

Ofis Kiralarının Kestiriminde Makine Öğrenmesi Yaklaşımları ve Pazar Analizi¹ Machine Learning Approaches for Predicting Office Rents and Market Analysis

Uğur ŞEN^a Furkan BAŞER^b Fahriye Nihan ÖZDEMİR SÖNMEZ^b

^a Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Gayrimenkul Geliştirme ve Yönetimi Anabilim Dalı, Ankara, Türkiye. ugr_sn@hotmail.com

^b Ankara Üniversitesi, Aktüerya Bilimleri Bölümü, Ankara, Türkiye. furkan.baser@ankara.edu.tr

^c Ankara Üniversitesi, Gayrimenkul Geliştirme ve Yönetimi Bölümü, Ankara, Türkiye. sonmezo@ankara.edu.tr

MAKALE BİLGİSİ	ÖZET
Anahtar Kelimeler: Ofis Kirası Değerleme Makine Öğrenmesi Yapay Zeka Gönderilme Tarihi 25 Aralık 2024 Revizyon Tarihi 17 Mart 2025 Kabul Tarihi 20 Mart 2025 Makale Kategorisi: Araştırma Makalesi	Amaç – Ofis kiralarının tespiti yeni ofis gelişim alanlarının, gayrimenkul yatırımlarının yönlendirilmesi ve planlama stratejilerinin oluşturulmasında önemli bir rol oynamaktadır. Bu amaçla kullanılan geleneksel değerlendirme yöntemlerinin değişkenler arasındaki karmaşık ilişkileri tam olarak açıklayamadığı, daha kısıtlı verilere ve öznel değerlendirmelere dayandığı ve böylece ofis kiralarının belirlenmesinde önemli hata paylarına neden olduğu görülmektedir. Bu araştırma, Ankara ili Çankaya ilçesindeki ofis kiralarının belirlenmesinde geleneksel değerlendirme yöntemleri ile makine öğrenmesi yöntemlerini karşılaştırarak, hangi yaklaşımın daha düşük hata sağladığını belirlemeyi amaçlamaktadır. Yöntem – Araştırmada, 2019-2024 yılları arasında Çankaya ilçesine ait ofis kira verileri kullanılmıştır. Geleneksel değerlendirme yöntemlerinden Emsal Değer Analizi; makine öğrenmesi yöntemlerinden Çoklu Doğrusal Regresyon, Ridge Regresyonu, Lasso Regresyonu, Karar Ağaçları, Rasgele Orman, k-En Yakın Komşu, Radyal ve Doğrusal Çekirdekli Destek Vektör Makinesi, XGboost Modeli, Yapay Sinir Ağları yöntemleri uygulanmıştır. Kök Hata Kareler Ortalaması (Root Mean Square Error - RMSE), Ortalama Mutlak Hata (Mean Absolute Error - MAE), Göreceli Kök Hata Kareler Ortalaması (Relative Mean Square Error - rMSE), ve Göreceli Ortalama Mutlak Hata (Relative Mean Absolute Error - rMAE) hata ölçütleri kullanılarak model performansları karşılaştırılmıştır. Bulgular – Analiz sonuçlarına göre, Rasgele Orman algoritması en düşük hata oranlarını sağlayarak en başarılı tahmin performansını göstermiştir. Geleneksel değerlendirme yaklaşımı, değişkenler arası etkileşimi tam olarak yansıtamazken, makine öğrenmesi modelleri ile daha hassas kestirim değerleri elde edilmiştir. Tartışma – Makine öğrenmesi yöntemleri, dinamik piyasa koşullarına uyum sağlayarak ofis kiralarının değerlendirilmesinde önemli avantajlar sunmaktadır. Araştırma, gayrimenkul sektöründe veri odaklı ve yenilikçi karar destek sistemlerinin geliştirilmesine katkı sağlamaktadır.
ARTICLE INFO	ABSTRACT
Keywords: Office Rent Valuation Machine Learning Artificial Intelligence Received 25 December 2024 Revised 17 March 2025 Accepted 20 March 2025 Article Classification: Research Article	Purpose – Determination of office rents plays an important role in directing new office development areas, real estate investments and planning strategies. It is observed that traditional valuation methods used for this purpose cannot fully explain the complex relationships between variables, are based on more limited data and subjective evaluations, and thus cause significant error margins in determining office rents. This study aims to determine which approach provides higher accuracy by comparing traditional valuation methods and machine learning methods in determining office rents in Çankaya district of Ankara province. Design/methodology/approach – In the research, office rent data of Çankaya district between 2019-2024 were used. Machine learning methods such as Multiple Linear Regression, Ridge Regression, Lasso Regression, Decision Trees, Random Forest, k-Nearest Neighbour, Radial and Linear Kernel Support Vector Machine, XGboost Model, Artificial Neural Networks were applied. Model performances were compared using various error measures. Findings – According to the results of the analyses, the Random Forest algorithm showed the most successful prediction performance by providing the lowest error rates. While the traditional valuation approach cannot fully reflect the interaction between variables, more accurate prediction values are obtained with machine learning models. Discussion – Machine learning methods offer significant advantages in the valuation of office rents by adapting to dynamic market conditions. The research contributes to the development of data-driven and innovative decision support systems in the real estate sector.

¹ Bu çalışmada “Ofis Kiralarının Bulanık Regresyon Yöntemiyle Belirlenmesi: Ankara İli Örneği” adlı henüz yayınlanmamış doktora tezinde kullanılan verilerden yararlanılmıştır.

Önerilen Atıf/Suggested Citation

Şen, U., Başer, F., Özdemir Sönmez, F. N. (2025). Ofis Kiralarının Kestiriminde Makine Öğrenmesi Yaklaşımları ve Pazar Analizi, İşletme Araştırmaları Dergisi, 17 (1), 844-861.

1. Giriş

Günümüzde ve geçmiş dönemlerde ortaya çıkan ekonomik dalgalanmalar, sosyal yapıdaki değişimler ve teknolojik ilerlemeler; işgücünün sektördeki dağılımının yer değiştirmesine ve modern ofis alanlarına olan taleplerde değişikliklere neden olmuştur. Bu sebeple ofis kiralama, evden çalışma ile paylaşımlı ofis gibi alanlara olan talepte genişlemeler ve daralmalar gözlenmektedir. Ofis kiralalarının tespiti yeni ofis gelişim alanlarının, gayrimenkul yatırımlarının yönlendirilmesi ve planlama stratejilerinin oluşturulmasında önemli bir rol oynamaktadır. Ofis kiralalarının belirlenmesinde kullanılan geleneksel değerlendirme yöntemlerinin değişkenler arasındaki karmaşık ilişkileri tam olarak açıklayamadığı, daha kısıtlı verilere ve öznel değerlendirmelere dayandığı ve böylece ofis kiralalarının belirlenmesinde önemli hata paylarına neden olduğu görülmektedir. Bu bağlamda yüksek doğruluk oranları, çok boyutlu, hızlı ve hassas veri analizi yapabilme yeteneğiyle makine öğrenmesi yöntemleri alternatif bir yöntem olarak değerlendirilmektedir. Ayrıca makine öğrenmesi yöntemleriyle yapılan analizler yerel, ulusal ve uluslararası pazar dinamiklerini kıyaslayarak, pazar aktörlerine etkin bir değerlendirme aracı sunmaktadır.

Bu araştırmada, Türkiye’de ve dünyada ofis kiralalarının belirlenmesinde kullanılan yöntemlerin ve değere etki eden sosyo-ekonomik, demografik ve fiziksel faktörlerin neler olduğuna yönelik literatür ve saha incelemesi yapılacaktır. Bu doğrultuda araştırmanın temel amacı, Ankara ili Çankaya ilçesindeki ofis binalarında bulunan ofis kiralalarının değerlemesinde kullanılan geleneksel yöntemlerin eksikliklerini analiz etmek ve daha isabetli kestirimler yapabilmek amacıyla makine öğrenmesi yöntemlerinin uygulanabilirliğini inceleyerek, bir ofis kira tahmin modeli geliştirmektir.

Araştırma, mevcut değerlendirme yöntemlerinin performansını analiz ederek, ofis kiralalarının kestiriminde makine öğrenmesi yöntemlerinin ne ölçüde uygulanabilir olduğunu araştırmayı ve bu yöntemlerin sunduğu faydaları, avantajları ve yenilikçi çözümleri ortaya koymayı hedeflemektedir. Model sonuçlarına dayanarak önemli değişkenler tespit edilebilecek ve yeni ofis yatırımlarına ilişkin kararların alınmasında genel ekonomik koşullardan bölgesel özelliklere kadar farklı değişkenlerin bütüncül bir yaklaşımla değerlendirilmesi mümkün hale gelecektir. Bu sayede, elde edilen bulgular literatüre anlamlı bir katkı sağlayarak sektörel uygulamalara yönelik stratejik bir rehber niteliği taşıyacaktır.

Gayrimenkul değerinin ve kirasının belirlenmesine ilişkin Türkiye’de ve dünyada yapılan çalışmaların, kullanılan yöntem ve seçilen örnekleme göre farklılıkları mevcuttur. Uzun süredir kullanılan klasik yöntemler, gayrimenkul değerlendirme alanındaki uygulayıcılar tarafından benimsenmiştir. Bu yaklaşımlar, gayrimenkulün konumu, fiziksel özellikleri, pazar koşulları ve yatırım getirisi gibi faktörleri dikkate alarak kirayı hesaplamak için sistematik bir yaklaşım sunmaktadırlar. Piyasa değeri yöntemleri, gelir yöntemleri ve maliyet yöntemleri literatürde en yaygın olarak kullanılan klasik yöntemlerdir.

Jud ve Winkler (1995) tarafından yapılan çalışmada, karşılaştırmalı satış analizi kullanılarak ticari gayrimenkullerin pazar değeri incelenmiştir. Fisher ve Martin (2004) çalışmasında, gelir getiren mülklerin değerlemesinde kullanılan yöntemler üzerine odaklanırken, maliyet yaklaşımını da ele almaktadır. Özellikle ticari gayrimenkullerde maliyet yöntemiyle değerlendirme yapmanın avantajları anlatılmaktadır. Eichholtz, Kok ve Quigley (2010) ise yeşil ofis binalarının değerlemesinde maliyet yaklaşımını incelemişler ve yeşil binaların inşaat maliyetleri ve enerji verimliliği gibi faktörlerin nasıl dikkate alındığını araştırmışlardır. Geltner, Miller, Clayton ve Eichholtz (2013) çalışmasında, ticari gayrimenkul yatırımları ve değerlendirme yöntemleri üzerine geniş ve kapsamlı bir inceleme yapmıştır.

Gayrimenkullerin özellikleri, konumu, kullanım amacı, hitap ettiği kitle ve mevcut pazar dinamikleri göz önüne alınarak değerlerinin belirlenmesine yönelik çeşitli istatistiksel yöntemler geliştirilmiştir. Fakat regresyon, hedonik fiyatlama modelleri, zaman serisi analizleri, mekânsal analizler gibi istatistiksel temelli analizler, gayrimenkul pazarının karmaşıklığını tam olarak yansıtamayabileceği eleştirisiyle karşı karşıya kalmıştır.

Tu, Yu ve Sun (2004), Singapur ofis fiyatlarının modellenmesinde ve işlem tabanlı ayırık ofis fiyat endekslerini oluşturmak için mekânsal-zamansal otoregresif bir yöntem kullanarak, 1992 yılı üçüncü çeyrek ile 2001 yılı dördüncü çeyrek dönemleri arasında gerçekleşen 2950 adet ofisin satış fiyatları ve bina özellikleri arasındaki ilişkiyi incelemişlerdir. Debrezion ve Willigers (2008), 1983-2005 dönemini kapsayan zaman diliminde Hollanda ofis pazarında, Amsterdam Güney Ekseni’nde planlanan demiryolu ulaşımının ofis kiralaları üzerindeki etkisini incelemiştir. Ardından, kira sözleşmesi verileri, mekânsal hedonik fiyat modelleri ile

tahmin edilmiş ve nihai çıktı, sonuç tahmininde kullanılmıştır. Karahan (2019), İstanbul'daki sekiz ofis alt pazarından (Esentepe, Levent ve Maslak, Basın Ekspres, Altunizade, Kavacık, Kozyatağı ve Ümraniye) elde ettiği ve 2005-2018 dönemini kapsayan kira ve boşluk verilerini, çeşitli ofis pazarı değişkenlerini ve ekonomik faaliyet göstergelerini kullanarak, ofis pazarı için uzun dönem denge kirasının tahminine yönelik çalışmalar gerçekleştirmiştir. Kangallı ve Uyar (2020), 2018 yılın Mart ayı sonuna kadarki dönemi kapsayan İstanbul'un 28 ilçesini kapsayan, Türkiye'nin en büyük emlak sitelerinden topladıkları 2348 ofise ait kira verileri ile ofislere ve ofislerin bulundukları binalara ait özelliklerine göre hedonik ofis kira modeli geliştirmişlerdir.

Günümüzde gayrimenkul sektörü, yalnızca geleneksel değerlendirme yöntemlerine dayalı bir alan olmaktan çıkmış, çok daha karmaşık ve çok boyutlu bir yapıya dönüşmüştür. Sektör, çeşitli faktörlerle olan mevcut bağlantıları nedeniyle, kontrol edilemeyen ve hatta öngörülemeyen fiyat değişimlerine tabi kalmaktadır. Bu bağlamda, Makine öğrenmesi yöntemleri son yıllarda birçok araştırma alanına uyarlanmış ve sunduğu çok yönlü algoritmalar sayesinde farklı uygulama alanlarında etkin bir şekilde kullanılmaya başlanmıştır.

Yılmaz ve Kocaman (2021) tarafından yapılan çalışmada, büyük ölçüde konutlardan ve az sayıda ticari mülklerden oluşan 2850 veri örneği için destek vektör makineleri ve yapay sinir ağları gibi iki popüler makine öğrenmesi yöntemi uygulanmıştır. Çeşitli model doğruluk değerlerine göre değerlendirmeler sonucunda, yapay sinir ağları modeli, destek vektör makinesi modeline kıyasla biraz daha iyi bir performans sergilediği belirlenmiştir. Mohd, Harussani ve Masrom (2022), yüksek ofis binalarının yoğunlukta olduğu Kuala Lumpur şehir merkezindeki ofislerin kirasını tahmin etmek için 2015-2021 yılları arasındaki 191 ofis binasını kapsayan 722 adet kira verilerini kullanarak, Karar Ağacı, Rasgele Orman ve Destek Vektör Makinesi olmak üzere üç farklı makine öğrenmesi algoritması kullanmışlardır. Kuala Lumpur, Malezya'daki ofis kira fiyatlarına dayanan gerçek vakalar üzerinde yapılan değerlendirmeler, çapraz doğrulama yöntemiyle kullanılan Rasgele Orman algoritmasının, en başarılı algoritma olduğunu göstermiştir. Demirhan ve Başer'in (2024) çalışmasında, makine öğrenmesi yöntemlerinin kategorik özellikleri yakalama konusundaki yetersizliğini gidermek amacıyla yeni bir çerçeve olan hiyerarşik bulanık regresyon fonksiyonları ele alınmıştır. Bu yöntem, özellikle kategorik verilerle yapılan gayrimenkul fiyat tahminlerinde doğruluğu artırmayı hedeflemektedir. Çalışma, doğrusal regresyon, destek vektör makineleri, derin sinir ağları ve uyarlamalı bulanık çıkarım sistemleri ile karşılaştırılarak test edilmiştir. Sonuçlar, önerilen hiyerarşik bulanık regresyon fonksiyonlarının, gayrimenkul fiyat tahmininde diğer yöntemlere kıyasla daha üstün performans gösterdiğini ortaya koymuştur.

2. Ofis Kiralarının Tespiti İçin Model Geliştirilmesi ve Emsal Değer Analizi

2.1 Makine Öğrenmesi Yöntemleri

Makine öğrenmesi, verilerden öğrenerek tahminler veya sınıflandırmalar yapabilen bilgisayar yöntemlerinin geliştirilmesini içermektedir. Veri analizinden model geliştirmeye kadar çok çeşitli alanlarda makine öğrenmesi teknikleri kullanılmaktadır. Son yıllarda yapılan araştırmalar, bu yöntemlerin çeşitli veri türleri ve uygulama alanları için nasıl geliştirildiğini ve uygulandığını göstermektedir. Makine öğrenmesi, belirli bir probleme ilişkin girdi ve çıktı değerlerini ilişkilendirerek ilgili sistemi açıklayan modelin tahmin edilmesi ve yeni bir girdi için çıktı değerinin kestiriminin elde edilmesi sürecidir (Canaz Sevgen 2022)

2.1.1 Çoklu Doğrusal Regresyon

Çoklu Doğrusal Regresyon, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi modellemek için kullanılan istatistiksel bir tekniktir. Bu yöntem, bağımlı değişkenin değerini kestirmek için bir doğrusal ilişkinin kurulmasını sağlamaktadır ve temel amaç doğrusal bir fonksiyon yardımıyla bağımlı değişkenin, birden fazla bağımsız değişkene bağlı olarak nasıl değiştiğini modellemek, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini ölçmek ve tahminler yapmaktır. Katsayılar, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini nicel olarak ifade etmektedir. Bağımsız değişkenler arasında yüksek korelasyon varsa, model doğruluğu etkilenmekte, hatalı model varsayımları sonuçların güvenilirliğini azaltabilmekte ve bağımlı değişkenin doğrusal olmayan ilişkilerini açıklamakta yetersiz kalabilmektedir.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon$$

Burada, Y bağımlı değişkeni, β_0 sabit terimi, $\beta_1, \beta_2, \dots, \beta_p$ bağımsız değişkenlerin katsayılarını, $X_1, X_2, \dots, X_p$ bağımsız değişkenleri, ε hata terimini ifade etmektedir. Klasik Doğrusal Regresyon, bağımsız değişkenler ile

bağımlı değişken arasında doğrusal bir ilişki olması, hata teriminin normal dağılması ve ilişkisiz olması gibi model varsayımlarına dayanmaktadır.

2.1.2 Ridge Regresyonu

Doğrusal modelleri düzenlemek, tahmin performansını iyileştirmek ve aşırı uyumu önlemek için Ridge ve Lasso regresyonu makine öğrenmesinde kullanılan tekniklerdir. Katsayıları kısıtlamak için her iki yaklaşım da model hatasına dayalı amaç fonksiyonuna bir ceza terimi eklemektedir, ancak bu yaklaşımda cezayı nasıl uyguladıkları farklıdır. Ridge regresyonu, modelin katsayılarının büyüklüğünü sınırlamak için bir ceza terimi eklemektedir ve amaç fonksiyonu aşağıdaki şekilde ifade edilmektedir:

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

$$L2 = \lambda \sum_{j=1}^p \beta_j^2$$

Burada, β_{ridge} ridge regresyonu için optimize edilen katsayı vektörünü, y_i gerçek değeri, $\hat{y}_i$ tahmin edilen değeri, β_0 sabit terimi, λ ceza terimini ifade etmektedir.

Standart doğrusal regresyonda amaç fonksiyonu sadece toplam hatanın enküçüklenmesine dayanmaktadır. Ridge Regresyonu, L2 düzenlemesi olarak da bilinmektedir ve aşırı uyumu önlemek için amaç fonksiyonuna L2 ceza terimi eklenmektedir. Özellikle çoklu doğrusallık durumlarında, ortalama karesel hatayı (MSE) bir düzenleme terimi olacak şekilde değiştiren, en küçük kareler regresyonunun bir versiyonudur. Birden çok değişken olduğunda, herhangi bir değişkeni ortadan kaldırmadan tahmin doğruluğunu iyileştirmede, veriler arasında aşırı uyum olduğunda, tüm değişkenlerle model kurmada, gerçeğe yakın değer bulmada ve çok boyutlu çözüm sunmada güvenilir bir yöntemdir (Geeksforgeeks 2024).

2.1.3 Lasso Regresyonu

Lasso regresyonu, L1 düzenlemesi olarak da bilinmektedir ürettiği modelin tahmin doğruluğunu ve yorumlanabilirliğini arttırmak için hem değişken seçimi hem de “regularization” yapmaktadır. Aynı Ridge regresyonunda olduğu gibi amaç hata kareler toplamını enküçükleyen eden katsayıları, katsayılara ceza uygulayarak bulmaktır ve bu ceza katsayıların mutlak değerlerine dayanmaktadır. Ridge regresyonundan farklı olarak ilgisiz değişkenlerin katsayılarını sıfıra eşitlemektedir. Ridge regresyonu tarzı cezalandırma ve lasso regresyonu tarzında değişken seçimi yapmaktadır. Lasso regresyonu, en küçük kareler yöntemine alternatif tahmin yöntemlerinden biridir ve çoklu doğrusal bağlantı ve aşırı öğrenme sorunları için kullanılabilir (Geeksforgeeks 2024). Lasso regresyonu, katsayıların toplam büyüklüğünü sınırlamak için farklı bir ceza terimi kullanmakta ve amaç fonksiyonu aşağıdaki şekilde ifade edilmektedir:

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

Tüm değişkenlerin mutlaka kullanılması gereken durumda ise Ridge Regresyon daha avantajlı olmaktadır. Lasso regresyonu, Ridge regresyonuna niteliksel olarak benzer davranışa yol açmaktadır, çünkü λ arttıkça, varyans azalmakta ve yalnlık artmaktadır. Lasso regresyon, bir tahmin alt kümesini içeren daha basit ve daha yorumlanabilir modeller üretmesi açısından Ridge regresyona göre büyük bir avantaja sahiptir (Geeksforgeeks 2024).

2.1.4 Karar Ağaçları

Karar ağaçları, makine öğreniminde sıklıkla kullanılan bir denetimli öğrenme yöntemidir. Bu yöntem, regresyon ve sınıflandırma problemlerinde veriler arasındaki ilişkileri görsel ve anlaşılır bir şekilde modellemeyi sağlamaktadır. Verileri hiyerarşik olarak bölerek tahminler amaçlanmakta, her bir düğümde bir karar alınmaktadır ve son düğümde sınıflandırma ya da tahmin sonuçlarına ulaşılmaktadır (Breiman, Friedman, Olshen ve Stone 1984).

Karar ağaçları, düğümlerden, dallardan ve yapraklardan oluşmaktadır. İlk düğüm, kök düğüm olarak adlandırılmaktadır ve verinin en önemli özelliğine dayalı olarak ilk ayrımı yapmaktadır. Her ayırmada, veri daha alt düğümlere yönlendirilmekte ve yaprak düğümlerinde sınıf etiketine ya da tahmine ulaşılmaktadır. Bilgi kazancı, Gini indeksi veya varyans azalması gibi kriterleri kullanarak bölünme noktalarını belirlemektedir. Bu ölçütler, her bölünmenin veri setini belirsiz hale getirdiğini göstermektedir (Breiman vd.

1984). Ağaç öğrenme yöntemi kullanılarak en iyi bölme işlemi elde etmek için amaç fonksiyonu (f) ve bölmeyi gerçekleştirecek özellik (D_p), (D_j) sırasıyla esas ve j . düğüme ait veri setleri, I , saf olmama ölçütü, N_p toplam eğitim verisi ve N_j ise j . düğümdeki örnek sayısı olarak tanımlanmaktadır (Raschka vd. 2022).

Model yöntemi aşağıdaki şekilde gösterilmektedir:

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

Gini indeksi, düğüm safiyetini ölçmek için kullanılan bir metriktir ve formülü şu şekildedir:

$$G = 1 - \sum_{i=1}^k p_i^2$$

Burada, p_i : Sınıf i 'nin olasılığıdır ve Gini değeri 0'a yaklaştıkça düğüm safiyeti artmaktadır.

Entropi, bilgi kazancı hesaplamada kullanılan bir metriktir ve formülü şu şekildedir:

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

$H(S)$: Entropi değeri, k : Sınıf sayısı ve p_i : i . sınıfın olasılığıdır. Entropi, belirsizliği ölçmektedir ve daha düşük entropi, daha saf düğümler anlamına gelmektedir.

2.1.5 Rasgele Orman

Rasgele Orman, birden fazla karar ağacının bir araya gelerek topluluk oluşturan makine öğrenimi yöntemidir. Bu model, çeşitli karar ağaçları arasında rasgele seçimler yaparak ve her ağacın tahminlerini birleştirerek daha genellenebilir ve daha doğru sonuçlar sağlamaktadır (Breiman 2001). Rasgele Orman, her ağacın veri setinin farklı bir alt kümesi üzerinde bağımsız olarak eğitilmesi yoluyla ve en iyi tahmini seçmesi yoluyla çalışmaktadır ve tek bir karar ağacında sıklıkla karşılaşılan aşırı uyum sorunu da bu yöntemle etkili bir şekilde çözülebilmektedir.

Rasgele orman, mevcut veri setinden çok büyük veri setleri üretmek üzere yeniden örnekleme yaparak orijinal veri setinden farklı alt kümeler seçerek her bir karar ağacını bu veri alt kümeleri üzerinde eğitmektedir ve bu işlem, aşırı uyum riskini azaltmaktadır. Modelin daha genel ve esnek olmasını sağlamak amacıyla her bir düğümden, rasgele seçilen bir özellik alt kümesi üzerinden en iyi bölünme yapılmaktadır. Son olarak eğitilen tüm ağaçların sonuçları birleştirilerek nihai tahmin elde edilmektedir.

$f_i(x)$ i . karar ağacının tahminini, n ağaç sayısını göstermek üzere nihai tahmin edilen sınıf,

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

biçiminde ifade edilmektedir.

Bir tahminin varyansını azaltmak için çok sayıda tahminin ortalaması kullanılabilir. Örneğin, bir dizi veri altkütmesi kullanılarak n adet farklı ağaç eğitilmekte, rasyonel olarak seçilmekte ve tüm birim f_i , i . ağaç olmak üzere hesaplanmaktadır.

2.1.6 k-En Yakın Komşu

k -En Yakın Komşu, denetimli öğrenme yöntemlerinden biri olup sınıflandırma ve regresyon problemlerinde etkili bir şekilde kullanılan makine öğrenmesi yöntemidir. Eğitim kısmında model oluşturmamakta; tüm veri noktalarını hafızada tutmakta ve yeni bir veri noktasıyla karşılaşıldığında en yakın k komşuya göre karar vermektedir. Model, bir veri noktasının sınıfını bulmak için k sayısında komşuları aramakta ve bu komşuların sınıfının çoğunlukla hangisiyse yeni veri noktasına o sınıfı atamaktadır. Regresyon sorunları ise komşuların ortalamasıyla tahmin edilmektedir. Model, bir veri kümesindeki her noktayı diğer veri noktalarına olan mesafelerine göre sıralamaktadır. Gözlemler arasındaki mesafeleri hesaplamak için Öklit, Manhattan, Minkowski gibi uzaklık ölçütleri kullanılmaktadır (Mukherjee 2024). Öklid uzaklığı, en yaygın metriktir ve iki nokta arasındaki gerçek uzaklığı ölçmektedir. Yeni bir örneğin hangi sınıfa veya tahmin değerine atanacağı bu mesafe ölçüsü kullanılarak belirlenmektedir. k sayısı, komşu sayısını göstermektedir ve çapraz doğrulama yöntemi kullanılarak en uygun k değeri bulunmaktadır. $k = 1$ olduğunda, en yakın komşunun sınıfına göre karar verilmekte ve $k > 1$ olduğunda ise komşular arasında çoğunluk oylaması yapılmaktadır (Mukherjee 2024).

2.1.7 Destek Vektör Makineleri

Destek Vektör Makinesi, veriyi doğrusal veya doğrusal olmayan bir şekilde sınıflandırmak için kullanılan gözetimli öğrenme yöntemlerinden biridir. 1963 yılında Vladimir Vapnik ve Alexey Chervonenkis tarafından temelleri atılmıştır. Özellikle doğrusal olarak ayrılabilir verilerde başarılı sonuçlar vermekte ve verileri en iyi şekilde ayıran bir hiper düzlem bulmaya çalışmaktadır. Doğrusal olmayan veri setlerinde de model, daha yüksek boyutlu bir uzaya verileri projeler ve doğrusal bir ayırım sağlamaktadır (Cortes ve Vapnik, 1995). Hiper düzlem, iki sınıf arasındaki en yüksek marjı sağlamakta ve destek vektörleri olarak bilinen noktalar bu marjı belirlemektedir (Burges 1998).

Temel çalışma prensibi, sınıflar arasında maksimum marjini sağlayan bir hiper düzlem bulmaktır. Böylece, karmaşık yapılar doğrusal bir hiper düzlemle ayrılabilir hale gelmektedir. Ancak, doğrusal olmayan bir problemde veriler düz bir hiper düzlemle ayrılma sorunu ortaya çıkabilmektedir. Bu durumda, iç çarpım çekirdeği kullanılarak veri, yüksek boyutlu bir uzaya dönüştürülmektedir ve doğrusal olmayan veri kümeleri doğrusal olarak ayrıştırılabilir hale gelmektedir. Model, doğrusal olmayan veri kümelerinde etkili olup veriler arasında eğri, dairesel veya karmaşık yapılar varsa yüksek doğruluğa ulaşabilmektedir. Modelin yüksek boyutlu veri setleriyle etkili çalışabilmesi, marjı maksimize eden hiper düzlemi bulduğu için genelleme yeteneği yüksek olması ve çekirdek dönüşümü ile doğrusal olmayan veri setlerinde bile etkili sonuçlar üretmesi avantajları olurken; büyük veri setlerinde eğitim süresinin uzun olması, parametrelerin (özellikle kernel ve marj parametreleri) doğru seçimi, model performansını büyük ölçüde etkilemesi dezavantajları olmaktadır.

2.1.8 XGBoost

Makine öğrenimi alanında, Boosting algoritmaları son yıllarda büyük ilgi görmektedir. Boosting algoritmaları, zayıf öğrencilerin bir araya getirilmesiyle tahmin modellerinin doğruluğunu artırmayı amaçlayan güçlü bir makine öğrenmesi yöntemidir. Bu teknik, her bir adımda hataları azaltarak modelin genel performansını iyileştirir ve bu süreç, yönteminin etkinliğini artırmaktadır (Friedman 2001). Boosting algoritmaları, makine öğreniminde tahmin doğruluğunu artıran güçlü ve esnek yöntemlerdir.

Gradient Boosting, XGBoost ve AdaBoost gibi yöntemler, zayıf öğrencilerin birlikte kullanılmasıyla karmaşık veri setleri üzerinde güçlü sonuçlar elde edebilmektedir. Günümüzde büyük veri setleri ve karmaşık ilişkiler içeren problemlerde, boosting algoritmalarının kullanımı yaygınlaşmıştır ve literatüre önemli katkılar sunmaktadır (Schapire 1999). Özellikle en yaygın kullanılan Gradient Boosting, Adaptive Boosting ve XGBoost tahmin modellerinin performansını güçlendirmede ve karmaşık veri setlerini işleyebilmede etkili bir şekilde kullanılmaktadır. Gradient Boosting, hataları kademeli olarak azaltarak modelin performansını iyileştirirken, AdaBoost ise yanlış sınıflandırılmış verileri ağırlıklandırarak sonraki adımlarda bu verilerin doğru sınıflandırılmasına odaklanmaktadır. (Friedman 2001). Her iki algoritma da yüksek doğruluk ve esneklik sunmaları nedeniyle birçok uygulamada tercih edilmektedir.

XGBoost, Gradient Boosting algoritmasının çeşitli düzenlemeler kullanılarak optimize edilmiş bir versiyonudur. Yüksek tahmin gücüne sahiptir ve aşırı öğrenmeyi önleyebilir ve boş verileri yönetebilir. Hızlı olması gibi nedenlerle, standart yöntemlere göre çok sayıda avantajı vardır. 2016 yılında Chen ve Guestrin tarafından yapılan bir çalışmada, Xgboost algoritması diğer yaygın algoritmalarından on kat daha hızlı çalıştığı kanıtlanmıştır (Chen ve Guestrin 2016). XGBoost, sistem optimizasyonu, regülerizasyon, budama ve boş değerler ile çalışma yetenekleri nedeniyle diğer yöntemlerden daha iyidir ve özellikle büyük veri setlerinde çalışmak için tasarlanmıştır (Yeşilyurt ve Dalkılıç 2021). XGBoost, gradyan temelli bir karar ağacı modelidir. Algoritma, karar ağaçlarını eğitim veri seti üzerinde sıralı olarak eğitmekte ve amaç fonksiyonunun değerini iyileştirmek için önceki karar ağaçlarına her iterasyonda yeni bir karar ağacı eklemektedir. En küçüklenmesi amaçlanan amaç fonksiyonu, hata fonksiyonunu (l) ve düzenleştirme teriminden (Ω) oluşmaktadır (Aydın 2021).


Boosting algoritmaları, özellikle ağaç tabanlı yöntemlerde güçlü performans sergilemektedir. Zayıf öğrencilerin birleştirilmesi, karmaşık veri setlerinde hem doğruluk oranını artırmakta hem de genelizasyon yeteneğini iyileştirmektedir. Ayrıca, gürültülü verilere karşı dayanıklı olması ve aşırı öğrenme riskini minimize etmesi, boosting yöntemlerinin güçlü yönlerinden biridir (Chen ve Guestrin 2016). Ancak, boosting algoritmalarının dezavantajları da bulunmaktadır. Bu algoritmalar, çok fazla sayıda zayıf öğrenci

kullanıldığında hesaplama maliyetlerinin artması ve eğitim sürecinin yavaşlaması gibi sorunlarla karşı karşıya kalabilmektedir. Ayrıca, algoritmanın aşırı uyum riskini azaltmak için dikkatli bir hiperparametre optimizasyonu gerekmektedir (Friedman 2001).

2.1.9 Yapay Sinir Ağları

Veri işletim sistemleri, sayısal işlemleri hızla çözebilme yeteneğine sahip olmalarına rağmen, idrak etme ve deneyimlerden elde edilen bilgileri kullanma konusunda insan beyniyle karşılaştırıldığında oldukça yetersiz kalmaktadır. İnsan beyninin üstünlüğü, sinirsel algılayıcılar tarafından kazanılmış ve görelî olarak sınıflandırılmış bilgileri etkili bir şekilde kullanabilmesinden kaynaklanmaktadır. Özellikle son yıllarda, uzman sistemler, bulanık mantık, genetik algoritmalar ve yapay sinir ağları gibi yapay zekanın alt dalları üzerine yoğun araştırmalar ve uygulamalar yapılmıştır (Elmas 2003).

Yapay sinir ağları, insan beyninin mimarisine benzeyen bir yapıdadır. 1943 yılında McCulloch ve Pitts, bu alandaki ilk teorileri ortaya koymuştur. Daha sonra Hebb, 1949'da yayınladığı "Hebb'in Öğrenme Teorisi" ile insan beynindeki nöronların öğrenme sürecini açıklamıştır. Rosenblatt, 1958 yılında algılayıcı hakkında önemli bir araştırma yapmıştır. 1960'lı yıllarda Widrow ve Hoff, yapay sinir ağlarının en iyi uygulamalarını geliştirerek bu alana katkıda bulunmuşlardır. Paul Werbos, 1974 yılında Widrow-Hoff prosedürü için karşıt hata geri yayılımı yapısını önermiştir. Bu gelişme, önceki tek katman kısıtını ortadan kaldırarak daha karmaşık süreçlerin hesaplanmasını kolaylaştırmıştır. Ayrıca, Kolmogorov'un (1957) süper durum teorisi, doğrusal olmayan sonuçların doğrusal sonuçlarla birleştirilmesi yoluyla sürekli fonksiyonların hesaplanabileceğini göstermiştir ve bu alandaki diğer ilerlemeleri büyük ölçüde etkilemiştir (Krycha ve Wagner 1999).



Şekil 1. Yapay Sinir Ağları şeması

Şekil 1'de görüldüğü gibi yapay sinir ağları da eğitim sürecinde girdi/çıkı verilerini işleyerek örnekler üzerinden öğrenmektedir (Tolon ve Güneri Tosunoğlu 2008). Bu süreç, eğitim algoritmasının bağlantı ağırlıklarını, bir yakınsama sağlamak amacıyla bu veriler aracılığıyla sürekli olarak ayarlamasını gerektirmektedir. YSA'lar, her biri önemli bir sorunun bir kısmını çözmeye odaklanan birçok basit işlem biriminden oluşmaktadır. En temel yöntem, bir işlem biriminin girdilerini belirli ağırlıklarla çarparak, bu verileri doğrusal olmayan bir dönüşümden geçirdikten sonra bir çıktı değeri üretmesidir. Yapay sinir ağları, genelleme yapabilme ve eksik bilgi ile çalışma yeteneğine sahiptir, bu da onları karmaşık problemlerin çözümünde güçlü bir araç haline getirmektedir (Seher 2024).

Yapay sinir ağları, geleneksel teknolojiler için oldukça karmaşık olan, doğrusal olmayan, eksik veya çok boyutlu veri setlerine sahip problemleri çözebilme yeteneğine sahiptir. Bu, yapay sinir ağlarının en büyük avantajıdır. Yapay sinir ağları, bu tür veri setlerinde matematiksel modellerin tahmin edilmesi, geleceğe yönelik öngörülerin yapılması ve eğilimlerin keşfedilmesi gibi sorunları çözmek için tercih edilen çözümlerdir. Örneğin, bir yapay sinir ağı, girdi/çıkı verileri öğrenerek veri setindeki eksik bilgileri doldurabilmekte ve aynı şekilde, yapay sinir ağı verilerin sınıflandırılmasını veya belirli girdi değerlerinin çıktı değerlerini tahmin etmesini de yapabilmektedir. Yapay sinir ağlarının karmaşık ve belirsiz verilerden anlam çıkarma yeteneği, insan tarafından fark edilmesi zor olan eğilimleri ve desenleri ortaya çıkarma gücüyle öne çıkmaktadır. Eğitilmiş bir sinir ağı, analiz ettiği konu hakkında bir uzman gibi hareket edebilmekte ve

ilgili alanda geleceğe yönelik projeksiyonlar yapabilmektedir. Bu sayede, "farz edelim ki" senaryolarına yanıt verebilir ve belirsizlik içeren durumlarda tahminler sunabilmektedir.

2.2. Emsal Değer Analizi

Ofislerin kiralarının doğru bir şekilde belirlenmesi, gayrimenkul sektöründe değerlendirme çalışmalarının önemli bir parçasıdır. Özellikle pazar koşullarının dinamik olduğu bölgelerde, kiraların pazar gerçeklerine uygun olması için doğru yöntemlerin kullanılması gerekmektedir. Bu bağlamda, emsal değer analizi, pazardaki benzer özelliklere sahip ofislerin kiralarının karşılaştırılması yoluyla yüksek doğruluk sağlayan bir yaklaşım olarak öne çıkmaktadır. Emsal değer; benzer niteliklere taşınmazların gerçekleşen kira fiyatlarından yararlanarak değerlendirme yapılması olup, bu işlem karşılaştırma esasına dayanmaktadır. Bu yaklaşımın temelini; varsa konu taşınmazın öncesi kira değeri, yoksa taşınmazın niteliklerine en yakın özellikte ve yakın zamanda kiralanmış benzer ve yeter sayıda kira değerlerinin incelenmesi ve mümkün olduğunca birebir benzerlik gösteren taşınmaz kiralarının bulunması oluşturmaktadır. Ayrıca geçmiş dönemlere ilişkin veriler kullanılarak analiz yapılırken, özellikle parasal değerlerde, verinin gerçekleştiği dönemden sonra değerlendirme zamanına kadar pazar davranışlarında meydana gelen değişikliklerin göz önüne alınması ve değerlerin güncellenmesi gerekmektedir.

Emsal değer analizi sürecinde, analiz için kullanılacak emsallerin doğru bir şekilde seçimi, yöntemin güvenilirliği ve doğruluğunu doğrudan etkileyen kritik bir aşamadır. Bu bağlamda, her bir ofis binası için emsal veriler, test veri setindeki ofis binalarının özelliklerine uygun olarak, eğitim veri setindeki aynı ofis binalarına ait veriler üzerinden belirlenmiştir. Bu yaklaşım, veri uyumunu artırmayı ve tahmin doğruluğunu maksimize etmeyi hedeflemektedir. Test veri setinde yer alan her bir ofis için, tekil olarak emsal değer analizi gerçekleştirilmiştir. Bu süreçte, her bir ofisin kendine özgü nitelikleri dikkate alınarak, eğitim veri setinden uygun emsaller belirlenmiş ve analiz bu doğrultuda yapılmıştır. Böylelikle, her bir ofis için spesifik pazar koşullarını ve özellikleri yansıtan daha doğru tahminler elde edilmesi amaçlanmıştır. Eğitim ve test veri setlerinde, ofislerin yapılı ya da yapısız durumlarına göre bir sınıflandırma yapılmıştır. Analiz sürecinde öncelikli olarak, aynı katta yer alan, benzer oda sayısına ve alana sahip olan ofisler seçilmiş; mümkün olduğunca yüksek benzerlik taşıyan ofisler arasındaki karşılaştırmalar esas alınmıştır.

Değerleme sürecinde, emsallerin aylık kiralarının (TL/m²) aritmetik ortalaması hesaplanmış ve bu ortalama üzerinden $\pm$ %15 sınırlarında kontrol yapılmıştır. Bu kapsamda, alt ve üst sınırlar belirlenmiş olup, değerlendirme bu sınırlar içerisinde gerçekleştirilmiştir. Alt ve üst sınırlar için kullanılan emsal birim değerlerin aritmetik ortalaması, analizin tutarlılığını ve pazar koşullarına uygunluğunu sağlamak amacıyla esas alınmıştır. Örneğin 1071 Plazada bulunan: İç mekânı tamamlanmış, Katı: 9, Oda Sayısı: 3 ve Alanı: 130 m² bir ofisin kirasını bulmak için: eğitim veri setinde yer alan 1071 Plazada, aynı katta (9. kat) bulunan ve yapılı durumdaki ofisler seçilmiştir. Emsal ofisler, analiz için kullanılmak üzere belirlenmiştir. Bu emsallerden elde edilen kiraların ortalaması ve sınır kontrolleri, hedef ofisin kirasının tahmininde temel oluşturmuştur. Emsal analizinde, eğitim veri setinde yer alan ofisler için birim metrekare kiraların ortalaması 412,19 TL/m² olarak hesaplanmıştır. Aynı zamanda, $\pm$ %15 sınırları içinde kalan değerler kullanılarak uç değerler: alt sınır: 350,35 TL/m² ve üst sınır: 474,02 TL/m² olarak belirlenmiştir. Bu sınırların altında veya üstünde kalan emsal değerler uç değer olarak nitelendirilmiş ve hesaplamalara dâhil edilmemiştir. Yeni emsallere dayalı olarak yapılan hesaplamada, uç değerler hesaplamaya dâhil edilmemiştir. Bu durum, analiz sürecinin daha doğru ve güvenilir bir şekilde gerçekleştirilmesini sağlamıştır. Yeniden belirlenen emsal veriler üzerinden yapılan hesaplama sonucunda, test verisindeki hedef ofis için ortalama birim kira değeri 387,16 TL/m² olarak bulunmuştur.

3. Yöntem

3.1 Veri Seti

Bu çalışmada çalışma alanı olarak; Ankara'nın 937.546 nüfusa sahip Çankaya ilçesinin idari sınırları içinde olan ve Şekil 2'de gösterilen Kızılırmak, Çukurambar, Söğütözü, İşçi Blokları ve Mustafa Kemal olmak üzere yaklaşık 10,50 km² yüzölçümüne sahip 5 mahalleden oluşmaktadır (Google Earth 2025). Ankara'nın merkezi iş alanı olan Çankaya, ofis binalarının yoğun olduğu bir yerdir ve ofis kiralarının değerlendirme süreçleri açısından önemli bir örnektir çünkü ticaret, hizmet ve bürokrasi için önemli bir merkezdir. Bu bölgenin ticari

gayrimenkul pazarının dinamikliği, ofis kiralardaki çeşitlilik ve bölgedeki ticari mülklerin kiralarnı etkileyen birçok faktör, çalışmanın bu bölgede yapılmasının temel nedenleridir.


Çankaya'da ofis kiralarnı, bölgenin ticari yoğunluğu, prestiji, altyapı olanakları ve bina özelliklerine göre önemli ölçüde değişmektedir. Bölgede modern ofis olanakları, yüksek teknolojik altyapı ve güvenlik özellikleriyle A+ ve A sınıfı ofis binaları, özellikle uluslararası şirketler ve büyük yerel şirketler tarafından tercih edilmektedir ve daha küçük ve yerel şirketler, ise B ve C sınıfı ofis binalarnı tercih etmektedirler.

Çankaya ilçesinin araştırma sahası olarak seçilmesi, bölgedeki ofis kira pazarını anlamak için önemli avantajlar sağlasa da araştırmanın genelleme yeteneğini kısıtlayan bazı faktörler vardır. Araştırma, yalnızca Ankara ilinin bir ilçesi olan Çankaya'ya odaklandığı için, elde edilen sonuçların Türkiye'nin diğer illerindeki ofis kira pazarları için genellenmesi zor olacaktır. Ayrıca, veri toplama sürecinde yalnızca belirli bir zaman diliminde elde edilen ofis kiralarnı, ekonomik faktörler ve diğer dışsal faktörler dikkate alındığında, araştırma sonuçları zamanla değişen pazar koşullarnı tam olarak yansıtmayabilecektir.


Türkiye'de tapu müdürlüklerinde gayrimenkul alım-satım verileri kayıt altına alınmasına rağmen, tapu harcının satış bedelinin %4'ü üzerinden hesaplanması nedeniyle, gerçek satış değerleri çoğunlukla Tapu Müdürlüklerine eksik veya yanlış şekilde beyan edilmektedir. Bu nedenle, bu çalışmada kullanılan ve 2019-2024 yılları arasında gerçekleşen ofis kiralarnı dayalı olarak elde edilen veriler, gerçeğe daha yakın değerler sunan lisanslı değerlendirme şirketlerinin raporlarından, gayrimenkul değerlendirme platformları veri havuzundan, yerel gayrimenkul firmalarından alınmıştır.

Araştırmanın amacına uygun, güncel ve spesifik veriler elde etmek amacıyla, doğrudan saha çalışmaları, görüşmeler ve doğrudan gözlemler yoluyla ofis kira verileri toplanmıştır. Ek olarak, Gelir İdaresi Başkanlığından, Türkiye İstatistik Kurumundan ve T.C. Merkez Bankasından veri talep edilmiştir, ancak bu talepler olumsuz karşılanmıştır. Araştırma alanında bulunan ofis kiracılarının, yatırımcıların, tesis yönetim firmalarının ve gayrimenkul profesyonellerinin görüşlerini almak ve derinlemesine bilgi sağlamak amacıyla görüşmeler yapılarak, ofis kiralarnı belirlenmesinde etkili olan değişkenler, pazar eğilimleri, kira beklentileri ve kullanıcı tercihleri gibi çeşitli konulara odaklanılmıştır.

Ofis binalarnı fiziksel durumlarının, konumlarının, bina özelliklerinin ve çevre koşullarnı kiralara olan etkisini analiz etmek ve verilerin doğrulanmasında kullanılmak amacıyla yerinde gözlemler yapılmıştır. Geçmişte yapılan akademik çalışmalar, Türkiye Değerleme Uzmanları Birliği, Gayrimenkul Yatırımcıları Derneği, Value Solution Partners, Colliers International, CB Richard Ellis Group, Real Estate Investment and Development Information Network ve Gayrimenkul Bilgi Merkezi gibi ulusal/uluslararası gayrimenkul firmalarının yayınladığı pazar raporları ve Sahibinden.com, Emlakjet ve Zingat gibi çevrimiçi gayrimenkul platformlarının analizleri araştırma kapsamında incelenmiştir. Bu raporlar ve analizler, ofis kiralarnı belirlenmesinde kullanılan yöntemler, pazar dinamikleri ve trendleri hakkında detaylı bilgiler sunmaktadır. Bu tür kaynaklar, özellikle pazar koşullarnı anlaşılması, bölgesel karşılaştırmalar yapılabilmesi, ofis kirasını etkileyen değişkenlerin sınıflandırılması ve çalışmada elde edilen verilerin doğruluklarının ve güvenilirliklerinin artırılması açısından faydalı olmuştur.




Şekil 2. Araştırma alanı



Şekil 3. Ofis binalarının dağılımı

Başlangıçta 30 ofis binasında bulunan 2610 ofis için toplam 92 olan değişken elde edilmiştir. Makine öğrenmesi modellerinin daha iyi genelleme yapabilmesi, aşırı öğrenmenin önüne geçilmesi ve gereksiz karmaşıklığın azaltılması amacıyla, öncelikle eksik veri oranı yüksek olan, hedef değişkenle anlamlı bir ilişki göstermeyen değişkenler veri setinden çıkartılarak değilken sayısı 57'ye düşürülmüştür. Ardından verilerin tutarlılığını ve analiz sonuçlarının güvenilirliğini artırmak için araştırma alanındaki ofis binalarının sayısı 14'e ve ofis kira veri sayısı ise 2228'e (Şekil 3) düşürülmüştür. Ofis binalarının araştırma alanı içindeki dağılımı ise Şekil 4'de (Google Earth 2025) gösterilmiştir.

Son olarak çoklu bağlantıyı ve korelasyonu azaltmak, değişkenlerin kirayı açıklama gücünü artırmak, kapsamı daraltarak daha kaliteli ve anlamlı bir veri seti oluşturmak ve daha doğru sonuçlar elde etmek amacıyla yapılan istatistiksel analizler ve değişken seçimi yöntemleri sonucunda ofis kirasını etkileyen ve kirayı anlamlı bir şekilde açıklayan ve Tablo 1'de yer verilen ofis adı, alan, iç mekân durumu (tamamlanmış/tamamlanmamış), oda sayısı ve kat bilgisi olmak üzere 5 (beş) temel değişken belirlenmiştir.



Şekil 4. Ofis binalarının harita üzerinde gösterimi

Tablo 1. Ofis Kirasını Etkileyen Değişkenler

No	Değişken	Değişken Veri Türü
1	Ofis Adı	Kategorik
2	Alan	Sürekli
3	İç mekânı tamamlanmış/ tamamlanmamış ofis	Kategorik
4	Oda Sayısı	Sürekli
5	Kat	Sürekli

3.2 Model Performans Ölçütleri

Makine öğrenmesi modellerinin performansını değerlendirmek için kullanılan en yaygın metriklerden bazıları Kök Hata Kareler Ortalaması (Root Mean Square Error - RMSE), Ortalama Mutlak Hata (Mean Absolute Error - MAE), Göreceli Kök Hata Kareler Ortalaması (Relative Mean Square Error - rMSE), ve Göreceli Ortalama Mutlak Hata (Relative Mean Absolute Error - rMAE)'dir. Her bir metrik, modelin tahmin sonuçlarının gerçek değerlerle ne kadar uyumlu olduğunu farklı bir açıdan değerlendirmektedirler.

RMSE, modelin kestirim hatalarının karelerinin ortalamasının karekökünü almaktadır. Bu metrik, büyük hatalara daha fazla ağırlık vermektedir çünkü hataları karesel olarak büyütmektedir. Örneğin, bir hata küçükse etkisi azdır, ancak büyük bir hata daha fazla ceza almaktadır. İdeal Değer: RMSE'nin 0'a yakın olmasıdır. Daha düşük bir RMSE, modelin kestirimlerinin gerçek değerlere daha yakın olduğunu göstermektedir. Modellerin tahmin performansını değerlendirmek için RMSE,

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

biçiminde tanımlanır (Demirhan ve Başer 2024). Burada, n gözlem sayısını, y_i bağımlı değişkenin gerçek değerini, $\hat{y}_i$ kestirim değerini, $\bar{y}$ bağımlı değişken değerlerinin aritmetik ortalamasını göstermektedir.

MAE, kestirilen değerler ile gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasıdır. Hataları kare almadan değerlendirmektedir, bu nedenle her bir hatanın büyüklüğüne eşit ağırlık vermektedir. İdeal değer 0'a yakın olması beklenmektedir. Düşük bir MAE, modelin hatalarının küçük olduğunu göstermektedir. Modellerin tahmin performansını değerlendirmek için, MAE aşağıda tanımlandığı gibi kullanılmaktadır (Demirhan ve Başer 2024).

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

rMSE, RMSE'yi gerçek değerlerin ortalamasına yani y_i bölerek göreceli bir ölçüm sağlamaktadır. Bu, modelin hata oranını değerlendirmek için ölçekten bağımsız bir metrik oluşturmaktadır. rMSE, genellikle % olarak ifade edilmektedir. %10'un altında olması, modelin iyi bir performans gösterdiği anlamına gelmektedir. %10-20 arası kabul edilebilir; %20'nin üzeri modelin iyileştirilmesi gerektiğine işaret etmektedir. Modellerin tahmin performansını değerlendirmek için, RMSE aşağıda tanımlandığı gibi kullanılmaktadır (Demirhan ve Başer 2024).

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

rMAE, MAE'nin göreceli bir versiyonudur ve tahmin hatalarını gerçek değerlerin ortalamasına oranlamaktadır ve hataların gerçek değerlere oranla büyüklüğünü ifade etmektedir. rMAE'nin %10 veya altı iyi performansı göstermekte; %10-20 arası performansın kabul edilebilir olduğunu, %20 üzeri ise modelin yeniden değerlendirilmesi gerektiğini işaret etmektedir. Modellerin tahmin performansını değerlendirmek için, RMSE aşağıda tanımlandığı gibi kullanılmaktadır (Demirhan ve Başer 2024).

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

RMSE ve rMSE modelin büyük hatalara daha duyarlı olması isteniyorsa tercih edilmektedir. Örneğin: Konut değerlemesi gibi durumlarda, büyük tahmin hataları (örneğin, bir dairenin fiyatını çok düşük tahmin etmek)


daha önemlidir. MAE ve RMAE modelin genel performansı değerlendirilecekse ve hataların tümü eşit önemdeyse kullanılmaktadır. Örneğin: Günlük hava durumu öngörüsünde, büyük bir hata küçük hatalar kadar önemlidir. Bu metriklerin değerleri, modelin tahmin edilebilirlik gücü ve veri setindeki varyans dikkate alınarak analiz edilmelidir. Düşük varyansa sahip bir veri setinde yüksek RMSE veya MAE, modelin yeterince iyi olmadığını göstermektedir.

RMSE ve MAE tahmin hataları, modellerin kapsamlı bir şekilde değerlendirilmesi için eşzamanlı olarak ele alınmalıdır. Modelin hata büyüklüğünün ortalamasını göstermek için MAE, gözlemlenen ve tahmin edilen değerler arasındaki ortalama mutlak farkı ölçmektedir. Bununla birlikte RMSE, hatalardaki varyasyonu ölçerek hataların sapma derecesini göstermektedir ve MAE'ye kıyasla daha hızlı artmaktadır. Hata büyüklüğünün ortalaması ve hata varyasyon derecesinin eşzamanlı olarak değerlendirilmesi, modelin sürekli olarak düşük hata ürettiği olup olmadığını belirlemek için gereklidir. MAE ve RMSE, farklı pazar fiyat seviyeleri nedeniyle, rMAE ve rRMSE gibi yeniden ölçeklendirilmiş versiyonları da değerlendirilmektedir. Bu versiyonlar birçok pazar için benzer olmasına rağmen, bireysel pazarlar için gerçek hata büyüklüğünü göstermemektedir (Demirhan ve Başer 2024).

4. Bulgular

Ofis kiralarnı belirleyen faktörlerin analiz edilmesi, gayrimenkul değerlendirme ve piyasa dinamiklerinin anlaşılması açısından önemli bir araştırma konusudur. Bu bağlamda, kiranın (TL/m²) bağımlı değişken olarak ele alındığı ve alan (m²), iç mekân durumu (tamamlanmış/tamamlanmamış), oda sayısı ve kat gibi bağımsız değişkenlerle ilişkisinin incelendiği bu çalışmada, veri setinin temel özelliklerini anlamak ve değişkenler arasındaki ilişkileri görselleştirmek amacıyla R programlama dili ve veri analiz kütüphaneleri kullanılarak çeşitli istatistiksel grafikler oluşturulmuştur bir analiz gerçekleştirilmiştir. Elde edilen grafikler, ofis pazarında kiralarnı etkileyen temel değişkenlerin belirlenmesi ve bu değişkenlerin kira tahmin modellerindeki rolünün anlaşılması açısından önemli bir çerçeve sunmaktadır.


Verinin dağılımını incelemek için, logaritmik dönüşümü uygulanmış kira (TL/m²) değişkeninin dağılım grafiği Şekil 5'de gösterilmektedir. Elde edilen grafik, kiralarnı belirli bir aralıkta yoğunlaştığını ve dağılımın tek modlu bir yapıya sahip olduğunu göstermektedir. Logaritmik dönüşüm ile, sağa çarpıklık azalmış ve dağılım daha simetrik hale gelmiştir. Ayrıca kiralarnı belirli seviyelerde yoğunlaşması da piyasa koşullarına ilişkin önemli bir göstergedir. Aşağıda sunulan grafikler ve açıklamalar, değişkenlerin istatistiksel özelliklerini sistematik bir biçimde ele alarak, modelleme sürecinde dikkate alınması gereken temel noktaları vurgulamaktadır.



Şekil 5. Kiranın (TL/m²) logaritmik dönüşümü sonrasında dağılım grafiği


Şekil 6'da kiralanan ofis alanı (m²) ile kira (TL/m²) arasındaki ilişki incelendiğinde, küçük alanlı ofislerin kiralarnı geniş bir dağılım gözlemlenirken, büyük alanlı ofislerin kira seviyelerinin daha dar bir aralıkta yoğunlaştığı görülmektedir. Bu durum, büyük alanlı ofislerin genellikle daha düşük birim fiyatla kiralandığını, küçük alanlı ofislerin ise fiyatlandırmada daha değişken olabildiğini göstermektedir. Ayrıca, veride bazı aykırı değerlerin bulunduğu ve kiralanan alan büyüdükçe kiranın azalabileceğine yönelik bir

eğilim olduğu dikkat çekmektedir. Ancak, değişkenler arasındaki ilişki doğrusal bir yapı sergilememekte olup, farklı faktörlerin de kira üzerinde etkili olabileceği değerlendirilmektedir.



Şekil 6. Kiralanan ofis alanı (m²) ile kira (TL/m²) arasındaki ilişki grafiği

Şekil 7’de ofislerin iç mekân durumlarına göre dağılımı gösterilmektedir. İç mekân durumu "Tamamlanmış" olan ofislerin toplamın %78,55'ini oluşturduğu, "Tamamlanmamış" durumdaki ofislerin ise %21,45 oranında kaldığı görülmektedir. Bu sonuçlar, araştırmada tamamlanmış ofislerin daha yaygın olduğunu ve ofis kiralama süreçlerinde hazır ve kullanıma uygun ofislere olan talebin yüksek olabileceğini düşündürmektedir. Tamamlanmamış ofislerin daha düşük oranı, bu tür alanların pazardaki sınırlı arzına veya düşük talebine işaret edebilmektedir. Ayrıca, tamamlanmamış ofislerin genellikle özelleştirme ve iç tasarım maliyetleri gerektirmesi, kiracılar açısından ek maliyet yaratabilmektedir ve tercih edilme oranlarını etkileyebilmektedir.



Şekil 7. Ofislerin iç mekân durumları ve oda sayıları

Şekil 7’de verilen ofislerin oda sayıları dağılımı incelendiğinde, ofislerin genellikle 2 ile 6 oda arasında değiştiği görülmektedir. Grafik üzerinde yapılan inceleme, 3 ve 4 odalı ofislerin en yaygın olan ve piyasada en fazla bulunan ofis türleri olduğunu göstermektedir. Bunun yanı sıra, 2 ve 6 odalı ofislerin de önemli bir pazar payına sahip olduğu, ancak 1 odalı ofislerin oldukça az sayıda bulunduğu gözlemlenmektedir. Bu sonuçlar, kiracıların genellikle orta büyüklükteki ofislere yöneldiğini, buna karşılık tek odalı küçük ofislerin sınırlı arz ve talebe sahip olduğunu göstermektedir. 5 odalı ofislerin ise diğer oda sayılarına kıyasla daha az yaygın olması, belirli büyüklükteki ofislerin piyasada daha fazla tercih edildiğine işaret etmektedir. Bu bulgular, oda sayısının kira üzerindeki etkisini incelemek adına önemli bir değişken olduğunu ortaya koymaktadır.

Veri analizi ve modelleme süreçlerinde R programı kullanılmıştır. R, geniş kütüphane desteği sayesinde istatistiksel analizlerden makine öğrenme modellerine kadar çeşitli yöntemlerin uygulanmasını sağlayan etkili bir araçtır. Bu çalışmada, yüksek boyutlu veri setleri üzerinde makine öğrenmesi yöntemleri kullanılarak analizler gerçekleştirilmiş ve modelleme süreçleri R programında yürütülmüştür. Analizler, eğitim ve test veri setleri üzerinde ayrı ayrı uygulanmış, model performansının değerlendirilmesi ve optimize edilmesi hedeflenmiştir.

İlk aşamada, eğitim veri seti kullanılarak çeşitli makine öğrenmesi algoritmaları (örneğin, Rasgele Orman, Destek Vektör Makineleri ve XG Boosting) eğitilmiş ve modellerin tahmin performansı değerlendirilmiştir. Elde edilen modeller, test veri seti üzerinde doğrulanmış ve model performansı metrikleri (örneğin, RMSE, MAE) ile karşılaştırmalı olarak analiz edilmiştir. Sonuçlar, makine öğrenmesi algoritmalarının değişken azaltma teknikleriyle birleştirilmesinin hem tahmin doğruluğunu artırdığını hem de işlem süresini kısalttığını göstermektedir. R programında gerçekleştirilen bu analizler, eğitim ve test veri setlerinin sistematik bir şekilde işlenmesi, model eğitimi ve doğrulama süreçlerinin detaylı bir şekilde optimize edilmesi açısından başarılı bir yaklaşım sunmaktadır.

Araştırmada, geliştirilen modellerin performansını değerlendirmek amacıyla eğitim ve test veri setleri üzerinde yapılan analizlerin sonuçları sunulmuştur. Tablo 2’de ve Tablo 3’te, bağımsız değişkenlerin hedef değişken kira (TL/m²) üzerindeki etkileri incelenmiş ve modelin genel doğruluk seviyeleri karşılaştırılmıştır. Yöntemlerin sonuçları, en düşük hata oranına sahip olanların belirlenmesini kolaylaştırmak amacıyla hata ölçütlerine göre sıralanmıştır. Bu tablolar, modelin eğitim sürecinde gösterdiği performans ile test verisi üzerinde elde edilen sonuçlar arasındaki farkları ortaya koyarak, modelin genelleme yeteneğini değerlendirmek için önemli bir temel sağlamaktadır.

Rasgele orman modeli, bu çalışmada test veri setinde elde edilen sonuçlar itibarıyla en başarılı yöntem olarak öne çıkmıştır. RMSE, modelin genel hata seviyesini göstermektedir. Hataların büyüklüğüne karşı daha duyarlıdır çünkü kare alma işlemi büyük hataları daha fazla büyütür. 0,2373 gibi düşük bir RMSE değeri, modelin tahminlerinin gerçek değerlere oldukça yakın olduğunu ve büyük hataların nadiren oluştuğunu göstermektedir. 0,1908 gibi düşük bir MAE değeri, tahmin edilen kira değerlerinin gerçek değerlere oldukça yakın olduğunu ve hataların küçük olduğunu göstermektedir. MAE, daha sade ve yorumlanabilir bir metrik olup, küçük ve büyük hataları eşit ağırlıkla değerlendirdiği için RMSE’ye göre daha genel bir hata ölçümüdür.

rRMSE, modelin hata oranını ifade etmektedir. 0,03997 gibi düşük bir değer, hataların gerçek değerlere göre çok küçük bir yüzdede olduğunu göstermektedir ve kira değerlerinin büyük bir kısmı model tarafından doğru bir şekilde tahmin edilmiştir. rRMSE, modelin farklı veri setlerinde nasıl performans gösterebileceğini karşılaştırmak için oldukça faydalıdır. rMAE’nin 0,03214 gibi bir değere sahip olması, modelin tahmin hatalarının gerçek değerlere kıyasla çok düşük bir seviyede olduğunu ifade etmektedir. rMAE, verinin ölçeğinden bağımsız olarak model performansını değerlendirmek için kullanışlıdır. RMSE, büyük hatalara karşı daha duyarlıdır, bu nedenle nadir görülen ama büyük hata yapan modellerin farkını göstermektedir. MAE ise hataları eşit ağırlıkla değerlendirdiği için daha sade ve genelleştirilebilir bir metrik sağlamaktadır. rRMSE ve rMAE, verinin ölçeğine bağımlı olmadıkları için farklı veri setlerinde model performansını karşılaştırmak için faydalıdır. Bu çalışmada, hem rRMSE (0,03997) hem de rMAE (0,03214) değerlerinin düşük olması, modelin hata oranının gerçek değerlere kıyasla oldukça düşük olduğunu göstermektedir. Bu metriklerin bir arada değerlendirilmesi, Rasgele Orman modelinin kira tahminleri için oldukça başarılı bir performans gösterdiğini ve hataların hem mutlak hem de göreceli düzeyde düşük olduğunu açıkça ortaya koymaktadır.

Tablo 2. Eğitim veri seti sonuçları

No	Yöntem	RMSE	MAE	rRMSE	rMAE
1	XGBoost	0,14570	0,10795	0,02448	0,01814
2	Rasgele Orman	0,18224	0,14487	0,03062	0,02434
3	K-En Yakın Komşu	0,21233	0,16749	0,03567	0,02814
4	Yapay Sinir Ağı	0,22620	0,18172	0,03800	0,03053
5	Radyal Destek Vek. Mak.	0,23140	0,17781	0,03888	0,02987
6	Çoklu Doğrusal Regresyon	0,24051	0,19523	0,04041	0,03280
7	Ridge Regresyonu	0,24072	0,19635	0,04044	0,03299
8	Doğrusal Destek Vek. Mak.	0,24316	0,19245	0,04085	0,03233
9	Lasso Regresyonu	0,24318	0,19951	0,04086	0,03352
10	Karar Ağacı	0,24393	0,20014	0,04098	0,03363

Tablo 3. Test veri seti sonuçları

No	Yöntem	RMSE	MAE	rRMSE	rMAE
1	Rasgele Orman	0,23733	0,19082	0,03997	0,03214
2	XGBoost	0,23870	0,18942	0,04020	0,03190
3	K-En Yakın Komşu	0,24507	0,19461	0,04128	0,03278
4	Radyal Destek Vek. Mak.	0,25000	0,19812	0,04211	0,03337
5	Yapay Sinir Ağı	0,25033	0,20356	0,04216	0,03428
6	Ridge Regresyonu	0,25129	0,20696	0,04232	0,03486
7	Çoklu Doğrusal Regresyon	0,25140	0,20645	0,04234	0,03477
8	Lasso Regresyonu	0,25266	0,20898	0,04255	0,03520
9	Emsal Değer Analizi	0,25278	0,19817	0,04257	0,03338
10	Doğrusal Destek Vek. Mak.	0,25641	0,20439	0,04319	0,03442
11	Karar Ağacı	0,26001	0,21253	0,04379	0,03580

XGBoost modeline göre analiz sonuçları: RMSE: 0,2387, MAE: 0,1894, rRMSE: 0,04020, rMAE: 0,03190 olarak ortaya çıkmıştır. XGBoost, Rasgele Orman modelinden çok az bir farkla ikinci sırada yer almaktadır. Daha düşük MAE değeri ile XGBoost, hata oranını minimize etmekte başarılı bir yöntem olduğunu göstermiştir. Boosting tekniğinin etkili bir şekilde genel hataları azaltması, model performansını artırmıştır. K-En Yakın Komşu modeline göre analiz sonuçları: RMSE: 0,2451, MAE: 0,1946, rRMSE: 0,04128, rMAE: 0,03278 olarak ortaya çıkmıştır. Model, komşu gözlemlere dayanarak tahmin yaptığı için, orta düzeyde bir performans sergilemiştir. Özellikle küçük veri setlerinde etkili olsa da daha karmaşık ilişkileri öğrenme kapasitesi sınırlıdır, bu yüzden diğer yöntemlere göre biraz daha yüksek hata oranlarına sahiptir.

Emsal Değer Analizi modeline göre analiz sonuçları: RMSE: 0,2528, MAE: 0,1982, rRMSE: 0,04257, rMAE: 0,03338 olarak ortaya çıkmıştır. Emsal Değer Analizi, tahmin hatalarını minimize etmede modern yöntemlerle rekabet edebilir düzeyde bir performans sergilemiştir. Bununla birlikte, modern yöntemlerin sağladığı esneklik ve karmaşık ilişkileri yakalama yeteneği sınırlı kalmıştır. En kötü sonuçları veren Karar Ağacı modeline göre analiz sonuçları: RMSE: 0,2600, MAE: 0,2125, rRMSE: 0,04379, rMAE: 0,03580 olarak ortaya çıkmıştır. Karar ağacı, görselleştirilebilir ve yorumlanabilir bir modelleme yöntemi sunmaktadır. Ancak, test

verisinde hatalar diğer yöntemlere göre yüksektir. Tek bir ağaç yapısının karmaşık veri ilişkilerini yakalamakta yetersiz kalması bu sonucu doğurmuştur.

5. Sonuç ve Tartışma

Türkiye’de ve dünyada daha önce yapılan çalışmalar incelendiğinde, ofis kiralarnı etkileyen faktörlerin belirlenmesinde çeşitli yöntemlerin kullanıldığı görülmektedir. Aksoy (2005) tarafından yapılan çalışmada, İstanbul’un Levent, Maslak, Gayrettepe-Esentepe ve Havaalanı Bölgesi ile Kozyatağı, Kavacık ve Altunizade bölgelerindeki 115 ofis binası örneklem olarak incelenmiş, belirlenen kriterlere uymayan 41 ofis binası örnekleminden çıkarılmıştır. Çalışmada, hedonik regresyon analizi kullanılarak ofis kiralarnı etkileyen faktörler analiz edilmiş ve bölgesel boşluk oranının ofis kirasını etkileyen en önemli faktör olduğu sonucuna ulaşılmıştır. Karımov (2010), İstanbul merkezi iş alanlarında bulunan 500 adet ofis alanı ve ofis binası verileri için binaların fiziksel özelliklerini, kira sözleşmesi koşullarını, kiracıların ofis kira bedeli belirleyicileri ile ilgili algılarını, kiracıların ikamet bölgelerini, kiracıların ulaşım yöntemlerini bulanık kural tabanlı sistemler yardımıyla incelemiştir. Bulanık kural tabanlı sistem modellemesi kullanılarak merkezi iş alanı alt bölgelerinde ortalama ofis kiralarnındaki mekânsal varyasyon, işçi sayısı ve kat sayısı gibi farklı değişken gruplarına bağlı olarak meydana gelen ofis kira değişimleri detaylı bir şekilde analiz edilmiştir. Bu yöntemler, değerlendirme çalışmalarında disiplinler arası bir yaklaşım sunmakta ve farklı veri türlerini analiz ederek daha kapsamlı sonuçlar elde etmeyi sağlamaktadır.

Kiralarnın belirlenmesinde hem ofis sahibini hem de kiracıyı memnun edecek şekilde, tarafların olabilecek en adil ve ortak bir paydada buluşması, sürdürülebilir bir pazar ekonomisi açısından büyük önem taşımaktadır. Adil bir sistemin oluşturulması, tarafların karşılıklı memnuniyetini sağlamanın yanı sıra pazar dengesine de katkıda bulunmaktadır. Son yıllarda, teknolojik imkânların genişlemesi ve veri işleme kapasitelerinin artmasıyla birlikte, ofis kira tahmin modelleri üzerine yapılan çalışmalar önemli ölçüde artmıştır. Bu modeller, ofis kiralarnının daha doğru, veriye dayalı ve tarafsız bir şekilde tahmin edilmesine olanak tanımakta, geleneksel yöntemlerin ötesine geçerek modern gayrimenkul pazarında etkin bir çözüm sunmaktadır.

Birçok matematiksel model, değişkenler arasındaki doğrusal ilişkiyi doğrusal bir denklemle ifade etmek üzere geliştirilmiştir. Ancak lokasyon değişiklikleri, bazı verilerin eksikliği nedeniyle istatistiksel olarak anlamsız ve çelişkili sonuçlara yol açabilmektedir. Mekânsal bağımlılık etkileri dikkate alınabilse de mekânsal veri setlerindeki artış, bu modellerin tahminini zorlaştırarak yeni sorunlar ortaya çıkarmaktadır. Ofis binaları ve iş merkezlerindeki kiralanabilir alan talebini, kira bedellerini ve yatırımların değerlerindeki değişimleri tahmin etmek, riskleri en aza indirmek ve tahmin problemlerini aşmak için, klasik modellere alternatif olarak daha tutarlı, gerçekçi ve güvenilir sonuçlar sunan makine öğrenmesi yöntemlerinin kullanılması önemli bir avantaj sağlayacaktır. Rastgele Orman yöntemi değişken önemini iyi belirlemesiyle, aşırı öğrenmeyi azaltmasıyla ve doğrusal olmayan ilişkileri etkili bir şekilde yakalayarak dengeli ve güvenilir tahminler sunmasıyla ve XGBoost yöntemi ise büyük veri setlerinde hızlı çalışması ve hata oranlarını minimize etmesiyle hem eğitim hem de test veri setleri üzerinde yüksek performans sergilemişlerdir. Bu sonuçlar, modellerin tahmin ettiği kiranın gerçek kiraya oldukça uyumlu olduğunu göstermektedir. Bu yöntemler, karmaşık veri setlerini işleyerek pazar dinamiklerini daha doğru bir şekilde modelleme imkânı sunmaktadır. Hangi yöntem seçilirse seçilsin, gayrimenkul değerlerinin makine öğrenmesi yöntemleriyle bulunulmaya çalışılmasının temel amacı, fiyat tahmin doğruluğunu artırmaktır. Ofis pazarına tek bir büyük pazar olarak yaklaşmak doğru değildir; ofis pazarını farklı alt pazarlara ayırmak için sağlam teorik argümanlar vardır. Ofis kirasını anlamak ve tahmin etmek için kullanılacak bir çerçeve sunulması gerekmektedir. Ofis pazarındaki farklı bölümleri tanıyarak; farklı organizasyon türleri ile tercih ettikleri ofis özellikleri arasında ayırım yapacak, arz ve talep unsurlarını yansıtan yapısal, mekânsal ve niteliksel özelliklere dayanan ve yerel pazar dinamikleriyle uyumlu bir model kullanılması gerekmektedir.

KAYNAKLAR

- Aydın, Z. E. (2021). Balina optimizasyonu algoritması ve rastgele alt uzaylar temelli eksik veri tamamlama yöntemleri.
- 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. A. (1998), Tutorial on support vector machines for pattern recognition. Data mining and knowledge discovery, 2(2), 121-167.
- Canaz Sevgen, S. (2022). Kitlesel değerlemede makine öğrenme algoritmaları. Doktora Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Gayrimenkul Geliştirme ve Yönetimi Anabilim Dalı, Ankara.
- Chen T. and Guestrin C. (2016). XGBoost. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining.
- Cortes, C. and Vapnik, V. (1995). Support-vector networks. Machine Learning 20, 273–297.
- 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.
- Demirhan, H. and 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.
- Eichholtz, P., Kok, N. and Quigley, J. M. (2010). Doing well by doing good? Green office buildings. American Economic Review, 100(5): 2492–2509.
- Elmas, Ç. (2003). Yapay zeka ve bulanık mantık uygulamaları. Seçkin Yayıncılık.
- Fisher, J. D. and Martin, R. (2004). Income property valuation. Dearborn Real Estate Education.
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. Annals of Statistics, 29(5), 1189-1232.
- Geltner, D., Miller, N., Clayton, J., and Eichholtz, P. (2013). Commercial real estate analysis and investments. Cengage Learning.
- Geeksforgeeks (2024). Ridge regression vs lasso regression. <https://www.geeksforgeeks.org/ridge-regression-vs-lasso-regression/> (Erişim tarihi: 19 Aralık 2024)
- Google Earth. (2025). Ankara, Türkiye Uydu görüntüsü. <https://www.google.com/earth/> (Erişim tarihi: 14 Şubat 2025)
- 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.
- 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.
- 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.
- Krycha, S., and Wagner, A. (1999). Applications of artificial neural networks in management science: a survey. Universität Wien, Institut für Betriebswirtschaftslehre.
- Kusan, H., Aytakin, O. and Özdemir, I. (2010). The use of fuzzy logic in predicting house selling prices. Expert Systems with Applications, 37(3), 1808-1813.

- 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.
- Mukherjee, T. (2024). Different types of distances used in machine learning explained. <https://tuhinmukherjee74.medium.com/different-types-of-distances-used-in-machine-learning-explained-550e2979752c> (Erişim tarihi: 20 Aralık 2024).
- Raschka, S., Liu, Y. and Mirjalili, V. (2022). *Machine learning with PyTorch and scikit-learn: Develop machine learning and deep learning models with Python*. Packt Publishing.
- Schapire, R. E. (1999). A brief introduction to boosting. *Proceedings of the 16th International Joint Conference on Artificial Intelligence*, 1401-1406.
- Seher, G. (2024). Yapay Sinir Ağları (Artificial Neural Network, ANN) <https://medium.com/@gulsahseher/yapay-sinir-aglari-artificial-neural-network-ann-af78c7b8f22e> (Erişim Tarihi: 3 Ekim 2024)
- 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.
- Yilmazer, 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.
- Yeşilyurt, S. N. and Dalkılıç, H. Y. (2021). XGBoost ve gradient boost machine ile günlük nehir akımı tahmini. *The 3rd International Symposium of Engineering Applications on Civil Engineering and Earth Sciences*, 22-24 Eylül 2021, Karabük, Turkey.