yöntem, geleneksel brute-force'a göre kalibrasyon süresini %80'e varan oranlarda kısaltırken, parametre duyarlılık analizi ve çok amaçlı hedef fonksiyon optimizasyonunu da kolaylaştırır; büyük ölçekli ve veri yoğun simülasyonlarda hız ve doğruluk dengesini iyileştirir.

#### **2.4.6 ABM-CA Hibritleri**

Ajan Tabanlı Modeller (ABM) ile CA entegrasyonunu ele alan hibrit yaklaşımlar, mikro–makro etkileşimleri daha gerçekçi yansıtmak için geliştirilmiştir. MATSIM ve TRANSIMS gibi ulaşım odaklı platformlar, trafik ajanlarının karar mekanizmalarını hücresele otomata hücreleriyle çift yönlü etkileşim halinde simüle eder. GAMA, Repast ve NetLogo gibi açık kaynak araçlar ise kentsel ABM modellerini kolayca inşa etmeye olanak tanıyan modüler altyapılar sağlar; bu sayede hanehalkı yer seçimi, yatırımcı kararları ve altyapı talepleri gibi sosyal süreçler mekânsal yayılım modellerine doğrudan dahil edilebilir.

#### 2.4.7 İleri Düzey Yapay Zekâ Algoritmaları

2000–2020 döneminin son yıllarında kentsel büyüme modellerinde derin öğrenme tabanlı hibrit modellerle karşılaşmakta, HO simülasyonlarına yapay zekâ katmanları eklenerek hem sınıflandırma hem de tahmin doğruluğunu artırmak için kullanıldığı görülmektedir. Genelde arazi kullanım/örtüsü tahminleri için kullanıldığı görülen Konvolüsyonel Sinir Ağları (CNN), yüksek çözünürlüklü uydu ve LiDAR verilerinden otomatik arazi kullanım haritaları çıkarırken; Uzun Kısa Süreli Bellek Ağları (LSTM), nüfus ve altyapı göstergeleri zaman serilerini analiz ederek gelecekteki arazi kullanım taleplerini öngörecektir. Ek olarak Üretici Karşıt Ağlar (GAN) ise sınırlı veriyle bile gerçekçi arazi örtüsü örnekleri üreterek modeli besleyip; hem mekânsal hem de zamansal belirsizlikleri azaltarak simülasyonların güvenilirliği artırdığı görülmektedir.

Buna karşın, HO entegrasyonları dışında, direkt olarak verilerle uzaktan algılama sistemlerinden elde edilen verilerin meteorolojik kestirimlerde ve arazi değişim simülasyonlarında çok sayıda yapılan çalışmaya karşılık kentsel büyüme alanında bu kapsamda az sayıda çalışma olduğu gözlemlenmiştir.

#### 2.5 Yeni Paradigmalar

Büyük dil modellerinin çok hızlı bir biçimde yayılması ve bu modellerin anlama/kavrama başarılarının her geçen gün artması ile tüm disiplinlerde olduğu gibi kentsel çalışmalara da ilham verdiği görülmektedir. 2018 yılında OpenAI tarafından ChatGPT'nin ilk versiyonunun tanıtılması tüm dünyada büyük yankı uyandırmıştır. Aslında 2010'lardan bu yana dil modellerinin başarılı örnekleri var olsa da ChatGPT'de kullanılan dil modeli, güçlü bağlantı kurma başarısı ile tüm insanlığı şaşırtmayı başarmıştır. Kısa süredeki bu popülerite yükselişinin ardından rakiplerin sektöre girişi de gecikmemiştir (örn.: Amazon – Anthropic, Google – Gemini, Meta – Llama). Dil modellerinin bu başarısı diğer disiplinlerce de ilgi ile takip edilmiş ve pek çok alana entegre edilmeye çalışılmıştır. Şüphesiz her disiplininde olduğu gibi kentsel alanda da benzer çalışmaları görmekteyiz. Özellikle 2022 yılında, Amazon Science takımı ile Hong Kong Bilim ve Teknoloji Üniversitesi iş birliği içinde uzay-zamanlı uydu görüntü verileri kullanarak “cuboid attention” tabanlı bir transformer modeli olan Earthformer'ı geliştirmiştir. Bu çalışmada MODIS ve GOES uydu verileri kullanılarak yağış tahmin hataları hesaplanmış ve “Cuboid Attention” metodu ortaya konulmuştur.

Yapılan literatür incelemesinde, 2022 yılı itibariyle kentsel çalışmaları da kapsayacak şekilde uzaktan algılama üzerine, dil modellerinin temelini oluşturan transformer mimarisini uzaysal-zamansal veri üzerine uygulayan çalışmalar ortaya çıkmıştır.<sup>1</sup>

Bu modellerin ortaya çıkmasının en büyük sebeplerinden biri de kentsel büyüme çalışmalarında kesit veriye ulaşma probleminin günümüzde ortadan kalkması ile uzaktan algılama sistemlerinden alınan verilerin çok boyutlu olarak kalitesinin artması gösterilebilir (Batty ve Longley, 1994). Örneğin gece ışıklarını almak için VIIRS (Visible Infrared Imaging Radiometer Suite) sensörleri birden çok uydu aracılığıyla günlük görüntü almaktadır. Benzer şekilde Wuhan üniversitesinin *Luojia-1* adlı uydusu ve Planet Labs şirketinin *PlanetScope* projesi günlük takip yapmaya uygun uzaktan algılama veri kaynağı olarak gösterilebilir. Artık veri kısıtından ziyade büyük veri üzerinde tahmin modellerinin en iyi şekilde eğitilmesi için yapılan çalışmalar önemli hale gelmiştir. Bu sebeple son yıllarda aynı veri ile eğitilen farklı model kıyaslamalarını içeren performans kıyaslama çalışmalarının -görece- fazla rağbet gördüğü anlaşılmaktadır.

Gelecekteki çalışmaların, kentsel yayılma dinamiklerini daha derinlemesine anlamak ve planlama süreçlerine entegre etmek amacıyla modelleri uzay-zamansal analizler ve çok ölçekli verilerle hibrit çalışmaların karşımıza çıkacağı beklenmektedir.

---

<sup>1</sup> *Transformer-Convolutional Neural Network Cellular Automata (TC-CA, 2024)*: Kentsel arazi kullanımı ve örtüsü değişimini (LUCC) modellemek için CNN ile mekânsal, Transformer ile zamansal ilişkileri çıkarıp bunları hücresel otomat simülasyonuna entegre eder; Çin'in Wuxi şehrinde geleneksel modellere kıyasla %2.85–8.14 daha yüksek doğrulukla tahmin ettiği iddia edilmiştir.

*Video Swin Transformer for Land Use Change Simulation (VST-PCA, 2024)*: Swin Transformer tabanlı video benzeri uzaktan algılama verilerinden mekânsal-zamansal öznitelikler çıkarır ve CA simülasyonundaki hotspot ön-ayırma stratejisiyle arazi kullanımı değişimini simüle eder.

*Spatial–Temporal De-Confounding Transformer (STDCformer, 2024)*: Kalabalık akışı tahmininde mekânsal ve zamansal karışıklıkları nedensel çıkarım yoluyla gideren bir strateji uygular ve elde edilen temsillerle daha sağlam öngörüler sunar.

## 2.6 Literetürde Yer Alan Çalışmalar

Bu çalışma kapsamında yapılan literatür taramasında ağırlıklı olarak 2000 yılı sonrasında başlıca kentsel büyüme çalışmaları incelenerek çalışma yılı kronolojisine göre sıralanmıştır.

Clarke ve diğ. (1997), kentleşme dinamiklerinin modellenmesi bağlamında "SLEUTH" adını taşıyan bir simülasyon modeli geliştirmiştir. Bu model, temelini hücresel otomat (HO) teorisinden alarak, kentsel yayılımın hem mekânsal hem de zamansal boyuttaki desenlerini tahmin etmeyi hedeflemiştir. Söz konusu modelin çalıştırılması için başlıca girdiler; topoğrafik eğim, mevcut arazi kullanımı durumu, yerleşime kapalı alanları belirleyen dışlama katmanı, var olan kentsel dokunun dağılımı, ulaşım altyapısı ve şehirselleşme (S-L-E-U-T-H) bileşenlerinden oluşan bir veri setidir. Modelin kalibrasyonu, yayılma (diffusion), oluşum (breed), genişleme (spread), eğim (slope) ve yol çekimi (road-gravity) şeklinde isimlendirilen beş ana parametrenin, geçmişe dönük kentleşme verileri üzerinde Monte Carlo yöntemine dayalı iteratif bir süreçle optimize edilmesiyle gerçekleştirilir. Yüksek çözünürlüklü grid verileri ve sokak ağı verileri kullanılarak, farklı planlama senaryolarının (örneğin, doğal alan koruma, kentsel yoğunluk artırımı veya yeni ulaşım hatları inşası) gelecekteki büyüme paternleri üzerindeki olası etkileri analiz edilebilmektedir. Araştırma sonuçları, modelin, tarihsel süreçteki kentsel genişlemeyi yüksek bir doğrulukla temsil edebildiğini, aynı zamanda ulaşım koridorlarının ve fizyografik engellerin kent formu üzerindeki belirleyici etkilerini ortaya koyabildiğini işaret etmektedir. Söz konusu çalışma, kentsel planlama kararlarına girdi sağlayabilecek nicel ve görsel bir değerlendirme ortamı sağlaması ile günümüze kadar en çok başvurulan kentsel büyüme tahmin modeli olmuştur.

White ve Engelen (2000), kentsel ve bölgesel sistemlerin karmaşık evrim sürecini modellemek için hücresel otomat (CA) tabanlı bir yaklaşım önermektedir. Söz konusu model, arazi tahsisi mekanizmalarını, erişilebilirlik ölçütlerini, komşuluk birimleri arasındaki etkileşimleri ve sistem içi geri besleme döngülerini bütünlük bir çerçevede ele alarak bütüncül bir simülasyon ortamı sunar. Model, farklı arazi kullanım türleri arasındaki rekabeti, mevcut altyapı ve çeşitli kısıtlayıcı koşullar altında, senaryo temelli olarak çözümler; kalibrasyon süreci ise çok zamanlı arazi kullanım haritaları ve mekânsal istatistikler (mekânsal metrikler) kullanılarak gerçekleştirilir. Bu

kavramsal çerçeve, daha sonra GEONAMICA/Metronamica yazılım ailesi içinde operasyonel bir modele dönüşmüş ve değişen politika, demografi ve ekonomi varsayımları altında yüksek çözünürlüklü arazi dağılımı projeksiyonları üretme kapasitesi kazanmıştır. Çalışmanın sonuçları, modelin çok ölçekli etkileşimleri ve geri beslemeleri açık bir şekilde temsil etmesinin, politika senaryolarının analizindeki ayırt ediciliği ve güvenilirliği önemli ölçüde artırdığını ortaya koymaktadır.

Herold ve diğ. (2001), "Remote sensing and urban growth models, demands and perspectives" başlıklı araştırmalarında, arazi kullanım değişim modellerinin parametreleştirilmesi, kalibrasyonu ve doğrulanması için gerekli verilerin, yüksek mekansal-zamansal çözünürlüklü uydu görüntüleriyle elde edilebilirliğini incelemiştir. Santa Barbara bölgesinde, yüksek çözünürlüklü uzaktan algılama verileriyle kentsel arazi kullanımını belirlemede en etkili yöntem değerlendirilmiştir. Arazi örtüsü yapısını, kentsel kullanım bilgisini ve sosyo-ekonomik özellikleri tanımlamak için mekansal ve fraktal metriklerden yararlanılmıştır. Hücresel otomat (HO) modeli temelinde, uzaktan algılama ile modelleme entegrasyonunun potansiyeli sunularak, hem arazi kullanım değişimi tahmini hem de kentsel büyüme sürecinin anlaşılması hedeflenmiştir. Elde edilen bulgular, bu kombine yaklaşımın geleceğe yönelik tahminlerde başarılı olduğunu göstermiştir.

Yüzer (2001), "Şehirselleşmelerde Fractal ve Hücresel Otomat Yöntemi İle Gelişme Alanlarının Belirlenmesi" çalışmasında, yerleşimlerin fraktal geometrisi ve hücresel fonksiyon ilişkileri temelinde geliştirilen Hücresel Otomat (HO) modelini, fiziksel ve sosyo-ekonomik verilerle birlikte tanımlamıştır. Planlama sürecine veri desteği sağlamayı amaçlayan araştırmada, HO'nun temelleri, planlama ile bağlantısı ve arazi kullanımıyla ilişkisi incelenmiştir. Model Bursa örneğinde test edilerek sonuçlar analiz edilmiştir. Model çıktıları başlangıç varsayımlarına göre sınanmış ve elde edilen bulgular ışığında planlama önerileri geliştirilmiştir.

Verburg ve diğ. (2002), göre geliştirilen "CLUE-S" modeli, bölgesel ölçekteki detaylı arazi kullanım değişimini, talep ile mekansal tahsis süreçlerini birbirinden ayıran iki aşamalı bir yapıda incelemiştir. Modelin ilk aşamasında, arazi kullanımı için gereken toplam talep miktarı mekansal olmayan (non-spatial) bir modül aracılığıyla belirlenir; ikinci aşamada ise bu talep, lojistik regresyon ile hesaplanan mekansal uygunluk yüzeyleri temel alınarak coğrafi olarak hesaplanır. Sınıf dönüşümleri, bir dönüşüm matrisi, esneklik katsayıları ve komşuluk kuralları ile kısıtlanarak modelin gerçekçiliği

artırılmaya çalışılmıştır. Farklı senaryolardan (tarımsal büyüme, kentleşme hızı vb.) türetilen talep projeksiyonları, yıllık adımlar halinde mekânsal dağılıma dönüştürülür ve sonuçlar tarihsel arazi haritaları ile karşılaştırılarak doğrulanır. Elde edilen bulgular, bu iki aşamalı yapının senaryo analizlerinin şeffaflığını ve izlenebilirliğini güçlendirdiğini, fakat modelin nihai çıktılarının, talep tahminlerindeki ve istatistiksel varsayımlardaki belirsizliklere karşı hassas olduğu belirtilmiştir.

Soares-Filho ve diğ. (2002), “DINAMICA” isimli çalışmalarında, özellikle tropikal bölgelerdeki ormansızlaşma dinamiklerini ve peyzaj değişimini simüle etmek amacıyla Kanıt Ağırlıklı (Weights of Evidence - WoE) yöntemine dayalı stokastik bir hücreli otomat modeli tasarlamışlardır. Bu yaklaşımda, arazi değişimine neden olan sürücü değişkenlere (yollara mesafe, topoğrafik özellikler, altyapı vb.) dayalı geçiş olasılıkları istatistiksel olarak WoE yöntemiyle türetilmiştir. Değişim süreci, mevcut yamaların genişlemesini (“Expander”) ve yeni yamaların oluşumunu (“Patcher”) kontrol eden iki temel işlev aracılığıyla ilerletilir; bu sayede yama boyutu ve şekli gibi morfolojik özellikler gerçekçi bir biçimde temsil edilebilir. Modelin doğrulama ve kalibrasyonu, çoklu iterasyonlar ve geçmiş dönem arazi örtüsü sınıflandırmaları kullanılarak yapılır. Farklı senaryolar altında, mekânsal değişim olasılık haritaları ve nihai değişim haritaları üretilir. Araştırma sonuçları, modelin, yama temelli peyzaj değişimini yüksek doğrulukla yakaladığını ve senaryo temelli projeksiyonlarda güçlü bir performans sergilediği rapor edilmiştir.

Waddell (2002), “UrbanSim” adlı çalışmasında, arazi kullanımı ve ulaşım etkileşimlerini (LUTI) modellemek için mikro-simülasyon tekniklerine dayalı yenilikçi bir çerçeve sunmuştur. Model, piyasa içindeki temel aktörleri (hanehalkları, işletmeler, geliştiriciler) doğrudan temsil eder ve bu aktörlerin kararlarını yıllık zaman adımlarında simüle etmek için ekonometrik ve ayrık seçim modellerinden yararlanır. Parsel ve bina ölçeğindeki detaylı veriler, konut ve iş yeri piyasasındaki fiyat ve kira göstergeleri, imar düzenlemeleri ve ulaşım ağlarının erişilebilirlik çıktıları modelin ana girdilerini oluşturur. Model, ulaşım modelleri ile çift yönlü ve dinamik bir entegrasyon kurar. Kalibrasyon ve geçerlilik süreçleri, modelin tarihsel dağılımları ve piyasa dinamiklerini ne ölçüde yeniden üretebildiği üzerinden değerlendirilir. Çalışma bulguları, bu davranışsal ve disiplinlerarası yaklaşımın, konut ve istihdamın mekânsal dağılımını, emlak piyasası dinamiklerini ve planlama politikalarının olası etkilerini değerlendirmede etkili bir araç olduğu rapor edilmiştir.

Silva ve Clarke (2002), "Calibration of the SLEUTH Urban Growth Model for Lisbon and Porto, Portugal" çalışmasında, SLEUTH modelini Lizbon ve Porto'da uygulamıştır. Avrupa kentlerindeki gelişimin modellenmesi ve model davranışındaki farklılıklar bu araştırmayla ortaya konmuştur. Model uygulaması sırasında; ölçeklenebilirlik, otomatik çok aşamalı optimizasyon, eşit sonuç (equifinality) problemi ve yerel parametre hassasiyeti gibi konular ele alınmıştır. SLEUTH uygulamalarının, 1960-70'lerin kent modelleri analizlerini ve kent büyüme modelinin evrensel geçerliliğini destekleyeceği savunulmuştur.

Pijanowski ve diğ. (2002), "Land Transformation Model (LTM)" başlıklı çalışmalarında, coğrafi bilgi sistemleri (CBS) ile çok katmanlı algılayıcı (MLP) tipi bir yapay sinir ağını entegre ederek geniş ölçekli bölgelerdeki arazi örtüsü değişimini modelleyen bir yöntem geliştirmişlerdir. Söz konusu model, tarihsel verilerde gözlemlenen dönüşüm olaylarından (örneğin tarım arazisinden kentsel alana geçiş) elde edilen veri seti ile eğitilerek, sürücü değişkenler ile mekânsal değişim arasındaki karmaşık ilişkiyi öğrenir. Yol ağına yakınlık, topoğrafik eğim ve mevcut arazi kullanımı gibi faktörlerden yola çıkarak dönüşüm olasılık yüzeyleri hesaplar ve bu yüzeyleri, nüfus projeksiyonları veya yeni altyapı yatırımları gibi senaryolara göre şartlandırarak gelecek projeksiyonları üretir. Modelin performansı, çapraz doğrulama ve bağımsız bir zaman periyodu üzerinden test edilmiş; elde edilen sonuçlar, LTM'nin politika senaryolarının olası mekânsal sonuçlarını etkili bir şekilde ortaya koyabildiğini ve yüksek doğruluk derecesine sahip tahmin haritaları üretebildiği rapor edilmiştir.

Li & Yeh (2002), "NN-CA" (Yapay Sinir Ağı - Hücresel Otomat) yaklaşımını çalışmalarında, eşzamanlı ve çoklu arazi sınıfı dönüşümlerinin simülasyonu için yapay sinir ağlarının (YSA) öğrenme yeteneği ile hücresel otomatın (HO) mekânsal dinamiklerini bir araya getirmişlerdir. Bu yaklaşım, geleneksel HO modellerinde karşılaşılan ve manuel kural tanımlama gerektiren önemli bir zorluğu, çok çıkışlı bir sinir ağı mimarisi ile dönüşüm kurallarını otomatik olarak öğrenerek aşmayı amaçlamaktadır. Komşuluk etkileri ve çeşitli kısıtlamalar, her simülasyon iterasyonunun sonunda dinamik olarak yeniden hesaplanır ve güncellenir. Güney Çin'deki hızlı kentleşme sürecine sahne olan bir bölge üzerinde yapılan uygulama, bu yöntemin, çoklu sınıflar arasındaki rekabeti ve zaman içinde değişkenlik gösteren mekânsal etkileşimleri geleneksel lojistik regresyon tabanlı CA modellerine kıyasla

daha iyi yakaladığını ve istatistiksel olarak daha tutarlı sonuçlar verdiği rapor edilmiştir.

Almeida ve diğ. (2003) tarafından öne sürülen çalışma, kentsel arazi kullanım dinamiklerinin olasılıksal bir stokastik hücreli otomat (S-HO) çerçevesi içinde modellenmesine odaklanmıştır. “Ampirik geliştirme ve kestirim” ilkesini merkeze alan bu yaklaşım, komşuluk yapılarını ve hücre durum geçişlerini istatistiksel olasılık kuralları şeklinde tanımlayarak model parametrelerinin doğrudan gözlemlenebilir veriden türetilmesini sağlar; böylece “keyfi” kural belirleme pratiğine olan bağımlılığı en aza indirgediği iddia edilmiştir. Brezilya'daki çeşitli kentsel alanlarda gerçekleştirilen model uygulamaları, geliştirilen çerçevenin, yama boyutu ve şekli ile yoğunluk deseni gibi mekânsal örüntüleri yüksek bir gerçekçilikle simüle edebildiğini göstermiştir. Ayrıca, çok zamanlı kalibrasyon ve doğrulama süreçlerinin, modelin tahmin güvenilirliğini ve gelecek projeksiyonlarındaki sağlamlığını belirgin şekilde artırdığı rapor edilmiştir.

Herold ve diğ. (2003), "The spatiotemporal form of urban growth: measurement, analysis and modeling" çalışmasında, Santa Barbara, California'daki kentsel büyümeyi analiz etmek için mekansal modelleme, metrikler ve uzaktan algılama entegrasyonunun potansiyelini araştırmıştır. IKONOS görüntüleri ve tarihsel hava fotoğraflarından oluşan 72 yıllık veri seti kullanılmıştır. Mekânsal metrikler, kentsel gelişimin zaman-mekan örüntülerini ölçmüş ve modelin tarihsel simülasyon doğruluğunu detaylandırmıştır. SLEUTH modeli çok zamanlı verilerle kalibre edilerek 2030 yılına kadar mekansal büyüme projeksiyonları üretilmiştir. Sonuçlar, kentsel büyümenin örüntü ve miktarını açıklamada modellemenin etkinliğini ve uzaktan algılama-metrik-modelleme kombinasyonunun başarısını kanıtlamıştır.

Allen ve Lu (2003), "Modeling and prediction of future urban growth in the Charleston Region of South Carolina" araştırmasında, Güney Carolina'nın hızlı büyüyen bölgelerinde parsel düzeyinde arazi kullanım değişimini belirlemek için yapı ruhsat verilerine dayalı alternatif bir yöntemin uygulanabilirliğini test etmiştir. Üç model karşılaştırılmıştır: Eğim, yol, koruma alanları ve kent merkezine dayalı Clarke HO modeli (1997), çoklu değişkenli Landis lojistik regresyon modelleri (1994, 1995), komşuluk etkileşimleri, mesafe, parsel büyüklüğü ve arazi uygunluk kriterlerini içeren Pijanowski'nin göreceli olasılık modeli (1997). Çalışma, bu modellerin hiçbirinin gelecekteki kentsel büyümeyi güvenilir şekilde test edemediği sonucuna varmıştır.

Meentemeyer ve diğ. (2013), tarafından geliştirilen FUTURES modeli, bölgesel ölçekteki gelişim talebi ile yerel ölçekteki mekânsal tahsis süreçlerini entegre eden çok düzeyli bir mimariye sahiptir. Bu mimarinin temelini, stokastik (rastlantısal) "yama-büyütme" (patch-growing) algoritması oluşturmaktadır. Model üç temel bileşen etrafında kurgulanmıştır:

- Talep (Demand): Demografik projeksiyonlara dayalı olarak gelecekteki kentsel gelişim için gereken toplam alan miktarını hesaplar,
- Potansiyel (Potential): Çevresel ve sosyo-ekonomik faktörlere bağlı olarak her bir hücrenin gelişime uygunluk derecesini belirler,
- Yama (Patch): Gelişim sürecini, yeni yamaların oluşumu (tohumlanması) ve mevcut yamaların genişlemesi şeklinde simüle eder.

Modelin, ABD'nin Güneydoğu bölgesinde yapılan uygulamaları, farklı nüfus ve politika senaryoları altında dahi kentsel-kırsal arazi mozağının evrimini tutarlı bir şekilde modellediğini; böylece yayılma desenlerini ve kentsel sınırlar üzerindeki etkileri görünür kıldığı rapor edilmiştir.

Başlık (2008), İstanbul ve Lizbon örnekleri üzerinden kentsel yayılma süreçlerini karşılaştırmalı olarak inceleyen araştırmasında, mekânsal büyümenin doğasını kavramak ve geleceğe dair projeksiyonlar oluşturabilmek amacıyla lojistik regresyon ile hücresel otomat tabanlı hibrit bir yaklaşım kullanmıştır. Çeşitli tarihsel dönemleri (1930, 1950, 1985, 1995 ve 2005) kapsayan bu model, uydu görüntüleri, arazi kullanım envanterleri, nüfus dağılım verileri ve arşiv belgelerinden derlenen kapsamlı bir veri seti ile beslenmiştir. Araştırmada, lojistik regresyon tekniği, nüfus yoğunluğu, ulaşım altyapısı, topoğrafik eğim ve mevcut arazi kullanımı gibi faktörlerin kentsel gelişim üzerindeki istatistiksel anlamlılığını ve etki derecesini ortaya koyarken; hücresel otomat modeli ise söz konusu bu eğilimlerin zamansal ve mekânsal boyutta nasıl bir yayılım desenine dönüştüğünü hücresel düzeyde simüle etmiştir. Çalışmada, İstanbul'daki büyüme dinamiğinin hızlı, yoğun ve plansız bir karakter sergilediği, Lizbon'da ise bu sürecin daha dengeli ve denetimli bir seyir izlediği rapor edilmiştir. Söz konusu bu farklılıklar, her iki kent içinde şekillendiği sosyo-ekonomik, politik ve kültürel bağlamların mekânsal gelişim üzerindeki belirleyici rolü vurgulanmıştır. Çalışma, kentleri doğrusal olmayan ve çok-değişkenli karmaşık sistemler olarak ele almanın gerekliliğini savunarak, geleneksel lineer modellerin sınırlılıklarını aşan daha gerçekçi bir kentsel büyüme modeli ihtiyacı belirtilmiştir. Araştırmanın sonuç

bölümünde, bu tarz parametrik ve dinamik modellerin sadece geçmiş eğilimleri analiz etmek için değil, aynı zamanda geleceğe yönelik senaryoların geliştirilmesinde ve etkin planlama politikalarının üretilmesinde operasyonel bir araç olarak kullanılmasının elzem olduğu vurgulanmakta; özellikle İstanbul benzeri hızlı bir kentleşme temposuna sahip metropollerde sürdürülebilir bir kentsel planlama için vazgeçilmez bir yöntem olduğu savunulmaktadır.

Liu ve diğ. (2017), FLUS (Future Land Use Simulation) modeli ile, üstten-aşağıya (top-down) işleyen ve sistem dinamikleri ile talep tahmini yapan bir modül ile alttan-yukarıya (bottom-up) çalışan ve mekânsal işlemi hücresele otomat (HO) ile gerçekleştiren bir modülü hibritlemiştir. Modelin HO bileşeni, dinamik bir direnç ve rekabet mekanizması kuralları içererek, farklı arazi kullanım türleri arasındaki etkileşim ve rekabeti daha gerçekçi bir biçimde temsil etme kapasitesi kazandırılmıştır. Mekânsal uygunluk alanları, makine öğrenmesi algoritmaları kullanılarak türetilmiştir. Çin genelinde yapılan simülasyon çalışmaları, modelin uzun dönemli arazi örtüsü değişimi (LUCC) yörüngelerini ve hem insan faaliyetlerinin hem de iklim değişikliğinin ortak etkilerini değerlendirmek için kullanılabileceğini göstermiştir. Elde edilen bulgular, FLUS'un, politika senaryolarına duyarlı tahminlerde ve parçalı (fragmented) arazi morfolojilerinin üretiminde yüksek bir performans sergilediği belirtilmiştir.

Clarke ve Johnson (2020), geniş bir veri setini 174 alt bölgeye bölerek her bölüm için SLEUTH kalibrasyonları arasındaki bağlantıyı incelemeyi hedeflemiştir. Bu alt gruplardan çıkan parametrelerle 2100 yılı kentsel büyüme projeksiyonu oluşturulmuş; farklı bölümlerdeki kalibrasyon sonuçlarının büyüme katsayıları üzerindeki değişken etkisi ortaya koyulmuştur. Bu bulgular, "tüm alt kümeler benzer kalibrasyon değerleri üretir, dolayısıyla eyalet çapında tek tip büyüme hızı uygulanabilir" varsayımının geçersizliğini kanıtlamıştır.

Liang ve diğ. (2021), PLUS (Patch-generating Land Use Simulation) modelini sunmuşlardır. Bu model, Arazi Genişleme Analiz Stratejisi (Land Expansion Analysis Strategy - LEAS) kullanarak, geçmiş veriden Rassal Orman (Random Forest - RF) gibi tekniklerle arazi değişimine neden olan "sürücü" değişkenler arasındaki ilişkileri çıkarır (kural tabanlı madencilik). Ardından, çoklu arazi tipi dönüşümlerini simüle etmek için rastgele yama oluşturma ve büyütme mekanizmasını kullanır. Çin'in Wuhan kenti örneğinde yapılan bir çalışma, bu yaklaşımın kentsel genişlemenin

ardındaki sürdürülebilirlikle ilgili sürücü faktörleri başarıyla ayırttığı rapor edilmiştir. Ayrıca, modelin, FLUS gibi CA-melez modelleri ile karşılaştırıldığında, yama geometrisi ve mekânsal süreklilik ölçütlerinde daha üstün bir doğruluk performansı sergilediği belirtilmiştir. Geliştirilen çerçeve, hem sürücü değişkenlerin katkılarının açıklanabilirliğini hem de farklı koruma ve yoğunlaşma senaryolarının test edilebilmesini sağlayarak yenilikçi bir katkı sağlamıştır.

Aslam ve diğ. (2023) tarafından yürütülen araştırmada, Pakistan'ın dört önemli metropolitan bölgesinde 1990 ile 2020 yılları arasında gözlemlenen demografik dinamikler ve kentsel genişleme eğilimlerini, açık kaynaklı uzaktan algılama verileri ve Google Earth Engine altyapısından faydalanarak incelemiştir. Araştırma kapsamında uygulanan Smile CART algoritmasına dayalı sınıflandırma işlemi, %93'lük bir isabet oranına ulaşmış; ayrıca kentsel yayılımdaki artış ile nüfus yoğunluğu arasında doğrudan bir korelasyon olduğu tespit edilmiştir. Çalışma bulguları, hızlanan kentleşme sürecinin tarımsal arazi kullanımını önemli ölçüde daralttığına ve altyapı hizmetleri üzerinde ciddi bir yük oluşturduğuna işaret ederek, sürdürülebilir kent planlama stratejilerinin aciliyetini vurgulamaktadır. Sonuç olarak, uzaktan algılama ve makine öğrenmesi yöntemlerinin sinerjik bir şekilde entegrasyonunun, kentsel büyüme modellerinin ileriye dönük olarak yüksek bir doğruluk ile izlenebilmesi için kilit bir çerçeve sunmaktadır.

Zhang ve diğ. (2024) tarafından geliştirilen çalışma, kentsel arazi kullanım değişiminin tahmin doğruluğunu artırmak amacıyla Transformer mimarisi, evrişimli sinir ağları (CNN) ve hücreli otomat (HO) bileşenlerini entegre eden TC-CA adlı yeni bir hibrit model önermektedir. Önerilen model, mekânsal bağlamdaki özelliklerin çıkarımı için CNN katmanlarından, zamansal dizilerdeki uzun vadeli bağımlılıkların modellenmesi için ise Transformer bloklarından yararlanmakta; nihai simülasyon süreci ise CA çerçevesi üzerinden yürütülmektedir. Çin'in Wuxi kentinde, 2000, 2010 ve 2020 yıllarına ait arazi kullanım verileri kullanılarak gerçekleştirilen deneysel çalışmalar, TC-CA modelinin, CNN-CA, Rassal Orman-CA (RF-CA) ve Uzun Kısa-Vadeli Bellek Ağları-CA (LSTM-CA) gibi geleneksel hibrit yöntemler karşısında performans açısından belirgin bir üstünlük sağladığını ortaya koymaktadır. Özellikle, Başarı Oranı (Figure of Merit - FoM) metriğinde %2,85 ile %8,14 arasında gözlemlenen iyileşme, modelin kentsel genişlemenin hem yönünü hem de yoğunluk dağılımını tahmin etmede kayda değer bir avantaj sunduğu raporlanmıştır. Sunulan bu

bütünleşik yaklaşım, derin öğrenme ile mekânsal dinamik simülasyon teknikleri gelişimini vurgulayarak, kentsel büyüme projeksiyonları alanına metodolojik açıdan yenilikçi bir çerçeve kazandırmaktadır.

Bu kısma kadar olan çalışmalar kentsel büyüme literatüründe yer alan çalışmaları kapsamaktaydı. Aşağıdaki 4 çalışma ise kentsel büyüme tahmini yapmamış olup Arazi Kullanım ve Arazi Örtüsü (LULC) tahmini için yapılmış daha çok sınıflama ağırlıklı çalışmalardır. Bu çalışmada kentsel büyüme tahmin problemi uzaktan algılama ve LULC tahmin problemi olarak ele alındığı için önerilen modele örnek teşkil eden çalışmalara yer verilmiştir.

He ve Jiang (2021), yüksek çözünürlüklü uydu görüntülerinden bina çıkarımı yapmak amacıyla CBAM destekli bir Tam Evrişimli Ağ (FCN) mimarisi önermişlerdir. Önerilen yaklaşım, kanal ve mekânsal dikkat mekanizmalarını bir arada kullanarak, bina sınırları ve çatı çizgilerinin ince detayların korunmasını sağlamakta ve özellikle kenar bölgelerinde oluşan hataları minimize etmektedir. Yöntem, WHU Building ve Inria Aerial veri setleri üzerinde test edilmiş ve bina sınır tespitinde F1 skorunun yükseldiği gözlemlenmiştir. Bu bulgular, CBAM tabanlı dikkat mekanizmalarının, kentsel ortamlardaki yapıların hassas bir şekilde segmentasyonu ve çıkarımı için güçlü bir araç olduğunu ve mevcut zorlukların üstesinden gelmede önemli bir potansiyele sahip olduğunu ortaya koymaktadır.

Zhang ve diğ. (2023) tarafından gerçekleştirilen çalışma, çok kaynaklı optik ve sentetik açıklıklı radar (SAR) verilerinin sinerjistik kullanımıyla arazi örtüsü sınıflandırma doğruluğunu artırmayı amaçlayan gelişmiş bir U-Net mimarisi önermektedir. Önerilen model, konvolüsyonel katmanlara ek olarak, hem kanal hem de mekânsal boyutta odaklanma yeteneği sunan Evrişimli Blok Dikkat Mekanizması (CBAM) entegrasyonu sayesinde spektral ve mekânsal bilgileri eşzamanlı ve etkin bir biçimde işleyebilmektedir. Bu tasarım, farklı veri kaynakları arasındaki tamamlayıcı özelliklerin bütünleşik bir çerçevede değerlendirilmesine olanak tanımaktadır. Deneysel çalışmalar, modelin heterojen veri kümeleri üzerinde sınıflandırma performansını kayda değer ölçüde iyileştirdiği raporlanmıştır. Bu sonuçlar, özellikle farklı veri kaynaklarından elde edilen verilerin entegrasyonunun gerekli olduğu ve yüksek doğruluk gerektiren Arazi Kullanımı/Arazi Örtüsü (LULC) sınıflandırma uygulamaları için önemli bir metodolojik ilerleme sunmaktadır.

Song ve diğ. (2024), ConvNeXt tabanlı bir derin öğrenme mimarisine CBAM dikkat modüllerini entegre ederek arazi örtüsü sınıflandırma performansını iyileştirmeyi hedefleyen yenilikçi bir yaklaşım sunmaktadır. Geliştirilen model, yakın kızılötesi bantlardan elde edilen spektral bilgilerin CBAM blokları vasıtasıyla gelişmiş bir şekilde işlenmesi sayesinde, spektral olarak birbirine yakın sınıflar arasındaki ayrımın güçlendirmiş ve sınıflandırma doğruluğunda belirgin bir artışa yol açtığı rapor edilmiştir. Elde edilen deneysel bulgular, modelin LULC sınıflandırması için mIoU metriğinde artışını ortaya koymakta; özellikle bitki örtüsü ve yapay yüzeyler gibi spektral olarak ayırt edilmesi zor olan sınıfların ayrımında yüksek bir güvenilirlik sergilediğini kanıtladığı vurgulanmıştır.

Liu ve diğ. (2025), karmaşık tarım arazisi manzaralarında sınır tespiti doğruluğunu artırmak amacıyla ConvNeXt-U adını verdikleri hafif bir derin öğrenme mimarisi tasarlamışlardır. Model, U-Net'in kodlayıcı-kod çözücü yapısının verimliliğini korurken, CBAM dikkat mekanizmalarının entegrasyonu ile özellikle arazi sınırları ve heterojen parseller gibi kritik bölgelerdeki özellik çıkarımını güçlendirdiği. Bu sayede, parçalı yapıdaki tarım arazilerinde daha hassas sınırlamalar yapılabildiği rapor edilmiştir. Gaofen-2 uydusundan elde edilen yüksek çözünürlüklü görüntüler üzerinde yapılan testler, modelin IoU (Kesişim Üzerine Birlik) metriğinde iyileşme sağladığını göstermiştir. Bu sonuç, hafif mimarilerle tasarlanmış olsa dahi, dikkat mekanizmalarının sınır belirleme ve nesne çıkarımı doğruluğuna önemli katkılar sunabileceği vurgulanmıştır.

### 3. KENTSEL BÜYÜME MODELİ

Bu bölümde, kentsel alanların gelecekteki büyüme ve dönüşüm dinamiklerini öngörebilecek hesaplamalı bir yöntem sunulmaktadır. Kentsel büyümenin tahmin edilmesi, yerleşim alanlarının hem zamansal hem de mekânsal değişimini modelleyerek planlama süreçlerine veri odaklı öngörüler kazandırmayı amaçlar.

Bu tezde “kentsel büyüme”den kastedilen, fiziksel/mekânsal büyümedir: Yerleşik alanların yayılması, yeni yapılaşma adalarının oluşması, mevcut kentsel dokunun yoğunluk ve biçim değiştirmesi ile bu dokunun çevresindeki kırsal alanlara doğru genişlemesidir. Başka bir deyişle; nüfus, ekonomi ya da yönetim gibi soyut göstergeler dolaylı olarak dikkate alınsa da modelin odak noktası kentin mekânsal makroformunun zamana bağlı değişimlerinin yakalanmasıdır.

Kentsel büyüme modelleri genellikle mekânsal istatistik, uzaktan algılama ve makine öğrenmesi tekniklerinin harmanlanmasıyla inşa edilir. Özellikle son yıllarda, geçmiş dönemlere ait uydu görüntülerinden türetilen arazi örtüsü, yerleşim yoğunluğu, yol ağları ve topoğrafya gibi katmanlar modelin temel bileşenleri hâline gelmiştir.

Kentsel büyüme ve kent makroformu durağan değildir. Bu sebeple kentsel büyüme sürecinin dinamik bir perspektifle ele alınması gereklidir. Dolayısıyla kentin geçmişten günümüze nasıl değiştiğinin çözümlemesi, geleceğe yönelik tahminlerin sağlıklı kurulabilmesi için ön koşuldur. Bu dinamik bakış açısı doğrultusunda çalışmada zaman serisi yaklaşımı benimsenmiştir. Çok katmanlı veri yapısı içinde her bir katmanın (örneğin yapılaşmış alan, yeşil alan, ulaşım altyapısı vb.) yıllar içindeki değişimi izlenmiş; bu değişimlerin birbirleriyle olan mekânsal bağımlılıkları değerlendirilerek modellemenin temeli oluşturulmuştur.

Zaman serisi yaklaşımları, söz konusu çok katmanlı verinin yıllık ya da dönemsel değişimini takip ederek hem mekânsal bağımlılıkları hem de zaman içindeki eğilimleri yakalamayı mümkün kılar. Böylece model, yalnızca “nerede büyüme oldu?” sorusuna değil, “hangi dinamikler ne şekilde büyümeyi tetikliyor?” sorusuna da yanıt verebilecek bir çerçeve sunar.

Bu tez kapsamında kentsel büyümenin tahmin edilmesi için çalışma alanı olarak Konya kenti seçilmiştir. Konya'nın tercih edilmesinin başlıca nedenleri şunlardır:

- **Hızlı gelişen bir kent olması:** Son yıllarda nüfus, sanayi ve hizmet sektörlerinde görülen artış, kentsel yayılmayı hızlandırmaktadır.
- **Doğal sınırlayıcıların net olmaması:** Deniz, dağ silsileleri ya da büyük su kütleleri gibi sert coğrafi engellerin sınırlı olması, yayılmanın yön ve biçimini daha çok sosyoekonomik etkenlere bırakmaktadır.
- **Dinamiklerinin hızlı değişmesi:** Ekonomik yapının çeşitlenmesi ve yeni ulaşım yatırımları kentin büyüme eksenlerini sık aralıklarla değiştirebilmektedir.
- **Kent-kır bağlantısının yoğunluğu:** Tarımsal üretimle kentsel tüketim ilişkileri güçlüdür; bu da geçiş bölgelerinde karma kullanımlı, parçalı bir arazi kullanım desenine yol açmaktadır.
- **Çeşitli ekonomik fonksiyonları bir arada barındırması:** Konya, aynı anda kırsal üretim, sanayi, hizmet ve ticaret faaliyetlerini içeren çok katmanlı bir ekonomik yapıya sahiptir; bu çeşitlilik farklı büyüme tiplerinin (sıçrama, dolgu, koridor boyunca yayılma vb.) birlikte gözlenmesine imkân tanır.


Bu özellikler, Konya'yı hem yöntemsel olarak zengin bir test alanı hâline getirmekte hem de modelin genellenebilirliğini değerlendirmek için uygun bir zemin sunmaktadır.

Bölümün ilerleyen kısımlarında, çalışma alanı (3.1), veri kaynakları (3.2), veri hazırlığı (3.3), derin öğrenme modeli ve eğitim (3.4) ardından model değerlendirme ve mekânsal dikkat (3.5) ayrıntılı şekilde ele alınacaktır.

### 3.1 Çalışma Alanı

Bu tezde çalışma alanı, Konya kent merkezini oluşturan üç büyükşehir merkez ilçesi Karatay, Meram ve Selçuklu ve bu ilçelerin bir kısım mücavir alanlarını da kapsayan bir alan belirlenmiştir (Şekil 3.2). Konya, 20 Haziran 1987 tarihli 3399 sayılı Kanun ile büyükşehir statüsü kazanmış; 12 Kasım 2012 tarihli 6360 sayılı Kanun sonrasında büyükşehir belediye sınırı il mülki sınırı olmuştur. Böylece kent ile kırsal alanlar arasındaki idari ayırım yeniden tanımlanmıştır. Merkez ilçelerde resmî kayıtlı mahalle

sayıları Selçuklu'da 72, Meram'da 69, Karatay'da 63 olup toplam 204 mahalle bulunmaktadır.



**Şekil 3.2:** Çalışma Alan Konumu

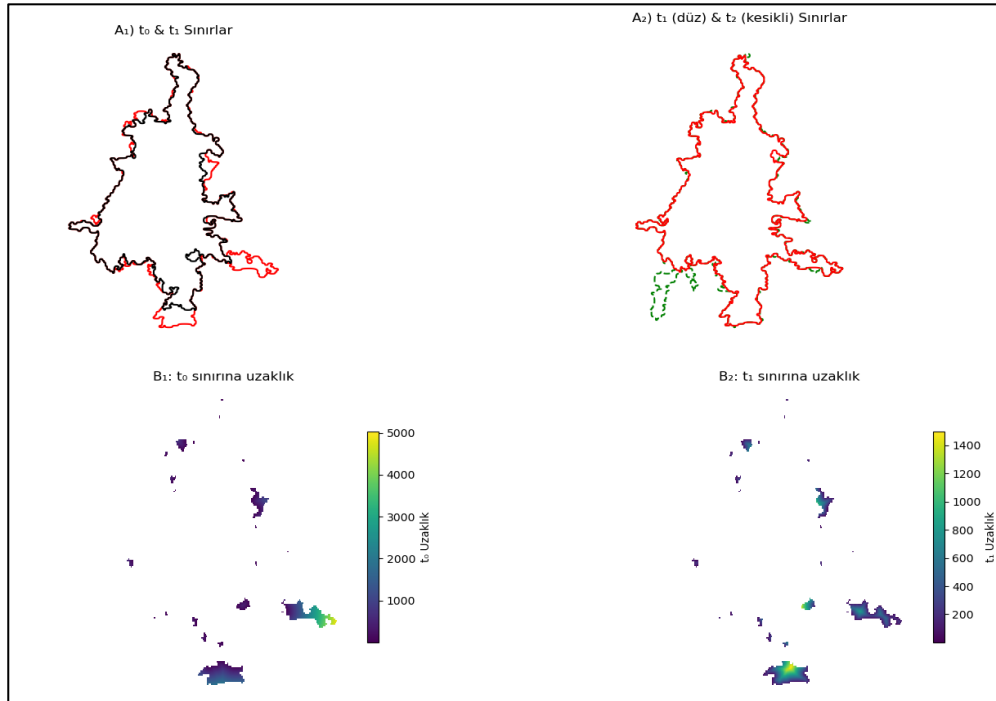
TÜİK'in ADNKS 2023 sonuçlarına göre merkez ilçelerde nüfus Selçuklu'da 695.771, Karatay'da 375.919, Meram'da 347.341 kişidir; üç ilçe toplamda yaklaşık 1,42 milyon kişi barındırmaktadır.

Kent merkezi, İç Anadolu'nun geniş alüvyal düzlüklerinden Konya Ovası üzerinde, ortalama 1000 m yükseltide yer alır; alanın büyük kısmı düşük eğimli düzlüktür. Batıda dağlık alanlarla ova arasında belirgin bir morfolojik kırık zonu (Konya fay zonu) bulunur. Tarihsel çekirdek Alaeddin Tepesi çevresinde şekillenmiş, yeni yerleşim ve sanayi alanları ovaya doğru yayılmıştır.

Neolitik döneme (Çatalhöyük) uzanan yerleşim izleriyle Anadolu'nun en eski kentleşme odaklarından biri olan Konya, 11. ve 13. yüzyıllar arasında Anadolu Selçuklu Devleti'ne başkentlik yapmıştır. Osmanlı döneminde bölgesel idari merkez niteliğini korumuş, 19. yüzyılda demiryolu (1896) sonrasında yapılan organize sanayi bölgeleri ve yüksek hızlı tren gibi altyapı yatırımlarıyla büyüme eksenleri şekillenmiştir.

Şekil-3.3'te yer alan büyüme analizinde uzaktan algılama sistemlerinden elde edilen veriler ile kent makroformunun oluşturduğu kentsel yamaların içerisinde kesintisiz (sıçrama olmadan) en büyük alan baz alınarak kentsel büyüme sınırı (UGB) çıkartılmış

ve bu şekilde Konya kentinin büyümesi incelenmiştir. Konya kentsel büyüme sınırlarında 1990-2010 arasında kentin güney ve doğusundaki kent çeperlerinde belirli yol akslarında büyüme gösterdiği tespit edilmiştir. 2010-2020 döneminde ise kent makroformunun önceki döneme göre kısıtlı bir büyüme gösterdiği görülmektedir. Kentin doğusundaki 1990-2010 arasındaki büyüme akslarında daha kısıtlı bir büyüme olduğu 2010-2020 arasındaki dönemdeki asıl büyüme yönlerinin kentin güney batısında ve sıçramalı bir büyüme ile karşılaştığı tespit edilmiştir. Bu sıçramalı büyüme alanında toplu konutların olduğu saha incelemelerinde tespit edilmiştir. Sonuç olarak Konya kentinin radyal büyümeden ziyade saçaklanma ve bazı bölgelerde sıçrama benzeri bir büyüme gösterdiği anlaşılmaktadır.



**Şekil 3.3:** Konya 1990 ( $t_0$ ), 2010( $t_1$ ) ve 2020 ( $t_2$ ) yıllarındaki kentsel büyüme sınırları ve büyüme mesafeleri

Konya il merkezinde başlıca iki sorundan bahsedildiği görülmektedir:

- **Kuraklık, yeraltı suyu azalması ve obruk riski:** Konya Kapalı Havzası'nda yoğun yeraltı suyu (belgeli ve kaçak kuyu) kullanımı nedeniyle statik su seviyesi her yıl yaklaşık 1–3 m düşmektedir.<sup>2</sup> Bu durum kuraklık riskini artırmakta ve obruk oluşumlarını tetiklemektedir.
- **Kentsel yayılma ve tarım arazisi kaybı:** 1950'lerden sonra hızlanan büyüme sürecinde özellikle 1970'ler sonrasında yaklaşık 15.000 ha verimli tarım arazisi yapılaşmaya açılmıştır. Bu kayıp, modelde kırsal-kentsel geçiş dinamiklerinin kritik önemini doğrulamaktadır.

Konya kent merkezinin;

- kentsel makroform açısından özellikle tarım arazilerine doğru hızlı yayılma göstermesi
- sanayi, hizmet, ticaret, tarım ve konut fonksiyonlarının birbirinin içine geçmiş ve eşine az rastlanacak şekilde net bir sınırla birbirinden ayrılamaması gibi karmaşık bir mekânsal ilişkiye sahip olması

çalışma alanı olarak belirlenmesinde etkili olmuştur. Önerilen kentsel büyüme tahmin modelinin, bu zorlukları barındıran bir çalışma alanında yaptığı başarılı tahminler iyi bir performans göstergesi olacaktır.

### 3.2 Veri Kaynakları

Bu çalışmada kentsel büyüme tahmini modelinde kullanmak amacıyla, Konya ili genelinde hem mekânsal hem de zamansal çeşitliliği yüksek veri seti oluşturulmuştur. Veri toplama aşamasında ağırlıklı olarak Google Earth Engine (GEE) platformu üzerinden erişilebilen raster ve vektör formatında dağıtılan kaynaklar tercih edilmiştir.

Uzaktan algılama verilerinde en temel verilerden Landsat gibi projelerin uydularından elde edilen görüntüler; bulut maskesi, atmosferik düzeltme ve mozaikleme gibi

---

<sup>2</sup> [https://www.tarimorman.gov.tr/SYGM/Belgeler/KURAKLIK YÖNETİM PLANLARI](https://www.tarimorman.gov.tr/SYGM/Belgeler/KURAKLIK_YONETIM_PLANLARI)  
09.01.2023/Kuzey Ege Havzası Kuraklık Yönetim Planı Yönetici Özeti.pdf

kapsamlı ön işlemler gerektirmektedir. Bu projelerde uydu alt sistemlerindeki teknolojiler geliştikçe farklı yıllardaki verilerde tahmin modelleri açısından sınıflandırma tutarlılığını bozma riski ortaya çıkmaktadır. Bu sebeple yapılan sınıflandırmaların güvenilir saha doğrulaması, farklı teknolojili sensörlerden alınan verinin kıyaslanabilir hale getirilmesi gibi yüksek maliyetli yöntemlerle desteklenmesi gerekmektedir. Bu nedenle, özellikle arazi sınıflarına ait düzenli zaman serisi elde etmek için karmaşık ön işlemlerden, yöntem uyumsuzluklarından ve ağır hesaplama yükünden kaçınmak; Birleşmiş Milletler, ESA, JRC ortak protokollerine uygun hazır katman elde etmek amacıyla GLC-FCS30D veri setleri tercih edilmiştir. Model eğitiminde kullanılan tüm veri tabanları aşağıda sıralanmıştır:

### **DEM Verisi - Shuttle Radar Topography Mission (SRTMGL1\_003)**

Bu veri kümesi, Şubat 2000'de NASA JPL tarafından uçuşla elde edilen SRTM ölçümlerinden türetilmiş, her bir 30 m × 30 m hücre için metre cinsinden mutlak yükseklik değerlerini sağlar.<sup>3</sup> Bu çalışmada modele girdi olan eğim (slope) ve bakı (aspect) katmanlarının üretilmesi için bu veri tabanı kullanılmıştır.

### **Küresel Yollar Veritabanı (GRIP4)**

Küresel Yol Envanteri Projesi kapsamında birçok farklı kaynağa (OpenStreetMap dahil) dayanan Bu vektörel veri kümesi, küresel çevre ve biyoçeşitlilik değerlendirme modellerinde kullanılmak üzere güncel ve tutarlı bir küresel yol veri seti sağlamak amacıyla geliştirilmiştir.<sup>4</sup>

### **Global Su Yüzeyi Verisi (JRC Global Surface Water v1.2)**

Landsat görüntülerinden türetilen bu veri kümesi Avrupa Komisyonu Ortak Araştırma Merkezi (JRC) tarafından geliştirilmiş, küresel ölçekte su yüzeyi değişimlerini izleyen bir kaynaktır. Bu veri seti, 1984'ten günümüze kadar olan uydu görüntülerini analiz

---

<sup>3</sup> [https://developers.google.com/earth-engine/datasets/catalog/USGS\\_SRTMGL1\\_003](https://developers.google.com/earth-engine/datasets/catalog/USGS_SRTMGL1_003)

<sup>4</sup> <https://gee-community-catalog.org/projects/grip/>

ederek su yüzeylerinin varlığını, mevsimselliğini ve değişimlerini 30 metre çözünürlükte haritalandırır.<sup>5</sup>

### **Gece Işıkları Veri Seti - NPP-VIIRS (1992–2023)**

Global ölçekte 1992–2023 yılları arasında kesintisiz gece ışıkları verisi sunan bu veri seti, DMSP-OLS ve NPP-VIIRS sensörlerinden elde edilen ham ışık verilerini U-Net tabanlı makine öğrenmesi yöntemiyle NPP-VIIRS benzeri yıllık ürünler üretir. Yaklaşık 500 m mekânsal çözünürlükte ve küresel kapsama alanı (–180° ila 180° boylam, –65° ila 75° enlem) sağlayan bu sıkıştırılmış COG formatındaki koleksiyon; kentsel yayılma, ekonomik büyüme ve çevresel analiz gibi pek çok uygulama için uygundur.<sup>6</sup>

2000, 2005, 2010 ve 2015 yıllarına ait veriler doğrudan model girdisi olarak kullanılmış herhangi bir interpolasyon gerek duyulmamıştır.

### **GHSL - Global built-up surface 1975-2030 (P2023A)**

Bu raster veri kümesi, yapılaşmış alanların olasılıksal dağılımını vermektedir. 1975 ile 2030 yılları arasında 5 yıllık aralıklarla mekânsal ve zamansal olarak ara doldurulur veya tahmin edilir.<sup>7</sup>

Bu çalışmada, 100 m çözünürlüğündeki bu katmandaki yapılaşma (built-up) yüzey değerleri %50 eşiğine göre ikili maskelere dönüştürülerek 2000, 2005, 2010 ve 2015 için ayrı yapılaşma rasterları üretilmiştir.

### **Arazi Kullanım/Örtüsü Verisi (GLC-FCS30D)**

GLC-FCS30D, 1985–2022 dönemini kapsayan ve küresel ölçekte 30 m çözünürlükte kara örtüsü değişimini izleyen ilk üründür. Landsat arşivine dayalı sürekli değişim tespiti (continuous change detection) yöntemleriyle üretilen bu veri seti; 2000 öncesi beşer yıllık dilimler (1985–1990, 1990–1995, 1995–2000) ve 2000’den itibaren yıllık

---

<sup>5</sup> <https://global-surface-water.appspot.com/download>

<sup>6</sup> [https://gee-community-catalog.org/projects/srunet\\_npp\\_viirs\\_ntl/?h=net+npp+viirs](https://gee-community-catalog.org/projects/srunet_npp_viirs_ntl/?h=net+npp+viirs)

<sup>7</sup> [https://humansettlement.emergency.copernicus.eu/documents/GHSL\\_Data\\_Package\\_2023.pdf?t=1683540422](https://humansettlement.emergency.copernicus.eu/documents/GHSL_Data_Package_2023.pdf?t=1683540422)

katmanlar olmak üzere toplam 26 zaman adımı sunar. Veri seti, 35 ince sınıflı arazi örtüsü alt kategorisi içerir.<sup>8</sup>

Çalışmada 2000, 2005, 2010 ve 2015 yılı verileri modele girdi olarak, 2020 yılına ait veri ise geçirimsiz yüzeyler “Impervious surfaces” filtrelenerek model tahmini için kullanılmıştır.

### **Landsat Surface Reflectance (SR) Koleksiyonu**

Bu veri kümesi, Landsat TM sensörü tarafından üretilen verilerden türetilen atmosferik olarak düzeltilmiş yüzey yansımaları ve arazi yüzey sıcaklığını içerir. Bu görüntüler, ortorektif yüzey yansımaları olacak şekilde işlenmiş 4 adet görünür bant, yakın kızılötesi (VNIR) bandı, termal kızılötesi (TIR) bandı ve 2 kısa dalga kızılötesi (SWIR) bandı içerir.<sup>9</sup>

Çalışmada 2013 yılı öncesinde Landsat-8 uydusu olmadığından 2000, 2005 ve 2010 Landsat-5 uydusuna ait **LANDSAT/LT05/C02/T1\_L2** verisi ile 2015 verisi için **LANDSAT/LC08/C02/T1\_L2** verisi kullanılmıştır. Landsat verilerinde mozaikleme uygulanmıştır. Bu sayede en az bulutlu sahnelerden başlanarak her bir piksel için bir yıl boyunca en az bulutlu veriler medyan değeri alınarak bulut lekeleri ve eksik veri problemleri aşılmıştır.

### **3.3 Veri Hazırlığı**

Bu aşamada, modelin girdi olacak bütün veri katmanlarının düzenlenmesi, ön işleme tabii tutulması ve nihai formatlara aktarılması işlemleri tamamlanmıştır. Veri setlerinin hazırlanması süreci, sadece ham verilerin temin edilmesinden ibaret olmayıp, açık kaynaklardan sağlanan katmanların tek bir mekânsal koordinat sistemine entegre edilmesi, ölçek uyumluluğunun temini ve nihayetinde modelin beklediği girdi yapısına dönüştürülmeleri gibi faaliyetleri kapsamaktadır.

Araştırmada faydalanılan katmanlar, iki temel kategoride incelenmiştir:

---

<sup>8</sup> [https://gee-community-catalog.org/projects/glc\\_fcs/?h=glc+fcs30d](https://gee-community-catalog.org/projects/glc_fcs/?h=glc+fcs30d)

<sup>9</sup> [https://developers.google.com/earth-engine/datasets/catalog/LANDSAT\\_LT05\\_C02\\_T1\\_L2](https://developers.google.com/earth-engine/datasets/catalog/LANDSAT_LT05_C02_T1_L2)

- **Statik Katmanlar:** Zamana bağılı olarak değişim göstermeyen ve tüm çalışma sahası üzerinde değişmez kalan unsurlardan oluşmaktadır (örneğin, eğim, baki, yüzey dalgalanması, ulaşım ağları–kent merkezi–su yollarına olan mesafe gibi).
- **Zaman Serisi Katmanları:** Zaman serisi şeklinde temin edilen ve kentsel yayılmayı doğrudan yansıtan veri kümeleridir (örneğin, Normalleştirilmiş Bitki Örtüsü İndeksi (NDVI), Normalleştirilmiş Yapılaşma İndeksi (NDBI), Normalleştirilmiş Su İndeksi (NDWI), arazi kullanımı/örtüsü, gece ışık yoğunluğu ve yapılaşmış alan maskeleri).

Yapılan bu sınıflandırma, modelin mekânsal ve zamansal boyutları aynı anda işleyebilme kapasitesine katkı sağlamıştır. Statik katmanlar çevresel ve topografik kesit verileri temsil ederken, zaman serisi katmanları kentsel büyümenin zaman içindeki seyirini ve dinamiklerini anlamada kilit bir rol oynamaktadır.

Veri temininde idari birim sınırları kullanılmamış olup, uzaktan algılama teknikleriyle üretilen raster ve vektör tabanlı veriler ana kaynak olarak belirlenmiştir. Bu yaklaşım, modelin idari birim ve sınırlardan bağımsız olarak mekânsal yapılaşma dokusunun bütüncül bir şekilde analiz edilmesine imkân tanımıştır. Sonuç olarak, Konya kentinde toplanan veriler, herhangi bir yapay idari sınır olmaksızın, doğal dinamiği ile modele aktarılmıştır.

Tüm veri kümelerinin tek bir mekânsal çerçevede işlenebilmesi amacıyla projeksiyon ve mekânsal çözünürlük uyumlulaştırması gerçekleştirilmiştir. Raster veriler, EPSG:4326 koordinat sistemine dönüştürülmüş ve 30x30 metrelik hücre boyutuna yeniden ölçeklendirilmiştir. Bu işlem, farklı çözünürlüklere sahip veri setlerinin (örneğin, 30 m çözünürlüklü Landsat uydu görüntüleri ve 500 m'lik gece ışıkları verisi) aynı koordinat düzleminde hizalanabilmesi sağlanmıştır. Hücre boyutlarının uyumsuz olması durumunda, piksel tabanlı örtüşme sağlanamayacak ve modelin öğrenme sürecinde önemli hatalar ortaya çıkacaktır. Bu sebeple, tüm katmanlar yeniden örnekleme teknikleri kullanılarak ortak bir çözünürlüğe getirilmiş ve her bir pikselin aynı fiziksel alanı temsil etmesi güvence altına alınmıştır.

Takip eden aşamada, veri setleri model tarafından doğrudan kullanılacak bir formata dönüştürülmüştür. Farklı bantlara ait değer aralıklarının standart hale getirilmesi için normalizasyon (0-1 arası ölçekleme) işlemi uygulanmış, ardından

kayan pencere tekniđi kullanılarak örtüşmeli yamalar (patches) üretilmiştir. Yama oluşturma stratejisi olarak, hem örtüşen hem de birbirinden bağımsız konumlardaki pikseller dahil edilmiştir. Bu sayede model, aynı mekânsal örüntünün farklı varyasyonlarını gözlemleyebilmiş ve veri kümesinin hacminin genişletilmesi yoluyla aşırı öğrenme riski minimize edilmiştir.

Özetle, veri hazırlama işlemleri şu adımlardan oluşmaktadır:

- Tüm katmanların yeniden projeksiyon ve kırpma işlemleriyle ortak bir coğrafi referans sistemine alınması,
- Sabit ve deđişken nitelikteki katmanların tanımlanması ve ayrı ayrı işlenmesi,
- Hücre boyutu uyumlulaştırması vasıtasıyla piksel bazlı çakışmanın temini,
- Eksik deđerlerin doldurulması ve veri normalizasyonunun uygulanması,
- Pencere kaydırma tekniđi ile yama üretimi ve bunların eğitim, dođrulama ve test alt kümelerine ayrılması.

Bu kapsamlı işlemler sonucunda, kentsel gelişim tahmin modeli için girdi olarak kullanıma hazır, tutarlı, standardize edilmiş ve çok boyutlu bir veri seti türetilmiştir.

### 3.3.1 Uydu verilerinden indekslerin oluşturulması

Landsat uydu görüntülerinden elde edilen bantlar kullanılarak üç temel spektral indeks (NDVI, NDBI, NDWI) hesaplanmıştır. İndeksler, yıllık bulutsuz median kompozit görüntüler üzerinden, her hedef yıl için hesaplanmıştır.

2000, 2005 ve 2010 yılları için Landsat 5 Collection 2 Level-2 ve 2015 için Landsat 8 Collection 2 Level-2 veri seti alınmıştır. Bulut ve gölge maskesi işlemleri, her görüntüdeki *QA\_PIXEL* bandındaki bulut ile gölge deđerleri filtrelenerek gerçekleştirilmiştir. Bu iki farklı veri setindeki bant deđerleri aynı deđerleri vermemektedir. Bu sebeple bant atamaları şu şekilde yapılmıştır:

- Landsat 5 görüntülerinde Yakın Kıızılötesi (NIR) bandı SR\_B4, kırmızı bant SR\_B3, Kısa Dalga Kıızılötesi (SWIR) bandı SR\_B5 ve yeşil bant SR\_B2;
- Landsat 8 görüntülerinde ise Yakın Kıızılötesi (NIR) bandı SR\_B5, kırmızı bant SR\_B4, Kısa Dalga Kıızılötesi (SWIR) bandı SR\_B6 ve yeşil bant SR\_B3 olarak tanımlanmıştır.

### NDVI (Normalleştirilmiş Fark Bitki Örtüsü İndeksi):

Bitki örtüsünün sağlığını ve yoğunluğunu ölçer; değer aralığı -1 ile +1 arasındadır. Yüksek pozitif değerler sık ve sağlıklı bitki örtüsünü, düşük veya negatif değerler ise toprak, kaya veya su yüzeyini işaret eder.

$$NDVI = \frac{\text{Yakın Kızılötesi} - \text{Kırmızı}}{\text{Yakın Kızılötesi} + \text{Kırmızı}}$$

#### **NDBI (Normalleştirilmiş Fark Yapılaşma İndeksi):**

Yapılaşmış (beton, asfalt vb.) yüzeyleri ayırt eder; yüksek pozitif değerler yoğun yapılaşmayı, negatif değerler doğal yüzeyleri gösterir.

$$NDBI = \frac{\text{Kısa Dalga Kızılötesi} - \text{Yakın Kızılötesi}}{\text{Kısa Dalga Kızılötesi} + \text{Yakın Kızılötesi}}$$

#### **NDWI (Normalleştirilmiş Fark Su İndeksi):**

Yüzeydeki su varlığını algılar; pozitif değerler su kütlelerini, negatif değerler su içermeyen bölgeleri işaret eder.

$$NDWI = \frac{\text{Yeşil} - \text{Yakın Kızılötesi}}{\text{Yeşil} + \text{Yakın Kızılötesi}}$$


### **3.3.2 Arazi Kullanım/Örtüsü sınıf azaltma**

GLC\_FCS30D veri setinde Konya merkezinde belirlenen analiz alanında 29 arazi kullanım sınıfı olduğu tespit edilmiştir. Bu çeşitlilik, oluşturulan tahmin modeli açısından zaman içinde yapılaşmış alan (impervious surface) dinamiklerini ve diğer sınıflardan dönüşüm potansiyelini izlemeyi güçleştirebilmektedir. Model eğitimi sırasında sınıf sayısının fazlalığı eğitim süresini ve hesaplama maliyetini önemli ölçüde artırmakta, modelin zamansal değişimi öğrenmesi aşamasında modelin kararlılığını düşürebilmektedir. Bu zorlukların üstesinden gelmek amacıyla, arazi kullanım sınıfları geçiş olasılıklarına dayalı olarak dört ana kategoriye indirgenmiştir.

Bu indirgeme için öncelikle 2000 ve 2020 yıllarına ait arazi kullanım katmanları her piksel için eşleştirilmiş; bu piksellerdeki orijinal sınıf kodları arasındaki değişimler için geçiş matrisi oluşturulmuştur. Geçiş olasılıkları

$$P(i \rightarrow j) = \frac{N_{ij}}{\sum_k N_{ik}}$$

formülü ile hesaplanmış olup, bu matris sıcaklık haritası yöntemiyle görselleştirilerek incelenmiştir (Şekil 3.4).



**Şekil 3.4:** 2000 yılından 2020'ye sınıf geçiş matrisi ısı haritası

Bu matriste 2020 yılına ait “yapılaşma” (impervious surface) koduna sahip hücreler filtrelenerek 2000 yılından hangi sınıfların bu sınıfa dönüştüğü belirlenmiş ve piksel sayısından hareketle geçiş olasılığı hesaplanmıştır. Bu sınıflar içerisinde yapılaşmış alan çıkartılarak 2000 yılında yapılaşmış alan olmayan sınıfların geçiş ağırlıkları oransal olarak da belirlenmiştir. (Çizelge 3.1.)

**Çizelge 3.1:** Yapılaşmış Alan'a dönüşme olasılığına göre ilk 10 arazi sınıfı.

<i>Sınıf Kodu</i>	<i>Sınıf Adı</i>	<i>Geçiş Olasılığı</i>	<i>Oran %</i>
11	Otsu örtülü tarım arazisi	0.189644	57.87
130	Çayır / mera	0.043978	13.42
20	Sulanan tarım arazisi	0.033354	10.17
200	Çıplak alanlar	0.030610	9.34
153	Seyrek otsu örtü (örtü<0,15)	0.009941	3.03
10	Yağmurla beslenen tarım arazisi	0.009634	2.94
150	Seyrek bitki örtüsü (örtü<0,15)	0.006208	1.89
12	Ağaç veya çalı örtülü tarım	0.002076	0.63
120	Çalılık	0.000905	0.27
152	Seyrek çalılık (örtü<0,15)	0.000380	0.11

Bu olasılıklara göre 2020 yılında yapılaşmış alana yani 190 koduna dönüşmüş olan sınıflar yüksek olasılıktan düşük olasılığa doğru sırasıyla; Otsu örtülü tarım arazisi , Çayır / mera, Sulanan tarım arazisi, Çıplak alanlar, Seyrek (%15'ten az) otsu örtü, Yağmurla beslenen tarım arazisi, Seyrek (%15'ten az) bitki örtüsü, Ağaç veya çalı örtülü tarım arazisi, Çalılık ve Seyrek (%15'ten az) çalılık sınıflarından oluşmaktadır.

Geçiş olasılıklarına ilişkin analiz sonucunda, her orijinal sınıf için dönüşüm potansiyeli eşikleri;

- Yüksek Potansiyel:  $P > 0,03$
- Orta Potansiyel:  $0,005 \leq P \leq 0,03$
- Düşük Potansiyel:  $P < 0,005$


olmak üzere 3 kategoriye ayrılmıştır.

Böylece, orijinal 29 sınıf; yüksek potansiyel sınıflar (1), orta potansiyel sınıflar (2), düşük potansiyel sınıflar (3) ve doğrudan yapılaşmış alan sınıfı (4) olarak 4 katogerede ifade edilmiştir.


Arazi sınıf katmanları yeniden sınıflandırma yöntemiyle yeni raster görüntüler elde edilmiştir (Şekil 3.5). Bu sınıflandırma sonucunda elde edilen yeni katmanlar ile modelin öğrenme karmaşıklığından ve sınıf dengesizliğinden oluşacak sorunların aşılması sağlanmıştır (Çizelge 3.2).

**Çizelge 3.2:** Arazi sınıfları ve yeniden sınıflandırma sonucu oluşan sınıflar.

<i>Sınıf Kodu</i>	<i>Sınıf Adı</i>	<i>Yeni Sınıf</i>
190	Geçirimsiz Yüzey (Yapılaşmış alan)	4
11	Otsu örtülü tarım arazisi	1
130	Çayır / mera	1
20	Sulanan tarım arazisi	1
200	Çıplak alanlar	1
153	Seyrek otsu örtü (örtü<0,15)	2
10	Yağmurla beslenen tarım arazisi	2
150	Seyrek bitki örtüsü (örtü<0,15)	2
Diğer	Diğer Sınıflar	3



■ Yüksek Potansiyel   
 ■ Orta Potansiyel   
 ■ Düşük Potansiyel   
 ■ Yapılı Alan



**Yüksek Potansiyel:**

- Otsu örtülü tarım arazisi
- Çayır / mera
- Sulanan tarım arazisi
- Çıplak alanlar

**Orta Potansiyel:**

- Seyrek otsu örtü (örtü<0,15)
- Yağmurla beslenen tarım arazisi
- Seyrek bitki örtüsü (örtü<0,15)

**Düşük Potansiyel:**

*Diğer Sınıflar*

**Şekil 3.5:** Arazi kullanım sınıf azaltma sonucu oluşan yeni sınıf katmanları.

### 3.3.3 Arazi/Yükselik varyansı

Topografik yapının karmaşık doğasını ortaya koymada, Sayısal Yükselik Modeli (DEM), eğim ve bakı gibi geleneksel topoğrafik parametreler tek başlarına genellikle sınırlı bir açıklayıcılığa sahiptir. Bu durumun temel nedeni, benzer ortalama eğim değerlerine sahip olmalarına rağmen, iki farklı sahanın yüzey morfolojilerinin büyük farklılıklar gösterebilme durumudur. Örneğin, bir alan homojen ve düzgün bir topoğrafik eğilim sergilerken, bir diğer saha, engebeli bir topoğrafik karakter oluşturan çok sayıda yerel çukurluk ve kabarıklık içerebilir.

Söz konusu bu morfolojik ayrışmayı niceliksel olarak ortaya çıkarabilmek ve model performansını artırmak amacıyla, her bir pikselde, onu çevreleyen 3x3'lük piksel matrisi içerisindeki yükseklik değerlerinin istatistiksel dağılımı (varyans) türetilmiştir. Hesaplanan bu "yükseklik varyansı" metriği, arazi yüzeyinin pürüzlülük derecesini ve heterojen yapısını nicelleştiren, gelişmiş bir topoğrafik özellik katmanı sağlamaktadır. Söz konusu değişkenin tahmin modeline entegre edilmesindeki temel hedef, kentsel gelişim dinamiklerinin modellenmesi sürecinde, topoğrafik çeşitliliğin ve yüzey engebelerinin rolünün daha net bir biçimde modele aktarılmasını sağlamaktır.

### 3.3.4 Uzaklık katmanları

Çalışma alanında öznitelik barındıran her piksel için yollara (Ana yol ve Yan/Tali yol), şehir merkezine ve su yüzeylerine olan uzaklıklar hesaplanarak modele girdi olmak üzere dört farklı uzaklık katmanı elde edilmiştir.

#### **Yol uzaklıkları**

Küresel Yollar Veritabanı (GRIP4) GP\_RTP özniteliğine göre sınıflandırılmış ana (1–2) ve tali (3–4) yol aksları filtrelenerek öklid uzaklığı formülü ile çalışma alanında Ana Yol Uzaklığı ve Yan Yol Uzaklığı olmak üzere iki adet mesafe katmanı oluşturularak raster elde edilmiştir.

#### **Şehir merkezine uzaklık**

Kent merkezi kabul edilen odak nokta koordinatları belirlenmiştir. Çalışma alanında belirlenen bu noktaya göre tüm piksellerin bu noktaya olan mesafeleri öklid uzaklığı yöntemiyle hesaplanarak şehir merkezine uzaklık katmanı oluşturulmuştur.

### Su yüzeylerine uzaklık

Küresel Su Yüzeyleri (JRC Global Surface Water v1.2) Landsat görüntülerinden türetilmiştir. Çalışmada yüzeydeki su varlığını belirlemek için “occurrence” bandı kullanılmış, bu band üzerinden su maskesi oluşturulduktan sonra çalışma alanındaki her piksel için suya uzaklık raster katmanı üretilmiştir.

### 3.3.5 Model girdi katmanları

Veri katmanları, modelin zaman boyutunu yakalaması gereken dinamik (zaman serisi) katmanlar ve çalışma alanının zamana göre değişmeyen topografik ve mesafe bilgilerini içeren statik katmanlar olarak iki gruba ayrılır. Dinamik katmanlar 2000, 2005, 2010 ve 2015 yıllarına ait Landsat (NDVI, NDBI, NDWI) ve çeşitli veri tabanlarından (GLC-FCS30D arazi örtüsü, GHSL yapılaşmış alan ve VIIRS gece ışıkları) edinilen veri ile zaman serisi yapısına uygun hâle getirilmiştir. Statik katmanlar ise tek bir zaman dilimine ait eğim, bakı, arazi varyansı ve mesafe (ana yol, tali yol, şehir merkezi, su) katmanlarından oluşmaktadır (Çizelge 3.3).

**Çizelge 3.3:** Model eğitiminde girdi olarak kullanılan katmanlar.

Tip	Katman	Kaynak Veri
Statik	Eğim	SRTM 30 m (USGS)
	Bakı (Aspect)	SRTM 30 m (USGS)
	Arazi Varyansı	SRTM 30 m (USGS)
	Ana Yol Uzaklığı	GRIP4/Europe
	Yan Yol Uzaklığı	GRIP4/Europe
	Şehir Merkezi Uzaklığı	Kullanıcı Tarafından
	Suya Uzaklık	JRC Global Surface Water
Dinamik (Zaman Serisi)	NDVI	Landsat (yıllık mozaik)
	NDBI	Landsat (yıllık mozaik)
	NDWI	Landsat (yıllık mozaik)
	Arazi Kullanım/Örtüsü	ESA GLC-FCS30D
	GHSL Built-up	JRC
	Gece Işıkları (NTL)	VIIRS SVNL

### 3.3.6 Eksik veri işlemleri

Veri setine dâhil edilen katmanlarda, çeşitli kaynaklardan elde edilen eksik (no-data) pikseller bulunabilmektedir. Bu eksik değerler, model eğitim sürecindeki öğrenmeyi olumsuz etkileyebileceğinden, öncelikle eksik veri maskeleri oluşturulmuş ve analiz edilmiştir. Çalışmada, eksik pikseller için dolgu yöntemi olarak sıfır atama tercih edilmiştir; bu yöntemle no-data değerler, sayısal olarak etkisiz bir değer olan sıfıra dönüştürülerek modelin öğrenme safhasında istatistiksel sapmalara neden olması engellenmiştir.

Eksik veri işleme adımının devamında, dolgu işlemi sonrasında oluşabilecek piksel dağılımındaki anormallikler tespit edilmiştir. Bu amaçla, her bant için ortalama sapma ve varyans değerleri hesaplanarak dolgu uygulamasının veri dağılımına etkisi analiz edilmiştir. Analiz sonuçlarına göre, dolgu işlemi sonrası bant bazında sapma değerlerindeki %0.5'in altındaki değişimler, orijinal verinin temel dağılımını büyük oranda koruduğunu göstermiştir. Böylece sıfır dolgu yönteminin, mekânsal desenleri bozmayacak yeterlilikte olduğu doğrulanmıştır.

### 3.3.7 Ölçeklendirme ve yama oluşturma

Modelin öğrenme sürecinde farklı katmanlardaki veri ölçeklerinin birbirinden ayrışması, optimizasyon sürecini zorlaştırabilmektedir. Bu nedenle, tüm bantlar minimum-maksimum normalizasyon yöntemi kullanılarak 0 ile 1 aralığındaki değerlere dönüştürülmüştür. Her bir bant için

$$X_{\text{norm}} = (X - X_{\text{min}}) / (X_{\text{max}} - X_{\text{min}} + \epsilon)$$

formülü uygulanarak, aşırı büyük veya küçük değerlerin modele dengesiz ağırlık kazandırması önlenmiştir.  $\epsilon$  değeri olarak  $1e-6$  kullanılmış, böylece bölme işlemi sırasında oluşabilecek belirsizlikler ortadan kaldırılmıştır.

Normalizasyon sonrasında, mekânsal boyuttaki örnekleme birimi olarak kayan pencere (sliding window) tekniği ile  $32 \times 32$  piksel boyutunda veri yamaları (patch) oluşturulmuştur. Yama oluşturma sırasında Yama büyüklüğü 32 piksel, Kaydırma büyüklüğü de 16 piksel kullanılarak hem örtüşen hem de farklı konumlardaki alt yamalar elde edilmiştir. Oluşturulan yamalar, eğitim, doğrulama ve test kümelerine %80-%10-%10 oranında ayrılmıştır.

Ayrıca, homojenlik filtresi uygulanarak bir yamada yapılaşmış alan seviyesinin %5–%95 aralığında olduğu yamalar seçilmiş, yerleşim içermeyen veya tamamen yerleşim alanı içeren bölümler eğitim verisinden çıkarılmıştır. Bu işlem sayesinde modelin farklı yapısal desenleri öğrenme kapasitesini artırması amaçlanmıştır.

Yapılan yama bölümlene ve filtreleme işlemleri sonucunda, hem mekânsal çeşitlilik korunmuş hem de modeli saptıracak dengesiz dağılım engellenerek eğitim süreci kalitesi artırılmıştır.

### **3.4 Derin Öğrenme Modeli ve Eğitim**

Bu çalışmada, Konya ili için kentsel büyüme tahmini görevini yerine getirebilmek amacıyla, görüntü tabanlı mekânsal temsilleri zaman boyutunda işlemeye olanak tanıyan hibrit bir derin öğrenme mimarisi kullanılmıştır. Model akışı; önce ConvEncoder ile çok kanallı girişten mekânsal özellik çıkarımı yapar, ardından TemporalTransformer bileşeni ile farklı tarihli temsiller arasındaki uzun dönemli zaman ilişkilerini modelleyerek derin bir bağlam oluşturur ve son olarak ConvDecoder + CBAM Spatial Attention modülü yardımıyla bu bağlamı yerel piksel düzeyinde ikili segmentasyon maskesine çevirir.

Alt bölümlerde, önce 3.4.1 Model Mimarisi başlığında modelin katman yapısı ve ilham kaynakları açıklanacak; ardından 3.4.2 Model Eğitim Süreci bölümünde kullanılan donanım, veri yükleme stratejileri, hiperparametreler ve eğitim dinamikleri detaylandırılacaktır.

#### **3.4.1 Model mimarisi**

Kentsel büyüme tahmini amacıyla, literatürde farklı görevler için önerilmiş mimarilerden esinlenilerek “ConvEncoder → TemporalTransformer → ConvDecoder + CBAM Spatial Attention” akışına sahip bir model tasarlanmıştır. Aşağıda, her bileşenin tasarım mantığı ile ilham kaynağı olan güncel çalışmalar özetlenmiştir.

#### **ConvEncoder**

Girdi olarak gelen  $64 \times 64 \times 35$  boyutlu coğrafi ve zaman serisi yamaları üzerinde birden fazla konvolüsyon katmanı uygulanır. Batch Normalization, katman çıktı dağılımını stabilize ederek daha yüksek öğrenme hızlarına izin verir; ReLU aktivasyonu ise modele doğrusal olmayan özellikleri kazandırır. Bu yapısal şablon, uzaktan algılama

verileri kullanarak arazi kullanım deęişiminin tespiti için tasarlanmış ChangeMask modelinin encoder kısmındaki CNN-Encoder aşamasıyla paralellik gösterir. Zheng ve arkadaşları (2022), ChangeMask ile hem “temporal-wise semantic segmentation” hem de “binary change detection” görevlerini tek bir encoder–transformer–decoder mimarisi içinde birleştirmiştir.

### **TemporalTransformer**

Encoder’dan elde edilen mekânsal temsiller, pozisyon kodlamaları eklenerek bir TransformerEncoder’a beslenir. Bu sayede, zaman boyutundaki uzun dönemli bağıntılar etkin biçimde modellenmiştir. Chen ve arkadaşları (2021) önerdikleri Bitemporal Image Transformer (BIT) modeli ile, çok yüksek çözünürlüklü uzaktan algılama görüntülerindeki deęişiklik tespitinde self-attention mekanizması kullanarak hesaplama verimlilięi ve doğruluk artışı sağladığını raporlamışlardır.

### **ConvDecoder**

Modelin orta katmanında, encoder ve Transformer aşamalarından sonra elde edilen “sıkıştırılmış özellik temsili” (yani modelin öğrendięi özet bilgi), önce küçük bir mekânsal haritaya dönüştürülür; ardından ardışık ConvTranspose2d katmanlarıyla orijinal çözünürlüğe geri yükseltilir. Bu simetrik encoder–decoder düzeni, “U-Net-like Transformer” yaklaşımıyla tasarlanan UNetFormer mimarisinin decoder bölümüne benzer bir akış sunar. Wang ve arkadaşları (2021) tarafından tanımlanan UNetFormer, ResNet18 tabanlı encoder ve global ve lokal dikkat mekanizmalı “transformer decoder” ile kentsel deęişim tespiti için segmentasyonu hızlı ve doğru biçimde gerçekleştirdiğini raporlamışlardır.

### **Mekânsal Dikkat (CBAM Spatial Attention)**

Decoder’ın son aşamasında, Woo ve arkadaşları (2018) tarafından görüntü sınıflandırma görevlerinde önerilen “Convolutional Block Attention Module” (CBAM) mekânsal dikkat modülü kullanılarak feature map üzerindeki önemli coğrafi bölgeler adaptif olarak vurgulanır ve modelin odaklanması güçlendirilmiştir.

Bu modülün Arazi Kullanım/Örtüsü (LULC) ve kentsel alandaki kentsel alan tespiti alanlarında elde ettiği kazançlar literatürde yer alan çalışmalarla aşağıda özetlenmiştir:

- Zhang ve diğ. (2023), çoklu kaynaklı optik ve SAR verilerini kullanan U-Net + CBAM mimarisinde LULC sınıflandırma doğruluğunu %91,2'ye çıkarmış; mIoU değeri 0,8667 olarak hesaplanmıştır.
- Song ve diğ. (2024), “ConvNeXt-CBAM” modelinde yakın kızılötesi bantlarla entegre CBAM kullanarak LULC mIoU'sini 0,8658'e yükseltmiştir.
- ConvNeXt-U (2024) çalışmasında, CBAM eklenmiş hafif U-Net türeviden oluşan parçalı tarım arazilerinin sınır tespitinde IoU'da %2,5'lik artış sağlanmıştır.
- He ve Jiang (2021), CBAM destekli FCN mimarisi ile WHU Building ve Inria Aerial veri setlerinde bina sınırlarının F1 skorunu 0,82'ye yükseltmiş; bu, kapsamlı kentsel yapı sınır tespitinde önemli bir iyileşme olduğunu göstermiştir.

Model eğitiminin sonunda mekânsal dikkat ağırlıkları haritalanarak, hangi coğrafi bölgelerin tahmin sürecine en çok katkı sağladığı görselleştirilir ve katmanlarla mekânsal olarak karşılaştırarak girdiler ile tahmin arasındaki ilişki yorumlanabilir/açıklanabilir hale gelir.

### 3.4.2 Model eğitim süreci

Önerilen model Python (v3.11.13) ile geliştirilmiş ve Google Colab ortamında Jupyter Notebook üzerinden çalıştırılmıştır. Eğitimde NVIDIA A100 GPU (40 GB VRAM) ve sistem belleği olarak 80 GB RAM kullanılmıştır. Çalışmada kullanılan  $64 \times 64$  boyutlu yamalar, bilgi içeriği düşük örnekleri elemek amacıyla %5–%95 homojenlik eşiğiyle filtrelendikten sonra eğitim, doğrulama ve test olmak üzere üç kümeye ayrılmıştır. Verilerin yüklenmesi ve *mini-batch* işlemleri için PyTorch DataLoader kullanılmış; her seferinde 16 örnekten oluşan batch'ler ile çalışılmıştır. Eğitim sırasında veri karışımını sağlayan “shuffle=True” parametresi modelin farklı örnek kombinasyonlarında öğrenmesini desteklerken, doğrulama ve test aşamalarında “shuffle=False” kullanılarak sonuçların tutarlılığı korunmuştur.

Eğitimde, ikili segmentasyon sorununu çözmek için birincil kayıp fonksiyonu olarak “BCEWithLogitsLoss” tercih edilmiş; bu fonksiyon, pozitif ve negatif örnekler arasındaki dengesizliği otomatik hesaplanan “pos\_weight” ile gidererek modelin

dengeli öğrenmesi sağlanmıştır. Küçük yapısal detayların ve bölgesel bütünlüğün daha iyi yakalanması için ek olarak “Dice Loss” terimi de toplam kayıba eklenmiştir. Model parametrelerinin güncellenmesi için “AdamW” optimizatörü (öğrenme hızı  $1 \times 10^{-3}$ ) kullanılırken, eğitim ilerledikçe doğrulama kaybındaki iyileşme durumu temelinde öğrenme oranını düşüren “ReduceLRonPlateau” planlayıcısı devreye girmektedir. Aşırı öğrenmeyi önlemek amacıyla, doğrulama kaybı üst üste on döngü (epoch) boyunca iyileşme göstermediğinde eğitim otomatik olarak sonlandırılır.

Eğitim en fazla 100 döngü boyunca sürdürülür. Her döngü sonunda, hem eğitim hem de doğrulama aşamalarında kayıp (Loss), bölge benzerliği ölçütü (IoU) ve F1 skoru gibi metrikler hesaplanarak modelin öğrenme durumu izlenir. Bu metrikler doğrultusunda, en düşük doğrulama kaybını veren ağırlık seti kaydedilmekte; ayrıca metriklerin döngüye göre değişimi incelenerek eğitim dinamikleri hakkında ayrıntılı geri bildirim sağlanmaktadır.

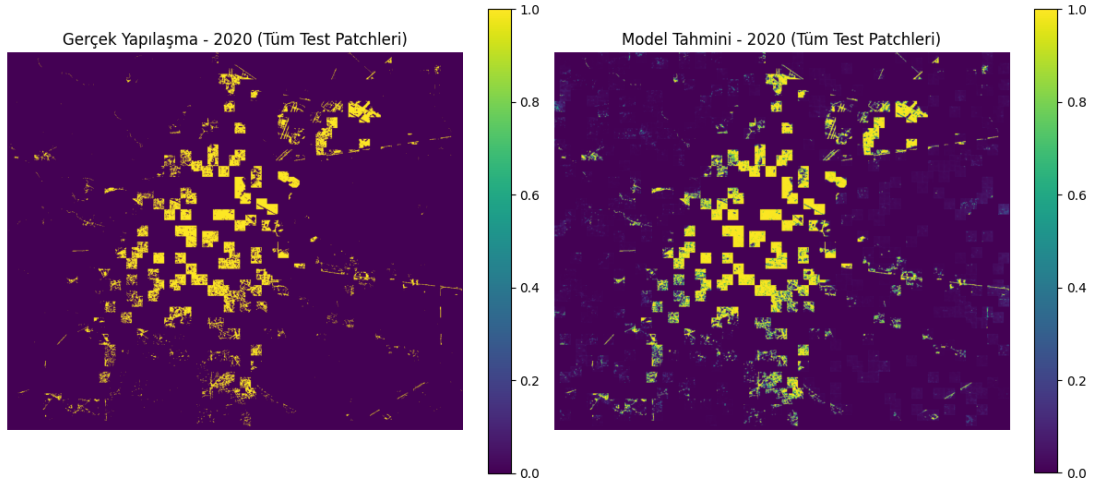
Uygulanan bu stratejiler, modelin hem mekânsal hem de zamansal boyutlarda güçlü temsiller öğrenmesini destekleyerek Konya kenti için kentsel büyüme tahmininde yüksek doğruluk elde etmeyi amaçlamaktadır.

### **3.5 Model Değerlendirme ve Mekânsal Dikkat**

Bu başlık altında, önerilen model mimarisinin niceliksel performansını detaylandırılmak için kullanılan metrikler tanımlanmış ve mekânsal dikkat bağlamında girdi katmanlarının model tahminindeki ağırlıkları coğrafi olarak incelenmektedir.

#### **3.5.1 Modelin değerlendirilmesi**

Konya kentine ait açık kaynaklardan elde edilen statik ve dinamik katmanlar yamalar halinde %80 eğitim, %10 doğrulama ve %10 test olarak ayrılmıştır. Eğitim sırasında erken durdurma (early stopping) mekanizmasıyla en düşük doğrulama kaybı (validation loss) elde edilen döngüde kaydedilen ağırlıklar kullanılmıştır. Bu sayede modelin, aşırı öğrenme (overfitting) riskini en aza indiren ve gerçek dünya verisine genellenebilir en iyi ağırlık dağılımını yakalaması sağlanmıştır. Test aşamasında ise yaklaşık 1.200 adet bağımsız yama üzerinden değerlendirme gerçekleştirilmiştir.



**Şekil 3.6:** Modelin test edildiği yamalar: Gerçek (sol) ve Tahmin (sağ).

Performans ölçümü için; Doğruluk oranı, Intersection over Union (IoU) ve F1 skoru olmak üzere üç metrik kullanılmıştır. IoU, 2020 yılı için modelin tahmin ettiği yapılaşma maskesi ( $\hat{Y}$ ) ile gerçek maskesi ( $Y$ ) arasındaki örtüşme oranını:

$$\text{IoU} = \frac{|\hat{Y} \cap Y|}{|\hat{Y} \cup Y|}$$

formülüyle hesaplar. Bu metrik, hem yanlış pozitif (false positive) hem de yanlış negatif (false negative) bölgeleri hesaba katarak modelin ne kadar doğru bir segmentasyon yaptığını gösterir.

F1 skoru ise, precision (kesinlik) ve recall (duyarlılık) değerlerinin harmonik ortalaması olarak:

$$\text{F1} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

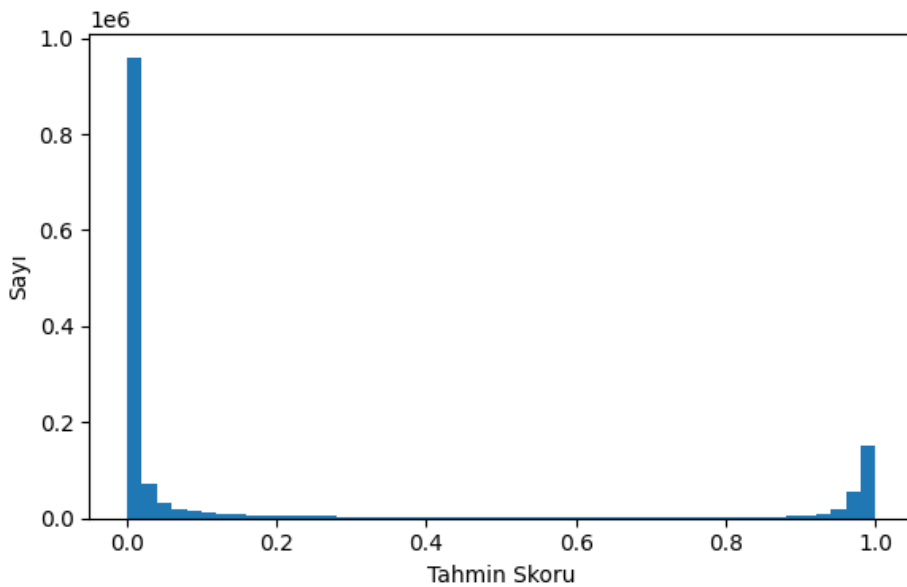
Formülüyle hesaplar. Bu sayede modelin yanlış pozitif ve yanlış negatif hatalarına eşit ağırlık vererek dengeli bir başarı ölçütü sunar.

Test seti üzerindeki deneysel sonuçlar, modelin yüksek bir örtüşme ve sağlam bir segmentasyon becerisi sergilediğini ortaya koymuştur: Doğruluk oranı %97, ortalama IoU değeri 0.85, ortalama F1 skoru ise 0.92 olarak hesaplanmıştır. %0.85'lik IoU, modelin gerçek yapılaşma alanlarıyla beşte dördten fazla oranında örtüşen tahminler yaptığını işaret ederken, %92'lik F1 skoru modelin hem doğru pozitif örnekleri yüksek oranda yakaladığını hem de yanlış alarm verme oranının düşük kaldığını göstermektedir. Bu yüksek başarı düzeyi, hem doğal konvolüsyonel katmanların

mekânsal desen tanıma kapasitesinin hem de Temporal Transformer'ın zaman boyutundaki dinamikleri modelleme gücünün birleşik etkisiyle elde edilmiştir.

Ayrıca modelin tahmin hataları, test yamalarının görsel incelemesiyle analiz edilmiş; karışık arazi dokularında dahi tahminlerin keskin ve tutarlı olduğu, küçük bölgesel sapmaların gözlemlendiği tespit edilmiştir. Bu kapsamlı değerlendirme, önerilen mimarinin Konya ölçeğinde doğruluk açısından yüksek performans sunduğunu ortaya koymuştur.

Test aşamasında elde edilen metriksel başarı ve görsel incelemelerde tespit edilen küçük bölgesel sapmalar ışığında, modelin sigmoid aktivasyon sonrası ürettiği 0-1 aralığındaki sürekli çıktılarının dağılımı incelenmiştir (Şekil 3.7). Bu inceleme, modelin sınıflandırma kararlarında ne ölçüde emin olduğunu ve tahminlerinin hangi aralıklarda yoğunlaştığını göstermesi açısından önemlidir. Şekil-3.5'te yer alan dağılım grafiği incelendiğinde, tahmin skorlarının büyük çoğunluğunun 0 ve 1 uç değerlerinde yoğunlaştığı, orta aralıklarda ise oldukça düşük bir dağılım sergilediği görülmektedir. Bu durum, modelin sınıflandırma kararlarında yüksek derecede kararlı olduğunu göstermektedir. Skorların özellikle 0'a ve 1'e yakın bölgelerde yoğunlaşması, modelin negatif ve pozitif sınıfı güvenle ayırt edebildiğini ortaya koymaktadır. Orta değerlerdeki seyrek dağılım ise modelin belirsizlik durumlarının sınırlı olduğunu göstermektedir. Dolayısıyla, bu sonuçlar modelin yüksek ayrıştırma gücüne sahip olduğunu ortaya koymaktadır.



Şekil 3.7: Sigmoid aktivasyon fonksiyonu çıkış dağılımı.

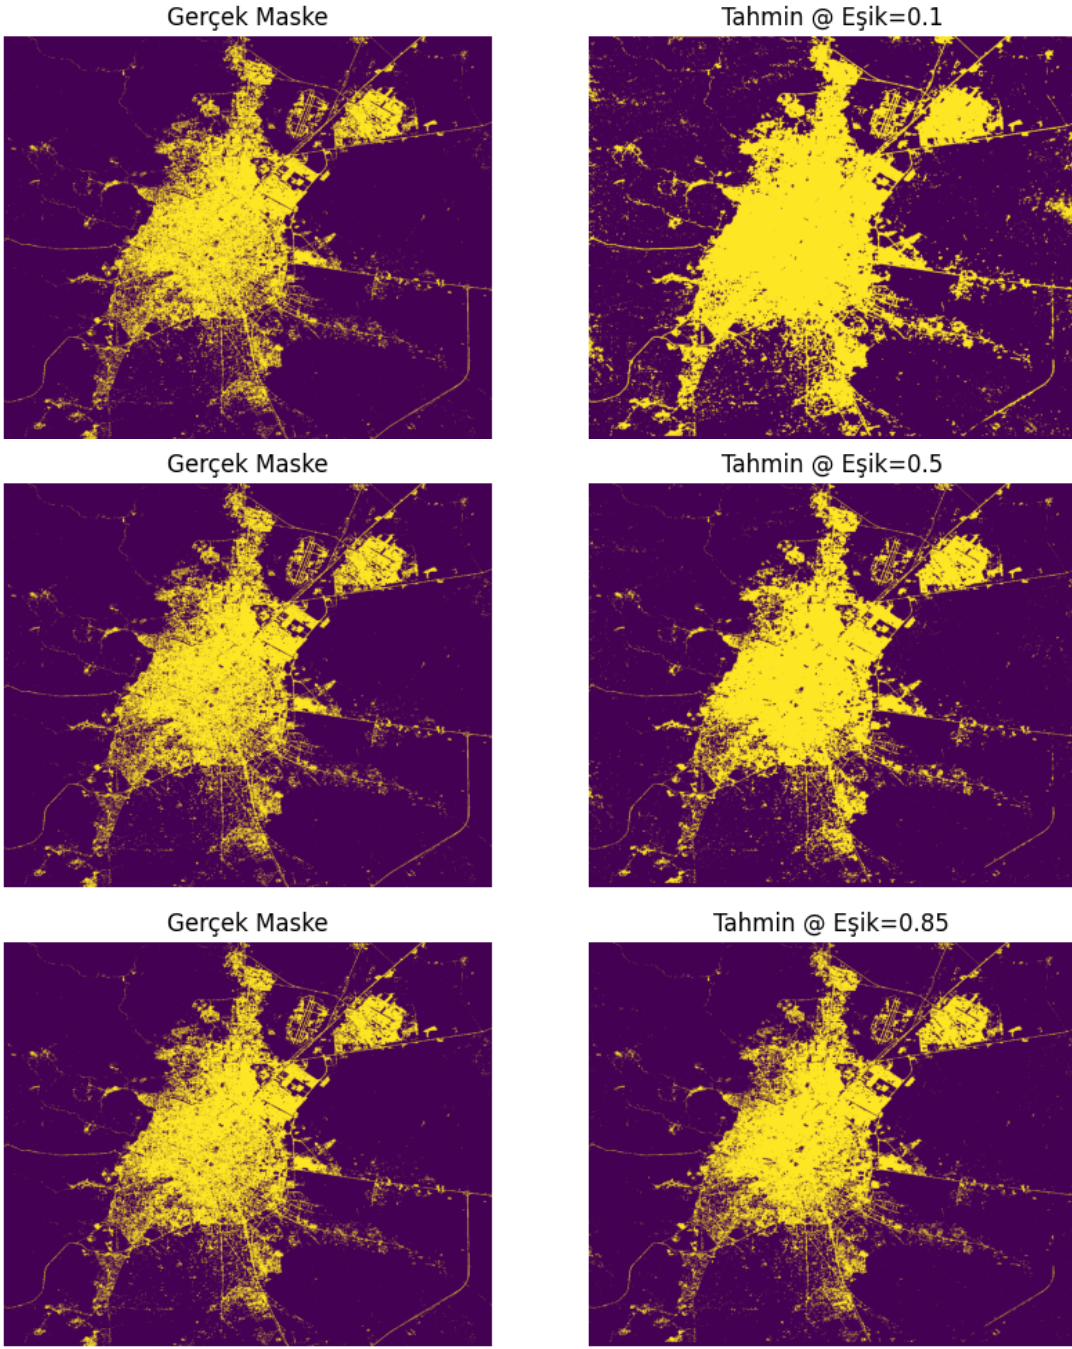
Test aşamasında elde edilen metriksel başarı ve görsel incelemelerde tespit edilen küçük bölgesel sapmalar ışığında, modelin sigmoid aktivasyon sonrası ürettiği 0-1 aralığındaki sürekli çıktılarını ikili (binary) maskelere dönüştürülmesi sırasındaki eşik değeri (threshold) ayarının önemi ortaya çıkmaktadır. Şekil-3.8.'te tüm alanı kapsayan sürekli tahmin haritasına üç farklı eşik (0.10, 0.50, 0.85) uygulanmış ve incelenmiştir. Bu analiz, eşik ayarının yanlış pozitif ve yanlış negatif dengesi üzerindeki belirleyici etkisini ortaya koymaktadır.

Uygulanan üç eşik değeri, modelin “yapılaşma” sınıfını tespit etmekteki duyarlılık/kesinlik (sensitivity/specificity) dengesini farklı açılardan inceleme imkanı tanımıştır (Çizelge 3.4).

**Çizelge 3.4:** Yapılaşma eşik değerlerinin yorumlanması.

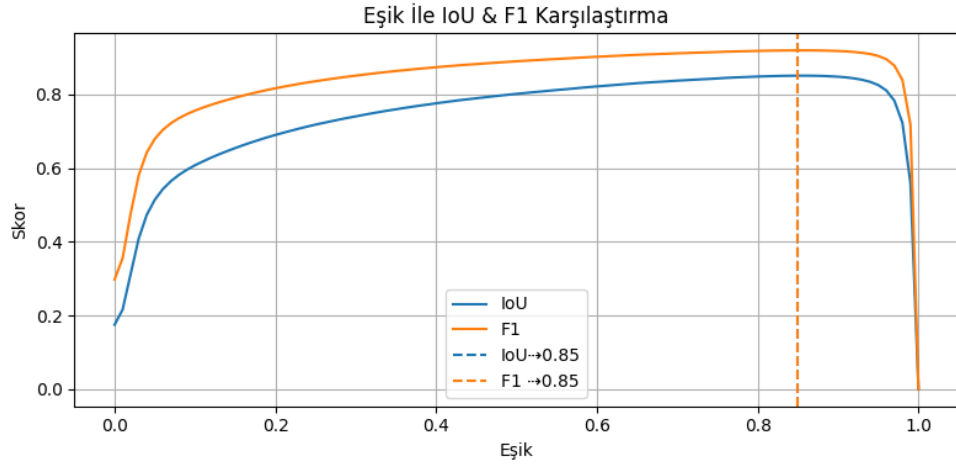
Eşik Değeri	Açıklama
<b>Eşik = 0.10</b>	Çok düşük bir eşik değere sahip olmak, neredeyse tüm pikselleri “yapılaşma” olarak sınıflandıracak kadar yüksek duyarlılık (recall) sağlar. Ancak bu durumda tarımsal, yeşil veya boş alanların yanlışlıkla yapılaşma olarak işaretlendiği için yanlış pozitif (false positive) sayısı dramatik biçimde artabilir.
<b>Eşik = 0.50</b>	Olasılık eşiklerinde yaygın bir varsayılan değer olan 0.50, modelin orta seviyede güvene (confidence) sahip pikselleri “yapılaşma” olarak tanımasına izin verir. Bu durum, hem yanlış pozitifleri hem de yanlış negatifleri (false negative) dengede tutan bir segmentasyon sunar; yapılan çalışmalarda genellikle denge metriklerinde (IoU, F1) makul sonuçlar ürettiği saptanmıştır.
<b>Eşik = 0.85</b>	Yüksek bir eşik değeri yalnızca modelin çok yüksek güvenle tahmin ettiği pikselleri “yapılaşma” olarak kabul eder. Bu sayede yanlış pozitifler büyük ölçüde azalır; ancak düşük kontrastlı veya karma dokulu yerleşim bölgelerindeki pikseller atlanarak yanlış negatife yol açabilir.

Bu karşılaştırma, sigmoid çıkışlarının ikili segmentasyona çevrilmesi için eşik değerinin önemini göstermektedir.



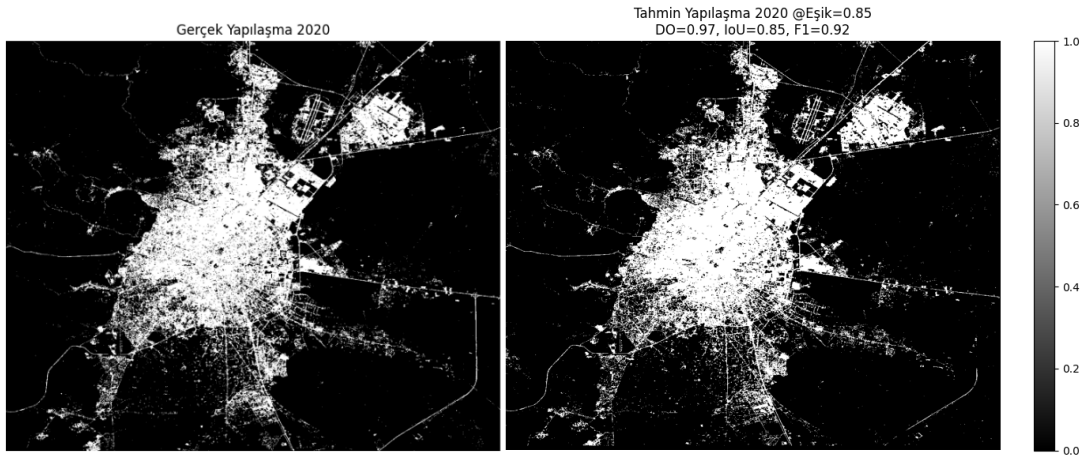
Şekil 3.8: Farklı eşik değerlerinde ikili segmentasyon sonuçlarının karşılaştırması.

Sigmoid çıktıdan ikili maskeye dönüştürme sürecinde optimum eşiği belirlemek amacıyla, eşik değeri 0–1 arasında 0.01 adımla taranmış ve her eşik için Jaccard (IoU) ile F1 skoru hesaplanmıştır. (Şekil 3.9)




**Şekil 3.9:** Maske eşik değeri ile tahmin skoru karşılaştırılması.

IoU ve F1 Metriklerin eşik aralığındaki değişimini gösteren eşik analizi ile optimum tahmin için %85 maskeleme eşiği belirlenmiştir. Bu sayede modelin hem doğruluk hem de denge metriklerinde en yüksek performansı bu eşik değeriyle sağladığı ortaya çıkmıştır. %85 maskeleme eşik değeri ile 2020 yılına ait yapılaşma alan tahmini görselleştirilerek karşılaştırma yapılmıştır. (Şekil 3.10)



**Şekil 3.10:** Optimum eşik değeri ile 2020 yılına ait tahmin ve gerçek maske.

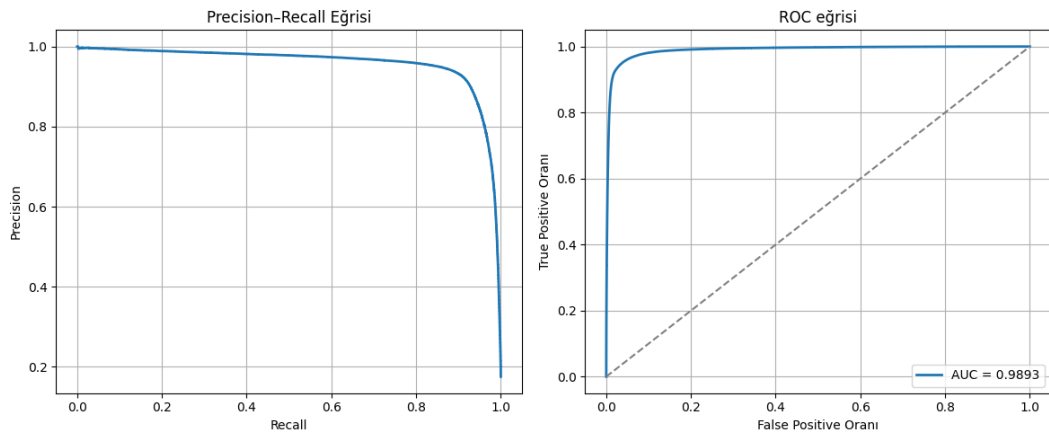
Tüm çalışma alanı ölçeğinden rastgele seçilen farklı 64×64 piksel'lik yamalar için gerçek yapılaşma maskesi ve model tarafından tahmin edilen sigmoid fonksiyon çıktısı karşılaştırılmıştır. (Şekil 3.11)



Şekil 3.11: Rastgele seçilen 20 yama örneğinin gerçek ve tahmin yapılaşması.

Tahmin yapılan yamalar incelendiğinde, modelin özellikle kentsel ve kırsal sınırlarındaki dokuları başarılı biçimde yakaladığı saptanmıştır. Bununla birlikte, heterojen arazi kullanımı içeren bölgelerde (örneğin yapılı alan ile yeşil alanın iç içe geçtiği örnekler) ya da yapılaşmanın olmadığı yerlerde zaman zaman yerel sapmalar olduğu ya da bölgenin tek bir bütün yerine parçalı halde yanlış sınıflandırılması şeklinde hatalar gözlemlenmiştir. Bu karşılaştırmalı inceleme, modelin genel kapsama ve hassasiyeti açısından iyi bir performans sunduğunu, ancak yapılaşma olmayan arazi dokularında daha iyi segmentasyon için iyileştirmelere ihtiyaç duyulabileceğini ortaya koymaktadır.

Modelin performansını değerlendirmek amacıyla Precision-Recall ve ROC eğrileri (Şekil 3.12) de incelenmiştir. Precision-Recall eğrisi, modelin pozitif sınıfı tahmin ederken elde ettiği duyarlılık (recall) ve doğruluk (precision) değerleri arasındaki ilişkiyi göstermektedir. Eğri incelendiğinde, modelin yüksek recall değerlerine ulaşırken aynı zamanda precision değerlerini de büyük ölçüde koruduğu görülmektedir. Bu durum, özellikle dengesiz veri setlerinde pozitif sınıfın başarılı bir şekilde ayırt edildiğini ortaya koymaktadır. ROC eğrisi ise modelin farklı eşik değerleri altında sınıfları ayırma gücünü yansıtmaktadır. Eğrinin sol üst köşeye yakın bir seyir izlemesi, modelin yanlış pozitif oranını düşük tutarken doğru pozitif oranını yüksek seviyede yakaladığını göstermektedir. Ayrıca eğri altında kalan alan (AUC) 0.9893 olarak hesaplanmış olup, bu değer modelin sınıflar arasında son derece yüksek bir ayırım gücüne sahip olduğunu kanıtlamaktadır. Hem Precision-Recall eğrisindeki yüksek performans hem de ROC eğrisinden elde edilen yüksek AUC değeri, modelin güvenilir ve güçlü bir sınıflandırma yaptığını göstermektedir.



**Şekil 3.12:** Precision-Recall eğrisi (sol), ROC eğrisi (sağ).

### 3.5.2 Mekânsal dikkat analizi

Araştırmada, sadece modelin nihai performans metriklerine dökülmemiş, bununla birlikte karar alma mekanizmalarında hangi coğrafi bölgelerin ve çevresel parametrelerin daha etkili olduğunun tespitine yönelik mekânsal odak (spatial attention) incelemeleri gerçekleştirilmiştir. Bu yaklaşım, modelin şeffaf olmayan yapısını (“kara kutu”) büyük ölçüde açıklanabilir bir forma dönüştürmeye katkıda bulunmuştur.

Modelin karar mekanizmasını daha iyi anlamak ve çıktılarının yorumlanabilirliğini artırmak amacıyla, ConvDecoder katmanlarından elde edilen mekânsal attention maskeleri detaylı biçimde incelenmiştir. İlk aşamada, her test patch’i için (H×W) boyutunda üretilen dikkat(attention) ağırlıkları sigmoid aktivasyonu sonrası normalize edilerek saklanmış; böylece her pikselin ne ölçüde “dikkat” ağırlığı alacağı sayısal olarak temsil edilmiştir. Daha sonra bu maskeler piksel bazında üst üste toplanarak ve toplam patch sayısına bölünerek, Konya ili ölçeğinde genel bir ortalama attention haritası çıkarılmıştır. Bu harita, şehir merkezinden çevre kırsal alanlara doğru düşen bir dikkat profili sunduğunu; merkezdeki ana arter ve yerleşim bölgelerinde yüksek, tarım ve ormanlık alanlarda ise düşük skorlar atandığını net biçimde göstermektedir.

Mekânsal dikkat ile girdiler arasındaki ilişkiler kantitatif olarak değerlendirilmiştir. Bu değişkenler ile attention skoru arasındaki Pearson korelasyon katsayısı:

$$r = \frac{\text{cov}(A, X)}{\sigma_A \sigma_X}$$

formülüyle hesaplanmıştır. (Çizelge 3.5)

**Çizelge 3.5:** Girdi Katmanları ile Mekânsal Dikkat arasındaki korelasyon.

Tip	Katman	Pearson (r) Katsayısı
Statik	Eğim	0.387
	Bakı (Aspect)	0.016
	Arazi Varyansı	0.324
	Ana Yol Uzaklığı	0.216
	Yan Yol Uzaklığı	0.409
	Şehir Merkezi Uzaklığı	0.339
	Suya Uzaklık	-0.129

<b>Dinamik (Zaman Serisi)</b>	NDVI	-0.171
	NDBI	0.366
	NDWI	0.121
	Arazi Kullanım/Örtüsü	-0.348
	GHSL Built-up	-0.503
	Gece Işıkları (NTL)	-0.533

Pearson korelasyon katsayıları dikkate alındığında, elde edilen değerlerin genel olarak  $\pm 0.5$  eşliğinin altında kaldığı görülmektedir. Bu durum, literatürde yaygın olarak kabul edilen sınıflandırmaya göre (0.0–0.3 düşük, 0.3–0.5 orta, 0.5 ve üzeri yüksek korelasyon) analiz edilen değişkenler ile model çıktıları arasındaki ilişkilerin çoğunlukla düşük ve kısmen orta düzeyde olduğunu göstermektedir. Bu kabulden hareketle, tekil değişkenlerin kentsel büyümeyi açıklamadaki gücünün sınırlı olduğu, dolayısıyla kentsel dinamiklerin tek boyutlu bir bakış açısıyla ele alınamayacağı anlaşılmaktadır. Kentsel büyüme süreci; bir çok faktörün eşzamanlı etkileşimiyle şekillendiğinden, çok katmanlı ve çok boyutlu bir analiz yaklaşımı gerektirmektedir. Bu bağlamda, derin öğrenme tabanlı yöntemlerin kullanılması, farklı veri katmanlarının bütüncül biçimde değerlendirilmesine ve karmaşık ilişkilerin ortaya çıkarılmasına olanak tanımaktadır. Dolayısıyla, kentsel büyümenin tahmininde derin öğrenme yaklaşımlarının tercih edilmesi isabetli bir yöntem olup, elde edilen sonuçlar modelin bu çok boyutlu yapıyı başarıyla yansıtabildiğini göstermektedir.

Gece Işıkları (NTL) (-0.533) ve GHSL Built-up (-0.503) değişkenleri -0.5 seviyesinin altında değerler alarak orta kuvvetli negatif korelasyon kategorisine girmekte, bu da yapı yoğunluğu ve yapay ışık göstergelerinin modelin tahminleri ile anlamlı ters yönlü bir ilişki içinde olduğunu ortaya koymaktadır. Pozitif korelasyon açısından değerlendirildiğinde, Yan Yol Uzaklığı (0.409), Eğim (0.387) ve NDBI (0.366) katsayıları 0.3–0.5 aralığında yer almakta olup, bu değişkenler modelin dikkate aldığı mekânsal örüntüler üzerinde orta düzeyde bir etkiye sahip görünmektedir. Öte yandan, Bakı (0.016) ve NDWI (0.121) gibi değişkenler 0.2'nin altında kalarak oldukça düşük korelasyon sergilemiş, modelin karar mekanizmasına katkılarının sınırlı olduğu anlaşılmıştır. NDVI (-0.171) ve Arazi Kullanım/Örtüsü (-0.348) gibi çevresel faktörler ise zayıf ile orta arasında değişen negatif korelasyonlar göstermiştir. Genel olarak,

katsayıların düşük düzeyde seyretmesi modelin tekil değişkenlerden ziyade çok boyutlu mekânsal ilişkilerle çalıştığını işaret etmekte; ancak yapay çevre göstergeleri ve ulaşım altyapısına uzaklık gibi bazı faktörlerin dikkat mekanizmasında görece daha belirleyici bir rol oynadığı anlaşılmaktadır.

Derin öğrenme mimarisinin temelinde, CBAM (Evrşimsel Blok Odak Modülü) esas alınarak geliştirilmiş mekânsal odak katmanları (SpatialAttention) konumlandırılmıştır. Bahsi geçen katmanlar, girdi verilerinin kanal eksenindeki ortalama ve en yüksek aktivasyon değerlerini birleştirerek, iki boyutlu bir evrişim işlemine tabi tutmakta ve sonuç olarak her bir piksel için  $[0, 1]$  aralığında normalize edilmiş bir odak maskesi (attention mask) oluşturmaktadır. Bu maskeler, modelin hangi lokasyonlara daha fazla önem verdiğine dair nicel bir gösterge sunmaktadır.


Mekânsal odak haritalarının türetilmesi amacıyla model eğitiminin ardından, ileri yayılım kancası (forward hook) tekniğine başvurulmuştur. Kancalar vasıtasıyla, modelin ileri besleme aşamasında söz konusu SpatialAttention katmanlarından elde edilen ara çıktılar kayıt altına alınmış ve ileri aşamada görselleştirilmek üzere saklanmıştır. Bu prosedürde bilhassa çözücü (decoder) katmanındaki SpatialAttention modülü merkeze alınmıştır; çünkü nihai çıktı maskesinin üretimi sırasında hangi mekânsal parçaların ön plana çıkarıldığının gözlemlenmesi, modelin içgüdüünün anlaşılmasında en değerli veriyi sağlamaktadır.

Takip edilen metodoloji şu şekilde özetlenebilir:

- **Kanca Tanımlama:** SpatialAttention katmanının evrişim çıktısı, sigmoid aktivasyon fonksiyonundan geçirilerek  $[0, 1]$  aralığına ölçeklendirilmiştir.
- **Yama Bazlı Çıkarım:** Test veri kümesinde bulunan her bir yama (patch) için ileri besleme işlemi yürütülmüş ve buna karşılık gelen odak maskesi çıktısı elde edilmiştir. Bu maskeler, modelin hangi piksel gruplarına daha yüksek ağırlık verdiğini işaret etmektedir.
- **Bütüncül Alan Entegrasyonu:** Tekil yamalardan çıkarılan odak maskeleri, koordinat bilgileri kullanılmak suretiyle orijinal görüntü boyutlarına tekrar dizilmiş ve örtüşen alanların değerleri ortalaması alınarak dengelenmiştir. Bu sayede Konya ili genelini kapsayan bütünlük bir mekânsal odak ısı haritası oluşturulmuştur.

- **Görselleştirme:** Nihai olarak üretilen odak haritası, 0 ile 1 arasındaki değer aralığına bir renk gradyanı atanmak suretiyle görsel bir forma kavuşturulmuş ve odak yoğunluğunun mekânsal dağılımı ortaya konulmuştur.

Elde edilen ortalama dikkat haritası girdi katmanlarıyla Coğrafi Bilgi Sistemi (GIS) ortamında mekânsal dağılım incelenmiştir. (Şekil 3.13) Konya ili sınırları, mahalle ve cadde ölçeğinde alt bölgelere ayrılarak her bölgenin ortalama dikkat skoru hesaplanmış; bu sayede modelin hangi mahallelere, hangi yol akslarına veya boş alanlara daha fazla odaklandığı görselleştirilmiştir.



**Şekil 3.13:** Ortalama Mekânsal Dikkat (Attention) Haritası.

Haritaların analizi, modelin bilhassa kent merkezine yakın olan kesimlerde, ana ulaşım hatları boyunca ve vejetasyon yoğunluğunun nispeten düşük olduğu arazilerde daha yüksek odak değerleri ürettiğini ortaya koymuştur. Diğer bir ifadeyle model, yapılaşma potansiyeli yüksek olan sahaları sadece doğru bir şekilde tahmin etmekle yetinmemiş, aynı zamanda odak mekanizması üzerinden bu bölgelere yoğunlaşmıştır.

Odak maskeleri ile mevcut çevresel değişkenler arasındaki ilişki korelasyon analizi ile incelenmiştir. Örneğin, NDVI (Normalleştirilmiş Bitki Örtüsü İndeksi) değişkeni ile

negatif, kent merkezine olan uzaklık deęişkeni ile ise pozitif yönlü bir korelasyon tespit edilmiştir. Bu gözlemler, modelin, kentsel gelişimi şekillendiren ve literatürde kabul görmüş olan mekânsal dinamikleri içselleştirdiğini teyit etmektedir.

Netice itibarıyla, mekânsal odak haritaları şu üç mühim katkıyı sağlamıştır:

- **Modelin Açıklanabilirliği:** Modelin tahminlerde bulunurken vurguladığı bölgelerin görselleştirilmesi, bu tahminlerin arka planında yatan gerekçelerin anlaşılmasına imkân tanımıştır.
- **Mekânsal Desenlerin Teyidi:** Elde edilen odak haritaları, kentleşme dinamiğinin ana arterler, merkezî alanlar ve çevresel elverişlilik gibi faktörler etrafında kümelenme eğiliminde olduğunu doğrulamıştır.
- **Politika Geliştirmeye Destek:** Yüksek odak değerine sahip bölgelerin gelecekte yapılaşma açısından daha fazla baskı altında kalma ihtimali göz önüne alındığında, söz konusu alanların kentsel planlama ve politika önceliklendirmesinde üst sıralarda değerlendirilmesi gerektiği sonucuna varılmıştır.

#### 4. SONUÇ VE DEĞERLENDİRME

Dünya genelinde artan nüfus, kırsaldan kente göç, sanayileşme ve ekonomik faaliyetlerin mekânsal yoğunlaşması, kentlerin giderek daha geniş alanlara yayılmasına yol açmaktadır. Bu süreç yalnızca mekânsal genişlemeyi değil, aynı zamanda ekolojik dengelerin bozulmasını, tarımsal arazilerin kaybını, su kaynaklarının kirlenmesini ve karbon salınımlarının artmasını beraberinde getirmektedir. Bu sebeple, kentsel alanların büyümesi, günümüzde şehir planlamasından, çevre bilimine, iktisat ve ekonomiden sosyal bilimlere kadar farklı disiplinlerin yakından ilgilendiği bir uğraş alanıdır. Türkiye’de ise kentsel büyüme, özellikle büyükşehir statüsüne sahip illerde, plansız ve kontrolsüz biçimde ortaya çıkabilmekte; bu durum hem sürdürülebilirlik hem de yaşam kalitesi açısından çeşitli sorunlara yol açmaktadır.

Bu bağlamda hazırlanan çalışmanın çıkış noktası, kentsel büyümenin gelecekte hangi alanlarda yoğunlaşacağını öngörmek ve karar vericilere bilimsel tabanlı, nesnel veriler ışığında bir model sunabilmektir. Konya ili örneği üzerinden yürütülen bu araştırma, hem ülkenin en geniş yüzölçümüne sahip ili olması hem de son yirmi senedir demografik ve mekânsal açıdan önemli değişimler geçirmesi nedeniyle anlamlı bir vaka incelemesi olmaktadır. Konya kenti özelinde tarım arazileri, göl ekosistemleri ve yeraltı su rezervleri üzerindeki kentleşme kaynaklı baskılar düşünüldüğünde, sürdürülebilir bir perspektifle tahminlerde bulunmanın önemi daha da belirginleşmektedir.

Literatürde kentsel büyümenin modellenmesine dair çeşitli yöntemler mevcuttur. Geleneksel istatistiksel yaklaşımlar, genellikle tek bir zaman kesitinde ve belirli mekânsal değişkenlerle sınırlı lojistik regresyon veya Markov zinciri analizlerine dayanmaktadır. Bu yöntemler genel eğilimleri yakalayabilmekle beraber, coğrafi heterojenliği ve zaman içindeki bağımlılıkları derinlemesine işleme kapasitesinden yoksundur. Hüresel otomata ve öge tabanlı modeller ise mekânsal komşuluk ilişkilerini modelleyebilmekte, fakat parametreleştirme süreçleri karmaşıklaşmakta ve modellerin genellenebilirliği tartışmalı hâle gelmektedir. Yakın dönemde ise makine öğrenmesi ve bilhassa evrişimli sinir ağları (CNN) temelli teknikler öne çıkmış; uydu görüntülerinden doğrudan mekânsal örüntüleri çıkarabilme becerileri sayesinde umut vaat etmişlerdir. Ancak, CNN tabanlı modellerin büyük kısmı mekânsal boyutu ön

planda tutmakta, zamansal deęişimlerin ardışıklığını ve dinamik yapısını yeterince modelleyememektedir.

Bu noktada, mevcut araştırmanın temel katkısı devreye girmektedir. Çalışmada, hem mekânsal hem de zamansal boyutları bütünleşik bir şekilde öğrenebilme kapasitesine sahip hibrit bir derin öğrenme mimarisi tasarlanmıştır. Önerilen mimari, ConvEncoder + Temporal Transformer + ConvDecoder şeklinde kurgulanmış; ConvEncoder mekânsal özellikleri, Temporal Transformer zaman serisi bağımlılıklarını, ConvDecoder ise çıktı üretirken mekânsal çözünürlüğün yeniden kazanılmasını sağlamıştır. Ayrıca, dikkat (attention) mekanizmalarının entegrasyonu sayesinde modelin hangi coğrafi bölgeleri ve öznitelikleri önceliklendirdiği görselleştirilebilir hâle getirilmiştir. Bu sayede yalnızca yüksek doğruluk oranlarına ulaşılmamış, aynı zamanda modelin karar süreçlerinin şeffaflaştırılması ve yorumlanabilirliği de sağlanmıştır.

Veri seti oluşturma stratejisi de çalışmanın özgün yönlerinden birini teşkil etmektedir. Çalışmada idari sınırlar yerine, uzaktan algılama verileri temel alınarak doğal ve sosyo-ekonomik süreçlerin gerçekçi bir yansıması olan veri katmanları kullanılmıştır. Kullanılan katmanlar, statik (eğim, bakı, yükseklik deęişimi, yol ağı, su kaynakları ve merkeze uzaklık gibi zaman içinde sabit kalanlar) ve dinamik (NDVI, NDBI, NDWI, arazi örtüsü, gece ışıkları, nüfus yoğunluğu, yapılaşma alanları gibi periyodik olarak deęişenler) olmak üzere iki gruba ayrılmıştır. Bu katmanların entegre bir şekilde işlenmesi, hem doğal çevre hem de beşeri faaliyetlerin kentsel gelişim üzerindeki birleşik etkilerinin modellenmesine olanak tanımıştır.

Veri hazırlama aşamasında, farklı çözünürlüklere sahip raster veriler ortak bir koordinat sistemine dönüştürülmüş ve 30×30 metrelik bir çözünürlükte yeniden yapılandırılmıştır. Bu işlem, çok kaynaklı verilerin uyumlu bir şekilde bir arada kullanılabilmesi için gerekli olan piksel hizalamasını sağlamıştır. Ayrıca, normalizasyon işlemleri uygulanarak tüm katmanlar 0-1 aralığına ölçeklenmiş, eksik veriler maskelenmiş ve aşırı öğrenmeyi engellemek amacıyla ötelenmiş pencereler kullanılarak yama (patch) tabanlı bir veri kümesi oluşturulmuştur. Böylece model eğitimi için çok boyutlu, dengeli ve zengin bir veri seti hazır hâle getirilmiştir.

Model eğitimi sonrasında ulaşılan performans metrikleri oldukça yüksektir. Ortalama doğruluk %97, IoU (Intersection over Union) 0.85 ve F1 skoru ise 0.92 olarak

ölçülmüştür. Bu değerler, önerilen yöntemin hem geleneksel yöntemlere hem de güncel CNN tabanlı modellere kıyasla kayda değer bir başarıya ulaştığını göstermektedir. Özellikle F1 skorunun yüksek olması, modelin pozitif (yapılaşma) ve negatif (yapılaşmamış) sınıflar arasında dengeli bir performans sergilediğine işaret etmektedir.

Mekânsal sonuçlar incelendiğinde, kentsel büyümenin ağırlıklı olarak Konya'nın merkez ilçeleri etrafında yoğunlaştığı gözlemlenmiştir. Ulaşım koridorlarına yakınlık, büyümenin yönlendirici unsurlarından biri olarak öne çıkmıştır. Benzer şekilde, merkezi iş alanlarına erişilebilirlik de kentsel yayılımı tetikleyen bir diğer faktör olarak tespit edilmiştir. Tarımsal potansiyeli yüksek arazilerin ve sulak alanların çevresinde artan bir yapılaşma eğilimi olduğu belirlenmiş olup, bu durum kentsel büyümenin yalnızca nüfus artışıyla değil, aynı zamanda çevresel faktörler ve erişilebilirlikle de doğrudan ilişkili olduğunu ortaya koymaktadır.

Dikkat haritaları üzerinden yapılan incelemeler de bu sonuçları destekler niteliktedir. Özellikle NDVI (vejetasyon indeksi), merkeze uzaklık ve ana yollara yakınlık gibi değişkenlerin, modelin karar mekanizmasında yüksek ağırlıklara sahip olduğu görülmüştür. Bu durum, modelin tahminlerinde hangi değişkenlere ne ölçüde önem verdiğinin anlaşılmasını kolaylaştırmıştır.

Araştırmanın katkıları üç ana başlıkta toplanabilir: İlki, yöntemsel açıdan getirdiği yeniliktir; CNN ve Transformer tabanlı hibrit model, mekânsal-zamansal bir tahminleme çerçevesi sunmuştur. İkincisi, veri entegrasyonu konusundaki özgün yaklaşımıdır; uzaktan algılamaya dayalı statik ve dinamik verilerin ortak bir çözünürlükte birleştirilmesiyle tutarlı ve zengin bir veri seti oluşturulmuştur. Üçüncüsü ise uygulamaya yönelik katkısıdır; üretilen tahmin haritaları, tarım arazilerinin korunması, su havzalarının sürdürülebilirliği ve ulaşım odaklı kentleşme politikaları gibi alanlarda karar vericilere nesnel bir dayanak sağlamaktadır.

Ancak çalışmanın bazı sınırlılıkları da mevcuttur. Farklı çözünürlüklerdeki veriler, küçük ölçekli yapılaşmaların tespitinde belirli sınırlamalara yol açmıştır. Ayrıca, sosyo-ekonomik ve politik faktörlerin (imar değişiklikleri, teşvik politikaları, göç yönetimi vb.) doğrudan modele dâhil edilmemiş olması, tahminlerin ağırlıklı olarak fiziki ve çevresel değişkenlere dayanmasına neden olmuştur. Bununla birlikte,

modelin 2000–2020 dönemi verileriyle eğitilmiş olması, daha uzun vadeli projeksiyonlarda belirsizliği artırabilecek bir unsurdur.

Gelecek çalışmalar için bir dizi öneri sunulabilir. Sosyo-ekonomik verilerin (gelir dağılımı, göç dinamikleri, yatırım bölgeleri) mekânsal verilerle entegre edilmesi modelin kapsamını genişletecektir. Yüksek çözünürlüklü uydu görüntülerinin kullanımı, küçük ölçekli yapılaşmaların daha isabetli tespit edilmesini sağlayacaktır. Senaryo temelli analizler (iklim değişikliği, su kıtlığı, yeni ulaşım yatırımları) ise farklı politikaların kentsel yayılım üzerindeki olası etkilerinin anlaşılmasına yardımcı olacaktır. Son olarak, aynı metodolojinin farklı kentlere uygulanması, modelin genellenebilirliğinin test edilmesi ve karşılaştırmalı analizler yapılmasına imkân tanıyacaktır.

Sonuç olarak, bu çalışma, Konya örneğinde olduğu gibi, kentsel büyümenin uzaktan algılama ve derin öğrenme teknikleri kullanılarak yüksek isabetle tahmin edilebileceğini ortaya koymuştur. Araştırma, alan yazınındaki mekânsal-zamansal modelleme açığını gidermeye katkı sunarken, aynı zamanda sürdürülebilir şehir planlaması için somut ve bilimsel bir veri kaynağı oluşturmaktadır. Elde edilen bulgular, yalnızca Konya için değil, benzer özellikler gösteren diğer kentler için de yol gösterici niteliktedir.

## 5. KAYNAKLAR

- Allen, J., and Lu, K.** (2003). Modeling and Prediction of Future Urban Growth in the Charleston Region of South Carolina: a GIS-Based Integrated Approach. *Conservation Ecology*, 8(2): 2.
- Almeida, C., José, M.** (2005). Cellular automata and neural networks as a modelling framework for the simulation of urban land use change. *XII Simposio Brasileiro de Sensoramento Remoto*, 3697-3705.
- Almeida, C. M., Batty, M., Monteiro, A. M. V., Câmara, G., & Soares-Filho, B. S.** (2003). Stochastic cellular automata modeling of urban land use dynamics: Empirical development and estimation. *Computers, Environment and Urban Systems*, 27(5), 481–509.
- Aslam, R. W., Shu, H., & Yaseen, A.** (2023). Monitoring the population change and urban growth of four major Pakistan cities through spatial analysis of open source data, *Annals of GIS*, 29(3), 355–367
- Başlık, S.** (2008). *Dinamik kentsel büyüme modeli: lojistik regresyon ve cellular automata (İstanbul ve Lizbon örnekleri)*. (Doktora Tezi). Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Batty, M., & Longley, P.** (1994). *Fractal cities: A geometry of form and function*. London: Academic Press.
- Batty, M., Xie, Y., & Sun, Z.** (1999). Modeling urban dynamics through GIS-based cellular automata. *Computers, Environment and Urban Systems*, 23(3), 205-233.
- Berberoğlu, S., Akin, A., & Clarke, K. C.** (2016). Cellular automata modeling approaches to forecast urban growth for Adana, Turkey: A comparative approach. *Landscape and Urban Planning*, 153, 11-27.
- Bithell, H. R., & Parry, M.** (2012). Large Scale Agent-Based Modelling: A Review and Guidelines for Model Scaling. In *Agent-Based Models of Geographical Systems*.

- Chen, Yimin, Liu, X., & Li, X.** (2017). Calibrating a Land Parcel Cellular Automaton (LP-CA) for urban growth simulation based on ensemble learning. *International Journal of Geographical Information Science*, 31(12), 2480–2504.
- Clarke, K. C., Hoppen, S., & Gaydos, L.** (1997). A Self-modifying Cellular Automaton Model Of Historical Urbanization In The San Francisco Bay Area. *Environment and Planning B: Planning and Design*, 24(2), 247–261.
- Clarke, K.C., and Gaydos, J.** (1998). Loose-Coupling a Cellular Automaton Model and GIS: Long-Term Urban Growth Prediction for San Francisco and Washington/Baltimore. *International Journal of Geographical Information Science*, 12(7): 699-714.
- Grekousis, G., Manetos, P., & Photis, Y. N.** (2013). Modeling urban evolution using neural networks, fuzzy logic and GIS: The case of the Athens metropolitan area. *Cities*, 30(1), 193-203.
- Güneş, M.** (2023). *Hücresel otomat tabanlı sleuth model kullanılarak kentsel büyümenin tarım alanları üzerindeki etkisinin incelenmesi.* (Yüksek Lisans Tezi). Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Konya.
- He, J., Li, X., Yao, Y., Hong, Y., & Jinbao, Z.** (2018). Mining transition rules of cellular automata for simulating urban expansion by using the deep learning techniques. *International Journal of Geographical Information Science*, 32(10), 2076-2097.
- He, S.** (2021). Boundary-Assisted Learning for Building Extraction from High-Resolution Remote Sensing Imagery. *Remote Sensing*, 13(4), Article 760.
- Hu, Z., & Lo, C. P.** (2007). Modeling urban growth in Atlanta using logistic regression. *Computers, Environment and Urban Systems*, 31(6), 667-688.
- Kesgin Atak, B.** (2013). *Didim yarımadası örneğinde SLEUTH modeli kullanılarak alan kullanım senaryolarının geliştirilmesi.* (Doktora Tezi). Ege Üniversitesi, Fen Bilimleri Enstitüsü, İzmir.
- Li, X., & Yeh, A.G.O.** (2002). Neural-network-based cellular automata for simulating multiple land-use changes using GIS. *International Journal of Geographical Information Science*, 16(4), 323–343.

- Liang, X., Guan, Q., Clarke, K. C., Liu, S., Wang, B., & Yao, Y.** (2021). Understanding the drivers of sustainable land expansion using a patch-generating land use simulation (PLUS) model: A case study in Wuhan, China. *Computers, Environment and Urban Systems*, 85, 101569.
- Liu, S., Cao, S., Lu, X., Peng, J., Ping, L., Fan, X., Teng, F., & Liu, X.** (2025). Lightweight deep learning model, ConvNeXt-U: An improved U-Net network for extracting cropland in complex landscapes from Gaofen-2 images. *Sensors*, 25(1), Article 261.
- Liu, X., Liang, X., Li, X., Xu, X., Ou, J., Chen, Y., ... Pei, F. (2017). A future land use simulation (FLUS) model for simulating multiple land-use scenarios by coupling human and natural effects. *Landscape and Urban Planning*, 168, 94–116.
- Liu, X., Wei, M., Li, Z., and Zeng, J.** (2022). Multi-scenario simulation of urban growth boundaries with an ESP-FLUS model: A case study of the Min Delta region, China. *Ecological Indicators*, 135: 1-14.
- Liu, Y., Wang, H., Jiao, L., Liu, Y., He, J., & Ai, T.** (2015). Road centrality and landscape spatial patterns in Wuhan Metropolitan Area, China. *Chinese Geographical Science*, 25(4), 511–522.
- López, E., Bocco, G., Mendoza, M., & Duhau, E.** (2001). Predicting land-cover and land-use change in the urban fringe. *Landscape and Urban Planning*, 55(4), 271-285.
- Matthews, R. B., Gilbert, N. G., Roach, A., Polhill, J. G., & Gotts, N. M.** (2007). Agent-based land-use models: A review of applications. *Landscape Ecology*, 22(10), 1447-1459.
- Meentemeyer, R. K., Tang, W., Dorning, M. A., Vogler, J. B., Cunniffe, N. J., & Shoemaker, D. A.** (2013). FUTURES: Multilevel simulations of emerging urban-rural landscape structure using a stochastic patch-growing algorithm. *Annals of the Association of American Geographers*, 103(4), 785–807.
- Mitsova, D., Shuster, W., & Wang, X.** (2011). A cellular automata model of land cover change to integrate urban growth with open space conservation. *Landscape and Urban Planning*, 99(2), 141-153.

- Mohammady, S., Delavar, M. R., & Pahlavani, P.** (2014). Urban growth modeling using an Artificial Neural Network a case study of Sanandaj city, Iran. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 40(2W3), 203-208.
- Nong, Y., & Du, Q.** (2011). Urban growth pattern modeling using logistic regression. *Geo-Spatial Information Science*, 14(1), 62-67.
- Park, S., Jeon, S., Kim, S., & Choi, C.** (2011). Prediction and comparison of urban growth by land suitability index mapping using GIS and RS in South Korea. *Landscape and Urban Planning*, 99(2), 104-114.
- Pijanowski, B. C., Brown, D. G., Shellito, B. A., & Manik, G. A.** (2002). Using neural networks and GIS to forecast land use changes: A Land Transformation Model. *Computers, Environment and Urban Systems*, 26(6), 553–575.
- Pijanowski, B. C., Tayyebi, A., Delavar, M. R., & Yazdanpanah, M. J.** (2009). Urban expansion simulation using geospatial information system and artificial neural networks. *International Journal of Environmental Research*, 3(4), 495–502.
- Soares-Filho, B. S., Cerqueira, G. C., & Pennachin, C. L.** (2002). DINAMICA—A stochastic cellular automata model designed to simulate the landscape dynamics in an Amazonian colonization frontier. *Ecological Modelling*, 154(3), 217–235.
- Silva, E. A., & Clarke, K. C.** (2002). Calibration of the SLEUTH urban growth model for Lisbon and Porto, Portugal. *Computers, Environment and Urban Systems*, 26(6), 525-552.
- Triantakonstantis, D., Stathakis, D., & Area, A. S.** (2015). Urban Growth Prediction in Athens, Greece, Using Artificial Neural Networks. 9(3), 234-238.
- Xu, S., Yan, Y., & diğ.** (2024). *ConvNeXt-CBAM*: Integrating CBAM and near-infrared data for improved land cover classification. In Proceedings of the Fifth International Conference on Control, Robotics, and Intelligent Systems.
- Veldkamp, A., & Fresco, L. O.** (1996). CLUE-CR: An integrated multi-scale model to simulate land use change scenarios in Costa Rica. *Ecological Modelling*, 91(1–3), 231-248.

- Verburg, P. H., Soepboer, W., Veldkamp, A., Limpiada, R., Espaldon, V., & Mastura, S. S. A. (2002).** Modeling the spatial dynamics of regional land use: The CLUE-S model. *Environmental Management*, 30(3), 391–405.
- Waddell, P. (2002).** UrbanSim: Modeling urban development for land use, transportation, and environmental planning. *Journal of the American Planning Association*, 68(3), 297–314.
- White, R., & Engelen, G. (1993).** Cellular Automata and Fractal Urban Form: A Cellular Modelling Approach to the Evolution of Urban Land-Use Patterns. *Environment and Planning A: Economy and Space*, 25(8), 1175-1199.
- White, R., & Engelen, G. (2000).** High-resolution integrated modelling of the spatial dynamics of urban and regional systems. *Computers, Environment and Urban Systems*, 24(5), 383–400.
- Wu, Fulong (2002).** Calibration of stochastic cellular automata: The application to rural-urban land conversions. *International Journal of Geographical Information Science*, 16(8), 795-818.
- Yang, Q., Li, X., & Shi, X. (2008).** Cellular automata for simulating land use changes based on support vector machines. *Computers and Geosciences*, 34(6), 592-602.
- Yang, Xin, Zheng, X. Q., & Lv, L. N. (2012).** A spatiotemporal model of land use change based on ant colony optimization, Markov chain and cellular automata. *Ecological Modelling*, 233, 11-19.
- Yüzer, M. A. (2004).** Growth estimations in settlement planning using a Land Use Cellular Automata Model (LUCAM). *European Planning Studies*, 12(4), 551-561.
- Zhang, H., Zeng, Y., Bian, L., & Yu, X. (2010).** Modelling urban expansion using a multi agent-based model in the city of Changsha. *Journal of Geographical Sciences*, 20(4), 540-556.
- Zhang, G., Roslan, S. N. A. B., Wang, C., & Quan, L. (2023).** Research on land cover classification of multi-source remote sensing data based on improved U-Net network. *Scientific Reports*, 13, Article 16275.

**Zhang, Y., Wang, L., Liu, Y., Chen, Y., & Zhao, Y. (2024).** A novel spatiotemporal urban land change simulation model: Transformer-CNN-CA. *Journal of Geographical Sciences*, 34(7), 1087–1103.

