

ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

OFİS KİRALARININ BULANIK REGRESYON YÖNTEMİYLE
BELİRLENMESİ: ANKARA İLİ ÖRNEĞİ

Uğur ŞEN

GAYRİMENKUL GELİŞTİRME VE YÖNETİMİ ANABİLİM DALI

ANKARA
2025

Her hakkı saklıdır

ÖZET

Doktora Tezi

OFİS KİRALARININ BULANIK REGRESYON YÖNTEMİYLE BELİRLENMESİ: ANKARA İLİ ÖRNEĞİ

Uğur ŞEN

Ankara Üniversitesi

Fen Bilimleri Enstitüsü

Gayrimenkul Geliştirme ve Yönetimi Anabilim Dalı

Danışman: Prof. Dr. F. Nihan ÖZDEMİR SÖNMEZ

Eş Danışman: Prof. Dr. Furkan BAŞER

Ekonomik dalgalanmalar, sosyal ve teknolojik gelişmeler; işgücünün sektörel yapısını dönüştürerek ofislerdeki taleplerde değişikliklere neden olmaktadır. Bu bağlamda, ofis kira pazarı; ekonomik eğilimlerden ve sektördeki değişikliklerden etkilenmekte ve dolayısıyla kiraların ekonomik, sosyal mekânsal veya çevresel faktörleri birlikte dikkate alan yöntemlerle belirlenmesi gerekmektedir. Ancak geleneksel yöntemler, homojen piyasa varsayımıyla çalıştıkları için, heterojen bir yapıya sahip olan ofis kira pazarında yetersiz kalabilmektedir. Nitekim konum ve bina özellikleri gibi faktörler kirayı önemli ölçüde etkilemekte; bu da ofis pazarının alt pazarlar şeklinde bölünerek analiz edilmesini gerektirmektedir. Bu noktada alt pazarlardaki arz ve talep dinamiklerinin incelenmesini mümkün kılan pazar bölümlendirmesi yaklaşımı, daha gerçekçi ve isabetli değerlendirme sonuçlarının elde edilmesine katkı sağlamaktadır. Diğer yandan pazar bölümlendirmesinde alt pazar sınırlarının kesin biçimde tanımlanamaması, kullanıcı tercihlerinin ölçülebilirliğindeki belirsizlikler, geleneksel modellerin açıklama gücünü sınırlamaktadır. Bu tür belirsizliklerin yönetilmesinde, matematiksel olarak belirsizliği ifade edebilen Bulanık Regresyon Fonksiyonları yöntemi öne çıkmaktadır. Bu araştırmanın amacı, geleneksel yöntemlerin ofis kira pazarını yansıtamadığını ortaya koymak ve bu bağlamda Makine Öğrenmesi ile pazar bölümlendirmesi yaklaşımlarının değerlemeye katkılarını incelemektir. Bu doğrultuda, belirsizlik ve çok boyutluluğun daha doğru modellenebilmesi için pazar bölümlendirmesi ile Bulanık Regresyon Fonksiyonları birlikte ele alınmış ve çeşitli makine öğrenmesi algoritmalarıyla karşılaştırılmıştır. Araştırmada, Ankara ili Çankaya ilçesindeki 14 adet ofis binasına ilişkin 2.228 kira verisi kullanılmıştır. Model performansları; kestirim doğruluğu ve hata oranları dikkate alınarak karşılaştırılmış, en yüksek doğruluk pazar bölümlendirmesi ve Bulanık Regresyon Fonksiyonlarıyla desteklenen Rasgele Orman Modelinde elde edilmiştir (RMSE: 0,237305; MAE: 0,187292; rRMSE: 0,039972; rMAE: 0,031545). Bu bulgular, önerilen yaklaşımın hem teorik hem pratik düzeyde daha duyarlı ve güvenilir sonuçlar sunduğunu göstermektedir. Gayrimenkul pazarının artan heterojenliği ve riskleri, değerlendirme çalışmalarında sağlıklı kestirimlerin yapılabilmesi için matematiksel modellerin kullanılmasını zorunlu kılmaktadır.

Mayıs 2025, 200 sayfa

Anahtar Kelimeler: Ofis kirası kestirim modeli, makine öğrenmesi yöntemleri, mekânsal analiz, pazar bölümlendirmesi, kirayı etkileyen değişkenler

ABSTRACT

PhD Thesis

DETERMINATION OF OFFICE RENT WITH FUZZY REGRESSION METHOD: THE CASE OF ANKARA PROVINCE

Uğur ŞEN

Ankara University
Graduate School of Natural and Applied Sciences
Department of Real Estate Development and Management

Supervisor: Prof. Dr. F. Nihan ÖZDEMİR SÖNMEZ
Co-Supervisor: Prof. Dr. Furkan BAŞER

Economic fluctuations, coupled with social and technological advancements, have significantly transformed the sectoral structure of the labour force, thereby leading to alterations in the demand for office space. Within this framework, the office rental market is subject to influence by prevailing economic trends and sectoral shifts, which underscores the necessity for comprehensive valuation methodologies that incorporate economic, spatial, and environmental considerations. Nevertheless, traditional valuation techniques, predicated on the assumption of a homogeneous market, frequently prove insufficient in the office rental context, which is inherently heterogeneous. Indeed, factors such as location and building characteristics exert a substantial impact on rental prices, warranting an analysis of the office market through a submarket-based approach. In this regard, the market segmentation methodology, which facilitates the examination of supply and demand dynamics within specific submarkets, enhances the accuracy and realism of valuation outcomes. Conversely, the challenges in precisely delineating submarket boundaries and the uncertainties associated with measuring user preferences restrict the explanatory power of traditional models. To address these uncertainties, the Fuzzy Regression Functions approach, capable of mathematically representing vagueness and imprecision, emerges as a robust alternative. The objective of this study is to demonstrate the limitations of traditional valuation methods in capturing the complexities of the office rental market and, in this context, to explore the contributions of Machine Learning and Market Segmentation techniques to rental value estimation. Accordingly, Fuzzy Regression Functions are integrated with Market Segmentation to better model uncertainty and multidimensional structures, with the performance of the proposed methodology compared against various machine learning algorithms. The empirical analysis utilizes a dataset comprising 2,228 rental observations from 14 office buildings situated in the Çankaya district of Ankara. The evaluation of model performance is based on prediction accuracy and error metrics. The optimal predictive performance is observed in the Random Forest model, which is supported by both Market Segmentation and Fuzzy Regression Functions (RMSE: 0.2373; MAE: 0.1873; rRMSE: 0.0399; rMAE: 0.0315). These findings suggest that the proposed approach yields more sensitive and dependable results, both theoretically and practically. Given the increasing heterogeneity and risks within the real estate sector, the utilisation of advanced mathematical models becomes indispensable for obtaining reliable valuation estimates.

May 2025, 200 pages

Keywords: Office rent estimate model, Machine learning methods, Spatial analysis, Market segmentation, Rental price determinants

TEŞEKKÜR

Doktora tezi kapsamında, eğitim sürecim boyunca bilgi ve deneyimleriyle bana rehberlik eden, her aşamada desteğini esirgemeyen ve çalışmanın gelişimine katkı sunan kıymetli danışman hocalarım: Prof. Dr. F. Nihan ÖZDEMİR SÖNMEZ ile Prof. Dr. Furkan BAŞER'e, en derin teşekkürlerimi iletmek isterim. Tez izleme sürecinde, kıymetli katkıları, yol gösterici değerlendirmeleriyle Tez İzleme Komitesi üyesi Sayın Prof. Dr. Nuray TOSUNOĞLU'na en derin teşekkürlerimi iletirim. Ayrıca, gerek yüksek lisans, gerekse doktora öğrenimim süresince akademik gelişimime önemli katkılar sağlayan ve her zaman desteklerini gördüğüm Ankara Üniversitesi Gayrimenkul Geliştirme ve Yönetimi Anabilim Dalı Başkanı Sayın Prof. Dr. Harun TANRIVERMİŞ'e ve Ankara Üniversitesi Gayrimenkul Geliştirme ve Yönetimi Anabilim Dalında görev yapan bütün akademik ve idari personele teşekkürü bir borç bilirim. Bu araştırmada ihtiyaç duyulan Ankara ili ofis piyasasına ilişkin veri setini bilimsel araştırma amaçlı olarak paylaşarak çalışmama önemli katkılar sunan Endeksa Teknoloji Anonim Şirketi yönetici ve çalışanlarına da teşekkürlerimi sunarım. Hayatımın her anında olduğu gibi tez sürecimde de sevgisi, sabrı ve desteğiyle yanımda olan sevgili eşim Esra ŞEN'e, yaşam kaynağım olan çocuklarım Duru ŞEN'e ve Aras ŞEN'e, ayrıca ŞEN ve EROĞLU ailelerinin değerli üyelerine sonsuz şükran ve minnettarlığımı ifade etmek isterim. Onların sevgisi, desteği ve fedakârlıkları, bu çalışmanın tamamlanmasında en büyük motivasyon kaynağım olmuştur. Araştırma sonuçlarının konu ile ilgili olarak yapılacak yeni ve ileri düzeydeki çalışmalara altlık teşkil etmesini ve araştırmacılara yararlı ve yol gösterici olmasını temenni ederim.

Uğur ŞEN

Ankara, Mayıs 2025

İÇİNDEKİLER

TEZ ONAYI

ETİK.....	i
ÖZET.....	ii
ABSTRACT.....	iii
TEŞEKKÜR	iv
KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ	x
1. GİRİŞ	1
1.1 Araştırmanın Önemi ve Amacı	1
1.2 Araştırmanın Kapsamı ve Sınırlılıkları	4
2. KAVRAMSAL ÇERÇEVE VE LİTERATÜR ARAŞTIRMASI	7
2.1 Ofis Pazarı ve Ofis Yapıları	7
2.2 Ofis Kiralarını Etkileyen Değişkenler	11
2.3 Önceki Çalışmalar.....	15
3. KÜRESEL DÜZEYDE VE TÜRKİYE ÖZELİNDE GAYRİMENKUL PAZARI.....	25
3.1 Küresel Gayrimenkul Pazarı ve Uluslararası Sermaye Hareketleri.....	25
3.1.1 Küresel gayrimenkul yatırımlarının sektörel dağılımı.....	34
3.1.2 Küresel gayrimenkul pazarının gelişimine dair tahminler	37
3.2 Türkiye’de Gayrimenkul Pazarının Görünümü	39
3.2.1 Türkiye’de gayrimenkul yatırımlarının sektörel dağılımı	43
3.2.2 Türkiye gayrimenkul pazarının gelişimine dair tahminler.....	45
3.2.3 Ankara ofis pazarının mevcut durumu ve gelişme eğilimleri	48
4. GAYRİMENKUL DEĞERLEMEDE KULLANILAN YÖNTEMLER VE MATEMATİKSEL MODELLERİN KULLANIM OLANAKLARI.....	52
4.1 Geleneksel Değerleme Yaklaşımları.....	54
4.1.1 Pazar yaklaşımı	55
4.1.2 Gelir yaklaşımı	58
4.1.3 Maliyet yaklaşımı	60
4.1.4 İstatistiksel ve matematiksel değerlendirme yöntemleri.....	61
4.2 Makine Öğrenmesi Yöntemleri.....	65

4.2.1 Çoklu Doğrusal Regresyon.....	69
4.2.2 Ridge Regresyonu	72
4.2.3 Lasso Regresyonu.....	74
4.2.4 Karar Ağaçları	75
4.2.5 Rasgele Orman	77
4.2.6 k-En Yakın Komşu.....	79
4.2.7 Destek Vektör Makinesi	84
4.2.8 XGBoost modeli.....	88
4.2.9 Yapay Sinir Ağları	93
4.3 Gayrimenkul Pazar Bölümlendirmesi.....	96
5. BULANIK REGRESYON FONKSİYONLARI VE GAYRİMENKUL DEĞERLEME ARAŞTIRMALARINDA KULLANIM OLANAKLARI.....	104
5.1 Bulanık Kümeleme Algoritmaları	104
5.1.1 Bulanık c-ortalama kümeleme algoritması.....	106
5.2 Bulanık Regresyon Fonksiyonları	113
5.2.1 Yapı tanımlama ve çıkarım	116
6. ANKARA İLİNDE YAPILAN SAHA ÇALIŞMASININ YÖNTEMLERİ.....	122
6.1 Çalışmada Kullanılan Veriler	122
6.2 Verilerin Analizinde Kullanılan Yöntemler	142
6.3 Model Performans Ölçütlerinin Değerlendirilmesi	152
7. ARAŞTIRMA BULGULARI VE TARTIŞMA.....	157
7.1 Araştırma Alanına İlişkin Bulgular	157
7.2 Emsal Değer Analizi.....	161
7.3 Makine Öğrenmesi Yöntemlerine İlişkin Bulgular.....	164
7.4 Bulanık Regresyon Fonksiyonları Yöntemine İlişkin Bulgular.....	168
7.5 Modelden Elde Edilen Bulguların Değerlendirilmesi.....	172
8. SONUÇ VE ÖNERİLER.....	177
KAYNAKLAR	183
ÖZGEÇMİŞ.....	200

KISALTMALAR DİZİNİ

ABD	Amerika Birleşik Devletleri
AdaBoost	Uyarlamalı Artırma (Adaptive Boosting)
ANN	Yapay Sinir Ağları (Artificial Neural Networks)
AVM	Alışveriş Merkezi
BOMA	Bina Sahipleri ve Yöneticileri Derneği (Building Owners and Managers Association)
BREEAM	Bina Araştırmaları Kuruluşu Çevresel Değerlendirme Metodu (Building Research Establishment Environmental Assessment Method)
CPSI	Gayrimenkul Duyarlılık Endeksi (Commercial Property Sentiment Index)
DT	Karar Ağaçları (Decision Trees)
ESG	Çevresel, Sosyal ve Yönetişim (Environmental, Social and Governance)
FCM	Bulanık c-Ortalama (Fuzzy c-Means)
FRF	Bulanık Regresyon Fonksiyonu (Fuzzy Regression Function)
GB	Gradyan Artırma (Gradient Boosting)
GSYH	Gayri Safı Yurtiçi Hasıla
GYODER	Gayrimenkul Yatırımcıları Derneği
IVS	Uluslararası Değerleme Standartları (International Valuation Standards)
IVSC	Uluslararası Değerleme Standartları Konseyi (International Valuation Standards Council)
JLL	Jones Lang LaSalle Anonim Şirketi (Jones Lang LaSalle Incorporated)
k-NN	k-En Yakın Komşu (k-Nearest Neighbors)
LEED	Enerji ve Çevre Tasarımında Liderlik (Leadership in Energy and Environmental Design)
Lineer-SVM	Doğrusal Çekirdekli Destek Vektör Makineleri (Linear Support Vector Machine)
LR	Lasso Regresyonu (Least Absolute Shrinkage and Selection Operator)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
MLR	Çoklu Doğrusal Regresyon (Multiple Linear Regression)
PB	Pazar Bölümlendirmesi
RBF-SVM	Radyal Tabanlı Çekirdekli Destek Vektör Makineleri (Radial Basis Function Support Vector Machine)
RF	Rasgele Orman (Random Forest)

RICS	Lisanslı Değerleme Uzmanları Kraliyet Kurumu (Royal Institution of Chartered Surveyors)
rMAE	Göreceli Ortalama Mutlak Hata (Relative Mean Absolute Error)
RMSE	Kök Hata Kareler Ortalaması (Root Mean Square Error)
RR	Ridge Regresyonu (Ridge Regression)
rRMSE	Göreceli Kök Hata Kareler Ortalaması (Relative Mean Square Error)
SVM	Destek Vektör Makineleri (Support Vector Machines)
TDUB	Türkiye Değerleme Uzmanları Birliği
XGBoost	Aşırı Gradyan Artırma (Extreme Gradient Boosting)

ŞEKİLLER DİZİNİ

Şekil 4.1 Makine öğrenmesi yöntemlerinin çalışma modeli	66
Şekil 4.2 Makine öğrenmesi algoritmaları	67
Şekil 4.3 Bağımsız ve bağımlı değişken arasındaki doğrusal regresyon ilişkisi.....	70
Şekil 4.4 Çoklu Doğrusal Regresyon modelinde uyum düzlemi	71
Şekil 4.5 Karar Ağaçları modelinin genel yapısı	76
Şekil 4.6 Rasgele Orman modelinin genel yapısı	78
Şekil 4.7 k-NN tahmin gösterimi	81
Şekil 4.8 Öklid uzaklığı	82
Şekil 4.9 Manhattan uzaklığı.....	83
Şekil 4.10 Minkowski uzaklığı	84
Şekil 4.11 SVM algoritmasında hiper düzlemin ve marjin alanının görsel gösterimi	85
Şekil 4.12 XGBoost modelleme yaklaşımı	91
Şekil 4.13 ANN temel işleyiş mekanizması.....	95
Şekil 5.1 FRF yaklaşımı ile bulanık sistem modelleme	116
Şekil 5.2 FRF akış şeması	117
Şekil 6.1 Ofis binalarının harita üzerinde gösterimi	132
Şekil 6.2 Ofis binalarının Eskişehir ve Konya yoluna cephe durumları	136
Şekil 6.3 Ofis binalarının Eskişehir ve Konya yoluna olan mesafeleri.....	137
Şekil 6.4 Ofis binalarının metro istasyonuna ve AŞTİ'ye olan mesafeleri.....	138
Şekil 6.5 Kira (TL/m ²) verilerinin dağılımsal incelemesi	143
Şekil 6.6 Logaritmik dönüştürülmüş kira (TL/m ²) verisinin dağılım özellikleri	144
Şekil 6.7 Kira (TL/m ²) verilerindeki aykırılıkların ve yayılımın gösterimi	145
Şekil 6.8 Logaritmik dönüştürülmüş kira (TL/m ²) verilerinin yayılımının incelemesi	146
Şekil 6.9 Ofis alanı (m ²) verisinin dağılım ve yayılım özellikleri	146
Şekil 6.10 Kiralanan ofis brüt alanı (m ²) ile kira (TL/m ²) arasındaki ilişkinin gösterimi .	147
Şekil 6.11 Oda sayısının dağılım ve yayılım özellikleri	149
Şekil 6.12 Oda sayısı ile kira (TL/m ²) verileri arasındaki ilişkinin gösterimi	150
Şekil 6.13 Kiralanan ofisin katı dağılım ve yayılım özellikleri	151
Şekil 6.14 Kiralanan ofisin katı ile kira (TL/m ²) arasındaki ilişkinin gösterimi.....	152
Şekil 7.1 Ankara ili çalışma alanı gösterimi	158

ÇİZELGELER DİZİNİ

Çizelge 3.1 Yeşil bina talebinde artış oranları	29
Çizelge 3.2 Türkiye’deki seçili bölgelerde Mart 2025 tarihinde A sınıfı ofis kiralari....	51
Çizelge 4.1 ANN fonksiyonları.....	96
Çizelge 5.1 Bazı önemli küme geçerlilik göstergeleri	112
Çizelge 6.1 Veri setinde yer alan ofislerin konum ağırlıkları	125
Çizelge 6.2 Veri setinde yer alan ofis binaları	125
Çizelge 6.2 Veri setinde yer alan ofis binaları(devamı).....	126
Çizelge 6.3 Ofis binalarına ilişkin değişkenler	127
Çizelge 6.3 Ofis binalarına ilişkin değişkenler (devamı).....	128
Çizelge 6.3 Ofis binalarına ilişkin değişkenler (devamı).....	129
Çizelge 6.4 Ön işleme sonrası elde edilen değişkenler	129
Çizelge 6.4 Ön işleme sonrası elde edilen değişkenler (devamı).....	130
Çizelge 6.4 Ön işleme sonrası elde edilen değişkenler (devamı).....	131
Çizelge 6.5 Veri setindeki ofis binalarının son dağılımı.....	131
Çizelge 6.5 Veri setindeki ofis binalarının son dağılımı (devamı)	132
Çizelge 6.6 Ofis kirasını etkileyen nihai değişkenler	133
Çizelge 6.7 Ofis sınıfı bazında toplanan kira verileri	134
Çizelge 6.8 Ofis binalarının yaş gruplarına göre kira gözlem sayıları.....	134
Çizelge 6.9 Blok sayısı aralıklarına göre kira gözlem sayıları.....	135
Çizelge 6.10 Veri setindeki ofislerin hizmet türlerine göre dağılımı.....	135
Çizelge 6.11 Ofis binalarında bulunan imkanlar.....	139
Çizelge 6.12 Ofis binalarında sunulan hizmetler	140
Çizelge 6.13 Ofis kirası için örnek veri seti	141
Çizelge 6.13 Ofis kirası için örnek veri seti (devamı)	142
Çizelge 6.14 İç mekânı tamamlanmış/tamamlanmamış ofisler tablosu.....	148
Çizelge 7.1 Ankara ilinin nüfusu	159
Çizelge 7.2 Ankara ilinin nüfusunun yaşlarına göre dağılımı (2023 ve 2024 yılları)...	159
Çizelge 7.3 Başkent’in merkez ilçelerinin nüfusu (2023 ve 2024 yılları).....	160
Çizelge 7.4 Türkiye’de işgücü piyasası verileri (Bin Kişi).....	160
Çizelge 7.5 Emsal alınan ofislerin özellikleri ve kira paraları	163
Çizelge 7.6 Sınırlar içinde kalan emsal ofislerin özellikleri ve kiralari	164

Çizelge 7.7 Makine öğrenmesi yöntemleri eğitim veri seti sonuçları.....	167
Çizelge 7.8 Makine öğrenmesi yöntemleri test veri seti sonuçları	168
Çizelge 7.9 Bulanık Regresyon Fonksiyonları eğitim veri seti sonuçları.....	171
Çizelge 7.10 Bulanık Regresyon Fonksiyonları test veri seti sonuçları.....	172

1. GİRİŞ

Geçmişten günümüze yaşanan ekonomik dalgalanmalar, toplumsal yapıda gerçekleşen dönüşümler ve teknolojik gelişmeler, işgücünde belirgin bir değişimi beraberinde getirmiş; bu durum, modern ofis alanlarına yönelik talebin daha dinamik ve değişken bir yapıya bürünmesine neden olmuştur. Bu çerçevede, geleneksel ofis kiralama modellerinin yanı sıra evden çalışma ve paylaşımlı ofis çözümleri dönemsel olarak artan bir ilgi görmüştür. Özellikle büyükşehirlerin hızlı büyümesiyle birlikte ofis talebinde yaşanan artış, yeni alt merkezlerin oluşumunda itici bir güç haline gelmiştir (Geltner vd. 2013). Ofis kiralalarının doğru ve güvenilir bir şekilde belirlenmesi yalnızca yeni ofis gelişim alanlarının tespitinde değil, aynı zamanda gayrimenkul yatırımlarının stratejik biçimde yönlendirilmesinde ve kentsel planlama süreçlerinin etkinliğinin artırılmasında da kritik bir rol oynamaktadır. Bu bağlamda, ofis pazarındaki dinamiklerin doğru analiz edilmesi ve değerlendirme süreçlerinde yenilikçi yöntemlerin kullanılması, sürdürülebilir şehircilik (örneğin merkezi iş alanı yoğunluklarının dengelenmesi) ve yatırım kararları açısından önem taşımaktadır (Sayce vd. 2012).

1.1 Araştırmanın Önemi ve Amacı

Birçok ülkede ve Türkiye’de ofis pazarı; geleneksel ofisler ve profesyonel yönetime sahip olan plaza tipi ofislerle karakterize edilmekte (dualistik veya ikilili yapı) ve bunların mülkiyet ve kullanım koşulları da farklılık göstermektedir. Profesyonel yatırımcılar tarafından geliştirilen ve inşa edilen ofis binalarında mülkiyet genellikle yatırımcı kuruluş veya kişilerde kalmakta ve kullanıcılara kiralama yapılmakla iken, geleneksel ofislerde mülkiyet ve kullanıcı aynı kişi ve kuruluştadır. Ofislerin büyüklüğü, konumu, kiralama koşulları ve kullanım özelliklerine bağlı olarak kira paraları ve yönetim giderlerinde önemli ölçüde değişimin olduğu ve hem ofis binalarının hem de kiralama pazarının “bölünmüş pazar özelliğini” açıkça yansıttığı bilinmektedir (Tanrıvermiş 2008; Tanrıvermiş 2017; Demirkaya 2025).

Ofis pazarı ve kiralaları; ekonomik eğilimlerden siyasi gelişmelere ve sektörel yeniliklere kadar birçok dışsal faktörden etkilenmektedir (Gyourko ve Keim 1992). Gelişen

ekonomik yapı, kentleşme ve iş dünyasının değişen ihtiyaçları doğrultusunda, ticari gayrimenkul kiralarının özellikle de ofis kiralarının, daha karmaşık ve sürekli değişen yöntemlerle belirlenmesini gerekli kılmaktadır. Bu bağlamda ofis kiralarının doğru ve güvenilir yöntemlerle belirlenmesi hem iş dünyası hem yatırım kararlarının doğruluğu hem de gayrimenkulün finansal performansı açısından büyük önem taşımaktadır. Bu noktada; konum, bina özellikleri, ekonomik ve mekânsal faktörler birlikte ele alınarak kapsamlı bir değerlendirme yapılması gerekmektedir.

Son yıllarda makine öğrenmesi alanındaki hızlı gelişmeler, birçok alanda olduğu gibi gayrimenkul değerlemesi süreçlerinde de yenilikçi uygulamaların önünü açmıştır. Ofis kiralarının belirlenmesinde yaygın biçimde kullanılan geleneksel değerlendirme yaklaşımları, değişkenler arasındaki çok boyutlu ve karmaşık ilişkileri kapsamlı biçimde ortaya koymakta yetersiz kalmakta, sınırlı veri setleri ve öznel değerlendirmeler nedeniyle alternatif yöntemlerin geliştirilmesi kaçınılmaz hâle gelmiştir (Selim ve Demirbilek 2009; Kok vd. 2017). Bu eksiklikler, ofis kira tahminlerinde daha esnek, dinamik ve doğruluğu yüksek modellere olan ihtiyacı artırmıştır. Bu bağlamda, makine öğrenmesi yöntemleri; çok boyutlu veri analiz kabiliyetleri, büyük veri setlerini hızlı işleyebilme potansiyelleri ve yüksek tahmin doğruluğu sunmaları sayesinde, geleneksel yaklaşımlara güçlü bir alternatif oluşturmaktadır (Bansal vd. 2022). Ayrıca makine öğrenmesine dayalı sistemler, yerelden küresele uzanan farklı pazar dinamiklerini karşılaştırmalı olarak analiz etme olanağı sunmakta; bu sayede değerlendirme süreçlerinde piyasa aktörlerine daha nesnel, veriye dayalı ve etkili karar destek mekanizmaları sağlamaktadır.

Türkiye'nin başkenti olan Ankara, nüfus büyüklüğü, kültürel, sosyal ve ekonomik etkisiyle ülkenin önde gelen şehirlerinden biridir. Başkent olmanın getirdiği idari ve diplomatik faaliyetler sayesinde, şehirde çok sayıda kamu kurumu, uluslararası kuruluşlar ve büyük ölçekli şirket faaliyet göstermektedir. Şehirde bölgelere göre değişen arz ve talep ofis kiralarının belirlenmesinde önemli bir rol oynamaktadır. Belirli bölgelerdeki iş merkezlerine olan yüksek talep, kiraların yüksek olmasına neden olurken; şehrin çevre bölgelerinde ise daha farklı kira eğilimleri görülmektedir. Bu durum, Ankara'daki ofis kira pazarının heterojen ve dinamik bir yapıya sahip olduğunu göstermekte, dolayısıyla yerel dinamiklerin detaylı biçimde analiz edilmesini zorunlu kılmaktadır.

Ticari gayrimenkul değerlemelerinde, özellikle de ofis kiralarının belirlenmesinde, geleneksel değerlendirme yaklaşımlarının yeterli olmadığı durumlar sıklıkla görülmektedir. Çünkü ofis kira pazarı, fiziksel özellikler, konum, bina sınıfı, ulaşım olanakları ve çevresel faktörler açısından homojen olmayan bir yapıya sahiptir. Bu karmaşık yapı, aynı şehir içerisinde bile ofis kiralarının büyük farklılıklar göstermesine neden olmaktadır. Bu bağlamda, pazar bölümlendirmesi (PB) yaklaşımı, farklı alt pazarlardaki arz ve talep dinamiklerinin ayrı ayrı analiz edilmesini mümkün kılarak, daha gerçekçi ve isabetli değerlendirme sonuçlarının elde edilmesine katkı sağlamaktadır (Goodman ve Thibodeau 1998). Özellikle büyük ve karmaşık şehirlerde, ofis kullanıcılarının ihtiyaçlarının çeşitlenmesi ve mekânsal dağılımdaki farklılıklar, PB yönteminin önemini daha da artırmaktadır. Buna karşılık PB yapılmaksızın geliştirilen modeller, bölgesel farklılıkları göz ardı edebileceğinden, kiralarda yanıltıcı kestirim sonuçları ortaya çıkarabilmektedir.

Belirtilen noktada devreye giren Bulanık Regresyon Fonksiyonu (Fuzzy Regression Function, FRF), belirsizlik içeren ve karmaşık yapıya sahip pazarların analizinde güçlü bir modelleme yaklaşımı sunmaktadır. Ofis kira pazarı gibi çok sayıda nitel ve nicel faktörlerin etkili olduğu karmaşık pazarlarda, klasik regresyon modelleri çoğu zaman yetersiz kalabilmekte; FRF ise uzman görüşü, kullanıcı tercihi ve çevresel algı gibi ölçülmesi güç fakat etkili faktörleri modelleyerek bu boşluğu kapatmaktadır. Bu sayede, klasik modellerin dışladığı nitel veriler modellemeye dâhil edilebilmekte; böylece daha esnek, duyarlı ve gerçekçi tahminler üretilmesi mümkün olmaktadır (Tanaka vd. 1989). Bu yöntem ile daha esnek, duyarlı ve gerçekçi tahminler üretilmesine olanak tanımaktadır ve bu nedenle hem akademik araştırmalarda hem de uygulayıcılar nezdinde alternatif bir modelleme yaklaşımı olarak değerlendirilmektedir.

Araştırmanın temel amacı, ofis kira değerlemesinde geleneksel yaklaşımların yetersizliklerini ortaya koymak; ofis binalarının fiziksel, konumsal ve fonksiyonel farklılıklarını dikkate alan PB yaklaşımının gerekliliğini vurgulamak ve bu bölümlere özgü belirsizliklerin analizinde FRF yöntemini alternatif bir modelleme aracı olarak değerlendirmektir. Gayrimenkul piyasalarının doğasında yer alan belirsizlik, değişkenler arası çok boyutlu ilişkiler ve doğrusal olmayan yapılar, geleneksel modelleme tekniklerinin açıklama gücünü sınırlamaktadır. Bu nedenle, belirsizlikleri matematiksel

olarak ifade edebilen ve karmaşık veri desenlerini yorumlayabilen FRF, özellikle ofis kiralarının tahmininde önemli bir alternatif sunmaktadır (Tanaka vd. 1982).

Ankara ili Çankaya ilçesi örneği üzerinden yürütülen araştırmada; PB yaklaşımı kullanılarak ofis pazarı alt bölümlere ayrılacak, geleneksel değerlendirme yöntemleri, çeşitli makine öğrenmesi algoritmaları ve FRF yöntemi karşılaştırmalı olarak analiz edilmiştir. Elde edilen bulgular; yalnızca kuramsal katkılar sağlamakla kalmayacak, aynı zamanda gayrimenkul sektöründe faaliyet gösteren profesyonellere, yatırımcılara ve karar vericilere yönelik olarak daha doğru, veri temelli ve stratejik değerlendirme uygulamalarının geliştirilmesine zemin hazırlayacaktır. Bu tür modellemelerin, sadece teknik değil aynı zamanda yönetsel ve kentsel planlama süreçlerinde de karar destek mekanizması olarak kullanılması mümkün olup yerel yönetimler ve planlama otoriteleri için veri temelli ofis yeri planlaması yapabilmenin yolunu açmaktadır. Böylece, araştırmanın bulguları hem literatürdeki yöntemsel boşlukları dolduracak hem de benzer yapısal özellikler gösteren şehirler için uygulanabilir model önerileri sunarak saha uygulamalarına ışık tutacaktır.

1.2 Araştırmanın Kapsamı ve Sınırlılıkları

Araştırmada, literatürdeki güncel çalışmalar incelendikten sonra, Ankara ili Çankaya ilçesinde yer alan çeşitli binalardaki ofislerin kiralarının belirlenmesi süreci ele alınmıştır. Bu kapsamda, ticari gayrimenkul pazarında yaygın olarak kullanılan emsal değer analizi gibi geleneksel değerlendirme yaklaşımı ile makine öğrenmesi algoritmaları ve FRF yöntemi değerlendirme kapsamına alınmıştır.

Ofis kiralarını etkileyen fiziksel özellikler (örneğin, ofis büyüklüğü, binanın yaşı ve kat sayısı), konumsal özellikler (örneğin, merkezi yerlere ve ulaşım ağlarına yakınlık), çevresel faktörler (örneğin, çevredeki ticari faaliyetler ve sosyal olanaklar) ve arz-talep dengesi gibi pazar koşulları dikkate alınarak çok sayıda değişken detaylı şekilde analiz edilmiştir. Bu değişkenlerin kira kestirimine olan etkisi ve farklı modelleme teknikleriyle verdikleri sonuçlar değerlendirilmiş; pazarın heterojen yapısı göz önüne alındığında, PB yaklaşımının gerekliliği vurgulanmıştır.

Farklı alt pazarlardaki dinamiklerin ayrı ayrı ele alınması, model doğruluğunu artıran temel unsurlardan biri olarak değerlendirilmiştir. Ayrıca FRF yöntemi, belirsizliklerin hâkim olduğu bu tür karmaşık piyasalarda alternatif ve tamamlayıcı bir modelleme yaklaşımı olarak ele alınmış; uygulama düzeyi ve tahmin başarımı açısından diğer yöntemlerle karşılaştırılmıştır. Bu yönüyle araştırma hem model performanslarını hem de ofis piyasasının yapısal karmaşıklığını dikkate alan bütüncül bir değerlendirme sunmaktadır.

Uygulama aşamasında, Ankara ili Çankaya ilçesinde yer alan ofis binalarına ilişkin toplanan veriler kullanılarak kira kestirimine yönelik analizler gerçekleştirilmiştir. Araştırmada, geleneksel yöntemler kapsamında emsal değer analizi yöntemi, farklı makine öğrenmesi algoritmaları ve FRF olmak üzere üç modelleme yaklaşımı karşılaştırmalı biçimde ele alınmıştır. Her bir yöntemle ilişkin tahmin doğruluğu, hata oranları ve modelin genelleme kapasitesi gibi performans ölçütleri dikkate alınmıştır. Bu değerlendirme ile amaçlanan, ofis kiralarını hangi yöntemin daha doğru ve güvenilir şekilde tahmin ettiğini belirlemek ve bu yöntemlerin hangi koşullar altında üstünlük sağladığını ortaya koymaktır. Elde edilen sonuçlar, gayrimenkul alanında esnek, yenilikçi ve veriye dayalı karar destek mekanizmalarının geliştirilmesine katkı sunmayı amaçlamaktadır.

Veri setinin analiz ve modelleme aşamalarında karşılaşılan sınırlılıklar, elde edilen sonuçların yorumlanması ve genellenebilirliği açısından kritik öneme sahiptir. Veri kalitesi ve özellikleri, verilerin toplanmasında zaman ve mekân kısıtlamaları, model seçimi, aykırı değerler ve veri dengesizliği gibi unsurlar, araştırmanın güvenilirliği ve geçerliliğini etkileyen temel sınırlılıklar arasında yer almaktadır. Ayrıca, dışsal faktörlerin etkisi gibi öngörülemeyen değişkenler de sonuçları sınırlayan unsurlar arasında değerlendirilmelidir.

Araştırmada kullanılan ofis kira verileri, saha araştırmaları ve Endeksa Teknoloji Anonim Şirketi tarafından sağlanan ilan verilerine dayanmaktadır. İlan verilerinin doğruluğunu ve güncelliğini sağlamak amacıyla sahadan elde edilen gözlemlerle karşılaştırmalar yapılmış ve veri tutarlılığı kontrol edilmiştir. Bu doğrultuda, nitel veri toplama yöntemleri

kapsamında yürütülen doğrudan saha çalışmaları, yüz yüze görüşmeler ve yerinde incelemeler aracılığıyla, ofis kiralarna ilişkin veriler yerel piyasa aktörlerinden doğrudan elde edilmiştir. Ancak, ilan verilerinin piyasa gerçeklerini tam olarak yansıtamama ihtimali ile saha verilerinin sınırlı örneklem büyüklüğü, modelin genellenebilirliği açısından dikkatle değerlendirilmesi gereken unsurlar arasında yer almaktadır. Analizde kullanılan ofis kiralari, yalnızca belirli bir zaman dilimini ve coğrafi bölgeyi kapsamakta ve bu nedenle, pazar koşullarındaki değişimlerin doğru şekilde analiz edilebilmesi için verilerin sürekli güncellenmesi gerekliliğı de bir sınırlılık olarak ortaya çıkmaktadır.

Kullanılan algoritmalar ve bu algoritmalara ait parametre ayarlarının seçimi ise model performansı üzerinde doğrudan etkilidir. Bu durum, elde edilen sonuçların doğruluğunu sınırlayabileceğı gibi, farklı veri kümelerinde aynı başarıyı gösterme olasılığını da azaltmaktadır. Bu noktada araştırmanın kapsamı, yalnızca Ankara iline bağılı Çankaya ilçesindeki ofis binaları ile sınırlandırılmış olup konutlar ve diğer gayrimenkul türleri araştırma dışında bırakılmıştır. Ankara'nın kendine özgü piyasa dinamikleri göz önüne alındığında, ulaşılan bulguların Türkiye'nin diğer şehirlerindeki ofis piyasalarına doğrudan aktarılması uygun olmayabilecektir.

Araştırma alanı olarak Ankara ili genelinde bir yaklaşım benimsenmiş olsa da veri yoğunluğu ve ticari ofis arzının en yüksek olduğu bölge olması nedeniyle araştırma ağırlıklı olarak Çankaya ilçesi sınırlarında gerçekleştirilmiştir. Çankaya, başkent Ankara'nın idari, finansal ve ticari merkezidir. Özellikle Söğütözü, Mustafa Kemal, Çukurambar, Kızılırmak ve İşçi Blokları gibi mahallelerde yer alan A ve A+ sınıfı ofis binaları; piyasanın dinamiklerini yansıtan en belirgin örnekleri sunmaktadır. Bu mahallelerdeki ofis stoku, kira düzeyleri ve arz-talep ilişkisi, Ankara ili profesyonel ofis piyasasının yapısını en iyi temsil edebilecek nitelikte bulunmaktadır. Buna ilave olarak veri erişilebilirliği, pazarın etkinliği ve fiyat farklılaşmasının gözlenebilirliği açısından bu bölge tercih edilmesi zorunluluğı bulunmaktadır. Açıklanan gerekçelerle Çankaya ilçesinin örnekleme yoğunluklu olarak yer alması, araştırmanın istatistiksel gücünü ve modelleme doğruluğunu artırmak amacıyla bilinçli olarak yapılmış bir tercih olmaktadır.

2. KAVRAMSAL ÇERÇEVE VE LİTERATÜR ARAŞTIRMASI

Gayrimenkul değeriemesi alanında yapılan çalışmalarda kavramsal altyapının doğru şekilde tanımlanması ve ilgili literatürün sistematik olarak analiz edilmesi, teorik yönelimin belirlenmesi ve yöntemsel tercihlerin gerekçelendirilmesi açısından büyük önem taşımaktadır. Bu bölümde, öncelikle ofis pazarı ve ofis yapıları ele alınarak, günümüz ofis piyasasını şekillendiren temel dinamikler ortaya konulacaktır. Ardından, ofis kirasını etkileyen fiziksel, konumsal, çevresel ve ekonomik faktörler çok boyutlu bir çerçevede değeriendirilecek; böylece değerieme sürecinde dikkate alınması gereken temel değişkenlerin yapısı analiz edilmiştir. Son olarak literatürde yer alan akademik çalışmalar, sistematik biçimde incelenerek hem geleneksel hem de yenilikçi modelleme yaklaşımlarının ofis kira kestiriminde kullanım biçimleri ve başarı düzeyleri karşılaştırmalı olarak değeriendirilmiştir. Bu kapsamda yapılan incelemeler, araştırmanın kuramsal temellerini güçlendirmekte ve çalışma kapsamında tercih edilen yöntemlerin literatürdeki yerini netleştirmektedir.

2.1 Ofis Pazarı ve Ofis Yapıları

Ofis pazarı, iş dünyasının ihtiyaçlarına göre şekillenen ve ticari gayrimenkul sektörünün önemli bir parçası olan bir pazardır. Talep ve arz dengesi, boşluk oranları, ekonomik koşullar, uzaktan çalışma gibi işyeri kültüründeki değişimler, teknoloji kullanımı vb. çeşitli faktörler bu pazarı etkilemektedir. Ayrıca, ticari gayrimenkul sektörü içinde önemli bir alt pazar olarak konumlanmakta olup hem yerel hem de ülke düzeyinde ekonomik açıdan dikkate değeri bir rol üstlenmektedir. Bu bağlamda ofis pazarına ilişkin kavramsal çerçeve çizilirken, pazarın dinamiklerinin anlaşılması, kiraları etkileyen değişkenlerin belirlenmesi ve değerieme süreçlerinin kapsamlı bir şekilde ele alınması, mevcut durumu ve gelecekteki kira eğilimlerini anlamada oldukça önemlidir.

Ofis pazarındaki bu dönüşümler, geleneksel yapıların sorgulanmasına ve yeni ofis tipolojilerinin gelişmesine neden olmuştur. Son yıllarda, ortak kullanım alanlarının ve paylaşımlı ofis çözümlerinin popülaritesi artmakta; bu nedenle işletmeler de fiziksel mekân ihtiyaçlarını yeniden değeriendirmektedir. Değişen sosyal ve ekonomik koşullarda

sürdürülebilir ofis uygulamaları, dijital dönüşüm ve iş modellerinin çeşitlenmesi gibi unsurlar, ofis alanlarına yönelik talebin önemli parçası haline gelmiştir.

Genel olarak ofis pazarı, büyükşehir merkezlerinde ekonomik aktivitelerin yoğunlaştığı merkezi iş alanlarında gelişim gösterirken, bu alanlardaki prestijli binalarda yüksek kiraların olduğu ve şehir merkezinden uzaklaştıkça da genellikle daha düşük kiraların olduğu görülmektedir. Yeni ofis binalarının inşaatları ve mevcut ofislerin fonksiyonel değişimleri arz tarafında etkili olurken; ekonomik ve sektörel değişiklikler ile yeni çalışma biçimlerinin ortaya çıkması, talep tarafında önemli unsurlar olarak karşımıza çıkmaktadır. Özellikle koronavirüs pandemisinin etkisiyle yaygınlaşan uzaktan çalışma modelleri, ofis pazarında 2022 yılı sonuna kadar önemli değişikliklere neden olmuş ve kiralardaki talebi yeniden şekillendirmiştir.

Gelir getirici nitelikteki gayrimenkullerin belirli kategorilere göre sınıflandırılması hem piyasa analizlerinde hem de değerlendirme çalışmalarında sistematik bir yaklaşım geliştirilmesini sağlamaktadır (Graham ve Bible 1992). Bu tür bir sınıflandırma, aynı zamanda uluslararası düzeyde gayrimenkullerin karşılaştırılabilirliğini artırarak küresel ölçekte analiz yapma olanağı sunmaktadır (Daud vd. 2011). Ofis binalarına yönelik sınıflandırmalarda, farklı ülkeler arasında olduğu gibi, aynı kent ya da bölge içindeki uygulamalarda da tanım ve değerlendirme farklılıkları gözlemlenebilmektedir. Bu tür sınıflandırmalarda temel alınan kriterler çoğunlukla yapının inşaat kalitesi, bulunduğu lokasyon, kullanıcı profili, bina yaşı vb. fiziksel nitelikler gibi parametreler etrafında şekillenmektedir (Dilaver 2016).

Adnan vd. (2009) çalışmasında, ofis binalarının sınıflandırılmasında dikkate alınan kriterlerin ülkeden ülkeye farklılık gösterebileceğini ifade etmiştir. Çalışmada, konum, ulaşılabilirlik, bina özellikleri, bina yaşı, toplam kat alanı, kat alanı, (!) tesisat, altyapı, yeşil unsurlar ve otopark gibi değişkenlerin farklı ülkelerde farklı ağırlıklarla ele alındığı belirtilmektedir. Örneğin, konum; Amerika Birleşik Devletleri (ABD), Avustralya, İngiltere, Japonya, Singapur ve Hong Kong gibi ülkelerde ortak bir sınıflandırma faktörü olarak kabul edilirken; yeşil bina bileşenleri yalnızca Avustralya, Hong Kong ve Singapur'da dikkate alınmaktadır. Benzer şekilde, otopark kriteri İngiltere, Japonya,

Hong Kong ve Singapur’da sınıflandırma ölçütleri arasında yer alırken, ABD ve Avustralya’da bu kriter daha az belirleyicidir. Bu durum, sınıflandırma kriterlerinin bölgesel piyasa koşulları, kullanıcı ihtiyaçları ve kentsel yapılaşma özelliklerine göre çeşitlendiğini ortaya koymaktadır.

Graham ve Bible’in (1992) çalışmasında, ofis binaları AA, A, B, C ve D olmak üzere beş farklı sınıfa ayrılmıştır. Bu sınıflandırmada, AA sınıfı, en yüksek düzeyde inşaat kalitesine ve prestijli kiracı profiline sahip yapıları ifade ederken; D sınıfı, tüm değerlendirilen kriterler bakımından en düşük nitelikleri taşıyan yapıları kapsamaktadır.

Uluslararası ölçekte, ofis binalarının sınıflandırılmasına ilişkin standartlaşmış ve genel geçer kabul gören bir sistem bulunmamaktadır. Bu alanda en yetkin kurum olarak değerlendirilen Bina Sahipleri ve Yöneticileri Derneği (Building Owners and Managers Association, BOMA), sınıflandırma uygulamalarının yerel piyasa koşullarına göre şekillenmesi gerektiğini savunmaktadır. Bu nedenle, BOMA tekil gayrimenkuller için resmi ve sabit sınıflandırma dereceleri yayımlamaktan özellikle kaçınmaktadır. Kuruluşun bu yaklaşımı, ülkeler, şehirler ve bölgeler arasında farklılık gösteren arz-talep dengelerinin dikkate alınması gerektiği görüşüne dayanmaktadır.

Her ne kadar BOMA ofis binalarının sınıflandırılmasına ilişkin kesin standartlar belirlemekten kaçınsa da özellikle A sınıfı ofis binaları için bazı temel nitelikler öne çıkarılmaktadır. BOMA’nın sınıflandırmasına göre; A sınıfı ofis binaları, bulundukları bölgede kira ortalamalarının üzerinde değer taşıyan, yüksek prestijli kullanıcılar tarafından tercih edilen ve üst düzey fiziksel ve teknik özelliklere sahip yapılar olarak tanımlanmaktadır. Ayrıca, bu yapıların yüksek kaliteli iç bitirme malzemeleri, ileri teknoloji sistemleri, kolay erişilebilirlik ve güçlü bir piyasa görünürlüğü ile öne çıkmaları beklenmektedir. B sınıfı ofis binaları daha geniş bir kullanıcı kitlesine hitap etmekte olup kiralari genellikle piyasa ortalamalarında seyretmektedir. Bu tür yapılar, A sınıfı kadar yüksek kalitede inşa edilmemiş olsa da yeterli teknolojik donanıma sahip, bakımlı ve fonksiyonel kullanım sunan yapılardır. C sınıfı ofis binalar ise genellikle piyasa ortalamasının altında kira seviyelerinde hizmet sunan, fonksiyonelliği ön planda tutan ve daha düşük bütçeli kullanıcı profiline hitap eden yapılardır. Bu binalar, genellikle daha

eski, yenileme ihtiyacı olan, teknolojik ve fiziksel özellikler bakımından geliştirilmesi gereken yapılardır (Anonymous 2025c). Ancak bu tanım, yorumlamaya açık bazı unsurlar içermektedir. Bu nedenle, çeşitli gayrimenkul piyasalarında yalnızca A, B ve C şeklinde üç sınıf üzerinden yapılan sınıflandırmaların yetersiz kaldığı görülmektedir.

Türkiye’de ise bu sınıflandırma sistemi, özellikle Tanrıvermiş (2016) tarafından detaylı biçimde açıklanmıştır. Tanrıvermiş’e göre ofis yapıları; A+, A, B+, B ve C olmak üzere beş ana sınıfa ayrılmaktadır. A+ sınıfı yapılar, genellikle son on yıl içinde inşa edilmiş, sürdürülebilirlik sertifikalarına sahip, ileri teknoloji ile donatılmış, merkezi konumda yer alan ve prestijli kullanıcılarca tercih edilen üst segment yapılardır. A sınıfı yapılar ise benzer özelliklere sahip olmakla birlikte, teknolojik ve mimari açıdan bir derece daha alt seviyededir.

B+ sınıfı yapılar, 0-10 yaş aralığında olup mimari ve yönetsel olarak belirli bir standartta yer almakla birlikte, teknoloji ve erişilebilirlik gibi açılardan sınırlılıklar içerebilmekte olup B sınıfı yapılar da genellikle 10-20 yaş aralığında, temel kullanıcı ihtiyaçlarını karşılayabilen, ancak eskiyen altyapı ve donanımları nedeniyle orta düzeyli kullanıcılar için uygun yapılardır. C sınıfı yapılar ise, 20 yıl üzeri yapılar olup modern ofis gereksinimlerine cevap vermekte zorlanan, düşük bütçeli ve daha küçük ölçekli işletmeler tarafından tercih edilen yapılardır (Tanrıvermiş 2016).

Ofis sınıflandırmaları, yalnızca değerlendirme süreçlerini kolaylaştırmakla kalmayıp; yatırımcı, kiracı ve yöneticiler açısından pazardaki konumlandırmayı da belirlemektedir. Ayrıca, bu sınıflandırmalar, pazar analizlerinde nesnel bir temel oluşturarak, kira farklılaşmasının nedenlerini açıklamada ve politikaların oluşturulmasında önemli bir rol oynamaktadır. Bu nedenle, bölgesel farkların ve yerel piyasa dinamiklerinin göz önünde bulundurulduğu çok katmanlı sınıflandırma sistemleri, yerli ve yabancı yatırımcılar açısından daha sağlıklı karar alma süreçlerine katkı sunmaktadır.

2.2 Ofis Kiralarını Etkileyen Değişkenler

Küresel ölçekte ekonomik faaliyetlerin en önemli yapı taşlarından biri olarak değerlendirilen ticari gayrimenkul sektörü, sanayi ve hizmet alanlarındaki gelişmelere bağlı olarak büyüme göstermektedir. Bu durum, özellikle kentsel alanlarda ofis kullanımına yönelik talebin artmasıyla daha da belirgin hâle gelmektedir (Feng ve Wu 2022). Uluslararası şirketlerin gelişmekte olan pazarlara giriş yapması ise, yüksek kaliteli ve stratejik ofis alanlarına olan ilgiyi artırmakta ve bu da yerel pazarları doğrudan etkilemektedir.

Gelişmekte olan ülkelerde ofis pazarı, yapısal düzeyde bazı temel problemlerle karşılaşmaktadır. Özellikle bina yaşam döngüsü boyunca gözlenen kiralardaki ve doluluk oranlarındaki dalgalanmalar, yalnızca ticari gayrimenkul sektörünü değil, genel ekonomik istikrarı da olumsuz yönde etkileyebilmektedir (Gholipour vd. 2022). Bu tür dalgalanmalar, pazar içerisinde belirsizlikleri artırarak yatırım kararlarını zorlaştırmakta ve sürdürülebilir büyüme açısından tehdit oluşturmaktadır. Çalışmaların çoğu ekonomik belirleyicilerin kira seviyeleri üzerindeki etkilerini incelemesine rağmen, büyük bir kısmının güncelliğini yitirdiği ve gelişmekte olan ekonomilerin özgün koşullarını yeterince yansıtmadığı görülmektedir (Akinsomi vd. 2018; Simon vd. 2015; Thebuwena ve Vaz 2025). Bu bağlamda, Türkiye gibi gelişen pazarlarda, güncel verilerle desteklenen analizlerin yapılması önem arz etmektedir.

Literatürde, ofis kiralarını belirleyen etkenler genellikle dört ana başlık altında sınıflandırılmaktadır: konumsal özellikler, bina ile ilgili faktörler, ekonomik göstergeler ve diğer tamamlayıcı değişkenler. Bu kategorilerden ilki olan konum değişkenleri, birçok akademik çalışmada ofis kirasını etkileyen en kritik faktörlerden biri olarak kabul edilmektedir. Ayrıca ulaşım noktalarına ve ana yollara erişim kolaylığı olan ve kent merkezine yakın ofislerin, çalışanlar ve müşteriler tarafından tercih edildiği görülmektedir. Bu sebeptendir ki İstanbul, Ankara ve İzmir gibi büyükşehirlerde merkezi bölgelerde yer alan ofislerin kiralari, diğer bölgelere kıyasla prestijli bölgelerde yer almaları sebebiyle oldukça yüksektir. Londra, New York ve Tokyo gibi küresel finans

merkezlerine bakıldığında ise yüksek talep ve sınırlı arz nedeniyle benzer eğilimlerin olduğu görülmektedir (Hendershott vd. 2010).

İkinci kategori olan bina değişkenleri, ofis kirasını doğrudan etkileyen fiziksel ve yapısal özellikleri kapsamaktadır. Ofisin büyüklüğü, yaşı, kat sayısı, cephesi, mimari tasarımı, iç mekân düzenlemesi ve bina altyapısı gibi birçok faktör, kirayı belirlemede önemli rol oynamaktadır (Eichholtz vd. 2013). Özellikle yeni ve modern ofis binalarında bulunan ileri teknoloji olanakları, güçlü altyapı sistemleri, enerji tasarrufu sağlayan uygulamalar ve sürdürülebilirlik kriterleri, kiracıların tercihlerini etkilemekte ve kiralari yukarı çekmektedir (Fuerst ve McAllister 2011).

Üçüncü olarak, ekonomik değişkenler ofis kiralariını etkileyen temel faktörlerden biridir. Enflasyon, işsizlik oranı, faiz oranları, döviz kuru, Gayri Safi Yurtiçi Hâsıla (GSYH), ekonomik göstergeler ve belirsizlikler, pazar rekabeti, arz ve talep dengesi gibi faktörler ofis kiralari üzerinde güçlü bir etkiye sahiptir. Türkiye’de ofis kira pazarı, özellikle döviz kuru dalgalanmaları ve faiz oranlarındaki değişimlere oldukça duyarlıdır. Bu durum, uluslararası şirketler için kira maliyetlerinin kestirimini zorlaştıran bir faktör olarak öne çıkmaktadır. Ekonomik büyümenin hızlandığı dönemlerde şirketlerin genişleme eğiliminde olmaları, işsizlik oranındaki düşüş ile istihdamın artması sonucunda ofislere olan talebin yükselmesine ve kiralariın artmasına neden olmaktadır (Wheaton 2003).

Açıklanan çerçevede, Yalçiner’in (2018) Gayrimenkul Finansmanı adlı eserinde de vurgulandığı üzere, gayrimenkul piyasaları döngüsel bir yapı sergilemektedir. Genişleme, aşırı arz, durgunluk ve toparlanma olmak üzere dört evrede ilerleyen bu döngü; ofis kiralariının seviyesini ve piyasa dengesini doğrudan etkileyebilmektedir. Genişleme evresinde talep artışı ve sınırlı arz kira artışlarını teşvik ederken, durgunluk evresinde artan boşluk oranları ve azalan talep, kiralariın düşmesine neden olmaktadır. Dolayısıyla, kira seviyelerinin değerlendirilmesinde içinde bulunulan gayrimenkul döngüsünün doğru şekilde analiz edilmesi büyük önem taşımaktadır.

GSYH’deki yükseliş ile gayrimenkul fiyatları arasındaki pozitif yönlü ilişki, yatırımcıların gelişen bölgeleri tercih etmesinde belirleyici bir unsur olmaktadır. Her ne

kadar kira bazlı gayrimenkul yatırımlarının cazibesi son yıllarda azalmış gibi görünse de ticari gayrimenkul kiralarının belirlenmesinde en etkin aktörlerin kiracılar olduğu unutulmamalıdır (Younglai 2023). Ayrıca yüksek enflasyon, gayrimenkul fiyatlarını ve kira sözleşmelerinde enflasyon oranında kiraları artırabilmektedir. Özellikle kira sözleşmelerinde enflasyon oranında artış maddelerinin yer alması sebebiyle kiraların düzenli olarak yükselmesine neden olabilmektedir. Düşük faiz oranları ise gayrimenkul yatırımlarını cazip hale getirerek ofis arzını artırabilmekte, bu durumla birlikte kiraları dengeleyebilmektedir (Hendershott vd. 2002).

Kira artış oranları, kira süresi, kiracının güvenilirliği ve döviz bazlı kira sözleşmeleri gibi faktörler, kira sözleşmelerini doğrudan etkileyen unsurlar arasındadır. Uluslararası işletmeler, Türkiye’de genellikle döviz bazlı kira sözleşmeleri tercih etmektedir ve döviz kurundaki dalgalanmalar, kiralarda önemli değişikliklere yol açabilmekte ve pazarlarında belirsizlikler yaratabilmektedir. Bu durum, kira sözleşmelerinin yenilenmesi veya müzakere süreçlerinde tarafların daha dikkatli hareket etmelerine neden olmaktadır. Nüfus yoğunluğu, eğitim düzeyi, işgücü kapasitesi ve bölgedeki ticari faaliyetlerin çeşitliliği, kira üzerinde doğrudan etkiye sahiptir (Balchin vd. 2000).

Dördüncü ve son kategori olan diğer değişkenler, doğrudan konum, bina ya da ekonomik yapı ile ilişkilendirilemeyen, ancak ofis kiraları üzerinde etkili olan farklı unsurları kapsamaktadır. Bu kapsamda, operasyonel maliyet farklılıkları, yeşil bina uygulamaları, markalaşma stratejileri, pandemi gibi olağanüstü durumların etkileri ve kullanıcı tercihlerini şekillendiren faktörler değerlendirilmektedir. Özellikle ofis kullanıcılarının hizmet kalitesi, sürdürülebilirlik uygulamaları ve marka değeri gibi ölçütleri dikkate alarak daha yüksek kira ödemeye istekli olmaları, bu değişkenlerin önemini ortaya koymaktadır.

Ofis kiralarını etkileyen temel faktörlerden biri de binalar arasındaki yapısal benzerliklere rağmen değişkenlik gösteren operasyonel maliyetlerdir. Özellikle enerji ve su verimliliği sağlayan özelliklerin kiracılar nezdinde kirayı artırdığı çeşitli çalışmalarda ortaya konmuştur. Örneğin, Şangay ofis piyasasında yapılan bir araştırma, enerji tasarruflu sistemlere sahip binaların daha yüksek kira geliri elde ettiğini göstermiştir (Zhang ve Yin

2022). Benzer şekilde, düşük işletme maliyeti sunan yapıların genellikle yeşil sertifikalı olduğu ve bu durumun kira oranlarını pozitif etkilediği belirlenmiştir. Bu doğrultuda, birçok ülkede çevre dostu ofis binaları çeşitli teşviklerle desteklenmekte ve yeşil bina uygulamaları yaygınlaşmaktadır (Thebuwena ve Vaz 2025).

Enerji ve Çevre Tasarımında Liderlik (Leadership in Energy and Environmental Design, LEED) ve Bina Araştırmaları Kuruluşu Çevresel Değerlendirme Metodu (Building Research Establishment Environmental Assessment Method, BREEAM) gibi akıllı bina teknolojileri ve enerji verimliliği sertifikalarına sahip ofisler, çevreye duyarlı özellikleri ve daha düşük işletme maliyetleriyle daha yüksek bir değer ile kiralanmaktadır (Miller vd. 2009). Bu durumda ise hem enerji maliyetlerinde tasarruf sağlamak isteyen kiracılar hem de çevreye duyarlı işletmeler için bu tarz ofisler tercih sebebi olarak karşımıza çıkmaktadır (Pivo ve Fisher 2010). Bir diğer önemli sorun, arzın ofis talebine yeterince hızlı yanıt verememesidir. İnşaat süreçlerinin uzunluğu ve yatırım kararlarının gecikmeli alınması, piyasalarda kısa vadeli arz fazlası veya eksikliği yaratmakta, bu da kiralara üzerinde dalgalanmalara neden olmaktadır (Madushika ve Gunawardhana 2019; Tedja vd. 2021).

Dengesizliği derinleştiren bir diğer unsur ise koronavirüs pandemisi sonrası dönemde ofis talebindeki azalmadır. Benzer özelliklere sahip ofis binaları arasında dahi kira ve doluluk oranı farklılıkları görülmesi, ofis kullanıcılarının yalnızca mekânsal ihtiyaçlara değil, aynı zamanda ek hizmetlere ve işlevsellik beklentilerine de önem verdiğini göstermektedir. Bilgi ekonomisinin, esnek çalışma biçimlerinin ve dijitalleşmenin etkisiyle ortaya çıkan bu değişim, sadece fiziki yapının yeterli olmadığı; destekleyici özelliklerin de tercihleri etkilediği bir yapıya işaret etmektedir (Delventhal vd. 2022; Nase vd. 2019; Nurzokhrufa vd. 2018; Thebuwena ve Vaz 2025).

Koronavirüs pandemisi, ofis piyasalarında kira ve doluluk oranları üzerinde küresel ölçekte farklı etkiler yaratmıştır. Birçok çalışma, pandeminin getirdiği belirsizliklerin proje geliştirme süreçleri, maliyet tahminleri, değerlendirme faaliyetleri ve yatırım geri dönüş oranları üzerinde olumsuz yansımaları olduğunu ortaya koymaktadır (Tanrıvermiş, 2020; Wang vd. 2022). Örneğin, Çin, ABD, Avustralya ve Hindistan gibi pazarlarda yapılan

arařtırmalar; ofis kiralarında düşüş, merkez dışı alanlara yönelim gibi yeni eğilimleri gündeme getirmiştir. Ancak bu eğilimlere karşıt bulgular da mevcuttur. Özellikle Avrupa ve ABD’de yapılan bazı arařtırmalar, kira gerilemesinin sınırlı düzeyde olduğunu ve ofis piyasasının kısa sürede toparlanma eğilimi gösterdiğini öne sürmektedir. Literatürdeki bu karşıtlık, pandeminin etkilerinin ülke bazında farklı dinamikler gösterdiğini ve yerel pazar koşullarına göre değerlendirilmesi gerektiğini göstermektedir (Thebuwena ve Vaz 2025).

İřletme maliyetleri de kira seviyeleri üzerinde belirleyici olmaktadır. Yeřil sertifikalı binaların enerji ve su tasarrufu sağlaması gibi özellikler, bu tür binaları kullanıcılar için daha cazip kılmakta ve daha yüksek kira getirisi sağlamaktadır (Jang vd. 2018). Uluslararası düzeyde bazı ülkelerde bu binalar, vergi indirimleri gibi teşviklerle desteklenmektedir (Olubunmi vd. 2016). Son olarak, aynı konumda ve benzer özelliklere sahip ofis binaları arasında kira gelirlerinde yaşanan farklılıkların, markalařma ve konumlandırma stratejileriyle iliřkili olduğu görülmektedir. Kullanıcıların marka değeri yüksek binalara daha fazla kira ödemeye istekli olduğu, yapılan arařtırmalarla doğrulanmıştır (Cheah vd. 2021; Jain ve Robinson 2018).

2.3 Önceki Çalışmalar

Gayrimenkullerin doğru fiyatlandırılması hem bireysel kullanıcılar hem de yatırımcılar açısından kritik bir öneme sahiptir. Bu önem ipotek kredisi, vergilendirme, yatırım kararları, birleřmeler, devralmalar, açık artırmalar, finansal bilançolar ve alım-satım faaliyetleri gibi geniş bir ekonomik yelpazedeki etkisinden kaynaklanmaktadır (Abidoye vd. 2019). Bu nedenle, gayrimenkul değerlerinin yanlış belirlenmesi, sadece bu faaliyetleri değil, yatırım kararlarında ciddi yanılgılara yol açabilmekte; aynı zamanda ekonomik büyüme ve kalkınmayı da olumsuz sonuçları etkileyebilmektedir (Usman vd. 2020).

Örneğin, gerçek değerinin üzerinde fiyatlandırılmış bir gayrimenkule yapılan yatırım, beklenen getiri oranlarının düşmesine ve finansal dengesizliklere neden olabileceken; diğer yandan, düşük fiyatlandırılmış bir gayrimenkul, pazar fırsatlarının gözden

kaçırılmasına yol açabilecektir. Doğru fiyatlandırma mekanizmaları, güvenilir endekslerin geliştirilmesi ve pazar dinamiklerinin daha iyi anlaşılması, bu tür risklerin azaltılmasında kritik bir role sahiptir. Hem düzenleyici kurumlar hem de pazar katılımcılarının etkin işbirliği ile şeffaf ve doğru fiyatlandırma stratejileri oluşturulması, ekonominin sürdürülebilirliği açısından oldukça önemlidir.

Uluslararası alanda ve Türkiye’de gayrimenkulün değer tespitine yönelik olarak farklı yöntemlerle gerçekleştirilen çok sayıda akademik ve uygulamalı araştırmalar yer almaktadır. Bu çalışmalar, kullanılan yöntemler ve seçilen örneklemeler açısından farklılık gösterse de temel olarak değerlendirme sürecinde geleneksel yaklaşımların hâlen önemli bir yer tuttuğunu göstermektedir. Özellikle Pazar, gelir ve maliyet yaklaşımı gibi geleneksel değerlendirme modelleri, uygulayıcılar tarafından uzun süredir benimsenmiş ve çeşitli gayrimenkul türlerinde uygulanmıştır. Bu bağlamda Jud ve Winkler (1995), ticari gayrimenkullerin pazar değerini belirlemek amacıyla karşılaştırmalı satış analizini kullanmış ve bu yöntemin ticari gayrimenkullerin piyasa getirileri üzerindeki etkilerini değerlendirmiştir. Benzer biçimde Geltner vd. (2013), ticari gayrimenkul yatırımları ve değerlendirme yöntemlerini kapsayan çalışmalarıyla, geleneksel değerlendirme yaklaşımlarının teorik ve uygulamalı temellerine dair önemli bir kaynak sunmuşlardır. Ayrıca bu çalışmalarda maliyet yaklaşımı yöntemleri, değerlendirme süreçlerinde alternatif bir yaklaşım olarak ele alınmış; özellikle yapı maliyeti, yeniden inşa bedeli gibi kriterlerin önemine dikkat çekilmiştir.

Maliyet yaklaşımının ticari nitelikli gayrimenkuller üzerindeki uygulamalarına odaklanan bir diğer kaynak ise Fisher ve Martin’in (2004) çalışmasıdır. Gelir getiren gayrimenkullerin değerlendirilmesinde kullanılan yöntemleri sistematik biçimde ele alan bu çalışma, özellikle ticari gayrimenkullerde maliyet yaklaşımının avantajlarını ortaya koymakta ve yatırımcı perspektifinden değerlemenin nasıl ele alınabileceğini tartışmaktadır.

Benzer şekilde Eichholtz ve arkadaşları (2010), değerlendirme konusunu yeşil bina örneği üzerinden ele alarak maliyet yaklaşımının sürdürülebilir yapılar üzerindeki etkilerini analiz etmişlerdir ve çalışmalarında, yeşil ofis binalarının değerlemesinde inşa

maliyetleri, enerji verimliliği ve işletme giderleri gibi faktörlerin nasıl dikkate alındığını incelemişlerdir. Bu yönüyle, maliyet yaklaşımının sadece geleneksel yapılarda değil, çevresel sürdürülebilirlik perspektifinden de uygulanabilirliğini göstermişlerdir.

Türkiye özelinde yapılan çalışmalar da benzer şekilde geleneksel yöntemlerin uygulandığı örneklerle dikkat çekmektedir. Örneğin, Çelik (2022) tarafından Samsun ve Gümüşhane illerinde yapılan çalışmada, konut ve sanayi alanlarının değerlendirme süreci incelenmiş; alan, imar hakkı, satış tarihi ve değeri gibi kriterlere dayalı olarak maliyet yöntemi, gelir yöntemi ve emsal karşılaştırma yöntemi üzerinden değerlendirme modelleri oluşturulmuştur. Araştırmada özellikle emsal karşılaştırma yönteminin yaygın biçimde tercih edildiği vurgulanmıştır.

Bölgesel farklılıkları esas alan bir diğer çalışma ise Karakuş (2011) tarafından gerçekleştirilmiştir. Balıkesir il merkezinde yapılan bu çalışmada, bölgesel gayrimenkul verileri ışığında kapitalizasyon oranları hesaplanmış; araştırma alanı, yapısal özelliklerine göre on beş ayrı gruba ayrılmış ve her bir grup için ayrı oranlar tanımlanmıştır. Bu yaklaşım, geleneksel gelir yöntemi içerisinde yer alan kapitalizasyon kavramının nasıl bölgesel düzeyde özelleştirilebileceğini göstermesi açısından dikkat çekicidir.

Ankara özelinde gerçekleştirilen bir diğer kapsamlı uygulama ise Arı'nın (2018) çalışmasıdır. Mamak ilçesinde yer alan konut nitelikli gayrimenkullere odaklanan bu çalışmada, 127 adet değerlendirme raporu ve pazar araştırması verileri kullanılarak Brüt ve Net Kira Çarpanı ile Kapitalizasyon Oranı analiz edilmiştir. Araştırma, bölgedeki düşük talep ve gelişmişlik düzeyine bağlı olarak piyasa değerinin uzman görüşlerine ve subjektif yorumlara dayalı olarak şekillendiğini ortaya koymuştur. Bu durum, geleneksel yöntemlerin saha uygulamalarında ne denli öznel faktörlerden etkilendiğini ve modelleme sürecinde dikkatle ele alınması gerektiğini göstermektedir.

Gayrimenkul değerinin ve özellikle ofis kiralarının belirlenmesinde istatistiksel ve matematiksel modellemeler uzun süredir araştırmacıların başvurduğu temel araçlardan biridir. Gayrimenkullerin fiziksel özellikleri, konumu, kullanım amacı, hedef kitlesi ve içinde bulunduğu pazar koşulları dikkate alınarak yapılan bu analizlerde; regresyon

yöntemleri, hedonik fiyatlama modelleri, zaman serisi analizleri ve mekânsal çözümlemeler öne çıkmaktadır. Ancak son yıllarda bu yöntemlerin, özellikle piyasanın karmaşık yapısı ve belirsizlik içeren durumlarında yetersiz kaldığı ve daha esnek modelleme ihtiyaçlarını karşılayamadığı yönünde eleştiriler de artmıştır.

Konut ve ofis kiralalarının belirlenmesinde uzun yıllardır kullanılan hedonik fiyatlama modeli, bir gayrimenkulün fiziksel ve çevresel özelliklerini dikkate alarak fiyat veya kiranın kestirimini amaçlamaktadır. Türkiye’de bu alanda yapılan ilk çalışmalardan biri, Türel (1981) tarafından gerçekleştirilmiştir. Türel, Ankara’nın sekiz alt bölgesinde 1969-1970 yıllarında toplanan verilerden faydalanarak, hedonik fiyat endeksi üzerinden bir regresyon modeli geliştirmiştir. Bu modelde bağımlı değişken olarak yıllık kira ele alınırken; kalorifer durumu, asansör ve bina yaşı gibi çeşitli fiziksel değişkenler bağımsız değişken olarak kullanılmıştır. Model çıktıları, konut fiyatlarını etkileyen en önemli unsurların oda sayısı ve kaloriferli ısıtma sistemi olduğunu ortaya koymuştur.

Konut piyasasına dair benzer çalışmalar da hedonik modelin geniş bir uygulama alanına sahip olduğunu göstermektedir. Esperanza ve Gallego (2004), Madrid’de 100 konuta ait verilerle gerçekleştirdikleri analizde, satış fiyatlarının yol, bina yaşı, alan ve konum gibi toplamda on iki değişken tarafından şekillendiğini ortaya koymuşlardır (Yılmaz vd. 2018). Ancak bazı çalışmalar, hedonik modele ilişkin eleştirel bulgular da sunmuştur. Örneğin, Wen vd. (2005), konutun yaşı, ticari alanlara yakınlığı ve kamu hizmetlerine erişim gibi faktörlerin konut satış fiyatı üzerinde anlamlı etkisinin olmadığını tespit etmiştir. Bu durum, konut piyasalarının heterojen yapısının geleneksel modellerle açıklanmasındaki güçlükleri gözler önüne sermektedir.

Türkiye ölçeğinde konut kiralalarının belirlenmesinde de bu yaklaşımlar yaygın biçimde kullanılmıştır. Yayar ve Bursal (2019), Türkiye İstatistik Kurumu’nun 2017 yılı Hanehalkı Bütçe Araştırması mikro verilerinden faydalanarak, ülke genelinde konutta kiracı olarak oturan 2.796 hanenin kira verilerini incelemiş ve üç farklı model geliştirmiştir. Elde edilen sonuçlara göre, kira kestiriminde en uygun modelin tam logaritmik form olduğu tespit edilmiştir. Bu modelle birlikte kirayı etkileyen faktörlerin

çok boyutlu bir yapı arz ettiği ve değişkenler arasındaki ilişkinin doğrusal olmaktan uzaklaştığı anlaşılmıştır.

Türkiye’de ofis pazarına yönelik yapılan erken dönem çalışmalardan biri olan Ustaoglu (2003), Ankara ofis piyasasında 2002 yılı verilerini kullanarak Hedonik Regresyon ve En Küçük Kareler yöntemleriyle analiz gerçekleştirmiştir. Çalışma, ofis kiralının özellikle binanın kat sayısı, yapım kalitesi ve konum gibi değişkenlerden anlamlı şekilde etkilendiğini göstermiştir. Benzer şekilde, İstanbul’da ofis piyasası üzerine yapılan çalışmalar da Hedonik Regresyon modelinin genişletilerek kullanıldığını göstermektedir. Aksoy (2005), İstanbul’un Levent, Maslak, Esentepe gibi merkezi bölgelerinde yer alan 115 ofis binası üzerinde Hedonik Regresyon modeli kullanarak yaptığı çalışmada, bölgesel boşluk oranının ofis kiralını etkileyen en güçlü değişken olduğunu saptamıştır.

Aynı bağlamda Öven ve Pekdemir (2006) ise İstanbul’daki 64 ofis kira verisini analiz ederek doğrusal ve doğrusal olmayan dört farklı hedonik model geliştirmiştir. Bu modeller aracılığıyla, boşluk oranı, ortak alan yüzdesi, faiz oranı, binanın fiziksel özellikleri ve konumun, kira üzerinde belirleyici etkiler oluşturduğu sonucuna varılmıştır. Bunlara ek olarak Özüs (2009) tarafından, İstanbul’daki 94 ofisin Mart 2007 dönemine ait kira verileri incelenmiş; çoklu doğrusal regresyon modeli uygulanarak kiralari etkileyen faktörler sıralanmıştır. Bulgular, ofis kiralını en çok etkileyen değişkenlerin kat sayısı, boşluk oranı, sosyal olanaklar, bina estetiği ve kiralanabilir alan olduğunu göstermiştir. Bu sonuçlar, ofis pazarında fiziki niteliklerin yanı sıra çevresel ve işlevsel özelliklerin de fiyat oluşumunda önemli olduğunu ortaya koymaktadır.

Başka bir çalışmada, Şentürk’de (2012) İstanbul’daki merkezi iş alanı ve dokuz alt pazarda, A ve B sınıfı ofislerin 2001-2010 yılları arasındaki gelişim eğilimlerini analiz etmiş ve bu analizlerde zaman serisi ve regresyon modelleri ile kira kestiriminde bulunmuştur. Bu çalışmalar, geleneksel istatistiksel yöntemlerin ofis piyasasının temel dinamiklerini yansıtmakta belirli bir başarı sağladığını, ancak zaman içinde gelişen pazar yapılarının daha derin analizlere ihtiyaç duyduğunu ortaya koymuştur.

İstanbul odaklı gerçekleştirilen araştırmalar, ofis piyasasının alt pazarlar temelinde ayrıştırılarak daha ayrıntılı biçimde analiz edilmesine olan gereksinimi gündeme getirmiştir. Örneğin Karahan (2019), Esentepe, Levent-Maslak, Basın Ekspres, Altunizade, Kavacık, Kozyatağı ve Ümraniye gibi sekiz farklı alt pazar için 2005-2018 dönemine ait kira düzeyleri, boşluk oranları ve ekonomik göstergeleri dikkate alarak uzun dönem denge kirasını tahmin etmeye yönelik modeller oluşturmuştur. Söz konusu yaklaşım, kira seviyeleri ile makroekonomik değişkenler arasındaki ilişkiyi ortaya koyarken, aynı zamanda, pazar bölümlendirmesinin değerlendirme süreçlerindeki önemine de dikkat çekmektedir.

Diğer yandan Kangallı ve Uyar (2020), İstanbul'un 28 ilçesinden toplanan 2.348 ofis ilanı verisiyle bir hedonik ofis kira modeli geliştirmiştir. Bu modelde, farklı ofis özelliklerinin kira üzerindeki doğrudan ve dolaylı etkileri değerlendirilmiş; özellikle mekânsal analizlerle kira arasındaki coğrafi dağılım farklılıkları ortaya konmuştur. Aynı araştırmacılardan Bera ve Kangallı-Uyar (2019), sadece fiziksel ve yapısal özelliklerin değil, binanın sunduğu hizmetlerin ve lokasyonel avantajların da küresel ve yerel etkilerini analiz etmiş ve pazarın işleyiş yapısının ofis kirası üzerinde çok katmanlı etkiler yarattığını göstermiştir. Bu bulgular, uluslararası çalışmalarla da desteklenmektedir. Örneğin Tu vd. (2004), Singapur ofis piyasasında 1992-2001 dönemine ait 2.950 işlem verisini kullanarak, mekânsal-zamansal otoregresif model geliştirmiştir. Bu model, ofis satış fiyatları ile bina özellikleri arasındaki ilişkileri ortaya koymuş ve belirli çalışma alanları içinde ofis fiyat değişikliklerinin yönetilmesindeki sınırlılıkları vurgulamıştır. Benzer şekilde, Debrezion ve Willigers (2008), Hollanda'nın Amsterdam Güney Ekseni'nde demiryolu erişiminin ofis kiralarına etkisini mekânsal hedonik fiyatlama modeli ile incelemiş; ulaşım olan yakınlık, hizmet kalitesi ve otoyol erişimi gibi faktörlerin kira düzeyleri üzerindeki etkisini ortaya koymuştur. Bu çalışmalarda Maksimum Olabilirlik gibi ileri istatistiksel tekniklerin de kullanılması, mekânsal bağılılıkların modellemedeki önemini göstermektedir.

Ofis pazarında lokasyonel etkilerin belirleyici rolünü vurgulayan diğer çalışmalar da dikkat çekicidir. Örneğin, Safian ve Nawawi (2013), merkezi iş alanındaki ticari binaların ofis kirallarıyla yüksek düzeyde pozitif ilişkili olduğunu ortaya koyarken; Hui vd. (2015),

lokasyonel deęiř-tokuř teorilerini temel alarak, fiyat ve kira dinamiklerinin mekânla nasıl iç içe geçtiğini tartışmıştır.

Yapılan çalışmalar genel olarak, istatistiksel ve matematiksel yöntemlerin ofis kiralarının belirlenmesinde anlamlı sonuçlar sunduğunu ancak pazarın mekânsal, zamansal ve çok deęişkenli yapısı nedeniyle daha esnek ve güçlü modelleme araçlarına ihtiyaç duyulduğunu ortaya koymaktadır. Son yıllarda gayrimenkul sektörü, yalnızca geleneksel deęerleme yöntemlerine baęlı bir alan olmaktan çıkarak, çok katmanlı, deęişken ve giderek daha karmařık bir yapıya dönüşmüřtür. Sektör, çok sayıda deęişkenle olan etkileřimi nedeniyle, çoęu zaman kontrol edilmesi güç ve öngörülmesi zor fiyat dalgalanmalarına maruz kalmaktadır (řen vd. 2025)

Makine öğrenmesi yöntemleri, son yıllarda çok sayıda disipline entegre edilmiř ve sunduęu esnek algoritmalar sayesinde farklı alanlardaki uygulamalarda yaygın biçimde kullanılmaya başlanmıştır. Makine öğrenmesi yöntemlerinin geliřimi, 20. yüzyılın ortalarından itibaren istatistik ve bilgisayar bilimi disiplinlerinin kesiřiminde řekillenmiştir. Bu yöntemlerin en eskilerinden biri olan k-En Yakın Komřu (k-NN) modeli, Fix ve Hodges (1951) tarafından ilk olarak geliřtirilmiř ve Cover ve Hart (1967) tarafından teorik temelleri ortaya konmuřtur. Dudani (1976), bu yöntemi mesafeye dayalı aęırlıklandırma ile geliřtirirken, Altman (1992) modeli regresyon problemlerinde kullanarak yöntemsel esneklięini ortaya koymuřtur.

Benzer biçimde, Karar Aęaçları (Decision Trees, DT) üzerine yapılan çalışmalar, sınıflandırma ve regresyon analizlerinde yorumlanabilirlik açısından önemli bir alternatif sunmuřtur. Quinlan (1986) tarafından geliřtirilen ID3 ve C4.5 algoritmaları, öğrenme sürecini sistematik hale getirmiřtir. Breiman vd. (1984) bu yapıyı sistematikleřtirirken, Ho (1995) ve Breiman (2001) tarafından geliřtirilen Rasgele Orman (Random Forest, RF) yöntemi ile karar aęaçlarının birleřtirilmesi, modelin genelleme kapasitesini artırmıştır. Bu modelin R yazılımındaki uygulaması ise Liaw ve Wiener (2002) tarafından detaylandırılmıştır.

Destek Vektör Makineleri (Support Vector Machines, SVM) Joachims (1998) ile metin sınıflandırma problemlerine uyarlanmış, Platt (1999) olasılık temelli uzantılarını tanımlamış, Schölkopf vd. (2002) ise çekirdek fonksiyonları ile modelin esnekliğini artırmıştır. Yapay Sinir Ağları (Artificial Neural Networks, ANN) algoritması ise özellikle doğrusal olmayan yapılarla baş etmede öne çıkmış; Tay vd. (1992) bu modeli konut fiyat kestiriminde kullanarak geleneksel regresyon modellerine göre daha başarılı sonuçlar elde etmiştir. Bu temeller, makine öğrenmesinin gayrimenkul değerlendirme sürecinde güçlü bir alternatif olarak yükselişini desteklemiştir.

Belirsizliğin hâkim olduğu gayrimenkul piyasalarında, geleneksel modellerin kesinlik temelli yapısı yetersiz kalabilmekte, bu noktada FRF devreye girmektedir. Bu yöntem ilk kez Tanaka vd. (1982) tarafından önerilmiş ve belirsizlik içeren verilere uygulanabilecek regresyon yapılarının teorik temeli oluşturulmuştur. Diamond (1988), bulanık regresyon analizini en küçük kareler yöntemi ile entegre ederek daha istikrarlı sonuçlar üretmiştir. İlerleyen yıllarda, Chang ve Ayyub (1995) farklı bulanık regresyon yöntemlerini karşılaştırmalı olarak analiz ederek, her bir yaklaşımın hangi koşullarda daha uygun olabileceğini ortaya koymuştur. Son olarak, Demirhan ve Başer (2024) tarafından önerilen hiyerarşik FRF, özellikle kategorik verilerin etkili şekilde modele dahil edilmesini sağlamış ve literatürde yeni bir yaklaşımın temellerini atmıştır.

Türkiye’de yapılan çalışmalardan Selim ve Demirbilek (2009), Hedonik Regresyon ve ANN’yi karşılaştırmalı biçimde kullanarak kiraya etki eden mekânsal, yapısal ve sosyoekonomik faktörleri analiz etmiş; Karımov (2010) ise ofis binalarındaki kira farklılıklarını bulanık kural tabanlı sistemler ile açıklamaya çalışmıştır. Benzer şekilde, Savaş (2019), Erkek vd. (2020), Doğan vd. (2022) gibi araştırmacılar, Türkiye’nin farklı illerindeki konut piyasalarını SVM, Çoklu Doğrusal Regresyon (Multiple Linear Regression, MLR), ANN ve Gradyan Artırma (Gradient Boosting, GB) gibi yöntemlerle analiz etmiş; modellerin performanslarını karşılaştırarak en etkili yaklaşımları ortaya koymuşlardır. Bu tür çalışmalar, makine öğrenmesinin yalnızca tahmin gücünü değil, veriye dayalı karar verme süreçlerinde sunduğu katkıyı da göstermektedir.

Uluslararası uygulamalar da benzer bir eğilim sergilemektedir. Örneğin, Moosavi (2017), İsviçre’de büyük veri üzerinden gayrimenkul portallarıyla bütünleşmiş çalışan otomatik fiyatlandırma modelleri geliştirmiş; Kok vd. (2017), SVM ile manuel yöntemlere kıyasla daha hızlı ve isabetli sonuçlar elde edildiğini vurgulamıştır. Chan (2023) ve Yoshida vd. (2024) ise topluluk modelleriyle istiflenmiş algoritmaları karşılaştırarak, hangi modelin hangi pazar koşullarında daha iyi çalıştığını ortaya koymuştur.

Makine öğrenmesi modellerinin performansını etkileyen önemli faktörlerden biri de konumsal değişkenlerin ve mekânsal heterojenliğin modele entegrasyonudur. Bu bağlamda Tu vd. (2004), Debrezion ve Willigers (2008) gibi çalışmalar, ulaşım erişim, demiryolu istasyonlarına yakınlık gibi mekânsal kriterlerin ofis fiyatlarına olan etkisini mekânsal hedonik modeller ile analiz etmişlerdir. Bu çalışmalar, ulaşım altyapısının ve konumun ofis kira değerlemesi üzerindeki etkilerini istatistiksel düzeyde doğrulamaktadır.

Türkiye’de yapılan benzer nitelikteki çalışmalar da konumsal parametrelerin değerlendirme üzerindeki belirleyiciliğini ortaya koymaktadır. Karakuş (2011) kapitalizasyon oranlarını bölgelere göre değişen yapılarla analiz ederken, Kangallı ve Uyar (2020) mekânsal modellerle İstanbul ofis piyasasında farklı bina özelliklerinin doğrudan ve dolaylı etkilerini analiz etmiştir. Ayrıca, Karahan (2019) uzun dönemli denge kirası hesaplamalarında alt pazarların dinamiklerini dikkate almış ve PB kavramının uygulanabilirliğini göstermiştir.

Son yıllarda geliştirilen çalışmalar, yalnızca bir modelin uygulanmasıyla yetinmeyip, farklı makine öğrenme ve istatistiksel yaklaşımların performanslarını karşılaştırmalı olarak analiz etmeye yönelmiştir. Yılmaz vd. (2021), Ayar ve Şen (2023) ve Türkan vd. (2023) gibi araştırmalar, çok sayıda algoritmayı aynı veri seti üzerinde test ederek doğruluk, hata oranları gibi metriklerle karşılaştırmalar yapmıştır. Bu çalışmaların ortak noktası, ANN, RF ve SVM gibi modellerin genel olarak daha yüksek doğruluk oranlarına ulaşmalarıdır. Ayrıca Bilgilioğlu ve Yılmaz (2021) ile Alkan vd. (2023) tarafından yapılan çalışmalar, toplu değerlendirme amaçlı olarak geliştirilen makine öğrenmesi modellerinin, büyük veri kümelerinde nasıl kullanılabileceğini ve hangi modellerin hangi

koşullarda daha etkin sonuçlar verdiğini göstermiştir. Bu bağlamda geliştirilen modeller hem vergi sistemleri hem de yatırım kararları açısından uygulamaya dönük karar destek sistemlerinin temelini oluşturmuştur.

3. KÜRESEL DÜZEYDE VE TÜRKİYE ÖZELİNDE GAYRİMENKUL PAZARI

Gayrimenkul pazarı hem küresel düzeyde hem de ulusal ölçekte ekonomik büyüme, finansal istikrar ve yatırım stratejileri açısından temel bir rol oynamaktadır. Bu bölümde, öncelikle dünya genelindeki gayrimenkul piyasasının güncel yapısı, uluslararası sermaye hareketleriyle olan ilişkisi ve sektörel dağılım eğilimleri kapsamlı biçimde ele alınmaktadır. Ardından, küresel ölçekteki pazar kestirimleri ile Türkiye’deki gayrimenkul piyasasının mevcut durumu, sektörel yatırım dağılımları ve geleceğe yönelik beklentileri analiz edilmektedir. Ayrıca, Türkiye’nin başkenti Ankara’nın ofis pazarı özelinde sergilediği performans da detaylı biçimde değerlendirilmekte; böylece hem makro hem mikro ölçekte gayrimenkul dinamiklerinin çok katmanlı bir yapıda nasıl şekillendiği ortaya konulmaktadır.

3.1 Küresel Gayrimenkul Pazarı ve Uluslararası Sermaye Hareketleri

Küresel gayrimenkul piyasası, dijitalleşme, sürdürülebilirlik, pandemi sonrası dönüşüm ve en önemlisi uluslararası sermaye hareketleri gibi dinamiklerin etkisiyle yeniden şekillenmektedir. Günümüzde dünya genelindeki gayrimenkul yatırımlarında belirleyici unsur olarak uluslararası sermaye akımları öne çıkmaktadır. Bu sermaye akışları, gelişmiş piyasalardaki güvenli liman algısı ile birleştiğinde, ofis yatırımlarından lojistik alanlara kadar pek çok alt sektörde dönüşüm yaratmaktadır. Bu bölümde, dünya genelindeki gayrimenkul piyasası görünümü, sermaye hareketlerinin etkisi bağlamında ele alınmaktadır.

Uluslararası gayrimenkul yatırımları, faiz oranları, enflasyon ve jeopolitik riskler gibi küresel belirsizliklerden etkilenmektedir. Özellikle ABD Merkez Bankası’nın faiz politikaları, yatırımcı davranışlarını doğrudan etkilemekte; düşük faiz ortamı yatırımcıları daha likit araçlara yönlendirirken, yüksek faiz ortamı gayrimenkul gibi varlıklara ilgiyi artırmaktadır. Yatırımcıların, küresel ekonomik belirsizlikler ve enflasyon baskıları devam ederken risklerini azaltmak için portföylerini çeşitlendirmeleri ve daha istikrarlı gayrimenkul pazarlarına yönelmeleri beklenmektedir.

Yatırımcılar ve kiracılar için dikkat çekici bir sektör olan gayrimenkul, ekonomik büyüme için önemli bir araç olarak görülmektedir. Son yıllarda yaşanan ekonomik dalgalanmalar, nüfus hareketleri ve teknolojik yeniliklerle birlikte farklı bölgelerdeki pazar dinamikleri, bölgesel ekonomik unsurlar, siyasi ve teknolojik gelişmeler gibi birçok çeşitli etkenlere bağlı olarak küresel gayrimenkul pazarı sürekli değişim ve dönüşüm yaşamaktadır. Özellikle gelişmiş ülkelerde gayrimenkul yatırımları düzenli gelir potansiyeli ve düşük risk ile uzun vadeli yatırımcılar tarafından tercih edilmektedir. Yatırımcılar için geniş fırsatlar sunmanın yanı sıra pazar dinamiklerinde yaşanan hızlı değişimlerle dikkat çeken Avrupa, Asya-Pasifik bölgeleri ve ABD, dünyadaki en büyük ve en dinamik gayrimenkul pazarları olarak öne çıkmaktadır. Özellikle ABD’deki ofis pazarında, geleneksel ofislere olan talebin azalması ve esnek çalışma alanlarına ilginin artması, uzaktan çalışma, dijitalleşme unsurları sektörde yeni bir dengelenme sürecini beraberinde getirmiştir (Anonymous 2024a).

New York ve San Francisco gibi büyük metropollerde uzaktan çalışma eğilimlerinin artması boşluk oranlarının yükselmesine ve kiralarda dalgalanmalara neden olmuştur. Birçok şirketin pandemi sonrasında uzaktan veya hibrit çalışma modellerine ağırlık vermesi doluluk oranlarını düşürse de bu durum sonucunda paylaşımlı veya esnek ofis alanları önem kazanmıştır. ABD’deki bu önemli yapısal değişiklikler, depo ve lojistik alanlarına olan talebi artırmış, teknoloji ve e- ticaret sektörlerinin alanlarının büyümesine katkı sağlamıştır ve ticari gayrimenkul yatırımlarına bakış açısını değiştirmiştir. Sektördeki büyüme, kurumsal yatırımcılar ve gayrimenkul yatırım fonları tarafından desteklenmektedir. Ekonomik dalgalanmalara rağmen, gayrimenkul yatırım fonları yüksek getirili varlıkları portföylerine eklemeye devam etmektedir. Geleneksel gayrimenkul yatırımlarına kıyasla, yenilenebilir enerji tesisleri, veri merkezleri ve yaşlı bakım konutları gibi alternatif gayrimenkuller daha yüksek gelir ve büyüme potansiyeli sunmaktadır (Anonymous 2024a)

Avrupa’da, Londra, Paris ve Frankfurt gibi şehirler Avrupa Birliği içindeki stratejik konumları ve gelişmiş seviyeleriyle, uluslararası gayrimenkul yatırımcıları için önemli merkezler olma niteliğindedirler. İngiltere’nin Avrupa Birliği’nden ayrılması sonrasında Londra, güçlü kira getirileriyle küresel finans merkezi özelliğini taşımaya, Paris

çeşitlendirilmiş kiracı profili ve düşük boşluk oranlarıyla, Berlin veri merkezleri gibi teknolojik altyapısı ve düşük maliyetli ofis alanlarıyla uluslararası yatırımcılar için cazibe merkezi özelliğini taşımaya devam etmektedir (Anonymous 2024b).

Asya-Pasifik bölgesinde, Hong Kong, Singapur ve Tokyo gibi şehirler, vergi avantajları, güçlü finansal sistemleri, düşük faiz politikaları, istikrarlı kira değişimleri ve düşük boşluk oranları ile gayrimenkul pazarı açısından uluslararası şirketler ve yatırımcılar için cazip yatırım yerleri olarak karşımıza çıkmaktadır. Japonya'nın Tokyo şehri, düşük faiz oranları ve istikrarlı ekonomik yapısı sayesinde kurumsal ofis yatırımları için yatırımcıların ilgisini çekmektedir. Özellikle düşük faiz oranları, yatırımcıların borçlanma maliyetlerini azaltarak daha yüksek getiriler elde etmelerine olanak tanımaktadır (Ando 2024). Diğer yandan, Çin'in gayrimenkul pazarı çeşitli zorluklarla karşı karşıya kalmıştır. Ekonomik belirsizlikler, yasal zorluklar ve sektördeki krizler nedeniyle birçok önemli geliştirici finansal sorunlar yaşamaktadır. Örneğin, büyük Çinli gayrimenkul geliştiricilerinden biri olan Country Garden, 2023 yılının ilk yarısında 6,7 milyar dolar zarar bildirmiştir (Liang 2023). Bu durum, yatırımcıların Çin gayrimenkul pazarına olan güvenini sarsarken, Japonya gibi daha istikrarlı pazarlara yönelmelerine neden olmaktadır. Pandemi sonrası düşük faiz oranları, özellikle ABD'de kurumsal yatırımcıların ofis ve lojistik sektörlerine ilgisini artırmıştır.

Benzer şekilde Asya-Pasifik'te artan çevrimiçi ticaret, bu alandaki yatırım fırsatlarını genişletmiştir. Böylece, sermaye akışı iki büyük bölgede de benzer temalar etrafında şekillenmektedir. Sınırlı arz ve yüksek talep nedeniyle, Hong Kong ve Singapur gibi şehirlerde kira oranlarında istikrarlı artışlar gözlemlenmektedir. Avrupa'da ise, jeopolitik belirsizlikler ve enerji krizi, gayrimenkul yatırımlarını etkilemektedir. Yatırımcılar, özellikle enerji verimliliği ve sürdürülebilir yatırımlar için cazip fırsatlar bulabilmektedirler. Buna ek olarak, merkez bölgelerdeki yüksek kaliteli ofis binalarına olan talep devam ederken, veri merkezleri ve lojistik gibi alanlarda büyük bir büyüme potansiyeli bulunmaktadır (Murray ve Trausch 2023).

Küresel sermaye hareketleri, emeklilik fonları, varlık yönetim şirketleri, devlet yatırım fonları ve özel sermaye fonları gibi kurumsal yatırımcılardan gelmektedir. Büyük ölçekli

yatırımcılar, uzun vadeli getiri hedefleri doğrultusunda güvenli liman olarak gördükleri yerlerde gayrimenkul yatırımlarına yönelmektedir. Örneğin Norveç'in devlet yatırım fonu, Londra, New York ve Paris gibi dünyanın dört bir yanındaki şehirlerde önemli gayrimenkul yatırımları gerçekleştirmiştir. Afrika ve Latin Amerika gibi gelişmekte olan bölgelerde ise yerel sermaye kaynaklarının sınırlı olması, uluslararası yatırımcılar için bu bölgeleri daha riskli hale getirmektedir. Bununla birlikte, bu bölgelerin büyüme potansiyeli, risk almak isteyen yatırımcılar için önemli fırsatlar sunmaktadır.

Gelecekte küresel sermaye hareketlerinde etkili olacağı tahmin edilen birkaç temel unsur daha mevcuttur. Veri odaklı yatırımlar ve dijitalleşme, gayrimenkul sektöründe daha hızlı ve esnek sermaye akışı sağlayacaktır. Bunun yanı sıra, çevresel ve sosyal sorumluluk standartlarını karşılayan gayrimenkul projeleri, sermaye sağlama konusunda önemli bir rol oynayacaktır.

Sermaye hareketleri, küresel ekonomik belirsizlikler ve faiz oranlarındaki değişiklikler nedeniyle değişebilmektedir. ABD Merkez Bankası'nın faiz politikaları, küresel sermaye akışının yönünü büyük ölçüde etkilemektedir. Ayrıca düşük faiz oranları, yatırımcıların riskli pazarlara gitmesini, yüksek faiz oranları ise yatırımcıların güvenli pazarlara gitmesini teşvik edebilmektedir. Bu nedenle, dünya çapındaki sermaye hareketleri, gayrimenkul pazarlarının nasıl işlediğini büyük ölçüde etkileyen faktörlerden biridir. Sermaye akışlarının yönünü ve yoğunluğunu bölgesel farklılıklar ve makroekonomik koşullar etkilemektedir, ancak Türkiye gibi gelişmekte olan pazarlardaki yüksek getiri potansiyeli ve stratejik avantajlar küresel yatırımcıların ilgisini çekmeye devam etmektedir (Green ve Sanghvi 2024).

Teknolojik dönüşüm, gayrimenkul sektöründe hem operasyonel süreçleri hem de yatırım modellerini yeniden şekillendirmektedir. Blokzincir teknolojisi, işlemlerde şeffaflığı artırmakta; dijital platformlar ise gayrimenkul erişimini kolaylaştırarak yeni iş modellerinin doğmasına yol açmaktadır. Özellikle bu teknoloji, gayrimenkul işlemlerinin güvenliğini ve şeffaflığını sağlayarak devrim niteliğinde bir yenilik olmuştur.

Lisanslı Uzmanlar Kraliyet Kurumu (Royal Institution of Chartered Surveyor, RICS) tarafından yayımlanan 2024 yılı sürdürülebilirlik raporuna göre, yatırımcılar ve kiracılar arasında yeşil binalara olan talep artış göstermektedir. Bölgesel dağılım incelendiğinde; talep artışı en yüksek oran %63 ile Avrupa’da ve ardından %54 ile İngiltere’de kaydedilmiştir. Orta Doğu ve Afrika bölgesinde %49, Asya-Pasifik’te %38 ve Amerika kıtasında %25 oranında yeşil bina talep artışı bildirilmiştir. Küresel ortalama ise %41 olarak gerçekleşmiş olup sürdürülebilir yapılar konusunda bölgesel farkındalık ve uygulama düzeylerinin farklılaştığı anlaşılmaktadır (Çizelge 3.1) (Anonymous 2024c).

Çizelge 3.1 Yeşil bina talebinde artış oranları (Anonymous 2024c)

No	Bölge	Oran (%)
1	Avrupa	63
2	İngiltere	54
3	Orta Doğu ve Afrika	49
4	Asya-Pasifik	38
5	Amerika	25
6	Küresel Ortalama	41

Özellikle ticari gayrimenkul pazarında sürdürülebilirlik konuları içinde karbon ayak izinin ve enerji tüketiminin azaltılması da özel önem kazanmıştır. Ancak, küresel standartların ve düzenlemelerin henüz yaygınlaşmamış olması, gerekli ölçüm ve raporlama kurallarının benimsenmesini engellemektedir. Ayrıca, sürdürülebilir binalara olan talep genç işgücü ve bilinçli tüketiciler sayesinde artmaktadır ve bu durum gayrimenkul sektörünün bu alana yönelmesine katkı sağlamaktadır. Ek olarak eski binaların yerine yeşil binaların yapılması özellikle İngiltere ve Avrupa’da daha sık tercih edilen bir uygulama haline gelmiştir ve Orta Doğu’da da bu bağlamda çevresel sorunları göz önünde bulunduran, çevre dostu projeler hızla artmaktadır (Anonymous 2024c).

Küresel düzeyde ticari gayrimenkul piyasalarında yatırımcı ve kiracı beklentileri, son on beş yıllık dönemde önemli dalgalanmalar göstermektedir. RICS tarafından geliştirilen Ticari Gayrimenkul Duyarlılık Endeksi (Commercial Property Sentiment Index, CPSI)) bu süreçte piyasaların hangi aşamada bulunduğu dair bölgesel ipuçları sunmaktadır. Son beş yıllık döneme bakıldığında ticari gayrimenkul piyasaları, pandemi sonrası ortaya çıkan ekonomik ve sosyal dalgalanmalara karşı farklı coğrafyalarda farklı yönelimler

sergilemektedir. Özellikle 2020 yılı, küresel ölçekte eş zamanlı bir kırılmanın yaşandığı dönem olarak öne çıkmakta; takip eden dört yıl boyunca duyarlılık seviyeleri bölgesel dinamiklere göre ayrılmaktadır. Bu ayrışma, yatırımcı davranışlarında yeniden yapılanma süreçlerini tetiklemekte ve sermaye yönelimlerinde belirgin bir coğrafi kaymaya neden olmaktadır (Anonymous 2025ç).

Açıklanan çerçevede Orta Doğu ve Afrika bölgesi, 2020 yılında yaklaşık -35 seviyesine kadar gerileyen CPSI değeriyle belirgin bir düşüş yaşamakta, ancak takip eden yıllarda istikrarlı bir toparlanma sürecine girmektedir. 2024 yılı itibarıyla duyarlılığın +10 seviyelerine yükselmesi, bölgeyi yatırımcılar açısından yeniden cazip hale getirmektedir. Bu iyileşmede, Birleşik Arap Emirlikleri gibi öncü pazarlarda artan yatırım talepleri ile bölgesel politik istikrarın etkili olduğu görülmektedir. Öte yandan Asya-Pasifik bölgesi ise 2020 yılında -35 seviyelerine ulaşan sert bir gerilemeyle küresel ölçekte en fazla etkilenen bölgelerden biri olmaktadır. Bunu izleyen yıllarda toparlanma yaşansa da 2024 itibarıyla endeks hâlen -20 seviyelerinde seyretmektedir. Bu durum, bölgede pandemi sonrası piyasa dengelerinin kırılma kaldığını ve Çin ile Hong Kong gibi başlıca ekonomilerdeki arz fazlasının yatırımcı güvenini baskılamaya devam ettiğini göstermektedir (Anonymous 2025ç). Buna karşılık, Avrupa bölgesi 2020 yılında -35 düzeyine düşen CPSI verisini izleyen süreçte sınırlı bir iyileşme kaydetmekte, ancak 2024 yılında hâlâ -5 ila -10 bandında kalmaktadır. Özellikle Almanya, Fransa ve Hollanda gibi gelişmiş piyasalarda yavaşlayan ekonomik büyüme, yüksek finansman maliyetleri ve değişen ofis kullanımı eğilimleri, bu sınırlı toparlanmanın başlıca nedenleri arasında yer almaktadır (Anonymous 2025ç).

Amerika kıtası ise 2020 yılında -40 ile en sert düşüşü yaşayan bölge olmakla birlikte, sonraki yıllarda gösterdiği güçlü performansla öne çıkmaktadır. 2024 yılına gelindiğinde CPSI değeri +5 ila +10 aralığına ulaşmakta ve özellikle ABD merkezli teknoloji yatırımları ile lojistik altyapı projeleri bu toparlanmayı desteklemektedir. Bununla birlikte, bölge genelinde perakende sektörüne ilişkin kırılma devam etmekte ve yatırımcılar bu alanda temkinli davranmaktadır (Anonymous 2025ç).

Genel küresel görünüm değerlendirildiğinde ise, 2020 yılında -38 seviyelerine kadar gerileyen CPSI endeksi, beş yıllık süreçte yavaş ancak istikrarlı bir artış eğilimi sergilemektedir. 2024 yılı itibarıyla global duyarlılık -5 ila -10 aralığına yükselmiş olup bu durum yatırımcı güveninin kademeli olarak yeniden tesis edilmeye başlandığını ortaya koymaktadır. Ancak söz konusu toparlanma tüm bölgelerde aynı hızla gerçekleşmemekte, bu da küresel sermaye hareketlerinin giderek daha seçici ve stratejik biçimde yönlendiğini göstermektedir (Anonymous 2025ç).

Jones Lang LaSalle Anonim Şirketi (Jones Lang LaSalle Incorporated, JLL) tarafından yayımlanan verilere göre, 2020-2025 döneminde doğrudan yabancı yatırımlar bölgesel olarak belirgin dalgalanmalar sergilemektedir. Özellikle pandemi koşullarının etkili olduğu 2020 yılının ilk yarısında yaşanan sert düşüş, sonraki yıllarda bölgesel toparlanmalarla telafi edilmeye çalışılmaktadır. Ancak bu toparlanma süreci her bölgede aynı yoğunlukta yaşanmamış; yatırım hacimleri, ekonomik ortam ve politika setlerine bağlı olarak farklı eğilimler göstermiştir (Anonymous 2025d).

2020 yılının ardından küresel yatırım ortamında gözlenen canlanma, özellikle 2021'in ilk çeyreğinde yıllık bazda %120'ye yaklaşan artış oranıyla dikkat çekmektedir. Bu artış, pandemi sürecinde ertelenmiş yatırımların yeniden devreye alınmasıyla ilişkilendirilmektedir. Ancak bu yüksek oranlı büyüme sürdürülebilir bir ivme oluşturamamış; 2022'den itibaren yavaşlayan bir tempoya evrilmiştir. 2023 ve 2024 yılları boyunca küresel yatırım performansı daha sınırlı oranlarda artış kaydederken, 2025'in ilk çeyreğinde yeniden %40 civarında bir artış yaşanarak toparlanma eğiliminin güçlendiği görülmektedir (Anonymous 2025d).

Amerika kıtası, değerlendirme döneminde en güçlü yatırım sıçramalarının yaşandığı bölge olarak öne çıkmaktadır. 2021 yılı boyunca bölgeye yönelen yatırımlar olağanüstü artışlar göstermiş; yılın ikinci çeyreğinde %160'a varan yıllık bazda artış oranları kaydedilmiştir. Ancak bu olağanüstü performans 2022 ve 2023 yıllarında yerini düşüşe bırakmış; 2023 yılı süresince yatırım akışlarının negatif doğrultuda seyrettiği gözlemlenmektedir. 2024 yılı sonlarında başlayan sınırlı toparlanma sinyalleri, 2025'in ilk çeyreğinde belirginleşmiş ve bölgedeki yatırımcı güveninin yeniden yükselişe

geçtiğini göstermektedir (Anonymous 2025d). Benzer biçimde, Avrupa, Orta Doğu ve Afrika bölgesi de dalgalı bir yatırım eğrisi izlemektedir. 2020 ve 2021 yıllarında nispeten durağan kalan yatırım hacmi, 2022'nin ikinci yarısından itibaren düşüş trendine girmiştir. 2023 ve 2024 yıllarında ise bölgedeki doğrudan yatırım büyümesi büyük ölçüde negatif seyretmiştir. Bu durum, yüksek faiz oranları, enerji fiyatlarındaki dalgalanmalar ve jeopolitik gerginliklerin bölge üzerindeki baskılayıcı etkileriyle açıklanabilmektedir.

Ancak 2025 yılı itibarıyla yaklaşık %40'lık bir artış yaşanarak bölgenin yeniden toparlanma potansiyeli sergilediği görülmektedir. Asya-Pasifik bölgesi ise değerlendirme döneminde daha geç ve daha sınırlı bir toparlanma süreci yaşamaktadır. 2020 sonrası toparlanma diğer bölgelere kıyasla daha yavaş gerçekleşmiş; 2022 ve 2023 boyunca yatırımlar genellikle negatif eğilimde kalmıştır. Bununla birlikte, 2024 yılında dikkat çekici bir sıçrama yaşanmış ve bazı ülkelerde yıllık bazda %80'e varan artış oranları kaydedilmiştir. Bu eğilim, özellikle Japonya, Avustralya ve Güney Kore gibi güçlü bölgesel ekonomilerde yeniden canlanan yatırım faaliyetleriyle ilişkilendirilmektedir (Anonymous 2025d).

Genel olarak 2020-2025 dönemine bakıldığında, doğrudan yatırım büyümesi bölgelere göre farklılık göstermekte; yatırımcı tepkileri yerel ekonomik ve politik koşullara bağlı olarak şekillenmektedir. Amerika kıtası en hızlı toparlanan bölge olurken, Asya-Pasifik en geç toparlanma sergileyen coğrafya olarak öne çıkmaktadır. 2025 yılının ilk çeyreği itibarıyla tüm bölgelerde pozitif büyüme oranlarının kaydedilmesi, küresel doğrudan yatırım ortamının daha dengeli ve sürdürülebilir bir yapıya evrildiğini göstermektedir. JLL'nin 2025 yılı birinci çeyreğine ilişkin küresel yatırım analizine göre ise, sınır ötesi gayrimenkul sermayesi, coğrafi çeşitlenme ve stratejik yönelim bağlamında belirgin bir dönüşüm göstermektedir. Dünyadaki dört temel sermaye kaynağı bölgesi: Amerika, Asya-Pasifik ve Avrupa-Orta Doğu-Afrika küresel fonlar çıkan yatırım hacimlerinin hangi bölgesel varlık pazarlarına yöneldiğini açıkça ortaya koymaktadır (Anonymous 2025d).

Dünyadaki sermaye kaynağı olan bölgelere bakıldığında, Avrupa-Orta Doğu-Afrika bölgesi, toplam 13,7 milyar Amerikan doları değerindeki yatırım akışıyla, en fazla sınır

ötesi sermaye üreten kaynak konumundadır. Bu bölgeden çıkan yatırımın önemli bir kısmı yine Avrupa-Orta Doğu-Afrika içindeki pazarlara ve Amerika kıtasına yönelmiştir. Küresel düzeyde faaliyet gösteren yatırım fonları da benzer şekilde 13,4 milyar dolarlık bir büyüklüğe ulaşmış; özellikle Asya-Pasifik varlıklarına yönelik güçlü bir yönelim sergilemiştir. Amerika kıtası ise toplamda 6,9 milyar dolarlık dış kaynaklı yatırım sağlamış; bu sermayenin ağırlıklı kısmı Avrupa-Orta Doğu-Afrika bölgesine kanalize olmuştur. Diğer yandan, Asya-Pasifik bölgesinden çıkan 5,1 milyar dolarlık yatırım nispeten daha sınırlı olsa da hedef odaklı bir biçimde Avrupa-Orta Doğu-Afrika ve bölge içi varlıklara yönelmiştir.

Yatırımın hedeflerinde ise, Avrupa-Orta Doğu-Afrika bölgesi, 20,7 milyar dolarlık yatırım hacmiyle en fazla sınır ötesi sermaye çeken bölge olarak öne çıkmaktadır. Bu durum, bölgenin köklü ve gelişmiş pazar yapısı, yeniden yapılandırma olanakları ve güvenilir yatırım ortamıyla ilişkilendirilebilecektir. İkinci sırada yer alan Asya-Pasifik, 8,6 milyar dolarlık yatırım çekmiş; bu sermayenin büyük kısmı küresel fonlardan ve Avrupa-Orta Doğu-Afrika bölgesi merkezli yatırımcılardan kaynaklanmıştır. Amerika kıtası ise 9,0 milyar dolarlık dış yatırım alarak, özellikle Asya ve Avrupa'dan sermaye girişine konu olmuştur (Anonymous 2025d).

Sonuç olarak, sınır ötesi yatırım akışlarının artık yalnızca ekonomik büyüme beklentilerine değil; aynı zamanda bölgesel farklılıklar, risk yönetimi ve portföy çeşitlendirme stratejilerine göre yönlendiği görülmektedir. Avrupa-Orta Doğu-Afrika bölgesi hem yatırım gönderen hem de yatırım çeken yapısıyla çift yönlü sermaye merkezi konumuna gelmiştir. Öte yandan, Asya-Pasifik pazarı özellikle global yatırım fonlarının radarına girerken; Amerika, geçmişe kıyasla daha az dış yatırım sağlasa da hâlâ önemli bir hedef bölge olma özelliğini korumaktadır. Bu durum, küresel sermaye hareketlerinin artık yalnızca ekonomik büyüme beklentileriyle değil; aynı zamanda döngüsel fırsatlar, portföy çeşitlendirme stratejileri ve bölgesel yeniden konumlandırma eğilimleriyle şekillendiğini göstermektedir.

3.1.1 Küresel gayrimenkul yatırımlarının sektörel dağılımı

Teknolojik gelişmeler, demografik değişiklikler ve ekonomik koşullar küresel gayrimenkul yatırımlarını sürekli olarak etkilemektedir. Gayrimenkul yatırımcıları, 2023 ve 2024 yıllarında yüksek faiz oranları ve ekonomik belirsizlikler nedeniyle daha dikkatli davranmaktadırlar. ABD, Avrupa ve Asya-Pasifik bölgelerinde gayrimenkul pazarlarının yeniden toparlanma sürecinde oldukları ve yatırımcıların artan riskler ve yeni fırsatlar arasında denge kurmaları gerektiği vurgulanmaktadır (Anonymous 2024a). Bu dönemde, faiz oranlarının kademeli olarak düşüşe geçmesi, yatırımcılar için gayrimenkul pazarını daha güvenilir hale getirirken, ofis, lojistik ve perakende gibi alt sektörlerde yeniden canlanmalara zemin hazırlamaktadır.

Dijitalleşme, demografik dönüşüm ve sürdürülebilirlik, sektörel yatırım kararlarını doğrudan şekillendirmektedir. 2024 yılında, yüksek kaliteli varlıklara olan talebin artmasıyla birlikte sektörel ve coğrafi çeşitliliğin önemi giderek yükselmiştir. Bu çerçevede yatırımcılar, ofis yatırımlarında artan rekabet ortamını göz önünde bulundurmakta ve özellikle pandemi sonrası lojistik merkezlerine yönelik daha sürdürülebilir ve etkili çözümler üretmeye yönelmektedirler.

Ofis yatırımları, gayrimenkul sektörünün en yaygın yatırım alanlarından biri olarak öne çıkmaktadır. A sınıfı ofis binaları, özellikle merkezi bölgelerde bulundukları ve düşük risk profili ve istikrarlı kira getirisi sağladıkları için uzun vadeli yatırımcılar için çekici bir yatırım seçeneğidir (Anonymous 2024ç). Öte yandan dijitalleşme ve hibrit çalışma modellerinin yaygınlaşması, ofis sektörü üzerinde yapısal etkiler yaratmakta ve geleneksel ofis binalarına olan talebi azaltmaktadır. Bu dönüşümle birlikte yatırımcılar, daha esnek ve yüksek kaliteli projelere yönelmektedirler (Sellers 2022). Tokyo, Hong Kong ve Singapur gibi şehirler, sınırlı arz ve güçlü ekonomik temelleri ile Asya-Pasifik bölgesinde öne çıkmakta; Londra, Paris ve Frankfurt ise Avrupa’da, finansal hizmetlerin yoğunluğu ve yatırımcı ilgisi ile dikkat çekmektedirler (Anonymous 2024b).

2007-2025 döneminde ofis piyasasında boşluk oranlarının bölgesel gelişimine bakıldığında, 2007 yılından itibaren ofis piyasalarında gözlemlenen boşluk oranları,

ekonomik dalgalanmalar, yapısal dönüşümler ve beklenmedik krizlerin etkisiyle önemli değişiklikler göstermektedir. Küresel finansal kriz, dijitalleşmenin hız kazanması ve özellikle Koronavirüs pandemisi gibi kırılmalar, bu süreci yönlendiren başlıca unsurlar arasında yer almaktadır. 2025 yılında ise, boşluk oranlarının belirli pazarlarda düşüş eğilimine girmesi beklenmektedir. Bu gelişme, son yıllarda durağan seyreden talebin yeniden canlanabileceğine işaret etmektedir.

Pandemi öncesindeki dönemde, ofis pazarlarında görece daha istikrarlı bir görünüm hâkim olmuştur. 2007-2019 yılları arasında küresel ölçekte ofis boşluk oranları genellikle %10-13 aralığında değişmiş, 2008 küresel krizinin ardından yükselen oranlar, 2014 yılından itibaren kademeli olarak azalma eğilimine girmiştir. Bu süreçte Avrupa piyasaları, %7 ile %10 arasında seyreden daha dengeli boşluk oranlarıyla öne çıkarken; Kuzey Amerika ve Asya-Pasifik bölgelerinde dalgalı ve nispeten yüksek oranlar gözlemlenmiştir. Bu fark, kıta bazlı arz politikaları ile talep yapılarındaki farklılıklara dayanmaktadır. Ancak 2020 yılı itibarıyla küresel salgının etkisiyle ofis piyasalarında belirgin bir kırılma yaşanmıştır. Pandeminin ikinci çeyreğinden itibaren hemen tüm bölgelerde ofis boşluk oranlarında sert artışlar kaydedilmiştir. 2021-2024 döneminde arz fazlası ve kullanıcı alışkanlıklarındaki köklü değişim nedeniyle bu artış eğilimi devam etmiştir. 2025'in ilk çeyreği itibarıyla, Kuzey Amerika'da boşluk oranı %22'ye ulaşarak son yirmi yılın en yüksek seviyesine çıkmıştır. Küresel ortalama %17 seviyesinde seyrederken, Asya-Pasifik bölgesinde bu oran %15 dolayında olmuştur. Avrupa ise %9 civarındaki düzeyiyle görece olarak dengeli bir tablo çizmeye devam etmektedir. Bu görünüm, kıta bazlı piyasa dinamikleri ve kiralama alışkanlıklarındaki farklılıklardan kaynaklanmaktadır (Anonymous 2025d).

Boşluk oranlarındaki bu yükseliş, yalnızca azalan talebin bir sonucu olmayıp, aynı zamanda ofis arzındaki hızlı genişleme ve kiralama kararlarının ertelenmesi gibi yapısal nedenlerle de açıklanmaktadır. Özellikle hibrit ve uzaktan çalışma modellerinin kalıcı hâle gelmesi, şirketlerin mekâna olan ihtiyaçlarını yeniden tanımlamasına neden olmuştur. Bu durum, kısa vadede boşluk oranlarının eski düzeylerine gerilemesini zorlaştırmaktadır. Bununla birlikte, bazı bölgelerde kiracı talebinde sınırlı da olsa toparlanma işaretleri gözlenmektedir. Özellikle Asya-Pasifik ve Kuzey Amerika'da talep

yönlü canlanma eğilimleri, geleceğe yönelik iyimser sinyaller vermektedir. Genel olarak değerlendirildiğinde, Kuzey Amerika salgın sonrası dönemde en keskin boşluk oranı artışını yaşayan bölge olarak öne çıkmaktadır. Avrupa, sınırlı arz yapısı ve geleneksel kira sözleşmelerinin etkisiyle görece dirençli bir görünüm sergilemektedir. Asya-Pasifik ise büyük kent merkezlerinde süregelen arz artışı ve talep dönüşümünün etkisiyle orta seviyelerde istikrar arayışını sürdürmektedir. Bu bağlamda, küresel ofis piyasasında boşluk oranlarının seyri, yalnızca ekonomik değil; aynı zamanda mekânsal davranışlardaki dönüşümle de şekillenmektedir (Anonymous 2025d).

Konut sektörü hem kurumsal hem de bireysel yatırımcılar için güvenli ve istikrarlı getiri sağlaması nedeniyle ön plandadır. Şehirleşme hızındaki artış, nüfusun büyümesi ve demografik değişiklikler, konut pazarına olan talebi sürekli olarak artırmaktadır (Hatipoğlu ve Tanrıvermiş 2017, Hatipoğlu ve Tanrıvermiş 2024). Özellikle gelişmekte olan ülkelerdeki konut ihtiyacının artmasıyla bu sektördeki yatırımlar da büyüme göstermektedir. Yerel ve uluslararası yatırımcılar, hızla kentleşen bölgelerdeki yeni konut projelerine ilgi göstermekte; kamu politikaları ve teşvikler de bu yatırımların finansmanını kolaylaştırmaktadır. Bu bağlamda enerji verimliliği ve sürdürülebilirlik, modern konut projelerinde yatırım kriteri haline gelmiştir (Anonymous 2024ç) ve New York, Los Angeles, Londra ve Berlin gibi metropollerdeki lüks konut projeleri, güçlü ekonomik temeller ve sınırlı arz koşulları nedeniyle yüksek getiri potansiyeli sunmaktadır.

Alışveriş merkezleri yatırımları, gayrimenkul piyasasında önemli bir yer tutmaya devam etmektedir. Ancak son yıllarda e-ticaretin hızlı yükselişi ve tüketici davranışlarındaki değişiklikler bu alandaki yatırım dinamiklerini dönüştürmüştür. Pandemi sonrası dönemde alışveriş merkezlerine olan ilgi kısmen azalmış, yatırımcılar karma kullanım projelerine ve küçük ölçekli mağaza konseptlerine yönelmiştir (Anonymous 2024b).

Sanayi ve lojistik merkezleri yatırımları ise son yıllarda en hızlı büyüyen gayrimenkul alanlarından biri olarak dikkat çekmektedir. E-ticaretin gelişmesiyle birlikte ürünlerin tüketicilere daha hızlı ulaştırılması yönündeki talep, yeni lojistik altyapı yatırımlarını beraberinde getirmiştir. Bu doğrultuda, teslimat merkezleri, dağıtım depoları ve bölgesel

lojistik üsleri yatırımcılar açısından büyük potansiyele sahiptir. Çin ve Hindistan gibi ülkelerde artan e-ticaret hacmi ve sanayi üretiminin genişlemesi, Asya-Pasifik bölgesindeki lojistik yatırımlarını desteklemektedir ve Avrupa’da ise Almanya ve Hollanda, gelişmiş altyapı sistemleri ve stratejik konumlarıyla öne çıkmaktadır (Anonymous 2024d).

Otel ve konaklama sektörü ise turizm faaliyetlerinin yeniden canlanmasıyla birlikte gayrimenkul yatırımcılarının yeniden ilgisini çekmeye başlamıştır. Pandemi döneminde düşüşe geçen otel yatırımları, özellikle lüks otel projeleri ve premium segmentte toparlanma sürecine girmiştir. Ayrıca yatırımcılar, enerji verimliliği ve sürdürülebilirlik ilkelerini benimseyen, aynı zamanda dijital hizmetler sunan modern otel projelerine yönelmektedir. Bu tür yapılar hem maliyet avantajı sağlamak hem de müşteri memnuniyetini artırarak yatırımcılara uzun vadeli değer yaratmaktadır.

Karma projeler sektörde çok işlevli kullanımı desteklemesi nedeniyle yatırımcılar açısından dikkat çekmektedir. Konut, ofis, alışveriş merkezi ve eğlence alanlarının bir arada bulunduğu bu projeler hem şehir merkezlerinde hem de banliyölerde tercih edilmekte, farklı kullanıcı profillerine hizmet ederek yatırımın sürdürülebilirliğini sağlamaktadır. Bu bütüncül yapılar, gayrimenkul yatırımlarının çeşitlendirilmesine katkı sunmakta ve değişen kullanıcı taleplerine uyum sağlamaktadır.

3.1.2 Küresel gayrimenkul pazarının gelişimine dair tahminler

Küresel gayrimenkul pazarı, ekonomik dalgalanmalar, demografik değişimler, dijitalleşme ve sürdürülebilirlik gibi makro eğilimlerden büyük ölçüde etkilenmektedir. Bu unsurlar yatırımcı stratejileri, gayrimenkul pazarına yönelik tahminlerde ortaya çıkacak fırsatlar ve zorluklar hakkında tahminler sunmaktadır. Gayrimenkul sektörünün geleceği, dijitalleşme ve teknolojik gelişmelerle bağlantılı olarak şekillenmektedir. Akıllı bina teknolojileri, büyük veri analitiği ve dijital yönetim sistemleri, yatırım kararlarını ve gayrimenkul yönetimini dönüştürmektedir. Yapay zekâ destekli değerlendirme sistemleri ve otomatik veri işleme çözümleri, gayrimenkul pazarında karar alma süreçlerini hızlandırarak daha verimli ve doğru kararlar alınmasını sağlamaktadır. Örneğin, yapay

zekâ geçmiş performans verilerini ve demografik bilgileri analiz ederek yatırımcıların gayrimenkulleri daha iyi değerlendirmelerine olanak tanımaktadır (Anonymous 2024a).

Gayrimenkul sektörü, dijitalleşmenin hızlanmasıyla birlikte blokzincir teknolojilerini kullanmaya başlamıştır. Mülkiyet haklarının güvenli ve şeffaf bir şekilde kaydedilmesini sağlayan blokzincir, gayrimenkul alım satım işlemlerinin maliyetini ve süresini kısaltmaktadır. Bu teknoloji hem işlem güvenliğini hem de dolandırıcılık riskini azaltarak, akıllı sözleşmeler sayesinde gayrimenkul işlemleri daha ucuza ve daha hızlı gerçekleştirilmektedir (Green ve Sanghvi 2024). Küresel yatırımcılar, bu yeni teknolojileri kullanarak daha iyi risk yönetimini ve yatırımlarını daha etkili bir şekilde yönlendirebilmektedirler. Dijital araçların ve yapay zekanın sağladığı doğruluk ve verimlilik, yatırımcıların karar verme süreçlerinde hayati önem taşımaktadır. Büyük veri analitiği, özellikle tüketici davranışını ve Pazar trendlerini daha iyi anlayarak stratejik kararların daha bilinçli alınmasına yardımcı olmaktadır (Naeem vd. 2023).

Hem yatırımcılar hem de kiracılar, gayrimenkul sektöründe sürdürülebilirliğe giderek daha fazla önem vermektedirler. Çevresel, sosyal ve yönetim standartlarını karşılayan konut ve ofis projeleri, yatırımcıların yanı sıra kiracıların da ilgisini çekmektedir. Bu tür projeler, enerji verimliliğini, sürdürülebilir kaynak kullanımını ve sosyal sorumluluğu ön planda tutarak hem çevreye duyarlı hem de topluma fayda sağlayan yapılar olarak öne çıkmaktadır.

Yeşil bina sertifikalarına sahip projeler hem kiracılar hem de yatırımcılar için uzun vadede güvenli limanlar olmaktadır. Daha düşük işletme maliyetleri, yüksek doluluk oranları ve artan gayrimenkul değeri, bu tür projelerin yatırımcıların getirilerini artırmasına yardımcı olmaktadır (Anonymous 2024c). Sürdürülebilirlik hedeflerini karşılayan özellikle Avrupa’da ve Kuzey Amerika’da enerji verimliliği yüksek binalara yapılan yatırımlar artmaktadır (Anonymous 2024ç).

Geleceğin gayrimenkul pazarı, artan şehirleşme oranı ve demografik değişikliklerden etkilenecektir. Büyükşehirlerde konut fiyatlarının artması, özellikle genç nüfusun yoğun olduğu bölgelerde konut ve ofis talebinin artmasına neden olmaktadır. Özellikle yaşanan

nüfusun etkisiyle, sağlık ve bakım hizmetlerine yönelik altyapı ihtiyacı artmakta, bu da bu alanda yapılacak yatırımları cazip hale getirmektedir.

Benzer şekilde, genç nüfusun yoğun olduğu şehirlerde konut, eğlence ve iş imkânlarına yönelik talep artışı, gayrimenkul yatırımlarını bu alanlara yönlendirmektedir. Bu eğilimler, yatırım stratejilerinin bölgesel ve demografik faktörlere göre yeniden şekillendirilmesini zorunlu kılmakta ve sektörde uzun vadeli sürdürülebilir büyüme için farklı fırsatlar yaratmaktadır. Bu nedenle hem konut hem de ofis pazarında sürdürülebilir ve yenilikçi kentsel dönüşüm projeleri ön plana çıkmaktadır.

3.2 Türkiye’de Gayrimenkul Pazarının Görünümü

Stratejik konumu ve yüksek getiri potansiyeli sayesinde Türkiye, özellikle İstanbul merkezli olmak üzere, uluslararası gayrimenkul yatırımcılarının ilgisini çekmeye devam etmektedir. Körfez ülkelerinden gelen yatırımcılar, lüks konut ve ticari projelere yoğun ilgi göstermekte, bu da pazarda önemli bir yabancı yatırım payı oluştumasına neden olmaktadır.

İstanbul ve Ankara gibi büyükşehirlerde hem konut hem de ticari gayrimenkul yatırımları, yüksek getirili fırsatlar sunmaktadır ve A+ ve A sınıfı ofis binaları ve lojistik merkezler, bu dönemde öne çıkan yatırım araçlarıdır. Ancak, siyasi belirsizlikler ve döviz kuru dalgalanmalar, bu yatırımların risk algısını yükseltmiştir. Buna karşın dijitalleşme, çevre dostu uygulamalar ve sürdürülebilirlik hedefleri, özellikle yeşil bina sertifikalı projeler aracılığıyla yatırımcı ilgisini canlı tutmuştur.

2024 yılının ilk altı ayında gerçekleşen konut satışları, önceki yılın aynı dönemine kıyasla %3,7 oranında azalarak 545.074 seviyesine gerilemiştir (Anonim 2024a). Bu azalma, artan konut fiyatları ve yükselen faiz oranlarının yanı sıra, konut kredisine erişimde yaşanan zorluklara bağlanmaktadır. İstanbul, tüm satışların %17,07’si ile lider konumunu korumaktadır. Özellikle 2023-2024 yılları arasında konut, ticari gayrimenkul ve ofis yatırımlarında yoğun bir hareketlilik yaşanmıştır.

Gayrimenkul sektörü, Türkiye ekonomisinde gerek GSYH'ye katkısı gerekse istihdam kapasitesi açısından stratejik bir rol oynamaktadır. 2023 yılında inşaat sektörü %7,8 oranında büyüme kaydederken, sektördeki istihdam 1,74 milyon kişiye ulaşmıştır (Anonim 2024b). Aynı yılın ilk yarısında yabancı gayrimenkul yatırımlarında ise ilk sırayı Rusya Federasyonu almıştır (Keskin 2023). Bunun yanı sıra pazarda, döviz bazlı kira sözleşmeleri, yabancı yatırım ilgisi ve kentsel dönüşüm uygulamaları önemli belirleyici faktörler hâline gelmiştir. Lüks konut projeleri ve yüksek kira getirili ticari gayrimenkuller, döviz gelir potansiyeli nedeniyle ön plana çıkmaktadır. Özellikle İstanbul'da yürütülen kentsel dönüşüm projeleri hem arzı artırmakta hem de piyasanın yeniden şekillenmesini sağlamaktadır. Ancak döviz kuru dalgalanmaları ve makroekonomik belirsizlikler, yatırım kararlarında temkinli bir yaklaşımın benimsenmesine yol açmaktadır. Yine de İstanbul, büyük ölçekli projeler ve potansiyeliyle yabancı yatırımcılar için cazibesini sürdürmektedir.

2024 yılı itibarıyla ofis pazarı İstanbul, Ankara ve İzmir'de yoğunlaşmıştır. İstanbul'da Levent, Maslak, Ataşehir ve Kozyatağı; Ankara'da Çankaya, Söğütözü ve Eskişehir Yolu; İzmir'de ise Bayraklı ve Alsancak, ofis pazarının ön plana çıktığı başlıca bölgeler olmuştur. Bu dönemde nitelikli ofis alanlarına olan talep güçlü şekilde devam etmiş, bu durum kiraların yükselmesine ve boşluk oranlarının azalmasına yol açmıştır. Türkiye'nin stratejik konumu ve yapısal potansiyeli, bu ilgiyi beslemekte, ancak döviz kuru oynaklığı ve siyasi istikrarsızlık gibi makroekonomik faktörler zaman zaman yatırım kararlarını baskılamaktadır.

Ticari gayrimenkul piyasasında 2024 yılı, önemli bir hareketliliğe sahne olmuştur. A sınıfı ofislerde doluluk oranı %10,3'e düşerek son 12 yılın en düşük seviyesine gerilemiş, buna karşılık kira %13,5 artış göstermiştir. İstanbul'un Levent bölgesinde metrekare başına 42 dolarlık kira seviyesi, son sekiz yılın zirvesine işaret etmektedir. Lojistik alanında ise e-ticaret kaynaklı talep artışı öne çıkmış; kiralama işlemleri %138 oranında artarken, kiralanan depo sayısındaki %50 düşüşe rağmen metrekare bazında %200 büyüme yaşanmıştır (İnci 2024).

Gayrimenkul piyasaları, arz ve talep dengesinin zaman içindeki değişimiyle şekillenen döngüsel yapıya sahiptir. Bu yapı tipik olarak dört ana evreyle tanımlanmaktadır: durgunluk, toparlanma, genişleme ve aşırı arz-yavaşlama (Wheaton 2003). Türkiye gayrimenkul piyasası da bu evrelere benzer şekilde 2020-2024 döneminde çeşitli dönüşümler yaşamıştır. 2020 yılında Koronavirüs salgınının etkisiyle arz ve talep önemli ölçüde daralmış, piyasada yatırımcı faaliyeti azalmış ve durgunluk evresi gözlemlenmiştir. 2021 ve 2022 yıllarında salgın kısıtlamalarının gevşemesiyle birlikte, özellikle konut ve lojistik sektörlerinde toparlanma süreci başlamıştır. Kredilere erişimin kolaylaştırılması, kamu destekli projelerin artırılması ve düşük faizli dönem politikaları, sektörü toparlanma fazına taşımıştır. 2023 yılına gelindiğinde ise, yatırım taleplerinde ciddi bir artış ve konut fiyatlarında rekor düzeyde yükseliş yaşanmıştır (Yüce vd. 2024).

Ofis ve ticari gayrimenkul yatırımları, özellikle İstanbul ve Ankara gibi büyükşehirlerde yoğunlaşmış; lüks konut, A sınıfı ofis ve lojistik depo yatırımlarında gözle görülür bir genişleme yaşanmıştır. Bu evrede kira artışları, doluluk oranlarındaki iyileşmeler ve yeni proje geliştirme eğilimleriyle birlikte piyasa, açıkça genişleme evresine girmiştir (Keskin 2023). Ancak 2024 yılında ekonomik sıkılaşma politikaları, faiz oranlarının yükselmesi, döviz kuru hareketliliği ve makroekonomik belirsizliklerin artmasıyla birlikte, özellikle konut ve ofis sektöründe talep baskılanmış, finansmana erişim zorlaşmış ve yatırım eğilimi yavaşlamıştır. Ticari gayrimenkulde kiralar yükselmeye devam etse de boşluk oranlarındaki artış, özellikle A sınıfı ofislerde arzın talebi aşmaya başladığına işaret etmektedir. Bu durum, döngüsel olarak yavaşlama evresinin başlangıcı olarak değerlendirilmektedir (İnci 2024).

Döngüsel eğilim, alt sektörler düzeyinde farklı hızlarla ilerlemektedir. Örneğin, lojistik sektörü hâlen e-ticaretin tetiklediği genişleme sürecini sürdürmekte; buna karşılık konut ve ofis piyasalarında yavaşlamanın etkileri daha belirgin hissedilmektedir. Özellikle büyükşehirlerde konut fiyatlarının ulaştığı yüksek seviyeler ve konut kredisi faizlerindeki yükselme, bireysel alıcıları piyasadan çekmekte ve yatırım kararlarını ertelemektedir. Yabancı yatırımcılar açısından da döviz bazlı kira gelirleri cazibesini korusa da döviz kurundaki belirsizlikler ve politik risk algısı, piyasanın momentumunu sınırlandırmaktadır. Tüm bu gelişmeler doğrultusunda, 2024 yılı itibarıyla Türkiye

gayrimenkul piyasası döngünün yavaşlama evresine geçmekte; yatırımcılar daha seçici olmakta, kısa vadeli risklere karşı daha temkinli davranmaktadır.

2025 yılının ilk çeyreğinde, küresel ekonomik görünüm üzerinde jeopolitik gerilimlerin etkisi belirginliğini korumuştur. Özellikle Rusya ile Ukrayna arasındaki savaşın devam etmesi ve Orta Doğu’da süregelen çatışmalar, küresel ölçekte belirsizlikleri artırmış; buna ek olarak, ABD ile Çin arasında karşılıklı uygulanan ticaret kısıtlamaları, uluslararası ticaret akışlarını olumsuz etkilemiştir. Bu gelişmelere rağmen, enflasyon oranları dünya genelinde kademeli bir yavaşlama eğilimi göstermiş, ancak gelişmiş ekonomilerdeki merkez bankaları, parasal genişlemeden uzak durarak ihtiyatlı para politikası duruşlarını sürdürmüştür (Gönden vd. 2025). Bu çerçevede küresel gelişmelerin yansımaları, Türkiye ekonomisinde de çeşitli kırılگانlıkların ve politika revizyonlarının gündeme gelmesine neden olmuştur. Türkiye ekonomisi, 2024 yılını %3,2’lik reel büyüme oranıyla kapatmış; kişi başına düşen GSYH 15.463,00 Amerikan doları olarak açıklanmıştır. Ekonomik büyümeye rağmen, uluslararası kredi derecelendirme kuruluşlarının değerlendirmeleri, ülkede süregelen kırılگانlıklara neden olmaktadır. Uluslararası kredi derecelendirme kuruluşu Moody’s tarafından 2024 yılı ortasında yapılan değerlendirme sonucunda Türkiye’nin kredi notu B3’ten B1 seviyesine çıkarılmış; görünüm ise “pozitif” olarak korunmuştur. Bu değerlendirme, 2025 yılı ilk çeyreğinde de aynı düzeyde kalmıştır. Öte yandan Fitch Ratings, Türkiye’nin uzun vadeli yabancı para cinsinden kredi notunu BB-seviyesinde sabit tutmuş ve kredi notu görünümünü “durağan” olarak sürdürmüştür (Gönden vd. 2025).

Makroekonomik göstergeler olumlu sinyaller üretmeye devam etse de, T.C. Merkez Bankası’nın para politikası uygulamaları ve piyasa beklentileri bu süreçte daha da önem kazanmıştır. 2025 yılı başında, T.C. Merkez Bankası para politikasındaki sıkı duruşunu korumakla birlikte, mart ayında politika faiz oranını %45 düzeyinden %42,5 seviyesine çekmiştir. Ancak, yılın ilk çeyreğinde hem siyasi belirsizliklerin hem de döviz kuru oynaklığının devam etmesi, fiyatların genel düzeyi üzerinde yukarı yönlü baskılar yaratmış; bu durum, enflasyonla mücadele sürecini karmaşık hâle getirmiştir. Ayrıca, makroekonomik tahminlerde revizyon ihtiyacını doğurmuş ve büyüme ile fiyat istikrarı arasında hassas bir denge gözetilmesini zorunlu kılmıştır (Gönden vd. 2025).

Açıklanan çerçevede, finansal piyasalarda artan hareketlilik ve döviz kurundaki dalgalanmalar, doğrudan gayrimenkul piyasasına da yansyarak kiralarda belirgin artışlara yol açmıştır. Döviz piyasalarında Türk Lirası'nın ABD doları karşısında tarihi düşük seviyelere gerilemesi, para otoritesinin ilave önlemler almasına yol açmıştır. Merkez Bankası, gecelik borç verme faiz oranını %46 seviyesine yükselterek finansal piyasalara yönelik temkinli tutumunu güçlendirmiştir. Türkiye'nin kredi temerrüt takası primi ise 328 baz puana ulaşmış ve yatırımcı algısında riskin sürdüğünü göstermiştir. Döviz kurundaki dalgalanmalar ve yüksek enflasyon oranları, maliyet yapısında ciddi bozulmalara neden olmuş; özellikle gayrimenkul sektöründe hem Türk Lirası hem de döviz bazında kiralarda yıllık artışlar gözlenmiştir. Talep artışına rağmen arzın sınırlı kalması, fiyatların yukarı yönlü hareketini pekiştirmiştir (Gönden vd. 2025).

3.2.1 Türkiye'de gayrimenkul yatırımlarının sektörel dağılımı

Türkiye ekonomisinin temel dinamiklerinden biri olan gayrimenkul sektörü, 2020-2024 döneminde demografik büyüme, hızla artan kentleşme oranı ve stratejik coğrafi konum gibi etkenlerle birlikte sektörel açıdan çeşitlenerek büyüme eğilimini sürdürmüştür. Bu süreçte konut ve ticari gayrimenkul yatırımları, talep artışı ve yenilikçi projelerle öne çıkarken; sanayi ve lojistik yatırımları, özellikle üretim ve ticaret hacmindeki artışa paralel olarak ivme kazanmıştır. Bu bölümde, gayrimenkul yatırımlarının sektörel bazda dağılımı ele alınmakta ve bu dağılımın sosyoekonomik arka planı değerlendirilmektedir.

Konut sektörü, Türkiye gayrimenkul pazarının en büyük ve en dinamik alt bileşenlerinden biri olmayı sürdürmektedir. Nüfus artışı, iç göç hareketleri ve kentleşme oranlarındaki yükseliş, bu sektördeki talebi canlı tutmaktadır ve İstanbul, Ankara ve İzmir gibi büyükşehirler, konut yatırımlarının yoğunlaştığı başlıca metropollerdir. Ayrıca bu şehirlerde yürütülen kentsel dönüşüm projeleri, mevcut yapı stokunun yenilenmesini sağlarken aynı zamanda yeni konut alanlarının gelişimine zemin hazırlamaktadır. İstanbul'un Levent, Maslak ve Ataşehir gibi bölgeleri, yüksek standartlı konut projeleriyle yatırımcı ilgisini çekmektedir. Öte yandan Antalya ve Muğla gibi turistik lokasyonlarda, ikinci konut ve konaklama tesisi yatırımları da yatırımcıların alternatif gelir kaynağı olarak benimsediği alanlardır (Yüce vd. 2024).

Ticari gayrimenkul yatırımları; ofis, perakende ve karma kullanımlı projeleri kapsamaktadır. Yerli ve yabancı yatırımcılar, özellikle İstanbul'daki A sınıfı ofis projelerine ilgi göstermektedir ve Levent, Maslak ve Ataşehir gibi merkezi iş alanları, yüksek kira getirisi sunan projelere ev sahipliği yapmaktadır. Ankara'da ise Çankaya ilçesinde yer alan Çukurambar, Kızılırmak, Söğütözü ve Mustafa Kemal gibi mahalleler, kamu kurumları ve büyük ölçekli şirketlerin tercih ettiği ofis lokasyonları olarak ön plana çıkmaktadır.

Türkiye, kişi başına düşen alışveriş merkezi (AVM) sayısı bakımından Avrupa ülkeleri arasında üst sıralarda yer almaktadır. Ancak son yıllarda dijitalleşme ve tüketici davranışlarındaki değişimle birlikte, geleneksel AVM projeleri dönüşüm sürecine girmiştir. Özellikle İstanbul, Ankara ve İzmir gibi büyükşehirlerde perakende yatırımları, karma kullanım konseptine sahip projelere kaymakta; böylece konut, ofis ve ticari alanlar aynı yapıda bütünleşmektedir (Anonymous 2024ç).

Türkiye'nin stratejik konumu, sanayi ve lojistik sektöründe son yıllarda önemli miktarda yatırımları beraberinde getirmiştir. Özellikle Marmara Bölgesi, Türkiye'nin lojistik ve sanayi yatırımlarının merkezidir ve İstanbul, Kocaeli ve Bursa gibi büyükşehirler, üretim ve dağıtım tesislerine yoğun yatırım çekerken, dağıtım merkezleri için tercih edilen başlıca bölgeler olmuştur (Anonymous 2024d).

E-ticaretin hızla gelişmesiyle birlikte, özellikle büyükşehirlerde ve ulaşım ağlarına yakın bölgelerde lojistik yatırımlarda belirgin bir artış yaşanmıştır. Bu bağlamda, İstanbul'un Hadımköy, Tuzla ve Gebze gibi bölgelerinde lojistik depo yatırımlarında kayda değer büyüme gözlemlenmiştir. Ayrıca, ulaştırma altyapısının gelişimi ve ihracat odaklı büyüme politikaları da bu alandaki yatırımları desteklemektedir (Anonymous 2024d).

Turizm sektörü, gayrimenkul yatırımları içinde özel bir yer tutmaktadır. Kıyı bölgelerinde yer alan Antalya, Bodrum ve Çeşme gibi lokasyonlarda geliştirilen resort otel ve tatil köyü projeleri hem yerli hem de uluslararası yatırımcıların ilgisini çekmektedir. Şehir otelciliği ise İstanbul ve Ankara gibi büyükşehirlerde iş ve kongre turizmine yönelik talebi karşılamakta; Ege ve Akdeniz sahillerinde ise sağlık ve termal turizme dayalı

yatırımların arttığı gözlenmektedir. Türkiye'nin yüksek turizm potansiyeli, bu alandaki yatırımların devamlılığını desteklemektedir (Yüce vd. 2024).

Sektörel yapı, 2022-2023 döneminde Türkiye gayrimenkul piyasasında gözlenen genişleme eğiliminin temel dayanaklarını oluşturmuş; 2024 yılı itibarıyla ise bazı alt sektörlerde finansal koşullar ve arz-talep dengesi kaynaklı olarak yavaşlama belirtileri ortaya çıkmıştır. Her alt sektör, gayrimenkul döngüsünün evrelerine farklı düzeyde yanıt vermekte; bu da yatırım kararlarında daha dikkatli ve seçici stratejilerin benimsenmesine yol açmaktadır.

3.2.2 Türkiye gayrimenkul pazarının gelişimine dair tahminler

Demografik değişiklikler, dijitalleşme ve kentsel dönüşüm projeleri, Türkiye gayrimenkul pazarının geleceğine ilişkin tahminlerin yapılmasını ön plana çıkarmaktadır (Hatipoğlu ve Tanrıvermiş 2017, Hatipoğlu ve Tanrıvermiş 2024). Özellikle endüstriyel ve ticari faaliyetlerin yoğunlaştığı büyükşehirlerde, eski konut ve ticari gayrimenkullerin yenilenmesi ve bu alanların daha modern projelere dönüştürülmesi hedeflenmektedir. İstanbul, Ankara, İzmir gibi büyükşehirlerde devam eden kentsel dönüşüm çalışmaları, dijitalleşme ve akıllı bina teknolojilerinin yaygınlaşmasıyla ofis ve ticari gayrimenkullerin değerini artıracakı düşünülmektedir.

Türkiye'de genç nüfusun yoğun olarak yaşadığı büyükşehirlerde konut ve ofis talebinin artması beklenmektedir. Aktif nüfusun (15-65 yaş arası nüfusun) toplam nüfus içindeki payı Türkiye'de %68 gibi oldukça yüksek düzeyde bulunmaktadır. Aktif nüfusun 2024 yılında %57,9'u hizmet sektöründe istihdam edilmiş olup, hizmet sektöründeki istihdamın yüksekliği ve artma eğiliminde olması, gelecek yıllarda ofis talebinin de artacağına işaret etmektedir. Ülke düzeyinde hizmet sektöründeki istihdamın payında artışın olması, özellikle büyük kentlerde ofis mekanlarına olan talebin yüksekliği ve artma eğilimini korunması bakımından özel öneme sahip bulunmaktadır (Demirkaya 2025; Demirkaya vd. 2025). Bu yapı, yerli ve yabancı yatırımcılar için ofis yapılarına ilave olarak konut pazarında ve gayrimemkul sektörünün diğer alt pazarlarında da yeni fırsatlar sunmaktadır. Bununla birlikte, Türkiye'deki yüksek enflasyon, ekonomik belirsizlikler

ve döviz kuru değışiklikleri gibi değışkenler, gayrimenkul pazarında hem zaman içinde veya yıllara göre hem de mevsimsel dalgalanmalara yol açmaktadır.

Makroekonomik koşullar, demografik eğilimler, kentsel dönüşüm projeleri ve uluslararası yatırımcıların ilgisi, Türkiye'deki gayrimenkul pazarını sürekli olarak etkilemektedir. Bu değışkenler, Türkiye'de gayrimenkul sektörünün önümüzdeki yıllarda nasıl bir yön alacağına dair önemli ipuçları sunmaktadır. Ekonomik ve demografik eğilimler, teknolojik ilerlemeler ve sürdürülebilirlik trendleri, bu bölümde Türkiye'deki gayrimenkul pazarının geleceğine yönelik tahminler hakkında ayrıntılı bir şekilde değeriendirilecektir.

Ekonomik belirsizlikler, Türkiye'deki gayrimenkul pazarının gelecekteki performansı üzerinde en büyük etkiye sahip unsurlardan biridir. Yüksek enflasyon, döviz kuru değışiklikleri ve faiz oranları, Türkiye'nin ekonomik ortamının özellikleridir. Özellikle yabancı yatırımcılar için Türkiye'de gayrimenkul yatırımı, döviz kuru değışiklikleri nedeniyle belirsizlik ve riskle karşı karşıyadır (Anonymous 2024d). Bu nedenle, döviz bazlı kira sözleşmelerinin yaygın olduğu ticari gayrimenkul pazarında kiraların kestirimi oldukça zor bir durumdur.

Yüksek faiz oranları ve enflasyon, Türkiye ekonomisinin büyümesini zorlaştırmaktadır. Yılın son çeyreğinde Türkiye Cumhuriyet Merkez Bankası'nın politika faiz indirimini planladığı düşünülmektedir. Bu durum, yatırımcıların gayrimenkul pazarında nasıl yatırım yapacaklarını etkileyebileceğinden, yatırımcılar bekleme eğilimine girebileceklerdir. Türkiye'deki gayrimenkul pazarında yatırım yapmak isteyenler için risk yönetimi çok önemli olup yatırımcılar, döviz kuru ve faiz oranlarındaki değışikliklere hazırlıklı olmalı ve bu nedenle finansal stratejilerini bu doğrultuda oluşturmalarıdır (Öztekin 2023).

Türkiye'nin konut ve ticari gayrimenkul sektörlerindeki gelecekteki büyüme, kentsel dönüşümlerle önemli ölçüde desteklenecektir. Özellikle İstanbul, Ankara ve İzmir gibi büyük kentlerde devam eden kentsel dönüşüm projeleri, eski binaların yenilenmesini ve bu alanların modern konut ve ofis projelerine dönüştürülmesini amaçlamaktadır. Bu

projeler hem deprem riskini azaltmak hem de daha sürdürülebilir ve yaşanabilir şehir alanları oluşturmak için çok önemlidir. İstanbul'da devam eden mega projeler ve yeni uydu kent projeleri, gelecekte arz-talep dengesini değiştirebilecektir. Ayrıca, bu projelerin finansmanında ve uygulanmasında kamu-özel sektör iş birliğinin devam etmesi beklenmektedir (Yüce vd. 2024).

Türkiye'nin genç ve hızla büyüyen nüfusu, 2024 yılında gayrimenkul talebinin artmasına katkı sağlamaya devam etmektedir. Birçok insan şehirlerde yaşamayı tercih etmekte, bu da özellikle büyükşehirlerde konut talebinin artmasına neden olmaktadır. İç göç hareketleri, kırsal alanlardan büyükşehirlere doğru hızla yayılmakta ve bu eğilim, şehirlerde konut projelerine olan talebi artırmaktadır. İstanbul ve Ankara gibi büyükşehirlerde gayrimenkul satışları ve kiralar bu nedenlerle yüksek seviyelerde seyretmektedir.

Ankara ilinde yapılan araştırmada, hane halkı gelir düzeyi, konut kredisi faiz oranları ve demografik özelliklerin konut talebini etkileyen temel faktörler olduğunu gösterilmiştir (Kapusuz ve Tanrıvermiş 2024). Bu veriler, Türkiye'nin konut pazarında, özellikle büyükşehirlerde konut talebinin sürekli olarak arttığını göstermektedir ve iç göç hareketleri de bu artışı desteklemektedir.

Nüfusun yaşlanmasıyla birlikte özel konut ve sağlık tesislerine olan talep artmakta ve orta gelir grubuna yönelik konut projelerinin öne çıkması beklenmektedir. Türkiye, yaşlanma eğilimiyle birlikte emekli ve yaşlı nüfusa hitap eden konut projeleri ve yaşam alanları geliştirmektedir. Yaşlı nüfusun artması, sağlık tesislerine ve yaşlılara uygun konut projelerine olan talebi ve gayrimenkul pazarında bu tür projelerin önemini artıracaktır (Köse ve Sertkaya Doğan 2022).

Akıllı bina teknolojileri ve dijitalleşme, Türkiye'deki gayrimenkul pazarının geleceğini şekillendiren bir diğer önemli faktörlerdir. Gelişmiş veri analitiği ve yapay zekâ tabanlı uygulamalar gibi teknolojiler, gayrimenkul değerlendirme süreçlerinde yatırım kararlarının daha hızlı ve doğru bir şekilde alınmasını sağlamaktadır (Green ve Sanghvi 2024). Ek olarak, enerji verimliliği yüksek projelere olan talep, akıllı ev ve ofis çözümleri sayesinde

artmaktadır ve gayrimenkul sektöründe dijitalleşme, sadece bina teknolojileri ile sınırlı kalmayıp, dijital satış çözümleri ve online gayrimenkul platformları ile de yaygınlaşmaktadır. Bu akım, özellikle genç nüfusun konut ve ofis arayışlarını çevrimiçi olarak gerçekleştirme eğiliminde olduğunu göstermektedir.

Türkiye’de enerji verimliliği yüksek, çevre dostu ve yeşil bina sertifikalarına sahip projelere olan talebin artması, gayrimenkul pazarında sürdürülebilirlik kavramının önem kazandığını göstermektedir. Türkiye, bu alanda henüz gelişmekte olan bir pazar olmasına rağmen, yeşil bina ve enerji verimliliği standartlarını karşılayan ofis ve konut projeleri büyükşehirlerde hızla yayılmaktadır. Küresel çevre kurallarına ve Çevresel, Sosyal ve Yönetişim standartlarına uyum sağlama zorunluluğu nedeniyle, Türkiye’deki gayrimenkul projeleri de bu standartlara yönelecektir. Gayrimenkul yatırımcıları, sürdürülebilirlik hedeflerine uygun projelere yatırım yaparak uzun vadede hem mali hem de çevresel kazançlar elde edecektir.

3.2.3 Ankara ofis pazarının mevcut durumu ve gelişme eğilimleri

Ankara’da ofis talebi, kentin başkent olma statüsünden kaynaklanan idari, siyasi ve kurumsal fonksiyonları doğrultusunda şekillenmektedir. Türkiye Büyük Millet Meclisi, Cumhurbaşkanlığı, bakanlıklar, yüksek yargı organları ve çeşitli kamu kuruluşlarının merkezlerinin burada yer alması, kenti ülkenin bürokratik kalbi hâline getirmiştir. Bu durum, hem kamu kurumlarına doğrudan hizmet veren profesyonel firmalar (hukuk büroları, danışmanlık şirketleri, inşaat ve mühendislik ofisleri vb.) hem de uluslararası kuruluşların ve sivil toplum örgütlerinin temsilcilikleri için Ankara’da nitelikli ofis alanlarına olan ihtiyacı artırmaktadır.

Özellikle Çankaya ilçesi ile Söğütözü, Çukurambar, Mustafa Kemal gibi mahallelerde yoğunlaşan ofis binaları hem A+ ve A sınıfı plazaları hem de küçük ve orta ölçekli işletmelere hitap eden ofis çözümleriyle bu talebe cevap vermektedir. Ofis kullanıcı profiline bakıldığında; kamu görevlileri, üst düzey bürokratlar, serbest meslek mensupları, beyaz yakalı çalışanlar ve uluslararası uzman personel başlıca gruplar olarak öne çıkmaktadır. Ayrıca üniversitelerin, araştırma kurumlarının ve teknoloji geliştirme

bölgelerinin varlığı, bilgiye dayalı sektörlerin ve yaratıcı endüstrilerin ofis ihtiyacını da artırmakta; bu durum Ankara’da ofis talebinin yalnızca niceliksel değil, niteliksel olarak da dönüşmesine neden olmaktadır.

Ankara’da ofis talebinin şekillenmesinde, klasik arz-talep dengesi yanında, piyasadaki özümseme kapasitesi de belirleyici bir rol oynamaktadır. Arz-talep dengesi, belirli bir dönemde piyasaya sunulan yeni ofis stoku ile bu stokun ne ölçüde kullanıcı bulduğunu ortaya koyarken; özümseme kapasitesi, piyasadaki boş ofis alanlarının kiralama yoluyla ne hızda eridiğini göstermektedir.

Özellikle yeni yapılan A+ ve A sınıfı ofis binalarının sayısının arttığı Söğütözü, Mustafa Kemal ve Çukurambar gibi bölgelerde, arz yönlü büyüme gözlemlenirken; bu alanların ne ölçüde kiralandığı, piyasadaki gerçek talep dinamiklerini anlamak açısından önem arz etmektedir. Eğer ofis arzı, talep artış hızının üzerinde gerçekleşiyorsa, bu durum boşluk oranlarını artırmakta ve piyasada dengesizliklere yol açmaktadır. Buna karşın, özümseme oranının yüksek olduğu bölgelerde, kullanıcıların mevcut stokları hızla tükettiği ve yeni arzlara yönelik potansiyel olduğu görülmektedir. Dolayısıyla Ankara’daki ofis piyasasının sürdürülebilirliği, sadece yeni bina üretim miktarıyla değil, aynı zamanda arzın ne kadarının kısa sürede kiracı bulabildiğiyle yakından ilişkilidir. Bu bağlamda, yatırım kararlarının salt arz fazlalığına değil, aynı zamanda özümseme eğilimlerine göre verilmesi büyük önem taşımaktadır.

Ankara ofis pazarında arz ve talep dengesi lokasyona göre değişmektedir. Çankaya, Söğütözü ve Eskişehir yolu gibi bölgelerde modern ofis binalarına olan talep devam etmektedir. A+ ve A sınıfı ofis binaları, özellikle kamu kurumları ve uluslararası kuruluşlar tarafından tercih edilmektedir. Bunlar, merkezi ve prestijli lokasyonlarda yer almaktadır. Özellikle yeni projelerde, ofis kiralari değerini korumaktadır. Yine de eski ofis binalarının yenilenmesi ve kentsel dönüşüm projelerinin gerekliliği gündeme gelmiştir. Ofis pazarının modernizasyon ihtiyacını karşılamak için bu dönüşüm projeleri önemli fırsatlar sunmaktadır.

Kızılay ve Kavaklıdere gibi bölgeler ise daha tipik ofis alanlarına sahiptir ve ticaretin ve günlük iş aktivitelerinin yoğun olduğu yerlerdir. Bu bölgelerdeki ofis talebi, büyük ölçüde küçük ve orta ölçekli şirketler tarafından karşılanmaktadır (Yüce vd. 2024). Bu bölgeler ayrıca metro ve otobüs hatlarının birleştiği yer olduğu için yoğun bir talep görmektedir.

Ankara’da ofis kiralari büyük ölçüde bölgeden bölgeye değişmektedir. A+ ve A sınıfı ofis binalarının kiralari, Çankaya ve Söğütözü gibi elit bölgelerde şehir genelindeki ortalama kiranın üzerindedir. Kiralar, özellikle Eskişehir yolundaki ofis projelerinde 500 TL/m² ile 900 TL/m² arasında değişmektedir. Kira, Kızılay ve Kavaklıdere gibi daha merkezi ve iş merkezlerinin yoğun olduğu bölgelerde daha makul seviyelerde seyretmektedir. Pandemi sırasında uzaktan çalışma ve hibrit modellerin yaygınlaşması, büyük metrekareli geleneksel ofis alanlarına olan talebin bir dönem azalmasına neden olmuştur. Bu nedenle, bazı ofis projelerinde kiralar düşmüştür. Pandemi sonrasında ise özellikle Kızılay, Söğütözü, Çukurambar ve Mustafa Kemal gibi prestijli bölgelerde ofis binalarının kiralari hala yüksektir.

2025 yılı mart ayı itibarıyla güncellenmiş verilere göre, Ankara’da A sınıfı ofislerin metrekare başına ortalama aylık kirası 723,00 TL/m² olarak ölçülmüştür (Çizelge 3.2). Bu seviye, aynı sınıftaki İstanbul ofislerinin önemli ölçüde gerisinde kalmakla birlikte, İzmir ile eş düzeydedir. Ankara’nın merkezi iş alanları kapsamında değerlendirilen Söğütözü, Çukurambar ve Mustafa Kemal Mahallesi gibi bölgelerde son yıllarda artan kurumsal talep, fiyatları yukarı çekmiştir. Ancak bu artış, İstanbul’un Levent (1.627,00 TL/m²), Maslak 1.157,00 TL/m²) gibi bölgelerine kıyasla oldukça sınırlı kalmaktadır. Bu durum, Ankara’da arz-talep dinamiklerinin daha dengeli işlediğini ve fiyatların henüz spekülative düzeyde şişmediğini göstermektedir. Bu durum Ankara’da gelir istikrarının ön planda tutulması olarak değerlendirilebilecektir.

Başkentte 2025 yılı verilerine göre A sınıfı ofis piyasasında %25 oranında yıllık kira artışının olduğu görülmektedir (Çizelge 3.2). Bu oran, aynı dönemde İzmir ile birebir aynı seviyede olup, İstanbul’un bazı bölgeleriyle kıyaslandığında oldukça dikkat çekicidir. Örneğin, İstanbul Maslak’ta yıllık büyüme %23,1 seviyesinde kalırken, Levent-Etiler

hattında bu oran %18,4 olarak gerçekleşmiştir. En yüksek yıllık büyüme ise %52,2 ile İstanbul Anadolu Yakası'nda gözlemlenmiştir (Gönden vd. 2025).

Beş yıllık döneme bakıldığında ise Ankara'da %9 oranında birikimli kira artışı meydana gelmiş olup bu oran Maslak ve Esentepe-Gayrettepe-Zincirlikuyu bölgelerinde %11 seviyesindedir. İzmir ise %10,8 ile Ankara'nın biraz üzerinde yer alırken, Levent-Etiler bölgesi %7,1 ile en düşük beş yıllık büyümeyi sergilemiştir. Bu veriler, Ankara'nın ofis piyasasında kısa vadeli ivmelenmenin güçlü olduğunu ancak uzun vadeli büyümesinin görece olarak daha sınırlı kaldığını ortaya koymaktadır. Dolayısıyla Ankara ofis piyasası, son bir yıllık dönemde hızla değer kazanan fakat uzun dönemli büyüme performansı daha ılımlı olan bir pazar görünümü sunmaktadır (Gönden vd. 2025).

Çizelge 3.2 Türkiye'deki seçili bölgelerde Mart 2025 tarihinde A sınıfı ofis kiralari (Gönden vd. 2025)

Farklı Ofis Lokasyonları	Aylık kira (TL/m ²)	Yıllık Büyüme (%)	Beş Yıllık Büyüme (%)
İstanbul (Levent-Etiler)	1.627,00	18,4	7,1
İstanbul (Esentepe-Gayrettepe-Zincirlikuyu)	1.157,00	14,3	11
İstanbul (Maslak)	1.157,00	23,1	11
İstanbul (Anadolu Yakası)	1.265,00	52,2	9,7
İzmir	723,00	25,00	10,8
Ankara	723,00	25,00	9

Esnek ofis çözümlerine olan talebin artması ve sürdürülebilir ofis projelerinin öne çıkması, hibrit çalışma modellerinin Ankara ofis pazarında geleceğe yönelik etkisinin bir sonucu olacaktır. Özellikle kamu kurumlarının ve uluslararası kuruluşların merkez ofislerinin bulunduğu bölgelerde, sürdürülebilirlik ve enerji verimliliği standartlarını karşılayan projelere olan ilginin artacağı tahmin edilmektedir. Ek olarak, yeni nesil çalışma alanlarına yönelik artan talep, teknoloji destekli ofis projelerine daha fazla esneklik sağlayacaktır. Ankara'nın kentsel dönüşüm projeleri kapsamında ofis pazarında yenileme ve eski binaların modernleştirilmesi hızlandırılacaktır. Ankara ofis pazarında bu dönüşüm, arz ve talep dengesini yeniden şekillendirebilecektir. Özellikle Çankaya ve Eskişehir yolu gibi yerlerde eski binaların yenilenmesi, kiralari artırabilecektir.

4. GAYRİMENKUL DEĞERLEMEDE KULLANILAN YÖNTEMLER VE MATEMATİKSEL MODELLERİN KULLANIM OLANAKLARI

Gayrimenkul değerlemesi, dinamik piyasa koşulları, çok değişkenli veri yapısı ve karar alma süreçleri üzerindeki etkisi nedeniyle hem akademik hem de uygulamalı çalışmalarda önemi artan disiplinlerarası bir araştırma alanı hâline gelmektedir. Bu çerçevede, bir gayrimenkulün değerinin doğru, nesnel ve tekrarlanabilir biçimde belirlenmesi, kullanılan değerleme yöntemlerinin metodolojik sağlamlığına ve analitik derinliğine doğrudan bağlı bulunmaktadır. 31 Ocak 2025 tarihinde yürürlüğe giren Uluslararası Değerleme Standartları (International Valuation Standards, IVS) doğrultusunda bu bölümde ele alınan yöntemler, üç ana grupta sınıflandırılmaktadır. Bunlar sırasıyla IVS'nin 105-Değerleme Yaklaşımları ve Metotları standardı temel alınan geleneksel değerleme yaklaşımları (pazar, gelir ve maliyet), istatistiki ve matematiksel yöntemler (nominal değerleme, çoklu regresyon ve hedonik modeller) ile makine öğrenmesine dayalı yöntemler (RF, ANN gibi) şeklinde yapılandırılmaktadır.

IVS'nin 2025 güncellemeleri doğrultusunda değerleme sürecine entegre edilmesi zorunlu hâle gelen çevresel, sosyal ve yönetişimsel kriterler (Environmental, Social and Governance, ESG) de değerleme yöntemleri içinde ele alınmıştır. Geleneksel uygulamaların ötesine geçilerek; enerji verimliliği, karbon ayak izi, sosyal sürdürülebilirlik katkısı ve kurumsal şeffaflık gibi göstergelerin, gayrimenkul değerinin ayrılmaz bileşenleri hâline geldiği görülmektedir. Bu kapsamda, değerleme uzmanlarının yalnızca metrekare değeri ya da kira getirisi değil; aynı zamanda ESG kriterlerine ilişkin performans göstergelerini de dikkate alması gerekmektedir. Bu bütüncül yapı sayesinde, farklı değerleme yaklaşımlarının güçlü ve sınırlı yönleri karşılaştırmalı olarak analiz edilmekte ve güncel standartlara uyumlu bir modelleme çerçevesi sunulmaktadır.

Çevresel kriterler enerji verimliliği, yeşil bina tasarımı, karbon emisyonlarının azaltılması ve yenilenebilir enerji kullanımı gibi unsurları içermektedir. LEED veya BREEAM gibi sertifikalara sahip olan sürdürülebilir gayrimenkuller, yatırımcı ve kullanıcılar tarafından daha fazla tercih edilmekte ve bu talep, söz konusu varlıkların benzerlerine kıyasla daha yüksek piyasa değerlerine ulaşmasına neden olmaktadır. Çevresel uyumu düşük, enerji

verimsiz ve eski teknolojilere sahip binalar ise “kahverengi iskonto” olarak adlandırılan bir değer kaybı ile karşı karşıya kalmaktadır (Hepşen 2025).

Sosyal faktörler yalnızca fiziksel erişilebilirlik ile sınırlı kalmamakta; toplumsal refah, sosyal donatı alanlarının varlığı, ulaşım bağlantıları ve yaşam kalitesi gibi unsurları da kapsamaktadır. Özellikle çalışan memnuniyetine odaklanan ofis binaları, hibrit çalışmaya uygun tasarımlar ve yeşil alanlarla çevrili konut projeleri, gayrimenkule olan talebi artırmakta ve uzun vadeli değer yaratmaktadır. Buna karşılık, kentsel dönüşüm bölgelerinde sosyal sürdürülebilirlik kriterlerini içermeyen projeler, yatırımcılar tarafından “sosyal risk” taşıyan alanlar olarak değerlendirilmektedir (Hepşen 2025).

Yönetişim ilkeleri ise şeffaflık, etik yönetim anlayışı, adil kira sözleşmeleri ve ESG raporlamalar gibi uygulamaları içermektedir. Özellikle büyük ölçekli kurumsal yatırımcılar, bu kriterleri karşılayan gayrimenkul projelerine yönelmekte ve uyum düzeyi düşük yatırımlardan uzak durmaktadır. Avrupa Birliği Taksonomi Regülasyonu ve ABD Menkul Kıymetler ve Borsa Komisyonu’nun ESG raporlama zorunlulukları, gayrimenkul geliştiricilerinin sürdürülebilir ve hesap verebilir yönetim uygulamaları benimsemesini zorunlu kılmaktadır (Hepşen 2025).

ESG kriterlerine uyum göstermeyen projeler piyasa değerinde kayıplar yaşama riski taşımakta; sürdürülebilirlik ve yönetim odaklı geliştirilen gayrimenkuller ise yatırımcılar açısından daha avantajlı konuma gelmektedir. Gayrimenkul değerlendirme uzmanları için artık yalnızca fiziksel ve ekonomik göstergeler değil; karbon ayak izi, sosyal etki düzeyi ve kurumsal şeffaflık gibi ESG kriterleri de dikkate alınması gereken zorunlu değişkenler arasında yer almaktadır. Bu dönüşüm, IVS’nin 2025 yılı güncellemesiyle birlikte değerlemede yeni bir standart sistematığının oluşmasına katkı sağlamaktadır (Hepşen 2025). Buna ilave olarak IVS’nin 2025 yılı versiyonuna veri ve matematiksel model başlığı altında yeni bir bölümde eklenmiş ve değerlemede kullanılacak matematiksel modellerin yapısı ile veri kaynakları, ilk defa uluslararası standartların gündemine girmiş bulunmaktadır.

Çalışmanın bu bölümünde ilk olarak, uzun yıllardan bu yana kurumsal ve profesyonel değerlendirme uygulamalarında yer bulan geleneksel değerlendirme yaklaşımları incelenmektedir. Bu yaklaşımlar; pazar, gelir ve maliyet yöntemleri olmak üzere üç temel alt başlıkta değerlendirilmektedir. Her biri farklı varsayımlara dayanan bu yöntemler, özellikle sınırlı veriyle çalışan uygulamalarda hâlen geçerliliğini korumaktadır.

İkinci olarak, geleneksel yöntemlerin ötesine geçerek daha sistematik, sayısal ve ampirik temellere dayanan istatistiki ve matematiksel değerlendirme yöntemleri ele alınmaktadır. Bu yöntemler arasında nominal değerlendirme, çoklu regresyon analizi ve hedonik fiyat modeli gibi istatistiki yaklaşımlar yer almakta; bu yöntemler yardımıyla, gayrimenkul özellikleri ile piyasa değeri arasındaki ilişkiler sayısal olarak modellenmektedir.

Üçüncü olarak, son yıllarda büyük veri analitiği ve yapay zekâ alanındaki gelişmelerin etkisiyle gayrimenkul değerlendirme literatüründe hızla yayılan makine öğrenmesi yöntemleri açıklanmaktadır. Bu kapsamda; MLR, Ridge Regresyonu (Ridge Regression, RR) ve Lasso Regresyonu (Least Absolute Shrinkage and Selection Operator, LR), DT, RF, k-NN, SVM, Aşırı Gradyan Artırma (Extreme Gradient Boosting, XGBoost) ve ANN gibi yöntemler ayrı alt başlıklarda detaylı biçimde ele alınmaktadır. Bu yöntemlerin her biri hem modelleme gücü hem de tahmin performansı açısından karşılaştırmalı olarak değerlendirilmiştir.

Son olarak, değerlendirme sürecinin vazgeçilmez bileşenlerinden biri olan gayrimenkul PB yaklaşımı ele alınmakta VE benzer özelliklere sahip alt pazarların nasıl belirlenebileceği açıklanmaktadır. Bu yapı sayesinde, her bir yöntem sınırlılıklarıyla birlikte değerlendirilmiş ve farklı piyasa koşullarında hangi modelin hangi durumlar için daha uygun olabileceğine dair bütüncül bir değerlendirme yapılması hedeflenmektedir.

4.1 Geleneksel Değerleme Yaklaşımları

Uluslararası Değerleme Standartları Konseyi (International Valuation Standards Council, IVSC) tarafından hazırlanan IVS'nin son hali 31 Ocak 2025 itibarıyla yürürlüğe girmiştir.

IVSC, deęerleme uygulamalarında řeffaflık, gvenilirlik ve tutarlılıęın saęlanması amacıyla uluslararası kabul gren standartlar geliřtirmektedir. Bu standartlar, zellikle gayrimenkul ve finans gibi disiplinlerde deęerleme faaliyetlerinin ortak bir erevede yrtlmesini kolaylařtırmaktadır (Anonymous 2025b). Geliřtirilen bu standartlar sayesinde konut, ticari ve tarımsal nitelikli gayrimenkuller ile maddi olmayan duran varlıkların deęerlemesi daha sistematik ve karřılařtırılabilir hale getirilmiřtir (Akbař ve Ayanoglu 2025).

IVS, finansal raporlama srelerinde, vergisel uygulamalarda, yasal uyumun saęlanmasında ve yatırım kararlarının desteklenmesinde nemli bir iřlev stlenmektedir. Bu baęlamda, deęerleme faaliyetlerinin yalnızca teknik bir sre olmanın tesine geerek, kamu gveninin srdrlebilirliğini temin eden temel bir kurumsal ara haline geldięi grlmektedir (Anonymous 2025b). Standartlara uyum, bazı durumlarda yasal zorunluluk olarak tanımlanmakta, bazı durumlarda ise deęerleme uzmanı ile hizmet talep eden taraflar arasında yapılan szleřmeler aracılıęıyla gnll řekilde benimsenmektedir.

Deęerleme yntemlerinin seiminde, deęerleme konusu varlıęın zellikleri ile deęerleme amacı dikkate alınmalıdır. Uygulanacak yaklařımın, deęerleme srecinin baęlamına ve ekonomik varsayımlarına uygun olması gerekmektedir. Bu erevede, standartlarda  temel deęerleme yaklařım ifade edilmektedir. Bu yaklařımlar fiyat dengesi, fayda beklentisi ve ikame ilkesi gibi ekonomik temellere dayanmaktadır Ařaęıda sırasıyla aıklanacak olan bu yntemler: Pazar Yaklařımı, Gelir Yaklařımı ve Maliyet Yaklařımıdır. Her biri farklı veri trleri ve varsayımlar erevesinde deęer retmekte, deęerleme uzmanına srecin baęlamına gre esnek seim imknı sunmaktadır.

4.1.1 Pazar yaklařımı

Pazar yaklařımı, deęerleme konusu gayrimenkuln, benzer nitelikteki gayrimenkullerle karřılařtırmalı olarak analiz edilmesi yoluyla deęerinin belirlenmesini amalayan bir yntemdir. IVS'ye gre, bu yntem; yeterli sayıda ve gvenilir nitelikte emsalin mevcut olduęu aktif piyasalarda en doęrudan ve řeffaf deęerleme yntemi olarak kabul

edilmektedir. Pazar yaklaşımı, özellikle likiditenin yüksek olduğu, ofis gibi ticari gayrimenkul piyasalarında etkin biçimde uygulanmaktadır (Anonymous 2025b).

Genellikle, bir gayrimenkulün yerel pazardaki muhtemel fiyatı dikkate alınarak değerlendirilmektedir. Değerleme, belirli bir pazardaki arz ve talep koşulları ile gayrimenkulün türüne göre gerçekleştirilmelidir. Ancak bu yöntemin uygulanabilmesi için gayrimenkulün rayiç değerinin veya emsallerinin güncel değerlerinin bilinmesi, ayrıca geçmiş yıllarda gerçekleşen satış değerlerinin sıklıkla Yurt İçi Üretici Fiyat Endeksi ile güncellenmesi yoluna gidilmektedir (Tanrıvermiş 2017).

Pazar yaklaşımı özellikle aktif ve likit pazarlarda doğru ve güvenilir sonuçlar sunmaktadır. Ancak yeterli veri yoksa ve pazarda dengesizlikler söz konusu olduğunda bu yöntem yanıltıcı sonuçlar verebilmektedir. Pazar analizlerini etkili bir şekilde kullanabilmek için, yakındaki benzer gayrimenkullere ait güncel ve güvenilir değerlere ihtiyaç vardır. Bununla birlikte bu yaklaşımın başarısı, hedef gayrimenkulle uyumlu emsal gayrimenkullerin belirlenmesine ve ilgili pazarın ne kadar likit olduğuna bağlıdır (Hendershott vd. 2010).

IVS'ye göre değerlemede, gösterge niteliğinde bir değere ulaşılabilmesi için değerlendirme konusu varlıkla aynı ya da benzer nitelikteki varlıklara ilişkin gerçekleşmiş işlem bilgilerinden yararlanılmaktadır. Bu yöntemle değerlendirme yapılırken, geçmiş dönemlere ait satış verileri kullanılıyorsa, pazar koşullarında meydana gelen değişiklikler mutlaka dikkate alınmalıdır. Bu bağlamda gelişmekte olan ülkelerde, fiyatların genel seviyesindeki hızlı artışlar nedeniyle en fazla son üç ila altı aylık verilere dayalı bir değerlendirme yapmak daha faydalıdır. Ayrıca değerlendirme uzmanlarının, ilgili kurumlardan ve tapu kayıtlarından elde edilen verileri kontrol ederek bilgilerin doğruluğunu teyit etmeleri gerekmektedir ve alım-satım sözleşmeleri bilgileri gibi ek bilgi kaynakları da kullanılmalıdır (Anonymous 2025b).

Gayrimenkul hakları, satış koşulları, finansman koşulları, konum ve ekonomik durum gibi faktörler değerlendirme sürecinde özellikle dikkate alınmalıdır. IVS'ye göre, yalnızca internet sitelerinde ilan edilen fiyatların kullanılması doğru değildir çünkü bu fiyatlar

pazar değeri hakkında genel bir fikir verse de kesin sonuçlar sunamamaktadır. Karşılaştırma yapılacak gayrimenkullerin, değeri yapılacak gayrimenkullerin özelliklerine benzer olması ve farklılıklar varsa bunların değerlendirilmesi gereklidir. Bununla birlikte, uygulamada bu tür düzeltmelerin sıklıkla yanlış yapıldığı ve soyut gerekçelerle nihai değerlerin belirlendiği görülmektedir. Ayrıca Tanrıvermiş (2016)'e göre, benzer nitelikteki gayrimenkul satışlarının karşılaştırılmasına dayalı değerlendirme sürecinde öncelikle ilgili verilerin araştırılması, toplanması ve doğrulanması; ardından değerlemede kullanılacak uygun karşılaştırma birimlerinin belirlenmesi, emsal satışların analiz edilip gerekli düzeltmelerin yapılması ve nihayetinde değerin hesaplanması adımlarının sırasıyla yürütülmesi gerekmektedir.

Sirmans vd. (2003) tarafından yapılan çalışmada tek ailelik konutlar için hedonik fiyatlandırma modellerinde en sık karşılaşılan metrekare alanı, arsa büyüklüğü, yaş, yatak odası sayısı, banyo sayısı, garaj, yüzme havuzu, şömine ve klima gibi konut özellikleri incelenmiştir ve çeşitli konut özelliklerinin pazar değeri üzerindeki etkileri karşılaştırmalı satış analizi yöntemi kullanılarak değerlendirilmiştir.

Örneğin, Ankara'nın Çankaya ilçesinde bulunan, 120 m² büyüklüğünde ve 10 yıllık bir ofisin kirasının belirlenmek istendiği varsayılmaktadır. Bu kapsamda aynı bölgede yer alan üç benzer ofise ait kira verileri incelenmektedir. Birinci emsal 115 m² büyüklüğünde olup aylık 57.500,00 TL'ye kiralanmıştır (500,00 TL/m²). İkinci emsal 125 m² olup aylık kirası 75.000,00 TL'dir (600,00 TL/m²). Üçüncü emsal ise 120 m² büyüklüğünde fakat 2+1 planlıdır ve 66.000,00 TL'ye kiralanmıştır (550,00 TL/m²). Bu emsaller dikkate alınarak, metrekare bazında kira hesaplanmakta ve fiziksel farklılıklara göre düzeltmeler yapılmaktadır. Sonuç olarak, değerlendirme konusu ofisin ortalama kirası 550,00 TL olarak belirlenmekte ve toplam aylık kirası yaklaşık 66.000,00 TL olarak kestirilmektedir. Bu örnek, pazar yaklaşımının gerçekçi kira verilerine dayalı karşılaştırmalı bir analiz süreci sunduğunu ortaya koymaktadır.

4.1.2 Gelir yaklaşımı

Gelir yaklaşımı, bir gayrimenkulün gelecekte sağlayacağı ekonomik faydaların bugünkü değere indirgenmesi esasına dayanan bir değerlendirme yöntemidir. IVS'ye göre bu yaklaşım, yatırım amaçlı gayrimenkullerin ve düzenli gelir akışı üreten ticari gayrimenkullerin değerlemesinde temel yöntem olarak kullanılmaktadır (Anonymous 2025b).

Gelire dayalı değerlendirme yöntemlerinde artık gelir yaklaşımı, net kira gelirinin hesaplanması, brüt ve net kira çarpanı analizleri, iskonto edilmiş nakit akımları yöntemi, marjinal verimlilik esaslı değerlendirme ile fırsat maliyeti yaklaşımı gibi çeşitli tekniklerden yararlanılmaktadır. Ancak Türkiye'deki uygulamalarda, bu kapsamlı yöntem yelpazesi yerine genellikle doğrudan kapitalizasyon yaklaşımı tercih edilmekte olup bu yöntemde gayrimenkulün yıllık ortalama net gelirinin uygun bir kapitalizasyon oranına bölünmesiyle değer tahmini yapılmaktadır (Tanrıvermiş 2008, Tanrıvermiş 2017). İfade edilen yöntem dışındaki diğer gelir temelli analiz tekniklerinin sektörde yeterince tanınmadığı ve uygulamada yaygınlık kazanmadığı görülmektedir. Bu yaklaşım özellikle düzenli gelir elde eden gayrimenkuller ve ticari gayrimenkuller için uygundur. Örneğin, bir alışveriş merkezi, ofis binası veya otel gibi ticari gayrimenkuller bu yöntemle değerlendirilebilmektedir ve ayrıca tarımsal araziler gibi gelir getiren yapısız arazilerin değerlendirilmesi için de kullanılabilir. Gelirlerin düzenli olmadığı veya güvenilir verilerin olmadığı durumlarda, bu yöntem daha genel analizler için kullanılabilir ve hatalı sonuçlar verebilmektedir (Tanrıvermiş 2017).

Türkiye'de otel, AVM ve ofis gibi gayrimenkullerin değerlemesi genellikle net faaliyet gelirine dayanmaktadır. Bununla birlikte, yeterli gelir ve gider bilgilerine erişim zor olabilmektedir. Bu durum, değerlendirme sonuçlarının güvenilirliğini etkileyebilmektedir ve önemli farklılıklar ortaya çıkmaktadır. Avrupa Birliği ve ABD gibi gelişmiş ülkelerde, tarımsal arazilerin değerleri ve kapitalizasyon oranları düzenli olarak raporlanmaktadır. Bu uygulama sayesinde değerlendirme sürecinde daha doğru ve güvenilir sonuçlar elde edilmektedir. Gelişmiş ülkelerde bu tür verilerin sık sık raporlanması, değerlendirme işlemlerinde tutarlı ve karşılaştırmalı sonuçlar sağlamaktadır. Türkiye'de ise benzer

uygulamalar ve veri kaynakları, gayrimenkul değerleme sürecinin güvenilirliğini artırabilmektedir (Tanrıvermiş 2017).

Yaklaşım kapsamında geliştirilen senaryoda, Ankara'nın Çankaya ilçesinde yer alan 150 m² büyüklüğünde bir ofisin, gelir yaklaşımıyla değerinin belirlenmesi hedeflenmektedir. Ofisin yıllık brüt kira geliri 1.000.000,00 TL olarak kestirilmektedir. Yıllık işletme giderleri (yönetim, bakım, sigorta vb. giderler dahil) toplamda 200.000,00 TL'dir. Bu durumda, ofisin Net İşletme Geliri aşağıdaki şekilde hesaplanmaktadır:

Net İşletme Geliri= Brut Gelir- Giderler Toplamı (Tanrıvermiş 2017)

Ofisin Net İşletme Geliri= 1.000.000,00 TL-200.000,00 TL= 800.000,00 TL olarak hesaplanmaktadır.

Bölgedeki benzer ofis yatırımları için piyasa analizleri sonucunda kapitalizasyon oranı (%8) olarak belirlenmiştir. Bu oran, yatırımcıların benzer gayrimenkullerden bekledikleri yıllık net getiri oranını temsil etmektedir.

Kapitalizasyon yaklaşımı kullanılarak değer aşağıdaki şekilde hesaplanmaktadır:

Değer = Net İşletme Geliri / Kapitalizasyon Oranı (Tanrıvermiş 2017).

Değer = 800.000,00 TL / 0,08 = 10.000.000,00 TL

Analiz sonucunda, söz konusu ofisin piyasa değeri 10.000.000 TL hesaplanmaktadır. Bu senaryo, gelir yaklaşımının, özellikle düzenli kira geliri üreten gayrimenkullerde piyasa temelli, şeffaf ve analitik bir değerlendirme çerçevesi sunduğunu göstermektedir.

4.1.3 Maliyet yaklaşımı

IVS'ye göre maliyet yaklaşımı, bir varlığın değerlemesinde alıcının, zaman kaybı, kullanım zorluğu veya risk gibi ilave maliyet doğuran durumlar olmadıkça, aynı işlevi görecektir başka bir varlığı inşa etmek ya da satın almak için katlanacağı maliyeti aşan bir bedeli ödemeyeceği temel varsayımına dayanan ekonomik ilkeye bağlı bir yöntemdir. Yaklaşımda, değerlendirme konusu varlığın gösterge niteliğindeki değeri belirlenmektedir (Anonymous 2025b).

Maliyet yaklaşımında, bir gayrimenkulün satın alınması yerine benzer bir yapının inşa edilebileceği fikri kullanılmaktadır. Genel olarak, insanlar zaman kısıtı veya risk unsurları söz konusu değilse, eşdeğer bir arazi üzerinde benzer bir yapıyı inşa etmek yerine daha fazla ödeme yapmayı tercih etmezler. Bu yöntem, gayrimenkulün değerlendirme günündeki yeniden inşaat maliyetinin tespit edilmesi üzerine yoğunlaşmaktadır ve genellikle otel, fabrika ve sanayi sitesi gibi özel amaçlı yapıların değerlemesinde yaygın olarak kullanılmaktadır.

Yapının yaşı, fiziksel durumu ve sunduğu fonksiyonel olanaklar göz önünde bulundurularak niceliksel ve niteliksel farklılıkların etkisini değerlendirmek amacıyla, inşaat ve geliştirme maliyetlerine ilişkin güncel veriler karşılaştırmalı olarak analiz edilmektedir. Yerine koyma ve yeniden inşa maliyetleri, değerlendirme literatüründe kullanılan iki ana maliyet yaklaşımı olup bununla birlikte, hurda bedeli ve levazım bedeli olarak bilinen iki ana maliyet ölçütü de sıklıkla kullanılmaktadır (Tanrıvermiş 2017).

Uygulamada bir gayrimenkulün mevcut kullanımına eşdeğer bir yapının bugünkü inşa maliyetinin belirlenmesi ve bu maliyetten yıpranma payının düşülerek, arsa değeri ile toplam değerinin hesaplanması esas alınmaktadır. Özellikle emsal verilerin yetersiz olduğu, özel amaçlı veya gelir üretmeyen gayrimenkullerin değerlemesinde temel yöntemlerden biri olarak kullanılmaktadır.

Yönteme ilişkin geliştirilen senaryoda, Ankara'nın yeni gelişen bir iş bölgesinde yer alan, 5 yıllık, 250 m² büyüklüğünde bir ofis biriminin piyasa değerinin tespiti amaçlanmaktadır. Türk Mühendis ve Mimar Odaları Birliği İnşaat Mühendisleri Odası tarafından yayımlanan inşaat birim fiyatlarına göre, benzer bir yapının yeniden inşa maliyetinin 10.000,00 TL/m² olduğunu varsayalım. Bu çerçevede, yapı maliyeti 250 m² x 10.000,00 TL = 2.500.000,00 TL olarak hesaplanmaktadır. Ofisin fiziki durumu dikkate alınarak, %10 oranında yıpranma ve kullanım kaynaklı değer kaybı tahmin edilmekte ve bu da 250.000,00 TL tutarında indirimden oluşmaktadır.

Böylece düzeltilmiş yapı maliyeti 2.250.000,00 TL olarak belirlenmektedir. Aynı bölgede yapılan arsa analizine göre metrekare arsa değeri 5.000,00 TL olarak saptanmakta, 250 m² arsa payı için toplam arsa değeri 1.250.000,00 TL olarak hesaplanmaktadır. Sonuç olarak, maliyet yaklaşımı ile ofis biriminin toplam değeri 3.500.000,00 TL olarak hesaplanmaktadır. Bu örnek, uluslararası değerlendirme standartlarına ve ulusal fiyat normlarına uygun olarak maliyet yaklaşımının yapı maliyeti, yıpranma payı ve arsa değeri bileşenleri temelinde nesnel ve sistematik bir değerlendirme süreci sunduğunu ortaya koymaktadır.

4.1.4 İstatistiksel ve matematiksel değerlendirme yöntemleri

İstatistik temelli ve matematiksel yaklaşımlar, gayrimenkullerin değerlemesinde nicel veri kullanımı ve istatistiksel modelleme yöntemleri ile desteklenen alternatif yöntemler arasında yer almaktadır. Bu yaklaşımlar, geleneksel değerlendirme yöntemlerinin özellikle veri yoğunluğu, nesnellik ve zamansal etkinlik açısından sınırlı kaldığı durumlarda önemli avantajlar sunmaktadır. Sayısal yöntemlerin öne çıkmasının başlıca nedenleri arasında daha büyük veri kümeleriyle analiz yapılabilmesi, istatistiksel yazılımlar aracılığıyla karmaşık ilişkilerin modellenmesi ve değerlendirme sürecinin daha sistematik hale getirilebilmesi yer almaktadır (Tanrıvermiş 2017).

Gelişmiş ülkelerde gayrimenkul piyasasına yönelik olarak istatistiksel değerlendirme yöntemleri sıklıkla uygulanmakta olup bu yöntemlerin geniş veri tabanları ile desteklenmesi, güvenilir ve tekrarlanabilir sonuçlara ulaşılmasını mümkün kılmaktadır.

Ancak birçok geliřmekte olan ÷lkede söz konusu yöntemlerin kullanım alanı henüz sınırlı düzeydedir ve çoğunlukla akademik düzeyde teorik çalışmalarla sınırlı kalmaktadır (Khamrabaeva 2020).

İstatistiksel ve matematiksel değlerleme, gayrimenkullerin nitelikleri ile değleri arasındaki sayısal ilişkilerin çeşitli istatistiksel tekniklerle tahmin edilmesine dayanmaktadır. Bu yaklaşımlarda çoğunlukla çoklu doğrusal regresyon analizleri kullanılmakta olup gayrimenkullerin konum, büyüklük, yapı kalitesi, ulaşım olanakları gibi özelliklerinin satış veya kira üzerindeki etkileri istatistiksel modeller aracılığıyla hesaplanmaktadır. Fonksiyonel ilişkinin belirlenmesinde grafik analizleri ve deneme-yanılma yöntemleri ile en uygun model formu seçilmekte, elde edilen parametreler ilgili değışkenlerin gayrimenkul değgerine olan dolaylı etkilerini temsil etmektedir (Tanrıvermiş 2017).

Bu tür modellerin oluşturulabilmesi için piyasa koşullarını yansıtan ve güvenilirliği test edilmiş emsal verilere ihtiyaç duyulmaktadır. Elde edilen modeller sayesinde yalnızca mevcut gayrimenkullerin değgerleri değil, benzer nitelikteki gayrimenkullerin potansiyel değgerleri de tahmin edilebilmektedir. Bu çerçevede, özellikle nominal değgerleme yöntemi, çoklu regresyon analizleri ve hedonik fiyat modeli istatistiksel ve matematiksel değgerleme süreçlerinde en sık başvurulanan temel teknikler arasında yer almaktadır.

Yöntemin temelinde, gayrimenkullerin değgerini etkileyen faktörlerin belirlenmesi ve her bir gayrimenkulün bu faktörler doğrultusunda sayısal bir değger ile temsil edilmesi yer almaktadır. Fiziksel, çevresel, konumsal ve sosyo-ekonomik niteliklere göre gayrimenkuller için nominal katsayılar oluşturulmaktadır. Bu katsayılar, piyasa değgeri ve emlak vergisine esas gayrimenkul değgerleri ile doğrudan ilişkilendirilebildiği gibi, puanlama yöntemine dayalı parametrik değgerlerle de ifade edilebilmektedir (Yomralıoğlu vd. 2011; Ezber Kurtar ve Tanrıvermiş 2024).

Nominal değgerleme yöntemi, geleneksel karşılaştırma yöntemlerinden farklı olarak, her bir gayrimenkulü bire bir karşılaştırmak yerine, değger unsurlarını sistemli bir biçimde puanlayarak görelî farklar üzerinden değgerlendirme yapılmasına olanak tanımaktadır. Bu

yönüyle, öznel hataların azaltılması ve geniş alanlardaki analizlerin daha objektif yürütülmesi mümkün olmaktadır. Farklı ekonomik, fiziksel ve sosyal özelliklere sahip alanlarda kullanılan faktörlerin farklılık gösterebilmesi nedeniyle yöntem yerel bağlam içerisinde ele alınmaktadır (Doldur ve Alkan 2021).

Yöntemin uygulanmasında ilk aşama, değerlendirme yapılacak alanda gayrimenkul değerini etkileyen kriterlerin tanımlanmasıdır. Bu kriterlere ilişkin puan aralıkları oluşturulmakta ve her bir gayrimenkule uygun puan atamaları yapılmaktadır. Sonrasında bu puanlar ağırlıklandırılarak veya katsayılarla işlenerek her bir gayrimenkul için nominal bir değer üretilmektedir. Bu süreç, özellikle gayrimenkul vergilendirmesinde kullanılan matrahların belirlenmesinde nesnel bir temel sunmaktadır (Derinpınar 2014; Vargün 2021).

Çoklu regresyon analizi, gerek geleneksel değerlendirme yöntemlerinin sınırlarını aşması gerekse tekrar edilebilir, objektif ve karşılaştırılabilir sonuçlar sunması nedeniyle modern değerlendirme teknikleri arasında önemli bir yer tutmaktadır (Shawn vd. 2019). Regresyon analizleri, bağımlı değişkenin, bir veya daha çok bağımsız değişken tarafından nasıl açıklandığını inceleyen matematiksel ilişkiyi modellemeyi amaçlamaktadır. Söz konusu analizde, yalnızca bir bağımsız değişkenin etkisi inceleniyorsa bu yöntem basit doğrusal regresyon; iki ya da daha fazla bağımsız değişken söz konusu olduğunda ise çoklu doğrusal regresyon olarak adlandırılmaktadır. Çoklu regresyon analizinde ise temel hedef, mevcut verilerden elde edilen örüntüler yardımıyla, bilinmeyen durumlara ilişkin tahminlerde bulunmaktır (Chatterjee ve Hadi 2015).

Değişkenler arasındaki ilişkinin yönü ve gücü ise korelasyon katsayısı ile ifade edilmektedir. Bu katsayının 0 değerine yaklaşması, iki değişken arasında ilişki bulunmadığını; +1.00 ya da -1.00 değerlerine yaklaşması ise güçlü ve yönlü bir ilişkinin varlığını göstermektedir. Pozitif korelasyon, iki değişkenin birlikte artması ya da azalması anlamına gelirken negatif korelasyon, bir değişken artarken diğersinin azalması durumunu yansıtmaktadır (Zeng ve Zhou 2001).

Gayrimenkul piyasasında çoklu regresyon modeli, fiyatı ya da kirayı etkileyen faktörlerin belirlenmesinde, bunların ağırlıklı etkilerinin sayısal olarak ifade edilmesinde ve nihayetinde piyasa değerinin kestiriminde etkili bir araç olarak kullanılmaktadır. Bu sayede, hem alana özgü değişkenlerin etkileri modellenebilmekte hem de farklı senaryolara göre değer kestirimi yapılabilmektedir.

Hedonik değerlendirme yöntemi, bir gayrimenkulün piyasa değerini belirleyen temel özelliklerin ayrı ayrı etkilerini ölçmeye yönelik istatistiki ve matematiksel bir yaklaşıma dayanmaktadır. Bu yaklaşım, gayrimenkul pazarında da geniş uygulama alanı bulmuştur ve gayrimenkulü oluşturan bileşenlerin, örneğin: büyüklük, konum, bina yaşı, kat durumu, cephe, ulaşım olanakları gibi niteliklerin her birinin toplam değer üzerindeki katkısını ayrı ayrı analiz etmektedir (Rosen 1974). Böylece gayrimenkul değeri, tekil bir unsur olarak değil, bileşenlerin bütünsel etkisinin sonucu olarak modellenmektedir.

Hedonik modelde esas alınan yaklaşım, piyasa verileri kullanılarak gayrimenkul özellikleri ile satış veya kira arasındaki ilişkinin regresyon analizi ile ortaya konulmasıdır. Bu modelleme sürecinde, bağımlı değişken olarak genellikle birim satış fiyatı (TL/m²) veya birim kira (TL/m²) kullanılmakta, bağımsız değişkenler ise gayrimenkulün fiziksel, çevresel ve yapısal nitelikleri olmaktadır. Bu sayede her bir değişkenin piyasa değeri üzerindeki marjinal etkisi sayısal olarak ifade edilebilmektedir (Tanrıvermiş 2016).

Model, özellikle konut, ofis ve ticari gayrimenkullerin değerlendirilmesinde sıklıkla tercih edilmektedir. Modelin temel varsayımı, piyasadaki benzer gayrimenkuller arasında fiyat farklılıklarının bu özelliklerden kaynaklandığıdır. Bu varsayımdan hareketle geliştirilen matematiksel modeller, farklı senaryolar altında fiyat kestirimleri yapılmasına olanak tanımaktadır (Sirmans vd. 2003).


Modelin en güçlü yönlerinden biri, değişken sayısının fazla olduğu durumlarda bile, hangi özelliklerin değeri daha fazla etkilediğini net bir şekilde ortaya koyabilmesidir. Bu durum, yatırımcılar, değerlendirme uzmanları ve politika yapıcılar açısından önemli bir karar destek aracı sunmaktadır. Ancak yöntemin geçerli sonuçlar üretebilmesi için, yeterli sayıda ve nitelikli piyasa verisine, ayrıca regresyon analizi konusunda istatistiksel

uzmanlığa ihtiyaç duyulmaktadır (Tanrıvermiş 2016). Model, konumsal ve çevresel faktörlerin ekonomik değere dönüştürülmesini sağladığı için özellikle kentleşme, çevresel kalite, ulaşım altyapısı gibi alanlardaki etkilerin analizinde de kullanılmaktadır. Bu yönüyle hem değerlendirme hem de kentsel planlama çalışmaları açısından çok boyutlu faydalar sağlamaktadır (Bourassa vd. 2007).

4.2 Makine Öğrenmesi Yöntemleri

Makine öğrenmesi, bilgisayar algoritmalarının mevcut verilerden öğrenerek tahmin ve sınıflandırma gibi görevleri otonom bir şekilde gerçekleştirebilmesini sağlayan bir bilim dalı olarak ön plana çıkmaktadır. Günümüzde veri analitiğinden model geliştirmeye kadar uzanan geniş bir uygulama yelpazesinde makine öğrenmesi tekniklerinden yoğun biçimde yararlanılmaktadır. 2023, 2024 ve 2025 yıllarında yapılan araştırmalara bakıldığında, makine öğrenmesi algoritmalarının farklı veri yapıları ve çeşitli kullanım alanlarına uyarlanacak şekilde nasıl tasarlandığı ve optimize edildiği ayrıntılı biçimde ortaya koyulmaktadır. Bu gelişmeler, makine öğrenmesinin, karmaşık veri yapılarını işleyebilme, tahmin performansını artırma ve çok boyutlu problemleri çözme kabiliyetini daha da ileriye taşıdığını göstermektedir.

Makine öğrenmesine dayalı modellerin geliştirilmesi, problemin açık biçimde tanımlanmasıyla başlamaktadır. Bu aşamada, tahmin edilmek istenen değişkenin türüne göre sınıflandırma ya da regresyon gibi uygun problem türü belirlenmektedir. Ardından modelin ihtiyaç duyduğu veri toplanmakta ve elde edilen veriler üzerinden anlamlı özniteliklerin seçimi yapılmaktadır. Devamında, eksik veya tutarsız değerlerin düzeltilmesi, verilerin uygun forma getirilmesi gibi işlemlerden oluşan veri temizleme ve ön işleme süreci uygulanmaktadır (Şekil 4.1) (Zhang 2020). Temizlenmiş veriyle birlikte probleme en uygun algoritma seçilmekte, ardından model eğitilmekte ve öğrenme süreci gerçekleştirilmektedir. Eğitilen model, daha önce kullanılmamış test verisi üzerinde değerlendirilerek başarımlar ölçütleri yardımıyla modelin performansı analiz edilmektedir (Zhang 2020). Son aşamada ise başarılı model gerçek verilerle uygulanarak pratik kullanıma sunulmaktadır (Şekil 4.1).




Şekil 4.1 Makine öğrenmesi yöntemlerinin çalışma modeli

Algoritmalar, öğrenme türlerine göre dört ana gruba ayrılmaktadır. Denetimli öğrenme yöntemleri, etiketli veriyle çalışmaktadır ve gelecekteki değerleri tahmin etmeye yarmaktadır. Denetimsiz öğrenme algoritmaları, verideki benzerlikleri ve yapıları keşfetmek için kullanılmaktadır. Pekiştirmeli öğrenme ise deneme-yanılma yoluyla öğrenme sağlayarak karar süreçlerini geliştirmektedir. Derin öğrenme ise çok katmanlı sinir ağlarıyla çalışarak daha karmaşık yapıları modelleyebilmektedir. Bu sınıflandırma, hangi algoritmanın hangi problemde daha etkili olacağını belirlemek açısından önemlidir (Şekil 4.2).

Denetimli öğrenme algoritmaları, etiketli verileri kullanarak makine öğrenmesi ile öğrenme sürecini içermekte olup sınıflandırma ve regresyon analizlerinde kullanılmaktadır. Örneğin, Doğrusal Regresyon, DT gibi yöntemler konum, bina özellikleri, kat sayısı ve bina yaşı gibi değişkenler kullanılarak ofis kira kestirimleri yapılabilmektedir. Modeller, yeni verilere dayalı tahminler yapmak için veri setindeki etiketli bilgilerle ilişki kurmayı öğrenmektedir. Örneğin, bir binanın lüks olup olmadığını

belirlemek için bina özellikleri ve fiyat aralığı gibi kriterlerden yararlanılmaktadır. Ayrıca büyük veri setleri üzerinde çalışarak pazar analizlerini ve yatırım kararlarını daha bilinçli hale getirebilmekte ve gayrimenkul sektöründe kira kestirimleri, pazar trend analizleri ve yatırım getirisi projeksiyonları bu yöntemlerle kolaylıkla yapılabilmektedir.



Şekil 4.2 Makine öğrenmesi algoritmaları

Denetimsiz öğrenme, etiketli veriye ihtiyaç duymadan veri setlerindeki gizli yapıları ve kalıpları keşfetmeyi amaçlayan bir yaklaşımdır. Bu yöntem, özellikle verilerin sınıflandırılmamış veya etiketlenmemiş olduğu durumlarda, verilerdeki gizli gruplamaları ve ilişkileri ortaya çıkarmada kullanılmaktadır. Kümeleme ve boyut indirgeme gibi tekniklerle, veriler belirli benzerliklere göre gruplandırılabilir ve bu sayede verinin altında yatan yapı daha iyi anlaşılabilir. Örneğin, ofis kiralarının benzerliklerine göre gruplandırılması, farklı bölgelerdeki kira dinamiklerini ve trendlerini belirlemek için kullanılabilir. k-ortalama veya hiyerarşik kümeleme gibi yöntemlerle, kiraların benzer olduğu bölgeler kümelenebilir ve bu kümeler üzerinden pazar analizi yapılabilir. Ayrıca, boyut indirgeme yöntemleri kullanılarak çok

boyutlu veriler daha anlaşılır hale getirilerek, veri setindeki ilişkiler daha net bir şekilde görselleştirilebilmektedir.

Pekiştirmeli öğrenme algoritmaları, karar verici birim ile çevresiyle etkileşim kurarak öğrenme sürecini nasıl öğrendiğini gözlemleyen algoritmalarından oluşmaktadır. Bu yöntemde, karar verici birim her işlem için bir ödül ya da ceza ile karşılaşmaktadır ve zamanla en fazla ödülü sağlayacak davranışları keşfetmektedir ve özellikle etkileşimli ortamlarda tercih edilmektedir çünkü klasik denetimli öğrenmenin yetersiz kaldığı sıralı karar problemlerinde etkili sonuçlar sağlamaktadır. Ayrıca Oyuncu-Eleştirmen ve Q-Öğrenme gibi algoritmalar da pekiştirmeli öğrenmenin uygulama alanlarında yaygın olarak kullanılmaktadır. Algoritmaların başarısını gösteren bu uygulamalara, bir robotun bir alan içinde yönünü bulmayı öğrenmesi veya bir yazılımın oyun oynayarak strateji oluşturması olarak örnek verilebilecektir (Mnih vd. 2015).

Derin öğrenme, insan beynindeki sinir ağlarından esinlenerek geliştirilen, çok katmanlı yapay sinir ağlarını kullanan bir makine öğrenmesi yaklaşımıdır. Özellikle büyük veriyle çalışılan alanlarda, karmaşık ilişkileri anlamada oldukça etkilidir. Görüntü tanıma için Evrişimli Sinir Ağları, metin ya da zaman serisi analizlerinde ise Tekrarlayan Sinir Ağları sıkça kullanılmaktadır (Goodfellow vd. 2016). Derin öğrenme, katmanlar arasında gerçekleşen öğrenme sayesinde, klasik algoritmaların yakalayamadığı karmaşık örüntüleri başarıyla modelleyebilmektedir. Bu nedenle günümüzde sağlık, finans, otomotiv ve birçok sektörde yapay zekâ çözümlerinin temelini oluşturmaktadır.

Makine öğrenmesi algoritmaları, çok çeşitli veri türleri ve problem alanları için de kullanılabilir. Sağlık, finans ve kamu güvenliği gibi birçok alanda kişisel verileri korumakla kalmaz, aynı zamanda büyük veri kaynaklarından elde edilen verilerin analizini de kolaylaştırmaktadır. Örneğin, yerel cihazlarda hasta verilerinin işlenmesiyle, yalnızca anonimleştirilmiş model parametreleri sunucuya gönderilerek verilerin gizliliği korunmaktadır. Veri gizliliği kurallarına uymak ve kullanıcıların güvenini artırmak için bu yöntem büyük avantaj sağlamaktadır. Algoritmalar, günümüzde yalnızca akademik araştırmalarda değil, finans ve kamu güvenliği gibi kritik sektörlerde de etkin biçimde kullanılmaktadır. Finansal uygulamalarda müşteri verilerinin korunması ve

dolandırıcılığın tespit edilmesi gibi güvenlik odaklı görevlerde bu algoritmalarından yararlanılmaktadır. Benzer şekilde, kamu güvenliği alanında suç tahminleri ve analizlerinde veri gizliliğini koruyarak daha güvenli ve etkili karar destek sistemleri geliştirilmektedir. Makine öğrenmesi, gelecekte de büyük veri analizi ve kişisel veri koruma konularında önemli bir rol üstlenmeye devam edecektir. Nitekim literatürde, ofis kira değerlemesine yönelik geliştirilen pek çok model arasında LR, DT, RF, k-NN, SVM, FRF, XGBoost ve ANN gibi makine öğrenmesi yöntemlerinin öne çıktığı görülmektedir (Zhao vd. 2022).


4.2.1 Çoklu Doğrusal Regresyon

Gauss (1821), Doğrusal Regresyonun temelini oluşturan En Küçük Kareler Yöntemi'ni geliştirmiştir. Bu yöntem, Doğrusal Regresyon analizlerinde hata kareler toplamını minimize etmek için yaygın olarak kullanılmaktadır. Galton (1886), “regresyon” terimini ilk kullanan araştırmacılardan biri olup iki değişken arasındaki ilişkiyi incelerken sonuçların genellikle ortalamaya yakınlaştığını fark etmiştir ve bu gözlemi Doğrusal Regresyon yönteminin temellerinden biri olarak kabul edilmiştir. Draper ve Smith (1998) ise uygulamalı regresyon analizine dair kapsamlı bilgiler sunarak, bu yöntemin pratikte nasıl kullanılacağını ve istatistiksel değerlendirmelerin nasıl yapılacağını detaylandırmıştır. Doğrusal Regresyon, özellikle makine öğrenmesi içinde sıkça başvurulan denetimli öğrenme tekniklerinden biri olup; konum, bina yaşı veya alan büyüklüğü gibi bağımsız değişkenlerin, ofis kirası gibi bir sonuç değişkeni üzerindeki etkilerini anlamaya yönelik kullanılmaktadır. Hem istatistiksel modelleme hem de tahmine dayalı analizlerde geniş bir uygulama yelpazesi bulunmaktadır ve formül aşağıda yer almaktadır. Genellikle β katsayıları en küçük kareler yöntemi kullanılarak tahmin edilmektedir. Basit doğrusal regresyon modeli Eşitlik 4.1’de gösterilmektedir.

$$Y = \beta_0 + \beta_1 X_1 + \epsilon \quad (4.1)$$

Doğrusal Regresyon analizine ilişkin temel bir görselde yatay ekseninde bağımsız değişken (X), dikey ekseninde ise bağımlı değişken (Y) yer almakta olup kırmızı noktalar gözlem değerlerini, mavi çizgi ise bu verilere en iyi uyan regresyon doğrusunu temsil etmektedir.

Regresyon doğrusu, veri noktaları arasındaki ilişkiyi özetleyerek, X değişkenindeki bir birimlik değişimin Y üzerindeki etkisini tahmin etmeye olanak tanımaktadır. Model, bağımlı değişkenin davranışını açıklamak ve geleceğe yönelik tahminlerde bulunmak amacıyla kullanılmaktadır (Şekil 4.3).




Şekil 4.3 Bağımsız ve bağımlı değişken arasındaki doğrusal regresyon ilişkisi

Modelin matematiksel olarak hesaplanmasının ve yorumlanmasının kolay olması, büyük veri setleri ile çalışırken diğer karmaşık modellere kıyasla daha az işlem gücü gerektirmesi ve çeşitli uygulama alanlarında esnek bir şekilde kullanılabilir olması avantajlar olarak karşımıza çıkarken karmaşık ve doğrusal olmayan ilişkilerin olduğu durumlarda performansının düşmesi, çok sayıda bağımsız değişken kullanıldığında aşırı uyum göstermesi, ilişkileri yakalamakta zayıf kalması ve tahmin doğruluğunun düşmesi dezavantajlar olarak söylenebilecektir (Lütkepohl 2005).

Doğrusal Regresyon yöntemi; ekonomi, mühendislik, sağlık ve sosyal bilimler başta olmak üzere çok sayıda alanda yaygın olarak kullanılmaktadır ve gayrimenkulün kira ya da satış değerinin belirlenmesi, hisse senedi fiyatlarının tahmin edilmesi, faiz oranları ve makroekonomik göstergelerin tahmini gibi finansal uygulamalarda tercih edilmektedir. Ayrıca, sağlık alanında hastalık riskinin değerlendirilmesi, tedaviye verilen yanıtın analiz

edilmesi ya da klinik bulgulara dayalı tahminlerin yapılmasında da önemli bir araç olarak kullanılmaktadır.

MLR, birden fazla açıklayıcı değişkenin tek bir hedef değişken üzerindeki etkilerini eş zamanlı olarak değerlendiren klasik bir istatistiksel modelleme yaklaşımıdır (Şekil 4.4). Bu teknik, özellikle değişkenler arasındaki doğrusal ilişkilerin yapısını ortaya koymak ve bu doğrultuda tahminler geliştirmek amacıyla kullanılmaktadır. MLR, bağımlı değişkenin değerini öngörmek için doğrusal formda bir denklem kurarak ve her bir bağımsız değişkene ait katsayılar aracılığıyla bu değişkenlerin etkilerini nicel olarak ifade etmektedir. Ancak, modelde yer alan bağımsız değişkenler arasında yüksek düzeyde çoklu bağlantı bulunması durumunda, katsayıların anlamlılığı azalabilmekte ve tahmin performansı düşebilmektedir. Ayrıca, bu yöntem yalnızca doğrusal yapıları modelleyebildiğinden, karmaşık veya doğrusal olmayan ilişkiler karşısında yetersiz kalabilmektedir. Bu bağlamda, uygun modelin seçimi, veri yapısına ve değişkenler arası ilişkinin doğasına bağlı olarak tahmin doğruluğunu doğrudan etkilemektedir.



Şekil 4.4 Çoklu Doğrusal Regresyon modelinde uyum düzlemi

MLR modelinin genel yapısı eşitlik (4.2)'deki gibi verilmektedir:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \epsilon \quad (4.2)$$

MLR modelinde, Y hedef değişkeni temsil ederken, β_0 sabit katsayısı, $\beta_1, \beta_2, \dots, \beta_p$ parametreleri açıklayıcı değişkenlerin etkisini, $X_1, X_2, \dots, X_p$ ise bağımsız değişkenleri ifade etmektedir.

Modelde yer alan ϵ rasgele hata terimini göstermektedir. MLR, açıklayıcı değişkenler ile hedef değişken arasında doğrusal bir bağ kurulabileceğini varsaymaktadır. Ayrıca, modelin sağlıklı işlemesi açısından hata terimlerinin birbirinden bağımsız olması ve normal dağılıma sahip olması beklenmektedir. Bu çerçevede, modelin istatistiksel geçerliliğini sağlayabilmesi için bazı temel varsayımların yerine getirilmesi zorunludur.

MLR analizinde modelin geçerliliğini koruyabilmesi için birtakım temel varsayımların sağlanması gerekmektedir. İlk olarak, bağımlı değişken ile bağımsız değişkenler arasında doğrusal bir ilişkinin var olduğu kabul edilmektedir. İkinci olarak, hata terimlerinin ortalamasının sıfır ve varyanslarının sabit olması koşulunun sağlanması beklenmektedir. Ayrıca, hata terimlerinin birbirinden bağımsız olması ve ardışık bağımlılık göstermemesi gereklidir. Bu varsayımlar dışında, hata terimlerinin normal dağıldığı da varsayılmakta, bu sayede parametrik testlerin uygulanabilirliği sağlanmaktadır. Son olarak, bağımsız değişkenler arasında yüksek dereceli doğrusal ilişkinin bulunmaması, yani çoklu doğrusal bağlantının düşük olması beklenmektedir. Bu varsayımlar, modelin tutarlılığı, yorumlanabilirliği ve tahmin gücü açısından kritik öneme sahiptir.

4.2.2 Ridge Regresyonu

Doğrusal modellerin düzenlenmesi, tahmin performansının artırılması ve aşırı uyumun önlenmesi amacıyla, RR ve LR teknikleri makine öğrenmesi uygulamalarında yaygın şekilde kullanılmaktadır. Her iki yöntem de modelin maliyet fonksiyonuna bir ceza terimi

ekleyerek katsayıları kısıtlamakta, ancak bu cezayı uygulama biçimleri farklılık göstermektedir.

RR, çoklu doğrusal bağlantı sorununu azaltmak ve tahmin doğruluğunu artırmak amacıyla, regresyon katsayılarının varyansını küçültmek üzere maliyet fonksiyonuna, belirli bir ceza bileşeni ekleyerek amaç fonksiyonunu eşitlik (4.3)'deki biçimde tanımlamaktadır:

$$\beta_{\text{ridge}} = \operatorname{argmin} \left\{ \sum_{i=1}^N \left(y_i - \beta_0 - \sum_{j=1}^P \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^P \beta_j^2 \right\} \quad (4.3)$$

Burada:

y_i , bağımlı değişkenin gözlenen değeri,

$$\hat{y}_i = \beta_0 + \sum_{j=1}^P \beta_j x_{ij} : \text{tahmin edilen değeri,}$$

N: gözlem sayısı,

p: bağımsız değişken sayısı,

λ : ceza katsayısı,

$\lambda \sum_{j=1}^P \beta_j^2$: L2 ceza terimi olup modelin katsayılarının büyüklüğünü sınırlayarak aşırı uyumu önlemeye yardımcı olmaktadır

Maliyet fonksiyonu yalnızca hata terimlerinden oluşurken, RR buna ek olarak L2 düzenlileştirme terimi içermektedir. L2 düzenlemesi olarak da bilinen bu yöntem, aşırı uyumu önlemek amacıyla hata kareler toplamına katsayıların karelerinin cezasını eklemektedir.

Özellikle çoklu doğrusallığın mevcut olduğu veri setlerinde RR, klasik en küçük kareler yönteminin bir modifikasyonu olarak hata kareler ortalamasını düzenlileştirme terimiyle değiştirmekte ve daha istikrarlı tahminler üretmektedir. Birden çok bağımsız değişkenin bulunduğu durumlarda, herhangi bir değişkeni model dışı bırakmadan tahmin doğruluğunu artırmakta, veriler arasında yüksek korelasyon olduğunda tüm değişkenleri kullanarak güvenilir modeller oluşturmaktadır. (Anonymous 2024e).

4.2.3 Lasso Regresyonu

LR, L1 düzenlemesi olarak bilinen ve modelin hata karelerini en aza indirirken aynı zamanda değişken seçimi yapan bir tekniktir. RR'den farklı olarak, katsayıların mutlak değerlerine ceza uygulamakta ve önemsiz değişkenlerin katsayılarını sıfıra eşitleyerek daha sade ve yorumlanabilir modeller oluşturmaktadır.

LR, RR'de olduğu gibi model karmaşıklığını cezalandırmakta, aynı zamanda değişken seçimi de yapmaktadır. En küçük kareler yöntemine alternatif bir tahmin yaklaşımı olan LR, özellikle çoklu doğrusal bağlantı ve aşırı öğrenme sorunlarının önlenmesinde kullanılmaktadır (Anonymous 2024e). LR, modelin bazı katsayılarını sıfıra indirerek değişken seçimini mümkün kılan ve parametrelerin mutlak değerlerinin toplamına dayalı ceza bileşeni içeren yöntem olup bu yöntemle ait amaç fonksiyonu eşitlik (4.4)'te verilmiştir:

$$\beta_{\text{lasso}} = \operatorname{argmin} \left\{ \sum_{i=1}^N \left(y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^p |\beta_j| \right\} \quad (4.4)$$

Bütün değişkenlerin modelde mutlaka yer alması gerektiği durumlarda, RR daha avantajlı olmaktadır. LR ise RR'ye niteliksel açıdan benzer bir davranış sergilemekte, λ parametresi arttıkça varyans azalmakta, buna karşılık yanlılık artmaktadır. Ancak LR, belirli değişkenlerin katsayılarını sıfıra indirerek bir değişken alt kümesi oluşturabilmekte ve böylece daha basit, daha yorumlanabilir modeller üretmesi bakımından RR'ye kıyasla önemli bir üstünlük sağlamaktadır (Anonymous 2024e).

4.2.4 Karar Ağaçları

DT, denetimli öğrenme kapsamında sıkça tercih edilen algoritmalarından biri olup yapısı itibarıyla hem sınıflandırma hem de regresyon görevlerinde kullanılabilir. Ağaç temelli bu yöntem, veri setindeki örüntülerin hiyerarşik ve sezgisel olarak yapılandırılmasına olanak tanıyarak, modelin görsellenebilir ve yorumlanabilir bir biçimde sunulmasını sağlamaktadır. DT, veriyi hiyerarşik bir yapı içerisinde bölerek her düğüm noktasında belirli bir karar almakta ve nihayetinde yaprak düğümlerde sınıflandırma ya da tahmin sonuçlarına ulaşmaktadır (Breiman vd. 1984).


DT, kök düğüm, dallar ve yaprak düğümlerinden oluşan hiyerarşik bir yapı sergilemektedir. İlk ayırım, kök düğümde gerçekleştirilmekte ve bu ayırım, veri setindeki en etkili değişkene dayanarak yapılmaktadır. Her bir ayırım sonucunda veri, alt düğümlere yönlendirilmekte ve nihayetinde yaprak düğümlerde sınıf etiketlerine veya tahmin değerlerine ulaşılmaktadır (Şekil 4.5).

Bölünme noktalarının belirlenmesinde bilgi kazancı, Gini indeksi ve varyans azalması gibi kriterler kullanılmakta olup; bu ölçütler, her ayırımın veri seti üzerindeki belirsizliği ne ölçüde azalttığını değerlendirmek amacıyla uygulanmaktadır (Breiman vd. 1984).

Ağaç öğrenme yöntemi kullanılarak en iyi bölmeyi gerçekleştirmek amacıyla bir amaç fonksiyonu (f) tanımlanmaktadır. Veri bölme sürecinde, (D_p), bölmeyi belirleyen özelliği, (D_j), j . düğüme ait veri setlerini, I , saf olmama ölçütünü, N_p toplam eğitim verisini ve N_j ise j . düğümdeki örnek sayısını göstermektedir. Böylece, en iyi bölme stratejisi, düğümlerdeki saflaştırmayı maksimize edecek şekilde optimize edilmektedir. (Raschka vd. 2022).

Basit ve anlaşılır olması, görsel yapılardan oluşması, kolayca yorumlanabilir, kategorik ve sürekli veri türlerinde etkili olması ve verilerin önceden ölçeklenmesine gerek olmaması modelin sağladığı avantajlar olarak ön plana çıkarken çok fazla dallara ayrıldığında aşırı uyum göstermesi ve eğitim verisine çok iyi uyum sağlamasına rağmen

test veri setinde düşük performans göstermesi dezavantajları olmaktadır (Hastie vd. 2009).



Şekil 4.5 Karar Ağaçları modelinin genel yapısı

İlgili modelleme yaklaşımının matematiksel ifadesi eşitlik (4.5)'te sunulmakta olup yöntemin yapısal özelliklerini ve temel bileşenlerini temsil etmektedir.

$$IG(D_p, f) = I(D_p) - \sum_{j=1}^m \frac{N_j}{N_p} I(D_j) \quad (4.5)$$

Gini indeksi, bir düğümdeki gözlem gruplarının homojenliğini değerlendiren bir saflık ölçütüdür. Düğümdeki sınıf dağılımlarının çeşitliliğini dikkate alarak bölmenin ne derece etkili olduğunu belirlemede kullanılmakta olup ölçüte ilişkin hesaplama formülü eşitlik (4.6)'da verilmiştir.

$$G = 1 - \sum_{i=1}^k p_i^2 \quad (4.6)$$

Bu ifadede, p_i : sınıf i 'nin olasılığıdır ve Gini indeksinin değeri sıfıra yaklaştıkça düğümdeki sınıflar arasındaki homojenlik artmakta, bu da daha yüksek bir saflık düzeyine işaret etmektedir. Entropi, bilgi kazancının hesaplanmasında başvurulmuş temel ölçütlerden biridir ve ilgili formül eşitlik (4.7)'de verilmiştir:

$$H(S) = - \sum_{i=1}^k p_i \log_2 p_i \quad (4.7)$$


Burada $H(S)$, örneklerin entropisini, k , toplam sınıf sayısını ve p_i : i . sınıfa ait gözlemlerin olasılığını temsil etmektedir. Entropi, düğümdeki belirsizliğin bir göstergesi olup değeri azaldıkça düğümdeki saflık düzeyi artmakta ve sınıflar arasındaki ayırım daha belirgin hâle gelmektedir.

4.2.5 Rasgele Orman

RF, çok sayıda karar ağacının rasgelelik temelli bir topluluk yöntemi çerçevesinde bir araya getirilmesiyle oluşturulan güçlü bir makine öğrenmesi yaklaşımıdır. Bu yöntemde, her bir ağaç, eğitim verisinin farklı bir alt kümesiyle bağımsız olarak eğitilmekte ve elde edilen tahminler toplu biçimde değerlendirilerek sonuç üretilmektedir (Breiman 2001). Modelin temel amacı, karar ağaçları arasında çeşitliliği artırmak ve bireysel ağaçların önyargılarını azaltarak genel doğruluk oranını yükseltmektir. Bu yapı sayesinde RF, özellikle tek bir karar ağacında görülebilecek aşırı öğrenme riskini minimize ederken, genellenebilirliği yüksek ve kararlı tahminler elde edilmesini sağlamaktadır.

RF algoritmasının sınıflandırma süreci Şekil 4.6'da ortaya koyulmaktadır. Üst kısımda yer alan “Gözlem” bileşeni, sınıflandırılması hedeflenen yeni bir veri örneğini temsil etmektedir. Bu gözlem, her biri farklı veri alt kümeleri ve özellik setleri kullanılarak oluşturulmuş çok sayıda karar ağacına (Ağaç 1, Ağaç 2, ..., Ağaç N) yönlendirilmektedir. Her bir ağaç, kendine özgü yapısı doğrultusunda veri üzerinde işlem yapmakta ve bağımsız bir sınıf tahmini üretmektedir. Ağaç yapılarında yer alan yeşil renkli düğümler karar noktalarını, turuncu renkli düğümler ise sınıflandırma sonucunu temsil eden yaprak düğümleri ifade etmektedir. Örneğin, Ağaç 1 ve Ağaç 2 ilgili gözlemi “Sınıf A” olarak

sınıflandırırken, Ağaç N söz konusu gözlemi “Sınıf B” olarak değerlendirmektedir. Bu tahminler, alt bölümde yer alan “Çoğunluk Oyu” kutusunda bir araya getirilmekte ve nihai karar çoğunluk ilkesine göre verilmektedir. Bu süreç sonucunda en fazla önerilen sınıf olan “Sınıf A”, modelin nihai çıktısı olarak belirlenmektedir. Bu yöntem, bireysel ağaçların önyargılarını azaltarak daha dengeli ve genellenebilir bir sınıflandırma performansı elde edilmesini sağlamaktadır (Bahrambanan vd. 2025).



Şekil 4.6 Rasgele Orman modelinin genel yapısı (Bahrambanan vd. 2025)

Modelde, her bir düğümde bölünme işlemi gerçekleştirilirken, tüm özellikler arasından rasgele seçilen bir alt küme üzerinden en iyi bölünme noktası belirlenmektedir. Bu yöntem, modelin içsel çeşitliliğini artırarak aynı zamanda esnek ve sağlam tahminler üretmesine olanak tanımaktadır. Son aşamada, tüm ağaçlardan elde edilen tahminler birleştirilmekte ve topluluk yapısının sağladığı avantajla nihai tahmin değeri elde edilmektedir. RF algoritmasında nihai tahmin değeri, her bir karar ağacının bağımsız

tahminlerinin ortalaması alınarak hesaplanmaktadır. Bu durum matematiksel olarak aşağıda eşitlik (4.8)'de ifade edilmektedir:

$$\hat{y} = \frac{1}{n} \sum_{i=1}^n f_i(x) \quad (4.8)$$

Burada, $f_i(x)$, i. karar ağacının ilgili gözlem x için yaptığı tahminini; n , topluluk içindeki toplam ağaç sayısını; $\hat{y}$ ise tüm ağaçların tahminlerinin ortalaması alınarak elde edilen nihai tahmin değerini temsil etmektedir.

RF modeli, çok sayıda öz niteliğin yer aldığı karmaşık veri yapılarında özellikle etkili sonuçlar vermektedir. Modelin varyansını düşürmek amacıyla, birbirinden bağımsız olarak oluşturulan çok sayıda tahmin sonucunun ortalamasının alınması, istatistiksel açıdan güvenilirliği artıran etkili bir strateji olarak değerlendirilmektedir. Bu yaklaşım, özellikle tahminlerdeki rasgele sapmaları dengeleyerek daha istikrarlı sonuçlar elde edilmesine katkı sağlamaktadır. Bu doğrultuda, farklı veri alt kümeleri üzerinde n adet bağımsız karar ağacı eğitilmekte ve her bir ağaçtan elde edilen tahmin sonuçları, f_i , i. ağaç şeklinde ifade edilmektedir. Elde edilen tüm bireysel tahminler birleştirilerek ortalama alınmakta ve böylece daha kararlı, düşük varyanslı ve genellenebilir bir nihai tahmin elde edilmektedir. Bu durumda konum, bina yaşı, alan ve kat sayısı gibi çok sayıda farklı değişkenin bulunduğu pazarlarda, RF etkili sonuçlar vermektedir (Cutler vd. 2012).

Hangi bağımsız değişkenlerin hedef değişken üzerindeki etkisinin daha baskın olduğunun belirlenebilmesi, aşırı uyumun birden çok karar ağacı ortalamasıyla azaltılması ve büyük veri setlerinde karmaşık yapıların etkin biçimde modellenmesi gibi avantajlara sahiptir. Ancak modelin, birden fazla karar ağacı oluşturulması gerektirmesi nedeniyle hesaplama maliyetinin yüksek olması ve tek bir karar ağacının sağladığı şeffaflığa kıyasla yorumlanabilirliğinin düşük olması gibi sınırlılıkları da bulunmaktadır.

4.2.6 k-En Yakın Komşu

k-NN, denetimli öğrenme sınıflandırma problemlerinde sıklıkla tercih edilen, örnek tabanlı ve parametrik olmayan bir yöntemdir. Bu yöntem, eğitim aşamasında herhangi bir

parametre tahmini veya model inşası gerçekleştirmemekte; bunun yerine tüm eğitim verilerini hafızada saklayarak, yeni bir veri örneği ile karşılaştığında, belirlenen (k) sayısındaki en yakın komşuya dayanarak karar vermektedir. Sınıflandırma problemlerinde, yeni veri noktasına komşuları arasında en sık rastlanan sınıf etiketi atanmaktadır.


Regresyon problemlerinde ise, komşu veri noktalarının değerlerinin aritmetik ortalaması alınarak tahmin gerçekleştirilmektedir. 2025 yılında yapılan çalışmalarda, k -NN algoritmasının küçük veri setlerinde oldukça başarılı sonuçlar verdiği, ancak özellikle yüksek boyutlu verilerde hesaplama maliyetinin ciddi şekilde arttığı vurgulanmaktadır (Daguplo 2025; Shamshad vd. 2025). Bu nedenle, son dönem araştırmalarında k -NN'nin boyut indirgeme teknikleri ya da hibrit algoritmalarla birlikte uygulanması önerilmekte ve algoritmanın enerji verimliliği, hassasiyet ve doğruluk gibi ölçütler açısından geliştirildiği görülmektedir.

k -NN algoritmasının temel sınıflandırma ilkesi Şekil 4.7'de açıklanmaktadır. Görselde, beyaz üçgen ile gösterilen “Yeni Üye”, sınıfı bilinmeyen bir gözlem örneğini temsil etmektedir. Bu gözlem, eğitim veri kümesinde yer alan sınıfı bilinen örneklerle olan mesafesi (örneğin Öklid uzaklığı) üzerinden değerlendirilmekte ve en yakın beş komşusu belirlenmektedir. Kesikli çember, en yakın komşuların bulunduğu mesafeyi temsil etmektedir.

Üçgenler farklı sınıflara ait örnekleri simgelemekte olup turuncu ve yeşil renklerle ayrılmıştır. En yakın beş komşunun üçü turuncu, ikisi ise yeşil sınıfa ait olduğundan, k -NN algoritması çoğunluk kuralına dayanarak yeni üyeyi turuncu sınıfa atamaktadır. Bu durum, k -NN'nin parametrik olmayan yapısı ve örnek tabanlı öğrenme yaklaşımıyla nasıl çalıştığını açık biçimde ortaya koymaktadır (Şekil 4.7).

Esnek, basit ve kolay uygulanabilir olması, eğitim süreci gerektirmeden; varsayımda bulunmadan verilerin doğrudan kullanılabilmesi modelin avantajları olurken; tüm veri setini hafızada tutması gerektiği için büyük veri setlerinde yavaş çalışması ve bellek sorunlarına yol açabilmesi, uygun bir (k) değeri seçilmediği takdirde uzak komşuların

etkisiyle performansının olumsuz etkilenebilmesi ve özellikler arasında büyük farklılıklar varsa, ölçeklendirme yapılmasının zorunlu olması dezavantajları olmaktadır.



Şekil 4.7 k-NN tahmin gösterimi


Yöntem, veri kümesindeki her bir gözlemi, diğer gözlemlere olan uzaklıklarına göre sıralayarak benzerlik temelli bir değerlendirme gerçekleştirmektedir. Gözlemler arası mesafelerin belirlenmesinde genellikle Öklid, Manhattan veya Minkowski gibi farklı mesafe ölçüm yöntemleri kullanılmakta olup seçilen uzaklık metriği modelin duyarlılığını doğrudan etkileyebilmektedir (Mukherjee 2021).

Öklid uzaklığı, iki nokta arasındaki doğrusal uzaklığı hesaplayan ve en yaygın kullanılan mesafe ölçütlerinden biridir. Bu metrik, yeni bir gözlemin hangi sınıfa ait olacağını ya da hangi değere yakınsamasının gerektiğini belirlemede temel bir araç olarak kullanılmaktadır. k-NN algoritmasında (k) parametresi, en yakın kaç komşunun dikkate alınacağını göstermektedir ve Modelin performansını en üst düzeye çıkarmak amacıyla, genellikle çapraz doğrulama yöntemiyle en uygun (k) değeri belirlenmektedir.

(k=1) olduğunda, en yakın komşunun sınıfına göre karar verilirken; (k>1) olduğunda ise en yakın komşuların sınıfına göre çoğunluk oyu ile sınıflandırma yapılmaktadır (Mukherjee 2021). İki vektör arasındaki Öklid uzaklığı eşitlik (4.9)'da ifade edilmektedir:

$$D(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.9)$$


$x = (x_1, x_2, \dots, x_n)$ ve $y = (y_1, y_2, \dots, y_n)$, n boyutlu iki farklı nokta olup x_i ve y_i , sırasıyla x ve y noktalarının, i . koordinatlarını göstermektedir. n ise boyut sayısını ifade etmektedir (Şekil 4.8).



Şekil 4.8 Öklid uzaklığı

Manhattan uzaklığı, iki veri noktası arasındaki her bir boyuttaki koordinat farklarının mutlak değerlerinin toplanmasıyla elde edilen bir mesafe ölçüsüdür (Şekil 4.9). Özellikle kategorik ya da ızgara tabanlı veri yapılarında etkili sonuçlar vermesi nedeniyle tercih edilmektedir. Bu mesafe ölçütüne ilişkin formül eşitlik (4.10)'da sunulmaktadır.

$$D(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (4.10)$$




Şekil 4.9 Manhattan uzaklığı

Öklid ve Manhattan uzaklığının genelleştirilmesi Minkowski uzaklığı oluşturmaktadır ve iki nokta arasındaki uzaklığı bulmak için x ve y eksenleri arasındaki koordinat farklarının toplamının birinci veya üçüncü derece kuvveti kullanılmaktadır. Bu durumda, $p=1$ olduğunda işlemler yapılır ve Minkowski uzaklığı Manhattan uzaklığına eşittir. Minkowski uzaklığı, $p=2$ olduğunda Öklid uzaklığına eşittir (Mukherjee 2021).

Minkowski uzaklığı algoritması aşağıdaki eşitlik (4.11)'de gösterilmektedir (Şekil 4.10):

$$D(x, y) = (\sum_{i=1}^n |x_i - y_i|^p)^{\frac{1}{p}} \quad (4.11)$$

Burada p uzaklık metriğini belirleyen derecesel parametreyi ifade etmektedir.



Şekil 4.10 Minkowski uzaklığı


4.2.7 Destek Vektör Makinesi

SVM hem doğrusal hem de doğrusal olmayan veri kümelerinde sınıflandırma ve regresyon problemlerine çözüm üretmek amacıyla geliştirilmiş etkili bir denetimli öğrenme yöntemidir. Teorik altyapısı ilk olarak 1963 yılında Vladimir Vapnik ve Alexey Chervonenkis tarafından geliştirilmiş olan bu yöntem, özellikle doğrusal olarak ayrılabilen veri yapılarında üstün sınıflandırma başarımıyla öne çıkmaktadır.

SVM, verileri en iyi şekilde ayıran optimal bir hiper düzlemi bulmayı amaçlamakta ve sınıflar arasındaki marjı maksimize etmektedir. Doğrusal olmayan veri kümelerinde ise, veriler uygun çekirdek fonksiyonları yardımıyla veri noktalarını daha yüksek boyutlu bir özellik uzayına dönüştürerek, bu uzayda doğrusal bir ayırım düzlemi elde edilmektedir. Bu sayede, karmaşık sınıf sınırlarının bulunduğu durumlarda dahi model, etkili ve genellenebilir sınıflandırmalar gerçekleştirebilmektedir (Cortes ve Vapnik 1995). Hiper

düzlemi belirleyen ve modelin karar sınırlarını oluşturan veri noktaları ise destek vektörleri olarak adlandırılmaktadır (Burges 1998).

Veriler iki kategoriye ayrılmıştır ve SVM algoritması kullanılarak sınıflandırılmaktadır. Sınıflandırma problemlerinin temel amacı, gelecekteki gözlemlerin hangi sınıfa ait olacağına karar vermektir. Bu amaca ulaşmak için sınıfları birbirinden ayıran bir doğrusal hiper düzlem çizilmektedir. Hiper düzlemin iki tarafında kalan yeşil alan, marjın olarak adlandırılmakta ve bu alanın genişliği arttıkça sınıflar arasındaki ayrım daha belirgin hale gelmektedir (Cortes ve Vapnik 1995). Bu bağlamda SVM, marjın genişliğini maksimize edecek şekilde hiper düzlemi belirlemeye çalışmaktadır. Hiper düzlem $w \cdot x + b = 0$ şeklinde tanımlanmakta olup karar düzleminin iki yanında yer alan ve $w \cdot x + b = \pm 1$ ile ifade edilen doğrular arasında kalan alan marjın olarak adlandırılmaktadır. Bu marjın alanının genişliği arttıkça, sınıflar arasındaki ayrım daha da netleşmekte ve modelin genelleme kabiliyeti yükselmektedir (Şekil 4.11) (Bansal vd. 2022).



Şekil 4.11 SVM algoritmasında hiper düzlemin ve marjın alanının görsel gösterimi

SVM'nin matematiksel optimizasyon problemi, aşağıda eşitlik (4.12)'deki gibi ifade edilmektedir:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \text{ koşuluyla } y_i(w \cdot x_i + b) \geq 1, \quad \forall i \quad (4.12)$$

Burada y , sınıf etiketini ve $\|w\| = \sqrt{\omega_1^2 + \omega_2^2 + \dots + \omega_n^2}$ ifadesi hiper düzlemin normunu, yani ağırlık vektörü'nün öklidyen uzunluğunu tanımlamaktadır. Bu değerin minimize edilmesi, marjinin maksimize edilmesini sağlamaktadır. Bu nedenle, SVM'ler karar sınırının netliğini artırmakta ve genellemeyi iyileştirmektedir (Cortes ve Vapnik 1995).

Modelin karar fonksiyonu, yeni bir veri noktası x için hesaplanan $f(x) = w \cdot x + b$ ifadesinin işaretine göre sınıf ataması yapmaktadır. Bu değer pozitifse bir sınıfa, negatifse diğer sınıfa ait olduğu kabul edilmekte olup sifıra yakın değerler ise karar sınırına yakın veri noktalarını temsil etmektedir. SVM bu özelliği sayesinde karışık ve ayırımı zor verilerde dahi etkili sınıflandırma yapabilmektedir. Ayrıca, SVM doğrusal olmayan veri yapıları için de çekirdek fonksiyonları aracılığıyla veriyi daha yüksek boyutlu uzaylara dönüştürerek doğrusal ayırımı mümkün kılmaktadır. Bu yönüyle, görüntü işleme, metin madenciliği, biyoinformatik ve finansal tahmin gibi alanlarda yaygın olarak kullanılmaktadır (Bansal vd. 2022).

Modelin yüksek boyutlu veri setlerinde etkili şekilde çalışabilmesi, karar sınırını maksimum marjla belirleyen hiper düzlemi oluşturması ve çekirdek fonksiyonları sayesinde doğrusal olmayan veri yapılarında dahi başarılı sonuçlar üretebilmesi önemli avantajlarından. Öte yandan, büyük hacimli veri setlerinde eğitimin uzun sürebilmesi, hiperparametrelerin dikkatli biçimde seçilmesi gerekliliği ve bu parametrelerin modelin genel performansı üzerindeki belirleyici etkisi ise yöntemin sınırlılıkları arasında yer almaktadır (Şen vd. 2025).

Doğrusal Çekirdekli Destek Vektör Makineleri (Linear Support Vector Machine, Lineer-SVM) sınıflandırma ve regresyon problemleri için kullanılan makine öğrenmesinde temel bir algoritmadır. Veriler doğrusal olarak ayrıldığında etkili sonuçlar sunarak, iki sınıfı

ayırarak bir düzlem bulmak için iki sınıf arasındaki en geniş mesafeyi sağlamaktadır. Özellikle yüksek boyutlu ve doğrusal olarak ayrılabilir veri setleri için uygundur. Doğrusal olarak ayrılabilir veri setlerinde yüksek performans sunması, yumuşak marjin ile doğrusal olarak ayrılamayan veri setlerinde esneklik sağlaması ve aşırı öğrenme riskini azaltması modelin avantajları olurken; veriler doğrusal olarak ayrılabilir değilse, performansı sınırlı kalabilmesi, sınıflar arasında karmaşık karar sınırları oluşturamaması dezavantajları arasında yer almaktadır.

$x \rightarrow \Phi(x)$ dönüşümünün yapılmasıyla ayırıcı düzlem $f(x) = w \cdot \Phi(x) + b = 0$ şekline gelecektir. İki boyutlu uzay ifadelerinde, $\langle x_i, x_j \rangle$ skaler çarpımları yerine, çok boyutlu uzay iç çarpımları $\langle \Phi_i, \Phi_j \rangle$ kullanılmaktadır. Bu durumda $\langle \Phi_i, \Phi_j \rangle$ çarpımı yerine, $K(X_1, X_2) = \Phi(X_1) \cdot \Phi(X_2) = \Phi(X_1)^T \Phi(X_2) = \langle \Phi(X_1), \Phi(X_2) \rangle$ olarak bilinen K fonksiyonu kullanılabilirse, çok büyük veri miktarları için çok büyük işlem yapılarak hesaplanabilecek olan $\langle \Phi(X_1), \Phi(X_2) \rangle$ iç çarpımları yerine $K(X_1, X_2)$ ifadesi kullanılarak bu hesaplamalar çok daha az zaman harcayarak gerçekleştirilecektir. Bu durumda K fonksiyonu bir çekirdek adını alarak; $\langle \Phi(X_1), \Phi(X_2) \rangle$ ifadesi yerine K'nın kullanılması ise çekirdek seçimi olarak isimlendirilmektedir (Güran vd. 2014). Aşağıda, K çekirdek fonksiyonu için kullanılabilecek doğrusal ve radyal çekirdek hakkında bilgi verilmektedir:

$$\text{Radyal çekirdek formülü: } K(x, y) = \exp(-\gamma ||x - y||^2) \quad (4.13)$$

$$\text{Doğrusal çekirdek formülü: } K(x, y) = x^T y + c \quad (4.14)$$

Burada $\exp$ e tabanlı üstel fonksiyondur ve γ veri setine göre ayarlanan pozitif bir parametredir.

Radyal Tabanlı Çekirdekli Destek Vektör Makineleri (Radial Basis Function Support Vector Machine, RBF-SVM), doğrusal olarak ayrılmayan veri kümelerinde sınıflandırma yapmak amacıyla geliştirilen etkili bir makine öğrenmesi yöntemidir. Bu yöntemde, veri noktaları çekirdek fonksiyonu kullanılarak daha yüksek boyutlu bir özellik uzayına

yansıtılmakta; böylece doğrusal olarak ayrılması güç olan veriler için sınıflandırma mümkün hâle gelmektedir. SVM, farklı sınıflara ait örnekleri birbirinden en geniş marjinle ayıran en uygun hiper düzlemi belirlemeyi hedefleyen bir algoritma mantığına dayanmaktadır.

Verilerin daha doğru ve genellenebilir bir şekilde sınıflandırılmasını bu yaklaşımla sağlanabilmektedir. Ancak, doğrusal olmayan veri kümelerinde sınıfların düz bir hiper düzlemle ayrılması mümkün olamayabilmektedir. Bu gibi durumlarda, çekirdek fonksiyonları kullanılarak veriler daha yüksek boyutlu bir özellik uzayına projekte edilmekte ve böylece doğrusal olmayan veri yapıları doğrusal olarak ayrıştırılabilir hale getirilmektedir. SVM modelleri, özellikle veriler arasında eğri, dairesel veya karmaşık ayırım sınırlarının bulunduğu durumlarda etkili olmakta ve yüksek sınıflandırma doğruluğu sağlamaktadır. SVM'nin başlıca avantajları arasında, yüksek boyutlu veri setlerinde etkili şekilde çalışabilmesi, karar sınırını en iyi şekilde ayıran hiper düzlemi belirlemesi sayesinde yüksek genelleme performansı sunması ve çekirdek yöntemi ile doğrusal olmayan problemlerde dahi başarılı sonuçlar üretebilmesi yer almaktadır. Bununla birlikte, büyük veri setlerinde eğitim süresinin uzaması, modelin karmaşıklığının artması ve hiperparametrelerin hassas bir şekilde seçilmesinin gerekliliği, yöntemin başlıca sınırlılıkları arasında değerlendirilmektedir.

4.2.8 XGBoost modeli

Makine öğrenmesi literatüründe artırma algoritmaları, özellikle son yıllarda model doğruluğunu artırmaya yönelik güçlü yaklaşımlar sunmaları nedeniyle yoğun akademik ilgi gören bir araştırma konusu hâline gelmiştir. Artırma algoritmaları, bireysel olarak zayıf performans gösteren öğrencilerin sistematik biçimde bir araya getirilmesi yoluyla güçlü ve yüksek doğrulukta tahmin modelleri oluşturmayı amaçlamaktadır. Bu yaklaşım, her adımda önceki modellerin yaptığı hataları azaltarak modelin genel performansını iyileştirmekte ve tahmin başarımına anlamlı ölçüde katkı sağlamaktadır (Friedman 2001).

GB ve Uyarlamalı Artırma (Adaptive Boosting, AdaBoost) gibi teknikler, zayıf öğrencilerin ardışık biçimde birleştirilmesi yoluyla, özellikle büyük veri setleri ve

karmaşık ilişkilere sahip problemlerde yüksek performanslı modeller oluşturabilmektedir. Günümüzde, bu algoritmaların uygulama alanı genişlemiş ve bu algoritmalar literatürde karmaşık veri yapılarının çözümünde sağladıkları katkılarla önemli bir yer edinmişlerdir (Schapire 1999). Özellikle GB, AdaBoost ve XGBoost algoritmaları, tahmin modellerinin doğruluğunu artırma, yüksek boyutlu ve karmaşık veri setlerini etkili biçimde işleme kapasitesiyle öne çıkan başlıca artırma tabanlı yöntemler arasında yer almaktadır. Bu yöntemler, çok boyutlu ve yüksek değişkenliğe sahip verilerde dahi güçlü ve genellenebilir modeller geliştirme imkânı sunarak, makine öğrenmesi literatürüne önemli katkılar sağlamaktadır.

GB, model hatalarını kademeli olarak minimize ederek her adımda performans iyileştirmeyi hedeflemekte iken, AdaBoost algoritması, yanlış sınıflandırılan gözlemlere daha yüksek ağırlık atayarak sonraki tahmin adımlarında bu hataları düzeltmeye çalışmaktadır (Friedman 2001). GB ve AdaBoost yöntemleri de sundukları doğru sonuçlar, esneklik ve farklı veri yapılarıyla başa çıkabilme kapasiteleri sayesinde, günümüzde makine öğrenmesi uygulamalarında yaygın olarak tercih edilmektedir.


GB algoritmasının temel çalışma prensibi, her adımda hataları azaltarak modelin doğruluğunu artırmaktır. İlk olarak, bir başlangıç ağacı oluşturulmaktadır. Ardından, hedef değişkenin gerçek değeri ile bu ağacın tahmin ettiği değerler arasındaki fark hesaplanmaktadır ve sonrasında bu hatayı azaltmak için, ikinci bir ağaç oluşturulmaktadır. Bu ağaç, birinci ağacın tahmin ettiği hatanın negatif gradyanını tahmin etmektedir. İkinci ağaç birinci ağacın bıraktığı hataları düzeltmeye odaklanmaktadır. Böylece, her yeni eklenen ağaç, önceki ağaçlardan kalan hataları daha da iyileştirerek, modelin doğruluğunu kademeli olarak artırmaktadır. Bu süreç, modelin genel performansını optimize etmek için bir dizi ağacın ardışık olarak eklenmesiyle devam etmektedir.

AdaBoost, modelin her adımında yanlış sınıflandırılmış verilerini daha fazla ağırlıklandırarak çalışmaktadır. İlk olarak bir zayıf öğrenici (örneğin, karar ağacı) oluşturularak ve yanlış sınıflandırılan örneklere daha fazla ağırlık verilerek yeni bir öğrenici eğitilmektedir. Bu süreç, modelin yanlış sınıflandırmalarına odaklanmasını

sağlar ve her yeni öğrenici, önceki öğrenicinin hatalarını düzeltmeye çalışmaktadır (Schapire 1999).

XGBoost, GB algoritmasının çeşitli sistem ve model düzeyinde iyileştirmelerle optimize edilmiş bir türevidir. Yüksek tahmin başarısı sunmasının yanı sıra, aşırı öğrenmeyi önleyebilme, eksik veriyle başa çıkabilme ve işlem hızının yüksek olması gibi avantajlarıyla dikkat çekmektedir. Chen ve Guestrin'in (2016) çalışmasında, XGBoost'un benzer algoritmalara kıyasla yaklaşık on kat daha hızlı çalıştığı ortaya konulmuştur. Sistemsel optimizasyon teknikleri, regülerizasyon mekanizmaları, budama stratejileri ve eksik değerlere karşı toleranslı yapısı sayesinde, XGBoost özellikle büyük ve karmaşık veri setlerinde etkili sonuçlar üretmektedir (Dalkılıç vd., 2021).

XGBoost algoritması, gradyan artırma yönteminin optimize edilmiş ve düzenlileştirme terimleri ile güçlendirilmiş bir versiyonudur. Algoritma, ardışık olarak inşa edilen çok sayıda karar ağacı üzerinden tahminleme yapmaktadır. Her bir ağaç, bir önceki ağacın hatalı tahminlerini minimize edecek şekilde eğitilmekte, bu da modelin genelleme yeteneğini artırmaktadır. İlk model (Sonuç 1) ham tahminleri üretirken, takip eden modeller (Sonuç 2 ve Sonuç 3) bu tahminlerdeki hataları düzeltmeye çalışmaktadır. Bu ardışık süreç sonucunda, tüm modellerin katkısı birleştirilerek nihai XGBoost tahmini elde edilmektedir. Her ağaç modeli, veri örneklerine farklı derecede ağırlık atar ve modelin öğrenme kapasitesi her adımda artmaktadır (Şekil 4.12). Bu yöntem, hem model karmaşıklığını kontrol altına almakta hem de yüksek doğruluk oranlarıyla aşırı öğrenme riskini azaltmaktadır.



Şekil 4.12 XGBoost modelleme yaklaşımı (Wang vd. 2022)

Algoritmanın temelinde, her iterasyonda toplam hatayı azaltmaya ve model karmaşıklığını kontrol altında tutmaya yönelik bir optimizasyon süreci yer almaktadır. Bu süreçte kullanılan ve eşitlik (4.15)'te gösterilen amaç fonksiyonu iki bileşenden oluşmaktadır: birincisi, tahmin hatasını ölçen kayıp fonksiyonu; ikincisi ise modelin aşırı uyuma eğilimini sınırlandırmayı hedefleyen düzenleme terimidir (Aydın 2021).

$$L^t = \sum_{i=1}^n l(y_i, \hat{y}_i^{t-1} + f_t(x_i)) + \Omega(f_t) \quad (4.15)$$

Burada L^t t. iterasyona karşılık gelen toplam maliyeti; y_i ve $\hat{y}_i^{(t-1)}$ ise sırasıyla i. gözlemin gerçek değeri ile önceki modelin tahminini temsil etmektedir. $f_t(x_i)$ t. turda elde edilen zayıf öğrenicinin çıktısıdır ve bu formülasyona dâhil edilen düzenleme terimi eşitlik (4.16)'daki gibi modellenmektedir:

$$\Omega(f_t) = \gamma T_t + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (4.16)$$

Tanımda yer alan T , karar ağacındaki yaprak sayısını; w_j , j. yaprağın ağırlığını; γ ve λ hiperparametrelerini ifade etmektedir. Bu bileşen, modelin yapısal karmaşıklığını dengeleyerek, daha sade ve genellenebilir bir yapı elde edilmesine katkı sağlamaktadır.

Kayıp fonksiyonunun yaklaşık değeri, ikinci dereceden Taylor açılımına dayalı olarak eşitlik (4.17)'deki biçimde elde edilmektedir:

$$L^t \cong \sum_{i=1}^n \left[l(y_i, \hat{y}_i^{t-1}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (4.17)$$

Bu bağlamda: $g_i = \frac{\partial}{\partial \hat{y}_i^{t-1}} l(y_i, \hat{y}_i^{t-1})$ kayıp fonksiyonunun birinci türevi (gradyan) ve $h_i = \frac{\partial^2}{\partial \hat{y}_i^{t-1}} l(y_i, \hat{y}_i^{t-1})$ ise ikinci türev olarak tanımlanmaktadır (Aydın 2021). Sabit bir ağaç yapısı altında, her yaprağın optimum ağırlığı aşağıda eşitlik (4.18)'de ifade edilmektedir:

$$w_j^* = - \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda}, \quad (4.18)$$

İlgili yaprak ağırlıkları temel alınarak, ağaç yapısının genel skor fonksiyonu eşitlik (4.19)'daki biçimi almaktadır:

$$L(q) = -\frac{1}{2} \sum_{j=1}^T \frac{(\sum_{i \in I_j} g_i)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T \quad (4.19)$$

Yöntemde, belirli bir karar ağacı yapısının doğruluk ve basitlik dengesine göre ne kadar uygun olduğunu hesaplamak amacıyla kullanılmaktadır. Böylelikle, sadece hatayı azaltmaya değil, aynı zamanda öğrenici yapısının genelleme kabiliyetini korumaya da odaklanılmaktadır. Literatürde artırma algoritmalarının özellikle DT temelli yapılarda yüksek performans gösterdiği belirtilmektedir. Zayıf öğrenicilerin birleştirilmesi, karmaşık ve çok değişkenli veri yapılarında başarılı sınıflandırma ve tahminleme sonuçları üretme potansiyelini artırmaktadır (Hastie vd. 2009).

Artırma algoritmaları, farklı yapay öğrenicilerin art arda eğitilmesiyle genellenebilirliği yüksek ve güçlü modellerin oluşturulmasına imkân tanımaktadır. Bu algoritmaların en dikkat çeken yönlerinden biri, veri setlerinde yer alan gürültüye karşı gösterdikleri yüksek toleranstır. Gürültülü veya eksik bilgi içeren veri kümelerinde dahi başarılı sonuçlar

üretebilmeleri, onları birçok gerçek dünya uygulaması için avantajlı kılmaktadır (Chen ve Guestrin 2016). Ayrıca, yerleşik düzenlileştirme mekanizmaları sayesinde aşırı öğrenme eğilimi kontrol altına alınabilmektedir.

Öte yandan, yöntemin bazı sınırlılıkları da bulunmaktadır. Özellikle çok sayıda zayıf öğreniciye dayalı modelleme süreci, hesaplama kaynakları üzerinde ciddi yük oluşturabilmekte; bu durum eğitim süresinin uzamasına ve sistem kaynaklarının verimsiz kullanımına neden olabilmektedir (Ke vd. 2017). Bu nedenle, XGBoost modelinin etkili biçimde uygulanabilmesi için hiperparametrelerin dikkatle seçilmesi, çapraz doğrulama gibi yöntemlerle aşırı uyum riskinin azaltılması büyük önem taşımaktadır (Friedman 2001).

4.2.9 Yapay Sinir Ağları


Geleneksel veri işleme sistemleri, sayısal hesaplamalarda yüksek hız ve doğruluk sunmalarına rağmen; algılama, öğrenme ve edinilen bilgileri esnek biçimde kullanma gibi bilişsel süreçlerde insan beyninin kapasitesine kıyasla belirgin sınırlılıklar taşımaktadır. İnsan zihninin bu konudaki üstünlüğü, duyuşal girdileri sınıflandırma ve bağlama dayalı olarak anlamlandırma yeteneğinden kaynaklanmaktadır. Bu bağlamda, özellikle son yıllarda yapay zekâ alanında; uzman sistemler, bulanık mantık, ANN ve genetik algoritmalar gibi alt disiplinlere yönelik yoğun akademik ilgi söz konusudur ve bu alanlarda çok sayıda uygulamalı çalışma yürütülmektedir (Elmas 2003).

ANN, insan beyninin işleyişinden ilham alınarak geliştirilen ve biyolojik sinir sistemlerinin yapısını temel alan hesaplama modelleridir. Bu alandaki ilk kuramsal temel, 1943 yılında McCulloch ve Pitts tarafından ortaya konmuş; nöronların matematiksel temsili üzerine yapılan bu çalışma, sinirsel bilgi işleme modellerinin başlangıcını oluşturmuştur. Hebb'in 1949'da geliştirdiği "Hebb Öğrenme Kuralı", sinaptik bağlantıların öğrenme yoluyla nasıl güçlendiğini açıklayarak yapay öğrenme süreçlerine önemli bir kavramsal çerçeve kazandırmıştır. 1958 yılında Rosenblatt'ın geliştirdiği algılayıcı modeli, ANN literatüründe önemli bir dönüm noktası olarak kabul edilmektedir (Krycha ve Wagner 1999).

1960'lı yıllarda Widrow ve Hoff, ANN'nin kullanım alanlarını yaygınlaştırarak bu alandaki uygulamalı gelişmelere öncülük etmişlerdir. Özellikle geliştirdikleri “Widrow-Hoff öğrenme algoritması”, yapay öğrenmenin temel taşlarından biri olmuştur. 1974 yılında Paul Werbos, bu algoritma için hata geri yayılımı yöntemini önermiş ve bu sayede çok katmanlı ağların eğitilebilmesi mümkün hâle gelmiştir. Ayrıca, Kolmogorov'un 1957 yılında ortaya koyduğu süperpozisyon teoremi, doğrusal olmayan ilişkilerin doğrusal fonksiyonların bileşimiyle yaklaşık olarak temsil edilebileceğini göstererek, çok katmanlı sinir ağlarının teorik temelini güçlendirmiştir (Krycha ve Wagner 1999).

ANN, biyolojik sinir sistemlerinden esinlenen yapısıyla, girdi-çıkı örüntüleri üzerinden öğrenme gerçekleştirmektedir. Bu öğrenme sürecinde, eğitim algoritması; her iterasyonda bağlantı ağırlıklarını, hedef çıktıya daha fazla yaklaşacak şekilde güncelleyerek ağı optimize etmeye çalışmaktadır. ANN yapısı, genellikle her biri belirli bir alt problemi çözmek üzere tasarlanmış çok sayıda basit işlem biriminden oluşmaktadır (Şekil 4.13) (Seher 2022).

Birimler, kendilerine iletilen girdileri ilgili ağırlıklarla çarpmakta, doğrusal olmayan bir aktivasyon fonksiyonu aracılığıyla işlemekte ve çıktıya dönüştürmektedir. ANN'nin genelleme kapasitesi, eksik ya da belirsiz veri altında dahi çalışabilme yeteneğiyle birleştiğinde, onları özellikle karmaşık ve çözümü zor problemlerde güçlü bir yöntem hâline getirmektedir (Seher 2022).



Şekil 4.13 ANN temel işleyiş mekanizması (Tolon ve Güneri Tosunoğlu 2008)

ANN, doğrusal olmayan, eksik ya da çok boyutlu veri yapılarının analizinde geleneksel yöntemlerin yetersiz kaldığı durumlarda etkili çözümler sunma kapasitesiyle öne çıkmaktadır. Bu esneklik, ANN'nin en belirgin avantajlarından biri olarak değerlendirilmektedir. Karmaşık veri kümeleri üzerinde matematiksel modelleme, eğilim analizi ve geleceğe yönelik tahminlerin yapılması gibi işlemlerde başarılı sonuçlar üretebilmesi, onu güçlü bir tahminleme aracı hâline getirmektedir.

ANN, eksik verilerin tamamlanması, sınıflandırma yapılması ve belirli girdilere karşılık gelen çıktıların tahmin edilmesi gibi uygulamalarda etkin rol oynamaktadır. Özellikle insan algısının yetersiz kaldığı karmaşık desenlerin ve örüntülerin keşfedilmesinde ANN, yüksek düzeyde analiz yeteneği sunmakta olup eğitilmiş bir ANN modeli, çalıştığı problem alanında bir uzman gibi davranarak, olasılık temelli öngörülerde bulunabilmekte ve belirsizlik içeren senaryolar karşısında tutarlı projeksiyonlar geliştirebilmektedir. Bu yapay sistemlerin üstlendiği temel işlevler, aşağıdaki tabloda ayrıntılı biçimde sunulmaktadır (Çizelge 4.1).

Çizelge 4.1 ANN fonksiyonları

No	Fonksiyon Adı	Fonksiyon Eşitliği
1	Doğrusal	$f(x) = x$
2	Lojistik	$f(x) = \frac{1}{1+e^{-x}}$
3	Sigmoid	$f(x) = \frac{1}{1-e^{-x}}$
4	Hiperbolik Tanjant	$f(x) = \tanh\left(\frac{x}{2}\right)$
5	İşaret Fonksiyonu	$f(x) = \begin{cases} +1 & \text{if } x \geq 0 \\ -1 & \text{if } x < 0 \end{cases}$
6	Hiperbolik	$f(x) = \frac{e^x + e^{-x}}{e^x - e^{-x}}$
7	Üssel	$f(x) = e^{-x}$
8	Birim Toplam	$f(x) = \frac{e^x}{\sum_j e^{x_j}}$
9	Kareköklü Aktivasyon	$f(x) = \sqrt{x}$
10	Sinüs	$f(x) = \sin(x)$
11	Basamak Fonksiyonu	$f(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases}$

4.3 Gayrimenkul Pazar Bölümlendirmesi

Gayrimenkullerin doğru fiyatlandırılması hem bireysel kullanıcılar hem de yatırımcılar açısından ipotek kredisi, vergilendirme, yatırım kararları, birleşme ve devralmalar, açık artırmalar, finansal bilançolar ve alım-satım faaliyetleri gibi geniş bir ekonomik yelpazedeki etkisinden kaynaklanan kritik bir öneme sahiptir (Abidoeye vd. 2019). Bu nedenle, gayrimenkul fiyatlarının yanlış belirlenmesi, sadece bu faaliyetleri değil, yatırım

kararlarında ciddi yanılgılara yol açabilmekte ve aynı zamanda sürdürülebilir ekonomik büyüme ve kalkınmayı da olumsuz etkileyebilmektedir (Usman vd. 2020).

Gerçek değerinin üzerinde fiyatlandırılmış bir gayrimenkule yapılan yatırım, beklenen getiri oranlarının düşmesine ve dolayısıyla finansal dengesizliklere yol açabilirken; değerinin altında fiyatlandırılmış bir gayrimenkul ise potansiyel pazar fırsatlarının gözden kaçırılmasına neden olabilmektedir. Bu bağlamda, doğru fiyatlandırma mekanizmalarının kurulması, güvenilir endekslerin geliştirilmesi ve pazar dinamiklerinin derinlemesine anlaşılması, söz konusu risklerin azaltılmasında kritik bir rol oynamaktadır. Düzenleyici kurumlar ile pazar aktörleri arasındaki etkin iş birliği sayesinde, şeffaf ve sağlıklı fiyatlandırma stratejilerinin oluşturulması, ekonomik istikrarın ve sürdürülebilirliğin sağlanması açısından büyük önem taşımaktadır. Öte yandan, teknolojik gelişmelerin etkisiyle çok sayıda gayrimenkulün hızlı ve düşük maliyetli biçimde değerlemesinin yapılmasına duyulan ihtiyaç, hedonik modele dayalı toplu değerlendirme yöntemlerinin gelişimini teşvik etmiştir (Abdullahi vd. 2018 ve Malinowski vd. 2018).

Geleneksel yaklaşımlar, gayrimenkulleri merkezi iş bölgesine olan mesafesiyle ters orantılı değer taşıyan mallar olarak ele alırken; yenilikçi modeller, gayrimenkul değerini sadece mesafe üzerinden değil, arz ve talebin mekânsal dengesi varsayımına dayalı olarak değerlendirmektedir. Bu yeni yaklaşımlar, bir gayrimenkulün piyasa değerini yapısal özellikler, mahalle özellikleri ve konumun örtük fiyatlarının toplamı olarak modellemektedir (Chen vd. 2009 ve Fonnesbech Wulf vd. 2011). Ancak, bu çerçeve özellikle bölgesel veri setleri kullanıldığında, mekânsal otokorelasyon ve heteroskedastisite gibi nedenlerle eleştirilmiştir (Dale-Johnson 1982; Bourassa vd. 2007 ve Beracha vd. 2017). Çünkü, konum etkileri modele dahil edilse bile, gayrimenkullerin mekânsal olarak birbirinden bağımsız olduğu varsayımı, fiyat kalıntılarının mekânsal bağımlılık gösterdiğine dair ampirik bulgularla çelişmektedir (Bourassa vd. 2007 ve Usman vd. 2020).

Gayrimenkullerin benzer konum özelliklerinden faydalanması, aralarındaki korelasyonu artırmakta ve bu durum hedonik modellere dayalı fiyat tahminlerini verimsiz hâle

getirmektedir. Bu yapısal bağımlılık, gayrimenkul fiyatlarının doğru biçimde modellenmesinde önemli bir sorun teşkil etmektedir (Tu vd. 2007; Manganelli vd. 2015 ve Wu vd. 2018). Öte yandan, gayrimenkullerin doğası gereği heterojen bir yapıya sahip olması hem konum hem de yapısal özellikler bakımından önemli farklılıklar göstermelerine neden olmaktadır (Islam ve Asami 2010). Bu farklılıklar, pazarın homojen bir bütün olarak ele alınmasını zorlaştırmakta; aksine, pazarın alt bölümlere ayrılmasını ve her bir bileşenin kendi dinamikleri çerçevesinde analiz edilmesini gerekli kılmaktadır (Usman vd. 2020).

PB, gayrimenkullerin fiziksel nitelikleri, konumsal özellikleri, kullanım biçimleri, hedef kullanıcı profili ve mevcut piyasa koşulları dikkate alınarak benzer özellikler taşıyan gruplar hâlinde alt pazarlara ayrıştırılması süreci olup alt pazarlarının belirlenmesine yönelik çeşitli yöntemler geliştirilmiştir. Bu yöntemler, faktör analizi, kümeleme ve mekânsal ekonometri gibi istatistiksel tekniklerden yararlanarak, önceden tanımlanmış sınırlarla gayrimenkul pazarlarının sınıflandırılmasına ve veriye dayalı alt pazarların oluşturulmasına odaklanmaktadır. Literatürde PB ile tahmin doğruluğunun artırılabilceği konusunda genel bir görüş birliği bulunmasına rağmen, alt pazarların sınıflandırılması ve tanımlanması için kullanılan strateji ve yöntemler üzerinde ortak bir yöntem anlayışı bulunmamaktadır (Usman vd. 2020).

Gayrimenkul piyasasındaki verilerin değişkenliğini azaltmak için gözlemlerin daha homojen alt pazarlara dağıtılması yaygın bir yaklaşımdır. Literatürde, gayrimenkul piyasalarının belirli özelliklere göre gruplandırılması ve bu alt pazarların fiyat tahmin süreçlerine dâhil edilmesi gerektiği görüşü güçlü bir şekilde desteklenmektedir. Fiyatlandırma modeli tahmininden önce pazarın bu şekilde ayrıştırılması, özellikle yığılma yanlılığının önlenmesine yardımcı olmakta ve parametre tahminlerinde daha doğru ve güvenilir sonuçlar elde edilmesini sağlamaktadır. Çünkü bir gayrimenkul alt pazarı, fiziksel özellikleri ve fiyat dinamikleri açısından diğer alt pazarlardan ayrırmakta ve kendine özgü bir yapı sergilemektedir. Bu nedenle, tüm pazarı temsil eden tek bir model kullanıldığında, katsayı tahminlerinin yanlı olması kaçınılmaz hale gelmekte; dolayısıyla her alt pazar için ayrı model tahminlerinin yapılması gerekliliği ortaya çıkmaktadır (Gabrielli vd. 2017).

Alt pazarların belirlenmesi, fiyat tahminlerinin doğruluğunu artırmakla kalmamakta; aynı zamanda araştırmacıların fiyatların zaman ve mekân açısından nasıl değiştiğini daha iyi modellemelerine yardımcı olmaktadır. Bunun yanı sıra, kredi verenler için kredi riskini daha doğru değerlendirme imkânı sunarken, gayrimenkul alıcılarının da arama sürecindeki maliyetlerini düşürmektedir (Demirhan ve Başer 2024).

Gayrimenkul pazarının bölümlendirmesinde deneyim temelli bilgi sınıflandırması ve veri odaklı yaklaşımlar olmak üzere kullanılan iki temel yöntem vardır. Alt pazarlar uzmanların görüşlerine göre genellikle idari sınırlar, sosyo-ekonomik göstergeler, nüfus sayımı bölgeleri, posta kodu alanları ve fiziksel özellikler gibi mekânsal ölçütlere dayanarak sınıflandırılmaktadır. Deneyim temelli bilgi sınıflandırması ise basit ve uygulanması kolay bir yöntemdir. Ancak bu yöntemin doğruluk, kesinlik ve nesnellik gibi açılardan bazı eksiklikleri bulunmaktadır. Bu nedenle, daha gelişmiş ve veri odaklı yaklaşımlar, bu eksiklikleri gidermek için tercih edilmektedir (Demirhan ve Başer 2024).

PB yaklaşımının gayrimenkul değerlemesi literatüründe giderek daha fazla önem kazandığı görülmektedir. Özellikle mekânsal heterojenliğin yoğun olduğu büyük kentlerde, konut veya ofis piyasalarının içsel farklılıklarını dikkate alan modeller, değerlendirme doğruluğunu artırmak açısından önemli katkılar sunmaktadır. Bu kapsamda, farklı dönemlerde ve coğrafi alanlarda yürütülen ampirik çalışmalar, alt pazar analizlerinin fiyat tahmin süreçlerine nasıl entegre edildiğini ve hangi koşullarda etkili sonuçlar verdiğini ortaya koymaktadır. Aşağıda bu çalışmalardan bazılarına yer verilerek, gayrimenkul piyasalarının bölümlenmesine dayalı modelleme yaklaşımları örneklendirilecektir.

San Francisco Körfez bölgesindeki konut fiyatlarının mahalle korelasyonlarını inceleyen Palm (1978), analizinde konut fiyatlarını etkileyen alt pazarların önemini vurgulamıştır. Çalışma, metropol alanındaki konut fiyatlarının ırksal-etnik yapı, gayrimenkul kurulu yetki alanları ve ortalama konut fiyatları gibi çeşitli faktörlerle ilişkilendirildiğini göstermiştir. Regresyon analizine dayalı bulgular, alt pazar modellerinin konut fiyatı analizinde etkili olabileceğini ortaya koymaktadır. Ancak bu modellerin, yalnızca belirli

bölgelerdeki ayrışık özellik-fiyat yapılarının açıkça tanımlandığı durumlarda kullanılmasının uygun olduğu sonucuna varılmıştır (Usman vd. 2020).

Goodman ve Thibodeau'nun (1998) çalışması, Dallas içindeki konut pazarının bölümlendirmesine odaklanarak önemli bulgular sunmaktadır. Çalışma, 1995 ile 1997 yılları arasındaki çekirdek ailelere ait konut işlemleri üzerinde yapılan analizlere dayanmakta olup araştırmacılar, işlem verilerini kamu ilkokullarındaki öğrenci performansını yansıtan bilgilerle tamamlayarak, konut pazarının kamu eğitim kalitesine göre nasıl bölümlendirildiğini göstermiştir. Carrollton-Farmers Branch Bağımsız Okul Bölgesi için yapılan gösterim, kamu eğitiminin kalitesinin, konut alt pazarlarının oluşumunda belirleyici bir faktör olduğunu ortaya koyulmuştur. Ayrıca, bu araştırmada kullanılan hiyerarşik modeller, konut alt pazarlarının belirlenmesi için etkili bir analitik çerçeve olarak değerlendirilmektedir. Araştırma, metodolojinin yalnızca çekirdek ailelere ait konutlar için değil, aynı zamanda kalabalık aileli konutlar, ofisler, perakende alanları ve endüstriyel depo gibi diğer gayrimenkul türlerinin alt pazar sınırlarını belirlemek için de uyarlanabileceğini vurgulamaktadır.

Ofis pazarında sınıflandırma yapmak için fiziksel, ekonomik veya demografik faktörlere dayanan veya bu üç faktörün bir kombinasyonu şeklinde ele alınabilecek özellikler kullanılmaktadır. Ancak, bu açıdan en uygun ve etkili özelliklerin belirlenmesi, bu alandaki temel araştırma sorularından biridir. Bir özelliğin faydalı olup olmadığını belirlemek için: bölümler arasındaki farklılıkları açıkça ortaya koyabilmesi, birbirinden bağımsız ve anlamlı gruplar oluşturma yeteneğinin olması ve farklı ofis türlerini ayırt etmek için pratik ve uygulanabilir olması gerekmektedir. Böylece bu kriterler hem teorik çerçevede hem de kentsel planlamaya yönelik uygulamalarda daha etkili analizler yapılmasına katkı sağlayacaktır.

Ofis pazarı bölümlendirmesini inceleyen çalışmalar, mikro düzeyde, arz tarafına ilişkin değişkenleri ele alarak konut sektöründeki yerleşik yöntemleri ve mevcut veri kısıtlamalarını takip etme eğilimindedir. Ürün türleri ve tüketici gruplarındaki farklılıkların etkisini analiz etmek amacıyla genellikle istatistiksel ve öznel temelli yöntemler kullanılmaktadır (Nemanja 2023).

Ofis kiralarına yönelik hedonik çalışmalar ise, farklı lokasyonların etkisini analiz etmek amacıyla tek bir regresyon denkleminde çeşitli bağımsız değişkenler ekleyerek PB'yi incelemektedir. Bu yöntem, modelin açıklama gücünü artırmayı ve geleneksel değişkenlerin açıklayamadığı belirgin lokasyon özelliklerini ortaya çıkarmayı hedeflemektedir. Bağımsız değişkenler genellikle tanınmış ofis bölgelerini temsil etmekte ve bu bölgeler, istihdam bileşimi, büyüme oranları, iş türleri, mahalle nitelikleri ve ofis stoku gibi ayırt edici özelliklerle karakterize edilmektedir. Bu, lokasyonların PB'de nasıl önemli rol oynadığını göstermektedir.

Ofis pazarının bölümlü bir yapıya sahip olduğu, son yıllarda yapılan birçok akademik çalışmada açıkça ortaya konulmuştur. Araştırmacılar bu pazarın sadece yapısal değil, aynı zamanda mekânsal, sosyo-ekonomik ve kullanıcı odaklı yönlerinin de analiz edilmesi gerektiği görüşündedir. Özellikle PB yaklaşımı gerek arz gerekse talep yönlü etkenleri dikkate alan çok boyutlu bir çerçeve sunmakta ve ofis kira analizlerinde daha gerçekçi sonuçlar elde edilmesini sağlamaktadır. Bu doğrultuda Clapp vd. (1992), lokasyonun kira üzerindeki etkisini anlamak için hem bağımsız değişkenleri hem de ayrı regresyon modellerini kullanmış, değişkenlerin anlamlılık düzeylerini PB'nin bir göstergesi olarak değerlendirmiştir. Benzer şekilde Nappi-Choulet vd. (2007), Paris'teki merkezi iş alanlarını alt pazarlara ayırarak, bu bölümlerin ofis kiraları üzerindeki etkilerini analiz etmiştir. Ceh vd. (2012) ise, kira aralıkları, bina yoğunluğu ve bina yaşı gibi değişkenleri temel alarak alt pazarları belirlemiş ve ofislerin perakende alanlara ve ulaşım noktalarına olan yakınlığının bölümlendirmede kritik bir rol oynadığını ortaya koymuştur.

Ofis pazarındaki bölümlenmenin sadece fiziksel değil, mekânsal boyutlarının da etkili olduğunu ortaya koyan çalışmalardan biri de Pivo'nun (1993) Toronto'da gerçekleştirdiği analizdir. Bu çalışmada otoyol kavşağına, metro istasyonuna olan uzaklık gibi mekânsal değişkenlerin yanı sıra, ofis kümelerinin boyutu ve yoğunluğu da değerlendirilmiştir. Dunse ve Jones (2002) da Glasgow ve Edinburgh şehirlerinde gerçekleştirdikleri çalışmalarında, ofis pazarının konut sektörü analizlerinde kullanılan istatistiksel yöntemlerle incelenebileceğini göstermiştir. Araştırmacılar, ofis alt tipleri, bina yaşı, boyutu, ısıtma sistemi, havalandırma, asansör gibi yapısal faktörleri değerlendirmenin yanı sıra, istihdam merkezlerine ve toplu ulaşımına olan mesafenin de belirleyici olduğunu

savunmuşlardır. Diğer yandan, bazı araştırmacılar ofis pazarını anlamada talep yönlü faktörlere odaklanmıştır. Margulis (2007), meslek grupları ve firma özellikleri üzerinden bir analiz gerçekleştirmiş; özellikle yönetim, satış, ulaşım, üretim ve profesyonel hizmetler gibi sektörlerin yüksek yoğunluklu ticari bölgelerde konumlandığını tespit etmiştir. Bu bulgu, işgücünün ve ticari faaliyetin bölgesel dağılımı ile ofis kullanım tercihlerinin doğrudan ilişkili olduğunu göstermektedir. Benzer şekilde, Costa vd. (2016) da Brezilya ofis pazarını ele aldığı çalışmada kurumsal kiracılar ile küçük ölçekli kiracıları ayırt etmiş ve bu gruplar arasında hem lokasyon hem de bina özelliklerine dayalı net bir bölümlendirme olduğunu ortaya koymuştur.

PB'nin yalnızca yerel ölçekte değil, aynı zamanda küresel ölçekte de farklı biçimlerde ortaya çıktığını gösteren önemli bir araştırma ise White ve Ke'nin (2014) Şanghai'da gerçekleştirdiği çalışmadır. Burada Puxi ve Pudong alt pazarlarının yabancı yatırım ve GSYH üzerindeki etkilerinin farklılık gösterdiği belirlenmiş; bu farklılığın, sürdürülebilir planlama politikaları ve devlet teşviklerinin sonucu olduğu vurgulanmıştır.

Yapılan önceki çalışmaların sonuçlarına göre ofis pazarında bölümlendirme yaklaşımı hem arz hem de talep yönlü faktörler üzerinden detaylı analizler yapılmasına imkân vermekte ve pazarın mekânsal, yapısal ve sosyo-ekonomik yönlerinin bir bütün olarak ele alınması mümkün olmaktadır. Bu çok boyutlu yaklaşım, kiraların daha sağlıklı ve doğru bir biçimde tahmin edilmesine katkı sağlamaktadır. Özellikle kent içindeki lokasyon, bina özellikleri, ulaşım imkanları ve kullanıcı profili gibi değişkenlerin birlikte değerlendirilmesi, alt pazarların dinamiklerini anlamada oldukça önemli bir zemin sunmaktadır. Ofis pazarlarının bölümlü yapısı genel bir kabul görse ve bağımsız değişkenlerin modele dahil edilmesinin önemi anlaşılmış olsa da hedonik modeller ile özgül araştırmalar doğrudan PB'ye odaklanmamaktadır.

Uluslararası çeşitli kuruluşlar tarafından hazırlanan raporlar, pazar trendlerini ve yatırım fırsatlarını analiz etmek için kullanılmaktadır. Buna karşın, hedonik çalışmalar daha çok değerlendirme modellerini geliştirmeyi veya kira dinamiklerini daha iyi anlamayı amaçlamaktadır. Bu nedenle, her iki tür çalışma da bölümlendirilmenin detaylı analizinden çok, pazar hakkında genel fikirler sunmayı hedeflemektedir (Nemanja 2023).

İlk arařtırmalar, gayrimenkul pazarını ırk, demografik ve coğrafi sınırlar gibi önceden belirlenmiş kriterlerle bölümlendirmiştir. Bununla birlikte, önceden belirlenmiş bölümlendirme yöntemlerinin keyfiliğı eleştirilmiştir. Bu nedenle PB, istatistiksel olarak veriye dayalı yaklaşımlarla gerçekleřtirmenin daha iyi olduğı savunulmuştur. İstatistiksel yaklaşımlara dayalı alt pazar analizleri, gayrimenkul piyasasının dinamik ve heterojen yapısını tam anlamıyla temsil edemedikleri gerekçesiyle eleştirilmiştir. Bu tür modellerin, özellikle mekânsal, sosyo-ekonomik ve davranışsal farklılıkları yeterince yansıtamama riski bulunduğı ifade edilmektedir. Bazı arařtırmacılar, gayrimenkul pazarının karmařık ve sürekli değıřen yapısına dikkat çekerek bölümlendirme tekniklerinin birleřtirilmesi gerektiğini öne sürmüştür.

Hangi bölümlendirme yöntemi seçilirse seçilsin, gayrimenkul pazarının alt pazarlara ayrılmasının temel amacı, fiyat tahmin doėruluğunu artırmaktır. Bununla birlikte, kullanılan sınıflandırma yönteminin belirli bir durumda en yüksek doėruluğı saėlayıp saėlamadığı uzun süredir devam eden tartışma konusu olmuştur. PB süreci, gayrimenkullerin arz ve talep dengesini etkileyen yapısal, mekânsal ve niteliksel özellikler temel alınarak gerçekleştirilmektedir. Ancak bu özelliklerin farklı pazar koşullarında nasıl etkileşimde bulundukları değışebilmektedir. Bu nedenle, herhangi bir yöntemin her durumda aynı düzeyde başarılı olacağı varsayılmamalı; seçilen yöntemin, arařtırmanın amaçları ve yerel pazar dinamikleriyle ne derece uyumlu olduėunun dikkatle deėerlendirilmesi gerekmektedir.

Farklı bölümlendirme yöntemlerinin üstünlüğü konusunda literatürde net bir uzlaşı bulunmamakla birlikte, bu yaklaşımların birleřtirilmesi; hem gayrimenkul piyasasındaki alt pazar yapılarını daha saėlıklı biçimde tanımlamak hem de kira deėerlemede daha isabetli tahminler üretmek açısından faydalı bir araç olarak deėerlendirilebilecektir. Ofis piyasasına tek ve homojen bir bütün olarak yaklařmak yanıltıcı olabilecektir; bu nedenle söz konusu piyasanın alt pazarlara ayrılmasına yönelik güçlü teorik temeller mevcuttur. Bu çalıřma, ofis kiralarını analiz etmek ve tahmin etmek amacıyla kullanılabilir bütüncül bir analitik çerçeve sunmayı amaçlamaktadır. Önerilen çerçeve, ofis pazarındaki farklı segmentleri dikkate alarak, farklı organizasyon türlerinin ofis tercihlerindeki farklılıkları da ayrıştırmalı bir biçimde ortaya koymaktadır.

5. BULANIK REGRESYON FONKSİYONLARI VE GAYRİMENKUL DEĞERLEME ARAŞTIRMALARINDA KULLANIM OLANAKLARI

Bulanık regresyon analizi, belirsizliklerle dolu veriler üzerinde kullanılabilir. Bu yaklaşımın temeli, bulanıklıkları ve belirsizlikleri modellemeye olanak tanıyan “bulanık kümeler” ve “bulanık mantık”tır. Bununla birlikte, bulanık regresyon, özellikle doğrusal ve kesin verilerin yeterli olmadığı durumlarda oldukça yararlıdır. Bu durumda, bağımsız değişkenlerin katsayıları, verilerin belirsizliğini gösteren bulanık sayılarla gösterilmektedir ve bu, klasik regresyon modellerinde olduğu gibidir (Tanaka vd. 1982).

Bulanık mantık ve bulanık küme kavramları Zadeh tarafından ortaya konulmuştur. Bulanık mantığın belirsizlik durumundan tahmin ve çıkarım yapmak amacıyla birçok alanda uygulamaları mevcuttur. Gürültü ve belirsizliklerin bir veri sisteminden tamamen çıkarılması mümkün olmadığından, belirsizlik halinde karmaşık sistemlerin modellenmesi için bulanık mantık ve teorisini kullanmak ise sıklıkla kullanılan bir yöntemdir (Başer 2013).

Bulanık kümeleme, üyelik dereceleri yardımıyla bir nesnenin hangi kümeye ait olduğunu belirlemek ve veri setindeki örtüşen küme yapısını tespit edebilmek amacıyla kullanılan bir yöntemdir. FRF yaklaşımına göre gözlemlerin benzerliklerine göre kümelenmesini sağlamak amacıyla Bezdek (1981) tarafından önerilen Bulanık c-Ortalama (FCM) kümeleme algoritmasından faydalanılmaktadır (Başer 2013).

5.1 Bulanık Kümeleme Algoritmaları

Bulanık kümeleme algoritmaları bir nesnenin birden fazla küme üyesine sahip olabileceği varsayımıyla çalışan bir sınıflandırma yöntemidir. Veriler arasındaki belirsizliği modellemek için tasarlanmıştır. Geleneksel kümeleme algoritmalarından farklı olarak, bu yaklaşım, her bir veri noktasına belirli bir küme üzerinden kesin bir karar vermek yerine, çeşitli kümelerdeki üyelik derecelerini kullanarak esnek bir yapı sağlamaktadır (Bezdek 1981).

Bulanık kümeleme algoritmaları verinin karmaşık yapısı veya çok boyutlu analizlerdeki belirsizlikler düşünüldüğünde çok önemlidir ve bir amaç fonksiyonu ile kovaryans matrisine veya bulanık bir ilişkiye dayanan sınır-bulanık kümeleme veya parametrik olmayan sınıflayıcı yapılarına göre birbirinden ayrılmaktadır. Uluslararası ve lokal sistem modelleme, esnek hesaplama ve sistem modelleme olarak bilinen bazı terimler bulunmaktadır (Babuška ve Verbruggen 1997).

Sistemin mevcut ilişkilerini göstermek için global modelleme tarafından kapsamlı bir şekilde incelenmektedir. Lokal modelleme yaklaşımı, sistemin genel yapısındaki karmaşıklığı azaltmak amacıyla ilk olarak sistemi anlamlı alt parçalara ayırmakta ve her bir bölüm için doğrusal ya da doğrusal olmayan yöntemlerle alt modeller oluşturmaktadır. Bu lokal modellerin yapısal özellikleri, hangi gözlemlerin hangi alt modele ait olacağını belirleyen bulanık kümeleme algoritmalarının özellikleri tarafından şekillendirilmektedir (Başer 2013). Bulanık kümeleme algoritmasında amaç, küme yapısına bağlı olarak tanımlanan kısıtlara göre amaç fonksiyonunun global minimum veya maksimumunu tespit etmektir (Çelikyılmaz ve Türkşen 2009).

Bulanık kümeleme algoritmalarında amaç fonksiyonları $J(f)$ veya J , hata ölçütü olarak kullanılmaktadır ve farklı çözümleri kıyaslamak için değerlendirilmektedir. Bulanık kümeleme algoritmalarının temel amaç, algoritmanın yapısına bağlı olarak J hedef fonksiyonunun global minimum ya da maksimum değerini belirlemektir. Bu fonksiyon, aynı kümeleme problemi için elde edilen alternatif çözümleri karşılaştırmak ve değerlendirmek amacıyla ölçüt olarak kullanılmaktadır (Çelikyılmaz ve Türkşen 2009).

$X = \{x_1, x_2, \dots, x_n\}$ nesneler kümesini göstermektedir. i nesnesi ($i = 1, 2, \dots, n$), d boyutlu $x_i = [x_{1,i} \ x_{2,i} \ \dots \ x_{d,i}]^T \in \mathbb{R}^d$ vektörü ile temsil edilmektedir. Buna göre, eşitlik (5.1)'de gösterilen $n \times d$ boyutlu veri matrisi,

$$X = \begin{bmatrix} x_{1,1} & x_{1,2} & \dots & x_{1,d} \\ x_{2,1} & x_{2,2} & \dots & x_{2,d} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n,1} & x_{n,2} & \dots & x_{n,d} \end{bmatrix} \quad (5.1)$$

biçiminde tanımlanmaktadır. Her bir verinin kümelere olan üyelik derecelerini gösteren U parçalanma matrisi tasarımıyla bulanık kümeleme algoritmaları, veri kümesini c adet birbiriyle örtüşen kümeye parçalamaktadır (Başer 2013).

Bulanık parçalanma matrisi U , her k ($k = 1, 2, \dots, c$) kümesinde yer alan x_i ($i = 1, 2, \dots, n$) nesnelerinin üyelik derecelerinden oluşan bir matristir ve k kümesindeki i . vektörün üyelik derecesi $\mu_{k,i} \in U$ ile gösterilmektedir. Eşitlik (5.2)'deki parçalanma matrisi ise,

$$U = \begin{bmatrix} \mu_{1,1} & \mu_{2,1} & \dots & \mu_{c,1} \\ \mu_{1,2} & \mu_{2,2} & \dots & \mu_{c,2} \\ \vdots & \vdots & \ddots & \vdots \\ \mu_{1,n} & \mu_{2,n} & \dots & \mu_{c,n} \end{bmatrix} \quad (5.2)$$

ile verilmektedir. Bulanık kümeleme algoritmasında; c sayıda örtüşen küme, merkez vektörleri ile temsil edilmektedir (Çelikyılmaz ve Türkşen 2009).

d boyutlu veri vektörlerinden oluşan bir X veri matrisi için, bulanık kümeleme algoritması $k = 1, 2, 3, \dots, c$ olacak şekilde her bir kümeye karşılık gelen merkez vektörlerini v_i , belirlemektedir. $V = \{v_1, v_2, \dots, v_c\} \in \mathbb{R}^{c \times d}$ biçiminde tanımlanmakta olup her bir $v_i \in \mathbb{R}^d$, d boyutlu uzayda konumlanan bir küme merkezini ifade etmektedir. Genellikle bu merkezler, küme içerisindeki verilerin ağırlıklı ortalamaları (ağırlık merkezleri) olarak hesaplanmaktadır (Başer 2013).

5.1.1 Bulanık c-ortalama kümeleme algoritması

$X = \{x_1, x_2, \dots, x_n\}$ veri setinin c küme merkezine bölmek için kullanılan bulanık c -ortalama kümeleme algoritması, veri madenciliği ve makine öğrenimi alanlarında sıklıkla tercih edilen bir yöntemdir. k -ortalama kümeleme algoritmasının bulanık mantık prensiplerine dayalı bir genellemesi olarak FCM, ilk olarak 1973 yılında Dunn tarafından ortaya konmuş, daha sonra 1981'de Bezdek tarafından geliştirilerek literatürde yaygın olarak kullanılan bir kümeleme yöntemi hâline gelmiştir (Başer 2013).

Algoritma, her bir veri noktasını farklı kümelere atarken, klasik k-ortalama algoritması yalnızca bir kümeye atamaktadır. Bu özellik, karmaşık veri yapıları veya sınırlı geçişkenliğe sahip verilerin analizinde esneklik sağlamaktadır. FCM kümeleme algoritmasında uygun küme sayısının c belirlenmesi, modelin başarısı açısından kritik öneme sahiptir. Bu amaçla, farklı kümeleme yapılarının değerlendirilmesine olanak tanıyan Küme Geçerlilik İndeksleri gibi analiz yöntemleri sıklıkla kullanılmaktadır (Başer 2013).

$$\min J(X; U, V) = \sum_{k=1}^c \sum_{i=1}^n (\mu_{k,i})^m d^2(x_i, v_k) \quad (5.3)$$

Eşitlik (5.3)'de verilen FCM kümeleme algoritması, belirlenen küme sayısı c ve bulanıklık parametresi m kullanılarak amaç fonksiyonunun en düşük seviyeye indirilmesini sağlamaktadır. Bu algorithmada, her bir küme, v_i olarak adlandırılan bir merkez vektör ile temsil edilmektedir. Denkleminde $m \in (1, \infty)$ değeri, bulanık kümeleme algoritmalarında, bulanıklık derecesi genellikle “bulanıklaştırma parametresi” olarak adlandırılmakta, üyelik seviyelerinin dağılımını kontrol eden temel bir unsur olarak işlev görmektedir. Ve kümelerin örtüşme derecesini belirlemektedir. “ $m = 1$ ” durumu, kümeler arasında herhangi bir örtüşmenin bulunmadığını ifade edip kesin kümeleme yapısını temsil etmektedir (Başer 2013).

Burada $d^2(x_i, v_k)$ ifadesi, i . nesne ile k . küme merkezi arasındaki uzaklık ölçüsünü göstermektedir. Karesel uzaklık kullanılarak, amaç fonksiyonunun negatif tanımlı olmaması sağlanmakta ve $J > 0$ koşulu sağlanmaktadır. Veri kümesindeki her bir nesne, birbirinden ayrılmış kümelerle ait bir merkez olarak tanımlandığında ($c = n$) amaç fonksiyonunun değeri sıfıra ulaşmaktadır. Veri noktalarının küme merkezlerinden uzaklaştığı durumlarda, amaç fonksiyonunun değeri yükselmekte ve modelin toplam hata oranı artmaktadır. Dolayısıyla, küme merkezlerinin sayısı ile uzaydaki yerleşimleri, optimizasyon fonksiyonunun değerini doğrudan etkilemekte ve modelin performansını belirleyici bir unsur olarak öne çıkmaktadır. Etkili bir kümeleme yapısı oluşturmak için, amaç fonksiyonunun minimum değere ulaşması beklenmekte ve bu bağlamda global minimumun bulunması temel hedef olarak belirlenmektedir. Ayrıca, çözüm uzayında

anlamsız veya gereksiz sonuçlardan kaçınmak amacıyla, U parçalanma matrisine belirli matematiksel kısıtlar eklenmekte ve bu kısıtlar algoritmanın istikrarını ve geçerliliğini artırmaktadır (Başer 2013).

$$\sum_{k=1}^c \mu_{k,i} = 1, \quad \forall i > 0 \quad (5.4)$$

$$0 < \sum_{i=1}^n \mu_{k,i} < n, \quad \forall k > 0 \quad (5.5)$$

Eşitlik (5.4), parçalanma matrisinde bulunan her bir satırın elemanlarının toplamının bire eşit olması gerektiği koşulunu tanımlamaktadır. Bu durum, her bir veri noktasının tüm kümelerle olan üyelik derecelerinin toplamının birlik koşulunu sağlamasını zorunlu kılmaktadır. Krishnapuram ve Keller (1993) tarafından bu koşul, bulanık kümeleme sürecine yönelik bir “olabilirlik yaklaşımı” olarak tanımlanmıştır. Öte yandan, eşitlik (5.5) ile verilen kısıt, parçalanma matrisindeki her bir sütundaki üyelik değerlerinin toplamının, toplam gözlem sayısı olan n’yi aşmaması ve sıfırdan büyük olması gerektiğini belirtmektedir. Bu kısıt, her bir kümeye en az bir gözlemin atanmasını güvence altına almaktadır. Bu modelleme yaklaşımında üyelik derecelerinin belirli bir olasılık dağılımı göstermesi şartı aranmaz. Veri noktaları ile küme merkezleri arasındaki mesafeleri ölçmek amacıyla kullanılan genel uzaklık fonksiyonu ise aşağıdaki şekilde tanımlanmaktadır (Başer 2013).

$$d^2(x_i, v_k) = (x_i - v_k)^T A_k (x_i - v_k) \geq 0 \quad (5.6)$$

Eşitlik (5.6)’da yer alan A_k , $k = 1, 2, \dots, c$ için tanımlanmış norm matrisidir ve pozitif tanımlı, simetrik bir yapıya sahiptir. Bulanık kümeleme algoritmalarında, küme merkezleri ile veri noktaları arasındaki uzaklıkları hesaplamak için farklı uzaklık ölçütleri kullanılabilir (Çizelge 4.1) (Çelikyılmaz ve Türkşen 2009).

FCM kümeleme algoritması ise, özellikle Öklid uzaklığını temel almaktadır. Bu nedenle, FCM’de norm matrisi A_k , genellikle birim matris olarak kabul edilmektedir ($A = 1$). Ayrıca, veri seti analizden önce ortalaması sıfır ve varyansı bir olacak şekilde

standartlaştırılarak normalize edilmektedir. Bu işlem, modelin hesaplamalarında istikrar ve ölçek bağımsızlığı sağlamaktadır (Başer 2013).

Eşitlik (5.3) ve (5.6) kapsamında değerlendirildiğinde, FCM kümeleme algoritmasının optimum çözüme, amaç fonksiyonunun minimum değere ulaşmasıyla eriştiği ve bu nedenle bir kısıtlı optimizasyon problemi çerçevesinde tanımlandığı anlaşılmaktadır. Bu doğrultuda, FCM algoritması, kümelerin belirlenmesi sürecini bir optimizasyon problemi olarak ele almakta ve bu problem, matematiksel olarak eşitlik (5.7) ile ifade edilmektedir (Bezdek, 1981).

$$\begin{aligned} \min J(X; U, V) &= \sum_{k=1}^c \sum_{i=1}^n (\mu_{k,i})^m d^2(x_i - v_k)_A \\ 0 &\leq \mu_{k,i} \leq 1, \quad \forall i, k \\ \sum_{k=1}^c \mu_{k,i} &= 1, \quad \forall i > 0 \\ 0 &< \sum_{i=1}^n \mu_{k,i} < n, \quad \forall k > 0 \end{aligned} \quad (5.7)$$

Problem, Lagrange Çarpanları yöntemiyle çözülerek, başlangıçta eşitlik kısıtları içeren yapısından çıkarılıp, amaç fonksiyonu aracılığıyla tanımlanan kısıtsız bir optimizasyon problemine dönüştürülebilmektedir (Khuri 2003). Bu dönüşüm sürecinde, eşitlik (5.7) ile tanımlanan asal problem, Lagrange çarpanları (λ) olarak adlandırılan parametreler yardımıyla yeniden yapılandırılmakta ve bu sayede FCM algoritmasının çözüm süreci analitik olarak daha yönetilebilir bir forma kavuşmaktadır (Başer 2013).

$$\max W(U, V) = \sum_{k=1}^c \sum_{i=1}^n (\mu_{k,i})^m d^2(x_k, v_i)_A - \lambda \left(\sum_{k=1}^c \mu_{k,i} - 1 \right) \quad (5.8)$$

Lagrange Çarpanları yöntemine göre, Lagrange fonksiyonu; primal değişkenler açısından minimuma, Lagrange çarpanları açısından ise maksimuma ulaşması gerekmektedir. Bu koşul, kısıtlı optimizasyon problemlerinin çözümünde temel ilkelerden biridir. Bu

yaklaşım, modelin orijinal parametreleri olan U (üyelik dereceleri) ve V (küme merkezleri) üzerinden türev alınarak, bu değişkenlerin elimine edilmesi hedeflenmektedir. Bu bağlamda, eşitlik (5.8) ile verilen amaç fonksiyonunun U ve V açısından kısmi türevleri alınarak, optimum üyelik dereceleri ve küme merkezleri aşağıdaki biçimde analitik olarak hesaplanmaktadır (Çelikyılmaz ve Türkşen 2009).

$$\mu_{k,i}^{(t)} = \left[\sum_{l=1}^c \left(\frac{d(x_i, v_k^{(t-1)})}{d(x_i, v_l^{(t-1)})} \right)^{\frac{2}{m-1}} \right]^{-1} \quad (5.9)$$

$$v_k^{(t)} = \frac{\sum_{i=1}^n (\mu_{k,i}^{(t)})^m x_i}{\sum_{i=1}^n (\mu_{k,i}^{(t)})^m}, \quad \forall k = 1, 2, \dots, c \quad (5.10)$$

Eşitlik (5.9)'da yer alan $v_k^{(t-1)}$, $(t - 1)$ iterasyonda k. kümeye ait olarak hesaplanan küme merkez vektörünü ifade etmektedir. Benzer şekilde, eşitlik (5.9) ve (5.10)'da birlikte yer alan $\mu_{k,i}^{(t)}$ ise t. iterasyon adımıyla elde edilen optimum üyelik derecelerini göstermektedir. Bu ifadelerden hareketle, FCM algoritmasında üyelik dereceleri ile küme merkezlerinin birbirine bağımlı biçimde güncellendiği; yani her birinin değerinin diğerine bağlı olarak belirlendiği açıkça ortaya konmaktadır.

Bezdek (1981), üyelik dereceleri ile küme merkezlerinin eşzamanlı olarak belirlenmesini sağlayan yinelemeli bir çözüm yöntemi önermiştir. Bu yöntemle göre, her bir t iterasyonunda, $J^{(t)}$ amaç fonksiyonu, üyelik değerleri ve küme merkezleri güncellenerek yeniden hesaplanmakta ve süreç, amaç fonksiyonunun minimum değere ulaştığı noktaya kadar sürdürülmektedir. Böylece, algoritmanın yakınsama davranışı sağlanmakta ve kümeleme çözümünün istikrarı güvence altına alınmaktadır.

$$J^{(t)} = \sum_{k=1}^c \sum_{i=1}^n (\mu_{k,i}^{(t)})^m d^2(x_i, v_k^{(t)}) > 0 \quad (5.11)$$

FCM algoritması, belirli bir iterasyon sayısına ulaşıldığında ya da ardışık iterasyonlarda elde edilen küme merkezleri arasındaki değişimin önceden tanımlanmış bir eşik değeri ϵ

altında kalması durumunda durdurulmaktadır. Bu durdurma kriteri, algoritmanın yakınsama sağlamasını ve hesaplama sürecinin sonlandırılmasını mümkün kılmaktadır. Aşağıda, FCM kümeleme algoritmasının temel yinelemeli adımları sistematik olarak sunulmaktadır (Çelikyılmaz ve Türkşen 2009).

Burada $X = \{x_1, x_2, \dots, x_n\}$ bir veri vektörü, c , küme sayısı, m , bulanıklık derecesi ve ξ ise durdurma sabiti olarak tanımlanmaktadır. Ayrıca başlangıç aşamasında U parçalanma matrisine ait üyelik değerleri rasgele seçilmektedir (Başer 2013).

Adım 1. (5.10) numaralı eşitlik kullanılarak, başlangıç üyelik matrisinde yer alan değerler doğrultusunda ilk küme merkezleri belirlenmektedir (Başer 2013).

Adım 2. $t = 1$ 'den başlangıç değeriyle başlatılan yineleme süreci, belirlenen maksimum iterasyon sayısına ulaşıncaya kadar sürdürülmektedir (Başer 2013).

Adım 2.1. x_i girdi veri vektörünü ve $(t - 1)$ iterasyonda elde edilen $v_k^{(t-1)}$ küme merkezleri kullanılarak, (5.9) denklemini yardımıyla, k . kümede her bir i girdi veri nesnesine ait üyelik değeri, $\mu_{k,i}^{(t)}$ hesaplanmaktadır (Başer 2013).

Adım 2.2. $\mu_{k,i}^{(t)}$ üyelik değeri ve x_i girdisi kullanılarak, eşitlik (5.10)'da verilen küme merkez fonksiyonu yardımıyla, t iterasyonda her bir k kümesine ait küme merkezleri hesaplanmaktadır (Başer 2013).

Adım 2.3. $\left| v_k^{(t)} - v_k^{(t-1)} \right| \leq \epsilon$ şeklindeki durdurma kriteri sağlandığında iterasyon sona ermektedir. Eğer bu koşul sağlanmazsa, süreç Adım 2'ye geri dönerek devam etmektedir (Başer 2013).

FCM kümeleme algoritmasında bulanıklık derecesi (m) ile ilgili etkinin analizi, eşitlik (5.9)'da verilen üyelik değeri hesaplama formülünün sınır değerleri için limitleri alınarak aşağıdaki şekilde incelenebilmektedir.

$$\lim_{m \rightarrow \infty} \mu_{k,i}(x) = \lim_{m \rightarrow \infty} \left[\sum_{l=1}^c \left(\frac{d^2(x_i, v_k)}{d^2(x_i, v_l)} \right)^{\frac{1}{m-1}} \right]^{-1} = \frac{1}{c}, \quad \forall k, l = 1, 2, \dots, c \quad (5.12)$$

Ayrıca, hiçbir küme merkezinin birbirine eşit olmadığı varsayımı altında,

$$\lim_{m \rightarrow 1} \mu_{k,i}(x) = \begin{cases} 1, & d^2(x_i, v_k) < d^2(x_i, v_l); \quad \forall k, l = 1, 2, \dots, c; \quad k \neq l \\ 0, & \text{diğer yerlerde} \end{cases} \quad (5.13)$$

olarak elde edilmektedir. Buna göre m değeri arttıkça $\mu_{k,i}$ üyelik değeri sıfıra yaklaşmaktadır. Çünkü m , kümeler arasındaki örtüşme düzeyini belirlemektedir. Bu artış, kümeleri daha bulanık hâle getirir ve gözlemler birden fazla kümeye daha eşit şekilde dağılmaktadır. Öte yandan, m küçüldüğünde bulanık kümeleme sonuçları kesin kümeleme modeline daha fazla yaklaşmaktadır. Özellikle $m = 1$ olması durumu, kümeler arasında herhangi bir örtüşmenin bulunmadığı kesin kümeleme yöntemiyle eşdeğer olup tüm üyelik değerleri $\mu_{k,i} \in \{0,1\}$ şeklinde olmaktadır. Sistem modellemeye bulanıklık parametresi olarak $m = 2$ değerinin kullanılması önerilmiştir.

Ayrıca, optimum küme sayısının belirlenmesinde Küme Geçerlilik İndeksi'nin kullanımı kritik bir öneme sahiptir. Literatürde yaygın olarak kullanılan bazı temel geçerlilik indekslerine yer verilmiştir. Genellikle, bu indekslerden birini minimum yapan c değeri, veri yapısına en uygun küme sayısı olarak kabul edilmektedir (Çizelge 5.1) (Çelikyılmaz ve Türkşen 2009).

Çizelge 5.1 Bazı önemli küme geçerlilik göstergeleri (Çelikyılmaz ve Türkşen 2009)

Bezdek'in Parçalanma Katsayısı	$\vartheta_{PK}(\mu) = \sum_{i=1}^n \sum_{k=1}^c \frac{\mu_{k,i}^2}{n}$
--------------------------------	---

Bezdek'in Parçalanma Entropisi	$\vartheta_{PE}(\mu) = \frac{\left[\sum_{i=1}^n \sum_{k=1}^c \mu_{k,i}^2 \log_a(\mu_{k,i}^2) \right]}{n}$
--------------------------------	--

Xie - Beni İndeksi	$\vartheta_{XB^*}(\mu) = \frac{\max_{k=1,\dots,c} \left\{ \sum_{i=1}^n \mu_{k,i}^m \ x_i - v_k\ ^2 \right\}}{n \min\{\ v_k - v_l\ \}}, \quad k \neq l$
Fukuyama - Sugeno İndeksi	$\vartheta_{FS}(\mu) = \sum_{i=1}^n \sum_{k=1}^c \mu_{k,i}^m (\ x_i - v_k\ - \ v_k - \bar{v}\)$ $\bar{v} = \left(\frac{1}{\sum_{i=1}^n \sum_{k=1}^c (\mu_{k,i})^m} \right) \sum_{i=1}^n \sum_{k=1}^c (\mu_{k,i})^m x_i$

FCM algoritması, Bezdek (1981) tarafından geliştirilen ve literatürde yaygın biçimde kullanılan temel bir bulanık kümeleme yöntemi olarak kabul edilmektedir. FCM'nin farklı ihtiyaçlara uyarlanabilmesi amacıyla pek çok çalışma yürütülmüş; bu çalışmalar algoritmanın çeşitli alanlara özel biçimlerde genişletilmesini hedeflemiştir. Bununla birlikte, FCM algoritması, daha gelişmiş kümeleme yaklaşımlarının oluşturulmasında da temel bir yapı taşı oluşturmaktadır (Başer 2013).

5.2 Bulanık Regresyon Fonksiyonları

Geleneksel bulanık sistem modelleri, sözel nitelikleri bulanık kümelerle tanımlayabilmek için uzman bilgisinden yararlanmaktadır. Ancak, bu tekniklerin öznel olması ve genelleştirilememesi gibi bazı sınırlamaları bulunmaktadır. Bu nedenle, kendi kendine öğrenebilen bulanık sistem modelleri geliştirilmiştir. Bu modellerde, veriden bulanık kümeleri öğrenmek amacıyla genellikle bulanık kümeleme gibi optimizasyon algoritmaları kullanılmaktadır (Başer 2013).

Standart bulanık sistemlerde, bulanık kural tabanlarına dayalı yapılar çeşitli uygulama zorlukları ve sınırlamalarla karşı karşıya kalabilmektedir. Bu zorluklardan ilki, öncül ve soncul üyelik fonksiyonlarının yanı sıra, parametrelerin doğru bir şekilde tanımlanması gerekliliğidir. Ayrıca, öncül ve sonucun birleştirilmesinde kullanılan bileşke işlemi kapsamında, en uygun t-norm ya da t-conorm operatörünün belirlenmesi, bulanık sistemin etkinliği açısından temel bir aşamayı oluşturmaktadır (Başer 2013).

Bunun yanı sıra, kuralların temsili ve bu kurallar üzerinden çıkarım yapılabilmesi için “ve”, “veya”, “ise” gibi sözel bağlaçlara ilişkin belirsizliğin giderilmesi gerekmektedir.

Bu amaçla, uygun bir gerektirme işlemcisinin belirlenmesi kritik bir rol oynamaktadır. Son olarak, durulaştırma yönteminin seçimi, sistemin doğruluğu ve genelleştirilebilirliği açısından önemli bir faktördür. Bu zorlukların etkili bir şekilde ele alınması, bulanık sistemlerin daha güvenilir ve verimli hale gelmesini sağlamaktadır (Başer 2013).

FRF yaklaşımının temel amacı, bulanıklaştırma, öncül-sonuç bileşimi, gerektirme ilişkisi ve üyelik fonksiyonlarının optimizasyonu gibi klasik bulanık sistemlerde yer alan işlemlerin sayısını azaltmaktır. FRF, bu tür işlemleri büyük ölçüde devre dışı bıraktığı için, geleneksel bulanık kural tabanlı modellere kıyasla daha yalın ve daha az hesaplama yükü gerektiren bir yapı sunmaktadır. Tip-1 FRF analizinin temel mantığı, sadeleştirilmiş formülasyon üzerinden aşağıda açıklanmaktadır (Başer 2013).

Burada $x \in X \subseteq \mathbb{R}^d$ olmak üzere d boyutlu girdi uzayı; v_k ile temsil edilen ve $k = 1, 2, 3, \dots, c$ şeklinde tanımlanan c adet örtüşen kümeye ayrılmaktadır. Belirlenen her bir kümeye, $f_k: v_k \rightarrow \mathbb{R}$ olacak şekilde bir yerel bir bulanık model atanmaktadır. FRF yaklaşım sistem, $x \in X$ şeklindeki her bir girdi için tanımlı bulanık modeller aracılığıyla birer bulanık çıktı üretmektedir (Başer 2013).

Elde edilen bu çıktılar, ilgili girdi vektörünün her bir kümeye ait olma derecesini yansıtan üyelik derecelerine göre ağırlıklandırılmakta ve nihai tahmin bu ağırlıklı bileşim üzerinden elde edilmektedir. Yüksek kestirim başarısı sağlayan ve daha az sayıda bulanık işlemciye ihtiyaç duyan etkili bir bulanık sistemin oluşturulabilmesi için üç temel koşul sağlanmalıdır (Çelikyılmaz ve Türkşen 2009).

Birincisi, sistemdeki parçalanma işlemi, çıkarım sürecinde yerel ilişkilerin doğru bir biçimde temsil edilmesini hedeflemektedir. Ancak, değişkenler arasında güçlü etkileşimler bulunduğunda tam bir ayrıştırma çoğu zaman mümkün olmamaktadır (Başer 2013). Bu nedenle FRF sistemlerinde, kural öncülleri etkileşimli üyelik değerleriyle tanımlanarak değişkenler birlikte ele alınmaktadır. Örneğin, “enlem” ve “boylam” yerine “konum” ifadesinin ya da “uzaklık” ve “zaman” yerine “hız” değişkeninin kullanılması önerilmektedir.

İkincisi, lokal modellerin karmaşıklığı, sistemin genelleme kapasitesini zayıflatmadan tahmin performansını yükseltecek şekilde dengelenmelidir. Gereksiz yere karmaşık modellerden kaçınılmalı, çıkarım süreci için basit ama etkili model kümeleri tercih edilmelidir.


Üçüncüsü, üyelik fonksiyonlarının davranışı, modelin çıktısını her kümede doğru bir biçimde temsil edebilmesi açısından kritik öneme sahiptir. Bu nedenle üyelik değerleri, gelişmiş bulanık kümeleme algoritmalarıyla belirlenmeli ve her modelin kestirim gücünü artırmak amacıyla uzmanlaşmış kümeleme teknikleri kullanılmalıdır (Başer 2013).

FRF sistem modelleri, tasarım aşamalarında klasik bulanık kural tabanlı yapılarla benzerlik göstermekte, ancak örüntü tanımlama ve çıkarım süreçleri açısından farklılaşmaktadır. Bu modellerde veriler, öncelikle örtüşen bulanık kümelere ayrılmakta ve her bir küme, farklı karar kurallarını tanımlamak amacıyla kullanılmaktadır. Başlangıç aşamasında, bulanık parçalanmaların belirlenmesi için FCM algoritması tercih edilmekte; böylece veri uzayında yer alan örüntüler daha esnek biçimde temsil edilebilmektedir (Başer 2013).

FRF yaklaşımının temel katkısı, üyelik derecelerinin ve bunların dönüştürülmüş biçimlerinin ek bulanık tanımlayıcılar olarak sisteme dâhil edilmesi yoluyla, belirsizliklerin daha güçlü ve esnek bir şekilde temsil edilebilmesine olanak sağlamasıdır. Bu üyelik dereceleri, orijinal girdi değişkenleriyle birlikte kullanılarak, sistemdeki girdi-çıkı ilişkilerini öğrenen ve tahminleyen modellerde belirleyici rol üstlenmektedir. Bu bağlamda, kümeye özgü farklı veri desenlerinin modellenmesi çözümlemesini mümkün kılmak amacıyla, üyelik dereceleri ve bunların dönüşümleri orijinal veri setine entegre edilerek yeni kestirimciler oluşturulmaktadır (Başer 2013).

Bulanık fonksiyonlar kullanılarak gerçekleştirilen sistem modelleme süreci şematik olarak sunulmuştur (Şekil 5.1) (Başer 2013). Süreç, iki ana bileşenden oluşmaktadır: Bulanık Fonksiyonlarla Çıkarım ve Sistem Tanımlama ve Eğitim Motoru. İlk bileşen, bulanık mantık ilkelerine dayalı çıkarım sürecini kapsarken; ikinci bileşen, modelin yapısal ve parametrik olarak tanımlanmasını içermektedir.

Yapı tanımlama aşamasında, önce girdi değişkenleri ve bu değişkenlere ait üyelik değerleri belirlenmekte, ardından bulanık fonksiyonlarla kural üretimi gerçekleştirilmektedir. Bu süreçte oluşturulan kural tabanı, modelin davranışsal temelini oluşturmaktadır. Sonrasında, çıkarım mekanizması devreye girerek, sistemin belirsizlik altında tahmin yeteneği geliştirilmektedir. Parametre tanımlama aşamasında ise, çıkarım motoru ile elde edilen sonuçlara dayalı olarak model parametreleri optimize edilmektedir. Bu iki bileşenin bütünsel şekilde işletilmesiyle, bulanık sistemlerin yüksek doğrulukta tahmin yeteneği kazandığı ve karmaşık ilişkileri temsil edebildiği görülmektedir.




Şekil 5.1 FRF yaklaşımı ile bulanık sistem modelleme (Başer 2013)

5.2.1 Yapı tanımlama ve çıkarım

İlk olarak Çelikyılmaz ve Türkşen (2006) tarafından literatüre kazandırılan ve daha sonra Başer vd. (2023) tarafından geliştirilen bu yaklaşım, sınıflandırma problemlerine yönelik FRF yaklaşımı, eğitim ve çıkarım aşamalarından oluşmaktadır. Eğitim aşamasında, model tahmini rasgele seçilmiş eğitim verisi ile gerçekleştirilirken, çıkarım aşamasında test veya doğrulama verisi kullanılarak modelin tahmin doğruluğu değerlendirilir. Bu sürecin detayları algoritmada açıklanmıştır. FRF uygulamasının temel adımları, girdi/çıktı (kümeleme adımı) ve küme parametrelerinin tahmini (tahmin adımı) olarak ikiye ayrılmaktadır (Edinsel 2023).

FCM kümeleme yöntemini kullanan FRF yaklaşımı, bulanık yapı tanımlama (eğitim) ve bulanık çıkarım (test) olmak üzere iki aşamada incelenmektedir. İlk aşamada tamamlanması gereken yedi adım bulunmakta olup bu adımların çıktıları ikinci aşamadaki beş adım ın girdilerini oluşturmaktadır.

FRF algoritmasının yapı tanımlama aşamasındaki yedi adım ve çıkarım aşamasındaki beş adım aşağıda açıklanmaktadır (Şekil 5.2).



Şekil 5.2 FRF akış şeması

Adım 1. Eğitim veri çiftlerinde $\{(x_i, y_i) ; i = 1, \dots, n\}$, $m \geq 1.1$ ve $c > 1$ için FCM kümeleme algoritması kullanılmaktadır. Bu örnekte, c küme sayısını ve m ise bulanıklığın derecesini göstermektedir.

$X = [x_{j,i} \mid i = 1, 2, \dots, n; j = 1, 2, \dots, d]$ olacak şekilde $Z = (X, y)$, $(n \times (d + 1))$ girdi-çıktı veri seti olmak üzere, burada d seçilen girdi sayısını ve n veri vektörlerinin toplam sayısını ifade etmektedir. $x_i = (x_{1,i}, x_{2,i}, \dots, x_{d,i}) \in \mathbb{R}^d$ ve çıktı $y_i \in \mathbb{R}$ olmak üzere $z_i = (x_i, y_i) \in \mathbb{R}^{d+1}$, $i = 1, 2, \dots, n$ eğitim veri setindeki herhangi bir veri noktasını belirtmektedir ve her veri noktası $(d + 1)$ boyutundaki girdi vektörlerinden oluşmaktadır. Ayrıca, $\mu_{k,i}(x, y) \in [0, 1]$ k kümesi içindeki i . verinin üyelik değerini göstermektedir. Buna göre; FCM'yi (Bezdek 1981) aşağıda verilen şekilde uygulayarak; $v_k(x, y) = (x_{1,k}^c, x_{2,k}^c, \dots, x_{d,k}^c, y_k^c) \in \mathbb{R}^{d+1}$ optimum küme merkezleri ve $\mu_{k,i}(x, y)$ etkileşimli üyelik değerleri yinelemeli olarak hesaplamaktadır.

$$v_k(x, y) = \frac{\sum_{i=1}^n (\mu_{k,i}(x, y))^m z_i}{\sum_{i=1}^n (\mu_{k,i}(x, y))^m} \quad (5.14)$$

$$\mu_{k,i}(x, y) = \left(\sum_{l=1}^c \left(\frac{d_{k,i}(x, y)}{d_{l,i}(x, y)} \right)^{\frac{2}{m-1}} \right)^{-1} \quad (5.15)$$

$$d_{k,i}(x, y) = \|(x_i, y_i) - v_k(x, y)\|; \quad i = 1, 2, \dots, n; \quad k = 1, 2, \dots, c \quad (5.16)$$

Kümeleme algoritmalarında parametre seçimi, elde edilen sonuçların doğruluğu ve yorumlanabilirliği açısından belirleyici bir rol oynamaktadır. Bu çerçevede, özellikle bulanık kümeleme yöntemlerinde, bulanıklık derecesi m ve küme sayısı c gibi parametrelerin en uygun değerlerinin belirlenmesinde küme geçerlilik indeksleri yaygın olarak kullanılmaktadır (Pal ve Bezdek 1995 ve Kim ve Ramakrishna 2005).

Söz konusu indeksler, kümeler arası ayrışma ile kümeler içi tutarlılığı değerlendirerek optimal parametre kombinasyonlarının seçilmesine katkı sağlamaktadır. Öte yandan, Türkşen'in (1999) önerdiği sistem modelleme yaklaşımında, gerçek veri kümeleri üzerinde tatmin edici sonuçlar elde edebilmek amacıyla, bulanıklık parametresi genellikle $m = 2$ olarak belirlenmektedir.

Adım 2. Önceki adımda belirlenen küme merkez vektörleri kullanılarak, her bir küme için giriş uzayında $v_k(x) = (x_{1,k}^c, x_{2,k}^c, \dots, x_{d,k}^c) \in \mathbb{R}^d$ şeklinde bir temsil elde edilmektedir. Bu merkez vektörleri aracılığıyla, aşağıda tanımlı (5.17) ve (5.18) eşitlikleri doğrultusunda giriş uzayındaki her bir veri noktası için üyelik dereceleri hesaplanmaktadır.

$$\mu_{k,i}(x) = \left(\sum_{l=1}^c \left(\frac{d_{k,i}(x)}{d_{l,i}(x)} \right)^{\frac{2}{m-1}} \right)^{-1} \quad (5.17)$$

$$d_{k,i}(x) = \|x_i - v_k(x)\|; \quad i = 1, 2, \dots, n; \quad k = 1, 2, \dots, c \quad (5.18)$$

Adım 3. Her bir küme için elde edilen $\mu_{k,i}$ üyelik değerleri ile bunlara karşılık gelen $\mu_{k,i}^2$, $\exp(\mu_{k,i})$, $\ln(\mu_{k,i})$ gibi kullanıcı tarafından tanımlanmış matematiksel dönüşümler, orijinal giriş verileriyle birlikte değerlendirilmektedir. Ayrıca, her bir k için,

$$\mu_{k,i} > \alpha\text{-kesim}, \quad k = 1, 2, \dots, c; \quad i = 1, 2, \dots; \quad l; \quad l < n \quad (5.19)$$

koşulu esas alınarak farklı α – kesim değerlerine bağlı biçimde değişken alt kümeler oluşturulabilmektedir.

α – değerinin sıfırdan büyük seçilmesi durumunda, belirli bir kümeye olan üyelik derecesi düşük olan gözlemler ilgili küme içerisinde dikkate alınmamaktadır. Bu sayede, model tahmin sürecinde bazı gözlemler kümelerin dışında bırakılmakta ve yalnızca yüksek üyelik değerine sahip örnekler kullanılmaktadır. Bu yaklaşım, özellikle büyük veri setlerinde, her bir kümeye düşen gözlem sayısını azaltarak işlem yükünü hafifletmekte ve hesaplama verimliliğini artırmaktadır. Ancak, deneysel bulgulara göre, eğer bir kümedeki gözlem sayısı n/c oranının altında kalıyorsa, genellikle α – kesim değeri sıfır olarak belirlenmektedir (Çelikyılmaz ve Türkşen 2009).

Adım 4. Her bir küme için bulanık sınıflandırma modelleri LR, sVM, k-NN, DT, RF ve ANN gibi makine öğrenmesi yöntemleri kullanılarak bulanık sınıflandırma modelleri oluşturulmakta ve tahminleme süreci gerçekleştirilmektedir.

Adım 5. Her bir küme için bulanık sınıflandırıcıdan elde edilen çıktı değerleri, bir sigmoid fonksiyonu aracılığıyla çıktılara dönüştürülmektedir (Kuhn 2008).

Adım 6. Her bir küme için elde edilen bulanık çıktı değerleri, bu çıktılara karşılık gelen üyelik dereceleriyle ağırlıklandırılarak tek bir birleşik çıktı değeri elde şeklinde eşitlik 5.20'deki gibi hesaplanmaktadır.

$$\hat{P}_i = \frac{\sum_{k=1}^c \hat{P}_{k,i} \mu_{k,i}}{\sum_{k=1}^c \mu_{k,i}}, \quad k = 1, 2, \dots, c; \quad i = 1, 2, \dots, n \quad (5.20)$$

Adım 7. Çıktılara dayalı olarak belirli bir FRF modeli için en uygun eşik değeri hesaplanmaktadır. Bu optimum eşik, her bir modelin eğitim veri seti üzerinde en yüksek doğru sınıflandırma oranını sağlayacak biçimde, yinelemeli bir süreçle belirlenmektedir.

FRF yaklaşımına ilişkin önerilen test aşaması, yapı tanımlama sürecinde belirlenen modellerin test veri seti üzerindeki genelleme yeteneklerini değerlendirmek amacıyla aşağıda beş adımdan oluşan bir süreç ile sunulmaktadır.

Adım 1. Küme merkezlerinden yararlanılarak, her bir giriş örneği için üyelik değerleri hesaplanmaktadır.

Adım 2. Önceki adımda elde edilen üyelik değerlerinin belirli matematiksel dönüşümleri ile orijinal giriş verileri birleştirilerek genişletilmiş bir girdi kümesi oluşturulmaktadır.

Adım 3. Elde edilen bu yeni girdiler üzerinden, bulanık sınıflandırıcıların tahminleri kullanılarak sınıf olasılıkları hesaplanmaktadır.

Adım 4. Her bir giriş örneği için farklı kümelerden elde edilen çıktılar, ilgili üyelik değerleri ile ağırlıklandırılarak tek bir birleşik çıktı değeri elde edilmektedir.

Adım 5. Her veri örneği için, $\hat{y}_i = 0$ ya da $\hat{y}_i = 1$, olacak şekilde ikili bir sınıf etiketi tahmin edilmekte ve bu işlem yapı tanımlama aşamasında belirlenen optimum eşik değerlerine göre gerçekleştirilmektedir. Böylece modelin doğruluk düzeyi, tahmin edilen sınıf etiketlerine göre değerlendirilmektedir.

6. ANKARA İLİNDE YAPILAN SAHA ÇALIŞMASININ YÖNTEMLERİ

Araştırmanın yöntemsel çerçevesi, çalışmanın amacına uygun olarak veri toplama süreci, analiz teknikleri ve model değerlendirme yaklaşımlarını kapsamaktadır. Çalışmanın temel amacı doğrultusunda, Ankara ili Çankaya ilçesindeki ofis piyasasına ilişkin emsal ve saha verileri derlenmiş; bu veriler çeşitli ön işleme adımlarından geçirilerek analiz için hazır hale getirilmiştir. İlk olarak, çalışmada kullanılan değişkenler ve veri kaynakları detaylandırılmış; ardından, klasik istatistiksel yöntemler ile makine öğrenmesi ve bulanık modelleme yaklaşımlarına dayalı analiz süreçlerine yer verilmiştir. Son olarak, kurulan modellerin doğruluk ve güvenilirlik düzeylerinin karşılaştırmalı olarak değerlendirilmesini sağlayan performans ölçütleri açıklanmıştır.

6.1 Çalışmada Kullanılan Veriler

Çankaya ilçesinde ofis kiralari; bölgenin ticari yoğunluğu, prestij seviyesi, fiziksel yapı kalitesi ile altyapı olanakları gibi çeşitli etkenlere bağlı olarak önemli ölçüde farklılık göstermektedir. Yüksek standartlarda inşa edilmiş, ileri düzey bilişim altyapısı ve fiziki güvenlik bileşenleri sunan birinci sınıf ve prestijli ofis yapıları, başta çok uluslu şirketler olmak üzere ile büyük ölçekli yerel işletmeler tarafından tercih edilmektedir. Buna karşın, daha küçük ölçekte faaliyet gösteren işletmelerin ve yerel şirketlerin genellikle B ve C sınıfı ofis yapıları yönünde tercih geliştirdiği görülmektedir. Bu yapı, ofis tercihinde şirket ölçeği ve operasyonel gereksinimlerin belirleyici rol oynadığını gösternesini bakımından önemli görülmektedir.

Başkente eski tip ofis pazarı ile yeni tip ve modern ofis piyasaları arasında açıkça ayrışma (veya mekânsal olarak bölünmüş pazar yapısı) gözlenmekte ve yeni plaza tipi ofislerin daha çok Çankaya ilçesi sınırları içindeki mahallelerde geliştirilip inşa edilerek kullanıma açıldığı görülmektedir (Demirkaya 2025). Bu bakımdan Çankaya ilçesinin çalışma sahası olarak belirlenmesi, bölgenin ofis kiralama pazarının mekânsal ve yapısal dinamiklerini analiz etme açısından önemli avantajlar sunmaktadır. Ancak, bu seçimin bazı sınırlılıkları da beraberinde getirdiğinin göz ardı edilmemesi gerekmektedir.

Araştırma yalnızca Ankara ili Çankaya ilçesiyle sınırlandırıldığından, elde edilen bulguların Türkiye genelindeki diğer kentsel ofis piyasalarına doğrudan genellenebilirliği sınırlı kalmaktadır. Bunun yanı sıra, veri toplama sürecinin belirli bir zaman aralığına odaklanmış olması, ekonomik konjonktür, piyasa dalgalanmaları ve dışsal faktörler dikkate alındığında, elde edilen sonuçların uzun vadeli piyasa eğilimlerini yansıtmaya kapasitesini kısıtlamaktadır. Bu çerçevede, araştırma bulgularının yorumlanmasında bağlamsal ve zamansal sınırlamaların dikkate alınması gerekmektedir.

Türkiye’de tapu müdürlüklerinde gerçekleştirilen gayrimenkul alım-satım işlemleri sistematik olarak kayıt altına alınmakla birlikte, tapu harcının beyan edilen satış değerinin %4’ü üzerinden hesaplanması uygulaması nedeniyle bildirilen değerlerin çoğu zaman piyasa gerçekliğini yansıtmadığı gözlemlenmektedir. Bu durum, resmi verilerin güvenilirliğini sınırlamakta ve özellikle piyasa değer analizlerinde kullanımını tartışılabilir hale getirmektedir. Söz konusu yapısal sınırlılığı aşmak amacıyla bu çalışmada, 2019-2024 yılları arasında gerçekleşen ofis kiralama piyasasına ilişkin daha gerçekçi ve güncel bilgiler sağlayan alternatif veri kaynakları tercih edilmiştir. Çalışmada, saha araştırmaları, Endeksa Teknoloji Anonim Şirketi veri havuzu ve yerel gayrimenkul firmalarından temin edilen piyasa verileri temel alınmıştır. Bu sayede, analizlerin Ankara ofis kira piyasasının güncel ve reel dinamiklerini daha sağlıklı biçimde yansıtmaya amaçlanmıştır.

Araştırmanın amacına uygun biçimde, alan odaklı ve güncel verilerin elde edilebilmesi için doğrudan saha çalışmaları, yüz yüze mülakatlar ve yerinde gözlemler gibi nitel veri toplama yöntemlerinden yararlanılmıştır. Bu çerçevede, ofis kiralama piyasasına ilişkin veriler doğrudan yerel piyasa aktörlerinden temin edilerek analiz sürecine dâhil edilmiştir. Buna ilave olarak Hazine ve Maliye Bakanlığı Gelir İdaresi Başkanlığı, Türkiye İstatistik Kurumu ve T.C. Merkez Bankası gibi kurumlardan resmi veri talebinde bulunulmuş, ancak ilgili kurumlardan olumsuz geri dönüş alınmıştır.

Buna karşılık, araştırma alanında faaliyet gösteren ofis kiracıları, yatırımcılar, tesis yönetim firmaları ve gayrimenkul uzmanları ile gerçekleştirilen görüşmeler sayesinde, ofis kiralama piyasasını etkileyen faktörler, pazar eğilimleri, kira beklentileri ve kullanıcı

tercihlerine yönelik derinlemesine bilgiler elde edilmiştir. Ayrıca, ofis binalarının fiziksel yapıları, konumsal özellikleri, altyapı olanakları ve çevresel faktörlerinin kira değerlerine etkisini değerlendirmek amacıyla kapsamlı saha incelemeleri gerçekleştirilmiş; elde edilen bulgular veri doğrulama sürecinde tamamlayıcı unsur olarak kullanılmıştır.

Araştırmada, yalnızca akademik kaynaklarla sınırlı kalınmamış; aynı zamanda Türkiye Değerleme Uzmanları Birliği (TDUB) ve Gayrimenkul Yatırımcıları Derneği (GYODER) gibi sektörel kuruluşların yanı sıra Colliers International, Coldwell Banker Richard Ellis, Value Solution Partners ve REIDIN gibi profesyonel danışmanlık firmalarının yayımladığı güncel piyasa raporları da kapsamlı biçimde analiz edilmiştir. Bunlara ek olarak, çevrimiçi gayrimenkul ilan siteleri olan Sahibinden.com, Emlakjet ve Zingat gibi platformlarda sunulan veri analizleri de incelenerek araştırmaya destekleyici nitelikte katkı sağlanmıştır. Kaynaklar, ofis kiralarının belirlenmesinde kullanılan yöntemler, pazarın temel dinamikleri ve sektörel eğilimlere dair güncel ve bütüncül bilgiler sunmaktadır. Bu rapor ve analizlerin kullanımı, bölgesel karşılaştırmaların yapılabilmesi, ofis kiralarını etkileyen faktörlerin sistematik olarak sınıflandırılması ve verilerin doğruluk ile güvenilirlik düzeyinin artırılması açısından çalışmaya önemli katkılar sağlamaktadır.

Veri setindeki toplam ofislerin mahallelere göre yüzdelik dağılımı incelendiğinde: Kızılırmak Mahallesi (%53,59) ve Mustafa Kemal Mahallesi (%31,19), toplam ofis stokunun büyük çoğunluğunu oluşturmaktadır. Bu, söz konusu mahallelerin ticari yoğunluğu yüksek bölgeler olduğunu ve ofis arzının en fazla bu lokasyonlarda bulunduğunu göstermektedir. Diğer mahalleler olan Söğütözü (%5,48), Çukurambar (%3,19) ve İşçi Blokları (%6,55) ise görece daha düşük paylara sahiptir (Çizelge 6.1). Bu oranlar, bu bölgelerde toplam ofis sayısının daha sınırlı olduğunu işaret edebilecektir. Genel olarak, veriler belirli mahallelerde ofis stokunun daha fazla yoğunlaştığını, dolayısıyla ticari faaliyetlerin ve iş merkezlerinin bu bölgelerde toplandığını ortaya koymaktadır. Bu analiz, yatırımcılar veya ticari alan arayışında olanlar için önemli bir içgörü sağlayabilecektir.

Çizelge 6.1 Veri setinde yer alan ofislerin konum ağırlıkları

Mahalle Adı	Mahallelere Göre Kira Verilerinin Dağılımı (%)
Kızılırmak	53,59
Mustafa Kemal	31,19
İşçi Blokları	6,55
Söğütözü	5,48
Çukurambar	3,19

Veri toplama sürecinin tamamlanmasının ardından, araştırma kapsamında Ankara ili Çankaya ilçesinde yer alan toplam 30 farklı A, A+ ve B+ sınıfı ofis binasında mevcut olan 2.610 adet bağımsız ofis birimine ilişkin ayrıntılı verilere ulaşılmıştır (Çizelge 6.2). Söz konusu ofis binaları, kentin iş merkezi niteliği taşıyan bölgelerinde yoğunlaşmakta olup; konum, fiziksel yapı, donatı, ulaşılabilirlik ve piyasa itibarı açısından bölgenin prestijli ve temsil kabiliyeti yüksek ofis stokunu yansıtmaktadır.

1071 Plaza, Arma Kule, Besa Kule, Cepa Ofis, Ege Plaza, Hayat Plaza, Kale Ofis, Koç Kuleleri, Köprülü Plaza, Mahall Ankara, Maidan, YDA Center ve Yıldırım Kule gibi örneklerden oluşan bu yapıların her biri, piyasa değeri ve kiralama hacmi açısından Ankara'nın ticari gayrimenkul piyasasında önemli bir yer tutmaktadır. Bu binalara ilişkin toplanan veriler; yapısal özellikler, kat planları, sosyal olanaklar, çevresel nitelikler veya lokasyon verileri gibi çok boyutlu bileşenleri içermektedir. Bu yolla ofis piyasasına ilişkin dinamikleri temsil eden kapsamlı ve güncel bir veri tabanı oluşturulmuştur.

Çizelge 6.2 Veri setinde yer alan ofis binaları

No	Ofis Bina Adı
1	1071 Plaza
2	312 Vista
3	Ankara Ticaret Merkezi
4	Arma Kule
5	Besa Kule
6	Cepa Ofis
7	Cubes Ankara
8	Çakıroğlu Beştepe
9	Ege Plaza
10	Hayat Plaza

Çizelge 6.2 Veri setinde yer alan ofis binaları(devamı)

No	Ofis Bina Adı
11	Kale Ofis
12	Koç Kuleleri
13	Köprülü Plaza
14	Mahall Ankara
15	Maidan
16	Mekik Plaza
17	Meva Plaza
18	Neorama
19	Nep Office
20	Next Level
21	Orion Plaza
22	Protokol Ankara
23	Regnum Sky Tower
24	Tepe Prime
25	The Paragon Tower
26	Via Green İş Merkezi
27	Via Tower
28	Via Twins
29	YDA Center
30	Yıldırım Kule

Her bir bağımsız ofis birimine ilişkin olarak konumsal, yapısal, fiziksel, çevresel ve piyasa temelli nitelikleri yansıtan toplam 92 değişken tanımlanmış ve analiz sürecine dâhil edilmiştir (Çizelge 6.3). Bu değişkenler, sadece yapının fiziksel özelliklerini değil, aynı zamanda çevresel erişilebilirlik (örneğin metro istasyonlarına, kamu kurumlarına veya alışveriş merkezlerine olan mesafeler), sosyal donatılar (güvenlik, spor salonu, restoran gibi) ve teknik altyapı (yangın sistemleri, jeneratör, açık ve kapalı otopark kapasitesi gibi) detaylarını da kapsamaktadır. Söz konusu değişkenler; kat sayısı, ofis alanı, bina yaşı, ofis sınıfı, aidat bedeli, tavan yüksekliği gibi içsel değişkenlerin yanı sıra, TBMM'ye, havaalanına, Eskişehir Yolu'na, metro istasyonuna veya üniversitelere olan mesafe gibi dışsal mekânsal değişkenleri de içermektedir. Ofis binalarına ilişkin ekonomik, sosyal ve mekânsal değişken sayısının artırılması ile daha sağlıklı kira ve değer tahminlerinin yapılması mümkündür. Ancak kullanılan değişken sayısı ve değişkenlere ilişkin veri aralığının artması, veri toplama, veri kalibrasyonu ve analiz için gerekli olan zamanın artmasına neden olmaktadır.

Çizelge 6.3 Ofis binalarına ilişkin değişkenler

No	Değişken Adı
1	Ada/Parsel
2	Anıtkabir’e Olan Mesafesi (m)
3	Ankara Ticaret Odasına Olan Mesafesi (m)
4	Araç Kiralama Hizmeti
5	Armada Alışveriş Merkezine Olan Mesafesi (m)
6	Ankara Şehirleri Terminal İşletmesine (AŞTİ) Olan Mesafesi (m)
7	Bayındır Hastanesine Olan Mesafesi (m)
8	Bilkent Şehir Hastanesi’ne Olan Mesafesi (m)
9	Bina Yaşı
10	Alışveriş Merkezi Olup Olmaması
11	Araç Şarj İstasyonu Olup Olmaması
12	Banka Şubesi Olup Olmaması
13	Çocuk Oyun Alanları Olup Olmaması
14	Çok Amaçlı Salon Olup Olmaması
15	Eczane Olup Olmaması
16	Mağaza Olup Olmaması
17	Restoran/Kafe Olup Olmaması
18	Sığınak Olup Olmaması
19	Sinema/Tiyatro Salonu Olup Olmaması
20	Spa & Wellness Olup Olmaması
21	Spor Salonu Olup Olmaması
22	Hidroforlu Su Sistemin Olup Olmaması
23	Binanın Arsa Yüz Ölçümü (m ²)
24	Arşiv ve Depo Destek
25	Binanın Asansör Sayısı
26	Binanın Yer Aldığı Alan İçerisindeki Cadde Sayısı
27	Blok Sayısı
28	Cephe Sayısı
29	Cumhurbaşkanlığı Külliyesine Olan Mesafesi (m)
30	Çalışma ve Sosyal Güvenlik Bakanlığı’na Olan Mesafesi (m)
31	Dışişleri Bakanlığı’na Olan Mesafesi (m)
32	Enerji ve Tabii Kaynaklar Bakanlığı’na Olan Mesafesi (m)
33	Eskişehir Yoluna Olan Mesafesi (m)
34	Eskişehir Yolu Cephesi
35	Etkinlik Organizasyonu Hizmeti
36	Güvenlik Hizmeti (7/24)
37	Havaalanı Transferi Hizmeti
38	Havaalanına Olan Mesafesi (m)
39	Hazine ve Maliye Bakanlığına Olan Mesafesi (m)
40	İş Kolu
41	Jeneratör
42	JW Marriott Oteline Olan Mesafesi (m)
43	Kapalı Devre TV

Çizelge 6.3 Ofis binalarına ilişkin değişkenler (devamı)

No	Değişken Adı
44	Kartlı Geçiş
45	Kat Mülkiyeti
46	Kat Sayısı
47	Kızılay'a Olan Mesafesi (m)
48	Kira
49	Kira Tarihi
50	Konum
51	Konya Yolu Cephesi
52	Konya Yoluna Olan Mesafesi (m)
53	Kuru Temizleme Hizmeti
54	Kültür ve Turizm Bakanlığı'na Olan Mesafesi (m)
55	m ² 'ye 1 Kapalı Otopark
56	Merkezi Havalandırma Sistemi
57	Merkezi Isıtma Sistemi
58	Metro İstasyonuna Olan Mesafesi (m)
59	Ofiste Mutfak Bulunma Durumu
60	Oda Sayısı
61	ODTÜ'ye Olan Mesafesi (m)
62	Ofis Adı
63	Ofis Aidat Metrekare Bedeli (TL)
64	Ofis Binası Metrekare aralıkları (m ²)
65	Ofis Sınıfı
66	Ofis Tavan Yüksekliği (m)
67	Temizlik Hizmeti
68	Kiralanan Ofisin Brüt Alanı
69	Kiralanan Ofisin Katı
70	İç Mekânı Tamamlanmış/Tamamlanmamış Ofis
71	Ofiste Ankastre Beyaz Eşya Bulunma Durumu
72	Ofiste Balkon Bulunma Durumu
73	Oto Kuaför Hizmeti
74	Otopark (Açık)
75	Otopark (Kapalı)
76	Otopark Kapasitesi
77	Posta, Kargo Yönetimi
78	Resepsiyon Hizmeti
79	Rezervasyon ve Bilet Hizmeti
80	Sayıştay'a Olan Mesafesi (m)
81	Seyahat Danışmanlığı Hizmeti
82	TBMM'ye Olan Mesafesi (m)
83	Teknik Destek Hizmeti
84	Terzi, Kuaför, Lostra Hizmeti
85	Ticaret Bakanlığı'na Olan Mesafesi (m)
86	TOBB ETÜ Hastanesi'ne Olan Mesafesi (m)

Çizelge 6.3 Ofis binalarına ilişkin değişkenler (devamı)

No	Değişken Adı
87	Toplam İnşaat Alan (m ²)
88	Toplam Ofis Sayısı
89	TPAO Genel Müdürlüğü'ne Olan Mesafesi (m)
90	WC
91	Yangın Algılama ve Güvenlik Sistemi
92	Yangın Merdiveni

Makine öğrenmesi modellerinde yüksek genelleme kapasitesine ulaşmak, aşırı öğrenme riskini azaltmak ve gereksiz model karmaşıklığını önlemek için veri seti üzerinde sistematik ve çok aşamalı bir ön işleme süreci yürütülmüştür. Bu süreçte öncelikle eksik veri oranı yüksek olan değişkenler değerlendirme dışı bırakılmış ve daha sonra hedef değişken üzerindeki etkisi istatistiksel olarak anlamlı olmayan değişkenler veri setinden çıkarılmıştır. Uygulanan değişken seçimi yöntemiyle yalnızca bilgi değeri taşıyan ve model performansına katkı sunabilecek değişkenlerin korunması hedeflenmiştir. Bu doğrultuda, başlangıçta 92 değişkenden oluşan veri seti, 57 anlamlı ve etkili değişkenle sınırlandırılmıştır (Çizelge 6.4). Seçilen değişkenler; konumsal mesafeler (örneğin, metro, kamu kurumları, merkezler), yapısal özellikler (kat sayısı, blok sayısı, alan büyüklüğü gibi), sosyal ve teknik donatılar (güvenlik, temizlik, restoran, kuru temizleme gibi) ile ofis sınıfı ve kat durumu gibi piyasaya özgü nitelikleri kapsamaktadır. Bu veri indirgeme süreci sayesinde, modellerin daha güvenilir, daha yorumlanabilir ve aşırı uyuma karşı daha dirençli hale getirilmesi sağlanmıştır. Böylelikle klasik ve yapay zekâ temelli modelleme yaklaşımları için daha istikrarlı ve anlamlı sonuçlar elde edilmesi mümkün olmuştur.

Çizelge 6.4 Ön işleme sonrası elde edilen değişkenler

No	Değişken Adı
1	Anıtkabir'e Olan Mesafesi (m)
2	Ankara Ticaret Odasına Olan Mesafesi (m)
3	Araç Kiralama Hizmeti
4	Armada Alışveriş Merkezine Olan Mesafesi (m)
5	AŞTİ'ye Olan Mesafesi (m)
6	Bayındır Hastanesine Olan Mesafesi (m)
7	Bilkent Şehir Hastanesi'ne Olan Mesafesi (m)

Çizelge 6.4 Ön işleme sonrası elde edilen değişkenler (devamı)

No	Değişken Adı
8	Bina yaşı
9	Alışveriş Merkezi Olup Olmaması
10	Banka Şubesi Olup Olmaması
11	Çocuk Oyun Alanları Olup Olmaması
12	Çok Amaçlı Salon Olup Olmaması
13	Eczane Olup Olmaması
14	Restoran/Kafe Olup Olmaması
15	Sinema/Tiyatro Salonu Olup Olmaması
16	Spa & Wellness Olup Olmaması
17	Spor Salonu Olup Olmaması
18	Blok Sayısı
19	Cumhurbaşkanlığı Külliyesine Olan Mesafesi (m)
20	Çalışma ve Sosyal Güvenlik Bakanlığı'na Olan Mesafesi (m)
21	Dışişleri Bakanlığı'na Olan Mesafesi (m)
22	Enerji ve Tabii Kaynaklar Bakanlığı'na Olan Mesafesi (m)
23	Eskişehir Yoluna Olan Mesafesi (m)
24	Eskişehir Yolu Cephesi
25	Etkinlik Organizasyonu Hizmeti
26	Havaalanı Transferi Hizmeti
27	Havaalanına Olan Mesafesi (m)
28	Hazine ve Maliye Bakanlığına Olan Mesafesi (m)
29	İş Kolu
30	JW Marriott Oteline Olan Mesafesi (m)
31	Kat Sayısı
32	Kızılay'a Olan Mesafesi (m)
33	Kira
34	Konum
35	Konya Yolu Cephesi
36	Konya Yoluna Olan Mesafesi (m)
37	Kuru Temizleme Hizmeti
38	Kültür ve Turizm Bakanlığı'na Olan Mesafesi (m)
39	Metro İstasyonuna Olan Mesafesi (m)
40	Oda Sayısı
41	ODTÜ'ye Olan Mesafesi (m)
42	Ofis adı
43	Ofis Sınıfı
44	Kiralanan Ofisin Brüt Alanı
45	Kiralanan Ofisin Katı
46	İç Mekânı Tamamlanmış/Tamamlanmamış Ofis
47	Oto Kuaför Hizmeti
48	Otopark Kapasitesi
49	Posta, Kargo Yönetimi
50	Rezervasyon ve Bilet Hizmeti

Çizelge 6.4 Ön işleme sonrası elde edilen değişkenler (devamı)

No	Değişken Adı
51	Sayıştay’a Olan Mesafesi (m)
52	Seyahat Danışmanlığı Hizmeti
53	TBMM’ye Olan Mesafesi (m)
54	Terzi, Kuaför, Lostra Hizmeti
55	Ticaret Bakanlığı’na Olan Mesafesi (m)
56	TOBB ETÜ Hastanesi’ne Olan Mesafesi (m)
57	TPAO Genel Müdürlüğü’ne Olan Mesafesi (m)

Veri tutarlılığını sağlamak ve gerçekleştirilen analizlerin güvenilirliğini artırmak amacıyla, çalışma kapsamına alınan ofis bina sayısı 30’dan 14’e, kira verisi sayısı ise 2.610’dan 2.228’e düşürülerek örneklem havuzu optimize edilmiştir (Çizelge 6.5). Bu örneklem daraltma süreci, çoklu veri kaynağı kullanımıyla oluşabilecek tutarsızlıkların önüne geçmek, eksik ya da şüpheli gözlemleri hariç tutmak ve yalnızca yüksek güvenilirlik düzeyine sahip ofis birimlerini analiz kapsamına almak amacıyla yürütülmüştür. Bu kapsamda seçilen 14 ofis binası temsil gücü yüksek ve farklı mekânsal kümeleri yansıtan nitelikli ticari gayrimenkulleri içermektedir. Örneğin, 1071 Plaza (433 veri), YDA Center (475 veri), Tepe Prime (251 veri) ve Mahall Ankara (212 veri) gibi yüksek sayıda güvenilir gözleme sahip binalar, model performansının artırılması açısından özellikle önem arz etmektedir. Örneklem daraltmasıyla birlikte, modelin hem hesaplamalı verimliliği hem de yorumlanabilirliği geliştirilmiştir.

Çizelge 6.5 Veri setindeki ofis binalarının son dağılımı

No	Bina Adı	Kira Veri Sayısı
1	1071 Plaza	433
2	Arma Kule	54
3	Besa Kule	71
4	Ege Plaza	54
5	Koç Kuleleri	56
6	Mahall Ankara	212
7	Maidan	156
8	Next Level	150
9	Regnum Sky Tower	92
10	Tepe Prime	251

Çizelge 6.5 Veri setindeki ofis binalarının son dağılımı (devamı)

No	Bina Adı	Kira Veri Sayısı
11	The Paragon Tower	82
12	Via Green İş Merkezi	76
13	Via Twins	66
14	YDA Center	475
	TOPLAM	2228

Analizde yer alan ofis binalarının mekânsal dağılımı görselleştirilmiş ve böylece lokasyon temelli farklılıkların coğrafi düzlemde sistematik biçimde değerlendirilmesi mümkün kılınmıştır (Şekil 6.1). Bu mekânsal görselleştirme, modelleme sürecinde konum değişkeninin etkisinin daha somut biçimde analiz edilmesine olanak tanımakta; özellikle ofislerin yer aldığı bölgeler arasındaki erişilebilirlik, altyapı ve çevresel avantaj farklılıklarının mekânsal bağlamda yorumlanmasını desteklemektedir.



Şekil 6.1 Ofis binalarının harita üzerinde gösterimi (Anonymous 2025a)

Son aşamada, başlangıçta yer alan 57 bağımsız değişkenin önemli bir kısmı istatistiksel açıdan yüksek çoklu bağlantı, anlamsız varyans, düşük korelasyon gücü ve bilgi tekrarı gibi nedenlerle analiz kapsamı dışında bırakılmıştır. Örneğin, YDA Center gibi büyük ofis binalarında tüm bağımsız ofis birimleri için “toplam otopark sayısı” değişkeni aynıdır. Bu tür değişkenler binaya özgü olmakla birlikte, bina içinde yer alan farklı ofisler

arasında herhangi bir ayırt edici bilgi sağlamamakta; bu da modele katkı sağlamayan sabit değişken niteliği taşımaktadır. Diğer bir ifadeyle, bu değişkenler varyans üretmediği için hedef değişken olan kira üzerinde ayırt edici bir etkide bulunmamaktadır. Ayrıca, bazı değişkenler arasında yüksek düzeyde korelasyon tespit edilmiş olup bu durum çoklu doğrusal bağlantı sorununu gündeme getirmiştir. Örneğin, “toplam kat sayısı” ile “binanın yüksekliği” gibi değişkenler yüksek korelasyon göstermekte ve modelde birlikte yer aldıklarında parametre tahminlerinin kararsız hale gelmesine neden olmaktadır. Bu nedenle, bilgi tekrarı yaratan bu tür değişkenler arasından yalnızca açıklayıcılığı yüksek olanlar seçilmiştir.

Kategorik değişkenlerin analizinde ise, bazı nitelikler kiraya etkisi bakımından istatistiksel olarak anlamlı bulunmamış; kimi zaman da örneklem içinde dengesiz dağılımlar sergilediği için modele anlamlı katkı sağlamamıştır. Ayrıca, modelde çok sayıda kategorik değişkenin yer alması, veri setindeki örneklem hacmine kıyasla parametrik yükün artmasına ve model karmaşıklığının gereksiz şekilde yükselmesine neden olmuştur. Gerçekleştirilen çok değişkenli analizler sonucunda, ofis kirasını istatistiksel olarak anlamlı düzeyde etkileyen ve yüksek açıklayıcılık gücüne sahip beş temel değişken tespit edilmiştir (Çizelge 6.6).

Değişkenler, kira tahmin modellerinde belirleyici rol oynamaları nedeniyle ayrıntılı olarak incelenmiştir. Sunulan bu değişkenler sırasıyla; ofis adı, kiralanan ofisin brüt alanı (m²), iç mekânı tamamlanmış ve/veya tamamlanmamış ofis, oda sayısı ve kiralanan ofisin bulunduğu kat şeklinde tanımlanmıştır. Bu değişkenler, ofislerin fiziksel ve yapısal niteliklerine doğrudan bağlı bulunmakta ve piyasa değerlerini de belirlemektedir.

Çizelge 6.6 Ofis kirasını etkileyen nihai değişkenler

No	Değişken	Değişken Veri Türü
1	Ofis Adı	Kategorik
2	Kiralanan Ofisin Brüt Alanı (m ²)	Sürekli
3	İç Mekânı Tamamlanmış/Tamamlanmamış Ofis	Kategorik
4	Oda Sayısı	Sürekli
5	Kiralanan Ofisin Katı	Sürekli

Veri setindeki ofisler A+, A ve B+ olmak üzere üç farklı sınıfa ayrılmıştır. A sınıfı ofislerden 288 adet bulunurken, A+ sınıfı ofisler 1.482 adet ile en yüksek sayıya sahiptir. B+ sınıfı ofisler ise 458 adet olarak yer almaktadır (Çizelge 6.7) Bu dağılım, A+ sınıfı ofislerin kiralama açısından daha yaygın tercih edildiğini, buna karşın A sınıfı ofislerin daha sınırlı bir kullanımda kaldığını ortaya koymaktadır.

Çizelge 6.7 Ofis sınıfı bazında toplanan kira verileri

Sınıf Adı	Sayı
A+	1.482
B+	458
A	288

Ofis binalarının yaş aralıklarına göre, 5-7 yaş aralığındaki binalar, 1.368 adet ile en yüksek sayıya sahip olup bu kategori ofis binalarının büyük bir kısmını oluşturmaktadır. Bunu sırasıyla 9-11 yaş aralığındaki 362 bina ve 13-15 yaş aralığındaki 251 bina takip etmektedir. 7-9 yaş aralığında ise sadece 181 bina bulunmaktadır. En düşük sayı, 11-13 yaş aralığında yer alan 66 bina ile kaydedilmiştir (Çizelge 6.8). Bu dağılım, ofis binalarının çoğunlukla daha genç yaş aralıklarında yoğunlaştığını göstermektedir.

Çizelge 6.8 Ofis binalarının yaş gruplarına göre kira gözlem sayıları

Yaş Aralığı	Sayı
[5, 7]	1.368
[7, 9]	181
[9, 11]	362
[11, 13]	66
[13, 15]	251

Ofis binalarının blok sayısına göre dağılımına bakıldığında, 2-3 blok aralığındaki binalar 1.046 adet ile en yüksek sayıya sahiptir ve bu kategori ofis binalarının çoğunluğunu oluşturmaktadır. Bunu sırasıyla 1-2 blok aralığındaki 551 bina ve 4-5 blok aralığındaki 475 bina takip etmektedir. En düşük sayı ise 3-4 blok aralığında yer alan 156 bina ile kaydedilmiştir. Bu dağılım, ofis binalarının genellikle 2 ila 3 bloktan oluştuğunu ve daha büyük blok sayılarına sahip binaların nispeten daha az olduğunu göstermektedir (Çizelge 6.9).

Çizelge 6.9 Blok sayısı aralıklarına göre kira gözlem sayıları


Blok Aralığı	Sayı
[1, 2]	551
(2, 3]	1.046
(3, 4]	156
(4, 5]	475

Ofis binalarındaki iş kollarına göre dağılıma göre sağlık hizmetleri, %70,11 ile en yüksek oranı temsil etmekte ve iş kolları arasında açık ara lider konumdadır. Bunu %11,27 ile bilişim, yazılım ve donanım hizmetleri, %8,35 ile inşaat ve mühendislik hizmetleri, %7,32 ile hukuk ve danışmanlık hizmetleri izlemektedir. En düşük oran ise %2,96 ile finansal işlemler ve gayrimenkul danışmanlığı hizmetleri sektörüne ait bulunmaktadır (Çizelge 6.10). Belirtilen dağılım, bilişim sektörünün iş kolları arasında baskın bir yere sahip olduğunu ve diğer sektörlerin ise görece daha az temsil edildiğini göstermektedir.

Çizelge 6.10 Veri setindeki ofislerin hizmet türlerine göre dağılımı


Hizmet Türü	Yüzde (%)
Bilişim, Yazılım ve Donanım Hizmetleri	11,27
Finansal ve Gayrimenkul Danışmanlık Hizmetleri	2,96
Hukuk ve Danışmanlık Hizmetleri	7,32
İnşaat ve Mühendislik Hizmetleri	8,35
Sağlık Hizmetleri	70,11

Ofis binalarının Eskişehir yoluna ve Konya yoluna cephe durumları incelendiğinde mavi renkle gösterilen Eskişehir yolu cephesi ve turuncu renkle gösterilen Konya yolu cephesi, binalar arasında eşit ya da farklı cephe durumunu göstermektedir. Birçok ofis binası Eskişehir yoluna cephe durumuna sahiptir. İki yol cephesine sahip binalar, ticari faaliyetlerde daha yüksek görünürlük ve ulaşılabilirlik sağlayabilmektedir (Şekil 6.2). İlke olarak ticari gayrimenkul pazarında binaların konumu ve görünürlüğünün en önemli talep ve değer ölçütü olduğunun gözden uzak tutulmaması gerekir (Tanrıvermiş 2017).



Şekil 6.2 Ofis binalarının Eskişehir ve Konya yoluna cephe durumları


Ofis binalarının Eskişehir yoluna ve Konya yoluna olan mesafeleri (metre cinsinden) karşılaştırmalı olarak gösterilmektedir (Şekil 6.3). Mavi çizgi, Eskişehir yoluna olan mesafeleri ve kırmızı çizgi ise Konya yoluna olan mesafeleri temsil etmektedir. Eskişehir yoluna olan mesafeler, çoğu bina için 1.000 metre altında seyretmekte ve oldukça düşük değerlere sahip bulunmaktadır. Konya yoluna olan mesafeler ise, daha geniş bir aralıkta değişiklik göstermekte ve bazı binalar için oldukça yüksektir. Örneğin, Mahall Ankara 5.300 metre, Tepe Prime 5.230 metre ve Via Green İş Merkezi 6.000 metre gibi yüksek mesafelere sahiptir. Bu sonuçlar, göre ofis binalarının her iki ana yola olan erişilebilirlik düzeylerini analiz etmek için önemli bir veri sunmakta ve özellikle ticari faaliyetlerin yoğunlaştığı bölgelerin değerlendirilmesine yardımcı olması bakımından önemli görülmektedir. Esasen son yıllarda başkentte iki önemli şehirlerarası yolun çevresinde ticari gayrimenkul yatırımlarının hız kazandığı ve yeni merkezi iş alanlarının da bu bölgelerin üzerinde ve çevresinde konumlandığı gözden uzak tutulmamalıdır. Birçok firmanın ofis için yer ve bina seçimi yapmasında da binanın adı ve sunduğu imkanlar kadar, ofis binasının kent içindeki konumu ve bilinirlik ile paydaşların erişilebilirliğinin de çok önemli olduğu vurgulanmaktadır (Demirkaya vd. 2025).



Şekil 6.3 Ofis binalarının Eskişehir ve Konya yoluna olan mesafeleri

Ofis binalarının metro istasyonuna ve AŞTİ'ye olan mesafeleri (metre cinsinden) karşılaştırmalı olarak gösterilmektedir (Şekil 6.4). Mavi çizgi metro istasyonlarına olan mesafeleri; kırmızı çizgi ise AŞTİ'ye olan mesafeleri temsil etmektedir. Çoğu ofis binasının metro istasyonlarına olan mesafesi 500 metre civarında veya daha azdır. Besa Kule (250 metre), Koç Kuleleri (100 metre) ve Next Level (300 metre) gibi binalar metro istasyonlarına oldukça yakın konumlanmıştır. Ege Plaza (2.000 metre), metro istasyonuna en uzak olan bina olarak dikkat çekmektedir. AŞTİ'ye olan mesafelerde daha büyük bir değişkenlik görülmektedir. Mahall Ankara (5.100 metre), Tepe Prime (5.030 metre) ve Via Green İş Merkezi (5.800 metre), AŞTİ'ye en uzak ofis binalarıdır. Buna karşın, Koç Kuleleri (100 metre), Next Level (700 metre) ve Arma Kule (900 metre) gibi binalar AŞTİ'ye oldukça yakın konumlanmıştır.

Araştırma için oluşturulan veri seti; ofis binalarının toplu taşıma erişimi ve AŞTİ gibi önemli ulaşım merkezlerine yakınlığını analiz etmek için önemli bir bilgi sağlaması bakımından da önemli görülmektedir. Metro hatlarına ve AŞTİ'ye yakın binalar, ulaşım kolaylığı açısından daha avantajlı konumda bulunmaktadır. Özellikle kısa mesafelere sahip binalar, ticari ve sosyal faaliyetler için tercih edilebilirliği artırabilmektedir.



Şekil 6.4 Ofis binalarının metro istasyonuna ve AŞTİ'ye olan mesafeleri

Ofis binalarının sahip olduğu sosyal ve ticari olanaklara ilişkin veriler sunulmaktadır (Çizelge 6.11). Bu olanaklar arasında ofis binalarının kullanıcı ihtiyaçlarına yönelik sunduğu hizmet çeşitliliğini yansıtan banka şubesi, çok amaçlı salon, eczane, restoran/kafe, sinema/tiyatro salonu, spa/wellness, spor salonu ve çocuk oyun alanları yer almaktadır. Next Level ve YDA Center, neredeyse tüm olanaklara sahip olarak dikkat çekerken, Mahall Ankara, Maidan ve Tepe Prime gibi binalar da kullanıcıların sosyal ve ticari ihtiyaçlarına önemli ölçüde yanıt vermektedir. Bununla birlikte Arma Kule, The Paragon Tower, Via Green İş Merkezi ve Via Twins gibi binalar, sınırlı sayıda olanak sunarak sosyal ve ticari bakımdan daha düşük donanıma sahip bulunmaktadır. Banka şubesi, sinema/tiyatro salonu ve çocuk oyun alanları gibi özellikler yalnızca belirli binalarda bulunmakta ve nadir olanaklar arasında yer almaktadır. Bu durum, ofis binalarının sosyal alan ve ticari hizmet çeşitliliği açısından farklılık gösterdiğini ve daha fazla olanak sunan yapıların kullanıcılar için cazibe merkezi olabileceğini ortaya koymaktadır.

Çizelge 6.11 Ofis binalarında bulunan imkanlar

Ofis Adı	Banka Şubesi	Çok Amaçlı Salon	Eczane	Restoran Kafe	Sinema Tiyatro Salonu	Spa Wellness	Spor Salonu	Çocuk Oyun Alanları
1071 Plaza	0	0	1	1	0	0	1	0
Arma Kule	0	1	0	1	0	0	0	0
Besa Kule	0	1	1	1	0	0	0	0
Ege Plaza	0	1	0	0	0	0	0	1
Koç Kuleleri	0	1	0	0	0	0	0	0
Mahall Ankara	1	1	1	1	0	0	0	0
Maidan	1	0	1	1	0	0	0	0
Next Level	1	1	1	1	1	1	1	1
Regnum Sky Tower	1	1	1	1	0	1	1	0
Tepe Prime	1	1	1	1	0	0	0	0
The Paragon Tower	0	1	0	1	0	0	0	0
Via Green İş Merkezi	0	1	0	1	0	0	0	0
Via Twins	0	1	0	1	0	0	0	0
YDA Center	1	1	1	0	1	1	1	1

Var olma durumu: 1 / Var olmama durumu: 0

Ofis binalarının kullanıcılarına sunduğu hizmetlerin çeşitliliği verilere dayalı olarak ortaya konulmaktadır (Çizelge 6.12). Hizmetler arasında araç kiralama, etkinlik organizasyonu, havaalanı transferi, kuru temizleme, oto kuaför, posta ve kargo yönetimi, rezervasyon ve bilet işlemleri, seyahat danışmanlığı, terzi, kuaför ve lostra hizmetleri bulunmaktadır. Ofis binaları arasında en fazla hizmet sunan yapı, tüm hizmetleri sağlayan YDA Center olmuştur. Bu bina, sunduğu kapsamlı hizmet yelpazesi ile kullanıcıların ihtiyaçlarına yönelik maksimum düzeyde bir çözüm sağlamaktadır.

Buna karşılık, The Paragon Tower, Via Green İş Merkezi ve Via Twins gibi ofis binaları, bu hizmetlerin hiçbirini sunmamaktadır. 1071 Plaza, Ege Plaza, Next Level ve Regnum Sky Tower gibi bazı ofis binaları, sınırlı sayıda ancak dikkat çeken hizmetler sunmaktadır. Özellikle, oto kuaför hizmeti birçok ofis binasında yaygın olarak sağlanırken, etkinlik organizasyonu, havaalanı transferi, seyahat danışmanlığı gibi hizmetlerin yalnızca belirli binalarda sunulduğu görülmektedir. Bu durum, ofis binalarının sunduğu hizmetlerin kapsamının kullanıcı ihtiyaçlarına yönelik olarak büyük ölçüde çeşitlilik gösterdiğini ve daha geniş hizmet yelpazesi sunan binaların kullanıcılar açısından daha cazip hale gelebileceğini ortaya koymaktadır.

Çizelge 6.12 Ofis binalarında sunulan hizmetler

Ofis Adı	Araç Kiralama	Etkinlik Organizasyonu	Havaalanı Transferi	Kuru Temizleme	Oto Kuaför	Posta, Kargo Yönetimi	Rezervasyon ve Bilet	Seyahat Danışmanlığı	Terzi, Kuaför, Lostra
1071 Plaza	0	0	0	1	1	1	0	0	1
Arma Kule	0	0	0	0	0	0	0	0	1
Besa Kule	0	0	0	0	1	0	0	0	0
Ege Plaza	1	0	1	0	0	0	0	0	0
Koç Kuleleri	0	0	0	0	0	0	0	0	1
Mahall Ankara	0	0	0	0	0	0	0	0	0
Maidan	0	0	0	0	1	0	0	0	1
Next Level	1	0	0	0	0	0	0	0	1
Regnum Sky Tower	0	0	0	0	1	0	0	1	0
Tepe Prime	0	0	0	0	0	0	0	0	0
The Paragon Tower	0	0	0	0	0	0	0	0	0
Via Green İş Merkezi	0	0	0	0	0	0	0	0	0
Via Twins	0	0	0	0	0	0	0	0	0
YDA Center	1	1	1	1	1	1	1	1	1

Var olma durumu: 1 / Var olmama durumu: 0

Araştırmada kullanılan eğitim ve test veri setleri, toplamda 2.228 gözlemden oluşmaktadır. Bu gözlemlerin 1.784'ü eğitim veri setinde, 444'ü ise test veri setinde yer almaktadır. Ofislere ilişkin temel değişkenler ve kiraya dair örnekler aşağıda sunulmuştur (Çizelge 6.13). Örneğin, 234 numaralı ofis, 1071 Plaza içerisinde konumlanmakta ve brüt alanı 86 m²'dir. İnceleme konusu ofisin aylık kirası 359,22 TL/m² olarak belirlenmiş, iç mekânı tamamlanmış, 3 odalı ve 7. katta yer aldığı tespit edilmiştir. Bu yapılandırma, modelleme sürecinde kullanılan veri setinin kapsamını ve ofislere ilişkin temel özelliklerin çeşitliliğini sistematik biçimde ortaya koymaktadır.

Çizelge 6.13 Ofis kirası için örnek veri seti

No	Kira	Ofis Adı	Alan	İç Mekânı Tamamlanmış/ Tamamlanmamış Ofis	Oda Sayısı	Kat
7	404,319	1071 Plaza	130	1	3	9
14	268,1593	1071 Plaza	103	0	3	8
17	347,9737	1071 Plaza	127	1	3	13
436	303,9886	Arma Kula	110	1	4	15
234	359,2242	1071 Plaza	86	1	3	7
439	366,5599	Arma Kula	96	1	3	5
506	304,8259	Besa Kule	90	0	3	3
510	416,4045	Besa Kule	200	1	5	2
559	316,1094	Ege Plaza	860	1	6	15
564	344,0212	Ege Plaza	126	1	4	19
614	234,8639	Koç Kuleleri	67	0	2	4
641	368,5198	Koç Kuleleri	240	1	6	8
670	266,6372	Mahall Ankara	67	0	2	7
676	256,4752	Mahall Ankara	200	0	6	6
678	263,0515	Mahall Ankara	90	0	3	8
895	315,2485	Maidan	1500	1	6	14
902	360,6139	Maidan	60	1	2	5
905	398,9428	Maidan	75	1	2	7
1043	526,1031	Next Level	150	1	4	9
1047	467,1589	Next Level	80	1	2	5
1052	524,9248	Next Level	75	1	2	18
1188	473,9684	Regnum Sky Tower	120	1	4	22
1203	403,3393	Regnum Sky Tower	180	1	5	9
1281	301,4132	Tepe Prime	144	1	4	8
1286	317,0602	Tepe Prime	174	1	6	9
1524	601,7385	Tepe Prime	144	1	4	9
1531	414,0414	The Paragon Tower	90	1	3	9
1533	380,4852	The Paragon Tower	140	1	4	5
1620	203,2184	Via Green İş Merkezi	145	0	6	5
1621	258,4795	Via Green İş Merkezi	57	1	2	3
1693	364,2166	Via Twins	73	1	2	4

Çizelge 6.13 Ofis kirası için örnek veri seti (devamı)

No	Kira	Ofis Adı	Alan	İç Mekânı Tamamlanmış/ Tamamlanmamış Ofis	Oda Sayısı	Kat
1694	379,8258	Via Twins	70	1	2	4
2209	589,2289	YDA Center	152	1	4	9
2213	578,8307	YDA Center	152	1	4	16
2214	570,7432	YDA Center	120	1	4	17
2216	652,7029	YDA Center	190	1	4	22
2223	670,6683	YDA Center	152	1	4	8
2225	637,1349	YDA Center	200	1	6	5
2227	679,6105	YDA Center	90	1	3	8

6.2 Verilerin Analizinde Kullanılan Yöntemler

Araştırma kapsamında, ofis kiralarını etkileyen değişkenlerin analiz edilmesi, yalnızca gayrimenkul değerlendirme süreçlerinin değil, aynı zamanda ofis piyasasındaki arz-talep dinamiklerinin anlaşılması açısından da kritik bir öneme sahiptir. Bu çerçevede bağımlı değişken olarak “kira (TL/m²)” belirlenmiş ve bağımsız değişkenler olarak da; “ofis adı”, “kiralanan ofisin brüt alanı (m²)”, “iç mekânı tamamlanmış ve/veya tamamlanmamış ofis olması”, “oda sayısı” ve “kiralanan ofisin bulunduğu katı” olarak dikkate alınmıştır.


Veri setinin yapısal özelliklerini ortaya koymak ve değişkenler arasındaki ilişkileri görsel olarak analiz edebilmek amacıyla R programlama dili ve bu dile özgü veri görselleştirme kütüphaneleri kullanılmıştır. Bu araçlar yardımıyla, değişkenlerin dağılımı, merkezi eğilimleri, aykırı değerleri ve korelasyonları grafiksel olarak sunulmuş; elde edilen bulgular, modelleme aşamasında kullanılacak değişken seçimi ve ön işleme adımları için yol gösterici olmuştur. Böylece hem açıklayıcı veri analizi hem de modelleme öncesi ön değerlendirme süreçleri bilimsel bir çerçevede yürütülmüştür.

Dağılım grafikleri, değişkenlerin frekans yapısını; serpmme grafikleri, bağımsız değişkenlerle kira arasındaki ilişkileri; kutu grafikleri ise değişkenlerin yayılımı ve uç değerlerini göstermektedir. Bu grafikler, ofis kiralarını etkileyen temel faktörlerin görsel olarak analiz edilmesini ve modelde hangi değişkenlerin daha açıklayıcı olduğunu belirlemeyi kolaylaştırmaktadır. Aşağıda yer alan şekiller, grafikler ve bunlara ilişkin

açıklamalar, değişkenlerin istatistiksel niteliklerini kapsamlı bir şekilde analiz ederek, modelleme aşamasında dikkate alınması gereken temel hususları ortaya koymaktadır.

Veri setinde yer alan bağımlı değişken olan kira (TL/m²) değerlerinin dağılımı görselleştirilmiştir (Şekil 6.5). Analiz sonuçlarına göre, ofis kiralарının büyük ölçüde 350,00 TL/m² ile 400,00 TL/m² aralığında yoğunlaştığı ve dağılımın sağa çarpık bir yapı sergilediği görülmektedir. Bu durum, düşük kiralарın veri setinde daha yaygın olduğunu, ancak nadir de olsa yüksek kiralara rastlandığını ortaya koymaktadır.


Pozitif çarpıklığın ve uç değerlerin varlığı, ofis pazarında kira düzeylerinin geniş bir çeşitlilik gösterdiğine ve kiralарı etkileyen çok sayıda değişkenin etkili olduğuna işaret etmektedir. Bu dağılım yapısı, modelleme sürecinde hem varyans hem de uç değerlerin dikkatle ele alınması gerektiğini ortaya koymaktadır.



Şekil 6.5 Kira (TL/m²) verilerinin dağılımsal incelemesi

Veri setindeki kira (TL/m²) değişkeninin dağılımını daha normal bir forma yaklaştırmak amacıyla logaritmik dönüşüm uygulanmış ve elde edilen sonuçlar görselleştirilmiştir


(Şekil 6.6). Elde edilen bulgular, kiraların belirli bir aralıkta yoğunlaştığını ve dağılımın tek tepe noktasına sahip olduğunu göstermektedir. Logaritmik dönüşüm sonrasında, verinin sağa çarpıklığı önemli ölçüde azalmış ve dağılım daha simetrik bir görünüm kazanmıştır. Modelleme aşamasında varsayılan normal dağılım kabulü için önemli bir iyileşme sağlanmaktadır. Ayrıca kiraların belirli değer aralıklarında yoğunlaşması, pazar dinamikleri açısından belirli segmentlerin varlığına işaret etmekte olup PB çalışmalarında dikkate alınması gereken önemli bir bulgu sunmaktadır. Logaritmik dönüşümle elde edilen bu simetrik yapı, tahmin modellerinin performansını artırma potansiyeline sahiptir.



Şekil 6.6 Logaritmik dönüştürülmüş kira (TL/m²) verisinin dağılım özellikleri


Kira (TL/m²) değişkenine ait kutu grafiği, veri setinde önemli ölçüde çarpıklık ve aşırı uç değerlerin varlığını ortaya koymaktadır (Şekil 6.7). Medyan değer kutunun merkezine yakın konumlanmış olması, dağılımın genel anlamda simetrik bir yapı gösterdiğine işaret etse de özellikle üst sınırların ötesinde yoğunlaşan aşırı uç değerler, veri setindeki bazı kiraların diğerlerinden anlamlı derecede yüksek olduğunu göstermektedir. Ofis kiralarının tahmininde istatistiksel modellerin uç değerlere duyarlılığı göz önünde bulundurularak daha esnek ve dayanıklı yöntemlerin tercih edilmesini gerekli

kılmaktadır. Ayrıca, veri setinde gözlemlenen bu varyasyon, pazar bölümlendirmesi ve farklı alt pazarların analiz edilmesi gerekliliğini bir kez daha desteklemektedir.



Şekil 6.7 Kira (TL/m²) verilerindeki aykırılıkların ve yayılımın gösterimi


Kira (TL/m²) değişkenine uygulanan logaritmik dönüşüm sonrası oluşturulan kutu grafiği, veri setinde aralık daralmasının sağlandığını ve dağılımdaki çarpıklığın önemli ölçüde azaltıldığını ortaya koymaktadır (Şekil 6.8). Logaritmik dönüşüm sonrasında, veri yapısının daha dengeli ve simetrik bir görünüm kazandığı gözlemlenmektedir. Şekil 6.7 ile Şekil 6.8 arasındaki farklılıklar, dönüşümün etkisini açık bir şekilde ortaya koymakta olup; özellikle ekonomik veriler gibi sağa çarpık dağılım gösteren veri setlerinde bu tür dönüşümlerin kullanılması, istatistiksel analizlerin güvenilirliğini artırmak açısından önemli bir yöntem olarak değerlendirilmektedir. Bu bağlamda, dönüşüm uygulaması, modelleme sürecinde daha doğru sonuçlar elde edilmesine katkı sağlamaktadır.



Şekil 6.8 Logaritmik dönüştürülmüş kira (TL/m²) verilerinin yayılımının incelemesi


Kiralanılan ofis alanlarının (m²) dağılımı incelendiğinde, ofis brüt alanlarının büyük kısmının 500 m²'den daha küçük mekanlardan oluştuğu ve piyasada daha çok küçük ve orta ölçekli ofislerin tercih edildiği görülmektedir (Şekil 6.9). Dağılımın sağa çarpık bir yapı sergilemesi, büyük metrekareli ofis alanlarının oldukça nadir olduğunu ve veri setinde uç değerlerin bulunduğunu göstermektedir.

Özellikle 1.000 m² üzerindeki ofislerin, pazar genelinde azınlıkta kaldığı anlaşılmaktadır. Ayrıca, oluşturulan kutu grafiği analizi, kiralanılan ofis alanlarının dağılımındaki merkezi eğilimleri ve uç değerleri sistematik bir biçimde ortaya koyarak, ofis pazarındaki mekânsal büyüklük tercihleri hakkında önemli bilgiler sunmaktadır.



Şekil 6.9 Ofis alanı (m²) verisinin dağılım ve yayılım özellikleri

Kiralanan ofis brüt alanı (m^2) ile kira (TL/m^2) arasındaki ilişkiyi gösteren serpmme grafiği incelendiğinde, iki değişken arasında belirli bir ilişki yapısının olduğu gözlemlenmektedir (Şekil 6.10). Analiz sonucunda, küçük metrekareli ofislerin kiralarda geniş bir dağılım gözlemlenirken, büyük metrekareli ofislerin kiralalarının daha dar bir aralıkta toplandığı tespit edilmektedir. Büyük ölçekli ofislerin genellikle daha düşük birim kira ile pazarda yer bulduğu, buna karşılık küçük ölçekli ofislerin fiyatlandırmasında ise daha fazla değişkenlik olduğu görülmektedir.



Şekil 6.10 Kiralanan ofis brüt alanı (m^2) ile kira (TL/m^2) arasındaki ilişkinin gösterimi

İlave olarak veri setinde bazı aykırı değerlerin varlığı dikkati çekmekte olup kiralanan alan arttıkça birim kirada azalma eğilimi gözlemlenmektedir. Ancak bu ilişki doğrusal bir yapı sergilememekte ve kiralaların yalnızca alan büyüklüğü ile açıklanamayacağı, modelde dikkate alınmayan bazı etkenlerin de sonuçlar üzerinde etkili olabileceği görülmektedir.

Ofis binaların geliştirilmesi, inşa edilmesi ve kullanıma açılması diğer birçok binadan farklı özellikler göstermektedir. Ofisler; tamamlanmamış (shell & core), tamamlanmış ve tefrişli olmak üzere üç farklı tipte kullanıcılara sunulmaktadır (Tanrıvermiş 2017;

Tanrıvermiş 2019). İncelenen ofislerin iç mekân durumlarına göre yapılan analiz sonuçlarına göre, iç mekânı “tamamlanmış” olan ofisler, toplam ofis stokunun %78,55’ini oluşturmaktadır. Bununla birlikte “natamam” veya “tamamlanmamış” durumdaki ofisler yalnızca %21,45’lik bir paya sahip olduğu görülmektedir (Çizelge 6.14). Belirtilen bulgular, araştırma kapsamında tamamlanmış ofislerin pazarda daha baskın olduğunu ve kullanıma hazır alanlara yönelik talebin yüksek seyrettiğini göstermesi bakımından önemli görülmektedir. Tamamlanmamış ofislerin görece düşük oranı, bu tür alanların sınırlı arzına ya da kiracılar tarafından daha az tercih edilmesine işaret etmektedir. Ayrıca, özelleştirme ve iç mekân düzenleme gibi ek maliyetler gerektirmesi, tamamlanmamış ofisleri kiralama sürecinde dezavantajlı konuma getirmektedir.

Çizelge 6.14 İç mekânı tamamlanmış/tamamlanmamış ofisler tablosu


Ofis Bina Adı	İç Mekânı Tamamlanmış Ofis	İç Mekânı Tamamlanmamış Ofis	Toplam
1071 Plaza	326	107	433
Arma Kule	39	15	54
Besa Kule	55	16	71
Ege Plaza	34	20	54
Koç Kuleleri	36	20	56
Mahall Ankara	104	108	212
Maidan	134	22	156
Next Level	132	18	150
Regnum Sky Tower	85	7	92
Tepe Prime	217	34	251
The Paragon Tower	62	20	82
Via Green İş Merkezi	61	15	76
Via Twins	50	16	66
YDA Center	415	60	475
Toplam	1.750	478	2.228
Yüzde (%)	78,55	21,45	

Oda sayısı dağılım grafiğine göre, en yaygın ofis tiplerinin 3 ve 4 odalı birimlerden oluştuğu görülmektedir (Şekil 6.11). 2 ve 6 odalı ofisler de dikkate değer bir paya sahiptir. Buna karşın, 1 odalı ofislerin oldukça sınırlı olduğu, 5 odalı ofislerin ise diğer kategorilere göre daha az bulunduğu gözlemlenmektedir. Bu dağılım, kiracıların genellikle orta

büyüklerdeki ofisleri tercih ettiğini ve küçük ölçekli ofislere yönelik arz ve talebin sınırlı kaldığını göstermektedir.


Kutu grafiğinde ise merkezi eğilimleri ve dağılımı görselleştirilmektedir. Medyan değerin 4 oda civarında olduğu ve ofislerin büyük bir kısmının 3 ila 5 oda arasında yoğunlaştığı görülmektedir. 1 ve 6 odalı ofisler ise uç değerler olarak değerlendirilmekte ve daha az sıklıkla gözlemlenmektedir. Alt ve üst çeyrekler arasındaki genişlik, oda sayısının çeşitliliğini ortaya koyarken, orta ölçekli ofislerin pazarda daha yaygın olduğu sonucuna ulaşılmaktadır.

Analizler, oda sayısının kira üzerindeki etkisini anlamak ve modelleme süreçlerinde dikkate almak açısından önemli bir değişken olduğunu göstermektedir. Özellikle, orta büyüklükteki ofislerin yaygınlığı, kira kestirim modellerinde önemli bir pazar dinamiği olarak karşımıza çıkmaktadır.



Şekil 6.11 Oda sayısının dağılım ve yayılım özellikleri

Oda sayısı ile kira (TL/m²) arasındaki ilişki incelendiğinde, oda sayısının artışına paralel belirgin bir kira trendi gözlenmemekle birlikte, kira değerlerinin genellikle 2 ila 6 oda aralığında yoğunlaştığı görülmektedir (Şekil 6.12). Her oda sayısı için geniş bir kira aralığı gözlemlenmekte olup belirli bir oda sayısına sahip ofislerin kiralarında yüksek bir varyans bulunmaktadır. Bu durum, kiraların sadece oda sayısına bağlı olarak değişmediğini, bunun yanında diğer faktörlerin de önemli olduğunu göstermektedir.




Şekil 6.12 Oda sayısı ile kira (TL/m²) verileri arasındaki ilişkinin gösterimi

Kiralanın ofisin bulunduđu kata ilişkin dağılım incelendiğinde, ofis sayısının en yoğun olduđu kat aralığının 1 ila 6. katlar arasında yer aldığı (882 adet) ve kat seviyesi yükseldikçe ofis sayısının belirgin biçimde azaldığı görülmektedir (Şekil 6.13). 6-11. kat aralığında 690, 11-16. kat aralığında ise 302 ofis bulunmaktadır. Bu durum, ofislerin genellikle alt ve orta katlarda yoğunlaştığını, üst katlara çıkıldıkça kiralanın ofis sayısının düştüğünü göstermektedir. En az ofis ise 36-41. kat aralığında olup yalnızca 1 adet ofis bulunmaktadır.

Kutu grafiğinde ise, kiralanın ofis katlarının dağılımı, merkezi eğilimleri ve uç değeri gösterilmektedir. Medyan değeri yaklaşık 8-10. kat arasında olduđu, alt çeyrek ile üst çeyrek arasındaki genişlik dikkate alındığında ofislerin büyük bir kısmının 5 ila 15. kat arasında yoğunlaştığı gözlemlenmektedir. Ayrıca 25. kat ve üzerindeki bazı ofisler uç değeri olarak değerlendirilmiştir, yani genel dağılıma kıyasla istisnai olarak yüksek katlarda yer almaktadırlar. Bu analiz, kiralanın ofislerin genellikle düşük ve orta katlarda konumlandığını, yüksek katlarda ise arzın ve talebin daha sınırlı olduğunu


göstermektedir. Kiraların da bu dağılımdan etkilenebileceği ve modelleme sürecinde kat sayısının önemli bir değişken olarak dikkate alınması gerektiği değerlendirilmektedir.



Şekil 6.13 Kiralanan ofisin katı dağılım ve yayılım özellikleri

Kiralanan ofisin katı ile metrekare başına kira (TL/m²) arasındaki ilişki görselleştirilmiştir (Şekil 6.14). Analiz sonuçları, alt ve orta katlardaki ofislerin daha yoğun şekilde kiralandığını ve genellikle daha yüksek kiraya sahip olduğunu göstermektedir. Özellikle 0-10. kat aralığında kiraların geniş bir dağılıma sahip olduğu, 10. kattan sonra ise kira seviyelerinde düşüş eğiliminin başladığı gözlemlenmektedir.

Üst katlara çıkıldıkça kiralarda daha fazla dalgalanma ve değişkenlik olduğu, bununla birlikte kiralanmış ofis sayısının da azaldığı anlaşılmaktadır. Ayrıca, bazı üst katlarda düşük kiralara görülmekte olup bu durumun arz ve talep dengesindeki farklılıklardan kaynaklanabileceği değerlendirilmektedir. Sonuç olarak, kiralanmış ofisin katı, kirayı etkileyen önemli bir değişken olmakla birlikte, kiraların belirlenmesinde tek başına yeterli bir faktör değildir ve diğer pazar dinamikleriyle birlikte değerlendirilmelidir.



Şekil 6.14 Kiralanan ofisin katı ile kira (TL/m²) arasındaki ilişkinin gösterimi

6.3 Model Performans Ölçütlerinin Değerlendirilmesi

Makine öğrenmesi modellerinin performansını değerlendirmek amacıyla en sık başvurulan metrikler arasında Kök Hata Kareler Ortalaması (Root Mean Square Error, RMSE), Ortalama Mutlak Hata (Mean Absolute Error, MAE), Göreceli Kök Hata Kareler Ortalaması (Relative Root Mean Square Error, rRMSE) ve Göreceli Ortalama Mutlak Hata (Relative Mean Absolute Error, rMAE) yer almaktadır (Şen vd. 2025). Bu performans ölçütlerinin her biri, modelin tahmin ettiği değerlerin gerçek gözlemlerle ne düzeyde örtüştüğünü farklı perspektiflerden değerlendirmektedir.

RMSE, tahmin hatalarının karesinin ortalamasının karekökünü alarak büyük hatalara daha duyarlı bir ölçüm sağlarken, MAE tahmin hatalarının mutlak değerlerinin ortalamasını dikkate alarak daha dengeli bir hata ölçümü sunmaktadır. rRMSE ve rMAE ise model performansının veri setinin ölçeğinden bağımsız olarak karşılaştırılabilmesine imkân tanıyarak, farklı veri setleri veya modeller arasında daha adil bir değerlendirme yapılmasına olanak sağlamaktadır.

RMSE, büyük tahmin hatalarına daha fazla ağırlık vermektedir çünkü hata değerlerinin karesini alarak bu hataları büyötmektedir. Bu özellik, küçük hataların etkisinin sınırlı kalmasını sağlarken, büyük hataların model performansı üzerindeki etkisini artırmaktadır. Örneğin, küçük ölçekli bir hata modelin genel hata düzeyine düşük bir katkı sağlarken, büyük ölçekli bir hata orantısal olarak çok daha fazla etki yaratmaktadır. Bu nedenle RMSE, özellikle büyük sapmaları tespit etmek açısından hassas bir metrik olarak öne çıkmaktadır. İdeal bir RMSE değeri sıfıra yakın olmalıdır; RMSE'nin düşük olması, modelin tahminlerinin gerçek gözlem değerlerine daha yakın olduğunu ve tahmin doğruluğunun yüksek olduğunu göstermektedir. Bu yönüyle, RMSE modellerin genel tahmin performansını değerlendirmek ve modeller arasında karşılaştırmalı analizler yapmak için sıkça tercih edilen bir ölçüt olmaktadır. Modellerin tahmin performansını değerlendirmek amacıyla, RMSE eşitlik (6.1)'deki gibi tanımlanmaktadır (Demirhan ve Başer 2024):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6.1)$$

Verilen formölde; n gözlem sayısını, y_i bağımlı değişkenin gerçek değerini, $\hat{y}_i$ kestirim değerini, $\bar{y}$ bağımlı değişken değerlerinin aritmetik ortalamasını ifade etmektedir (Şen vd. 2025).

MAE, model tarafından tahmin edilen değerler ile gözlenen gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasıdır. Bu metrik, her bir hataya eşit ağırlık vermesi nedeniyle, sapmaların büyüklüğünü doğrudan yansıtmaktadır ve kare alma işlemi içermediğinden, aykırı değerlere karşı daha az duyarlıdır. İdeal olarak, MAE değerinin sıfıra yakın olması beklenmektedir. Düşük bir MAE değeri, modelin tahminlerinde küçük sapmalar bulunduğunu ve genel doğruluk düzeyinin yüksek olduğunu göstermektedir. Makine öğrenmesi modellerinin tahmin performanslarını karşılaştırmak amacıyla sıklıkla kullanılan bu performans metriğı, eşitlik (6.2)'deki gibi tanımlanmaktadır (Demirhan ve Başer 2024; Şen vd. 2025).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6.2)$$

Burada $|-|$ işareti mutlak değeri ifade etmektedir. y_i gözlemlenen değerleri, $\hat{y}$ ise karşılık gelen model tarafından tahmin edilen değerleri temsil etmektedir. n , eğitim veya test veri setindeki toplam gözlem sayısını göstermekte, $\hat{y}$ ise ilgili veri setindeki bağımlı değişken değerlerinin aritmetik ortalamasını ifade etmektedir (Demirhan ve Başer 2024).

Farklı fiyat seviyelerine sahip gayrimenkul piyasalarında, mutlak hata ölçütleri olan RMSE VE MAE'nin doğrudan karşılaştırılması sağlıklı sonuçlar vermemektedir. Bu nedenle, bu ölçütlerin ortalama gözlem değeriyle oranlanarak elde edilen yeniden ölçeklendirilmiş versiyonları olan rRMSE ve rMAE, özellikle farklı pazarlar arasında model performansını karşılaştırmak amacıyla tercih edilmektedir. Ancak, bu bağıl hata ölçütleri her ne kadar pazarlar arası kıyaslamaya olanak sağlasa da tekil bir pazarın iç dinamikleri açısından mutlak hata büyüklüğünü tam olarak yansıtmaz. Bu bağlamda, yeniden ölçeklendirilmiş metrikler model karşılaştırmalarında faydalı olmakla birlikte, tahminlerin gerçek değerlerden ne derece saptığını değerlendirmek için mutlak hata ölçütleri ile birlikte ele alınmaları gerekmektedir (Demirhan ve Başer 2024).

rRMSE, RMSE değerinin gözlemlenen gerçek değerlerin ortalamasına bölünmesiyle elde edilmekte ve böylece ölçekten bağımsız bir hata ölçümü sağlamaktadır. Bu metrik, modelin tahmin hatasının bağımlı değişkenin büyüklüğüyle karşılaştırılmasına olanak tanımaktadır. rRMSE değerinin 0.10'un altında olması, modelin yüksek doğrulukta tahminler ürettiğini göstermektedir. 0.10 ile 0.20 arasındaki değerler kabul edilebilir hata düzeyine işaret ederken, 0.20'nin üzerindeki değerler modelin iyileştirilmesi gerektiğini göstermektedir. Modellerin tahmin performansını değerlendirmek amacıyla, rRMSE eşitlik (6.3)'te tanımlanan şekilde hesaplanmaktadır (Demirhan ve Başer 2024).

$$rRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}}{\bar{y}} \quad (6.3)$$

Eşitlikteki rMAE; MAE değerinin gözlemlenen gerçek değerlerin ortalamasına oranlanmasıyla elde edilmekte ve tahmin hatalarının gerçek değerlere kıyasla büyüklüğünü ölçmektedir. rMAE, modelin hata büyüklüğünü ölçekten bağımsız bir

şekilde değerlendirmeye imkân tanımaktadır. rMAE değerinin 0,10 veya altında olması, modelin yüksek doğrulukta tahminler gerçekleştirdiğini göstermektedir. 0,10 ile 0,20 arasındaki rMAE değerleri kabul edilebilir performans düzeyine işaret ederken, 0,20'nin üzerindeki değerler modelin performans açısından yeniden gözden geçirilmesi gerektiğini ortaya koymaktadır. Modellerin öngörü gücünü analiz edebilmek için, rMAE eşitlik (6.4)'te belirtilen şekilde hesaplanmaktadır (Demirhan ve Başer 2024).

$$rMAE = \frac{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|}{\bar{y}} \quad (6.4)$$

RMSE ve rMSE metrikleri, büyük tahmin hatalarına daha duyarlı analizlerin gerekli olduğu durumlarda tercih edilmektedir. Özellikle ofis değerlemesi gibi uygulamalarda, büyük hata paylarının (örneğin, bir gayrimenkulün piyasa değerinin önemli ölçüde düşük tahmin edilmesi gibi) kritik etkiler yaratması nedeniyle, bu tür hataların daha fazla ağırlıklandırılması önemli hale gelmektedir. Buna karşılık, MAE ve rMAE gibi metrikler, modelin genel tahmin performansının değerlendirilmesinde ve tüm hataların eşit önemde kabul edildiği analizlerde kullanılmaktadır. Örneğin, günlük hava tahminlerinde küçük ya da büyük hataların benzer etkiler yaratması nedeniyle, bu metriklerin kullanımı daha uygun olmaktadır. Model performansı yorumlanırken, bu metriklerin değerlerinin yanı sıra veri setinin varyansı da dikkate alınmalıdır. Düşük varyansa sahip veri setlerinde yüksek RMSE veya MAE değerleri, modelin yeterli bir doğruluk düzeyine ulaşamadığını ve iyileştirme gerekliliğini işaret etmektedir (Demirhan ve Başer 2024).

MAE ve RMSE metrikleri, tahmin hatalarının bütüncül biçimde analiz edilebilmesi için birlikte değerlendirilmelidir. MAE, modelin ortalama sapma düzeyini belirlemek amacıyla, tahmin edilen değerler ile gerçek gözlemler arasındaki mutlak farkların aritmetik ortalamasını hesaplamaktadır. Buna karşılık, RMSE hata varyansını dikkate alarak hataların sapma derecesini yansıtmaktadır ve hata büyüklüğüne daha duyarlı olması nedeniyle MAE'ye kıyasla daha hızlı artış göstermektedir. Bu nedenle, RMSE yüksek sapma gösteren hatalara daha fazla ağırlık verirken, MAE daha dengeli bir hata ölçüsü sunmaktadır. Bu iki metrik birlikte değerlendirildiğinde, modelin hem ortalama hata düzeyi hem de aşırı sapmalar karşısındaki duyarlılığı hakkında daha bütüncül bir


değerlendirme yapılabilmektedir (Şen vd. 2025). Bu nedenle, bir modelin yalnızca ortalama hata düzeyini değil, aynı zamanda hata dağılımındaki değişkenliği de değerlendirmek için MAE ve RMSE'nin birlikte incelenmesi kritik öneme sahiptir. Böylece, modelin sistematik olarak düşük hata üretip üretmediği daha sağlıklı bir biçimde analiz edilebilmektedir. Dolayısıyla, mutlak ve görelî hata metriklerinin birlikte değerlendirilmesi, modelin hem genel doğruluk düzeyi hem de farklı pazar dinamikleri karşısındaki uyum kabiliyetini kapsamlı bir şekilde ortaya koymaktadır (Demirhan ve Başer 2024 ve Şen vd. 2025).

7. ARAŞTIRMA BULGULARI VE TARTIŞMA

Ankara ili Çankaya ilçesi örneğinde gerçekleştirilen çalışma kapsamında, ofis kiralarının belirlenmesine yönelik geliştirilen modellere ilişkin uygulama süreci ayrıntılı olarak ele alınmış ve elde edilen bulgular değerlendirilmiştir. Modelleme süreci, veri hazırlığından performans değerlendirmesine kadar olan tüm aşamaları kapsamlı bir biçimde açıklamakta ve elde edilen sonuçların yorumlanmasına zemin hazırlamaktadır. Öncelikle araştırma alanına ilişkin fiziksel, mekânsal ve sosyoekonomik veriler değerlendirilerek alanın yapısal özellikleri analiz edilmiştir. Devamında, emsal değerlendirme yöntemine dayalı olarak elde edilen veriler ışığında, ofis piyasasına ilişkin mevcut kira düzeyleri analiz edilmiştir. Sonraki aşamada, makine öğrenmesi yöntemleri ile bulanık regresyon fonksiyonları ayrı ayrı uygulanarak modelleme çalışmaları gerçekleştirilmiş; her bir yöntemin tahmin performansları değerlendirilmiştir. Son olarak, elde edilen sonuçlar karşılaştırmalı olarak incelenmiş ve bu modellerin pratik değerlendirme süreçlerine katkı potansiyeli tartışılmıştır. Bu bağlamda bölüm, geleneksel ve istatistiksel yaklaşımlar ile modern algoritmik yöntemlerin birlikte değerlendirilerek gayrimenkul değerlendirme sürecine nasıl entegre edilebileceğini ortaya koymayı amaçlamaktadır.

7.1 Araştırma Alanına İlişkin Bulgular

Araştırma kapsamında saha çalışması Ankara'nın Çankaya ilçesine bağlı Kızılırmak, Çukurambar, Söğütözü, İşçi Blokları ve Mustafa Kemal mahallelerini kapsayan ve yaklaşık 10,50 km² yüzölçümüne sahip bölge seçilmiştir (Şekil 7.1). Nüfusu 947.330 olan Çankaya, başkent Ankara'nın merkezi iş alanı özelliği taşıyan en yoğun ilçelerinden biridir. Ofis yapılaşmasının belirgin şekilde yoğunlaştığı bu bölge, kira değerlendirme çalışmaları açısından uygun örneklem alanı oluşturarak, piyasa dinamiklerinin modellenmesi için temsil gücü yüksek bir zemin sunmaktadır. Zira bölge, ticaret, hizmet ve kamu bürokrasisi açısından başat bir merkez konumunda bulunmaktadır. Bu bölgedeki ticari gayrimenkul piyasasının dinamik yapısı, ofis kiralarındaki çeşitlilik ve kiralari etkileyen çok sayıda faktör, saha çalışmasının bu alanda yapılmasını gerekli ve hatta zorunlu kılmaktadır.



Şekil 7.1 Ankara ili çalışma alanı gösterimi (Anonymous 2025a)

Ankara'nın en büyük ve en gelişmiş ilçelerinden biri olan Çankaya ilçesi, özellikle Kızılay, Balgat, Söğütözü ve Çukurambar gibi bölgelerin iş merkezleri olarak bilinmektedir. Bu bölgeler hem kamu hem de özel işletmelerin iş merkezlerinin yoğunlaştığı yerlerdir ve önemli bir ulaşım ağı ile stratejik konuma sahiptirler (örneğin alışveriş merkezleri, restoranlar ve oteller). Son zamanlarda yapılan yatırımlar ve çağdaş ofis projeleri, bölgenin gayrimenkul pazarında da hareketlilik yaratmıştır. Buna ilave olarak uzun süreden bu yana kullanımda olan eski yapılar ve yeni inşa edilen modern ofis binaları birarada olduğu için, birim kira paraları arasında önemli ölçüde farklılık olduğu görülmektedir. Resmi verilere göre, tüm ilçeleriyle birlikte 2024 yılında Ankara'nın toplam nüfusu 5.864.049 olarak kaydedilmiştir. Ankara'nın nüfus artışı son yıllarda örneğin 2019'dan 2020'ye %0,43, 2020'den 2021'e %1,48, 2021'den 2022'ye %0,61, 2022'den 2023'e ve 2023'ten 2024'e %1,04 oranlarında gerçekleşmiş (Çizelge 7.1) olup, ilde nüfus artış oranının oldukça düşük düzeye gerilediği dikkati çekmektedir. Bu sonuçlar, başkentin nüfusunun yıllar içerisinde düzenli bir şekilde artış gösterdiğini, ancak artış hızının son dönemde azalma eğiliminde olduğunu ortaya koymaktadır.

Çizelge 7.1 Ankara ilinin nüfusu

Yıllar	Nüfus (kişi)
2019	5.639.076
2020	5.663.322
2021	5.747.325
2022	5.782.285
2023	5.803.482
2024	5.864.049

Ankara'nın nüfus yapısı incelendiğinde, 2024 yılı resmi verilerine göre en büyük yaş grubu 40-49 yaş aralığındaki bireylerden oluşmaktadır. Bu grubu sırasıyla 30-39 ve 20-29 yaş aralığı takip etmektedir. Öte yandan, 70 yaş ve üzeri bireyler, Ankara'nın toplam nüfusunun yalnızca %6.50'sini oluşturmaktadır (Çizelge 7.2). Bu veriler, Ankara'nın nüfusunun ağırlıklı olarak genç ve orta yaş gruplarında yoğunlaştığını, yaşlı nüfusun ise daha sınırlı bir oran teşkil ettiğini göstermektedir.

Çizelge 7.2 Ankara ilinin nüfusunun yaşlarına göre dağılımı (2023 ve 2024 yılları)

Yaş Aralığı	2023 Yılı Nüfusu (kişi)	2024 Yılı Nüfusu (kişi)
0-9	711 031	681 406
10-19	809 023	820 213
20-29	899 343	900 367
30-39	901 555	902 725
40-49	901 875	912 680
50-59	720 380	734 480
60-69	503 432	530 820
70 ve üzeri	356 843	381 358

Ankara'nın merkez ilçelerindeki nüfus dağılımına bakıldığında, 2024 yılı itibarıyla en fazla nüfusa sahip ilçenin Çankaya olduğu, Keçiören'in ise onu çok az bir farkla takip ettiği görülmektedir (Çizelge 7.3). Buna karşılık, Altındağ ilçesi, Ankara'nın merkez ilçeleri arasında en düşük nüfusa sahip olan ilçe olarak dikkat çekmektedir. Nüfus verileri, Çankaya ve Keçiören'in, Ankara'nın merkez nüfusu üzerinde önemli bir ağırlığa sahip olduğunu göstermektedir. İlin merkez ilçelerinin toplam nüfusları nispeten yüksek olmasına karşın, ilçe yüzölçümünün fazla olması nedeniyle fiziksel nüfus yoğunluğunun düşük olduğu görülmektedir. Ancak kentsel kesimin yüzölçümü üzerinden fiziksel nüfus yoğunluğunun tespit edilmesi halinde, yoğunluğun oldukça bulunması kaçınılmazdır.

Çizelge 7.3 Başkentin merkez ilçelerinin nüfusu (2023 ve 2024 yılları)

İlçeler	2023 Nüfusu	2024 Nüfusu
Çankaya	937.546	947.330
Keçiören	923.404	932.128
Yenimahalle	701.638	714.866
Mamak	682.279	686.777
Etimesgut	617.229	629.112
Sincan	571.889	590.309
Altındağ	412.267	414.893

Türkiye işgücü piyasasının son beş yıllık gelişimi, özellikle pandemi sonrası toparlanma süreci ve demografik genişlemeyle birlikte değerlendirildiğinde önemli dönüşümlere işaret etmektedir. 2019 Aralık ayında 15 ve daha yukarı yaştaki nüfus 61,9 milyon düzeyinde iken, bu rakam 2024 Aralık ayı sonu verilerine göre 66,1 milyona ulaşarak yaklaşık 4,2 milyonluk artış göstermiştir (Çizelge 7.4). Aynı dönemde işgücü 32,1 milyondan 35,2 milyona yükselmiş ve bu artış, işgücü piyasasına katılımın canlandığını ortaya koymaktadır. Nitekim işgücüne katılma oranı %51,8'den %53,3'e yükselmiş, istihdam oranı da %44,8'den %48,7'ye çıkarak kayda değer bir iyileşme sergilemiştir. Özellikle istihdam edilen kişi sayısındaki 4,5 milyonluk artış, ekonomik toparlanmanın ve iş yaratma kapasitesinin gücünü yansıtmaktadır. Diğer yandan, işsiz sayısı bu dönemde 4.349 milyondan 3.049 milyona gerileyerek yaklaşık 1,3 milyonluk bir düşüşle birlikte, işsizlik oranının %13,6'dan %8,7'ye gerilemesine neden olmuştur (Anonim 2025). Bu bağlamda, işgücü piyasasında hem niceliksel hem de oransal iyileşmenin eşzamanlı olarak gerçekleştiği ve ülke ekonomisinin işgücü absorpsiyon kapasitesinin güçlendiği dikkati çekmektedir.

Çizelge 7.4 Türkiye’de işgücü piyasası verileri (Bin Kişi) (Anonim 2025)

Yıllar	15 ve daha yukarı yaştaki nüfus	İş gücü	İstihdam	İşsiz	İş gücüne dahil olmayanlar	İş gücüne katılma oranı (%)	İstihdam oranı (%)	İşsizlik oranı (%)
2019	61.921	32.077	27.728	4.349	29.844	51,8	44,8	13,6
2020	63.140	30.271	26.327	3.944	32.869	47,9	41,7	13,0
2021	64.173	33.298	29.550	3.749	30.875	51,9	46,0	11,3
2022	65.102	34.811	31.173	3.637	30.292	53,5	47,9	10,4
2023	65.683	35.259	32.113	3.146	30.424	53,7	48,9	8,9
2024	66.124	35.245	32.197	3.049	30.878	53,3	48,7	8,7

Türkiye işgücünün yaklaşık %7,2'sine ev sahipliği yapan Ankara, özellikle nitelikli işgücü açısından dikkat çeken bir şehir konumundadır. Ankara'daki nitelikli işgücü oranı %41,6 ile ülke ortalamasının (%29,6) oldukça üzerinde seyretmektedir. Bu durum, kentte yükseköğrenim düzeyinde eğitim almış bireylerin yoğunluğuna işaret etmekte ve Ankara'nın kamu yönetimi, savunma sanayii, yüksek teknoloji ve akademik alanlarda uzmanlaşmış iş alanları açısından güçlü bir merkez olduğunu göstermektedir. Nitekim, Türkiye'de lise ve dengi meslek okulu mezunu işgücünün %7,7'si ve yükseköğretim mezunu işgücünün ise %10,1'i Ankara'da yer almaktadır (Anonim 2025). Bu oranlar, başkentin eğitilmiş işgücü potansiyelini ve özellikle hizmet sektörleri ile ofis temelli istihdam alanlarında neden cazip bir iş piyasası sunduğunu açıklamaktadır. Ayrıca, Ankara'da işgücünün eğitime ve cinsiyete göre dağılımı, kentteki toplumsal ve ekonomik yapının daha ayrıntılı anlaşılması açısından önemli bir gösterge niteliğindedir.

7.2 Emsal Değer Analizi

Doğru ve güvenilir ofis kira tespiti, gayrimenkul değerleme süreçlerinin en temel unsurlarından biri olarak kabul edilmektedir. Özellikle piyasa koşullarının sürekli değişim gösterdiği dinamik bölgelerde, kiraların pazar gerçekleriyle uyumlu bir şekilde tespit edilebilmesi için bilimsel ve sistematik yöntemlerin kullanılması büyük önem arz etmektedir. Bu çerçevede, emsal değer analizi yöntemi; benzer fiziksel, mekânsal ve fonksiyonel özelliklere sahip ofislerin kiralarının karşılaştırılması esasına dayanmaktadır ve yüksek doğruluk düzeyi sunan etkili bir yöntem olarak öne çıkmaktadır (Şen vd. 2025).

Emsal değer analizi, benzer niteliklere sahip gayrimenkullerin piyasa fiyatlarının karşılaştırılması yoluyla değer tespiti yapılmasına dayanan geleneksel değerleme yöntemi olarak bilinmektedir. Bu yaklaşımın temel amacı, değerlemesi yapılacak gayrimenkule en yakın özelliklere sahip yeterli sayıda emsalin belirlenmesi ve bu emsallerin detaylı biçimde analiz edilmesidir. Analiz sürecinde geçmiş dönemlere ait veriler kullanılırken, özellikle parasal değerlerin, verinin toplandığı tarihten değerleme tarihine kadar geçen sürede pazar davranışlarında meydana gelen değişimlerin etkisini yansıtacak şekilde güncellenmesi gerekliliği kritik bir unsur olarak ortaya çıkmaktadır (Tanrıvermiş 2017).

Analiz sürecinde, yöntemin güvenilir ve geçerli sonuçlar üretebilmesi açısından, kullanılacak emsal verilerin titizlikle ve uygun kriterlere göre seçilmesi büyük önem taşımaktadır. Bu çerçevede, test veri setinde yer alan her bir ofis için, benzer özelliklere sahip emsaller eğitim veri seti içerisinde belirlenmiş ve karşılaştırmalı değerlendirme bu temelde gerçekleştirilmiştir. Bu yaklaşım, veri setleri arasındaki uyumu güçlendirerek tahmin başarımını en üst düzeye çıkarmayı hedeflemektedir. Test veri setindeki her bir ofis için, özel olarak emsal değer analizi uygulanmıştır. Bu aşamada, her ofisin sahip olduğu özgün fiziksel ve mekânsal özellikler göz önünde bulundurularak, eğitim veri setinden en uygun niteliklere sahip emsaller seçilmiştir. Böylece, her bir ofisin bulunduğu pazar bölümünün dinamiklerini ve özgün özelliklerini yansıtan daha isabetli ve gerçekçi tahminler elde edilmesi sağlanmaktadır. Bu yaklaşım, hem mikro düzeyde özelleştirilmiş analiz imkânı sunmakta hem de modelin açıklayıcılık ve güvenilirliğini artırmaktadır.

Eğitim ve test veri setlerindeki ofisler, iç mekân durumlarına göre (tamamlanmış ve/veya tamamlanmamış) sınıflandırılarak bu doğrultuda analiz edilmiştir. Bu işlem sırasında, özellikle aynı katta bulunan, benzer büyüklükte ve eşdeğer oda sayısına sahip ofislerin seçimine öncelik verilmiştir. Böylelikle, mümkün olan en yüksek düzeyde benzerlik taşıyan ofisler arasındaki karşılaştırmalar esas alınmaktadır. Bu yaklaşım, emsal değer analizinin doğruluk seviyesini artırmakta ve pazar koşullarını daha gerçekçi biçimde yansıtan bir değerlendirme süreci oluşturmaktadır.

Emsal satışların karşılaştırılmasına dayalı değerlendirme işleminde, seçilen ofislerin birim kira değerlerinin (TL/m²) aritmetik ortalaması saptanmakta ve bu ortalama etrafında sapma sınırları ($\pm\%15$ veya 20 gibi tolerans aralığı) içinde belirlenn sonuçların istikrarı ve güvenilirliği tesis edilmektedir (Tanrıvermiş 2017). Bu çerçevede her bir tekil değerlendirme çalışması için alt ve üst sınırların tespiti yapılmakta ve nihai değer kestirimi de söz konusu sınırlar içinde gerçekleştirilmektedir. Böylece hem piyasa gerçeklerine duyarlı hem de sistematik bir değerlendirme yaklaşımı benimsenmiş olmaktadır. Örneğin, 1071 Plazada bulunan ve iç mekânı tamamlanmış, 7. katta yer alan, üç odalı ve 86 m² alana sahip bir ofisin kirasının belirlenmesi sürecinde; eğitim veri setinde yer alan aynı plazada bulunan ve benzer özellikler taşıyan ofisler seçilerek emsal grubu oluşturulmuştur. Bu kapsamda, kat konumu, oda sayısı ve kiralanan brüt alan büyüklüğü

gibi temel nitelikler dikkate alınmış ve yüksek benzerlik gösteren ofisler analiz kapsamına alınmıştır. İlgili ofise ilişkin seçilen emsal verilere Çizelge 7.5'te yer verilmiştir.

Çizelge 7.5 Emsal alınan ofislerin özellikleri ve kira paraları

Sıra No	Kiralanan Ofisin Brüt Alanı (m ²)	İç Mekânı Tamamlanmış/ Tamamlanmamış Ofis (Adet)	Oda Sayısı (Adet)	Kiralanan Ofisin Katı	Aylık Emsal Kira (TL/m ²)
5	70	1	2	7	381,04
33	110	1	3	7	389,82
47	70	1	2	7	390,99
49	75	1	3	7	390,99
124	80	1	3	7	333,78
137	85	1	3	7	323,75
170	100	1	3	7	389,15
209	72	1	2	7	334,12
220	86	1	3	7	378,65
297	75	1	2	7	461,27
331	135	1	4	7	373,72

Emsallerden elde edilen kira birim değerlerinin ortalaması ve belirlenen sınır kontrolleri, hedef ofisin kira kestirimi için temel teşkil etmektedir. Analzi ve değerlendirme sonuçlarına göre eğitim veri setinde yer alan ofisler için birim metrekare kira ortalaması 377,03 TL/m² olarak bulunmuştur. Buna ilave olarak $\pm\%15$ sınır aralığı dikkate alınarak kira parasının alt sınırı 320,48 TL/m² ve üst sınırı ise 433,58 TL/m² olarak tespit edilmektedir (Çizelge 7.5). Belirlenen sınırlar dışında kalan değerler uç değer olarak değerlendirilmiş ve analiz dışında tutulmuştur. Uygun görülen emsal kira verileri ise ayrıntılı biçimde sunulmuştur (Çizelge 7.6).

Yeni emsallere dayalı olarak gerçekleştirilen hesaplamalarda, uç değerler analiz dışı bırakılmıştır. Bu uygulama, tahmin sürecinin doğruluğunu ve güvenilirliğini artırarak, sonuçların pazar gerçeklikleriyle daha tutarlı olmasına katkı sağlamıştır. Yeniden

belirlenen emsal veriler kullanılarak yapılan hesaplamalar neticesinde, test veri setinde yer alan hedef ofis için ortalama birim kira 368,60 TL/m² olarak tespit edilmiştir.

Çizelge 7.6 Sınırlar içinde kalan emsal ofislerin özellikleri ve kiralari

Sıra No	Kiralanan Ofisin Brüt Alanı (m ²)	İç Mekânı Tamamlanmış/ Tamamlanmamış Ofis (Adet)	Oda Sayısı (Adet)	Kiralanan Ofisin Katı	Aylık Emsal Kira (TL/m ²)
5	70	1	2	7	381,04
33	110	1	3	7	389,82
47	70	1	2	7	390,99
49	75	1	3	7	390,99
124	80	1	3	7	333,78
137	85	1	3	7	323,75
170	100	1	3	7	389,15
209	72	1	2	7	334,12
220	86	1	3	7	378,65
331	135	1	4	7	373,72

7.3 Makine Öğrenmesi Yöntemlerine İlişkin Bulgular

Araştırmada, veri analizi ve modelleme uygulamaları R programlama dili kullanılarak gerçekleştirilmiştir. R, sunduğu zengin kütüphane altyapısı ve esnek analiz araçları sayesinde hem temel düzeyde istatistiksel hesaplamalara hem de ileri seviye makine öğrenmesi tekniklerinin uygulanmasına imkân tanımaktadır. Bu çerçevede, yüksek boyutlu ve çok değişkenli veri setleri üzerinde çeşitli algoritmalar yardımıyla tahmin modelleri oluşturulmuş, söz konusu modellerin kurulumu, değerlendirilmesi ve karşılaştırılması R ortamında sistematik biçimde yürütülmüştür. Özellikle eğitim ve test veri setlerinin ayrı ayrı ele alınması, modelleme sürecinde genelleme yeteneğinin doğru biçimde ölçülmesine olanak sağlamıştır.

İlk aşamada, eğitim veri seti kullanılarak RF, SVM, DT, ANN ve XGBoost gibi farklı makine öğrenmesi algoritmaları ile tahmin modelleri geliştirilmiştir. Bu modellerin

doğruluk düzeyleri, test veri seti üzerinde uygulanarak RMSE ve MAE gibi performans ölçütleri aracılığıyla değerlendirilmiştir. Uygulama bulguları, değişken seçimi ve boyut indirgeme tekniklerinin model başarımını olumlu etkilediğini ve işlem süresi açısından da verimlilik sağladığını ortaya koymuştur. Böylelikle, model kurma ve doğrulama süreçlerinin optimizasyonu açısından R programı güçlü ve bütüncül bir analiz ortamı sunmuştur.

Elde edilen bulguların detaylı karşılaştırması karşılaştırmalı olarak sunulmuştur (Çizelge 7.7 ve Çizelge 7.8). Bu tablolarda, bağımsız değişkenlerin hedef değişken olan kira (TL/m²) üzerindeki etkileri analiz edilmiş ve her bir algoritmanın tahmin gücü, hata metrikleri ışığında sıralanarak değerlendirilmiştir. Bu yaklaşım, yalnızca model performanslarının nesnel biçimde karşılaştırılmasına değil, aynı zamanda genelleme kapasitesi yüksek modellerin seçilmesine de olanak tanımıştır. Sonuç olarak, test verisi üzerinde en başarılı tahmin sonuçlarını veren ilk üç algoritma belirlenmiş ve bu yöntemlerin modelleme sürecindeki katkıları ayrı ayrı tartışılmıştır.

Makine öğrenmesi modelleri arasında RF algoritması, ofis kiralarının kestiriminde en yüksek doğruluğu sağlayan yöntem olarak öne çıkmıştır. Bu modelin test veri setinde elde ettiği hata ölçütleri; RMSE: 0,237328, MAE: 0,190815, rRMSE: 0,039968 ve rMAE: 0,032138 şeklindedir. Bu sonuçlar, modelin hem büyük hatalara karşı duyarlılığının düşük olduğunu hem de tahminlerinin genel olarak gerçek değerlere çok yakın gerçekleştiğini göstermektedir. Düşük RMSE değeri, uç değerlerdeki sapmaların minimum düzeyde olduğunu ortaya koyarken, düşük MAE değeri ortalama hatanın küçük olduğunu vurgulamaktadır.

Özellikle rRMSE ve rMAE değerlerinin 0,04 seviyesinin altında kalması, modelin farklı ölçeklerde uygulanabilirliğini ve genellenebilirliğini desteklemektedir. RF'nin çok sayıda karar ağacını birleştirerek varyansı azaltan yapısı, değişkenler arası karmaşık ilişkilerin öğrenilmesini mümkün kılmakta; bu da özellikle mekânsal ve yapısal çeşitlilik gösteren ofis piyasası gibi heterojen veri yapılarında önemli bir avantaj sağlamaktadır ve aşırı öğrenmeye karşı direnç göstermektedir.

XGBoost algoritması, test verisi üzerinde gösterdiği yüksek başarı ile RF'nin hemen ardından ikinci sırada yer almıştır. Yöntemin hata ölçütleri; RMSE: 0,238705, MAE: 0,189423, rRMSE: 0,040204 ve rMAE: 0,031904 olarak hesaplanmıştır. MAE ve rMAE değerlerinin RF'ye kıyasla daha düşük olması, bu modelin tahmin hatalarını daha dengeli bir şekilde minimize ettiğini ve sistematik hataları daha etkili biçimde giderdiğini göstermektedir.

RMSE ve rRMSE değerlerinin de oldukça düşük düzeyde kalması, modelin sadece küçük hatalarda değil, aynı zamanda uç sapmalarda da güçlü olduğunu ortaya koymaktadır. Ağaç tabanlı ardışık öğrenme yapısı sayesinde küçük kalıpları bile tanıyabilme yetisi, bu yöntemi detaylı segmentlerde avantajlı hâle getirmiştir. Gradyan artırma mekanizması ile her bir yeni modelin bir önceki hataları düzeltmesi, XGBoost'un özellikle hata düzeltme odaklı çalışmalarda tercih edilmesini desteklemektedir. Modelin hiperparametre ayarlarına duyarlılığı yüksek olsa da doğru optimize edildiğinde, özellikle büyük ve karmaşık veri setlerinde istikrarlı ve güvenilir tahminler üretme kapasitesine sahiptir.

Üçüncü sırada yer alan k-NN algoritması, parametrik olmayan yapısıyla, benzer örnekler arasında mesafe temelli tahmin üretme yeteneği sayesinde test verisi üzerinde anlamlı bir performans sergilemiştir. Yöntemin hata ölçütleri şu şekildedir: RMSE: 0,245066, MAE: 0,194609, rRMSE: 0,041275 ve rMAE: 0,032777. Bu değerler, özellikle mutlak hata düzeylerinde k-NN'nin görece olarak başarılı olduğunu ancak RMSE ve rRMSE değerlerinin biraz daha yüksek olması nedeniyle uç değerlerdeki sapmalar konusunda daha az dirençli olduğunu göstermektedir.

Modelin özellikle lokal benzerliklere dayalı yapısı, homojen alt pazarlarda güçlü performans sağlarken, heterojen ve yüksek varyanslı veri yapılarında genelleme kabiliyetinin sınırlı kalmasına neden olabilecektir. Bununla birlikte, düşük rMAE değeri modelin ortalama oransal hata düzeyinin makul düzeyde olduğunu ortaya koymaktadır. k-NN'nin güçlü yönü, modelin sezgisel olarak anlaşılabilir yapısı ve karmaşık parametre ayarlarına ihtiyaç duymadan uygulanabilir olmasıdır. Ancak veri ölçeklendirme ihtiyacı ve yüksek boyutlu uzaylardaki zayıflıkları, bu yöntemin sınırlılıkları olarak değerlendirilmektedir.

Emsal değer analizi ile elde edilen test veri seti, üzerinde gösterdiği hata düzeyleri bakımından modern makine öğrenmesi yöntemlerinin gerisinde kalmakla birlikte, belirli açılardan dikkate değer bir performans sergilemiştir. Bu yöntemin hata ölçütleri; RMSE: 0,252778, MAE: 0,198174, rRMSE: 0,042574 ve rMAE: 0,033377 olarak hesaplanmıştır. RMSE ve rRMSE değerlerinin yüksek olması, özellikle uç değerler karşısında modelin duyarlılığının sınırlı olduğunu ve kiralarda yüksek sapmaların daha belirgin hale geldiğini göstermektedir.

Buna karşın MAE ve rMAE değerlerinin bazı regresyon tabanlı modellere yakın sonuçlar vermesi, bu yöntemin ortalama düzeydeki tahmin hatalarını makul ölçüde kontrol edebildiğini göstermektedir. Özellikle değişkenler arası çok boyutlu, doğrusal olmayan ilişkileri içselleştirememesi, tahmin gücünü sınırlamaktadır. Ayrıca mekânsal heterojenlik, bina özelliklerindeki çeşitlilik ve kullanıcı tercihlerinin etkili olduğu piyasalarda bu yöntem, daha gelişmiş veri odaklı tekniklerle karşılaştırıldığında açıklayıcılığını yitirebilmektedir.

Çizelge 7.7 Makine öğrenmesi yöntemleri eğitim veri seti sonuçları

No	Yöntem	RMSE	MAE	rRMSE	rMAE
1	XGBoost	0,145702	0,107949	0,024479	0,018136
2	RF	0,182245	0,144869	0,030618	0,024339
3	k-NN	0,212332	0,167485	0,035673	0,028138
4	ANN	0,226201	0,181724	0,038003	0,030531
5	RBF-SVM	0,231401	0,177807	0,038877	0,029873
6	MLR	0,240507	0,19523	0,040407	0,0328
7	RR	0,240722	0,196347	0,040443	0,032987
8	Lineer-SVM	0,243162	0,192453	0,040852	0,032333
9	LR	0,243181	0,199507	0,040856	0,033518
10	DT	0,24393	0,200144	0,040982	0,033625

Elde edilen bulgular, test veri seti üzerinde uygulanan makine öğrenmesi ve klasik yöntemlerin, kira kestirim performansları arasında anlamlı farklar olduğunu açıkça ortaya koymaktadır. Özellikle RF ve XGBoost algoritmaları, hem mutlak hata ölçütleri (RMSE,

MAE) hem de normalize edilmiş hata oranları (rRMSE, rMAE) açısından en düşük değerleri vererek yüksek doğruluk düzeyiyle öne çıkmıştır. k-NN yöntemi ise lokal benzerliklere dayalı yapısıyla makul düzeyde başarılı sonuçlar üretmiş, ancak özellikle uç değerlerdeki sapmalara karşı daha kırılgan bir yapı sergilemiştir. Geleneksel bir yaklaşım olan Emsal Değer Analizi ise basitliği ve pratik uygulanabilirliğiyle dikkat çekse de çok değişkenli yapıya sahip heterojen piyasa koşullarında yetersiz kalmış ve makine öğrenmesi yöntemlerinin gerisinde kalmıştır. Genel olarak, modern algoritmaların pazarın karmaşık dinamiklerini daha iyi modelleyebildiği, tahmin gücünün daha yüksek olduğu ve genellenebilirliğinin klasik yöntemlere kıyasla daha güçlü olduğu görülmektedir. Bu bulgular, veri odaklı modelleme tekniklerinin gayrimenkul değerlendirme süreçlerine entegrasyonunun önemini ve gerekliliğini bir kez daha ortaya koymaktadır.

Çizelge 7.8 Makine öğrenmesi yöntemleri test veri seti sonuçları

No	Yöntem	RMSE	MAE	rRMSE	rMAE
1	RF	0,237328	0,190815	0,039968	0,032138
2	XGBoost	0,238705	0,189423	0,040204	0,031904
3	k-NN	0,245066	0,194609	0,041275	0,032777
4	RBF-SVM	0,250004	0,198115	0,042107	0,033367
5	ANN	0,250333	0,203561	0,042162	0,034285
6	RR	0,251286	0,206956	0,042323	0,034857
7	MLR	0,251404	0,20645	0,042343	0,034771
8	LR	0,252659	0,20898	0,042554	0,035197
9	Emsal Değer Analizi	0,252778	0,198174	0,042574	0,033377
10	Lineer-SVM	0,256407	0,204385	0,043185	0,034423
11	DT	0,26001	0,212533	0,043792	0,035796

7.4 Bulanık Regresyon Fonksiyonları Yöntemine İlişkin Bulgular

Makine öğrenmesi temelli modelleme sonuçları, ofis kiralalarının belirlenmesinde yüksek doğruluk ve esneklik sağlayan yöntemlerin varlığını ortaya koymakla birlikte, bu yöntemlerin tamamı temelde deterministik yapıya sahip algoritmalara dayanmaktadır. Oysaki gayrimenkul piyasası, doğası gereği çok sayıda nicel ve nitel değişkenin etkileşim

hâlinde olduğu, aktör davranışlarının rasyonel olmayan biçimlerde şekillenebildiği ve karar süreçlerinin belirsizlikle kuşatıldığı karmaşık bir sistemdir. Özellikle piyasa katılımcılarının beklentileri, mekânsal algılar, bina imajı, marka değeri gibi ölçülmesi zor değişkenlerin kararlar üzerindeki etkisi düşünüldüğünde, geleneksel makine öğrenmesi algoritmalarının bu örtük yapıyı bütünüyle modellemesi sınırlı kalabilmektedir. Bu bağlamda, bulanık küme teorisine dayanan ve nümerik olmayan belirsizlikleri modelleme gücüyle öne çıkan FRF, gayrimenkul değerlendirme uygulamalarında alternatif ve tamamlayıcı bir yaklaşım sunmaktadır. Bu yöntem hem istatistiksel ilişki kurma yeteneğini hem de belirsizliğin modellenmesine yönelik esnek yapıyı bir araya getirerek, özellikle klasik regresyon varsayımlarının geçerliliğini yitirdiği karmaşık piyasa koşullarında avantaj sağlamaktadır.

Çalışmanın bu bölümünde, FRF yöntemi kullanılarak oluşturulan çeşitli tahmin modellerinin test veri seti üzerindeki performansları detaylı biçimde analiz edilmiştir. Modeller, tıpkı makine öğrenmesi yöntemlerinde olduğu gibi dört temel hata ölçütü olan RMSE, MAE, rRMSE ve rMAE çerçevesinde değerlendirilmiş; bu ölçütler aracılığıyla hem genel tahmin doğruluğu hem de normalize edilmiş hata dağılımı açısından karşılaştırmalı bir performans analizi gerçekleştirilmiştir.

Bulgular, bulanık sistemlerin özellikle kısmi bilgi içeren veya çoklu belirsizlik koşullarında yüksek uyum yeteneği sergileyebildiğini ortaya koymaktadır. Araştırma kapsamında geliştirilen bulanık kümeleme tabanlı makine öğrenmesi algoritmalarının performansını değerlendirmek amacıyla, eğitim ve test veri setleri üzerinde yürütülen analizlerin bulguları sistematik biçimde sunulmuştur (Çizelge 7.9 ve Çizelge 7.10). İlgili performans ölçütleri doğrultusunda, test veri seti üzerinde en yüksek başarıyı gösteren ilk üç yöntem ayrıntılı olarak incelenmiş ve karşılaştırmalı analizlere tabi tutulmuştur.

Analiz sonuçlarına göre, en yüksek tahmin doğruluğuna ulaşan yöntem FRF RF modeli olmuştur. Modelin hata ölçütleri sırasıyla RMSE: 0,237305, MAE: 0,187292, rRMSE: 0,039972 ve rMAE: 0,031545 olarak hesaplanmıştır. Özellikle tüm metriklerde en düşük hata değerlerini vermesi, bu yöntemin hem genel doğruluk hem de normalize edilmiş sapma açısından en istikrarlı model olduğunu göstermektedir. RMSE'nin düşük olması,

modelin büyük hatalardan güçlü biçimde kaçındığını, MAE'nin düşük olması ise tahminlerin ortalama olarak gerçek değerlere oldukça yakın seyrettiğini ortaya koymaktadır. rRMSE ve rMAE'nin 0,04 seviyesinin altında kalması, tahmin başarısının gözlem ortalamasına göre oldukça yüksek olduğunu göstermekte; modelin sadece sayısal doğruluğu değil, aynı zamanda oransal istikrarı da sağladığını ortaya koymaktadır.

RF algoritması, çok sayıda karar ağacının çıktısını birleştirerek hata varyansını minimize etmekte, bunun yanında bulanık kümeleme ile zenginleştirildiğinde, belirsiz sınırlar içinde gruplanmış alt pazar bölümlerinin etkilerini de modele yansıtabilmektedir. Bu sayede, mekânsal çeşitliliğin ve yapısal heterojenliğin yoğun olduğu ofis piyasası gibi ortamlarda, daha isabetli tahmin sonuçları elde edilebilmektedir. Model, özellikle hem açıklayıcı değişkenler hem de hedef değişken üzerinde belirsizliklerin bulunduğu karmaşık veri ortamlarında son derece başarılı bir performans sergilemiştir.

FRF yöntemleri arasında ikinci en yüksek başarıyı gösteren model FRF XGBoost algoritması olmuştur. Bu modelin hata ölçütleri RMSE: 0,238654, MAE: 0,189555, rRMSE: 0,040195 ve rMAE: 0,031926 şeklindedir. MAE ve rMAE değerlerinin FRF RF'ye oldukça yakın olması, modelin genel hata seviyesinde oldukça rekabetçi olduğunu ve küçük sapmaları minimize etmede etkili olduğunu göstermektedir. RMSE ve rRMSE değerlerinin de düşük olması, bu modelin hem sistematik hem de rasgele hataları dengeleme gücünün yüksek olduğunu ortaya koymaktadır.

XGBoost algoritması, klasik biçimiyle karar ağaçları üzerinden ardışık hataları düzelterek öğrenmeyi güçlendiren bir yapıya sahiptir. Bu yapı, bulanık kümeleme ile birleştiğinde, verilerdeki açıklanamayan varyansları azaltmada etkili olmuş; özellikle değişkenlerin sınır değerlerde tanımlandığı, örneğin “merkeze yakınlık” gibi öznel tanımların net çizgilerle ayrılmadığı durumlarda esneklik sağlamıştır. Ayrıca, modelin hiperparametre ayarlarına duyarlılığı bulunmakla birlikte, doğru yapılandırıldığında yüksek doğruluk ve genelleme kapasitesi göstermiştir. Bu durum, ofis piyasası gibi belirsizliklerin yoğun olduğu alanlarda, öğrenmenin yalnızca veriye değil aynı zamanda verinin bulanık karakterine duyarlı şekilde gerçekleştiğini göstermektedir.

Üçüncü sırada yer alan FRF RBF-SVM yöntemi, klasik SVM'ye kıyasla daha esnek çekirdek fonksiyonlarıyla birlikte bulanık kümeler üzerinden optimize edilmiş bir tahmin mekanizması sunmaktadır. Modelin hata ölçütleri RMSE: 0,248785, MAE: 0,196069, rRMSE: 0,041901 ve rMAE: 0,033023 şeklinde belirlenmiştir. RMSE ve rRMSE değerlerinin artış göstermesi, modelin özellikle uç değerlerdeki sapmalar konusunda daha az toleranslı olduğunu, ancak MAE ve rMAE değerlerinin makul seviyede kalması, genel tahmin hatalarının belirli sınırlar içinde tutulduğunu göstermektedir.

Radyal çekirdek fonksiyonları, özellikle doğrusal olmayan örüntülerin öğrenilmesinde başarılı bir yaklaşım sunarken, bu yapının bulanık kümelenmiş veri gruplarıyla bütünleştirilmesi, çoklu pazar yapısının etkilerini daha esnek bir biçimde yansıtma imkânı sağlamıştır. Bu modelin öne çıkan yönlerinden biri de yani sınıflandırılması net olmayan, öz nitelikleri keskin biçimde ayrışmamış ofisleri daha esnek biçimde tahmin edebilmesidir. Bu yönüyle FRF RBF-SVM, özellikle ortalama hata düzeylerinde tatmin edici bir performans sunmakta, ancak yüksek hassasiyet ve uç değer doğruluğu gerektiren durumlarda daha güçlü algoritmalara kıyasla sınırlı kalmaktadır.

Çizelge 7.9 Bulanık Regresyon Fonksiyonları eğitim veri seti sonuçları

No	Yöntem	RMSE	MAE	rRMSE	rMAE
1	FRF_RF	0,13045	0,098891	0,021916	0,016614
2	FRF_XGBoost	0,136398	0,101659	0,022916	0,017079
3	FRF_k-NN	0,213691	0,169627	0,035901	0,028498
4	FRF_RBF-SVM	0,224814	0,16963	0,03777	0,028499
5	FRF_MLR	0,239792	0,194021	0,040286	0,032597
6	FRF_RR	0,241148	0,197504	0,040514	0,033182
7	FRF_ANN	0,241376	0,187143	0,039552	0,031953
8	FRF_LR	0,242817	0,199101	0,040795	0,03345
9	FRF_Lineer-SVM	0,242896	0,19161	0,040808	0,032192
10	FRF_DT	0,242967	0,198445	0,04082	0,03334

FRF ile elde edilen test verisi analiz sonuçları, gayrimenkul piyasası gibi yüksek belirsizlik içeren alanlarda bu yöntemin anlamlı avantajlar sunduğunu ortaya koymuştur.

Özellikle FRF RF ve FRF XGBoost modelleri, hem mutlak hata ölçütleri (RMSE, MAE) hem de normalize edilmiş hata oranları (rRMSE, rMAE) bakımından en düşük değerleri vererek öne çıkmıştır. Bu durum, söz konusu modellerin yalnızca sayısal doğruluk açısından değil, aynı zamanda oranlı hata düzeylerinde de istikrarlı ve güvenilir tahminler sunduğunu göstermektedir.

Bununla birlikte, FRF XGBoost ve FRF RBF-SVM gibi modellerin de orta düzeyde güçlü performans sergilemesi, doğrusal olmayan örüntülerin ve sınırlı bilgi içeren gözlemlerin başarıyla modellendiğini göstermektedir. Bulgular genel olarak, bulanık kümeleme temelli regresyon yapılarının, klasik makine öğrenmesi algoritmalarına entegre edildiğinde tahmin doğruluğunu artırmakla kalmayıp, piyasa dinamiklerindeki belirsizlikleri de daha iyi temsil edebildiğini göstermektedir. Sonuç olarak, FRF yöntemleri; çok değişkenli, eksik, yoruma açık ve bölgesel heterojenlik barındıran ofis kira piyasası gibi alanlarda alternatif değil, güçlü bir tamamlayıcı modelleme yaklaşımı olarak değerlendirilmektedir.

Çizelge 7.10 Bulanık Regresyon Fonksiyonları test veri seti sonuçları

No	Yöntem	RMSE	MAE	rRMSE	rMAE
1	FRF RF	0,237305	0,187292	0,039972	0,031545
2	FRF XGBoost	0,238654	0,189555	0,040195	0,031926
3	FRF RBF-SVM	0,248785	0,196069	0,041901	0,033023
4	FRF MLR	0,251175	0,207214	0,042304	0,0349
5	FRF ANN	0,251472	0,205566	0,043038	0,034801
6	FRF k-NN	0,252169	0,199561	0,042471	0,033611
7	FRF LR	0,252537	0,208782	0,042533	0,035164
8	FRF RR	0,252538	0,209279	0,042534	0,035248
9	FRF Lineer-SVM	0,254884	0,203711	0,042929	0,03431
10	FRF DT	0,259852	0,211844	0,043765	0,03568

7.5 Modelden Elde Edilen Bulguların Değerlendirilmesi

Araştırmada, ofis kiralarının tahminine yönelik geliştirilen farklı modelleme yaklaşımları hem makine öğrenmesi hem de FRF kapsamında test veri seti üzerinde ayrı ayrı

değerlendirilmiştir. Her iki yöntem sınıfı da çok değişkenli ve mekânsal olarak heterojen bir yapıya sahip olan ofis piyasasında, kira kestirimine ilişkin farklı öğrenme stratejileri sunmakta ve hata oranları bakımından farklı düzeylerde başarı sağlamaktadır. Bu bağlamda, model performanslarının sağlıklı bir şekilde değerlendirilebilmesi amacıyla dört temel hata ölçütü olan RMSE, MAE, rRMSE ve rMAE kullanılmıştır. Belirtilen ölçütler, modellerin hem tahmin doğruluğunu hem de hata dağılımını gözlemlemek açısından kapsamlı bir değerlendirme zemini sunmaktadır.

Aşağıda, her iki yaklaşım sınıfında en yüksek performans gösteren ilk üç model detaylı olarak karşılaştırmalı biçimde ele alınmakta, hem hata metrikleri hem de yöntemlerin yapısal farklılıkları bağlamında açıklayıcı bir çerçeve sunulmaktadır. Böylece, farklı öğrenme paradigmalarına dayalı modellerin, belirsizlik taşıyan gayrimenkul piyasasında ne ölçüde başarılı oldukları ve hangi bağlamlarda üstünlük sağladıkları ortaya konulmaktadır.

Bulanık kümeleme temelli RF ve klasik makine öğrenmesi tabanlı RF modelleri, her iki yaklaşım sınıfında da en başarılı sonuçları veren algoritmalar olarak öne çıkmıştır. Her iki model de çok sayıda karar ağacının kolektif çalışmasıyla tahmin sürecini yürütmekte, ancak temel fark, FRF modelinin giriş verilerinde bulanık kümeleme uygulanarak bölümlere ayrılmış ve gözlemlerin farklı kümeler üyeliğine göre ağırlıklandırılmış olmasıdır. Bu yapı, heterojen ofis piyasası gibi sınırları net olmayan veri kümelerinde daha esnek bir modelleme yaklaşımı sunmaktadır.

Model performanslarına bakıldığında, makine öğrenmesi tabanlı RF modeli test verisinde RMSE: 0,237328, MAE: 0,190815, rRMSE: 0,039968, rMAE: 0,032138 değerlerine ulaşmıştır. Buna karşılık bulanık kümeleme temelli test verisinde RMSE: 0,237305, MAE: 0,187292, rRMSE: 0,039972, rMAE: 0,031545 değerleriyle klasik modele oldukça yakın, hatta bazı hata ölçütlerinde daha düşük sonuçlar üretmiştir. Özellikle MAE ve rMAE değerlerindeki iyileşme, FRF versiyonunun tahminlerin ortalama sapmasını daha başarılı şekilde minimize ettiğini göstermektedir. Bu durum, modelin küçük ama anlamlı hata düzeltmeleri yaptığına işaret etmektedir.

Farklılıkların temelinde, makine öğrenmesi tabanlı RF'nin her gözlemi tek bir sınıfa dahil ederek öğrenme süreci yürütmesine karşın, bulanık kümeleme temelli RF modelinin gözlemlerin bulanık küme aidiyetlerini dikkate alması yer almaktadır. Bu özellik, özellikle “geçiş bölgesi” özellikleri taşıyan verilerde (örneğin hem konut hem ofis bölgesi özellikleri gösteren yapılar) tahmin doğruluğunu artırmıştır. Böylece FRF RF, keskin sınıflamalardan kaçınarak, çoklu etkilerin bir arada değerlendirildiği tahmin sonuçları üretmiştir. Sonuç olarak, iki model arasında istatistiksel olarak çok büyük farklar olmamakla birlikte, belirsizlik yönetimi açısından FRF RF modeli daha üstün bir yapıya sahiptir ve bu durum hata oranlarına da yansımıştır.

İkinci sırada yer alan modeller olan FRF XGBoost ve XGBoost, ardışık öğrenmeye dayalı ağaç temelli yapıları sayesinde, özellikle sistematik hata düzeltme gücüyle dikkat çekmektedir. Her iki model de yüksek doğruluk seviyelerine ulaşmış olmakla birlikte, FRF versiyonunun bulanık kümeleme ile güçlendirilmiş yapısı, klasik modele göre belirsizliği daha etkin yönettiğini göstermiştir. Performans ölçütlerine göre XGBoost modeli RMSE: 0,238705, MAE: 0,189423, rRMSE: 0,040204, rMAE: 0,031904 değerlerini verirken, FRF XGBoost modeli RMSE: 0,238654, MAE: 0,189555, rRMSE: 0,040195, rMAE: 0,031926 değerleriyle çok benzer sonuçlar üretmiştir. Bu sayısal yakınlık, algoritmaların temel öğrenme mekanizmalarının aynı yapıda olduğunu göstermektedir. Ancak ayrıntılı incelendiğinde, XGBoost modeli MAE ve rMAE açısından çok az farkla daha iyi performans sergilerken, FRF versiyonu RMSE ve rRMSE’de küçük bir üstünlük sağlamıştır. Bu durum, klasik modelin küçük sapmaları daha etkili şekilde düzelttiğini, ancak FRF modelinin uç değer sapmalarına karşı daha dirençli olduğunu göstermektedir.

Yapısal fark, öğrenme sürecinde öne çıkmaktadır. XGBoost her gözlemi rasgele olmayacak şekilde işlerken, FRF versiyonu her bir gözlemi birden fazla kümeye belli derecelerle atamaktadır. Bu yaklaşım, özellikle karma tanımlı bölgeler, mekânsal belirsizlik taşıyan ofis alanları veya tam sınıflandırılamayan bina özellikleri içeren veri kümelerinde avantaj yaratmaktadır. Örneğin bir ofisin hem A sınıfı hem B+ sınıfı nitelikleri taşıması hâlinde klasik model tek bir sınıfa zorla atama yaparken, FRF modeli bu çoklu aidiyeti dikkate alarak daha esnek tahmin üretmektedir. Bu fark, gayrimenkul

gibi nitel deęiřkenlerin sayısal aıklık gstermedięi durumlarda FRF XGBoost'un potansiyelini artırmaktadır.

Üüncü sırada yer alan modeller olan k-NN ve FRF RBF-SVM modelleri, benzer doęruluk seviyelerine ulaşmakla birlikte metodolojik olarak oldukça farklı yapılara sahiptir. k-NN modeli, komřuluk temelli basit bir yaklaşımı temsil ederken, RBF-SVM modeli yüksek boyutlu veri yapılarında doęrusal olmayan sınırlara duyarlılıęı artırmak amacıyla çekirdek fonksiyonları kullanmaktadır.

Performans açısından bakıldığında, k-NN modeli RMSE: 0,245066, MAE: 0,194609, rRMSE: 0,041275, rMAE: 0,032777 sonuçlarını verirken; FRF RBF-SVM modeli RMSE: 0,248785, MAE: 0,196069, rRMSE: 0,041901, rMAE: 0,033023 sonuçlarına ulaşmıştır. Bu karşılařtırmada, k-NN modeli tüm hata ölçütlerinde istatistiksel olarak ok az farkla daha düşük hata üretmiştir. Ancak bu farklar oldukça küçüktür ve pratik uygulamalarda genellikle anlamlı performans farkı oluşturmaz. Bununla birlikte, model yapılarına bakıldığında, k-NN modelinin sınırlı genelleme kapasitesi dikkate alındığında, FRF RBF-SVM'nin yüksek boyutlu ve karmařık örüntülere sahip veri yapılarında daha stabil alıřtığı söylenebilecektir.

FRF RBF-SVM'nin en önemli avantajı, çekirdek fonksiyonu ile doęrusal olmayan iliřkileri öğrenebilmesi ve bulanık kümeler üzerinden veri segmentasyonu yapabilmesidir. Bu yapı, özellikle deęiřkenlerin etkilerinin net sınırlara sahip olmadığı veri ortamlarında daha esnek karar yüzeyleri üretmesini saęlamaktadır. k-NN, benzerlięe dayalı öğrenme yaklaşımı ile öne ıkmakla birlikte, veri sayısı arttıka performansı düşebilirken, RBF-SVM modeli yüksek veri hacimlerinde daha kontrollü bir tahmin süreci sunmaktadır. Özellikle belirsizlik içeren gözlemlerde, FRF_RBF-SVM oklu etkileri daha bütüncül olarak deęerlendirebildięi için pratikte daha güvenilir bir alternatif haline gelmektedir.

Arařtırma sonuçlarının önemli sınırlılıklarının olduęunun gözden uzak tutulmaması gerekecektir. Öncelikle elde edilen sonuçların başkentte belirli lokal alanı ve sınırlı sayıda ofis binasını kapsadıęı ve sonuçların genelleřtirilmesinde ihtiyatlı olunması gerektięi

açıkça ifade edilmelidir. İkinci olarak kullanılan modelden geleceğe yönelik tahminlerin yapılamayacağı ve doğal olarak elde edilen sonuçların ofis pazarı kira oluşumu ve tahminleri için kullanım olanağının sınırlı olacağı da unutulmamalıdır. Bu alanda gelecek yıllarda yapılacak çalışmalarda daha geniş bölge ve hatta birden fazla ilde ofis binalarının kira parasının tahminine imkân verecek modellerle kapsamı analizlerin yapılması ve şok değişikliklerin ofis kiralari ve getirilerine olası etkilerinin tahminine odaklanması gerekli ve yararlı olacaktır.

8. SONUÇ VE ÖNERİLER

Ofis kiralarının belirlenmesinde etkili olan faktörlerin ortaya konulması hem akademik çalışmalar hem iş dünyası hem de gayrimenkul değerlendirme uygulamaları açısından stratejik öneme sahiptir. Literatürde yapılan çalışmalar, farklı istatistiksel ve yapay zekâ temelli yöntemlerin kullanıldığını göstermektedir. Örneğin, Aksoy (2005) tarafından İstanbul'un çeşitli merkezi bölgelerinde gerçekleştirilen analizde, Hedonik Regresyon yöntemi kullanılarak bölgesel boşluk oranlarının kira seviyeleri üzerinde belirleyici etkileri olduğu ortaya konmuştur. Benzer şekilde, Karımov'un (2010) çalışmasında, İstanbul'un merkezi iş alanlarındaki ofis kiraları; bina fiziksel özellikleri, ulaşım kolaylığı ve kiracı eğilimleri gibi çok boyutlu verilerle değerlendirilmiş, bulanık kural tabanlı sistemler aracılığıyla mekânsal farklılıklar derinlemesine incelenmiştir. Bu örnekler, karmaşık ve çok değişkenli gayrimenkul piyasalarında, geleneksel analiz yöntemlerinin yanı sıra daha esnek ve çok katmanlı modelleme tekniklerinin kullanımının önemini ortaya koymaktadır.

Ofis binalarının kira parasının tespitinde yalnızca gayrimenkul sahiplerinin beklentilerini değil, aynı zamanda kullanıcı taleplerini karşılayabilecek adil ve dengeleyici yaklaşımlar geliştirmek, sürdürülebilir piyasa düzeninin tesis edilmesi açısından kritik rol oynamaktadır. Son yıllarda hızla gelişen teknolojiler ve artan veri işleme kapasiteleri sayesinde, ofis kiralarının tahmini için geliştirilen modeller daha yüksek doğruluk düzeyine ulaşmış ve geleneksel yaklaşımların ötesine geçmiştir. Bu doğrultuda geliştirilen yeni nesil kestirim modelleri, ofis kiralarını daha nesnel, veriye dayalı ve dinamik bir biçimde tahmin etme olanağı sunarak gayrimenkul sektöründe karar alma süreçlerini desteklemektedir. Ancak geleneksel istatistiksel modeller, değişkenler arasındaki ilişkileri çoğunlukla doğrusal yapılarla açıklamaya çalışmakta; bu da mekânsal farklılıklar, eksik veriler ve pazarın heterojen yapısı gibi nedenlerle modelin açıklayıcılık gücünü sınırlayabilmektedir. Mekânsal bağımlılıkların dikkate alınması belirli avantajlar sağlasa da mekânsal veri setlerinin büyüklüğü ve çeşitliliği, model performansını olumsuz yönde etkileyen yeni zorluklar ortaya çıkarmaktadır. Özellikle büyük ölçekli ticari gayrimenkul projelerinde kiralanabilir alan talebindeki değişimler, ofis kira değerlemelerinde yüksek doğrulukta tahmin gereksinimini doğurmaktadır. Bu

gereksinim, klasik yöntemlerin ötesine geçilerek, daha esnek, uyarlanabilir ve veri odaklı çözümler sunan makine öğrenmesi yaklaşımlarının kullanılmasını gerektirmektedir.

Araştırma, söz konusu ihtiyaçlara yanıt verebilmek için yüksek hacimli veri setleri, mekânsal ve yapısal heterojenliği dikkate alan modeller ve tahmin doğruluğunu artıracak nitelikteki değişken seçimi stratejileriyle kapsamlı bir analiz sunmaktadır. Makine öğrenmesi temelli bu yaklaşım, ofis kiralarının belirlenmesinde hem akademik hem de uygulamalı bağlamda yeni bir perspektif sunarak, gayrimenkul pazarına yönelik daha isabetli ve güvenilir öngörüler geliştirilmesine katkı sağlamaktadır. Bu bağlamda geliştirilen bu tez çalışmasında, klasik değerlendirme yöntemlerinin eksikliklerini gidermek ve ofis kira değerlemesini daha gerçekçi, dinamik ve belirsizliği içerecek bir biçimde modellemek amacıyla, makine öğrenmesi yöntemleri ile FRF'nin birlikte kullanıldığı yenilikçi bir yaklaşım geliştirilmiştir. Özellikle Ankara ili Çankaya ilçesi örneği üzerinden yürütülen bu araştırma, gayrimenkul piyasalarının doğası gereği sahip olduğu mekânsal ve yapısal heterojenliği dikkate alarak, ofis kiralarının belirlenmesinde daha hassas, esnek ve yüksek doğruluk düzeyine sahip modeller oluşturulabileceğini ortaya koymaktadır.

Araştırma sonuçları sadece akademik çevreler için değil, kamu planlama otoriteleri, gayrimenkul geliştiricileri, finansal kuruluşlar ve politika yapıcılar açısından da değerli bulunmaktadır. Elde edilen modeller, yerel yönetimlerin ofis alanlarına ilişkin mekânsal planlamaları, kira müdahale stratejileri ve yatırım teşvik politikaları için kullanılabilecek özelliklere sahip bulunmaktadır. Özellikle pazar bölümlendirmesi ve belirsizlik analizi, karar vericilerin daha adil, hedefli ve kanıta dayalı politikalar geliştirmesine katkı sağlayabilecektir.

Araştırmanın bulguları, Ankara ili Çankaya ilçesindeki A, A+ ve B+ sınıfı ofis binalarına dayansa da kullanılan metodolojik yaklaşımın mekânsal, yapısal ve piyasa temelli değişkenleri birlikte dikkate alması sayesinde, benzer veri yapılarının mevcut olduğu diğer büyükşehirlerde de uyarlanabilir ve genelleştirilebilir niteliktedir. Ancak, her kentin kendine özgü sosyo-ekonomik yapısı, arz-talep dengesi ve mekânsal planlama koşulları farklılık gösterdiğinden, genelleme yapılmadan önce bölgesel piyasa dinamiklerinin

dikkatle analiz edilmesi gerekmektedir. İlerleyen çalışmalarda, modelin kapsamının genişletilerek konut, ticari alan ve lojistik gibi farklı gayrimenkul türlerini de içermesi; ayrıca satış fiyatları, boşluk oranları, yatırım getirileri gibi ek değişkenlerin dahil edilmesi, modelin hem öngörü gücünü hem de karar destek sistemlerine entegrasyon potansiyelini önemli ölçüde artıracaktır.

Araştırmanın temel çıkış noktası, literatürde sıklıkla vurgulanan gayrimenkul piyasalarındaki mekânsal farklılıklar ve heterojenlik olgusudur (Jud ve Winkler 1995; Dunse ve Jones 2002 ve Debrezion ve Willigers 2008). Bu çerçevede, PB kavramı ön plana çıkarılmış; homojen alt pazarların belirlenmesinin, değerlendirme modellerinin doğruluk düzeyini artırmada kritik bir etkiye sahip olduğu ortaya konmuştur. Bunun yanı sıra, ofis pazarında sıkça karşılaşılan belirsizliklerin (örneğin, kullanıcı tercihleri, algılanan çevresel kalite gibi ölçülemeyen değişkenlerin) klasik regresyon yöntemleri ile yeterince temsil edilemediği görülmektedir. Bu nedenle, FRF yöntemi kullanılarak, verideki belirsizliklerin sistematik bir şekilde modele dâhil edilmesi sağlanmıştır. Tanaka vd. (1982) ve Diamond (1988) gibi öncü çalışmaların da gösterdiği üzere, bulanık regresyon modelleri, belirsizlik içeren verilerde doğrusal modellere kıyasla daha etkili sonuçlar üretebilmektedir.

Ayrıntılı biçimde değerlendirilen karşılaştırmalı analizler gerek makine öğrenmesi gerekse FRF yaklaşımı altında geliştirilen modellerin, ofis kiralarının tahmininde yüksek düzeyde başarı sağladığını göstermektedir. Her iki yöntem kümesinde de RF ve XGBoost algoritmaları en iyi performansları sunarken, üçüncü sırada yer alan k-NN ve RBF-SVM gibi modeller daha sınırlı ancak istikrarlı sonuçlar üretmiştir. Belirleyici fark ise, bulanık kümeleme temelli yaklaşımların, klasik makine öğrenmesi algoritmalarına kıyasla belirsizliğe, sınır geçişlerine ve çoklu etkili gözlemlere karşı daha esnek ve uyarlanabilir bir yapı sunduğu noktada ortaya çıkmaktadır. Özellikle FRF RF ve FRF XGBoost modelleri, klasik versiyonlarına oldukça yakın hata oranları üretmekle kalmamış, aynı zamanda MAE ve rMAE gibi küçük hata odaklı metriklerde daha düşük sapmalar sağlayarak yorumlanabilirlik açısından dengeli ve güvenilir tahminler sunmuştur.

Belirsizlik ve sınır geişlerine karşı uyarlanabilirlik avantajına ek olarak, FRF modellerinin yapısal esnekliğı, niteliklerin ve sınıflandırma sınırlarının bulanıklaştığı gerçek dünya koşullarında model başarısını önemli ölçüde artırmaktadır. Özellikle pazar bölümlerinin iç içe geçtiğı, kullanıcı tercihlerinin ölçülemez faktörlerle şekillendiğı ya da yapısal belirsizlik taşıyan veri ortamlarında, FRF modellerinin ürettiğı sonuçlar yalnızca sayısal doğruluğı değil, aynı zamanda karar destek sistemleri açısından daha gerçekçi ve bağlamsal doğruluğı da içinde barındırmaktadır. Bu yönüyle, çalışma kapsamında test edilen modeller arasında klasik makine öğrenmesi algoritmalarının yüksek tahmin doğruluğı avantajı ile, FRF modellerinin belirsizliğı yöneten esnek öğrenme yapısı arasında tamamlayıcı bir ilişki olduğu ortaya çıkmaktadır. Dolayısıyla, ofisler gibi çok boyutlu ve heterojen yapıya sahip pazarlarda, her iki yaklaşımın birlikte değerlendirilmesi hem kuramsal hem de uygulamalı düzeyde daha güçlü karar mekanizmalarının geliştirilmesine katkı sağlamaktadır. Ayrıca, geliştirilen modelleme yaklaşımlarının yalnızca teknik doğruluk sağlaması değil, aynı zamanda kentsel planlama, ofis arz-talep dengesinin yönetimi, yatırım kararlarının yönlendirilmesi ve kullanıcı memnuniyetinin artırılması gibi sosyal ve yönetsel süreçlerde de önemli katkılar sunabileceğı değerlendirilmektedir. Bu tür modellerin ofis pazarındaki aktörler tarafından kullanılması, karar alma süreçlerinin nesnellik temelinde şekillendirilmesini kolaylaştırmakta ve piyasa aktörleri arasında şeffaflığı artırmaktadır.

Gelişmiş ülkelerde faaliyet gösteren kiralama şirketleri ile değerlendirme kuruluşları, gayrimenkul pazar analizlerinde CoStar, Argus, Real Capital Analytics ve Yardi Matrix gibi gelişmiş yazılımlardan yararlanmaktadır. Bu sistemler; büyük veri işleme kapasitesi, otomatik tahminleme mekanizmaları ve mekânsal modelleme araçlarını bir arada sunan entegre platformlar olarak öne çıkmaktadır. Bu tez kapsamında R programlama dili ile geliştirilen modeller, uygun yazılım mimarileri ve uygulama programlama arayüzleri aracılığıyla söz konusu sistemlerle entegre edilebilecek şekilde modüler ve esnek bir yapıda tasarlanmıştır. Türkiye’de benzer dijital altyapıların geliştirilmesine katkı sağlayabilecek bu model, yerli yazılım çözümleriyle bütünleştirildiğinde, gayrimenkul sektörüne yönelik veri temelli karar destek sistemlerinin oluşturulmasında işlevsel bir bileşen olarak değerlendirilebilecektir.

Karşılaştırmalı analizler aynı zamanda, FRF ile desteklenmemiş standart makine öğrenmesi yöntemlerinin de yüksek doğruluk sağladığını, ancak bulanık bölümlendirme eklemesinin özellikle heterojen veri yapısına sahip gayrimenkul piyasalarında model başarımını anlamlı ölçüde artırdığını göstermektedir. Literatürde makine öğrenmesi yöntemlerinin gayrimenkul değer tahminindeki etkinliğine ilişkin çeşitli bulgulara yer verilmektedir (Peterson vd., 2009; Moosavi 2017 ve Yoshida vd. 2024), ancak bu araştırmada, FRF ile PB'nin entegrasyonu sayesinde tahmin hatalarının daha da azaltılabildiği ortaya konulmuştur. Çalışmanın başka bir bulgusu da, emsal karşılaştırma yöntemi ile makine öğrenmesi ve bulanık model yaklaşımlarının doğrudan karşılaştırılmasıdır. Araştırma sonuçlarına göre geleneksel değerlendirme yöntemleri, veri setinin genişliği ve değişkenlerin karmaşıklığı karşısında sınırlı performans gösterebilmekte, oysa makine öğrenmesi temelli modeller çok sayıda değişkenin etkisini aynı anda analiz edebilme kabiliyetiyle daha başarılı tahmin sonuçları üretebilmektedir.

Çalışmanın sınırlılıkları ve bulguları ışığında, gelecekte yapılacak araştırmalarda bazı geliştirmelere odaklanılması önerilmektedir. Öncelikle, veri setinin zaman serisi özellikleri daha ayrıntılı bir şekilde dikkate alınarak, kiralardaki zamansal değişimlerin modellenmesi sağlanmalı ve dinamik modellemeler geliştirilebilmektedir. Bunun yanı sıra, farklı şehirlerde veya ülkelerde benzer pazar bölümlendirme ve bulanık regresyon uygulamaları yapılarak, geliştirilen modellerin farklı coğrafi ve ekonomik ortamlardaki geçerliliği test edilebilmektedir. Ayrıca, yapay zekâ tabanlı daha gelişmiş yöntemler (örneğin, derin öğrenme ağları veya hibrit modellemeler) bulanık modelleme teknikleriyle birlikte kullanılarak, çok daha büyük veri setleri ve daha karmaşık ilişkiler daha yüksek doğrulukla modellenebilmektedir. Son olarak, kullanıcı algısını ve çevresel kaliteyi doğrudan ölçebilecek anket verileri gibi veri kaynakları toplanarak, bu tür subjektif değişkenlerin kira kestirim modellerine entegrasyonu sağlanabilmektedir.

Makine öğrenmesi teknikleri, büyük veri setlerinden yüksek doğrulukta tahminler üretme kabiliyetleri sayesinde gayrimenkul değerlendirme süreçlerinde giderek daha fazla kullanılmaktadır. Ancak, bu yöntemlerin sahip olduğu bazı yapısal ve uygulamaya özgü sınırlamaların dikkatlice değerlendirilmesi gerekmektedir. Öncelikle, makine öğrenmesi genellikle veriye dayalı bir yaklaşım benimsemekte; bu da onu pazarın yapısal

dinamiklerini analiz etmekten çok, verilerdeki örüntüleri tanımaya yönlendirmektedir. Bu durum, modelin karar alma süreçlerinde şeffaflık sunamamasına ve yorumlanabilirliğinin azalmasına yol açabilmektedir. Ayrıca, özellikle heterojen veri kümelerinde karşılaşılan aşırı öğrenme riski, modelin yalnızca eğitim verisine sıkı sıkıya bağlı kalmasına ve bu nedenle genelleme yetisinin zayıflamasına neden olabilmektedir. Eğitim sürecinde kullanılan algoritmaların seçimi, hiperparametrelerin dikkatle ayarlanması ve veri ön işleme süreçlerinin titizlikle yürütülmesi, bu modellerin etkinliği açısından son derece kritik adımlardır. Ancak bu süreçler hem teknik uzmanlık hem de ciddi zaman ve kaynak gerektirir (Bansal vd. 2022). Bu nedenlerle, makine öğrenmesine dayalı yaklaşımlar, geleneksel yöntemlerle birlikte tamamlayıcı bir araç olarak değerlendirilmelidir.

Sonuç olarak araştırmada, veri temelli ve çok boyutlu modelleme yaklaşımlarının, özellikle mekânsal olarak heterojen ve yapısal olarak karmaşık olan gayrimenkul piyasalarında, değerlendirme süreçlerinde gelecekte daha geniş bir biçimde benimsenmesi gerektiği ortaya konulmaktadır. Ofis kiralarının doğru, nesnel ve güncel şekilde tahmin edilmesine yönelik geliştirilen bu yaklaşımlar hem modelleme doğruluğunu artırmakta hem de geleneksel yöntemlerin sınırlılıklarını önemli ölçüde aşmaktadır. Araştırmada uygulanan makine öğrenmesi algoritmaları ve FRF'nin karşılaştırmalı analizleri, her iki yaklaşımın da belirli bağlamlarda güçlü yönler sunduğunu göstermekte ve özellikle belirsizlik, veri eksikliği ve çoklu değişkenli yapıların baskın olduğu ortamlarda bu modellerin birbirini tamamlayıcı biçimde kullanılabileceğini göstermektedir. Bu bağlamda araştırma, literatürde uzun süreden bu yana tartışılan metodolojik eksikliklere cevap vermekte ve çok katmanlı veri yapılarının analizine yönelik yenilikçi çözümler ortaya koymaktadır. Ayrıca bu araştırma, yalnızca teorik bir çerçeve sunmakla kalmamakta; aynı zamanda uygulamalı düzeyde geliştirilen modeller aracılığıyla, ilerleyen araştırmalara hem teknik hem de uygulayıcı düzlemde sağlam bir zemin oluşturmakta ve bu yolla gayrimenkul değerlemesi disiplininde yeni yöntemsel açılımlara vurgu yapmaktadır. Özellikle yerel, bölgesel ve ulusal gayrimenkul pazarlarında gayrimenkul türlerine göre kira parası ve değer oluşumuna ilişkin daha kapsamlı çalışmaların yapılması, hem geliştirme projelerinin analizi hem de gayrimenkul pazar stratejilerinin geliştirilmesi sürecine önemli ölçüde katkı yapabilecektir.

KAYNAKLAR

- Abdullahi, A., Usman, H. and Ibrahim, I. 2018. Determining house price for mass appraisal using multiple regression analysis modeling in Kaduna North, Nigeria. *ATBU Journal of Environmental Technology*, 11(1), 26-40
- Abidoye, R. B. and Chan, A. P. C. 2017. Critical review of hedonic pricing model application in property price appraisal: A case of Nigeria. *International Journal of Sustainable Built Environment*, 6(1), 250-259.
- Adnan, Y. M., Daud, M. N., Ahmad, I. M. and Aziz, A. 2009. Determining the criteria for the classification of purpose built office buildings in malaysia. *Pacific Rim Property Research Journal*, 15(2), 225-243.
- Ali, N., Neagu, D. and Trundle, P. 2019. Evaluation of k-nearest neighbour classifier performance for heterogeneous data sets. *SN Appl. Sci.* 1, 1559.
- Alkan, T., Dokuz, Y., Ecemiş, A., Bozdağ, A. ve Durduran, S., S. 2023. Using machine learning algorithms for predicting real estate values in tourism centers. *Soft Comput* 27, 2601-2613.
- Alshboul O, Shehadeh A, Almasabha G. and Almuflih AS. 2022. Extreme Gradient Boosting-Based Machine Learning Approach for Green Building Cost Prediction. *Sustainability*, 14(11), 6651.
- Altman, N. S. 1992. An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175-185.
- Akbaş, A. ve Ayanoğlu, Y. 2025. Maddi olmayan duran varlıkların Uluslararası Değerleme Standartları ile Uluslararası Muhasebe Standartları açısından karşılaştırılması. *Muhasebe ve Denetim Bakış Dergisi*, (75), 77-102.
- Akinsomi, O., Mkhabela, N. and Taderera, M. 2018. The role of macro-economic indicators in explaining direct commercial real estate returns: evidence from South Africa. *Journal of Property Research*, 35(1), 28-52.
- Aksoy, S. 2005. İstanbul Metropolen Alanı'nda Ofis Kira Değerini Etkileyen Faktörlerin Analizi. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Gayrimenkul Geliştirme Anabilim Dalı, İstanbul.
- Ando, M. 2024. The Impact of Low Interest Rates on Japanese Property Prices. *The Worldfolio*. <https://www.theworldfolio.com/interviews/the-impact-of-low-interest-rates-on-japanese-property-prices/6431/>. Erişim Tarihi: 30.09.2024.
- Anonim. 2024a. Türkiye İstatistik Kurumu Konut Satış İstatistikleri Raporu. Ankara.
- Anonim. 2024b. Türkiye İnşaat Malzemesi Sanayicileri Derneği Aylık Sektör Raporu. İstanbul.

- Anonim. 2025. Türkiye İstatistik Kurumu Temel İşgücü Göstergeleri. Ankara.
- Anonymous. 2024a. Web Sitesi: <https://www.pwc.com/gx/en/industries/financial-services/real-estate/emerging-trends-real-estate/global-outlook-2022.html>. Erişim Tarihi: 30.09.2024.
- Anonymous. 2024b. Web Sitesi: <https://www.cbre.com/-/media/project/cbre/shared-site/insights/books/uk-real-estate-market-outlook-2023/uk-real-estate-market-outlook-2023.pdf>. Erişim Tarihi: 30.09.2024.
- Anonymous. 2024c. Web Sitesi: <https://www.rics.org/news-insights/current-topics-campaigns/sustainability/sustainability-report-2024>. Erişim Tarihi: 22.10.2024.
- Anonymous. 2024ç. Web Sitesi: <https://content.knightfrank.com/research/104/documents/en/the-london-office-market-report-2023-q2-10422.pdf>. Erişim tarihi: 22.10.2024.
- Anonymous. 2024d. Web Sitesi: <https://www2.deloitte.com/cn/en/pages/financial-services/articles/financial-services-industry-outlooks-2023/pr-commercial-real-estate-outlook.html>. Erişim tarihi: 22.10.2024.
- Anonymous. 2024e. Web Sitesi: <https://www.geeksforgeeks.org/ridge-regression-vs-las-so-regression/>. Erişim tarihi: 20.12.2024.
- Anonymous. 2025a. Web Sitesi: <https://www.google.com/earth/>. Erişim Tarihi: 14.02.2025.
- Anonymous. 2025b. Uluslararası Değerleme Standartları Konseyi Uluslararası Değerleme Standartları. Londra.
- Anonymous. 2025c. Web Sitesi: <https://boma.org/boma-standards/building-class-definitions/> Erişim Tarihi: 01.06.2025.
- Anonymous. 2025ç. Web Sitesi: <https://www.rics.org/news-insights/market-surveys/global-commercial-property-monitors>. Erişim Tarihi: 01.06.2025.
- Anonymous. 2025d. Web Sitesi: <https://www.jll.com/en-us/insights/market-perspectives/global>. Erişim Tarihi: 09.06.2025.
- Arı, E. 2018. Konut sektöründe kira çarpanları analizi: Ankara ili Mamak ilçesi Kayaş bölgesi örneği. Yüksek Lisans Tezi. Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Ayar, M.D. ve Şen, A. 2023. Makine Öğrenimi Yöntemlerini Kullanarak Gayrimenkul Değer Tahmini. 19. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara, Türkiye, 1.
- Aydemir, E., Aktürk, C. ve Yalçınkaya, M. A. 2020. Yapay zekâ ile konut fiyatlarının tahmin edilmesi. Turkish Studies-Applied Sciences, 15(2), 183-194.

- Aydın, Z.E. 2021. Balina optimizasyonu algoritması ve rastgele alt uzaylar temelli eksik veri tamamlama yöntemleri.
- Aydınoğlu, A.Ç., Bovkır, R. ve Çölkesen, İ. 2023. Toplu taşınmaz değerlemede makine öğrenme algoritmalarının kullanımı ve konumsal/konumsal olmayan özniteliklerin tahmin doğruluğuna etkilerinin karşılaştırılması. *Jeodezi ve Jeoinformasyon Dergisi*, 10(1), 63-83.
- Babuška, R. and Verbruggen, H. B. 1997. Constructing Fuzzy Models by Product Space Clustering. In: Hellendoorn, H., Driankov, D. (eds.) *Fuzzy Model Identification: Selected Approaches*. Springer, pp. 53-90, Berlin.
- Bahrambanan, F., Alizamir, M., Moradveisi, K., Heddami, S., Kim, S., Kim, S., Soleimani, M., Afshar, S. and Taherkhani, A. 2025. The development of an efficient artificial intelligence-based classification approach for colorectal cancer response to radiochemotherapy: Deep learning vs. machine learning. *Scientific Reports*, 15(1), Article 62.
- Balchin, P., Kieve, J. and Bull, G. H. 2000. *Urban Land Economics and Public Policy*. Palgrave Macmillan.
- Bansal, A., Sharma, D. and Goel, A. 2022. *Machine Learning Algorithms: Foundations and Applications*. Springer.
- Başer, F. 2013. Aktüeryal Modellemede Bulanık Destek Vektör Makineleri. Doktora Tezi. Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Başer, F., Koç, O., Kestel, A.S.S. 2023. Credit Risk Evaluation Using Clustering Based Fuzzy Classification Method, *Expert Systems With Applications* 223 (2023) 119882, 1-12.
- Belgiu, M. and Drăguț, L. 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31.
- Bera, A. K., and Kangalli Uyar, S. G. 2019. Local and global determinants of office rents in Istanbul: The mixed geographically weighted regression approach. *Journal of European Real Estate Research*, 12(2), 227-249.
- Beracha, E., Hardin, W. G. III, and Skiba, H. M. 2018. Real Estate Market Segmentation: Hotels as Exemplar. *The Journal of Real Estate Finance and Economics*, 56, 252-273.
- Bezdek, J. C. 1981. *Pattern Recognition with fuzzy objective function*. Plenum press, New York
- Bilgilioglu S., S. and Yılmaz H., M. 2021. Comparison of different machine learning models for mass appraisal of real estate, *Survey Review*,

- Bourassa, S.C., Cantoni, E. and Hoesli, M. 2007. Spatial Dependence, Housing Submarkets, and House Price Prediction. *The Journal of Real Estate Finance and Economics*, 35, 143-160.
- Breiman, L., Friedman, J. H., Olshen, R. A. and Stone, C. J. 1984. *Classification and Regression Trees*. Wadsworth International Group. New York.
- Breiman, L. 2001. Random Forests. *Machine Learning*, 45(1), 5-32.
- Burges, C.J. 1998. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery* 2, 121-167.
- Burhan, H. A. 2023. Konut Fiyatları Tahmininde Makine Öğrenmesi Sınıflandırma Algoritmalarının Kullanılması: Kütahya Kent Merkezi Örneği, *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, 76, 221-237.
- Cao, S., Liao, W. and Huang, J. 2023. Research on Renting Price Prediction Based on Machine Learning. *Proceedings of the 5th Management Science Informatization and Economic Innovation Development Conference, MSIEID 2023*, December 8-10, Guangzhou, China.
- Ceh, M., Viitanen, K. and Perus, I. 2012. A non-parametric CAE approach to office rents: Identification of Helsinki metropolitan area submarkets. *Expert Systems with Applications*, 39(1), 460-471.
- Chang, C.L., and Ayyub, B.M. 1995. Fuzzy regression methods – a comparative assessment. *Fuzzy Sets and Systems*, 74(3), 375-393.
- Chan H., R., 2023. Rent price prediction with advanced machine learning methods: a comparison of California and Texas. *Highlights in Science, Engineering and Technology*, 85(2024), 505-522.
- Chatterjee, S. and Hadi, A.S. 2015. *Regression Analysis By Example*: John Wiley and Sons.
- Cheah, J.H., Ting, H., Thaichon, P., Fam, K.S. and Bazylewich, M. 2021. Can positioning strategies help influence willingness to pay for office space? Evidence on the moderating effect of office space grade and industry sector for occupiers of leased office space. *Journal of Strategic Marketing*, 29(4) 1-22.
- Chen, Z., Cho, S., Poudyal, N. and Roberts, R. K. 2009. Forecasting Housing Prices under Different Market Segmentation Assumptions. *Urban Studies (Edinburgh, Scotland)*, 46(1), 167-187.
- Chen, T. and Guestrin, C. 2016. XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794.
- Clapp, J., Pollakowski, H.O. and Lynford, L. 1992. Intrametropolitan location and office market dynamics. *Real Estate Economics*, 20(2), 229-258.

- Cortes, C. and Vapnik, V. 1995. Support-vector networks. *Machine Learning* 20, 273-297.
- Costa, O., Fuerst, F. and Mendes-Da-Silva, W. 2016. Office market segmentation in emerging markets: A study of Sao Paulo. Available at SSRN 2831615.
- Cover, T. and Hart, P. 1967. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21-27.
- Cutler, D.R., Edwards Jr, T.C., Beard, K.H., Cutler, A., Hess, K. T., Gibson, J. and Lawler, J.J. 2012. Random Forests for Classification in Ecology. *Ecology Society Of America*, 88(11), 2783-2792.
- Çelik, K. 2022. Gayrimenkul değerlemesinde geleneksel yöntemler. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 12(1), 246-259.
- Çelikyılmaz, A. and Türkşen, I. B. 2007. Fuzzy functions with support vector machines. *Information Sciences*, 177, 5163-5177.
- Çelikyılmaz, A. and Türkşen, I.B. 2008. Enhanced Fuzzy system models with improved fuzzy clustering algorithm. *IEEE Transactions on Fuzzy Systems*, 16(3), 779-794.
- Çelikyılmaz A. and Türkşen, I.B. 2009. *Modeling Uncertainty with Fuzzy Logic: With Recent Theory and Applications*. Springer-Verlag, pp. 11-119, Berlin Heidelberg.
- Daguplo, R.J.R. 2025. An enhanced K-nearest neighbors (KNN) algorithm for predicting child malnutrition in the city of Manila. *International Journal for Multidisciplinary Research*, 7(2), 1-15.
- Dale-Johnson, D. 1982. An Alternative Approach to Housing Market Segmentation Using Hedonic Price Data. *Journal of Urban Economics*, 11, 311-332.
- Dalkılıç, H.Y., Yeşilyurt, S.N. and Samui, P. 2021. Daily Flow Modeling With Random Forest and K-Nearest Neighbor Methods. *Erzincan University Journal of Science and Technology*, 14(3), 914-925.
- Daud, M.N., Adnan, Y.M., Mohd, I. and Aziz, A.A. 2011. Developing a model for Malaysia's office classification. *Building Research & Information*, 39(3), 301-313.
- Deaconu A., Buiga A. and Tothăzan H. 2022. Real estate valuation models performance in price prediction. *International Journal of Strategic Property Management*, 26(2):86-105.
- Debrezion, G. and Willigers, J. 2008, The effect of railway stations on office space rent levels: The implication of HSL South in station Amsterdam South Axis. In: Bruinsma, F., Pels, E., Rietveld, P., Priemus, H., van Wee, B. (eds) *Railway Development*. Physica-Verlag HD, 265-293.

- Delventhal, M. J., Kwon, E. and Parkhomenko, A. 2022. JUE Insight: How do cities change when we work from home? *Journal of Urban Economics*, 127, 103331.
- Demirhan, H. ve Başer, F. 2024. Hierarchical fuzzy regression functions for mixed predictors and an application to real estate price prediction. *Neural Computing and Applications*, 36(19), 11545-11561.
- Demirkaya, S. 2025. Ofis Binalarının Mekânsal Organizasyonu ve Mekânsal Tasarım Parametrelerinin Kullanıcı Memnuniyeti ve Yönetim Başarısına Etkileri: Ankara İli Ofis Piyasaları Örneği, Doktora Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü Gayrimenkul Geliştirme ve Yönetimi Anabilim Dalı, Ankara.
- Demirkaya, S., Tanrıvermiş, H. ve İncesu, Ö.E. 2025. Ofis Yatırımlarının Gelişimi ve Ofis Binalarının Yönetiminin Değerlendirilmesi: Ankara İli Ofis Piyasası Örneği, *İdealkent Kent Araştırmaları Dergisi (Journal of Urban Studies)*, 18(49), 32-61.
- Deppner, J., von Ahlefeldt-Dehn, B., Beracha, E. and Schaefer, W. 2023. Boosting the accuracy of commercial real estate appraisals: An interpretable machine learning approach. *J Real Estate Finan Econ*.
- Derinpınar, M.A. 2014. Bulanık mantık ile coğrafi bilgi teknolojilerini kullanarak taşınmaz değerlendirme: Sarıyer-İstanbul Örneği. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Bilişim Enstitüsü, İstanbul.
- Diamond, P. 1988. Fuzzy least squares. *Information Sciences*, 46(3), 141-157.
- Dilaver, D. 2016. Ofis yer seçimi kriterlerinin belirlenmesi: Anadolu Yakası A sınıfı ofis piyasası örneği. Yüksek lisans tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Doğan, O., Bande, N., Genç, Y. ve Akyon, F.C. 2022. Keçiören/Ankara Özelinde Konut Rayiç Değerlerinin Yapay Sinir Ağları Metodu Kullanılarak Tahmini. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, (35), 113-128.
- Doldur, M. ve Alkan, R.M. 2021. Nominal değerlendirme yöntemi ile Cbs destekli gayrimenkul değer haritalarının oluşturulması: Avanos/Nevşehir örneği. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 21, 846-863.
- Draper, N.R. and Smith, H. 1998. *Applied regression analysis*. John Wiley & Sons.
- Dudani, S.A. 1976. The distance-weighted k-nearest-neighbor rule. *IEEE Transactions on Systems, Man, and Cybernetics*, 6(4), 325-327.
- Dunse, N. and Jones, C. 2002. The existence of office submarkets in cities. *Journal of property Research*, 19(2), 159-182
- Edinsel, E.H. 2023. Bulanık Regresyon Fonksiyonları Yöntemi İle Konut Kredisi Riski Modellemesi. Ankara Üniversitesi Gayrimenkul Geliştirme ve Yönetimi Anabilim Dalı Yüksek Lisans Tezi.

- Eichholtz, P., Kok, N. and Quigley, J.M. 2010. Doing well by doing good? Green office buildings" American Economic Review, 100 (5), 2492-2509.
- Eichholtz, P., Kok, N. ve Quigley, J. M. 2013. The economics of green building. The Review of Economics and Statistics, 95(1), 50-63.
- Elmas, Ç. 2003. Yapay zeka ve bulanık mantık uygulamaları. Seçkin Yayıncılık, Ankara.
- Erkek, M., Çayırılı, K. and Alpaydın, Y. 2020. Predicting House Prices in Turkey by Using Machine Learning Algorithms. Journal of Statistical and Econometric Methods, 9(4), 35-54.
- Ezber Kurtar, S. ve Tanrıvermiş, H. 2024. Çok katlı meskenlerde bağımsız bölüm değeri ve şerefiye değerini etkileyebilecek faktörlerin değerlendirilmesi. Avrasya Bilimler Akademisi İşletme ve İktisat Dergisi, 38, 21-44.
- Esperanzo, M. and Gallego, J. 2004. Artificial Intelligence Applied to Real Estate Valuation an Example fort he Appraisal of Madrid. Catastro. April 2004, 255-265.
- Feng, Z. and Wu, Z. 2022. Local economy, asset location and REIT firm growth. The Journal of Real Estate Finance and Economics, 65(1), 75-102.
- Fisher, J.D. ve Martin, R. 2004. Income property valuation. Dearborn Real Estate Education.
- Fix, E. and Hodges, J.L. 1951. Discriminatory analysis: Nonparametric discrimination, consistency properties. US Air Force School of Aviation Medicine, No. 4, 1-31.
- Fonnesbech-Wulf, A., Termansen, M., Fuglsang, M., Smart, J., Ladenburg, J. and Hasler, B. 2011. Welfare impacts of landscape dis-amenities: comparative hedonic approaches. Conference of the Danish Environmental Economic Council.
- Friedman, J.H. 2001. Greedy function approximation: A gradient boosting machine. Annals of Statistics, 29(5), 1189-1232.
- Fuerst, F. ve McAllister, P. 2011. Green noise or green value? Measuring the effects of environmental certification on office values. Real Estate Economics, 39(1), 45-69.
- Gabrielli, L., Giuffrida, S. and Trovato, M.R. 2017. Gaps and Overlaps of Urban Housing Sub-market: Hard Clustering and Fuzzy Clustering Approaches, in Appraisal: From theory to practice, pp. 203-219.
- Galton, F. 1886. Regression towards mediocrity in hereditary stature. The Journal of the Anthropological Institute of Great Britain and Ireland, 15, 246-263.
- Gauss, C.F. 1821. Theoria combinationis observationum erroribus minimis obnoxiae. Royal Society of Göttingen.

- Geltner, D., Miller, N., Clayton, J. and Eichholtz, P. 2013. Commercial real estate analysis and investments. Cengage Learning.
- Gholipour, H.F., Arjomandi, A., Farzanegan, M.R. and Yam, S. 2022. Global and local economic uncertainties and office vacancy in Australia: a sub-class analysis. *Applied Economics*, 54(47), 5393-5411.
- Goodfellow, I., Bengio, Y., and Courville, A. 2016. Deep Learning. Massachusetts Institute of Technology Press.
- Goodman, A.C. and Thibodeau, T.G. 1998. Housing Market Segmentation. *Journal of Housing Economics*, 7, 121-143.
- Gönden, T., İnci, G.N. ve Körlü, E. 2025. MarketBeat Türkiye 2025 yılı 1. çeyrek raporu. <https://cw-tr.com/tr/arastirma-detay/1921/turkiye-marketbeat-1ceyrek-2025>. Erişim Tarihi: 10.06.2025.
- Graham, M.F. and Bible, D.S. 1992. Classifications for commercial real estate. *The Appraisal Journal*, 60(2), 237-246.
- Green, A. ve Sanghvi, A. 2024. The real deal with real estate deals. McKinsey & Company. <https://www.mckinsey.com/featured-insights/sustainable-inclusive-growth/charts/the-real-deal-with-real-estate-deals>. Erişim Tarihi: 22.10.2024.
- Güran, A., Uysal, M ve Doğrusöz Ö. 2014. Destek vektör makineleri parametre optimizasyonunun duygu analizi üzerindeki etkisi. *Dokuz Eylül üniversitesi Mühendislik Fakültesi Mühendislik Bilimleri Dergisi Cilt: 16 Sayı: 48 sh. 86-93*.
- Gyourko, J. and Keim, D.B. 1992. What does the stock market tell us about real estate returns? *Real Estate Economics, American Real Estate and Urban Economics Association*, vol. 20(3), pages 457-485.
- Hacıbeyoğlu, M., Çelik, M. ve Çiçek, E.N. 2023. K-En Yakın Komşu Algoritması ile Binalarda Enerji Verimliliği Tahmini. *Necmettin Erbakan Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 2(1), 65-74
- Halder, R.K., Uddin, M.N., Uddin, M.A., Aryal, S. and Khraisa, A. 2024. Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications. *J Big Data* 11, 113.
- Hatipoğlu, Ü. ve Tanrıvermiş, H. 2017. Türkiye’de arz ve talep açısından konut yatırım tercihlerini etkileyen faktörlerin değerlendirilmesi, *Bankacılar*, 28 (100), 49-75.
- Hatipoğlu, Ü. ve Tanrıvermiş, H. 2024. Bir demografik faktör olarak nüfusun konut yatırımı geri dönüş süresi üzerindeki etkisi: İstanbul ilinin analizi. *Bankacılar Dergisi*, (130), 39-64.
- Hastie, T., Tibshirani, R. and Friedman, J. 2009. The elements of statistical learning: Data mining, inference, and prediction. Springer Science & Business Media.

- Hendershott, P.H., MacGregor, B.D. and Tse, R.Y. 2002. Estimation of the rental adjustment process. *Real Estate Economics*, 30(1), 91-109.
- Hendershott, P.H., Lizieri, C.M., ve MacGregor, B.D. 2010. Asymmetric Adjustment in the City of London Office Market. *Journal of Real Estate Finance and Economics*, 41(1), 80-101.
- Hepşen, A. 2025. Gayrimenkul değerlemesinde ESG etkisi: Yeni standartlar, yeni gerçekler. *Dünya Gazetesi*. <https://www.dunya.com/kose-yazisi/gayrimenkul-degerlemesinde-esg-etkisi-yeni-standartlar-yeni-gercekler/767928>. Erişim Tarihi : 04.06.2025.
- Ho, T. K. 1995. Random decision forests. *Proceedings of the 3rd International Conference on Document Analysis and Recognition*, 278-282.
- Hui, E. C., Chan, E. W. ve Yu, K. 2015. The effect of LEED certification on Shanghai's prime office rental value. *Journal of Facilities Management*, 13(3), 297-310.
- Islam, K. S. and Asami, Y. 2010. Housing Market Segmentation: A Review. *Review of Urban and Regional Development Studies*, 21(2). Advance online publication.
- Jain, P. and Robinson, S. J. 2018. Do large-scale owners enjoy brand-induced premiums? *Journal of Real Estate Portfolio Management*, 24(1), 35-49.
- Jang, D.C., Kim, B. and Kim, S.H. 2018. The effect of green building certification on potential tenants' willingness to rent space in a building. *Journal of Cleaner Production*, 194, 645-655
- Joachims, T. 1998. Text categorization with Support Vector Machines: Learning with many relevant features. In *Proceedings of the 10th European Conference on Machine Learning* 137-142.
- İnci, G.N. 2024. Türkiye Gayrimenkul Pazarı Görünümü İlk Yarı 2024. Cushman & Wakefield. <https://cw-tr.com/tr/arastirma-detay/1787/turkiye-gayrimenkul-pazari-gorunumu-ilk-yari-2024>. Erişim tarihi: 22.10.2024.
- Jud, G. D. and Winkler, D. T. 1995. The capitalization rate of commercial properties and market returns. *Journal of Real Estate Research*, 10(5), 509-518.
- Kangallı Uyar, S.G. 2020. Büyük veri setlerinde üstel mekânsal matris tanımı yaklaşımı: İstanbul ofis piyasası analizi. *Sosyoekonomi*, 28 (43); 65-87.
- Kapusuz, Y.E. ve Tanrıvermiş, H. 2024. Konuta erişilebilirlik, konut talebi ve talebi etkileyen faktörlerin analizi: Ankara ili örneği. *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 42(1), 66-89.
- Karahan, G. 2019. İstanbul ofis pazarı kiralari için uzun dönem denge kira tahmini. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Gayrimenkul Geliştirme Anabilim Dalı, İstanbul.

- Karakuş, H. 2011. Kentsel alanlarda gayrimenkul değerlemesi ve Balıkesir örneği. Yüksek Lisans Tezi. Balıkesir Üniversitesi, Fen Bilimleri Enstitüsü, Balıkesir.
- Karimov, A. 2010. İstanbul Mia’da ofis kira değişimi: Mamdani ve Tsk bulanık kural tabanlı model uygulaması. Yüksek Lisans Tezi. Orta Doğu Teknik Üniversitesi, Finansal Matematik Bölümü, Ankara.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W. and Liu, T.Y. 2017. LightGBM: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*, 30, 3146-3154.
- Keskin, K. 2023. 2023’ün ilk 6 ayında yabancı yatırımlar 2022’nin aynı dönemine göre metrekaare bazında %50 azaldı. Gayrimenkul Haber. <https://www.gayrimenkulhaber.com/emlak-haberleri/2023un-ilk-6-ayinda-yabanci-yatirimlar-2022nin-ayni-donemine-gore-metrekaare-bazinda-yuzde-50-azaldi/>. Erişim tarihi: 22.11.2024.
- Khamrabaeva, L. 2020. Gayrimenkul değerlendirme yöntemleri: hedonik fiyat modeli üzerine bir uygulama. Yüksek Lisans Tezi. Bursa Uludağ Üniversitesi, Sosyal Bilimler Enstitüsü Bursa.
- Khuri, A.I. 2003. *Advanced Calculus with Applications in Statistics*. Wiley Interscience, Hoboken.
- Kok, N., Koponen, E. And Martínez-Barbosa, C.A. 2017. Big data in real estate? From manual appraisal to automated valuation. *Journal of Portfolio Management*, 43(6), 202-211.
- Köse, M. ve Sertkaya Doğan, Ö. 2022. Nüfus Politikaları Bağlamında Türkiye Nüfusunun Demografik Dönüşümü, Yapısal Değişimi ve Geleceği. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi* (74), 247-267.
- Krishnapuram, R. and Keller, J.M. 1993. A possibilistic approach to clustering. *IEEE Transactions on Fuzzy Systems*, 1(2), 98-110.
- Krycha, S. and Wagner, A. 1999. Applications of artificial neural networks in management science: a survey. Universität Wien, Institut für Betriebswirtschaftslehre, Lehrstuhl für Marketing, A-1210 Wien, Brünnerstraße 72, Austria.
- Kusan, H., Aytekin, O. and Özdemir, I. 2010. The Use of Fuzzy Logic in Predicting House Selling Prices. *Expert Systems with Applications*, 37(3), 1808-1813.
- Quinlan, J.R. 1986. Induction of decision trees. *Machine Learning*, 1(1), 81-106.
- Liang, A. 2023. China’s factory activity shrinks for fifth month in a row. BBC News. <https://www.bbc.com/news/business-66667082>. Erişim Tarihi: 22.10.2024.
- Liaw, A. and Wiener, M. 2002. Classification and regression by randomForest. *The Newsletter of the R Project*, 2(3), 18-22.

- Loh, W.Y. 2011. Classification and regression trees. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 1(1), 14-23.
- Lütkepohl, H. 2005. New Introduction to Multiple Time Series Analysis. Springer Science & Business Media, Berlin.
- Madushika, S.D. and Gunawardhana, T. 2019. Forecasting Space Demand: A Study in Colombo Office Space Market (Paper presentation). International Conference on Real Estate Management and Valuation. Colombo, Sri Lanka.
- Malinowski, A., Piwowarczyk, M., Telec, Z., Trawinski, B., Kempa, O., and Lasota, T. 2018 An Approach to Property Valuation Based on Market Segmentation with Crisp and Fuzzy Clustering. International Conference on Computational Collective Intelligence, 534-548.
- Manganelli, B., Pontrandolfi, P., Azzato, A. and Murgante, B. 2014. Using geographically weighted regression for housing market segmentation, International Journal of Business Intelligence and Data Mining, 9(2), 161-177.
- Margulis, H.L. 2007. Commercial sub-markets in suburban Cuyahoga County, Ohio. Urban Studies, 44(2), 249-274.
- Mayer, M., Bourassa, S.C., Hoesli, M. and Scognamiglio, D. 2019. Estimation and updating methods for hedonic valuation. Journal of European Real Estate Research, 12(1), 134-150.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., et al. 2015. Human-level control through deep reinforcement learning. Nature, 518(7540), 529-533.
- Mohd, T., , Harussani, M. and Masrom S. 2022. Rapid modelling of machine learning in predicting office rental price. International Journal of Advanced Computer Science and Applications, 13(12), 545-551.
- Moosavi, V. 2017. Urban data streams and machine learning: A case of Swiss real estate market. 1704.04979, arXiv.org.
- Murray, J. and Trausch, F. 2023. Real Estate Reckoning. PIMCO. <https://www.pimco.com/gbl/en/insights/real-estate-reckoning>. Erişim Tarihi: 22.10.2024.
- Mukherjee, T. 2021. Different types of Distances used in Machine Learning Explained!. Medium. <https://tuhinmukherjee74.medium.com/different-types-of-distances-used-in-machine-learning-explained-550e2979752c>. Erişim tarihi: 20.12.2024.
- Naeem, N., Rana, I.A. and Nasir, A.R. 2023. Digital real estate: a review of the technologies and tools transforming the industry and society. Smart Constr. Sustain. Cities 1, 15.
- Namlı, E., Ünlü, R. ve Gül, E. 2019. Fiyat Tahminlemede Makine Öğrenmesi Teknikleri ve Doğrusal Regresyon Yöntemlerinin Kıyaslanması; Türkiye’de

Satılan İkinci El Araç Fiyatlarının Tahminlenmesine Yönelik Bir Vaka Çalışması. Konya Journal of Engineering Sciences, 7(4), 806-821.

- Nappi-Choulet, I., Maleyre, I. and Maury, T.P. 2007. A hedonic model of office prices in Paris and its immediate suburbs. *Journal of Property Research*, 24(3), 241-263.
- Nase, I., van Assendelft, N. and Remøy, H. 2019. Rent premiums and vertical sorting in Amsterdam's multi-tenant office buildings. *The Journal of Real Estate Finance and Economics*, 59, 419-460.
- Nemanja, N. 2023. Office market segmentation at the intra-urban level: The relationship between office users and market structure. Master's thesis, University of New South Wales. Sydney.
- Nurzukhrufa, A., Setijanti, P. and Dinapradipta, A. 2018. Factors Influencing Rental Office Selections (Case Studies: Class A Rental Offices Multifunction in Surabaya). *International Journal of Scientific and Research Publications*, 8(7), 26-272.
- Olubunmi, O. A., Xia, P. B. and Skitmore, M. 2016. Green building incentives: a review. *Renewable and Sustainable Energy Reviews*, 59, 1611-1621.
- Öven, V.A. ve Pekdemir, D. 2006. Office Rent Determinants Utilising Factor Analysis-A Case Study for Istanbul. *The Journal of Real Estate Finance and Economics*, 33(1); 51-73.
- Özüs, E. 2009. Determinants of Office Rents in The Istanbul Metropolitan Area. *European Planning Studies*. 17(4); 621-633.
- Özşahin, M., Yilmaz, K.B. ve Akcan, S. 2022. Makine Öğrenmesi Algoritmaları İle Ev Kirası Tahmini. *Mühendislikte Araştırma ve Değerlendirmeler II*, 24-36(2).
- Öztekin, Ö. 2023. 2024'te Türkiye ekonomisi ve gayrimenkul sektörü: Zorluklar ve fırsatlar. <https://www.onderoztekin.com/blog/2024te-turkiye-ekonomisi-ve-gayrimenkul-sektoru-zorluklar-ve-firsatlar>. Erişim tarihi: 22.10.2024.
- Palm, R. 1978. Spatial segmentation of the urban housing market. *Economic Geography*, 54(3), 210-221.
- Peterson, S.P. and Flanagan, A.B. 2009. Neural Network Hedonic Pricing Models in Mass Real Estate Appraisal. *Journal of Real Estate Research*, 15(3), 112-128.
- Pivo, G. 1993. A taxonomy of suburban office clusters: the case of Toronto. *Urban Studies*, 30(1), 31-49.
- Pivo, G. and Fisher, J.D. 2010. Income, value, and returns in socially responsible office properties. *Journal of Real Estate Research*, 32(3), 243-270.
- Platt, J.C. 1999. Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods. In *Advances in Large Margin Classifiers*, (61-74).

- Ragapriya, N., Kumar, T.A., Parthiban, R., Divya, P., Jayalakshmi, S. and Raman, D.R. 2023. Machine learning based house price prediction using modified extreme boosting. *asian journal of applied science and technology*. 7(1), 41-54.
- Raschka, S., Liu, Y. and Mirjalili, V. 2022. Machine learning with pytorch and scikit-learn-develop machine learning and deep learning models with python. Birmingham: Packt Publishing Ltd.
- Rosen, S. 1974. Hedonic prices and implicit markets: Product differentiation in pure competition. *Journal of Political Economy*, 82(1), 34-55.
- Safavian, S.R. and Landgrebe, D. 1991. A survey of decision tree classifier methodology. *IEEE Transactions on Systems, Man, and Cybernetics*, 21(3), 660-674.
- Safian, E.E.M. and Nawawi, A.H. 2013. Occupier's perceptions on building and locational characteristics of purpose-built office. *Procedia-Social and Behavioral Sciences*, 101, 575-584.
- Savaş, B. 2019. Makine Öğrenme Algoritmalarının Konut Değer Tahmininde Kullanımı: Ankara Gölbaşı Uygulaması. Yüksek Lisans Tezi, Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Harita Mühendisliği Anabilim Dalı, Konya.
- Sayce, S., Smith, J., Cooper, R. and Venmore-Rowland, P. 2009. Real estate appraisal: From value to worth. Wiley-Blackwell.
- Schapire, R.E. 1999. A brief introduction to boosting. *Proceedings of the 16th International Joint Conference on Artificial Intelligence*, 1401-1406.
- Schölkopf, B. and Smola, A. J. 2002. Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond. Massachusetts Institute of Technology Press.
- Seher, G. 2022. Yapay Sinir Ağları (Artificial Neural Network, ANN). Medium. <https://medium.com/@gulsahseher/yapay-sinir-aglari-artificial-neural-network-ann-af78c7b8f22e>. Erişim Tarihi 03.10.2024.
- Sellers, K. 2022. Flexible office space: now and next. <https://www.savills.com/impacts/social-change/flexible-office-space-now-and-next.html>. Erişim tarihi: 22.10.2024.
- Shamshad, N., Wang, L., Saleem, K., Sarwr, D., Bharany, S., Almogren, A., Choi, J., Rehman, A.U. And Altameem, A. 2025. Advanced KNN-based cost-efficient algorithm for precision localization and energy optimization in dynamic underwater sensor networks. *Scientific Reports*, 15, Article 2182.
- Shawn L.R., McKnight, A., Misty R.P. and Rachel N.C. 2019. Considerations for a regression-based real estate valuation and appraisal model: A pilot study, *Accounting and Finance Research*, 8 (2).

- Simon, Z.Z., Achsani, N.A., Manurung, A.H. and Sembel, R. 2015. The determinants of rental rates and selling prices of office spaces in Jakarta: a macro econometric model using VECM approach. *International Journal of Economics and Finance*, 7(3), 165-178.
- Sirmans, G.S., MacDonald, L., Macpherson, D.A. and Zietz, E.N. 2003. The value of housing characteristics: A meta-analysis. *The Journal of Real Estate Finance and Economics*, 27(2), 203-214.
- Şen, U., Başer, F. ve Özdemir Sönmez, F.N. 2025. Ofis kiralalarının kestiriminde Makine Öğrenmesi Yaklaşımları ve pazar analizi, *İşletme Araştırmaları Dergisi*, 17(1), 844-872.
- Şentürk, T. 2012. Gayrimenkul Döngüsü bağlamında arz-talep dengesinin sorgulanması; İstanbul ofis piyasası örneği. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Gayrimenkul Geliştirme Anabilim Dalı, İstanbul.
- Şişman, S. ve Aydınoglu, A.Ç. 2023. Toplu taşınmaz değerlendirme için coğrafi verinin işlenmesi ve Rastgele Orman Makine Öğrenmesi Tekniğiyle tahmin modelinin geliştirilmesi. *Harita Dergisi*, 169, 13-27.
- Tabar, M.E., Başara, A.C. ve Şişman, Y. 2021. Çoklu Regresyon ve Yapay Sinir Ağları ile Tokat ilinde konut değerlendirme çalışması. *Türkiye Arazi Yönetimi Dergisi*, 3(1), 1-7.
- Tanaka, H., Uejima, S. ve Asai, K. 1982. Linear regression analysis with fuzzy model. *IEEE Transactions on Systems, Man, and Cybernetics*, 12(6), 903-907.
- Tanrıvermiş, H. 2008. Taşınmaz değerlemede gelir çarpanları yaklaşımı ve Türkiye’de kentsel ve kırsal taşınmaz değerlendirme uygulamalarında kullanım olanakları, *Vergi Sorunları Dergisi*, 241,106-148.
- Tanrıvermiş, H. 2017. Gayrimenkul değerlendirme esasları. SPL Sermaye Piyasası Lisanslama Sicil ve Eğitim Kuruluşu, Lisanslama Sınavları Çalışma Kitapları Ders Kodu, 1014, Ankara.
- Tanrıvermiş, H. 2019. Türkiye ekonomisinde inşaat ve gayrimenkul sektörlerinin rolleri ve gelişme eğilimlerinin değerlendirilmesi. *Kent, İnşaat ve Ekonomi Kongresi*, Gaziantep, ss.37-58.
- Tanrıvermiş, H. 2020. Possible impacts of COVID-19 outbreak on real estate sector and possible changes to adopt: A situation analysis and general assessment on Turkish perspective. *Journal of Urban Management*, 9(3), 263-269.
- Tay, D.P.H. and Ho, D.K.H. 1992. Artificial Intelligence and the Mass Appraisal of Residential Apartments, *Journal of Property Valuation and Investment*, Vol. 10 No. 2, pp. 525-540.

- Tedja, M., Septiani, M.M. and Noegroho, N. 2021. A Study about office space needs with consideration of supply and demand for office buildings in Jakarta. IOP Conference Series: Earth and Environmental Science, 794(1), 012219.
- Tolon, M. ve Güneri Tosunoğlu, N. 2008. Tüketici tatmini verilerinin analizi: Yapay Sinir Ağları ve Regresyon Analizi karşılaştırması. Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 10(2), 247-259.
- Tu, Y., Yu, S.M. and Sun, H. 2004. Transaction-Based office price indexes: a spatiotemporal modeling approach. Real Estate Economics, 32(2), 297-328.
- Tu, Y., Sun, H., and Yu, S. 2007. Spatial autocorrelations and urban housing market segmentation. The Journal of Real Estate Finance and Economics, 34, 385-406.
- Tuna, M., Türk, T. ve Kitapçı, O. 2015. Lineer Regresyon ve Coğrafi Bilgi Sistemleri Yardımıyla ev fiyatlarının tahmin edilmesi: Ankara örneği. TMMOB Harita ve Kadastro Mühendisleri Odası Yayınları.
- Türel, A. 1981. Ankara’da konut fiyatlarının mekansal farklılaşması. Orta doğu Teknik Üniversitesi Mimarlık Fakültesi Dergisi, 7(1), 97-109.
- Türkan, M., Bozdağ, A., Karkınlı, A.E. ve Ulucan, A.G. 2023. Kent ölçeğinde konutlara ilişkin toplu değer değişiminin Makine Öğrenim Algoritmaları ile analizi. Türkiye Arazi Yönetimi Dergisi, 5(2), 66-77.
- Türkşen, I.B. 1999. Type-1 and Type-2 fuzzy system modeling. Fuzzy Sets and Systems 106, 11-34.
- Türkşen, I.B. 2008. Fuzzy functions with LSE. Applied Soft Computing, 8, 1178-1188.
- Wen, H. Z., Sheng-hua, J. and Xiao-yu, G. 2005. Hedonic price analysis of urban housing: an empirical research on Hangzhou, China. Journal of Zhejiang University-Science A, 6(8), 907-914.
- Wheaton, W. C. 2003. Real estate “cycles”: Some fundamentals. Real Estate Economics, 27(2), 209-230.
- White, M. and Ke, Q. 2014. Investigating the dynamics of and interactions between, Shanghai office submarkets. Journal of Property Research, 31(1), 26-44.
- Wu, C., Ye, X., Ren, F. and Du, Q. 2018. Modified data-driven framework for housing market segmentation Modified data-driven framework for housing market segmentation. Journal of Urban Planning and Development, 144(4), 04018036.
- Usman, H., Lizam, M. and Adekunle, M.U. 2020. Property price modelling, market segmentation and submarket classifications: a review. Real Estate Management and Valuation, Sciendo, vol. 28 no. 3, pp. 24-35.

- Ustaoğlu, E. 2003. İşyeri kiralalarının hedonik fiyat analizi: Ankara’da işyeri pazarı üzerine bir değerlendirme. Yüksek Lisans Tezi. Orta Doğu Teknik Üniversitesi, Sosyal Bilimleri Enstitüsü, Ekonomi Anabilim Dalı, Ankara.
- Uzut, D. and Buyrukoglu, S. 2020. Prediction of real estate prices with data mining algorithms. *Euroasia Journal of Mathematics Engineering Natural and Medical Sciences*. 7. 77-84.
- Vargün, H. 2021. Yatırım amaçlı gayrimenkullerin gerçeğe uygun değer hiyerarşisine göre sınıflandırılması ve Bds620 kapsamında incelenmesi. *İktisadi ve İdari Bilimlerde Araştırma ve Değerlendirmeler*, Gece Kitaplığı, Cilt I, Ankara, ss. 339-364.
- Von Ahlefeldt-Dehn, B., Cajias, M. and Schäfers, W. 2023. Forecasting office rents with ensemble models-the case for European real estate markets. *Journal of Property Investment & Finance*, Vol. 41 No. 2, pp. 182-207.
- Wang, S., Lee, C.L. and Song, Y. 2022. The COVID-19 sentiment and office markets: evidence from China. *Buildings*, 12(12), 2100
- Yalçın, K. 2018. Gayrimenkul Finansmanı. Detay Yayıncılık. Ankara.
- Yaman Selçi, B. 2021. Türkiye’nin konut satışı değerlerinin Yapay Sinir Ağları ile öngörülmesi. *EKOIST Journal of Econometrics and Statistics* (35), 19-32.
- Yayar, R. ve Bursal, M. 2019. Türkiye’de konut kira fiyatlarının hedonik tahmini. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 8 (3), 2010-2026.
- Yılmazel, Ö., Afşar, A. ve Yılmazel, S. 2018. Konut fiyat tahmininde yapay sinir ağları yönteminin kullanılması. *Uluslararası İktisadi ve İdari İncelemeler Dergisi (UIİİD)*, 2018(20), 285-300.
- Yılmazel, S. and Kocaman, S. 2021. On the prediction performances of SVM and ANN methods for mass appraisal assessment: a case study from Ankara (Turkey). *FIG e-Working Week 2021*, 21-25 Haziran, Netherlands.
- Yomralıoğlu, T., Nişancı, R., Çete, M. ve Candaş, E., 2011. Dünyada ve Türkiye’de taşınmaz değerlemesi. Türkiye’de Sürdürülebilir Arazi Yönetimi Çalıştayı, Okan Üniversitesi, İstanbul.
- Younglai, R. 2023. With office vacancies still high in Toronto, tenants privately negotiating best deals in years. *The Globe and Mail* web edition, <https://www.theglobeandmail.com/business/article-office-rental-costs-downtown-toronto/>. Erişim tarihi: 01.06.2025
- Yoshida, T., Murakami, D. ve Seya, H. 2024. Spatial prediction of apartment rent using regression-based and machine learning-based approaches with a large dataset. *The Journal of Real Estate Finance and Economics*, 69, 1-28.

- Yu, L., Jiao, C., Xin, H., Wang, Y. and Wang, K. 2018. Prediction on housing price based on deep learning. *International Journal of Computer and Information Engineering*, 12(2), 90-99.
- Yüce, C., Demir, A., Cin, K., Şahin, H. ve Ercan, T. 2023. 2023 İlk yarı Türkiye gayrimenkul piyasası raporu. Colliers International. <https://www.colliers.com/en-tr/research/202308803-2023-1h-review>. Erişim tarihi: 22.10.2024.
- Zeng, T.Q., and Zhou, Q. 2001. Optimal spatial decision making using gis: a prototype of a real estate geographical information system, *International Journal of Geographical Information Science*, 15(4), 307-321
- Zhang, Y. and Yin, H. 2022. Willingness to pay for green office: evidence from Shanghai. *Environmental Science and Pollution Research*, 29(56), 84345-84356.
- Zhao, J., Li, Y. and Wang, Q. 2023. Machine Learning Approaches for real estate valuation: A review and comparative analysis. *Artificial Intelligence Review*, 56(2), 621-647.