T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OTOMATİK GAYRİMENKUL PORTFÖYÜ OPTİMİZASYON SİSTEMİ TASARIMI

Fatih TURAN

YÜKSEK LİSANS TEZİ
Elektronik ve Haberleşme Mühendisliği Anabilim Dalı
Elektronik Programı

Danışman
Doç. Dr. Bülent BOLAT

Şubat, 2026

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OTOMATİK GAYRİMENKUL PORTFÖYÜ OPTİMİZASYON SİSTEMİ TASARIMI

Fatih TURAN tarafından hazırlanan tez çalışması 03.02.2026 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Elektronik Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Bülent BOLAT
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Bülent BOLAT, Danışman
Yıldız Teknik Üniversitesi _____

Dr. Öğr. Üyesi Murat TAŞKIRAN, Üye
Yıldız Teknik Üniversitesi _____

Dr. Öğr. Üyesi Surhan BOZKURT, Üye
Doğuş Üniversitesi _____

Danışmanım Doç. Dr. Bülent BOLAT sorumluluğunda tarafımca hazırlanan Otomatik Gayrimenkul Portföyü Optimizasyon Sistemi Tasarımı başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Fatih TURAN

İmza

Aileme

Eşime ve kızıma

TEŞEKKÜR

Yüksek lisans tezimde akademik bilgisi ve tecrübesiyle bana yol gösterip yanımda olduğu ve ne zaman ihtiyacım olsa bana desteğini sunduğu için değerli danışman hocam Doç. Dr. Bülent BOLAT'a,

Eğitim konusunda beni her zaman teşvik eden, arkamda olduklarını hissettiren ve desteklerini benden esirgemeyen sevgili annem Ayla TURAN ve babam Mustafa TURAN'a,

Bana alan, imkan ve vakit sağlayan, ne zaman ihtiyacım olsa beni sıkılmadan dinleyen sevgili eşim Hande TURAN'a,

Son olarak da on yıl sonra bile olsa, pes etmeden sonuna kadar gitme kararlılığına sahip olan kendime,

Teşekkür Ederim.

Fatih TURAN

İÇİNDEKİLER

SİMGE LİSTESİ vii

KISALTMA LİSTESİ ix

ŞEKİL LİSTESİ x

TABLO LİSTESİ xi

ÖZET xii

ABSTRACT xiv

1 GİRİŞ 1

1.1 Literatür Özeti 1
1.2 Tezin Önemi, Kapsamı ve İzlenen Yol 2
1.3 Araştırma Soruları ve Sınanan Öngörüler 4
1.4 Tezin Organizasyonu 4

2 Yöntem 6

2.1 Problemin Çerçevesi ve Hedef 6
2.2 Veri, İş Akışı ve Sızıntıyı Önleme 7
2.3 Özellik Tasarımı 8
2.4 Model ve Eğitim Protokolü 10
2.5 Değerlendirme ve Doğrulama Tasarımı 11
2.6 Yeniden Üretilebilirlik ve Uygulama 14

3 Deneyler ve Sonuçlar 15

3.1 Deney Kurulumu ve Değerlendirme Çerçevesi 15
3.2 Uçtan Uca Modelleme Akışı 16
3.3 Test Sonuçlarının Özeti (DIFF Odaklı) 17
3.4 Hedef Varyantları: ABS ve RATIO 19
3.5 Açıklanabilirlik 20
3.6 Öngörüler ve Hata Görselleştirmesi 22
3.7 Vaka Örnekleri 24

4 Tartışma **27**
4.1 Bulguların Özeti ve Yorumu 27
4.2 Hedef Tanımları: DIFF, RATIO, ABS 29
4.3 Literatürle Konumlandırma 29
4.4 Güçlü ve Zayıf Yönler 30
4.5 Uygulama Çıkarımları ve Politika 31

5 SONUÇ **32**
5.1 Bulgular ve Katkılar 32
5.2 Gelecek Çalışmalar 34

KAYNAKÇA **36**

A Ekler **39**
A.1 DIFF ve DIFF+band Karşılaştırmaları (Dükkan/Arsa) 39
A.2 ABS/RATIO Karşılaştırmaları (Dükkan) 39
A.3 ABS/RATIO Karşılaştırmaları (Arsa) 40

TEZDEN ÜRETİLMİŞ YAYINLAR **41**

SİMGE LİSTESİ

$\mathrm{mean}(\cdot)$	Aritmetik ortalama işleci
$\mathrm{wmean}(\cdot)$	Ağırlıklı ortalama oran
R^2	Determinasyon katsayısı
$\log$	Doğal logaritma
y_i	Gerçek değer (i gözlemi için nihai satış bedeli)
$\bar{y}$	Gerçek değerlerin aritmetik ortalaması
bid	Gerçekleşen ihale bedeli (nihai satış bedeli)
$\mathbb{1}\{\cdot\}$	Gösterge (indicator) fonksiyonu
ABS	Hedef dönüşümü: $\log(1+\mathrm{bid})$
DIFF	Hedef dönüşümü: $\log(1+\mathrm{bid}) - \log(1+\mathrm{est_val})$
RATIO	Hedef dönüşümü: $\log\big(1+\mathrm{bid}/\mathrm{est_val}\big)$
d_{ij}	İlan i ile j arasındaki mesafe (metre)
t_i	İlan i için zaman damgası
$\mathcal{N}_i$	Komşu kümesi (ST-lag)
t_j	Komşu ilan j için zaman damgası
ℓ_2	Karesel hata kaybı (RMSE'nin temel aldığı kayıp)
I	Moran's I (artıkların mekânsal otokorelasyonu)
$\mathrm{median}(\cdot)$	Medyan işleci
$\mathrm{est_val}$	Muhammen bedel (ihale öncesi tahmini değer)
n	Örnek sayısı
ϕ_k	Özellik k'nın SHAP katkı değeri
ϵ	Sıfırdan kaçınmak için kullanılan küçük pozitif sabit
$\widehat{\mathrm{bid}}$	Tahmin edilen nihai satış bedeli (TL)

$\hat{y}_i$	Tahmin edilen değer (i gözlemi için)
r_i	Değerleme oranı, $r_i = \hat{y}_i / y_i$
r	ST-lag yarıçapı (metre)
$t_{\min}$	ST-lag için asgari zaman farkı
$t_{\max}$	ST-lag için azami zaman farkı
η	Öğrenme oranı (learning rate)
τ	Göreli hata eşiği (outlier tanımı için)

KISALTMA LİSTESİ

AVM	Automated Valuation Model (Otomatik Değerleme Modeli)
CNN	Convolutional Neural Network (Evrişimsel Sinir Ağı)
COD	Coefficient of Dispersion (Dağılım Katsayısı)
CPI	Consumer Price Index (TÜFE)
CSV	Comma-Separated Values (tahmin/çıktı dosya biçimi)
ES	Early Stopping (erken durdurma)
GWR	Geographically Weighted Regression (Coğrafi Ağırlıklı Regresyon)
HPI/KFE	House Price Index / Konut Fiyat Endeksi
IDW	Inverse Distance Weighting (ters mesafe ağırlığı)
JSON	JavaScript Object Notation (özellik listesi yan dosya biçimi)
LODO	Leave-One-District-Out (ilçe bırakmalı doğrulama)
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	Mean Absolute Percentage Error (Ortalama Yüzde Hata)
ML	Machine Learning (Makine Öğrenmesi)
MLOps	Machine Learning Operations (Makine Öğrenmesi Operasyonları)
POI	Points of Interest (İlgi Noktaları)
PRD	Price-Related Differential (Fiyata Duyarlı Fark)
R^2	Coefficient of Determination (Determinasyon Katsayısı)
RMSE	Root Mean Square Error (Kök Ortalama Kare Hata)
SHAP	SHapley Additive exPlanations (özellik katkı yöntemi)
ST-lag	Spatio-Temporal lag (mekânsal-zamansal komşuluk sinyali)
UYAP	Ulusal Yargı Ağı Bilişim Sistemi (e-Satış)
WGS84	World Geodetic System 1984 (koordinat referans sistemi)

ŞEKİL LİSTESİ

Şekil 3.1 Uçtan uca hat: veri, öznitelikler, CatBoost eğitimi, TL uzayına geri dönüşüm ve değerlendirme 17
Şekil 3.2 Konut—SHAP ilk 10 (DIFF+band). Küresel önem sıralaması $\mathbb{E}[|\phi_k|]$ ölçütüne göre verilmiştir 21
Şekil 3.3 Konut—SHAP bağımlılık grafiği: `estimated_value`. Muhammen değer arttıkça katkının daha negatif yönde değiştiği görülmektedir 21
Şekil 3.4 Konut—SHAP bağımlılık grafiği: `stlag_log_bid_idw`. Komşuluk sinyali arttıkça katkı pozitiftir; yüksek seviyelerde ise doygunluk davranışı gözlenmektedir 22
Şekil 3.5 Konut—DIFF ve DIFF+band karşılaştırması. 45° doğrusu kalibrasyon için referans çizgisi olarak verilmiştir 23
Şekil 3.6 Konut—RATIO ve RATIO+band karşılaştırması 24
Şekil 3.7 Konut—ABS ve ABS+band karşılaştırması 24
Şekil A.1 DIFF türü için Dükkan/Arsa karşılaştırma grafikleri (test kesiti). . 39
Şekil A.2 Dükkan türü için ABS/RATIO karşılaştırma grafikleri (test kesiti). 40
Şekil A.3 Arsa türü için ABS/RATIO karşılaştırma grafikleri (test kesiti). . . 40

TABLO LİSTESİ

Tablo 2.1 Modelleme sürecinde kullanılan öznitelik grupları. Nihai öznitelik adları ve sıralaması, eğitim sırasında kaydedilen `.features.json` yan dosyası üzerinden kilitlenmektedir. . . 9
Tablo 3.1 Taşınmaz türü ve veri dilimlerine göre gözlem sayıları 15
Tablo 3.2 Konut test performansı (DIFF hedefi) 18
Tablo 3.3 Dükkan test performansı (DIFF hedefi) 18
Tablo 3.4 Arsa test performansı (DIFF hedefi) 18
Tablo 3.5 Konut — Esenyurt kırılımı ($n = 112$, tam pay) 18
Tablo 3.6 Konut—hedef varyantları (test, tam pay) 19
Tablo 3.7 Dükkan—hedef varyantları (test, tam pay) 19
Tablo 3.8 Arsa—hedef varyantları (test, tam pay) 19
Tablo 3.9 Seçilmiş tekil ihale bilgileri 25
Tablo 3.10 Seçilmiş tekil ihaleler için DIFF ve DIFF+band karşılaştırması. Tahminler M TL cinsindendir 25
Tablo 3.11 Seçilmiş dosyalar için hedef–band varyantlarının yüzde hata (%) karşılaştırması (test). En düşük değer kalın gösterilmiştir 25

ÖZET

Otomatik Gayrimenkul Portföyü Optimizasyon Sistemi Tasarımı

Fatih TURAN

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi

Danışman: Doç. Dr. Bülent BOLAT

Bu tez, Türkiye'de Ulusal Yargı Ağı Bilişim Sistemi Elektronik Satış Platformu (UYAP e-Satış) kapsamında gerçekleştirilen yargı ihalelerinde *nihai satış bedelini* öngörmek amacıyla sızıntı-güvenli ve üretim ortamına uygun bir tablo-veri modelleme çerçevesi sunmaktadır. Hedef değişken, dönemsel ve ölçek kaynaklı fiyat değişimlerine dayanıklı olacak biçimde $\mathrm{DIFF} = \log(1+\mathrm{bid}) - \log(1+\mathrm{est_val})$ olarak tanımlanmıştır. Tüm öznitelikler, ihale kapanış tarihinden *önce* mevcut olan bilgilerden türetilmiş; makroekonomik reelleştirme (TÜFE/KFE) ile yalnızca geçmiş işlemlere dayalı mekânsal-zamansal gecikme sinyali (spatio-temporal lag, ST-lag) yöntemin omurgasını oluşturmuştur. Ana öğrenen olarak CatBoost kullanılmış; kategorik değişkenler sıralı hedef istatistiklerine dayalı kodlama ile işlenmiş ve simetrik (oblivious) karar ağaçları tercih edilmiştir. Doğrulama, zaman-sıralı veri bölünmesi ve ilçe-bırakmalı değerlendirme ile gerçekleştirilmiş; üretim tutarlılığı için öznitelik şeması `.features.json` dosyası aracılığıyla dondurulmuştur. Model performansı, MAE, MAPE, RMSE ve R^2 ölçütlerinin yanı sıra kitlesel değerlemeye özgü kalibrasyon göstergeleri olan COD ve PRD ile değerlendirilmiştir. 2025 test kesitinde Konut türü için CatBoost–DIFF modeli $R^2 \approx 0.70$, MAE $\approx$ 1.20 milyon TL ve MAPE $\approx$%25 üretmiş; fiyat bandı göstergesi küresel ölçekte nötr veya sınırlı bir katkı sağlamıştır. Dükkan türünde yüzde hata azalırken varyans artabilmekte; Arsa türünde ise fiyat bandı bilgisi RMSE ve R^2'yi belirgin biçimde iyileştirmektedir. Alternatif hedef tanımları da incelenmiş; RATIO ($\log(1 + \mathrm{bid}/\mathrm{est_val})$) performans olarak DIFF'e yakın bulunurken, ABS ($\log(1 + \mathrm{bid})$) kalibrasyon göstergeleri açısından daha zayıf sonuçlar üretmiştir.

Shapley Additive Explanations (SHAP) temelli açıklanabilirlik analizleri, model tahminlerinin ağırlıklı olarak metrekare başına muhammen değer, reelleştirilmiş parasal göstergeler, konumsal değişkenler, tapu alanı ve mekânsal-zamansal gecikme sinyaline dayandığını; Moran's I testleri ise artıkların istatistiksel olarak anlamlı bir mekânsal bağımlılık taşımadığını göstermektedir. Sonuç olarak bu çalışma, UYAP bağlamında sızıntı-güvenli mekânsal-zamansal öznitelik üretimi ve makroekonomik reelleştirme ile desteklenen CatBoost tabanlı bir otomatik değerleme modelini, tekrarlanabilir ve devreye alıma uygun bir doğrulama ve izleme çerçevesiyle birlikte sunmaktadır.

Anahtar Kelimeler: Yargı ihaleleri, otomatik değerleme modeli, CatBoost, DIFF hedefi, mekânsal-zamansal gecikme

ABSTRACT

Automated Real Estate Portfolio Optimization System Design

Fatih TURAN

Department of Electronics and Communication Engineering
Master of Science Thesis

Supervisor: Assoc.Prof. Dr. Bülent BOLAT

This thesis presents a leak-free and deployment-oriented tabular modeling framework for predicting the *final sale price* in judicial auctions on Turkey's *National Judiciary Informatics System Electronic Sales Platform (UYAP e-Sales)*. The target variable is defined as $\mathrm{DIFF} = \log(1 + \mathrm{bid}) - \log(1 + \mathrm{est_val})$, which is robust to time- and scale-related price shifts. All features are derived strictly from information available *prior* to auction closing; macroeconomic deflation using the Consumer Price Index and House Price Index (CPI/HPI; Turkish: TÜFE/KFE), together with a spatio-temporal neighborhood signal computed solely from past transactions (spatio-temporal lag, ST-lag), constitute the methodological backbone. The primary learner is CatBoost, which employs ordered target statistics for categorical variables and symmetric (oblivious) decision trees. Model validation follows time-ordered splits and leave-one-district-out evaluation; for deployment consistency, the feature schema is frozen via a `.features.json` sidecar. Performance is assessed using MAE, MAPE, RMSE, R^2, and mass-appraisal calibration metrics (COD and PRD). On the 2025 test set for Apartment properties, the CatBoost–DIFF model achieves $R^2 \approx 0.70$, MAE ≈ 1.20 million TL, and MAPE $\approx 25\%$, while the price-band indicator exhibits a neutral to limited global effect. For Shop properties, percentage errors decrease at the cost of increased variance; for Land properties, the band substantially improves RMSE and R^2. Alternative target definitions are also examined: RATIO ($\log(1 + \mathrm{bid}/\mathrm{est_val})$) performs close to DIFF, whereas ABS ($\log(1 + \mathrm{bid})$) shows weaker calibration. Feature attribution analyses based on Shapley Additive Explanations (SHAP) indicate that

predictions primarily rely on price per square meter, deflated value indicators, spatial coordinates, deed area, and the spatio-temporal lag signal. Moran's I tests reveal no statistically significant spatial autocorrelation in the residuals. Overall, the study delivers a reproducible and practically deployable CatBoost-based automated valuation model for judicial auctions, grounded in leak-free spatio-temporal feature construction, macroeconomic deflation, and a transparent validation and monitoring framework.

Keywords: Judicial auctions, automated valuation model, CatBoost, DIFF target, spatio-temporal lag

1
GİRİŞ

1.1 Literatür Özeti

Bu tez, otomatik değerleme modellerinin (Automated Valuation Models; AVM) yargı ihaleleri bağlamına uyarlanmasını ele almaktadır. AVM, çok sayıda geçmiş işlemden öğrenerek bir taşınmazın beklenen değerini tahminleyen veri odaklı yaklaşımların genel adıdır. Son on yılda, özellikle *gradyan artırmalı ağaç* tabanlı yöntemlerin, klasik doğrusal ve hedonik modellere kıyasla daha düşük hata ve daha yüksek genelleme başarımı sağladığı gösterilmiştir. Bu üstünlük, konum, yapı ve çevresel özellikler arasındaki karmaşık ve doğrusal olmayan etkileşimlerin ağaç tabanlı yapılarla daha etkin biçimde yakalanabilmesinden kaynaklanmaktadır [1–3].

Bu yöntemler arasında **CatBoost**, kategorik değişkenleri hedef sızıntısını azaltacak biçimde işleyen sıralı artırma yaklaşımı ve simetrik ağaç mimarisiyle ayrışmaktadır. Bu özellikler, özellikle il, ilçe, mahalle ve kullanım türü gibi yüksek kardinaliteli kategorik alanların yaygın olduğu gayrimenkul değerleme problemlerinde kararlı ve tekrarlanabilir sonuçlar üretmesini desteklemektedir [4–6]. Büyük ölçekli tablo verilerinde CatBoost'un hesaplama verimliliği ve kararlılığı da literatürde vurgulanan avantajlar arasındadır [7].

Yargı (cebri) satış literatürü, bu satışların serbest piyasa işlemlerine kıyasla çoğu zaman iskontolu gerçekleştiğini; iskonto düzeyinin başlangıç fiyatı, ihale yapısı, teminat oranı ve piyasa koşulları gibi kurumsal unsurlara duyarlı olduğunu göstermektedir [8–10]. Politika ve ihale kuralı değişimlerini doğal deney olarak ele alan çalışmalar, bu tür düzenlemelerin hem nihai satış fiyatını hem de satış süresini anlamlı biçimde etkileyebildiğini ortaya koymaktadır [11, 12]. Bununla birlikte, mevcut çalışmaların önemli bir bölümü serbest piyasa satışlarına odaklanmakta; yargı ihalelerine özgü veri yapısı ve kurumsal kısıtları dikkate alan, sızıntıyı sistematik biçimde kontrol eden uçtan uca tahmin çerçeveleri görece sınırlı kalmaktadır.

Konut fiyatlarının modellenmesinde uzun süre baskın yaklaşım, taşınmazın fiziksel, konumsal ve çevresel özelliklerini ayrıştırarak fiyatı açıklamayı amaçlayan *hedonik fiyatlama* modelleri olmuştur. Bu yaklaşımın teorik temeli Rosen [13] tarafından ortaya konmuş; konut fiyatının bireysel özelliklerin marjinal katkılarının bir bileşimi olduğu varsayımına dayandırılmıştır. Türkiye özelinde yapılan çalışmalar, hedonik regresyonun açıklayıcı bir başlangıç noktası sunduğunu; ancak doğrusal varsayımlar ve sınırlı etkileşim yapısı nedeniyle tahmin performansının belirli ölçülerde kısıtlı kaldığını göstermektedir [14, 15].

Bu sınırlamaları aşmak amacıyla, son yıllarda hedonik modellerin yerine (veya tamamlayıcısı olarak) makine öğrenmesi tabanlı yaklaşımların yaygınlaştığı görülmektedir. Güncel derleme ve karşılaştırmalı çalışmalar, özellikle ansambl ve ağaç tabanlı yöntemlerin klasik hedonik regresyona kıyasla daha düşük hata ve daha iyi genelleme sağladığını ortaya koymaktadır [16]. Buna karşın, yalnızca geçmiş gözlemlerden türetilen mekânsal-zamansal komşuluk sinyallerini (ST-lag) kullanan ve makro reelleştirme ((Tüketici Fiyat Endeksi, TÜFE / Konut Fiyat Endeksi, KFE) ile dönemler arası karşılaştırılabilirliği güvence altına alan bütünleşik ve sızıntı-güvenli çerçeveler literatürde görece nadirdir [3, 17].

Türkiye bağlamında yapılan çalışmalar, emlak vergisi ve kamu taşınmazları kapsamında toplu değerleme yaklaşımlarının uygulanabilirliğini ortaya koymakta; bu tür modellerin yalnızca mutlak hata ölçütleriyle değil, dağılım ve kalibrasyon göstergeleriyle birlikte değerlendirilmesi gerektiğini vurgulamaktadır [18]. Uluslararası toplu değerleme standartları da benzer biçimde, modellerin adalet, tutarlılık ve şeffaflık açısından izlenmesini zorunlu kılmakta; bu bağlamda Dağılım Katsayısı (COD) ve Fiyata Duyarlı Fark (PRD) gibi ölçütler, temel performans göstergeleri arasında yer almaktadır [19].

Türkiye'de toplu değerleme bağlamında yapay zekâ ve makine öğrenmesi yaklaşımlarının uygulanabilirliğini inceleyen çalışmalar, veri yoğun bölgelerde doğrusal modellere kıyasla daha esnek ve başarılı sonuçlar elde edilebildiğini göstermektedir [20]. Bu tez, söz konusu literatürden farklılaşarak, dışsal erişim ve ilgi noktası (Point of Interest; POI) katmanlarını bilinçli olarak dışarıda bırakmakta ve odağını tamamen sızıntı-güvenli ST-lag üretimi, makro reelleştirme ve üretime uygun bir model tasarımı üzerine kurmaktadır.

1.2 Tezin Önemi, Kapsamı ve İzlenen Yol

Türkiye'de UYAP e-Satış platformu üzerinden yürütülen yargı ihaleleri, serbest piyasa satışlarından farklı bir kurumsal çerçeveye sahiptir. Satışların iskonto

veya prim düzeyi yalnızca makroekonomik koşullara değil, aynı zamanda ihale yapısı, teminat oranları ve yasal düzenlemelere de bağlı olarak şekillenmektedir. Bankacılık, icra uygulamaları ve gayrimenkul yatırım kararları açısından bu sürece özgü, ölçeklenebilir ve açıklanabilir bir tahmin aracına duyulan ihtiyaç açıktır. Bu tez, bir taşınmazın *nihai satılacağı bedeli*—dolayısıyla ihale indirimi veya primini—öngörmeye yönelik veri temelli bir yöntem sunmayı amaçlamaktadır.

Analizler, yargı ihalelerinde en yaygın karşılaşılan üç ana taşınmaz türü üzerinde gerçekleştirilmiştir: **Konut**, **Dükkan** ve **Arsa**. Bu ayrım, hem piyasa dinamiklerinin hem de veri yoğunluğunun türler arasında anlamlı biçimde farklılaşması nedeniyle özellikle gözetilmiştir.

Hedef değişken, dönem ve ölçek farklarına karşı dayanıklılık sağlayacak biçimde Denklem 1.1'te tanımlanan log-fark (DIFF) formu ile modellenmiştir:

$$\mathrm{DIFF} = \log\big(1 + \mathrm{bid}\big) - \log\big(1 + \mathrm{est_val}\big), \tag{1.1}$$

burada bid ihale sonucunda oluşan nihai satış bedelini, $\mathrm{est_val}$ ise ihale öncesinde belirlenen muhammen bedeli ifade etmektedir. Bu tanım, mutlak fiyat seviyelerinden kaynaklanan heteroskedastisiteyi bastırırken, farklı dönemler ve fiyat ölçekleri arasında karşılaştırılabilirliği artırmaktadır.

Modelleme sürecinde üç temel ilke benimsenmiştir. Birincisi, **ileri bakış sızıntısının önlenmesi**dir: tüm öznitelikler yalnızca ilan kapanış tarihinden *önce mevcut olan* bilgilerden türetilmiştir. İkincisi, **komşuluk sinyali**dir: mekânsal-zamansal komşuluk etkisi (ST-lag), ilan noktasının yakın çevresinde (ör. 1000 m yarıçap ve 3–12 aylık zaman penceresi) gerçekleşmiş geçmiş ihalelerin ağırlıklı etkisini özetleyerek yerel piyasa dinamiklerini yakalamayı amaçlamaktadır. Üçüncüsü ise **makro reelleştirme**dir: parasal büyüklükler TÜFE/KFE endeksleri kullanılarak aynı reel döneme taşınmış ve böylece dönemler arası kıyas olanaklı kılınmıştır.

Veri yapısının çok sayıda kategorik alan, seyrek sınıflar ve eksik değerler içermesi, CatBoost'un ordered hedef istatistikli kodlamasını ve simetrik (*oblivious*) ağaç mimarisini bu problem için özellikle uygun kılmaktadır [4, 5]. Algoritmik aile kıyaslaması bu tezin kapsamı dışında tutulmuş; ancak hedef tanımına ilişkin sağlamlık analizleri kapsamında **ABS** ($\log(1 + \mathrm{bid})$) ve **RATIO** ($\log(1 + \mathrm{bid}/\mathrm{est_val})$) varyantları da aynı veri bölünmeleri altında eğitilerek karşılaştırılmıştır.

Elde edilen sonuçlar, Konut türünde **RATIO** hedefinin **DIFF**'e oldukça yakın bir performans sergilediğini; buna karşılık Dükkan ve Arsa türlerinde **DIFF** hedefinin

daha istikrarlı sonuçlar ürettiğini ve **ABS** hedefinin genel olarak daha zayıf kaldığını göstermektedir (bkz. Bölüm 3 ve Bölüm 4).

1.3 Araştırma Soruları ve Sınanan Öngörüler

Bu bölümde, önceki kısımda tanımlanan yaklaşımın geçerliliğini ve performansını değerlendirmek amacıyla, hedef değişken tanımı ve özellik tasarımına ilişkin araştırma soruları ve öngörüler ampirik olarak sınanmıştır.

Çalışma kapsamında aşağıdaki öngörüler nicel olarak test edilmiştir: (i) **DIFF** hedefinin, mutlak fiyat seviyelerine dayalı hedeflere kıyasla dönem ve ölçek değişimlerine karşı daha kararlı performans sergilemesi; (ii) yalnızca geçmiş gözlemlerden hesaplanan mekânsal-zamansal komşuluk sinyalinin (ST-lag) tahmin doğruluğunu anlamlı biçimde artırması; (iii) parasal büyüklüklerin TÜFE/KFE endeksleri ile reelleştirilmesinin dönemler arası karşılaştırılabilirliği ve model başarımını iyileştirmesi; (iv) muhammen değere göre tanımlanan fiyat bandı göstergesinin, taşınmaz türü ve ilçe düzeyinde heterojen etkiler üretmesi; (v) **RATIO** hedefinin Konut türünde **DIFF**'e yakın performans sergilerken, Dükkan ve Arsa türlerinde görece daha zayıf sonuçlar vermesi ve **ABS** hedefinin tüm türlerde sistematik olarak daha düşük performans göstermesi.

Bu öngörülerin iktisadi ve kurumsal arka planı yargı ihaleleri literatürüyle uyumludur: yargı ve icra satışlarının serbest piyasa işlemlerine kıyasla çoğu zaman iskontolu gerçekleştiği; bu iskontonun başlangıç fiyatı, ihale yapısı ve genel piyasa koşullarıyla yakından ilişkili olduğu daha önce gösterilmiştir [8, 9, 21]. Son dönem çalışmalar, yargı ihalelerinde gözlenen iskonto düzeyinin konut segmentlerine göre heterojenlik gösterdiğini ve fiyat dilimleriyle etkileşimli bir yapı sergilediğini ortaya koymaktadır [11, 12]. Bu bulgu, bu tezde `fiyat_bandı` değişkeni için gözlemlenen etkinin taşınmaz türü ve ilçe bazında yön değiştirebilmesiyle tutarlı bir çerçeve sunmaktadır.

Bu çalışmada kalibrasyon yöntemleri (örneğin, isotonik regresyon veya konformal tahmin) kapsam dışı bırakılmış ve gelecekteki çalışmalar için doğal bir genişletme alanı olarak değerlendirilmiştir.

1.4 Tezin Organizasyonu

Bu tez altı ana bölümden oluşmaktadır. Bölüm 2, çalışmada izlenen veri işleme hattını, özellik tasarımını (ST-lag üretimi ve makro reelleştirme adımları dâhil) ve kullanılan modeli ayrıntılı biçimde sunmakta; modelleme sürecine

ilişkin hiperparametreler ve eğitim durdurma (*early stopping*) kuralları açıkça tanımlanmaktadır.

Bölüm 3, zaman sıralı ve ilçe-bırakmalı ayrımlar altında oluşturulan deney kurulumunu ve değerlendirme çerçevesini raporlamakta; **DIFF** hedefi için elde edilen ana sonuçların yanı sıra **ABS** ve **RATIO** hedeflerine ilişkin duyarlılık karşılaştırmalarını sunmaktadır.

Bölüm 4, deneysel bulguları mevcut literatürle ilişkilendirerek yorumlamakta; yöntemin güçlü ve zayıf yönlerini, uygulama senaryolarını ve politika çıkarımlarını tartışmaktadır. Son olarak Bölüm 5, temel bulguları özetlemekte ve gelecekteki genişletme olanaklarını(çok kipli mimariler, mekânsal blok doğrulaması, dinamik fiyat bantları ve kalibrasyon yaklaşımları) işaret etmektedir.

2
Yöntem

2.1 Problemin Çerçevesi ve Hedef

UYAP e-Satış üzerindeki yargı ihalelerinde *nihai satış bedelini* (kazanan teklif, `bid`) öngörmek gözetimli bir regresyon problemidir. Bu çalışmada ana hedef değişken, dönemler arası kıyaslanabilirliği artıran, yüksek tutarlarda büyüyen hata yayılımını bastıran ve ölçekten bağımsız bir yorum sunan log-fark biçiminde tanımlanmıştır (bkz. Denklem 1.1).

Sezgisel olarak DIFF, muhammen değere göre göreli sapmayı temsil eder. $\mathrm{DIFF} > 0$ durumunda satışın *prim* ile, $\mathrm{DIFF} < 0$ durumunda ise *iskonto* ile gerçekleştiği yorumu yapılabilir.

Buna karşılık RATIO hedefi, $\mathrm{bid}/\mathrm{est_val}$ oranını log-ölçekte kodlar; ancak sıfır referansının (eşik noktasının) doğrudan prim/iskonto yorumuna karşılık gelmemesi, bu hedefi DIFF kadar sezgisel kılmaz.

Hedef tanımının sağlamlığını değerlendirmek amacıyla, aynı veri bölünmeleri ve aynı öznitelik seti kullanılarak iki alternatif hedef değişken de incelenmiştir:

$$\mathrm{ABS} = \log\bigl(1 + \mathrm{bid}\bigr) \tag{2.1}$$

$$\mathrm{RATIO} = \log\bigl(1 + \tfrac{\mathrm{bid}}{\mathrm{est_val}}\bigr) \tag{2.2}$$

Bu tezde taşınmaz tür adları Türkçe olarak kullanılır: **Konut**, **Dükkan** ve **Arsa** (eklerde ve kodlarda sırasıyla *Apartment*, *Shop* ve *Land*).

Hedef varyantları için ters dönüşüm (çıkarım) eşitlikleri: Model çıktılarını TL cinsinden nihai satış bedeli tahminine ($\widehat{\mathrm{bid}}$) dönüştürmek için aşağıdaki eşitlikler

kullanılır:

$$\widehat{\text{bid}} = (1 + \text{est_val}) \cdot \exp\big(\widehat{\text{DIFF}}\big) - 1 \tag{2.3}$$

(2.3), $\widehat{\text{bid}} = \exp(\log(1 + \text{est_val}) + \widehat{\text{DIFF}}) - 1$ ifadesiyle eşdeğerdir.

$$\widehat{\text{bid}} = \exp\big(\widehat{\text{ABS}}\big) - 1 \tag{2.4}$$

$$\widehat{\text{bid}} = \text{est_val} \cdot \Big(\exp\big(\widehat{\text{RATIO}}\big) - 1\Big) \tag{2.5}$$

Böylece tüm hedefler için değerlendirme metrikleri aynı TL uzayında, doğrudan $(y_i = \text{bid}_i,\ \hat{y}_i = \widehat{\text{bid}}_i)$ üzerinden hesaplanır.

2.2 Veri, İş Akışı ve Sızıntıyı Önleme

Veri seti, UYAP e-Satış platformundan elde edilen ilan ve ihale kayıtlarını ve bunlara eşlik eden yardımcı katmanları (TÜFE/KFE endeksleri ve idari sınırlar) içermektedir. Tüm kayıtlar ortak bir şemaya hizalanmış; sayısal alanlarda ondalık ayırıcı olarak nokta kullanılmış ve coğrafi koordinatlar World Geodetic System 1984 (WGS84) referans sistemi altında temsil edilmiştir. `id` ve `auction_file_content` alanları, izlenebilirlik ve denetlenebilirlik amacıyla hiçbir aşamada veri setinden çıkarılmamıştır.

Pay oranı bilgisi (`share`), farklı gösterim biçimlerinden tekil bir oransal değere dönüştürülmüştür. Teklif davranışında yapısal kırılmalar yaratabilen *hisseli* satışlar dışarıda bırakılarak, temel deneyler **tam pay** ($\texttt{share} \approx 1.0$) kayıtları üzerinde yürütülmüştür. Eksik veya şüpheli değerler otomatik doldurma yoluna gidilmeden `Unknown` olarak korunmuş; yalnızca güçlü ve doğrulanabilir kanıt bulunması hâlinde düzeltilmiştir.

İleri bakış sızıntısının önlenmesi (look-ahead leakage), önerilen yöntemin temel ilkelerinden biridir. Bu kapsamda tüm öznitelikler, yalnızca ilanın kapanış tarihinden *önce* mevcut olan bilgiler kullanılarak üretilmiştir. Bu ilke üç düzeyde sistematik olarak uygulanmaktadır: (i) ST-lag sinyali hesaplanırken yalnızca $t_j < t_i$ koşulunu sağlayan geçmiş ihalelerin kullanılması, (ii) makro reelleştirme adımında yalnızca ilgili döneme ait TÜFE/KFE endeks değerlerinden yararlanılması ve (iii) eğitim aşamasında kullanılan öznitelik listesinin `.features.json` dosyasında

dondurularak saklanması.

Üretim ortamında tutarlılığı sağlamak amacıyla, eğitimde kullanılan özniteliklerin adları ve sıralaması bu yan dosya üzerinden tahmin ve SHAP analizi aşamalarında aynen yüklenmektedir. Bu yaklaşım, zaman içinde oluşabilecek şema kayması (*zamanla değişen veri şeması*) riskini azaltmayı amaçlamaktadır.

Modelleme aşamasında kullanılan modelin de sızıntıya duyarlı olmaması hedeflenmiştir. Bu bağlamda CatBoost'un *ordered* hedef istatistiklerine dayalı kategorik kodlama mekanizması, hedef istatistiklerini her gözlem için veri içi permütasyon sırasındaki önceki örneklerden hesaplayarak hedef sızıntısını yapısal olarak azaltan bir avantaj sunmaktadır [6].

2.3 Özellik Tasarımı

Nominal parasal değerlerin dönemler arası karşılaştırılabilirliği, TÜFE/KFE endeksleri kullanılarak reelleştirme yoluyla sağlanmıştır. Aynı değişkenin t dönemindeki nominal değeri y_t için reelleştirilmiş değer $\tilde{y}_t$ aşağıdaki şekilde tanımlanır:

$$\tilde{y}_t = y_t \times \frac{\mathrm{Index}_{t_0}}{\mathrm{Index}_t} \tag{2.6}$$

Burada Index, TÜFE veya KFE endeksini; t_0 ise ortak baz dönemi ifade etmektedir. Bu dönüşüm, farklı makroekonomik rejimlerde oluşmuş parasal büyüklüklerin aynı reel ölçekte değerlendirilmesini mümkün kılmaktadır.

Zamansal rejim farklarını yakalayabilmek amacıyla dönem kuklaları ile birlikte `auction_year`, `auction_month` ve `month_id` gibi takvimsel değişkenler de özellik setine dâhil edilmiştir.

Tablo 2.1, modelde kullanılan öznitelikleri kavramsal gruplar altında özetlemektedir. Kimlik ve filtre öznitelikleri taşınmaz türünü ve payı tanımlamaktadır. Konumsal değişkenler taşınmazın coğrafi konumunu ve idari bağlamını temsil ederken, ölçek ve bina özellikleri fiziksel nitelikleri yansıtmaktadır. Kurumsal değişkenler ihale sürecine ilişkin bilgileri (teklif sayısı ve KDV oranı), zamansal değişkenler ise kapanış tarihi ve dönem etkilerini kodlamaktadır. Makro değişkenler, TÜFE/KFE endeksleri kullanılarak parasal büyüklüklerin reel karşılaştırılabilirliğini sağlamaktadır. ST-lag özniteliği, yalnızca geçmiş gözlemlerden türetilmiş mekânsal-zamansal komşuluk sinyalini temsil etmektedir. İmar ve arsa nitelikleri taşınmazın hukuki ve kullanım kısıtlarını, `fiyat_bandı` ise muhammen değere göre tanımlanan fiyat rejimlerini ifade etmektedir.

Tablo 2.1 Modelleme sürecinde kullanılan öznitelik grupları. Nihai öznitelik adları ve sıralaması, eğitim sırasında kaydedilen `.features.json` yan dosyası üzerinden kilitlenmektedir.

Grup	Öznitelik(ler)
Kimlik/Filtre	property_type, share
Konum	lat, lon, city, province, neighborhood
Ölçek/Alan	Alan ölçütleri, m^2 başına muhammen değer
Bina	building_age, room_count, total_floors, floor_number
Kurumsal	offer_count, vat_rate
Zaman	end_date_1, auction_year, auction_month, month_id
Makro	TÜFE/KFE göstergeleri, reelleştirilmiş parasal değişkenler
ST-lag	stlag_log_bid_idw
İmar/Arsa	zoning_status, land_status, usage_status
Bant	`fiyat_bandı` (`price_band`)

Mekânsal etkilerin toplu değerleme performansı üzerindeki rolü, çoklu regresyon ve coğrafi ağırlıklı regresyon (Geographically Weighted Regression; GWR) gibi yöntemlerle daha önce gösterilmiş; mekânsal bağımlılığın ihmal edilmesi durumunda model artıklarında anlamlı örüntülerin kalabildiği raporlanmıştır [22]. Coğrafi verinin uygun biçimde ön işlenmesi ve makine öğrenmesi tabanlı yöntemlerle birlikte kullanılması, toplu değerleme doğruluğunu artıran önemli bir unsur olarak literatürde yer almaktadır [23].

Bu çalışmada mekânsal-zamansal komşuluk etkisini özetlemek amacıyla ST-lag sinyali tanımlanmıştır. İlan i için komşu kümesi

$$\mathcal{N}_i = \{j : \; d_{ij} \le r, \; t_{\min} \le (t_i - t_j) \le t_{\max}, \; t_j < t_i\} \tag{2.7}$$

şeklinde belirlenmekte; burada d_{ij} iki ilan arasındaki coğrafi mesafeyi, $t_i - t_j$ ise zaman farkını ifade etmektedir. Bu komşuluk kümesi kullanılarak ST-lag değeri, mesafeye göre ters ağırlıklandırılmış ortalama biçiminde hesaplanır:

$$\mathrm{ST_lag}_i = \frac{\sum_{j \in \mathcal{N}_i} \dfrac{\log\!\left(1 + \mathrm{bid}_j\right)}{d_{ij} + \epsilon}}{\sum_{j \in \mathcal{N}_i} \dfrac{1}{d_{ij} + \epsilon}} \tag{2.8}$$

Aşağıdaki parametreler kullanılmıştır:

$$r = 1000 \text{ m}, \quad t_{\min} = 3 \text{ ay}, \quad t_{\max} = 12 \text{ ay}, \quad \epsilon > 0 \tag{2.9}$$

olarak belirlenmiştir. Aynı gün gerçekleşen işlemler ($t_j = t_i$) ileri bakış sızıntısını

önlemek amacıyla komşuluk kümesine dâhil edilmemiştir. Burada $\epsilon > 0$ terimi, sıfıra bölme problemini engelleyen küçük bir sabit değeri temsil etmektedir. Bu çalışmada $\epsilon = 1$ metre alınmıştır. $\mathcal{N}_i = \emptyset$ durumunda ST-lag değeri eksik (*NaN*) bırakılmış; bu durum deneysel analizlerde kapsama oranı üzerinden ayrıca izlenmiştir.

İhale tasarımına ilişkin değişkenler (başlangıç oranı, tur sayısı, teminat bedeli ve ilan-satış gecikmesi), modele kurumsal bağlam kazandırmak amacıyla özellik setine dâhil edilmiştir. Buna ek olarak, muhammen değere göre tanımlanan basit bir `fiyat_bandı` (`price_band`) kategorisi (0–2M, 2–6M, 6–15M, 15M+), bazı alt popülasyonlarda faydalı bir *rejim işareti* olarak davranabilmektedir. Ancak bu değişkenin küresel etkisinin sınırlı kaldığı, deneysel bölümde ayrıntılı biçimde gösterilmektedir.

2.4 Model ve Eğitim Protokolü

Tablo verisinde doğruluk, açıklanabilirlik ve eğitim süresi arasındaki dengeyi gözeterek **CatBoost** bu çalışmada ana model olarak seçilmiştir [6, 7, 24]. Bu tercih üç temel teknik gerekçeye dayanmaktadır: (i) il, ilçe, mahalle, kadastro/özellik etiketleri ve `fiyat_bandı` (`price_band`) gibi yüksek kardinaliteli kategorik değişkenlerin ve nadir sınıfların varlığı; (ii) eksik değerlerin ve farklı ölçeklerdeki sayısal değişkenlerin doğal biçimde yönetilebilmesi; (iii) *ordered(sıralı)* hedef istatistikli kategorik kodlama sayesinde hedef sızıntısının azaltılması ve *oblivious* (simetrik) ağaç yapılarıyla kararlı ve raporlanabilir bölünmelerin elde edilmesi.

Ayrıca, CatBoost çok sayıda sığ karar ağacını ardışık biçimde kuran bir gradyan artırmalı ansambl yöntemidir; her yeni ağaç, önceki ağaçların artık hatalarını azaltacak yönde öğrenilir [6, 24]. Ağaçların *simetrik* yapıda olması, aynı derinlikteki tüm düğümlerin aynı özelliğe göre bölünmesini sağlar; bu özellik, hızlı çıkarım süreleri ve daha tutarlı açıklanabilirlik üretimi açısından avantaj sunmaktadır.

Bu çalışmada kayıp işlevi olarak karesel hata (ℓ_2) kullanılmış, doğrulama kümesinde iyileşme gözlenmediğinde eğitim *erken durdurma* ile sonlandırılmıştır (sabır 200 tur, azami 2500 ağaç, rastgele tohum 42). Hiperparametreler makul aralıklarda taranmış (öğrenme oranı $\approx$ 0.02–0.2; ağaç derinliği 4–10), nihai seçimler yalnızca doğrulama performansına dayalı olarak yapılmıştır.

Hedef tanımının etkisini izole edebilmek amacıyla, *ABS* ve *RATIO* hedefleri için model mimarisi ve hiperparametreler *DIFF* hedefiyle birebir aynı tutulmuştur.

Böylece performans farklarının model yapısından değil, yalnızca hedef değişken tanımından kaynaklanması sağlanmıştır. Her taşınmaz türü için (*Konut*, *Dükkan*, *Arsa*) ayrı modeller eğitilmiştir.

CatBoost'un *ordered boosting (sıralı artırma)* mekanizması, hedef istatistiklerinin her gözlem için veri içi permütasyon sırasındaki önceki örneklerden türetilmesini sağlayarak, özellikle zaman sıralı veya sızıntıya duyarlı veri yapılarında daha güvenli bir öğrenme süreci sunmaktadır [6]. Karşılaştırmalı çalışmalar, CatBoost'un Extreme Gradient Boosting (XGBoost) ve Light Gradient Boosting Machine (LightGBM) gibi diğer gradyan artırmalı algoritmalarla benzer veya üstün performans gösterebildiğini; özellikle kategorik değişken yoğunluğu yüksek veri setlerinde daha istikrarlı sonuçlar üretebildiğini ortaya koymaktadır [24].

2.5 Değerlendirme ve Doğrulama Tasarımı

Gerçek kullanım senaryosunu taklit etmek amacıyla veri seti, geçmişten geleceğe doğru kronolojik olarak *eğitim* ($\leq$ 2023/12/31), *doğrulama* (2024) ve *test* ($\geq$ 2025) olmak üzere üçe ayrılmıştır. Coğrafi heterojenliği izlemek için, buna ek olarak ilçe bazlı alt-kırılım raporlaması yapılmıştır. Özellik üretimi bu bölünmeye tam uyumludur: ST-lag sinyali yalnızca geçmiş gözlemlerden hesaplanmış, aynı gün gerçekleşen işlemler komşuluk kümesine dâhil edilmemiştir. Tüm karşılaştırmalar sabit rastgele tohumlarla yalnızca *test* dilimi üzerinde raporlanmıştır.

Bu çalışma kapsamında $\mathrm{bid} > 0$ olduğundan, (2.12) ile tanımlanan MAPE metriği pratikte kararlı biçimde hesaplanabilmiştir.

Zaman bağımlılığı içeren problemler için, rastgele örnekleme veya klasik k-katlı çapraz doğrulamanın ileri bakış yanlılığı (*look-ahead bias*) üretebildiği ve model performansını yapay olarak şişirebildiği bilinmektedir [25, 26]. Bu nedenle bu çalışmada, gerçek kullanım koşullarını daha doğru yansıtan kronolojik veri bölünmesi tercih edilmiştir.

Toplu değerleme literatürü, model performansının yalnızca ortalama hata ölçütleriyle değil, değer dağılımı boyunca gösterdiği davranışla da değerlendirilmesini önermektedir. Bu bağlamda, kitlesel değerleme standartlarında yaygın biçimde kullanılan COD (Dağılım Katsayısı; *Coefficient of Dispersion*) ve PRD (Fiyat-İlişkili Diferansiyel; *Price-Related Differential*) göstergeleri, klasik hata metriklerine ek olarak tamamlayıcı kalibrasyon göstergeleri olarak raporlanmıştır [18, 19].

Konut fiyatlarının mekânsal bağımlılık gösterebildiği ve bu durumun model artıklarında mekânsal otokorelasyon şeklinde ortaya çıkabileceği literatürde yaygın biçimde belgelenmiştir [27, 28]. Bu nedenle, artıkların mekânsal yapısı Moran's I istatistiği ile ayrıca kontrol edilmiştir.

Hata ve uyum ölçütleri: Gerçek değer y_i, tahmin $\hat{y}_i$ ve örnek sayısı n olmak üzere:

$$\mathrm{MAE} = \frac{1}{n}\sum_{i=1}^{n}|\hat{y}_i - y_i| \tag{2.10}$$

Bu ölçüt, tahminlerin gerçek değerlere göre ortalama mutlak sapmasını TL cinsinden ifade eder.

$$\mathrm{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i - y_i)^2} \tag{2.11}$$

Bu ölçüt, büyük hataları daha güçlü cezalandırarak tipik hatanın ölçeğini vurgular.

$$\mathrm{MAPE} = 100 \cdot \frac{1}{n}\sum_{i=1}^{n}\left|\frac{\hat{y}_i - y_i}{y_i}\right| \tag{2.12}$$

Bu ölçüt, hatayı yüzde cinsinden vererek farklı fiyat seviyelerinin karşılaştırılmasını sağlar.

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(\hat{y}_i - y_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2} \tag{2.13}$$

Bu ölçüt, modelin toplam varyansın ne kadarını açıkladığını gösterir.

Kalibrasyon ölçütleri: Oran $r_i = \hat{y}_i/y_i$ olarak tanımlanır:

$$r_i = \frac{\hat{y}_i}{y_i} \tag{2.14}$$

Bu oran, tahminin gerçek değere göreli konumunu ifade eder.

$$\mathrm{COD} = 100 \cdot \frac{\mathrm{median}\big(|r_i - \mathrm{median}(r)|\big)}{\mathrm{median}(r)} \tag{2.15}$$

COD, göreli hataların medyan etrafındaki saçılmasını ölçerek kalibrasyon tutarlılığını değerlendirir.

$$\mathrm{wmean}(r) = \frac{\sum_{i=1}^{n} \hat{y}_i}{\sum_{i=1}^{n} y_i} \tag{2.16}$$

Ağırlıklı ortalama oran, toplam tahmin edilen değer ile toplam gerçek değer arasındaki ilişkiyi yansıtır.

$$\mathrm{PRD} = \frac{\mathrm{mean}(r)}{\mathrm{wmean}(r)} \tag{2.17}$$

PRD, modelin düşük ve yüksek değerler arasında sistematik yanlılık gösterip göstermediğini ortaya koyar.

Büyük sapma riskini izlemek amacıyla, göreli hata eşiklerine dayalı kuyruk oranları da raporlanmıştır:

$$\mathrm{Out}_{\geq\tau} = \frac{1}{n}\sum_{i=1}^{n} \mathbf{1}\left\{\frac{|\hat{y}_i - y_i|}{y_i} \geq \tau\right\}, \quad \tau \in \{0.50,\, 0.75\} \tag{2.18}$$

Bu gösterge, yüksek göreli hataya sahip gözlemlerin toplam içindeki payını ifade eder.

Basit örnek (tek ihale): Gerçek değer $y = 3{,}000{,}000$ TL ve tahmin $\hat{y} = 2{,}400{,}000$ TL olsun. Bu durumda mutlak hata $600{,}000$ TL, yüzdesel hata %20 ve oran $r = 0.80$ olarak bulunur. Bu örnek, yaklaşık %20 oranında göreli düşük takdire işaret eder. Tek gözlem için R^2, COD ve PRD anlamlı değildir; bu ölçütler çoklu gözlem gerektirir.

Neden RMSE genellikle MAE'den büyüktür? İki ihalede hatalar sırasıyla 0.6 ve 1.2 milyon TL olduğunda, $\mathrm{MAE} = 0.9$ milyon TL iken $\mathrm{RMSE} \approx 0.95$ milyon TL olur. Bu fark, büyük hataların RMSE üzerinde orantısız bir etki yaratmasından kaynaklanır.

ABS/RATIO değerlendirme notu: *ABS* ve *RATIO* hedefleriyle elde edilen model çıktıları, geri dönüşüm eşitlikleri kullanılarak $\widehat{\mathrm{bid}}$ değerlerine çevrilmiş; tüm performans ölçütleri aynı TL uzayında hesaplanmıştır. Böylece hedef tanımından bağımsız, adil bir karşılaştırma sağlanmıştır.

2.6 Yeniden Üretilebilirlik ve Uygulama

Bu çalışmada yürütülen tüm deneyler, yeniden üretilebilirliği garanti edecek biçimde sürüm ve tarih bilgileriyle birlikte kaydedilmiştir. Eğitilen modeller (`.cbm`), kullanılan öznitelik listeleri (`.features.json`), tahmin çıktıları ve performans metriklerine ait tablolar ayrı ayrı arşivlenmiştir. Bu yapı, deneylerin daha sonraki çalışmalarda aynı veri ve ayarlar altında birebir yeniden çalıştırılmasına olanak tanımaktadır.

Eğitim ve çıkarım aşamalarında aynı öznitelik adları ve sıralaması kullanıldığından, (*şema kayması*) riski en aza indirilmektedir. Öznitelik listesinin eğitim sırasında sabitlenmesi ve çıkarım aşamasında aynen yüklenmesi, özellikle üretim ortamlarında sık karşılaşılan (*sessiz hata*) türlerinin önüne geçilmesini amaçlamaktadır.

Üretime alım senaryoları için, model performansının yalnızca genel metrikler üzerinden değil, alt kırılımlar bazında da düzenli olarak izlenmesi önerilmektedir. Bu kapsamda; ilçe bazlı MAE ve MAPE değerleri, yüksek hata kuyruk oranları ($\mathrm{Out}_{\geq 0.50}$, $\mathrm{Out}_{\geq 0.75}$), ST-lag kapsama oranı ve `fiyat_bandı` dağılımındaki olası kaymaların periyodik olarak raporlanması, modelin zaman içindeki kararlılığını değerlendirmek açısından kritik göstergeler olarak değerlendirilmektedir.

Özetle, önerilen yaklaşım; ileri bakış sızıntısını engelleyen veri üretim süreci, makro reelleştirme ve mekânsal-zamansal sinyallerle zenginleştirilmiş sağlam bir öznitelik tasarımı ve ansambl tabanlı bir model kullanımı ile, *DIFF*, *ABS* ve *RATIO* hedef varyantları için ortak ve tutarlı bir doğrulama çerçevesi altında, yargı ihalelerinde nihai satış bedelinin öngörülebilirliğini artırmayı amaçlamaktadır.

3
Deneyler ve Sonuçlar

3.1 Deney Kurulumu ve Değerlendirme Çerçevesi

Aksi belirtilmedikçe, tüm deneysel sonuçlar yalnızca *tam pay* (`share` ≈ 1.0) kayıtlar üzerinden raporlanmıştır. Gerçek kullanım senaryosunu taklit etmek amacıyla veri seti, zaman sıralı olarak üç dilime ayrılmıştır: *eğitim* ($\leq$ 2023/12/31), *doğrulama* (2024) ve *test* ($\geq$ 2025).

Tüm çalıştırmalarda rastgele tohum 42'ye sabitlenmiş, doğrulama kümesinde 200 ardışık tur boyunca iyileşme gözlenmediğinde eğitim süreci *erken durdurma* ile sonlandırılmıştır (azami 2500 ağaç). Eğitim sırasında kullanılan öznitelik listesi, tahmin ve SHAP analizi aşamalarında birebir yeniden yüklenmek üzere yan bir dosyada (`.features.json`) dondurulmuş; böylece zaman içinde ortaya çıkabilecek olası *şema kaymaları* önlenmiştir.

Mekânsal-zamansal komşuluk sinyali (ST-lag) yalnızca *geçmiş* gözlemlerden türetilmiştir. Bu amaçla yarıçap $r = 1000\,\mathrm{m}$, zaman penceresi ise $t_{\min} = 3$–$t_{\max} = 12$ ay olarak belirlenmiştir. Aynı gün gerçekleşen işlemler komşuluk kümesine dâhil edilmemiştir. Bu tasarım sayesinde, geleceğe ait bilginin istemeden özniteliklere sızması engellenmiş ve değerlendirme sonuçlarının gerçekçi kalması sağlanmıştır.

Taşınmaz türlerine göre eğitim, doğrulama ve test örneklem büyüklükleri Tablo 3.1'te sunulmaktadır. ST-lag kapsaması (geçmiş komşu bulunabilen gözlem oranı), Konut türünde yaklaşık $\%83.3$, Dükkan türünde $\%63.5$ ve Arsa türünde $\%37.6$ olarak gerçekleşmiştir.

Tablo 3.1 Taşınmaz türü ve veri dilimlerine göre gözlem sayıları

Tür	Eğitim n	Doğrulama n	Test n
Konut	5290	881	868
Dükkan	1417	208	259
Arsa	965	185	133

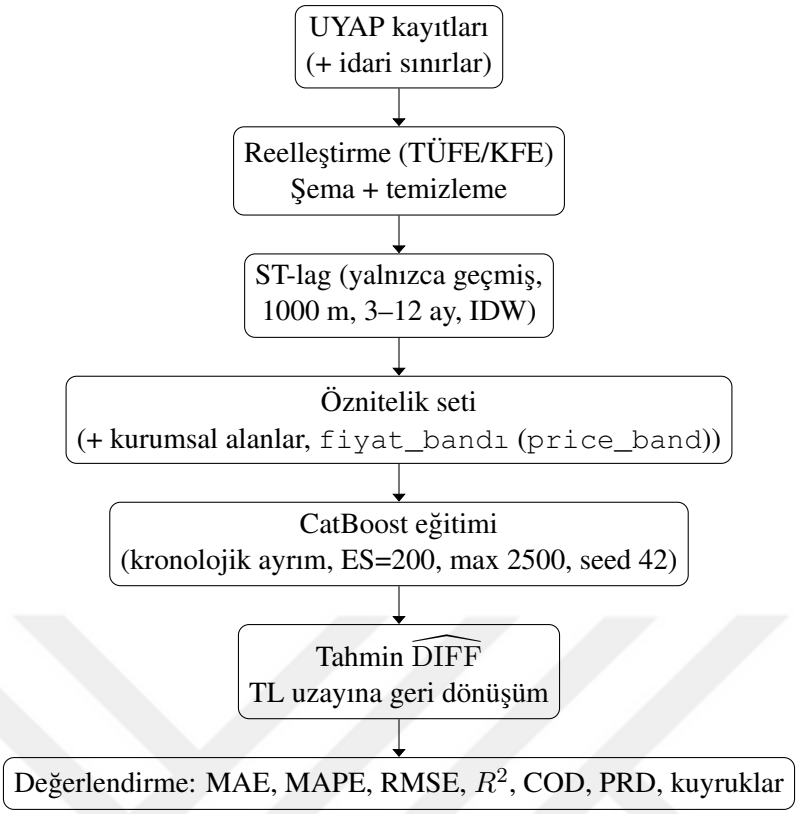
Bu tezde kullanılan temel öğrenici **CatBoost** regresyon modelidir. Karşılaştırmalar, aynı CatBoost yapılandırması altında yalnızca *hedef tanımı* ve/veya `fiyat_bandı` (`price_band`) özniteliğinin eklenip eklenmemesi üzerinden yürütülmüştür. Temel senaryoda hedef **DIFF** olarak tanımlanmış; `fiyat_bandı` (`price_band`) değişkeninin eklenmesiyle **DIFF+band** varyantı elde edilmiştir. Hedef tanımına ilişkin duyarlılığı değerlendirmek amacıyla **ABS** ve **RATIO** hedefleri de aynı veri bölünmeleri ve aynı öznitelik seti kullanılarak ayrıca çalıştırılmıştır.

Ana bulgular, daha geniş örneklem büyüklüğü ve yüksek ST-lag kapsaması nedeniyle **Konut** türü üzerinde sunulmaktadır. **Dükkan** ve **Arsa** türlerine ilişkin sonuçlar ise, daha sınırlı veri hacmi ve düşük komşuluk kapsaması nedeniyle *keşifsel* nitelikte raporlanmıştır.

Literatürde XGBoost ailesi ve derin öğrenme tabanlı yaklaşımlar (örneğin evrişimsel sinir ağları (Convolutional Neural Networks; CNN)) ile konut fiyat tahmini de incelenmiş olsa da [29–32], bu tezde algoritma ailesi taraması yapılmamış; bunun yerine hedef değişken tanımı (*DIFF*/*ABS*/*RATIO*) ve sızıntı-güvenli özellik üretiminin etkileri izole biçimde değerlendirilmiştir.

3.2 Uçtan Uca Modelleme Akışı

Uçtan uca süreç Şekil 3.1'de özetlenmektedir. (i) UYAP kayıtlarının ve idari sınır katmanlarının birleştirilmesi, (ii) makro endekslerle (TÜFE/KFE) reelleştirme ve şema/temizleme adımları, (iii) yalnızca geçmiş gözlemlerden türetilen sızıntı-güvenli mekânsal-zamansal komşuluk sinyalinin (ST-lag) üretilmesi ($r = 1000\,\mathrm{m}$, $t_{\min} = 3$–$t_{\max} = 12$ ay, ters mesafe ağırlığına dayalı (Inverse Distance Weighting; IDW)), (iv) öznitelik setinin oluşturulması (ihaleye ilişkin mevcut alanlar; örneğin, `offer_count`, `vat_rate` ve `fiyat_bandı` dâhil), (v) kronolojik veri ayrımı altında CatBoost modelinin eğitilmesi. Bu aşamada eğitim süreci, doğrulama kümesinde iyileşme gözlenmediğinde durdurulacak biçimde erken durdurma (sabır=200 iterasyon) ile sınırlandırılmış, azami ağaç sayısı 2500 olarak belirlenmiş ve tekrarlanabilirlik amacıyla rastgele tohum değeri 42'ye sabitlenmiştir, (vi) hedef uzayında tahmin üretilmesi ve çıktının TL uzayına geri dönüştürülmesi, (vii) model performansının değerlendirilmesi (MAE: ortalama mutlak hata, MAPE: ortalama yüzde hata, RMSE: büyük hatalara duyarlı karekök hata, R^2: açıklanan varyans, COD: göreli hata oranlarının medyan merkezli saçılımı, PRD: düşük ve yüksek değerlerde sistematik sapma göstergesi).



Şekil 3.1 Uçtan uca hat: veri, öznitelikler, CatBoost eğitimi, TL uzayına geri dönüşüm ve değerlendirme

3.3 Test Sonuçlarının Özeti (DIFF Odaklı)

Bu bölümde, test kesiti üzerinde elde edilen küresel performans metrikleri özetlenmektedir. Konut türünde `fiyat_bandı` (`price_band`) değişkeninin eklenmesi, küresel ölçekte nötr veya sınırlı bir etki üretmiştir: R^2 değeri benzer kalırken, RMSE hafifçe düşmüş, MAE ve MAPE ise küçük bir artış göstermiştir (MAE farkı yaklaşık 24 bin TL). Dükkan türünde *DIFF+band* modeli MAPE değerini düşürürken, RMSE artmış ve R^2 sınırlı biçimde düşmüştür. Arsa türünde ise *DIFF+band* varyansı belirgin biçimde azaltmış (RMSE düşüşü) ve açıklanan varyansı anlamlı ölçüde artırmıştır; MAPE değeri ise yaklaşık sabit kalmıştır.

Not: MAE (ortalama mutlak hata) ve RMSE (büyük hatalara daha duyarlı karekök hata) değerleri **milyon TL (M TL)** cinsinden raporlanmıştır (örn. 1.20 = 1.20M TL). MAPE (ortalama yüzde hata) ve COD (oranların medyan etrafındaki saçılması) değerleri **yüzde (%)** birimindedir. R^2 modeli tarafından açıklanan varyans oranını, PRD ise düşük ve yüksek bedellerde sistematik fazla/eksik değerleme eğilimini özetler. *Out 50/75* sütunu, yüzde hata eşiği $\geq 50\%$ ve $\geq 75\%$ olan gözlemlerin oranını $(\%)$ biçiminde sırasıyla göstermektedir. Dükkan ve Arsa için DIFF ile DIFF+band karşılaştırmalarına ait saçılım grafikleri bkz. Ek A (Şekil A.1); ABS/RATIO hedeflerine ilişkin karşılaştırmalar için bkz. Şekil A.2 ve Şekil A.3.

Tablo 3.2 Konut test performansı (DIFF hedefi)

Hedef	n	MAE	MAPE	RMSE	R^2	COD	PRD	Out 50/75
DIFF	868	1.20	24.97	3.10	0.70	19.07	1.07	9.45 / 2.88
DIFF+band	868	1.22	25.96	3.09	0.70	19.33	1.07	9.10 / 2.65

Tablo 3.3 Dükkan test performansı (DIFF hedefi)

Hedef	n	MAE	MAPE	RMSE	R^2	COD	PRD	Out 50/75
DIFF	259	3.27	59.60	5.67	0.62	27.20	1.12	55.98 / 42.86
DIFF+band	259	3.18	56.87	5.81	0.60	22.99	1.12	56.37 / 35.91

Tablo 3.4 Arsa test performansı (DIFF hedefi)

Hedef	n	MAE	MAPE	RMSE	R^2	COD	PRD	Out 50/75
DIFF	133	7.92	44.94	28.25	0.54	29.73	1.09	34.59 / 18.80
DIFF+band	133	7.53	45.02	23.08	0.70	28.59	1.12	37.59 / 16.54

Bu sonuçlar şu şekilde yorumlanabilir: Konut türünde ana model, R^2 değerinde yaklaşık 0.70 ve MAE değerinde yaklaşık 1.20 milyon TL düzeyinde bir performans sergilemektedir. Fiyat bandı bilgisinin eklenmesi, RMSE ve R^2 metriklerinde çok sınırlı bir iyileşme sağlarken, MAE ve MAPE değerlerinde küçük bir artışa yol açmıştır; buna karşın yüksek hata kuyruklarında (Out$\geq 50\%$, Out$\geq 75\%$) hafif bir düşüş gözlenmiştir.

Dükkan türünde, `fiyat_bandı` (`price_band`) bilgisi yüzdesel hatayı azaltmış, ancak RMSE'nin artması ve R^2'nin düşmesi, uç değerlerdeki davranışın tam olarak iyileştirilemediğini işaret etmektedir. Arsa türünde ise, *DIFF+band* modeli varyansı belirgin biçimde azaltmış (RMSE düşüşü) ve açıklanan varyansı anlamlı ölçüde artırmıştır; yüzdesel hata düzeyi yaklaşık %45 civarında sabit kalmıştır.

Alt-bölge analizleri, fiyat bandı bilgisinin her coğrafi veya yapısal alt grupta aynı yönde iyileştirme üretmediğini göstermektedir. Örneğin Esenyurt kırılımında (Konut, $n = 112$), *DIFF* modeli, *DIFF+band* modeline kıyasla daha düşük MAE ve MAPE değerleri üretmiştir (0.36 M TL ve %26.33 *vs.* 0.39 M TL ve %30.47).

Tablo 3.5 Konut — Esenyurt kırılımı ($n = 112$, tam pay)

Hedef	İlçe	n	MAE	MAPE (%)
DIFF	Esenyurt	112	0.36	26.33
DIFF+band	Esenyurt	112	0.39	30.47

3.4 Hedef Varyantları: ABS ve RATIO

Tablo 3.6 Konut—hedef varyantları (test, tam pay)

Hedef	n	MAE	MAPE	RMSE	R^2	COD	PRD	Out 50/75
DIFF	868	1.20	24.97	3.10	0.70	19.07	1.07	9.45 / 2.88
RATIO	868	1.19	25.81	2.99	0.72	19.59	1.06	10.25 / 3.00
ABS	868	2.12	36.36	5.08	0.19	21.52	1.33	22.12 / 3.11
DIFF+band	868	1.22	25.96	3.09	0.70	19.33	1.07	9.10 / 2.65
RATIO+band	868	1.20	26.02	3.56	0.60	18.38	1.05	11.29 / 3.92
ABS+band	868	1.90	32.55	4.95	0.23	21.43	1.27	16.82 / 2.76

Tablo 3.7 Dükkan—hedef varyantları (test, tam pay)

Hedef	n	MAE	MAPE	RMSE	R^2	COD	PRD	Out 50/75
DIFF	259	3.27	59.60	5.67	0.62	27.20	1.12	55.98 / 42.86
RATIO	259	3.34	62.91	5.84	0.60	21.67	1.15	59.46 / 44.79
ABS	259	2.64	30.29	7.53	0.33	25.84	1.45	20.08 / 3.86
DIFF+band	259	3.18	56.87	5.81	0.60	22.99	1.12	56.37 / 35.91
RATIO+band	259	3.22	59.50	5.83	0.60	24.02	1.14	58.69 / 38.22
ABS+band	259	2.62	30.75	7.51	0.34	23.50	1.44	18.92 / 5.02

Tablo 3.8 Arsa—hedef varyantları (test, tam pay)

Hedef	n	MAE	MAPE	RMSE	R^2	COD	PRD	Out 50/75
DIFF	133	7.92	44.94	28.25	0.54	29.73	1.09	34.59 / 18.80
RATIO	133	9.20	49.56	35.07	0.30	29.48	1.10	34.59 / 21.05
ABS	133	13.22	44.87	40.35	0.07	34.00	2.20	36.09 / 12.03
DIFF+band	133	7.53	45.02	23.08	0.70	28.59	1.12	37.59 / 16.54
RATIO+band	133	9.45	50.63	37.59	0.19	30.69	1.09	41.35 / 24.06
ABS+band	133	13.33	43.75	40.55	0.06	33.32	2.08	39.85 / 11.28

Bu bölümde, hedef değişken tanımının model performansı üzerindeki etkisi *DIFF*, *RATIO* ve *ABS* varyantları için karşılaştırmalı olarak incelenmiştir. Tüm karşılaştırmalar, model çıktılarının TL uzayına geri dönüştürülmesi ($\widehat{\text{bid}}$) sonrasında, aynı değerlendirme metrikleri kullanılarak yapılmıştır.

Konut türünde elde edilen sonuçlar, **RATIO** hedefinin beklenmedik biçimde **DIFF** hedefine oldukça yakın bir performans sergilediğini göstermektedir. RATIO hedefi, R^2 açısından DIFF'e kıyasla hafif bir üstünlük sağlarken, MAE değerleri benzer düzeyde kalmış, MAPE ise sınırlı ölçüde yükselmiştir. Buna karşılık, **ABS** hedefi, muhammen değere göre bir normalizasyon içermemesi nedeniyle hem mutlak hem de yüzdesel hata metriklerinde belirgin biçimde daha zayıf sonuçlar üretmiştir.

Dükkan ve Arsa türlerinde, *DIFF* hedefinin genel olarak daha dengeli ve istikrarlı bir performans sunduğu görülmektedir. RATIO hedefi bu türlerde ne mutlak

hata ne de kalibrasyon ölçütleri açısından DIFF'i sistematik biçimde geçememiş; ABS hedefi ise özellikle R^2, PRD ve yüksek hata kuyrukları bakımından belirgin dezavantajlar sergilemiştir.

Konut özelinde, **RATIO** hedefinin DIFF'e yakın sonuç vermesi, muhammen değere göre yapılan oransal normalizasyonun heterojenlik kaynaklı bazı varyans bileşenlerini dengeleyebilmesiyle açıklanabilir. Bununla birlikte, `fiyat_bandı` (`price_band`) değişkeni eklendiğinde RATIO hedefinin R^2 değerinde gözlenen düşüş, band bilgisi ile oransal hedef tanımı arasındaki etkileşimin kalibrasyonu olumsuz yönde etkileyebileceğine işaret etmektedir.

ABS hedefi ise, mutlak ölçek üzerinden öğrenme yapması nedeniyle yüksek bedelli ihalelerde hata büyüklüklerini artırmakta; bu durum özellikle yüzdesel hata metrikleri (MAPE) ve PRD değerlerinde bariz bir performans kaybı olarak ortaya çıkmaktadır. Bu bulgular, yargı ihaleleri gibi geniş değer aralığına ve yüksek heterojenliğe sahip veri setlerinde, muhammen değere göre normalize edilmiş hedef tanımlarının (*DIFF* veya *RATIO*) daha uygun bir modelleme çerçevesi sunduğunu desteklemektedir.

3.5 Açıklanabilirlik

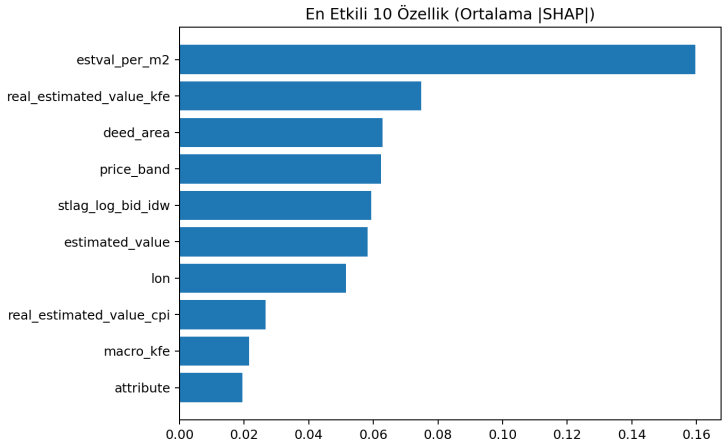
Modelin hangi değişkenlere dayandığını ve bu değişkenlerin tahmin üzerindeki yönlü etkilerini incelemek amacıyla SHAP (SHapley Additive exPlanations) yaklaşımı kullanılmıştır. SHAP, her bir gözlem için model tahminini, tüm veri üzerindeki ortalama tahmin değeri ile özellik katkılarının toplamı biçiminde ayrıştırır. Bu çerçevede, $\phi_k(x) > 0$ ilgili özelliğin tahmini yükselttiğini, $\phi_k(x) < 0$ ise tahmini aşağı çektiğini ifade eder.

Konut türü için elde edilen SHAP sonuçları, model tahminlerinde en baskın belirleyicilerin `real_estimated_value_kfe` ve `estval_per_m2` olduğunu göstermektedir. Bu değişkenleri, taşınmazın konum ve ölçek özelliklerini temsil eden `lon`, `deed_area` gibi konum/ölçek göstergeleri ve makro değişkenler (`macro_kfe`, reelleştirilmiş değerler) izlemektedir. Mekânsal-zamansal komşuluk sinyali (`stlag_log_bid_idw`) orta düzeyde fakat tutarlı bir katkı sunarken, `fiyat_bandı` (`price_band`) değişkeninin görece ikincil bir öneme sahip olduğu görülmektedir.

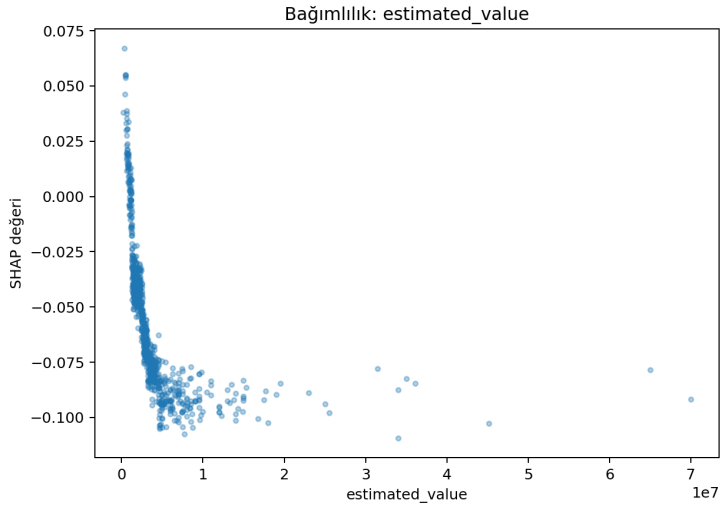
Bağımlılık grafikleri, `estimated_value` arttıkça SHAP katkısının sistematik biçimde daha negatife kaydığını ortaya koymaktadır. Bu bulgu, yüksek muhammen bedelli taşınmazlarda nihai satış bedelinin muhammen değere oranla görece

daha düşük kalma eğilimini, başka bir ifadeyle $\mathrm{bid}/\mathrm{est_val}$ oranının azalmasını yansıtmaktadır.

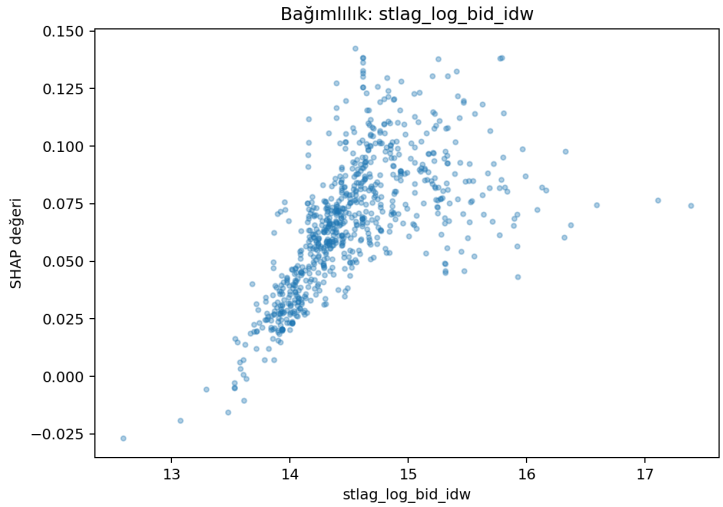
`stlag_log_bid_idw` için elde edilen bağımlılık grafiği ise, komşuluk sinyalinin artmasıyla birlikte tahmin üzerindeki katkının pozitif yönde güçlendiğini, ancak yüksek seviyelerde bu etkinin *doyuma girdiğini* göstermektedir. Bu durum, yakın çevrede gerçekleşen yüksek bedelli satışların fiyat sinyali taşıdığını, ancak belirli bir eşikten sonra ek bilginin marjinal katkısının azaldığını işaret etmektedir.



Şekil 3.2 Konut—SHAP ilk 10 (DIFF+band). Küresel önem sıralaması $\mathbb{E}[|\phi_k|]$ ölçütüne göre verilmiştir



Şekil 3.3 Konut—SHAP bağımlılık grafiği: `estimated_value`. Muhammen değer arttıkça katkının daha negatif yönde değiştiği görülmektedir



Şekil 3.4 Konut—SHAP bağımlılık grafiği: `stlag_log_bid_idw`. Komşuluk sinyali arttıkça katkı pozitiftir; yüksek seviyelerde ise doygunluk davranışı gözlenmektedir

3.6 Öngörüler ve Hata Görselleştirmesi

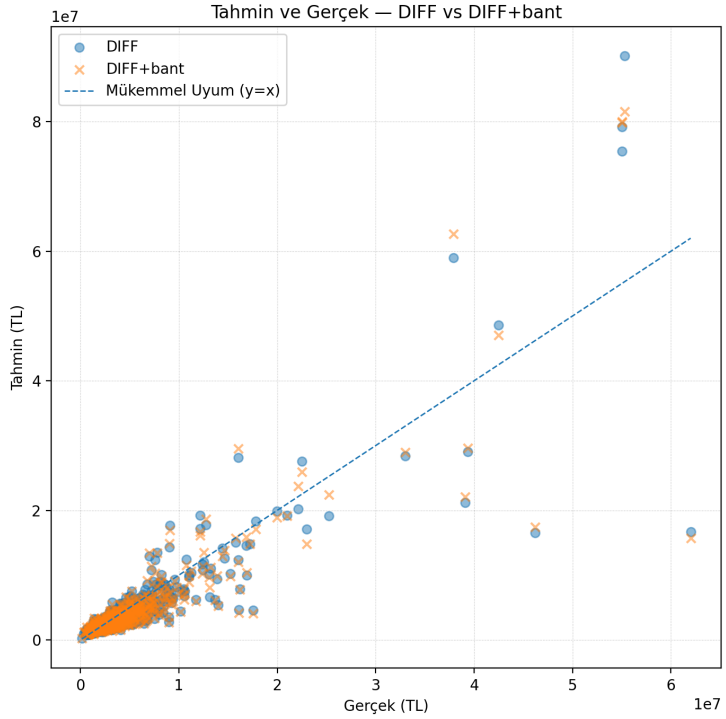
Aşağıdaki karşılaştırma grafikleri, Konut türü için **DIFF/DIFF+band**, **RATIO/RATIO+band** ve **ABS/ABS+band** varyantlarının kalibrasyon ve hata örüntülerini yan yana sunmaktadır. Grafiklerde 45° doğrusu, mükemmel kalibrasyon için referans çizgisi olarak alınmıştır. Bu doğruya yakınlık tahminlerin kalibrasyon kalitesini, dikey yöndeki saçılma hata büyüklüğünü, uç bölgelerde gözlenen sistematik sapmalar ise aşırı veya eksik değerleme eğilimlerini göstermektedir.

Genel olarak, ana model olan **CatBoost–DIFF**, Konut test kesitinde $R^2 \approx 0.70$ ve MAE ≈ 1.20 milyon TL düzeyinde bir performans üretmektedir. `fiyat_bandı` (`price_band`) bilgisinin eklenmesi, Konut türünde küresel ölçekte sınırlı bir katkı sağlamakta; kalibrasyon çizgisine yakınlık büyük ölçüde korunurken, hata dağılımında yalnızca marjinal değişimler gözlenmektedir.

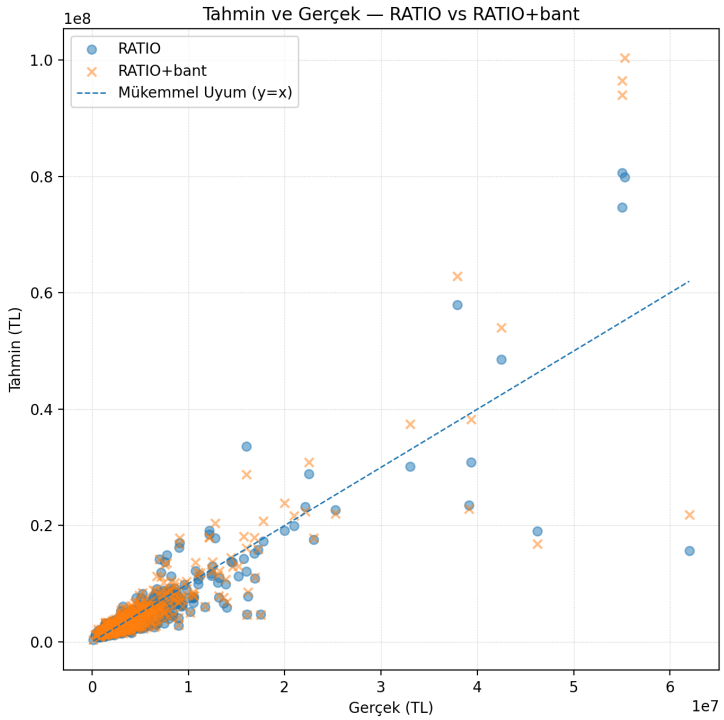
Türler arası karşılaştırmada, band sinyalinin etkisinin heterojen olduğu görülmektedir: Dükkan türünde band bilgisi yüzdesel hatayı (MAPE) düşürürken, RMSE'nin artması, uç değerlerdeki varyansın tam olarak bastırılamadığını işaret etmektedir. Arsa türünde ise `fiyat_bandı` (`price_band`) eklenmesi, hata varyansını belirgin biçimde azaltmakta ve açıklanan varyansı (R^2) yükseltmektedir; bu durum, fiyat bantlarının arsa segmentinde daha güçlü bir rejim göstergesi olarak çalıştığını düşündürmektedir.

Hedef tanımları açısından bakıldığında, Konut türünde **DIFF** ve **RATIO** hedefleri

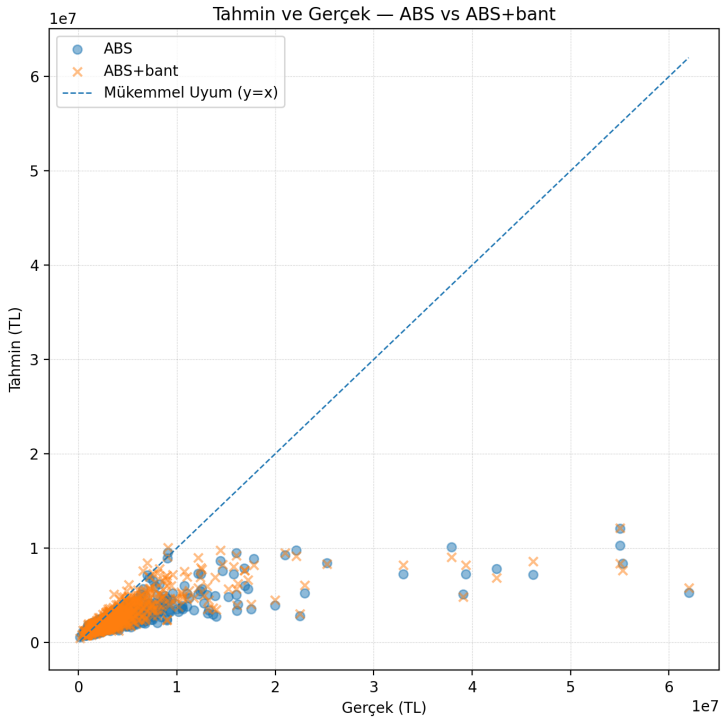
için artıkların mekânsal bağımlılığına dair anlamlı bir örüntü gözlenmemektedir. Buna karşılık, **ABS** hedefinde Moran's I istatistiğinin sınırda bir anlamlılığa yaklaşması, mutlak ölçekli hedeflerin mekânsal yapıyı daha zayıf temsil ettiğine işaret etmektedir.



Şekil 3.5 Konut—DIFF ve DIFF+band karşılaştırması. $45°$ doğrusu kalibrasyon için referans çizgisi olarak verilmiştir



Şekil 3.6 Konut—RATIO ve RATIO+band karşılaştırması



Şekil 3.7 Konut—ABS ve ABS+band karşılaştırması

3.7 Vaka Örnekleri

Hedef çıktılarının sahadaki tekil dosyalara nasıl yansıdığını göstermek amacıyla dört seçilmiş ihalenin özet bilgileri Tablo 3.9'de sunulmuştur. Aynı ihaleler için

DIFF ve **DIFF+band** modellerine ait tahminlerin yüzde hata karşılaştırmaları ise Tablo 3.10'de yer almaktadır. Bu bölüm, küresel metriklerin (MAE, RMSE, MAPE) tekil dosyalar düzeyinde nasıl somutlaştığını göstermeyi amaçlamaktadır.

Bu analizde hata $|\hat{y} - y|$, yüzde hata ise $|\hat{y} - y|/y \times 100$ şeklinde hesaplanmıştır. `band_low`, `band_mid`, `band_upper` ve `band_lux` etiketleri sırasıyla $\{0$–$2\,\mathrm{M},\ 2$–$6\,\mathrm{M},\ 6$–$15\,\mathrm{M},\ 15\,\mathrm{M}+\}$ TL muhammen değer dilimlerini temsil etmektedir.

Tablo 3.9 Seçilmiş tekil ihale bilgileri

ID	İlçe/Mahalle	Tarih	Muhammen (M TL)	Gerçek (M TL)
13852445042	Üsküdar/Toygar Hamza	2025-01-02	6.5	3.6
14093944389	Kartal/Yakacık	2025-01-22	4.0	3.0
14891311030	Kadıköy/Zühtüpaşa	2025-06-25	21.0	17.8
14328283333	Kağıthane/Merkez	2025-03-04	1.35	1.82

Tablo 3.10 Seçilmiş tekil ihaleler için DIFF ve DIFF+band karşılaştırması. Tahminler M TL cinsindendir

ID	DIFF tah.	Hata (%)	DIFF+band tah.	Hata (%)	Band
13852445042	4.7	30.8	4.56	26.5	band_upper
14093944389	2.94	1.9	2.96	1.4	band_mid
14891311030	18.30	2.9	17.14	3.7	band_lux
14328283333	1.54	15.4	1.54	15.6	band_low

Tablo 3.10 incelendiğinde, `fiyat_bandı` (`price_band`) bilgisinin tekil dosyalar üzerindeki etkisinin homojen olmadığı görülmektedir. Örneğin, Üsküdar/Toygar Hamza örneğinde **DIFF+band** modeli yüzde hatayı yaklaşık 4 puan azaltırken, Kadıköy/Zühtüpaşa örneğinde band eklenmesi küçük bir performans kaybına yol açmıştır. Bu bulgu, fiyat bantlarının her alt bölgede ve her fiyat seviyesinde aynı yönde katkı üretmediğini göstermektedir.

Tablo 3.11 Seçilmiş dosyalar için hedef–band varyantlarının yüzde hata (%) karşılaştırması (test). En düşük değer kalın gösterilmiştir

ID	DIFF	DIFF+band	RATIO	RATIO+band	ABS	ABS+band
13852445042	30.8	26.5	37.8	56.6	**11.8**	42.0
14093944389	1.9	**1.4**	3.6	12.7	34.5	22.9
14891311030	2.9	3.7	**2.6**	16.7	50.0	53.8
14328283333	15.4	15.6	19.6	**6.0**	25.0	16.2

Tablo 3.11, farklı hedef tanımlarının tekil dosyalarda nasıl farklı davranabildiğini açık biçimde ortaya koymaktadır. Bazı örneklerde **ABS** hedefi en düşük yüzde hatayı üretse de, bu başarımın küresel metriklere yansımadığı ve genelleme

gücünün zayıf kaldığı önceki bölümlerde gösterilmiştir. Benzer şekilde, **RATIO** hedefi belirli dosyalarda avantaj sağlasa da, band bilgisi ile etkileşimi bazı vakalarda kalibrasyonu bozabilmektedir.

Bu vaka analizleri, küresel ölçekte dengeli performans sunan **DIFF** hedefinin, tekil dosyalar düzeyinde her zaman en düşük hatayı üretmese bile, daha öngörülebilir ve tutarlı bir hata profili sunduğunu göstermektedir. Bu gözlem, önceki bölümlerde raporlanan MAE, RMSE, MAPE ve kalibrasyon metrikleriyle uyumlu bir tablo çizmektedir.

Not: Yüzde hata $= |\widehat{y} - y|/y \times 100$ olarak hesaplanmıştır.

4
Tartışma

4.1 Bulguların Özeti ve Yorumu

Bu çalışma, UYAP e-Satış ihalelerinde *nihai satış bedelini* (dolayısıyla ihale indirimi/primini) öngörmek üzere; sızıntı-güvenli bir veri hattını, yalnızca geçmiş gözlemlerden türetilen ST-lag tabanlı komşuluk sinyalini ve makro reelleştirmeyi bir araya getiren bir yaklaşımı değerlendirmiştir (bkz. Bölüm 2). Deneyler, gerçek kullanım senaryosunu yansıtacak biçimde kronolojik ayrım ve sabit özellik şeması altında yürütülmüştür (bkz. Bölüm 3).

Fiyat bandı (`price_band`): DIFF+band varyantı Konut'ta küresel ölçekte *sınırlı* ek katkı sağlamıştır: RMSE (büyük hatalara duyarlı) hafifçe düşerken R^2 (açıklanan varyans) benzer kalmış / marjinal değişmiştir, MAE/MAPE (tipik TL hatası / yüzde hata) ise küçük artışlar göstermiştir (Tablo 3.2). Dükkan'da band bilgisi yüzde hata (MAPE) açısından faydalı olurken, RMSE'nin (büyük hatalara duyarlı) yükselmesi ve R^2 (açıklanan varyans)'nin azalması, uç değerlerdeki hata varyansının tamamen bastırılamadığına işaret etmektedir (Tablo 3.3). Arsa'da ise DIFF+band, varyansı belirgin biçimde azaltmış ve R^2 (açıklanan varyans)'yi yükseltmiştir (Tablo 3.4).

Bu desen, türler arası veri yoğunluğu ve ST-lag kapsamasındaki farklarla (Konut $\approx$%83.3, Dükkan $\approx$%63.5, Arsa $\approx$%37.6) uyumlu görünmektedir: komşuluk sinyalinin zayıfladığı ve örneklemin küçüldüğü türlerde, band gibi kaba rejim göstergeleri, olası olarak daha görünür katkı verebilmektedir.

Küçük farklar ve istatistiksel belirsizlik: Konut'ta DIFF ile DIFF+band arasındaki MAE farkı yaklaşık 24 bin TL'dir; temel MAE seviyesinin ($\sim$ 1.20 milyon TL) yaklaşık $\sim$%2'sine karşılık gelmektedir; bu durum operasyonel açıdan *küçük* bir etkiyi işaret eder. Bu tür farkların örnekleme oynaklığından ayrışıp

ayrışmadığını değerlendirmek için eşleştirilmiş (paired) bootstrap ve permütasyon testleri önerilir. Bu çalışmada resmi bir anlamlılık testi yürütülmemiştir. Bu yönüyle bulgular, kesin çıkarımlar yerine, model davranışının büyüklük ve yön bakımından tutarlılığını betimlemeyi amaçlamaktadır. Kurumsal izleme bağlamında, periyodik (örn. aylık) eşleştirilmiş yeniden örnekleme raporları üretmek, küçük farkların *istikrarlı* olup olmadığını görünür kılacaktır. Bu nedenle raporlanan farklar, istatistiksel anlamlılıktan ziyade operasyonel etki büyüklüğü bağlamında yorumlanmalıdır.

Yerel heterojenlik: Esenyurt kırılımı (Konut, n=112), band bilgisinin her alt bölgede aynı yönde katkı üretmeyebileceğini göstermektedir: DIFF, DIFF+band'e kıyasla daha düşük MAE/MAPE üretmiştir (Tablo 3.5). Tekil vaka örnekleri de band etkisinin dilim ve mahalleye göre yön değiştirebildiğini ortaya koymaktadır (Tablo 3.9 ve Tablo 3.10). Sabit TL band eşiklerinin yerel fiyat rejimleriyle her zaman hizalanmaması, bu davranışın olası nedenlerinden biridir. Bu bulgu, band tanımının sabit TL eşikleri yerine enflasyona veya dağılıma duyarlı biçimde yeniden ele alınması gerektiğine işaret etmektedir.

Vaka analizi (ABS/RATIO/DIFF): Tablo 3.11'daki vaka karşılaştırması, hedef tanımı ve band sinyalinin *tekil ihale* düzeyinde tutarlı ve tek yönlü bir üstünlük oluşturmadığını göstermektedir: Üsküdar/Toygar Hamza örneğinde **ABS** en düşük yüzde hatayı üretirken (%11.8), Kartal/Yakacık'ta **DIFF+band** (%1.4), Kadıköy/Zühtüpaşa'da **RATIO** (%2.6) ve Kağıthane/Merkez'de **RATIO+band** (%6.0) en iyi sonucu vermiştir. Bu çeşitlilik, sabit TL band eşikleri ile oransal normalizasyonun (RATIO) etkileşiminin mahalle ve fiyat dilimine göre farklı yanlılık/dağılım örüntüleri yaratabildiğine işaret etmektedir. Kurumsal kullanımda, kritik ilçeler ve üst dilimler için hedef–band kombinasyonlarının periyodik izlenmesi ve band eşiklerinin enflasyona/dağılıma endeksli biçimde dinamik yönetilmesi önerilir.

Artıkların mekânsal bağımlılığı: Konut için Moran's I (artıkların mekânsal otokorelasyonu) DIFF ve RATIO hedeflerinde anlamlı bulunmamıştır. ABS'de ise sınırdadır. (DIFF: I=0.0009, p≈0.415; RATIO: $I = -0.0028$, p≈0.545; ABS: I=0.0622, p≈0.050; n=868). Bu sonuç, ST-lag ve konumsal değişkenlerin genel resimde belirgin bir mekânsal artık örüntüsü bırakmadığına işaret etmektedir. ABS hedefi için $p \approx 0.05$ düzeyi, bulgunun *sınırda* olabileceğini düşündürür; dolayısıyla bu bulgunun, daha geniş örneklemler ve farklı uzamsal ağırlık matrisleri altında

yeniden sınanması uygun olacaktır.

4.2 Hedef Tanımları: DIFF, RATIO, ABS

Konut: **RATIO**, **DIFF**'e beklenenden yakın bir performans göstermiştir: R^2 biraz daha yüksek (0.72 *vs.* 0.70), MAE çok yakındır (1.20 *vs.* 1.19 milyon TL), MAPE ise hafif daha yüksektir (%25.81 *vs.* %24.97). Bu yakınlık, muhammen değere göre yapılan oransal normalizasyonun, heterojenlik kaynaklı varyansın bir bölümünü dengeleyebilmesiyle açıklanabilir. Buna karşılık **ABS** hedefi, muhammen değer ile normalize edilmediğinden TL ölçeğinde gözlenen heteroskedastisiteyi yeterince bastıramamış ve göreli kalibrasyon göstergelerinde daha zayıf kalmıştır (örn. PRD: 1.33; ayrıca $\text{Out}_{\geq 0.50}$ oranı belirgin biçimde yükselmektedir).

Dükkan ve Arsa: Dükkan'da **ABS** hedefi, yüzde hata (MAPE) açısından daha düşük bir değer üretebilse de, RMSE'nin belirgin biçimde artması ve R^2'nin düşmesi, büyük sapmaların (uç hataların) arttığını ve kalibrasyon–varyans dengesinin bozulabildiğini düşündürmektedir. Arsa'da ise **DIFF** ailesi genel olarak daha dengeli sonuçlar verirken, `fiyat_bandı` (`price_band`) eklenmesi özellikle DIFF için RMSE'yi anlamlı ölçüde düşürmüş ve R^2'yi yükseltmiştir. Genel resimde **DIFF**, türler arası denge ve kalibrasyon açısından daha güvenli bir varsayılan hedef olarak öne çıkmaktadır.

Kalibrasyon göstergeleri: Konut'ta COD değerleri DIFF/RATIO için $\sim$%19 civarındadır; ABS'de ise $\sim$%21–22 aralığına yükselmektedir. PRD'nin DIFF/RATIO'da $\approx$ 1.06–1.07 bandında kalması, ABS'de ise 1.27–1.33 aralığına çıkması, ABS hedefinin *regresif* bir örüntüye (yüksek değerlerin göreli olarak düşük, düşük değerlerin göreli olarak yüksek takdiri) daha yatkın olabileceğini ima eder. Bu nedenle ABS ile çalışma durumunda, kalibrasyon (COD/PRD) ve kuyruk riski (Out oranları) birlikte izlenmelidir.

4.3 Literatürle Konumlandırma

Bu çalışmadan elde edilen bulgular, (i) gradyan artırmalı ağaç tabanlı yöntemlerin karmaşık ve doğrusal olmayan etkileşimleri yakalayarak tahmin hatasını düşürebildiğini, (ii) kategorik değişkenlerin hedef sızıntısını azaltacak biçimde *ordered(sıralı)* hedef istatistikleriyle temsil edilebildiğini ve (iii) mekânsal komşuluk sinyallerinin (ST-lag) yalnızca geçmişe dayalı ve sızıntı-güvenli biçimde

kurulmasının doğruluğa anlamlı katkı sunabildiğini raporlayan literatürle genel olarak uyumludur.

Bu çalışmada kullanılan *DIFF* hedefi, muhammen değere göre göreli sapmayı log-uzayında temsil ederek ölçek etkilerini ve dönemler arası parasal büyümeyi baskılamış; makro reelleştirme (TÜFE/KFE) ve zaman kodları (ay/yıl değişkenleri) ise farklı makroekonomik rejimler arasında karşılaştırılabilirliği desteklemiştir. Bu yaklaşım, özellikle ağaç tabanlı ansamblların (XGBoost türevleri) ve derin öğrenme tabanlı mimarilerin (örneğin CNN tabanlı modellerin) emlak fiyat tahmini bağlamında başarıyla uygulandığını raporlayan çalışmalarla tutarlıdır [29–32].

Önerilen yöntem, hedonic fiyatlama literatürünün temel varsayımlarını reddetmekten ziyade, doğrusal ve önceden tanımlı fonksiyonel biçimlere dayalı modelleme yaklaşımının sınırlarını aşmayı amaçlamaktadır. Başka bir ifadeyle, klasik hedonic regresyonun açıklayıcı çerçevesi korunurken, değişkenler arası doğrusal olmayan ilişkiler ve yüksek dereceli etkileşimler veri tarafından öğrenilen esnek fonksiyonlar aracılığıyla modellenmiştir. Nitekim makine öğrenmesi tabanlı yöntemler ile hedonic regresyonu karşılaştıran güncel çalışmalar, özellikle karmaşık etkileşimlerin ve yüksek mekânsal heterojenliğin söz konusu olduğu kentsel piyasalarda, ML tabanlı yaklaşımların daha düşük hata ve daha iyi genelleme performansı sunabildiğini göstermektedir [16].

4.4 Güçlü ve Zayıf Yönler

Bu çalışmanın başlıca güçlü yönleri arasında, tüm özniteliklerin yalnızca geçmiş bilgilere dayanması sayesinde *ileri bakış* sızıntısının sistematik olarak önlenmesi; üretim ortamında öznitelik şemasının (`.features.json`) dondurulmasıyla eğitim ve çıkarım aşamaları arasındaki hizanın korunması ve buna bağlı olarak şema kayması riskinin azaltılması sayılabilir. Ayrıca, SHAP tabanlı açıklanabilirlik analizi ile Moran's I istatistiğinin birlikte kullanılması, model çıktılarının hem değişken katkıları hem de mekânsal artık örüntüleri açısından çok yönlü biçimde denetlenmesine olanak sağlamıştır.

Buna karşılık, çalışmanın bazı sınırlılıkları da bulunmaktadır. Dükkan ve Arsa türlerinde görece küçük örneklem büyüklükleri ve düşük ST-lag kapsaması, tahmin varyansını ve yüksek hata kuyruk riskini artırmaktadır. İlan metninden türetilen bazı nitelikler, veri kaynağının heterojenliği nedeniyle eksik veya gürültülü kalabilmekte; bu durum özellikle metinsel özelliklerin model katkısını sınırlayabilmektedir. Ayrıca, sabit TL eşiklerine dayalı `fiyat_bandı` (`price_band`) tanımı, yerel fiyat rejimleri ve enflasyon dinamikleriyle her zaman

hizalanamadığından, bazı alt popülasyonlarda istenmeyen kalibrasyon etkilerine yol açabilmektedir.

Bu yönleriyle önerilen yaklaşım, konut fiyat modellemesinde mekânsal bağımlılığın tanısal olarak incelenmesini savunan önceki çalışmalarla uyumlu bir çerçeve sunmaktadır [27, 28]. Özellik üretiminin yalnızca geçmiş bilgilere dayandırılması ve zaman sıralı doğrulama rejiminin benimsenmesi ise, denetimli öğrenme uygulamalarında sıkça raporlanan veri sızıntısı senaryolarını önlemeye yönelik iyi uygulamalarla örtüşmektedir [33].

4.5 Uygulama Çıkarımları ve Politika

Pratik devreye alım senaryoları için, ilçe bazlı MAE ve MAPE değerleri ile yüksek hata kuyruk oranlarının ($\text{Out}_{\geq 0.50}$, $\text{Out}_{\geq 0.75}$) düzenli olarak izlenmesi önerilmektedir. Buna ek olarak, mekânsal-zamansal komşuluk sinyalinin (ST-lag) kapsama oranının ve `fiyat_bandı` (`price_band`) dağılımının operasyonel panolarda görünür tutulması, model davranışındaki olası sapmaların erken aşamada tespit edilmesine katkı sağlayacaktır.

Fiyat bandı eşiklerinin, sabit TL değerleri yerine enflasyona (TÜFE/KFE) veya dağılıma dayalı (örneğin kantil bazlı) biçimde dinamik olarak yönetilmesi, özellikle yerel piyasa koşullarına duyarlılığı artırabilir. Bu tür bir yaklaşım, band bilgisinin bazı alt bölgelerde olumsuz kalibrasyon etkileri üretmesini sınırlandırmaya yardımcı olabilir.

Modelin haftalık veya aylık periyotlarla yeniden eğitilmesi, sürümleme ve performans takibiyle birlikte yönetilmelidir. Özellikle mevzuat, ihale kuralları veya piyasa rejimlerinde meydana gelen yapısal değişim noktalarında, yeniden eğitim ve doğrulama sıklığının artırılması yerinde olacaktır. Kurumsal kullanım bağlamında, model çıktıları yalnızca nihai tahminler olarak değil; muhammen bedel güncellemeleri, teminat oranları ve ihale zamanlamasına ilişkin kararlar için erken uyarı göstergeleriyle birlikte bir karar destek aracı olarak değerlendirilebilir.

5
SONUÇ

Bu tez, Türkiye'de UYAP e-Satış ihalelerinde *nihai satış bedelini* (dolayısıyla ihale indirimi veya primini) öngörmek üzere, sızıntı-güvenli bir uçtan uca modelleme çerçevesi sunmaktadır. Hedef değişken olarak, dönemsel ve ölçek kaynaklı farklara dayanıklı olacak biçimde tanımlanan **DIFF** ölçütü kullanılmıştır (bkz. Denklem 1.1). Bu çerçevede, veri toplama ve temizleme aşamalarından başlayarak, yalnızca *geçmiş* gözlemlere dayalı özellik inşasını (ST-lag ve makro reelleştirme) ve CatBoost tabanlı modellemeyi kapsayan bütüncül bir iş akışı tasarlanmıştır.

Eğitim aşamasında kullanılan öznitelik şeması, yan bir dosyada (`.features.json`) dondurulmuş ve çıkarım ile SHAP analizleri sırasında yeniden yüklenmiştir; bu yaklaşım sayesinde üretim ortamında *şema kayması* riski sistematik olarak azaltılmıştır. Temel deneyler, karşılaştırılabilirliği artırmak amacıyla, yalnızca *tam pay* (`share`≈ 1.0) kayıtlar üzerinden yürütülmüştür.

5.1 Bulgular ve Katkılar

Konut türünde ana model olan **CatBoost–DIFF**, test kesitinde $R^2 \approx 0.70$ ve MAE $\approx$ 1.19 milyon TL düzeyinde bir performans üretmiştir ($n = 868$; Tablo 3.2). `fiyat_bandı` (`price_band`) bilgisinin eklenmesi (DIFF+band), küresel ölçekte *sınırlı* bir ilave katkı sağlamış; RMSE çok küçük ölçüde düşerken, R^2 benzer kalmış / marjinal değişmiştir, MAE ve MAPE değerleri ise marjinal biçimde artmıştır.

Dükkan türünde DIFF+band, yüzdesel hatayı azaltmasına karşın RMSE'nin artmasına ve R^2'nin düşmesine yol açmıştır (Tablo 3.3). Arsa türünde ise varyans belirgin biçimde azalmış ve açıklanan varyans anlamlı ölçüde yükselmiştir (Tablo 3.4). Bu desen, taşınmaz türleri arasındaki ST-lag kapsama farklarıyla uyumludur (Konut $\sim$%83.3, Dükkan $\sim$%63.5, Arsa $\sim$%37.6).

Konut'ta DIFF ile DIFF+band arasındaki MAE farkı yaklaşık 24 bin TL olup,

bu değer temel MAE seviyesinin yaklaşık $\sim$%2'sine karşılık gelmektedir. Söz konusu farkın istatistiksel anlamlılığı bu çalışmada ayrıca sınanmamış, bulgular operasyonel etki büyüklüğü bağlamında yorumlanmıştır.

Bu çalışmada **RATIO** hedefi, oransal farkın log-uzayında yumuşatılmış bir temsili olarak $\log(1 + \frac{\text{bid}}{\text{est_val}})$ biçiminde tanımlanmıştır. Konut türünde **RATIO**, beklenenden *yakın* bir performans sergilemiştir: R^2 değeri DIFF'e kıyasla biraz daha yüksek (0.72), MAE değeri DIFF ile neredeyse aynıdır (≈ 1.20 milyon TL), MAPE ise DIFF'ten marjinal düzeyde büyüktür (%25.81 *vs.* %24.97).

Buna karşılık **ABS** ($\log(1 + \text{bid})$), muhammen değere göre bir normalizasyon içermediğinden, TL ölçeğinde gözlenen heteroskedastisiteyi yeterince bastıramamış ve kalibrasyon ölçütlerinde daha zayıf sonuçlar üretmiştir (örneğin PRD $\approx$ 1.27–1.33). Dükkan ve Arsa türlerinde de genel tablo, **DIFF** ailesinin kalibrasyon–varyans dengesi açısından daha güvenli bir varsayılan hedef olduğunu göstermektedir. Bu bulgular, ana analizlerde DIFF hedefinin kullanılmasının hem metodolojik olarak gerekçeli hem de ampirik olarak destekli olduğunu ortaya koymaktadır.

Esenyurt kırılımı (Konut, $n = 112$), fiyat bandı bilgisinin her alt bölgede aynı yönde iyileştirme üretmeyebileceğini göstermiş; DIFF modeli, DIFF+band'e kıyasla daha düşük MAE ve MAPE değerleri üretmiştir (Tablo 3.5). Tekil vaka örnekleri de band etkisinin fiyat dilimine ve mahalleye göre yön değiştirebildiğini ortaya koymaktadır.

Artıkların mekânsal bağımlılığı, Moran's I istatistiği ile incelendiğinde, Konut türünde DIFF ve RATIO hedefleri için anlamlı bir mekânsal bağımlılık saptanmamış; ABS hedefi için ise bulgunun sınırda bir anlamlılık düzeyine yaklaştığı görülmüştür (DIFF: $I = 0.0009$, $p \approx 0.415$; RATIO: $I = -0.0028$, $p \approx 0.545$; ABS: $I = 0.0622$, $p \approx 0.050$). Bu sonuçlar, ana modelleme şemasında belirgin bir *eksik mekânsal modelleme* olmadığını desteklemekte; buna karşın mekânsal denetimin daha geniş veri setleriyle tekrarlanmasının yararlı olabileceğini düşündürmektedir.

Sonuç olarak bu çalışma, (i) yargı ihaleleri bağlamında dönem ve ölçek farklarına dayanıklı bir hedef tanımını (DIFF) ve sızıntı-güvenli ST-lag üretimini, (ii) makro reelleştirme (TÜFE/KFE) ve zaman kodlarıyla dönemsel karşılaştırılabilirliği, (iii) üretim ortamına uygun öznitelik kilitleme ve tekrarlanabilirliği, (iv) açıklanabilirlik (SHAP) ve mekânsal artık denetimini (Moran's I) bir araya getirerek, uygulamaya dönük ve devreye alıma uygun bir otomatik değerleme modeli (AVM) çerçevesi sunmaktadır.

5.2 Gelecek Çalışmalar

Bu tezde elde edilen bulgular ve gözlenen sınırlılıklar doğrultusunda, aşağıdaki araştırma ve geliştirme başlıkları gelecek çalışmalar için öncelikli görülmektedir:

Dinamik fiyat bantları: Sabit TL eşiklerine dayalı `fiyat_bandı` (`price_band`) tanımı yerine, TÜFE/KFE ile endekslenen veya veri dağılımına dayalı (kantil bazlı) dinamik bantların kullanılması, özellikle yerel piyasa koşullarına duyarlılığı artırabilir. Bu yaklaşımın, bazı alt bölgelerde gözlenen kalibrasyon sapmalarını azaltıp azaltmadığı sistematik olarak test edilmelidir.

İstatistiksel anlamlılık ve belirsizlik analizi: Model varyantları arasındaki küçük farkların örnekleme oynaklığından ayrıştırılabilmesi için, eşleştirilmiş bootstrap ile $\Delta\mathrm{MAE}$ ve $\Delta\mathrm{RMSE}$ güven aralıklarının raporlanması; permütasyon testleriyle yönlü hata farklarının sınanması, bulguların istatistiksel gücünü artıracaktır.

Genişletilmiş mekânsal modelleme: ST-lag sinyalinin yarıçap ve zaman penceresi parametrelerinin uyarlanabilir biçimde öğrenilmesi; çok ölçekli komşuluk tanımları veya uzamsal gömlemeler (uzamsal temsil vektörleri) ile daha zengin mekânsal temsillerin kullanılması, özellikle Arsa ve Dükkan türlerinde performansı iyileştirebilir.

Metinsel ve görsel öznitelikler: İlan metinlerinden elde edilen niteliklerin ön-eğitimli dil modelleriyle zenginleştirilmesi veya uydu/sokak görüntülerinden türetilen görsel sinyallerin modele entegre edilmesi, heterojen özelliklere sahip taşınmazlar için tamamlayıcı bilgi sağlayabilir.

Zaman içi güncelleme ve kavramsal kayma: Piyasa rejimlerinde veya ihale kurallarında oluşabilecek kavramsal kaymayı izlemek amacıyla, periyodik yeniden eğitim, performans izleme panoları ve erken uyarı eşikleri içeren bir Makine Öğrenmesi Operasyonları (Machine Learning Operations; MLOps) çerçevesinin kurulması önerilmektedir.

Kurumsal karar destek entegrasyonu: Model çıktılarının yalnızca nihai tahmin olarak değil; muhammen bedel revizyonu, teminat oranı belirleme ve ihale

zamanlaması gibi süreçlerde karar destek sinyalleri olarak kullanılması, uygulama değerini artırabilir.

Bu başlıklar doğrultusunda yapılacak çalışmalar, önerilen çerçevenin hem akademik katkısını hem de kurumsal ölçekteki uygulanabilirliğini daha da güçlendirecektir.

KAYNAKÇA

[1] Ö. G. Erbulut Z. Çolak, "A hybrid machine learning approach for housing price prediction: the stacking regressor method," *International Journal of Housing Markets and Analysis*, no. ahead-of-print, 2025.

[2] J. Hong ve diğ., "An application of XGBoost, LightGBM, CatBoost algorithms on house price appraisal system," *Housing Finance Research*, c. 4, ss. 33–64, 2020.

[3] A. H. Erciyes, T. Atasoy, A. Tursun S. Canaz Sevgen, "Learning the Value of Place: Machine Learning Models for Real Estate Appraisal in Istanbul's Diverse Urban Landscape," *Buildings*, c. 15, no. 15, s. 2773, 2025.

[4] T. Wang, Y. Wang M. Liu, "A price prediction method based on CatBoost," *2021 International Conference on Culture-oriented Science & Technology (ICCST)*, IEEE, 2021, ss. 403–408.

[5] B. N. Tunç Ü. H. Atasever, "CatBoost algoritmasının taşınmaz değerlemede kullanımı: Bayesian hiperparametre optimizasyonu ile karşılaştırmalı analiz," *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, c. 14, no. 2, ss. 668–679, 2025.

[6] L. Prokhorenkova, G. Gusev, A. Vorobev, A. V. Dorogush A. Gulin, "CatBoost: unbiased boosting with categorical features," *Advances in neural information processing systems*, c. 31, 2018.

[7] J. T. Hancock T. M. Khoshgoftaar, "CatBoost for big data: an interdisciplinary review," *Journal of big data*, c. 7, no. 1, s. 94, 2020.

[8] H. Donner, H.-S. Song M. Wilhelmsson, "Forced sales and their impact on real estate prices," *Journal of Housing Economics*, c. 34, ss. 60–68, 2016.

[9] H. Donner, "Determinants of a foreclosure discount," *Journal of Housing and the Built Environment*, c. 35, no. 4, ss. 1079–1097, 2020.

[10] C. Elgin, "Auction structure and court-ordered real estate sale outcomes: evidence from co-ownership dissolution cases in Turkey," *European Journal of Law and Economics*, ss. 1–26, 2025.

[11] N. Bu, W. Shen X. Guo, "From premium to discount: A quasi-natural experiment in Shanghai's judicial auction housing market," *Finance Research Letters*, c. 77, s. 107 058, 2025.

[12] W. Qu Y. Huang, "Judicial auction housing discounts and housing segments interaction: Evidence from China," *Habitat International*, c. 146, s. 103 053, 2024.

[13] S. Rosen, "Hedonic prices and implicit markets: product differentiation in pure competition," *Journal of political economy*, c. 82, no. 1, ss. 34–55, 1974.

[14] S. Selim, "Determinants of house prices in Turkey: A hedonic regression model," *Doğuş Üniversitesi Dergisi*, c. 9, no. 1, ss. 65–76, 2008.

[15] P. F. Gebeşoğlu, "Housing price index dynamics in Turkey," *Yaşar Üniversitesi E-Dergisi*, c. 14, ss. 100–107, 2019.

[16] M. Gorjian, "Integrating machine learning and hedonic regression for housing price prediction: A systematic international review of model performance and interpretability," 2025.

[17] A. Soltani, M. Heydari, F. Aghaei C. J. Pettit, "Housing price prediction incorporating spatio-temporal dependency into machine learning algorithms," *Cities*, c. 131, s. 103 941, 2022.

[18] A. T. İlhan S. Öz, "Türkiye'de emlak vergi değerinin toplu değerleme sistemi ile belirlenmesi," *Maliye Çalışmaları Dergisi*, no. 64, ss. 73–92, 2020.

[19] A. Kara, V. Çağdaş Ü. Işıkdağ, "Taşınmaz Değerlemesinde Uluslararası Bir Standarda Doğru," *16. Türkiye Harita Bilimsel ve Teknik Kurultayı*, TMMOB Harita ve Kadastro Mühendisleri Odası, Ankara, Türkiye, May. 2017.

[20] A. T. İlhan S. Öz, "Yapay sinir ağlarının gayrimenkullerin toplu değerlemesinde uygulanabilirliği: Gölbaşı ilçesi örneği," *Hacettepe Üniversitesi Sosyal Bilimler Dergisi*, c. 2, no. 2, ss. 160–188, 2020.

[21] Y. Arslan, B. Güler T. Taşkin, *Joint Dynamics of House Prices and Foreclosures*. Türkiye Cumhuriyet Merkez Bankasi, 2014.

[22] M. F. Toprak O. Güngör, "Kayseri'de çoklu regresyon ve coğrafi ağırlıklı regresyon yöntemleri ile konutların toplu değerlemesi," *Türk Uzaktan Algılama ve CBS Dergisi*, c. 4, no. 1, ss. 114–124, 2023.

[23] S. Csicsman A. Ç. Aydınoğlu, "Toplu Taşınmaz Değerlemesi için Coğrafi Verinin İşlenmesi ve Rastgele Orman Makine Öğrenmesi Tekniğiyle Tahmin Modelinin Geliştirilmesi," *Harita Dergisi*, c. 169, ss. 13–27, 2023.

[24] C. Bentéjac, A. Csörgő G. Martínez-Muñoz, "A comparative analysis of gradient boosting algorithms," *Artificial Intelligence Review*, c. 54, no. 3, ss. 1937–1967, 2021.

[25] J. Duarte, C. S. Jones, M. Khorram, H. Mo J. L. Wang, "Too good to be true: Look-ahead bias in empirical options research," *Available at SSRN 4590083*, 2023.

[26] C. Bergmeir, R. J. Hyndman B. Koo, "A note on the validity of cross-validation for evaluating autoregressive time series prediction," *Computational Statistics & Data Analysis*, c. 120, ss. 70–83, 2018.

[27] O. Moralı N. Yılmaz, "An analysis of spatial dependence in real estate prices," *The journal of real estate finance and economics*, c. 64, no. 1, ss. 93–115, 2022.

[28] A. Soltani, C. J. Pettit, M. Heydari F. Aghaei, "Housing price variations using spatio-temporal data mining techniques," *Journal of Housing and the Built Environment*, c. 36, no. 3, ss. 1199–1227, 2021.

[29] C. Sheng H. Yu, "An optimized prediction algorithm based on XGBoost," *2022 international conference on networking and network applications (NaNA)*, IEEE, 2022, ss. 1–6.

[30] Y. Zhao, G. Chetty D. Tran, "Deep learning with XGBoost for real estate appraisal," *2019 IEEE symposium series on computational intelligence (SSCI)*, IEEE, 2019, ss. 1396–1401.

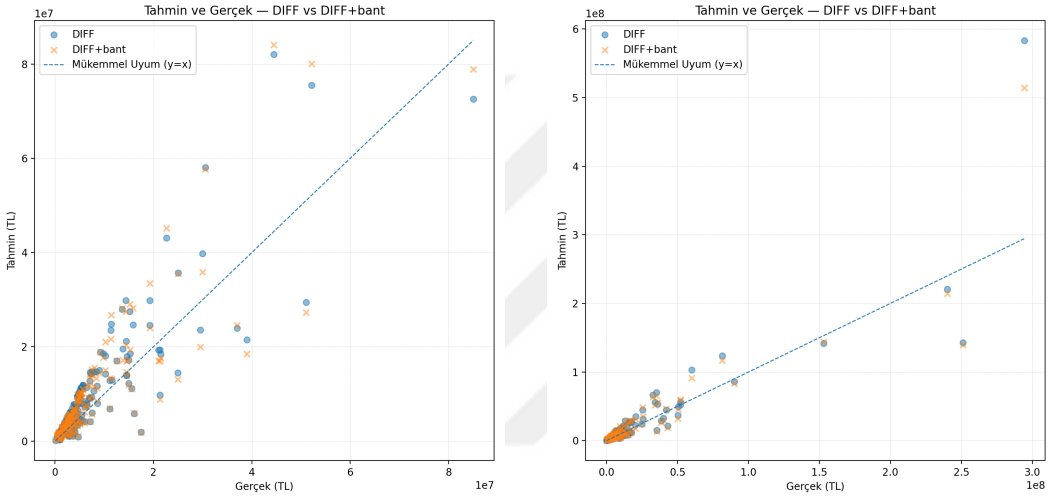
[31] M. Jain, "House price prediction with Convolutional Neural Network (CNN)," *World Journal of Advanced Engineering Technology and Sciences (WJAETS), World Journal of Advanced Engineering Technology and Sciences*, c. 8, no. 1, ss. 10–30 574, 2023.

[32] M. A. Shbool, R. Al-Dmour, B. A. Al-Shboul, N. T. Albashabsheh N. Almasarwah, "Real estate decision-making: precision in price prediction through advanced machine learning algorithms," *International Journal of Housing Markets and Analysis*, 2025.

[33] L. Sasse ve diğ., "Overview of leakage scenarios in supervised machine learning," *Journal of Big Data*, c. 12, no. 1, s. 135, 2025.

A Ekler

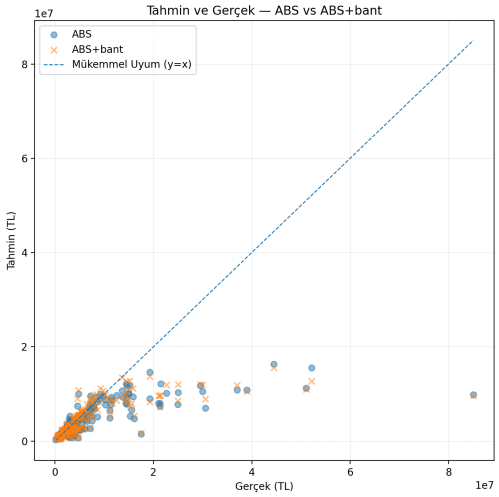
A.1 DIFF ve DIFF+band Karşılaştırmaları (Dükkan/Arsa)



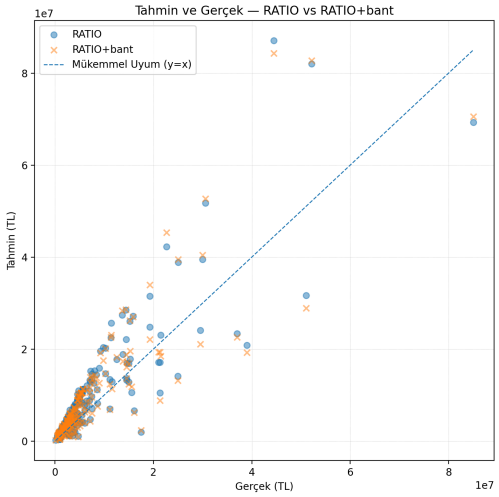
DIFF vs. DIFF+band (Dükkan) DIFF vs. DIFF+band (Arsa)

Şekil A.1 DIFF türü için Dükkan/Arsa karşılaştırma grafikleri (test kesiti).

A.2 ABS/RATIO Karşılaştırmaları (Dükkan)



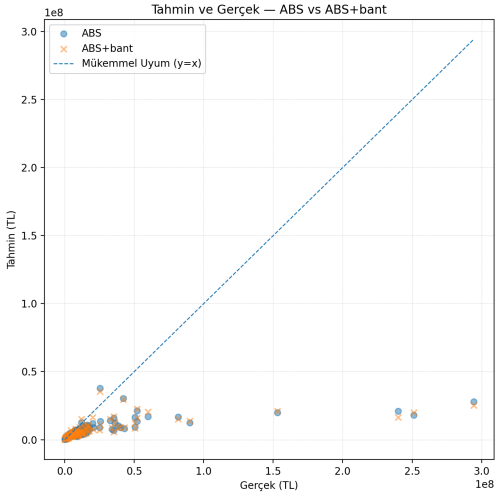
ABS vs. ABS+band (Dükkan)



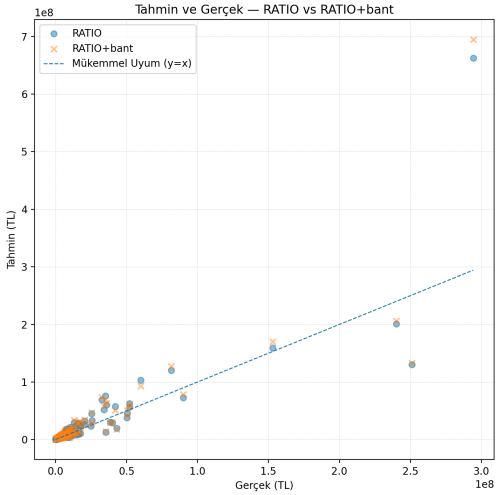
RATIO vs. RATIO+band (Dükkan)

Şekil A.2 Dükkan türü için ABS/RATIO karşılaştırma grafikleri (test kesiti).

A.3 ABS/RATIO Karşılaştırmaları (Arsa)



ABS vs. ABS+band (Arsa)



RATIO vs. RATIO+band (Arsa)

Şekil A.3 Arsa türü için ABS/RATIO karşılaştırma grafikleri (test kesiti).

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirisi

1. Predicting Hammer Prices in Judicial Real-Estate Auctions on UYAP: A Leakage-Safe CatBoost Baseline with Robust Targeting. In *Proceedings of the 16th International Conference on Electrical and Electronics Engineering (ELECO)*, 2025. IEEE Xplore.