

Erzurum ili örneğinde konutların değeri ve özellikleri arasındaki ilişkilerin XGBoost makine öğrenmesi algoritması ile analizi

Analyzing the relationships between value and attributes of residential real estate in Erzurum province using the XGBoost machine learning algorithm

Ayşe YAVUZ ÖZALP*¹, Halil AKINCI¹, Ali MUTİ²

¹Artvin Çoruh Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 08100, Artvin

²Tapu ve Kadastro Genel Müdürlüğü, Yakutiye Tapu Müdürlüğü, 25100, Erzurum

• Geliş tarihi / Received: 19.11.2025

• Kabul tarihi / Accepted: 12.05.2026

Öz

Konut pazar değerinin tahmininde makine öğrenmesi algoritmalarının kullanımı, geleneksel istatistiksel modellere kıyasla daha etkili ve başarılı sonuçlar elde etme olanağı sağlamaktadır. Bu çalışmada, XGBoost algoritması kullanılarak Erzurum İli Yakutiye İlçesi örneğinde konut pazar değerinin tahmin edilmesi ve pazar değerini etkileyen başlıca özelliklerin ortaya konulması amaçlanmıştır. Bu doğrultuda, 2024 yılında satışı gerçekleşen ve pazar değerine ulaşılabilen 101 konuttan oluşan veri seti analiz edilmiştir. XGBoost algoritmasıyla geliştirilen model sonuçlarına göre, çalışma alanında konut pazar değeri üzerinde özellikle emlak beyan değeri, net alan (m²), bina yaşı, konut fiyat indeksi değeri ve bulunduğu katın belirleyici olduğunu, üniversiteye yakınlık, banyo sayısı, konutun en üst katta bulunması, yönü ve şehir hastanesine yakınlık gibi özelliklerin ise görece daha az etkili olduğu belirlenmiştir. Model performansı, literatürde yaygın olarak kullanılan belirleme katsayısı (R²), ortalama mutlak yüzde hata (MAPE), kök ortalama kare hatası (RMSE) ve ortalama mutlak hata (MAE) metrikleri kullanılarak değerlendirilmiştir. Elde edilen sonuçlara göre modelin R² değeri 0,76, MAPE değeri %17,77, RMSE değeri 515.240,58 ve MAE değeri 405.611,09 olarak hesaplanmıştır. Bu bulgular, çalışma kapsamında ele alınan konut özelliklerinin, konut pazar değerindeki değişimin %76'sını açıkladığını ve XGBoost algoritmasının konut değerlendirme çalışmalarında kabul edilebilir yeterlilikte performans sağladığını göstermektedir. Bununla birlikte veri setinin genişletilmesiyle başarı performansının daha da artacağı düşünülmektedir. Konutların değer-özellik ilişkisinin mekâna, veri setine ve lokal dinamiklere bağlı olarak değişmesi, çalışmaların farklı coğrafyalarda yapılmasının önemini göstermektedir. Çalışma sonuçlarının yatırımcılar, konut sahipleri, emlakçılar gibi sektörün tüm aktörlerine yön gösterici olması umulmaktadır.

Anahtar kelimeler: Gerçekleşmiş satış fiyatı, Konut pazar değeri, Makine öğrenmesi, Taşınmaz değerlendirme, XGBoost

Abstract

The use of machine learning algorithms in residential market value prediction has enabled more effective and successful results compared to traditional statistical models. This study aims to predict residential market values and reveal the principal features affecting market value in the case of Yakutiye District, Erzurum Province, using the XGBoost algorithm. In this context, a dataset comprising 101 residential properties sold in 2024, for which market value data were available, was analyzed. According to the model results created by the XGBoost algorithm, the property tax value, net floor area (m²), building age, housing price index value, and floor level are the most influential determinants of residential market value in the study area, while features such as proximity to the university, number of bathrooms, top-floor position, aspect, and proximity to the city hospital have a relatively less significant impact. Model performance was evaluated using metrics typically used in the literature, including the coefficient of determination (R²), mean absolute percentage error (MAPE), root mean square error (RMSE), and mean absolute error (MAE). According to the results obtained, the model's R² value was calculated as 0,76, the MAPE value as 17,77%, the RMSE value as 515.240,58, and the MAE value as 405.611,09. These results demonstrate that the housing characteristics considered in the study explain 76% of the variation in residential market value, and that the XGBoost algorithm provides acceptable performance in residential valuation studies. However, it is believed that the expansion of the data set will increase further performance. The fact that the value-feature relationship of real estate varies depending on location, data set, and local dynamics, the importance of conducting studies in different geographical areas becomes apparent. It is hoped that the results of this study will guide all stakeholders in the sector, such as investors, homeowners, and real estate agents.

Keywords: Actual sales price, Residential market value, Machine learning, Real Estate Valuation, XGBoost

* Ayşe YAVUZ ÖZALP; ayavuzozalp@artvin.edu.tr

1. Giriş

1. Introduction

Konut, temel insan haklarından biri olan barınma ihtiyacını karşılayan, güvenli ve yüksek getirili bir yatırım imkânı sunan ve yapısal, çevresel, konumsal açıdan farklı özellikleri olan dolayısıyla da heterojen bir yapıya sahip ekonomik bir maldır. Konut, aynı zamanda gıda, ulaşım, giyim, eğitim ve kültür gibi hane halkının temel ihtiyaçları listesinde önemli bir kalemdir ve hane halkı gelirinin büyük bir yüzdesini oluşturur (Yılmaz vd., 2018). Dünyadaki en büyük ekonomik segmentlerden biri olan gayrimenkul piyasası; arz, talep, ekonomi, hükümet politikaları, sosyoloji, topoğrafya, finans, teknoloji gibi faktörlerle iç içe olan ve birbirini şekillendiren dinamik, çok boyutlu ve çok disiplinli bir kavramdır (Ancy & Praveenchandar, 2025; Zeydan, 2025). Bu kapsamda, pazar değeri açısından ekonomik bağlamda önemli olan konut fiyatlarının, doğru ve gerçekçi tahmin edilmesi başta alıcılar olmak üzere sektörün tüm paydaşları ve ülkelerin ekonomik istikrarı için gerekli ve oldukça önemlidir (Gündoğmuş vd., 2022; Zeydan, 2025).

Kişilerin, isteklerine uygun konutu doğru fiyata alabilme ve yaşamları boyunca yaptıkları birikimlerini konuta bağlama çabaları, gayrimenkule göre doğru fiyat tahmini yapan sistemlerin büyük önem taşımaya ve konut değerlendirme çalışmalarının bireyler açısından da oldukça önemli olmasına neden olmaktadır (Aydemir vd., 2020; Oral vd., 2021). Dolayısıyla hakkaniyetli ve gerçekçi bir konut değerlendirme süreci gerek ülke gayrimenkul pazarının canlanmasını gerek taşınmaz dayalı uygulamaların başarıyla gerçekleştirilebilmesini gerekse dinamik gayrimenkul sektöründe bilgiye dayalı karar vermeyi mümkün kılmaktadır (İban, 2021; Mathotaarachchi vd., 2024). Gayrimenkul değerlemesi, alıcı ve satıcı gibi piyasanın tüm aktörleri için gayrimenkulün adil ve kabul edilebilir piyasa değerini belirleme sürecidir (Çılgin & Gökçen, 2023). Bu süreç; değeri etkileyen özelliklerin belirlenmesi, güncel ve yeterli sayıda veri seti, örneklem grubu, gerçekçi piyasa değerlerinin temini, uygun yöntem seçimi, doğrulama gibi birçok aşamadan oluşan çok boyutlu bir süreçtir. Bu bağlamda, mesken amaçlı kullanılan gayrimenkulleri değerlendirme; (i) konutun değerini etkileyen çok sayıda özelliğin olması ve bu özelliklerin zamana, kişiye ve mekana bağlı olarak değişmesi, (ii) 2020’li yıllarda hala taşınmaz alım/satımında devlete “gerçekdışı beyanda bulunma” inisiyatifinin sürmesi, (iii) taşınmazın nitelik ve gerçek satış verilerini içeren bir veri tabanının henüz tesis edilememiş olması, (iv) mevcut verilere erişim kısıtlılığı, (v) gerçek satış fiyatlarına ulaşmada çok fazla gayret sarf edilmesi ve (vi) serbest piyasa ekonomisi nedeniyle aynı şehirde benzer evler arasında bile büyük fiyat farklılıklarının oluşması gibi faktörler (Aydemir vd., 2020; Sevgen & Tanrıvermiş, 2020; Gündoğmuş vd., 2022; Yavuz Özalp & Akinci, 2024) dikkate alındığında daha da zorlaşmaktadır. Bu nedenle, adil, doğru ve gerçekçi bir konut fiyat tahmini elde etmek ve konut değerlemelerinde kişiye özgü özellik ve yanlılıktan kaçınmak için doğru konut değerlendirme modelleri geliştirme ihtiyacı her geçen gün artmaktadır (Yazdani, 2021; Çılgin & Gökçen, 2023).

Gelinen noktada, süreci kolaylaştırma ve fiyat tahmin doğruluğunu artırma bağlamında, gelişen bilgi teknolojilerine bağlı olarak özellikle son dönemlerde arazi uygunluk değerlendirmesi (Yavuz Özalp & Akinci, 2023), duyarlılık haritalaması (Akinci vd., 2021; Alkan Akinci vd., 2024) ve risk değerlendirmesi (Fidanboy vd., 2022; Tan & Feng, 2023) gibi çeşitli alanlarda kullanımı yaygın olan makine öğrenmesi (Machine Learning, ML) algoritmalarının taşınmaz değerlemede de klasik modelleme yöntemlerine alternatif olması önemli fırsat doğurmaktadır (Ceh vd., 2018; Louati vd., 2021). Literatür incelendiğinde, farklı coğrafyalarda konut fiyatını etkileyen özellikleri ya da farklı ML algoritmalarının konut değer tahmin performanslarını araştıran çok sayıda çalışma olduğu, bununla birlikte Türkiye’de yapılan çalışmaların sınırlı sayıda olduğu (Tablo 1) görülmektedir. Bu çalışmalarda, ML algoritmalarının ya tek başına ya da karşılaştırmalı (iki ya da daha fazla) olarak kullanıldığı (Ravikumar, 2016; Ceh vd., 2018; Aydınoglu vd., 2021; Yavuz Özalp & Akinci, 2024) ve üretilen bu modellerde ana amacın konutun değeri üzerinde etkili olan özelliklerin belirlenerek değer tahminlerinin iyileştirilmesi olduğu söylenebilir (Bilgilioğlu & Yılmaz, 2021).

Öte yandan literatürde sadece kullanılan yöntem ve özelliklerde farklılık olmadığı aynı zamanda veri temini bağlamında da farklılık olduğu göze çarpmaktadır. Veri temini bağlamında, bazı çalışmalarda (Hayrulloğlu vd., 2018; Alkan vd., 2023; Çılgin & Gökçen, 2023) internette yer alan satılık konut ilanlarından dolayısıyla talep edilen satış fiyatları kullanılırken, bazı çalışmalarda (Saraç, 2012; Tabanoğlu, 2019; Esen & Tokgöz, 2021) Sermaye Piyasası Kurulu (SPK) lisanslı değerlendirme uzmanlarınca hazırlanan değerlendirme raporları, bazı çalışmalarda (İban, 2021; Oral vd., 2021) ise kaggle gibi internette açık olarak sunulan veri depolama platformları kullanılmıştır. Bunların yanı sıra emlakçılardan ya da alıcı ve satıcılardan temin edilen konut fiyatları kullanılan çalışmalar da (Muti & Dursun, 2022; Yavuz Özalp & Akinci, 2024) bulunmaktadır.

Tablo 1. Türkiye’de ML algoritmalarıyla konut özellikleri/fiyat ilişkisini araştıran çalışmalar
Table 1. Literatures investigating the relationship between house attributes and prices using ML algorithms in Türkiye

Yazar	ML algoritma	Çalışma alanı	Yazar	ML algoritma	Çalışma alanı
Savaş (2019)	Destek Vektör Makineleri Çoklu Linear Regresyon	Gölbaşı/ Ankara	Tabanoğlu (2019)	Yapay Sinir Ağları Regresyon Analizi	Düzce
Altun (2022)	Yapay Sinir Ağları	Etimesgut/ Ankara	Yücebaş vd. (2022)	CART karar ağacı modeli	Çanakkale
Doğan vd. (2022)	Yapay Sinir Ağları	Keçiören / Ankara	Özdemir vd. (2022)	Yapay Sinir Ağları Polinomal Regresyon Random Forest	Sakarya
Mete & Yomralıoğlu (2022)	XGBoost CatBoost LightGBM Random Forest Nominal Değerleme	İstanbul, İzmir	Tekin & Sarı (2022)	Lineer Regresyon Polinom Regresyon Karar Ağaçları Random Forest XGBoost	İstanbul
Aydinoğlu vd. (2023)	Çoklu Doğrusal Regresyon Genel Doğrusal Model Destek Vektör Makineleri Karar Ağaçları Rastgele Orman	Pendik/ İstanbul	Burhan (2023)	Naive Bayes k-En Yakın Komşuluk Karar Ağaçları Rastgele Orman	Kütahya
Türkan vd. (2023)	Lineer Regresyon, Yapay Sinir Ağları Regresyon Ağaçları, Destek Vektör Regresyonu Gauss Süreç Regresyonu	Niğde	Narin vd. (2023)	Çoklu Regresyon Analizi Yapay Sinir Ağları	Keçiören/ Ankara
Şişman & Aydınoğlu (2023)	Rastgele Orman Çoklu Linear Regresyon	İstanbul Kocaeli	Doğan vd. (2023)	Yapay Sinir Ağları	Yenimahalle
Akyüz vd. (2023)	Destek Vektör Makineleri K-means clustering K-NN classification	Kadıköy/ İstanbul	Alkan vd. (2023)	k-En Yakın Komşuluk Random Forest Destek Vektör Makineleri	Alanya/ Antalya
Hazer vd. (2024)	Topluluk Regresyonu, Çekirdek Regresyonu, Doğrusal Regresyon, Destek Vektör Regresyonu İkili Karar Ağacı Regresyonu	Yozgat	Kara (2024)	Gauss Süreç Regresyonu Destek Vektör Makinaları Rastgele Orman Doğrusal Regresyon Karar Ağaçları Topluluk Torbalı Ağaç	Giresun
Yavuz Özalp & Akinci (2024)	Rastgele Orman Gradyan Artırma Makinaları AdaBoost XGBoost	Artvin	Doğan vd. (2024)	Karar Ağaçları	Adana
Alkan vd. (2024)	Karar Ağacı k-En Yakın Komşu Yapay Sinir Ağları Rastgele Orman	Konya	Okurlar & Eroğlu (2025)	AdaBoost Gradyan Artırma k-En Yakın Komşuluk Yapay Sinir Ağları Destek Vektör Makineleri	Gaziantep

ML algoritmalarının klasik yöntemlerden temel farkı, karmaşık ve büyük veri setlerini analiz ederek örüntüleri tanımlama ve mantıklı öngörülerde bulunabilme yeteneklerine sahip olması, modelin bir dizi talimat yerine girdi verilerinden tasarlanması (Louati vd., 2021; Adetunji vd., 2022; Hazer vd., 2024), çeşitli algoritmalar kullanılarak seçilen çalışma alanındaki mevcut veri setiyle eğitilmiş modellerin oluşturulması ve geçmiş deneyimlerden bilgi edinme sürecini içermesi nedeniyle güvenilir tahminler yapabilmesidir (İban, 2021; Sharma vd., 2024). Aynı zamanda konut değerlerinin belirlenmesinde çok sayıda özelliklerin bulunması ve karmaşık veri desenlerini analiz etme konusundaki üstün yeteneği, bu alanda makine öğrenmesi ve derin öğrenme modellerini daha çekici hale getirmektedir (Çılgin & Gökçen, 2023; Hoxha, 2023).

Tablo 1’den de anlaşılacağı üzere, ML algoritmalarından Yapay Sinir Ağlarının yaygın olarak kullanıldığı ve toplu değerlendirme için iyi sonuçlar verdiği araştırmacılarca belirtilmektedir. Bununla birlikte son yıllarda yapılan birçok çalışmada (Hjort vd., 2022; Zaki vd., 2022; Çılgin & Gökçen, 2023; Jafary vd., 2024; Sharma vd., 2024; Yavuz Özalp & Akinci, 2024) XGBoost gibi ağaç tabanlı topluluk öğrenme algoritmalarının diğer algoritmalara göre daha iyi performans gösterdiği vurgulanmaktadır. Bu noktada XGBoost algoritmasının az sayıda veri olması durumunda performansının incelenmesi ve özellikle lokal dinamikleri nedeniyle farklı illerde kullanılabilirliğinin araştırılması büyük önem taşımaktadır. Aynı zamanda XGBoost algoritmasının

yorumlanabilirliği, ölçeklenebilirliği, sadeliği ve performans doğruluğu (Sharma vd., 2024) bu algoritmanın seçiminde etkili olmuştur. Öte yandan Doğu Anadolu Bölgesinin en büyük ve gelişmiş kenti olan Erzurum İli kapsamında konut fiyatı ile konut özellikleri ilişkisini ele alan az sayıda araştırmacının (Oktay vd., 2014; Orçanlı vd., 2020; Güller & Varol, 2022; Muti & Dursun, 2022) yapılmış olması ve ML algoritmalarının konut değerlemedeki etkinliğini araştıran bir çalışmaya rastlanılmamış olması bu çalışmanın ana motivasyonunu oluşturmuştur. Ayrıca literatürdeki çalışmalarda genellikle internet sitelerindeki satılık ilan verilerinin kullanıldığı ve çok az sayıda çalışmada gerçekleşmiş satış değerlerinin kullanıldığı dikkate alındığında bu çalışmanın materyalini oluşturan gerçekleşmiş satış değerlerinin kullanılması bu çalışmayı benzerlerinden ayıran bir diğer husus olmuştur. Emlak beyan değerlerinin ilk defa bu çalışmada konut özelliği olarak ele alınması da çalışmanın özgünlüğünü artırdığı söylenebilir. Dolayısıyla tüm bu bilgiler ışığında bu çalışmada, Erzurum İli Yakutiye İlçesi örneğinde XGBoost algoritması kullanılarak konut pazar değerinin tahmin edilmesi ve konut özellikleri ile fiyat ilişkisinin analizi amaçlanmıştır.

2. Materyal ve metot

2. Material and method

2.1. Materyal

2.1.1. Material

Çalışmanın materyalini, Erzurum'un üç merkez ilçesinden biri olan, konut ve nüfus yoğunluğunun en fazla olduğu Yakutiye (kent merkezi) ilçesi kapsamında 2024 yılının Ocak-Aralık ayları içerisinde satışa konu olan ve gerçekleşmiş satış fiyatlarına ulaşılabilen konutlar oluşturmaktadır. Doğu Anadolu Bölgesi'nin en büyük ve en kalabalık kenti olan Erzurum, aynı zamanda 30 büyükşehirden biridir. Erzurum Kent merkezi 3850 dönümlük alana sahiptir ve genellikle 3000 metreden daha yüksek olan dik dağların arasında konumlanmıştır (Yılmaz vd., 2008). Adrese Dayalı Nüfus Kayıt Sistemi 2025 verilerine göre Erzurum il nüfusu 745.005 kişidir ve bunların %26'sı (191.228) Yakutiye İlçesinde ikamet etmektedir (Erzurum Valiliği, 2025). Yakutiye İlçesi, aynı zamanda, kentin eski yerleşim bölgelerini içermektedir.

Üniversitelerin, kentin ekonomisi üzerindeki olumlu etkisi tartışılmaz bir gerçektir. Bu bağlamda bölgenin en eski ve en büyük üniversitesinin Erzurum İlinde bulunması, kentin bütününde ve özellikle üniversite civarındaki konutlarda etkili olduğu düşünülmektedir. Bu çerçevede 1957 yılında kurulan Atatürk Üniversitesi ile 2010 yılında kurulan Erzurum Teknik Üniversitesi önem taşımaktadır. Özellikle halihazırda 62.609 öğrenci ve 4784 personel (Atatürk Üniversitesi, 2025) olmak üzere toplamda 67.393 kişiye sahip olan Atatürk Üniversitesi'nin kentin gelişmesinde ve konut piyasasında etkili olduğu düşünülmektedir.


Erzurum ili 2020-2024 yılları konut satışları incelendiğinde yıllık ortalama 10.000 civarında satışın gerçekleştiği söylenebilir (Tablo 2). Merkez ilçeler ele alındığında Aziziye ve Palandöken İlçelerinde konut satışlarında istikrarlı bir şekilde artışın olduğu gözlenirken, çalışma alanımızı oluşturan Yakutiye İlçesinde 2023 yılından sonra önemli bir düşüşün olduğu görülmektedir. Bu rakamların oluşmasında Palandöken ve Aziziye ilçelerinin yeni yapılaşmalara konu olması, Yakutiye İlçesinin tarihi dokusu, koruma amaçlı imar planlarının varlığı ve aynı zamanda konut yoğunluğu ve dolayısıyla eski yapılaşmanın etkili olduğu söylenebilir.

Tablo 2. 2020-2024 yılları Erzurum konut satış sayıları

Table 2. Housing sales figures for 2020-2024 in Erzurum (TÜİK, 2025)

İlçe	2020	2021	2022	2023	2024
Yakutiye	4045	4387	4410	3839	3674
Palandöken	3414	3189	3468	3726	4646
Aziziye	1445	1227	1204	1540	1949
Erzurum	9937	10014	10356	10257	11704

Tapu ve Kadastro Genel Müdürlüğü (TKGM)'nin Parsel sorgulama uygulamasına göre 2024 yılında Erzurum Yakutiye İlçesi kapsamında 2047 bağımsız bölüm (BB) satışı gerçekleşmiştir ve bu satışların dağılımı Şekil 1'de görülmektedir (TKGM, 2025).



Şekil 1. Yakutiye İlçesinde 2024 yılında konut satışlarının yoğunlaştığı bölgeler (TKGM, 2025)

Figure 1. The areas where housing sales were concentrated in Yakutiye district in 2024 (TKGM, 2025)

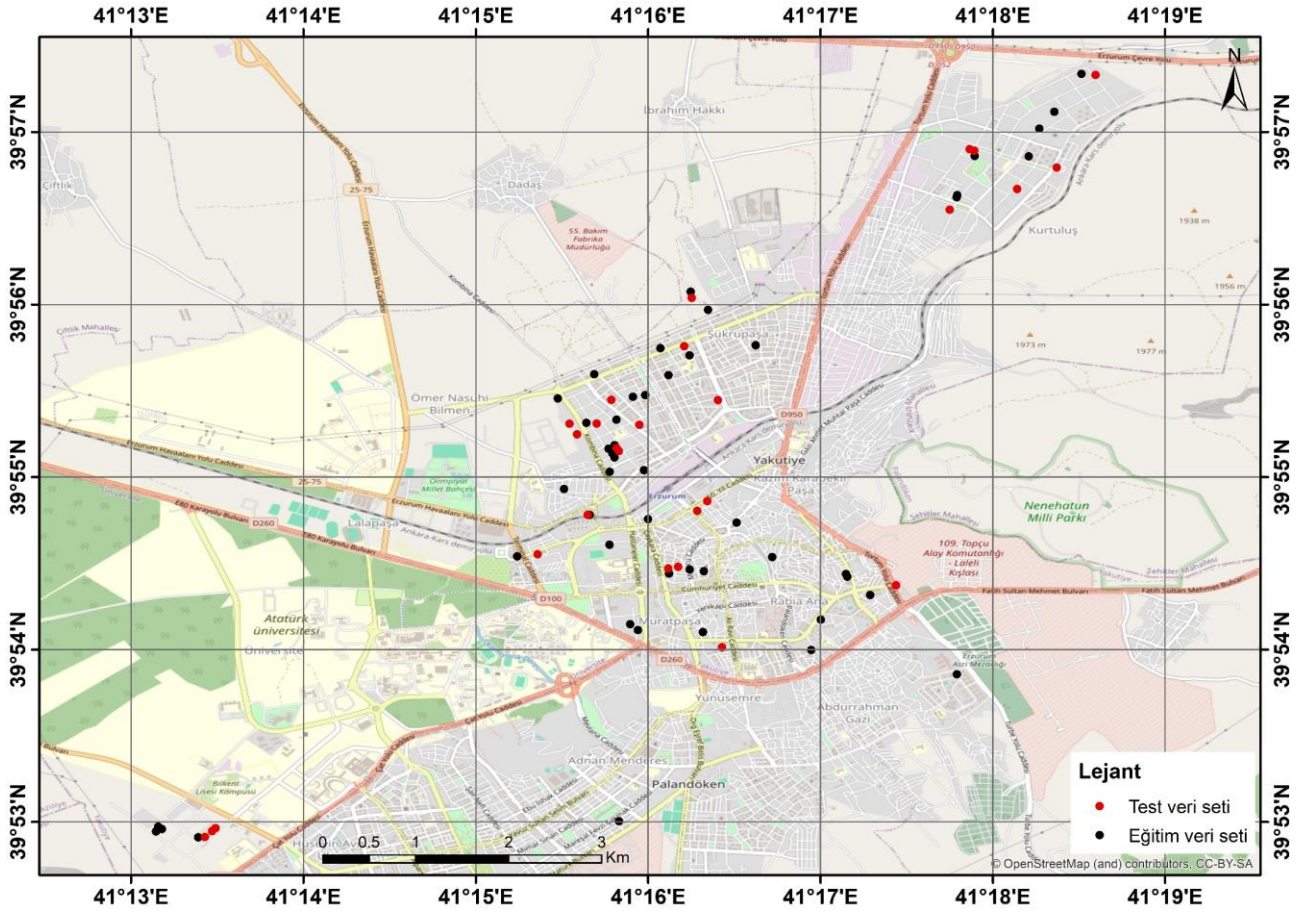
Bu çalışma kapsamında Ocak 2024-Aralık 2024 periyodunda satışa konu olan ve gerçekleşmiş satış değerine ulaşılabilen 101 konuttan oluşan veri seti kullanılmıştır. Çalışmada bir yıllık satış verisinin ele alınmasında, Yazdani (2021)'in de belirttiği gibi zamanın taşınmaz fiyatları üzerindeki etkisinin izole edilmesi etkili olmuştur.

2.2. Veri seti ve uygulama

2.2. Dataset and application

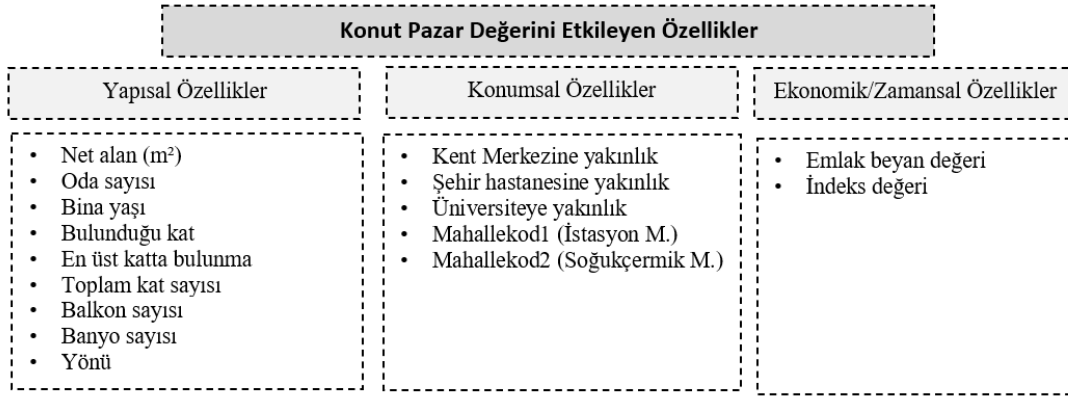
Konut değerlerinin gerçekçi bir şekilde tahmin edilmesi, konutları birbirinden ayıran özelliklerin ve gerçekleşmiş satış değerlerinin teminiyle mümkündür. Veri temini bağlamında, literatürdeki bazı çalışmalarda (Muti & Dursun, 2022; Yavuz Özalp & Akıncı, 2024) olduğu gibi gerçekleşmiş satış değerleri kullanılmıştır. Bu kapsamda gerçekleşmiş satış değerleri, alıcı ve satıcılarla yüz yüze görüşme yapılarak temin edilmiş ve bu değerlerle modelin oluşturulması mümkün kılınmıştır. Bu nedenle veri setinin, piyasa koşullarında oluşan değerleri yansıtması bakımından güvenilir olduğu ve konutların pazar değerini temsil etme açısından uygun olduğu söylenebilir.

Bu çalışmada, Erzurum İli Yakutiye İlçesine ait Ocak 2024-Aralık 2024 periyodunda satışa konu olan ve gerçekleşmiş satış değerine ulaşılabilen 101 konut verisi kullanılmıştır. Şekil 2'de bu çalışmada ele alınan konutların Yakutiye İlçesindeki dağılım haritası görülmektedir. Literatürde özellikle ML yöntemlerini inceleyen çalışmalarda genellikle büyük verinin tercih edildiği gözlenmektedir. Ancak az sayıda veri (kısıtlı veri) ile yapılmış çalışmalar da mevcuttur. Özellikle Türkiye'de yapılan çalışmalarda bu verileri içeren veri setlerinin olmaması nedeniyle nispeten daha az sayıda veri ile çalışmaların yapıldığı söylenebilir. Örneğin Yücebaş vd. (2022) 61 konut, Saraç (2012) 100 konut, Yavuz Özalp ve Akıncı (2024) 103 konut, Narin vd. (2023) ile Doğan vd. (2022) 149 konut, Tabanoğlu (2019) 150 konut, Tabar vd. (2021) 176 konut ve Özdemir vd. (2022) 213 konut verisi kullanmışlardır. Dolayısıyla bu çalışmada kullanılan 101 konuttan oluşan veri setinin literatürdeki benzer çalışmalar dikkate alındığında kabul edilebilir bir düzeyde olduğu söylenebilir.



Şekil 2. Veri setindeki konutların eğitim ve test veri gruplarına göre dağılımı
Figure 2. Distribution of the housing data across the training and test sets

Konutların değeri üzerinde etkili olduğu düşünülen özelliklerin seçiminde, önceki çalışmalar (Yavuz Ozalp & Akinci, 2017; Doğan vd., 2024; Zeydan, 2025), uluslararası ve ulusal standartlar (IAAO, 2013; TDUB, 2022) ve Erzurum İlinin lokal dinamikleri ile bu kente ait önceki çalışmalar (Yılmaz vd., 2008; Sevinç, 2022; Muti & Dursun, 2022; Güller & Varol, 2022) dikkate alınmıştır. Bilindiği gibi konut piyasasının lokal niteliğe sahip olması, konut fiyatını etkileyen özelliklerin lokal düzeyde tespit edilmesini önemli ve gerekli kılmaktadır. Bu bağlamda 16 özellik belirlenmiştir (Şekil 3). Konutların yapısal özelliklerinden net alan (m²), binanın yaşı, oda sayısı, bulunduğu kat, toplam kat sayısı, balkon sayısı, banyo sayısı, yönü ve en üst katta bulunma gibi özellikleri dikkate alınırken konumsal özelliklerinden şehir hastanesine yakınlık, kent merkezine yakınlık ve üniversiteye yakınlık özellikleri kullanılmıştır. Üniversiteye yakınlık özelliği incelenirken, çalışma alanındaki konut piyasası üzerinde mekânsal etkisi daha belirgin olduğu değerlendirilen Atatürk Üniversitesi esas alınmıştır. Erzurum Teknik Üniversitesi'nin yeni gelişen bir yerleşim alanında olması (Şekil 1) ve çevresinin ağırlıklı olarak tarım arazilerinden oluşmuş olması nedeniyle, incelenen konut örneklemini üzerinde ayırt edici bir değer etkisi üretmediği kabul edilmiştir. Bu nedenle çalışmada söz konusu üniversite için ayrıca bir yakınlık analizi yapılmamıştır. Zeydan (2025), konutların bulunduğu konumun, konut fiyatını etkileyen önemli unsurlardan biri olduğunu vurgulamıştır. Dolayısıyla konutların yapısal özelliklerinin yanı sıra konumsal özellikleri de dikkate alınmıştır. Bu bağlamda mahalle bilgisi de kullanılmıştır. Yakutiye İlçesinin 12 farklı mahallesinde bulunan 101 konutun 39 tanesi İstasyon Mahallesi, 21 tanesi de Soğukçermik Mahallesi yer almaktadır. İstasyon Mahallesi kentin merkezinde yer alırken Soğukçermik Mahallesi nispeten merkezden daha uzak bir alanda konumlanmıştır. Bu nedenle söz konusu mahalleler, mahallekod1 (İstasyon Mahallesi) ve mahallekod2 (Soğukçermik Mahallesi) şeklinde iki ayrı konumsal özellik olarak modele dahil edilmiştir. Diğer yandan, literatürdeki çalışmalardan farklı olarak, bu çalışmada konutların bulunduğu cadde/sokak bazında belirlenen emlak beyan değeri de bir özellik olarak ele alınmıştır. Her ne kadar analiz kapsamında bir yıllık satış verileri kullanılmış olsa da TÜİK tarafından aylık olarak yayımlanan konut fiyat indeksi değerlerinin fiyat üzerindeki etkisini gözlemlemek adına indeks değeri de bir diğer özellik olarak kullanılmıştır. Böylece emlak beyan değeri ile indeks değeri, ekonomik/zamansal göstergeler kategorisinde değerlendirilmiştir (Şekil 3).



Şekil 3. Konut pazar değerini etkileyen özelliklerin sınıflandırılması

Figure 3. Classification of the attributes affecting residential market value

Konut değerini etkileyen özelliklerin belirlenmesinin ardından, bu özelliklere ait bilgiler, alıcı ve satıcılardan, Yapı İzin Belgelerinden ve Kat Mülkiyeti Kütüğünden temin edilmiştir. Konumsal özellikler ise Belediyeden temin edilen ve güncellenen halihazır harita üzerinden ArcGIS 10.2 yazılımı yardımıyla kuş uçuşu mesafesi kullanılarak elde edilmiştir. Literatürde üniversiteye yakınlık, kent merkezine yakınlık gibi özelliklerde bazen sürekli mesafe bazen de 1000 m ya da 3000 m gibi farklı kategori eşiklerinin (Yılmaz vd., 2022) kullanıldığı görülmektedir. Bu bağlamda kent merkezi ile şehir hastanesine kuş uçuşu 3000 metre ve Atatürk Üniversitesine 2000 metre mesafede bulunan konutlar 1, diğerleri 0 alınarak kategorik değişken olarak ele alınmıştır. Burada kent merkezi olarak Valilik binası, Atatürk Üniversitesi'nde ise Rektörlük binası esas alınmıştır. Böylece yapısal özelliklerin yanı sıra konumsal özelliklerin de kullanılmasıyla ML algoritmalarının performansının artırılması ve daha iyi tahmin yapabilme hedeflenmiştir. Nitekim Wang ve Wu (2018) ile Aydınoglu vd. (2023), konumsal ve konumsal olmayan özelliklerin modelleme sürecinde birlikte kullanımıyla değer tahmininde daha iyi tahminlerin yapılabileceğini belirtmektedir.

Çalışmada kullanılan özelliklerin belirlenmesi ve bu özelliklere ait bilgilerin temin edilmesinin ardından nümerik veriler için tanımlayıcı istatistiksel analiz gerçekleştirilmiştir (Tablo 3). Bu bağlamda Erzurum İli Yakutiye İlçesinde satışı gerçekleşen konutların fiyatının 590.000 TL ile 5.350.000 TL aralığında olduğu ve ortalama fiyatın 2.460.612 TL olduğu gözlenmiştir (Tablo 3). Çalışmada ele alınan konutların yaşlarının 0-24 arasında değiştiği ve konutların %75'inin 5 yaş altı olduğu görülmektedir. Toplam kat sayısı açısından ise konutların 4 ila 8 katlı olduğu ve %80'inin 5 kat üstü olduğu belirlenmiştir. Bu rakamlar yeni konutların nispeten daha çok satışa konu olduğu şeklinde yorumlanabilir.

Tablo 3. Veri setine ilişkin tanımlayıcı istatistiksel bilgiler

Table 3. Descriptive statistical information for the dataset

	Gerçekleşmiş Satış değeri	NetAlan (m ²)	Bina yaşı	Oda sayısı	Toplam kat sayısı	Bulunduğu kat	Balkon sayısı	Banyo sayısı
Ortalama	2.460.612	121,41	5,20	2,99	6,55	3,62	1,47	1,50
Min. Değer	590.000	31,55	0	1	4	0	0	1
Max. Değer	5.350.000	320,00	24	5	8	8	4	4
Ortanca	2.100.000	125,80	2	3	7	4	1	1
Veri sayısı	101	101	101	101	101	101	101	101

Modelleme aşamasına gelindiğinde veri seti, eğitim ve test verisi olarak iki kısma ayrılır. Sevgen ve Tanrıvermiş (2020) eğitim seti oranının sonucu etkileyebileceğini ve bu oranın literatürde %60 ile %80 arasında değiştiğini belirtmektedir. Dolayısıyla bu çalışmada birçok literatürde (Aydınoglu vd., 2021; Türkan vd., 2023; Tunç & Atasever, 2025) olduğu gibi verilerin rastgele seçilen %70'i modellerin eğitimi, geri kalan %30'u ise doğrulama amacıyla kullanılmıştır. Veri setindeki konutların eğitim ve test veri gruplarına göre dağılımı Şekil 2'de görülmektedir. Modelleme aşamasında, R programında caret ve xgboost kütüphanelerinden yararlanılmıştır. Oluşturulan modelin kullanılabilirliğinin ve veri seti ile ilgili yapılan tahminlerin başarısını ölçmek için de literatürde yaygın olarak kullanılan, belirleme katsayısı (coefficient of determination- R²), ortalama mutlak yüzde hata (Mean Absolute Percentage Error- MAPE), kök ortalama kare hatası (Root Mean Square Error- RMSE) ve ortalama mutlak hata (Mean Absolute Error- MAE) metriklerinden yararlanılmıştır.

2.3. Yöntem: Extreme gradient boosting (XGBoost) algoritması

2.3.1. Method: Extreme gradient boosting (XGBoost) algorithm

Baldominos vd. (2018), konut fiyat tahmininin bir regresyon problemi olduğunu ve ML yaklaşımlarından regresyon tabanlı modellerin daha iyi sonuçlar verdiğini bu nedenle de regresyon ağaçlarından oluşan topluluk öğrenme modellerinin kullanımının daha güçlü bir seçenek sunduğunu belirtmektedir. Bu nedenle çalışmada heyelan, taşkın, orman yangını, taşınmaz değer tahmini gibi farklı uygulamalarda, karşılaştırıldığı diğer ML algoritmalarına göre üstün performans gösterdiği kanıtlanan (Alkan Akıncı & Akıncı, 2024; Sharma vd. 2024; Yavuz Özalp & Akıncı, 2024; Akıncı & Yavuz Ozalp, 2025) XGBoost algoritmasının kullanımı tercih edilmiştir. Mete ve Yomralıoğlu (2023) de XGBoost algoritmasının, en yaygın ve en başarılı gradyan artırma algoritmalarından biri olduğunu vurgulamıştır.

XGBoost (Extreme Gradient Boosting), Chen ve Guestrin (2016) tarafından geliştirilen, etkili ve optimize edilmiş bir gradyan artırma algoritması türüdür. Bir tür denetimli öğrenme algoritmasıdır ve hem regresyon hem de sınıflandırma problemleri için kullanılabilen en popüler artırma (boosting) algoritmalarından biridir. XGBoost, aynı zamanda, en az kaynakla gerçek dünya ölçeğindeki sorunları çözebilen bir algoritmadır (Sharma vd., 2024). XGBoost'un başarılı olmasında, ölçeklenebilir olması ve mevcut popüler ML çözümlerinden daha hızlı çalışması en önemli etkenlerdir (Chen & Guestrin, 2016; Çılgin & Gökçen, 2023). XGBoost, aşırı öğrenmeyi (overfitting) kontrol etmek için düzenleme tekniklerini (L1 Lasso ve L2 Ridge) entegre eder ve gradyan iniş tabanlı hata minimizasyonu yapar (Can vd., 2021). Geleneksel ağaç öğreniminden farklı olarak, XGBoost sadece önceki ağaçlardan bilgi çıkarmakla kalmaz, aynı zamanda ilgili yapraklardaki puanları birleştirerek gradyanlara dayalı artıkları (residuals) minimize eder ve böylece daha doğru sonuçlara ulaşabilir (Çılgin & Gökçen, 2023).

Bu çalışmada XGBoost algoritması, R programlama dilinde caret ve xgboost kütüphaneleri kullanılarak gerçekleştirilmiştir. XGBoost modelinin genelleme performansını daha güvenilir şekilde tahmin etmek ve hiper parametre optimizasyonu yaparken aşırı uyumu (overfitting) önlemek için 10 katlı çapraz doğrulama (10-fold cross validation) kullanılmıştır. XGBoost algoritmasının, karar ağacı sayısı (n_estimators), ağaç derinliği (max_depth), öğrenme oranı (eta), örnek sayısı (subsample) ve özellik sayısı (colsample_bytree) gibi 5 temel hiper parametresi bulunmaktadır. Modelde hiper parametre optimizasyonu için en yaygın kullanılan yaklaşımlardan biri olan grid search (ızgara taraması) yöntemi uygulanmıştır. Her hiper parametre için belirlenen değerler kümesinden üretilen kombinasyonların her biri için model eğitilmiş ve en iyi performansı veren kombinasyon şu şekilde belirlenmiştir: n_estimators=200, max_depth= 8, eta=0,1, subsample=0,8 ve colsample_bytree=0,8. Sinap (2025)'in de belirttiği gibi uygun şekilde ayarlanan hiper parametreler, modelin hem eğitim hem de test veri setlerinde daha iyi genelleme yapabilmesine ve tahmin performansının artırılmasına imkân sağlamaktadır.

3. Bulgular ve tartışma

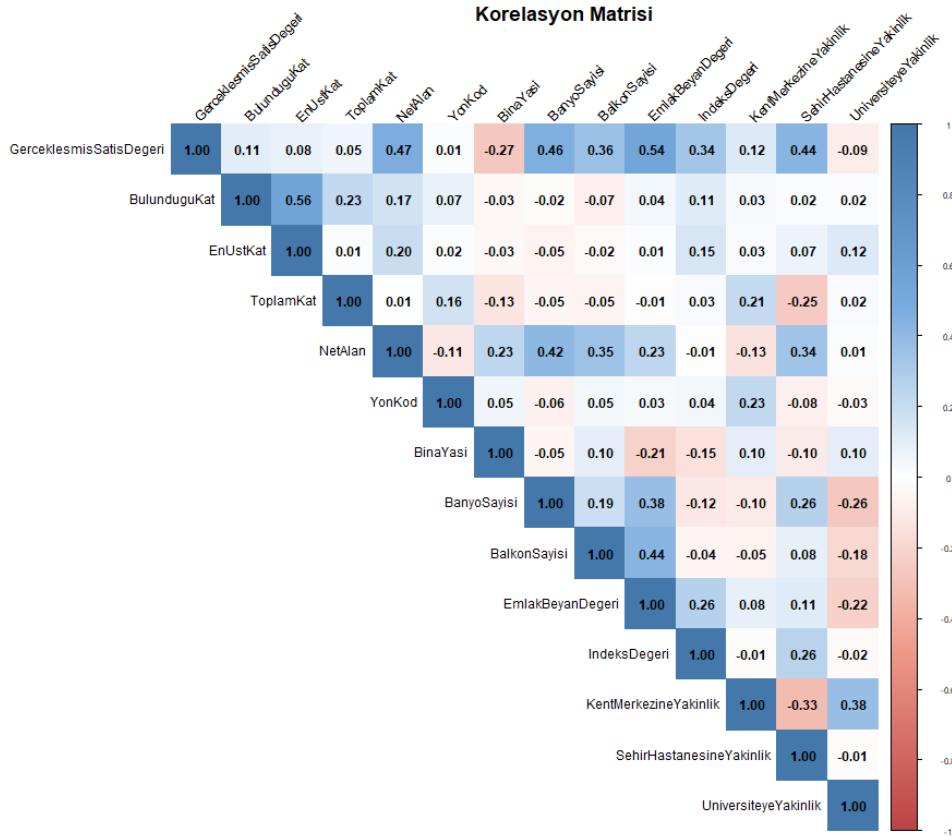
3. Results and discussion

3.1. XGBoost modelinin ve konut fiyatını etkileyen özelliklerin analizi

3.1.1. Analysis of the XGBoost model and attributes affecting residential real estate prices

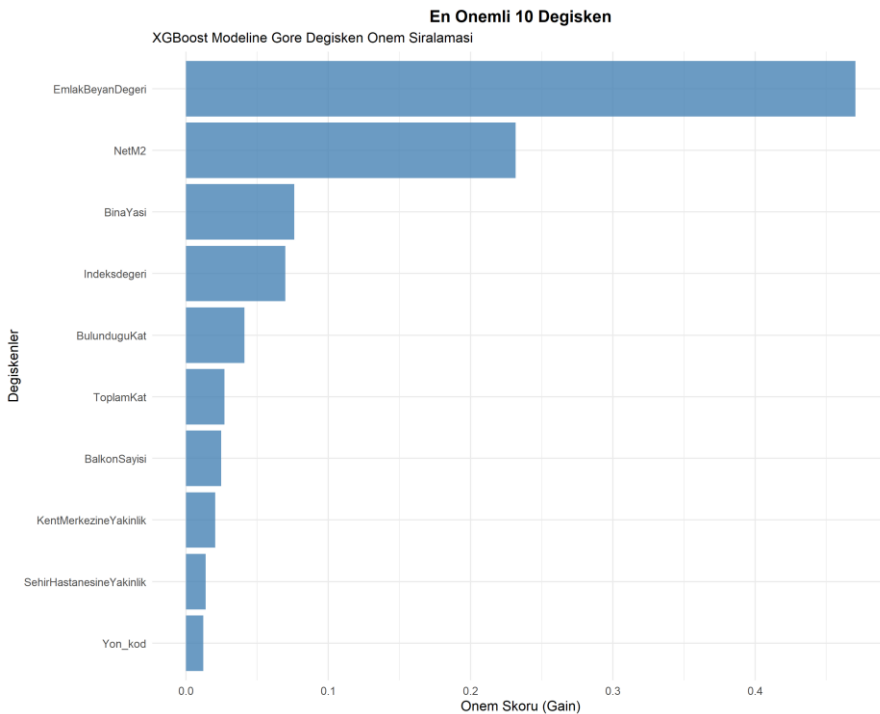
Bir konutun değeri üzerinde çok sayıda özelliğin etkili olduğu bilinen bir gerçektir. Hatta Aydemir vd. (2020), çok sayıda özelliği dikkate alan modellerin daha doğru fiyat tahmininde bulunacağını ve insanların alım/satım fikri üzerinde daha etkili olacağını belirtmektedir. Bu bağlamda çalışmada, konutun net alanı (m²), yaşı, oda sayısı, bulunduğu kat, toplam kat sayısı, balkon sayısı, banyo sayısı, yönü, en üst katta bulunması gibi yapısal özellikleri, şehir hastanesine, kent merkezine ve Atatürk Üniversitesi'ne yakınlık, Mahalle bilgisi, emlak rayiç değeri gibi konumsal özellikleri ile konut fiyat indeksi değeri dikkate alınmıştır (Şekil 3). Modelleme sürecinde belirlenen bu özelliklerin korelasyon analizi önemlidir. Corsini (2009), konut özellikleri dikkate alındığında, bağımsız değişkenler arasında genellikle güçlü bir korelasyon olabileceğini ve bağımsız değişkenler arasındaki bu güçlü korelasyonun değişkenleri kısıtlayabileceğini ve modeli yanıltabileceğini belirtmektedir. Dolayısıyla öncelikle özelliklerin korelasyon analizi gerçekleştirilmiştir. Bu analiz sonucunda oda sayısının konutun alanı ile, mahallekod1 (İstasyon Mahallesi) ve mahallekod2 (Soğukçermik Mahallesi) özelliklerinin Kent Merkezine Yakınlık özelliği ile yüksek korelasyona sahip olduğu belirlenmiş ve bu üç özellik (oda sayısı, mahallekod1 ve mahallekod2) çalışmaya dahil edilmemiştir. Böylece XGBoost algoritmasıyla 13 özelliği kapsayan model üretilmiştir. Kullanılan özelliklerin korelasyon matrisi, ısı haritası şeklinde Şekil 4'de

sunulmuştur. Korelasyon katsayılarının renklerle ifade edilmesi, yüksek veya düşük korelasyonların kolayca gözlemlenebilmesini mümkün kılmaktadır. Şekil 4'deki korelasyonların yüksek olmaması (0.6'nın altında), özelliklerin modelleme için uygun olduğunu göstermektedir.



Şekil 4. Veri setine ait korelasyon matrisi
Figure 4. Correlation matrix for the dataset

Uygulanan XGBoost algoritması sonucunda üretilen modelde, fiyat üzerinde etkili olan özellikler ve önem derecelerine bakıldığında en etkili 5 özelliğin emlak beyan değeri, net alan (m²), bina yaşı, konut fiyat indeks değeri ve bulunduğu kat olduğu görülmektedir (Şekil 5).



Şekil 5. Konut özelliklerinin önem grafiği
Figure 5. Importance graph of residential real estate attributes

Şekil 5'te kullanılan veri seti bağlamında konut değeri üzerinde etkili olan 10 özellik sunulmuştur. Etkili olan özellikler dikkate alındığında teorik beklenti ile uyumlu olduğu görülmektedir. Zira Aktürk ve Tekman (2016)'ın Erzurum'da ikamet eden kişilerin konut tercihlerine yönelik yaptıkları çalışmada da konutun alanı ve merkeze yakın olma özelliği etkili bulunmuştur. Yine Erzurum İline yönelik yapılan bir diğer çalışmada Muti ve Dursun (2022), lokasyon, konutun bulunduğu kat, yaş gibi özelliklerin değer üzerinde en etkili özellikler arasında olduğunu tespit etmişlerdir. Çalışmanın bir diğer bulgusu, emlak beyan değeri özelliğinin fiyat üzerinde oldukça etkili olmasıdır. Literatürde, emlak vergisine esas değer ile piyasa değeri arasında önemli farklılıklar bulunduğu ve bu farklılıkların yalnızca emlak vergisi bakımından değil, tapu harçları başta olmak üzere birçok açıdan maddi kayıplara yol açtığı belirtilmektedir (Büyükkaracığan, 2016; Küpeli & Saygın, 2019). Bu çerçevede, emlak vergisine esas değerlerin gerçekçi ve piyasa koşullarıyla uyumlu biçimde belirlenmesi, taşınmaz alım-satım işlemlerinde gerçekleşmiş satış bedelinin eksik ya da gerçeğe aykırı beyan edilmesi sorununun azaltılmasına da katkı sağlayacağı düşünülmektedir. Ayrıca gayrimenkul sektöründeki kayıt dışı ekonominin de önlenmesine katkı sağlayacaktır. Konutun büyüklüğü (net/brüt m²) ve yaşı literatürdeki hemen hemen tüm çalışmalarda en etkili özellikler arasında yer almaktadır (Yusof & Ismail, 2012; Yavuz Ozalp & Akinci, 2017; Orçanlı vd., 2020; Yazdani, 2021; Güller & Varol, 2022). Güller ve Varol (2022) yaptıkları çalışmada kentin merkezini içinde barındıran ve ilk yerleşim alanlarından olan Yakutiye İlçesinde konutların balkon varlığının önemli olduğunu vurgulamaktadır. Nitekim bu çalışmada da balkon sayısı konut değeri üzerinde etkili çıkmıştır.

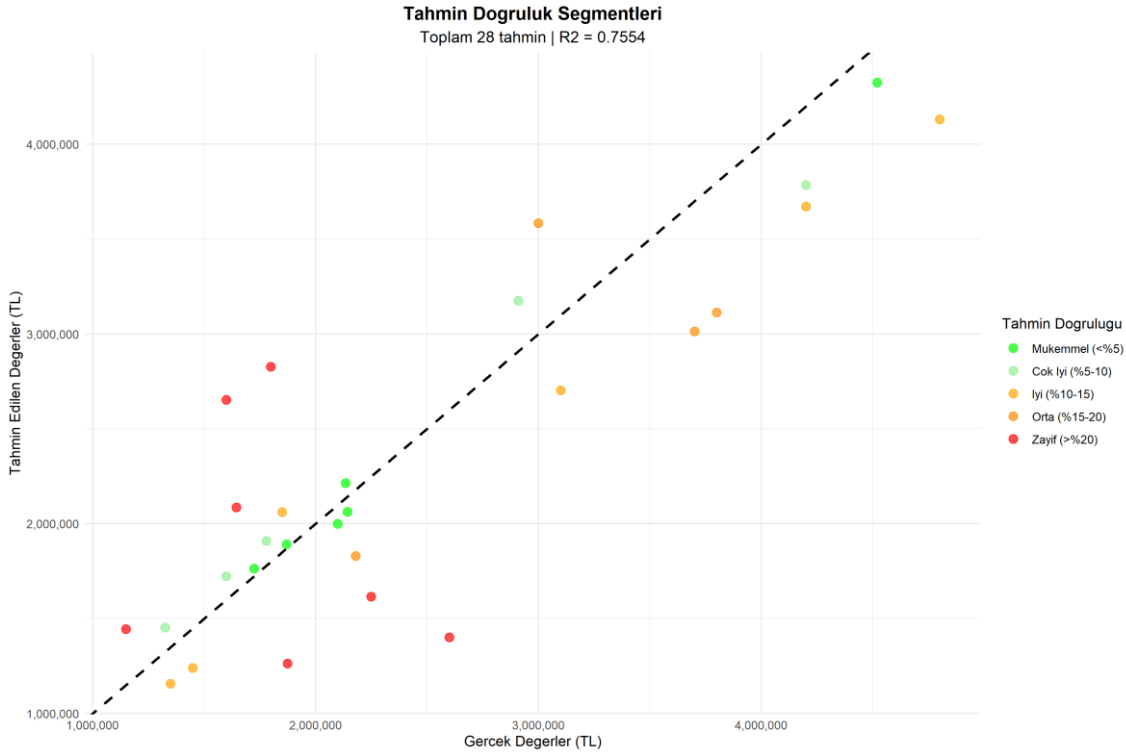
Öte yandan üretilen modelde en az etkili olan beş özellik ise üniversiteye yakınlık, banyo sayısı, konutun en üst katta bulunması, yönü ve şehir hastanesine yakınlık olmuştur (Şekil 5). Sevgen (2022) yaptığı çalışmada konutun yönünü, fiyatı en az etkileyen değişkenler arasında belirtirken üniversiteye olan yakınlığı değeri en çok etkileyen üç parametreden biri olarak tespit etmiştir. Bu çalışmanın aksine Güller ve Varol (2022) yaptıkları çalışmada, Yakutiye İlçesinde konutların çoğunlukla eski olması ve yalıtımlarının bulunmamasına Erzurum'un soğuk havası da eklendiğinde güney cephe değişkeninin konut fiyatını en fazla etkileyen değişken haline getirdiğini ifade etmektedir. Özdemir vd. (2022) de üniversite civarındaki evlerin yüksek kira gelirine sahip olduğunu dolayısıyla da üniversiteye yakın konutların özellikle yatırım fırsatı taşıması nedeniyle daha cazip olduğu ve daha yüksek fiyatlara satıldığını belirtmektedir. Bununla birlikte bu çalışma sonuçları kısmen farklılaşmaktadır.

Konutların özelliklerinin fiyat üzerinde etkili olmasının yanı sıra etkinin şekli de önem taşımaktadır. Bazı özellikler konut değerini artırırken bazı özellikler olumsuz yönde etkileyerek fiyatı düşürmektedir. Bu çalışmada konutun yaşı ve üniversiteye yakınlık fiyatı olumsuz etkileyen özellikler olarak tespit edilirken diğer özelliklerin olumlu (pozitif) yönde etkili olduğu görülmektedir. Konutun yaşının fiyatı düşüren önemli bir özellik olması teorideki beklentiyle ve literatürdeki birçok çalışma ile uyumludur (Yayar & Gül, 2014; Muti & Dursun, 2022). Bununla birlikte Tekin ve Sarı (2022) konutun yaşının fiyat ile bir korelasyonu olmadığını, Tuna vd. (2015) ise yaş ile konut fiyatının arttığını tespit etmişlerdir. Benzer şekilde bu çalışmada üniversiteye yakınlık özelliğinin olumsuz etkilemesi, mekanların farklı dinamiklerine, kullanılan veri setine, eski bir yerleşim bölgesi olmasına, taşınmaz pazarının kısıtlı hacmine ve satış fiyatı belirlemedeki inisiyatif gibi nedenlere bağlanabilir. Sonuçta konutların fiyat-özellik ilişkisinin mekana, veri setine ve lokal dinamiklere bağlı olarak değişmesi çalışmaların farklı coğrafyalarda yapılmasının gerekliliğini ve önemini göstermektedir.

Şekil 6'da test veri setindeki konutların gerçekleşmiş satış değerleri ile XGBoost algoritmasıyla tahmin edilen değerler arasındaki ilişkiyi gösteren grafik verilmiştir. Grafikte test verilerinin tahmin doğruluğu 5 kategoride (mükemmel, çok iyi, iyi, orta ve zayıf) sınıflandırılmıştır. Test verilerinin %61'inin mükemmel, çok iyi ve iyi kategorisinde tahminlerinin gerçekleştirildiği gözlenmektedir.

XGBoost algoritması kullanılarak tahmin edilen fiyatlar dikkate alındığında test veri seti için tahmin edilen değerlerin 1.155.652 TL ile 4.324.178 TL arasında değiştiği ve gerçek değer ile tahmin edilen değer arasında minimum 20.896 TL, maksimum 1.199.559 TL fark olduğu belirlenmiştir (Şekil 6). Oral vd. (2021) yaptığı çalışmada özellikle küçük fiyat değerlerine sahip konutların model tarafından daha iyi tahmin edildiğini savunmaktadır. Bu rakamlar, bazı konutlarda olması gereken fiyat ile tahmin edilen fiyatlar arasında fahiş farkların oluştuğunu ve bazı konutların kasıtlı olarak daha pahalıya ya da daha ucuza satıldığını dolayısıyla istikrarsız ve denetimsiz bir konut pazarının olduğunu göstermektedir.

Sonuç olarak bu çalışma, Erzurum İlinde farklı yıllarda ve kapsamda gerçekleştirilen diğer çalışmalarla benzerlikler göstermekle birlikte bazı farklılıklara da konu olmuştur.



Şekil 6. Test veri seti için gerçekleşmiş satış ve tahmini fiyat grafiği

Figure 6. Actual sales price and estimated price chart for the test data set

Bu farklılıkların çıkmasında ele alınan özelliklerdeki çeşitlilik, seçilen uygulama ölçeğindeki farklılık ve en önemlisi kullanılan veri setinin farklı olması etkili olmuştur. Aynı zamanda, ML algoritmasının kullanımı da önemli fırsatlar sunmuştur. Öte yandan ülkedeki ekonomik istikrarsızlık, yüksek enflasyon ve fiyat algısının bozulması gibi etkenlerin de gayrimenkul sektöründe etkisini gösterdiği ve piyasa verilerinin yorumlanmasını güçleştirdiğini söylemek yanlış olmayacaktır.

3.2. XGBoost Modelinin Doğruluk Analizi

3.2. XGBoost model accuracy analysis

Çalışmada, Erzurum İli Yakutiye İlçesi örneğinde konut özellikleri ile konut değeri ilişkisi incelenerek konutların değeri üzerinde etkili olan özelliklerin belirlenmesi ve özellikleri bilinen konutların değer tahminlerinin yapılabilmesi amaçlanmıştır. Bu amacı gerçekleştirmek üzere üstün performansı ile bilinen XGBoost algoritması kullanılarak oluşturulan modelin performansının, kullanılabilirliğinin ve veri seti ile ilgili yapılan tahminlerin başarısını ölçmek için literatürde yaygın olarak kullanılan hata metriklerinden yararlanılmıştır. Bu metrikler; belirleme katsayısı (R^2), ortalama mutlak yüzde hata (MAPE), kök ortalama kare hatası (RMSE) ve ortalama mutlak hata (MAE) ölçütleridir. R^2 ölçütü, eğitim için rastgele seçilen veri setiyle eğitilen modelin test verileri bağlamında başarısını ve modeldeki bağımsız değişkenlere (konut özellikleri) göre bağımlı değişkenin (konut fiyatı) varyasyon oranını ölçer. Bu ölçüt, 0 ile 1 arasında değer alır ve değer 1'e yakın olması oluşturulan modelin performansının iyi olduğunu gösterir (Aydoğan vd., 2023). Bu çalışmada R^2 performans ölçütü, test veri seti için 0,755 olarak hesaplanmıştır.

R^2 değerinin %70'in üstünde olması, modelin verileri iyi bir şekilde açıkladığı ve modelin performansının kabul edilebilir olduğunu göstermektedir (Türkan vd., 2023). Bir diğer ölçüt olan kök ortalama kare hatası (RMSE) değeri 0 ile ∞ arasında değişir ve düşük değer daha iyi performans olduğunu gösterir (Ozdemir vd., 2022). Bu veri seti için RMSE değeri 515.240,58 olarak bulunmuştur. Ortalama mutlak yüzde hata (MAPE) metriği ise, tahmin hatalarını yüzdesel olarak gösteren bir metriktir (Toprak & Güngör, 2023) ve bu çalışma için %17,77 olarak hesaplanmıştır. Literatürde (Chen vd., 2003; Altun, 2022), MAPE değerinin %10'un altında olması "çok iyi", %10 ile %20 arasında olması "iyi", %20 ile %50 arasında olması "kabul edilebilir" ve %50'nin üzerinde olması "yanlış ve hatalı" olarak belirtilmektedir. Bu bağlamda çalışmada elde edilen %17,77 değerinin iyi kategorisinde yer aldığı görülmektedir. Ortalama mutlak hata (MAE), tahmin edilen değerler ile gerçek değerler arasındaki mutlak hataların ortalamasını gösteren bir performans ölçütüdür. Tahminlerin gerçek değerlere ne kadar yakın olduğunu gösterir (Toprak & Güngör, 2023; Chuhan, 2024). Bu

çalışma kapsamında MAE değeri 405.611,09 olarak bulunmuştur. Tüm bu rakamlar, XGBoost algoritmasının konut değerlendirme alanında kullanılabileceğini göstermektedir. Bununla birlikte üretilen modelin konut değerini tahmin etme başarısı literatürdeki bazı çalışmalara göre (Zaki vd., 2022; Mete & Yomralıoğlu, 2023; Agadagba, 2024; Tunç & Atasever, 2025) düşük olurken bazı çalışmalara (Sinap, 2025; Zeydan, 2025) göre de yüksek olduğu söylenebilir. Bu rakamın çıkması kullanılan veri setiyle doğrudan ilişkilidir. Aynı zamanda çalışmanın materyalini oluşturan gerçek satış fiyatlarının kullanılması ve konut fiyatlarının belirlenmesindeki esneklik bu rakamların oluşmasında etkili olduğu düşünülmektedir. Daha geniş örneklem grubu ile daha yüksek başarının ve daha iyi tahminlerin elde edilebileceği öngörülmektedir. Nitekim Yılmaz ve Kocaman (2020) da ML algoritmalarının güvenilirliğini veri sayısına ve kalitesine bağlamıştır.

4. Sonuç

4. Conclusion

Bu çalışmada, Erzurum İli Yakutiye İlçesi örneğinde 2024 yılına ait gerçekleşmiş satış verileri kullanılarak XGBoost algoritmasının konut pazar değerinin tahminindeki performansı ve pazar değerini etkileyen başlıca özellikler incelenmiştir. Çalışmada üretilen modelin performansı ve uygulanabilirliği, R^2 belirleme katsayısı, ortalama mutlak yüzde hata (MAPE), kök ortalama kare hatası (RMSE) ve ortalama mutlak hata (MAE) gibi literatürde yaygın olarak kullanılan hata metrikleriyle ölçülmüştür. Bu kapsamda 0,76 olarak hesaplanan R^2 metriği ile %17,77 olarak hesaplanan MAPE metriği, konut değerlendirme alanında modelin kabul edilebilir bir performans sunduğunu göstermektedir.

Analiz sonuçlarına göre, konut pazar değeri üzerinde en etkili özelliklerin emlak beyan değeri, net alan (m^2), bina yaşı, konut fiyat indeksi değeri ve bulunduğu kat olurken, en az etkili özelliklerin ise üniversiteye yakınlık, banyo sayısı, konutun en üst katta bulunması, yönü ve şehir hastanesine yakınlık olduğu tespit edilmiştir. Ayrıca konutun yaşı ve üniversiteye yakınlık özelliklerinin fiyatı olumsuz etkilerken diğer konut özelliklerinin değeri olumlu etkilediği gözlenmiştir. Bu sonuçların elde edilmesinde mekanların farklı dinamiklerinin, kullanılan veri setinin, taşınmaz pazarının kısıtlı hacminin ve satış fiyatı belirlemedeki inisiyatif gibi nedenlerin etken olduğu öngörülmektedir.

Çalışmanın önemli yönlerinden biri, modelin gerçekleşmiş satış değerleriyle kurulmuş olmasıdır. Ayrıca emlak beyan değerinin bir özellik olarak modele dahil edilmesi çalışmanın özgün yönlerinden birini oluşturmaktadır. Aynı zamanda Erzurum İlinde ML algoritması kullanılarak yapılan tek çalışma olması da önem taşımaktadır. Bununla birlikte veri setinin 101 konutla sınırlı olması ve iç mekan özellikleri, sosyal donatılara erişim gibi konut değerini etkileyen tüm değişkenlerin güvenilir ve standart veri teminindeki güçlükler nedeniyle modele dahil edilememesi çalışmanın temel kısıtıdır. Konutların fiyat-özellik ilişkisinin mekâna, veri setine ve lokal dinamiklere bağlı olarak değişmesi çalışmaların farklı coğrafyalarda yapılmasının gerekliliğini ve önemini göstermektedir.

Sonuç olarak, XGBoost algoritmasının konut değerlendirme çalışmalarında az veri durumunda bile kabul edilebilir bir performans sağladığı görülmüştür. Bu çalışmanın sonuçlarının Erzurum özelinde ve Türkiye genelinde yatırımcılar, konut sahipleri, emlakçılar gibi sektörün tüm aktörlerine yön gösterici olması umulmaktadır. Gelecek çalışmalarda veri setinin genişletilmesi, daha çok sayıda yapısal, konumsal ve ekonomik özelliklerin eklenmesi ve farklı yöntemlerin karşılaştırmalı analizlerinin yapılması performansın daha çok artmasına ve daha genellenebilir sonuçlara ulaşılmasına katkı sağlayacaktır.

Yazar katkısı

Author contribution

Ayşe Yavuz Özalp: Kavramsallaştırma, metodoloji, araştırma, görselleştirme, inceleme ve düzenleme, orijinal taslak hazırlama, yazma. Halil Akıncı: Araştırma, metodoloji, yazılım, görselleştirme, yazma, inceleme ve düzenleme. Ali Muti: Araştırma, metodoloji, inceleme ve düzenleme, orijinal taslak hazırlama.

Etik beyanı

Declaration of ethical code

Bu makalenin yazarları, bu çalışmada kullanılan materyal ve yöntemlerin etik kurul izni ve / veya yasal-özel izin gerektirmediğini beyan etmektedir.

Çıkar çatışması beyanı*Conflicts of interest*

Yazarlar, herhangi bir çıkar çatışması olmadığını beyan ederler.

Kaynaklar*References*

- Adetunji, A. B., Akande, N., Ajala, F. A., Oyewo, O., Akande, Y. F., & Oluwadara, G. (2022). House price prediction using random forest machine learning technique. *Procedia Computer Science*, 199, 806–813. <https://doi.org/10.1016/j.procs.2022.01.100>
- Agadagba, O. (2024). *Predicting real estate prices with machine learning* [Master's thesis, Vilnius University Faculty of Mathematics And Informatics Data Science].
- Akinci, H., Zeybek, M., & Dogan, M. (2021). Evaluation of landslide susceptibility of Şavşat District of Artvin Province (Turkey) using machine learning techniques. In Y. Zhang and Q. Cheng (Eds.), *Landslides* (pp. 69-95), IntechOpen.
- Akinci, H., & Yavuz Ozalp, A. (2025). Investigating the effects of different data classification methods on landslide susceptibility mapping. *Advances in Space Research*, 75(4), 3427-3450. <https://doi.org/10.1016/j.asr.2024.12.020>
- Aktürk, E., & Tekman, N. (2016). Konut talebi ve Erzurum kent merkezinde tüketicilerin konut edinme kararlarını etkileyen faktörler. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 30(2), 423-440.
- Akyüz, S. Ö., Erdogan, B. E., Yıldız, Ö., & Ataş, P. K. (2023). A novel hybrid house price prediction model. *Computational Economics*, 62, 1215–1232. <https://doi.org/10.1007/s10614-022-10298-8>
- Alkan, T., Dokuz, Y., Ecemiş, A., Bozdağ, A., & Durduran, S. S. (2023). Using machine learning algorithms for predicting real estate values in tourism centers. *Data Analytics and Machine Learning*, 27, 2601–2613. <https://doi.org/10.1007/s00500-022-07579-7>
- Alkan, T., Karakoyun, M., & Durduran, S. S. (2024). Investigation of the effect of current value on real estate value using machine learning algorithms. In C. Özalp, & S. Bardak (Eds.), *International Research and Evaluations in The Field of Engineering* (ss. 153-172). Serüven Yayınevi.
- Alkan Akinci, H., Akinci, H., & Zeybek, M. (2024). Comparison of diverse machine learning algorithms for forest fire susceptibility mapping in Antalya, Türkiye. *Advances in Space Research*, 74(2), 647-667. <https://doi.org/10.1016/j.asr.2024.04.018>
- Altun, Ö. (2022). Yapay zekâ yöntemleriyle hazine taşınmazlarının değerlendirilmesi: yapay sinir ağları ile kamu konutları üzerine bir uygulama. *Türkiye Arazi Yönetimi Dergisi*, 4(2), 62-74. <https://doi.org/10.51765/tayod.1133588>
- Ancy, S. G., & Praveenchandar, J. (2024). An effective machine learning algorithm for forecasting the market value of a house. *Proceedings of the 3rd International Conference on Applied Artificial Intelligence and Computing (ICAAIC-2024)* (pp. 1567-1574), Salem, India.
- Atatürk Üniversitesi. (2025, 7 Ekim). <https://istatistik.atauni.edu.tr/istatistik/sayfalar/anasayfa.php>
- Aydemir, E., Aktürk, C., & Yalçınkaya, M. A. (2020). Estimation of housing prices with artificial intelligence. *Turkish Studies*, 15(2), 183-194. <http://dx.doi.org/10.29228/TurkishStudies.43161>
- 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, 349-365. <https://doi.org/10.1080/00396265.2020.1771967>
- Aydınoglu, A.Ç., Bovkır, R., & Çölkesen, İ. (2023). Toplu taşınmaz değerlemede makine öğrenme algoritmalarının kullanımı ve konumsal/konumsal olmayan özneliklerin tahmin doğruluğuna etkilerinin karşılaştırılması. *Journal of Geodesy and Geoinformation*, 10, 63-83.
- Baldominos, A., Blanco, I., Moreno, A., Iturrarte, R., Bernardez, O., & Afonso, C. (2018). Identifying real estate opportunities using machine learning. *Applied Sciences*, 8(11), 2321. <https://doi.org/10.48550/arXiv.1809.04933>

- Bilgiliođlu, S. S., & Yılmaz, H. M. (2021). Comparison of different machine learning models for mass appraisal of real estate. *Survey Review*, 55, 32-43. <https://doi.org/10.1080/00396265.2021.1996799>
- Burhan, H. A. (2023). Konut fiyatları tahmininde makine öğrenmesi sınıflandırma algoritmalarının kullanılması: Kütahya kent merkezi örneđi. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, 76, 221-237. <https://doi.org/10.51290/dpusbe.1249461>
- Büyükkaracıđan, N. (2016). Gayrimenkullerde emlak vergisi matrah değeri ile piyasa değeri arasındaki farklılıkların araştırılması ve Konya Meram örneđi. *Selçuk Üniversitesi Sosyal ve Teknik Araştırmalar Dergisi*, 11, 143-157.
- Can, R., Kocaman, S., & Gokceoglu, C. (2021). A comprehensive assessment of XGBoost algorithm for landslide susceptibility mapping in the upper basin of Ataturk Dam, Turkey. *Applied Science*, 11, 4993. <https://doi.org/10.3390/app11114993>
- Ceh, M., Kilibarda, M., Liseç, 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>
- Chen, T., & Guestrin, C. (2016). XG Boost: A scalable tree boosting system. *22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining-KDD* (pp. 785–794), New York.
- Chen, R. J. C., Bloomfield, P., & Fu, J. S. (2003). An evaluation of alternative forecasting methods to recreation visitation. *Journal of Leisure Research*, 35(4), 441-454.
- Chuhan, N. (2024). House price prediction based on different models of machine learning. *Applied and Computational Engineering*, 49(1), 47-57. <https://doi.org/10.54254/2755-2721/49/20241058>
- Corsini, K. R. (2009). *Statistical analysis of residential housing prices in an up and down real estate market: a general framework and study of Cobb county, GA* [Master's Thesis, Georgia Institute of Technology].
- Çılğın, C., & Gökçen, H. (2023). Machine learning methods for prediction real estate sales prices in Turkey. *Revista de la Construcción. Journal of Construction*, 22(1), 163-177. <https://doi.org/10.7764/RDLC.22.1.163>
- Dođan, O., Bande, N., Genç Y., & Akyön, F.Ç. (2022). Estimation of housing fair values using artificial neural networks method in Kecioren/Ankara. *International Journal of Economic and Administrative Studies*, 35, 113-128. <https://doi.org/10.18092/ulikidince.941952>
- Dođan, O., Bande, N., Genç Y., Akyön, F.Ç., & Tanç, R. (2023). The importance of digitization in estimating housing fair value with the artificial neural networks method: the case of Yenimahalle/Ankara/Turkey. *Journal of Brilliant Engineering*, 1, 4768. <https://doi.org/10.36937/ben.2023.4768>
- Dođan, S., Genç, L., Yücebaş, S. C., Uşaklı, M., & Dumlu, C. (2024). Determination of the relationship between housing characteristics and housing prices before and after the Kahramanmaraş earthquake using machine learning: A case study of Adana, Türkiye. *Megaron*, 19(2), 259–274. <https://doi.org/10.14744/megaron.2024.22316>
- Erzurum Valiliđi. (2025, 15 Eylül). *İlçelerimiz*. <https://www.ErzurumValiligi.gov.tr/ilcelerimiz>
- Esen, Y., & Tokgöz, H. (2021). A different perspective to real estate valuation with fuzzy logic modeling. *Journal of Engineering Sciences and Design*, 9(4), 1155-1165. <https://doi.org/10.21923/jesd.876523>
- Fidanboy, M., Adar, N., & Okyay, S. (2022). Derin öğrenmeye dayalı orman yangını tahmin modeli geliştirilmesi ve Türkiye yangın risk haritasının oluşturulması. *Ormançılık Araştırma Dergisi*, 9(2), 206-218. <https://doi.org/10.17568/ogmoad.1066557>
- Güller, C., & Varol, Ç. (2022). Erzurum'da konut fiyatlarına etki eden faktörlerin hedonik analiz yardımıyla belirlenmesi. *Sosyoekonomi*, 30(54), 377-400. <https://doi.org/10.17233/sosyoekonomi.2022.04.20>
- Gündođmuş, M. E., Kalfa, V. R., & Başkaya, H. (2022). Gayrimenkul değerlendirme ve istatistiksel analiz. *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 1(42), 173-197.

- Hayrullohoğlu, G., Aliefendioğlu, Y., Tanrıvermiş, H., & Hayrullohoğlu, A.C. (2018). Estimation of the hedonic valuation model in housing markets: the case of Cukurambar region in Çankaya district of Ankara province. *Ecoforum*, 1, 1-9.
- Hazer, A., Bozdağ, A., & Atasever, Ü. H. (2024). Hiper-optimize edilmiş makine öğrenim teknikleri ile taşınmaz değerlendirilmesi, Yozgat kenti örneği. *Geomatik*, 9(3), 299-312. <https://doi.org/10.29128/geomatik.1454915>
- 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>
- Hoxha, V. (2023). Comparative analysis of machine learning models in predicting housing prices: a case study of Prishtina's real estate market. *International Journal of Housing Markets and Analysis*, 18(3), 694-711. <https://doi.org/10.1108/IJHMA-09-2023-0120>
- IAAO- International Association of Assessing Officers. (2022, April 14). <https://www.iaao.org/media/standards/StandardOnMassAppraisal.pdf>
- İban, M.C. (2021). Accuracy analysis of community algorithms in estimating the value of real estate. *1st International Artificial Intelligence and Data Science Congress* (pp. 226-232), İzmir.
- 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>
- Kara, M. A. (2024). Makine öğrenmesi algoritmalarıyla konut fiyatlarının tahmini: Giresun örneği. *Journal of Statistics and Applied Sciences*, 10, 105–111. <https://doi.org/10.52693/jsas.1571979>
- Küpeli, İ., & Saygın, Ö. (2019). Emlak vergisi değeri ve piyasa değeri arasındaki farka bağlı vergi kayıpları: Gebze örneği. *Business & Management Studies: An International Journal*, 7(5), 2372-2384. <http://dx.doi.org/10.15295/bmij.v7i5.1369>
- Louati, A., Lahyani, R., Aldaej, A., Aldumaykhi, A., & Otai, S. (2021). Price forecasting for real estate using machine learning: A case study on Riyadh city. *Concurrency and Computation: Practice and Experience*, 1-16. <https://doi.org/10.1002/cpe.6748>
- Mathotaarachchi, K.V., Hasan, R., & Mahmood, S. (2024). Advanced machine learning techniques for predictive modeling of property prices. *Information*, 15, 295. <https://doi.org/10.3390/info15060295>
- Mete, M. O., & Yomralıoğlu, T. (2022). GIS and machine learning based mass valuation of residential properties. *11th Turkish National Photogrammetry and Remote Sensing Union (TUFUAB) Technical Symposium* (pp. 1-5), Mersin.
- Mete, M. O., & Yomralıoğlu, T. (2023). A hybrid approach for mass valuation of residential properties through geographic information systems and machine learning integration. *Geographical Analysis*, 55, 535–559. <https://doi.org/10.1111/gean.12350>
- Muti, A., & Dursun, A. (2022). Konut fiyatlarına etki eden faktörlerin hedonik fiyat modeli ile belirlenmesi: Erzurum ili örneği. *Bingöl Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 6(2), 349-380. <https://doi.org/10.33399/biibfad.1146664>
- Narin, S., Doğan, O., Bande, N., & Genç, Y. (2023). Keçiören/ankara özelinde konut rayiç değerlerinin tahmininde çoklu regresyon analizi ve yapay sinir ağları yöntemlerinin karşılaştırılması. *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 15(2), 828-839. <https://doi.org/10.29137/umagd.1297672>
- Oktay, E., Karaaslan, A., Alkan, Ö., & Çelik, A. K. (2014). Determinants of housing demand in the Erzurum province, Turkey. *International Journal of Housing Markets and Analysis*, 7(4), 586-602. <https://doi.org/10.1108/IJHMA-11-2013-0056>
- Okurlar, H., & Eroğlu, Y. (2025). Real estate price estimation with AI: A hybrid approach combining clustering and machine learning. *International Journal of Multidisciplinary Studies and Innovative Technologies*, 9(1), 137-144. <https://doi.org/10.36287/ijmsit.9.1.19>

- Oral, M., Okatan, E., & Kırbaş, İ. (2021). A study on house price prediction using machine learning methods: the case of Madrid. *3rd International young researchers student congress* (pp. 263-272), Burdur.
- Orçanlı, K., Oktay, E., Sarı, N. B., Boztoprak, H. (2020). Konut değerinin oluşmasında ve zorunlu deprem sigortası sahipliğinde etkili olan faktörlerin analizi: Erzurum ili örneği. *International Journal of Economic and Administrative Studies*, 26, 195-224. <https://doi.org/10.18092/ulikidince.559539>
- Özdemir, M., Yıldız, K., & Büyüktanır, B. (2022). Housing price estimation with deep learning: a case study of Sakarya Turkey. *BSEU Journal of Science*, 9(1), 138-151. <https://doi.org/10.35193/bseufbd.998331>
- Ravikumar, A.S. (2016). *Real estate price prediction using machine learning* [Master's Thesis, National College of Ireland School of Computing].
- Saraç, E. (2012). *Real estate appraisal with artificial neural networks method* [Master's Thesis, İstanbul Kültür University Institute of Science].
- Savaş, B. (2019). *Makine öğrenme algoritmalarının konut değer tahmininde kullanımı: Ankara Gölbaşı uygulaması* [Yüksek Lisans Tezi, Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü].
- Sevinç, V. (2022). Determining the flat sales prices by flat characteristics using bayesian network models. *Computational Economics*, 59, 549–577. <https://doi.org/10.1007/s10614-021-10099-5>
- Sevgen, S. C. (2022). *Kitlesel değerlendirilmede makine öğrenme algoritmaları* [Doktora Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü]
- Sevgen, S.C., & Tanrivermiş, Y.A. (2020). Mass appraisal with a machine learning algorithm: random forest regression. *Journal of Information Technologies*, 13(3), 301-311. <https://doi.org/10.17671/gazibtd.555784>
- Sharma, H., Harsora, H., & Ogunleye, B. (2024). An optimal house price prediction algorithm: XGBoost. *Analytics*, 3, 30–45. <https://doi.org/10.3390/analytics3010003>
- Sinap, V. (2025). Optuna tabanlı hiper parametre optimizasyonu ile konut fiyat tahminlemede makine öğrenmesi tekniklerinin karşılaştırmalı analizi. *Gazi Üniversitesi Fen Bilimleri Dergisi*, 13(1), 10-28. <https://doi.org/10.29109/gujsc.1544987>
- Şişman, S., & Aydınoglu, A.Ç. (2023). Toplu taşınmaz değerlemesi için coğrafi verinin işlenmesi ve rastgele orman makine öğrenmesi tekniğiyle tahmin modelinin geliştirilmesi. *Harita Dergisi*, 169, 13-27.
- Tabar, M. E., Başaran, A. C., & Şişman, Y. (2021). Housing valuation study in Tokat province with multiple regression and artificial neural networks. *Turkish Journal of Land Management*, 3(1), 01-07. <https://doi.org/10.51765/tayod.832227>
- Tabanoğlu, M. (2019). *Estimating the market value of residential buildings with artificial neural networks method: Düzce sample* [Master's Thesis, Düzce University Graduate School of Natural Sciences].
- Tan, C., & Feng, Z. (2023). Mapping forest fire risk zones using machine learning algorithms in Hunan Province, China. *Sustainability*, 15, 6292. <https://doi.org/10.3390/su15076292>
- TDUB-Türkiye Değerleme Uzmanları Birliği. (2022, 15 Nisan). https://tdub.org.tr/uploads/documents/1667807030_d7767c42b3a070c20179
- Tekin, M. & Sari, I. U. (2022). Real estate market price prediction model of Istanbul. *Real Estate Management and Valuation*, 30(4), 01-16. <https://doi.org/10.2478/remav-2022-0025>.
- TKGM- Tapu ve Kadastro Genel Müdürlüğü. (2025, 11 Temmuz). Parsel sorgulama. <https://parselsorgu.tkgm.gov.tr/>
- Toprak, M. F., & Güngör, O. (2023). Kayseri’de çoklu regresyon ve coğrafi ağırlıklı regresyon yöntemleri ile konutların toplu değerlemesi. *Türk Uzaktan Algılama ve CBS Dergisi*, 4(1), 114-124. <https://doi.org/10.48123/rsgis.1255881>
- Tuna, M.F., Türk, T., & Kitapçı, O. (2015). House prices with the help of linear regression and GIS estimating: the example of Ankara. *TMMOB HKMO 15. Türkiye Harita Bilimsel ve Teknik Kurultayı* (pp. 1-5), Ankara.

- Tunç, B. N., & Atasever, Ü. H. (2025). CatBoost algoritmasının taşınmaz değerlendirilmede kullanımı: Bayesian hiperparametre optimizasyonu ile karşılaştırmalı analiz. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 14(2), 668-679. <https://doi.org/10.28948/ngumuh.1597288>
- TÜİK- Türkiye İstatistik Kurumu. (2025, 29 Ağustos). <https://data.tuik.gov.tr/Bulten/Index?p=Konut-Satis-Istatistikleri-Ocak-2024-53766>
- Türkan, M., Bozdağ, A., Karkınlı, A.E., & Ulucan, A.G. (2023). Kent ölçeğinde konutlara ilişkin toplu değer değişiminin makine öğrenim algoritmaları ile analizi. *Türkiye Arazi Yönetimi Dergisi*, 5(2), 66-77. <https://doi.org/10.51765/tayod.1275671>
- Wang, C., & Wu, H. (2018). A new machine learning approach to house price estimation. *New Trends in Mathematical Sciences*, 6(4),165-171. <https://doi.org/10.20852/ntmsci.2018.327>
- Yavuz Ozalp, A., & Akinci, H. (2017). The use of hedonic pricing method to determine the parameters affecting residential real estate prices. *Arabian Journal of Geoscience*, 10, 535. <https://doi.org/10.1007/s12517-017-3331-3>
- Yavuz Özalp, A., & Akıncı, H. (2024). Comparison of tree-based machine learning algorithms in price prediction of residential real estate. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 14(1), 116-130. <https://doi.org/10.17714/gumusfenbil.1363531>
- Yavuz Ozalp, A., & Akinci, H. (2023). Evaluation of land suitability for olive (*Olea europaea* L.) cultivation using the Random Forest algorithm. *Agriculture*, 13(6), 1208. <https://doi.org/10.3390/agriculture13061208>
- Yayar, R., & Gül, D. (2014). Hedonic estimation of housing market prices in Mersin city center. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 14(3), 87-100.
- Yazdani, M. (2021). *Machine learning, deep learning, and hedonic methods for real estate price prediction* [Master's Thesis, Colorado University Department of Economics].
- Yılmaz, H., Bulut, Z., Temurlenk, M. S., & Yeşil, P. (2008). Determination of the impact of parks and playgrounds on house prices in the city of Erzurum, Turkey. *International Journal of Natural and Engineering Sciences*, 2(1), 47-51.
- Yılmaz, O., Talavera, O., & Jia, J. Y. (2022). Rental market liquidity, seasonality, and distance to universities. *International Journal of the Economics of Business*, 29(2), 223-239. <https://doi.org/10.1080/13571516.2022.2033078>
- Yılmazel, Ö., Afşar, E., & Yılmazel, S. (2018). Using artificial neural network method to predict housing prices. *International Journal of Economic and Administrative Studies*, 20, 285-300. <https://doi.org/10.18092/ulikidince.341584>
- Yılmazel, 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>
- Yusuf, A., & Ismail, S. (2012). Multiple regressions in analysing house price variations. *Communications of the IBIMA*, 38310. <https://doi.org/10.5171/2012.383101>
- Yücebaş, S. C., Doğan, M., & Genç, L. (2022). A c4.5 – cart decision tree model for real estate price prediction and the analysis of the underlying features. *Konya Mühendislik Bilimleri Dergisi*, 10(1), 147-161. <https://doi.org/10.36306/konjes.1013833>
- 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, 1-15. <https://doi.org/10.1002/cpe.734>
- Zeydan, İ. (2025). Investigation of the factors affecting housing prices for sale in Zonguldak central county using multivariate regression models. *Istanbul Gelisim University Journal of Social Sciences*, 12(1), 170-189. <https://doi.org/10.17336/igusbd.1429433>