



**PROPTECH ODAKLI TOPLU DEĞERLEME:
TUCBS VERİLERİNE DAYALI YAPAY ZEKÂ VE
COĞRAFİ BİLGİ SİSTEMLERİ PERSPEKTİFİ**

UZMANLIK TEZİ

HAZIRLAYAN: EMEL PERÇEM

Ankara – 2025



T.C.

ÇEVRE, ŞEHİRCİLİK VE İKLİM DEĞİŞİKLİĞİ BAKANLIĞI

**PROPTECH ODAKLI TOPLU DEĞERLEME:
TUCBS VERİLERİNE DAYALI YAPAY ZEKÂ VE
COĞRAFİ BİLGİ SİSTEMLERİ PERSPEKTİFİ**

TEZİ HAZIRLAYAN: EMEL PERÇEM

TEZ DANIŞMANI: AKIN KISA

BİRİM AMİRİ: ÖMER ALAN

Emel PERÇEM tarafından hazırlanan PropTech Odaklı Toplu Değerleme: TUCBS Verilerine Dayalı Yapay Zekâ ve Coğrafi Bilgi Sistemleri Perspektifi adlı bu tezin Coğrafi Bilgi Sistemi Uzmanlık Tezi olarak uygun olduğunu onaylarım.

Dr. Akın KISA

Tez Danışmanı

Bu çalışma, tez savunma komisyonumuz tarafından Coğrafi Bilgi Sistemi Uzmanlık Tezi olarak kabul edilmiştir.

Başkan: Genel Müdür, Ömer ALAN

Üye: Genel Müdür Yardımcısı, Dr. Akın KISA

Üye: Genel Müdür Yardımcısı, Mustafa Yavuz TORUN

Üye: Daire Başkanı, Emra SERT

Üye: Daire Başkanı, Bülent UZUNAY

Bu tez, Coğrafi Bilgi Sistemi Uzmanlığı Tez Hazırlama Yönergesi'ne uygundur.

İÇİNDEKİLER

ÖZET.....	viii
ABSTRACT.....	x
TEŞEKKÜR.....	xii
TABLO LİSTESİ.....	xiii
ŞEKİL LİSTESİ.....	xiv
KISALTMALAR.....	xvii
SEMBOLLER.....	xix
GİRİŞ.....	1

BÖLÜM 1

GAYRİMENKUL TEKNOLOJİLERİ (PROPTECH)

1.1. PropTech'in Tanımı ve Kapsamı.....	5
1.2. PropTech'in Evrimi.....	8
1.2.1. PropTech 1.0 (2000–2007).....	8
1.2.2. PropTech 2.0 (2008–2013).....	9
1.2.3. PropTech 3.0 (2014–2020).....	10
1.2.4. PropTech 4.0 (2020 ve sonrası).....	12
1.3. PropTech Ekosistemi.....	14
1.3.1. Akıllı Taşınmaz Teknolojileri.....	14
1.3.2. Nesnelerin İnterneti ve Akıllı Altyapılar.....	15
1.3.3. İnşaat Teknolojileri.....	18
1.3.4. Finans ve Yatırım Teknolojileri.....	19
1.3.5. Paylaşımlı Ekonomi.....	20
1.3.6. Dijital Pazar Yerleri.....	21
1.3.7. Veri Analitiği, Yapay Zekâ ve AVM'ler.....	22
1.3.8. Blokzincir ve Akıllı Sözleşmeler.....	23

1.4.	PropTech Pazarı	25
1.5.	Proptech Girişimlerinin Global ve Türkiye Örnekleri.....	29
1.5.1.	Akıllı Binalar ve IoT Çözümleri	30
1.5.2.	ConTech.....	31
1.5.3.	Gayrimenkul, Varlık ve Tesis Yönetimi.....	32
1.5.4.	FinTech ve InvestTech.....	33
1.5.5.	Aracılık ve Pazar Yerleri	34
1.5.6.	Veri Analitiği, Yapay zekâ ve AVM'ler.....	35
1.5.7.	Blokzincir ve Akıllı Sözleşmeler	36
1.5.8.	Sanal Gerçeklik ve Görselleştirme	37
1.5.9.	Sürdürülebilirlik ve ESG Uygulamaları	38
1.6.	Türkiye’de PropTech Ekosistemi: Mevcut Durum ve Gelişme Potansiyeli	39

BÖLÜM 2

ULUSLARARASI ÇALIŞMALAR

2.1.	Uluslararası ve Ulusal Gayrimenkul Değerleme Standartları ve Kurumları...	42
2.1.1.	RICS - Lisanslı Değerleme Uzmanlığı Kraliyet Enstitüsü	42
2.1.2.	IVSC - Uluslararası Değerleme Standartları Konseyi	43
2.1.3.	TEGoVA - Avrupa Değerleme Örgütleri Birliği.....	44
2.1.4.	TAF - ABD Değerleme Vakfı	45
2.1.5.	AI - ABD Değerleme Enstitüsü	45
2.1.6.	AIC - Kanada Değerleme Enstitüsü.....	46
2.1.7.	ASA - Amerikan Değerlemeciler Birliği	46
2.1.8.	IAAO - Uluslararası Değerlemeciler Birliği.....	47
2.1.9.	FIABCI - Uluslararası Taşınmaz Federasyonu.....	48
2.1.10.	Ce.S.E.T. - Taşınmaz Ekonomisi ve Değerleme Çalışmaları Merkezi	49
2.1.11.	CRE - Gayrimenkul Danışmanları Kuruluşu	50

2.1.12.	IFEI - Fransa Değerleme Enstitüsü.....	51
2.1.13.	HypZert – GmbH - Almanya Mortgage Sertifikasyonu Şirketi.....	52
2.1.14.	BVS - Federal Kamuya Atanan Yeminli Uzmanlar Birliği	52
2.1.15.	JAREA - Japon Gayrimenkul Değerlendiricileri Birliği.....	53
2.1.16.	API - Avustralya Emlak Enstitüsü	54
2.1.17.	RSA - Rusya Değerleme Uzmanları Derneği	54
2.1.18.	CAS - Çin Değerleme Topluluğu.....	55
2.1.19.	KAPA - Kore Mülkiyet Değerlendiricileri Derneği.....	56
2.1.20.	TDUB - Türkiye Değerleme Uzmanları Birliği	56
2.2.	Yurtdışı Örnekleri.....	57

BÖLÜM 3

ULUSAL ÇALIŞMALAR

3.1.	Gayrimenkul Değerine İlişkin Yasal Uygulamalar	73
3.1.1.	Temel Kanunlar ve Mevzuat.....	73
3.1.1.1.	Medeni Kanun (4721 sayılı Kanun).....	73
3.1.1.2.	Tapu Kanunu (2644 sayılı Kanun).....	74
3.1.1.3.	İmar Kanunu (3194 sayılı Kanun)	74
3.1.1.4.	Vergi Usul Kanunu (213 sayılı Kanun)	75
3.1.1.5.	Emlak Vergisi Kanunu (1319 sayılı Kanun).....	75
3.1.1.6.	Kamulaştırma Kanunu (2942 sayılı Kanun)	76
3.1.1.7.	Afet Riski Altındaki Alanların Dönüştürülmesi Hakkında Kanun (6306 sayılı Kanun)	77
3.1.1.8.	Sermaye Piyasası Kanunu (6362 sayılı Kanun)	77
3.1.1.9.	Konut Finansmanı Kanunu (5582 sayılı Kanun)	78
3.1.1.10.	Bankacılık Kanunu (5411 sayılı Kanun) ve ilgili BDDK Düzenlemeleri	79
3.1.1.11.	Özelleştirme Mevzuatı ve Diğer İlgili Yasal Dayanaklar	80

3.2.	Değerleme Amaçlı Kullanılan Farklı Değer Türleri	81
3.3.	Türkiye’de Gayrimenkul Değerleme ile İlgili Kurum ve Kuruluşlar.....	82
3.3.1.	Sermaye Piyasası Kurulu	83
3.3.2.	Bankacılık Düzenleme ve Denetleme Kurumu	84
3.3.3.	Türkiye Değerleme Uzmanları Birliği	85
3.3.4.	Milli Emlak Genel Müdürlüğü	86
3.3.5.	Belediyeler ve Diğer Kamu Kurumları.....	86
3.3.6.	Tapu ve Kadastro Genel Müdürlüğü	87
3.4.	Türkiye’de Toplu Değerleme Sistemine Yönelik Çalışmalar ve Pilot Uygulamalar.....	88

BÖLÜM 4

METODOLOJİ

4.1.	Gayrimenkul Değerleme	92
4.2.	Toplu Değerleme	94
4.3.	Değişkenlerin Belirlenmesi	108
4.4.	Coğrafi Bilgi Sistemleri.....	110
4.5.	Yapay Zekâ ve Makine Öğrenmesi Yöntemleri.....	113
4.6.	Regresyon Algoritmaları	116
4.6.1.	Karar Ağacı Algoritması.....	118
4.6.2.	Ensemble Learning Yöntemleri	119
4.6.3.	Bagging Tabanlı Yöntemler.....	120
4.6.3.1.	Random Forest Regressor	121
4.6.3.2.	Bagging Regressor	122
4.6.3.3.	Extra Trees Regressor	123
4.6.4.	Boosting Tabanlı Yöntemler.....	123
4.6.4.1.	Gradient Boosting Regressor	125

4.6.4.2.	AdaBoost Regressor.....	125
4.6.4.3.	CatBoost Regressor.....	126
4.6.4.4.	XGBoost Regressor.....	127
4.6.4.5.	LighGBM Regressor	128
4.7.	Model Performans Metrikleri.....	129
4.8.	Model Yorumlanabilirliği ve Açıklanabilir Yapay Zekâ Yöntemleri	131
4.8.1.	Küresel Açıklamalar – PFI Analizi.....	132
4.8.2.	Yerel Açıklamalar - SHAP Analizi	133

BÖLÜM 5

ÖRNEK UYGULAMA

5.1.	Çalışma Alanı	139
5.2.	Veri Seti.....	142
5.3.	Coğrafi Verilerin Analizi.....	145
5.3.1.	Yüzey Analizleri	145
5.3.2.	Yakınlık Analizleri	150
5.4.	Coğrafi Özelliklerin Entegrasyonu.....	172
5.5.	Keşifsel Veri Analizi	173
5.5.1.	İlçelere Göre Konut Değeri Dağılımı	174
5.5.2.	İlçe Bazında Konut Değeri ve Alan İlişkisi	175
5.5.3.	İlçe Bazında Mahallelere Göre Ortalama Konut Değeri	176
5.5.4.	İlçe Bazında Isınma Tiplerine Göre Alan-Fiyat İlişkisi.....	179
5.5.5.	İlçe Bazında Konutların Alan, Fiyat ve Merkeze Uzaklık İlişkisi.....	181
5.5.6.	İlçe Bazında Alan, Fiyat ve Alışveriş Merkezlerine.....	184
5.5.7.	İlçe Bazında Alan, Fiyat ve Havalimanına Uzaklık İlişkisi.....	186
5.5.8.	Bütünleşik Veri Seti Üzerinden Analizler	188
5.6.	Özellik Mühendisliği	196

5.7.	Başlangıç Model Eğitimi.....	200
5.8.	PFI Analizi ile Özellik Seçimi.....	205
5.9.	Hiperparametre Optimizasyonu.....	217
5.10.	İyileştirilmiş Model Eğitimi	222
5.11.	Başlangıç ve İyileştirilmiş Modellerin Karşılaştırmalı Analizi	227
5.12.	SHAP Analizi ile Model Açıklamaları	230
5.12.1.	Örnek No: 758.....	234
5.12.2.	Örnek No: 3095.....	237
5.12.3.	Örnek No: 5381	239
5.13.	Konut Değer Haritalarının Oluşturulması ve Paylaşımı	241
	SONUÇ VE ÖNERİLER	244
	KAYNAKLAR	250
	EK-1 PEARSON KORELASYON MATRİSİ	279
	EK-2 UYGULAMADA KULLANILAN PYTHON KODLARI.....	280
	ETİK KURALLARA UYGUNLUK BEYANI	295
	ÖZGEÇMİŞ	296

ÖZET

ÇEVRE, ŞEHİRCİLİK VE İKLİM DEĞİŞİKLİĞİ BAKANLIĞI	
Tezin Adı	PropTech Odaklı Toplu Değerleme: TUCBS Verilerine Dayalı Yapay Zekâ ve Coğrafi Bilgi Sistemleri Perspektifi
Türü	Coğrafi Bilgi Sistemi Uzmanlık Tezi
Yazar	Emel PERÇEM
Teslim Tarihi	25.08.2025
Anahtar Kelimeler	Gayrimenkul Teknolojileri, Toplu Değerleme, Makine Öğrenmesi, Coğrafi Bilgi Sistemleri, Açıklanabilir Yapay Zekâ, Türkiye Ulusal Coğrafi Bilgi Sistemi
Tez Danışmanı	Dr. Akın KISA
Sayfa Adedi	296
Gayrimenkul sektöründe teknolojik dönüşümün öncüsü olarak kabul edilen PropTech uygulamaları, değerlendirme süreçlerinde yapay zekâ ve coğrafi bilgi sistemlerinin (CBS) entegrasyonu ile hızla önem kazanmaktadır. Uluslararası düzeyde IVSC (Uluslararası Değerleme Standartları Konseyi), RICS (Lisanslı Değerleme Uzmanlığı Kraliyet Enstitüsü) ve TEGOVA (Avrupa Değerleme Örgütleri Birliği) gibi kuruluşlar, toplu değerlendirme uygulamalarında şeffaflık, doğruluk ve sürdürülebilirlik ilkelerini vurgulamaktadır. Bu bağlamda, makine öğrenmesi (ML) tabanlı modellerin CBS ile birlikte kullanımı gayrimenkul değerlemesinde nesnel, erişilebilir ve tekrarlanabilir sonuçlar üretme potansiyeli taşımaktadır. Türkiye’de ise değerlendirme süreçleri hâlen farklı kurumsal veri tabanları üzerinden yürütülmekte olup PropTech odaklı bütünsel bir sisteme tam olarak geçilememiştir. Bu çalışma, Türkiye Ulusal Coğrafi Bilgi Sistemi (TUCBS) verilerine dayalı bir uygulama geliştirerek uluslararası yaklaşımlarla karşılaştırmalı bir çerçeve sunmaktadır. Tez çalışması kapsamında Ankara’nın Yenimahalle ve Keçiören ilçelerine ait konut verileri kullanılarak ML yöntemleriyle toplu değerlendirme analizi gerçekleştirilmiştir. Çalışmanın amacı, farklı ML algoritmalarının performanslarını karşılaştırmak, açıklanabilir yapay zekâ (XAI) yöntemleriyle model karar mekanizmalarını yorumlamak ve konut değerlerinin mekânsal dağılımını	

görselleştirmektedir. Yöntemsel olarak, veri seti coğrafi olarak zenginleştirilerek hazırlanmış, ardından Random Forest, Extra Trees, Bagging, Gradient Boosting, AdaBoost, XGBoost, LightGBM ve CatBoost algoritmaları test edilmiştir. Özellik seçimi için Permütasyon Tabanlı Özellik Önemi (PFI) analizi yapılmış, katkısı düşük değişkenler çıkarılmıştır. GridSearchCV ile hiperparametre optimizasyonu gerçekleştirilmiş, en iyi parametrelerle modeller yeniden eğitilmiş ve performanslar R^2 (Belirleme Katsayısı), RMSE (Ortalama Kök Karesel Hata) ve MAE (Ortalama Mutlak Hata) metrikleriyle değerlendirilmiştir. SHAP (Shapley Additive Explanations) analiziyle değişkenlerin tahmin üzerindeki yönlü ve nicel etkileri açıklanmıştır. Ayrıca, altıgen ızgara gösterimi üzerinden ortalama konut değer haritaları üretilmiş ve servis edilmiştir.

Bulgular, konut değerlerini belirleyen en önemli faktörlerin fiziksel yapı özellikleri olduğunu göstermektedir. Özellikle toplam kat sayısı, brüt alan, bina yaşı ve bulunduğu kat değişkenleri öne çıkmıştır. Mekânsal erişim değişkenleri orta düzeyde etkili olurken, sosyal ve çevresel göstergeler sınırlı katkı göstermiştir. Model karşılaştırmalarında XGBoost, LightGBM ve Random Forest 0.91–0.92 aralığında R^2 değerleriyle en başarılı modeller olmuştur. LightGBM kısa eğitim süresiyle zaman-performans dengesinde öne çıkmıştır. SHAP analizi modellerin şeffaf biçimde yorumlanmasına imkân tanımış, yatırımcılar ve politika yapıcılar açısından güvenilir bir karar desteği sağlamıştır.

Sonuç olarak, bu çalışma ML, CBS ve XAI entegrasyonunu bir araya getirerek Türkiye’de konut değerlendirme süreçlerine hem bilimsel hem de uygulamalı düzeyde önemli katkılar sunmaktadır. Elde edilen modellerin bankacılık, gayrimenkul değerlendirme, emlak vergisi ve kentsel planlama gibi alanlarda kullanılabileceği öngörülmektedir. Ayrıca geliştirilen konut değer haritaları, mekânsal eşitsizliklerin belirlenmesi ve sosyal konut politikalarının planlanmasında stratejik bir referans oluşturmaktadır.

ABSTRACT

MINISTRY OF ENVIRONMENT, URBANIZATION AND CLIMATE CHANGE	
Thesis	PropTech-Oriented Mass Appraisal: An Artificial Intelligence and Geographic Information Systems Perspective Based on TUCBS Data
Type	Geographic Information System Specialization Thesis
Author	Emel PERÇEM
Submission Date	25.08.2025
Key Words	Property Technology, Mass Appraisal, Machine Learning, Geographic Information Systems, Explainable Artificial Intelligence, Turkish National Geographic Information System
Advisor	Dr. Akın KISA
Total Page	296
PropTech applications, recognized as the driving force of technological transformation in the real estate sector, have rapidly gained importance through the integration of artificial intelligence and Geographic Information Systems (GIS) into valuation processes. At the international level, institutions such as the International Valuation Standards Council (IVSC), the Royal Institution of Chartered Surveyors (RICS), and the European Group of Valuers' Associations (TEGOVA) emphasize transparency, accuracy, and sustainability in mass appraisal practices. In this context, the integration of machine learning (ML) models with GIS offers the potential to generate more objective, accessible, and reproducible results in property valuation. In Turkey, however, valuation processes are still conducted through various institutional databases, and a fully integrated PropTech-based system has not yet been established. This study presents a practical example of how AI- and GIS-based mass appraisal systems can be implemented in Turkey by utilizing data from the Turkish National Geographic Information System (TUCBS) and providing a comparative perspective with international approaches. Within the scope of the thesis, housing data from the Yenimahalle and Keçiören districts of Ankara were analyzed using ML methods for mass appraisal. The study aimed to compare the performance of different ML algorithms, interpret	

model decision-making mechanisms through explainable AI (XAI) methods, and visualize the spatial distribution of housing values. Methodologically, the dataset was geographically enriched and prepared, followed by testing several algorithms including Random Forest, Extra Trees, Bagging, Gradient Boosting, AdaBoost, XGBoost, LightGBM, and CatBoost. Permutation Feature Importance (PFI) was applied for feature selection, eliminating variables with low contribution. Hyperparameter optimization was performed with GridSearchCV, and the models were retrained with the best parameters. Model performance was evaluated using R^2 (Coefficient of Determination), RMSE (Root Mean Squared Error), and MAE (Mean Absolute Error) metrics, while SHAP (Shapley Additive Explanations) analysis was employed to explain the directional and quantitative impacts of the features. In addition, average housing value maps were generated and published using a hexagonal grid structure through ArcGIS Pro.

The findings revealed that physical building attributes were the most influential determinants of housing values, particularly total number of floors, gross area, building age, and floor level. While accessibility variables (e.g., distance to public transport or airport) showed moderate effects, social and environmental indicators had limited contributions. Model comparisons demonstrated that XGBoost, LightGBM, and Random Forest achieved the best performance with R^2 values in the range of 0.91–0.92. LightGBM, in particular, stood out with its balance of short training time and high accuracy. SHAP analysis enabled transparent interpretation of model decisions, providing a reliable decision-support mechanism for investors and policymakers.

In conclusion, this study integrates ML, GIS, and XAI to make significant contributions to property valuation processes in Turkey, both at the scientific and applied levels. The developed models can serve as decision-support tools in banking, real estate appraisal, property taxation, and urban planning. Furthermore, the generated housing value maps constitute a strategic reference for identifying spatial inequalities and planning social housing policies.

TEŞEKKÜR

Tez sürecim boyunca bilgi ve deneyimiyle her aşamada yol gösteren, akademik desteğini ve yapıcı eleştirilerini esirgemeyen tez danışmanım Sayın Dr. Akın KISA'ya içtenlikle teşekkür ederim.

Çalışmanın hazırlık aşamasında, birçok akademisyenle temasa geçtim. Yanıtların sınırlı kaldığı bu süreçte, Dünya Bankası Gayrimenkul Değerleme Uzmanlarından Sayın Richard GROVER ile PropTech Academy kurucu ortağı Sayın Deniz KARAHAN'ın paylaştığı kaynaklar ve yönlendirmeler, çalışmanın yönünün belirlenmesinde önemli rol oynamıştır. Kendilerine nazik ilgileri ve değerli paylaşımları için teşekkür ederim.

Tez çalışmam süresince gerekli imkânları sağlayarak araştırmalarımın yoğunlaşmam için alan açan ve desteğini esirgemeyen Genel Müdürüm Sayın Ömer ALAN'a teşekkür ederim.

Hayatım boyunca her koşulda yanımda olan değerli aileme minnettarım. Sevgili annem, kıymetli kardeşlerim ve hayatıma neşe katan yeğenlerim, verdikleri manevi destek ve sevgileriyle bu sürecin en güçlü dayanağı olmuşlardır.

Ayrıca süreç boyunca yanımda olan, gösterdikleri dayanışmayla beni her zaman motive eden sevgili arkadaşlarıma da teşekkür ederim.

Emel PERÇEM

TABLO LİSTESİ

Tablo 1. Diğer Ülkelerde Uygulanan Toplu Değerleme Yöntemleri, Sorumlu Kurumlar ve Yasal Dayanakları.....	60
Tablo 2. Literatürdeki Toplu Değerleme Çalışmalarında Kullanılan Veri Setleri, Metot ve Bulguların Özeti.	98
Tablo 3. TUCBS'den Temin Edilen Katmanlar.....	143
Tablo 4. Çalışmada Kullanılan Coğrafi Veri Seti	198
Tablo 5. Başlangıç Model Performans Karşılaştırması.....	201
Tablo 6. Regresyon Modellerinin PFI Sonuçlarının Karşılaştırması	214
Tablo 7. İyileştirilmiş Model Performans Karşılaştırması.....	223
Tablo 8. Başlangıç ve İyileştirilmiş Model Performans Karşılaştırması	228

ŞEKİL LİSTESİ

Şekil 1. PropTech kapsamı.....	7
Şekil 2. PropTech firmalarının küresel dağılımı.	26
Şekil 3. Ülke Başına PropTech Firma Sayısı (Her 1 Milyonda)	27
Şekil 4. Bölgeye Göre PropTech Pazar Payı.....	28
Şekil 5. PropTech Pazar Boyutu.	29
Şekil 6. FIABCI Kurumsal ve Düzenli Üyeler Haritası.....	48
Şekil 7. Toplu değerlendirme yöntemlerinin kavramsal şeması.....	95
Şekil 8. Yapay zekâ, makine öğrenmesi, derin öğrenme hiyerarşisi.	114
Şekil 9. Karar ağacının şematik gösterimi.	118
Şekil 10. Bagging çalışma mantığı.	120
Şekil 11. Boosing çalışma mantığı.....	124
Şekil 12. Yaprak Bazlı ve Seviye Bazlı Büyüme Yaklaşımları.	128
Şekil 13. Örnek Uygulamada Kullanılan Yöntemlere Ait İş Akış Şeması	136
Şekil 14. Çalışmada Kullanılan Yöntemlere Ait İş Akış Şeması (Devamı)	137
Şekil 15. Çalışmada Kullanılan Yöntemlere Ait İş Akış Şeması (Devamı)	138
Şekil 16. Konut Satış Adedi En Yüksek İller.....	139
Şekil 17. Gayrimenkul Değerleme Raporu Sayısı En Yüksek İlçeler	140
Şekil 18. Çalışma Alanı	142
Şekil 19. Temin Edilen Verilerin Gösterimi	144
Şekil 20. Topoğrafya Haritası	146
Şekil 21. Eğitim Analizi	147
Şekil 22. Bakı Analizi	148
Şekil 23. Park Alanlarına Yakınlık Analizi.....	151
Şekil 24. Güvenlik Merkezlerine Yakınlık Analizi.....	152
Şekil 25. Askeri Alanlara Yakınlık Analizi	153
Şekil 26. Endüstri Bölgelerine Yakınlık Analizi.....	154
Şekil 27. Okullara Yakınlık Analizi.....	155
Şekil 28. Üniversitelere Yakınlık Analizi	156
Şekil 29. Hastanelere Yakınlık Analizi.....	157
Şekil 30. Havalimanına Yakınlık Analizi	158
Şekil 31. İbadet Yerlerine Yakınlık Analizi.....	159

Şekil 32. İtfaiye Merkezlerine Yakınlık Analizi	160
Şekil 33. Kültür Merkezlerine Yakınlık Analizi	161
Şekil 34. Mahalle Merkezlerine Yakınlık Analizi	162
Şekil 35. Metro İstasyonlarına Yakınlık Analizi.....	163
Şekil 36. Otobüs Duraklarına Yakınlık Analizi	164
Şekil 37. Pazar Yerlerine Yakınlık Analizi.....	165
Şekil 38. Turizm Merkezlerine Yakınlık Analizi.....	166
Şekil 39. Yollara Yakınlık Analizi.....	167
Şekil 40. Mezarlıklara Yakınlık Analizi	168
Şekil 41. Atık Alanlarına Yakınlık Analizi.....	169
Şekil 42. Nüfus Yoğunluğu Haritası	170
Şekil 43. Bina Yoğunluğu Analizi	171
Şekil 44. İlçelerin Konut Değeri Dağılımı	175
Şekil 45. Konut Değeri ve Alan Dağılımı.....	176
Şekil 46. Keçiören Mahallelerine Göre Ortalama Konut Değeri.....	177
Şekil 47. Yenimahalle Mahallelerine Göre Ortalama Konut Değeri	178
Şekil 48. Keçiören İlçesi Farklı Isınma Tiplerine Göre Alan-Fiyat İlişkisi.....	179
Şekil 49. Yenimahalle İlçesi Farklı Isınma Tiplerine Göre Alan-Fiyat İlişkisi	180
Şekil 50. Keçiören İlçesi Brüt Alan, Fiyat ve Merkeze Uzaklık İlişkisi.....	182
Şekil 51. Yenimahalle İlçesi Brüt Alan, Fiyat ve Merkeze Uzaklık İlişkisi	183
Şekil 52. Keçiören ve Yenimahalle İlçeleri Brüt Alan, Fiyat ve Alışveriş Merkezlerine Uzaklık İlişkisi	185
Şekil 53. Keçiören ve Yenimahalle İlçeleri Brüt Alan, Fiyat ve Havalimanına Uzaklık İlişkisi.....	186
Şekil 54. Konut Değeri Dağılımı	188
Şekil 55. Konut Değeri ve Brüt Alan Dağılımı.....	189
Şekil 56. Mahallelere Göre Ortalama Konut Değeri.....	190
Şekil 57. Veri Setinin Tanımlayıcı İstatistikleri	191
Şekil 58. Veri Setinin Tanımlayıcı İstatistikleri (Devamı)	192
Şekil 59. Konut Değeri ile Tüm Bağımsız Değişkenler Arasındaki İlişki.....	195
Şekil 61. Başlangıç Model R^2 Değerlerinin Karşılaştırma Grafiği	202
Şekil 62. Başlangıç Model MAE Değerlerinin Karşılaştırma Grafiği	203

Şekil 63. Başlangıç Model RMSE Değerlerinin Karşılaştırma Grafiği	204
Şekil 64. Random Forest PFI	206
Şekil 65. Extra Trees PFI	207
Şekil 66. Bagging PFI	208
Şekil 67. Gradient Boosting PFI	209
Şekil 68. AdaBoost PFI.....	210
Şekil 69. CatBoost PFI.....	211
Şekil 70. XGBoost PFI.....	212
Şekil 71. LGBM PFI	213
Şekil 72. Pearson Korelasyon Haritası (PFI Sonrası)	216
Şekil 73. Random Forest, Extra Trees, Bagging ve Gradient Boosting Regresyonları İçin Parametre Aralıkları.....	218
Şekil 74. AdaBoost, CatBoost, XGBoost ve LightGBM Regresyonları İçin Parametre Aralıkları	219
Şekil 75. GridSearchCV Hiperparametre Arama Süreci.....	220
Şekil 76. İyileştirilmiş Model R^2 Değerlerinin Karşılaştırma Grafiği	224
Şekil 77. İyileştirilmiş Model MAE Değerlerinin Karşılaştırma Grafiği	225
Şekil 78. İyileştirilmiş Model RMSE Değerlerinin Karşılaştırma Grafiği	226
Şekil 79. LGBM Modelinin Gerçek ve Tahmin Değerlerinin Karşılaştırılması.....	229
Şekil 80. SHAP Değeri Özellik Önemi.....	231
Şekil 81. SHAP Değeri Beeswarm Grafiği	232
Şekil 82. Örnek 758 SHAP Force Grafiği.....	234
Şekil 83. Örnek 758 SHAP Waterfall Grafiği.....	235
Şekil 84. Örnek 3095 SHAP Force Grafiği.....	237
Şekil 85. Örnek 3095 SHAP Waterfall Grafiği.....	238
Şekil 86. Örnek 5381 SHAP Force Grafiği.....	239
Şekil 87. Örnek 5381 SHAP Waterfall Grafiği.....	240
Şekil 88. Yenimahalle ve Keçiören İlçeleri Konut Değeri Haritası.....	242

KISALTMALAR

3B: 3 Boyutlu

AVM: Otomatik Değerleme Modeli (Automated Valuation Model)

BIM: Bina Bilgi Modellemesi (Building Information Modeling)

CAMA: Bilgisayar Destekli Toplu Değerleme (Computer-Assisted Mass Appraisal)

CatBoost: Category Boosting

CBS: Coğrafi Bilgi Sistemleri

ConTech: Construction Technology (İnşaat Teknolojileri)

DEM: Digital Elevation Model (Dijital Yükseklik Modeli)

EDA: Exploratory Data Analysis (Keşifsel Veri Analizi)

ESG: Environmental, Social, Governance (Çevresel, Sosyal ve Yönetişim)

EVS: European Valuation Standards (Avrupa Değerleme Standartları)

FIABCI: International Real Estate Federation (Uluslararası Taşınmaz Federasyonu)

FinTech: Financial Technology (Finansal Teknolojiler)

GWR: Geographically Weighted Regression (Coğrafi Ağırlıklı Regresyon)

IAAO: International Association of Assessing Officers (Uluslararası Değerlemeciler Birliği)

InvestTech: Investment Technology (Yatırım Teknolojileri)

IVS: International Valuation Standards (Uluslararası Değerleme Standartları)

IVSC: International Valuation Standards Council (Uluslararası Değerleme Standartları Konseyi)

LightGBM: Light Gradient Boosting Machine

MAE: Mean Absolute Error (Ortalama Mutlak Hata)

MRA: Multiple Regression Analysis (Çoklu Regresyon Analizi)

MSE: Mean Squared Error (Ortalama Kare Hata)

ML: Machine Learning (Makine Öğrenmesi)

PFI: Permutation Feature Importance (Permütasyon Temelli Özellik Önemi)

PropTech: Property Technology (Gayrimenkul Teknolojileri)

RICS: Royal Institution of Chartered Surveyors (Lisanslı Değerleme Uzmanlığı Kraliyet Enstitüsü)

SHAP: Shapley Additive Explanations

UDS: Türkiye Değerleme Standartları

SPK: Sermaye Piyasası Kurulu

BDDK: Bankacılık Düzenleme ve Denetleme Kurumu

TKGM: Tapu ve Kadastro Genel Müdürlüğü

TAKBİS: Tapu ve Kadastro Bilgi Sistemi

TKMP: Tapu ve Kadastro Modernizasyon Projesi

TDUB: Türkiye Değerleme Uzmanları Birliği

TUCBS: Türkiye Ulusal Coğrafi Bilgi Sistemi

TEGoVA: The European Group of Valuers' Associations (Avrupa Değerleme Örgütleri Birliği)

USPAP: Uniform Standards of Professional Appraisal Practice (Mesleki Değerlendirme Uygulamalarının Standartları)

XGBoost: Extreme Gradient Boosting

XAI: Explainable Artificial Intelligence (Açıklanabilir Yapay Zekâ)

SEMBOLLER

X : Bağımsız değişken

Y : Bağımlı değişken

n : Örneklem büyüklüğü

R^2 : Belirleme katsayısı

r : Korelasyon katsayısı

Σ : Toplam

y : Gerçek değer,

$\hat{y}$: Tahmin değeri

$\bar{y}$: Ortalama değer

N : Örneklem sayısı

p : Bağımsız değişken sayısını ifade eder.

m^2 : Metrekare

$\approx$: Yaklaşık eşittir işareti

TL : Türk lirası

GİRİŞ

Gayrimenkul, arsa ve üzerinde sabit nitelikteki yapılar ile eklentilerinden oluşan ve hukuken taşınmaz olarak tanımlanan varlıklardır. Tapu siciline tescil edilen bu taşınmazlar mülkiyet devrine konu olabilir. Bireyler ve kurumlar; barınma, kira geliri elde etme, sermaye birikimi ya da yatırım yapma gibi amaçlarla gayrimenkul alım-satımı gerçekleştirir. Piyasanın istikrarlı ve güvenilir işleyebilmesi, değerlendirme süreçlerinin nesnel, doğru ve güvenilir yöntemlere dayanmasına bağlıdır. Bu nitelikleri taşımayan değerlendirme uygulamaları yalnızca piyasa işleyişini olumsuz etkilemekle kalmaz, aynı zamanda emlak vergisi ve tapu harcı gibi kamu gelirlerinin adil ve etkin tahsilini de güçleştirir. Bu nedenle gayrimenkul değerlendirme, konut sektörü başta olmak üzere gayrimenkule dayalı pek çok alanda temel bir unsur olarak öne çıkmaktadır.

Son yıllarda dijitalleşmenin hız kazanmasıyla gayrimenkul sektöründe teknolojik çözümlerin kullanımında büyük artış yaşanmıştır. Bu bağlamda ortaya çıkan Gayrimenkul Teknolojileri (*PropTech, Property Technology*) kavramı; yapay zekâ, büyük veri analitiği, coğrafi bilgi sistemleri (CBS), blokzincir, artırılmış gerçeklik, sanal gerçeklik ve nesnelerin interneti (IoT) gibi teknolojilerin sektöre entegrasyonunu ifade etmektedir. PropTech uygulamaları; şeffaflık, hız, verimlilik ve veri odaklı karar desteği sağlayarak gayrimenkul değerlendirme süreçlerinde önemli dönüşümler yaratmaktadır. Özellikle Otomatik Değerleme Modelleri (AVM), makine öğrenmesi (ML) algoritmaları ile geniş veri kümeleri üzerinden hızlı ve sistematik tahminler üretmekte; bankacılık, sigortacılık ve yatırım kararlarında yaygın biçimde kullanılmaktadır (RICS, 2022). Ayrıca CBS tabanlı analizler taşınmazın konumu, çevresel koşulları, ulaşım imkânları ve sosyal donatı alanlarına olan mesafesi gibi mekânsal faktörleri değerlendirmekte; blokzincir teknolojisi ise gayrimenkul işlemlerine ilişkin kayıtları değiştirilemez biçimde saklayarak şeffaflığı ve güveni artırmaktadır. Bunun yanı sıra artırılmış ve sanal gerçeklik uygulamaları, henüz inşa edilmemiş projelerin görselleştirilerek değerlendirme sürecinde kullanılmasına olanak tanımaktadır.

Türkiye’de de PropTech ekosistemi son yıllarda gelişim göstermektedir. Endeksa, Tapusor, Fizbot ve Get Twin gibi girişimler; yapay zekâ, büyük veri ve dijital ikiz teknolojilerini kullanarak değerlendirme, müşteri ilişkileri yönetimi, pazar analizi ve

yatırım karar destek sistemleri alanlarında yenilikçi çözümler sunmaktadır. Bu gelişmeler, sektörde şeffaflık, hız ve verimliliği artırmakta ve PropTech uygulamalarının değerlemeden pazarlamaya kadar birçok alanda dönüşüm potansiyeli taşıdığını göstermektedir.

Bununla birlikte, kamu verilerine dayalı olarak geliştirilmiş, vatandaşların erişimine açık ve kamu otoriteleri tarafından işletilen kapsamlı bir PropTech platformu henüz mevcut değildir. Ancak 12. Kalkınma Planı'nın 776.2 numaralı maddesinde, "Gayrimenkul değerlemesi için taşınmazların güncel değerlerini ilgili kurumlarla koordinasyon içinde kayıt altına alan bir veri tabanı oluşturulacak ve bilgisayar destekli toplu değerlendirme yöntemlerinin uygulanmasına yönelik çalışmalar yürütülecektir." ifadesiyle bu alandaki hedefler açıkça ortaya konulmuştur. Ayrıca TUCBS kapsamında kamu kurum ve kuruluşları aracılığıyla 520 farklı veri seti yetkili paydaşların erişimine açılmıştır.

Bu tez çalışmasının amacı, kamu verilerinden yararlanarak teknolojik gelişmeler, yapay zekâ uygulamaları ve yenilikçi yaklaşımlar doğrultusunda ML ve CBS yöntemleri kullanılarak toplu değerlendirme gerçekleştirmektir. Bunun yanında, geliştirilen modellerin sonuçlarını XAI yaklaşımıyla açıklamak, gayrimenkul değer haritaları üretmek ve bu haritaları e-Devlet altyapısı üzerinden ilgili paydaşların erişimine sunmak suretiyle örnek bir uygulama ortaya koymak hedeflenmektedir.

Literatür incelendiğinde, yurt dışındaki toplu değerlendirme çalışmalarında kamu verilerinin yanı sıra özel sektör verilerinin de etkin biçimde kullanıldığı görülmektedir. Bu tez çalışmasının kapsamı ise TUCBS bünyesinde yer alan kamu kurum ve kuruluşlarının sunduğu veri setleri ile Endeksa firmasından temin edilen satış verilerinden oluşmaktadır. Çalışma, Ankara ili Yenimahalle ve Keçiören ilçeleriyle sınırlandırılmıştır. Bu kapsamda, konut verileri mekânsal bağlamsal özniteliklerle zenginleştirilmiş; gerekli veri ön işleme adımlarının ardından ML algoritmalarıyla modellenmiştir. Elde edilen sonuçlar XAI yöntemleriyle açıklanmış, altıgen ızgara tabanlı değer haritalarına dönüştürülmüş ve web ortamında sunularak karar destek amaçlı kullanılabilirliği ortaya konulmuştur.

Çalışma kapsamında geliştirilen modelin, Türkiye’de PropTech temelli kamu uygulamalarına katkı sağlaması; şeffaf, açıklanabilir ve kamuya açık bir değerlendirme altyapısının oluşturulmasına zemin hazırlaması amaçlanmaktadır.

Bu doğrultuda aşağıdaki araştırma sorularına yanıt aranmıştır:

- PropTech kavramı nasıl tanımlanmakta ve sektöre hangi kolaylıkları sağlamaktadır?
- Yurt dışında gayrimenkulün toplu değerlemesi hangi yöntemlerle yapılmakta ve bu alandaki yetkin kuruluşlar hangileridir?
- Türkiye’de mevcut durum nedir, sorumlu kuruluşlar ve yasal düzenlemeler nelerdir?
- Farklı ML algoritmaları ile yapılan toplu değerlemede hangi yöntemler daha yüksek performans göstermektedir?
- Konut değerini en fazla etkileyen değişkenler hangileridir?
- Model çıktısına göre hangi özellikler tahmin değerine hangi yönde ve ne ölçüde katkı sağlamaktadır?

Tezin birinci bölümünde, PropTech kavramı tanımlanmış; kavramın evrimi, kapsamı ve toplu değerlendirme süreçleriyle ilişkisi açıklanmış, ayrıca Türkiye’deki PropTech ekosistemi değerlendirilmiştir.

İkinci bölümde, uluslararası değerlendirme kuruluşları ve standartlar incelenmiş; farklı ülkelerde uygulanan toplu değerlendirme sistemlerine ilişkin literatür sunulmuş ve bu sistemlerin Türkiye açısından uyarlanabilir yönleri tartışılmıştır.

Üçüncü bölümde, Türkiye’deki mevcut durum ele alınmış; gayrimenkul değerlemesine yönelik yasal düzenlemeler, ulusal düzeydeki kurumlar incelenmiştir. Ayrıca Türkiye’de toplu değerlendirme sistemine geçiş sürecine ilişkin yürütülen çalışmalar değerlendirilmiştir.

Dördüncü bölümde, gayrimenkul değerlendirme yöntemleri genel hatlarıyla tanıtılmış; toplu değerlendirme yöntemlerine yönelik literatür incelenmiş ve tez kapsamında kullanılacak makine öğrenmesi algoritmalarının teorik temelleri ile metodolojik yaklaşımlar ayrıntılı biçimde açıklanmıştır.

Beşinci bölümde, tez kapsamında yürütülen uygulama çalışması sunulmuştur. Çalışma alanı olarak seçilen Ankara'nın Yenimahalle ve Keçiören ilçeleri; yüksek işlem hacmi, konut satış yoğunluğu ve sosyo-demografik çeşitlilik gerekçeleriyle tanıtılmıştır. Veri seti, TUCBS'den temin edilen mekânsal veriler ve Endeksa firmasından sağlanan satış verilerinin entegrasyonu ile oluşturulmuş; mekânsal bağlamsal özniteliklerle zenginleştirilmiştir. Veri ön işleme sürecinden sonra veri seti üzerinde Random Forest, Extra Trees, Bagging, Gradient Boosting, AdaBoost, CatBoost, XGBoost ve LightGBM algoritmaları eğitilmiş; modellerin performansları R^2 (Belirleme Katsayısı), MAE (Ortalama Mutlak Hata) ve RMSE (Ortalama Kök Kare Hata) metrikleri kullanılarak karşılaştırılmıştır. Ayrıca, model sonuçlarının açıklanabilirliği için PFI yöntemiyle özellik önem düzeyleri belirlenmiş ve SHAP analizi ile her bir değişkenin tahminlere olan katkısı ayrıntılı biçimde değerlendirilmiştir. Sonrasında altıgen ızgara tabanlı konut değer haritaları üretilmiş ve bu haritalar web ortamında sunularak karar destek amaçlı kullanılabilirlikleri gösterilmiştir.

Son bölümde, elde edilen bulgular tartışılmış; geliştirilen modelin güçlü yönleri ve sınırlılıkları ortaya konulmuş, politika yapıcılar ve uygulayıcılar için çıkarımlar yapılmış ve gelecekteki araştırmalara yönelik öneriler sunulmuştur.

BÖLÜM 1

GAYRİMENKUL TEKNOLOJİLERİ (PROPTech)

Gayrimenkul sektörü, uzun yıllar boyunca geleneksel yöntemlerle değerlendirme, alım-satım ve yönetim süreçlerini sürdürmüştür. Ancak dijitalleşme, büyük veri ve yapay zekâ gibi teknolojik gelişmeler, sektörde dönüşümü zorunlu kılmıştır. PropTech, gayrimenkul sektöründe bu dönüşümü hızlandıran, iş süreçlerini veri ve teknolojiyle optimize eden çözümleri ifade eder. Bu bölümün amacı; PropTech kavramını tanımlamak, kapsamını ortaya koymak, tarihsel evrimini incelemek, global ve ulusal örnekleri ele almak ve Türkiye’deki PropTech ekosisteminin mevcut durum ve gelişme potansiyelini ortaya koymaktır.

Bu çerçevede, PropTech olgusunun kuramsal temelini sağlamlaştırmak ve sektördeki uygulanma biçimlerini daha iyi kavrayabilmek adına, öncelikle kavramın tanımı ve kapsamı ayrıntılı biçimde ele alınacaktır.

1.1. PropTech’in Tanımı ve Kapsamı

Property (taşınmaz/gayrimenkul) ve *technology* (teknoloji) kavramlarının anlamlarını incelemek, *property technology* (PropTech) teriminin yalnızca sözlük düzeyinde değil, aynı zamanda sektörel, kavramsal ve pazar dinamikleri açısından taşıdığı anlamı derinlemesine kavramak için temel bir başlangıç noktasıdır. Bu iki kavramın etkileşiminden doğan yeni yapının anlaşılması, gayrimenkul sektöründe teknolojik dönüşümün kapsamını ve etkisini değerlendirmek açısından önemlidir.

Property, en genel anlamıyla fiziksel mülkiyet hakkına konu olan taşınmaz varlıkları kapsar. Bu kategoriye; konut, ticari yapı, sanayi tesisi, arsa ve arazi gibi çeşitli gayrimenkul türleri dahildir. Gayrimenkul sektörü ise bu varlıkların edinimi, geliştirilmesi, yönetimi, kullanımı ve el değiştirmesi süreçlerini içeren geniş ve çok boyutlu bir ekonomik alandır. Sektörün temel işlevleri arasında yatırım, finansman, değerlendirme, pazarlama ve yönetim süreçleri bulunmaktadır (Braesemann & Baum, 2020a; Karahan, 2023b).

Diğer yandan *technology*, bilgiyi ve uzmanlığı sistematik biçimde kullanarak ürün ve hizmetlerin geliştirilmesine imkân sağlayan araç, yöntem, süreç ve

uygulamalar bütünü temsil eder. Teknoloji, dijitalleşme, otomasyon, veri analitiği, yapay zekâ, ML, IoT ve blokzincir gibi çok çeşitli alt bileşenleri içeren, sürekli gelişen ve dönüştürücü bir yapıya sahiptir (Cruz Rambaud & López Pascual, 2023; J. Yang, 2024a).


Bu iki kavramın etkileşiminden doğan PropTech, gayrimenkul sektörünün dijitalleşmesini, teknoloji temelli yeniden yapılandırılmasını ve iş modellerinin dönüşümünü ifade eden çok boyutlu bir olgu olarak tanımlanabilir. PropTech; veri üretimi, işleme ve analizinden, dijital işlem platformlarına ve akıllı yönetim sistemlerine kadar gayrimenkul değer zincirinin tüm aşamalarında teknolojinin sistematik entegrasyonunu ve kullanımını kapsamaktadır (Baum, 2017; Braesemann & Baum, 2020a).

PropTech, yalnızca dijital araçların sektöre entegrasyonunu değil, aynı zamanda veri temelli karar alma süreçlerinin gelişimini, operasyonel verimlilik artışını, piyasa şeffaflığının iyileştirilmesini ve müşteri deneyimlerinin yeniden tasarlanmasını da içeren kapsamlı bir dönüşümü temsil eder (Llorca-Ponce & Rius-Sorolla, 2023; Maalsen vd., 2024). Bu bağlamda PropTech, gayrimenkul piyasasında yeni iş modellerinin (ör. dijital mülkiyet platformları, tokenizasyon), AVMLer ve akıllı altyapıların yaygınlaşmasının önünü açmaktadır (Cruz Rambaud & López Pascual, 2023; J. Yang, 2024a). Bu bütüncül perspektif ışığında PropTech, yalnızca teknolojik bir yenilik alanı değil, aynı zamanda gayrimenkul sektörünün iş yapış biçimlerini ve değer yaratma süreçlerini köklü biçimde dönüştüren bir dijitalleşme dalgası olarak ele alınmalıdır (Baum vd., 2020).

PropTech kavramı kapsam olarak oldukça geniştir ve gayrimenkulün yaşam döngüsündeki hemen her adımı içine alır. Yönetim, yatırım, alım-satım, kiralama, inşaat ve tasarım gibi süreçlerin tamamı PropTech uygulamalarının alanına girmektedir. Örneğin, dijital yenilikler sayesinde gayrimenkul varlık yönetimi, emlak yatırımları, pazarlama ve satış işlemleri ile inşaat projeleri daha verimli ve şeffaf hale getirilebilmektedir. Bu kapsamda PropTech, inşaat şirketlerinden gayrimenkul danışmanlarına, yatırımcılardan son kullanıcılara kadar sektördeki tüm aktörleri ilgilendiren bir dönüşümü ifade eder. PropTech, geleneksel emlak piyasasında uzun yıllardır süre gelen kâğıt tabanlı, emek-yoğun ve yerel uygulamaların yerine dijital,

otomasyona dayalı ve ölçeklenebilir uygulamaları getirmektedir. Sonuç olarak, gayrimenkul aramasından değerlendirme ve satış sonrası yönetime kadar tüm süreçler teknoloji desteğiyle yeniden tanımlanmaktadır.

Şekil 1. PropTech kapsamı.



Kaynak: (Freshcode, 2025)

Kapsamı Şekil 1’de verilen PropTech, çoğunlukla finansal teknolojiler (*FinTech*), inşaat teknolojileri (*ConTech*), akıllı gayrimenkul (*Smart Real Estate*) ve paylaşım ekonomisi (*Shared Economy*) gibi alt alanlarla iç içedir. Nitekim Oxford Üniversitesi’nin bir çalışmasında PropTech’in kökeninin finans teknolojileri, akıllı bina teknolojileri ve paylaşım ekonomisi hareketlerine dayandığı belirtilmiştir (Baum, 2017). Bu doğrultuda PropTech, finansal hizmet inovasyonlarından (ör. kitle fonlamalı emlak yatırımları) akıllı bina otomasyon sistemlerine, paylaşım ekonomisi modellerinden (ör. Airbnb gibi) dijital inşaat süreçlerine kadar geniş bir yelpazedeki yenilikleri şemsiye kavram olarak birleştirir.

PropTech teriminin kapsamına ConTech olarak adlandırılan inşaat teknolojileri de sıklıkla dahil edilir, ancak bazı otoriteler bunları ayrı sınıflandırmaktadır. PropTech genellikle emlak ve mülkiyet odaklı dijital çözümleri ifade eden bir üst kavramken, ConTech daha dar biçimde inşaat süreçlerine özel

teknolojik çözümleri tanımlar. Örneğin, çevrimiçi emlak ilan siteleri veya kiralama platformları PropTech kapsamında değerlendirilirken, bir şantiyede kullanılan hava aracı (drone) ölçüm sistemleri veya 3B baskı ile inşa teknikleri ConTech kapsamında değerlendirilebilir. Bu ayrım kesin olmamakla birlikte, genel kabul PropTech ekosisteminin inşaat öncesi ve sonrası tüm gayrimenkul döngüsünü içerdiği, ConTech'in ise özellikle inşaat yapım aşamasındaki yenilikleri vurguladığı yönündedir.

Özetle, PropTech kavramı gayrimenkul sektörünün dijital çağa uyum sağlama çabalarını tanımlayan geniş kapsamlı bir şemsiye kavramdır. Teknolojik bileşenleri ve alt sektörleri ile PropTech, geleneksel gayrimenkul işleyişini daha veri odaklı, otomatik, bütünsel ve kullanıcı dostu bir yapıya dönüştürmektedir.

1.2. PropTech'in Evrimi

PropTech'in evrimi, dijitalleşmenin gayrimenkul sektörüne adım atmasıyla birlikte şekillenmiş ve dört temel dönem çerçevesinde incelenmiştir: PropTech 1.0, 2.0, 3.0 ve 4.0. Belirtilen aşamalar (1.0 - ilan siteleri, 2.0 - platform bazlı sistemler, 3.0 - veri analitiği ve blokzincir, 4.0 - akıllı ve otonom sistemler) detaylandırılacak ve örneklerle açıklanacaktır. Her bir dönem, teknolojik yetkinliklerin ve kullanıcı beklentilerinin değişimine paralel olarak farklı inovasyon dalgalarını beraberinde getirmiştir (Braesemann & Baum, 2020a; Ullah vd., 2018).

1.2.1. PropTech 1.0 (2000–2007)

PropTech sektörünün ilk evresi olarak kabul edilen bu dönem, gayrimenkul sektörünün dijitalleşme yolculuğunda temel bir kırılma noktasıdır. Bu dönemin karakteristik özelliği, internetin yaygınlaşmasıyla birlikte dijital ilan platformlarının ve temel düzeyde bilgi paylaşımının sektör geneline entegre olmaya başlamasıdır (Braesemann & Baum, 2020a; Llorca-Ponce & Rius-Sorolla, 2023).

1990'ların sonlarında ve 2000'li yılların başında internet teknolojilerinin gelişimi, gayrimenkul pazarlama ve satış süreçlerinde geleneksel yöntemlerin (basılı ilanlar, yüz yüze görüşmeler, yerel ağlar üzerinden bilgi akışı) yetersiz kalmasına neden olmuş; sektörde yeni, daha geniş kitlelere erişebilen dijital çözümler talep

edilmeye başlanmıştır. Bu bağlamda, web tabanlı ilan portalları (ör. Realtor.com, Rightmove, Zillow, Immobiliare.it gibi ulusal ve bölgesel platformlar) gayrimenkul sektörüne entegre olmuş ve ilanların çevrimiçi olarak sunulmasına imkân tanımıştır (Baum vd., 2020).

Bununla birlikte, PropTech 1.0 dönemi hâlâ sınırlı işlevselliğe sahip bir evredir. Dijital araçlar daha çok pasif bilgi paylaşımı ve reklam odaklı kullanımla sınırlı kalmış; müşteri ilişkileri yönetimi, işlem süreçlerinin dijitalleştirilmesi veya değerlendirme gibi daha karmaşık fonksiyonlar henüz bu evrede yaygınlaşmamıştır (Llorca-Ponce & Rius-Sorolla, 2023).

1.2.2. PropTech 2.0 (2008–2013)

PropTech'in evriminde ikinci aşama olarak değerlendirilen PropTech 2.0 dönemi, gayrimenkul sektörünün dijital dönüşümünde yalnızca bilgi sunumunun ötesine geçerek etkileşim, mobil erişim ve kullanıcı merkezli deneyim tasarımı ile öne çıkmaktadır. Bu dönem, bir önceki fazda temelleri atılan dijitalleşmenin daha gelişkin ve işlevsel bir aşamaya taşındığı evredir.

Özellikle akıllı telefon teknolojilerinin yaygınlaşması, mobil uygulamaların günlük yaşamın vazgeçilmez unsurlarına dönüşmesi ve kullanıcıların interneti yalnızca bilgi edinme değil, karar alma sürecinin aktif bir parçası olarak kullanmaya başlaması, PropTech 2.0 döneminin temel belirleyicileri arasında yer almaktadır (Braesemann & Baum, 2020a; J. Yang, 2024a).

Gayrimenkul arama, ilan görüntüleme, konum bazlı filtreleme ve randevu talebi gibi işlemler, mobil uygulamalar aracılığıyla yapılabilir hâle gelmiştir. Zillow, Trulia ve Redfin gibi öncü platformlar bu dönemde mobil kullanıcılar için özel uygulamalar geliştirerek pazarda önemli avantaj elde etmiştir (Llorca-Ponce & Rius-Sorolla, 2023). Kullanıcıların istedikleri lokasyonlarda, anlık olarak mülk bilgilerine ulaşabilmesi, karar verme süreçlerini hızlandırmıştır.

Web siteleri ve mobil uygulamalar, bu dönemde daha fazla kullanıcı dostu hâle getirilmiş; sade arayüzler, gelişmiş filtreleme sistemleri ve kişiselleştirilmiş öneri

algoritmaları geliştirilmiştir. Kullanıcı deneyimi, yalnızca estetik bir tercih değil, aynı zamanda dönüşüm oranlarını etkileyen stratejik bir faktör olarak değerlendirilmiştir.

Ayrıca PropTech 2.0 döneminde, statik görsellerin yanı sıra etkileşimli içerikler (ör. 360° sanal turlar, video gösterimleri, artırılmış gerçeklik tabanlı görüntülemeler) kullanılmaya başlanmıştır. Bu sayede, özellikle fiziksel olarak mülkü ziyaret edemeyen kullanıcılar için deneyim kalitesi artırılmış, dijital platformlar üzerinden daha fazla işlem gerçekleştirilmeye başlanmıştır.

Kullanıcıların mülklere puan vermesi, yorum yapması ve deneyimlerini paylaşması gibi etkileşimler, platformların topluluk temelli veri kaynakları hâline gelmesini sağlamıştır. Bu durum hem diğer kullanıcıların kararlarını etkilemiş, hem de firmaların kullanıcı davranışlarını analiz ederek hizmet kalitesini artırmalarına olanak tanımıştır (Baum vd., 2020).

PropTech 2.0 evresi, gayrimenkul teknolojilerinin yalnızca arz tarafını değil, talep tarafının davranışlarını ve ihtiyaçlarını merkeze alan bir yaklaşım geliştirmesini sağlamıştır. Kullanıcılara zaman ve mekândan bağımsız erişim imkânı sunulması, müşteri yolculuğunun dijital ortama taşınması ve kullanıcı odaklı veri analizlerinin ön plana çıkması, bu dönemin PropTech tarihinde dönüştürücü etkilerinden olmuştur. Ayrıca, bu evre, veri toplama ve davranışsal analitik açısından daha sofistike sistemlerin geliştirilmesi için de bir geçiş noktası işlevi görmüştür. PropTech 3.0 ve 4.0'a giden süreçte temel oluşturmuş, müşteri ilişkileri yönetimi (*Customer Relationship Management*), AVM ve yapay zekâ entegrasyonlarının zeminini hazırlamıştır.

1.2.3. PropTech 3.0 (2014–2020)

PropTech 3.0 dönemi, gayrimenkul sektöründe dijitalleşmenin temel bileşenlerinin ötesine geçerek, ileri veri analitiği, yapay zekâ, IoT ve blokzincir gibi yeni nesil teknolojilerin sektörel uygulamalara derinlemesine entegre olduğu bir dönüşüm aşamasını temsil etmektedir (Baum vd., 2020; Braesemann & Baum, 2020a; J. Yang, 2024a).

Bu evre, yalnızca gayrimenkul pazarlama ve satış süreçlerinin değil, değer zincirinin tüm aşamalarının dijitalleşmesi açısından kritik bir dönüm noktasıdır. İnşaat, yatırım, mülk yönetimi, değerlendirme, tapu işlemleri ve kullanıcı deneyimi gibi süreçler, bu yeni teknolojiler sayesinde daha otomatik, şeffaf, ölçeklenebilir ve veri odaklı bir yapıya kavuşmuştur (Llorca-Ponce & Rius-Sorolla, 2023).

PropTech 3.0 ile birlikte yapay zekâ temelli uygulamalar gayrimenkul değerlendirme, müşteri davranış tahminleme, risk analizi ve satış tahmini gibi alanlarda yaygınlaşmıştır. AVM'ler, yapay zekâ destekli olarak geliştirilen algoritmalar sayesinde daha doğru ve dinamik piyasa analizleri üretmektedir (J. Yang, 2024a). Ayrıca, sohbet robotu ve yapay zekâ destekli müşteri ilişkileri yönetimi sistemleri, müşteri ilişkilerinde kişiselleştirilmiş ve otomatik etkileşimleri mümkün kılmaktadır.

IoT teknolojileri, özellikle akıllı bina yönetimi ve enerji verimliliği uygulamalarında ön plana çıkmıştır. Akıllı sensörler aracılığıyla binaların enerji tüketimi, güvenlik durumu, hava kalitesi gibi veriler gerçek zamanlı olarak izlenebilmekte ve bu veriler üzerinden öngörücü bakım ve optimizasyon çözümleri geliştirilmektedir (Karahana, 2023a).

Blockchain teknolojisi ve akıllı sözleşmeler (*smart contracts*), gayrimenkul sektöründe özellikle şeffaflık, güvenlik ve aracı maliyetlerini azaltma hedefleri doğrultusunda dikkat çekmiştir (J. Yang, 2024a). Tapu kayıtlarının blokzincir üzerinde tutulması, sahteciliğin önlenmesi ve işlem süreçlerinin hızlandırılması açısından potansiyel yaratmıştır. Singapur, Estonya gibi ülkelerde bu tür uygulamaların ilk örnekleri ortaya çıkmıştır. Ayrıca, tokenizasyon uygulamaları, gayrimenkul yatırımlarının küçük parçalara bölünerek daha geniş yatırımcı kitlelerine açılmasına olanak sağlamış ve böylece likiditenin artmasına katkıda bulunmuştur (Baum, 2020).

PropTech 3.0 döneminde gayrimenkul sektörü, giderek daha fazla veri odaklı bir yapıya dönüşmüştür. Büyük veri analitiği sayesinde pazar trendleri, yatırım fırsatları ve müşteri tercihleri daha isabetli bir biçimde öngörülebilmektedir (Munawar vd., 2020). Ayrıca, platform ekonomisi ve paylaşımlı gayrimenkul modelleri bu dönemde önemli bir yükseliş göstermiştir.

PropTech 3.0 evresi, gayrimenkul sektörünü yalnızca dijital bir pazarlama ve iletişim alanı olmaktan çıkararak, iş süreçlerinin tamamını teknoloji destekli, veri temelli ve kullanıcı odaklı bir yapıya dönüştürmüştür. Bu dönüşüm, sektörün daha şeffaf, daha verimli ve daha erişilebilir hâle gelmesini sağlamış; aynı zamanda yeni iş modelleri ve ekosistem aktörleri yaratmıştır. Ayrıca, bu evre, yapay zekâ ve blokzincir uygulamalarının daha da olgunlaşarak PropTech 4.0 döneminde tam entegre ve yaygın bir yapıya dönüşmesinin temelini atmıştır.

1.2.4. PropTech 4.0 (2020 ve sonrası)

PropTech 4.0 dönemi, gayrimenkul sektöründe dijital dönüşümün daha olgun ve stratejik bir aşamaya ulaştığı, teknoloji uygulamalarının entegre ve sürdürülebilir ekosistemler hâlini aldığı bir evreyi temsil etmektedir. Bu dönemde, daha önceki PropTech aşamalarında ayrı ayrı geliştirilen dijital çözümler, birbiriyle bağlantılı ve bütüncül platformlar üzerinden yönetilmeye başlanmış; böylece sektör genelinde operasyonel verimlilik, müşteri deneyimi ve sürdürülebilirlik ön plana çıkmıştır (Llorca-Ponce & Rius-Sorolla, 2023).

Bu dönemin temel dinamikleri arasında akıllı toplumlar, ESG (Çevresel, Sosyal ve Yönetişim, İng. *Environmental, Social, Governance*) kriterlerine uyum, Web3 (blokzincir tabanlı, merkeziyetsiz internet teknolojileri) ve tokenizasyon, dijital kimlik sistemleri, yapay zekâ destekli karar destek mekanizmaları ve şehir ölçeğinde veri paylaşım altyapıları yer almaktadır (Cruz Rambaud & López Pascual, 2023; Fitzpatrick vd., 2023). Küresel ölçekte artan iklim krizi ve sosyal sorumluluk bilinci doğrultusunda, bu dönemde ESG ilkeleriyle uyumlu teknolojilerin geliştirilmesi ve benimsenmesi kritik bir eğilim hâline gelmiştir (Cruz Rambaud & López Pascual, 2023).

PropTech 4.0 evresinde, farklı teknolojilerin (yapay zekâ, IoT, blokzincir, büyük veri analitiği) entegre şekilde çalışan platformlarda bir araya gelmesi önem kazanmıştır. Akıllı mülk yönetim platformları, otomatik değerlendirme ve yatırım yönetimi çözümleri, blokzincir tabanlı tapu ve işlem platformları bu entegrasyonun somut örnekleridir (Braesemann & Baum, 2020a). Bu yapı sayesinde tüm paydaşlar (yatırımcılar, mülk sahipleri, yöneticiler, kiracılar), aynı veri platformunda etkileşim

kurabilmekte; böylece gerçek zamanlı veriye dayalı daha hızlı ve doğru kararlar alınabilmekte, işlem maliyetleri ve hatalar önemli ölçüde azaltılmaktadır (Baum vd., 2020).

ESG kriterlerine uyum, PropTech 4.0'ın en belirgin itici güçlerinden biridir. Gayrimenkul sektöründe çevresel etkilerin azaltılması ve sürdürülebilir kalkınma hedeflerine katkı sağlanması amacıyla geliştirilen teknolojiler arasında şunlar öne çıkmaktadır:

- IoT destekli bina otomasyon sistemleri ile enerji verimliliği optimizasyonu,
- Karbon ayak izi izleme ve raporlama araçları,
- Yeşil bina sertifikasyonu süreçlerini dijitalleştiren yazılımlar,
- İç mekân hava kalitesi ve kullanıcı memnuniyeti izleme çözümleri (Karahan, 2023a).

Ayrıca, PropTech 4.0 döneminde odak sadece bireysel mülkler değil, akıllı şehir ve toplum düzeyinde çözümler geliştirmek olmuştur. Akıllı altyapılar, kamu hizmetleriyle entegre mülk yönetimi ve dijital vatandaşlık uygulamaları (ör. dijital kimlik entegrasyonlu tapu işlemleri), bu sürecin temel unsurları arasında yer almaktadır (Al-Rimawi & Nadler, 2025).

Gayrimenkulün tokenizasyonu, yatırım süreçlerini daha demokratik hâle getiren ve likiditeyi artıran önemli bir gelişme olarak dikkat çekmektedir (Baum, 2020). Web3 teknolojileri sayesinde; kısmi sahiplik modelleri, akıllı sözleşme tabanlı kira ve satış işlemleri ile merkeziyetsiz yatırım yapıları yaygınlaşmıştır.

Sonuç olarak, PropTech 4.0 gayrimenkul sektörünü yalnızca dijitalleşmenin ötesine taşıyarak, veri merkezli, iş birliğine dayalı ve sürdürülebilirliğe duyarlı bir yapıya dönüştürmektedir. Bu evrede teknoloji, yalnızca operasyonel kolaylık sağlayan bir araç değil; stratejik karar süreçlerinin ve kamusal yönetim modellerinin temel bir bileşeni hâline gelmiştir. PropTech 4.0'ın etkisi yalnızca özel sektörle sınırlı kalmayıp, kamu-özel iş birlikleri, uluslararası regülasyonlar ve akıllı şehir politikaları aracılığıyla tüm toplumu etkileyen yapısal dönüşümleri de kapsamaktadır. Bu yönüyle PropTech

4.0, sektörde normatif ve etik bir dönüşümün başlangıcı olarak değerlendirilmektedir (Maalsen vd., 2024).

1.3. PropTech Ekosistemi

PropTech, yalnızca bireysel yazılım çözümleri veya teknolojik uygulamalardan ibaret olmayan, çok katmanlı ve çok aktörlü bir dönüşüm sürecini temsil etmektedir. Bu dönüşüm, gayrimenkul sektöründeki dijitalleşmenin araçsal olmanın ötesine geçerek yapısal ve stratejik bir değişim niteliği taşıdığını ortaya koymaktadır. Bu bağlamda, PropTech ekosistemi, sektörde yer alan tüm paydaşların, teknolojik çözümlerin, veri altyapılarının ve düzenleyici mekanizmaların oluşturduğu dinamik ve etkileşimli bir sistem olarak tanımlanabilir (Baum, 2017; Mattarocci & Scimone, 2022).

Bu ekosistem; girişim sermayesi destekli teknoloji girişimleri, geleneksel gayrimenkul firmaları, kamu kurumları, veri sağlayıcılar, FinTech platformları, akıllı bina teknolojileri geliştiricileri ve son kullanıcılar gibi geniş bir aktör yelpazesini kapsamaktadır. Bu aktörlerin her biri, veri üretimi, paylaşımı, analizi ve karar destek sistemlerine entegrasyon süreçlerinde kritik roller üstlenmektedir (Baum vd., 2020).

PropTech ekosistemi, gayrimenkul sektörü üzerindeki etkileri ve teknolojik çözüm alanları doğrultusunda işlevsel olarak sınıflandırılabilir. Bu yaklaşım, sektörde faaliyet gösteren girişimlerin uzmanlaştıkları teknoloji türlerini, hizmet sundukları alanları ve oluşturdukları kullanım senaryolarını sistematik biçimde değerlendirme imkânı sunar.

1.3.1. Akıllı Taşınmaz Teknolojileri

Bina içi IoT sistemleri, sensör destekli enerji ve güvenlik yönetimi, akıllı cihaz entegrasyonları ve kullanıcı dostu bina otomasyon platformları bu başlık altında değerlendirilir. Bu teknolojiler, konut ve ticari yapıların verimli, sürdürülebilir ve kullanıcı odaklı hale gelmesini sağlar.

Akıllı taşınmaz teknolojileri, gayrimenkul sektöründe dijitalleşmenin ötesine geçerek taşınmazların kendilerini veri üreten, analiz eden ve çevresiyle etkileşim

kurabilen akıllı sistemlere dönüştürmesini ifade eder. Bu kapsamda geliştirilen teknolojiler; enerji verimliliği, sürdürülebilirlik, kullanıcı konforu ve operasyonel verimliliği artırmak gibi çok yönlü amaçlara hizmet etmektedir (Karahana, 2023b).

Akıllı taşınmaz çözümleri; sensör teknolojileri, IoT, yapay zekâ, dijital ikizler (*digital twins*) ve bina yönetim sistemleri gibi bileşenlerle entegre çalışır. Özellikle ticari binalarda, hastanelerde, havaalanlarında ve büyük ölçekli konut projelerinde akıllı bina teknolojileri yaygın şekilde uygulanmaktadır. Bu sistemler, bina içi sıcaklık, nem, ışık ve hava kalitesi gibi çevresel parametreleri izleyerek otomatik karar mekanizmalarıyla yönetim sağlar (Karahana, 2023a).

Bunun yanı sıra, kullanıcı odaklı hizmetler de akıllı taşınmaz teknolojilerinin bir parçasıdır. Örneğin, kiracılar mobil uygulamalar üzerinden ısıtma ayarlarını değiştirebilir, arıza talepleri oluşturabilir ya da enerji tüketimlerini takip edebilir (Karahana, 2023c). Bu sayede kullanıcı deneyimi ve memnuniyeti artarken, bina sahipleri de bakım maliyetlerini düşürebilmekte ve varlık değerini koruyabilmektedir.

Türkiye'de akıllı taşınmaz teknolojileri henüz gelişmekte olan bir alandır. Ancak bazı öncü projeler dikkat çekmektedir. Örneğin, İstanbul'daki Zorlu Center ve Skyland projelerinde gelişmiş bina otomasyon sistemleri kullanılarak enerji yönetimi ve konfor koşulları optimize edilmiştir. Ayrıca, yerli girişimler arasında Evreka, Reengen ve Apsiyon gibi firmalar akıllı bina yönetimi ve enerji verimliliği odaklı çözümler geliştirmektedir.

Akıllı taşınmaz teknolojilerinin uzun vadede en büyük katkılarından biri, sürdürülebilirlik hedefleriyle entegrasyonudur. Enerji tüketiminin azaltılması, karbon ayak izinin düşürülmesi ve döngüsel ekonomi ilkelerine uygun yapıların teşviki gibi stratejiler, PropTech ekosisteminin bu alt kolu üzerinden desteklenmektedir (Baum, 2017; Baum vd., 2020).

1.3.2. Nesnelerin İnterneti ve Akıllı Altyapılar

Nesnelerin İnterneti (IoT), fiziksel nesnelerin birbirleriyle ve merkezi sistemlerle internet üzerinden veri alışverişi yapabilmesini sağlayan teknolojik bir ekosistemdir. Gayrimenkul sektöründe IoT uygulamaları, akıllı binalar, akıllı şehirler

ve akıllı mülk yönetimi sistemleri kapsamında kritik bir rol üstlenmektedir. Bu teknolojiler, yapıların enerji tüketiminden güvenliğe, bakım planlamasından kullanıcı konforuna kadar birçok alanda veri odaklı otomasyon sağlar.

IoT'nin gayrimenkulde kullanım alanları;

- **Enerji Yönetimi:** Akıllı sayaçlar, termostatlar ve sensörler aracılığıyla binaların enerji verimliliği artırılır. Örneğin, kullanıcı davranışına göre ısıtma/soğutma sistemlerinin otomatik ayarlanmasıyla enerji israfı azaltılır. Bu uygulama, sürdürülebilir bina sertifikaları açısından da önemlidir (Llorca-Ponce & Rius-Sorolla, 2023).
- **Güvenlik ve Erişim Kontrolü:** Hareket sensörleri, yüz tanıma sistemleri, akıllı kilitler ve güvenlik kameraları, özellikle konut siteleri ve ticari gayrimenkullerde güvenliği artırır. Bu sistemler aynı zamanda merkezi ağlarla entegre edilerek uzaktan izleme ve anlık müdahale olanağı sunar (Maalsen vd., 2024).
- **Tahmine Dayalı Bakım:** IoT cihazları, HVAC sistemleri (*Heating, Ventilation, and Air Conditioning*), asansörler veya yangın alarmları gibi ekipmanlardan gelen verileri izleyerek arıza meydana gelmeden önce uyarı verir. Bu da bakım maliyetlerini düşürür, kullanım süresini uzatır.
- **Konut Konforu ve Kullanıcı Deneyimi:** Aydınlatma, perde sistemleri, ses sistemleri gibi öğelerin otomatik kontrolü ile konfor seviyesi artırılır. Aynı zamanda kullanıcılar, mobil uygulamalar veya sesli asistanlar (ör. Alexa, Google Home) aracılığıyla mülkleriyle etkileşim kurabilir.

Gayrimenkul teknolojileri, yalnızca bina düzeyinde değil, giderek artan biçimde şehir ölçeğinde de dönüşüm yaratmaktadır. Bu bağlamda IoT altyapıları, ulaştırma sistemleri, atık yönetimi, trafik kontrolü ve çevre izleme sistemleri gibi birçok alanda kullanılmakta; böylece kentsel yaşam kalitesinin ve altyapı verimliliğinin artırılmasına katkıda bulunmaktadır (J. Yang, 2024a).

Bu sistemlerin gayrimenkulle entegrasyonu, yatırım kararlarında erişilebilirlik, çevresel kalite ve altyapı yeterliliği gibi faktörlerin önemini artırmış; yatırımcı ve

kullanıcıların mekânsal tercihlerine yön veren yeni parametreler ortaya çıkarmıştır (J. Yang, 2024a).

Örnek olarak:

- Barcelona, kentsel IoT uygulamaları aracılığıyla trafik akışını, hava kalitesini ve otopark doluluk oranlarını gerçek zamanlı olarak izlemekte ve bu verileri açık veri platformları üzerinden paylaşmaktadır (Ajuntament de Barcelona, 2025; Barcelona City Council, 2025).
- İstanbul ise “Akıllı Şehir Strateji Belgesi” kapsamında, çevrimiçi altyapı verisi paylaşımı, sensör temelli ulaşım sistemleri ve dijital imar izleme platformları gibi uygulamaları geliştirmekte ve yaygınlaştırmaktadır (Akıllı Şehir İstanbul, 2025).

Bu tür uygulamalar, şehir genelinde veri odaklı karar alma süreçlerini desteklemekte; gayrimenkul değerlendirme, kentsel planlama ve altyapı yatırımlarında daha bütüncül ve sürdürülebilir bir yaklaşımın benimsenmesine olanak tanımaktadır.

Diğer yandan, IoT tabanlı sistemlerin gayrimenkul sektöründe yaygınlaşması, birçok avantajının yanı sıra çeşitli sınırlılıkları ve zorlukları da beraberinde getirmektedir. Öncelikli olarak, IoT cihazları aracılığıyla toplanan büyük hacimli kişisel verilerin güvenliği ve gizliliği, ciddi etik ve hukuki sorumluluklar doğurmakta; bu nedenle verilerin korunması, IoT uygulamalarının sürdürülebilirliği açısından temel bir gereklilik olarak öne çıkmaktadır.

Buna ek olarak, farklı üreticiler tarafından geliştirilen IoT cihazları arasında birlikte çalışabilirlik konusundaki teknik uyumsuzluklar, sistem entegrasyonu aşamasında önemli problemler yaratmaktadır. Bu durum, özellikle çok aktörlü akıllı bina veya akıllı şehir projelerinde karmaşık ve maliyetli entegrasyon süreçlerine yol açabilmektedir.

Ayrıca, söz konusu teknolojilerin ilk kurulum maliyetlerinin yüksek olması, özellikle gelişmekte olan ülkelerde bu sistemlere erişim düzeyini sınırlamakta ve yaygınlaşma hızını düşürmektedir. Yatırımcı ve mülk sahipleri için bu maliyet unsuru, teknolojinin benimsenmesinde belirleyici bir faktör hâline gelmektedir.

Tüm bu nedenlerle, IoT tabanlı uygulamaların sürdürülebilir biçimde hayata geçirilebilmesi, yalnızca teknolojik gelişmelere bağlı değildir; aynı zamanda uygulamaya uygun mevzuatın oluşturulması, standardizasyonun sağlanması ve yenilikçi finansman modelleriyle desteklenmesi gerekmektedir. Bu çok boyutlu yaklaşım, IoT teknolojilerinin gayrimenkul değer zincirine daha sağlıklı ve bütüncül bir şekilde entegre olmasının ön koşulu olarak değerlendirilmektedir.

1.3.3. İnşaat Teknolojileri

İnşaat Teknolojileri (ConTech), yapının inşaat süreçlerine odaklanan dijital ve teknik yenilikleri kapsayan çok disiplinli bir alandır. PropTech ekosisteminin bir alt kümesi olarak kabul edilen ConTech, planlama, tasarım, inşaat, bakım ve yıkım gibi yapı yaşam döngüsünün tüm aşamalarında verimlilik artışı, maliyet azaltımı, güvenlik geliştirme ve sürdürülebilirlik hedeflerine katkı sağlayan teknolojileri içermektedir (Baum vd., 2020).

Bu kapsamda ConTech, BIM (Yapı Bilgi Modellemesi), robotik yapım teknolojileri, modüler inşaat, ön üretim, malzeme teknolojileri ve dijital şantiye yönetimi gibi yenilikçi uygulamaları bünyesinde barındırır. Bu teknolojiler sayesinde inşaat projelerinde süre, kalite ve maliyet boyutlarında önemli iyileşmeler sağlanmakta; aynı zamanda veri temelli karar verme süreçleri desteklenerek projelerin daha etkin yönetimi mümkün olmaktadır.

ConTech uygulamaları arasında 3B yazıcılarla yapı üretimi, artırılmış gerçeklik ve sanal gerçeklik destekli tasarım ve inşaat simülasyonları, yapay zekâ destekli inşaat yönetimi yazılımları, modüler yapı sistemleri ve dijital inşaat takibi gibi çeşitli çözümler öne çıkmaktadır. Özellikle karmaşık inşaat projelerinde iş akışlarının dijitalleştirilmesi ve gerçek zamanlı veri analizi sayesinde süreçlerin daha şeffaf, izlenebilir ve sürdürülebilir şekilde yürütülmesi sağlanmaktadır.

Türkiye’de ConTech uygulamaları ve girişimleri son yıllarda ivme kazanmıştır. Örneğin, Bimcrone gibi yerli teknoloji firmaları, inşaat süreçlerinin dijital ikizlerini oluşturarak şantiye yönetiminde dijitalleşmeyi desteklemektedir. Ayrıca

YapıRadar platformu, inşaat ihaleleri ve sektörel projeleri veri temelli analiz eden yapısıyla, sektörde bilgiye dayalı stratejik karar alma süreçlerini kolaylaştırmaktadır.

ConTech'in yaygınlaşması, yapı üretim süreçlerinin yalnızca teknik anlamda değil, aynı zamanda stratejik ve sürdürülebilir bir yaklaşımla ele alınmasını mümkün kılmaktadır. Bu yönüyle ConTech, PropTech ekosistemi içerisinde giderek daha merkezi bir konuma gelmekte ve gayrimenkul değer zincirinin dijital dönüşümünde kilit bir rol oynamaktadır.

1.3.4. Finans ve Yatırım Teknolojileri

Finansal Teknolojiler (FinTech), geleneksel finansal hizmetlerin dijital ortama taşınmasını ve otomasyonunu sağlayan teknolojileri kapsarken; Yatırım Teknolojileri (InvestTech), ise özellikle yatırım süreçlerinin dijitalleşmesine odaklanan bir alt alan olarak öne çıkmaktadır. Bu iki teknoloji alanı, PropTech'in finansal altyapısını oluşturarak gayrimenkul sektörüyle doğrudan etkileşim içindedir.

Gayrimenkul yatırımlarının dijital platformlar aracılığıyla gerçekleştirilebilmesi, büyük ölçüde FinTech uygulamaları sayesinde mümkün hâle gelmiştir. Dijital mortgage sistemleri, çevrimiçi kredi puanlama araçları ve blokzincir tabanlı ödeme altyapıları, FinTech'in PropTech ile entegrasyonunun somut örneklerini oluşturmaktadır. Bu sistemler aracılığıyla işlem süreçleri hem daha şeffaf hem de daha düşük maliyetli bir yapıya kavuşmuştur (Braesemann & Baum, 2020a).

Öte yandan, InvestTech çözümleri, yatırımcıların portföy yönetimi, risk analizi ve varlık dağılımı gibi işlemlerini yapay zekâ destekli dijital platformlar üzerinden gerçekleştirmelerine olanak tanımaktadır. Özellikle gayrimenkul yatırım fonları, tokenizasyon aracılığıyla küçük yatırımcılara açılmış; yatırım kararları ise algoritmik karar destek sistemleri ile yönlendirilmeye başlanmıştır (Llorca-Ponce & Rius-Sorolla, 2023; J. Yang, 2024a).

Günümüzde gayrimenkul değer zincirinde yatırım kararları, yalnızca fiziki değerlendirme raporlarıyla değil, yapay zekâ temelli öngörü modelleriyle desteklenmektedir. Bu alandaki yenilikçi çözümler arasında, öngörücü analitik, robo-danışmanlar (*robo-advisors*) ve otomatikleştirilmiş portföy yönetim sistemleri (ör.

Wealthfront ve Betterment gibi platformlar) yer almakta olup bu teknolojiler yatırım kararlarını veri odaklı ve kişiselleştirilmiş bir şekilde yönlendirme imkânı sunmaktadır.

Ayrıca kripto para temelli gayrimenkul alım-satım uygulamaları da FinTech-PropTech kesişiminde değerlendirilmektedir. Blokzincir teknolojisi ile tokenize edilen gayrimenkuller, yatırımcılara parçalı sahiplik ve likidite imkânı sunmakta, bu da geleneksel yatırım modellerine alternatif oluşturmaktadır (Shukla vd., 2024).

Sonuç olarak, gayrimenkule dayalı tokenizasyon, dijital portföy yönetimi, blokzincir tabanlı kredi ve tapu sistemleri, P2P (Eşler Arası, İng, *Peer-to-Peer*) fonlama modelleri ve dijital gayrimenkul fonları, sektörde erişilebilirliği artırmakta, yatırımcıların aracı kurumlara olan bağımlılığını azaltmakta ve gayrimenkul yatırımlarında daha esnek, şeffaf ve veri temelli bir yaklaşım oluşturmaktadır.

1.3.5. Paylaşımlı Ekonomi

Paylaşımlı ekonomi (*Shared Economy*), mülkiyete dayalı geleneksel ekonomik modellerin yerine, erişim temelli dijital platformlar aracılığıyla mal ve hizmetlerin kısa süreli kullanıma sunulmasını esas alan bir yaklaşımdır. Gayrimenkul sektörü, bu dönüşümden en çok etkilenen alanlardan biri olmuştur. Özellikle konutların kısa dönemli kiralanmasını mümkün kılan dijital platformlar, paylaşımlı ekonomiyi PropTech uygulamalarıyla doğrudan ilişkilendirmektedir (Braesemann & Baum, 2020a).

Airbnb, Spotahome, WeWork ve Booking gibi platformlar, geleneksel otelcilik anlayışına alternatif oluşturarak kullanıcılar arasında doğrudan etkileşim sağlayan sistemler geliştirmiştir. Bu tür uygulamalar, arz-talep dengesini dinamik bir yapıya kavuştururken, aynı zamanda mülk sahiplerinin ek gelir elde etmelerine olanak tanımaktadır. Ayrıca paylaşımlı ekonomi, yalnızca konut paylaşımını değil; ofis alanı (ör. WeWork), depo, otopark veya ortak yaşam alanlarının da kullanımını kapsayan daha geniş bir gayrimenkul paylaşım ekosistemi yaratmıştır. Bu model, kullanım sıklığı düşük olan taşınmaz kaynakların verimli kullanılmasını teşvik ederken, gayrimenkul piyasasında esneklik ve erişilebilirlik gibi yeni değerler yaratmaktadır.

Öte yandan, paylaşım ekonomisine dayalı sistemlerde blokzincir, güvenli ödeme altyapıları ve itibar yönetimi algoritmaları kullanılarak kullanıcı güveni artırılmakta; dolayısıyla PropTech çözümleri bu ekosistemin altyapısını oluşturmaktadır (Shukla vd., 2024).

Ancak paylaşımlı ekonomi, geleneksel kiralama piyasaları üzerinde regülasyon ihtiyacı doğurmuş; bazı kentlerde arz kısıtlamaları, vergi uygulamaları ve kullanıcı güvenliği gibi yeni politika alanlarını da beraberinde getirmiştir. Bu da, PropTech'in sadece bir teknolojik değil, aynı zamanda sosyo-politik bir dönüşüm aracı olduğunu göstermektedir (J. Yang, 2024a).

1.3.6. Dijital Pazar Yerleri

Dijital pazar yerleri, alıcılar ve satıcılar arasında dijital ortamda aracılık yapan platformlardır. Emlak alım, satım, kiralama işlemlerinin dijital ortamda yürütülmesini sağlayan portallar (Zillow, Sahibinden, EmlakJet vb.) bu sınıfa girer. Bu alan, dijitalleşmenin gayrimenkule ilk ve en temel katkı alanıdır. Bu tür platformlar, gayrimenkul satışı, kiralaması ve yatırımına ilişkin işlemlerin dijitalleştirilmesini sağlamaktadır. Bu platformlar, geleneksel emlakçılık hizmetlerinin dijital eşleniğini sunmakla kalmayıp; veri analitiği, görselleştirme ve algoritmik eşleştirme gibi işlevlerle kullanıcı deneyimini ve işlem verimliliğini de artırmaktadır (Braesemann & Baum, 2020a; J. Yang, 2024a).

Zillow, Redfin, Realtor gibi küresel pazar yerlerinin yanı sıra, Türkiye'de Sahibinden.com, Zingat ve Tapu.com gibi platformlar bu dönüşümün yerel örneklerini temsil etmektedir. Bu sistemler hem bireysel kullanıcıların hem de kurumsal yatırımcıların geniş veri havuzlarına erişmesini sağlamaktadır. Aynı zamanda emlak ilanlarını görsellik, haritalama ve puanlama sistemleri, geçmiş satış verileri gibi pek çok özelliklerle desteklenmektedir.

Dijital pazar yerlerinin en önemli katkılarından biri şeffaflığı artırmasıdır. İlanların merkezi olarak sunulması, fiyat karşılaştırmalarının yapılmasına olanak tanımakta; kullanıcı yorumları, geçmiş işlem verileri ve algoritmik öneriler sayesinde piyasa bilgisi daha güçlü hale gelmektedir (Ye vd., 2022). Ayrıca bu platformlar

üzerinden yapılan işlemlerde büyük veri ve makine öğrenimi teknikleri kullanılarak, kullanıcıya özel öneriler geliştirilmekte; bu da PropTech'in pazarlama, değerlendirme ve müşteri yönetimi gibi alanlardaki etkisini derinleştirmektedir. Bununla birlikte, bu pazar yerleri aynı zamanda rekabet, veri gizliliği, sahte ilanlar ve regülasyon gibi yeni risk ve sorumluluk alanlarını da beraberinde getirmiştir. Dolayısıyla PropTech'te dijital pazar yerleri yalnızca bir ticaret aracı değil, aynı zamanda dijital altyapının ve piyasa düzenlemesinin temel bileşenlerinden biri olarak konumlanmaktadır (Maalsen vd., 2024).

1.3.7. Veri Analitiği, Yapay Zekâ ve AVM'ler

Veri analitiği ve yapay zekâ, PropTech ekosisteminin en kritik bileşenleri arasında yer almakta ve gayrimenkul sektörünün dijital dönüşümünde belirleyici bir rol üstlenmektedir. Tarihsel olarak parçalı veri yapısı ve düşük şeffaflık seviyesiyle tanımlanan gayrimenkul piyasası, büyük veri, ML ve yapay zekâ uygulamaları sayesinde daha bütüncül, şeffaf ve öngörülebilir bir yapıya evrilmiştir (Braesemann & Baum, 2020a).

Bu kapsamda veri analitiği; konut fiyat tahmini, talep öngörüsü, yatırım potansiyelinin belirlenmesi, kiralama performansı analizi ve risk modellemeleri gibi geniş bir uygulama alanına sahiptir. Kullanılan yöntemler arasında regresyon analizleri, zaman serisi modellemeleri, mekânsal analizler, kümelenme algoritmaları ve öngörücü analitik yaklaşımlar öne çıkmaktadır. Bu yöntemler, geleneksel süreçlere kıyasla daha hızlı, şeffaf ve kişiselleştirilmiş analizler üretmektedir. Ayrıca, sensörler, sosyal medya, mobil uygulamalar ve kullanıcı etkileşimlerinden elde edilen gerçek zamanlı veriler, analitik sistemlerin daha dinamik ve güncel öngörüler sunmasını sağlamaktadır.

Yapay zekâ tabanlı AVM'ler, bu dönüşümün en somut çıktılarından. Geleneksel olarak uzman görüşlerine dayalı ve manuel yürütülen değerlendirme işlemleri, ML ve büyük veri destekli AVM'ler aracılığıyla daha hızlı, tutarlı ve denetlenebilir biçimde gerçekleştirilmektedir (Braesemann, 2020; Lewis, 2022). AVM'ler; toplu değerlendirme, ipotek teminat analizi, portföy yönetimi ve belediye vergilendirme gibi alanlarda hem kamu hem de özel sektör açısından önemli katkılar sağlamaktadır. Bu

modellerin temelinde regresyon, karar ağaçları, gradyan artırılmalı algoritmalar (XGBoost, LightGBM, CatBoost) ve yapay sinir ağları yer almakta; yüksek hız ve verimlilik sayesinde çok sayıda taşınmazın kısa sürede analiz edilmesine olanak tanınmaktadır.

Bununla birlikte, veri analitiği ve yapay zekâ uygulamalarında dikkat edilmesi gereken kritik noktalar bulunmaktadır. Veri gizliliği, güvenliği ve etik kullanım bu teknolojilerin sürdürülebilirliği açısından vazgeçilmezdir. Ayrıca, AVM'lerin başarısı kullanılan veri setlerinin doğruluğu, güncelliği ve mekânsal heterojenliği ne ölçüde dikkate aldığıyla doğrudan ilişkilidir. Bu nedenle, XAI ilkelerine uygunluk, önyargısızlık ve şeffaflık, PropTech uygulamalarında güvenilirliği ve toplumsal kabulü artıran temel unsurlar olarak öne çıkmaktadır (Maalsen vd., 2024).

1.3.8. Blokzincir ve Akıllı Sözleşmeler

Blokzincir, dağıtık defter teknolojisine dayalı, şeffaf ve değiştirilemez veri kayıtları oluşturan bir sistemdir. Blokzincir, dijital belgeler için eşsiz dijital parmak izleri (*hash*) oluşturarak belgelerin doğrulanabilirliğini ve değiştirilemezliğini garanti altına almaktadır. Blokzincir teknolojisine konum bilgisinin entegre edilmesiyle ortaya çıkan geoblokzincir kavramı, özellikle mülkiyet temelli işlemlerde kullanım alanlarını genişletmiştir. Bu bağlamda geliştirilen blokzincir tabanlı merkeziyetsiz konumsal veri protokolü (FOAM), Ethereum blokzinciri üzerinde güvenli ve merkezi olmayan coğrafi verilerin doğrulanabilmesini sağlayan bir konum katmanı sunmaktadır. Böylelikle standart blokzincir sistemlerinde yer almayan mekânsal veri bileşeni de sisteme dâhil edilmektedir (King vd., 2022).

Gayrimenkul sektöründe blokzincir teknolojisi; tapu kayıtlarının güvenli biçimde saklanması, işlem sürelerinin kısaltılması ve aracı kurumlara olan bağımlılığın azaltılması gibi avantajlar sunmaktadır. Geleneksel tapu sistemleri, merkezi yapıları nedeniyle manipülasyona açık ve şeffaflıktan uzak işlem süreçleriyle sınırlı kalmaktadır. Buna karşılık, blokzincir tabanlı sistemlerde mülkiyet bilgileri kriptografik olarak güvence altına alınmakta, her işlem blok olarak zincire eklenmekte ve tüm işlemler kamuya açık şekilde doğrulanabilir hâle gelmektedir (J. Yang, 2024a). Bu sistemin ayrılmaz bileşeni olan akıllı kontratlar, önceden tanımlanmış koşullar

gerçekleştğinde otomatik olarak yürürlüğe giren dijital sözleşmelerdir. Örneğin, alım-satım sürecinde taraflar yükümlülüklerini yerine getirdiğinde sözleşme otomatik olarak tetiklenmekte ve tapu devri gerçekleşmektedir. Böylece noter ve benzeri aracılara olan ihtiyaç en aza indirilmekte, işlem maliyetleri düşürülmektedir (Shukla vd., 2024).

Blokzincir tabanlı mülkiyet yönetimi, pek çok ülkede pilot ya da kurumsal düzeyde uygulanmaya başlanmıştır. Gürcistan, bu alanda öncü bir ülke olup, 2016 yılında Ulusal Tapu ve Kayıt Ajansı ve BitFury Group iş birliğiyle blokzincir tabanlı bir tapu sistemine geçmiştir. Söz konusu sistem, Bitcoin blokzinciri üzerine zaman damgalı doğrulama yöntemi ile işlemektedir ve mülkiyet verilerinin değiştirilmezliğini sağlamaktadır (Shin, 2022). Hindistan'ın Andhra Pradesh eyaletinde ise gayrimenkul devri işlemlerinde şeffaflık sağlamak amacıyla blokzincir tabanlı tapu sistemi pilot olarak uygulanmış, aynı taşınmazın birden fazla kişiye satılması gibi dolandırıcılık vakaları bu sayede engellenmiştir. Ayrıca satış, ipotek ve kredi gibi işlemler akıllı sözleşmeler aracılığıyla otomatik olarak kamu sistemlerine yansıtılmakta; bu da işlem hızını ve veri güvenilirliğini artırmaktadır (Government of India, 2025).

İsveç'te, Ulusal Kadastro ve Harita Dairesi öncülüğünde, blokzincir destekli tapu pilot projesi yürütmüştür. Bu proje kapsamında, tapu devir işlemleri blokzincir aracılığıyla gerçekleştirilmiş ve işlem süresi ortalama %90 oranında azalmıştır. Bunun yanı sıra, işlem geçmişinin takibi, belge doğruluğu ve mülkiyet zincirinin bütünlüğü sağlanmıştır (Lantmäteriet, 2016). Dubai'de ise *Dubai Blokzincir Strategy* çerçevesinde, 2020 yılına kadar tüm kamu belgelerinin blokzincire aktarılmasını hedeflemiş ve taşınmaz kayıtlarını merkeziyetsiz dijital bir sisteme entegre etmiştir. Dubai Arazi Dairesi, bu sistem sayesinde kira sözleşmeleri, ödeme işlemleri ve mülkiyet transferlerini blokzincir aracılığıyla kayıt altına alarak doğrulama süreçlerini hızlandırmıştır (Dubai Land Department, 2025).

Türkiye'de ise Tapu ve Kadastro Genel Müdürlüğü (TKGM), 2023 yılında blokzincir altyapılı tapu doğrulama sistemleri üzerine Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) destekli projeler başlatmış; bu kapsamda dijitalleşme yönünde stratejik adımlar atmıştır. Uygulama aşamasındaki projelerin kamu-özel sektör iş birliğiyle genişletilmesi planlanmaktadır.

Bununla birlikte, blokzincir teknolojisinin sunduğu imkânlar yalnızca işlem güvenliğiyle sınırlı değildir. Tokenizasyon aracılığıyla gayrimenkul varlıklarının dijital tokenlara bölünerek parçalı sahiplik (*fractional ownership*) modeli oluşturulması mümkündür. Bu sistem sayesinde küçük yatırımcılar da büyük mülklere yatırım yapabilir; gayrimenkul sektörü likit bir piyasa hâline gelir. Örneğin, RealT gibi platformlar bu modeli kullanarak yatırımcıların düşük maliyetle gayrimenkul hissesi edinmesini sağlamaktadır (RealT, 2025a).

Her ne kadar teknolojik olarak gelişmiş çözümler sunulsa da blokzincir sistemlerinin gayrimenkul tapularında tam anlamıyla uygulanabilirliği, yerel hukuk sistemleri ve tapu sicilinin resmi otorite kabul edilme zorunluluğu gibi nedenlerle sınırlı kalmaktadır. Ayrıca, teknolojik erişim farkı ve dijital okuryazarlık gibi konular da dikkate alınmalıdır. Tüm bu teknolojik olanaklara rağmen blokzincir tabanlı tapu sistemlerinin uygulanabilirliği; yerel mevzuat, tapu sicilinin resmî otorite tarafından tutulması zorunluluğu, dijital okuryazarlık ve teknolojik erişim gibi yapısal sınırlılıklara bağlı olarak farklılık göstermektedir. Hukuki çerçeveye uygunluk, merkezîyetçilikten doğan güvenlik endişeleri ve vatandaş nezdinde farkındalık eksikliği bu sistemlerin yaygınlaşmasının önündeki temel engeller arasında yer almaktadır (Braesemann & Baum, 2020).

Sonuç olarak, blokzincir ve akıllı sözleşmeler, gayrimenkul sektöründe şeffaflığı, güvenliği ve işlem verimliliğini artıran devrimsel teknolojilerdir. Bu teknolojilerin PropTech ekosisteminde yaygınlaşabilmesi için teknik altyapının güçlendirilmesi, hukuki düzenlemelerin yapılması ve kurumlar arası iş birliğinin artırılması büyük önem taşımaktadır.

1.4. PropTech Pazarı


PropTech, gayrimenkul sektörünün dijital dönüşümüne öncülük eden ve hem teknoloji girişimlerinin hem de geleneksel aktörlerin iş yapış biçimlerini kökten değiştiren dinamik bir pazardır. Bu pazar; yapay zekâ, büyük veri, blokzincir, dijital pazaryerleri, akıllı bina çözümleri ve AVM'ler gibi çok çeşitli teknolojik bileşenleri kapsamaktadır. Son yıllarda dünya genelinde PropTech alanına yapılan yatırımlar, FinTech ile gösterdiği yakın ilişki sayesinde dikkat çekici biçimde artmıştır. Özellikle

Kuzey Amerika, Avrupa ve Asya'da girişim sermayesi destekli PropTech şirketlerinin sayısında ve değerlemesinde hızlı bir yükseliş gözlemlenmektedir (Braesemann & Baum, 2020a)

Küresel PropTech pazarının büyümesinin arkasında, gayrimenkul alım-satım süreçlerinin dijitalleşmesi, akıllı şehir projeleriyle artan entegrasyon ihtiyacı ve sürdürülebilir yapılaşmaya olan talep yer almaktadır. Ayrıca, pandemi sonrası dönemde fiziksel temasın asgariye indirilmesi hedefiyle geliştirilen dijital tapu işlemleri, sanal turlar ve otomatik fiyatlandırma sistemleri, PropTech çözümlerine olan talebi hızlandırmıştır (J. Yang, 2024a).

PropTech uygulamaları küresel ölçekte giderek yaygınlaşmakta, ancak bu teknolojilerin benimsenme düzeyi ve uygulama biçimi ülkeden ülkeye önemli farklılıklar göstermektedir. Bu farklılıkların temelinde; ekonomik gelişmişlik düzeyi, teknoloji altyapısı, mevzuat yapısı, kamu politikaları ve toplumsal dijital okuryazarlık seviyesi gibi unsurlar yer almaktadır (Yang, 2024; Llorca-Ponce, 2023).

Şekil 2. PropTech firmalarının küresel dağılımı.




Kaynak: (Braesemann & Baum, 2020b)

Şekil 2’de görüldüğü üzere, PropTech girişimlerinin coğrafi dağılımı tüm dünyayı kapsamaktadır; burada her bir nokta bir PropTech şirketini, noktanın

büyüklüğü ise o şirketin aldığı finansman miktarını simgelemektedir. Bununla birlikte, PropTech faaliyetlerinin belirli coğrafi bölgelerde yoğunlaştığı açıkça görülmektedir. Sektörün başlıca merkezleri arasında Kaliforniya, Amerika Birleşik Devletleri'nin doğu kıyısı, Batı Avrupa (özellikle Birleşik Krallık) ile Asya metropollerinden Delhi, Şanghay, Pekin, Seul ve Singapur sayılabilir. Diğer birçok bölgeye kıyasla, bu odak noktaları dışındaki alanlarda PropTech ekosistemleri henüz olgunlaşma aşamasındadır (Braesemann & Baum, 2020b).

Şekil 3. Ülke Başına Proptech Firma Sayısı (Her 1 Milyonda)




Kaynak: (Braesemann & Baum, 2020b).

Normalleştirilmiş bir istatistik, Şekil 3'te sunulmaktadır. Bu grafik, ülkeler bazında her bir milyon kişi başına düşen PropTech firması sayısını, daha büyük coğrafi bölgeler halinde gruplayarak göstermektedir. Batı Avrupa, Okyanusya ve Kuzey Amerika ekonomilerinde, ortalama olarak her bir milyon kişiye 6 ile 9 PropTech firması düşerken; Küresel Güney'de yer alan gelişmekte olan ülkelerde bu oran 0,2 ile 1,1 arasında kalmaktadır. Bu veriler, yüksek gelirli ülkeler ile düşük gelirli ülkeler

arasındaki PropTech endüstrisinin gelişmişlik düzeyinde belirgin bir fark olduğunu ortaya koymaktadır (Braesemann & Baum, 2020b).


Şekil 4. Bölgeye Göre PropTech Pazar Payı.



Kaynak: (Precedence Research, 2025).

Şekil 4’de bölgeye göre PropTech pazar payı grafiği yer almaktadır. Coğrafi bölge perspektifinde ekonomik olarak Kuzey Amerika 2024 yılında pazarın yaklaşık %56’sını domine ederken, Asya-Pasifik bölgesi hızlı bir yükseliş trendi sergilemektedir; Hindistan, Çin ve Japonya gibi ülkelerde blokzincir, IoT ve akıllı bina teknolojilerine yönelik kamu-özel ortaklıklarla oluşturulan PropTech altyapıları önemli rol oynamaktadır. Orta Doğu ve Afrika’da (MEA) altyapı yatırımlarının artmasıyla güçlü kazanımlar elde etmektedir; örneğin Dubai, 2025’te başlattığı Dubai PropTech Hub girişimiyle 2030 itibarıyla 1,23 milyar USD’lik (Amerikan Doları) yatırım hedeflemekte, 200’den fazla PropTech firmasını desteklemeyi amaçlamaktadır (Precedence Research, 2025).

Şekil 5. PropTech Pazar Boyutu.



Kaynak: (Precedence Research, 2025).

PropTech pazarı, dijitalleşme ve teknolojik dönüşüm eğilimlerinin gayrimenkul sektörüne entegrasyonu sayesinde hızlı bir büyüme göstermektedir. Şekil 5'te yer aldığı gibi global ölçekte, 2024 itibarıyla 40,58 milyar USD değerinde olan PropTech pazarı, 2025–2034 döneminde yıllık ortalama %16'lık bileşik büyüme oranıyla 2034 yılına kadar yaklaşık 179,03 milyar USD'ye ulaşması beklenmektedir (Precedence Research, 2025). Bu büyüme, öncelikli olarak yazılım çözümleri, bulut tabanlı modeller ve hizmetler aracılığıyla şekillenmekte olup, 2024 yılında total pazar içinde yazılım segmentlerinin %64'e yakın pay aldığı görülmektedir.

1.5. PropTech Girişimlerinin Global ve Türkiye Örnekleri

PropTech, gayrimenkul sektöründe dijital dönüşümün somutlaştığı uygulama alanlarıyla dikkat çekmektedir. Bu bölümde PropTech alanında faaliyet gösteren girişimler işlevsel kategorilere ayrılarak incelenmektedir. Söz konusu kategoriler, pazar yeri platformlarından akıllı bina teknolojilerine, finansal uygulamalardan blokzincir çözümlerine kadar geniş bir yelpazeyi kapsamaktadır. Her bir kategori altında, hem küresel ölçekte öne çıkan girişimlere hem de Türkiye'deki karşılıklarına yer verilerek sektörün dünya genelindeki gelişim eğilimleri ile Türkiye'deki durumu karşılaştırmalı biçimde analiz edilmektedir. Bu yaklaşım, PropTech ekosisteminin

bileşenlerini anlamayı kolaylaştırmakta ve Türkiye'nin sektörel konumunu değerlendirmeye olanak sunmaktadır.

1.5.1. Akıllı Binalar ve IoT Çözümleri

Akıllı binalar ve IoT girişimleri, bina içi sistemlerin sensörler, AI ve otomasyonla yönetilmesini kapsar. Enerji verimliliği, güvenlik, konfor ve sürdürülebilirlik ana hedeflerdir. Hem konut hem ticari gayrimenkuller için uygulanabilir.

Global Örnekler:

- View Inc. (ABD): Akıllı cam sistemleri geliştirir. Güneş ışığını algılayarak otomatik olarak camların şeffaflık seviyesini ayarlar. Enerji verimliliği sağlar (View, 2025).
- Kisi (ABD-Almanya): Bina erişim sistemlerini dijitalleştirir. Telefon, kart ya da yüz tanıma ile giriş yapılmasını sağlayan bir IoT tabanlı erişim kontrol sistemidir (Kisi, 2025).
- Spaceti (Çekya): Ofis alanlarında sıcaklık, hava kalitesi, doluluk oranı gibi verileri sensörlerle izleyerek bina yöneticilerine dijital gösterge panelleri sunar (Spaceti, 2025).
- SmartThings veya Siemens Desigo CC: IoT tabanlı bina kontrol sistemleri sunarak gerçek zamanlı otomasyon sağlar (Desigo CC, 2025; SmartThings, 2025).

Türkiye Örnekleri:

- Evreka: Başlangıçta atık yönetimi üzerine kurulu olsa da, entegre IoT cihazları ile bina ve şehir ölçeğinde çevresel veri toplayan bir çözüm sunar (Evreka, 2025).
- Reengen: Binalar için enerji yönetimi ve analitiği sunar. IoT cihazlarıyla enerji tüketimini takip eder, anormallikleri tespit eder ve maliyetleri düşürür (Reengen, 2025).

1.5.2. ConTech

Bu girişimler, inşaat sektörünü dijitalleştiren çözümleri içerir. Planlama, proje yönetimi, 3B modelleme, BIM, saha verisi takibi, iş güvenliği, tedarik zinciri yönetimi ve yapay zekâ ile tahminleme gibi alanları kapsar.

Global Örnekler:

- Procore (ABD): Şantiye yönetimini dijitalleştiren kapsamlı bir platformdur. Zaman çizelgesi, iş gücü takibi, bütçe kontrolü, dokümantasyon ve BIM ile entegredir (Procore, 2025).
- PlanGrid (Autodesk – ABD): İnşaat projelerinde plan çizimlerinin ve revizyonlarının tablet üzerinden takibini sağlar. Ekipler arası eş zamanlı koordinasyon için idealdir (PlanGrid, 2025).
- Autodesk Construction Cloud: Tasarım, planlama, inşaat ve işletme aşamalarını tek platformda birleştiren BIM çözümü sağlar. Revit, BIM 360, AutoCAD gibi ürünlerle entegre çalışır (Autodesk Construction Cloud, 2025).
- Bridgit (Kanada): İş gücü yönetimi ve şantiye kaynak planlaması sağlar. Bridgit Bench platformu ile inşaat firmalarına insan kaynağı optimizasyonu sunar (Bridgit, 2025).
- Buildots (İsrail / İngiltere): Yapay zekâ destekli şantiye görüntü analizi sağlar. Kask kameraları ve bilgisayarla görme (*computer vision*) ile inşaat ilerlemesini otomatik izler (Buildots, 2025).
- OpenSpace (ABD): 360° şantiye görüntüleme ve proje dokümantasyonu sağlar. Yalnızca video kamera ile şantiyeyi gezmek yeterlidir, sistem otomatik eşleştirir (OpenSpace, 2025).
- Buildvision: İnşaat sürecindeki tüm teknik, finansal ve yönetsel verileri tek çatı altında toplayan bir ConTech platformudur. Yatırımcı, yüklenici ve şantiye arasında veri akışı sağlar (BuildVision, 2025).

Türkiye Örnekleri:

- Bulutistan: Türkiye merkezli bir bulut tabanlı yönetim sistemidir. Contech içinde doğrudan bir BIM aracı veya sahada görev takibi sistemi olmasa da;

şantiye veri altyapısı, sensör bağlantıları, veri güvenliği ve yüksek erişilebilirliği gibi kritik ihtiyaçları karşılayarak ConTech ekosistemine altyapı seviyesinde katkı sağlar (Bulutistan, 2025).

- Yapıradar: Şantiye radar sistemi, yatırım analizi, rakip izleme çözümleri sunar (YapıRadar, 2025).
- BIMCRONE: İnşaat sektöründe 3B BIM tabanlı dijital ikiz, zaman ve maliyet takibi, saha operasyonlarının yönetimi, taşeron-kabul süreçlerinin dijitalleşmesi ve güvenli veri paylaşımı gibi çok boyutlu işlevler sunan entegre bir platformdur. Bu kapsamıyla, saha verilerinin dijitalleştirilip gerçek zamanlı izlenmesi, şeffaf iş akışı ve veriye dayalı karar mekanizmalarını destekleyerek projelerde verimlilik, kârlılık ve kontrol sağlar (BIMCRONE, 2025).

1.5.3. Gayrimenkul, Varlık ve Tesis Yönetimi

Gayrimenkul, varlık ve tesis yönetimi girişimleri; bina, site veya tesislerin bakımı, kira takibi, aidat yönetimi, arıza bildirimi, enerji izleme gibi operasyonlarını dijitalleştiren çözümleri kapsar. Genellikle B2B ((İşletmeden İşletmeye, İng. *Business-to-Business*) ve B2B2C (İşletmeden İşletmeye ve Tüketicieye, *Business-to-Business-to-Consumer*) modellerde çalışır.

Global Örnekler:

- Building Engines (ABD): Ticari mülk yöneticileri için bakım takibi, kiracı iletişimi, belge yönetimi ve raporlama araçları sunar (Building Engines, 2025).
- Yardi (ABD): Çok yönlü bir platformdur. Kiralama, muhasebe, enerji yönetimi, CRM ve tesis yönetimini tek sistemde sunar (Yardi, 2025).
- Facilio (Hindistan / ABD): Gerçek zamanlı tesis verisi toplar, operasyonları merkezi panel üzerinden yönlendirir. Büyük ölçekli binalar ve kampüsler için uygundur (Facilio, 2025).

Türkiye Örnekleri:

- Apsiyon: Site ve apartman yönetimleri için Türkiye’de en yaygın kullanılan platformlardan biridir. Aidat takibi, gelir-gider yönetimi, online ödeme, anket ve duyuru sistemleri gibi işlevler sunar (Apsiyon, 2025).
- Yönetimcell: Site ve apartman yönetimi otomasyonu sağlar. Aidat tahsilatı, raporlama, iletişim ve bakım taleplerinin yönetimi gibi işlevler sunar (Yönetimcell, 2025).

1.5.4. FinTech ve InvestTech

FinTech ve InvestTech girişimleri, gayrimenkul yatırım süreçlerini dijitalleştiren ve finansal hizmetlerle entegre çözümler sunan platformları kapsar. Kitle fonlaması, dijital mortgage, tokenizasyon, kredi skorelama gibi alt alanlar içerir.

Global Örnekler:

- Fundrise (ABD): Bireysel yatırımcıların küçük meblağlarla büyük gayrimenkul projelerine ortak olmasını sağlar. Dijital gayrimenkul fonları üzerinden pasif gelir imkânı sunar (Fundrise, 2025).
- RealT (ABD): Blokzincir tabanlı tokenizasyon platformudur. Mülkiyet hakkını dijital token’lara bölerek yatırımcıların küçük parçalara yatırım yapmasına olanak tanır (RealT, 2025b).
- LendInvest (İngiltere): Kredi derecelendirme ve dijital ipotek süreçlerinde uzmanlaşmış bir PropTech-FinTech hibriti. Geliştiriciler ve alıcılar için alternatif finansman sağlar (Lendinvest, 2025).

Türkiye Örnekleri:

- Tapu.com: Aynı zamanda finansal modellemeye dayalı açık artırma sistemine sahiptir. Özellikle portföy yönetimi ve kurumsal satışlar açısından yatırımcı dostudur (Tapu.com, 2025).
- Housearch: Türkiye ve BAE merkezli bir PropFinTech platformudur. Kullanıcıların konut kredisi olanaklarını dijital ortamda karşılaştırarak en uygun finansman seçeneğini bulmalarına imkân verir (Housearch, 2025).

1.5.5. Aracılık ve Pazar Yerleri

Aracılık ve pazar yerleri girişimleri, emlak ilanlarının çevrim içi platformlarda listelenmesini, alım-satım ve kiralama işlemlerinin dijitalleştirilmesini kapsar. Genellikle son kullanıcı (B2C, İng. *Business-to-Consumer*) ya da emlak ofisleri (B2B) hedeflenir.

Global Örnekler:

- Zillow (ABD): ABD merkezli en büyük çevrim içi emlak portalıdır. Satış/kiralama ilanları, tahmini ev değerleri (Zestimate), mortgage hesaplama gibi çok sayıda hizmet sunar (Zillow, 2025b).
- Rightmove (İngiltere): İngiltere'nin en büyük dijital emlak platformudur. Tüm ülke çapındaki ilanlar tek bir çatı altında sunulur. Emlakçılar ve bireysel kullanıcılar hizmetten faydalanır (Rightmove, 2025).
- PropertyGuru (Güneydoğu Asya): Singapur merkezli bu platform Tayland, Malezya ve Endonezya gibi ülkelerde lider konumdadır. Alıcı, satıcı ve geliştirici üçgeninde pazar yeri sunar (PropertyGuru, 2025).

Türkiye Örnekleri:

- Zingat: Kullanıcıya bölge puanı, eğitim durumu, ulaşım gibi detaylarla karar desteği sunar. Aynı zamanda Endeksa ile entegre çalışarak değer tahmini verir (Zingat, 2025).
- Emlakjet: İlan platformu olarak konumlanmakla birlikte, kullanıcıya özel reklam gösterimi, kredi analizleri gibi destekler sunar. Sahibinden.com ile rekabet hâlinde (Emlakjet, 2025).
- Tapu.com: Özellikle icralık, bankadan veya kamu mülkiyetinden satılık taşınmazların şeffaf ihale süreciyle sunulduğu yenilikçi bir modeldir (Tapu.com, 2025).

1.5.6. Veri Analitiği, Yapay zekâ ve AVM'ler

Bu girişimler, gayrimenkul piyasalarına ilişkin büyük verinin toplanması, analiz edilmesi ve bu analizlerin karar destek sistemlerine dönüştürülmesini kapsar. Veri ve analitik çözümler, sadece kullanıcı davranışlarının modellenmesinde değil aynı zamanda AVM'lerin temel veri kaynağını oluşturması açısından da önemlidir. ML, istatistiksel modelleme ve CBS ile gayrimenkullerin otomatik olarak değerinin tahmin edilmesini sağlar. Fiyat tahmini, pazar eğilimleri, yatırım değerlemesi, bölgesel analizler gibi birçok kullanım alanı bulunur. Bankalar, kamu kurumları, yatırımcılar ve sigorta şirketleri bu sistemlerden yararlanır.

Global Örnekler:

- Cotality (ABD): ABD'deki konut piyasasına dair en kapsamlı veri sağlayıcılardan biridir. Mortgage risk puanlamasından bölgesel değer tahminlerine kadar çok sayıda hizmet sunar (Cotality, 2025).
- HouseCanary (ABD): Gayrimenkul değerlemesi alanına odaklanan yenilikçi bir aracılık platformu olarak, sektöre yönelik yazılım ve hizmet çözümleri geliştirmektedir. Kurumun sunduğu araçlar; başta finans kuruluşları, yatırımcılar, kredi sağlayıcıları ve ipotek piyasası aktörleri olmak üzere geniş bir kullanıcı kitlesi tarafından, ileri düzeyde değerlendirme, piyasa tahmini ve işlem destek süreçlerinde etkin biçimde kullanılmaktadır (HouseCanary, 2025).
- Zillow (ABD) – Zestimate: Zillow'un geliştirdiği "Zestimate" modeli, milyonlarca gayrimenkulün piyasa değerini otomatik olarak hesaplar. Model, geçmiş satışlar, konum, bina özellikleri gibi birçok değişkeni analiz eder (Zillow, 2025a).
- PriceHubble (İsviçre): Yapay zekâ tabanlı bir AVM platformudur. Avrupa pazarlarında konut ve ticari mülkler için değerlendirme, kiralama geliri tahmini ve yatırım potansiyeli analizleri sunar (PriceHubble, 2025)

Türkiye Örnekleri:

- Endeksa: Türkiye’de emlak değerkleme ve pazar analitiđi alanında lider platformlardan biridir. Yapay zekâ ile konut değerk tahmini, kira analizi, amortisman süresi hesaplama gibi hizmetler sunar (Endeksa, 2025a).
- Tapusor: Tapu kayıtlarından ve bölgesel verilerden faydalanarak gayrimenkul analizleri üretir. Yatırım yapılabilir bölgelerin tespiti konusunda araçlar sağlar (Tuvimer, 2025).
- UrbanStat: Başlangıçta sigorta analitiđi için kurulmuş olsa da mekânsal analiz yetkinliđiyle gayrimenkul alanında da kullanılmaktadır. Lokasyon bazlı risk modellemeleri yapar (UrbanStat, 2025).
- Fizbot: Fizbot, Türkiye’de emlak danışmanları ve ofisleri için geliştirilen yapay zekâ destekli bir müşteri ilişkileri yönetimi platformudur. Müşteri takibi, portföy yönetimi, performans analizi, veri analitiđi ve otomatik raporlama gibi özellikler sunarak emlak işlemlerinin verimliliđini artırmayı amaçlamaktadır. 2023 yılında 500 bin dolar yatırım alan girişim, Türkiye genelinde kullanıcı sayısını artırmış ve sektördeki dijitalleşme sürecine önemli katkılar sunmuştur (Fizbot, 2025).

1.5.7. Blokzincir ve Akıllı Sözleşmeler

Bu girişimler, gayrimenkul işlemlerinde şeffaflık, güvenlik ve otomasyon sağlamak için blokzincir teknolojisini kullanan çözümleri içerir. Tapu kayıtları, mülkiyet transferi, tokenizasyon ve akıllı sözleşmeler bu alanın temel bileşenleridir.

Global Örnekler:

- Propy (ABD): Tapu devri, satış sözleşmesi ve ödeme işlemlerini blokzincir üzerinden gerçekleştiren uçtan uca dijital bir platformdur. Akıllı sözleşmelerle mülkiyet devri sağlar (Propy, 2025).
- Ubitquity (ABD): Tapu ve ipotek kayıtlarını blokzincir üzerinde saklayan, belediyelere ve tapu ofislerine yönelik bir SaaS (Hizmet Olarak Yazılım, İng. *Software as a Service*) çözümüdür (Ubitquity, 2025).
- RealT (ABD): Gerçek gayrimenkul mülkiyetini Ethereum blokzinciri üzerinde tokenize eder. Token sahipleri mülkten pay alır ve gelir elde eder (RealT, 2025b).

- Chromaway + Lantmäteriet (İsveç): İsveç Kadastro Kurumu ile birlikte geliştirilen bu proje, gayrimenkul işlemlerinin blokzincir tabanlı yürütülmesini test etmiştir (ChromaWay, 2025).

Türkiye Örnekleri

Türkiye’de bu alanda aktif bir özel sektör platformu henüz görülmemektedir. Ancak kamu-özel iş birliği potansiyeli bulunmaktadır.

1.5.8. Sanal Gerçeklik ve Görselleştirme

Bu girişimler, gayrimenkullerin dijital ortamda üç boyutlu olarak modellenmesi, sanal turlar düzenlenmesi ve artırılmış gerçeklik ile deneyimlenmesini sağlar. Özellikle pazarlama, satış, mimari tasarım ve planlama süreçlerinde etkilidir.

Global Örnekler:

- Matterport (ABD): En bilinen sanal gerçeklik, 3B görselleştirme platformlarından biridir. Kameralarla taranan mekânlar dijital ortama aktarılır ve kullanıcılar sanal olarak gezebilir (Matterport, 2025).
- Cupix (Güney Kore): Yapı içi 3B görselleştirme ve proje takibi için çözüm sunar. BIM entegrasyonu ile şantiye ilerlemesi izlenebilir (Cupix, 2025).
- Augment (Fransa): Artırılmış gerçeklik tabanlı ürün ve yapı sunumu yapar. Kullanıcı, telefonu veya tabletiyle gerçek dünya ortamında, gerçek zamanlı olarak ölçeklenen nesnelerin 3B görsellerini oluşturabilir (Augment, 2025).

Türkiye Örnekleri:

- Simularge: Gerçek zamanlı 3B simülasyon ve mühendislik analizleri yapan bir teknoloji şirkettir. Mimari modelleme ve yapı performans analizlerinde kullanılabilir (Simularge, 2025).
- Tridify (Türkiye ofisi): BIM modellerini web tabanlı 3B gezilebilir hale getiren platformdur. Sanal turlar ve projelendirme sunumları için kullanılır.

- Visartech (Türkiye iş ortaklıkları ile): Yurt dışı merkezli olsa da Türkiye'de de hizmet sunmaktadır. Gayrimenkul projelerinde etkileşimli tanıtım turları ve sanal tanıtım alanı çözümleri sunar (Visartech, 2025).
- Get Twin: Get Twin, yapay zekâ ve 3B modelleme ile gayrimenkul projelerinin dijital ikizlerini oluşturarak yatırımcılara ve geliştiricilere karar destek sistemleri sunan bir girişimdir. 2024 yılında Grifon Capital'dan 120 bin dolarlık yatırım alan Get Twin, sanal tur, risk analizi ve değer tahmini gibi veri odaklı çözümleriyle gayrimenkul sektöründeki dijitalleşmeye katkı sağlamaktadır (Get Twin, 2025).

1.5.9. Sürdürülebilirlik ve ESG Uygulamaları

Bu girişimler, enerji verimliliği, karbon ayak izinin azaltılması, sürdürülebilir bina sertifikaları, çevresel izleme sistemleri ve sosyal-sorumluluk temelli mülkiyet yönetimini kapsar. ESG (Çevresel, Sosyal ve Yönetişim; İng. *Environmental, Social, Governance*) kriterlerine uygunluk burada temel odaktır.

Global Örnekler:

- Measurabl (ABD): Ticari gayrimenkul portföyleri için sürdürülebilirlik performansını izleyen bir ESG veri platformudur. Enerji, su, karbon emisyonu verilerini toplayarak raporlar (Measurabl, 2025).
- Envizi (Avustralya): ESG veri yönetimi platformudur. Yeşil bina performansı, sürdürülebilirlik hedefleri ve mevzuata uyum süreçlerini tek merkezde toplar (IBM Envizi, 2024).
- Prescriptive Data – Nantum OS (ABD): Yapay zekâ destekli bir bina işletim sistemi sunar. Enerji tüketimini optimize eder, sürdürülebilirlik hedeflerini destekler (Nantum AI, 2025).

Türkiye Örnekleri:

- Reengen: IoT destekli enerji analitiği platformudur. Ticari ve konut binalarında enerji tüketimi, karbon salımı ve performans izleme ile sürdürülebilirlik verisi üretir (Reengen, 2025).

- Evreka: Atık toplama ve çevre yönetimi süreçlerini dijitalleştiren bir sistemdir. Belediyeler ve site yönetimleri için sürdürülebilir atık takibi sağlar (Evreka, 2025).

Çevre Dostu Binalar Derneği (ÇEDBİK) de bu alanda dijitalleşme projeleri geliştirmektedir. Türkiye’de sürdürülebilir bina sertifikasyonlarını dijitalleştirme çalışmaları yürütmektedir. Gelişen PropTech sistemleriyle entegrasyon potansiyeli mevcuttur (ÇEDBİK, 2025).

PropTech girişimleri, faaliyet alanlarına göre sınıflandırılarak küresel ve ulusal düzeyde karşılaştırmalı biçimde incelenmiştir. Verilen örnekler, PropTech’in çok boyutlu yapısını somutlaştırmakta ve her bir kategoride farklı teknolojik çözümlerin geliştirilmekte olduğunu göstermektedir. Türkiye’de özellikle mülkiyet yönetimi, veri analitiği ve dijital pazar yerleri alanlarında öne çıkan girişimler bulunurken; blokzincir, artırılmış gerçeklik, sanal gerçeklik ve ESG uyumlu teknolojilerdeki girişim sayısı henüz sınırlıdır. Bu durum, sektörel gelişimin yönelimlerini ve gelecekte öncelikli yatırım alanlarını işaret etmektedir.

1.6. Türkiye’de PropTech Ekosistemi: Mevcut Durum ve Gelişme Potansiyeli

Türkiye’de PropTech ekosistemi, henüz gelişiminin erken aşamalarında olmakla birlikte, yüksek bir büyüme potansiyeli barındırmaktadır. Özellikle bölgesel farkındalık düzeyinin artması ve kamu-özel sektör arasında dijital köprülerin kurulması, sektördeki yapının giderek daha kurumsal hâle gelmesini sağlamaktadır. Yerli platformlar, teknoloji kullanımı, veri işleme kapasitesi ve kullanıcı deneyimi açısından önemli bir gelişim ivmesi yakalamıştır. Önümüzdeki dönemde, bu girişimlerin daha kapsamlı API (Uygulama Programlama Arayüzü) entegrasyonları, uluslararası açılımlar ve sürdürülebilirlik odaklı teknolojiler geliştirmesi beklenmektedir.

Türkiye'deki PropTech girişimlerinin büyümesi yalnızca özel sektörün inovasyon gücüyle sınırlı kalmamış; aynı zamanda çeşitli kamu destek mekanizmaları, teknopark yapılanmaları ve yatırım ortamındaki dinamizmle desteklenmiştir. TÜBİTAK, Tapu ve Kadastro Genel Müdürlüğü (TKGM) ile Sanayi ve Teknoloji Bakanlığı gibi kurumlar doğrudan PropTech’e odaklanmasa da dijital dönüşüm, yapay

zekâ, akıllı şehir uygulamaları ve coğrafi bilgi sistemlerine yönelik destek programları aracılığıyla sektöre dolaylı katkılar sunmaktadır.

İTÜ ARI Teknokent, ODTÜ Teknokent ve Yıldız Teknopark gibi teknoloji geliştirme bölgelerinde ortaya çıkan PropTech girişimleri; konut değerlendirme sistemleri, kentsel dönüşüm analitiği, sürdürülebilir yapı teknolojileri ve tapu işlemlerinin dijitalleştirilmesi gibi alanlarda faaliyet göstermektedir.

Erken aşama girişimlere yönelik melek yatırımcı ilgisinde artış gözlemlenirken, PropTech odaklı tematik yatırım fonları ve girişim sermayesi destekleri hâlen sınırlı düzeydedir. Öte yandan, REIDIN ve Globalworth gibi uluslararası yatırımcıların Türkiye merkezli girişimlere ilgisi giderek artmaktadır.

PropTech sektörünün sürdürülebilir gelişimi için aşağıdaki alanlarda stratejik planlama yapılması gerekmektedir:

- İmar, tapu ve çevresel verilere ilişkin açık veri politikalarının yaygınlaştırılması,
- Yasal altyapının dijital tapu sistemleri ve AVMler ile uyumlu hâle getirilmesi,
- PropTech ile şehircilik politikaları arasında entegrasyonu destekleyen kamu stratejilerinin oluşturulması,
- Üniversite-sanayi iş birliklerinin ve yatırım fonlarının çeşitlendirilmesi,
- Kırsal ve küçük ölçekli yerleşim yerlerinde erişilebilir dijital çözümlerin yaygınlaştırılması.

Türkiye'nin genç ve dijital uyum yeteneği yüksek nüfusu, hızlı kentleşme süreci ve teknolojik dönüşüme açıklığı dikkate alındığında; PropTech'in önümüzdeki beş yıl içerisinde yalnızca bir yenilik alanı değil, aynı zamanda yerleşik bir kamu-özel sektör işleyiş modeli olarak kurumsallaşması mümkündür.

BÖLÜM 2

ULUSLARARASI ÇALIŞMALAR

Gayrimenkul değerlendirme faaliyetleri, küresel ölçekte farklı ekonomik, hukuki ve kurumsal yapılar içinde yürütülse de mesleğin güvenilirliği ve şeffaflığı açısından ortak standart ve ilkelerin benimsenmesi büyük önem taşımaktadır. Uluslararası düzeyde oluşturulan değerlendirme standartları, yatırımcıların, finansal kurumların, kamu otoritelerinin ve bireysel paydaşların karar alma süreçlerinde tutarlılığı sağlamayı amaçlamaktadır. Bu bağlamda, farklı ülkelerde faaliyet gösteren profesyonel değerlendirme kuruluşları, mesleki yeterlilik kriterlerinin belirlenmesi, etik kuralların uygulanması, metodolojik çerçevenin geliştirilmesi ve meslek mensuplarının sürekli eğitimi gibi konularda kritik roller üstlenmektedir.

Bu bölümde, gayrimenkul değerlendirme alanında küresel ölçekte kabul gören başlıca standartlar ve bu standartların oluşturulmasında etkin olan kurumlar tanıtılmaktadır. Lisanslı Değerleme Uzmanlığı Kraliyet Enstitüsü (RICS), Uluslararası Değerleme Standartları Konseyi (IVSC) ve Avrupa Değerleme Örgütleri Birliği (TEGoVA) gibi kuruluşlar, uluslararası düzeyde mesleki yönetişimi sağlayan ve standartları belirleyen önde gelen yapılardır. Bunun yanında, ABD Değerleme Vakfı (TAF) ve ABD Değerleme Enstitüsü (AI) gibi Amerika Birleşik Devletleri merkezli kurumlar ile Kanada Değerleme Enstitüsü (AIC), Uluslararası Değerlemeciler Birliği (IAAO) ve Uluslararası Taşınmaz Federasyonu (FIABCI), gibi kuruluşlar, kendi ülkelerinde olduğu kadar uluslararası platformda da etkili çalışmalara imza atmaktadır.

Ayrıca, Asya-Pasifik, Avrupa ve diğer bölgelerde faaliyet gösteren Japon Gayrimenkul Değerlendiricileri Birliği (JAREA), Avustralya Emlak Enstitüsü (API), Rusya Değerleme Uzmanları Derneği (RSA), Çin Değerleme Birliği (CAS) ve Kore Mülkiyet Değerlendiricileri Derneği (KAPA) gibi bölgesel kuruluşlar, kendi coğrafyalarında standartların yerelleştirilmesi, meslek mensuplarının sertifikasyonu ve eğitim faaliyetlerinin yürütülmesi gibi işlevler üstlenmektedir. Türkiye’de ise Türkiye Değerleme Uzmanları Birliği (TDUB), ulusal değerlendirme standartlarının uygulanması, sektörün mesleki gelişiminin sağlanması ve uluslararası kurumlarla iş birliği yapılması konularında öncü rol oynamaktadır.

Bu çerçevede, izleyen alt başlıklarda her bir kuruluşun tarihçesi, yapısı, işleyiş biçimi, görev ve yetki alanları ile ulusal ve uluslararası değerlendirme pratiğine katkıları detaylı olarak ele alınacaktır. Böylece, küresel ölçekte gayrimenkul değerlendirme standartlarının oluşum süreci ve bu sürece yön veren kurumların rolü bütüncül bir bakış açısıyla ortaya konulacaktır.

Bölüm kapsamında ayrıca, farklı ülkelerin taşınmaz değerlendirme sistemleri karşılaştırmalı olarak incelenmiş; her ülkenin kullandığı toplu değerlendirme yöntemleri, bu süreçten sorumlu olan resmi veya yarı resmî kurumlar ve uygulamanın dayandığı yasal düzenlemeler bir arada sunulmuştur. Böylece, çeşitli coğrafyalarda benimsenen yöntemsel yaklaşımlar, kurumsal yapı farklılıkları ve hukuki çerçeveler tek bir formatta görülerek, uluslararası uygulamalar arasındaki benzerlik ve farklılıkların daha net biçimde analiz edilmesi mümkün hale gelmiştir.

2.1. Uluslararası ve Ulusal Gayrimenkul Değerleme Standartları ve Kurumları

Uluslararası değerlendirme uygulamalarının tutarlılık, şeffaflık ve karşılaştırılabilirlik ilkeleri etrafında şekillenebilmesi, ulusal düzenlemelerin ötesinde evrensel bir standart setine duyulan ihtiyacın bir sonucudur. Bu bağlamda, uluslararası değerlendirme kuruluşları hem metodolojik çerçeveler hem de etik ve yeterlilik gereksinimleri açısından rehberlik sağlar. Söz konusu kuruluşlar, piyasa koşullarına uyumlu, güncel ve tarafsız değerlendirme yöntemleri tanımlayarak, değerlendirme sürecinin tüm paydaşlarca güvenilir bulunmasını mümkün kılar (IVSC, 2023; RICS, 2024b; TEGOVA, 2025b). Aşağıdaki alt başlıklarda bu kurumların temel misyonları, yayınladıkları standartlar ve uygulamada sundukları yapı taşları ayrıntılı olarak ele alınacaktır.

2.1.1. RICS - Lisanslı Değerleme Uzmanlığı Kraliyet Enstitüsü

RICS, 1868'de İngiltere'de kurulmuş köklü bir meslekî kuruluş olarak dünya çapında inşaat, gayrimenkul ve altyapı sektörlerinde çalışan profesyonellerin yetkinlik, etik ve metodolojik açıdan ortak bir çerçevede hareket etmesini amaçlamaktadır. Zamanla, üyelik yapısı ve faaliyet alanları genişlemiş ve 1881'de

Royal unvanını alarak *Royal Institution of Chartered Surveyors* adını benimsemiştir. 140'tan fazla ülkede 130.000'den fazla üyesi bulunan RICS, dünya genelinde gayrimenkul, inşaat ve altyapı alanında profesyonel standartları belirleyen ve bu alandaki uzmanların meslek gelişimini destekleyen bir kuruluştur (RICS, 2024b). Kuruluşun temel misyonları arasında kamu yararı ilkesine dayalı olarak tüketici, yatırımcı ve kamunun güven duyacağı şeffaf ve tarafsız standartlar geliştirmek; üyelerinin teknik bilgi birikimini araştırma, eğitim ve yayın programlarıyla sürekli güncellemek ve sürdürülebilir uygulamaları teşvik etmek yer alır (RICS, 2024b).

RICS, meslekî yeterlilikler, etik kurallar ve iyi uygulamalar konusunda çok sayıda standart yayımlamaktadır. Bu kapsamda, en önemli belgelerden biri, tüm değerlendirme çalışmalarında uyulması zorunlu kurallar ile yorumlayıcı rehberleri içeren ve Uluslararası Değerleme Standartları'nı (IVS) da bünyesinde barındıran Red Book'tur. Ayrıca, gayrimenkul ölçümlerinde küresel tutarlılık sağlamak amacıyla Uluslararası Değerleme Standartları (IPMS) yayımlamıştır. Etik davranış ve meslekî yeterlilik ilkelerini belirleyen *Rules of Conduct* ise dürüstlük, bütünlük, yeterlilik ve kamusal çıkar ilkeleri etrafında yapılandırılmıştır (RICS, 2024c).

Uygulamada RICS; üyelerin eğitim, deneyim ve etik gereklilikleri karşıladıklarını belgeleyen akreditasyon çerçeveleri, zorunlu sürekli mesleki gelişim programlarıyla üyelerin güncel piyasa ve teknoloji gelişmelerine adapte olmalarını sağlayan eğitim mekanizmaları, dijital bilgi erişim araçları ile Birleşmiş Milletler ve IPMS Koalisyonu gibi uluslararası iş birlikleri sunmaktadır (RICS, 2024a). Bu unsurlar, değerlendirme ve danışmanlık süreçlerini hem teknik hem de etik açıdan güçlü bir zemine oturtarak tüm paydaşlar için güvenilir bir altyapı oluşturmaktadır.

2.1.2. IVSC - Uluslararası Değerleme Standartları Konseyi

IVSC, 1981'de kurulmuş, kâr amacı gütmeyen ve Birleşik Krallık merkezli bir standart belirleyici kuruluş olarak, değerlendirme mesleğinin uluslararası alanda tutarlı, şeffaf ve güvenilir uygulamalar etrafında gelişmesini amaçlamaktadır. IVSC'in birincil misyonu; başta finansal piyasalar ve sermaye akışları için kritik öneme sahip değerlendirme hizmetlerinin kalitesini artırmak üzere IVS'i hazırlamak ve küresel ölçekte benimsenmesini teşvik etmektir (IVSC, 2023). Ayrıca, değerlendirme uzmanlarının teknik

ve etik yeterliliklerini artırmak için ulusal meslek birlikleri, düzenleyici kurumlar ve akademik çevrelerle iş birliği geliştirmekte, kullanıcılar ile hazırlayıcıların ihtiyaçlarını dengeli bir şekilde karşılayan bir danışma süreci işletmektedir. IVSC'nin dünya çapında 137 ülkede faaliyet gösteren 200'den fazla üye kuruluşu bulunmaktadır (IVSC, 2023).

IVSC tarafından yayımlanan IVS değerlendirme projelerinin planlanması, raporlanması ve sıkı kurallara bağlı şekilde gerçekleştirilmesi için ilke temelli bir rehber sunar. IVS, teknik kurullar tarafından hazırlanır. Her güncelleme öncesi tartışma belgeleri ve görüşe açma taslakları yoluyla kamuoyu ve paydaş görüşlerine sunulur (IVSC, 2025). Bu süreç, standartların hem güncel piyasa dinamiklerine uyumlu kalmasını hem de geniş bir profesyonel topluluğun katkısını almasını garanti eder. Bu mekanizmalar sayesinde IVSC, değerlendirme mesleğinin teknik yeterliliğini yükseltirken aynı zamanda uygulayıcılar, düzenleyiciler ve kullanıcılar arasında ortak bir dil ve güven altyapısı oluşturur.

2.1.3. TEGoVA - Avrupa Değerleme Örgütleri Birliği

TEGoVA, 1977 yılında kurulmuş olup Avrupa genelinde gayrimenkul değerlendirme uygulamalarının uyumlu, şeffaf ve yüksek nitelikli standartlar çerçevesinde yapılmasını amaçlayan çatı örgüttür (TEGOVA, 2025b). Birliğin temel misyonları arasında; tüm üye dernekler nezdinde kabul gören “The Blue Book” Avrupa Değerleme Standartlarını (EVS) geliştirmek ve güncellemek, Avrupa kurumları düzeyinde değerlendirme mesleğinin çıkarlarını savunmak ve mesleki etik ile yeterlilik kriterlerini belirlemek yer alır (TEGOVA, 2025a). EVS'nin onuncu (2025) baskısı, değerlendirme sürecinin planlanması, metodolojisi, raporlama gereksinimleri ve etik ilkeleri konusunda kapsamlı rehberlik sunar; bu rehber, her yıl kamuoyu görüşüne açılan taslaklar aracılığıyla güncellenir (TEGOVA, 2025a).

Kuruluş, ayrıca, Tanınmış Avrupa Değerleme Uzmanı ve TEGoVA Konut Değerleme Uzmanı gibi sertifikasyon programları ile belirlenen eğitim ve deneyim koşulları doğrultusunda uygulanan bir mesleki yeterlilik belgelendirme sistemi de bulunmaktadır. Bunun yanı sıra, Brüksel merkezli Sekretarya ve 77 ulusal derneği kapsayan geniş bir üyelik ağına sahiptir (TEGOVA, 2025b). Tüm bu yapı ve

mekanizmalar aracılığıyla, Avrupa genelinde gayrimenkul değerlendirme uygulamalarında tutarlılık, şeffaflık ve kalite güvencesi sağlanmasına katkıda bulunmakta ve mesleğin genel olarak itibarını ve profesyonel standartlarını desteklemektedir.

2.1.4. TAF - ABD Değerleme Vakfı

TAF, ABD’de gayrimenkul başta olmak üzere çeşitli varlık sınıflarının değerlemesinde mesleki standartların geliştirilmesi ve mesleki yeterliliğin desteklenmesi amacıyla faaliyet gösteren bağımsız ve kar amacı gütmeyen bir kuruluştur (TAF, 2021). Vakfın temel misyonu, kamu yararına hizmet eden bağımsız ve tarafsız değerlendirme standartları ile mesleki nitelik kriterlerinin oluşturulması ve güncellenmesidir. Bu misyon doğrultusunda, TAF bünyesindeki Değerleme Standartları Kurulu tarafından yayımlanan ve ABD’de değerlendirme uygulamalarının temel çerçevesini oluşturan Mesleki Değerlendirme Uygulamalarının Standartları (USPAP) en önemli standart setini teşkil etmektedir (TAF, 2024). USPAP, değerlendirme raporlarının hazırlanması ve sunulmasına ilişkin etik kurallar, performans standartları ve raporlama ilkelerini kapsamaktadır. Ayrıca, TAF bünyesindeki Değerleme Uzmanı Yeterlilik Kurulu aracılığıyla, değerlendirme uzmanlarının eğitim, deneyim ve sınav gerekliliklerine dair ulusal nitelik standartları belirlenmekte ve güncellenmektedir (TAF, 2021)

2.1.5. AI - ABD Değerleme Enstitüsü

AI, 1932 yılında kurulmuş olan ve dünya genelinde saygınlığı yüksek bir profesyonel değerlendirme kuruluşudur. Merkezi Washington DC’de bulunmaktadır. Enstitünün temel misyonu, değerlendirme mesleğinin gelişimini desteklemek, üyelerinin mesleki yetkinliklerini artırmak ve yüksek etik standartların benimsenmesini teşvik etmektir (AI, 2025). Bu doğrultuda AI hem gayrimenkul hem de diğer varlık sınıflarına ilişkin değerlendirme uygulamalarında kaliteyi ve mesleki mükemmeliyeti artırmayı amaçlamaktadır.

AI, doğrudan bağlayıcı yasal standartlar yayınlamamakla birlikte, üyeleri için etik ve uygulama standartları geliştirmekte ve bu çerçevede USPAP ile uyumlu

kapsamlı mesleki rehberler ve en iyi uygulama kılavuzları sunmaktadır. Ayrıca, uluslararası düzeyde tanınan sertifikasyon programları aracılığıyla üyelerin uzmanlık alanlarına göre mesleki yeterliliklerini belgelemektedir (AI, 2025).

2.1.6. AIC - Kanada Değerleme Enstitüsü

AIC, 1938 yılında kurulmuş olup Kanada'nın en büyük ve en etkili gayrimenkul değerlendirme kuruluşlarından biridir. 5.500'den fazla üyesi bulunan AIC, Kanada Akredite Değerleme Uzmanları Enstitüsü ve Kanada Konut Değerleme Uzmanı unvanlarını vermek için 10 bağlı eyalet derneğiyle iş birliği içinde çalışmaktadır. (AIC, 2025). AACI ve CRA unvanlarını alabilmek için profesyonel deneyim, sınav ve eğitim şartları aranmaktadır. Enstitünün temel misyonu, kamu yararına hizmet eden yüksek kaliteli değerlendirme hizmetlerinin sunulmasını teşvik etmek, üyelerinin mesleki gelişimini desteklemek ve etik değerlendirme uygulamalarını güçlendirmek olarak tanımlanmaktadır (AIC, 2025). Bu kapsamda AIC, Kanada'daki değerlendirme mesleğinin kalite ve güvenilirlik düzeyinin korunmasına ve geliştirilmesine önemli katkılar sağlamaktadır.

Enstitü, Kanada'da değerlendirme pratiğinin temel standartlarını oluşturan Kanada Mesleki Gayrimenkul Değerleme Uygulamalarında Standartlar (CUSPAP) belgesini yayımlamakta ve güncellemektedir. CUSPAP kendi içinde Etik, Raporlama, Gayrimenkul Değerleme, İnceleme, Danışmanlık, Rezerv Planlama, Makine ve Ekipman Değerlendirme, Toplu Değerlendirme Standardını içermektedir. Ayrıca CUSPAP; etik kurallar, performans standartları ve raporlama yükümlülükleri gibi değerlendirme sürecine ilişkin kapsamlı ilkeleri içermektedir ve ülke genelinde tüm AIC üyeleri için bağlayıcı niteliktedir (AIC, 2024). Bunun yanı sıra AIC, ulusal ve uluslararası düzeyde tanınan mesleki sertifikasyon programları aracılığıyla üyelerinin mesleki yeterliliklerini ve uzmanlık alanlarını belgelemektedir (AIC, 2024).

2.1.7. ASA - Amerikan Değerlemeciler Birliği

Amerikan Değerlemeciler Birliği (ASA) 1936 yılında kurulmuş, çok disiplinli bir değerlendirme kuruluşu olup, yalnızca gayrimenkul değil aynı zamanda iş ve gayri maddi varlıklar, makineler ve ekipman gibi çeşitli varlık sınıflarının değerlemesini

kapsayan bir mesleki birliktir (ASA, 2025). 1987'de TAF'ı kuran sekiz büyük değerlendirme topluluğundan biridir ve de 1994'ten beri IVSC'nde temsil edilmektedir. Birliğin temel misyonu, değerlendirme alanında faaliyet gösteren profesyonellerin etik, bağımsız ve yüksek nitelikli değerlendirme hizmetleri sunmasını desteklemek ve meslek için yüksek standartların geliştirilmesini teşvik etmek olarak tanımlanmaktadır.

ASA doğrudan bağlayıcı yasal standartlar yayımlamamakla birlikte, üyeleri için etik kurallar ve uygulama standartları geliştirmekte ve bu standartların USPAP ile uyumlu olmasına önem vermektedir (ASA, 2025). Bu çerçevede, ASA üyeleri değerlendirme faaliyetlerini yürütürken USPAP hükümlerine ve ASA tarafından yayımlanan Etik Kurallar ve Profesyonel Uygulama Rehberi doğrultusunda hareket etmektedirler. ASA ayrıca, çeşitli değerlendirme alanları için mesleki yeterlilik sertifikasyonları sunmaktadır. Bu kapsamda *Accredited Senior Appraiser* ve *Accredited Member* unvanları, ilgili uzmanlık alanlarındaki yüksek mesleki yeterliliği belgeleyen sertifikasyon programlarıdır.

2.1.8. IAAO - Uluslararası Değerlemeciler Birliği

IAAO, 1934 yılında kurulmuş olup özellikle kamuya yönelik toplu değerlendirme ve vergilendirme amaçlı değerlendirme uygulamaları alanında dünya çapında önde gelen mesleki kuruluşlardan biridir (IAAO, 2025). Birliğin temel misyonu, adil ve eşit vergilendirme uygulamalarını desteklemek, küresel değerlendirme yöntemlerinin geliştirilmesini teşvik etmek ve bu alanda görev yapan profesyonellerin mesleki yetkinliklerini artırmak olarak tanımlanmaktadır.

IAAO, doğrudan bağlayıcı ulusal standartlar yayımlamamakla birlikte, Emlak Vergisi Politikası Standartları ve Gayrimenkulün Toplu Değerlemesine İlişkin Standartlar gibi önemli mesleki standart ve rehber belgeler üretmektedir. Bu standartlar; toplu değerlendirme yöntemleri, vergiye esas değerlendirme uygulamaları, veri yönetimi, model geliştirme ve sonuçların raporlanması gibi süreçler için kapsamlı ilkeler ve en iyi uygulama önerileri sunmaktadır.

Uygulamada IAAO, mesleki yeterlilik sertifikasyonları aracılığıyla üyelerinin uzmanlık düzeyini belgelemekte; ayrıca eğitim programları, araştırma faaliyetleri,

yayınlar ve uluslararası konferanslar yoluyla küresel düzeyde toplu değerlendirme pratiğinin gelişimine ve standardizasyonuna katkı sağlamaktadır (IAAO, 2025). IAAO'nun çalışmaları, özellikle AVM ve CBS tabanlı değerlendirme uygulamalarının gelişimi açısından da uluslararası alanda referans niteliği taşımaktadır (IAAO, 2018)

2.1.9. FIABCI - Uluslararası Taşınmaz Federasyonu

FIABCI, 1951 yılında Paris'te kurulmuş olup, dünya genelinde gayrimenkul profesyonellerini bir araya getiren en köklü ve en geniş kapsamlı uluslararası sektör örgütlerinden biridir (FIABCI, 2018). Federasyonun temel misyonu, uluslararası gayrimenkul iş birliğini ve bilgi paylaşımını teşvik etmek, mesleki etik ve kalite standartlarını geliştirmek ve sürdürülebilir gayrimenkul uygulamalarını desteklemek olarak tanımlanmaktadır.

FIABCI doğrudan teknik bağlayıcı değerlendirme standartları yayımlamamakla birlikte, üyeleri arasında mesleki etik ilkeler, en iyi uygulama kılavuzları ve politik öneriler geliştirilmesini desteklemektedir. Ayrıca FIABCI, Birleşmiş Milletler Ekonomik ve Sosyal Konseyi (ECOSOC) nezdinde danışmanlık statüsüne sahip olması sayesinde, küresel sürdürülebilir kalkınma hedefleri doğrultusunda sorumlu ve sürdürülebilir kentsel gelişim politikalarının oluşturulmasına katkı sunmaktadır.

Şekil 6. FIABCI Kurumsal ve Düzenli Üyeler Haritası.



Kaynak: (FIABCI, 2018)

Gayrimenkul sektörüyle ilişkili tüm profesyoneller için dünya çapında bir iş ağı organizasyonu olan FIABCI, uluslararası kongreler ve konferanslar, mesleki eğitim programları, çalışma grupları ve uzmanlık komiteleri, uluslararası iş ağı oluşturma faaliyetleri ve yayınladığı sektörel raporlar oluşturmaktadır (FIABCI, 2018). Bu faaliyetler sayesinde, farklı ülkelerdeki gayrimenkul profesyonelleri arasında bilgi ve deneyim paylaşımını, mesleki standartların yaygınlaştırılmasını ve sektörün küresel düzeyde daha bütünleşik ve sürdürülebilir bir yapıya kavuşmasını desteklemektedir.

2.1.10. Ce.S.E.T. - Taşınmaz Ekonomisi ve Değerleme Çalışmaları Merkezi

Taşınmaz Ekonomisi ve Değerleme Çalışmaları Merkezi (Ce.S.E.T.), İtalya’da faaliyet gösteren ve özellikle taşınmaz ekonomisi, arazi kullanımı ve değerlendirme alanlarında araştırma, eğitim ve bilgi paylaşımı amaçlı çalışan önemli bir akademik ve bilimsel merkezdir (Ce.S.E.T., 2025). Üyeler Meclisi, Bilimsel Komite, Başkan, Sekreter, Sayman, Denetleme Kurulu gibi organlardan oluşmaktadır. Şu anda 117 İtalyan, 57 fahri, 11 olağan yabancı ve 4 hak sahibi üyesi bulunmaktadır (Ce.S.E.T., 2025). Merkez gayrimenkul ve arazi ekonomisine ilişkin çalışmaların disiplinler arası bir bakış açısıyla geliştirilmesini ve bu alanda yenilikçi yöntemlerin, standartların ve politikaların oluşturulmasını hedeflemektedir.

Ce.S.E.T.’in temel misyonları arasında, taşınmaz değerlendirme teorisi ve uygulamasının geliştirilmesi, sürdürülebilir arazi yönetimi ve bölgesel kalkınma politikalarına katkı sağlanması, gayrimenkul ekonomisi alanında bilimsel araştırmaların teşvik edilmesi ve bilgi ve deneyim paylaşımına yönelik ulusal ve uluslararası iş birliklerinin güçlendirilmesi yer almaktadır (Ce.S.E.T., 2025). Merkez doğrudan resmî bağlayıcı değerlendirme standartları yayımlamamakla birlikte, üyeleri ve iş birliği yaptığı kurumlar için teorik çerçeveler, metodolojik kılavuzlar ve araştırma raporları üretmektedir. Özellikle toplu değerlendirme yöntemleri, pazar analizi, CBS entegrasyonu ve sürdürülebilir değerlendirme yaklaşımları gibi alanlarda öncü çalışmalar yürütmektedir.

Uygulamada Ce.S.E.T. bilimsel yayınlar (ör. *Valori e Valutazioni* dergisi), uluslararası sempozyumlar, eğitim ve sertifika programları, proje tabanlı araştırma faaliyetleri ve sektörel danışmanlık çalışmaları oluşturmaktadır (Ce.S.E.T., 2025). Ayrıca altı aylık süreli olarak ve hem İtalyanca hem de İngilizce yazılmış makaleler içeren *Aestimum* dergisini yayımlamaktadır. *Aestimum*, arazi değerlemesi ve ekonominin metodolojik çalışmasına adanmış hakemli bir dergidir. Dergide işlenen konular arasında kırsal, kentsel ve çevresel değerlendirme, kamu yatırımlarının analizi ve bölge planlaması bulunmaktadır. Tüm bu tematik alanlar, uluslararası bir senaryo çerçevesinde ele alınmaktadır (Ce.S.E.T., 2025). Bu faaliyetler sayesinde Ce.S.E.T., Avrupa ve uluslararası ölçekte taşınmaz değerlendirme biliminin gelişimine ve uygulama kalitesinin artırılmasına katkıda bulunmaktadır.

2.1.11. CRE - Gayrimenkul Danışmanları Kuruluşu

CRE, 1953 yılında kurulmuş olup uluslararası düzeyde tanınan bağımsız gayrimenkul danışmanları ve uzmanlarından oluşan seçkin bir mesleki organizasyondur (CRE, 2025b). Kuruluşun temel misyonu, kamu yararını ön planda tutan, bağımsız ve tarafsız gayrimenkul danışmanlık hizmetlerinin teşvik edilmesi, üyeleri arasında yüksek etik standartların benimsenmesi ve mesleki mükemmeliyetin desteklenmesidir. Üyeleri 22 farklı ülkede faaliyet gösterir ve 60'tan fazla gayrimenkul disiplini uzmanlık sahibidir; bu sayede her tür varlık sınıfı ve coğrafi pazarda danışmanlık yapabilirler (CRE, 2025b).

CRE doğrudan bağlayıcı teknik değerlendirme standartları yayımlamamakla birlikte, üyeleri için etik kurallar ve en iyi uygulama kılavuzları geliştirmekte ve mesleki standartların yaygınlaştırılmasına katkıda bulunmaktadır. Üyeler, bağımsız ve tarafsız danışmanlık hizmeti sunma taahhüdüyle hareket etmekte ve danışmanlık süreçlerinde USPAP ve uluslararası iyi uygulama ilkeleriyle uyumlu yöntemleri benimsemektedir.

Kuruluş, CRE unvanının verilmesi yoluyla gerçekleştirilen mesleki yeterlilik belgelendirmesi, gayrimenkul sektörüne yönelik araştırma ve yayın faaliyetleri, sektörel raporlar ve en iyi uygulama rehberlerinin hazırlanması, eğitim programları ve uluslararası mesleki ağ oluşturma etkinlikleri oluşturmaktadır (CRE, 2025b). CRE

unvanı, meslektaşlarının davetiyle ve belirli kabul şartlarını (örneğin en az 10 yıl sektör deneyimi) yerine getiren adaylara verilir. Bu unvan, etik, deneyim, uzmanlık ve etki gibi beş temel ölçütte hakem onayıyla kazanılır ve uluslararası alanda prestijli bir yeterlilik belgesi sayılır (CRE, 2025a). Ayrıca CRE, her yıl yayımladığı “Gayrimenkul Etkileyen En Önemli On Sorun” raporu aracılığıyla sektördeki güncel gelişmeler, eğilimler ve zorluklara ilişkin kamuoyu bilgilendirmesi ve politik öneriler geliştirilmesine de katkıda bulunmaktadır.

2.1.12. IFEI - Fransa Değerleme Enstitüsü

1979 yılında kurulan IFEI, Fransa’da gayrimenkul değerleme mesleğini desteklemek, profesyonel standartların geliştirilmesini sağlamak ve sektörde etik ve şeffaf değerleme uygulamalarını teşvik etmek amacıyla faaliyet gösteren önde gelen bir mesleki kuruluştur (IFEI, 2018). Enstitünün temel misyonu, Fransa’da ve Avrupa düzeyinde gayrimenkul değerlemesi alanındaki bilgi ve uygulama standartlarını geliştirmek ve bu standartların uyumlaştırılmasına katkıda bulunmaktır.

IFEI, doğrudan bağlayıcı yasal standartlar yayımlamamakla birlikte, üyeleri için etik ilkeler, mesleki davranış kuralları ve en iyi uygulama kılavuzları geliştirmektedir (IFEI, 2018). Ayrıca, IFEI’nin çalışmaları Fransa’da Gayrimenkul Değerleme Uzmanlık Tüzüğü belgesine dayanmaktadır. Bu belge, Fransa’da gayrimenkul değerlemesine ilişkin profesyonel uygulama ilkelerini ve raporlama standartlarını belirlemekte ve IFEI üyeleri için temel referans kaynağı niteliği taşımaktadır.

Ayrıca IFEI, Avrupa’da TEGoVA çalışmalarına aktif katkı sağlamanın yanı sıra RICS ve IVSC ile iş birliği geliştirerek metodoloji uyumunu destekler (IFEI, 2018). Üyelik başvuruları, mesleki deneyim ve etik kriterlere göre değerlendirilir. Fransa genelinde bölgesel şubeleri bulunan IFEI, her bölgede yerel etkinlikler ve çalışma grupları aracılığıyla doğrudan saha deneyimini paylaşmayı teşvik eder.

Uygulamada IFEI, üyelik sistemi aracılığıyla mesleki yeterliliğin tanınması, sürekli mesleki eğitim programları, sektörel araştırma ve yayın faaliyetleri, mesleki toplantılar ve konferanslar ile uluslararası iş birliği projeleri oluşturmaktadır (IFEI,

2018). Bu faaliyetler sayesinde IFEI, Fransa’da gayrimenkul değerleme pratiğinin profesyonelleşmesine, etik ve kalite standartlarının güçlendirilmesine ve Avrupa genelinde değerleme standartlarının uyumlaştırılmasına katkıda bulunmaktadır.

2.1.13. HypZert – GmbH - Almanya Mortgage Sertifikasyonu Şirketi

HypZert – GmbH, Almanya merkezli, 1996 yılında Almanya Bankalar Birliği girişimiyle kurulmuş bir gayrimenkul değerleme sertifikasyon kuruluşudur (HypZert, 2025). Kuruluşun misyonu, yüksek kaliteli ve bağımsız değerleme hizmetleri sunacak nitelikli değerleme uzmanlarının sertifikalandırılması ve böylece bankacılık ve finans sektöründe güvenilir değerleme uygulamalarının yaygınlaştırılmasıdır. Özellikle Almanya’da teminatlı kredi sistemine dayalı finansman modelinin gereksinimlerini karşılayan değerleme uzmanlarının yetkilendirilmesinde önemli bir rol oynamaktadır.

HypZert doğrudan değerleme standartları yayımlamamakla birlikte, Almanya’da yasal ve düzenleyici çerçevede önemli referans olan Teminat Değerleme Yönetmeliği (BelWertV) esasına dayanan değerleme uygulamalarını desteklemektedir (HypZert, 2025). HypZert sertifikalı uzmanlar, değerleme çalışmalarını yürütürken BelWertV, IVSC ve EVS gibi uluslararası standartlarla uyumlu yöntemleri benimsemektedir.

HypZert ayrıca HypZert S (*Standard Residential*), HypZert F (*Commercial Real Estate*) ve HypZert MLV (*Mortgage Lending Value*) gibi farklı sertifikasyon programları oluşturur (HypZert, 2025). HypZert, sürekli mesleki eğitim faaliyetleri, sektörel yayınlar ve uluslararası iş birlikleri aracılığıyla Almanya’da ve Avrupa’da değerleme mesleğinin profesyonelleşmesine ve yüksek kalite ve güvenilirlik standartlarının yaygınlaşmasına katkıda bulunmaktadır.

2.1.14. BVS - Federal Kamuya Atanan Yeminli Uzmanlar Birliği

BVS, Almanya’da kamusal olarak yetkilendirilmiş, yeminli ve nitelikli uzmanların mesleki temsilini üstlenen en köklü ve kapsamlı meslek birliğidir (BVS, 2025). 1961 yılında kurulmuş olan BVS’nin misyonu, bilirkişilik ve değerleme mesleğinde yüksek kalite standartlarının geliştirilmesi, etik ilkelere dayalı profesyonel

uygulamaların teşvik edilmesi ve kamu yararı doğrultusunda bağımsız ve tarafsız uzman görüşünün güvence altına alınmasıdır.

BVS, üyeleri için mesleki davranış ilkeleri, etik kurallar ve en iyi uygulama rehberleri geliştirmektedir. Ayrıca Almanya’da gayrimenkul değerlendirme, makine ve ekipman değerlendirme, maddi olmayan varlık değerlendirme gibi çok çeşitli alanlarda faaliyet gösteren bilirkişiler için yetkilendirme, eğitim ve kalite güvence süreçlerinde etkin rol oynamaktadır.

Almanya’daki kamu tarafından atanmış ve yeminli bilirkişi unvanı taşıyan uzmanların önemli bir kısmı BVS üyesidir ve bu statü, Almanya’da hukuki ve ticari süreçlerde yüksek güvenilirlik ve tarafsızlık göstergesi olarak kabul edilmektedir (BVS, 2025). BVS üyeleri, değerlendirme ve bilirkişilik faaliyetlerinde Alman Federal Ticaret ve Sanayi Odaları tarafından belirlenen kalite gerekliliklerine uygun hareket etmektedirler.

2.1.15. JAREA - Japon Gayrimenkul Değerlendiricileri Birliği

JAREA, Japonya’da gayrimenkul değerlendirme mesleğini temsil eden en büyük ve en etkili mesleki kuruluşlardan biridir. 1954 yılında kurulmuş olan JAREA, ülke genelinde profesyonel, bağımsız ve tarafsız gayrimenkul değerlendirme hizmetlerinin geliştirilmesi, etik standartların yaygınlaştırılması ve mesleki yeterlilik düzeyinin yükseltilmesi temel misyonudur (JAREA, 2025).

JAREA’nın faaliyetleri Japanese Valuation Standards (JVS) adı verilen standart seti etrafında yapılandırılmıştır. JVS, Japonya’da gayrimenkul değerlendirme süreçlerinde temel başvuru kaynağı niteliğinde olup, değerlendirme raporlarının hazırlanmasında etik kurallar, metodolojik ilkeler, değerlendirme süreçlerinin şeffaflığı ve izlenebilirliği gibi konuları düzenlemektedir (JAREA, 2025). Ayrıca JVS, IVS ile de uyumluluk gözeterek, Japonya’nın uluslararası değerlendirme topluluğu ile bütünleşmesine katkıda bulunmaktadır. Uygulamada JAREA, resmi onaylı gayrimenkul değerlendirme uzmanlarının sertifikasyonu, sürekli mesleki gelişim programları, mesleki etik kuralların denetimi, bilimsel yayınlar ve araştırma faaliyetleri, uluslararası iş birlikleri ve politik danışmanlık çalışmaları oluşturmaktadır

(JAREA, 2025). JAREA, aynı zamanda Japonya’da mahkemelerde, kamu kurumlarında ve finans sektöründe kullanılan değerlendirme raporlarının niteliğini güvence altına alarak gayrimenkul piyasasının şeffaflığını ve etkinliğini desteklemektedir.

2.1.16. API - Avustralya Emlak Enstitüsü

1926 yılında kurulan API, Avustralya’da ve bölgesel olarak Asya-Pasifik bölgesinde gayrimenkul değerlendirme, mülk yönetimi, arazi ekonomisi ve danışmanlık hizmetleri alanlarında faaliyet gösteren en köklü ve en etkili meslek kuruluşlarından biridir (API, 2025a). API’nin değerlendirme uygulamalarında temel referans kaynağı, API Standards belgesidir (API, 2025b). Bu standart seti; değerlendirme süreçlerinin metodolojisi, raporlama standartları, etik ilkeler ve mesleki davranış kurallarını kapsamakta ve IVS ile de uyumlu olarak güncellenmektedir. Bu yapı sayesinde API, Avustralya’da değerlendirme uygulamalarının şeffaflığını, kalitesini ve uluslararası geçerliliğini güvence altına almaktadır.

Uygulamada API, sertifikasyon ve akreditasyon süreçleri (ör. Sertifikalı Uygulayıcı Değerleme Uzmanı - CPV unvanı), sürekli mesleki gelişim programları, etik standartlar ve mesleki denetim mekanizmaları, sektörel araştırma ve yayın faaliyetleri, politik danışmanlık çalışmaları ve uluslararası mesleki iş birlikleri oluşturmaktadır (API, 2025a).

2.1.17. RSA - Rusya Değerleme Uzmanları Derneği

RSA, 1993 yılında kurulmuş olup Rusya Federasyonu’nda değerlendirme mesleğini temsil eden en büyük ve en etkili meslek kuruluşudur (RSA, 2025). Kuruluşun temel hedefleri arasında, değerlendirme sektöründeki profesyonelleri bir araya getirmek, mesleki çıkarları korumak, sektör süreçlerini geliştirmek ve değerlendirme uygulamalarında kalite güvencesini sağlamak yer almaktadır. 2007 yılında kendi kendini düzenleyen dernek statüsü kazanan RSA, bu sayede değerlendirme faaliyetlerine yönelik standart geliştirme, mesleki denetim ve etik uygulama gözetimi gibi işlevleri üstlenmiştir.

RSA'nın faaliyetleri, Rusya'da yürürlükte olan Federal Değerleme Standartları (FSO) temelinde yürütülmektedir. FSO, Rusya Federasyonu yasaları ve düzenleyici kurumları tarafından belirlenen ve ülkede değerlendirme faaliyetlerinin yasal çerçevesini oluşturan bağlayıcı standartlardır (RSA, 2025). Günümüzde RSA, ülke genelinde 6700'den fazla kalifiye değerlendirme uzmanını temsil etmekte olup, 78 bölge ve il şubesi aracılığıyla ulusal düzeyde örgütlenmiştir (RSA, 2025). RSA; sertifikasyon sistemleri, sürekli mesleki eğitim ve metodolojik destek, bağımsız değerlendirme raporu inceleme mekanizmaları, sektör için standart ve kural geliştirme çalışmaları, mesleki çıkarların temsili ve korunması, bilimsel yayın faaliyetleri oluşturmaktadır (RSA, 2024). Ayrıca RSA; IVSC, IAAO, IACVA, TEGoVA, FIABCI, ve RICS gibi uluslararası kuruluşlarla iş birliği içerisinde faaliyet göstermekte ve üyelerinin küresel değerlendirme topluluğuna entegrasyonunu desteklemektedir.

2.1.18. CAS - Çin Değerleme Topluluğu

1993 yılında kurulan CAS, Çin'de değerlendirme mesleğini temsil eden en yetkili ve en geniş kapsamlı mesleki organizasyonlardan biri olarak faaliyet göstermektedir (CAS, 2025). Kuruluşun; değerlendirme mesleğinin gelişimini desteklemek, profesyonel ve etik standartların oluşturulmasını sağlamak, meslek üyelerinin mesleki yeterliliklerini artırmak ve uluslararası değerlendirme standartları ile uyumlu uygulamaların yaygınlaştırılması temel misyonudur.

CAS, Çin'de değerlendirme uygulamalarının temel çerçevesini belirleyen Çin Değerleme Standartları (CVS) belgesinin hazırlanması ve güncellenmesinden sorumludur (CAS, 2025). CVS, Çin Maliye Bakanlığı onayı ile yürürlüğe girmiş olup, değerlendirme süreçlerinde etik kurallar, metodolojik ilkeler, raporlama standartları ve profesyonel davranış kurallarını kapsamaktadır (CAS, 2025). Ayrıca, CVS ile IVS arasında uyum sağlanması amacıyla sürekli güncelleme ve geliştirme çalışmaları yürütülmektedir. CAS ayrıca, IVSC, TEGoVA, IAAO ve diğer uluslararası kuruluşlarla iş birliği içerisinde çalışarak, Çin değerlendirme mesleğinin küresel standartlarla bütünleşmesine ve uluslararası alanda rekabet edebilirliğinin artırılmasına katkıda bulunmaktadır.

2.1.19. KAPA - Kore Mülkiyet Değerlendiricileri Derneği

KAPA, Güney Kore’de gayrimenkul değerlendirme mesleğini temsil eden en yetkili ve en kapsamlı mesleki kuruluş konumundadır (KAPA, 2025). 1961 yılında kurulan KAPA, gayrimenkul değerlendirme hizmetlerinde profesyonel standartların geliştirilmesi, meslek üyelerinin mesleki yeterliliklerinin ve etik davranış düzeylerinin yükseltilmesi ve kamu yararına şeffaf ve güvenilir değerlendirme uygulamalarının teşvik edilmesidir.

KAPA, Güney Kore’de yürürlükte olan Kore Gayrimenkul Değerleme Standartları (KREAS) belgesinin hazırlanması ve güncellenmesinde aktif rol oynamaktadır (KAPA, 2025). KREAS, değerlendirme süreçlerinde kullanılan temel standartları belirlemekte olup, etik ilkeler, metodolojik esaslar, raporlama standartları ve profesyonel uygulama ilkelerini kapsamaktadır. Ayrıca, KREAS ile IVS arasında uyum sağlanması ve küresel değerlendirme pratiğiyle entegrasyonun güçlendirilmesi de KAPA’nın öncelikli hedefleri arasında yer almaktadır.

Uygulamada KAPA; sertifikalı değerlendirme uzmanlarının yetkilendirilmesi ve mesleki lisanslama süreçleri, sürekli mesleki gelişim ve eğitim programları, etik kuralların uygulanması ve mesleki davranışın denetlenmesi, sektörel araştırma ve yayın çalışmaları, değerlendirme raporlarının kalite güvence süreçleri, ve uluslararası iş birliği ve bilgi paylaşımı faaliyetleri oluşturmaktadır (KAPA, 2025).

2.1.20. TDUB - Türkiye Değerleme Uzmanları Birliği

TDUB, 2007 yılında kurulmuş olup, Türkiye’de gayrimenkul değerlendirme mesleğini düzenleyen ve temsil eden en yetkili meslek kuruluşudur (TDUB, 2025d). 6362 sayılı Sermaye Piyasası Kanunu ve ilgili düzenlemeler çerçevesinde faaliyet gösteren TDUB’un temel misyonu; gayrimenkul değerlendirme mesleğinin gelişimini desteklemek, meslek üyelerinin mesleki yeterlilik ve etik düzeylerini yükseltmek, kamu yararına şeffaf, güvenilir ve kaliteli değerlendirme hizmetlerinin sunulmasına katkıda bulunmak ve Türkiye’de değerlendirme sektörünün kurumsallaşmasını güçlendirmektir (TDUB, 2025d).

TDUB iç işleyişi, Üyelik, Yönetim Kurulu, Denetim ve Disiplin gibi temel organların yanı sıra Mesleki Eğitim, Etik Sözleşme, Değerleme Standartları, Bilirkişilik, Uluslararası İlişkiler ve Dijitalleşme gibi çok sayıda komite ile yapılandırılmıştır (TDUB, 2025e). Bu komiteler aracılığıyla birlik; UDS (Türkiye Değerleme Standartları) uyumlu uygulamaları denetlemekte, SPK mevzuatına uygunluğu gözetmekte, kalite güvence işlevleri yürütmekte, üyelere yönelik eğitim ve sürekli geliştirme programları sunmakta ve mesleki etiği gözetim altında tutmaktadır.

TDUB, ayrıca kamu kurumu niteliğindeki bir bildirim ve danışmanlık merci olarak, SPK, BDDK, Dünya Bankası ve Tapu ve Kadastro Genel Müdürlüğü gibi kurumlarla aktif iş birliği halinde çalışmalar yürütmektedir (TDUB, 2025g).

2.2. Yurtdışı Örnekleri

Gayrimenkul vergilendirmesinde kullanılan toplu değerlendirme sistemleri, ülkeler arası farklılık göstermekle birlikte küresel ölçekte giderek yaygınlaşmaktadır. Özellikle 2000'li yıllardan itibaren dijitalleşme ve veri teknolojilerindeki ilerlemeler sayesinde birçok ülke, pazar değerine dayalı vergi matrahlarının hesaplanmasında bilgisayar destekli toplu değerlendirme (CAMA) ve CBS entegre eden uygulamalara yönelmiştir (Braesemann & Baum, 2020b; IAAO, 2018)

Gelişmiş ekonomilerde piyasa değerine dayalı toplu değerlendirme uygulamaları standarda dönüşmüştür. Hollanda, İngiltere, Yeni Zelanda ve Avustralya gibi ülkelerde belediye ölçeğinde yürütülen değerlendirme süreçleri, gelişmiş yazılımlar, geniş veri tabanları ve şeffaf denetim mekanizmalarıyla desteklenmektedir (Almy, 2014). Bu sistemlerde tapu kayıtları, satış fiyatları, yapı özellikleri ve konum verileri entegre edilerek, emlak vergilerinin gerçek piyasa koşullarına uygun biçimde hesaplanması sağlanmaktadır.

Avrupa ve Kuzey Amerika'daki uygulamalar, güçlü yasal çerçeve ve kurumsal kapasiteye dayanmaktadır. Buna karşılık, Afrika, Orta Asya ve bazı Asya-Pasifik ülkelerinde sistemler ya henüz pilot düzeyde kalmış ya da değerlendirme halen geleneksel, alan bazlı yöntemlerle yürütülmektedir (OECD, 2022; J. Yang, 2024b). Örneğin, Polonya ve Slovakya gibi bazı Orta Avrupa ülkelerinde piyasa değerine dayalı

sistemler benimsenmemiş, bina vergileri uzun süre yalnızca metrekare esaslı hesaplanmıştır. Benzer şekilde Afrika'da, Güney Afrika ve Kenya gibi ülkeler metropol bölgelerde modern sistemler uygulasa da kırsal alanlarda manuel yöntemler yaygındır.

Toplu değerlendirme sistemlerinin başarısı, dört temel faktöre dayanmaktadır: güncel ve güvenilir veri altyapısı, yasal zorunluluk ve kurumsal koordinasyon, teknik kapasite ve uzman personel, vatandaş nezdinde şeffaflık ve itiraz mekanizmaları (IAAO, 2018). Bu unsurların bir arada bulunduğu ülkelerde sistemler hem sürdürülebilir hem de adil bir yapı kazanmıştır. Hollanda'daki Taşınmaz Malların Değerlemesi Kanunu (WOZ - *Wet Waardering Onroerende Zaken*), sistemi buna iyi bir örnek olup hem otomatik değerlendirme hem de mükellef erişimi ve şeffaflık açısından örnek niteliğindedir (Zaken, 2016).

Değerleme sistemlerinin başarısını belirleyen bir diğer unsur da şeffaflıktır. İngiltere, İrlanda ve Hollanda gibi ülkelerde değerlendirme raporları kamuya açık olarak paylaşılmakta ve mükelleflerin benzer mülklerle kıyaslama yapmasına olanak tanınmaktadır. Buna karşın Fransa ve Almanya gibi ülkelerde vergi mahremiyeti nedeniyle değerlendirme bilgilerine erişim sınırlıdır (Rowland, 2024). Ayrıca, sistemin etkinliğini sürdürebilmesi için değerlendirme sonuçlarının düzenli güncellenmesi önemlidir. IAAO (2018) verilerine göre bu sürenin 4–6 yıl aralığında olması önerilmekle birlikte, bazı ülkelerde bu süre 10 yıl ve daha fazlasına uzamaktadır.

Uluslararası uygulamalar, Türkiye'de kurulması planlanan toplu değerlendirme sistemine ışık tutacak birçok unsur sunmaktadır. Özellikle Hollanda'daki merkezi denetimli yerel uygulama modeli, İngiltere'deki değerlendirme şeffaflığı ve Avustralya'daki teknik kapasite kullanımı örnek alınabilir. Buna karşın, veri erişimi, kurumlar arası entegrasyon ve kırsal alanlardaki uygulama zorlukları açısından, Afrika ve Orta Asya ülkelerinin karşılaştığı yapısal sorunlar Türkiye'nin bazı bölgeleriyle benzerlik göstermektedir. Bu nedenle, teknolojiye yatırım kadar idari kapasitenin artırılması ve yasal reformlar da önem taşımaktadır.

Yurtdışı örneklerini ele aldığımız bu bölümde, farklı coğrafi bölgelerdeki uygulamaları karşılaştırmalı olarak incelemek amacıyla Tablo 1'de ülkeler, Kuzey

Amerika, Güney Amerika, Avrupa, Afrika, Orta Doğu, Orta Asya, Asya Pasifik olmak üzere yedi ana bölgeye ayrılmıştır. Sınıflandırmada Birleşmiş Milletler Coğrafi Bölge Tanımlamaları temel alınmıştır. Her bir bölgeye ilişkin analizde, söz konusu bölgede benimsenen toplu değerlendirme yaklaşımları, sorumlu kurumlar, veri yönetimi modelleri ve düzenleyici çerçeveler değerlendirilecektir. Kuzey Amerika'dan Asya-Pasifik'e kadar uzanan bu coğrafi sınıflandırma, farklı ekonomik, kültürel ve yasal koşulların nasıl çeşitlilik yarattığını ortaya koymayı hedefler. Ayrıca, her bir bölgeye özgü uygulama pratikleri karşılaştırılarak hem ortak eğilimler hem de bölgesel farklılıklar aydınlatılacaktır. Bu sayede dünya genelindeki değerlendirme sistemlerinin bütüncül bir bakış açısıyla kavranması mümkün olacaktır.

Tablo 1. Diğer Ülkelerde Uygulanan Toplu Değerleme Yöntemleri, Sorumlu Kurumlar ve Yasal Dayanakları.

Ülke	Kurum	Yöntem	Yasal Dayanak
ABD	Eyalet düzeyindeki Assessor's Office'ler.	1.Çoklu Regresyon Analizi (MRA-Multiple Regression Analysis) 2.Mevcut Değerleme Endekslenmesi (Indexation) 3.Uyarlanabilir Tahmin İşlemi (AEP-Adaptive Estimation Procedure,) 4.Karşılaştırmalı Satış Analizi (CSA-Comparable Sale Analysis-) 5.Yapay Sinir Ağları (ANN-Artificial Neural Network) 6.Maliyet Yaklaşımı (CA-Cost Approach) 7.Eş-Değerli Gruplama (Benchmarking)	Her eyaletin kendi yasama sürecinde Emlak Vergisi yasaları prosedürlerini belirler. Standartlaştırma ve metodolojik rehberlik ise IAAO tarafından sağlanır.
Kanada	Ontario: Belediye Mülk Değerleme Kurumu British Columbia: BC Değerleme Otoritesi Alberta: Alberta Belediye İşleri – Değerleme Yönetim Ekibi Kanada Eyalet Vergi İdaresi	1.CA 2.Gelir Yaklaşımı (IA-Income Approach) 3.MRA 4.Hedonik Regresyon	Ontario'da Assessment Act (1990) Municipal Act (2001) BC'de Assessment Act (1974) Alberta'da Municipal Government Act ve Assessment Review Boards Act (2018) yasaları çerçevesinde faaliyet gösterir.

Meksika	Belediyelerde Kadastro Dairesi büroları, mülk kayıt ve değerlendirme işlemlerini yönetir. Ulusal Varlıkların Yönetimi ve Değerlendirilmesi Enstitüsü (INDAABIN), federal hükümete ait gayrimenkullerin değerlemesini yapar.	1.Birim Değer Çizelgeleri (Cartas de Valores Unitarios) 2.Otomatik Toplu Değerleme (VMA-Valuación Masiva Automatizada) 3.CBS Tabanlı VMA. Bazı büyük belediyeler GIS, yapay zekâ ve büyük veri analizini birleştirerek kütle değerlendirme modelleri geliştirmiştir.	“Ley de Coordinación Fiscal” ve “Ley General de Bienes Nacionales” INDAABIN’e yetki verir. Mülk vergisi ve kadastral süreçler düzenlenir. Her bir eyaletin veya belediyenin kendi kadastral kanunları vardır; bunlar, mülk değerlendirme kriterlerini ve güncelleme sıklığını belirler.
Brezilya	Her belediyenin Kadastro Sicil Dairesi (Departamento de Cadastro Imobiliário) sorumludur.	1.Parametrik birim-değer tabloları 2.Eyalet düzeyinde (São Paulo ve Rio de Janeiro) Hedonik Regresyon Modelleri + CBS	National Tax Code (1966) Belediyelerin kendi Belediye Vergi Kanunu (Código Tributário Municipal) düzenlemeleri mevcuttur.
Kolombiya	Ulusal Vergi ve Gümrük Müdürlüğü (Dirección de Impuestos y Aduanas Nacionales) Vergi Dairesi (Oficina de Impuestos)	1.Hedonik Regresyon MRA + CBS 2.CA 3.IA	Her belediye kendi Kadastro Yönetmeliğini (Ordenanza de Catastro) çıkarır.
Arjantin	Buenos Aires Eyaleti: Gelirler Genel Müdürlüğü (Dirección General de Rentas) Cordoba, Santa Fe ve Mendoza gibi diğer büyük eyaletlerde İl Kadastro (Catastro Provincial) birimleri ve belediyelerin Kadastro Ofisleri	1.Hedonik regresyon ve GWR 2.Küçük belediyelerde Parametrik Yaklaşımlar	Arjantin’de her eyalet, kendi İl Vergi Kanununa (Código Fiscal Provincial) dayanarak toplu değerlendirme programı oluşturur.
Şili	Şili Gelir İdaresi (Servicio de Impuestos Internos)	1.Hedonik Regresyon 2.CA	Ley de Impuesto Territorial, (1970)

Uruguay	Ulusal Kadastro Müdürlüğü (Dirección Nacional de Catastro), merkezi bir kadastral kurum olarak tüm ülke mülklerinin değerlendirilme sürecine veri sağlar.	1.Hedonik Regresyon	Impuesto a las Contribuciones Inmobiliarias, (1989) ve Decreto, (2015) mevzuatı düzenlenmiştir.
Hollanda	Belediyeler (Gemeenten) Değerleme Kurulu (Waarderingkamer)	1.MRA 2.Benzer Mülklerin Kümelenmesine (Clustering) Dayalı Modeller	Hollanda’da toplu değerlendirilme, Wet Waardering Onroerende Zaken- WOZ, Act for Real Estate Assessment (1994) ile sağlanır.
Almanya	Almanya Eyalet vergi dairesi (Germany State Tax Authority) Belediyeler (Değerleme Komisyonları)	1.En küçük kareler yöntemi ile regresyon analizi 2.Parametrik / CA 3.IA	Property Tax Reform Act, (2022)
Birleşik Krallık	Değerleme Ofisi Ajansı (VOA - Valuation Office Agency) (İngiltere) İskoç Değerlendiriciler Derneği (Scottish Assessors Association) (İskoçya)	1.CAMA Hedonik regresyon, komşuluk tipi basitleştirilmiş değerlendirilme yaklaşımı 2.CA 3.IA	Lands Valuation Acts (Scotland) Değerlemeciler, başta Royal Institution of Chartered Surveyors (RICS) olmak üzere Değerleme Standartları Konseyi (IVSC) ve meslekî kuruluşların “Red Book” kurallarına uymayı kabul eder.
Polonya	Genel Harita Müdürlüğü (Główny Geodeta Kraju) Kadastro Dairesi ve Belediye Meclisleri	1.Parametrik birim-değer tabloları 2.Polonya’da hâlihazırda devlet destekli, piyasa değerine dayalı bir toplu değerlendirilme sistemi yoktur.	Arazi Yönetimi Kanunu (1977) Gayrimenkul Kitle Değerlemesi Hakkında Bakanlar Kurulu Kararı (Rozporządzenie Rady Ministrów, 2005)
Slovakya	Maliye Bakanlığı (Department of the Exchequer)	1.CA 2.IA	382/2004 sayılı Kanun ve 492/2004 sayılı Bakanlık Kararnameleri

İsveç	Ulusal Vergi Kurulu (Skatteverket) Bölgesel Vergi Daireleri (Regional Tax Authorities) Ulusal Arazi Araştırması (The National Land Survey)	1.Hedonik regresyon MRA + GWR	Gayrimenkul değerlendirme kanunu ve ilgili yönetmelik (Real property assessment act and the corresponding ordinance)
Finlandiya	Belediyeler (Kunnat) Finlandiya Vergi İdaresi (Verohallinto) İstatistik Merkezi (Tilastokeskus) Finlandiya Ulusal Kadastro Genel Müdürlüğü (National Land Survey of Finland) Finlandiya Teknik Araştırma Merkezi Finans Bakanlığı (Ministry of Finance)	1.Satış Karşılaştırma (SC-Sales Comparison) 2.CA 3.Vergi değerlendirme değeri (veroarvio) CAMA yazılımı ve CBS entegrasyonu kullanılarak otomatikleştirilmiştir.	Kiinteistöveroaki (Property Tax Act, 654/1992) Kamulaştırma Kanunu (Expropriation Act) Değerleme Yönergeleri (Valuation Guidelines) Mülkiyet Kayıt Düzenlemeleri (Cadastral and Title Registration Acts)
İspanya	Kadastro Genel Müdürlüğü (Dirección General del Catastro) Belediyelerde (municipios)	1.Parametrik Kadastral Model 2.GIS Tabanlı Entegrasyon 3.MRA + ANN	The Local Property Act Ley 39/1988 ve Ley 13/2015 çerçevesinde tüm taşınmazlara “cadastral value (valor catastral)” atar.
İtalya	İtalya Gelir İdaresi, Kadastral Ofisi (Agenzia delle Entrate – Ufficio del Catasto e della Cartografia) Belediyeler (Comuni)	1.Parametrik 2.IA 3.CA	Her parsel, Legge n. 23/1985 ve Decreto Legislativo n. 23/2011 ile belirlenen kriterlere göre değerlendirilir.
Danimarka	Belediyeler (Kommuner) Danimarka Vergi İdaresi (Danish Customs and Tax Administration)	1.Hedonik Regresyon MRA 2.Parametrik Düzenlemeler	“On Public Valuation of Real Property” (2017)

Estonya	Arazi ve Mekansal Kalkınma Kurulu (Land and Spatial Development Board) Ulusal Vergi ve Gümrük Kurulu (National Tax and Customs Board) Yerel Yönetimler (Municipalities)	1.Hedonik Regresyon MRA 2.Parametrik Düzenlemeler 3.Arazi bazlı toplu değerlendirme	Arazi Değerleme Kanunu (Land Valuation Act, 1994) Arazi Vergilendirme Kanunu (Land Taxation Act, 1993) Land Valuation Act, (2022) EVS 875 Estonya Değerleme Standartları, IVS ve RICS uygundur.
Moldova	Arazi İlişkileri ve Kadastro Kurumu (Agency for Land Relations and Cadastre) Başmaliye Denetleme Kurumu (Main State Fiscal Inspectorate) Taşra Vergi Daireleri ve Yerel Yönetimler	1.Hibrid Model (MRA+CBS) (değer bölgesi haritaları) (2004) 2.SC 3.CA 4.IA	Vergi Kanunu (Tax Code) 279(4) Arazi İlişkileri ve Kadastro Kurumu Lisanslama Düzenlemeleri
Finlandiya	Ulusal Arazi Araştırmaları Kurumu (National Land Survey of Finland) Ulusal Vergilendirme Kurulu (National Board of Taxation) Finlandiya Teknik Araştırma Merkezi (Technical Research Centre of Finland) Belediyeler (Municipalities)	1.Arsa için fiyat karşılaştırma metodu (NLS'nin Resmi Piyasa Fiyatı Kayıt Sistemi'nden elde edilen çok değişkenli modellerle) 2.IA	Emlak Vergisi Kanunu, (1992) Uluslararası Değerleme Standartlarına ve RICS Değerleme Standartlarına uygun olarak yürütmektedirler.
Fransa	Kamu Maliyesi Genel Müdürlüğü (Direction Générale des Finances Publiques) Arazi Değeri Talebi (Demande de Valeur Foncière)	1.Hedonik Regresyon. 2.Parametrik ve İdari Model	Code Général des Impôts (CGI; Vergi Kanunları Kodu) ve Cadastre Law (1810'dan beri kademeli olarak güncellenen mevzuat)

Letonya	Letonya Cumhuriyeti Devlet Arazi Servisi (The State Land Service of the Republic of Latvia) Devlet Arazi Hizmetinin Gayrimenkul Değerleme Kurulu (Real Estate Valuation Board of the State Land Service)	1.- Kadastral Toplu Değerleme (Mass Appraisal) 2.- İstatistiksel modelleme + CBS tabanlı yaklaşımlar 3.- Farklı kullanım türlerine göre ayırım ("Fiskal" vergi ve harçlarda, "universal" değer ise ticari/raporlama amaçlarında kullanılıyor).	Gayrimenkul Vergisi Kanunu (Nekustamā īpašuma nodokļa likums) Devlet Gayrimenkul Kadastrası Kanunu (Nekustamā īpašuma valsts kadastra likums)
Slovenya	Maliye Bakanlığı (Ministry of Finance) Vergi İdaresi	1.Toplu Değerleme 2.Regresyon analizleri + CBS tabanlı modeller	Real Property Mass Valuation Act Real Estate Recording Act İkincil düzenlemeler ve kararname düzeyindeki teknik uygulama talimatları
Litvanya	Kamu İhtiyaçları Değerleme Dairesi Başkanlığı Devlet Tapu Kadastro ve Sicili (State Land Cadastre and Register) Gayrimenkul Değerleme Konseyi (Council of Real Estate Assessment) Devlet Kurumu Kayıt Merkezi (Registru Centras) Devlet Vergi Müfettişliği (State Tax Inspectorate, STI)	1.SC 2.CA 3.Devlet destekli toplu değerlendirme sistemi uzun yıllardır aktif biçimde çalışmaktadır.	Taşınmaz Kadastro Kanunu (2000) Değerleme Faaliyetleri Kanunu (2002) Arazi ve Bina Vergisi Kanunları (1992, 1995, 2002, 2013) Ulusal Değerleme Standartları (EVS 875)
Rusya	Federal Değerleme Servisi (Federal Service for State Registration) Kadastro ve Kartografya Değerleme Şube Müdürlüğü (Cadastre and Cartography Valuation Branch Office)	1.Hedonik regresyon MRA 2.SC 3.CA 4.IA	"On Valuation Activity in the Russian Federation" (1998)

Güney Afrika	Belediye Değerleme Ofisi (Municipal Valuer's Office)	Hedonik regresyon MRA	Municipal Property Rates Act, 6 of 2004 (MPRA)
Kenya	Nairobi için İlçe Değerleme Dairesi (Nairobi City County Valuation Department)	CAMA / AVM / CBS Entegrasyonlu (Nairobi, Kisumu)	Valuers Act, Cap 532, Laws of Kenya ve Land Rates Act, Cap 267 kapsamında, ilçe (county) yönetimleri her yıl CAMA tabanlı "valuation roll" hazırlar.
Tanzanya	Belediyeler ve yerel ofisleri	1.Hedonik Regresyon Modelleri 2.Parametrik / Unit-Value Yaklaşımlar	Urban Authorities (Rating) Act, No. 2 of 1983 ve Valuation for Rating Purposes Regulations, 2000
Uganda	Kampala Başkent Şehir Otoritesi (Kampala Capital City Authority) ve diğer büyük şehir belediyeleri (Entebbe, Jinja) Gelir Tahsilatı Müdürlüğü (Directorate of Revenue Collection)	1.Hedonik Regresyon 2.Parametrik Tablolar	Property Rates Act, 2005 ve Valuers Registration Act
Etiyopya	Addis Ababa Şehir İdaresi Addis Ababa Arazi Geliştirme ve Yönetim Ajansı	1.Hedonik Regresyon 2.Parametrik / Birim Değer Yaklaşımları	Addis Ababa Disclaimer Directive, No. 5/2002 (Mahallî Yönetim: Değerleme ve Vergilendirme Yönetmeliği)
Ruanda	Kigali Şehir Meclisi Kigali Şehir Meclisi Değerleme Departmanı	Hedonik Regresyon	Law No. 05/2018 of 13/04/2018 on Land Tenure and the Ministerial Order No. 001/11.01 of 01/03/2018 ("Valuation and Compensation Guidelines")
Gana	Belediye ve İlçe Meclisleri Gana Gelir İdaresi	Hedonik Regresyon (MRA)	Local Governance Act, 2016 (Act 936) ve Valuation and Rating Act, Cap 327 kapsamında

Japonya	Her belediyenin Vergi Dairesi	1.Hedonik Regresyon 2.Maliyet Yaklaşımı	Değerlemeler, İşçileri ve İletişim Bakanlığı tarafından yayımlanan “Fixed Asset Valuation Standards” (FAVS) esas alınarak yapılır
Güney Kore	Arazi, Altyapı ve Ulaştırma Bakanlığı (Ministry of Land, Infrastructure and Transport)	Hedonik regresyon modelleri	Standard Land Price System (1989) ve House Price Public Announcement System (2005) gibi düzenlemelerle “Standard Market Price” ve “Standard Land Price” (MOLIT belirler)
Singapur	Singapur Değerleme Kurumu (Inland Revenue Authority of Singapore)	1.Mevcut Değerleme Endekslenmesi (Indexation) 2.Değer Tabanlı Değerleme (MRA + Annual Value (AV))	“Property Tax Act”
Çin	Devlet Vergi İdaresi (State Administration of Taxation) Doğal Kaynaklar Bakanlığı (Ministry of Natural Resources) Maliye Bakanlığı (Ministry of Finance) Yerel Tapu Büroları (Shenzhen Gayrimenkul Değerleme ve Geliştirme Merkezi)	1.Hedonik Regresyon (MRA) 2.CA 3.IA 4.Pilot Programlar (Shanghai, Chongqing, Hangzhou, Dandong vb.)	Law on Valuation Activity in the PRC, (1998) Real Estate Tax Law (Pilot), (2011) IAAO Standartları
Tayvan	Maliye Bakanlığı ve İşçileri Bakanlığı, Kadastro, Yerel düzeyde (İl/Belediye Vergi Daireleri)	Hedonik regresyon modeli	2019’dan itibaren IVS çerçevesi uygulamaktadır.

Hong Kong	Derecelendirme ve Değerleme Kurumu (Rating and Valuation Department)	1.Mevcut Değerleme Endekslenmesi (Indexation) 2.MRA + CBS 3.Parametrik yaklaşımlar	Rating Ordinance (Cap. 116) ve Government Rent (Assessment and Collection) Ordinance (Cap. 515) uyarınca.
Malezya	Gayrimenkul Değerleme Birimi (Valuation and Property Services) Değerleme Enstitüsü (National Institute of Valuation) Gayrimenkul Bilgi Merkezi (National Property Information Center)	1.MRA + CBS 2.Değerleme Bilgi Sistemi mevcuttur.	Local Government Act ve Valuation and Assessment Act (1921) uyarınca Director General of Valuation and Property Services (Pejabat Penilaian Negara) teknik rehberlik yapar; Standard Operating Procedures (SOP) çerçevesinde belediyeler değerlendirme faaliyetlerini yürütür.
Avustralya	Her eyaletteki Valuer-General's Office (NSW, VIC, QLD, WA vb.)	1.Hedonik Regresyon MRA 2.CA	Valuations of Land Act (Eyalet Bazlı Yasalar: SW Valuation of Land Act (1916); VIC Valuation of Land Act (1960); QLD Valuation of Land Act (1944))
Yeni Zelanda	Yeni Zelanda Değerleme Bürosu (Valuer-General's Office of New Zealand)	1.Hedonik Regresyon MRA + GWR 2.Stratifikasyon ve Benchmarking	Government Valuation of Land Act (1896) Rating Valuations Act (1998) Valuers Act (1948) ile her yerel otoritenin (Territorial Authority – TA) “Rating Valuation Roll” oluşturma yükümlülüğü tanımlanmıştır.

Hindistan	Eyalet Gelir İdaresi Başkanlığı Büyükşehir Belediye Değerleme Daireleri	1.Eyalet bazlı birim-değer tabloları 2.Mumbai, Bengaluru, Delhi’de hedonik regresyon ve GWR temelli AVM denemeleri mevcuttur.	State Stamp Duty & Registration Acts (Eyalet Bazlı)
Pakistan	Belediye Değerleme Daireleri Gelir Kurulu	1.Eyalet bazlı birim-değer tabloları 2.Belediye Düzeyinde Kısıtlı CAMA/AVM Deneyleri: Karachi (Karachi Metropolitan Corporation), Lahore (Lahore Development Authority)	“Land Revenue Act” (2019)
Kazakistan	Maliye Bakanlığı, Belediye Değerleme Ofisleri (Ministry of Finance, State Revenue Committee)	1.Hedonik regresyon + İstatistiksel modeller 2.Parametrik / benchmark tabloları	“Law on Valuation Activities” (2018)
Özbekistan	Ekonomi ve Maliye Bakanlığı (Ministry of Economy and Finance) Kadastro Ajansı (Cadastre Agency), Ulusal Toplu Değerleme Merkezi (State Tax Committee (National Center for Mass Assessment of Real Estate)	1.CAMA (hedonik regresyon + birim-değer tabloları) 2.Pilot deneyler (Tashkent)	“Law on Valuation Activities” (1999), NSOI No. 12 (2012)
Kırgızistan	Ekonomi Bakanlığı (Ministry of Economy) Yerel Vergi Daireleri (Local Tax Authorities)	1.Hedonik Regresyon 2.Parametrik Yaklaşım 3.Kadastro Tabanlı Toplu Değerleme	Tax Code (2021), “Law on Estimative Activities” (2021)

	Gayrimenkul Değerleme Dairesi (Department of Property Valuation) Maliye Bakanlığı (Ministry of Finance)		
Tacikistan	Ulusal Gayrimenkul Değerleme Merkezi (National Property Valuation Center)	1.Hedonik Regresyon 2.Parametrik Yaklaşım	Property Tax Act (2013), Taxation Law (2013)
	Değerleme Şube Ofisi (Valuation Branch Offices)		
Birleşik Arap Emirlikleri	Dubai Tapu Dairesi- Gayrimenkul Değerleme Departmanı Abu Dabi Belediyeler ve Ulaştırma Dairesi- Değerleme Birimi Tapu Sicil Toplu Değerleme Servisi- Ras Al Khaimah Belediyesi	1.Hedonik regresyon + CBS 2.Eş-Değerli Gruplama 3.CA 4.IA	Real Estate Regulatory Authority Law, (2015) DLD (Dubai Land Department) ve RERA (Real Estate Regulatory Authority) (Valuation Guidelines) kılavuzları
İsrail	Adalet Bakanlığı'na bağlı, lisanslama ve standart geliştirme birimi (Council of Land Valuers) Belediye Değerleme Daireleri (Tel Aviv, Kudüs) Kamu arazileri kayıt ve izleme (Israel Land Administration)	1.Hedonik regresyon + GWR 2.Parametrik düzeltme (coğrafi katsayılar ve demografik göstergelerle düzeltme)	Valuation Act, (2001) Basic Law: Israel Lands (1960)

Suudi Arabistan	Suudi Akredite Değerleme Kurumu (Saudi Authority for Accredited Valuers)		
	Suudi Merkez Bankası (Saudi Central Bank)	1.AVM tabanlı hedonik regresyon + CBS 2.CA	SAMA Supplementary Circular ve Suudi Akredite Değerleme Kurumu Yönergeleri (2019)
	İmar ve Emlak Bakanlığı Düzenleme Kurumu (Ministry of Housing & Real Estate Regulatory Authority)		
Türkiye	Tapu ve Kadastro Genel Müdürlüğü (TKGM)	1.SC 2.CA	Vergi Usul Kanunu (VUK) Belediye Gelirleri Kanunu
	Gelir İdaresi Başkanlığı (GİB)	3.IA	TKMP (Tapu ve Kadastro Modernizasyon Projesi) kapsamındaki uygulama raporları ve teknik belgeler
	Türkiye Değerleme Uzmanları Birliği (TDUB)	4.Pilot uygulamalarda mekânsal analiz + AVM tabanlı yöntemler test edilmektedir	Bölüm 3'te detaylı olarak ele alınmıştır.
Gösterim:  Kuzey Amerika,  Güney Amerika,  Avrupa,  Afrika,  Asya-Pasifik,  Orta Asya,  Orta Doğu.			

BÖLÜM 3

ULUSAL ÇALIŞMALAR

Türkiye’de gayrimenkul değerlendirme çalışmaları, köklü bir tarihsel arka plana sahip olmakla birlikte, özellikle son yirmi yılda kurumsallaşma, standardizasyon ve dijitalleşme süreçleri açısından önemli dönüşümler geçirmiştir. Gayrimenkul değerlemesi, ekonomik karar alma, kentsel gelişim politikalarının yönlendirilmesi, yatırım değerlendirmesi, kamu gelirlerinin artırılması ve vergi adaletinin sağlanması açısından stratejik bir alan olarak değerlendirilmektedir.

Türkiye’de bu alanın gelişimi, başlangıçta daha çok kamulaştırma süreçleri, emlak vergisi matrahı belirleme ve kamusal alım-satım işlemleri gibi özel amaçlı değerlendirme uygulamaları üzerinden yürütülmüştür. SPK’nın 2001 yılında yayımladığı düzenlemelerle birlikte kurumsal değerlendirme şirketleri ve lisanslı değerlendirme uzmanları sistemine geçilmiş ve değerlendirme sektörü profesyonel bir niteliğe kavuşmuştur. Bunu takiben BDDK tarafından getirilen düzenlemelerle değerlendirme faaliyetleri bankacılık ve finans sektöründe de standart bir yapıya kavuşturulmuştur.

Ulusal düzeyde yasal ve kurumsal çerçeve, gayrimenkul değerlemesinin güvenilir, şeffaf ve karşılaştırılabilir biçimde yürütülmesi için kritik önemdedir. Ancak Türkiye’de mevcut sistem halen farklı kurum ve mevzuat yapılarının etkisi altında çok sayıda farklı değer tanımı ve değerlendirme yöntemi barındırmaktadır. Pazar değeri, rayiç bedel, vergi değeri, kamulaştırma değeri, gerçeğe uygun değer gibi farklı tanımlar, ayrı ayrı yasa ve yönetmeliklerde yer almakta ve bu durum bütüncül ve tutarlı bir değerlendirme sisteminin oluşumunu zorlaştırmaktadır.

Öte yandan, Tapu ve Kadastro Modernizasyon Projesi (TKMP) kapsamında yürütülen Pilot Çalışmalar (Fatih, Mamak, Amasya vb.) ve Gayrimenkul Bilgi Merkezi girişimleri sayesinde son yıllarda toplu değerlendirme uygulamalarına yönelik önemli deneyimler kazanılmıştır. Bu deneyimler, uluslararası en iyi uygulamalara yaklaşma açısından Türkiye’ye önemli fırsatlar sunmaktadır.

Bu bölümde, Türkiye’de gayrimenkul değerlemesinin yasal altyapısı, ilgili kurum ve kuruluşların rolleri, mevcut toplu değerlendirme girişimleri ve sistemin geliştirilmesine yönelik çalışmalar detaylı biçimde ele alınacaktır.

3.1. Gayrimenkul Değerine İlişkin Yasal Uygulamalar

Türkiye’de gayrimenkul değerlendirme faaliyetleri, farklı amaçlara ve farklı kamu politikalarına hizmet eden çok sayıda yasal düzenlemenin etkisi altında yürütülmektedir. Bu durum, gayrimenkul değerlemesinin ulusal düzeyde ortak bir terminolojiye ve bütüncül bir metodolojik çerçeveye kavuşturulmasını güçleştirmektedir. Değerleme uygulamaları, vergilendirme, kamulaştırma, yargı süreçleri ve özelleştirme gibi farklı alanlara yönelik olarak çeşitlenmiş değer türleri ve yöntemleri üzerinden gerçekleştirilmektedir. Bu nedenle, mevcut yasal altyapının detaylı biçimde analiz edilmesi, Türkiye’de etkili ve şeffaf bir toplu değerlendirme sistemine geçiş açısından temel bir gereklilik olarak öne çıkmaktadır.

Taşınmaz değerleri, emlak vergisi, kamulaştırma, devletleştirme, özelleştirme ve toprak düzenlemeleri gibi kamusal işlemlerde ve tescile esas işlemler, irtifak hakkı tesisi gibi hukuki işlemlerle sermaye piyasası, bankacılık, kredilendirme ve sigortacılık gibi özel sektör faaliyetlerinde önemli bir gereksinimdir.

Türkiye’de taşınmaz değerlemesi faaliyetleri, çeşitli mevzuat düzenlemeleriyle belirlenmiştir. Aşağıda, değer belirlenmesine ilişkin bazı temel düzenlemeler özetlenmektedir.

3.1.1. Temel Kanunlar ve Mevzuat

Türkiye’de gayrimenkul değerlendirme faaliyetlerinin doğrudan veya dolaylı biçimde dayandığı temel yasal metinler aşağıdaki şekilde özetlenebilir.

3.1.1.1. Medeni Kanun (4721 sayılı Kanun)

Taşınmazların mülkiyeti ve bu mülkiyetin kazanılması, devri ve korunmasına ilişkin temel hükümler, 4721 sayılı Türk Medeni Kanunu kapsamında düzenlenmiştir. Kanunun Mülkiyet Hakkı başlıklı hükümleri, taşınmaz mülkiyetine ilişkin hak ve

yükümlülüklerin yanı sıra taşınmazın hukuki durumunun değerlendirilme sürecinde dikkate alınması gereken unsurlarını belirlemektedir (Türk Medeni Kanunu, 2001).

Özellikle taşınmaz mülkiyetinin tapuda tescil yoluyla kazanılması (md. 705) ve tapu sicilinin güvenilirliği, gayrimenkul değerlendirme çalışmalarının temel referansını oluşturmaktadır. Ayrıca, sınırlı ayni hakların (irtifak, ipotek vb.) varlığı taşınmazın piyasa değerini doğrudan etkilemektedir (Türk Medeni Kanunu, 2001).

3.1.1.2. Tapu Kanunu (2644 sayılı Kanun)

Türkiye’de taşınmazların mülkiyetine ilişkin en temel bilgi kaynağı olan Tapu Sicilinin oluşturulması, yönetilmesi ve korunması, 2644 sayılı Tapu Kanunu ile düzenlenmektedir. Kanun, taşınmazların tescili, devir işlemleri, hak ve yükümlülüklerin kaydı ile tapu sicilinin aleniyet ilkesi kapsamında herkesçe incelenebilirliğini güvence altına almaktadır (Tapu Kanunu, 1934).

Gayrimenkul değerlendirme uygulamaları açısından Tapu Sicilinin doğruluğu ve güncelliği, değerlendirme çalışmalarının temel hukuki ve teknik altyapısını oluşturur. Zira taşınmaz mülkiyetinin tapu siciline tescil yoluyla kazanılması ve sicilde yer alan yükümlülüklerin doğru şekilde değerlendirilmesi, taşınmazın piyasa değerini doğrudan etkileyen unsurlar arasında yer almaktadır.

Ayrıca Kanunun dijital sicil altyapısına geçişi mümkün kılan düzenlemeleri çerçevesinde geliştirilen TAKBİS (Tapu ve Kadastro Bilgi Sistemi), günümüzde profesyonel değerlendirme faaliyetleri için başlıca mülkiyet verisi kaynağı olarak kullanılmaktadır.

3.1.1.3. İmar Kanunu (3194 sayılı Kanun)

İmar planlaması, yapılaşma koşulları ve arsa düzenlemelerine ilişkin temel düzenlemeleri belirleyen 3194 sayılı İmar Kanunu, gayrimenkul değerini doğrudan etkileyen yasal altyapının başlıca unsurlarından biridir. Kanun, imar planlarının hazırlanması ve uygulanması, yapı ruhsatı ve iskân süreçleri, arsa ve arazi düzenlemeleri gibi taşınmaz değerini belirleyen çok sayıda faktörü düzenlemektedir (İmar Kanunu, 1985).

Değerleme uygulamaları açısından imar planı kararları ve yapılaşma hakları, taşınmazın potansiyel kullanım değeri üzerinde belirleyici rol oynar. İmar planında yer alan fonksiyon (konut, ticaret, sanayi vb.), emsal ve maksimum yapı yüksekliği gibi imar parametreleri, piyasa değerini oluşturan ana bileşenler arasındadır. Ayrıca imar planı değişiklikleri ve imar hakkı kısıtlamaları taşınmazın değerinde önemli dalgalanmalara neden olabilmektedir (TKGM, 2017).

3.1.1.4. Vergi Usul Kanunu (213 sayılı Kanun)

Vergilendirme işlemlerine ilişkin genel usul ve esasları düzenleyen temel mevzuat olan 213 sayılı Vergi Usul Kanunu, gayrimenkul değerlemesi açısından da dolaylı ancak önemli etkilere sahiptir. Vergi alacaklarının doğması, tarhı, tahakkuku, tahsili ve denetimi süreçlerine ilişkin genel hükümleri ve usulleri belirler. Kanunun amacı, vergi alacağının kanuni şekilde hesaplanması ve tahsil edilmesi için gerekli düzenlemeleri ortaya koymaktır (Vergi Usul Kanunu, 1961).

Hangi vergi türü olursa olsun (gelir vergisi, kurumlar vergisi, katma değer vergisi, emlak vergisi vb.) usule ilişkin işlemler Vergi Usul Kanunu'na tabidir.

Bu kapsamda, taşınmaz mallar üzerinden alınan emlak vergisine ilişkin maddi hukuk hükümleri ise 1319 sayılı Emlak Vergisi Kanunu ile düzenlenmiştir.

3.1.1.5. Emlak Vergisi Kanunu (1319 sayılı Kanun)

Türkiye'de taşınmazların vergilendirilmesine yönelik temel düzenlemeleri içeren 1319 sayılı Emlak Vergisi Kanunu, gayrimenkul değerlemesi açısından vergisel değer kavramının çerçevesini belirlemektedir. Kanuna göre, Türkiye sınırları içinde bulunan bina, arsa ve araziler, ilgili belediyelere emlak vergisi ödemekle yükümlüdür (Emlak Vergisi Kanunu, 1970).

Verginin matrahı, arsa ve arazi için "arazi metrekaresi birim değerine", binalar için ise "bina vergi değerine" dayanmaktadır (md. 29-30). Bu değerler, belediyeler bünyesinde oluşturulan takdir komisyonları tarafından belirlenmekte ve dört yılda bir güncellenmektedir. Ancak bu süreçte kullanılan değerler piyasa değerinden önemli

ölçüde sapma göstermekte, bu da vergisel adaletin sağlanmasını zorlaştırmaktadır (TKGM, 2016).

Öte yandan, mevcut mevzuatta piyasa değerine dayalı vergilendirmeye geçişi destekleyecek açık düzenlemeler henüz bulunmamaktadır. Yasal Altyapı Oluşturma Komisyonu raporunda da vurgulandığı üzere, 1319 sayılı Kanun'un modernize edilmesi ve piyasa değerine dayalı vergi matrahı sistemine geçilmesi, Türkiye'de toplu değerlendirme sisteminin kurumsallaşmasının ön koşulları arasında yer almaktadır (TKGM, 2017).

3.1.1.6. Kamulaştırma Kanunu (2942 sayılı Kanun)

Kamu yararı amacıyla taşınmazların kamulaştırılması süreçlerini düzenleyen 2942 sayılı Kamulaştırma Kanunu, kamulaştırma bedelinin belirlenmesi ve taşınmaz malikine ödenecek tazminatın tespit edilmesi süreçlerinde piyasa koşullarına uygun ve adil bir değerlendirme yapılmasını öngörmektedir (Kamulaştırma Kanunu, 1983).

Kanuna göre, kamulaştırma bedeli, taşınmazın kamulaştırma tarihindeki serbest piyasa koşullarındaki değerine göre belirlenir (md. 11). Bu kapsamda değerlendirme yapılırken:

- Taşınmazın cinsi ve niteliği,
- Konumu,
- İmar durumu,
- Kullanım şekli,
- Gelir getirici potansiyeli,
- Resmi kayıt ve belgeler dikkate alınmaktadır.

Ancak uygulamada bilirkişilik kurumunun heterojen yapısı, raporlama standartlarının eksikliği ve kullanılan yöntemlerin farklılık göstermesi, kamulaştırma bedellerinin belirlenmesinde bölgesel ve vaka bazlı tutarsızlıklara yol açmaktadır (TKGM, 2017).

3.1.1.7. Afet Riski Altındaki Alanların Dönüştürülmesi Hakkında Kanun (6306 sayılı Kanun)

Afet Riski Altındaki Alanların Dönüştürülmesi Hakkında Kanun (6306 sayılı Kanun) ve Uygulama Yönetmeliği, kentsel dönüşüm sürecinin uygulanmasında ödemenin ve paylaşımın adil bir şekilde belirlenebilmesi için gayrimenkul değerlendirme yöntemlerini netleştirmektedir. Yönetmeliğin 12. maddesine göre, dönüşüm alanlarındaki taşınmazların değeri; taşınmaz değerlendirme konusunda uzman kişi, kurum veya kuruluşlardan bilgi alınarak 2942 sayılı Kamulaştırma Kanunu'nun usullerine uygun şekilde tespit edilir (Afet Riski Altındaki Alanların Dönüştürülmesi Hakkında Kanun, 2012).

Bu kapsamda, en az üç kişiden oluşan komisyonlar veya lisanslı değerlendirme kuruluşları tarafından hazırlanan raporlar, hem maliklere verilecek bedellerin hesaplanmasında hem maliklerin yeni konut veya işyerlerini hak sahiplerine uygun biçimde tahsisinde kullanılır (Afet Riski Altındaki Alanların Dönüştürülmesi Hakkında Kanun, 2012). Ayrıca, Komisyonun kullanımına sunulan bu yöntemler; yapılan yıkım ve yeniden inşa sonrası arsa payı hesaplamaları, dönüşüm gelirlerinin paylaşımı ve kira yardımı bedellerinin belirlenmesi gibi alanlarda da başvuru kaynağı oluşturmaktadır.

3.1.1.8. Sermaye Piyasası Kanunu (6362 sayılı Kanun)

6362 sayılı Sermaye Piyasası Kanunu, sermaye piyasalarının düzenlenmesi ve yatırımcı haklarının korunmasının yanı sıra, gayrimenkul değerlemesi süreçlerine de önemli ölçüde yön veren temel yasal düzenlemelerden biridir. Kanun, gayrimenkul değerlendirme faaliyetlerinin profesyonelleşmesine ve standartlaşmasına katkıda bulunmaktadır (Sermaye Piyasası Kanunu, 2012).

Kanun kapsamında, Sermaye Piyasası Kurulu (SPK) tarafından yetkilendirilen gayrimenkul değerlendirme kuruluşları aracılığıyla:

- Sermaye piyasasına arz edilen gayrimenkullerin ve projelerin değerlemesi,

- Gayrimenkul yatırım ortaklıklarının portföy değerlemesi,
- Gayrimenkul teminatlı menkul kıymetleştirme işlemleri gibi faaliyetlerde lisanslı değerlendirme uzmanları tarafından hazırlanan raporlar kullanılmaktadır.

Bu yapı sayesinde gayrimenkul değerlendirme mesleği, özellikle sermaye piyasaları ile ilişkili segmentte IVSC ile büyük ölçüde uyumlu hale gelmiştir (TKGM, 2011).

Öte yandan, SPK'nın III-62.3 sayılı Tebliği doğrultusunda yetkilendirilen değerlendirme kuruluşlarının:

- Sermaye piyasası dışındaki değerlendirme faaliyetleri bu düzenlemenin kapsamına girmemekte;
- Bu faaliyetlerdeki uyumsuzlukların değerlendirilmesi Türkiye Değerleme Uzmanları Birliği (TDUB) tarafından yürütülmektedir (SPK, 2019).

3.1.1.9. Konut Finansmanı Kanunu (5582 sayılı Kanun)

Türkiye’de konut finansmanı sisteminin geliştirilmesi ve mortgage piyasasının oluşturulması amacıyla çıkarılan 5582 sayılı Konut Finansmanı Kanunu, gayrimenkul değerlendirme uygulamalarında teminat değerlemesi alanında (md. 6, 10) önemli bir işlev üstlenmektedir (Konut Finansmanı Kanunu, 2007). Kanun, konut kredilerinin güvenli biçimde kullanılması ve gayrimenkullerin teminat olarak değerlendirilmesi süreçlerinde lisanslı ve bağımsız değerlendirme raporlarının kullanılmasını zorunlu kılmaktadır.

Kanun kapsamında, bankalar tarafından kullanılacak konut kredilerinde:

- Gayrimenkulün değer tespiti,
- Kredi teminatının değerlendirme raporuna dayandırılması,
- Ekspertiz raporlarının güncel ve güvenilir olması zorunlu hale getirilmiştir.

Bu süreçte SPK tarafından yetkilendirilen gayrimenkul değerleme kuruluşları ve lisanslı değerleme uzmanları görev almaktadır. Bu düzenleme, Türkiye’de özellikle konut piyasasında değerleme mesleğinin kurumsallaşmasına katkıda bulunmuş ve teminat değerlemesi uygulamalarının profesyonel standartlara göre yürütülmesini sağlamıştır.

3.1.1.10. Bankacılık Kanunu (5411 sayılı Kanun) ve ilgili BDDK Düzenlemeleri

Bankacılık sektöründe kredi teminatı olarak kullanılan taşınmazların değerlemesine ilişkin temel çerçeve, 5411 sayılı Bankacılık Kanunu ve bu Kanun kapsamında çıkarılan Bankacılık Düzenleme ve Denetleme Kurumu (BDDK) düzenlemeleri ile belirlenmektedir. Bankacılık Kanunu’nun 50. maddesi uyarınca, bankalar tarafından kullandırılan kredilerde teminat olarak alınan gayrimenkullerin değerlemesinin bağımsız ve yetkilendirilmiş kuruluşlarca yapılması esastır (Bankacılık Kanunu, 2005).

Bu kapsamda BDDK tarafından yayımlanan Bankaların Kredi İşlemlerine İlişkin Yönetmelik ve ilgili düzenleyici tebliğler, gayrimenkul değerleme raporlarının:

- Yetkili değerleme kuruluşları tarafından hazırlanmasını,
- Bağımsız ve tarafsız olması gerektiğini,
- Uluslararası değerleme standartlarına uygun şekilde hazırlanmasını zorunlu kılmaktadır (BDDK, 2023).

Bu düzenlemelere göre bankalar, SPK tarafından yetkilendirilen gayrimenkul değerleme kuruluşları ile çalışmakta ve bu kuruluşların hazırladığı raporları kredi teminat değerlemesi için kullanmaktadır.

BDDK düzenlemeleri, Türkiye’de gayrimenkul değerleme mesleğinin özellikle bankacılık uygulamaları alanında profesyonelleşmesine ve standartlaşmasına büyük katkı sağlamıştır (TKGM, 2011). Bu sayede bankalar, daha şeffaf, bağımsız ve güvenilir teminat değerlemesi süreçleri uygulamaktadır.

3.1.1.11. Özelleştirme Mevzuatı ve Diğer İlgili Yasal Dayanaklar

Kamuya ait taşınmazların özelleştirilmesi süreçlerinde, özelleştirme mevzuatı kapsamında belirlenen değerlendirme esasları (md. 3, 18), gayrimenkul değerlendirme uygulamaları açısından özel bir alan oluşturmaktadır (Özelleştirme Uygulamaları Hakkında Kanun, 1994).

4046 sayılı Kanun çerçevesinde gerçekleştirilen özelleştirme işlemlerinde, taşınmazların değerlemesi:

- Serbest piyasa koşulları çerçevesinde,
- Bağımsız ve uzman değerlendirme kuruluşları tarafından,
- Uluslararası değerlendirme standartları doğrultusunda yapılmaktadır.

Ayrıca, Özelleştirme İdaresi Başkanlığı tarafından yayımlanan Özelleştirme Değerleme Yöntemleri Rehberi ve ilgili ikincil düzenlemeler, bu süreçte uygulanacak metodolojilere dair ayrıntılı hükümler içermektedir.

Diğer ilgili yasal dayanaklar arasında ise:

Belediye Kanunu (5393 sayılı Kanun); belediyelerin taşınmaz satış ve tahsis işlemlerine ilişkin değerlendirme yükümlülükleri,

Milli Emlak Mevzuatı; Hazine taşınmazlarının değerlemesine yönelik özel hükümler içermektedir. Milli Emlak Genel Müdürlüğü bünyesinde yürütülen değerlendirme faaliyetleri, ilgili taşınmazın satış, kiralama, irtifak hakkı tesisi veya trampa işlemleri öncesinde emsal karşılaştırma, gelir kapitalizasyonu ve maliyet yaklaşımı gibi yöntemlerle gerçekleştirilmektedir (Kurt vd., 2022). (Milli Emlak Genel Müdürlüğü Değerleme Raporu, 2021)

Kamu İhale Kanunu (4734 sayılı Kanun); kamu taşınmazlarının ihale yoluyla satışı ve kiralanmasına yönelik değerlendirme süreçleri de yer almaktadır.

3.2. Değerleme Amaçlı Kullanılan Farklı Değer Türleri

Gayrimenkul değerlemesinde kullanılan değer kavramları, farklı amaçlar ve bağlamlar doğrultusunda çeşitlilik göstermekte ve her biri kendine özgü hukuki ve ekonomik anlam taşımaktadır. Değer; genel anlamda bir mal, hak ya da hizmetin belirli bir tarihte, belirli piyasa koşulları altında alıcı ve satıcı arasında oluşabilecek olası değişim değerini ifade eder (Tanrıvermiş, 2016). Ancak uygulamada değer, fiyat, bedel, maliyet ve tazminat gibi kavramların sıklıkla birbirinin yerine kullanıldığı, fakat teknik anlamda farklı içeriklere sahip oldukları görülmektedir (Tanrıvermiş, 2016).

Piyasa Değeri, IVS kapsamında şöyle tanımlanmaktadır: “Bir taşınmazın, değerlendirme tarihinde, ilgili tarafların bilgili, istekli ve bağımsız olduğu varsayılan bir işlemde, açık ve rekabetçi bir pazarda el değiştirmesi beklenen tahmini bedel” (IVSC, 2025). Türkiye’de SPK lisanslı değerlendirme raporlarında ve bankacılık teminat işlemlerinde bu tanım esas alınmaktadır. Fiyat, belirli bir işlemde gerçekten oluşan tutardır ve piyasa değerinden sapma gösterebilir. Maliyet ise bir malın üretimi veya yeniden üretimi için gereken harcamaları ifade eder ve piyasa değerinden farklı olabilir; örneğin bir binanın inşaat maliyeti, o binanın satış fiyatını her zaman doğrudan yansıtmayabilir (Tanrıvermiş, 2016).

Bedel kavramı özellikle Türk hukukunda, özellikle kamulaştırma ve kamu yararı işlemlerinde önem taşır. Bedel, çoğu zaman mevzuatın öngördüğü şekliyle “hak edilen karşılık” olarak belirlenmekte olup piyasa değerinin üzerinde veya altında olabilir (Tanrıvermiş, 2016). Tazminat ise mal varlığında meydana gelen zararın parasal karşılığıdır ve değerlendirme bağlamında zarar-zıyan hesaplamalarında kullanılır (Tanrıvermiş, 2016).

Ayrıca, değerlendirme sürecinde adil piyasa değeri ve gerçeğe uygun değer gibi muhasebe ve finans uygulamalarında sıklıkla başvuru kavramları da kullanılmaktadır. Adil piyasa değeri, gönüllü taraflar arasında bilgiye dayalı olarak oluşacak olası satış fiyatını tanımlar. Gerçeğe uygun değer ise muhasebe standartlarına göre raporlanan varlıkların mevcut piyasa koşullarındaki değerini temsil eder (IVSC, 2022).

Türkiye’de uygulamada öne çıkan başlıca değer türleri aşağıda özetlenebilir:

- **Pazar Değeri:** Bir taşınmazın, değerlendirme tarihinde, ilgili tarafların bilgili, istekli ve bağımsız olduğu varsayılan bir işlemde, açık ve rekabetçi bir pazarda el değiştirmesi beklenen tahmini bedel (IVSC, 2025).
- **Rayiç Bedel:** Emlak vergisi ve tapu harcı işlemlerinde kullanılan, genellikle belediye takdir komisyonları veya piyasa araştırmalarına dayalı olarak belirlenen değer.
- **Vergi Değeri:** Emlak Vergisi Kanunu kapsamında belediyeler tarafından dört yılda bir belirlenen, çoğu zaman piyasa değerinden düşük olan değer.
- **Kamulaştırma Değeri:** Kamulaştırma süreçlerinde mahkemelerce veya bilirkişilerce belirlenen değer.
- **Gerçeğe Uygun Değer:** Mali raporlama ve muhasebe standartları çerçevesinde bazı özel işlemlerde kullanılmaktadır.

Bu farklı değer türlerinin yasal tanımlarının ve kullanım amaçlarının net olarak ayrışmaması, Türkiye’de değerlendirme uygulamalarında karmaşıklığa ve uygulama farklılıklarına yol açmaktadır. Bu durum, özellikle toplu değerlendirme sistemi kurulurken ortak bir değer kavramı etrafında mevzuatın uyumlaştırılmasını gerektirmektedir (TKGM, 2017).

3.3. Türkiye’de Gayrimenkul Değerleme ile İlgili Kurum ve Kuruluşlar

Türkiye’de gayrimenkul değerlendirme faaliyetleri çok sayıda kamu kurumu, bağımsız düzenleyici otorite, meslek örgütü ve yerel idarenin katkısıyla yürütülmektedir. Ancak, bu kurum ve kuruluşların faaliyet alanlarının paralel değil, çoğu zaman kesişen ve dağınık biçimde yapılandığı gözlemlenmektedir. Bu durum, ulusal çapta tutarlı ve bütünlüklü bir toplu değerlendirme sistemi geliştirilmesinin önündeki temel kurumsal zorluklardan birini teşkil etmektedir.

Aşağıda Türkiye’de gayrimenkul değerlendirme sisteminin şekillenmesinde doğrudan veya dolaylı rol oynayan başlıca kurum ve kuruluşlar özetlenmektedir.

3.3.1. Sermaye Piyasası Kurulu

SPK, Türkiye sermaye piyasalarının güvenli, şeffaf ve istikrarlı şekilde işlemlerini sağlamak, tasarruf sahiplerinin hak ve menfaatlerini korumak ve sermaye piyasasına yatırım yoluyla ekonomik kalkınmayı desteklemek amacıyla kurulmuş bağımsız ve mali özerkliğe sahip bir kamu tüzel kişisidir. Kuruluşunun yasal dayanağı, 28 Temmuz 1981 tarihli ve 2499 sayılı Sermaye Piyasası Kanunu olup, günümüzde 6362 sayılı Sermaye Piyasası Kanunu yürürlükte (SPK, 2025c). Hazine ve Maliye Bakanlığı'na bağlı olarak faaliyet gösteren kurulun merkezi İstanbul'dadır. Kurulun karar organı, biri Başkan ve biri İkinci Başkan olmak üzere toplam yedi üyeden oluşmaktadır (SPK, 2025b). Başkan, aynı zamanda Başkanlık teşkilatının da başında bulunur ve kurumun genel idari ve temsil yetkisini haizdir. İkinci Başkan ve Başkan Vekili, Kurul üyeleri arasından belirlenir. Başkan, İkinci Başkan, Başkan Vekili ve diğer üyeler, Cumhurbaşkanı tarafından atanır (SPK, 2025b). Bu yapı, Kurulun yönetim ve karar alma süreçlerinde merkezi ve bütüncül bir yetki ve sorumluluk düzeni oluşturmayı amaçlamaktadır.

SPK'nın temel hedefleri arasında sermaye piyasası kurum ve kuruluşları için işleyiş kurallarını oluşturmak, şirketlerin piyasalardan fon temin ederken düzenlemelere uygun hareket etmelerini sağlamak, yatırımcı haklarını korumak ve piyasaların adil ve etkin biçimde çalışmasını temin etmek yer almaktadır (SPK, 2025a).

Türkiye'de gayrimenkul değerlendirme mesleğinin kurumsallaşmasında SPK'nın düzenleyici rolü belirleyici olmuştur. Özellikle 2001 yılında yayımlanan Seri: VIII, No: 35 sayılı Tebliğ ile ilk kez gayrimenkul değerlendirme kuruluşlarının lisanslanması ve denetlenmesi uygulamasına geçilmiş, böylece profesyonel değerlendirme hizmetleri için bir çerçeve oluşturulmuştur.

Bu düzenleme, 31 Ağustos 2019 tarihinde yayımlanan III-62.3 sayılı Tebliğ ile güncellenmiştir. Yeni Tebliğ, sermaye piyasasında faaliyet gösterecek gayrimenkul değerlendirme kuruluşlarının yetkilendirilmesi, faaliyetlerinin yürütülmesi ve yetkilerinin iptaline ilişkin usul ve esasları belirlemektedir (SPK, 2019). Ayrıca, değerlendirme raporlarının asgari içerik standartları da bu Tebliğ ile netleştirilmiştir. SPK tarafından

yetkilendirilen değerleme kuruluşlarının, sermaye piyasası dışındaki değerleme faaliyetleri bu düzenlemenin kapsamına girmemektedir. Bu kapsamda ortaya çıkan uyuşmazlıklar ve şikayetler, TDUB tarafından değerlendirilmektedir ve bu değerlendirmeler bağlayıcı niteliktedir (SPK, 2019).

Bu yapı sayesinde, Türkiye’de sermaye piyasasına yönelik değerleme uygulamaları, IVS ile uyumlu biçimde ve yüksek denetim standartları altında yürütülmekte, böylece değerleme mesleğinin profesyonel gelişimi desteklenmektedir.

3.3.2. Bankacılık Düzenleme ve Denetleme Kurumu

Türkiye’de bankacılık sektöründe faaliyet gösteren kuruluşların düzenlenmesi, denetlenmesi ve gözetimi amacıyla kurulan Bankacılık Düzenleme ve Denetleme Kurumu (BDDK), 5411 sayılı Bankacılık Kanunu çerçevesinde faaliyet göstermektedir (Bankacılık Kanunu, 2005). BDDK’nın temel görevleri arasında bankacılık faaliyetlerinin güvenli, etkin ve istikrarlı bir şekilde yürütülmesini sağlamak, kredi sisteminin gelişimine katkıda bulunmak ve finansal sistemin tüm paydaşlarının hak ve menfaatlerini korumak yer almaktadır.

Gayrimenkul değerleme açısından BDDK, özellikle kredi teminatı olarak gösterilen taşınmazların değerlemesine ilişkin düzenlemeler yoluyla sektörde önemli bir rol oynamaktadır. Bankacılık Kanunu’nun 50. maddesi uyarınca bankaların, teminat olarak aldıkları taşınmazların değerlemesinin, bağımsız ve yetkilendirilmiş değerleme kuruluşları tarafından yapılmasını sağlamaları zorunludur (Bankacılık Kanunu, 2005).

Bu çerçevede BDDK, Bankaların Kredi İşlemlerine İlişkin Yönetmelik ve ilgili düzenleyici tebliğler aracılığıyla:

- Gayrimenkul değerleme raporlarının SPK tarafından yetkilendirilen gayrimenkul değerleme kuruluşları tarafından hazırlanmasını,
- Hazırlanan raporların uluslararası değerleme standartlarına ve BDDK’nın belirlediği usul ve esaslara uygun olmasını,
- Raporların bağımsız, tarafsız ve güncel verilere dayanmasını zorunlu

kılmaktadır (BDDK, 2023).

Bu düzenleme sayesinde Türkiye’de bankacılık sektöründe uygulanan gayrimenkul değerlendirme faaliyetleri, profesyonel ve denetimli bir çerçevede yürütülmekte; böylece hem kredi teminatlarının doğru ve güvenilir biçimde değerlemesi sağlanmakta hem de finansal istikrar desteklenmektedir.

3.3.3. Türkiye Değerleme Uzmanları Birliği

TDUB, Türkiye’de gayrimenkul değerlendirme mesleğinin kurumsallaşması, meslek standartlarının geliştirilmesi ve etik ilkelerin oluşturulması amacıyla faaliyet gösteren temel meslek örgütüdür. TDUB, 6362 sayılı Sermaye Piyasası Kanunu'nun 76. maddesine dayanılarak, 30 Ekim 2009 tarihli Bakanlar Kurulu Kararıyla kurulmuş ve 2 Nisan 2014 tarihli yönetmelikle güncellenmiştir (TDUB, 2025c). Birliğin üyeleri, SPK tarafından lisans verilen gayrimenkul değerlendirme uzmanları ile yetkilendirilmiş değerlendirme kuruluşlarından oluşmaktadır.

TDUB’un temel amaç ve görevleri şunlardır:

- Mesleki standartlar ve etik kurallar geliştirme,
- Üyelerinin eğitim ve mesleki gelişim faaliyetlerini koordine etme,
- Değerleme raporlarının standardizasyonu ve uyumlu hale getirilmesi,
- Şikâyeti değerlendirme ve mesleki denetim işlevleri,
- Komiteler aracılığıyla sektörel araştırma, rehber ve iyi uygulamaların geliştirilmesi.

TDUB’un organları arasında Yönetim, Denetim, Disiplin Kurulları ve birçok uzmanlık komitesi yer almakta; özellikle “İyi Uygulamalar Kılavuzları” sayesinde uluslararası standartlara uygun rehberlik sağlanmaktadır (TDUB, 2025f). Ayrıca, SPK tebliğleriyle düzenlenen sermaye piyasası dışı değerlendirme faaliyetlerinden kaynaklanan şikâyet ve uyuşmazlıklar TDUB tarafından bağlayıcı şekilde sonuçlandırılmaktadır, bu da kurumun sektörde öz düzenleyici bir otorite işlevi gördüğünü göstermektedir.

3.3.4. Milli Emlak Genel Müdürlüğü

Milli Emlak Genel Müdürlüğü (MEGM), Türkiye’de Hazine taşınmazlarının yönetimi, satışı, kiralanması, trampa edilmesi, irtifak hakkı tesis edilmesi ve diğer taşınmaz işlemleri konusunda sorumluluğa sahip temel kurumsal aktördür. Kurumun görevleri arasında, bu işlemler öncesinde taşınmazların değer tespiti yapılarak piyasaya uygun ve hukuki doğruluğa sahip kararlar alınması da bulunmaktadır (Milli Emlak Genel Müdürlüğü, 2025).

MEGM, Türkiye genelinde il ve ilçe taşra teşkilatlarıyla örgütlenmiş olup, işlemler sırasında SMS/e-posta bilgilendirmesi gibi dijital hizmetler de sunmaktadır. Kurum, satış ve kiralama süreçlerinde alıcıları ve ilgilileri bilgilendirmekte, bu sayede şeffaflık ve etkinlik sağlamaktadır (Milli Emlak Genel Müdürlüğü, 2025).

Gayrimenkul değerlendirme açısından MEGM, emsal karşılaştırma, gelir kapitalizasyonu ve maliyet yaklaşımı gibi klasik yöntemlere dayalı olarak taşınmazların değer tespiti işlemlerini yürütmektedir. Bu işlemler gerek kurum içindeki uzmanlar gerekse SPK lisanslı değerlendirme kuruluşları tarafından gerçekleştirilebilmektedir.

Ancak hâlihazırda MEGM'nin uygulamalarında, merkezi, otomatikleştirilmiş bir toplu değerlendirme sistemi bulunmamakta; süreçler halen değişken veri kalitesi ve manuel yöntemlere dayanmaktadır. Bu durum, veri standardizasyonu, metodolojik tutarlılık ve şeffaflık alanlarında iyileştirme ve geliştirme ihtiyacı doğurmaktadır.

3.3.5. Belediyeler ve Diğer Kamu Kurumları

Türkiye’de gayrimenkul değerlemesi, merkezi kurumların yanı sıra yerel düzeyde belediyeler ve diğer kamu kurumları tarafından da yürütülmektedir. Belediyeler, emlak vergisi matrahlarının belirlenmesinde rayiç bedel esaslı değerlendirme raporlarına başvurarak ticari şeffaflık ve vergi adaletini artırmayı amaçlamaktadır. Bunun yanı sıra, arsa satışları, kamu kullanımına ayrılma, imar işlemleri ve kamulaştırma süreçleri gibi çeşitli uygulamalarda yerel yönetimler aktif rol alır; özellikle belediyelerin varlık yönetimini sistemli hale getirmeye yönelik çalışmalar, şehir gelişim projelerinde kaynak yaratımı açısından büyük önem taşımaktadır.

Kamu kurumları arasında dikkat çekenler şunlardır:

İller Bankası: Belediyelerin yatırım projeleri için kaynak sağlama amacıyla gayrimenkul değerlemesi yapar; bu kapsamda, yerel yönetimlerin varlık portföylerinin stratejik yönetimine destek sağlar.

Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'na bağlı Kentsel Dönüşüm Başkanlığı, 6306 sayılı Kanun kapsamında kentsel dönüşüm süreçlerinde gayrimenkul değerlemesini kapsamlı bir şekilde yürütmektedir. Başkanlık; riskli yapıların tespiti, dönüşüm alanlarının ilanı, taşınmazların değer tespiti ve bu değerlerin güncellenmesi ile dönüşüm uygulamaları sonucunda yeni yapıların değer tespiti gibi işlemleri gerçekleştirir (Kentsel Dönüşüm Başkanlığı, 2025).

Özelleştirme İdaresi Başkanlığı, Çevre ve Şehircilik Bakanlığı, TOKİ (Toplu Konut İdaresi) ve Kamu İhale Kurumu gibi diğer kurumlar da projelerine yönelik taşınmaz değerlemesinde görev üstlenir ve bu süreçler sırasında hem piyasa verileri hem de değerlendirme uzmanı raporlarına başvurulur.

3.3.6. Tapu ve Kadastro Genel Müdürlüğü

Tapu ve Kadastro Genel Müdürlüğü (TKGM), Türkiye'de mülkiyet haklarının tescili ve kadastro bilgilerinin üretimi, güncellenmesi ve yönetimi görevlerini yürüten en temel kamu kurumudur. 1847 yılında kurulmuş olan Genel Müdürlük, bugün Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'na bağlı olarak faaliyet göstermektedir (TKGM, 2025b).

TKGM'nin temel görevleri arasında şunlar yer almaktadır:

- Türkiye genelindeki tüm taşınmazların mülkiyet haklarının güvenli biçimde tescili ve tapu sicilinin güncellenmesi,
- Kadastro çalışmalarının yürütülmesi ve ülke genelinde mekânsal veri altyapısının oluşturulması,
- Tapu ve Kadastro Bilgi Sistemi (TAKBİS) ve Mekânsal Gayrimenkul Sistemi (MEGSİS) gibi dijital platformlar aracılığıyla veri paylaşımının

sağlanması (TKGM, 2025a),

- Tapu siciline güven ilkesi kapsamında, vatandaşların mülkiyet haklarının hukuki güvence altına alınması.

Gayrimenkul değerlendirme açısından TKGM, Türkiye’de toplu değerlendirme sisteminin geliştirilmesi için en kritik veri sağlayıcı kurumlardan biridir. TAKBİS ve MEGSİS üzerinden sağlanan mülkiyet, parsel, yapı ve coğrafi bilgi verileri, gayrimenkul değerlendirme modellerinin temel veri kaynakları arasında yer almaktadır (TKGM, 2025a). Özellikle TKMP kapsamında geliştirilen uygulamalarda, TKGM’nin, parsel ve yapı verilerinin kalitesinin artırılması, 3B kadastro çalışmalarının desteklenmesi, toplu değerlendirme için kullanılabilecek veri setlerinin standardize edilmesi gibi önemli katkılar sağladığı görülmektedir (TKGM, 2025a).

3.4. Türkiye’de Toplu Değerleme Sistemine Yönelik Çalışmalar ve Pilot Uygulamalar

Türkiye’de gayrimenkul değerlemesi, uzun yıllar boyunca münferit mülkler için hazırlanan bireysel ekspertiz raporlarıyla sınırlı kalmıştır. Bu durum hem kamusal şeffaflık hem de vergisel adalet açısından önemli sınırlılıklara yol açmıştır. Türkiye’de toplu değerlendirme sistemi geliştirilmesine yönelik çalışmalar, 2000’li yıllardan itibaren artan bir önem kazanmış ve özellikle TKGM tarafından yürütülen TKMP kapsamında kurumsal bir çerçeveye oturtulmuştur. Bu süreç, Türkiye’de vergisel adaletin sağlanması, kamusal taşınmaz yönetiminin iyileştirilmesi ve şeffaf bir gayrimenkul piyasasının desteklenmesi gibi stratejik hedeflerle doğrudan bağlantılıdır. TKMP kapsamında yürütülen çalışmalar, pazar değeri odaklı, düzenli güncellenebilen ve kamusal kullanım için erişilebilir bir toplu değerlendirme sistemi kurulmasına zemin hazırlamayı amaçlamaktadır.

Bu bağlamda Amasya İli Merkez İlçe Toplu Değerleme Pilot Çalışması, kentsel dönüşüm ve taşınmaz envanteri oluşturma amaçlı toplu değerlendirme modelinin uygulanmasına yönelik önemli bir adım teşkil etmektedir (TKGM, 2022). Proje kapsamında, 26 mahalledeki yaklaşık 12.552 parsel ve 18.577 bina için CBS tabanlı üç boyutlu kadastro modelleri kullanılarak toplu değerlendirme sistemi oluşturulmuştur

(Dursun, 2023). Değerleme sürecine temel oluşturan veri kaynakları arasında Tapu ve Kadastro Bilgi Sistemi (TAKBİS), emsal veri tabanları (Ziraat Bankası, TDUB) ve parsel bazlı kamusal kısıtlama verileri yer almıştır (Dursun, 2023). Kullanılan metodolojiler arasında ise istatistiksel modelleme, konumsal enterpolasyon ve 3B şehir modeli entegre analizleri öne çıkmaktadır. Bu sayede değerleme süreçlerinde standardizasyon sağlanmış ve kamusal veri entegrasyonu başarıyla gerçekleştirilmiştir (Dursun, 2023). Projenin çıktıları arasında, değer bilgi merkezlerinin kurulması, parsel bazlı değer haritalarının geliştirilmesi ve itiraz-temyiz mekanizmalarının tanımlanması gibi kurumsal altyapının güçlendirilmesine yönelik önemli katkılar bulunmaktadır. Çalışma, Türkiye’de toplu değerleme sistemlerinin kentsel dönüşüm ve kamusal planlama süreçlerine entegrasyonu açısından örnek teşkil etmektedir.

Benzer şekilde, Ankara İli Gölbaşı İlçesi Toplu Değerleme Pilot Projesi ise 2022 yılı sonunda tamamlanmıştır (TKGM, 2024). Bu proje kapsamında, yaklaşık 4.930 bağımsız bölüm için mimari proje verilerine dayalı değer tespiti modeli geliştirilmiştir. Çalışma sürecinde, CBS tabanlı istatistiksel modelleme teknikleri, konumsal analizler ve 3B bina modelleri kullanılmış; böylece parsel ve bağımsız bölüm düzeyinde detaylı değer haritaları üretilmiştir. Gölbaşı İlçesi, benzer CBS ve bulut bilişim tabanlı modellemeyle analiz edilen pilot belediyeler arasında yer almakta ve elde edilen sonuçlar, toplu değerlemenin geniş ölçekli uygulamalara entegrasyonu açısından kurumsal kapasitelerin geliştirilmesine katkı sağlamaktadır.

İstanbul’un tarihi ve merkezi ilçelerinden biri olan Fatih ise, Türkiye’de toplu değerleme sisteminin uygulanabilirliğini test etmek amacıyla yürütülen pilot projelerde kritik bir örneklem alanı olarak seçilmiştir. Bu çalışma, karmaşık kentsel doku, tarihi yapı stoku ve yoğun mülkiyet ilişkileri gibi unsurların değerleme süreçleri üzerindeki etkilerini değerlendirmek amacı taşımaktadır (TKGM, 2014). Pilot uygulama kapsamında kullanılan temel veri kaynakları arasında TAKBİS, MEGSİS, belediye kayıtları, piyasa satış verileri ve saha çalışmaları yer almıştır. Bu kapsamlı veri seti doğrultusunda, hedonik regresyon modeli ve istatistiksel analiz teknikleri aracılığıyla taşınmazların pazar değerine yakın tahminleri üretilmiştir. Ancak, Fatih ilçesinin tarihi ve kültürel miras niteliği taşıyan taşınmazları, koruma statüleri, fonksiyonel çeşitlilik ve sosyo-ekonomik heterojenlik gibi faktörler, değerlendirme

modellerinin açıklayıcılığını sınırlamıştır (TKGM, 2014). Elde edilen bulgular, ilçede uygulanan emlak vergisi beyan değerlerinin, çoğu durumda taşınmazların gerçek pazar değerlerini yansıtmadığını ortaya koymuştur (TKGM, 2015). Bu durum, vergisel adaletin sağlanamaması, mali şeffaflığın zedelenmesi ve kamusal gelir kaybı gibi sorunlara yol açmaktadır (TKGM, 2014). Bununla birlikte pilot uygulama, değer haritalarının oluşturulması, konumsal değer farklılıklarının belirlenmesi ve sayısal modelleme kapasitesinin geliştirilmesi açısından önemli katkılar sağlamıştır.

Bir diğer uygulama bölgesi olarak seçilen Ankara'nın Mamak ilçesi gecekondu bölgelerinden başlayarak zamanla çok katlı konut alanlarına dönüşen ve farklı nitelikte taşınmazları bünyesinde barındıran bir yerleşim alanıdır. Bu çeşitlilik, toplu değerlendirme modelleri için sosyo-mekânsal değişkenliği yüksek bir örneklem sunmuştur. Uygulama kapsamında CAMA sistemleri, taşınmaza ilişkin mekânsal veriler, saha gözlemleri, emlak vergisi beyan değerleri ve piyasa verileri entegre edilerek çok değişkenli istatistiksel analizler yürütülmüştür (TKGM, 2015). İlçedeki taşınmazların değerlerinde alt bölgeler bazında büyük farklılıklar olduğunu ve bu farklılıkların çoğunlukla beyan edilen vergisel değerlerle örtüşmediğini göstermiştir (TKGM, 2015). Bu durum, değerlendirme sisteminde şeffaflık ve adalet eksikliği gibi temel sorunların altını çizmiştir. Ayrıca model sonuçlarıyla karşılaştırıldığında, emlak vergisi matrahlarının pazar koşullarını yansıtmaktan uzak olduğu tespit edilmiştir (TKGM, 2014).

Türkiye'de toplu değerlendirme sistemine geçiş çabaları yalnızca teknik değil, aynı zamanda kurumsal, hukuki ve yönetsel açılardan da kapsamlı bir dönüşüm süreci gerektirmektedir. Bu doğrultuda TKGM koordinasyonunda kurulan:

- Yasal Altyapı Oluşturma Komisyonu,
- Parametrelerin Belirlenmesi ve Standart Oluşturma Komisyonu,
- İdari ve Teknik Altyapı Komisyonu,

gibi yapıların yürüttüğü çalışmalar kapsamında, değerlendirme yöntemleri, değer türleri, veri setleri ve kalite kontrol mekanizmaları gibi teknik parametrelerin tanımı yapılmıştır (TKGM, 2011, 2017). Aynı zamanda mevcut Vergi Usul Kanunu, Tapu

Kanunu, Milli Emlak Mevzuatı ve Belediye mevzuatı ile uyumlu bir düzenleme çerçevesi oluşturulmasına yönelik mevzuat analizleri yürütülmüştür.

Türkiye, bu dönüşüm sürecinde yalnızca iç kaynaklara değil, aynı zamanda uluslararası iyi uygulamalara da başvurmuştur. Özellikle Finlandiya ve Estonya’da uygulanan toplu değerlendirme sistemleri, modelleme süreçleri, yasal düzenleme biçimleri ve veri paylaşım sistemleri açısından örnek alınmıştır (TKGM, 2012). Bu ülkelerdeki uygulamalardan çıkarılan sonuçlar ışığında, Türkiye için önerilen model; merkezi veri yönetimi, otomatik değerlendirme sistemleri ve belirli periyotlarda güncellenen sistematik değerlendirme döngüleri üzerine kuruludur.

Toplu değerlendirme sistemi, yalnızca vergi matrahının güncellenmesi açısından değil; aynı zamanda:

- Kamusal yatırım kararlarının iyileştirilmesi,
- Kentsel dönüşüm projelerinin adil planlanması,
- Gayrimenkul teminatlı finansal sistemlerin güçlendirilmesi,
- Şeffaf ve erişilebilir gayrimenkul veri sistemlerinin oluşturulması gibi birçok stratejik fayda üretmektedir.

Bu bağlamda, e-Devlet entegrasyonu, blokzincir tabanlı mülkiyet sistemleri, coğrafi bilgi sistemleriyle (CBS) tam uyumlu değerlendirme platformları gibi ileri dijitalleşme çözümleri de gündemdedir.

Türkiye’de toplu değerlendirme sistemine geçiş kurumsal bir reform sürecidir. Gerek pilot uygulamalar gerekse kurumsal analizler, bu sistemin hem yasal dayanaklara hem de teknik altyapıya sahip olduğunu, ancak tam ölçekli uygulanabilirlik için politika sahipliğine, veri kalitesine, kurumlar arası entegrasyona ve sürekli güncellenebilir dijital altyapılara ihtiyaç olduğunu göstermektedir.

BÖLÜM 4

METODOLOJİ

Bu bölümde, toplu değerlendirme çalışmalarında kullanılan yöntemler ve literatürde öne çıkan yapay zekâ ile makine öğrenmesi tabanlı algoritmalar ayrıntılı olarak ele alınmaktadır. Öncelikle gayrimenkul değerlendirme ve toplu değerlendirme kavramlarının kuramsal temelleri açıklanmış, bu bağlamda değerlendirme sürecinde kullanılan değişkenlerin belirlenmesi ve coğrafi bilgi sistemlerinin katkısı tartışılmıştır.

Bölümün devamında, toplu değerlendirme modellerinde yaygın biçimde kullanılan regresyon algoritmaları ve bunların türevleri ayrıntılı biçimde incelenmiştir. Karar Ağaçları, Bagging ve Boosting tabanlı yöntemler gibi ağaç temelli algoritmaların işleyiş mantıkları, güçlü ve sınırlı yönleriyle birlikte literatür bulguları ışığında değerlendirilmiştir. Random Forest, Extra Trees, Bagging, AdaBoost, Gradient Boosting, XGBoost, LightGBM ve CatBoost gibi farklı yöntemlerin performansları karşılaştırmalı olarak ele alınmış; toplu değerlendirme çalışmalarında hangi koşullarda öne çıktıkları tartışılmıştır.

Ayrıca, kullanılan modellerin doğruluk ve güvenilirliğini ölçmeye yönelik performans göstergeleri ile XAI teknikleri üzerinde durulmuştur. Bu kapsamda, PFI ve SHAP analizlerinin, değişkenlerin model sonuçlarına katkısını ortaya koymadaki işlevi açıklanmıştır.

Sonuç olarak, bu bölümde sunulan içerik, örnek uygulama bölümünde izlenecek yöntemlerin kuramsal ve bilimsel temellerini oluşturmaktadır. Böylece, uygulamada kullanılan algoritmaların seçimi ve açıklanabilirliği için güçlü bir teorik çerçeve sağlanmıştır.

4.1. Gayrimenkul Değerleme

Gayrimenkul değerlendirme, bir gayrimenkulün piyasa koşullarına, hukuki durumuna, fiziki niteliklerine, mekânsal özelliklerine ve diğer ilgili faktörlere dayanarak ekonomik değerinin belirlenmesi sürecidir. Dolayısıyla piyasada doğru fiyatlamayı sağlamak, yatırımcıların doğru kararlar almasına yardımcı olmak ve

finansal kurumların risklerini minimize etmek için büyük bir öneme sahiptir. Değerleme süreci, çeşitli yöntemler ve teknikler kullanılarak gerçekleştirilir ve her bir yöntem, mülkün farklı özelliklerine göre en uygun değerlemenin yapılabilmesi için farklı bakış açıları sunar. Gayrimenkul değerleme yöntemlerini sınıflandırmayı konu alan birçok çalışma mevcuttur (Dimopoulos & Bakas, 2019; Ja'afar vd., 2021; Numan & Yusoff, 2024; Renigier-Bilozor vd., 2022; D. Wang & Li, 2019; Xu & Zhang, 2021).

Gayrimenkul değerleme yöntemleri tekil değerleme ve toplu değerleme olarak iki ayrı başlığa ayrılır. Tekil değerleme yaklaşımı, değerleme uzmanının taşınmaz üzerinde yaptığı yerinde fiziksel inceleme ve mesleki deneyime dayalı muhakeme süreçleri sonucunda piyasa değerinin belirlenmesini ifade eder. Buna karşılık toplu değerleme yöntemleri, çok sayıda taşınmazın değerlemesinde veri kümeleri üzerinden istatistiksel ve matematiksel modellerin eşzamanlı olarak uygulandığı yöntemler bütünüdür.

Benzer şekilde (Guliker vd., 2022) çalışmasında, gayrimenkul değerlemesinde model tabanlı olmayan (*non-model based*) ve model tabanlı (*model based*) olarak iki ana yaklaşım öne çıkmaktadır. Model tabanlı olmayan, geleneksel değerleme yöntemleri genel olarak dört ana grupta toplanmaktadır: piyasa, maliyet, gelir ve geliştirme yaklaşımı (Gabrielli & French, 2021). Piyasa yaklaşımı, benzer özelliklere sahip gayrimenkullerin satış fiyatlarını karşılaştırarak değer tespiti yapar. Maliyet yaklaşımı, mülkün yeniden inşa edilme maliyetini dikkate alarak, mevcut yapıdaki yıpranma ve eskime gibi faktörleri göz önünde bulundurur. Gelir yaklaşımı, gayrimenkulden elde edilebilecek potansiyel gelir akışlarını temel alır ve özellikle ticari gayrimenkuller ve kira gelirine dayalı yatırımlar için değerlemede uygundur. Geliştirme yaklaşımı ise, arsa veya proje alanının değerini, geliştirilmiş varlığın öngörülen satış gelirinden inşaat giderleri ile geliştirici kâr payının düşülmesi yoluyla belirleyen bir yöntemdir. Böylece, potansiyel geliştirme projesinin nihai değerine dayalı olarak arsanın mevcut piyasa değeri saptanmış olur. Bu dört yaklaşım, her bir mülk türü için uygun değerlendirme tekniklerinin seçilmesine olanak tanır.

Model tabanlı değerlendirme, geçmişte satılmış benzer konutlara ait verilerin istatistiksel veya makine öğrenimi yöntemleriyle analiz edilmesine dayanarak fiyat tahminlerinin otomatikleştirilmesini sağlar. Bu yaklaşım, işlem maliyetlerini

azaltmakla birlikte, tahminlerin doğruluk düzeyi kullanılan referans verilerin kapsamı ve niteliği ile sınırlıdır (Numan & Yusoff, 2024). Toplu değerlendirme ise, bu kapsamda uygun modeller seçilerek geniş ölçekli taşınmaz portföylerine uygulanan değerlendirme biçimi olarak tanımlanmaktadır.

4.2. Toplu Değerleme

Toplu değerlendirme yaklaşımları; mantıksal modellere ve istatistiksel yöntemlere dayalı kurgular kullanılarak, çok sayıda taşınmazın kısa sürede, eş zamanlı ve sistematik biçimde değerlemesini gerçekleştirmek amacıyla geliştirilmiştir. Literatürde bu kavram kimi zaman “kitlesel değerlendirme”, ancak daha yaygın olarak “toplu değerlendirme” terimiyle ifade edilmektedir.


IAAO tarafından yayımlanan standardında, toplu değerlendirme; “bir grup taşınmazın belirli bir tarih itibarıyla değerlerinin, güncel ve güvenilir veriler, standartlaştırılmış yöntemler ve istatistiksel testler kullanılarak belirlenmesi süreci” olarak tanımlanmaktadır (IAAO, 2018). Bu tanım, toplu değerlemenin yalnızca değer tahminlerini değil, aynı zamanda verinin kalitesini, yöntemlerin tutarlılığını ve sonuçların istatistiksel olarak test edilmesini zorunlu kıldığını vurgulamaktadır.

Ayrıca, toplu değerlendirme için standartlar geliştiren ve yayınlayan kurumlar Bölüm 2’de ayrıntılı olarak ele alınmıştır. Bu standartlar, ulusal ve uluslararası uygulamalarda değerlendirme süreçlerinin şeffaflığını, karşılaştırılabilirliğini ve güvenilirliğini artırmak açısından kritik önem taşımaktadır.

Toplu değerlendirme süreci, öncelikle veri toplama, veri ön işleme ve taşınmaz kayıtlarının düzenli tutulması gibi ardışık aşamalardan oluşur. Bu aşamalar tamamlandıktan sonra, taşınmazların değerleri (bağımlı değişken) ile özellikleri (bağımsız değişkenler) arasındaki ilişkiyi açıklayan modeller geliştirilir ve parametre tahminleri yapılır. Elde edilen modeller, aynı anda çok sayıda taşınmazın değer tahmininde kullanılarak toplu değerlemenin eşzamanlı ve tutarlı biçimde gerçekleştirilmesini sağlar. Bu noktada modelin güvenilirliği büyük ölçüde kullanılan verilerin kalitesine bağlıdır.

Literatür incelendiğinde, toplu değerlemenin, bilgisayar destekli toplu değerlendirme (CAMA) ve otomatik değerlendirme yöntemleri (AVM'ler) gibi ileri otomasyon çözümlerine geçiş sürecinin; kavramsal belirsizlikler, insan denetimine ilişkin kaygılar ve metodolojik tartışmalar nedeniyle hâlen eleştirel bir çerçevede değerlendirildiği görülmektedir. Bu nedenle, uluslararası standartlar, yasal düzenlemeler ve uygulayıcı görüşleri ışığında, CAMA, AVM, toplu ve tekil değerlendirme kavramlarının terminolojik açıdan sistematikleştirilmesi, bu yöntemler arasındaki benzerliklerin, farklılıkların ve etkileşim mekanizmalarının ortaya konması önemli hale gelmiştir. Şekil 7'de toplu değerlendirme yöntemlerinin kavramsal şeması yer almaktadır.

Şekil 7. Toplu değerlendirme yöntemlerinin kavramsal şeması.



Kaynak: (Renigier-Bîlozor vd., 2022).

Bu diyagramda gelişmiş AVM'leri en dış çerçevede yer almakta ve değerlendirme süreçlerinin dijitalleşme ile yapay zekâ tabanlı dönüşümünü temsil etmektedir. İç kısımdaki kümeler; CAMA, AVM ve tekil değerlendirme (SA) yaklaşımlarını göstermektedir. Bu üç yaklaşımın kesişim alanında toplu değerlendirme (MA) konumlandırılmış olup hem kurumsal uygulamalar hem de piyasa odaklı yöntemlerle ortak yönler taşımaktadır. Grafiğin kenarlarında ise bu yöntemlerin uygulanabilirliğini ve güvenilirliğini belirleyen temel faktörler (teknolojik erişilebilirlik, analiz kapsamı, yasal düzenlemeler, metodoloji, piyasa şartları, amaç ve ihtiyaçlar) gösterilmektedir.

Son yıllarda dijital dönüşümün hız kazanmasıyla birlikte PropTech sektörünün etkisi, istatistiksel yöntemler, yapay zekâ teknikleri ve insan uzmanlığının hibrit modeller aracılığıyla bütünleştirilmesini gündeme getirmiştir. Bu hibrit yaklaşımın, hem operasyonel verimliliği artıracak hem de değerlendirme sonuçlarının güvenilirliğini güçlendireceği ileri sürülmektedir (Renigier-Bilozor vd., 2022).

Literatürde toplu değerlendirme için birçok farklı yöntem kullanılmaktadır. Toplu değerlendirmede kullanılan başlıca hesaplama yöntemleri, teknik kavramlar arasındaki ilişkiler, önde gelen yazarlar ve bulguların derlendiği çalışmalar bu alanda makale sayısının sürekli arttığı ve özellikle son yıllarda üssel bir büyüme gösterdiğini ortaya koymuştur (Dimopoulos & Bakas, 2019; Xu & Zhang, 2021).

Toplu değerlendirmede kullanılan modeller üç ana kategoride sınıflandırılmaktadır: Yapay zekâ Tabanlı Modeller, CBS Tabanlı Modeller ve Karma (MIX) Tabanlı Modeller. Bu sınıflandırma literatürde “3I-Trend” olarak adlandırılmaktadır (D. Wang & Li, 2019).

Yapay zekâ tabanlı modeller, farklı yapay zekâ ve makine öğrenimi tekniklerini içermektedir. Bunlar arasında; Çoklu Regresyon Analizi (MRA - Multiple Regression Analysis), Uzman Sistemleri (ES - Expert System,), Karar Destek Sistemleri (DSS - Decision Support System), Yapay Sinir Ağları (ANN - Artificial Neural Networks), Ağaç Tabanlı Modeller, Hiyerarşik Modeller, Kümeleme Analizi, Kaba Küme ve Bulanık Küme Teorileri (Rough/Fuzzy Set Theory), Genetik Algoritmalar (GA), Destek Vektör Makineleri (SVM) yer almaktadır.

CBS tabanlı modeller, mekânsal istatistik ve konumsal analiz tekniklerine dayanmaktadır. Bu grupta Coğrafi Ağırlıklı Regresyon (GWR - Geographically Weighted Regression), Coğrafi Ağırlıklı Temel Bileşen Analizi (GWRPCA - Geographically Weighted Principal Component Analysis), Mekânsal Hata Modeli (SEM - Spatial Error Model), Mekânsal Gecikme Modeli (SLM - Spatial Lag Model) ve Konum-Değer Tepkisi Yüzeyi (LVRS - Location Value Response Surface) yöntemleri öne çıkmaktadır.

MIX tabanlı modeller ise yapay zekâ ve CBS yaklaşımlarını birleştiren hibrit yöntemlerdir. Bu modeller, yapay zekâ ve coğrafi bilgi sistemleri tekniklerini, geleneksel değerlendirme yöntemleriyle entegre ederek daha kapsamlı çözümler sunar. Bulanık kümeleme, jeo-istatistiksel modelleme, çok kriterli analiz, genetik algoritmalar, yapay sinir ağları, destek vektör makineleri ve CBS tabanlı yöntemlerin birlikte kullanılması, daha güçlü ve güvenilir modellerin geliştirilmesine imkân vermektedir. Bu tür hibrit yaklaşımların karar destek sistemleriyle entegrasyonu, değerlendirme süreçlerinde hem doğruluğu hem de kapsamı artırarak daha etkin sonuçlar elde edilmesine olanak tanımaktadır (D. Wang & Li, 2019). Bu bağlamda bu tez çalışmasında toplu değerlendirme yöntemi olarak MIX Tabanlı Model olan ML-GIS yöntemi benimsenmiştir.

Literatürde toplu değerlendirme çalışmalarında geleneksel yöntemlerden yapay zekâ tabanlı yaklaşımlara kadar geniş bir yöntem çeşitliliği kullanıldığı görülmektedir. Son yıllarda özellikle ağaç tabanlı topluluk öğrenmesi algoritmaları (Random Forest, XGBoost, LightGBM vb.) yüksek doğruluk sağlamaları nedeniyle öne çıkmıştır. Bu kapsamda, incelenen çalışmalarda kullanılan yöntemler, veri setleri, değişkenler ve bulgular Tablo 2’de özetlenmiştir.

Tablo 2. Literatürdeki Toplu Değerleme Çalışmalarında Kullanılan Veri Setleri, Metot ve Bulguların Özeti.

No	Yazar	Çalışma Alanı	Veri Sayısı	Değişken	Metot	Bulgular
1.	(Michae Dellstad, 2018)	İsveç	57.974	44	SVM, ANN ve RF	RF diğer modellere göre daha başarılı olmuştur.
2.	(Čeh vd., 2018)	ljubljana, Slovenya	7.407	35	RF ve LR	RF, LR göre daha iyi sonuç vermiştir.
3.	(Torres-Pruñonosa vd., 2021)	Brezilya	1.223.582	19	RF ve RNN	RF daha iyi sonuç verdiği görülmüştür.
4.	(Akar & Yalpir, 2021)	Konya	319	31	SVM ve MRA	SVM 0.88, MRA ise 0.86 R^2 değeri elde etmiştir.
5.	(Savaş, 2019)	Gölbaşı, Ankara	95	42	SVM ve MRA	SVM daha başarılıdır.
6.	(Vargason, 2019)	Salamanca, Madrid	2.266	70	RF, SVM ve KNN	RF algoritması 0.17 RMSE değeri ile en başarılı sonucu vermiştir.
7.	(Guliker vd., 2022)	Hollanda	12.594	31	LR, GWR, MGWR, XGBoost	Uygulanan modellerden, XGBoost modeli 0.83 R^2 ile en yüksek doğruluğa sahiptir.
8.	(Dimopoulos vd., 2018)	Kıbrıs	3.527	15	RF, MRA	RF daha iyi performans göstermiştir.
9.	(Teoh vd., 2023)	Melbourne Ames	2.930 34.857	26	LR, RF	İki şehirde de RF algoritması en yüksek R^2 ile tahmin etmiştir.

10.	(H. Yang vd., 2020)	Boston Ames	506 2930	14 80	Lasso, RF, DNN, XGBoost, SVM	XGBoost ve RF, en düşük MSE ve MAPE ile en yüksek R^2 değerlerine sahip olarak konutların medyan fiyatını tahmin eden en iyi algoritmalarıdır.
11.	(Hjort vd., 2024)	Oslo, Norveç	14.382	15	GAM, GBM, LitBoost	Litboost daha başarılı performans göstermiştir.
12.	(Krämer vd., 2023)	Almanya	1.200.000	38	LR, GAM, XGBoost, ANN	XGBoost algoritması MAPE değeri diğer modellerle karşılaştırınca daha düşüktür.
13.	(Zhang vd., 2024)	Kanada	10.418	10	GBM, SVM, RF, ANN	GBM hem sayısal hem de açıklama verileri kullanılarak en iyi model olmuştur.
14.	(Zaki vd., 2022)	ABD	506	13	HPM, XGBoost	XGBoost algoritması 0.84 R^2 değeri ile daha başarılı olmuştur.
15.	(Gao vd., 2022)	Sidney, Avustralya	63.426	18	GWR, LR, Lasso, RR, ElasticNet, DT, RF, GBM, XGBoost, ANN	GBM yüksek doğruluk oranıyla başarılı olmuştur.
16.	(Zhao vd., 2019)	Canberra, Çin	248	-	CNN, KNN ve XGBoost.	En düşük 8.70 MAPE oranıyla XGBoost algoritması başarılı olmuştur.
17.	(Soltani vd., 2022)	Adelaide, Avustralya	428.000	38	LR, DT, GBM	En yüksek 0.89 R^2 değeri ile GBM algoritması başarılı olmuştur.

18.	(Iban, 2022a)	Mersin, Türkiye	1.002	44	RF, GBM, XGBoost, LightGBM, LR	GB R^2 0.90 ve XGBoost en düşük MAPE değeri 0.09 ve RMSE 146.83 ile başarı göstermiştir.
19.	(Hjort vd., 2022)	Norveç	126.719	26	LR, KNN, RF, XGBoost	XGBoost algoritması R^2 91.9 değeri ile daha başarılı olmuştur.
20.	(Rampini & Re Cecconi, 2022)	İtalya	1.203	8	ElasticNet, XGBoost, ANN	ANN 77.01, XGBoost 81.02 ve ElasticNet 92.98 MAE skoru olarak ANN daha başarılı bir sonuç elde etmiştir.
21.	(Steurer vd., 2021)	Graz, Avusturya	18.957	17	LR, RF, MARS, Lasso, ANN	RF modeli en iyi performansı göstermiştir.
22.	(Stanišić vd., 2021)	Belgrad, Sırbistan	12.904	41	BHPM, LR, GBM, RF, XGBoost	RF 81.78 ve XGBoost 81.02 R^2 değeriyle başarılı sonuçlar vermiştir.
23.	(Marzagão vd., 2019)	Brezilya	15.627	21	LR, SVM, ANN, BT, RF	RF 8.14 MAE ile daha başarılı olmuştur.
24.	(Ho vd., 2021)	Hong Kong	40.000	13	SVM, RF, GBM	RF algoritması R^2 0.90 ve GBM algoritması R^2 0.90 ile başarılı olmuşlardır.

25.	(Lin vd., 2023)	Çin	120.403	37	KNN, GBM, OLS	GBM, R^2 0.96 değeri ile daha başarılıdır.
26.	(Bogin & Shui, 2020)	ABD	4.203.709	24	RF, Boosting, OLS, ElasticNet, Lasso, RR	R^2 değeri en yüksek olan model RF olmuştur.
27.	(Hong vd., 2020)	Güney Kore	16.061	21	HPM, RF	RF en düşük MAPE 5.48 ve en yüksek R^2 0.97 ile başarılı olmuştur.
28.	(Gnat, 2021)	Polonya	318	-	MRA, KNN, XGBoost,	KNN ve XGBoost daha başarılı olmuştur.
29.	(Y. Huang, 2019)	California, Los Angeles, ABD	89.412	26	LR, DT, GBM, RF, SVM	Ağaç tabanlı modeller daha başarılıdır.
30.	(Dimopoulos & Bakas, 2019)	Kıbrıs	3.561	9	RF, GB, LR, NLR	En düşük MAE ile GB algoritması başarılı olmuştur.
31.	(İban, 2021)	Melbourne, Avustralya	6.858	15	RF, GB, Adaboost	GB ve RF modellerinin korelasyon katsayısı sırasıyla 0.97 ve 0.90 olarak başarılı bulunmuştur.
32.	(Koktashev vd., 2019)	Rusya	1.970	10	RR, RF, LR	En düşük MAE ile RF algoritması başarılı olmuştur.

33.	(Allard & Hagström, 2021)	Stockholm	8.405	20	RF, XGBoost, LightGBM, CatBoost	XGBoost, LightGBM, CatBoost sırasıyla 0.907, 0.913, 0.914 R^2 değeri ile başarı göstermiştir.
34.	(S. Li vd., 2021)	Shenzhen, Çin	12.137	35	XGBoost-HPM	XGBoost 0.94 R^2 değeri ile başarılı olmuştur.
35.	(Stang vd., 2023)	Almanya	1.2M	37	OLS, GAM, XGBoost	XGBoost 0.89 R^2 değeri ile daha başarılı olmuştur.
36.	(Yoshida vd., 2022)	Japonya	4.588.632	10	OLS, NNGP, DNN, RF, XGBoost	XGBoost en düşük MAPE değerine sahip olarak başarılı olmuştur.
37.	(Çılgın vd., 2023)	Ankara	18.420	24	LR, Lasso, RR, NN, XGBoost	XGBoost ve NN en düşük MAPE değerine sahip olarak başarılı olmuştur.
38.	(Sağlam vd., 2023)	Melbourne, Avustralya	13.580	13	LR, DT, RF, Bagging, AdaBoost, GBM, XGBoost	RF ve XGBoost algoritmaları yakın ve daha doğru R^2 değerine sahip olmuştur.
39.	(Jafary vd., 2024)	Melbourne, Avustralya	26.700	26	SVR, DNN, RF, XGBoost	XGBoost algoritması 0.86 R^2 değeri ile başarılı olmuştur.

40.	(Sajol & Uddin, 2024)	Dakka Chittagong, Bangladeş	8000	11	SVM, DT, KNN, LightGBM, RF, LightGBM birinci 0.85 ve XGBoost XGBoost, LR, 0.94 R^2 ise ikinci en iyi model Kernel RR, olduğunu gösterdi. ElasticNet
41.	(Ghamrawi & Nat, 2024)	Denver, Colorado	15.000	11	DT, GB, LightGBM, RF, RR 0.83, GB ve XGBoost 0.82 R^2 XGBoost, LR, RR, değeri ile başarılı olmuştur. ElasticNet, Lasso
42.	(Ostrikova & Selyutin, 2024)	Rusya	6.847	9	LR, LightGBM, İleri ML algoritmaları 0.87 R^2 değeri XGBoost, CatBoost ile başarılı olmuştur.
43.	(Neves vd., 2024)	Lizbon, Portekiz	23.781	26	XGBoost, AdaBoost, ANN, XGBoost 0.79 ve RF 0.78 R^2 değeri RF ile başarılı olmuşlardır.
44.	(Yagmur, 2025)	Berlin, Munich, Cologne, Stuttgart, Dusseldorf, 233 City Frankfurt, Almanya		14	XGBoost, RF Test veri kümesinin genel doğruluğu %62.63'tür.

45.	(Rolli, 2020)	Ventura, Orange ve Los Angeles, Californiya	90.275	26	LR, GB, BRR, RR, RF, XGBoost	GB ve XGBoost yakın ve 0.0530 gibi en düşük MAE değeri ile başarılı olmuştur.
46.	(Stang, 2023)	Berlin, Munich, Cologne, Stuttgart, Dusseldorf, Frankfurt,Almanya	1.212.546	37	OLS, XGBoost	XGBoost modeli tüm bölgelerde daha yüksek R^2 değeri ile başarılı olmuşlardır.
47.	(Eriksen & Müller, 2024)	Oslo, Norveç	353.997	18	LAD, CSRS, KNN, XGBoost	XGBoost modeli diğer modellere kıyasla daha düşük MAPE değeri ile başarılı olmuştur.
48.	(Tarasov & Dessoulavy-Śliwiński, 2025)	Varşova, Polonya	10.827	56	RF, XGBoost	XGBoost ve RF modeli sırasıyla 0.089 ve 0.091 MAPE değeri ile XGBoost daha başarılı olmuştur.
49.	(Sharma vd., 2024)	Ames, ABD	2.930	10	LR, RF, SVM, MLP, XGBoost,	XGBoost 0.92 R^2 değeri ile başarılı olmuştur.
50.	(Sapakova & Sapakov, 2024)	Almaty, Kazakistan	3.882	23	LR, Lasso, ElasticNet, RF, RR, DT	RF 0.90 R^2 değeri ile başarılı olmuştur.

51. (Oust vd., 2025)	Oslo, Bergen ve Trondheim, Avustralya	6.651, 2.975, 1.677	12	SVR, XGBoost, DNN, RF	0.96 R^2 değeri ile başarılı olmuştur.
52. (Mayer vd., 2019)	İsviçre	123.000	21	OLS, RLM, MEM, RF, GBM, NN	En düşük MAE 0.16 ve RMSE 0.234 değeri ile GBM modeli daha başarılı olmuştur.
53. (Et. Al., 2021)	Boston	1500	80	XGBoost	4.4 karesel ortalama hata ile başarılı sonuç elde etmiştir.
54. (Z. Li, 2022)	Chicago	2.500	16	SLM, XGBoost, MGWR	XGBoost modeli 0.893 R^2 değeri ile daha başarılı olmuştur.
55. (Peng vd., 2019)	Chengdu, Çin	27.961	11	MRA, DT, XGBoost	XGBoost modeli 0.925 R^2 değeri ile daha başarılı olmuştur.
56. (T. Wang vd., 2021)	Christchurch, New Zealand	108.000	16	LR, KNN, SVM, RF, GBDT, XGBoost, LightGBM, CatBoost, DL	CatBoost modeli en düşük RMSE değeri ile daha başarılı olmuştur.

57.	(Silhavy vd., 2021)	King Seattle	County,	21.613	21	LR, BR, ETR, LightGBM, Stacking	LightGBM ve Stacking modelleri birbirine oldukça yakın ve en düşük RMSE değeri almıştır.
58.	(Yilmazer & Kocaman, 2020)	Mamak, Ankara		1.200	37	MRA, RF	RF modeli 0.734 R^2 değeri ile daha başarılı olmuştur.
59.	(Aydinoglu vd., 2021)	Pendik, İstanbul		1.459	34	RF	RF modeli 0.08 RMSE ve 0.05 MAE değerine ulaşılmıştır.
60.	(García-Magariño vd., 2020)	Çin		89	13	LR, SVR, NN, KNN	SVR modeli daha başarılı olmuştur.
61.	(Schirm vd., 2019)	Şile		334.353	25	ANN, RF, SVM	RF modeli en düşük 0.096 MAE değeri ile daha başarılı olmuştur.
62.	(Mohamad & Ismail, 2019)	Kota, Kelantan, Malezya	Bharu,	893	25	Ridge, Lasso, LR, DT, RF	RF modeli daha başarılı olmuştur.
63.	(Ja'afar & Mohamad, 2021)	Malezya		248	19	Ridge, Lasso, LR, DT, RF	RF modeli 0.917 R^2 değeri ile daha başarılı olmuştur.
64.	(Garcia vd., 2022)	Alicante, İspanya		39.343	-	LR, RF, ET, GB, XGBoost, LightGBM	GBR modeli 0.92 R^2 değeri ile daha başarılı olmuştur.

65.	(Choy & Ho, 2023)	Hong Kong, Çin	24.317	17	RF, OLS	RF modeli 0.92 R ² değeri ve 8.89% MAPE oranıyla başarılı olmuştur.

Support Vector Machines (SVM), Artificial Neural Network (ANN), Random Forest (RF), Linear Regression (LR), Recurrent Neural Networks (RNN), K-nearest neighbors (KNN), Multiple Regression Analysis (MRA), Geographically Weighted Regression (GWR), Multi-Scale Geographically Weighted Regression, (MGWR), Extreme Gradient Boosting (XGBoost), Least Absolute Shrinkage and Selection Operator (Lasso), Deep Neural Network (DNN), Generalized additive models (GAM), Gradient Boosting Model (GBM), Gradient Boosting (GB), Hedonic Price Model (HPM), Ridge Regression (RR), Decision Tree (DT), Light Gradient Boosting Machine (LightGBM), Multivariate Adaptive Regression Splines (MARS), Bayesian Hedonic Regression Model (BHRM), Boosted Tree (BT), Non-Linear Regression (NLR), Adaptive Boosting (AdaBoost), Category Boosting (CatBoost), Nearest Neighbor Gaussian Processes (NNGP), Bayesian Ridge Regression (BRR), Ordinary Least Square (OLS), Least Absolute Deviation (LAD), Case-Shiller Repeated Sales (CSRS), Multi-Layer Perceptron (MLP), Spatial Lag Model (SLM) Deep Learnin (DL) Extra-Trees Regression (ETR) Bagging Regression (BR), Extreme Learning Machine (ELM), Extra Trees (ET), Principal Component Analysis (PCA).

Literatürde incelenen çalışmaların büyük bir kısmında, tahmin doğruluğu açısından en başarılı sonuçların ağaç tabanlı makine öğrenmesi algoritmaları ile elde edildiği görülmektedir. Deneysel bulgular, bu algoritmaların yüksek performans doğruluğunun yanı sıra model yapısının görece sade olması, değişkenlerin katkılarının kolaylıkla yorumlanabilmesi ve farklı veri türlerine uyum sağlayabilmesi gibi avantajlara sahip olduğunu ortaya koymaktadır. Bu doğrultuda, tez kapsamında konut değeri tahmini amacıyla Ensemble Learning yaklaşımlarından hem Bagging tabanlı hem de Boosting tabanlı algoritmalar uygulanmıştır. Bagging tabanlı yöntemler arasında Random Forest Regressor, Extra Trees Regressor ve Bagging Regressor; Boosting tabanlı yöntemler arasında ise Gradient Boosting Regressor, AdaBoost Regressor, XGBoost Regressor, LightGBM Regressor ve CatBoost Regressor tercih edilmiştir. Böylece, literatürde raporlanan yüksek doğruluk oranlarının yanı sıra, farklı topluluk yöntemlerinin model başarısına etkileri de kapsamlı biçimde karşılaştırmalı olarak değerlendirilmiştir.

Literatürde öne çıkan yöntemler ve performans karşılaştırmaları bu şekilde özetlendikten sonra, değerlendirme çalışmalarında hangi değişkenlerin taşınmaz fiyatlarını etkilediği sorusu önem kazanmaktadır.

4.3. Değişkenlerin Belirlenmesi

IAAO standartlarına göre, konut türü gayrimenkullerin değerinin tahmininde çeşitli özellikler dikkate alınmaktadır (IAAO, 2018). Yaşam alanı, yapı kalitesi, temel ve dış duvar tipi gibi temel bileşenlerin yanı sıra bina yaşı, tasarımı, bodrum, balkon, garaj, banyo sayısı ve merkezi klima gibi unsurlar da fiyat üzerinde belirleyici rol oynamaktadır. Ayrıca müstakil ek yapılar, altyapı olanakları (kanalizasyon, su, elektrik), market veya pazar alanına yakınlık, site imkânları ve manzara gibi özellikler değeri artırabilirken; yoğun trafik, havaalanı gürültüsü veya ticari kullanımlara yakınlık gibi çevresel faktörler değer kaybına yol açabilmektedir. Ancak değerlendirme değişkenleri ülkeler arasında farklılık gösterebildiğinden, bunların tek bir standart altında toplanması güçtür.

Yeterli sayıda satış verisi mevcut olduğunda, değerlendirme sürecinin en kritik aşaması söz konusu taşınmaza ilişkin güvenilir ve doğru verilerin toplanmasıdır.

Konutun temel fiziksel özellikleri ile çevresel ve mahalle düzeyindeki veriler genellikle resmî kurumlar tarafından yayınlanan kaynaklardan temin edilmektedir. Bu nedenle hem nicelik hem de nitelik açısından kapsamlı veri setlerine dayalı çalışmalar, değer tahminlerinde daha tutarlı sonuçlar sağlamaktadır (Guliker vd., 2022).

Değerleme değişkenlerinin önem sırası, farklı paydaş gruplarında değişkenlik gösterebilmektedir. (Sajnog & Jaskolska, 2024), potansiyel alıcılar ve sektörde çalışan profesyoneller üzerinde yaptıkları ankette, her iki grupta da konum, konut alanı, binanın yapısal durumu, otopark ve şehir merkezine mesafenin en etkili beş faktör olduğunu ortaya koymuştur. Literatürde, özellikle konutun fiziksel özellikleri fiyat belirlemede en ayırt edici unsurlar arasında yer almakta (Amri, 2012; Brander & Koetse, 2011; So vd., 1997) ve birçok vergi modelinde en sık kullanılan değişkenler olarak öne çıkmaktadır. Bina yaşı, konut alanı, oda ve banyo sayısı, asansör ve otopark gibi değişkenlerin fiyat üzerindeki etkisine ilişkin çok sayıda çalışma bulunmaktadır (Goodman, 1978; Zhou vd., 2018).

Konumsal özellikler de konut fiyatlarının belirlenmesinde kritik bir rol üstlenmektedir (Brander & Koetse, 2011). Şehir merkezine, alışveriş merkezlerine ve yeşil alanlara yakınlık genellikle fiyatlar üzerinde pozitif etki yaratırken (Gong, 2017), ibadet merkezine yakınlık hem olumlu hem de olumsuz etkiler gösterebilmektedir (Fuerst vd., 2015). Ulaşım altyapısına yakınlık erişim avantajı sağlasa da, gürültü kirliliği nedeniyle değer kaybına neden olabilir (Henri L.F. de Groot, 2009). Kültürel simgeler genellikle hafif pozitif etki yaratırken, işsizlik oranı negatif etki göstermektedir (McMillen, 2004). Benzer biçimde, manzara gibi görsel nitelikler fiyatı artırırken; rüzgâr türbinleri veya yoğun yapılaşma olumsuz etkiler doğurabilmektedir (Fischer & Getis, 2010; Gong, 2017).

Mahalle düzeyindeki sosyoekonomik göstergeler de konut değerlerini etkiler. Ortalama hane halkı gelirinin yüksek olması genellikle yüksek fiyatlı konutlarla ilişkilidir; suç oranındaki artış ise güvenlik algısını zayıflatarak fiyatları düşürmektedir (Ambrose vd., 2013). Ayrıca konut stokunun fazla olması ve nüfus yoğunluğunun belirli seviyelere kadar artması, fiyatlar üzerinde pozitif etki yaratabilmektedir.

Sonuç olarak, taşınmaz değerlendirme süreci; yapısal, coğrafi ve yerel faktörlerin bütüncül bir yaklaşımla değerlendirilmesini gerektirir. Bu değişkenlerin doğru ölçülmesi ve güvenilir veri kaynaklarıyla desteklenmesi, tahmin doğruluğunu artırarak daha sağlıklı sonuçlar elde edilmesini sağlar. Bu bağlamda, çalışmada kullanılacak değişken seti; literatür bulguları, uluslararası standartlar ve yerel piyasa dinamikleri dikkate alınarak belirlenmiştir. Bölüm 5’te değişkenler, konutların yapısal, coğrafi ve yerel özellikleri olmak üzere üç ana başlık altında toplanmış ve her bir grupta, değere etkisi literatürce desteklenen ölçütlere yer verilmiştir. Böylece, modelin hem teorik hem de uygulamalı olarak sağlam bir temele dayandırılması hedeflenmiştir.

4.4. Coğrafi Bilgi Sistemleri

CBS, konum bilgisine sahip verilerin toplanması, depolanması, yönetilmesi, analiz edilmesi ve görselleştirilmesini sağlayan bütünleşik bilgi sistemleridir (Longley vd., 2015). Veri, donanım, yazılım, insan ve yöntemler gibi bileşimlerden oluşan CBS, karar verme süreçlerinde kritik bir destek aracı olarak öne çıkar.

Tarihte CBS benzeri bir yaklaşım ilk kez 1854 yılında Dr. John Snow tarafından kolera salgınının kaynağını belirlemek amacıyla coğrafi verilerin görselleştirilmesinde kullanılmıştır (*History of GIS*, 2025). Ardından, 1959’da Waldo Tobler’in “MIMO” (harita girişi-harita çıkışı) paradigmasıyla bilgisayar destekli kartografyayı başlatmasıyla olgunlaşmıştır. 1960’larda “CBS’nin babası” olarak atfedilen Roger Tomlinson’ın Kanada Coğrafi Bilgi Sistemini geliştirmesi ve yaptığı uygulamalar sayesinde raster ve vektör veri modelleri tanımlayarak CBS’yi deneysel bir araçtan kurumsal bir disiplin hâline taşımıştır. 1970–80’lerdeki ilk uluslararası konferanslar, ARC/INFO ve GRASS gibi yazılımlar, ESRI öncülüğünde hem akademik hem de endüstriyel düzeyde CBS kullanımını yaygınlaştırmıştır (Dempsey, 2015). 1990’lardan 2010’a kadar geçen dönemde CBS, maliyetlerin düşmesi, işlem hızı ve kapasitesinin artması, ticari yazılım seçeneklerinin çeşitlenmesi ile dijital harita verilerinin erişilebilirliğinin sağlanması gibi bilişim teknolojilerindeki ilerlemeler sayesinde ana akım bir araç hâline gelmiştir (*The Beginning of GIS: The History of Geographic Information Systems*, 2022). Aynı dönemde uzaktan algılama tekniklerinin CBS ortamına entegrasyonu ve yeni nesil dünya gözlem uydularının devreye alınması, CBS uygulamalarının ölçek ve kapsamını genişletmiştir. Sonuç

olarak, CBS; akademik eğitim kurumlarından özel sektöre ve kamu yönetimlerine kadar geniş bir yelpazede kullanılmaya başlanmıştır. 2010'dan itibaren CBS ekosisteminde açık kaynaklı çözümlerin yükselişi, coğrafi veri setlerinin genel erişime açılması ve bulut bilişim ile mobil teknolojilerin yaygınlaşması gözlenmiştir. Bu gelişmeler, coğrafi verilerin çevrimiçi olarak depolanması, paylaşılması ve mobil cihazlar üzerinden analiz edilmesine imkân vererek CBS'nin hem kullanım kolaylığını hem de erişim alanını önemli ölçüde genişletmiştir. Ulusal ve uluslararası Mekânsal Veri Altyapıları (NSDI, INSPIRE) ile Açık CBS Konsorsiyumu (OGC) standartları, coğrafi verinin paylaşımını ve birlikte çalışabilirliğini güvence altına alarak CBS'in kurumsal olgunluğunu pekiştirmiştir.

Türkiye'de CBS alanındaki koordinasyon, Çevre, Şehircilik ve İklim Değişikliği Bakanlığı bünyesindeki Coğrafi Bilgi Sistemleri Genel Müdürlüğü tarafından yürütülmektedir. Bu kurum, Ulusal CBS'nin kurulması, işletilmesi ve geliştirilmesinin yanı sıra, yerel yönetimlerin kent bilgi sistemlerine ilişkin standartların belirlenmesinden ve Ulusal Coğrafi Bilgi Portalı'nın yönetiminden sorumludur (*Coğrafi Bilgi Sistemleri Genel Müdürlüğü*, 2025). Bu kapsamda önemli yasal ve kurumsal adımlar atılmıştır:

- 49 Sayılı Coğrafi Bilgi Sistemleri Hakkında Cumhurbaşkanlığı Kararnamesi
- 7221 Sayılı Coğrafi Bilgi Sistemleri ile Bazı Kanunlarda Değişiklik Yapılması Hakkında Kanun
- Ulusal Akıllı Şehirler Stratejisi ve Eylem Planı Hakkında Cumhurbaşkanlığı Genelgesi
- Coğrafi Bilgi Sistemlerine İlişkin Oluşturulan Kurullar ve Çalışma Heyetleri Hakkında Yönetmelik
- Coğrafi Bilgi Sistemi Uzmanlığı Yönetmeliği
- Türkiye CBS Kurulu Kararları
- Türkiye CBS Yürütme Kurulu Kararları

Son yıllarda, büyük veri kavramının öne çıkmasıyla birlikte CBS'nin yüksek hacimli mekânsal veri işleme ve analiz kapasitesi daha fazla önem kazanmıştır. Uydu

görüntüleri, ortofotolar, sayısal yükseklik modelleri ve LIDAR verileri gibi kaynaklar gigabaytlarca veri üretmekte; bu verilerin coğrafi bulut platformları aracılığıyla hızlı analiz edilmesi, yeni mekânsal desenlerin keşfine ve konum zekâsı odaklı karar süreçlerine katkı sağlamaktadır. Geleneksel tablo ve grafik temelli istatistiksel analizlerin yerini, etkileşimli, katmanlı ve yorum kolaylığı sağlayan akıllı haritalar almıştır. Bu haritalar, karar vericilerin eğilimleri kavramasına, kaynak tahsisini optimize etmesine ve karmaşık projelerde koordineli adımlar atmasına imkân tanımaktadır.

CBS’de veriler, ilişkisel veri tabanlarında saklanır ve gerektiğinde sorgu–analiz işlemleriyle ham veriden anlamlı bilgi üretilir. İki temel veri modeli bulunur:

- Vektör veri: Nokta, çizgi ve poligon geometrileri aracılığıyla nesnelerin temsil edildiği model.
- Raster veri: Piksellerden oluşan sürekli matris yapısıdır ve uydu görüntüleri, sayısal yükseklik modelleri, arazi örtüsü/kullanımı haritaları gibi verileri içerir.

CBS işlevlerinin yürütülmesi için çeşitli yazılımlar kullanılmaktadır. ArcGIS, QGIS, GRASS, SAGA, uDig, OpenJump ve gvSIG bunlar arasındadır. ArcGIS, kullanıcı dostu arayüzü, ileri düzey analiz yetenekleri ve geniş kullanıcı topluluğu ile öne çıkmakta; QGIS ise açık kaynak kodlu olması ve modüler yapısıyla yaygın bir alternatif sunmaktadır. ESRI’nin masaüstü çözümleri arasında ArcMap ve ArcGIS Pro bulunmakta olup, ArcMap desteği sonlandırılarak geliştirmeler yalnızca ArcGIS Pro üzerinden sürdürülmektedir.

Bu çalışmada, veri setinin mekânsal olarak zenginleştirilmesi ve konuma bağlı değişkenlerin üretilmesi amacıyla CBS tekniklerinden yararlanılmıştır. Çalışma alanı olan Yenimahalle ve Keçiören ilçelerine ait coğrafi veriler ArcGIS Pro yazılımında işlenmiştir. Analiz sürecinde taşınmazların belirli mekânsal kriterlere (havalimanına, eğitim kurumlarına, yeşil alanlara mesafe vb.) olan uzaklıkları, nüfus ve eğitim değerleri ile çevresel etki alanı değişkenleri üretilmiştir. Bu değişkenler, konut fiyatlarının mekânsal dağılımının modellenmesinde temel girdiler olarak kullanılmıştır.

Öte yandan konut değerlerinin mekânsal dağılımının görselleştirilmesi ve analiz edilmesinde kullanılan hücre geometrisi, elde edilen sonuçların doğruluğu, yorumlanabilirliği ve karar destek süreçlerindeki kullanılabilirliği açısından kritik bir önem taşımaktadır. Bu çalışmada, değer haritasının üretiminde altıgen ızgara yapısı tercih edilmiştir.

Altıgen ızgara yapısı, yön bağımsız (izotropik) komşuluk ilişkisi sunması nedeniyle mekânsal analizlerde öne çıkan üstün bir geometrik tercihtir. Kare veya üçgen tabanlı ızgaralarda görülen yönsel farklılıkların aksine, altıgen hücrelerin tüm komşuları eşit uzaklıkta ve tek tiptir. Bu özellik, mekânsal süreçlerin izotropik varsayımlarıyla daha uyumlu sonuçlar üretmektedir. Ayrıca, altıgen ızgaralar komşuluk temelli özet istatistiklerin (örneğin, ortalama, medyan, varyans) daha dengeli hesaplanmasına olanak tanımaktadır. Bu yapı, mekânsal yumuşatma (*smoothing*) ve sağlam (*robust*) analiz uygulamalarında avantaj sağlayarak hücre bazlı varyansı azaltmakta ve model çıktılarının kararlılığını artırmaktadır. Bunun yanı sıra, altıgen hücreler mekânsal sürekliliği daha gerçekçi biçimde yansıtarak görselleştirmelerde yüksek okunabilirlik sunmaktadır. Çok çözünürlüklü yapısı sayesinde ise farklı ölçeklerde hem genelleştirilmiş hem de ayrıntılı haritaların üretimine imkân tanımaktadır.


Bu kapsamda, ArcGIS Pro'daki Generate Tessellation aracı ile çalışma alanı üzerinde eşit boyutlu altıgen ızgaralar üretilmiş; her bir ızgara hücresine düşen konutların ortalama değerleri yansıtılmıştır. Böylece, konut değerlerinin mekânsal dağılımı görselleştirilmiş ve sonuçlar web ortamında servis edilerek kullanıcı erişimine açılmıştır.

4.5. Yapay Zekâ ve Makine Öğrenmesi Yöntemleri

Yapay zekâ, bilgisayar sistemlerinin insan zekâsına özgü işlevleri taklit ederek karar verme, problem çözme, öğrenme ve yorumlama süreçlerini üstlenmesini sağlayan geniş kapsamlı bir alandır. Yapay zekânın en önemli alt dallarından biri olan ML, bilgisayarların açıkça programlanmadan, geçmiş verilere dayanarak örüntüleri tanımasını ve bu doğrultuda tahminler üretmesini mümkün kılar. Makine öğrenmesi içinde yer alan derin öğrenme ise, insan beyninin sinir ağlarını taklit eden yapay sinir

ağları kullanarak çok katmanlı ve karmaşık veri yapılarından anlamlı sonuçlar çıkarabilen bir yöntemdir. Özellikle büyük hacimli ve çok boyutlu verilerde öne çıkan derin öğrenme, günümüzde görüntü işleme, doğal dil işleme ve ses tanıma gibi alanlarda yoğun biçimde kullanılmaktadır.

Şekil 8. Yapay zekâ, makine öğrenmesi, derin öğrenme hiyerarşisi.



Söz konusu kavramlar arasındaki hiyerarşik ilişki Şekil 8’de gösterilmektedir. Buna göre, yapay zekâ en geniş üst alanı temsil ederken; ML, yapay zekânın veri temelli öğrenme yaklaşımlarını kapsayan bir alt disiplini olarak konumlanmaktadır. Derin öğrenme ise ML’in bir alt dalı olarak, özellikle büyük ve karmaşık veri setleri üzerinde üstün performans göstermektedir.

Yapay zekâ alanının kökeni, 1950’lerde Frank Rosenblatt’ın geliştirdiği perceptron algoritmasına dayanmaktadır. Perceptron, yapay sinir ağlarının temelini atmış ve sonraki yöntemlerin çıkış noktası olmuştur. Bunu, 1967’de Cover ve Hart’ın ortaya koyduğu en yakın komşu (k-NN) algoritması izlemiş, böylece sınıflandırma ve regresyon problemlerine yönelik örnek tabanlı öğrenme yaklaşımı literatüre kazandırılmıştır. Bu ilk adımlar, günümüzde gayrimenkul değerlendirme çalışmalarında da kullanılan denetimli öğrenme yöntemlerinin teorik temelini oluşturmuştur.

1970’ler ve 80’lerde “Yapay zekâ kışı” yaşanmış olsa da 1990’lı yıllarda hesaplama gücü ve optimizasyon tekniklerinin gelişmesiyle ML yeniden ivme

kazanmıştır. Özellikle topluluk öğrenmesi yaklaşımları ve ağaç tabanlı yöntemler, tahmin performansının artırılmasında kritik rol oynamıştır. International Business Machines Corporation (IBM) tarafından geliştirilen Deep Blue ve TD-Gammon projeleri, bu dönemin simgesel başarı örnekleri olarak öne çıkmıştır.

2000’li yıllardan itibaren derin öğrenme kavramı yapay zekâ literatürüne girmiş, Fei-Fei Li’nin başlattığı ImageNet projesi büyük ölçekli veri setlerinin model performansını nasıl geliştirdiğini göstermiştir. Takip eden dönemde AlphaGo, DeepFace ve benzeri sistemler, derin öğrenmenin karmaşık problem çözmedeki gücünü ortaya koymuştur. 2017’de Vaswani ve arkadaşlarının geliştirdiği transformer mimarisi, günümüzde büyük dil modellerinin temelini atarak doğal dil işleme alanında bir devrim yaratmıştır.

Bu tarihsel süreç, yalnızca yapay zekânın evrimini değil, aynı zamanda günümüzde toplu değerlendirme çalışmalarında kullanılan yöntemlerin bilimsel arka planını da şekillendirmiştir. Özellikle ağaç tabanlı yöntemler (Random Forest, XGBoost, LightGBM, CatBoost) ve toplu öğrenme yaklaşımları, gayrimenkul değerlendirme modellerinde öne çıkan algoritmalar haline gelmiştir.

Makine öğrenmesi algoritmaları kullanarak bir problemi çözme süreci genellikle dört aşamadan oluşur: veri toplama ve hazırlama, modelin eğitilmesi, modelin doğrulanması ve sonuçların analizi. İlk aşamada, problemle ilgili veriler toplanır ve gerekli durumlarda ön işleme tabi tutulur. İkinci aşamada, verilerin büyük kısmı modelin eğitilmesi için kullanılırken, daha küçük bir kısmı test amacıyla ayrılır. Üçüncü aşamada, test verisiyle modelin performansı değerlendirilir. Son aşamada ise elde edilen sonuçlar, farklı analiz yöntemleriyle yorumlanarak genel başarı değerlendirilir.

Öğrenme, bir sistemin, verilen veriler doğrultusunda doğru sonuçlar üretecek şekilde eğitilip uyarlanması sürecidir. Bu süreçte model tipik olarak iki temel aşamadan geçer: Eğitim Seti ve Test Seti. Eğitim seti, modelin verilerden örüntüleri öğrenmesi için kullanılırken; test seti, modelin doğruluk ve genelleme yeteneğini ölçmek amacıyla ayrılır. Genellikle verilerin %80–85’i eğitim için, %15–20’si ise test

için kullanılır. Böylece modelin yalnızca öğrenme sürecindeki değil, daha önce görmediği verilerdeki başarısı da güvenilir biçimde değerlendirilebilir.

Makine öğrenimi uygulamaları, öğrenme şekline yani veri etiketleme durumuna göre üç ana kategoriye ayrılmaktadır. Denetimli öğrenme (*Supervised Learning*), girdi verileri ile bunlara karşılık gelen çıktılar (etiketler) kullanılarak modelin eğitildiği yöntemdir. Denetimsiz öğrenme (*Unsupervised Learning*), etiketlenmemiş verilerden örüntü ve yapı keşfetmeye dayanır. Pekiştirmeli öğrenme (*Reinforcement Learning*) ise deneme-yanılma ve geri bildirim mekanizması üzerinden öğrenme sağlar.

Bunun yanı sıra, makine öğrenmesi görevleri üretilen çıktının türüne göre sınıflandırılabilir. Sınıflandırma (*Classification*) problemleri, örnekleri önceden tanımlı etiketler üzerinden kategorilere ayırır; örneğin bir hücrenin kanserli olup olmadığını belirlemek veya el yazısıyla yazılmış rakamları tanımak bu kapsama girer. Kümeleme (*Clustering*) ise denetimsiz öğrenme yöntemlerinden biridir ve veri noktalarını etiket bilgisi olmadan benzerlik temelli gruplara ayırır. Pazar sepeti analizi ve öneri sistemlerinde yaygın olarak kullanılan bu teknik, verinin yapısını keşfetmek amacıyla kullanılmaktadır. Regresyon (*Regression*) problemleri, sürekli sayısal değerleri tahmin etmeye yöneliktir; örneğin bir çalışanın maaş düzeyinin tahmin edilmesi. Gayrimenkul değerlendirme çalışmalarında da konut fiyatı gibi sürekli değişkenlerin tahmin edilmesinde yaygın biçimde kullanılan bu algoritmalar, sonraki alt başlıkta ayrıntılı olarak ele alınacaktır.

4.6. Regresyon Algoritmaları

Regresyon, bağımlı bir değişken ile bir veya birden çok bağımsız değişken arasındaki doğrusal ya da doğrusal olmayan ilişkiyi nicel olarak ortaya koyan ve bu ilişkiye dayanarak tahminler üreten istatistiksel bir tekniktir. Örneğin, bir çocuğun boyundaki yıllık ortalama artış regresyon modeliyle formüle edilerek geleceğe yönelik tahmin yapılabilir. Benzer şekilde, gayrimenkul değer tahminleri de regresyon problemleri kapsamında ele alınmaktadır.

Regresyon algoritmaları genel olarak parametrik ve parametrik olmayan yöntemler olarak ikiye ayrılır. Parametrik yöntemlerde model yapısı sabit parametrelerle tanımlanır. Basit doğrusal regresyon, çoklu doğrusal regresyon, Ridge (L2) ve Lasso (L1) düzenlileştirmeli regresyon ile Elastik Net bu grupta yer alır. Bu yaklaşımlar, önceden belirlenmiş katsayılar üzerinden modelin karmaşıklığını kontrol eder. Parametrik olmayan yöntemler ise veri kümesinin büyüklüğü ve yapısına göre esnek şekilde uyarlanabilir. K-En Yakın Komşu (KNN) regresyon, Destek Vektör Regresyonu (SVR), karar ağacı tabanlı yöntemler (ör. Random Forest) ve Gaussian Süreç Regresyonu bu kategoriye örnektir.

Doğrusal regresyon teknikleri, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi matematiksel olarak ifade eder. Basit doğrusal regresyon, tek değişken üzerinden en küçük kareler yöntemiyle en iyi uyumu sağlayan doğruyu belirlerken; çoklu doğrusal regresyon birden fazla değişkenin etkisini eşzamanlı inceler. Polinom regresyon ise doğrusal olmayan ilişkileri modellemek amacıyla bağımsız değişkenlere daha yüksek dereceli terimler ekler.


Parametrik olmayan yöntemlerde ise farklı yaklaşımlar öne çıkar. Yapay sinir ağı regresyonu, çok katmanlı algılayıcı mimarisiyle karmaşık ilişkileri öğrenir. SVR, verilerin çoğunu belirli bir tolerans aralığına sığdırarak modelin hem doğruluğunu hem de karmaşıklığını dengelemeyi amaçlar. Karar ağacı regresyonu, değişkenleri dallara ayırarak yaprak düğümlerinde alt kümenin ortalama hedef değerini tahmin eder.

Bu çalışmanın uygulama bölümünde Karar Ağacı algoritmasına doğrudan yer verilmemiştir. Ancak, literatürde yaygın olarak kullanılan birçok topluluk öğrenme yönteminin (Bagging ve Boosting tabanlı modellerin) temelinde karar ağaçları bulunduğundan, bu algoritmanın işleyişinin açıklanması gerekli görülmüştür. Karar Ağaçları, regresyon ve sınıflandırma problemlerinde kullanılan bağımsız bir yöntem olmanın ötesinde, diğer pek çok gelişmiş modelin altyapısını oluşturan yapıtaşı konumundadır. Dolayısıyla, bu algoritmanın temel prensiplerinin ele alınması, ilerleyen alt başlıklarda açıklanan yöntemlerin anlaşılması için kavramsal bir zemin hazırlamaktadır.

4.6.1. Karar Ağacı Algoritması

Karar Ağacı algoritması, ML alanında hem sınıflandırma hem de regresyon problemlerinde yaygın olarak kullanılan denetimli öğrenme yöntemlerinden biridir. Temel olarak, dallanmalar ve düğümlerden oluşan ağaç benzeri bir yapı kurarak, olası yol kombinasyonları üzerinden karar süreçlerini yürütür. Bu yapı; kök düğüm (*root node*), iç düğümler/dallar (*branches/internal nodes*) ve yaprak düğümler (*leaf/terminal nodes*) olmak üzere Şekil 9'daki gibi üç ana bileşenden oluşur.

Şekil 9. Karar ağacının şematik gösterimi.



Eğitim veri kümesinin tamamı kök düğümde başlar ve en belirleyici özneliğe göre bölünür. Kategorik öznelikler doğrudan işlenebilirken, sürekli öznelikler için genellikle ön işleme uygulanır. Kök ve iç düğümlere hangi özneliklerin yerleştirileceği, bilgi kazancı ve Gini indeksi gibi ölçütlerle belirlenir. Amaç, hata kareleri toplamını en fazla azaltacak bölünmeyi seçerek model performansını artırmaktır (Breiman, 2017). Yaprak düğümler ise nihai tahmin veya sınıflandırma sonucunu ifade eder.

Entropi, veri kümesindeki düzensizlik derecesini ölçen temel bir kavramdır. Bilgi kazancı ise belirli bir öznelik üzerinden yapılan bölünme öncesi ve sonrası entropi farkını ifade eder ve öznelik seçimi sürecinde kullanılır. Böylece entropideki

azalma, ilgili özniteliğin sınıflandırma başarısına katkısını yansıtır. Regresyonda ise bu metrikler yerine MSE ya da Varyans Azaltımı kullanılarak ayırım hesaplanır.

Karar ağaçları, parametrik olmayan yapıları sayesinde hem sayısal hem de kategorik veriler üzerinde esnek biçimde uygulanabilir. Minimal ön işleme gerektirmeleri ve görselleştirilebilir olmaları, karar mekanizmalarının anlaşılmasını kolaylaştırır. Ancak eksik verileri doğrudan işleyememeleri ve derinleştikçe aşırı uyum (*overfitting*) eğilimi göstermeleri önemli sınırlılıklardır.

Karar ağaçlarının oluşturulması için geliştirilmiş çeşitli algoritmalar mevcuttur. Bu algoritmalar, veri ön işleme yöntemleri, bölme ölçütleri ve derinlik–kapsam stratejileri bakımından farklılık gösterir. En yaygın kullanılan karar ağacı algoritmaları arasında ID3 (*Iterative Dichotomiser 3*), C4.5 (ID3'ün geliştirilmiş versiyonu), CHAID (*Chi-square Automatic Interaction Detection*), MARS (*Multivariate Adaptive Regression Splines*) ve CART (*Classification and Regression Tree*) yer almaktadır.

4.6.2. Ensemble Learning Yöntemleri

Ensemble Learning, bağımsız olarak eğitilen birden fazla zayıf öğrencinin (*weak learner*) tahminlerinin belirli bir yöntemle birleştirilerek tek ve daha güçlü bir model oluşturulması yaklaşımıdır. Bu yöntem, tek bir modelin sınırlı kapasitesini aşmak ve genelleme performansını artırmak amacıyla, farklı algoritmaların veya aynı algoritmanın farklı versiyonlarının bir arada kullanılmasına dayanır.

Örneğin, Random Forest algoritmasında tek bir karar ağacı yerine çok sayıda karar ağacı (n adet) paralel olarak eğitilir. Her bir ağaç, veri kümesinin farklı alt kümeleri üzerinde tahmin üretir; bu tahminler, çoğunluk oylaması (sınıflandırma) veya ortalama alma (regresyon) gibi yöntemlerle birleştirilerek nihai çıktı elde edilir. Bu yaklaşım, tek bir karar ağacına kıyasla hem doğruluk hem de kararlılık açısından daha üstün sonuçlar sağlayabilir.


Ensemble Learning teknikleri, temel olarak iki ana strateji çerçevesinde sınıflandırılmaktadır: Bagging tabanlı yöntemler ve Boosting tabanlı yöntemler.

4.6.3. Bagging Tabanlı Yöntemler

Bagging (*Bootstrap Aggregating*), topluluk öğrenmesi yöntemleri arasında yer alan ve modelin varyansını azaltarak genelleme kabiliyetini artırmayı amaçlayan bir yaklaşımdır. Bu yöntemde, orijinal eğitim veri kümesinden bootstrap örnekleme yöntemi ile tekrar seçme esasına dayalı olarak, aynı boyutta ancak farklı gözlem kombinasyonlarına sahip çok sayıda alt küme oluşturulur. Her alt küme üzerinde bağımsız bir tahminleyici (ör. Karar Ağacı) eğitilir. Böylece, farklı alt kümeler üzerinde eğitilen modeller veri setindeki gürültüye karşı daha dayanıklı hâle gelir ve aşırı uyum riski azalır.

Bagging yönteminin işleyiş adımları Şekil 10'da görselleştirilmiştir.

Şekil 10. Bagging çalışma mantığı.



Kaynak: (Chawla, 2023).

Bu süreç, tek bir derin karar ağacında görülen yüksek varyans riskini azaltarak modelin genelleme performansını güçlendirir. Ayrıca, farklı alt küme ve öznitelik kombinasyonları üzerinde eğitilen modellerin hata desenleri birbirini dengelediği için toplam hata oranı düşmektedir. Bagging'in önemli avantajlarından biri, modellerin bağımsız olarak paralel biçimde eğitilebilmesidir; bu da büyük veri kümeleri üzerinde hesaplama verimliliğini artırır.

Bagging tabanlı yöntemlerin en yaygın örneği Random Forest algoritmasıdır. Random Forest, yalnızca bootstrap ile oluşturulmuş farklı alt kümeleri değil, her

düğümde rastgele seçilmiş özellik alt kümelerini de kullanarak klasik Bagging yaklaşımını çeşitlendirir. Bu ek rastgelelik, ağaçlar arasındaki korelasyonu azaltarak modelin tahmin gücünü artırır. Bunun dışında, Bagging Regressor ve Extra Trees (Extremely Randomized Trees) Regressor da Bagging prensibini temel alan yöntemlerdir. Bagging Regressor, bootstrap ile üretilmiş alt kümelerde aynı tip öğrencilerin eğitilmesi mantığına dayanırken; Extra Trees Regressor, bölünme noktalarını tamamen rastgele seçerek farklılaşır.

Sonuç olarak, Random Forest, Bagging Regressor ve Extra Trees Regressor, Bagging stratejisinin farklı varyasyonlarını temsil etmektedir. Özellikle yüksek varyans gösteren temel modellerde, bu yöntemler düşük yanlılık (*low bias*) ile güçlü ve esnek tahminler üretme kapasitesine sahiptir.

4.6.3.1. Random Forest Regressor

Random Forest, Bagging yaklaşımına dayalı olarak geliştirilen, çok sayıda karar ağacının topluluk öğrenmesi yöntemi ile bir araya getirilmesiyle oluşturulan güçlü bir makine öğrenmesi algoritmasıdır. Hem sınıflandırma hem de regresyon problemlerinde yüksek tahmin doğruluğu sağlaması nedeniyle literatürde yaygın şekilde kullanılmaktadır. Yöntemin temel ilkesi, farklı veri alt kümeleri üzerinde bağımsız karar ağaçlarının eğitilmesi ve bu ağaçlardan elde edilen tahminlerin birleştirilerek daha genellenebilir ve kararlı sonuçlar elde edilmesidir.

Random Forest algoritması, temel öğrenciler (*base learners*) karar ağaçlarından oluşmaktadır. Modelin çeşitliliğini artırmak ve ağaçlar arasındaki korelasyonu azaltmak amacıyla iki aşamalı bir örnekleme stratejisi uygulanır:

1. Satır Örnekleme: Veri setinden *bootstrapping* yöntemi ile rastgele satırlar seçilir.
2. Özellik Örnekleme: Her düğümde, tüm özellikler yerine rastgele seçilen bir alt özellik kümesi üzerinden bölünme yapılır.

Bu yöntem, her bir karar ağacının farklı veri ve özellik kombinasyonlarıyla eğitilmesini sağlayarak modelin çeşitliliğini artırır ve aşırı uyum riskini azaltır.

Tahmin Süreci;

- Sınıflandırma problemlerinde her karar ağacı bağımsız olarak tahmin üretir; nihai sınıf etiketi çoğunluk oylaması yöntemi ile belirlenir.
- Regresyon problemlerinde ise tüm ağaçların tahminleri aritmetik ortalama alınarak nihai sonuç elde edilir.

Tek bir karar ağacı, düşük yanlılığa sahip olmasına rağmen yüksek varyans gösterebilir ve bu durum aşırı uyuma yol açabilir. Random Forest, çok sayıda karar ağacının bir arada kullanılmasıyla varyansı düşürerek daha genelleştirilebilir ve dengeli tahminler üretir.

Random Forest algoritmasının başlıca avantajı, aşırı uyum riskini azaltmasıdır. Çok sayıda karar ağacının topluluk yaklaşımı ile bir araya getirilmesi, tek bir ağacın eğilim gösterdiği yüksek varyans sorununu ortadan kaldırarak modelin genelleme yeteneğini artırır. Bu yöntem hem sınıflandırma hem de regresyon problemlerinde yüksek tahmin performansı sergilemekte olup, karar ağaçlarının güçlü yönlerini korurken zayıf yönlerini dengeleyici bir rol üstlenir. Bununla birlikte, algoritmanın bazı dezavantajları da bulunmaktadır. Özellikle büyük veri setlerinde çok sayıda ağacın eğitilmesi, hesaplama süresini ve kaynak kullanımını artırabilmektedir. Ayrıca, tek bir karar ağacı kadar kolay yorumlanabilir olmaması, modelin karar mekanizmasının anlaşılmasını güçleştirmektedir.

4.6.3.2. Bagging Regressor

Bagging Regressor, scikit-learn kütüphanesinde uygulanabilen ve bagging yaklaşımının regresyon problemlerine uyarlanmış genel bir versiyonudur. Temel olarak, belirlenen sayıda temel öğrenici (ör. DecisionTreeRegressor) bootstrap yöntemiyle oluşturulan farklı veri alt kümeleri üzerinde eğitilir. Her bir modelin çıktısı, regresyon görevlerinde ortalama alınarak birleştirilir.

Bagging Regressor, Random Forest'a kıyasla öznitelik rastgeleliği uygulamaz; bu nedenle modelin çeşitliliği yalnızca veri alt kümelerinin farklı olmasından kaynaklanır. Bu yapı, özellikle yüksek varyansa sahip temel modellerde performans iyileştirmesi sağlarken, düşük varyansa sahip modellerde sınırlı fayda sağlayabilir.

Ayrıca, paralel işlemeye uygun olması nedeniyle büyük veri setlerinde verimli bir şekilde kullanılabilir.

4.6.3.3. Extra Trees Regressor


Extra Trees Regressor, Bagging prensibini temel alan ve çok sayıda karar ağacının birlikte kullanıldığı bir topluluk öğrenmesi yöntemidir. Random Forest’a benzer şekilde her bir ağaç, veri kümesinin farklı alt kümeleri ve rastgele seçilmiş öz nitelikler kullanılarak oluşturulur. Ancak Random Forest’tan temel farkı, her düğümde bölünme noktalarının optimize edilmek yerine tamamen rastgele seçilmesidir (Geurts vd., 2006).

Bu yaklaşım, ağaçlar arasındaki korelasyonu azaltarak modelin çeşitliliğini artırır ve hesaplama süresini kısaltır. Rastgele bölünmeler sayesinde modelin aşırı uyum yapma riski de düşebilir. Öte yandan, rastgelelik seviyesinin yüksek olması, özellikle küçük veya gürültülü veri kümelerinde tahmin kararlılığını olumsuz etkileyebilir. Extra Trees Regressor, yüksek boyutlu ve büyük hacimli veri kümelerinde hızlı eğitim süresi, esnekliği ve gürültüye dayanıklılığı ile öne çıkmaktadır.

4.6.4. Boosting Tabanlı Yöntemler

Boosting, zayıf öğrenicilerin art arda eğitilerek bir araya getirilmesiyle güçlü bir tahmin modeli oluşturmayı amaçlayan bir topluluk öğrenme yöntemidir. Bagging yönteminde olduğu gibi modeller paralel olarak değil, ardışık olarak eğitilir. Her yeni model, kendisinden önce gelen modelin hatalarına odaklanır ve bu hataları azaltmaya çalışır. Çalışma mantığı Şekil 11’de sunulmuştur.

Şekil 11. Boosting çalışma mantığı.



Kaynak: (Chawla, 2023).

Boosting süreci şu şekilde işler:

1. İlk modelin eğitilmesi: Orijinal veri kümesi ile ilk zayıf öğrenici (ör. Karar Ağacı) eğitilir.
2. Hataların belirlenmesi: Modelin yanlış tahmin ettiği örnekler belirlenir ve bu örnekler daha yüksek ağırlık atanır.
3. Ağırlıklı veri ile sonraki modelin eğitilmesi: Bir sonraki model, ağırlıkları güncellenmiş veri kümesi ile eğitilir; böylece önceki modelin hatalı sınıflandırdığı örnekler daha fazla önem verilir.
4. Tekrarlayan süreç: Bu işlem, belirlenen iterasyon sayısı boyunca devam eder. Her adımda modellerin tahmin performansları değerlendirilir ve hatalar yeniden ağırlıklandırılır.
5. Tahminlerin birleştirilmesi: Nihai çıktı, tüm modellerin ağırlıklı oyları (sınıflandırmada) veya ağırlıklı ortalamaları (regresyonda) ile belirlenir.

Genel olarak bakıldığında, Bagging ve Boosting yöntemleri arasında bazı temel farklılıklar bulunmaktadır. Öncelikle, Bagging yönteminde modeller paralel olarak eğitilirken, Boosting yönteminde modeller ardışık şekilde eğitilmektedir. Hedef

açısından bakıldığında Bagging, modelin varyansını azaltmayı amaçlarken, Boosting daha çok modelin yanlılığını azaltmayı hedefler. Ayrıca, kullanılan öğrenici türleri bakımından Bagging genellikle güçlü öğrenicilerle çalışırken, Boosting zayıf öğrenicileri adım adım iyileştirerek güçlü hâle getirmektedir.

4.6.4.1. Gradient Boosting Regressor

Gradient Boosting, birden fazla zayıf öğrenicinin, genellikle karar ağaçlarının, ardışık olarak eğitilmesi prensibine dayanan güçlü bir topluluk öğrenme yöntemidir. Bu yöntemde her yeni model, bir önceki modelin tahmin hatalarını öğrenerek bunları azaltmayı hedefler. Böylece hatalar kademeli olarak düzeltilir ve güçlü bir nihai model oluşturulur. Bu yaklaşım, esnekliği ve doğruluğu ile öne çıkmasına rağmen, eğitim süresinin uzunluğu ve aşırı uyum riski nedeniyle öğrenme oranı ve ağaç derinliği gibi hiperparametrelerin dikkatli seçilmesini gerektirir.

Gradient Boosting'in avantajları arasında yüksek tahmin doğruluğu, esnek yapı ve hem regresyon hem sınıflandırma problemlerinde uygulanabilirlik yer alır. Bununla birlikte, yüksek iterasyon sayılarında ve derin ağaç yapılarında eğitim süresinin uzaması ve uygun parametre ayarlamaları yapılmadığında aşırı uyum riski dezavantaj olarak değerlendirilebilir. Gayrimenkul değerlendirme bağlamında Gradient Boosting Regressor, konut fiyat tahmininde karmaşık değişkenler arasındaki doğrusal olmayan ilişkileri yakalamada ve yüksek doğrulukta değer tahminleri üretmede etkili bir yöntemdir.

4.6.4.2. AdaBoost Regressor

AdaBoost (*Adaptive Boosting*), zayıf öğrenicileri ardışık biçimde eğitip ağırlıklandırarak güçlü bir tahmin modeli elde eden ilk ve en temel Boosting algoritmalarından biridir. AdaBoost algoritması, Freund ve Schapire (1995) tarafından geliştirilmiş olup zayıf sınıflandırıcıların birleştirilmesiyle güçlü bir öğrenici elde edilmesini sağlamaktadır. Algoritma başlangıçta tüm gözlemlere eşit ağırlık tanır. İlk zayıf öğrenici (çoğunlukla *decision stump* olarak adlandırılan tek seviyeli karar ağacı) eğitildikten sonra, hatalı tahmin edilen örneklerin ağırlıkları artırılırken doğru tahmin edilenlerin ağırlıkları azaltılır. Böylece sonraki iterasyonlarda, model özellikle önceki

adımlarda yanlış sınıflandırılmış gözlemler üzerine yoğunlaşır. Bu ardışık güncellemeler, hataların kademeli biçimde azaltılmasına imkân tanır.

AdaBoost'un diğer boosting algoritmalarından farkı, model çıktılarının doğruluklarına göre ağırlıklandırılarak birleştirilmesidir. Son aşamada tüm zayıf öğrencilerin tahminleri kendi katsayılarıyla ağırlıklandırılarak toplulaştırılır ve güçlü bir nihai model elde edilir. Bu yapı, AdaBoost'un “adaptif” özelliğini yansıtarak hem basit öğrencilerin gücünü artırır hem de modelin doğruluk oranını yükseltir.

4.6.4.3. CatBoost Regressor

CatBoost (*Categorical Boosting*), Yandex tarafından geliştirilen ve özellikle kategorik değişkenleri doğrudan işleyebilme yeteneği ile öne çıkan, Gradient Boosting tabanlı bir makine öğrenmesi algoritmasıdır. İsmi, *Categorical* ve *Boosting* sözcüklerinin birleşiminden almaktadır. CatBoost hem sınıflandırma hem de regresyon problemlerinde yüksek doğruluk ve verimlilik sağlaması sayesinde literatürde geniş bir uygulama alanına sahiptir.

Diğer Gradient Boosting yöntemlerinin aksine, kategorik değişkenlerin önceden kodlama yöntemleriyle dönüştürülmesini gerektirmez. Bunun yerine, *ordered boosting* yaklaşımını kullanarak kategorik değişkenleri hedef değişken istatistiklerine dayalı sayısal temsillere dönüştürür. Bu yöntem, yalnızca geçmiş gözlemlerden bilgi kullanarak veri sızıntısı riskini azaltır.

CatBoost, simetrik karar ağaçları inşa ederek eğitim süresini hızlandırır ve genelleme yeteneğini artırır. Bu yaklaşım, her seviyede tüm dalların aynı özniteliğe göre bölünmesini sağlayarak modeli dengeler. Regresyon bağlamında ise sürekli hedef değişkenlerin tahmininde genellikle MSE veya MAE kayıp fonksiyonları kullanılmaktadır.

Özellikle kategorik değişken oranının yüksek olduğu veri setlerinde, CatBoost'un geleneksel Gradient Boosting algoritmalarına göre üstünlüğü belirginleşmektedir. Daha az ön işleme gereksinimi hem CPU (*Central Processing Unit*) hem GPU (*Graphics Processing Unit*) üzerinde verimli çalışabilmesi başlıca

avantajlarıdır. Bununla birlikte, çok büyük veri setlerinde eğitim süresinin uzaması önemli bir dezavantaj olarak değerlendirilebilir.

Gayrimenkul değerlendirme çalışmalarında CatBoost Regressor, özellikle bina özellikleri ve tapu türü gibi kategorik değişkenlerin yoğun olduğu veri setlerinde, yüksek tahmin doğruluğu ve düşük model karmaşıklığı ile önemli avantajlar sağlamaktadır. Bu nedenle, mekânsal ve yapısal heterojenliği yüksek veri setlerinde CatBoost'un diğer boosting algoritmalarına kıyasla daha başarılı sonuçlar vermesi beklenmektedir.

4.6.4.4. XGBoost Regressor

XGBoost (Extreme Gradient Boosting), Gradient Boosting algoritmasının optimize edilmiş ve özellikle büyük veri setleri ile karmaşık modellerde yüksek başarı sağlayan gelişmiş bir versiyonudur (Chen & Guestrin, 2016). Temel amacı, modelin tahmin performansını artırırken aşırı uyum riskini azaltmaktır. Bu kapsamda, bir dizi optimizasyon stratejisi kullanılmaktadır.

Öncelikle, *pruning* (budama) yöntemiyle karar ağaçları *post-pruning* yaklaşımıyla optimize edilmekte, gereksiz dallanmalar ortadan kaldırılmaktadır. *Regularization* kapsamında L1 ve L2 ceza terimleri kullanılarak model karmaşıklığı kontrol altında tutulur. Ayrıca XGBoost, paralel hesaplama kabiliyetine sahip olması sayesinde çok çekirdekli işlemciler üzerinde hızlı çalışır; bellek optimizasyonu da kaynak kullanımını verimli hale getirir.


Çalışma mantığında ise XGBoost, başlangıçta bir temel tahmin modeli oluşturur. Regresyon problemlerinde bu tahmin genellikle hedef değişkenin ortalamasına dayanır. Her iterasyonda mevcut tahminler ile gerçek değerler arasındaki hata hesaplanır ve bu değerler yeni ağacın hedef değişkeni olur. Ardından, olası bölünmeler için bilgi kazancı değeri ölçülür, en yüksek kazanç sağlayan bölünme seçilir ve yeni ağaç öğrenme oranı katsayısı ile modele eklenir.

XGBoost, hesaplama verimliliği, aşırı uyuma karşı güçlü düzenleme mekanizmaları ve ölçeklenebilirliği sayesinde, milyarlarca örneğe kadar geniş veri setlerinde etkili çözümler sunarak literatürde yaygın kabul görmüştür.

4.6.4.5. LighGBM Regressor

LightGBM (Light Gradient Boosting Machine), Microsoft tarafından geliştirilen, büyük veri setleri üzerinde yüksek hız ve bellek verimliliği sağlayan, Gradient Boosting tabanlı bir makine öğrenmesi algoritmasıdır. Hafıza dostu yapısı, hızlı çalışması ve yüksek doğruluk performansı nedeniyle geniş uygulama alanına sahiptir. LightGBM'in en belirgin farkı, karar ağaçlarını yaprak bazlı büyütme stratejisiyle inşa etmesidir (Şekil 12).

Şekil 12. Yaprak Bazlı ve Seviye Bazlı Büyüme Yaklaşımları.



Geleneksel seviye bazlı büyüme stratejisinde (ör. XGBoost), ağaçlar dengeli olarak genişlerken, LightGBM her iterasyonda yalnızca bilgi kazancının en yüksek olduğu, en iyi yaprağı genişletir. Bu yöntem genellikle daha düşük hata oranı sağlasa da aşırı uyum riskini artırabilir.

Bir diğer önemli özelliği, “histogram tabanlı binning” yaklaşımıdır. Sürekli değişkenler, model tarafından işlem öncesinde belirli sayıda (genellikle 256) aralığa (bin) dönüştürülür. Bu yaklaşım, olası bölünme noktalarının sayısını azaltarak hem hesaplama hızını hem de bellek verimliliğini artırır.

LightGBM’de gain hesaplaması, histogram aralıkları üzerinden toplam Gradyan (hata fonksiyonunun türev değerleri) ve Hessian (hata fonksiyonunun ikinci

türev değerleri) değerleri kullanılarak yapılır. Bu sayede LightGBM, XGBoost’a kıyasla daha düşük bellek kullanımıyla daha hızlı eğitim süresi sunar (Ke vd., 2017).

Bu nedenle LightGBM, gayrimenkul değerlendirme gibi hem kategorik hem de sürekli değişkenlerin yoğun olarak bulunduğu veri setlerinde, diğer boosting algoritmalarına göre hız-doğruluk dengesi bakımından öne çıkmaktadır.

4.7. Model Performans Metrikleri

Toplu değerlendirme standartlarında “Modelleme ve Kalite Güvence” bölümünde değerlendirme modelinin performans ölçütleri ele alınmıştır (IAAO, 2018). Her model, eğitim ve doğrulama setlerinde hem çapraz doğrulama hem de ayırık test seti ile sınanır; performans değerlendirmesinde hata metrikleri kullanılır. Model doğruluğu, ilgili performans ölçütlerinin uygulanması ve elde edilen sonuçların farklı yöntemlerle karşılaştırılması yoluyla değerlendirilir (Numan & Yusoff, 2024). Bu doğrultuda, tahminlerin performansını değerlendirmek için yaygın olarak kullanılan regresyon metrikleri; Belirleme Katsayısı (R^2), Ortalama Mutlak Hata (MAE, *Mean Absolute Error*), Ortalama Kare Hata (MSE, *Mean Squared Error*) ve Ortalama Kök Kare Hatası (RMSE, *Root Mean Squared Error*)’dır.

R^2 ; regresyonda bağımlı ile bağımsız değişkenlerin ne ölçüde birbiriyle bağlantılı olduğunu gösteren bir göstergedir. R^2 , toplam varyans oranı üzerinden modelin ne kadar iyi uyduğunu belirtir. Bu değer, tahmin modelinin veri setindeki değişkenliği ne kadar iyi açıkladığını gösterir (Botchkarev, 2019; Plevris vd., 2022). R^2 değeri 0 ile 1 arasında değişir ve 1’e yakın değerler, tahmin edilen değerlerin gözlemlenen verilere mükemmel uyumunu gösterir.

MAE, gerçek ve tahmin edilen değerler arasındaki mutlak farkların ortalamasını temsil eder. Düşük bir MAE, modelin tahminlerinin gerçek değerlere çok yakın olduğunu gösterir.

MSE, gerçek ve tahmin edilen değerler arasındaki farkların karelerinin ortalamasını temsil eder. Bu metrik, hata büyüklüklerini karesini alarak değerlendirir ve büyük hatalara daha fazla ağırlık verir.

RMSE, gerçek ve tahmin edilen değerler arasındaki kare hataların ortalamasının karekökü alınarak elde edilir. Bu ölçekte büyük hatalar daha fazla önem taşır ve düşük RMSE değerleri daha iyi model performansını işaret eder. Bu performans ölçümleri için matematiksel formülasyonlar aşağıda sunulmuştur.

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

$$RMSE = \sqrt{\sum_{i=1}^N \frac{(y_i - \hat{y}_i)^2}{N}}$$

Bu denklemlerde; y gerçek değer, $\hat{y}$ tahmin değeri, $\bar{y}$ ortalama değer N örneklem sayısı, p bağımsız değişken sayısını ifade eder.

Bununla birlikte, model başarısı yalnızca doğruluk oranlarıyla sınırlı değildir. Model önyargısı (*bias*), tahminlerin ortalama değeri ile gerçek gözlemler arasındaki farkı; varyans ise farklı veri setleri üzerindeki tahminlerin sapma düzeyini gösterir. Yüksek önyargı, modelin yetersiz öğrenmesini (*underfitting*) ve yüksek hata oranlarını beraberinde getirirken; yüksek varyans, modelin eğitim verisine aşırı uyum (*overfitting*) sağlaması ve yeni verilerde düşük performans sergilemesiyle sonuçlanır. Basit doğrusal modeller genellikle yüksek önyargı–düşük varyans, Random Forest gibi karmaşık modeller ise düşük önyargı–yüksek varyans eğilimi taşır. Bagging ve boosting tabanlı topluluk yöntemleri, bu iki unsur arasında denge kurarak daha başarılı sonuçlar elde etmektedir (Bühlmann, 2012).

4.8. Model Yorumlanabilirliği ve Açıklanabilir Yapay Zekâ Yöntemleri

Yapay zekâ tekniklerinin, özellikle makine öğrenimi yaklaşımlarının, gayrimenkul değerlendirme sektöründe uygulanmasında en temel engellerden biri, modellerin yorumlanabilirlik eksikliğidir (Lee, 2022b). Bu sorun, şeffaflık ve hesap verilebilirliğin zorunlu olduğu vergi değerlemesi gibi alanlarda daha da kritik hale gelmekte ve literatürde geniş şekilde tartışılmaktadır.

Yüksek doğruluk, kararlılık ve genellenebilirlikleri sayesinde sınıflandırma ve regresyon problemlerinde sıklıkla tercih edilen topluluk öğrenmesi yöntemleri, sınır ağları veya kernel tabanlı yöntemlere kıyasla daha açıklanabilir kabul edilmektedir (D. Wang & Li, 2019). Toplu değerlendirme sistemlerinde ağaç tabanlı modellerin yaygınlaşması, Açıklanabilir Yapay Zekâ (XAI) yöntemleri ile entegrasyon çalışmalarını da artırmıştır.

Literatürde bazı araştırmacılar, model eğitimi öncesinde korelasyon katsayıları gibi istatistiksel yöntemler kullanarak özellik seçimi yaparken (Pai & Wang, 2020; Yilmazer & Kocaman, 2020), bazıları kapsamlı saha çalışmaları ile bu süreci yürütmüştür (Yalpir vd., 2021). Ancak bu yaklaşımlar, özelliklerin mülk fiyatı tahminine yaptığı görece katkıyı doğrudan ortaya koymakta yetersizdir. Yalnızca yüksek doğruluklu tahminler elde etmek yeterli değildir; şeffaflık ve adalet ilkeleri gereği, her bir girdi değişkeninin tahmin sürecindeki rolünün açıkça belirlenebilmesi gerekmektedir (Iban, 2022b). Bu gereklilik, açıklanabilirlik kavramını ön plana çıkarmakta; analistlerin gayrimenkul değerini en çok etkileyen faktörleri sistematik olarak belirlemelerine olanak tanımaktadır. Böylelikle açıklanabilir bir toplu değerlendirme sistemi, doğruluk ve yorumlanabilirlik boyutlarını aynı anda güçlendirmektedir.

Model açıklanabilirliği, girdi değişkenlerinin tahmin sonuçlarına katkılarını nicel olarak ortaya koyarak, analistlerin gayrimenkul fiyatlarını belirlerken modelin hangi öznitelikleri temel aldığını görmelerini sağlar (Das & Rad, 2020; Islam vd., 2021; Konstantinov & Utkin, 2021; Van Der Waa vd., 2021). Açıklamalar iki düzeyde ele alınmaktadır: küresel ve yerel.

4.8.1. Küresel Açıklamalar – PFI Analizi

Küresel açıklamalar, modelin tüm veri kümesi üzerindeki genel davranışını analiz ederek özelliklerin ortalama önem derecelerini gösterir. Özellik önemi (*feature importance*), kısmi bağımlılık grafikleri (*partial dependence plots*) ve modele özgü görselleştirme yöntemleri bu kapsamda değerlendirilmektedir. Gini önemi veya sütun atlama önemi, değerlendirme çalışmalarında sıklıkla kullanılan yöntemlerdir (Hong vd., 2020). Ancak, değişken ölçekleri ve veri tiplerindeki farklılıklar nedeniyle bu yöntemlerin güvenilirliği sınırlı olabilmektedir (Strobl vd., 2007). Bu noktada PFI, değişkenlerin modele katkısını daha güvenilir biçimde ölçen bir teknik olarak öne çıkmaktadır (Adadi & Berrada, 2018; N. Huang vd., 2016).

PFI yöntemi, her bir özelliğin değerlerini veri seti içerisinde rastgele karıştırarak (permütasyon uygulayarak) söz konusu değişken ile hedef değişken arasındaki ilişkinin bozulmasını sağlar. Ardından, modelin bu yeni ve bozulmuş veri seti üzerindeki tahmin performansı ölçülür. Eğer ilgili özelliğin model tahminleri açısından önemli bir rolü varsa, değerlerinin karıştırılması sonrasında modelin hata oranı belirgin şekilde artar. Buna karşın, önemsiz özelliklerin permütasyonu, model hatasında anlamlı bir değişikliğe yol açmaz. Bu yöntem, iki temel avantaj sağlamaktadır: İlki, herhangi bir makine öğrenmesi algoritmasına özgü olmaksızın uygulanabilen model bağımsızlığıdır. İkincisi ise, permütasyon işlemi sırasında değişkenin istatistiksel dağılımının korunması sayesinde gerçekçi bir bozulma senaryosunun oluşturulabilmesidir.

PFI, XAI kapsamında küresel açıklama teknikleri içinde konumlanmaktadır. Küresel açıklamalar, modelin tüm veri kümesindeki genel davranışını analiz ederek her bir özelliğin ortalama önem derecesini ortaya koyar. Bu bağlamda PFI, modelin hangi değişkenleri genel olarak daha fazla dikkate aldığını belirlemeye imkân tanır.

Toplu değerlendirme sistemlerinde PFI, özellik seçimi amacıyla uygulanabilecek etkili bir araçtır. Önem derecesi düşük veya ihmal edilebilir seviyede olan değişkenlerin veri setinden çıkarılması, modelin hesaplama verimliliğini artırır ve aşırı uyum riskini azaltır. Bu tez kapsamında da PFI, küresel açıklama yöntemi olarak tercih

edilmiştir. Böylece, modelin doğruluk düzeyi korunurken yorumlanabilirliği ve genel performansı artırılmıştır.

Bununla birlikte, PFI sonuçları, tek tek gözlemler düzeyinde hangi değişkenlerin tahmini ne yönde etkilediğini göstermez. Bu nedenle, yerel açıklama yöntemleri (ör. *Shapley Additive Explanations*) ile birlikte kullanıldığında hem küresel hem de yerel düzeyde bütüncül bir açıklama elde edilir. PFI, değişkenlerin model genelindeki göreceli önemini ortaya koyarken; SHAP, her bir tahmin için değişken katkılarının büyüklüğünü ve yönünü belirleyerek daha ayrıntılı bir yorumlama sağlar.

4.8.2. Yerel Açıklamalar - SHAP Analizi

Yerel açıklamalar, belirli bir gözlem ya da küçük bir gözlem alt kümesi için model tahminlerinin gerekçesini ortaya koyar. LIME (*Local Interpretable Model-Agnostic Explanations*) ve SHAP (*Shapley Additive Explanations*) bu kategoriye örnektir. LIME, açıklanacak gözlemin çevresinde sentetik veri üretip bu veriler üzerinden tahmin farklılıklarını inceler; ancak yalnızca lokal çevreyle sınırlı olması, genellenebilirliğini azaltır (Doumard vd., 2022; Ghalebikesabi vd., 2021). SHAP ise, her bir özelliğin katkısını tüm olası kombinasyonları dikkate alarak hesaplar ve daha sağlam bir teorik çerçeve sunar (Amparore vd., 2021; Lundberg vd., 2019).

SHAP analizinde her bir girdi değişkenine atanan Shapley değeri, modelin çıktısındaki değişime olan katkısının yönünü (pozitif veya negatif) ve büyüklüğünü nicel biçimde gösterir. Böylelikle, SHAP yalnızca değişkenlerin önem sırasını belirlemekle kalmaz, aynı zamanda bu değişkenlerin tahminlere etkisinin yönünü de açıklar. Yerel düzeyde, tek bir gözlem için hangi özelliklerin tahmine ne ölçüde etki ettiği görselleştirilirken; küresel düzeyde modelin tüm veri kümesi genelinde dikkate aldığı özellikler ortaya konur. Özellikle ağaç tabanlı algoritmalar için geliştirilen TreeExplainer kütüphanesi, SHAP değerlerini hızlı ve doğru biçimde hesaplayarak her girdinin katkısını ayrıntılı biçimde görselleştirme olanağı sunar.

Bu tez çalışmasında SHAP, gayrimenkul değer tahmini sürecinde kullanılan makine öğrenmesi modellerinin şeffaflığını artırmak, tahminlere en fazla etki eden özellikleri belirlemek ve sonuçların yorumlanabilirliğini güçlendirmek amacıyla tercih


edilmiştir. Analiz çıktıları, değişkenlerin önem derecelerini ve tekil tahminlere yaptıkları katkıları grafiksel ve sayısal olarak sunarak modelin karar verme sürecine dair derinlemesine bilgiler sağlayacaktır.

BÖLÜM 5




ÖRNEK UYGULAMA

Bu bölümde, çalışmada önerilen veri yönetimi ve analiz modeli kapsamında geliştirilen yöntemlerin uygulanabilirliğini test etmeye yönelik bir örnek uygulama sunulmaktadır. Söz konusu uygulamada, ML, CBS ve XAI bileşenlerinden oluşan hibrit tabanlı bir yöntem uygulanmıştır. Çalışma alanı olarak Ankara ili Yenimahalle ve Keçiören ilçeleri seçilmiş olup bölgeye ait gayrimenkul verileri CBS analizleri sonucunda elde edilen özelliklerin entegrasyonu ile zenginleştirilmiştir. İlk aşamada veri ön işleme ve özellik mühendisliği adımları uygulanmış, ardından konutların değerini tahmin etmek için ML tabanlı bir dizi regresyon algoritması kullanılmıştır. Bu algoritmalar Random Forest, Extra Trees, Bagging, Gradient Boosting, AdaBoost, CatBoost, XGBoost, LightGBM gibi gelişmiş tahmin modelleridir. Değer tahminleri yapılarak elde edilen sonuçlar, modellerin performans metrikleri üzerinden karşılaştırılmıştır. Model sonuçlarını iyileştirmek üzere özellik değişkenlerinin konut fiyatı tahminine yaptıkları göreceli katkıyı ortaya koymak için PFI yöntemi uygulanmıştır. Katkısı düşük veya önemsiz olan özellikler çıkarılmıştır. ML algoritmalarının en yüksek performans seviyesine ulaşabilmesi için hiperparametre optimizasyonunu sağlamak amacıyla, GridSearchCV kullanılmıştır. Gerçek performans hakkında daha iyi bir tahmin sunması için 5 katlı çapraz doğrulama (*K-fold Crossvalidation*) uygulanmıştır. Elde edilen en iyi parametreler uygulanarak iyileştirilmiş model sonuçları R^2 , MAE ve RMSE gibi performans metrikleri kullanılarak karşılaştırmalar yapılmıştır. Başarılı performans gösteren modeller belirlenerek değişkenlerin konutun değeri üzerindeki etkilerini yorumlamak için ise SHAP analizi uygulanmıştır. Son olarak değer haritaları altıgen ızgaralarla gösterimi sağlanarak üretilmiş ve e-devlet sistemi üzerinde paylaşmaya hazır halde servis edilmiştir. Böylece, önerilen modelin pratik uygulanabilirliği ve mekânsal karar destek süreçlerine katkı potansiyeli ortaya konmuştur. Yapılan örnek uygulamada kullanılan yöntemlere ilişkin iş akış şemaları Şekil 13-15'te özetlenmiştir.

Şekil 13. Örnek Uygulamada Kullanılan Yöntemlere Ait İş Akış Şeması




Şekil 14. Çalışmada Kullanılan Yöntemlere Ait İş Akış Şeması (Devamı)




Şekil 15. Çalışmada Kullanılan Yöntemlere Ait İş Akış Şeması (Devamı)

7



8




5.1. Çalışma Alanı

Çalışma alanı seçiminde TDUB tarafından yayımlanan sektörel raporlar temel alınmıştır. TDUB'un 2025 yılı 1. Çeyrek Değerleme Sektörü Özet Verileri Raporu'na göre, tek taşınmazlı değerlendirme raporları içinde konut nitelikli taşınmazlara ilişkin raporlar %58,23 ile en yüksek paya sahiptir (TDUB, 2025b). Dolayısıyla, sektördeki değerlendirme faaliyetlerinin büyük çoğunluğunu konutlar oluşturmaktadır.

Bu doğrultuda, çalışma kapsamında gayrimenkul değer tahminleri konut verileri üzerinden gerçekleştirilmiştir. Konut sektörü, piyasa hacmi bakımından arsa, arazi ve ticari taşınmazlara kıyasla en büyük ağırlığa sahip olduğundan, konut piyasasındaki hareketlilik ve trendler analiz açısından öncelikli bir konumda değerlendirilmiştir. TÜİK tarafından yayımlanan konut satış istatistiklerine göre, 2025 yılı ilk çeyreğinde (Ocak-Şubat-Mart toplamında) konut satış adedi en yüksek iller İstanbul (58.079 adet), Ankara (31.152 adet) ve İzmir (21.046 adet) olmuştur (Coğrafi İstatistik Portalı, 2025). Şekil 16'da görülen bu üç büyük il, Türkiye genelinde konut piyasasının lokomotifi konumundadır.

Şekil 16. Konut Satış Adedi En Yüksek İller




Benzer şekilde, TDUB'un 2025 1. Çeyrek raporuna göre aynı dönemde değerlendirme uzmanlarınca hazırlanan rapor sayıları da en çok İstanbul (38.900 rapor), Ankara (19.162 rapor) ve İzmir (13.808 rapor) illerinde gerçekleşmiştir (TDUB,

2025a). Bu bulgular, konut satış hacmi yüksek illerde değerlendirme raporlarına olan talebin de paralel biçimde arttığını göstermektedir.

Ankara ili özelinde bakıldığında, TDUB verilerine göre 2025 yılı ilk çeyreği itibarıyla Yenimahalle (2.361 rapor) ve Keçiören (1.935 rapor), en fazla gayrimenkul değerlendirme raporu düzenlenen ilçeler olmuştur (TDUB, 2025b). Hem değerlendirme raporu sayıları hem de gerçekleşen satış adetleri bakımından bu iki ilçe, Ankara konut piyasasının en aktif bölgeleri arasında yer almaktadır.

Şekil 17. Gayrimenkul Değerleme Raporu Sayısı En Yüksek İlçeler




Keçiören, Ankara'nın kuzeydoğusunda yer alan ve nüfus bakımından kentin en kalabalık ilçelerinden biri olan bir yerleşim merkezidir. 1980'li yıllardan sonra yoğun iç göç alması sonucu plansız yapılaşma, konut stokunun niteliğini olumsuz etkilemiştir. Son yıllarda özellikle Adnan Menderes ve Bağlarbaşı mahallelerinde yürütülen kentsel dönüşüm projeleri ile ilçe genelindeki fiziki yapı yenilenmeye çalışılmaktadır. Keçiören'de sosyo-ekonomik yapı heterojen bir karakter gösterir; çoğunlukla düşük ve orta gelir grupları ağırlıktadır. Bununla birlikte, Etlik bölgesinde son dönemde yapılan büyük ölçekli sağlık yatırımları (ör. şehir hastanesi kompleksi) ve yeni ulaşım projeleri dikkat çekmiş, bu gelişmeler bölgedeki gayrimenkul değerlerini yukarı çekmiştir. İlçede bulunan Keçiören Şelalesi ve Atatürk Botanik

Bahçesi gibi rekreasyon alanları da Keçiören'e çevresel değer katan unsurlar arasındadır.

Yenimahalle, Ankara'nın batısında yer alan ve daha planlı bir kentleşme süreci geçirmiş bir ilçedir. İlçe, güçlü altyapısı ve barındırdığı sanayi-ticaret bölgeleriyle ekonomik çeşitlilik gösterir. Türkiye'nin önemli organize sanayi bölgelerinden OSTİM ve İvedik OSB Yenimahalle sınırları içinde yer alır ve ilçe ekonomisinin dinamizmini artırmaktadır. Ulaşım altyapısı bakımından da avantajlıdır: metro hatları ve ana arter karayolları ile şehir içinde ve şehirlerarası bağlantıları güçlüdür. Bu sayede Yenimahalle'deki konut ve ticari gayrimenkullerin değerleri ulaşım erişilebilirliğinden olumlu etkilenmektedir. İlçede kamu çalışanları ile orta-üst gelir grubunun yoğun olması, eğitim düzeyinin görece yüksekliği ve Atatürk Orman Çiftliği gibi büyük yeşil alanlara yakınlık, yaşam kalitesini artıran faktörlerdir. Son yıllarda Şentepe, Demetevler ve Karşıyaka mahallelerinde yürütülen kentsel dönüşüm projeleri sonucunda modern konut arzı artmış ve gayrimenkul değerlerinde belirgin bir yükseliş gözlemlenmiştir.

Özetle, her iki ilçe de Ankara'nın önemli yerleşim bölgeleri olup farklı kentsel dinamiklere sahiptir. Keçiören hızlı nüfus artışı ve kentsel dönüşüm ihtiyacıyla öne çıkarken, Yenimahalle planlı gelişimi ve sanayi-ticari altyapısıyla dikkat çekmektedir. Bu farklılıklar, özellikle konut fiyatlarının mekânsal dağılımında anlamlı bir etki yaratmakta ve gayrimenkul değerlendirme süreçlerinde dikkate alınması gereken belirleyici unsurlar olarak karşımıza çıkmaktadır. Ankara ilinin genelinde gayrimenkul piyasası, yüksek işlem hacmi ve değerlendirme raporu sayılarıyla dikkat çekici bir hareketlilik sergilemektedir. Ayrıca bu araştırmada yapılacak mekânsal veri analizleri ve makine öğrenmesi uygulamaları için ihtiyaç duyulan veri temininin Ankara özelinde görece daha kolay olması da çalışma alanı olarak bu bölgenin seçilmesinde etkili olmuştur. Sosyo-demografik yapıları ve kentsel gelişmişlik düzeyleri bakımından birbirine hem kontrast hem de tamamlayıcı özellikler sunan Keçiören ve Yenimahalle, nicel ve nitel boyutlarda konut değerlerindeki farklılıkların incelenmesine olanak tanıdıkları için çalışma alanı olarak seçilmiştir (Şekil 18).

Şekil 18. Çalışma Alanı



5.2. Veri Seti


Çalışmada kullanılan konut satış verileri, Endeksa firmasından temin edilmiştir. Endeksa, yapay zekâ ve makine öğrenimi tabanlı gayrimenkul değerlendirme hizmeti sunan, güncel piyasa verilerine sahip bir veri platformudur (Endeksa, 2025b). Bu çalışmaya özgü olarak alınan veri seti, Ankara ili konut nitelikli taşınmazlara ait detaylı satış kayıtlarını içermektedir. Ham veri setinde başlangıçta 44 değişken (sütun) ve 37.095 adet satış kaydı (satır) yer almaktadır. Veriler; konutların konumu, fiziki özellikleri (metrekare, oda sayısı, kat durumu vb.), satış fiyatları ve satış tarihi gibi bilgileri kapsamaktadır.

Bunun yanında, çalışmada kullanılan coğrafi veriler Tablo 1’de gösterildiği üzere, TUCBS altyapısındaki ilgili kamu kurumlarından temin edilmiştir. Farklı kurum ve kuruluşların sunduğu katmanlar, çalışmanın amacına uygun olarak analiz sürecinde değerlendirilmiş ve mekânsal modelleme süreçlerine entegre edilmiştir.

Tablo 3. TUCBS’den Temin Edilen Katmanlar

Kurum		Katman	Kullanım Durumu
Çevre, Şehircilik ve İklim Değişikliği Bakanlığı	Coğrafi Bilgi Sistemleri Genel Müdürlüğü	POİ	✓
Çevre, Şehircilik ve İklim Değişikliği Bakanlığı	Coğrafi Bilgi Sistemleri Genel Müdürlüğü	SRTM DEM (30m)	✓
Ulaştırma ve Altyapı Bakanlığı	Karayolları Genel Müdürlüğü	Karayolu	✓
Sanayi ve Teknoloji Bakanlığı	Sanayi Bölgeleri Genel Müdürlüğü	Endüstri Bölgeleri Sınırı	✓
Sağlık Bakanlığı	Sağlık Bilgi Sistemleri Genel Müdürlüğü	Sağlık Tesisleri	✓
Hazine ve Maliye Bakanlığı	Türkiye İstatistik Kurumu Başkanlığı	Nüfus Gridi 2024	✓
Millî Eğitim Bakanlığı	İnşaat ve Emlak Genel Müdürlüğü	Okul	✓
İçişleri Bakanlığı	İller İdaresi Genel Müdürlüğü	İl sınırı	✓
İçişleri Bakanlığı	İller İdaresi Genel Müdürlüğü	İlçe sınırı	✓
İçişleri Bakanlığı	İller İdaresi Genel Müdürlüğü	Coğrafi yer adları	✓

Şekil 19. Temin Edilen Verilerin Gösterimi



Şekil 19’da çalışma alanına ilişkin farklı veri katmanlarını temsil eden dört harita yer almaktadır. Sol üstteki Dijital Yükseklik Modeli (DEM) haritası, bölgenin topoğrafik yapısını renk geçişleriyle göstermekte olup, yükseklik arttıkça kahverengi, azaldıkça yeşil tonların hâkim olduğu görülmektedir. Sağ üstteki Konut Satış Verilerinin Dağılımı haritası, analizlerde kullanılan konut satış noktalarının mekânsal dağılımını göstermekte ve yoğunlukların özellikle belirli kentsel merkezlerde toplandığını belirtmektedir. Sol alttaki Temin Edilen Veriler haritasında, çalışma kapsamında kullanılan yollar, hastaneler, endüstri bölgeleri ve okulların konumları bir

arada sunulmuş, böylece veri çeşitliliği görselleştirilmiştir. Sağ alttaki Nüfus Yoğunluğu (2024) haritası ise ızgara tabanlı yapı üzerinden nüfus yoğunluğunu yansıtarak demografik bilgilerin mekânsal analizlerde kullanılmasına temel teşkil etmektedir.


5.3. Coğrafi Verilerin Analizi

Toplu değerlendirme çalışmalarında, konutun yalnızca fiziksel özellikleri değil, aynı zamanda bulunduğu çevresel ve konumsal koşullar da önemli rol oynamaktadır. Coğrafi özelliklerin konut değerine etkisi, Bölüm 4: Değişkenlerin Belirlenmesi başlığı altında ayrıntılı olarak incelenmiştir. Bu bölümde ise, çalışma alanına ilişkin mekânsal özelliklerin belirlenmesi ve sayısal olarak ifade edilmesi ele alınmakta olup, bu süreç modelleme aşamasının temel adımlarından birini oluşturmaktadır. Coğrafi özelliklerin modellenmesi, değer tahminlerinde konutların yalnızca bireysel niteliklerini değil, aynı zamanda bulundukları çevresel bağlamı da dikkate almayı mümkün kılmakta; böylece tahminlerin doğruluğunu ve güvenilirliğini artırmaktadır. Bu kapsamda yüzey ve yakınlık analizleri gerçekleştirilmiştir.

5.3.1. Yüzey Analizleri

Önceki bölümde de vurgulandığı üzere, konumsal faktörler gayrimenkul değerlemesinde önemli belirleyiciler arasında yer almaktadır. Bu bağlamda, çalışma alanındaki çevresel ve konumsal unsurlar CBS temelli analizlerle sayısallaştırılmıştır. Analizler, ArcGIS Pro yazılımı kullanılarak gerçekleştirilmiş ve yüzey analizlerinde Coğrafi Bilgi Sistemleri Genel Müdürlüğü tarafından yayımlanan 30 m çözünürlüklü DEM verisi kullanılmıştır. ArcGIS Pro'nun Analysis modülü aracılığıyla, eğim (Slope), bakı (Aspect), topoğrafik gölgeleme (Hillshade) ve eş yükselti eğrileri (Contour) analizleri üretilmiştir.


Şekil 20. Topoğrafya Haritası



Öncelikle, seçilen bölgenin yüzey şekillerini anlamak amacıyla topoğrafya haritası oluşturulmuştur. Şekil 20’de sunulan bu harita, çalışma alanının topografik özelliklerini detaylı biçimde ortaya koymaktadır. Haritada, yükseklik değerleri metre cinsinden sınıflandırılmış, 50 m aralıklarla eş yükselti eğrileri çizilmiş ve akarsu ağı mavi çizgilerle gösterilmiştir.

Haritadan görüldüğü üzere, güney ve batı kesimlerde alçak platolar ve düz alanlar yayginken, kuzey ve doğuya doğru yükselti artmakta; topoğrafya giderek daha engebeli ve eğimli bir görünüm kazanmaktadır. Bu durum, bölgedeki arazi kullanımı, ulaşım ağlarının gelişimi ve yapılaşma potansiyeli üzerinde doğrudan etkili olmaktadır.

Şekil 21. Eğim Analizi




Şekil 21’de sunulan harita, çalışma alanındaki topoğrafik eğim dağılımını göstermektedir. Eğim, yüzeyin yatay düzleme göre yaptığı açıyı ifade eden bir ölçüttür ve yüzdeler (%) değerlerle ifade edilmiştir. Haritada eğim değerleri dört sınıfa ayrılarak renk skalasıyla görselleştirilmiştir:

- <5% (Koyu yeşil): Düz ve hafif eğimli alanları temsil eder. Bu bölgeler yapılaşma ve tarım faaliyetleri açısından en elverişli alanlardır.
- 5 – 15% (Açık yeşil): Orta eğimli alanları ifade eder. Bu alanlar kısıtlı da olsa yerleşim ve tarım için değerlendirilebilir.
- 15 – 30% (Sarı): Dik eğimli alanları gösterir. Bu bölgelerde inşaat faaliyetleri sınırlı olup, erozyon riski yüksektir.

- 30 – 113.812% (Kırmızı): Çok dik ve sarp arazileri temsil eder. Bu alanlar genellikle yerleşim ve tarım için uygun değildir ve doğal afet riskleri (heyelan, toprak kayması vb.) açısından dikkatle değerlendirilmelidir.

Eğim, gayrimenkul değerini etkileyen önemli fiziksel faktörlerden biridir. Düşük eğimli alanlar, altyapı maliyetlerinin görece düşük olması, erişilebilirlik ve yapılaşma kolaylığı gibi nedenlerle daha yüksek piyasa değerine sahip olma eğilimindedir. Buna karşılık, yüksek eğimli alanlarda inşaat maliyetlerinin artması, erişim zorlukları ve doğal afet riskleri, gayrimenkul değerinin düşmesine neden olabilmektedir. Bu nedenle eğim analizi, değerlendirme çalışmalarında mekânsal bağlamın doğru şekilde değerlendirilmesi açısından önem taşımaktadır

Şekil 22. Bakı Analizi



Şekil 22’de sunulan harita, çalışma alanının bakı (aspect) dağılımını göstermektedir. Bakı analizi, arazinin eğimli yüzeylerinin yönelimini ifade eder ve özellikle güneşlenme süresi yapılaşma kararları açısından kritik bir rol oynamaktadır. Bu bağlamda, farklı yönlere bakan yamaçlar farklı çevresel ve fiziksel özellikler sergilemektedir.

Haritada, eğimli yüzeylerin yönelimi derece cinsinden sınıflandırılmış ve 0°–360° aralığındaki yönelimler renk skalasıyla temsil edilmiştir:

- Düz (0°) – Eğimli olmayan alanlar (sarımsı ton).
- Kuzey (0°–22.5°) ve Kuzeydoğu (22.5°–67.5°) – Güneşlenme süresi daha kısa olup nemli mikroklimaya sahiptir.
- Doğu (67.5°–112.5°) – Sabah güneşine açık yönelim.
- Güneydoğu (112.5°–157.5°) ve Güney (157.5°–202.5°) – En fazla güneş alan yönlerdir, kuraklık riski yüksektir.
- Güneybatı (202.5°–247.5°) ve Batı (247.5°–292.5°) – Öğleden sonra güneşine maruz kalır.
- Kuzeybatı (292.5°–337.5°) – Güneşlenme süresi sınırlıdır, serin ve nemli alanlardır.
- Kuzey (337.5°–360°) – Tekrar kuzeye dönen yönelim, düşük güneşlenme oranıyla karakterizedir.


Bakı, gayrimenkul değerlemesinde dolaylı fakat önemli bir etkidir. Güney ve güneydoğu yönelimli araziler, yıl boyunca daha fazla güneş alması nedeniyle enerji verimliliği, ısınma maliyetleri ve yaşam konforu açısından avantaj sağlayabilir; bu durum özellikle soğuk iklimlerde piyasa değerini artırabilir. Buna karşılık, kuzey yönelimli alanlar daha düşük güneşlenme süreleri, nemli koşullar ve ısınma gereksiniminin artması gibi nedenlerle genellikle daha düşük piyasa değerine sahiptir. Dolayısıyla bakı analizi, gayrimenkul değerinin mekânsal bağlamda doğru yorumlanması açısından dikkate alınması gereken önemli bir topoğrafik değişkendir.

5.3.2. Yakınlık Analizleri

Topoğrafik faktörlere ek olarak, gayrimenkul değerlerini etkileyen bir diğer önemli unsur erişilebilirliktir. Bu kapsamda tüm yakınlık analizleri, öklidyen (doğrusal) mesafe ölçütü esas alınarak gerçekleştirilmiştir. Analizlerde, Coğrafi Bilgi Sistemleri Genel Müdürlüğü tarafından sağlanan Point of Interest (POI) katmanında yer alan önemli mekânsal unsurlar referans olarak kullanılmıştır. Söz konusu katmanda otobüs durakları, metro istasyonları, havaalanı, otogar, mezarlıklar, kültür merkezleri, itfaiye istasyonları, alışveriş merkezleri, pazar yerleri, askeri alanlar, parklar, polis merkezleri, ibadet alanları, turistik alanlar ve atık toplama noktalarına ilişkin konumsal veriler yer almaktadır.

Bu veriler, çalışma alanındaki her bir konutun söz konusu noktalara olan mesafesinin hesaplanmasında ve mekânsal değişkenlerin oluşturulmasında kullanılmıştır. Yakınlık analizleri, gayrimenkul değerlemesinde önemli bir rol oynamaktadır; zira ulaşım olanaklarına, kamusal hizmetlere, ticari alanlara veya rekreasyon alanlarına olan mesafe, bir mülkün piyasa değerini doğrudan etkileyebilmektedir. Dolayısıyla, bu analizler hem modelin mekânsal bağlamı doğru yansıtmasını hem de konut değer tahminlerinin gerçekçi ve güvenilir olmasını sağlamaktadır.


Şekil 23. Park Alanlarına Yakınlık Analizi



Şekil 23’de sunulan harita, çalışma alanındaki park alanlarına olan coğrafi yakınlık durumunu göstermektedir. Haritada, park alanları koyu yeşil renkle, çalışma alanı sınırı ise siyah çizgiyle belirtilmiştir.

Renk skalası, park alanlarına olan mesafeye göre gradyanlı bir şekilde görselleştirilmiştir: Koyu yeşil alanlar, park alanlarına çok yakın mesafede (0 metreye yakın) bulunan bölgeleri temsil etmektedir. Açık sarıdan pembe tonlara doğru ilerleyen renkler, park alanlarına olan mesafenin arttığını göstermektedir.


Şekil 24. Güvenlik Merkezlerine Yakınlık Analizi



Şekil 24’de sunulan harita, çalışma alanı sınırları içerisinde polis merkezlerine olan coğrafi yakınlık durumunu göstermektedir. Harita, kırmızıdan maviye doğru uzanan renk skalasıyla, güvenlik birimlerine olan yakınlık ve uzaklık düzeylerini görselleştirmektedir.

Haritada görüldüğü üzere, çalışma alanının güney ve güneydoğu kesimleri, güvenlik merkezlerine oldukça yakın olup kırmızı tonlarla ifade edilmiştir. Bu durum, söz konusu bölgelerdeki güvenlik altyapısının yoğunlaştığını ve erişilebilirliğin yüksek olduğunu göstermektedir. Buna karşılık, kuzey ve kuzeybatı bölgelerinde mesafeler arttıkça renk açık mavi ve koyu maviye dönmektedir; bu da bu alanların görece daha az güvenlik merkezi erişimine sahip olduğunu işaret etmektedir.


Şekil 25. Askeri Alanlara Yakınlık Analizi



Şekil 25’de sunulan harita, çalışma alanındaki konumların askeri alanlara olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, askeri bölgeler tarama (çizgili) desenle gösterilmiş, çalışma alanı ise siyah konturla sınırlandırılmıştır.

Renk skalasındaki kahverengi, açık turuncu tonlar, askeri bölgelere en yakın alanları (0 metreye yakın) göstermektedir. Koyu mor tonlar, askeri bölgelere en uzak bölgeleri temsil etmektedir.


Şekil 26. Endüstri Bölgelerine Yakınlık Analizi



Şekil 26’da sunulan harita, çalışma alanındaki konumların endüstri bölgelerine olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, endüstri bölgeleri gri renk ile gösterilmiş, çalışma alanı ise siyah konturla sınırlandırılmıştır.

Renk skalasındaki koyu kahverengi tonlar, endüstri bölgelerine en yakın alanları (0 metreye yakın) göstermektedir. Açık sarıdan mavi-yeşil tonlara doğru ilerledikçe mesafenin arttığı görülmektedir. Haritanın özellikle güney ve batı kesimlerinde koyu tonlar yoğunlaşmakta, bu durum söz konusu bölgelerin endüstri alanlarına fiziksel olarak oldukça yakın olduğunu göstermektedir. Buna karşılık, kuzey kesimdeki açık ve yeşil tonlar, endüstri bölgelerine en uzak mesafedeki alanları temsil etmektedir.


Şekil 27. Okullara Yakınlık Analizi



Şekil 27’de sunulan harita, çalışma alanındaki konumların okul alanlarına olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, okullar açık sarı tonlarla gösterilmiş, çalışma alanı ise siyah konturla sınırlandırılmıştır.

Renk skalasındaki mor tonlar, okul alanlarına en yakın bölgeleri (0 metreye yakın) göstermektedir. Yeşil tonlara doğru ilerledikçe mesafe artmakta, okullara erişim azalmaktadır. Haritanın güney ve orta kesimlerinde mor renklerin yoğunluğu, bu bölgelerin okullara oldukça yakın olduğunu göstermektedir. Buna karşılık, kuzey kesimdeki yeşil tonlar, okullara en uzak mesafedeki alanları temsil etmektedir. Bu bölgelerde eğitim altyapısına erişimin sınırlı olduğu görülmektedir.


Şekil 28. Üniversitelere Yakınlık Analizi



Şekil 28’de sunulan harita, çalışma alanındaki konumların üniversitelere olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, üniversite yerleşkeleri açık bej renkle gösterilmiş, çalışma alanı ise siyah konturla sınırlandırılmıştır.

Renk skalasında, kırmızı ve turuncu tonlar, üniversitelere en yakın bölgeleri (0 metreye yakın) temsil ederken; sarı, yeşil ve maviye doğru geçişler, üniversitelere olan mesafenin arttığını göstermektedir. Haritanın güney kesimlerinde üniversiteye erişim oldukça yüksek düzeydeyken, kuzey bölgelerinde mesafenin artmasıyla birlikte erişim olanakları zayıflamaktadır. Özellikle kuzeydeki koyu mavi tonlar, üniversiteye erişimin en sınırlı olduğu alanları temsil etmektedir.


Şekil 29. Hastanelere Yakınlık Analizi




Şekil 29’da sunulan harita, çalışma alanındaki konumların hastane alanlarına olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, hastaneler açık bej tonla gösterilmiş, çalışma alanı ise siyah konturla sınırlandırılmıştır.

Renk skalasında koyu kırmızı tonlar, hastanelere en yakın konumları (0 metreye yakın) temsil ederken, açık gri-siyah tonlara doğru ilerledikçe mesafenin arttığı görülmektedir. Haritanın güney ve güneydoğu bölgelerinde kırmızı tonlar yoğunlaşmakta olup bu bölgelerin hastanelere oldukça yakın olduğu anlaşılmaktadır. Kuzey kesiminde ise hastanelere olan uzaklık artmakta ve sağlık hizmetlerine erişimin sınırlı olduğu bir alan oluşmaktadır.

Şekil 30. Havalimanına Yakınlık Analizi




Şekil 31. İbadet Yerlerine Yakınlık Analizi



Şekil 31’de sunulan harita, çalışma alanındaki konumların ibadet yerlerine olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, ibadet yerleri koyu yeşil renkle sembolize edilmiş, çalışma alanı ise siyah konturla sınırlandırılmıştır.

Renk skalasında, pembe tonlar, ibadet yerlerine en yakın bölgeleri (0 metreye yakın) temsil ederken, açık yeşil tonlara doğru ilerledikçe mesafenin arttığı görülmektedir. Haritanın güney ve güneydoğu kesimlerinde ibadet yerlerinin yoğunluğu fazla olup, bu alanlarda dini mekânlara erişim oldukça yüksektir. Buna karşın, kuzey kesimlerinde ibadet yerlerinin seyrek olması nedeniyle mesafe artmakta ve bu durum açık renklerle haritaya yansımaktadır.


Şekil 32. İtfaiye Merkezlerine Yakınlık Analizi



Şekil 32’de sunulan harita, çalışma alanındaki konumların itfaiye merkezlerine olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, itfaiye merkezleri açık bej renkle gösterilmiş, çalışma alanı ise siyah konturla sınırlandırılmıştır.

Renk skalasında, koyu kırmızı tonlar, itfaiye merkezlerine en yakın alanları (0 metreye yakın) temsil ederken; açık kırmızıdan griye doğru ilerledikçe mesafenin arttığı gözlemlenmektedir. Haritanın güney kesimlerinde kırmızı renk yoğunluğu, bu bölgelerde itfaiye hizmetlerine erişimin güçlü olduğunu göstermektedir. Buna karşılık, kuzey kesimlerinde açık tonlardan griye geçişle birlikte erişim mesafesi artmakta ve acil müdahale sürelerinin uzayabileceği alanlar ortaya çıkmaktadır.


Şekil 34. Mahalle Merkezlerine Yakınlık Analizi



Şekil 34'te sunulan harita, çalışma alanındaki konumların yerleşim merkezlerine (mahalle merkezleri, semt merkezleri vb.) olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, merkezler kırmızı noktalarla gösterilmiş, çalışma alanı ise siyah konturla sınırlandırılmıştır.

Renk skalasında, kırmızı ve turuncu tonlar, merkezlere en yakın alanları (0 metreye yakın) ifade ederken; açık mavi ve mor tonlara doğru ilerledikçe merkezlere olan mesafenin arttığı gözlemlenmektedir. Bu görselleştirme sayesinde, çalışma alanının büyük kısmının çeşitli merkezlere oldukça yakın olduğu ve merkezlerin nispeten homojen bir şekilde dağıldığı anlaşılmaktadır. Ancak özellikle kuzeydoğu ve kuzeybatı kesimlerde mesafe artmakta, bu durum mekânsal erişim açısından bazı dezavantajları işaret etmektedir.


Şekil 36. Otobüs Duraklarına Yakınlık Analizi



Şekil 36’da sunulan harita, çalışma alanındaki konumların otobüs duraklarına olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, otobüs durakları beyaz çerçeveli nokta sembolleriyle gösterilmiş, çalışma alanı ise siyah konturla sınırlandırılmıştır.

Renk skalasında, koyu pembe-kırmızı tonlar, otobüs duraklarına en yakın alanları (0 metreye yakın) göstermekte; sarıdan yeşil-maviye doğru geçişler ise mesafenin giderek arttığını ifade etmektedir. Haritanın güney ve güneybatı bölgelerinde kırmızı tonların yoğunluğu, bu bölgelerde otobüs duraklarına erişimin oldukça yüksek olduğunu göstermektedir. Buna karşılık, kuzey ve kuzeydoğu bölgelerinde renk tonlarının açılmasıyla birlikte duraklara olan mesafe artmakta ve erişim açısından dezavantajlı alanlar oluşmaktadır.


Şekil 37. Pazar Yerlerine Yakınlık Analizi



Şekil 37’de sunulan harita, çalışma alanındaki konumların pazar yerlerine olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, pazar yerleri siyah renkli sembollerle gösterilmiş, çalışma alanı sınırı ise siyah konturla belirlenmiştir.

Renk skalasında, kırmızı tonlar, pazar yerlerine en yakın bölgeleri (0 metreye yakın) temsil ederken; sarıdan yeşile doğru geçişler, pazar yerlerine olan mesafenin arttığını göstermektedir. Haritanın güney ve güneydoğu bölgelerinde kırmızı renklerin yoğunluğu, bu alanlarda pazar yerlerine erişimin yüksek olduğunu ortaya koymaktadır.


Şekil 38. Turizm Merkezlerine Yakınlık Analizi



Şekil 38’de sunulan harita, çalışma alanındaki konumların turizm merkezlerine olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, turizm merkezleri açık bej tonla sembolize edilmiş, çalışma alanı ise siyah konturla sınırlandırılmıştır.

Renk skalasında, pembe tonlar, turizm merkezlerine en yakın alanları (0 metreye yakın) temsil ederken; açık yeşil ve koyu yeşil tonlara doğru ilerledikçe mesafenin arttığı gözlemlenmektedir. Haritanın güneydoğu kesimlerinde, turizm merkezlerine yakınlık yüksek olup bu alanlar daha avantajlı konumdadır. Buna karşılık, kuzey ve batı kesimlerinde mesafe artmakta ve bu bölgelerde turistik çekim merkezlerine erişim zayıflamaktadır.


Şekil 39. Yollara Yakınlık Analizi



Şekil 39’da sunulan harita, çalışma alanındaki konumların karayolu ağına olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, yollar gri çizgilerle gösterilmiş, çalışma alanı sınırları ise siyah konturla belirtilmiştir.

Renk skalasında, yeşil tonlar, yolların hemen yakınındaki alanları (0 metreye yakın) temsil ederken; açık sarı-beyaz tonlara doğru geçişler, yollara olan mesafenin arttığını göstermektedir. Çalışma alanının büyük bir bölümünde koyu yeşil tonların baskın olması, bu bölgelerde yol altyapısına erişimin oldukça yüksek olduğunu ortaya koymaktadır. Bununla birlikte, haritanın kuzey ve kuzeybatısında yer alan sarımsı bölgeler, yol ağından görece daha uzak alanlara işaret etmektedir.


Şekil 40. Mezarlıklara Yakınlık Analizi



Şekil 40'ta sunulan harita, çalışma alanındaki konumların mezarlıklara olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, mezarlıklar açık bej tonlarla gösterilmiş, çalışma alanı ise siyah konturla sınırlandırılmıştır.

Renk skalasında, koyu mavi tonlar, mezarlıklara en yakın alanları (0 metreye yakın) göstermektedir. Açık sarıya doğru geçiş ise mesafenin arttığını ifade etmektedir. Haritanın merkez ve güney kesimlerinde mezarlıklar yoğunlaştığı için erişim oldukça kolaydır. Bu bölgeler, mavi tonların baskın olduğu ve mezarlıklara yakın konumlanan alanlardır. Buna karşılık, kuzey ve batı uç kesimlerinde mezarlıklara olan mesafe artmakta ve bu durum açık sarı tonlarla haritaya yansımaktadır.


Şekil 41. Atık Alanlarına Yakınlık Analizi



Şekil 41’de sunulan harita, çalışma alanındaki konumların atık alanlarına olan mesafelerini analiz etmek amacıyla oluşturulmuştur. Haritada, atık noktaları beşgen sembollerle gösterilmiş, çalışma alanı ise siyah konturla sınırlandırılmıştır.


Renk skalasındaki koyu kahverengi tonlar, atık alanlarına en yakın bölgeleri (0 metreye yakın) göstermektedir. Açık yeşil-yeşil tonlara doğru ilerledikçe, mesafenin arttığı görülmektedir. Haritanın güney kısmında yer alan koyu tonlu bölgeler, atık noktalarına doğrudan komşu veya yakın olan alanlardır. Kuzeye doğru uzaklaştıkça renkler açılmakta ve mesafe artmaktadır.

Şekil 42. Nüfus Yoğunluğu Haritası



Şekil 42’de sunulan 2024 yılına ait çalışma alanının nüfus yoğunluğu dağılımı grid tabanlı olarak gösterilmektedir. Nüfus yoğunluğu kişi/km² değerlerine göre sınıflandırılmış olup, en düşük değerler beyaz ve açık tonlarda, en yüksek değerler ise koyu kırmızı tonlarda temsil edilmiştir. Analiz sonuçlarına göre en yoğun nüfuslu alanlar, çalışma alanının güneydoğu kesiminde yer almakta ve km² başına 25.000’in üzerinde nüfusa ulaşmaktadır. Orta yoğunluklu bölgeler genellikle doğu ve güney kısımlarda konumlanırken, düşük yoğunluklu veya yerleşimin olmadığı bölgeler kuzey ve batı kesimlerde yoğunlaşmıştır. Bu mekânsal dağılım, kentsel gelişim alanlarının, ulaşım ağlarının ve ekonomik faaliyetlerin yoğunlaştığı bölgelerle doğrudan ilişkilidir.

Şekil 43. Bina Yoğunluğu Analizi



Şekil 43’de sunulan harita, çalışma alanında bina yoğunluğunun mekânsal dağılımını göstermektedir. Haritada koyu kırmızı tonlardan açık krem tonlara kadar uzanan bir renk skalası kullanılarak, alan biriminde düşen bina yoğunluğu görselleştirilmiştir. Yoğunluk değerleri, “Density” analiziyle elde edilmiştir.

- Açık tonlar (0,001 – 74.354): Bina yoğunluğunun oldukça düşük olduğu, yapılaşmanın seyrek olduğu alanlar.
- Orta tonlar (208.035 – 491.875): Orta düzeyde yapılaşmanın olduğu bölgeler.
- Koyu tonlar (646.709 – 729.241): Yüksek bina yoğunluğuna sahip, genellikle yoğun yerleşim bölgeleri ve/veya çok katlı yapıların bulunduğu alanlar.

Çalışma alanının güneydoğu kesimi, en koyu renk tonlarında gösterilmiş olup, bu bölgede bina yoğunluğunun en yüksek seviyede olduğu anlaşılmaktadır. Bu alanın, çok katlı konutlar, ticaret merkezleri veya yoğun kentsel gelişim bölgelerini kapsadığı değerlendirilebilir. Kuzey ve batı bölgeleri ise açık renklerle gösterilmiş olup, bu alanlarda bina yoğunluğu düşük, yerleşim daha seyrek veya kırsal özellik taşımaktadır. Ortaya çıkan bu mekânsal desen, kentsel gelişimin belirli odaklarda toplandığını ve yapılaşmanın homojen dağılmadığını göstermektedir.

Bina yoğunluğu, gayrimenkul değerini etkileyen önemli kentsel morfoloji göstergelerinden biridir. Yüksek bina yoğunluğuna sahip bölgeler, genellikle merkezî konum, gelişmiş altyapı, ticaret ve hizmet olanaklarına erişim avantajlarıyla ilişkilidir ve bu durum gayrimenkul talebini artırarak piyasa değerlerini yükseltebilmektedir. Öte yandan, aşırı yoğunluk, trafik sıkışıklığı, gürültü veya çevresel baskılar gibi olumsuz etkiler yaratabileceğinden, bazı durumlarda alıcı tercihlerine bağlı olarak değeri olumsuz yönde etkileyebilir. Düşük yoğunluklu alanlar ise daha geniş yaşam alanı ve düşük nüfus baskısı gibi avantajlara sahip olmakla birlikte, merkezî olanaklara erişim kısıtlılığı nedeniyle nispeten daha düşük piyasa değerine sahip olabilmektedir.

5.4. Coğrafi Özelliklerin Entegrasyonu

Bu çalışmada, coğrafi analizler sonucunda elde edilen tematik veriler konut veri kümesine entegre edilerek, her bir konutun çevresel özelliklerinin sayısal olarak temsil edilmesi sağlanmıştır. Bu kapsamda, raster tabanlı analiz çıktıları (örneğin eğim, bina yoğunluğu, nüfus yoğunluğu vb.) uygun formatta konut nokta verisi ile Spatial Join yöntemi kullanılarak ilişkilendirilmiştir. Spatial Join işlemi sırasında, her konut noktasının karşılık geldiği analiz değeri veri tablosuna yeni bir sütun olarak eklenmiştir. Veri setindeki özelliklerin ArcGIS Pro ve Python ortamında Türkçe karakterleri kabul etmemesi nedeniyle sütun isimleri İngilizce olarak yazılmış, ancak Türkçe karşılıkları tabloda ayrıca belirtilmiştir. Böylece her bir konut, fiziksel niteliklerinin yanı sıra çevresel ve konumsal bağlamı da temsil eden mekânsal öz niteliklerle zenginleştirilmiştir. Entegre edilen öz nitelikler aşağıda sıralanmaktadır:

- Havaalanına Uzaklık – “DistanceToAirport”
- Otogara Uzaklık – “DistanceToBusStation”

- Otobüs Duraklarına Uzaklık – “DistanceToBusStop”
- Mezarlıklara Uzaklık – “DistanceToCemetery”
- Kültür merkezlerine Uzaklık – “DistanceToCulture”
- Endüstri Alanlarına Uzaklık – “DistanceToIndustry”
- İtfaiye Merkezine Uzaklık – “DistanceToFireStation”
- Hastanelere Uzaklık – “DistanceToHospital”
- Alışveriş Merkezine Uzaklık – “DistanceToMall”
- Pazar Yerlerine Uzaklık – “DistanceToMarketplaces”
- Askeri Alanlara Uzaklık – “DistanceToMilitary”
- Parklara Uzaklık – “DistanceToParks”
- Şehir Merkezlerine Uzaklık – “DistanceToCenters”
- Polis Merkezlerine Uzaklık – “DistanceToPolice”
- İbadet Alanlarına Uzaklık – “DistanceToPrayerHalls”
- Okullara Uzaklık – “DistanceToSchools”
- Turistik Alanlara Uzaklık – “DistanceToTouristic”
- Üniversitelere Uzaklık – “DistanceToUniversity”
- Atık Noktalarına Uzaklık – “DistanceToWaste”
- Eğim – “Slope”
- Bakı – “Aspect”

Bu entegrasyon süreci sonucunda, her bir konutun bulunduğu konum itibarıyla çevresel faktörlere ilişkin sayısal değerleri içeren ve coğrafi olarak zenginleştirilmiş bir veri kümesi (*geo-enriched dataset*) oluşturulmuştur. Bu veri kümesi, konutların mekânsal ve çevresel özelliklerini tek bir yapıda bütünleştirerek modelleme sürecinde kullanılacak kapsamlı bir girdi seti sağlamaktadır. Elde edilen bu yapı, sonraki aşamada makine öğrenmesi algoritmalarının eğitilmesinde temel veri kaynağı olarak kullanılmıştır. Bu sayede, mekânsal boyutun konut değer tahminlerine yansıtılması mümkün hale gelmiş ve elde edilen sonuçların gerçekçiliği artırılmıştır.

5.5. Keşifsel Veri Analizi

Mekânsal özelliklerin konut verilerine entegre edilmesinin ardından, ilk olarak coğrafi olarak zenginleştirilmiş veri seti Jupyter Notebook ortamında Python

kullanılarak Pandas DataFrame formatına aktarılmıştır. Veriler hakkında ayrıntılı ve derinlemesine bilgi elde edebilmek amacıyla keşifsel veri analizi (EDA, *Exploratory Data Analysis*) süreci yürütülmüştür.

EDA, veri bilimi projelerinin temel adımlarından biri olup, veri setinin istatistiksel özetler ve görsel yöntemler aracılığıyla sistematik biçimde incelenmesini sağlar. Bu süreç, verilerin yapısını anlamamanın yanı sıra modelleme öncesinde gerekli veri temizleme ve dönüştürme adımlarına yön vermesi açısından kritik öneme sahiptir. Erken aşamada yapılacak doğru analizler, sonraki modelleme sürecinde hem doğruluk hem de güvenilirlik açısından önemli kazanımlar sağlar.


Bu aşamada veri kümesindeki minimum, maksimum, ortalama ve standart sapma gibi tanımlayıcı istatistikler hesaplanmış; eksik (null) değerler tespit edilerek nedenleri incelenmiştir. Değişkenler arasındaki ilişkileri ortaya koymak amacıyla korelasyon matrisleri oluşturulmuş; ayrıca histogramlar, kutu grafikleri, dağılım grafikleri ve ikili karşılaştırma grafikleri gibi görselleştirme tekniklerinden yararlanılmıştır. Bu analizler sırasında Pandas, NumPy, Matplotlib ve Seaborn kütüphaneleri kullanılmıştır.

Bu sayede, veri setindeki genel yapılar, eğilimler, aykırı değerler ve olası veri tutarsızlıkları erken aşamada belirlenebilmiş, böylece modelleme aşamasına sağlam ve güvenilir bir veri temeli sağlanmıştır.

5.5.1. İlçelere Göre Konut Değeri Dağılımı

Yenimahalle ve Keçiören ilçelerine ait konut değerlerinin dağılımı incelenerek her iki ilçedeki fiyat aralıklarının genel eğilimleri karşılaştırmalı biçimde ortaya konulmuştur. Grafikler, konut değerlerinin yoğunlaştığı aralıkları görsel olarak sunmakta ve dağılımın genel yapısını ortaya koymaktadır. Analizlerin sağlıklı yapılabilmesi için grafikler aykırı değerlerden arındırılmıştır. Bu sayede ilçeler arasındaki tipik değer farklılıkları ya da benzerlikler daha net bir biçimde gözlemlenebilmektedir.

Şekil 44. İlçelerin Konut Değeri Dağılımı



Şekil 44'te Keçiören ve Yenimahalle ilçelerine ait konut değerlerinin dağılımı gösterilmektedir. Grafikler, histogram ve üzerine yerleştirilmiş yoğunluk eğrisi (*kernel density estimation*) ile hazırlanmıştır.

Keçiören'deki fiyat dağılımı sağa çarpık bir yapı sergilemekte olup, konut değerleri büyük ölçüde 2–4 milyon TL aralığında yoğunlaşmaktadır. Bu durum, ilçede daha uygun fiyatlı konut stokunun baskın olduğunu ve ağırlıklı olarak düşük-orta gelir gruplarına hitap eden bir konut piyasasının varlığını göstermektedir.


Yenimahalle'de ise fiyat dağılımı daha simetrik bir görünüm arz etmekte, 3,5–5 milyon TL bandında yoğunlaşmaktadır. Bu eğilim, bölgedeki konutların fiyat açısından daha homojen dağıldığını ve orta-üst gelir grubuna yönelik konutların ağırlıkta olduğunu ortaya koymaktadır.

Her iki ilçede de yüksek fiyatlı konutların sayısı sınırlıdır; ancak Keçiören'de bu konutların genel dağılım üzerindeki etkisi daha belirgindir.

5.5.2. İlçe Bazında Konut Değeri ve Alan İlişkisi

Konutların kullanım alanı ile piyasa değeri arasındaki ilişkinin ilçeler bazında nasıl değiştiği incelenerek genel eğilimler karşılaştırmalı biçimde ortaya konulmuştur. Grafikler, alan büyüklüğünün fiyat üzerindeki etkisini ve bu ilişkinin Keçiören ile Yenimahalle ilçelerinde gösterdiği farklılıkları göstermektedir.

Şekil 45. Konut Değeri ve Alan Dağılımı



Şekil 45'te sunulan dağılım grafiği, konut değeri ile brüt alan arasındaki ilişkiyi göstermektedir. Genel olarak her iki ilçede de iki değişken arasında pozitif yönlü bir ilişki olduğu görülmektedir.


Keçiören'de alan aralığı 50 m² ile 275 m² arasında değişmekte, değerler ise 1–9 milyon TL bandında dağılım göstermektedir. Yoğunluk, özellikle 80–200 m² büyüklüğe sahip konutlarda ve 2–6 milyon TL değer aralığında belirginleşmektedir. Ayrıca, yüksek fiyatlı küçük alanlı konutların görece daha fazla olduğu dikkat çekmektedir.

Yenimahalle'de alan dağılımı benzer şekilde 50–275 m² aralığında olmakla birlikte, 80–200 m² bandında daha yoğun bir kümelenme gözlenmektedir. Değerler yine 1–9 milyon TL aralığında olmakla birlikte, 2–6 milyon TL bandında yoğunlaşma görülmektedir. Bu durum, Yenimahalle'de fiyatların alan ile daha orantılı bir dağılım sergilediğini ortaya koymaktadır.

5.5.3. İlçe Bazında Mahallelere Göre Ortalama Konut Değeri

Mahalle ölçeğinde ortalama konut değerleri grafikler aracılığıyla gösterilmiş ve ilçeler arasındaki mekânsal değer farklılıkları mahalle düzeyinde ayrıntılı biçimde karşılaştırılmıştır. Bu yaklaşım, ilçeler arasındaki piyasa farklılıklarının mekânsal ölçekte daha net bir şekilde ortaya konmasına olanak sağlamaktadır.

Şekil 46. Keçiören Mahallelerine Göre Ortalama Konut Değeri




Şekil 46’da Keçiören ilçesindeki mahallelere göre ortalama konut değerleri (TL cinsinden) gösterilmektedir. Grafikte her çubuk bir mahalleyi temsil etmekte, çubukların yüksekliği ortalama konut değerini, üzerlerindeki küçük siyah çizgiler ise standart hata/güven aralığını yansıtmaktadır.

Ovacık Mahallesi, yüksek ortalama fiyatı ile dikkat çekmekte ve diğer mahallelerden ayrılmaktadır. Buna karşılık Karargahtepe, Gümüşdere, Güzelyurt ve Yeşilöz gibi mahallelerde fiyatlar görece düşük seyretmektedir. Bu durum, söz konusu mahallelerdeki konutların fiziksel ve çevresel özelliklerinden veya sosyal-ekonomik yapısından kaynaklanabilir.

Yükseltepe, Şefkat, Ayvalı ve Şenlik gibi mahallelerde fiyatlar ortalama düzeyde seyretmektedir. Ancak Yavuz ve Ovacık Mahallesi istisnai biçimde yüksek ortalama değeriyle öne çıkmaktadır. Bu durum, veri setinde yer alan konutların özelliklerine (ör. daha büyük kullanım alanları veya yeni yapılaşmalar) bağlı olabilir.

Bazı mahallelerde hata çubuklarının uzunluğu dikkat çekmektedir. Bu, fiyatların mahalle içinde oldukça değişken olduğunu (heterojen yapı) göstermektedir. Örneğin, Gümüşdere, Hasköy, Yeşilöz, Şefkat, Gümüşkaya ve Şenyuva mahallelerinde yüksek hata payı gözlenmektedir. Bu durum, aynı mahallede lüks ve daha mütevazı konutların bir arada bulunmasından kaynaklanıyor olabilir.

Şekil 47. Yenimahalle Mahallelerine Göre Ortalama Konut Değeri



Şekil 47’de ise Yenimahalle ilçesindeki mahallelerin ortalama konut değerleri (TL cinsinden) gösterilmektedir. Keçiören için hazırlanan grafikte benzer yapıda olan bu grafik, mekânsal düzeydeki değer farklılıklarını mahalle bazında görselleştirmektedir.

En yüksek ortalama konut değerine sahip mahalleler arasında Susuz, Yuvaköy, Aşağı yahyalar, Emniyet ve Gayret öne çıkmaktadır. Susuz, yaklaşık 7 milyon TL’ye yaklaşan ortalama fiyatıyla ilk sırada yer almaktadır. Bu durum, söz konusu mahallelerde yüksek değerli konutların, merkezi konum avantajının veya prestijli yapılaşmaların etkisini yansıtır olabilir.


En düşük ortalama konut değerleri ise İvedikköy, Demetlale, Demetgöl, Demetevler, Karşıyaka ve Ergenekon, mahallelerinde görülmektedir. Özellikle İvedikköy Mahallesi, 2 milyon TL’nin altında kalan değeriyle dikkat çekmektedir.

Özevler, Mehmet Akif Ersoy, Ostim, İvedikOSB, 25 Mart, Barış, Beştepe ve Gayret gibi mahallelerde hata çubuklarının uzunluğu, konut değerlerinin mahalle içinde oldukça değişken olduğunu göstermektedir. Başka bir deyişle, bu mahallelerde hem yüksek standartlı hem de daha düşük segmentte konutlar bir arada bulunmaktadır.

5.5.4. İlçe Bazında Isınma Tiplerine Göre Alan-Fiyat İlişkisi

Farklı ısınma tiplerine sahip konutlarda brüt alan ile fiyat arasındaki ilişki incelenmiş ve ısınma türünün fiyatlandırma üzerindeki etkisi ilçeler bazında değerlendirilmiştir.

Şekil 48. Keçiören İlçesi Farklı Isınma Tiplerine Göre Alan-Fiyat İlişkisi




Şekil 48’de Keçiören ilçesindeki konutlarda ısıtma türlerine göre konut fiyatı ile brüt alan (m^2) arasındaki ilişkiyi görselleştirmektedir. Her bir ısıtma tipi farklı bir grup olarak ele alınmış, regresyon eğrileri ve bunlara ait güven aralıkları grafik üzerinde sunulmuştur.

Tüm ısıtma tiplerinde brüt alan arttıkça konut fiyatının da yükseldiği gözlenmektedir. Ancak regresyon eğimlerinin farklılığı, artış hızının her ısıtma tipinde aynı olmadığını ortaya koymaktadır. Yerden Isıtma ve Merkezi Isı Pay Ölçer sistemlerinin eğrisi daha yukarıdan başlıyor, yani yüksek fiyatlı konutlarda yaygın. Bu durum söz konusu sistemlerin konfor ve enerji verimliliği açısından avantaj

sağlamasıyla açıklanabilir. Doğalgaz Kombi ve Merkezi Sistem konutlar daha yaygın ve yoğunluk olarak orta düzeyde fiyatlandırılmıştır. Buna karşılık, Kat Kaloriferi ve Diğer kategorileri genellikle daha düşük fiyatla başlayıp daha geniş alana sahip konutlarda da bulunmaktadır. Dolayısıyla, ısınma tipleri konut değerlerinde belirleyici bir farklılaşma yaratmakta ve bu durum değerlendirme modellerine entegre edilmesi gereken önemli bir değişken olduğunu göstermektedir.

Şekil 49. Yenimahalle İlçesi Farklı Isınma Tiplerine Göre Alan-Fiyat İlişkisi



Şekil 49’da, Yenimahalle ilçesindeki konutlarda farklı ısıtma tiplerine göre konut fiyatı ile brüt alan (m²) arasındaki ilişki gösterilmektedir. Her bir ısıtma türü ayrı bir kategori olarak ele alınmış; regresyon doğruları ve bunlara ait güven aralıkları grafik üzerinde sunulmuştur.

Tüm ısıtma türlerinde brüt alan ile konut fiyatı arasında pozitif yönlü bir ilişki bulunmakta, alan arttıkça fiyat da yükselme eğilimi göstermektedir. Ancak artış hızının (regresyon eğimi) ısıtma türlerine göre farklılık gösterdiği görülmektedir.


Yerden Isıtma, Merkezi Isı pay Ölçer ve Merkezi Sistem uygulamalarında güven aralıklarının görece dar olması, verinin daha homojen ve stabil bir dağılıma sahip olduğunu ortaya koymaktadır. Buna karşılık, Diğer kategorisinde güven aralıklarının oldukça geniş olması, bu grupta veri çeşitliliğinin ve belirsizliğin fazla olduğunu göstermektedir.

Sonuçlar, Yenimahalle ilçesinde konut fiyatları ile brüt alan arasındaki ilişkinin kullanılan ısıtma sistemine bağlı olarak anlamlı biçimde farklılaştığını ortaya koymaktadır. Özellikle Yerden Isıtma sistemine sahip konutlar, diğer ısıtma türlerine kıyasla daha yüksek fiyat seviyelerine ulaşmaktadır. Merkezi sistemler ve Kat Kaloriferi de benzer şekilde fiyat üzerinde olumlu etki yaratmaktadır. Buna karşılık, Doğalgaz Kombili sistemlerin Keçiören'e kıyasla Yenimahalle'de daha sınırlı bir fiyat artışı ile ilişkili olduğu gözlenmiştir. Diğer kategorisindeki sistemler ise fiyat üzerinde düşük etkili kalmaktadır. Bu bulgular, konut değerlemesinde ısıtma sisteminin dikkate alınması gereken önemli bir değişken olduğunu göstermektedir.

5.5.5. İlçe Bazında Konutların Alan, Fiyat ve Merkeze Uzaklık İlişkisi

Bu analizde, konutun şehir merkezine olan mesafesi ile fiyat ve brüt alan arasındaki ilişkiler incelenmektedir. Mesafe faktörünün piyasa değeri üzerindeki etkisi ilçeler özelinde değerlendirilmiştir.

Şekil 50. Keçiören İlçesi Brüt Alan, Fiyat ve Merkeze Uzaklık İlişkisi




Şekil 50, Keçiören ilçesindeki konutların brüt alanı, konut fiyatı, merkeze uzaklığı (DistanceToCenters) ve nüfus yoğunluğu (Population) arasındaki çok değişkenli ilişkiyi görselleştirmektedir. Grafikte her bir nokta bir konutu temsil etmekte olup dört temel değişken bir arada gösterilmiştir. X eksenini brüt alanı (m^2), Y eksenini ise konut fiyatını (TL) ifade etmektedir. Renk skalasında açık tonlar merkeze daha uzak, koyu tonlar ise merkeze daha yakın konutları göstermektedir. Baloncuk büyüklüğü ilgili konutun bulunduğu mahallenin nüfusunu yansıtmakta, daha büyük baloncuklar daha kalabalık bölgeleri temsil etmektedir.

- Brüt alan ile fiyat arasında pozitif ilişki olduğu görülmektedir. Genel olarak brüt alan arttıkça konut fiyatları da artış göstermektedir. Ancak bazı büyük konutların görece olarak düşük fiyatlı olması, mekânsal konum veya nitelik farklılıklarını işaret edebilir.
- Renk dağılımı dikkate alındığında, merkeze daha yakın konutların (koyu tonlar) benzer büyüklükteki konutlara kıyasla görece daha yüksek fiyatlara sahip olma eğilimi gözlenmektedir. Ancak bu eğilim tüm brüt alan gruplarında belirgin değildir; özellikle $100 m^2$ ve üzerindeki konutlarda, merkezden uzak mahallelerde de geniş fiyat aralıkları ortaya çıkmaktadır. Bu durum, konumsal

faktörlerin piyasa değeri üzerinde etkili olmakla birlikte tek başına belirleyici olmadığını göstermektedir.

- Nüfus yoğunluğunun etkisi, büyük baloncuklarla temsil edilmiştir. Nüfusun yoğun olduğu bölgelerdeki konutlar, genel olarak daha çeşitli fiyat ve alan aralıklarında yer almakta olup, bu durum kentsel karma kullanım alanlarının etkisi veya nitelik farklılıklarının fazlalığı olarak yorumlanabilir.
- Grafik aynı zamanda yoğunlukla 70–150 m² arasındaki konutların piyasada baskın olduğunu ve bu alan aralığındaki konutların geniş bir fiyat dağılımına sahip olduğunu ortaya koymaktadır.

Şekil 51. Yenimahalle İlçesi Brüt Alan, Fiyat ve Merkeze Uzaklık İlişkisi



Şekil 51’de, Yenimahalle ilçesindeki konutların brüt alanı ile fiyatı arasındaki ilişki, aynı zamanda merkeze uzaklık (DistanceToCenters) ve nüfus yoğunluğu (Population) değişkenleriyle birlikte çok boyutlu olarak görselleştirilmiştir. Grafikte her bir nokta bir konutu temsil etmekte olup dört temel değişken bir arada sunulmaktadır. X eksenini brüt alanı (m²), Y eksenini ise konut fiyatını (TL) göstermektedir. Renk skalasında açık tonlar merkeze daha uzak, koyu tonlar ise merkeze daha yakın konutları temsil etmektedir. Baloncuk büyüklüğü, ilgili konutun

bulunduğu mahallenin nüfusunu yansıtmakta; daha büyük baloncuklar daha kalabalık bölgeleri ifade etmektedir.


- Renk dağılımı dikkate alındığında, merkeze daha yakın konutların (koyu tonlar) benzer büyüklükteki konutlara kıyasla genel olarak daha yüksek fiyatlara sahip olma eğiliminde olduğu görülmektedir. Ancak bu eğilim tüm alan gruplarında belirgin değildir; bazı uzak mahallelerde de benzer fiyat seviyeleri gözlenmektedir. Bu durum, konumsal faktörlerin piyasa değeri üzerinde etkili olmakla birlikte tek başına belirleyici olmadığını ortaya koymaktadır.
- Grafik ayrıca, yüksek nüfuslu bazı mahallelerdeki konutların görece daha düşük fiyatlara sahip olduğunu göstermektedir. Bu bulgu, nüfus yoğunluğunun fiyat üzerindeki etkisinin tek yönlü olmadığını ve mahalle düzeyindeki diğer sosyoekonomik faktörlerle birlikte değerlendirilmesi gerektiğini ortaya koymaktadır.

Genel olarak, her iki ilçede de merkezî alanlara yakınlık fiyatlar üzerinde belirgin bir artış etkisi yaratırken, nüfus yoğunluğunun etkisi mahallelerin sosyoekonomik yapısına bağlı olarak değişkenlik göstermektedir.

5.5.6. İlçe Bazında Alan, Fiyat ve Alışveriş Merkezlerine

Bu analizde, konutların alışveriş merkezlerine olan uzaklıklarının fiyat ve alan değişkenleriyle ilişkisi analiz edilmekte; ilçeler arasındaki farklar erişilebilirlik ve tüketici davranışları bağlamında yorumlanmaktadır.

Şekil 52. Keçiören ve Yenimahalle İlçeleri Brüt Alan, Fiyat ve Alışveriş Merkezlerine Uzaklık İlişkisi



Şekil 52, Keçiören ve Yenimahalle ilçelerindeki konutların üç boyutlu (3B) dağılımını göstermektedir. Her iki alt grafik de konut değerinin, brüt alan (m²) ve alışveriş merkezlerine uzaklık (km) değişkenleriyle ilişkisini görselleştirmektedir.

Keçiören:

- Brüt alan ile fiyat arasında pozitif yönlü bir ilişki göze çarpmaktadır; alan arttıkça konut fiyatları da genellikle artmaktadır.
- Alışveriş merkezine olan uzaklık (Z eksen) arttıkça konut fiyatlarının daha düşük seviyelerde kümelendiği dikkat çekmektedir.
- Noktaların çoğunluğunun 1–2 km mesafede yoğunlaşması, konutların büyük kısmının alışveriş merkezlerine nispeten yakın konumlandığını ve bu yakınlığın fiyatlar üzerinde yukarı yönlü etki yaratabileceğini göstermektedir.

Yenimahalle:

- Benzer şekilde, brüt alan ile fiyat arasında pozitif bir ilişki söz konusudur.
- Ancak Keçiören'e kıyasla daha geniş bir uzaklık dağılımı bulunmaktadır. 0,5–3 km aralığında çok sayıda konut yer almakta olup, bu durum ilçedeki yerleşimin daha geniş bir alana yayıldığını düşündürmektedir.


- Uzaklığın artmasına rağmen yüksek fiyatlı konutların da var olması, fiyatların yalnızca alışveriş merkezine yakınlıkla açıklanamayacağını; yapı kalitesi, ulaşım imkânları ve çevresel donatılar gibi diğer faktörlerin de belirleyici olduğunu ortaya koymaktadır.

Sonuç olarak, bu üç boyutlu görselleştirme mekânsal etkenlerin konut fiyatları üzerindeki etkisini çok boyutlu olarak ortaya koymaktadır. Hem Keçiören hem de Yenimahalle’de brüt alan ve alışveriş merkezlerine yakınlık gibi fiziksel ve konumsal değişkenlerin piyasa değerleri üzerinde anlamlı bir rol oynadığı görülmektedir.

5.5.7. İlçe Bazında Alan, Fiyat ve Havalimanına Uzaklık İlişkisi

Bu analizde, konutların havalimanına uzaklığı ile fiyat ve brüt alan arasındaki ilişki incelenmiştir. Ulaşım altyapısına yakınlığın piyasa değeri üzerindeki etkisi ilçeler karşılaştırılarak değerlendirilmiştir.

Şekil 53. Keçiören ve Yenimahalle İlçeleri Brüt Alan, Fiyat ve Havalimanına Uzaklık İlişkisi



Şekil 53, Keçiören ve Yenimahalle ilçelerinde konutların brüt alanı, fiyatı ve havalimanına uzaklığı arasındaki ilişkiyi üç boyutlu olarak görselleştirmektedir.

Keçiören;

- Konutların büyük çoğunluğu, 10–18 km mesafede yer almaktadır.

- Havalimanına daha yakın olan konutlar (mor tonlu) genellikle düşük fiyat seviyelerinde yoğunlaşmıştır.
- Havalimanına uzaklık arttıkça (sarı tonlara geçildikçe), konut fiyatlarında sınırlı da olsa bir artış eğilimi gözlenmektedir.
- Bu durum, hava trafiği, gürültü, çevresel etkiler veya konumun dezavantajı nedeniyle havaalanına çok yakın bölgelerin dezavantajlı algılanabileceğini düşündürmektedir.

Yenimahalle;

- Konutların havalimanına uzaklığı Keçiören'e kıyasla daha geniş bir dağılım göstermektedir (17.5–36 km).
- Havalimanına daha uzak konutların (sarı tonlu) fiyatlarının genellikle daha yüksek olduğu göze çarpmaktadır.
- Konut fiyatlarındaki artışta sadece brüt alan değil, havalimanından uzak olmanın getirdiği konfor ve sessizlik gibi faktörler de rol oynamaktadır.

Bu grafik, havalimanına uzaklığın konut fiyatları üzerindeki mekânsal etkilerini ortaya koyan önemli bir görselleştirme sunmaktadır. Özellikle gürültü, hava kirliliği ve trafik yoğunluğu gibi olumsuz çevresel dışsallıkların fiyatları düşürücü etkisi gözlemlenmektedir. Bu bulgular, mekânsal regresyon modelleri veya makine öğrenimi temelli değerlendirme yaklaşımlarında havalimanına uzaklık gibi coğrafi değişkenlerin mutlaka dikkate alınması gerektiğini ortaya koymaktadır.

Yukarıda, Keçiören ve Yenimahalle ilçelerine ait konut piyasası verileri mekânsal ve yapısal değişkenler açısından ayrı ayrı analiz edilmiştir. Bu analizler, her iki ilçenin farklı sosyoekonomik dinamiklere ve fiziksel karakteristiklere sahip olduğunu göstermektedir. Bununla birlikte, ilçelerin coğrafi yakınlığı, benzer pazar koşullarını paylaşımları ve veri setlerinin birleştirilmesiyle istatistiksel gücün artması, modelleme sürecinde daha kapsamlı ve temsili analizler yapılmasına olanak sağlamaktadır.


Bu nedenle, sonraki bölümde Keçiören ve Yenimahalle ilçelerine ait veriler birleştirilerek bütünleşik bir veri seti üzerinden değerlendirilmiştir. Bu kapsamda

sunulan grafikler ve analizlerin amacı, konut değerlerini etkileyen faktörlerin genel eğilimlerini daha geniş bir perspektiften ortaya koymak ve iki ilçe arasındaki ortak özellikler ile farklılıkları bütünsel veri üzerinden analiz etmektir.

5.5.8. Bütünsel Veri Seti Üzerinden Analizler

Her iki ilçeyi kapsayan tüm veri seti birlikte incelenmekte ve konut değerlerini etkileyen faktörler bütüncül bir bakış açısıyla ortaya konmaktadır. Böylece, genel eğilimler ile ilçeler bazındaki farklılıklar ve benzerlikler daha net bir biçimde karşılaştırılabilmektedir. Sunulan grafikler, veri setinin tamamını temsil ederek modelleme sürecine temel oluşturacak kapsamlı bir ön değerlendirme niteliği taşımaktadır.


Şekil 54. Konut Değeri Dağılımı



Şekil 54'teki histogram ve KDE eğrisi, Keçiören ve Yenimahalle ilçelerini kapsayan birleşik veri setine ait konut fiyatlarının dağılımını göstermektedir. Grafikte, konut değerlerinin asimetrik (sağa çarpık) bir dağılım sergilediği gözlemlenmektedir. Bu, düşük ve orta değerli konutların piyasada daha yaygın olduğunu, yüksek değerli konutların ise görece daha sınırlı sayıda bulunduğunu göstermektedir. En yoğun

dağılım yaklaşık 2 – 4 milyon TL bandında yer almakta olup bu aralık piyasadaki ortalama konut değerini temsil etmektedir.

Şekil 55. Konut Değeri ve Brüt Alan Dağılımı




Şekil 55'te sunulan dağılım grafiği, brüt alan ile konut değeri arasındaki ilişkiyi göstermekte olup Keçiören ve Yenimahalle ilçelerinin birleşik veri setine dayanmaktadır. Grafik, konut değeri ile brüt alan arasında pozitif yönlü bir ilişki bulunduğunu ortaya koymaktadır. Brüt alan arttıkça konut değerinde de genel olarak artış gözlenmektedir. Bu bulgu, konut değerinin önemli belirleyicilerinden birinin brüt alan olduğunu desteklemektedir.

Ancak grafik aynı zamanda şunları da ortaya koymaktadır:

- 80–200 m² arasındaki konutların oldukça yoğun bir şekilde dağıldığı görülmektedir. Bu, veri setinde orta büyüklükteki konutların baskın olduğunu gösterir.
- Aynı brüt alana sahip konutların değerlerinde ciddi değişkenlik olduğu gözlemlenmektedir. Örneğin, yaklaşık 100 m²'lik konutların fiyatları 2 milyon TL ile 7 milyon TL arasında değişebilmektedir. Bu durum, fiyatların yalnızca brüt alana bağlı olmadığını, başka birçok faktörün (konum, bina yaşı, cephe, donatı, kat, vb.) etkili olduğunu göstermektedir.
- Hem alan hem de fiyat bakımından uç noktada kalan bazı gözlemler bulunmakta, bu da dağılımın uçlara doğru genişlediğini göstermektedir.

Şekil 56. Mahallelere Göre Ortalama Konut Değeri



Şekil 56'daki grafik, Yenimahalle ve Keçiören ilçelerine ait mahallelerin ortalama konut değerlerini karşılaştırmalı olarak sunmaktadır. Mahalle adları yatay eksende yer alırken, dikey eksende konutların ortalama fiyatları (TL cinsinden) gösterilmiştir. Mahalleler, ait oldukları ilçeye göre renklendirilmiştir.

Genel eğilim olarak, Yenimahalle ilçesine ait bazı mahallelerin konut fiyatları, Keçiören'e kıyasla daha yüksek ortalamalara sahiptir. Örneğin; Susuz, Yuvaköy Aşağı Yahyalar, Gazi, ve Gayret gibi Yenimahalle mahallelerinde konut değerlerinin oldukça yüksek olduğu dikkat çekmektedir. Keçiören ilçesinde ise genel olarak daha düşük fiyat düzeyine sahip mahalleler bulunmaktadır, ancak Ovacık, Yayla, Sancaktepe gibi bölgelerde fiyatlar görece yüksektir. Bu farklılıklar, konut değerlerinin yalnızca ilçeye değil, mikro bölgelere özgü faktörlere (ulaşım erişilebilirliği, sosyal donatı varlığı, yeşil alanlar vb.) bağlı olarak şekillendiğini göstermektedir.

Her iki ilçede de mahalleler arasında belirgin fiyat farklılıkları görülmektedir. Bu durum, ilçelerin homojen olmadığını, farklı sosyo-ekonomik yapı ve mekânsal avantajlara sahip mahalleler barındırdığını göstermektedir.

Şekil 57. Veri Setinin Tanımlayıcı İstatistikleri

	count	mean	std	min	25%	50%	75%	max
TerraceArea	34272.0	4.3798	10.4754	0.0	0.0	0.0	0.0	49.0
BrutArea	34272.0	133.7244	34.4501	40.0	110.0	130.0	145.0	273.0
Room	34272.0	3.0370	0.7277	1.0	3.0	3.0	3.0	6.0
LivingRoom	34272.0	1.0062	0.0786	1.0	1.0	1.0	1.0	2.0
Bathroom	34272.0	1.3633	0.5026	1.0	1.0	1.0	2.0	3.0
TotalFloor	34272.0	5.9206	5.0965	0.0	3.0	3.0	6.0	30.0
FloorNumber	34272.0	2.5907	3.6348	-4.0	0.0	2.0	3.0	30.0
FrontageNorth	34272.0	0.1770	0.3817	0.0	0.0	0.0	0.0	1.0
FrontageSouth	34272.0	0.5999	0.4899	0.0	0.0	1.0	1.0	1.0
FrontageEast	34272.0	0.4837	0.4997	0.0	0.0	0.0	1.0	1.0
FrontageWest	34272.0	0.4482	0.4973	0.0	0.0	0.0	1.0	1.0
AttributeMainRoad	34272.0	0.3943	0.4887	0.0	0.0	0.0	1.0	1.0
AttributeWideRoad	34272.0	0.5676	0.4954	0.0	0.0	1.0	1.0	1.0
AttributeSportComplex	34272.0	0.2196	0.4140	0.0	0.0	0.0	0.0	1.0
AttributePlayGround	34272.0	0.2826	0.4503	0.0	0.0	0.0	1.0	1.0
AttributeElevator	34272.0	0.5152	0.4998	0.0	0.0	1.0	1.0	1.0
AttributeGenerator	34272.0	0.2465	0.4310	0.0	0.0	0.0	0.0	1.0
AttributeGateKeeper	34272.0	0.4980	0.5000	0.0	0.0	0.0	1.0	1.0
AttributeSecurity	34272.0	0.2070	0.4052	0.0	0.0	0.0	0.0	1.0
AttributeParkingAreaOutdoor	34272.0	0.7256	0.4462	0.0	0.0	1.0	1.0	1.0
AttributeParkingAreaIndoor	34272.0	0.2507	0.4334	0.0	0.0	0.0	1.0	1.0
AttributeSwimmingPoolOutdoor	34272.0	0.0982	0.2976	0.0	0.0	0.0	0.0	1.0
AttributeSwimmingPoolIndoor	34272.0	0.1020	0.3027	0.0	0.0	0.0	0.0	1.0
AttributeHeatIsolation	34272.0	0.5687	0.4953	0.0	0.0	1.0	1.0	1.0
AttributeAirCondition	34272.0	0.1594	0.3660	0.0	0.0	0.0	0.0	1.0
ViewCity	34272.0	0.5263	0.4993	0.0	0.0	1.0	1.0	1.0
ViewNature	34272.0	0.2712	0.4446	0.0	0.0	0.0	1.0	1.0
AttributeTerrace	34272.0	0.1605	0.3671	0.0	0.0	0.0	0.0	1.0
UsageStatus	33719.0	2.2749	0.8845	1.0	1.0	3.0	3.0	3.0
DeedStatus	33818.0	1.1693	0.9273	1.0	1.0	1.0	1.0	9.0

Şekil 58. Veri Setinin Tanımlayıcı İstatistikleri (Devamı)

	count	mean	std	min	25%	50%	75%	max
DistanceToAirport	34272.0000	17.4199	4.0487	9.4680	14.4225	16.7492	18.8540	35.8240
DistanceToBusStation	34272.0000	5.1098	2.0978	0.0915	3.5215	4.8659	6.4398	11.9297
DistanceToBusStop	34272.0000	0.5190	0.4870	0.0004	0.1489	0.3397	0.7122	2.5795
DistanceToCemetery	34272.0000	2.0965	1.1240	0.0000	1.2059	2.0741	2.8593	5.7684
DistanceToCulture	34272.0000	3.0103	1.6092	0.0075	1.7968	2.9160	3.9068	7.7756
DistanceToIndustry	34272.0000	2.2770	1.1712	0.0000	1.3834	2.1083	3.1508	5.6241
DistanceToFireStation	34272.0000	3.0778	1.4174	0.0000	2.0509	2.8774	4.0613	7.1448
DistanceToHospital	34272.0000	1.4105	1.0479	0.0000	0.6669	1.0958	1.8485	5.0000
DistanceToMall	34272.0000	1.4383	0.7909	0.0000	0.9127	1.3367	1.7784	4.4868
DistanceToMarketplaces	34272.0000	0.8470	0.8463	0.0000	0.3788	0.6122	0.9392	5.0351
DistanceToMilitary	34272.0000	2.6317	1.6473	0.0000	1.3498	2.2181	3.8945	7.1698
DistanceToParks	34272.0000	0.1538	0.1424	0.0000	0.0601	0.1158	0.1964	0.9981
DistanceToCenters	34272.0000	0.4435	0.2856	0.0010	0.2467	0.3885	0.5776	3.2384
DistanceToPolice	34272.0000	1.4763	1.2805	0.0000	0.7161	1.1005	1.6519	6.7457
DistanceToPrayerHalls	34272.0000	0.2357	0.1682	0.0000	0.1274	0.1998	0.2944	1.5975
DistanceToSchools	34272.0000	0.2438	0.2008	0.0000	0.1214	0.2076	0.3105	2.0258
DistanceToTouristic	34272.0000	3.2604	1.4695	0.0200	2.2647	3.3096	4.1336	11.6050
DistanceToUniversity	34272.0000	2.2331	1.5112	0.0000	1.2610	1.9053	2.7591	10.5190
DistanceToRailwayStation	34272.0000	2.1596	1.3283	0.0051	1.1215	2.0141	2.8416	7.0235
Slope	34242.0000	10.9567	7.0536	0.0000	5.7939	9.4318	14.6862	39.9581
BuildingDensity	34272.0000	405.2141	200.5613	5.8912	250.5504	431.2146	563.7095	729.2413
DistanceToWaste	34272.0000	4.1788	1.3722	0.0982	3.2779	4.3365	5.0939	8.6322
Population	34272.0000	20663.5018	9525.0405	0.0000	13617.0000	23043.0000	28722.0000	42894.0000
BuildingAge	34272.0000	12.9428	9.5317	0.0000	5.0000	13.0000	21.0000	40.0000
AdjustedPrice	34272.0000	3610962.8220	1503501.6842	1059056.6000	2544672.0000	3243000.0000	4186000.0000	8800000.0000
Heating	34272.0000	2.3510	0.8173	0.0000	2.0000	2.0000	2.0000	5.0000

Şekil 57-58’de sunulan tanımlayıcı istatistikler hem yapısal hem de konumsal özellikleri kapsayan geniş bir konut envanterine ilişkin özet bilgiler vermektedir. Bu istatistikler, veri setinin genel yapısını anlamada önemli ipuçları sağlamaktadır.

Yapısal değişkenler incelendiğinde, brüt alan ortalama 133,75 m² olup minimum 40 m² ile maksimum 273 m² arasında değişmektedir. Bu durum, farklı büyüklüklerdeki konutların veri setinde yer aldığını göstermektedir. Cephe dağılımına göre konutların %59,9’u güney cepheli, %48,3’ü doğu cepheli ve %44,8’i batı cephelidir. Teras kullanım oranı %16 iken, asansör bulunan konutların oranı %51,5’tir. Bu oran, yüksek katlı binaların yaygınlığını desteklemektedir. Açık otopark (%72,6), kapalı otopark (%25), çocuk oyun alanı (%28,2), spor alanı (%21,9) ve güvenlik

(%20,7) gibi site içi olanakların dağılımı, modern konut komplekslerinin veri setinde önemli bir yer tuttuğunu göstermektedir.

Konumsal ve çevresel değişkenler açısından bakıldığında, konutların havalimanına uzaklığı ortalama 17,4 km, otobüs durağına uzaklığı ise ortalama 0,52 km'dir. Bu bulgular, toplu taşıma olanaklarına genel erişimin yüksek olduğunu ortaya koymaktadır. Eğitim, sağlık, ticaret ve sosyal alanlara olan uzaklık değişkenlerinin standart sapmalarının görece yüksek olması, ilçeler arasında belirgin mekânsal çeşitlilik bulunduğunu göstermektedir. Örneğin, üniversiteye uzaklık ortalama 2,23 km olmakla birlikte 0,15 km ile 10,5 km arasında değişmektedir.

Topografik değişkenler arasında eğim (slope) ortalaması %10,95 olarak hesaplanmıştır. Bina yaşı ise ortalama 12,95 yıl olup, 0 ile 40 yıl arasında değişmektedir. Bu dağılım, yeni ve eski yapı stoğunun birlikte temsil edildiği bir örneklem yapısına işaret etmektedir.

Hedef değişken olan düzeltilmiş konut değeri (AdjustedPrice) ortalama 3,61 milyon TL olup, 1,09 milyon TL ile 8,8 milyon TL arasında geniş bir dağılıma sahiptir. Bu durum, konut değerlerinin hem fiziksel hem de mekânsal faktörlerden etkilendiğini ve heterojen bir piyasa yapısını yansıttığını göstermektedir.

Konut değerlerinin dağılımına ilişkin bu genel bulgular elde edildikten sonra, veri setinde yer alan değişkenler arasındaki ilişkilerin incelenmesi önem kazanmaktadır. Pearson korelasyon katsayısı, sürekli sayısal değişkenler arasındaki doğrusal ilişkiyi ölçmede yaygın olarak kullanılan, istatistiksel olarak güçlü ve yorumlanması kolay bir yöntemdir. Ayrıca değişkenler arasındaki ilişki düzeyini tek bir katsayı ile özetlemesi, çok sayıda değişkenin bulunduğu veri setlerinde ilişkilerin hızlı ve görsel olarak değerlendirilebilmesine olanak tanımaktadır. Bu kapsamda çalışmada yer alan değişkenler arasındaki doğrusal ilişkiler Pearson korelasyon analizi ile incelenmiştir. Analiz sonucunda elde edilen korelasyon matrisi, değişkenler arasındaki ilişki yönü ve gücü hakkında genel bir fikir vermektedir. Matrisin ayrıntılı biçimi Ek-1'de sunulmuştur. Korelasyon katsayıları -1 ile +1 arasında değişmekte olup; +1 mükemmel pozitif ilişkiyi, -1 mükemmel negatif ilişkiyi, 0 ise ilişki


olmadığını ifade etmektedir. Görselleştirme, renk skalası yardımıyla bu katsayıların şiddetini görsel olarak da ortaya koymaktadır.

Matriste, Brüt Alan (BrutArea) ile Konut Değeri (AdjustedPrice) arasında görece yüksek bir pozitif korelasyon gözlenmektedir ($r \approx 0.65$). Bu bulgu, konutun fiziksel büyüklüğünün değer üzerindeki belirleyici rolünü açıkça göstermektedir. Benzer şekilde, oda sayısı (Room) ($r \approx 0.50$) ve banyo sayısı (Bathroom) ($r \approx 0.64$) da konut değerleriyle pozitif ve anlamlı bir ilişki sergilemektedir. Bu değişkenlerin kullanıcı konforunu doğrudan etkileyen iç mekân nitelikleri olması, piyasa değerlemesi açısından beklenen bir sonucu yansıtmaktadır.

Yapı yaşı (BuildingAge) ile konut değeri arasında negatif yönde bir korelasyon ($r \approx -0.50$) tespit edilmiştir. Bu sonuç, daha yeni yapıların daha yüksek piyasa değerine sahip olma eğilimini doğrulamaktadır. Öte yandan, toplu taşıma ve sosyal donatı alanlarına uzaklık gibi mekânsal değişkenler ile konut değeri arasındaki ilişkiler zayıf ve çoğunlukla negatiftir. Örneğin, otobüs durağına uzaklık (DistanceToBusStop) ile konut değeri arasında düşük seviyede negatif bir ilişki ($r \approx -0.16$) görülmektedir. Bu bulgu, ulaşılabilirliğin artmasının konut değerini olumlu yönde etkileyebileceğini işaret etmektedir.

Genel olarak, korelasyon matrisi veri setindeki tüm değişkenler arasındaki doğrusal ilişkilerin kapsamlı bir biçimde değerlendirilmesine imkân tanımaktadır. Ancak, hedef değişken AdjustedPrice ile bağımsız değişkenler arasındaki ilişkilerin daha açık görülebilmesi için bu katsayılar ayrıca tek boyutlu bir sıralama grafiğinde sunulmuştur. Bu görselleştirme, değişkenleri hedef değişkenle olan korelasyon katsayılarının büyüklüğüne göre sıralamakta ve renk skalası yardımıyla ilişkinin yönü ve şiddetini ortaya koymaktadır. Böylece, modelleme sürecinde önem arz eden değişkenlerin önceliklendirilmesi ve fiyat üzerindeki etkilerin daha kolay yorumlanması mümkün olmaktadır.

Şekil 59. Konut Değeri ile Tüm Bağımsız Değişkenler Arasındaki İlişki



Şekil 60'ta görüldüğü üzere, en yüksek pozitif korelasyon binadaki toplam kat sayısı (TotalFloor) değişkeni ile bulunmuştur ($r \approx 0.65$). Bu bulgu, yüksek katlı binalarda yer alan konutların daha yüksek piyasa değerine sahip olma eğilimini ortaya koymaktadır. Bunu sırasıyla brüt alan (BrutArea), ısıtma tipi (Heating), bulunduğu kat (FloorNumber), banyo sayısı (Bathroom) ve oda sayısı (Room) değişkenleri takip etmektedir. Bu değişkenlerin yüksek korelasyon katsayıları ($r > 0.40$), konutun fiziksel özelliklerinin fiyat belirlemede kritik rol oynadığını göstermektedir.

Negatif korelasyonlara sahip değişkenler incelendiğinde, en dikkat çekici bulgu bina yaşı (BuildingAge) ile konut değeri arasındaki ters yönde ilişkidir ($r \approx -0.35$). Bu durum, daha eski yapıların görece daha düşük değerlendirildiğini göstermektedir. Ayrıca, nüfus yoğunluğu (Population), bina yoğunluğu (BuildingDensity), eğim (Slope) ve otobüs durağına uzaklık (DistanceToBusStop) gibi çevresel faktörlerin de negatif korelasyona sahip olduğu görülmektedir. Bu bulgular, yoğun yapılaşma ve düşük erişilebilirliğin konut değerleri üzerinde olumsuz etki yaratabileceğini işaret etmektedir.

EDA sonucunda, veri setinin yapısı, değişkenler arasındaki ilişkiler, olası aykırı değerler ve eksik veriler ayrıntılı olarak değerlendirilmiştir. Bu analizler, modelleme sürecinde hangi değişkenlerin doğrudan kullanılabileceğini, hangilerinin dönüştürülmesi veya yeniden tanımlanması gerektiğini ortaya koymuştur. Elde edilen bulgular ışığında, veri setinin tahmin gücünü artırmak ve modellerin daha isabetli sonuçlar üretmesini sağlamak amacıyla özellik mühendisliği aşamasına geçilmiştir.

5.6. Özellik Mühendisliği

Özellik mühendisliği (*Feature Engineering*), makine öğrenmesi modellerinin başarısını doğrudan etkileyen en kritik aşamalardan biridir. Bu süreç, mevcut veriden daha anlamlı, temsil gücü yüksek ve modelin öğrenme kapasitesini artıracak yeni öznitelikler türetmeyi, mevcut değişkenleri dönüştürmeyi ve gereksiz ya da düşük bilgi içeriğine sahip değişkenleri ele almayı kapsamaktadır.

Bu çalışmada, aykırı değerlerin tespiti ve giderilmesi, eksik verilerin uygun yöntemlerle tamamlanması, kategorik değişkenlerin uygun kodlama teknikleri (ör. *one-hot encoding*, *label encoding*) ile sayısal formata dönüştürülmesi gibi işlemler uygulanmıştır.

Veri setinde yer alan 2025 yılının Ocak-Şubat-Mart satış fiyatları, Türkiye Cumhuriyet Merkez Bankası'nın Ankara bölgesi için yayımladığı konut fiyat endeksi kullanılarak düzeltilmiştir (TCMB, 2025). İlgili endeks değerleri Ocak ayı için 165.88, Şubat ayı için 170.55 ve Mart ayı için 173.88 olup; buna göre Ocak-Mart katsayısı

1.0482, Şubat–Mart katsayısı ise 1.0195 olarak hesaplanmıştır. Bu katsayılar kullanılarak fiyatlar Mart 2025 değerine normalize edilmiştir.

Ayrıca, binanın yapım yılı bilgisini içeren “BuildingDate” değişkeninden 2025 yılı çıkarılarak bina yaşı “BuildingAge” kolonu oluşturulmuştur.

Veri setinde bulunan aykırı gözlemler regresyon modellerinin doğruluğunu ve uyum düzeyini olumsuz etkileyebileceğinden, standart sapma ve grafiksel yöntemlerle tespit edilmiş; özellikle “AdjustedPrice” değişkeni için IQR (Interquartile Range) yöntemi uygulanmıştır. Bu yöntemle alt ve üst sınırlar belirlenmiş, sınırların dışında kalan aykırı gözlemler veri setinden çıkarılmıştır.

Kategorik değişkenler regresyon modellerine doğrudan uygun olmadığından sayısal değerlere dönüştürülmüştür. Örneğin, ısınma tipini ifade eden “Heating” değişkeni (Kat Kaloriferi, Doğalgaz Kombi, Merkezi Sistem, Merkezi Isı Pay Ölçer, Yerden Isıtma, Diğer) Label Encoding yöntemiyle sayısallaştırılmıştır.

Eksik değerler, değişkenin türüne göre mod, medyan veya ortalama gibi merkezi eğilim ölçütleri kullanılarak tamamlanmıştır. Örneğin, “UsageStatus” değişkeninde yer alan boş kayıtlar, veri setinde en sık görülen ve boş konutları temsil eden “3” değeriyle doldurulmuştur.

Bu kapsamlı özellik mühendisliği süreci, modelin tahmin doğruluğunu artırmayı ve konut değerlendirme probleminde mekânsal ve fiziksel bağlamın daha iyi temsil edilmesini sağlamayı hedeflemiştir. Yapılan işlemler sonucunda veri seti 34.272 satır ve 56 değişken ile model eğitime hazır hale getirilmiştir. Tablo 4’te çalışmada kullanılan veri seti sunulmaktadır.

Tablo 4. Çalışmada Kullanılan Coğrafi Veri Seti

Kategori	Değişken	Açıklama	Veri Tipi
Bağımlı Değişken	AdjustedPrice	Satış fiyatı (TL)	Float
Yapısal Özellikler	TerraceArea	Balkon Alanı (m ²)	Float
	BrutArea	Konut alanı (m ²)	Float
	Room	Oda Sayısı	Int
	LivingRoom	Oturma Oda Sayısı	Int
	Bathroom	Banyo Sayısı	Int
	TotalFloor	Toplam Kat Sayısı	Int
	FloorNumber	Konutun Bulunduğu Kat	Int
	AttributeMainRoad	Ana Yol Varlığı	Binary
	AttributeWideRoad	Geniş Yol Varlığı	Binary
	AttributeSportComplex	Spor Kompleksi Varlığı	Binary
	AttributePlayGround	Oyun Alanı Varlığı	Binary
	AttributeElevator	Asansör Varlığı	Binary
	AttributeGenerator	Güç Kaynağı Varlığı	Binary
	AttributeGateKeeper	Apartman Görevlisi Varlığı	Binary
	AttributeSecurity	Güvenlik Varlığı	Binary
	AttributeParkingAreaOutdoor	Açık Otopark Varlığı	Binary
	AttributeParkingAreaIndoor	Kapalı Otopark Varlığı	Binary
	AttributeSwimmingPoolOutdoor	Açık Havuz Varlığı	Binary
	AttributeSwimmingPoolIndoor	Kapalı Havuz Varlığı	Binary
	AttributeHeatIsolation	Isı İzolasyonu Varlığı	Binary
	AttributeAirCondition	Klima Varlığı	Binary
	AttributeTerrace	Balkon Varlığı	Binary
	UsageStatus	Kullanım Durumu	Int
	DeedStatus	Tapu Durumu	Int
	BuildingAge	Bina Yaşı	Float
	Heating	Isınma Tipi	Int

Coğrafi Özellikler	DistanceToAirport	Havaalanına Uzaklık (m)	Float
	DistanceToBusStation	Otogara Uzaklık (m)	Float
	DistanceToBusStop	Otobüs Duraklarına Uzaklık (m)	Float
	DistanceToCemetery	Mezarlıklara Uzaklık (m)	Float
	DistanceToCulture	Kültür merkezlerine Uzaklık (m)	Float
	DistanceToIndustry	Endüstri Alanlarına Uzaklık (m)	Float
	DistanceToFireStation	İtfaiye Merkezine Uzaklık (m)	Float
	DistanceToHospital	Hastanelere Uzaklık (m)	Float
	DistanceToMall	Alışveriş Merkezine Uzaklık(m)	Float
	DistanceToMarketplaces	Pazar Yerlerine Uzaklık (m)	Float
	DistanceToMilitary	Askeri Alanlara Uzaklık (m)	Float
	DistanceToParks	Parklara Uzaklık (m)	Float
	DistanceToCenters	Şehir Merkezlerine Uzaklık (m)	Float
	DistanceToPolice	Polis Merkezlerine Uzaklık (m)	Float
	DistanceToPrayerHalls	İbadet Alanlarına Uzaklık (m)	Float
	DistanceToSchools	Okullara Uzaklık (m)	Float
	DistanceToTouristic	Turistik Alanlara Uzaklık (m)	Float
	DistanceToUniversity	Üniversitelere Uzaklık (m)	Float
	DistanceToWaste	Atık Noktalarına Uzaklık (m)	Float
	DistanceToRailwayStation	Metro İstasyonlarına Uzaklık(m)	Float
	Slope	Eğim	Float
	FrontageNorth	Kuzey Cephe	Binary
	FrontageSouth	Güney Cephe	Binary
	FrontageEast	Doğu Cephe	Binary
	FrontageWest	Batı Cephe	Binary
	ViewNature	Doğa Manzarası	Binary
	ViewCity	Şehir Manzarası	Binary
Yerel Özellikler	BuildingDensity	Bina Yoğunluğu (bina/km ²)	Float
	Population	Nüfus (kişi/km ²)	Int

5.7. Başlangıç Model Eğitimi

Veri ön işleme ve özellik mühendisliği süreçlerinin tamamlanmasının ardından, makine öğrenmesi tabanlı regresyon analizleri gerçekleştirilmiştir. Bu kapsamda bağımlı değişken olarak AdjustedPrice (düzeltilmiş konut değeri) belirlenmiş; geri kalan 56 değişken ise bağımsız değişkenler olarak kullanılmıştır.

Veri seti, Scikit-learn kütüphanesinin train_test_split fonksiyonu aracılığıyla eğitim ve test alt kümelerine ayrılmıştır. Test seti oranının belirlenmesi için sırasıyla %15, %20, %25 ve %30'luk ayrımlar denenmiş; model performansları karşılaştırılarak en uygun ayrımın %20 test - %80 eğitim şeklinde olduğu sonucuna varılmıştır.

Model eğitim süreci, 16 GB RAM ve 11th Gen Intel(R) Core(TM) i7-1165G7 2.80 GHz işlemciye sahip bir cihazda gerçekleştirilmiştir. Bu çalışmada sekiz farklı regresyon modeli uygulanmıştır:

- Random Forest Regressor
- Extra Trees Regressor
- Bagging Regressor
- Gradient Boosting Regressor
- AdaBoost Regressor
- CatBoost Regressor,
- XGBoost Regressor
- LightGBM Regressor

Modelleme sürecinde Scikit-learn, XGBoost, LightGBM ve CatBoost kütüphanelerinden yararlanılmış; veri işleme ve yönetimi için Pandas ve NumPy, görselleştirme aşamalarında ise Matplotlib ve Seaborn kütüphaneleri kullanılmıştır.

Başlangıç aşamasında tüm modeller, ilgili algoritmaların varsayılan hiperparametreleri ile eğitilmiştir. Bu sayede, modellerin temel tahmin yetenekleri değerlendirilmiş ve ilerleyen aşamalarda yapılacak hiperparametre optimizasyonu için referans değerler elde edilmiştir. Uygulanan eğitim süreci aşağıda verilmiştir:

Eğitim sonrasında modellerin genelleme kapasiteleri, daha önce görmedikleri test verileri üzerinde analiz edilmiştir. Modellerin eğitim süreleri 0.55 saniye ile 124.91 saniye arasında değişmiş olup, ortalama eğitim süresi yaklaşık 29.8 saniye olarak gerçekleşmiştir.

Tablo 5. Başlangıç Model Performans Karşılaştırması

Model	Train			Test		
	RMSE	MAE	R ²	RMSE	MAE	R ²
Random Forest	165430.86	111796.04	0.9880	428919.49	292684.93	0.9167
Extra Trees	10951.24	1188.21	0.9999	421107.57	286348.93	0.9197
Bagging	202384.53	128613.89	0.9823	455661.56	310050.34	0.9060
Gradient Boost	518947.30	384144.85	0.8815	528000.09	389666.87	0.8738
AdaBoost	737592.22	605527.16	0.7606	748638.91	614820.63	0.7464
CatBoost	367564.35	276286.83	0.9406	446851.76	325347.91	0.9096
XGBoost	322594.94	242723.07	0.9542	459702.78	329359.62	0.9044
LightGBM	422048.53	315539.32	0.9216	471365.11	343344.67	0.8994


Regresyon modellerinin başlangıç performansları Tablo 5’te sunulmaktadır. Eğitim ve test setlerindeki RMSE, MAE ve R² metrikleri incelendiğinde, Random Forest, XGBoost, CatBoost ve LightGBM modelleri hem düşük hata oranları hem de yüksek R² değerleri ile öne çıkmıştır. Bu modeller, test setinde istikrarlı sonuçlar elde ederek güçlü birer tahmin aracı olduklarını göstermektedir.

Extra Trees Regressor eğitim setinde neredeyse sıfıra yakın hata ile çok yüksek bir performans sergilemiş, ancak test setinde anlamlı seviyede hata üretmiştir. Bu

durum, modelin aşırı öğrenme eğilimi gösterdiğine işaret etmektedir. AdaBoost Regressor ise, düşük R^2 skorları ve yüksek hata değerleri ile hem öğrenme hem de genelleme açısından en zayıf model olmuştur. Eğitim süreleri değerlendirildiğinde, CatBoost, XGBoost ve LightGBM algoritmalarının kısa sürede yüksek doğruluk elde ettiği görülmektedir. Genel olarak, XGBoost ve CatBoost modelleri bu aşamada en dengeli ve verimli tahmin algoritmaları olarak öne çıkmıştır.

Her metrik için grafiksel gösterim yaparak açıklamak gerekirse:

Şekil 60. Başlangıç Model R^2 Değerlerinin Karşılaştırma Grafiği




Şekil 61’de, sekiz farklı regresyon modelinin eğitim (Train) ve test veri setlerindeki R^2 performanslarını karşılaştırmalı olarak göstermektedir. R^2 değeri, modelin bağımlı değişkendeki değişimin ne kadarını açıkladığını gösterir ve 1’e yaklaştıkça modelin başarısı artar.

Sekiz modelin eğitim ve test R^2 değerleri incelendiğinde, bazı modellerde (ör. Extra Trees, Bagging) eğitim performansı ile test performansı arasında belirgin farklar olduğu ve bunun aşırı öğrenme eğilimine işaret ettiği görülmektedir. AdaBoost Regressor, her iki veri setinde de düşük R^2 değerleri ile yetersiz öğrenme sergilemiştir.

Random Forest modeli eğitim kümesinde yüksek bir R^2 skoru üretmiş ancak test performansının görece düşük kalması sınırlı bir aşırı öğrenme olasılığını düşündürmektedir. CatBoost, XGBoost ve LightGBM modelleri ise eğitim ve test değerleri arasında dengeli farklar sergileyerek yüksek doğruluk oranları elde etmiştir.


Şekil 61. Başlangıç Model MAE Değerlerinin Karşılaştırma Grafiği



Şekil 62’deki grafik, sekiz farklı regresyon modelinin eğitim ve test veri setleri üzerindeki MAE değerlerini karşılaştırmalı olarak sunmaktadır. MAE değeri, modelin tahmin hatalarının ortalamasını verir ve düşük MAE değeri daha yüksek tahmin doğruluğuna işaret eder.

MAE sonuçları, test setinde en düşük ortalama hata değerini Random Forest modelinin (≈ 292.685) ürettiğini göstermektedir. CatBoost, XGBoost ve LightGBM modelleri de 300.000–350.000 TL aralığında düşük ve dengeli hata değerleri ile başarılı bulunmuştur. AdaBoost, her iki veri setinde de yüksek MAE değerleri ile en zayıf model olmuştur. Extra Trees ve Bagging modelleri eğitim hatalarının çok düşük olmasına rağmen test hatalarının belirgin şekilde yüksek olması sebebiyle aşırı uyum riski taşımaktadır.

Şekil 62. Başlangıç Model RMSE Değerlerinin Karşılaştırma Grafiği



Şekil 63'teki grafik, sekiz farklı regresyon modelinin eğitim ve test veri setleri üzerindeki RMSE performanslarını karşılaştırmalı olarak sunmaktadır. RMSE, hata karelerinin ortalamasının karekökünü alarak daha büyük hataları daha fazla cezalandırır. Bu yüzden özellikle büyük sapmaların etkisini görmekte kullanışlıdır. Daha düşük RMSE, daha yüksek tahmin doğruluğunu ve daha iyi model performansını ifade eder.

RMSE analizinde Extra Trees (≈ 421.108) ve Random Forest (≈ 428.919) test setinde en düşük hata değerlerini üretmiştir. Ancak Extra Trees'in eğitim setindeki çok düşük RMSE değeri (≈ 10.951), modelin veriye aşırı uyum sağladığını göstermektedir. CatBoost, XGBoost ve LightGBM modelleri, eğitim ve test RMSE değerleri arasında dengeli farklarla yüksek genelleme kabiliyeti sergilemiştir. AdaBoost ise yüksek hata değerleri ile bu problem için yetersiz kalmıştır.

Elde edilen sonuçlar, toplu öğrenme yöntemleri arasında CatBoost, XGBoost ve LightGBM modellerinin hem doğruluk hem de genelleme açısından en dengeli ve başarılı sonuçları sunduğunu göstermektedir. Extra Trees ve Random Forest modelleri yüksek doğruluk sağlamalarına rağmen, belirli ölçüde aşırı uyum riski taşımaktadır. AdaBoost ise düşük performansı nedeniyle bu problem için uygun bulunmamaktadır.

Elde edilen bulgular doğrultusunda, bir sonraki aşamada PFI ve hiperparametre optimizasyonu uygulanarak model performanslarının iyileştirilmesi hedeflenmiştir.

5.8. PFI Analizi ile Özellik Seçimi

Konut fiyatlarını etkileyen en önemli bağımsız değişkenlerin belirlenmesi ve tahmin gücü düşük olanların modelden çıkarılması amacıyla özellik seçimi süreci uygulanmıştır. Bu sayede yalnızca anlamlı ve katkı sağlayan değişkenlerle çalışılarak modellerin hem doğruluğu hem de işlem verimliliği artırılmıştır. Literatürde yaygın olarak önerildiği üzere, bu çalışmada özellik seçimi yöntemi olarak PFI tercih edilmiştir.

PFI yöntemi, modelin doğruluğundaki değişimi temel alır. Bir özelliğin değerleri rastgele karıştırıldığında, model performansındaki düşüş, o özelliğin model açısından önem derecesini gösterir. İşlemin birçok kez tekrarlanması, rastgeleliğe bağlı belirsizliği (standart sapma) ortaya koyar ve her özelliğin performansa katkısı daha güvenilir biçimde hesaplanır.


PFI'nin tercih edilmesinin bir başka nedeni, modelden bağımsız olarak çalışabilmesi ve doğrusal olmayan ilişkilerde dahi değişken önemini güvenilir şekilde ölçebilmesidir. Ayrıca değişkenlerin önem sıralamasını doğrudan modelin tahmin performansına dayandırması, yöntemin diğer istatistiksel ölçütlere kıyasla daha yorumlanabilir ve uygulamaya dönük sonuçlar sunmasını sağlamaktadır.

Bu çalışmada PFI analizi, Scikit-learn kütüphanesinin inspection modülü kullanılarak gerçekleştirilmiştir. Ortalama önemi sıfıra yakın olan değişkenler modele anlamlı katkı sağlamayan değişkenler olarak değerlendirilmiştir. Özellikle ortalama önem değeri 0,01'in altında kalan değişkenler veri setinden çıkarılmıştır. Böylece yalnızca anlamlı öznitelikler, nihai regresyon modellerinin eğitimi için kullanılmıştır.

PFI, her modelin bağımlı değişken olan AdjustedPrice üzerindeki tahmin performansına en fazla katkı sağlayan değişkenleri belirlemek amacıyla her modele ayrı ayrı uygulanmıştır. Bu yaklaşım, modellerin değişken önemlerini karşılaştırmalı olarak incelemeye ve her bir algoritmanın veri setindeki özniteliklere duyarlılığını değerlendirmeye imkân tanımaktadır.

Aşağıda, sekiz farklı regresyon modeline ait PFI sonuçları sunulmakta ve her model için en etkili öznitelikler ile bu özniteliklerin göreceli önem düzeyleri yorumlanmaktadır.

Şekil 63. Random Forest PFI




Şekil 64'te sunulan PFI grafiğine göre, Random Forest Regressor modelinde konut fiyatlarını en fazla etkileyen değişkenler sırasıyla Toplam Kat Sayısı (TotalFloor), Bina Yaşı (BuildingAge), Bulunduğu Kat (FloorNumber) ve Brüt Alan (BrutArea) olmuştur. Bu değişkenler, modelin tahmin performansına en yüksek katkıyı sağlayan özniteliklerdir.

Orta düzeyde etkili değişkenler arasında Oda Sayısı (Room), Havalimanına Uzaklık (DistanceToAirport) ve Banyo Sayısı (Bathroom) öne çıkmaktadır.

Buna karşılık, daha düşük önem skoruna sahip değişkenler arasında Otobüs Durağına Uzaklık (DistanceToBusStation), Nüfus Yoğunluğu (Population) ve diğer ulaşım, hizmet veya altyapı yakınlığına ilişkin değişkenler yer almaktadır. Bu bulgu, modelin öncelikle fiziksel yapı özelliklerine, ikincil olarak ise mekânsal erişim faktörlerine daha fazla ağırlık verdiğini göstermektedir.

Şekil 64. Extra Trees PFI




Şekil 65'te sunulan Extra Trees Regressor modeline göre, konut fiyat tahmininde en kritik değişkenler Toplam Kat Sayısı (TotalFloor), Bulunduğu Kat (FloorNumber) ve Brüt Alan (BrutArea) olmuştur. Bu değişkenler, modelin tahmin performansına en yüksek katkıyı sağlamaktadır.

Bu öznitelikleri, Banyo Sayısı (Bathroom), Bina Yaşı (BuildingAge) ve Oda Sayısı (Room) gibi diğer fiziksel yapı özellikleri takip etmektedir.

Orta düzeyde etkili değişkenler arasında Havalimanına Uzaklık (DistanceToAirport), Isıtma Tipi (Heating) ve Nüfus Yoğunluğu (Population) yer almaktadır. Buna karşılık, mekânsal ve sosyal olanaklara erişimle ilgili değişkenlerin (ör. Otobüs Durağına Uzaklık, Sanayiye Uzaklık, Kültürel Alanlara Uzaklık) göreceli etkisi daha düşük kalmıştır.

Şekil 65. Bagging PFI




Şekil 66’da sunulan Bagging Regressor modelinde en yüksek önem skorları, Toplam Kat Sayısı (TotalFloor), Bulunduğu Kat (FloorNumber) ve Bina Yaşı (BuildingAge) değişkenlerine aittir. Bu öznelilikler, modelin tahmin performansına en yüksek katkıyı sağlayan değişkenler olarak öne çıkmaktadır.

Bu değişkenleri, Brüt Alan (BrutArea), Havalimanına Uzaklık (DistanceToAirport) ve Oda Sayısı (Room) takip etmektedir.

Buna karşılık, mekânsal erişim değişkenleri (ör. Otobüs Durağına Uzaklık, Turistik Alanlara Uzaklık, Çarşı/Pazar Mesafesi) görece daha düşük önem değerlerine sahip bulunmuştur.

Şekil 66. Gradient Boosting PFI




Şekil 67’de sunulan Gradient Boost Regressor modelinde en yüksek önem skorları, Toplam Kat Sayısı (TotalFloor), Brüt Alan (BrutArea) ve Bina Yaşı (BuildingAge) değişkenlerine aittir. Bu öznelilikler, modelin tahmin performansına en güçlü katkıyı sağlayan faktörler olarak öne çıkmaktadır.

Bunları, Bulunduğu Kat (FloorNumber) ve Havalimanına Uzaklık (DistanceToAirport) izlemektedir. Banyo Sayısı (Bathroom), Otobüs Durağına Uzaklık (DistanceToBusStation) ve Oda Sayısı (Room) gibi değişkenler ise orta düzeyde katkı sağlamaktadır.

Buna karşılık, mekânsal erişim faktörleri (ör. Atık Alanına Uzaklık, Yangın İstasyonuna Uzaklık, Turistik Alanlara Uzaklık) görece daha düşük önem seviyesine sahiptir. Bu bulgu, modelin konut fiyatlarını tahmin ederken ağırlıklı olarak fiziksel yapı özelliklerine dayandığını göstermektedir.


Şekil 67. AdaBoost PFI



Şekil 68’de sunulan AdaBoost Regressor modelinde en yüksek önem skoru Brüt Alan (BrutArea) değişkenine aittir. Bu değişkeni Bina Yaşı (BuildingAge) ve Toplam Kat Sayısı (TotalFloor) izlemektedir.

Bulunduğu Kat (FloorNumber), Havalimanına Uzaklık (DistanceToAirport) ve Banyo Sayısı (Bathroom) orta düzeyde etkiye sahiptir. Buna karşılık, diğer mekânsal ve donanımsal faktörler (ör. Polis Karakoluna Uzaklık, Isıtma Türü, Mezarlığa Uzaklık) daha düşük önem skorlarıyla modelin tahmin performansına sınırlı katkı sağlamaktadır.


Şekil 68. CatBoost PFI



Şekil 69’de CatBoost Regressor modelinde en yüksek önem skoru Toplam Kat Sayısı (TotalFloor) değişkenine aittir. Bunu sırasıyla Bina Yaşı (BuildingAge), Brüt Alan (BrutArea) ve Bulunduğu Kat (FloorNumber) izlemektedir.

Havalimanına Uzaklık (DistanceToAirport) ve Oda Sayısı (Room) orta düzeyde etkili değişkenler arasında yer almakta, Banyo Sayısı (Bathroom), Otobüs Durağına Uzaklık (DistanceToBusStation) ve Nüfus (Population) ise daha düşük fakat yine de dikkate değer katkılar sunmaktadır. Diğer mekânsal ve donanımsal özelliklerin modelin tahmin performansına etkisi ise sınırlı kalmıştır.


Şekil 69. XGBoost PFI



Şekil 70’de XGBoost Regressor modelinde en yüksek önem skoru Toplam Kat Sayısı (TotalFloor) değişkenine aittir. Bunu sırasıyla Bina Yaşı (BuildingAge), Brüt Alan (BrutArea) ve Bulunduğu Kat (FloorNumber) izlemektedir.

Havalimanına Uzaklık (DistanceToAirport) ve Oda Sayısı (Room) da dikkate değer katkılar sunarken, Banyo Sayısı (Bathroom), Otobüs Durağına Uzaklık (DistanceToBusStation) ve Nüfus (Population) orta düzeyde etkiye sahiptir. Diğer mekânsal ve sosyal altyapı değişkenlerinin modelin tahmin performansına katkısı ise sınırlı düzeyde kalmıştır.

Şekil 70. LGBM PFI



Şekil 71’de LightGBM Regressor modelinde en yüksek önem skoru Toplam Kat Sayısı (TotalFloor) değişkenine aittir. Bunu sırasıyla Brüt Alan (BrutArea), Bina Yaşı (BuildingAge) ve Bulunduğu Kat (FloorNumber) izlemektedir.

Havalimanına Uzaklık (DistanceToAirport) ve Banyo Sayısı (Bathroom) da dikkate değer katkılar sağlarken, Oda Sayısı (Room) ve Nüfus (Population) orta düzeyde önem taşımaktadır. Buna karşılık, mekânsal konum ve altyapı erişimine ilişkin değişkenler (ör. Otobüs Durağına Uzaklık, Atık Alanına Uzaklık, Mezarlığa Uzaklık) modelin tahmin performansına daha sınırlı katkı yapmıştır.

Sekiz farklı modelin PFI (Permutation Feature Importance) analiz sonuçları birlikte değerlendirildiğinde, bazı değişkenlerin tüm modellerde belirgin biçimde öne çıktığı görülmektedir.

Tablo 6. Regresyon Modellerinin PFI Sonuçlarının Karşılaştırması

Değişken	Random Forest	Extra Trees	Bagging	Gradient Boosting	AdaBoost	CatBoost	XGBoost	LightGBM	Genel Eğilim
Toplam Kat Sayısı (TotalFloor)	Çok yüksek	Çok yüksek	Çok yüksek	Çok yüksek	Orta	Çok yüksek	Çok yüksek	Çok yüksek	Tüm modellerde en belirleyici değişken
Brüt Alan (BrutArea)	Yüksek	Yüksek	Yüksek	Çok yüksek	En yüksek	Yüksek	Yüksek	Yüksek	Fiziksel büyüklük kritik
Bina Yaşı (BuildingAge)	Yüksek (negatif)	Yüksek (negatif)	Çok yüksek (negatif)	Yüksek (negatif)	Yüksek (negatif)	Çok yüksek (negatif)	Çok yüksek (negatif)	Yüksek (negatif)	Yeni yapılar daha değerli
Bulunduğu Kat (FloorNumber)	Yüksek	Çok yüksek	Çok yüksek	Orta	Orta	Yüksek	Yüksek	Yüksek	Kat konumu fiyatı etkiliyor
Havalimanına Uzaklık (DistanceToAirport)	Orta	Orta	Orta	Orta	Orta	Orta	Orta	Orta	Mekânsal faktör olarak önemli
Oda Sayısı (Room)	Orta	Orta	Orta	Orta	Düşük	Orta	Orta	Orta	Orta düzey katkı
Banyo Sayısı (Bathroom)	Orta	Yüksek	Orta	Orta	Orta	Düşük	Orta	Orta	Orta düzey katkı


Genel olarak:

- Fiziksel yapı özellikleri (Toplam Kat Sayısı, Brüt Alan, Bina Yaşı, Bulunduğu Kat) hemen her modelde ilk sıralarda yer almış, konut değerinin tahmininde en belirleyici faktörler olmuştur.
- Konum bazlı erişim değişkenleri (Havalimanına, Otobüs Durağına, Turistik alanlara uzaklık gibi) modeller arasında değişen önem derecelerine sahip olmakla birlikte, çoğunlukla orta düzey etkili bulunmuştur.
- İç donanım özellikleri (Banyo Sayısı, Isıtma tipi, Asansör varlığı) bazı modellerde anlamlı katkı sağlarken, bazılarında düşük önem skorlarıyla yer almıştır.
- Sosyal ve çevresel faktörler (Nüfus yoğunluğu, Atık alanına uzaklık, Mezarlığa uzaklık vb.) genel olarak daha düşük öneme sahiptir.

Tüm modeller birlikte değerlendirildiğinde, yapısal ve metrekare temelli değişkenlerin en yüksek tahmin gücüne sahip değişken grubu olduğu; mekânsal ve sosyo-çevresel faktörlerin ise modelden modele değişmekle birlikte genellikle ikinci planda kaldığı görülmektedir. Bu durum, çalışmada kullanılan veri setinin ve konut değerlendirme bağlamının özellikle fiziksel yapı özelliklerine daha duyarlı olduğunu göstermektedir.

Ayrıca, her bir model için PFI değeri 0.01'in altında kalan ve tahmin performansına düşük katkı sağlayan değişkenler veri setinden çıkarılmıştır. Sonraki aşamada, geriye kalan değişkenler arasındaki ilişkiler incelenmiş ve bu amaçla oluşturulan korelasyon matrisi yardımıyla bağımsız değişkenler arasındaki doğrusal ilişki düzeyleri görsel olarak ortaya konmuştur.

Şekil 71. Pearson Korelasyon Haritası (PFI Sonrası)



Şekil 72’de sunulan korelasyon ısı haritası, veri setindeki değişkenler arasındaki doğrusal ilişkilerin yönünü ve gücünü ortaya koymaktadır. Analiz sonuçlarına göre, düzeltilmiş fiyat değişkeni ile en yüksek pozitif korelasyona sahip değişkenler Toplam Kat Sayısı ($r = 0,72$), Brüt Alan ($r = 0,65$), Banyo Sayısı ($r = 0,64$) ve Bulunduğu Kat ($r = 0,64$) olarak belirlenmiştir. Bu bulgu, konutun fiziksel büyüklüğü ve kat özelliklerinin fiyat artışında en belirleyici faktörler olduğunu göstermektedir. Buna karşılık, Bina Yaşı ($r = -0,50$) fiyatla anlamlı düzeyde negatif ilişki sergilemiş; bina yaşı arttıkça fiyatın düşme eğilimi açıkça ortaya konmuştur.

Değişkenler arası ilişkiler incelendiğinde, Brüt Alan ile Oda Sayısı ($r = 0,81$) arasında oldukça yüksek pozitif korelasyon bulunmuştur. Bu, geniş metrekaireli konutlarda oda sayısının da arttığını göstermektedir. Benzer şekilde, Toplam Kat

Sayısı ile Bulunduğu Kat ($r = 0,70$) arasındaki güçlü ilişki, yüksek katlı binalarda üst kat numaralarının görülmesinin doğal bir sonucu olarak değerlendirilebilir. Ayrıca Bina Yaşı ile Banyo Sayısı ($r = -0,50$) arasındaki negatif korelasyon, yeni yapılarda banyo sayısının daha fazla olduğunu işaret etmektedir.

Uzaklık değişkenleri açısından, Havalimanına Uzaklık ile Otobüs Durağına Uzaklık ($r = -0,57$) arasında orta düzeyde negatif ilişki tespit edilmiştir. Bu durum, havalimanına yakın bölgelerin genellikle toplu taşıma olanaklarına daha sınırlı erişim sağladığını göstermektedir. Genel olarak, uzaklık değişkenlerinin fiyat ile düşük düzeyde ilişki göstermesi, konut değerinin belirlenmesinde fiziksel yapı özelliklerinin mekânsal mesafe faktörlerine kıyasla daha baskın bir rol oynadığını ortaya koymaktadır.

5.9. Hiperparametre Optimizasyonu

Önceki aşamada, modellerin tahmin performansına düşük katkı sağlayan değişkenler çıkarılarak veri seti sadeleştirilmiş ve değişkenler arasındaki ilişkiler analiz edilmiştir. Bu aşamadan sonra, her bir modelin performansını artırmak amacıyla hiperparametre optimizasyonu (*Hyperparameter Tuning*) sürecine geçilmiştir. Bu süreçte, model parametreleri sistematik olarak farklı kombinasyonlarda denenmiş, çapraz doğrulama yöntemi ile en iyi parametre setleri belirlenmiş ve modeller bu optimal değerlerle yeniden eğitilmiştir.

Her makine öğrenmesi algoritmasının performansını etkileyen kendine özgü hiperparametreleri bulunmaktadır. Regresyon modellerinde iyileştirme sağlamak için, model eğitimi öncesinde bu parametrelerin en uygun biçimde belirlenmesi kritik önemdedir. Bu çalışmada, en iyi parametre kombinasyonlarını tespit etmek amacıyla GridSearchCV yöntemi uygulanmıştır.

Optimizasyon sürecinde Python programlama dili kullanılmış; scikit-learn (Random Forest, Extra Trees, Bagging, Gradient Boosting, AdaBoost), XGBoost, LightGBM ve CatBoost kütüphanelerinden yararlanılmıştır.

Şekil 72. Random Forest, Extra Trees, Bagging ve Gradient Boosting Regresyonları İçin Parametre Aralıkları


GridSearchCV <pre>GridSearchCV(cv=KFold(n_splits=5, random_state=42, shuffle=True), estimator=RandomForestRegressor(random_state=42), n_jobs=-1, param_grid={'max_depth': [None, 10, 20], 'max_features': ['auto', 'sqrt', 'log2'], 'min_samples_leaf': [1, 2, 4], 'min_samples_split': [2, 5], 'n_estimators': [300, 500]}, scoring='neg_mean_absolute_error', verbose=2)</pre> best_estimator_: RandomForestRegressor
GridSearchCV <pre>GridSearchCV(cv=KFold(n_splits=5, random_state=42, shuffle=True), estimator=ExtraTreesRegressor(random_state=42), n_jobs=-1, param_grid={'bootstrap': [False, True], 'max_depth': [None, 10, 20], 'max_features': ['log2', 'sqrt'], 'min_samples_leaf': [1, 2, 4], 'min_samples_split': [2, 5], 'n_estimators': [300, 500]}, scoring='neg_mean_absolute_error', verbose=2)</pre> best_estimator_: ExtraTreesRegressor
GridSearchCV <pre>GridSearchCV(cv=KFold(n_splits=5, random_state=42, shuffle=True), estimator=BaggingRegressor(estimator=DecisionTreeRegressor(random_state=42), random_state=42), n_jobs=-1, param_grid={'bootstrap': [True, False], 'estimator__max_depth': [3, 5, 7], 'max_features': [0.6, 0.8, 1.0], 'max_samples': [0.6, 0.8, 1.0], 'n_estimators': [300, 500]}, scoring='neg_mean_absolute_error', verbose=2)</pre> best_estimator_: BaggingRegressor
GridSearchCV <pre>GridSearchCV(cv=KFold(n_splits=5, random_state=42, shuffle=True), estimator=GradientBoostingRegressor(random_state=42), n_jobs=-1, param_grid={'learning_rate': [0.01, 0.05, 0.1], 'max_depth': [3, 5, 7], 'max_features': ['sqrt', 'log2'], 'min_samples_leaf': [1, 3], 'min_samples_split': [2, 5], 'n_estimators': [200, 300], 'subsample': [0.6, 0.8, 1.0]}, scoring='neg_mean_absolute_error', verbose=2)</pre> best_estimator_: GradientBoostingRegressor

Şekil 73. AdaBoost, CatBoost, XGBoost ve LightGBM Regresyonları İçin Parametre Aralıkları



Şekil 73-74’te her bir regresyon modeli için GridSearchCV ile gerçekleştirilen parametre aralıkları sunulmuştur. Hiperparametre arama sürecinin toplam çalışma süreleri ise Şekil 75’te saniye cinsinden sunulmaktadır. Görsellerde renk yoğunluğu, sürelerin büyüklüğünü vurgulamakta ve farklı modellerin hesaplama maliyetlerinin görsel olarak karşılaştırılmasına imkân tanımaktadır.

Şekil 74. GridSearchCV Hiperparametre Arama Süreci



Bu analiz, yalnızca tahmin performansının değil, aynı zamanda hesaplama maliyetinin de değerlendirilmesine olanak sağlayarak model seçimini daha bütüncül bir yaklaşımla yapmayı mümkün kılmaktadır. Zaman maliyetinin dikkate alınması, özellikle büyük veri setleriyle çalışılan ya da donanım kısıtlarının bulunduğu ortamlarda model seçiminde kritik bir rol oynamaktadır.

Elde edilen sonuçlar, Bagging Regressor’un yaklaşık 3 saat 20 dakikada tamamlanarak tüm modeller arasında en uzun süreye sahip olduğunu göstermektedir. Bu durum, modelin yüksek ağaç sayısı, örnekleme oranları ve ağaç derinliği parametreleri ile ilişkili olduğu düşünülmektedir.

XGBoost (yaklaşık 2 saat 16 dakika) ve Random Forest (yaklaşık 2 saat 15 dakika) süre açısından ikinci grupta yer almakta; her iki model de 500 ağaç ve geniş hiperparametre aralıklarıyla çalıştırıldığından hesaplama yükü artmıştır.

LGBM (yaklaşık 1 saat 33 dakika) ve Gradient Boosting (yaklaşık 1 saat 27 dakika) orta düzey sürelerle sonuçlanırken, histogram tabanlı yapısı sayesinde LGBM'nin nispeten daha verimli olduğu görülmektedir.

CatBoost (yaklaşık 33 dakika), 5.184 aday parametre kombinasyonuna rağmen kendi optimizasyon mekanizmaları sayesinde daha kısa sürede tamamlanmıştır. AdaBoost (yaklaşık 17 dakika) ve Extra Trees (yaklaşık 15 dakika) olmuştur. Özellikle Extra Trees, deterministik bölme stratejisi sayesinde düşük sürelerde sonuç üretmiştir.

GridSearchCV parametrelerinin 5 katlı çapraz doğrulama sonucunda elde edilen en iyi parametre kombinasyonları aşağıda sunulmaktadır. Her bir model için belirlenen optimal değerler, ilgili algoritmanın performansını en üst düzeye çıkarmak amacıyla yeniden eğitim sürecinde kullanılmıştır:

- *Random Forest*: {'max_depth': 20, 'max_features': 'sqrt', 'min_samples_leaf': 1, 'min_samples_split': 2, 'n_estimators': 500}
- *Extra Trees*: {'bootstrap': True, 'max_depth': 20, 'max_features': 'sqrt', 'min_samples_leaf': 1, 'min_samples_split': 2, 'n_estimators': 500}
- *Bagging*: {'bootstrap': True, 'estimator__max_depth': 7, 'max_features': 0.8, 'max_samples': 0.6, 'n_estimators': 500}
- *Gradient Boosting*: {'learning_rate': 0.1, 'max_depth': 7, 'max_features': 'sqrt', 'min_samples_leaf': 3, 'min_samples_split': 2, 'n_estimators': 500, 'subsample': 1.0}
- *AdaBoost*: {'estimator': DecisionTreeRegressor(max_depth=1), 'estimator__max_depth': 3, 'learning_rate': 0.01, 'loss': 'linear', 'n_estimators': 500}
- *CatBoost*: {'bagging_temperature': 0.2, 'border_count': 32, 'depth': 10, 'iterations': 500, 'l2_leaf_reg': 1, 'learning_rate': 0.1}

- *XGBoost*: {'colsample_bytree': 0.8, 'gamma': 0, 'learning_rate': 0.05, 'max_depth': 9, 'min_child_weight': 1, 'n_estimators': 500, 'reg_alpha': 0.1, 'reg_lambda': 1, 'subsample': 0.8}
- *LGBM*: {'colsample_bytree': 0.6, 'learning_rate': 0.1, 'max_depth': -1, 'min_child_samples': 5, 'n_estimators': 500, 'num_leaves': 100, 'reg_alpha': 0, 'reg_lambda': 0.1, 'subsample': 0.6}

5.10. İyileştirilmiş Model Eğitimi

Bu aşamada, her bir makine öğrenmesi algoritması için GridSearchCV yöntemiyle gerçekleştirilen hiperparametre optimizasyonu sonucunda elde edilen en iyi parametre kombinasyonları kullanılarak nihai model eğitimleri yapılmıştır. Bu süreç, modellerin varsayılan parametrelerle elde edilen başlangıç performanslarının ötesine geçerek hem tahmin doğruluğunu artırmayı hem de genelleme yeteneğini güçlendirmeyi amaçlamaktadır.

Hiperparametre optimizasyonu ile belirlenen değerler, doğrudan model eğitime uygulanmış ve bu sayede özelleştirilmiş, iyileştirilmiş modeller elde edilmiştir. Böylelikle yalnızca tahmin gücü yüksek değil, aynı zamanda veri setine ve probleme özgü en uygun parametrelerle çalışan modeller geliştirilmiştir.

Elde edilen sonuçlar Tablo 7’de özetlenmektedir. Tablo, sekiz farklı regresyon modelinin eğitim ve test veri setlerindeki performans metriklerini (R^2 , RMSE, MAE) karşılaştırmalı biçimde sunmaktadır.

Tablo 7. İyileştirilmiş Model Performans Karşılaştırması


Model	Train			Test		
	RMSE	MAE	R ²	RMSE	MAE	R ²
Random Forest	220734.41	159872.89	0.9786	438108.10	304642.11	0.9131
Extra Trees	289812.29	212969.30	0.9630	458298.70	326607.62	0.9049
Bagging	546371.94	406888.41	0.8687	560824.74	414048.32	0.8577
Gradient Boost	543602.90	399268.45	0.8700	551055.81	404542.88	0.8626
AdaBoost	799583.03	653418.22	0.7187	808309.44	661578.26	0.7043
CatBoost	312809.51	233082.53	0.9569	448563.46	320320.92	0.9089
XGBoost	227876.91	168363.53	0.9772	431341.08	304085.41	0.9158
LightGBM	244172.96	181949.35	0.9738	435256.97	308295.15	0.9143

Tablo incelendiğinde, sekiz farklı regresyon modelinin eğitim ve test veri setlerindeki performans metrikleri karşılaştırmalı olarak değerlendirilmiştir. Test sonuçlarına göre XGBoost ($R^2=0.9158$), LightGBM ($R^2=0.9143$) ve Random Forest ($R^2=0.9131$) modelleri, en yüksek doğruluk oranları ile birlikte en düşük hata değerlerini (RMSE ve MAE) sergileyerek öne çıkmaktadır. Extra Trees modeli, bu üç modele yakın doğruluk sağlamasına karşın hata değerleri açısından nispeten daha zayıf bir performans göstermektedir. CatBoost, R^2 değeri bakımından rekabetçi olsa da hata metriklerinde ilk üç modelin gerisinde kalmıştır. Gradient Boosting ve Bagging modelleri ise hem doğruluk hem de hata metrikleri açısından orta düzeyde bir başarı sunarken, AdaBoost modeli yüksek hata değerleri ve düşük doğruluk oranı ($R^2=0.7043$) ile en düşük performansı ortaya koymuştur.

Bu bulgular, hiperparametre optimizasyonunun model performansını anlamlı ölçüde iyileştirdiğini ve en uygun model seçiminin yalnızca varsayılan parametrelere değil, özelleştirilmiş parametre ayarlarına dayandırılması gerektiğini ortaya

koymaktadır. Aşağıda her bir metrik (R^2 , MAE, RMSE) için karşılaştırmalı grafikler sunulmuştur.

Şekil 75. İyileştirilmiş Model R^2 Değerlerinin Karşılaştırma Grafiği



Şekil 76'deki grafikte sekiz farklı regresyon modelinin eğitim ve test veri setlerindeki R^2 değerleri karşılaştırılmaktadır.

Random Forest, XGBoost ve LightGBM modelleri hem eğitim (≈ 0.97 – 0.98) hem de test (≈ 0.91 – 0.92) setlerinde yüksek R^2 skorları elde ederek güçlü bir genelleme kabiliyeti sergilemiştir. Bu durum, modellerin karmaşık ilişkileri öğrenebildiğini ve aşırı uyum riskinin düşük olduğunu göstermektedir.


Extra Trees Regressor da yüksek R^2 değerlerine sahiptir; ancak eğitim ve test performansı arasındaki fark Random Forest'a kıyasla biraz daha fazladır. Bu durum, modelin serbest ağaç bölünmeleri nedeniyle test verisinde sınırlı performans kaybı yaşamasından kaynaklanıyor olabilir.

CatBoost Regressor ise 0.9569 (eğitim) ve 0.9089 (test) R^2 değeri ile dengeli bir başarı göstermektedir. Buna karşın, Bagging ve Gradient Boosting modellerinin R^2 değerleri (≈ 0.86 – 0.87) daha düşük kalmıştır. Adaboost Regressor ise hem eğitim

(0.7187) hem de test (0.7043) setlerinde en düşük R^2 skorlarıyla öğrenme ve genelleme açısından en zayıf model olmuştur.

Genel olarak yüksek R^2 değerleri, modelin bağımlı değişkendeki varyansın büyük kısmını açıkladığını gösterir. Bu sonuçlar, Random Forest, XGBoost ve LightGBM'in çalışma kapsamında en uygun adaylar olduğunu ortaya koymaktadır.

Şekil 76. İyileştirilmiş Model MAE Değerlerinin Karşılaştırma Grafiği



Şekil 77'de sekiz regresyon modelinin eğitim ve test veri setlerindeki MAE değerleri karşılaştırılmaktadır. MAE, tahmin edilen ve gerçek değerler arasındaki ortalama mutlak farkı ölçer; dolayısıyla düşük MAE, daha yüksek tahmin doğruluğuna işaret eder.


Random Forest, XGBoost ve LightGBM modelleri hem eğitim hem de test setlerinde en düşük MAE değerlerine ulaşarak öne çıkmıştır. Random Forest özellikle eğitim setinde oldukça düşük hata seviyesine sahiptir.

Extra Trees Regressor da düşük MAE değerleri ile güçlü bir performans göstermiş, ancak test hatası Random Forest ve XGBoost'a göre biraz daha yüksek kalmıştır. CatBoost modeli dengeli bir performans sergileyerek orta düzey hata değerleri üretmiştir.

Bagging ve Gradient Boosting modelleri daha yüksek MAE değerleri ile görece daha düşük tahmin isabeti sağlamıştır. Adaboost Regressor ise açık ara en yüksek MAE değerlerine sahip olup, karmaşık ilişkileri yakalamakta yetersiz kalmıştır.

Genel olarak, Random Forest, XGBoost ve LightGBM modelleri düşük hata düzeyleri ve dengeli eğitim-test sonuçları ile öne çıkmaktadır.

Şekil 77. İyileştirilmiş Model RMSE Değerlerinin Karşılaştırma Grafiği



Şekil 78’de sekiz regresyon modelinin eğitim ve test veri setlerindeki Kök RMSE değerleri karşılaştırılmaktadır. RMSE, hata karelerinin ortalamasının karekökünü alarak büyük hataların etkisini daha belirgin şekilde yansıtır.

Random Forest, XGBoost ve LightGBM modelleri hem eğitim hem de test setlerinde en düşük RMSE değerlerini elde ederek en doğru tahminleri sağlamıştır. Random Forest eğitim setinde en düşük hata seviyesini gösterirken test setinde de güçlü performansını sürdürmüştür.

Extra Trees Regressor düşük RMSE değerleriyle başarılı bulunmuş, ancak test performansı Random Forest ve XGBoost’a kıyasla biraz daha zayıf kalmıştır.

CatBoost modeli orta düzey hata değerleri ile dengeli bir sonuç üretmiş ve aşırı uyum belirtisi göstermemiştir.

Bagging ve Gradient Boosting modelleri daha yüksek RMSE değerlerine sahip olup, karmaşık veri yapısını modellemede sınırlı başarı göstermiştir. Adaboost Regressor ise en yüksek RMSE değerleriyle bu problem için en zayıf model olmuştur.

Genel olarak, Random Forest, XGBoost ve LightGBM modelleri hem düşük hata düzeyleri hem de eğitim-test dengesini korumaları bakımından en başarılı modeller olarak öne çıkmaktadır.

5.11. Başlangıç ve İyileştirilmiş Modellerin Karşılaştırmalı Analizi

Bu bölümde, başlangıç aşamasında varsayılan parametrelerle eğitilen modeller ile GridSearchCV yöntemiyle optimize edilmiş hiperparametrelerle yeniden eğitilen modellerin performansları karşılaştırılmaktadır. Karşılaştırma, R^2 , RMSE ve MAE performans metrikleri üzerinden yapılmış; böylece modellerin doğruluk, hata düzeyi ve genelleme kabiliyeti açısından nasıl farklılaştığı ortaya konmuştur.


Başlangıç ve iyileştirilmiş modellerin performans metrikleri daha önce ayrı ayrı sunulmuştur. Tablo 8’de ise her iki aşama bir arada verilerek karşılaştırmalı bir değerlendirme yapılması amaçlanmıştır. Böylece özellik seçiminin ve hiperparametre optimizasyonunun modeller üzerindeki etkileri daha net bir şekilde gözlemlenebilmektedir. Özellikle Random Forest, XGBoost ve LightGBM gibi güçlü temel performansa sahip algoritmalarda test R^2 değerlerinde küçük düşüşler gözlemlense de (ör. Random Forest’ta 0.9167’den 0.9131’e), bu durum genellikle aşırı uyumun azaltılmasıyla ilişkilidir. Aynı zamanda bu modellerde train–test hata farklarının azalmış olması, daha dengeli ve güvenilir bir genelleme yeteneğine işaret etmektedir. Buna karşılık, başlangıçta düşük performans gösteren AdaBoost ve Gradient Boosting modellerinde R^2 değerlerindeki gerileme ve hata metriklerindeki artış, optimizasyonun bu algoritmalar için beklenen iyileştirmeyi sağlamadığını göstermektedir. Benzer şekilde Bagging Regressor’da RMSE ve MAE değerlerinin belirgin biçimde yükselmesi, test performansının zayıflamasına yol açmıştır.

Tablo 8. Başlangıç ve İyileştirilmiş Model Performans Karşılaştırması

Başlangıç Model Performans Metrikleri						
Model	Train			Test		
	RMSE	MAE	R ²	RMSE	MAE	R ²
Random Forest	165430.86	111796.04	0.9880	428919.49	292684.93	0.9167
Extra Trees	10951.24	1188.21	0.9999	421107.57	286348.93	0.9197
Bagging	202384.53	128613.89	0.9823	455661.56	310050.34	0.9060
Gradient Boost	518947.30	384144.85	0.8815	528000.09	389666.87	0.8738
AdaBoost	737592.22	605527.16	0.7606	748638.91	614820.63	0.7464
CatBoost	367564.35	276286.83	0.9406	446851.76	325347.91	0.9096
XGBoost	322594.94	242723.07	0.9542	459702.78	329359.62	0.9044
LightGBM	422048.53	315539.32	0.9216	471365.11	343344.67	0.8994
İyileştirilmiş Model Performans Metrikleri						
Model	Train			Test		
	RMSE	MAE	R ²	RMSE	MAE	R ²
Random Forest	220734.41	159872.89	0.9786	438108.10	304642.11	0.9131
Extra Trees	289812.29	212969.30	0.9630	458298.70	326607.62	0.9049
Bagging	546371.94	406888.41	0.8687	560824.74	414048.32	0.8577
Gradient Boost	543602.90	399268.45	0.8700	551055.81	404542.88	0.8626
AdaBoost	799583.03	653418.22	0.7187	808309.44	661578.26	0.7043
CatBoost	312809.51	233082.53	0.9569	448563.46	320320.92	0.9089
XGBoost	227876.91	168363.53	0.9772	431341.08	304085.41	0.9158
LightGBM	244172.96	181949.35	0.9738	435256.97	308295.15	0.9143

Genel bulgular, XGBoost, LightGBM ve Random Forest modellerinin hem tahmin gücü hem de genelleme yeteneği açısından diğer modellere kıyasla üstün olduğunu ortaya koymaktadır. Bununla birlikte, performans değerlendirmeleri yalnızca doğruluk ölçütleriyle sınırlı kalmamalı, hesaplama süreleri de dikkate alınmalıdır. Eğitim süreleri incelendiğinde, XGBoost (≈ 2 saat 16 dk) ve Random Forest (≈ 2 saat 15 dk) uzun süreler gerektirse de elde ettikleri yüksek doğruluk oranları bu maliyeti makul kılmaktadır. LightGBM (≈ 1 saat 33 dk) ise benzer doğruluk düzeyini daha kısa sürede sağlayarak zaman-performans dengesi açısından en avantajlı model olmuştur. Buna karşın Bagging Regressor (≈ 3 saat 20 dk) çok uzun sürede tamamlanmasına rağmen yalnızca orta düzeyde başarı göstermiştir. Extra Trees (≈ 15 dk) ve AdaBoost (≈ 17 dk) en kısa sürede eğitilen modeller olsa da, özellikle AdaBoost düşük doğruluk oranı ile en zayıf sonuçları vermiştir. CatBoost (≈ 33 dk) ve Gradient Boosting (≈ 1 saat 27 dk) ise süre-performans açısından orta seviyede dengeli fakat en iyi modellerin gerisinde kalmıştır.

Şekil 78. LGBM Modelinin Gerçek ve Tahmin Değerlerinin Karşılaştırılması



Sonuç olarak, LightGBM modeli hem yüksek doğruluk hem de nispeten düşük eğitim süresi ile en uygun zaman-performans dengesini sağlamış, bu nedenle çalışmada detaylı yorumlama için seçilmiştir. Şekil 79'daki grafikte LightGBM modelinin tahmin değerleri (y eksen) ile gerçek değerler (x eksen) karşılaştırılmıştır. Kırmızı kesikli çizgi, mükemmel tahmin senaryosunu (tahmin = gerçek değer) temsil etmektedir. Noktaların büyük çoğunluğu bu çizgiye oldukça yakın konumlanmış olup, modelin genel olarak yüksek doğrulukta tahminler ürettiğini göstermektedir. Veri noktalarının çizgi etrafında yoğunlaşması, modelin sistematik bir sapma (*bias*) üretmediğine işaret ederken, çizgiden uzaklaşan noktalar tahmin hatalarının görece yüksek olduğu gözlemleri temsil etmektedir. Özellikle uç değerlerde (çok yüksek veya düşük fiyat aralıklarında) sınırlı sayıda sapma gözlenmekte, bu da modelin uç değerlerde kısmen daha az isabetli tahminler yaptığını göstermektedir. Genel olarak dağılım, LightGBM'in veri setindeki konut değerlerini yüksek bir doğrulukla modelleyebildiğini ve genelleme kabiliyetinin güçlü olduğunu ortaya koymaktadır.

5.12. SHAP Analizi ile Model Açıklamaları

Makine öğrenmesi modellerinin yüksek doğruluk düzeyine ulaşması, tek başına karar verme süreçlerinde yeterli değildir. Özellikle gayrimenkul değerlendirme gibi ekonomik, sosyal ve mekânsal faktörlerin birlikte rol oynadığı karmaşık problemlerde, modelin nasıl ve neden belirli tahminler ürettiğinin anlaşılması kritik önem taşımaktadır. Bu bağlamda, SHAP analizi, her bir değişkenin tahmine olan katkısını yönü ve büyüklüğü ile ortaya koyan güçlü bir XAI yöntemidir.


SHAP yaklaşımı, kooperatif oyun teorisindeki Shapley değerleri prensibine dayanmakta olup, modelin karar sürecini şeffaflandırmakta ve değişkenler arası etkileşimlerin görselleştirilmesine olanak sağlamaktadır. Bu bölümde, çalışmada kullanılan modeller için elde edilen SHAP grafikleri incelenerek, konut değeri tahminlerinde hangi değişkenlerin öne çıktığı ve bu etkinin hangi yönde gerçekleştiği ayrıntılı biçimde tartışılmaktadır.

Analiz sonuçları, özellikle brüt alan, oda sayısı, cephe yönleri ile ulaşım ve mekânsal erişilebilirlik göstergelerinin fiyat tahminlerinde yüksek etkiye sahip

olduğunu göstermektedir. Ayrıca mekânsal faktörlerin etkisinin yönü, konutun fiziksel özellikleri ile bulunduğu konum arasındaki etkileşimler üzerinden değerlendirilmiştir.

Bu bölümde sunulan SHAP görselleştirmeleri, yalnızca model performansını değil, aynı zamanda modelin karar mantığını da açık, sistematik ve yorumlanabilir biçimde ortaya koymaktadır.

Şekil 79. SHAP Değeri Özellik Önemi




Şekil 80'deki grafikte, SHAP analizi sonucunda modelde kullanılan değişkenlerin konut değeri tahminine ortalama katkı düzeyleri, ortalama mutlak SHAP değeri üzerinden sıralanarak gösterilmektedir.

- TotalFloor (Bina Toplam Kat Sayısı) en yüksek öneme sahip değişken olup yaklaşık 400.000 birim SHAP değeri ile model tahminlerinde en güçlü etkiye sahiptir. Bu durum, binanın toplam kat sayısının fiyat tahminlerinde belirleyici bir rol oynadığını göstermektedir.
- Onu sırasıyla FloorNumber (Konutun Bulunduğu Kat) ve BrutArea (brüt alan) izlemektedir. Bu iki özellik, konutun fiziksel büyüklüğü ve konumuna ilişkin doğrudan bilgiler sunduğu için fiyat üzerinde yüksek etkili olmaktadır.

- BuildingAge (Bina Yaşı) da önemli bir değişken olup yeni binaların genellikle daha yüksek değer tahminleri ile ilişkilendirildiği görülmektedir.
- Mekânsal erişilebilirlik göstergelerinden DistanceToBusStation ve DistanceToAirport orta düzeyde etkiye sahiptir. Bu, ulaşım altyapısına yakınlığın konut değeri üzerinde kayda değer bir rol oynadığını göstermektedir.
- Bathroom (Banyo Sayısı) ve Room (oda sayısı) gibi iç mekân özellikleri fiyat üzerinde pozitif etki yaratmakta, ancak etki büyüklüğü fiziksel konum ve büyüklük değişkenlerine kıyasla daha sınırlı kalmaktadır.
- Population (Nüfus) en düşük öneme sahip değişken olarak görülmektedir. Bu durum, nüfus yoğunluğunun fiyat tahminleri üzerinde dolaylı veya sınırlı bir etkisi olabileceğini düşündürmektedir.

Bunun yanında, Şekil 81’de yer alan Beeswarm grafiği, her bir özelliğin önem sırasına göre SHAP değerlerinin dağılımını görselleştirmektedir.

Şekil 80. SHAP Değeri Beeswarm Grafiği



Grafikte her bir nokta, veri setindeki bir gözlemi temsil etmektedir. Yatay eksen, ilgili özelliğin SHAP değerini; nokta renkleri ise özelliğin değerinin diğer

örneklere kıyasla yüksek (kırmızı) ya da düşük (mavi) olduğunu göstermektedir. Noktaların yatay konumu, söz konusu özelliğin konut değeri tahmini üzerinde pozitif (fiyat artırıcı) veya negatif (fiyat düşürücü) etkiye sahip olup olmadığını ortaya koymaktadır.

Özetle, Beeswarm grafiği her bir özelliğin tahmin üzerindeki yönlü etkisini ve bu etkinin şiddetini görsel olarak sunarak modelin karar mekanizmasının daha ayrıntılı biçimde anlaşılmasına katkı sağlamaktadır.

- TotalFloor (Toplam Kat Sayısı): Yüksek toplam kat sayısına sahip binalar (kırmızı noktalar) model tahminlerinde fiyatı genel olarak artırma eğilimindedir. Düşük kat sayısına sahip binalar (mavi noktalar) ise genelde fiyatı azaltıcı etki yapmaktadır.
- FloorNumber (Bulunduğu Kat): Yüksek katlarda yer alan konutlar fiyatı artırırken, düşük katlardakiler fiyatı düşürme eğilimi göstermektedir. Bu, özellikle yüksek katların manzara, ışık ve prestij faktörleri ile ilişkilendirilebileceğini düşündürür.
- BrutArea (Brüt Alan): Alan büyüdükçe (kırmızı), SHAP değeri pozitif yönde artmakta, yani fiyat tahminini yükseltmektedir. Küçük alanlı konutlar ise (mavi) fiyatı düşürmektedir.
- BuildingAge (Bina Yaşı): Düşük yaşa sahip binalar (mavi) pozitif etkiye sahipken, yaşlandıkça (kırmızı) fiyat üzerinde negatif etki görülmektedir.
- DistanceToBusStation (Otobüs Durağına Uzaklık): Uzaklık arttıkça (kırmızı), SHAP değeri çoğunlukla negatife kaymakta, yani duraktan uzak konutlar daha düşük değer tahminlerine yol açmaktadır. Yakın mesafe (mavi) ise fiyatı yükseltici etkidedir.
- Bathroom (Banyo Sayısı): Banyo sayısının artması (kırmızı) fiyatı genelde artırmakta, az banyo sayısı (mavi) fiyatı düşürmektedir.
- DistanceToAirport (Havalimanına Uzaklık): Havalimanına uzaklık arttıkça (kırmızı) fiyat tahminleri çoğunlukla düşmektedir. Ulaşım kolaylığı sağlayan yakın mesafe (mavi) pozitif etkilidir.
- Room (Oda Sayısı): Oda sayısının fazla olması fiyatı pozitif etkilerken, düşük oda sayısı negatif etki yapmaktadır.


- Population (Nüfus): Yüksek nüfus (kırmızı) bazı durumlarda pozitif etki yaratsa da genel olarak etkinin düşük ve daha dağınık olduğu görülmektedir. Bu da nüfusun fiyat üzerinde güçlü ve tek yönlü bir belirleyici olmadığını göstermektedir.

Bu bulgular, literatürde sıklıkla vurgulanan “konutun fiziksel özellikleri ve mikro-konum faktörlerinin fiyat üzerindeki baskın rolü” ile uyumlu olup, geliştirilen modellerin karar mekanizmasının şeffaf biçimde anlaşılmasına katkı sunmaktadır. Böylece yalnızca modelin performansı değil, aynı zamanda karar verme mantığı da hem sayısal metrikler hem de görsel çıktılar aracılığıyla desteklenmiştir.

Özelliklerin genel önem düzeyleri ve yönlü etkileri bu şekilde belirlendikten sonra, modelin tekil tahminlerde nasıl karar verdiğinin incelenmesi de kritik bir aşamadır. Bu amaçla, belirli gözlemler seçilerek force plot ve waterfall görselleştirmeleri hazırlanmıştır. Söz konusu grafikler, her bir tahminin başlangıç değeri (modelin ortalama tahmini) ile nihai tahmin arasındaki farkın, değişkenlerin bireysel katkılarıyla nasıl şekillendiğini ayrıntılı biçimde göstermektedir. Böylece yalnızca genel eğilimler değil, tekil örneklerde hangi özelliklerin fiyatı ne ölçüde artırdığı veya azalttığı da somut olarak izlenebilmektedir.

5.12.1. Örnek No: 758

Şekil 81. Örnek 758 SHAP Force Grafiği



Şekil 82’de Force grafiği, rastgele seçilen 758 indeksindeki konut için modelin tahmin sürecini ayrıntılı biçimde ortaya koymaktadır.

- Grafiğin merkezindeki base value (≈ 3.29 milyon TL), modelin tüm veri seti için ürettiği ortalama tahmin değerini temsil etmektedir. Bu değer, herhangi bir

özellik bilgisi dikkate alınmadan elde edilen başlangıç tahminidir. Grafiğin ortasındaki base value (≈ 3.29 milyon TL), modelin tüm veri seti için ortalama tahmin değeridir. Bu, modelin herhangi bir özellik bilgisi olmadan verdiği başlangıç fiyat tahminidir.


- Kırmızı alanlar tahmini artıran, mavi alanlar ise tahmini azaltan özellik katkılarını temsil etmektedir.

Bu örnekte:

- FloorNumber = 4 ve DistanceToBusStation ≈ 2.44 km, tahmini yukarı yönlü etkilemektedir. Özellikle yüksek kat faktörünün fiyat üzerinde güçlü bir artırıcı etkisi bulunmaktadır.
- Buna karşılık TotalFloor = 4, BuildingAge = 31, Bathroom = 1, BrutArea = 133 m², Room = 3 ve Population ≈ 1764 gibi değerler tahmini aşağı çekmektedir. Özellikle binanın yaşı, düşük banyo sayısı ve ortalama brüt alan büyüklüğü fiyat üzerinde negatif etki yaratmaktadır.

Sonuç olarak, tüm katkılar bir araya geldiğinde model tahmini, başlangıç ortalamasının altında bir seviyede gerçekleşmiştir.

Şekil 82. Örnek 758 SHAP Waterfall Grafiği



Şekil 83'te sunulan SHAP Waterfall grafiği, seçilen gözlem için modelin tahmin sürecini ayrıntılı biçimde ortaya koymaktadır. Grafik, ortalama tahmin değerinden başlayarak nihai tahmine kadar her bir değişkenin katkısını adım adım göstermektedir.

- Grafiğin sağ alt köşesindeki $E[f(X)] \approx 3.62$ milyon TL, modelin veri seti genelindeki ortalama tahmin değerini temsil etmektedir.
- Bu gözlem için hesaplanan $f(x) \approx 3,29$ milyon TL ise nihai tahmindir. Aradaki fark, değişkenlerin fiyatı artırıcı veya düşürücü katkılarının toplam etkisinden kaynaklanmaktadır.

Pozitif katkılar (kırmızı çubuklar):

- DistanceToBusStation = 2.4 km, $\approx +289.274$ TL katkı sağlamış ve fiyatı yukarı çekmiştir.
- FloorNumber = 4 ise $\approx +88.053$ TL katkı sağlamıştır.


Negatif katkılar (mavi çubuklar):

- TotalFloor = 4 ≈ -242.876 TL düşüşe neden olmuştur.
- BuildingAge = 31 yıl ≈ -214.169 TL değer kaybına yol açmıştır.
- Bathroom = 1 adet ≈ -113.349 TL azalış sağlamıştır.
- BrutArea = 130 m², Room = 3, Population = 17.841, DistanceToAirport = 18.45 km gibi değişkenler ise daha küçük negatif katkılar yapmıştır.

Bu görselleştirme, modelin nihai tahmininin yalnızca ortalama eğilimlere değil, konuta özgü özelliklerin bireysel katkılarının bileşiminden oluştuğunu göstermekte ve Force grafiğindeki analizi tamamlayıcı nitelikte ayrıntılı bir bakış sunmaktadır.

5.12.2. Örnek No: 3095

Şekil 83. Örnek 3095 SHAP Force Grafiği



Şekil 84’te sunulan SHAP Force grafiği, seçilen ikinci gözlem için konut değerinin nasıl belirlendiğini adım adım göstermektedir.

- *Base value* $\approx$ 3,17 milyon TL olup, herhangi bir özellik bilgisi kullanılmadan modelin öngördüğü fiyat seviyesini ifade etmektedir. Kırmızı alanlar fiyatı artıran, mavi alanlar ise fiyatı düşüren özellik katkılarını göstermektedir.

Pozitif katkılar:


- DistanceToAirport = 13,95 km ve BuildingAge = 9 yıl fiyatı yükseltmiş, ayrıca FloorNumber = 2 küçük bir pozitif etki sağlamıştır.

Negatif katkılar:

- TotalFloor = 3, DistanceToBusStation $\approx$ 6.79 km, Bathroom = 1, Population $\approx$ 3045 ve BrutaArea = 130 m² fiyatı düşürücü etkiler göstermiştir. Özellikle otobüs durağına uzaklık ve düşük banyo sayısı tahmin üzerinde belirgin negatif etki yapmaktadır.

Sonuç olarak, pozitif ve negatif katkıların toplam etkisiyle nihai tahmin değeri, base value seviyesine oldukça yakın bir noktada oluşmuş; bu da modelin bu örnekte ortalama fiyat seviyesinden büyük bir sapma göstermediğini ortaya koymuştur.

Şekil 84. Örnek 3095 SHAP Waterfall Grafiği



Şekil 85'teki SHAP Waterfall grafiği ise aynı gözlem için fiyat tahmininin, değişkenlerin önem sırasına göre katkılarıyla nasıl şekillendiğini göstermektedir.

- $E[f(X)] \approx 3.62$ milyon TL, modelin veri seti genelindeki ortalama tahmin değeridir.
- $f(x) \approx 3.17$ milyon TL, bu gözlem için üretilen nihai tahmindir. Yani model, ortalama değere kıyasla ≈ -450 bin TL daha düşük bir fiyat öngörmüştür.

Negatif katkılar:

- TotalFloor = 3 ≈ -239.169 TL
- DistanceToBusStation ≈ 6.78 km ≈ -228.582 TL
- Bathroom = 1 ≈ -112.971 TL
- Population $\approx 30.457 \approx -88.160$ TL
- BrutArea = 130 m² ≈ -71.441 TL

Pozitif katkılar:


- FloorNumber = 2 $\approx +199.300$ TL
- BuildingAge = 9 yıl $\approx +68.198$ TL

- DistanceToAirport ≈ 13.95 km $\approx +31.430$ TL

Bu görselleştirme, özellikle ulaşım olanaklarına uzaklık ve düşük donanım özelliklerinin fiyatı aşağı çekerken; kat konumu, görece yeni bina yaşı ve ulaşım kolaylığının fiyatı yukarı taşıdığını göstermektedir. Böylece Force ve Waterfall grafikleri birlikte değerlendirildiğinde, modelin bu gözlem için karar mekanizması hem sayısal hem de görsel açıdan şeffaf biçimde ortaya konmaktadır.

5.12.3. Örnek No: 5381

Şekil 85. Örnek 5381 SHAP Force Grafiği



Şekil 86’da sunulan SHAP Force grafiği, seçilen üçüncü gözlem için modelin fiyat tahmin sürecini görselleştirmektedir.

- Grafiğin ortasında yer alan base value $\approx 3,33$ milyon TL, modelin tüm veri seti için öngördüğü ortalama fiyat seviyesini göstermektedir. Kırmızı alanlar fiyatı artıran, mavi alanlar ise fiyatı düşüren özellik katkılarını göstermektedir.

Pozitif katkılar:

- BuildingAge = 10 yıl ve FloorNumber = 2 fiyatı yukarı yönlü etkilemiştir. Özellikle görece düşük bina yaşı, fiyatın ortalama seviyenin üzerine çıkmasına katkı sağlamaktadır.


Negatif katkılar:

- TotalFloor = 3, Bathroom = 1 adet, BrutArea = 130 m², Population ≈ 29.880 ve DistanceToBusStation ≈ 5.06 km fiyatı aşağı çekmiştir.

Özellikle düşük banyo sayısı ve durağa görece uzaklık belirgin negatif etki göstermektedir.

Sonuç olarak, pozitif katkılara rağmen negatif etkilerin baskın gelmesi nedeniyle nihai tahmin değeri, ortalama seviyeye oldukça yakın fakat biraz altında olmuştur.

Şekil 86. Örnek 5381 SHAP Waterfall Grafiği



Şekil 87'deki Waterfall grafiği ise aynı gözlem için nihai tahmin değerinin, değişkenlerin sıralı katkılarıyla ortalama fiyat seviyesinden nasıl saparak oluştuğunu ayrıntılı biçimde göstermektedir.

- $E[f(X)] \approx 3.62$ milyon TL, modelin veri seti genelindeki ortalama konut değeri tahminidir.
- $f(x) \approx 3.33$ milyon TL, bu konut için üretilen nihai tahminidir. Model, ortalama değere kıyasla ≈ -290 bin TL daha düşük bir fiyat öngörmüştür.

Negatif katkılar:

- TotalFloor = 3 ≈ -235.436 TL
- Bathroom = 1 ≈ -117.210 TL
- BrutArea = 130 m² ≈ -113.823 TL

- Population $\approx 28.980 \approx -58.443$ TL
- DistanceToBusStation ≈ 5.08 km ≈ -35.268 TL
- Daha küçük ölçekte negatif etkiler, DistanceToAirport ≈ 15.38 km ve Room = 3 değerlerinden gelmektedir.

Pozitif katkılar:

- FloorNumber = 2 $\approx +213.918$ TL
- BuildingAge = 10 yıl $\approx +67.011$ TL


Bu örnek, özellikle düşük banyo sayısı ve sınırlı metrekare büyüklüğünün fiyatı düşürdüğünü; görece genç bina yaşı ve uygun kat konumunun ise fiyatı yukarı çektiğini göstermektedir. Böylece modelin tekil bir tahmin için karar mekanizması hem Force hem de Waterfall grafiği ile şeffaf bir şekilde ortaya konmuştur.

Bu bulgular, açıklanabilir yapay zekâ yöntemlerinin gayrimenkul değerlendirme süreçlerinde neden kritik öneme sahip olduğunu ortaya koymaktadır. SHAP analizi sayesinde modelin yalnızca hangi tahmini ürettiği değil, bu tahminin hangi faktörlerin etkisiyle ve hangi yönde şekillendiği de net biçimde görülebilmektedir. Böylece, karar alma süreçleri şeffaflaşmakta, model çıktılarının hem alan uzmanları hem de politika yapıcılar tarafından güvenle yorumlanabilmesi sağlanmaktadır. Ayrıca, bu şeffaflık, olası model önyargılarının tespit edilmesine, veri kalitesinin artırılmasına ve gelecekteki değerlendirme sistemlerinin daha adil ve güvenilir biçimde tasarlanmasına katkı sunmaktadır.

5.13. Konut Değer Haritalarının Oluşturulması ve Paylaşımı

Bu başlıkta, çalışma alanı olan Yenimahalle ve Keçiören ilçelerine ait konut ortalama değerlerinin mekânsal dağılımı 500 m²'lik altıgen ızgara ile görselleştirilmiştir. Haritalama sürecinde mekânsal analiz ve görselleştirme amacıyla ArcGIS Pro yazılımı kullanılmıştır. Analiz adımlarında Generate Tessellation aracı ile altıgen ızgaralar oluşturulmuş, Spatial Join aracı ile her ızgara hücrelerine düşen konut ortalama değeri birleştirilmiştir. Daha sonra, elde edilen konut değerleri Symbology aracılığıyla sınıflandırılarak sarıdan koyu kırmızıya uzanan bir renk skalası ile görselleştirilmiştir.

Şekil 87. Yenimahalle ve Keçiören İlçeleri Konut Değeri Haritası



Konut değerleri, Türk Lirası cinsinden on farklı sınıfa ayrılmıştır. Analiz sonuçlarına göre, en yüksek konut değerleri (7.000.000 TL ve üzeri) çalışma alanının güney ve güneydoğu kesimlerinde yoğunlaşmaktadır. Orta değer aralıkları (3.000.000–5.000.000 TL) ilçelerin doğu, güney ve batı bölümlerinde kümelenmiş, düşük değerli veya konut bulunmayan alanlar (0–2.500.000 TL) ise kuzey ve kuzeybatı kesimlerde yoğunlaşmıştır. Bu mekânsal dağılım, kentsel merkezlere, ulaşım altyapısına, ticari alanlara ve sosyal donatı bölgelerine yakınlık ile doğrudan

ilişkilidir. Elde edilen konut değeri haritası, kentsel planlama, gayrimenkul değerlendirme ve yatırım karar destek süreçleri için önemli bir mekânsal referans niteliği taşımaktadır.

Mekânsal dağılım incelendiğinde, yüksek değerli bölgelerin yoğunlaştığı alanlar ile nüfus yoğunluğu haritasındaki yüksek yoğunluk bölgeleri arasında kısmi bir örtüşme olduğu görülmektedir. Bu durum, konut değerlerinin yalnızca nüfus yoğunluğundan değil, aynı zamanda ulaşılabilirlik, arazi kullanımı, çevresel kalite ve sosyo-ekonomik statü gibi çok boyutlu faktörlerden etkilendiğini ortaya koymaktadır. Dolayısıyla, bu harita kentsel planlama, gayrimenkul yatırımları ve değerlendirme çalışmaları için önemli bir mekânsal referans niteliği taşımaktadır.

Bu çalışmada üretilen Yenimahalle ve Keçiören Konut Değer Haritaları, ArcGIS Server altyapısı üzerinden servis edilerek kullanıcı erişimine açılmıştır. ArcGIS Pro ortamında oluşturulan veri katmanları, “map service” formatında paketlenmiş ve ArcGIS Server üzerinde Toplu Değerleme klasörü altında yayımlanmıştır. Böylece hem kurum içi kullanıcılar hem de yetkilendirilmiş harici kullanıcılar, web tabanlı istemciler veya masaüstü CBS yazılımları aracılığıyla bu verilere erişebilmiştir.

Çalışma kapsamında oluşturulan harita servisine aşağıdaki bağlantı üzerinden doğrudan erişim sağlanabilmektedir:

https://arcgissrv06s01.csb.local/server/rest/services/TopluDeğerleme/yenimahalle_kecioren_konut_degeri_haritasi/MapServer

Bu yöntem, mekânsal analiz çıktılarının yalnızca görsel olarak sunulmasını değil, aynı zamanda karar destek süreçlerinde etkin biçimde kullanılabilmesini de mümkün kılmıştır.

SONUÇ VE ÖNERİLER

Bu çalışmada, Ankara'nın Yenimahalle ve Keçiören ilçelerine ait konut verileri kullanılarak farklı makine öğrenmesi yöntemleriyle konut değerlendirme analizi gerçekleştirilmiştir. Çalışma, konut değerlerini etkileyen yapısal, mekânsal ve çevresel faktörlerin sistematik biçimde incelenmesini, modellerin tahmin performanslarının karşılaştırılmasını ve açıklanabilir yapay zekâ yöntemleri aracılığıyla model kararlarının yorumlanmasını kapsamaktadır.

Yöntemsel olarak, öncelikle veri seti düzenlenmiş, tanımlayıcı istatistiklerle yapısı analiz edilmiştir. Ardından sekiz regresyon algoritması (Random Forest, Extra Trees, Bagging, Gradient Boosting, AdaBoost, XGBoost, LightGBM, CatBoost) başlangıç parametreleriyle test edilmiştir. Özellik seçimi için PFI analizi uygulanmış, katkısı düşük olan değişkenler modelden çıkarılmıştır. Daha sonra GridSearchCV yöntemiyle hiperparametre optimizasyonu gerçekleştirilmiş ve elde edilen en iyi parametreler kullanılarak modeller yeniden eğitilmiştir. Performans değerlendirmesinde R^2 , RMSE ve MAE metrikleri kullanılmıştır. Bunun yanında, SHAP analizi ile modellerin karar mekanizmaları açıklanmış; değişkenlerin tahminlere olan katkıları yön ve büyüklük açısından görselleştirilmiştir. Son aşamada ise mekânsal analizler gerçekleştirilmiş ve ortalama konut değer dağılımları 500 m²'lik altıgen ızgara yapıları kullanılarak haritalandırılmıştır.

Elde edilen bulgular, konut değerlerini belirleyen en önemli faktörlerin fiziksel yapı özellikleri olduğunu göstermiştir. Özellikle toplam kat sayısı, brüt alan, bina yaşı ve bulunduğu kat değişkenleri hem PFI hem de SHAP analizlerinde en yüksek katkıyı sağlamıştır. Bu bulgu, literatürde konutun fiziksel niteliklerinin fiyat üzerindeki belirleyici rolünü vurgulayan çalışmalarla uyumludur. Mekânsal erişim değişkenleri (ör. otobüs durağına veya havalimanına uzaklık) orta düzeyde etkili bulunmuş, ancak fiziksel değişkenler kadar güçlü bir belirleyicilik göstermemiştir. Sosyal ve çevresel göstergeler (ör. nüfus yoğunluğu) ise düşük katkı sağlamış olmakla birlikte belirli durumlarda kısmi etkiler göstermiştir.

Model performans karşılaştırmaları, XGBoost, LightGBM ve Random Forest algoritmalarının yüksek R^2 değerleri ile düşük RMSE ve MAE skorları sayesinde en

başarılı sonuçları verdiğini ortaya koymuştur. Bu modeller, farklı çalışmalarda da raporlanan güçlü genelleme kapasiteleriyle literatürle tutarlılık göstermektedir. Özellikle LightGBM, daha kısa eğitim süresiyle yüksek doğruluk sağlaması sayesinde zaman–performans dengesinde öne çıkmıştır. AdaBoost ise düşük doğruluk ve yüksek hata değerleriyle en zayıf performansı sergilerken; Bagging ve Gradient Boosting orta düzeyde kalmıştır. Bu sonuçlar, algoritmaların veri seti özelliklerine farklı düzeylerde uyum sağladığını ve model seçiminde yalnızca doğruluk değil, hesaplama maliyeti ile genelleme kabiliyetinin de dikkate alınması gerektiğini göstermektedir.

SHAP analizi sayesinde modellerin yalnızca tahmin çıktıları değil, aynı zamanda karar mekanizmaları da şeffaf biçimde incelenebilmiştir. Bu durum, gayrimenkul değerlendirme gibi ekonomik açıdan kritik alanlarda model güvenilirliği ve kullanıcı güveni açısından önemli bir katkı sunmaktadır. Ayrıca SHAP tabanlı görselleştirmeler, fiyat tahmininde etkili olan faktörlerin yönünü ve büyüklüğünü açıkça ortaya koyarak, karar vericilerin yalnızca tahmini değil, tahminin gerekçesini de anlamasına imkân tanımaktadır. Dolayısıyla çalışmanın en önemli bilimsel katkısı, makine öğrenmesi tabanlı tahmin modellerinin yalnızca doğruluk odaklı performanslarıyla değil, aynı zamanda açıklanabilirlik (XAI) yöntemleri ve mekânsal görselleştirmelerle birlikte ele alınmasıdır. Bu yaklaşım, gayrimenkul değerlendirme ve kentsel planlama süreçlerinde güvenilir, şeffaf ve bütüncül bir metodoloji sunmaktadır.

Bu doğrultuda, Türkiye’de taşınmaz değerlendirme süreçlerinin dijital dönüşümüne katkı sağlayacak bazı somut öneriler geliştirilebilir. Öncelikle, bu tez kapsamında geliştirilen modelin, ulusal ölçekte standart bir toplu değerlendirme sistemi oluşturulması amacıyla değerlendirilmesi önerilmektedir. Böyle bir sistem, belediyelerin emlak vergisi değerlerini güncellerken piyasa gerçekliğini yansıtan, daha adil ve şeffaf vergilendirme süreçlerinin oluşturulmasına katkı sağlayacaktır. Bununla birlikte, 1319 sayılı Emlak Vergisi Kanunu ve ilgili yönetmeliklerde toplu değerlendirme yöntemlerine açık atıf yapılması veya bu yöntemleri esas alan ulusal bir standardın hazırlanarak yayımlanması, yapay zekâ destekli değerlendirme yaklaşımlarının kurumsal ve hukuki altyapısını güçlendirecektir. Ayrıca, TUCBS temelli verilerin modelle entegrasyonu, kurumlar arası veri paylaşımını kolaylaştırarak sistemin ülke genelinde

ölçeklenmesine imkân tanıyacaktır. Gayrimenkul değerleme süreçlerinde veri standardizasyonunun sağlanması ve açık veri politikalarının benimsenmesi ise kamu-özel sektör iş birliğini güçlendirecek, sektörde şeffaflık ve güvenilirliği artıracaktır.

Bu çalışmanın pratik katkıları da dikkate değerdir. Tez, Çevre, Şehircilik ve İklim Değişikliği Bakanlığı bünyesinde ulusal ölçekte taşınmaz değerleme sisteminin kurulması, veriye dayalı planlama süreçlerinin geliştirilmesi ve akıllı şehir politikalarının desteklenmesi açısından yatay olarak tüm genel müdürlüklerle ilişkilidir.

Önerilen model, taşınmaz değerleme, satış, kira, tahsis ve kamulaştırma gibi tüm Millî Emlak işlemlerinde karar destek mekanizması olarak kullanılabilir. Kamu taşınmazlarının gerçek piyasa değerleri üzerinden kiralanması ve satışı, bölgesel değer eşitsizliklerinin azaltılmasına ve kamu gelirlerinin optimizasyonuna katkı sağlayacaktır. Ayrıca model, mekânsal plan kararlarının ekonomik etkilerini analiz etmede kullanılabilir; örneğin imar yoğunluğu artışı gibi planlama kararlarının konut değeri üzerindeki etkilerini tahmin ederek sürdürülebilir kentsel gelişim politikalarına veri temelli destek sunar.

Değer haritaları, dönüşüm alanlarının önceliklendirilmesinde, riskli alanlardaki piyasa değerlerinin izlenmesinde ve dönüşüm öncesi-sonrası değer farkı analizlerinde etkin biçimde kullanılabilir. Bu sayede hak sahipliği belirleme süreçleri daha objektif, şeffaf ve veri temelli bir yapıya kavuşur. Sosyoekonomik ve çevresel göstergelerin (örneğin yeşil alan erişimi) değer üzerindeki etkilerinin modellenmesi, çevresel planlama süreçlerinde ekonomik göstergelerin üretilmesini sağlar. Bu doğrultuda “Yaşanabilirlik Endeksi” veya “Sürdürülebilir Mahalle Endeksi” gibi yeni ölçütlerin geliştirilmesi mümkündür.

Korunan alanlarda veya yakın çevrelerinde taşınmaz değerleri üzerindeki etkilerin analiz edilmesiyle, koruma kararlarının ekonomik sonuçları değerlendirilebilir. Doğal sit veya koruma alanları için ekosistem hizmet değeri analizleri yürütülerek çevresel politikaların ekonomik temeli güçlendirilebilir.

Model, belediyelerin emlak vergisi ve kentsel planlama süreçlerinin dijital dönüşümünü de desteklemektedir. Belediyelere toplu değerlendirme servisleri sunulurken emlak vergisi taban değerlerinin otomatik hesaplanması sağlanabilir; belediye CBS sistemleriyle entegre edilen değer haritalarının halka açık biçimde paylaşılmasıyla da şeffaflık ve katılımcılık artırılabilir. Bunun yanında sistem, kamusal varlık yönetimi, bütçeleme ve performans ölçümünde veri temelli karar alma süreçlerine katkı sunar; proje yatırım getirisi (ROI) analizlerinde model çıktılarının kullanımı “değer temelli yatırım önceliklendirmesi” yaklaşımını güçlendirir.

Ayrıca model, taşınmaz değer uyumsuzlukları ve kamulaştırma bedellerinde nesnel bir referans sistemi olarak kullanılabilir. Kamulaştırma bedel tespitlerinde veri temelli raporların üretilmesi ve yargısal süreçlerde bilirkişi desteği olarak kullanımı, adil ve şeffaf değerlendirmeleri teşvik edecektir. Model, yeni yatırım ve projelerin çevresel etkilerinin ekonomik karşılıklarını analiz etmede de kullanılabilir; ÇED raporlarında ekonomik etki analizi modülü olarak entegre edilebilir.

Tezde geliştirilen yaklaşım, AB fonlu “akıllı şehir”, “dijital kadastro” veya “sürdürülebilir kentsel gelişim” temalı projelere entegre edilerek Horizon Europe, Copernicus ve INSPIRE uyum projelerinde pilot uygulama olarak kullanılabilir. Böylece Türkiye, uluslararası veri standardizasyonu ve açık veri paylaşımı çerçevesinde örnek bir uygulama ülke konumuna gelebilir. Model ayrıca, arazi değer kaybı analizlerinde ve erozyon riski yüksek bölgelerde arazi değeri-toprak kalitesi ilişkilerinin modellenmesinde kullanılabilir; bu sayede arazi tahribatının ekonomik maliyeti tahmin edilerek çevresel sürdürülebilirlik politikalarına katkı sağlanabilir.

Son olarak, proje çıktılarının kamuoyuna tanıtımı “Veriyle Şeffaf Gayrimenkul Yönetimi” temalı bilgilendirme kampanyalarıyla desteklenebilir. Bu tür uygulamalar, kamu farkındalığını artırarak katılımcı, veri odaklı ve sürdürülebilir bir gayrimenkul yönetim kültürünün oluşmasına katkı sunacaktır. Ayrıca, önerilen sistemin blokzincir tabanlı çözümlerle desteklenmesi durumunda, taşınmaz değerlendirme, sertifikasyon ve mülkiyet yönetimi süreçleri güvenli, izlenebilir ve merkeziyetsiz hale gelebilir. Bu da dijital gayrimenkul piyasalarının oluşumu, değer zinciri süreçlerinin bütünleşmesi ve veri güvenliğinin sağlanması bakımından önemli bir potansiyel taşımaktadır.

Genel olarak, bu çalışma akıllı şehir politikalarıyla tam uyum içinde olup, veri odaklı, şeffaf ve sürdürülebilir kentsel yönetim anlayışının geliştirilmesine katkı sunmaktadır. Çalışmanın ortaya koyduğu model, Coğrafi Bilgi Sistemleri Genel Müdürlüğü, Milli Emlak Genel Müdürlüğü, Mekânsal Planlama Genel Müdürlüğü ve Yerel Yönetimler Genel Müdürlüğü başta olmak üzere bakanlık birimlerinin yürüttüğü “Dijital Dönüşüm”, “Taşınmaz Değer Bilgi Merkezi” ve “Akıllı Şehir Stratejisi” projelerine doğrudan entegre edilebilir niteliktedir. Bu yönüyle, tezde geliştirilen metodoloji yalnızca akademik bir katkı değil, aynı zamanda ulusal düzeyde akıllı şehir ekosisteminin veri ve analiz altyapısına stratejik bir girdi sunmaktadır.

Bununla birlikte, çalışmanın bazı sınırlılıkları bulunmaktadır. Kullanılan veri seti yalnızca Yenimahalle ve Keçiören ilçeleriyle sınırlıdır; dolayısıyla sonuçların Ankara geneline veya diğer kentlere doğrudan genellemesi sınırlı olabilir. Ayrıca veri, belirli bir döneme ait konut ilanlarını kapsamaktadır; piyasa dalgalanmaları veya uzun vadeli trendler tam olarak yansıtamamıştır. Modelde kullanılan değişkenler, veri erişilebilirliğine bağlı olarak kısıtlı kalmıştır. Sosyo-ekonomik (hane geliri, eğitim düzeyi, suç oranları) veya çevresel (hava kalitesi, gürültü, trafik yoğunluğu) göstergeler veri eksiklikleri nedeniyle dahil edilememiştir. Bu durum, konut değerini etkileyen bazı faktörlerin göz ardı edilmesine yol açabilir. Ayrıca, kullanılan algoritmaların sonuçları veri seti yapısına ve hiperparametre seçimlerine bağlıdır; farklı parametreler veya farklı algoritmalar farklı sonuçlar üretebilir. GridSearchCV tabanlı optimizasyon ise yüksek hesaplama maliyetine sahiptir ve donanım kısıtları nedeniyle daha geniş parametre aralıkları test edilememiştir.

Öte yandan model, piyasa koşullarına bağlı değer değişimlerini tahmin etmeye odaklanmakta olup, imar planı değişiklikleri sonucunda ortaya çıkan değer artış paylarını (rant artışlarını) doğrudan içermemektedir. Bu tür değer artışları, genellikle fonksiyon değişikliği, yoğunluk artışı veya plan notu revizyonu gibi idari kararların sonucu olduğundan, piyasa verilerine dayalı modellerle sınırlı biçimde temsil edilebilir. Ancak gelecekte, plan kararlarının mekânsal etkilerini modele entegre eden “değer artış analiz modülleri” geliştirilmesiyle bu kısıt aşılabılır.

Bu bağlamda, gelecek araştırmalar için bazı öneriler de sunulabilir. Öncelikle, bu çalışmada analiz yalnızca Yenimahalle ve Keçiören ilçeleriyle sınırlı kalmıştır;

ilerleyen arařtırmalarda Ankara'nın tamamını veya farklı řehirleri kapsayan daha geniř veri setlerinin kullanılması, modellerin genellenebilirlięini artıracaktır. Ayrıca, farklı dönemlere ait verilerin dahil edilmesi, piyasa dinamiklerinin zamansal deęiřimlerinin incelenmesine imkân saęlayacaktır.

Gelecek çalıřmalarda sosyo-ekonomik göstergeler (ör. hane gelir düzeyi, eęitim seviyesi, suç oranları), çevresel faktörler (ör. hava kalitesi, gürültü düzeyi, trafik yoğunluęu) ve mekânsal etkileřimler (ör. istihdam alanlarına eriřim) modele entegre edilerek daha bütüncül tahminler elde edilebilir. Bunun yanı sıra uydu görüntüleri, mobil veri veya sosyal medya yoğunlukları gibi mekânsal büyük veri kaynakları da destekleyici veri setleri olarak kullanılabilir.

Ayrıca, yapay zekâ modellerinin yalnızca statik veri setleriyle deęil, sürekli güncellenen dinamik veri akıřlarıyla beslenmesi, modellerin sürdürülebilirlięini artıracaktır. Belediyeler, emlak portalları, tapu-kadastro sistemleri ve dięer kurumsal kaynaklardan elde edilecek verilerin entegrasyonu ile kendi kendini güncelleyen öęrenme sistemleri tasarlanabilir. Bu sayede, modeller uzun vadede doęruluęunu koruyarak karar destek mekanizmalarına sürekli katkı saęlayabilecektir.

Son olarak, gayrimenkul deęerleme ve sertifikalandırma süreçlerinde blokzincir tabanlı çözümlerden yararlanılması önerilmektedir. Böylece hem veri güvenlięi ve řeffaflık artırılabilir hem de gayrimenkul varlıklarının dijital sertifikalar veya token'lar aracılıęıyla temsil edilmesi mümkün hale gelebilir. Bu yaklařım, mülkiyet haklarının güvence altına alınmasını kolaylařtıracak ve alternatif dijital gayrimenkul piyasalarının oluřumuna zemin hazırlayacaktır.

KAYNAKLAR

Adadi, A., & Berrada, M. (2018). Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI). *IEEE Access*, 6, 52138-52160. <https://doi.org/10.1109/ACCESS.2018.2870052>

Afet Riski Altındaki Alanların Dönüştürülmesi Hakkında Kanun, 6306 Afet Riski Altındaki Alanların Dönüştürülmesi Hakkında Kanun 26 (2012). <https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=6306&MevzuatTur=1&MevzuatTertip=5>

AI. (2025). *Appraisal Institute*. <https://www.appraisalinstitute.org/>

AIC. (2024). *Canadian Uniform Standards Of Professional Appraisal Practice*. <https://www.aicanada.ca/>

AIC. (2025). *Appraisal Institute of Canada*. <https://www.aicanada.ca/>

Ajuntament de Barcelona. (2025). *Ajuntament de Barcelona*. <https://opendata-ajuntament.barcelona.cat/en/>

Akar, A. U., & Yalpir, S. (2021). Using SVR And MRA Methods For Real Estate Valuation In The Smart Cities. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLVI-4/W5-2021, 21-26. <https://doi.org/10.5194/isprs-archives-XLVI-4-W5-2021-21-2021>

Akıllı Şehir İstanbul. (2025). *Akıllı Şehir İstanbul Projeler*. <https://www.akillisehir.istanbul/projeler-2/>

Allard, N., & Hagström, T. (2021). *Modern Housing Valuation: A Machine Learning Approach*.

Almy, R. (2014). *Valuation and Assessment of Immovable Property* (No. 19; OECD Working Papers on Fiscal Federalism, C. 19). OECD. <https://doi.org/10.1787/5jz5pzvr28hk-en>

Al-Rimawi, T., & Nadler, M. (2025). Leveraging Smart City Technologies for Enhanced Real Estate Development: An Integrative Review. *Smart Cities*, 8(1), 10. <https://doi.org/10.3390/smartcities8010010>

Ambrose, B. W., Eichholtz, P., & Lindenthal, T. (2013). House Prices and Fundamentals: 355 Years of Evidence. *Journal of Money, Credit and Banking*, 45(2-3), 477-491. <https://doi.org/10.1111/jmcb.12011>

Amparore, E., Perotti, A., & Bajardi, P. (2021). To trust or not to trust an explanation: Using LEAF to evaluate local linear XAI methods. *PeerJ Computer Science*, 7, e479. <https://doi.org/10.7717/peerj-cs.479>

Amri. (2012). Performance Of Multiple Linear Regression And Nonlinear Neural Networks And Fuzzy Logic Techniques In Modelling House Prices. *Journal of Mathematics and Statistics*, 8(4), 419-434. <https://doi.org/10.3844/jmssp.2012.419.434>

API. (2025a). *Australian Property Institute*. <https://www.api.org.au/>

API. (2025b). *Guidance Papers*. Australian Property Institute. <https://www.api.org.au/standards/standards-resources/>

Apsiyon. (2025). *Apartman ve Site Yöneticisinin Yanında*. <https://www.apsiyon.com/>

ASA. (2025). <https://www.appraisers.org>

Augment. (2025). *3D and augmented reality product visualization platform*. Augment. <https://www.augment.com/>

Autodesk Construction Cloud. (2025). *Construction Management Software*. <https://construction.autodesk.com/>

Aydinoglu, A. C., Bovkir, R., & Colkesen, I. (2021). Implementing a mass valuation application on interoperable land valuation data model designed as an extension of the national GDI. *Survey Review*, 53(379), 349-365. <https://doi.org/10.1080/00396265.2020.1771967>

Bankacılık Kanunu, 5411 Bankacılık Kanunu (2005). <https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=5411&MevzuatTur=1&MevzuatTertip=5>

Barcelona City Council. (2025). *Barcelona City Council Open Data catalogue*. <https://datos.gob.es/es/catalogo/101080193-catalogo-de-los-datos-abiertos-del-ajuntament-de-barcelona-open-data-bcn>

Baum, A. (2017). *PropTech 3.0: The future of real estate* (s. 98) [Araştırma raporu]. Oxford Said Business School. www.sbs.oxford.edu

Baum, A. (2020). Tokenisation – The Future of Real Estate Investment? *Saïd Business School University of Oxford*.

Baum, A., Saull, A., & Braesemann, F. (2020). *PropTech 2020: The future of real estate* (s. 112) [Araştırma raporu]. Oxford Said Business School.

BDDK. (2023). *Bankaların Kredi İşlemlerine İlişkin Yönetmelik*. BDDK. <https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=40520&MevzuatTur=7&MevzuatTertip=5>

BIMCRONE. (2025). *Digital twin and BIM based Construction Project Management Platform*. Digital Twin of Life. <https://bimcrone.com/>

Bogin, A. N., & Shui, J. (2020). Appraisal Accuracy and Automated Valuation Models in Rural Areas. *The Journal of Real Estate Finance and Economics*, 60(1-2), 40-52. <https://doi.org/10.1007/s11146-019-09712-0>

Botchkarev, A. (2019). A New Typology Design of Performance Metrics to Measure Errors in Machine Learning Regression Algorithms. *Interdisciplinary Journal of Information, Knowledge, and Management*, 14, 045-076. <https://doi.org/10.28945/4184>

Braesemann, F., & Baum, A. (2020a). PropTech: Turning Real Estate Into a Data-Driven Market? *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3607238>

Braesemann, F., & Baum, A. (2020b). PropTech: Turning Real Estate Into a Data-Driven Market? *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3607238>

Brander, L. M., & Koetse, M. J. (2011). The value of urban open space: Meta-analyses of contingent valuation and hedonic pricing results. *Journal of Environmental Management*, 92(10), 2763-2773. <https://doi.org/10.1016/j.jenvman.2011.06.019>

Bridgit. (2025). *Construction Resource Management Software*. Bridgit. <https://gobridgit.com/>

Building Engines. (2025). *Property Management Software for CRE*. Building Engines. <https://www.buildingengines.com/>

Buildots. (2025). *Performance-Driven Construction Management*. Buildots. <https://buildots.com/>

BuildVision. (2025). *Transform Your Construction Business with AI*. BuildVision. <https://buildvisionai.com>

Bulutistan. (2025). *Bulutistan*. <https://www.bulutistan.com/>

Bühlmann, P. (2012). Bagging, Boosting and Ensemble Methods. İçinde J. E. Gentle, W. K. Härdle, & Y. Mori (Ed.), *Handbook of Computational Statistics* (ss. 985-1022). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-21551-3_33

BVS. (2025). *Federal Yeminli Uzmanlar Birliği | BVS*. <https://www.bvs-ev.de/>

CAS. (2025). *China Appraisal Society (CAS)*. China Appraisal Society (CAS). <https://www.cas.org.cn>

Čeh, M., Kilibarda, M., Lisec, A., & Bajat, B. (2018). Estimating the Performance of Random Forest versus Multiple Regression for Predicting Prices of the Apartments. *ISPRS International Journal of Geo-Information*, 7(5), 168. <https://doi.org/10.3390/ijgi7050168>

Ce.S.E.T. (2025). *Centro di Estimo e di Economia Territoriale*. <https://www.ceset.it>

Chawla, A. (2023, Nisan 20). *A Visual and Overly Simplified Guide To Bagging and Boosting*. <https://blog.dailydoseofds.com/p/a-visual-and-overly-simplified-guide-4b1>

Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794. <https://doi.org/10.1145/2939672.2939785>

Choy, L. H. T., & Ho, W. K. O. (2023). The Use of Machine Learning in Real Estate Research. *Land*, 12(4), 740. <https://doi.org/10.3390/land12040740>

ChromaWay. (2025). *Pioneers of Blockchain*. <https://chromaway.com/>

Coğrafi Bilgi Sistemleri Genel Müdürlüğü. (2025). Coğrafi Bilgi Sistemleri Genel Müdürlüğü. <https://cbs.csb.gov.tr/>

Coğrafi İstatistik Portalı. (2025). Coğrafi İstatistik Portalı. <https://cip.tuik.gov.tr/>

Cotality. (2025). *Intelligence beyond bounds*. <https://www.cotality.com/>

CRE. (2025a). *The CRE Designation*. Counselors of Real Estate. <https://cre.org/about/the-cre-designation/>

CRE. (2025b, Haziran 5). *The Counselors of Real Estate*. Counselors of Real Estate. <https://cre.org/>

Cruz Rambaud, S., & López Pascual, J. (2023). Insurtech, PropTech, and Fintech Environment: Sustainability, Global Trends and Opportunities. *Sustainability*, 15(12), 3. <https://doi.org/10.3390/su15129574>

Cupix. (2025). *4D Digital Twin For Construction & Facility Management*. <https://www.cupix.com/>

ÇEDBİK. (2025). *Çevre Dostu Yeşil Binalar Derneği*. <https://www.cedbik.org>

Çılgın, C., Gökçen, H., & Gazi University, Ankara (Türkiye). (2023). Machine learning methods for prediction real estate sales prices in Turkey. *Revista de La Construcción*, 22(1), 163-177. <https://doi.org/10.7764/RDLC.22.1.163>

Das, A., & Rad, P. (2020). *Opportunities and Challenges in Explainable Artificial Intelligence (XAI): A Survey* (No. arXiv:2006.11371). arXiv. <https://doi.org/10.48550/arXiv.2006.11371>

Dempsey, C. (2015). *A Brief History of GIS*. Geography Realm. <https://www.geographyrealm.com/history-of-gis/>

Desigo CC. (2025). *Desigo CC. Siemens Türkiye*. <https://www.siemens.com/tr/tr/urunler/bina-teknolojileri/otomasyon/desigo/bina-yonetim-sistemleri/desigo-cc.html>

Dimopoulos, T., & Bakas, N. (2019). Sensitivity Analysis of Machine Learning Models for the Mass Appraisal of Real Estate. Case Study of Residential Units in Nicosia, Cyprus. *Remote Sensing*, 11(24), 3047. <https://doi.org/10.3390/rs11243047>

Dimopoulos, T., Tyrallis, H., Bakas, N. P., & Hadjimitsis, D. (2018). Accuracy measurement of Random Forests and Linear Regression for mass appraisal models that estimate the prices of residential apartments in Nicosia, Cyprus. *Advances in Geosciences*, 45, 377-382. <https://doi.org/10.5194/adgeo-45-377-2018>

Doumard, E., Aligon, J., Escriva, E., Excoffier, J.-B., Monsarrat, P., & Soulé-Dupuy, C. (2022). *A comparative study of additive local explanation methods based on feature influences*. 11.

Dubai Land Department. (2025). *Dubai Land Department*. <https://dubailand.gov.ae/#/>

Dursun, İ. (2023, Temmuz 30). 3 Boyutlu Kadastro Veri Modeli Tasarımı, Gayrimenkul Değerleme Entegrasyonu ve Uygulaması: Amasya Pilot Projesi. *TKGM*. <https://tkgmmakale.com/3-boyutlu-kadastro-veri-modeli-tasarimi-gayrimenkul-degerleme-entegrasyonu-ve-uygulamasi-amasya-pilot-projesi>

Emlak Vergisi Kanunu, 1319 Emlak Vergisi Kanunu 34 (1970). <https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=1319&MevzuatTur=1&MevzuatTertip=5>

Emlakjet. (2025). *Ev ve Daire Aramanın Yeni Nesil Yolu*. <https://www.emlakjet.com/>

Endeksa. (2025a). *Evinizin Kıymetini Bilin, Danışman Bulun, Güvenle Satın*. Endeksa. <https://www.endeksa.com/tr/>

Endeksa. (2025b). *Evinizin Kıymetini Bilin, Danışman Bulun, Güvenle Satın*. Endeksa. <https://www.endeksa.com/tr/>

Eriksen, R. L., & Müller, J. (2024). *Using historical sales data to enhance the accuracy of AVMs in real estate finance*. 73.

Et. Al., J. A. (2021). Prediction of House Price Using XGBoost Regression Algorithm. *Turkish Journal of Computer and Mathematics Education*, 12(2). <https://doi.org/10.17762/turcomat.v12i2.1870>

Evreka. (2025). *Atık Yönetim Platformu*. <https://evreka.co/tr/>

Facilio. (2025). *Property Operations Done Right*. <https://facilio.com/>

FIABCI. (2018). *International Real Estate Federation*. <https://www.fiabci.org/>

Fischer, M. M., & Getis, A. (Ed.). (2010). *Handbook of Applied Spatial Analysis: Software Tools, Methods and Applications*. Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-03647-7>

Fitzpatrick, M., Gujral, V., Kapoor, A., & Wolkomir, A. (2023). *The Power Of Generative AI In Real Estate*. <https://www.mckinsey.com/industries/real-estate/our-insights/generative-ai-can-change-real-estate-but-the-industry-must-change-to-reap-the-benefits>

Fizbot. (2025). *Fizbot Sales Navigator*. <https://fizbot.net/tr>

Freshcode. (2025). *How Technology is Changing the Real Estate Market*. <https://www.freshcodeit.com/blog/real-estate-technology-trends>

Fuerst, F., McAllister, P., Nanda, A., & Wyatt, P. (2015). Does energy efficiency matter to home-buyers? An investigation of EPC ratings and transaction prices in England. *Energy Economics*, 48, 145-156. <https://doi.org/10.1016/j.eneco.2014.12.012>

Fundrise. (2025). *Fundrise*. <https://fundrise.com/>

Gabrielli, L., & French, N. (2021). Pricing to market: Property valuation methods – a practical review. *Journal of Property Investment & Finance*, 39(5), 464-480. <https://doi.org/10.1108/JPIF-09-2020-0101>

Gao, Q., Shi, V., Pettit, C., & Han, H. (2022). Property Valuation Using Machine Learning Algorithms On Statistical Areas In Greater Sydney, Australia. *Land Use Policy*, 123, 106409. <https://doi.org/10.1016/j.landusepol.2022.106409>

Garcia, M., Tomas, R., Lopez, C., Francisca, M., Sanchez, P., & Raul, V. (2022). Housing Price Prediction Using Machine Learning Algorithms in COVID-19 Times. *Land*, 11(11), 32. <https://doi.org/10.3390/land11112100>

García-Magariño, I., Medrano, C., & Delgado, J. (2020). Estimation Of Missing Prices In Real-Estate Market Agent-Based Simulations With Machine Learning And Dimensionality Reduction Methods. *Neural Computing and Applications*, 32(7), 2665-2682. <https://doi.org/10.1007/s00521-018-3938-7>

Get Twin. (2025). *Get Twin*. <https://gettwin.com/>

Ghalebikesabi, S., Ter-Minassian, L., Diaz-Ordaz, K., & Holmes, C. (2021). On Locality of Local Explanation Models. *University of Oxford*.

Ghamrawi, T., & Nat, M. (2024). House Value Estimation using Different Regression Machine Learning Techniques. *Acta Infologica*, 8(2), 245-259. <https://doi.org/10.26650/acin.1543650>

Gnat, S. (2021). Property Mass Valuation on Small Markets. *Land*, 10(4), 388. <https://doi.org/10.3390/land10040388>

Gong, Y. (2017). The Spatial Dimension of House Prices. *Architech Built Environ*, 4, 186.

Goodman, A. C. (1978). Hedonic Prices, Price Indices and Housing Markets. *Journal of Urban Economics*, 5(4), 471-484. [https://doi.org/10.1016/0094-1190\(78\)90004-9](https://doi.org/10.1016/0094-1190(78)90004-9)

Government of India. (2025). *Centre Of Excellence In Blockchain Technology*. <https://blockchain.gov.in/Home/CaseStudy?CaseStudy=LandRegistration>

Guliker, E., Folmer, E., & Van Sinderen, M. (2022). Spatial Determinants of Real Estate Appraisals in The Netherlands: A Machine Learning Approach. *ISPRS International Journal of Geo-Information*, 11(2), 125. <https://doi.org/10.3390/ijgi11020125>

Henri L.F. de Groot, F. de V. (2009). *The Impact of Industrial Sites on Residential Property Values*. 609-623.

History of GIS. (2025). History of GIS. <https://www.esri.com/en-us/what-is-gis/history-of-gis>

Hjort, A., Pensar, J., Scheel, I., & Sommervoll, D. E. (2022). House price prediction with gradient boosted trees under different loss functions. *Journal of Property Research*, 39(4), 338-364. <https://doi.org/10.1080/09599916.2022.2070525>

Hjort, A., Scheel, I., Sommervoll, D. E., & Pensar, J. (2024). Locally interpretable tree boosting: An application to house price prediction. *Decision Support Systems*, 178, 114106. <https://doi.org/10.1016/j.dss.2023.114106>

Ho, W. K. O., Tang, B.-S., & Wong, S. W. (2021). Predicting property prices with machine learning algorithms. *Journal of Property Research*, 38(1), 48-70. <https://doi.org/10.1080/09599916.2020.1832558>

Hong, J., Choi, H., & Kim, W. (2020). A House Price Valuation Based On The Random Forest Approach: The Mass Appraisal Of Residential Property In South Korea. *International Journal of Strategic Property Management*, 24(3), 140-152. <https://doi.org/10.3846/ijspm.2020.11544>

Housearch. (2025). *Türkiye’de gayrimenkul arama*. <https://housearch.com/tr/turkey/>

HouseCanary. (2025). *Unlocking Real Estate Opportunities with Accurate Property Data and AI-Powered Analytics*. <https://www.housecanary.com/>

Huang, N., Lu, G., & Xu, D. (2016). A Permutation Importance-Based Feature Selection Method for Short-Term Electricity Load Forecasting Using Random Forest. *Energies*, 9(10), 767. <https://doi.org/10.3390/en9100767>

Huang, Y. (2019). Predicting Home Value in California, United States via Machine Learning Modeling. *Statistics, Optimization & Information Computing*, 7(1), 66-74. <https://doi.org/10.19139/soic.v7i1.435>

HypZert. (2025). *HypZert GmbH*. HypZert. <https://www.hypzert.de>

IAAO. (2018). *Standard on Mass Appraisal of Real Property* [Standart]. IAAO. <https://www.iaao.org/industry-data/iaao-technical-standards/>

IAAO. (2025). *International Association of Assessing Officers*. <https://www.iaao.org/>

Iban, M. C. (2022b). An Explainable Model For The Mass Appraisal Of Residences: The Application Of Tree-Based Machine Learning Algorithms And Interpretation Of Value Determinants. *Habitat International*, 128, 102660. <https://doi.org/10.1016/j.habitatint.2022.102660>

Iban, M. C. (2022a). An explainable model for the mass appraisal of residences: The application of tree-based Machine Learning algorithms and interpretation of value

determinants. *Habitat International*, 128, 102660.
<https://doi.org/10.1016/j.habitatint.2022.102660>

IBM Envizi. (2024, Mayıs 16). *IBM Envizi*. <https://www.ibm.com/products/envizi>

IFEI. (2018). *L'institut Français de l'Expertise Immobilière*. <https://www.ifei.org/UK/>

Islam, S. R., Eberle, W., Ghafoor, S. K., & Ahmed, M. (2021). *Explainable Artificial Intelligence Approaches: A Survey* (No. arXiv:2101.09429). arXiv.
<https://doi.org/10.48550/arXiv.2101.09429>

IVSC. (2023). *International Valuation Standards Council*. <https://ivsc.org/>

IVSC. (2025). *International Valuation Standards (IVS)*.

İban, M. C. (2021). *Taşınmaz Mal Değeri Kestiriminde Topluluk Algoritmalarının Doğruluk Analizi*. 47.

İmar Kanunu, 3194 İmar Kanunu 54 (1985).
<https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=3194&MevzuatTur=1&MevzuatTertip=5>

Ja'afar, N. S., & Mohamad, J. (2021). Application Of Machine Learning In Analysing Historical And Non-Historical Characteristics Of Heritage Pre-War Shophouses. *PLANNING MALAYSIA*, 19. <https://doi.org/10.21837/pm.v19i16.953>

Ja'afar, N. S., Mohamad, J., & Ismail, S. (2021). Machine Learning For Property Price Prediction And Price Valuation: A Systematic Literature Review. *Planning Malasia*, 19. <https://doi.org/10.21837/pm.v19i17.1018>

Jafary, P., Shojaei, D., Rajabifard, A., & Ngo, T. (2024). Automated land valuation models: A comparative study of four machine learning and deep learning methods

based on a comprehensive range of influential factors. *Cities*, 151, 105115. <https://doi.org/10.1016/j.cities.2024.105115>

JAREA. (2025). *Japanese Association of Real Estate Appraisers*. <https://www.fudousan-kanteishi.or.jp/>

Kamulaştırma Kanunu, 2942 Kamulaştırma Kanunu 33 (1983). <https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=2942&MevzuatTur=1&MevzuatTertip=5>

KAPA. (2025). *Korea Association of Property Appraisers*. <https://www.kapanet.or.kr>

Karahan, D. (2023a). *The Future of Buildings: Smart & Autonomous*.

Karahan, D. (2023b). *The Inception of Property Technology*.

Karahan, D. (2023c). *Valuation of Sustainable Real Estate*.

Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). *LightGBM: A Highly Efficient Gradient Boosting Decision Tree*.

Kentsel Dönüşüm Başkanlığı. (2025). *Kentsel Dönüşüm Başkanlığı*. <https://kdb.gov.tr/>
King, R., Zavyalova, K., & Josefsson, K. (2022, Eylül 22). *Introducing the FOAM Protocol*. Medium. <https://blog.foam.space/introducing-the-foam-protocol-2598d2f71417>

Kisi. (2025). *Cloud-Based Access Control & Security Platform*. <https://www.getkisi.com/>

Koktashev, V., Makeev, V., Shchepin, E., Peresunko, P., & Tynchenko, V. V. (2019). Pricing modeling in the housing market with urban infrastructure effect. *Journal of*

Physics: Conference Series, 1353(1), 012139. <https://doi.org/10.1088/1742-6596/1353/1/012139>

Konstantinov, A. V., & Utkin, L. V. (2021). Interpretable machine learning with an ensemble of gradient boosting machines. *Knowledge-Based Systems*, 222, 106993. <https://doi.org/10.1016/j.knosys.2021.106993>

Konut Finansmanı Kanunu, 5582 Konut Finansmanı Sistemine İlişkin Çeşitli Kanunlarda Değişiklik Yapılması Hakkında Kanun (2007). <https://www.resmigazete.gov.tr/eskiler/2007/03/20070306-1.htm>

Krämer, B., Stang, M., Doskoč, V., Schäfers, W., & Friedrich, T. (2023). Automated valuation models: Improving model performance by choosing the optimal spatial training level. *Journal of Property Research*, 40(4), 365-390. <https://doi.org/10.1080/09599916.2023.2206823>

Kurt, S., Kara, İ., & Yalçın, M. E. (2022). *Değerleme*. Millî Emlak Genel Müdürlüğü.

Lantmäteriet. (2016). *Framtidens husköp i blockkedjan* (s. 42). Lantmäteriet.

Lendinvest. (2025). *Mortgages*. <https://www.lendinvest.com/>

Li, S., Jiang, Y., Ke, S., Nie, K., & Wu, C. (2021). Understanding the Effects of Influential Factors on Housing Prices by Combining Extreme Gradient Boosting and a Hedonic Price Model. *Land*, 10(5), 533. <https://doi.org/10.3390/land10050533>

Li, Z. (2022). Extracting spatial effects from machine learning model using local interpretation method: An example of SHAP and XGBoost. *Computers, Environment and Urban Systems*, 96, 101845. <https://doi.org/10.1016/j.compenvurbsys.2022.101845>

Lin, W., Shi, Z., Wang, Y., & Yan, T. H. (2023). Unfolding Beijing in a Hedonic Way. *Computational Economics*, 61(1), 317-340. <https://doi.org/10.1007/s10614-021-10209-3>

Llorca-Ponce, A., & Rius-Sorollila, G. (2023, Temmuz 13). Real Estate meets technology. The impact of new technologies on the real estate sector in Spain. *Libro de Actas. 5th International Conference. Business Meets Technology*. <https://doi.org/10.4995/BMT2023.2023.16747>

Longley, P. A., Goodchild, M. F., Maguire, D. J., & Rhind, D. W. (2015). *Geographic Information Science and Systems*. John Wiley & Sons.

Lundberg, S. M., Erion, G., & Chen, H. (2019). *Explainable AI for Trees: From Local Explanations to Global Understanding* (No. arXiv:1905.04610). arXiv. <https://doi.org/10.48550/arXiv.1905.04610>

Maalsen, S., Rogers, D., & Wolifson, P. (2024). The social lives of rental proptech: Entanglements between capitalist, care and techno-utopian values. *Environment and Planning D: Society and Space*, 42(4), 476-491. <https://doi.org/10.1177/02637758241231105>

Marzagão, T., Ferreira, R., & Sales, L. (2019). *Real Estate Appraisal in Brazil*. Open Science Framework. <https://doi.org/10.31219/osf.io/zrgv6>

Mattarocci, G., & Scimone, X. (2022). *The New Era of Real Estate: An Analysis of Business Models in the Proptech Industry*. Springer International Publishing. <https://doi.org/10.1007/978-3-031-16731-7>

Matterport. (2025). *Capture, share, and collaborate the built world in immersive 3D*. Matterport. <https://matterport.com>

Mayer, M., Bourassa, S. C., Hoesli, M., & Scognamiglio, D. (2019). Estimation and updating methods for hedonic valuation. *Journal of European Real Estate Research*, 12(1), 134-150. <https://doi.org/10.1108/jerer-08-2018-0035>

McMillen, D. P. (2004). Geographically Weighted Regression: The Analysis of Spatially Varying Relationships. *American Journal of Agricultural Economics*, 86(2), 554-556. https://doi.org/10.1111/j.0002-9092.2004.600_2.x

Measurabl. (2025). *The World's Leading ESG Platform for Real Estate*. Measurabl. <https://www.measurabl.com/>

Michaël Dellstad. (2018). *Comparing three machine learning algorithms in the task of appraising commercial real estate* [Tez]. KTH Royal Institute Of Technology School Of Electrical Engineering And Computer Science.

Milli Emlak Genel Müdürlüğü. (2025). *Milli Emlak Genel Müdürlüğü*. <https://www.milliemlak.gov.tr/#/>

Mohamad, J., & Ismail, S. (2019). Capabilities Of Revealed Preference Method For Heritage Property Valuation. *Planning Malaysia Journal*, 17(9). <https://doi.org/10.21837/pmjournal.v17.i9.613>

Munawar, H. S., Qayyum, S., Ullah, F., & Sepasgozar, S. (2020). Big Data and Its Applications in Smart Real Estate and the Disaster Management Life Cycle: A Systematic Analysis. *Big Data and Cognitive Computing*, 4(2), 4. <https://doi.org/10.3390/bdcc4020004>

Nantum AI. (2025). *Nantum AI*. <https://www.nantum.ai>

Neves, F. T., Aparicio, M., & De Castro Neto, M. (2024). The Impacts of Open Data and eXplainable AI on Real Estate Price Predictions in Smart Cities. *Applied Sciences*, 14(5), 2209. <https://doi.org/10.3390/app14052209>

Numan, J. A. A., & Yusoff, I. M. (2024). Identifying the Current Status of Real Estate Appraisal Methods. *Real Estate Management and Valuation*, 32(4), 12-27. <https://doi.org/10.2478/remav-2024-0032>

OECD. (2022). *Housing Taxation in OECD Countries*. OECD. <https://doi.org/10.1787/03dfe007-en>

OpenSpace. (2025). *Reality Capture & Construction Site Capture | OpenSpace*. <https://www.openspace.ai/>

Ostrikova, A., & Selyutin, V. (Ed.). (2024). Machine Learning for Mass Valuation of Residential Real Estate. İçinde *Advances in Information and Communication: Proceedings of the 2024 Future of Information and Communication Conference (FICC), Volume 1* (C. 919, ss. 570-578). Springer Nature Switzerland. <https://doi.org/10.1007/978-3-031-53960-2>

Oust, A., Westgaard, S., Waage, J. E., & Yemane, N. K. (2025). Assessing the Explanatory Power of Dwelling Condition in Automated Valuation Models. *Journal of Real Estate Research*, 47(1), 1-27. <https://doi.org/10.1080/08965803.2023.2280280>

Özelleştirme Uygulamaları Hakkında Kanun, 4046 Özelleştirme Uygulamaları Hakkında Kanun (1994). <https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=4046&MevzuatTur=1&MevzuatTertip=5>

Pai, P. F., & Wang, W.-C. (2020). Using Machine Learning Models and Actual Transaction Data for Predicting Real Estate Prices. *Applied Sciences*, 10(17), 5832. <https://doi.org/10.3390/app10175832>

Peng, Z., Huang, Q., & Han, Y. (2019). Model Research on Forecast of Second-Hand House Price in Chengdu Based on XGboost Algorithm. *2019 IEEE 11th International*

Conference on Advanced Infocomm Technology (ICAIT), 168-172.
<https://doi.org/10.1109/icait.2019.8935894>

PlanGrid. (2025). *PlanGrid, Login & Get Support*.
<https://construction.autodesk.com/products/plangrid/>

Plevris, V., Solorzano, G., Bakas, N., & Ben Seghier, M. (2022). Investigation of performance metrics in regression analysis and machine learning-based prediction models. *8th European Congress on Computational Methods in Applied Sciences and Engineering*. 8th European Congress on Computational Methods in Applied Sciences and Engineering. <https://doi.org/10.23967/eccomas.2022.155>

Precedence Research. (2025). *PropTech Market Size to Surge USD 179.03 Bn By 2034*. <https://www.precedenceresearch.com/proptech-market>

PriceHubble. (2025). *Real estate valuation & insights solutions*.
<https://www.pricehubble.com/en/>

Procore. (2025). *Procore Construction Management Software*. Procore.
<https://www.procore.com/procore>

PropertyGuru. (2025). *Singapore Property, Property for Sale/Rent, Singapore Real Estate | PropertyGuru*. <https://www.propertyguru.com.sg/>

Propy. (2025). *Propy*. <https://propy.com/home/>

Rampini, L., & Re Cecconi, F. (2022). Artificial intelligence algorithms to predict Italian real estate market prices. *Journal of Property Investment & Finance*, 40(6), 588-611. <https://doi.org/10.1108/JPIF-08-2021-0073>

RealT. (2025a). *Fractional Investment in Tokenized Real Estate Assets | RealT*.
<https://realt.co/>

RealT. (2025b). *RealT, Inc.* RealT, Inc. <https://realt.co/>

Reengen. (2025). *Https://reengen.com.* <https://reengen.com>

Renigier-Biłozor, M., Żróbek, S., Walacik, M., Borst, R., Grover, R., & d'Amato, M. (2022). International acceptance of automated modern tools use must-have for sustainable real estate market development. *Land Use Policy*, 113, 105876. <https://doi.org/10.1016/j.landusepol.2021.105876>

RICS. (2022). *Automated valuation models (AVMs): Implications for the profession and their clients* [Standart]. <https://www.rics.org/profession-standards/rics-standards-and-guidance/sector-standards/valuation-standards/automated-valuation-models>

RICS. (2024a). *Corporate Governance at RICS.* <https://www.rics.org/about-rics/corporate-governance>

RICS. (2024b). *RICS.* <https://www.rics.org/>

RICS. (2024c). *ROC Case Study.* <https://www.rics.org/profession-standards/rics-standards-and-guidance/conduct-competence/rules-of-conduct/roc-case-studies-02>

Rightmove. (2025). *UK's number one property website for properties for sale and to rent.* <https://www.rightmove.co.uk/>

Rolli, C. S. (2020). *Zillow Home value Prediction Using XGBOOST.* 47.

Rowland, L. (2024, Aralık 30). *Revaluation of property data used to set local taxes delayed in France but concerns continue.* <https://www.connexionfrance.com/news/revaluation-of-property-data-used-to-set-local-taxes-delayed-in-france-but-concerns-continue/697096>

RSA. (2025). *Международная деятельность*. Russian Society of Appraisers (RSA). <http://sroroo.ru/about/activities/about-rsa/>

Sağlam, B. K., Mete, M. O., Özerman, U., & Alkan, R. M. (2023). *Comparison of machine learning regression methods for mass real estate valuation*.

Sajnog, N., & Jaskolska, M. (2024). The Importance of Residential Real Estate Characteristics in the Assessment of Selected Groups of Real Estate Market Participants. *Real Estate Management and Valuation*, 11. <https://doi.org/10.2478/remav-2025-0011>

Sajol, S. I., & Uddin, M. N. (2024). *Comparative Analysis of Housing Price Prediction of Dhaka City Using Machine Learning*.

Sapakova, S., & Sapakov, A. (2024). Features of modeling the online real estate market in Almaty. *Procedia Computer Science*, 231, 409-414. <https://doi.org/10.1016/j.procs.2023.12.226>

Savaş, B. (2019). *Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü*.

Schirm, I. C., Concha, F. M., Bergel, A., & Sierra, P. D. (2019). *Predicción De Rentas En Santiago De Chile Utilizando Algoritmos De Aprendizaje Automático*. 64.

Sermaye Piyasası Kanunu, 6362 Sermaye Piyasası Kanunu 113 (2012). <https://resmigazete.gov.tr/eskiler/2012/12/20121230-1.htm>

Sharma, H., Harsora, H., & Ogunleye, B. (2024). An Optimal House Price Prediction Algorithm: XGBoost. *Analytics*, 3(1), 30-45. <https://doi.org/10.3390/analytics3010003>

Shin, L. (2022, Temmuz 17). *Republic Of Georgia To Pilot Land Titling On Blockchain With Economist Hernando De Soto*, BitFury. Forbes.

<https://www.forbes.com/sites/laurashin/2016/04/21/republic-of-georgia-to-pilot-land-titling-on-blockchain-with-economist-hernando-de-soto-bitfury/>

Shukla, V., Raipurkar, A. R., & Chandak, M. B. (2024). Blockchain and ML in land registries a transformative alliance. *International Journal of Informatics and Communication Technology*, 13(2), 239. <https://doi.org/10.11591/ijict.v13i2.pp239-247>

Silhavy, R., Silhavy, P., & Prokopova, Z. (Ed.). (2021). Stacking-Based Ensemble Learning Method for House Price Prediction. *Çinde Software Engineering Application in Informatics: Proceedings of 5th Computational Methods in Systems and Software 2021, Vol. 1* (s. 224). Springer International Publishing. <https://doi.org/10.1007/978-3-030-90318-3>

Simularge. (2025). *CAE and Digital Twin Software*. <https://www.simularge.com/>

SmartThings. (2025). *Akıllı bir ev için Samsung SmartThings | Samsung Türkiye*. <https://www.samsung.com/tr/smarthings/>

So, H. M., Tse, R. Y. C., & Ganesan, S. (1997). Estimating the influence of transport on house prices: Evidence from Hong Kong. *Journal of Property Valuation and Investment*, 15(1), 40-47. <https://doi.org/10.1108/14635789710163793>

Soltani, A., Heydari, M., Aghaei, F., & Pettit, C. J. (2022). Housing price prediction incorporating spatio-temporal dependency into machine learning algorithms. *Cities*, 131, 103941. <https://doi.org/10.1016/j.cities.2022.103941>

Spaceti. (2025). *All-in-One Workplace Experience Platform powered by AI*. Spaceti, Space & Time Efficiency. <https://spaceti.com/>

SPK. (2019). *Sermaye Piyasasında Faaliyette Bulunacak Gayrimenkul Değerleme Kuruluşları Hakkında Tebliğ III- 62.3.* SPK. <https://resmigazete.gov.tr/eskiler/2019/08/20190831-12.htm>

SPK. (2025a). *Görev Yetki ve Sorumluluklar.* <https://spk.gov.tr>. <https://spk.gov.tr/hakkimizda/gorev-yetki-ve-sorumluluklar>

SPK. (2025b). *Organizasyon.* <https://spk.gov.tr>. <https://spk.gov.tr/hakkimizda/organizasyon>

SPK. (2025c). *Spk Web.* <https://spk.gov.tr>. <https://spk.gov.tr/>

Stang, M. (2023). *Real Estate Valuation in the Age of Artificial Intelligence – Modern Machine Learning Algorithms and their Application in Property Appraisal* [Tez]. Submitted to the Faculty of Business, Economics, and Management Information Systems at the University of Regensburg.

Stang, M., Krämer, B., Nagl, C., & Schäfers, W. (2023). From human business to machine learning methods for automating real estate appraisals and their practical implications. *Zeitschrift Für Immobilienökonomie*, 9(2), 81-108. <https://doi.org/10.1365/s41056-022-00063-1>

Stanišić, N., Radojević, T., & Stanić, N. (Ed.). (2021). Appraisal of apartments in Belgrade using hedonic regression: Model specification, predictive performance, suitability for mass appraisal, and comparison with machine learning methods. İçinde *Artificial Intelligence: Theory and Applications* (C. 973, ss. 293-312). Springer International Publishing. <https://doi.org/10.1007/978-3-030-72711-6>

Steurer, M., Hill, R. J., & Pfeifer, N. (2021). Metrics for evaluating the performance of machine learning based automated valuation models. *Journal of Property Research*, 38(2), 99-129. <https://doi.org/10.1080/09599916.2020.1858937>

Strobl, C., Boulesteix, A.-L., Zeileis, A., & Hothorn, T. (2007). Bias in random forest variable importance measures: Illustrations, sources and a solution. *BMC Bioinformatics*, 8(1), 25. <https://doi.org/10.1186/1471-2105-8-25>

TAF. (2021). *About The Appraisal Foundation*. About The Appraisal Foundation. https://appraisalfoundation.org/imis/TAF/About_Us/TAF/About_Us.aspx?hkey=52dedd0a-de2f-4e2d-9efb-51ec94884a91

TAF. (2024). *Uniform Standards of Professional Appraisal Practice (USPAP)*. Wiley. <https://doi.org/10.1002/9781119200130.ch10>

Tanrıvermiş, H. (2016). *Gayrimenkul Değerleme Esasları*.

Tapu Kanunu, 2644 Tapu Kanunu 12 (1934). <https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=2644&MevzuatTur=1&MevzuatTertip=3>

Tapu.com. (2025). *Tapu.com*. Yeni Nesil Gayrimenkul Pazar Yeri. <https://www.tapu.com/>

Tarasov, S., & Dessoulavy-Śliwiński, B. (2025). Algorithm-Driven Hedonic Real Estate Pricing – An Explainable AI Approach. *Real Estate Management and Valuation*, 33(1), 22-34. <https://doi.org/10.2478/remav-2025-0003>

TCMB. (2025). *EVDS*. <https://evds2.tcmb.gov.tr/index.php?/evds/portlet/KSAktmjeowo%3D/tr>

TDUB. (2025a). *2025 YILI I. ÇEYREK DEĞERLEME SEKTÖRÜ ANALİZ RAPORU*. MKK Gayrimenkul Bilgi Merkezi A.Ş. <https://tdub.org.tr/sayfa/degerleme-sektoru-ozet-verileri>

TDUB. (2025b). *Değerleme Sektörü 2025 Yılı I. Çeyrek Raporu* [Analiz Raporu]. MKK Gayrimenkul Bilgi Merkezi A.Ş. <https://tdub.org.tr/sayfa/degerleme-sektoru-ozet-verileri>

TDUB. (2025c). *Hakkımızda*. Türkiye Değerleme Uzmanları Birliği. <https://tdub.org.tr/sayfa/hakkimizda?lang=tr#>

TDUB. (2025d). *Türkiye Değerleme Uzmanları Birliği*. <https://tdub.org.tr/>

TDUB. (2025e). *Türkiye Değerleme Uzmanları Birliği*. https://tdub.org.tr/komite/degerlendirme-komitesi?lang=tr&utm_source=chatgpt.com

TDUB. (2025f). *Türkiye Değerleme Uzmanları Birliği*. Komiteler. <https://tdub.org.tr/komite/degerlendirme-komitesi?lang=tr>

TDUB. (2025g). *Türkiye Değerleme Uzmanları Birliği Faaliyetleri*. <https://tdub.org.tr/duyuru/turkiye-degerleme-uzmanlari-birligi-faaliyetleri-hakkinda-bilgilendirme---06-07-2019>

TEGOVA. (2025a). *European Valuation Standards (EVS)*. TEGOVA.

TEGOVA. (2025b). *The European Group of Valuers' Associations*. <https://tegova.org>
Teoh, E. Z., Yau, W.-C., Ong, T. S., & Connie, T. (2023). Explainable housing price prediction with determinant analysis. *International Journal of Housing Markets and Analysis*, 16(5), 1021-1045. <https://doi.org/10.1108/IJHMA-02-2022-0025>

The Beginning of GIS: The History of Geographic Information Systems. (2022, Şubat 28). MGISS. <https://gistest1.rajasthan.gov.in/Home/EducationalGIS>

TKGM. (2011). *Parametrelerin Belirlenmesi ve Standart Oluşturma Komisyonu Raporu* (s. 100). TKGM. <https://www.tkgm.gov.tr/tasinmazd-db/raporlar>

TKGM. (2012). *Finlandiya-Estonya Görev Raporu* (s. 59). Tapu ve Kadastro Genel Müdürlüğü.

TKGM. (2014). *Pilot Tamamlanma Raporu* (s. 199). TKGM. <https://www.tkgm.gov.tr/tasinmazd-db/raporlar>

TKGM. (2015). *Ticari Taşınmazlar Pilot Uygulama Raporu* (s. 37). TKGM. <https://www.tkgm.gov.tr/tasinmazd-db/raporlar>

TKGM. (2016). *Draft Property Valuation Policy Report*. 30.

TKGM. (2017). *Yasal Altyapı Oluşturma Komisyonu* (s. 105). TKGM. <https://www.tkgm.gov.tr/tasinmazd-db/raporlar>

TKGM. (2022, Aralık 29). *Amasya İli Merkez İlçesi Toplu Değerleme Pilot Çalışması*. <https://www.tkgm.gov.tr/tasinmazd-db/amasya-ili-merkez-ilcesi-toplu-degerleme-pilot-calismasi>

TKGM. (2024, Şubat 6). *Ankara İli Gölbaşı İlçesi Toplu Değerleme Pilot Projesi*. <https://www.tkgm.gov.tr/tasinmazd-db/ankara-ili-golbasi-ilcesi-toplu-degerleme-pilot-projesi>

TKGM. (2025a). *Mekânsal Gayrimenkul Sistemi*. <https://www.tkgm.gov.tr/projeler/mekansal-gayrimenkul-sistemi-megsis>

TKGM. (2025b). *Tapu ve Kadastro Genel Müdürlüğü*. <https://www.tkgm.gov.tr/>
Torres-Pruñonosa, J., García-Estévez, P., & Prado-Román, C. (2021). Artificial Neural Network, Quantile and Semi-Log Regression Modelling of Mass Appraisal in Housing. *Mathematics*, 9(7), 783. <https://doi.org/10.3390/math9070783>

Tuvimer. (2025). *Türkiye'nin Gayrimenkul Bilgi Bankası ve Risk Analizi*. <https://tapusor.com>

Türk Medeni Kanunu, 4721 Türk Medeni Kanunu 206 (2001).
<https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=4721&MevzuatTur=1&MevzuatTertip=5>

Ubitquity. (2025). *Ubitquity*. <https://ubitquity.io/>

Ullah, F., Sepasgozar, S. M. E., & Wang, C. (2018). A Systematic Review of Smart Real Estate Technology: Drivers of, and Barriers to, the Use of Digital Disruptive Technologies and Online Platforms. *Sustainability*, 10(9), 3142. <https://doi.org/10.3390/su10093142>

UrbanStat. (2025). *UrbanStat*. Property Underwriting on Steroids. <https://www.urbanstat.com/>

Van Der Waa, J., Nieuwburg, E., Cremers, A., & Neerincx, M. (2021). Evaluating XAI: A comparison of rule-based and example-based explanations. *Artificial Intelligence*, 291, 103404. <https://doi.org/10.1016/j.artint.2020.103404>

Vargason, D. (2019). *Data Mining Techniques for Predicting Real Estate Trends*.
 Vergi Usul Kanunu, 213 Vergi Usul Kanunu 200 (1961).
<https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=213&MevzuatTur=1&MevzuatTertip=4>

View. (2025). *View*. <https://view.com/>

Visartech. (2025). *Technology Partner Worldwide*. Visartech. <https://www.visartech.com/>

Wang, D., & Li, V. J. (2019). Mass Appraisal Models of Real Estate in the 21st Century: A Systematic Literature Review. *Sustainability*, 11(24), 7006. <https://doi.org/10.3390/su11247006>

Wang, T., Wang, Y., & Liu, M. (2021). *A Price Prediction Method Based on CatBoost*. International Conference on Culture-oriented Science & Technology.

Xu, X., & Zhang, Y. (2021). House price forecasting with neural networks. *Intelligent Systems with Applications*, 12, 200052. <https://doi.org/10.1016/j.iswa.2021.200052>

Yagmur, A. (2025). *Real Estate Valuation Decision-Making System Using Machine Learning and Geospatial Data*.

Yalpir, S., Sisman, S., Akar, A. U., & Unel, F. B. (2021). Feature selection applications and model validation for mass real estate valuation systems. *Land Use Policy*, 108, 105539. <https://doi.org/10.1016/j.landusepol.2021.105539>

Yang, H., Qiu, R., & Chen, W. (Ed.). (2020). *Smart Service Systems, Operations Management, and Analytics: Proceedings of the 2019 INFORMS International Conference on Service Science*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-30967-1>

Yang, J. (2024a). Comparative Analysis of the Impact of Advanced Information Technologies on the International Real Estate Market. *Transactions on Economics, Business and Management Research*, 7, 102-108. <https://doi.org/10.62051/cx32zy09>

Yang, J. (2024b). Comparative Analysis of the Impact of Advanced Information Technologies on the International Real Estate Market. *Transactions on Economics, Business and Management Research*, 7, 102-108. <https://doi.org/10.62051/cx32zy09>

YapıRadar. (2025). *İnşaat Sektörünün Pusulası*. <https://www.yapiradar.com/>

Yardi. (2025). *Yardi*. <https://www.yardi.com/>

Ye, Z., Zhang, Y., Jiang, J., & Liu, T. (2022). Intelligent Community and Real Estate Management Based on Machine Learning. *Computational Intelligence and Neuroscience*, 2022, 1-10. <https://doi.org/10.1155/2022/7738811>

Yilmazer, S., & Kocaman, S. (2020). A mass appraisal assessment study using machine learning based on multiple regression and random forest. *Land Use Policy*, 99, 104889. <https://doi.org/10.1016/j.landusepol.2020.104889>

Yoshida, T., Murakami, D., & Seya, H. (2022). Spatial Prediction of Apartment Rent using Regression-Based and Machine Learning-Based Approaches with a Large Dataset. *The Journal of Real Estate Finance and Economics*, 69(1), 1-28. <https://doi.org/10.1007/s11146-022-09929-6>

Yönetimcell. (2025). *Kullanımı kolay, sade ve anlaşılır Site/Apartman yönetim programı*. <https://www.yonetimcell.com/>

Zaken, M. van A. (2016, Mayıs 16). *Valuation of immovable property*. Ministerie van Algemene Zaken. <https://www.government.nl/topics/valuation-of-immovable-property/how-can-i-check-the-woz-value-is-correct>

Zaki, J., Nayyar, A., Dalal, S., & Ali, Z. H. (2022). House price prediction using hedonic pricing model and machine learning techniques. *Concurrency and Computation: Practice and Experience*, 34(27), e7342. <https://doi.org/10.1002/cpe.7342>

Zhang, H., Li, Y., & Branco, P. (2024). Describe the house and I will tell you the price: House price prediction with textual description data. *Natural Language Engineering*, 30(4), 661-695. <https://doi.org/10.1017/s1351324923000360>

Zhao, Y., Chetty, G., & Tran, D. (2019). *Deep learning with XGBoost for Real Estate Appraisal*. Symposium Series on Computational Intelligence (SSCI), Xiamen, China.

Zhou, J., Zhang, H., Gu, Y., & Pantelous, A. A. (2018). Affordable levels of house prices using fuzzy linear regression analysis: The case of Shanghai. *Soft Computing*, 22(16), 5407-5418. <https://doi.org/10.1007/s00500-018-3090-4>

Zillow. (2025a). *What is a Zestimate? Zillow's Zestimate Accuracy*. Zillow.
<https://www.zillow.com/z/zestimate/>

Zillow. (2025b). *Zillow: Real Estate, Apartments, Mortgages & Home Values*. Zillow.
<https://www.zillow.com/>

Zingat. (2025). *Emlak. Bilgi. Güven. Çok Bilgili Emlak Sitesi*. ZİNGAT.
<https://www.zingat.com/>

- 1.0

[illegible]

EK-2 UYGULAMADA KULLANILAN PYTHON KODLARI

```
# Veriyi okutma
df = pd.read_csv("housing.csv", encoding="latin1", low_memory=False,
sep=";")

# Veri Temizleme ve Preprocessing Aşamaları sonrasında bağımlı ve bağımsız
değişkenlerin belirlenmesi (dependent and independent feature)
X = df.drop('AdjustedPrice', axis = 1)
y = df['AdjustedPrice']

# Eğitim ve test verilerinin ayrılması (test - train split)
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.20,
random_state = 42)

# Regresyon modellerinin tanımlanması ve eğitilmesi (models fitting)
models = {
    "Random Forest Regressor" : RandomForestRegressor(),
    "Extra Trees Regressor" : ExtraTreesRegressor(),
    "Bagging Regressor" : BaggingRegressor(),
    "Gradient Boost Regressor" : GradientBoostingRegressor(),
    "Adaboost Regressor" : AdaBoostRegressor(),
    "Catboost Regressor" : CatBoostRegressor(),
    "XGBoost Regressor" : XGBRegressor(),
    "LGBM Regressor" : LGBMRegressor()
}

for i in range(len(list(models))):
    model = list(models.values())[i]
    model.fit(X_train, y_train)

# Eğitim sonrası tahminlerin gerçekleştirilmesi (prediction)
y_train_pred = model.predict(X_train)
y_test_pred = model.predict(X_test)

# Model metriklerinin yazdırılması
model_train_mae, model_train_mse, model_train_rmse, model_train_r2 =
evaluate_model(y_train, y_train_pred)
```

```

        model_test_mae, model_test_mse, model_test_rmse, model_test_r2 =
        evaluate_model(y_test, y_test_pred)

```

```

        print(list(models.keys())[i])
        print("Model performance for Training Set")
        print("Root Mean Squared Error: ", model_train_rmse)
        print("Mean Squared Error: ", model_train_mse)
        print("Mean Absolute Error: ", model_train_mae)
        print("R2 Score: ", model_train_r2)

```

```

        print("-----")

```

```

        print("Model performance for Test Set")
        print("Root Mean Squared Error: ", model_test_rmse)
        print("Mean Squared Error: ", model_test_mse)
        print("Mean Absolute Error: ", model_test_mae)
        print("R2 Score: ", model_test_r2)

```

```

        print("-----")
        print("\n")

```

```

        # PFI hesapla ve listeye ekle
        pfi_df = calculate_pfi(model, X_test, y_test, model_name)
        pfi_results.append(pfi_df)

```

```

        # PFI plotları için

```

```

        def plot_pfi(pfi_df, model_name):

```

```

            top = pfi_df.head(20)

```

```

            plt.figure(figsize=(10, 6))

```

```

            sns.barplot(data=top, x="Importance", y="Feature", color="royalblue")

```

```

            plt.errorbar(top["Importance"], range(len(top)), xerr=top["StdDev"],

```

```

                        fmt='none', ecolor='gray', capsize=3)

```

```

plt.title(f"{model_name} - Permutation Feature Importance")
plt.xlabel("Önem Skoru")
plt.ylabel("Özellik")
plt.tight_layout()

# 0.01'den küçük öneme sahip özellikleri filtrele
low_importance_features = pfi_df[pfi_df['Importance'] < 0.01]

# Sonuçları göster
print("PFI < 0.01 olan özellikler:")
print(low_importance_features.sort_values(by='Importance'))

# Liste şeklinde sadece kolon isimlerini al:
low_importance_columns = low_importance_features['Feature'].tolist()
print("\nSadece kolon isimleri:")
print(low_importance_columns)

# Belirli sütunları df'den çıkar
df_cleaned = df.drop(columns=features_to_drop)

# 5.Bölüm ve 5.9 nolu başlıkta her model için belirtilen parametrelere
GridSearchCV uygulanması
model_rf = RandomForestRegressor(random_state=42)
model_et = ExtraTreesRegressor(random_state=42)
model_bagging = BaggingRegressor(estimator=tree, random_state=42)
model_gbr = GradientBoostingRegressor(random_state=42)
model_ada = AdaBoostRegressor(random_state=42)
model_cat = CatBoostRegressor(random_state=42)
model_xgb = XGBRegressor(random_state=42)
model_lgbm = LGBMRegressor(random_state=42)

```

```
grid_search_rf = GridSearchCV( estimator=rfr, param_grid=param_grid,
cv=5, n_jobs=-1, verbose=1, scoring='r2' )
```

```
start_time = time.time() grid_search_rf.fit(X_train, y_train) end = time.time()
```

```
print("RandomForest GridSearchCV süresi: {:.2f} saniye".format(end - start))
print("En iyi parametreler:", grid_search_rf.best_params_) print("En iyi R2 skoru:",
grid_search_rf.best_score_)
```

```
grid_search_et = GridSearchCV( estimator=etr, param_grid=param_grid,
cv=5, n_jobs=-1, verbose=1, scoring='r2' )
```

```
start_time = time.time() grid_search_et.fit(X_train, y_train) end = time.time()
```

```
print("ExtraTrees GridSearchCV süresi: {:.2f} saniye".format(end - start))
print("En iyi parametreler:", grid_search_et.best_params_) print("En iyi R2 skoru:",
grid_search_et.best_score_)
```

```
grid_search_bag = GridSearchCV( estimator=bag,
param_grid=bag_params, cv=5, n_jobs=-1, verbose=1, scoring='r2' )
```

```
start_time = time.time() grid_search_bag.fit(X_train, y_train) end_time =
time.time()
```

```
print("BaggingRegressor GridSearchCV süresi: {:.2f}
saniye".format(end_time - start_time)) print("En iyi parametreler:",
grid_search_bag.best_params_) print("En iyi R2 skoru:",
grid_search_bag.best_score_)
```

```
grid_search_gbr = GridSearchCV( estimator=gbr, param_grid=gbr_params,
cv=5, n_jobs=-1, verbose=1, scoring="r2" )
```

```
start_time = time.time() grid_search_gbr.fit(X_train, y_train) end_time =
time.time()
```

```
print("GradientBoosting GridSearchCV süresi: {:.2f} saniye".format(end_time -
start_time)) print("En iyi parametreler:",
grid_search_gbr.best_params_) print("En iyi R2 skoru:",
grid_search_gbr.best_score_)
```

```
grid_search_ada = GridSearchCV(estimator=ada,
param_grid=ada_params, cv=5, n_jobs=-1, verbose=1, scoring='r2')
```

```
start_time = time.time() grid_search_ada.fit(X_train, y_train) end_time =
time.time()
```

```
print("AdaBoost GridSearchCV süresi: {:.2f} saniye".format(end_time -
start_time)) print("En iyi parametreler:", grid_search_ada.best_params_) print("En
iyi R2 skoru:", grid_search_ada.best_score_)
```

```
grid_search_xgb = GridSearchCV(estimator=xgb_model,
param_grid=xgb_params, cv=5, n_jobs=-1, verbose=1, scoring='r2')
```

```
start_time = time.time() grid_search_xgb.fit(X_train, y_train) end_time =
time.time()
```

```
print("XGBoost GridSearchCV süresi: {:.2f} saniye".format(end_time -
start_time)) print("En iyi parametreler:", grid_search_xgb.best_params_) print("En
iyi R2 skoru:", grid_search_xgb.best_score_)
```

```
grid_search_lgbm = GridSearchCV(estimator=lgbm_model,
param_grid=lgb_params, cv=5, n_jobs=-1, verbose=1, scoring='r2')
```

```
start_time = time.time() grid_search_lgbm.fit(X_train, y_train) end_time =
time.time()
```

```
print("LGBMRegressor GridSearchCV süresi: {:.2f} saniye".format(end_time
- start_time)) print("En iyi parametreler:", grid_search_lgbm.best_params_)
print("En iyi R2 skoru:", grid_search_lgbm.best_score_)
```

İyileştirilmiş model eğitimi

```
best_params = {
    "Random Forest Regressor": {
        'bootstrap': True,
        'max_depth': 20,
        'max_features': 'sqrt',
        'min_samples_leaf': 1,
        'min_samples_split': 2,
        'n_estimators': 500
    },
    "Extra Trees Regressor": {
        'bootstrap': True,
        'max_depth': 20,
        'max_features': 'sqrt',
        'min_samples_leaf': 1,
        'min_samples_split': 2,
        'n_estimators': 500
    },
    "Bagging Regressor": {
        'bootstrap': True,
        'estimator__max_depth': 7,
        'max_features': 0.8,
        'max_samples': 0.6,
        'n_estimators': 500
    },
}
```

```

"Gradient Boosting Regressor": {
    'learning_rate': 0.1,
    'max_depth': 7,
    'max_features': 'sqrt',
    'min_samples_leaf': 3,
    'min_samples_split': 2,
    'n_estimators': 500,
    'subsample': 1.0
},
"AdaBoost Regressor": {
    'estimator': DecisionTreeRegressor(max_depth=1),
    'estimator__max_depth': 3,
    'learning_rate': 0.01,
    'loss': 'linear',
    'n_estimators': 500
},
"CatBoost Regressor": {
    'bagging_temperature': 0.2,
    'border_count': 32,
    'depth': 10,
    'iterations': 500,
    'l2_leaf_reg': 1,
    'learning_rate': 0.1
},
"XGBoost Regressor": {
    'colsample_bytree': 0.8,
    'gamma': 0,
    'learning_rate': 0.05,
    'max_depth': 9,
    'min_child_weight': 1,
    'n_estimators': 500,
    'reg_alpha': 0.1,

```



```

        'reg_lambda': 1,
        'subsample': 0.8
    },
    "LGBM Regressor": {
        'colsample_bytree': 0.6,
        'learning_rate': 0.1,
        'max_depth': -1,
        'min_child_samples': 5,
        'n_estimators': 500,
        'num_leaves': 100,
        'reg_alpha': 0,
        'reg_lambda': 0.1,
        'subsample': 0.6
    }
}

```

```

from sklearn.ensemble import RandomForestRegressor, AdaBoostRegressor,
GradientBoostingRegressor, ExtraTreesRegressor, BaggingRegressor
from sklearn.tree import DecisionTreeRegressor
from xgboost import XGBRegressor
from lightgbm import LGBMRegressor
from catboost import CatBoostRegressor
from sklearn.metrics import r2_score, mean_absolute_error,
mean_squared_error
import numpy as np

def evaluate_model(true, predicted):
    mae = mean_absolute_error(true, predicted)
    mse = mean_squared_error(true, predicted)
    rmse = np.sqrt(mse)
    r2 = r2_score(true, predicted)
    return mae, mse, rmse, r2

```

```

# Model tanımları
models = {
    "Random Forest Regressor":
RandomForestRegressor(**best_params.get("Random Forest Regressor", {})),
    "Extra Trees Regressor": ExtraTreesRegressor(**best_params.get("Extra
Trees Regressor", {})),
    "Bagging Regressor": BaggingRegressor(estimator=bagging_estimator,
**bagging_model_params),
    "Gradient Boost Regressor":
GradientBoostingRegressor(**best_params.get("Gradient Boost Regressor", {})),
    "Adaboost Regressor": AdaBoostRegressor(**best_params.get("Adaboost
Regressor", {})),
    "Catboost Regressor": CatBoostRegressor(**best_params.get("CatBoost
Regressor", {}), verbose=0),
    "XGBoost Regressor": XGBRegressor(**best_params.get("XGBoost
Regressor", {})),
    "LGBM Regressor": LGBMRegressor(**best_params.get("LGBM
Regressor", {}))
}

# Tahminler
y_train_pred = model.predict(X_train)
y_test_pred = model.predict(X_test)

# Performans metrikleri
train_mae, train_mse, train_rmse, train_r2 = evaluate_model(y_train,
y_train_pred)
test_mae, test_mse, test_rmse, test_r2 = evaluate_model(y_test,
y_test_pred)

# Sonuç yazdırma

```

```

print("Training Set")
print(f"RMSE: {train_rmse:.2f}, MAE: {train_mae:.2f}, R²: {train_r2:.4f}")

print("Test Set")
print(f"RMSE: {test_rmse:.2f}, MAE: {test_mae:.2f}, R²: {test_r2:.4f}")
print("-" * 60)

# SHAP analizi ile model açıklamaları
# SHAP summary plot
# pip install shap
# Eğitilmiş LightGBM model: model_lgbm
# Eğitim verisi: X_train (DataFrame), Test verin: X_test (tercihen)
# Özellik adları X_train.columns

# SHAP değerlerini hesapla (TreeExplainer, LightGBM için hızlı)
explainer = shap.TreeExplainer(model_lgbm)
X_eval = X_test # veya X_train
shap_values = explainer.shap_values(X_eval, check_additivity=False)

# "Beeswarm" summary plot (önem + etki yönü)
shap.summary_plot(
    shap_values,
    X_eval,
    feature_names=X_eval.columns,
    show=True,
    plot_type="dot" # varsayılan; renk = feature değeri (mavi düşük, kırmızı
yüksek)
)

# Sadece önem sırası (ortalama mutlak SHAP) için bar grafiği
shap.summary_plot(
    shap_values,

```

```

        X_eval,
        feature_names=X_eval.columns,
        show=True,
        plot_type="bar"
    )

# Örnek No: 758 için Force plot
import shap
import matplotlib.pyplot as plt

X_eval = X_test.copy()
explainer = shap.TreeExplainer(model_lgbm)
shap_values = explainer.shap_values(X_eval, check_additivity=False)

i = 758 # açıklamak istenilen kayıt

# --- HTML (etkileşimli) ---
shap.initjs()
fp = shap.force_plot(explainer.expected_value, shap_values[i, :],
X_eval.iloc[i, :], matplotlib=False)
shap.save_html("force_plot_sample.html", fp)

# --- PNG (statik) ---
plt.close('all') # önce tüm figürleri kapat
shap.force_plot(
    explainer.expected_value,
    shap_values[i, :],
    X_eval.iloc[i, :],
    matplotlib=True,
    show=False
)
fig = plt.gcf() # SHAP'in oluşturduğu figür

```

```

fig.set_size_inches(28, 4)      # boyut
fig.savefig("force_plot_sample_758.png", dpi=300, bbox_inches="tight",
facecolor="w")
plt.show()

```

Örnek No: 758 için Waterfall plot

```

exp = explainer(X_eval.iloc[[i]])
plt.close('all')
plt.figure(figsize=(20, 12))

```

```

ax = shap.plots.waterfall(exp[0], show=False)

```

```

plt.savefig("shap_waterfall_758.png", dpi=300, bbox_inches="tight")
plt.show()

```

Örnek No: 3095 için Force plot

```

import shap
import matplotlib.pyplot as plt

```

```

X_eval = X_test.copy()
explainer = shap.TreeExplainer(model_lgbm)
shap_values = explainer.shap_values(X_eval, check_additivity=False)

```

i = 3095 # açıklamak istediğin kayıt

--- HTML (etkileşimli) ---

```

shap.initjs()
fp = shap.force_plot(explainer.expected_value, shap_values[i, :],
X_eval.iloc[i, :], matplotlib=False)
shap.save_html("force_plot_sample.html", fp)

```

```

# --- PNG (statik) ---
plt.close('all') # önce tüm figürleri kapat
shap.force_plot(
    explainer.expected_value,
    shap_values[i, :],
    X_eval.iloc[i, :],
    matplotlib=True,
    show=False
)
fig = plt.gcf() # SHAP'in oluşturduğu figür
fig.set_size_inches(28, 4) # boyut
fig.savefig("force_plot_sample_3095.png", dpi=300, bbox_inches="tight",
facecolor="w")
plt.show()

```

Örnek No: 3095 için Waterfall plot

```

exp = explainer(X_eval.iloc[[i]])
plt.close('all')
plt.figure(figsize=(20, 12))

```

```

ax = shap.plots.waterfall(exp[0], show=False)

```

```

plt.savefig("shap_waterfall_3095.png", dpi=300, bbox_inches="tight")
plt.show()

```

Örnek No: 5381 için Force plot

```

import shap
import matplotlib.pyplot as plt

```

```

X_eval = X_test.copy()
explainer = shap.TreeExplainer(model_lgbm)
shap_values = explainer.shap_values(X_eval, check_additivity=False)

i = 5381 # açıklamak istediğin kayıt

# --- HTML (etkileşimli) ---
shap.initjs()
fp = shap.force_plot(explainer.expected_value, shap_values[i, :],
X_eval.iloc[i, :], matplotlib=False)
shap.save_html("force_plot_sample.html", fp)

# --- PNG (statik) ---
plt.close('all') # önce tüm figürleri kapat
shap.force_plot(
    explainer.expected_value,
    shap_values[i, :],
    X_eval.iloc[i, :],
    matplotlib=True,
    show=False
)
fig = plt.gcf() # SHAP'in oluşturduğu figür
fig.set_size_inches(28, 4) # boyut
fig.savefig("force_plot_sample_5381.png", dpi=300, bbox_inches="tight",
facecolor="w")
plt.show()

# Örnek No: 5381 için Waterfall plot
exp = explainer(X_eval.iloc[[i]])
plt.close('all')
plt.figure(figsize=(20, 12))

```

```
ax = shap.plots.waterfall(exp[0], show=False)
```

```
plt.savefig("shap_waterfall_5381.png", dpi=300, bbox_inches="tight")
```

```
plt.show()
```


ETİK KURALLARA UYGUNLUK BEYANI

Uzmanlık tezi olarak sunduğum bu çalışmayı, bilimsel ahlak ve geleneklere aykırı düşecek bir yol ve yardıma başvurmaksızın yazdığımı, yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, bunlardan her seferinde değinme yaparak yararlandığımı ve Coğrafi Bilgi Sistemi Uzmanlık Yönetmeliğine uygun olarak hazırladığımı belirtir, bunu onurumla doğrularım.

Çevre, Şehircilik ve İklim Değişikliği Bakanlığı tarafından belli bir zamana bağlı olmaksızın, tezimle ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacağımı bildiririm.

25.08.2025

Emel PERÇEM

ÖZGEÇMİŞ

1992 yılında Ankara'nın Çankaya ilçesinde doğdu. İlk ve ortaöğrenimini Erciş Bayazıt İlköğretim Okulu'nda, lise öğrenimini ise Tuşba Vali Haydar Bey Anadolu Lisesi'nde Devlet Parasız Yatılı olarak tamamladı. 2014 yılında Gümüşhane Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Harita Mühendisliği Bölümü'nden mezun oldu.

2024 yılında Ankara Üniversitesi Uygulamalı Bilimler Fakültesi Gayrimenkul Geliştirme ve Yönetimi Anabilim Dalı'nda yüksek lisans eğitimine başlamış olup çalışmalarına devam etmektedir.

Özel sektörde, Türkiye'nin farklı bölgelerinde yürütülen kamulaştırma, hâlihazır harita yapımı, CBS tabanlı otomasyon sistemlerinin geliştirilmesi, tarımsal alanların sulanması ve regülatör yapımına ilişkin projelerde Harita Mühendisi olarak görev yaptı.

Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Coğrafi Bilgi Sistemleri Genel Müdürlüğü tarafından açılan Coğrafi Bilgi Sistemi Uzman Yardımcılığı yarışma sınavını kazanarak Ağustos 2022'de göreve başladı. Hâlen aynı kurumda Coğrafi Bilgi Sistemi Uzman Yardımcısı olarak görevini sürdürmektedir.

