

Makine Öğrenmesinde Sektörel Veri Entegrasyonu: Emlak Gayrimenkul Yatırım OrtaklıĞı Hisse Senedi Fiyat Tahmini

Ahmet AKUSTA* 

ÖZ

Bu çalışmanın temel amacı, Emlak Konut Gayrimenkul Yatırım OrtaklıĞı (EKGYO) hisse senedi fiyatlarını tahmin etmek amacıyla sektörel veriler ve gelişmiş makine öğrenimi modellerini kullanmaktadır. EKGYO hisse senedi fiyatları ile makroekonomik göstergeler arasındaki güçlü korelasyonlar, genel ekonomik şartların gayrimenkul sektörünün finansal performansı üzerindeki etkilerini gözler önüne sermektedir. Çalışmada, USD/TL kuru, konut fiyat endeksi, yurt içi üretici fiyat endeksi (YI-ÜFE) ve ipotekli konut satışları gibi önemli ekonomik göstergeler incelenmiş ve bu göstergeler ile EKGYO hisse senedi fiyatları arasındaki ilişki detaylı bir şekilde analiz edilmiştir. Aşırı bulgular, Kalman Filtresi modelinin en düşük ortalama mutlak hata (MAE), ortalama kare hata (MSE) ve kök ortalama kare hata (RMSE) değerleri ile en yüksek tahmin doğruluğunu sağladığını göstermektedir. Bu durum, Kalman Filtresi modelinin finansal verilerdeki dalgalandırmaları yönetebilme ve doğru tahminler sunabilme potansiyelini ortaya koymaktadır. Kalman Filtresi ile karşılaşıldığında biraz daha yüksek hata oranlarına sahip olmasına rağmen ETS modelinin de iyi bir performans sergilediği görülmüştür. Buna karşın, Neural Prophet modeli, mevsimsellik ve trendleri yakalamaya yönelik gelişmiş tasarıma rağmen, karmaşık finansal veri setlerinde veya kısa vadeli tahminlerde bazı sınırlamaları işaret eden daha yüksek hata oranlarına sahiptir.

Anahtar Kelimeler: Hisse Senedi Fiyat Tahmini, Makine Öğrenmesi, Özellik Mühendisliği, Zaman Serisi Analizi, Finansal Piyasalar

Sectoral Data Integration in Machine Learning: Predicting Real Estate Investment Trust (REIT) Stock Prices

ABSTRACT

The main objective of this study is to use sectoral data and advanced machine learning models to predict the stock prices of Real Estate Investment Trust (EKGYO). The strong correlations between EKGYO stock prices and macroeconomic indicators reveal the effects of general economic conditions on the financial performance of the real estate sector. In this study, important economic indicators such as USD/TL exchange rate, housing price index, domestic producer price index (D-PPI) and mortgage sales are examined and the relationship between these indicators and EKGYO stock prices is analysed in detail. Empirical findings show that the Kalman Filter model provides the highest prediction accuracy with the lowest mean absolute error (MAE), mean square error (MSE) and root mean square error (RMSE) values. This reveals the potential of the Kalman Filter model to manage fluctuations in financial data and provide accurate forecasts. Although it has slightly higher error rates compared to the Kalman Filter, the ETS model also performs well. In contrast, the Neural Prophet model, despite its advanced design to capture seasonality and trends, has higher error rates, indicating some limitations in complex financial data sets or short-term forecasting.

Keywords: Stock Price Prediction, Machine Learning, Feature Engineering, Time Series Analysis, Financial Markets

1. Giriş

Gayrimenkul hisse senetleri, özgün özellikleri ve makroekonomik temellerle olan bağlantıları nedeniyle genel hisse senedi piyasasında önemli bir yere sahiptir. Bu menkul kıymetler, reel varlıklara dayanan bir yatırım aracı olup, davranışları makroekonomik dinamiklerle karmaşık ilişkiler içindedir (Lee vd., 2018). Bu özgün özelliklerin incelenmesi, sektör dinamiklerinin ve bunların borsa üzerindeki etkilerinin anlaşılmasına katkı sağlayacaktır.

* Corresponding Author/Sorumlu Yazar, Öğr. Gör. Dr., Konya Teknik Üniversitesi, Konya, Türkiye/ Lect. Ph.D., Konya Technical University, Konya, Türkiye, ahmetakusta@hotmail.com

Makale Gönderim ve Kabul Tarihleri/Article Submission and Acceptance Dates: 15.08.2024-23.12.2024

Citation/Atif: Akusta, A. (2025). Makine öğrenmesinde sektörel veri entegrasyonu: emlak gayrimenkul yatırım ortaklıĞı hisse senedi fiyat tahmini. *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 56, 147-161. <https://doi.org/10.52642/susbed.1533673>

Gayrimenkul menkul kıymetlerinin oynaklığı, birçok makroekonomik risk göstergesi ile güçlü bir pozitif korelasyon göstermektedir. Bu ilişki, makroekonomik temellerin gayrimenkul hisse senedi davranışlarını şekillendirmektedeki kritik rolünü ortaya koymaktadır (Lee vd., 2018). Türkiye'nin ithalat bağımlılığı dikkate alındığında, döviz kuru ile Yİ-ÜFE arasındaki iletim kanalları, fiyat seviyeleri ve maliyet yapılarında belirleyici bir etkiye sahiptir. Döviz kurlarındaki değişimler, özellikle Türk Lirası'nın değer kaybı, ithal girdilerin maliyetini artırarak üretim maliyetlerinin yükselmesine ve bu durumun Yİ-ÜFE'ye yansımmasına neden olmaktadır (Aşık, 2023). Döviz kurundan Yİ-ÜFE'ye doğru tek yönlü bir ilişkinin bulunması, döviz kuru dalgalanmalarının üretici fiyatlarını doğrudan etkilediğini göstermektedir (Usupbeyli & Uçak, 2020). Maliyet enflasyonu, inşaat maliyetlerini ve dolayısıyla konut fiyatlarını artırmaktadır.

Döviz kuru ile konut fiyat endeksi arasındaki ilişki, finansal piyasaların etkileşimleri ve reel sektör dinamikleri açısından oldukça karmaşık bir yapı sergilemektedir. Türkiye'de yapılan ampirik analizler, dolar kuru ile konut fiyat endeksi arasında çift yönlü bir nedensellik ilişkisi olduğunu ortaya koymaktadır (Yılmaz, 2022). Döviz kurundaki artışlar, inşaat sektöründe kullanılan ithal malzeme ve ekipmanların maliyetini yükselterek konut üretim maliyetlerini artırmaktadır. Konut fiyatlarındaki artış, yerli yatırımcıların dövizde yönelmesine veya yabancı yatırımcıların gayrimenkul piyasasına ilgisinin artmasına yol açarak döviz talebini etkilemektedir. Böylece, konut fiyat endeksi ve döviz kuru arasındaki ilişki, hem maliyet kanalı hem de yatırımcı davranışları üzerinden karşılıklı etkileşim göstermektedir.

Yİ-ÜFE, iç piyasadaki mal ve hizmetlerin maliyetini etkileyerek çeşitli sektörleri doğrudan etkilemektedir. Üretici fiyatlarındaki artışlar, özellikle inşaat sektöründe kullanılan hammaddelerin ve ara malların maliyetini yükselterek, gayrimenkul sektöründe maliyet bazlı fiyat artışlarına yol açmaktadır (Khan vd., 2018). Bu durum, konut fiyat endeksinin yükselmesine neden olarak gayrimenkul hisse senetlerinin değerlemesini ve yatırımcı bekłentilerini etkilemektedir (Yılmaz, 2022). Ayrıca, Yİ-ÜFE'deki artışlar, genel ekonomik istikrarı ve enflasyon bekłentilerini etkileyerek finansal piyasalarda belirsizlige ve volatiliteye yol açabilmektedir (Aşık, 2023).

Gayrimenkul fiyatlarının yatırımcı duyarlılığı ve borsa performansı üzerindeki etkisi de dikkate değerdir. Yüksek konut fiyatları, servet etkisi yaratarak tüketici harcamalarını ve yatırımcıların risk alma istahını artırabilmektedir. Bu durum, hisse senedi piyasasında yükselişlere ve potansiyel olarak yanlış fiyatlandırımlara yol açarak piyasa verimliliğini etkileyebilmektedir (Yang vd., 2024). Diğer yandan, döviz kurlarındaki dalgalanmalar ve enflasyonist baskilar, yatırımcıların risk algısını ve yatırım stratejilerini etkileyerek gayrimenkul hisse senedi fiyatlarını doğrudan etkileyebilmektedir (Shabbir vd., 2023).

Bu bağlamda, gayrimenkul sektörü ile makroekonomik göstergeler arasındaki iletim kanallarının anlaşılması, hisse senedi fiyatlarının doğru tahmin edilmesi için kritik öneme sahiptir. Döviz kuru dalgalanmaları, üretici fiyatlarını ve konut fiyatlarını etkileyerek gayrimenkul sektörünün kârlılığını ve hisse senedi performansını şekillendirmektedir. Benzer şekilde, Yİ-ÜFE'deki değişimler, maliyet yapısını ve fiyatlandırma stratejilerini etkileyerek sektörün genel performansını ve yatırımcı bekłentilerini belirlemektedir (Kundieieva & Martyniuk, 2021).

Son yıllarda, sektörle verilerin hisse senedi fiyat tahmin modellerine dahil edilmesi, tahminlerin doğruluğunu artırmadaki potansiyel etkisi nedeniyle ilgi görmektedir. Bazı çalışmalar, sektörle verilerin modellerin doğruluğunu artırabileceğini ve sektör rotasyon stratejilerinin pozitif anomal getiri ve daha yüksek Sharpe oranları sağlayabileceğini öne sürmektedir (McMillan, 2021). Ayrıca, gelişmiş finansal veri ön işleme yöntemlerinin ve makine öğrenimi tekniklerinin kullanılması, bu modellerin tahmin gücünü daha da artırmıştır (Bounid vd., 2022).

Bununla birlikte, sektörle verilerin geleneksel finansal modellere dahil edilmesi, tahmin süreçlerinin karmaşaklısı ve finansal piyasaların değişken yapısı gibi zorlukları da beraberinde getirmektedir (Jiang & Subramanian, 2019). Bu zorluklara rağmen, sektörle verilerin dahil edilmesinin faydalari açıkta. Karşılaştırmalı analizler, asimetrik modellerin çeşitli sektörler için zaman serisi modellerine göre üstün performans gösterdiğini ve sektörle verilerin tahmin doğruluğunu önemli ölçüde artırabileceğini göstermektedir (Salisu vd., 2019).

Bu çalışma, EKGYO hisse senedi fiyatlarının tahmin edilmesinde sektörle verilerin ve gelişmiş makine öğrenimi modellerinin entegrasyonunu araştırmayı amaçlamaktadır. Çalışmada aşağıdaki hipotezler test edilecektir:

H1: Sektörel veriler ve makroekonomik göstergeler kullanılarak, gayrimenkul sektörü fiyatları makine öğrenimi modelleri ile tahmin edilebilir.

H2: Kalman Filtresi modeli, EKGYO hisse senedi fiyatlarını tahmin etmede Neural Prophet ve ETS (Hata, Trend, Mevsimsellik) modellerine kıyasla daha yüksek doğruluk sağlamaktadır.

Çalışma kapsamında, USD/TRY kuru, konut fiyat endeksi ve Yİ-ÜFE gibi ekonomik göstergeler ile EKGYO hisse senedi fiyatları arasındaki ilişkiler inceleneciktir. Bu ilişkilerin anlaşılması, ilgili ekonomik verilerin tahmin modellerine dahil edilmesine yardımcı olacak ve tahmin güçlerini artıracaktır.

Nihai amaç, yatırımcılara ve finansal analistlere bilinçli kararlar vermelerinde yardımcı olmak üzere doğru EKGYO hisse senedi fiyat tahminleri sağlamaktır. Çalışma, hisse senedi fiyat tahmin stratejilerinin geliştirilmesine katkı sağlamayı ve yatırım karar verme süreçlerini iyileştirmeyi amaçlamaktadır.

2. Literatür

Gayrimenkul sektörü, ekonomik büyümeye ve finansal piyasalardaki dalgalanmalarla olan yakın ilişkisi nedeniyle akademik araştırmalarda önemli bir yer tutmaktadır. Gayrimenkul hisse senetleri, sektördeki gelişmelerden doğrudan etkilendigidinden yatırımcılar ve analistler tarafından yakından takip edilmektedir. Bu bağlamda, gayrimenkul hisse senedi fiyatlarının tahmin edilmesinde sektörel verilerin ve makine öğrenimi modellerinin etkin bir şekilde kullanılması, doğru ve güvenilir tahminler yapılabilmesi açısından büyük önem taşımaktadır.

Mevcut literatür, çeşitli makine öğrenimi modellerinin ve sektörel verilerin entegrasyonunun tahmin doğruluğunu önemli ölçüde artırduğunu göstermektedir. Sektörel verilerin hisse senedi fiyatları üzerindeki etkisini inceleyen çalışmalar, özellikle menkul kıymetleştirilmiş piyasalarda gayrimenkul getirilerinin sektörde özgü veriler kullanılarak tahmin edilebileceğini ortaya koymaktadır. Örneğin, Hoesli ve Oikarinen (2012), Gayrimenkul hisse getirilerinin diğer varlık sınıflarına kıyasla benzersiz bir öngörülebilirlik sergilediğini ve bunun temel nedeninin gayrimenkul hisse senetlerinin sektörel ekonomik koşullara olan duyarlılığı olduğunu vurgulamaktadır.

Sektörel verilerin önemini gösteren bir diğer çalışma, Gurav vd. (2018) tarafından gerçekleştirılmıştır. Bu araştırma, enflasyon, faiz oranları ve döviz kurları gibi makroekonomik değişkenlerin gayrimenkul hisse senedi getirileri üzerindeki etkisini incelemekte ve bu göstergelerin hisse senedi performansını önemli ölçüde etkilediğini göstermektedir. Çalışma, sektörde özgü ekonomik değişkenlerin tahmin gücünün altını çizmektedir.

Döviz kurlarının gayrimenkul hisse senedi fiyatları üzerindeki etkisine odaklanan Parisiana vd. (2022), özellikle USD/TRY döviz kurunun gayrimenkul hisse senedi fiyatlarını etkilemede kritik bir rol oynadığını belirtmektedir. Bu çalışma, döviz kurlarındaki dalgalanmaların gayrimenkul hisse senedi performansını önemli ölçüde etkilediğini göstererek, sektörel ekonomik koşulların gayrimenkul sektöründeki hisse senedi hareketlerini tahmin etmek için gerekli olduğuna dair kanıt sunmaktadır.

Makine öğrenimi modelleri, gayrimenkul sektöründeki hisse senedi fiyat tahminlerinin doğruluğunu artırmada önemli bir potansiyel göstermiştir. Hansun vd. (2022), LQ45 gayrimenkul sektöründeki hisse senedi fiyatlarını tahmin etmek için Çift Yönlü Uzun Kısa Süreli Bellek (Bi-LSTM) ağını uygulayarak, hisse senedi verilerindeki karmaşık zamansal kalıpları yakalamış ve yüksek doğruluk elde etmiştir. Çalışma, makine öğrenimi tekniklerinin finansal verilerdeki karmaşık ilişkileri modellemede etkili olduğunu göstermektedir.

Benzer şekilde, Zhang vd. (2023), GYO hisse senedi getirilerini tahmin etmek için Grup Veri İşleme Yöntemi (GMDH) sinir ağı modelini kullanarak, sektörel veriler üzerinde eğitildiğinde modelin yüksek tahmin doğruluğu sağladığını göstermektedir. Bu bulgular, gayrimenkul sektöründe finansal tahmin için makine öğrenimi tekniklerine artan güveni desteklemektedir.

Liu ve Xu (2023) ise gayrimenkul şirketlerinin hisse senedi fiyat tahminini geliştirmek için faktör analizini Geri Yayılma (BP) sinir ağı ile entegre ederek, sektörde özgü faktörlerin tahmin performansını artırmada başarılı bir şekilde kullanılabileceğini vurgulamaktadır. Çalışma, makine öğrenimi modellerinin sektörel verilerle desteklendiğinde daha yüksek doğruluk sunabileceğini ortaya koymaktadır.

Ekonometrik ve zaman serisi yaklaşımları gibi geleneksel tahmin modelleri de hisse senedi ve varlık fiyatlarını tahmin etmek için uzun süredir gayrimenkul piyasalarına uygulanmaktadır. Brooks ve Tsolacos

(2001), gayrimenkul getirilerini tahmin etmek için finansal spread ve zaman serisi tekniklerinin kullanımını incelemiş ve bu yöntemlerin gayrimenkul hisse senedi fiyatlarını tahmin etmek için genişletilebileceği sonucuna varmıştır. Bu çalışma, geleneksel tahmin modellerinin gayrimenkul hisse senedi tahmininde makine öğrenimi yöntemlerini tamamlayabileceği fikrini desteklemektedir.

İçinde, Tsolacos vd. (2013), ticari kiraları tahmin etmek için öncü ekonomik göstergeleri kullanarak, makroekonomik faktörlerin her iki piyasayı da etkilediği konusundaki benzerlik göz önüne alındığında, bu göstergelerin gayrimenkul hisse senedi fiyatlarını tahmin etmek için uygulanabileceğini öne sürmektedir. Bu çalışma, makroekonomik göstergelerin hisse senedi fiyat tahmin modellerine dahil edilmesinin faydasını vurgulamaktadır.

Bazı çalışmalar, gayrimenkul hisse senedi tahmininin daha geniş bağlamına ilişkin ek bilgiler sunmaktadır. Ooi ve Liow (2004), gelişmekte olan piyasalardaki gayrimenkul hisse senetlerinin riske göre ayarlanmış performansını analiz ederek, hisse senedi getirilerinin temel belirleyicilerini tespit etmiş ve sektörde özgü verilerin bu piyasalardaki hisse senedi fiyat değişimlerini açıklamada önemli bir rol oynadığını göstermiştir.

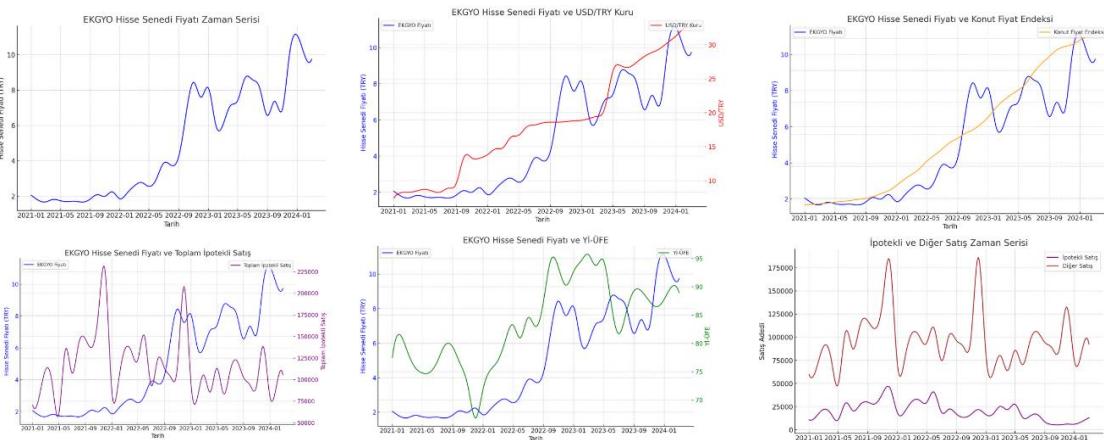
Wolski (2018), gayrimenkul şirketlerinin hisse senedi getirileri ile ikincil konut piyasası fiyatları arasındaki ilişkiye araştırarak, gayrimenkul hisse senedi performansının daha geniş piyasa eğilimleri için bir öngörücü olarak hizmet etme potansiyelini ortaya koymuştur. Bu çalışma, gayrimenkul hisse senetlerinin genel piyasa hareketlerini yansıtabileceğini ve tahmin modellerinde dikkate alınması gerektiğini göstermektedir.

İçinde, Fan ve Chen (2022), yatırımcı duyarlılık endekslerini hisse senedi fiyat tahmin modellerine dahil ederek, duyarlılık verilerinin gayrimenkul hisse senedi fiyat hareketleri üzerindeki etkisini vurgulamıştır. Bu çalışma, sosyal medya ve diğer duyarlılık kaynaklarından elde edilen verilerin, hisse senedi fiyat tahminlerinde kullanılmasının potansiyel faydalarını ortaya koymaktadır.

Sektörel veriler ve makine öğrenimi modellerinin entegrasyonu ile GYO hisse senedi fiyatlarını tahmin etmeye yönelik literatür, çeşitlenmeye ve genişlemektedir. Araştırmalar, enflasyon, döviz kurları ve Gayri Safi Yurt İçi Hasila (GSYİH) gibi makroekonomik göstergelerin, gayrimenkul hisse senedi fiyatlarının öngörülebilirliğini artırdığını göstermektedir. Özellikle sınır ağları ve derin öğrenme modelleri gibi makine öğrenimi teknikleri, hisse senedi fiyat tahmininde gelişmiş yetenekler sunarken, geleneksel tahmin modelleri de değerli bilgiler sağlamaktadır. Bu çalışmalar, sektörde verilerin makine öğrenimi teknikleriyle bireleştirilmesinin gayrimenkul hisse senedi fiyat tahminlerinde faydalı olabileceğini göstermektedir.

3. Keşifsel Veri Analizi

Bu bölümde, Emlak Konut Gayrimenkul Yatırım Ortaklısı (EKGYO) hisse senedi fiyatları ile çeşitli ekonomik göstergelere ait zaman serisi verileri keşifsel olarak analiz edilmektedir. İncelenen ekonomik göstergeler arasında toplam ipotekli satışlar, diğer satışlar, USD/TRY döviz kuru, konut fiyat endeksi ve yurt içi üretici fiyat endeksi (Yİ-ÜFE) bulunmaktadır.



Şekil 1. Veri Seti İkili Grafikleri

Şekil 1'de görüldüğü üzere, toplam ipotekli satışlar zaman serisi belirgin zirve ve dip noktaları ile döngüsel bir yapı sergilemektedir. Özellikle 2022 ortası ve 2023 ortasında önemli zirveler gözlemlenmekte olup, bu dönemler artan ipotekli satış faaliyetlerine işaret etmektedir.

İpotekli satışlar ile diğer satışlar karşılaştırıldığında, her iki serinin de benzer döngüsel yapılar sergilediği ancak diğer satışların genliğinin çok daha yüksek olduğu görülmektedir. İki seri arasındaki korelasyon, her iki satış türünü etkileyen ortak faktörlere işaret etmektedir.

EKGYO hisse senedi fiyatı ile USD/TRY döviz kuru arasındaki ilişki incelendiğinde, özellikle 2022 ortasından itibaren her iki seride de belirgin bir pozitif trend gözlemlenmektedir. Döviz kurundaki zirvelerin genellikle hisse senedi fiyatındaki zirvelerle örtüşlüğü dikkat çekmektedir.

EKGYO hisse senedi fiyatı ile konut fiyat endeksi arasındaki ilişki de güçlü bir yukarı yönlü trend sergilemektedir. Konut fiyat endeksi zaman içinde istikrarlı bir şekilde artarken, EKGYO hisse senedi fiyatı daha fazla dalgalanma göstermekte ve belirgin zirve ve dip noktalarına sahip bulunmaktadır. Bu iki seri arasında uzun dönemli bir korelasyona işaret etmektedir.

EKGYO hisse senedi fiyatı ile yurt içi üretici fiyat endeksi (Yİ-ÜFE) karşılaştırıldığında, her iki seride de belirgin zirve ve dip noktaları ile genel bir yukarı yönlü trend gözlemlenmektedir. Yİ-ÜFE'deki zirve noktalarının, EKGYO hisse senedi fiyatında daha ani değişikliklere neden olduğu görülmektedir. Bu durum, üretici fiyatlarının EKGYO hisse senedinin değerlemesinde önemli bir faktör olabileceğini göstermektedir.

EKGYO hisse senedi fiyatı ile toplam ipotekli satışlar karşılaştırıldığında, her iki serinin de döngüsel yapılar sergilediği ve hisse senedi fiyatında daha belirgin bir yukarı yönlü trendin olduğu gözlenmektedir. İpotekli satışlardaki zirve noktalarının hisse senedi fiyatlarına göre belirgin bir gecikme göstermesi, ipotekli satışlardaki değişimlerin hisse senedi fiyatlarındaki değişimlerden önce geldiğini düşündürmektedir. Bu ilişki, ipotekli satışların EKGYO hisse senedi fiyat hareketlerini öngormek için öncü bir gösterge olabileceğini göstermektedir.

EKGYO hisse senedi fiyatının zaman serisi tek başına incelendiğinde, 2021 başından 2024'e kadar belirgin bir büyümeye eğilimi gözlemlenmekte olup, hızlı artış ve kısa süreli düşüş dönemleri bulunmaktadır. 2021 sonundan 2023 sonuna kadar genel bir artış trendi görülmektedir.

USD/TRY döviz kuru zaman serisi, 2021'den 2024'e kadar güçlü bir yukarı yönlü trend sergilemeye ve küçük dalgalanmalar içermektedir. Özellikle 2021 sonu ve 2022larında önemli artışlar gözlemlenmekte olup, bu durum döviz kurunu etkileyen ekonomik olayları yansıtmaktadır.

Konut fiyat endeksi zaman serisi, 2021'den 2024'e kadar sürekli bir artış trendi göstermekte olup, konut fiyatlarındaki sürekli büyümeyi yansımaktadır. Önemli düşüşler gözlenmemektedir, bu da konut piyasası fiyatlarındaki istikrarlı artışı göstermektedir.

Son olarak, yurt içi üretici fiyat endeksi (Yİ-ÜFE) zaman serisi, belirgin zirve ve dip noktaları ile genel bir yukarı yönlü trend sergilemektedir. Özellikle 2021 sonu ve 2023 başında yüksek enflasyon dönemlerine işaret eden önemli zirve noktaları bulunmaktadır.

4. Metodoloji

Bu çalışmada, EKGYO hisse senedi fiyatlarının tahmin edilmesi amacıyla Neural Prophet, Kalman Filtresi ve ETS modeli olmak üzere üç farklı makine öğrenimi modeli kullanılmıştır. Çalışmada kullanılan veri seti, 2021/01 ile 2024/01 tarihleri arası kapsamaktadır ve veri kaynakları Tablo 1'de özetlenmiştir:

Tablo 1. Veri Seti ve Kaynakları

Veri	Kaynak
EKGYO Stock Price	investing.com
USD/TRY	investing.com
Konut Fiyat Endeksi (KFE)	TÜİK
Yİ-ÜFE	TÜİK
Toplam İpotekli Satış	TÜİK
Adet İpotekli Satış	TÜİK
İpotekli Satış (%)	TÜİK
Adet Diğer Satış	TÜİK

Diğer Satış (%)	TÜİK
Adet İlk El Satış	TÜİK
İlk El Satış (%)	TÜİK
Adet İkinci El Satış	TÜİK
İkinci El Satış (%)	TÜİK

4.1. Öznitelik Mühendisliği

Öznitelik mühendisliği, mevcut verilerden yeni öznitelikler oluşturmayı içerir ve bu sayede tahmine dayalı öğrenme performansını artırmayı hedeflemektedir (Khurana vd., 2018). Ham verilerden en uygun girdi değişkenlerini çıkartarak model karmaşaklığını azaltmaka ve basit, doğru ve sağlam modellerin oluşturulmasına katkı sağlamaktadır (Ustundag vd., 2022). Ayrıca, boyut indirgeme temelli etkileşimli öznitelik mühendisliği şemaları, modelin yorumlanabilirliğini artırarak tahmin yeteneğinin geliştirilmesine yardımcı olmaktadır (Gkorou vd., 2020). Ancak, öznitelik mühendisliği insan yoğun bir süreç olup, alan bilgisi ve sezgi gerektirmektedir. Bu süreç, deneme yanılma ve önemli ölçüde insan dikkatini içermektedir (Khurana vd., 2018).

Bu çalışmada, veri setine yıl, ay ve çeyrek bilgileri eklenmiştir. Bu öznitelikler, zaman serisi verilerinin mevsimsel ve dönemsel etkilerini yakalamak için kullanılmaktadır. Hareketli ortalama, verinin kısa vadeli dalgalanmalarını düzleştirmek genel trendi yakalamaya yardımcı olduğu için, EKGYO hisse senedi fiyatının üç aylık hareketli ortalaması hesaplanmıştır. Ayrıca, EKGYO hisse senedi fiyatı, USD/TRY kuru, konut fiyat endeksi ve YıL-ÜFE için yüzdelik değişimler hesaplanmıştır. Yüzde değişim öznitelikleri, değişkenler arasındaki göreceli değişimleri ve ilişkileri modele dahil etmek amacıyla kullanılmaktadır.

4.2. Modelleme Süreci

Çalışmada, EKGYO hisse senedi fiyatlarının tahmin edilmesinde kullanılacak yöntemlerin seçiminde, literatürdeki başarılı tahminleri ve finansal zaman serilerindeki uygulamaları göz önünde bulundurulmuştur. Bu bağlamda, Neural Prophet, Kalman Filtresi ve ETS modelleri tercih edilmiştir.

Neural Prophet modeli, sinir ağı prensiplerine dayalı olarak otomatik fark alma, trend ve mevsimselliği dikkate alma ve dış değişkenlerin entegrasyonu gibi özelliklere sahiptir. Bu özellikler, tahmin doğruluğunu artırmak amacıyla kullanılmaktadır (Noviandy vd., 2023). Özellikle hisse senedi fiyatları gibi karmaşık ve değişken finansal verilerin kısa vadeli tahminlerinde başarılı sonuçlar elde edilmiştir (Prakhar vd., 2022). Modelin otomatik parametre ayarlama özelliği ve mevsimsel etkileri modelleyebilme kabiliyeti, tahmin performansını artırmaktadır (Du Toit vd., 2024).

Tablo 2. Neural Prophet Modeli Hiperparametreleri

Parametre	Kullanılan Değer
yearly_seasonality	True
seasonality_mode	additive
n_changepoints	15
seasonality_reg	0.1
trend_reg	0.1
learning_rate	0.01
epochs (model.fit())	100, 500

Neural Prophet modelinde, yıllık mevsimsellik desenlerini dikkate almak için yearly_seasonality parametresi True olarak ayarlanmıştır. Bu ayar, yıllık döngülerin modellenmesini sağlayarak tahminlerin doğruluğunu artırmaktadır. Mevsimselligin modele eklenmesi için seasonality_mode parametresi ise 'additive' olarak seçilmiştir (Triebe vd., 2021).

Trenddeki olası değişim noktalarının sayısını belirlemek için n_changepoints parametresi 15 olarak belirlenmiştir. Daha fazla değişim noktası, trenddeki ani değişimleri daha iyi yakalamayı sağlamakla ancak aşırı uyum riskini artırıbmaktadır. Mevsimsel ve trend bileşenleri için düzenleme parametreleri olan seasonality_reg ve trend_reg değerleri 0.1 olarak seçilmiştir. Bu parametreler, aşırı öğrenmeyi engelleyerek modelin genelleme yeteneğini iyileştirmektedir (Triebe vd., 2021).

Modelin öğrenme hızını belirleyen learning_rate parametresi 0.01 olarak ayarlanmıştır. Küçük bir öğrenme hızı, daha kararlı bir yakınsama sağlamasına rağmen eğitim süresini uzatabilmektedir. Eğitim sürecinde, modelin veri seti üzerinde öğrenme denemesisayısını belirten epochs parametresi 100 ve 500 olarak kullanılmıştır. Daha fazla epoch sayısı, modelin veriye daha iyi uyum sağlamasına yardımcı olabilir ancak aşırı öğrenme riskini artırabilmektedir (Tribe v.d., 2021).

Kalman Filtresi, özellikle doğrusal sistemler için yaygın olarak kullanılan bir yinelemeli durum tahmin edicisidir (Lefebvre v.d., 2004). Bu model, tahmin ve ölçüm olarak iki yinelemeli işlem aracılığıyla çalışmaktadır. Bu süreç, gelen verilere dayalı olarak sürekli tahminlerin rafine edilmesini sağlamaktadır (Hun v.d., 2016). Hisse senedi fiyatlarının dinamik ve oynak doğası göz önüne alındığında, Kalman Filtresi'nin durum uzayı modellemesi ve gürültü yönetimi yetenekleri nedeniyle tercih edilmiştir. ABD ve Çin hisse senedi piyasaları üzerinde yapılan bir çalışmada, genişletilmiş Kalman Filtresi'nin trend ve döngü bileşenlerini etkili bir şekilde ayırtıldığı ve tahmin performansını artırdığı gösterilmiştir (Alp v.d., 2023). Ayrıca, Kalman Filtresi'nin volatiliteyi yakalayarak hisse senedi fiyatlarında daha doğru tahminler sağladığını belirtmektedir (Ntemi & Kotropoulos, 2018).

Tablo 3. Kalman Filtresi Hiperparametreleri

Parametre	Kullanılan Değer
initial_state_mean	0
n_dim_obs	1

Kalman Filtresi modelinde, gizli durumun başlangıçtaki ortalama tahmini olan initial_state_mean parametresi 0 olarak belirlenmiştir. Ön bilgi olmadığı durumlarda bu değer genellikle 0 olarak ayarlanmaktadır. Gözlem vektörünün boyutunu belirten n_dim_obs parametresi ise 1 olarak seçilmiştir; çünkü bu çalışmada tek bir değişken olan hisse senedi fiyatını gözlemlenmektedir (Balatsko, 2012).

ETS modeli olarak da bilinen yöntem, üstel düzeltme prensiplerini durum uzayı modellemesi ile bireleştirerek doğru tahminler oluşturmaktadır (Prapcoyo & As'ad, 2022). Model, zaman serisi verilerinde trend, mevsimsellik ve hata bileşenlerini tahmin etmek için üstel düzeltme yöntemlerini kullanmaktadır (Hyndman v.d., 2002). ETS model bileşenlerinin özellik tabanlı seçimi ile tahmin doğruluğunun artırılabileceği gösterilmiştir (Qi v.d., 2023). Hisse senedi fiyat tahmininde, ETS modelinin diğer istatistiksel yöntemlerle karşılaştırıldığında etkin bir performans sergilediği ve hibrit modellerle birleştirildiğinde doğruluğun daha da artırılabilenliği belirtilmektedir (Alostath v.d., 2022). ETS modelinin otomatik tahmin yapabilme kabiliyeti ve büyük ölçekli zaman serilerinde hesaplama etkinliği sağlaması, bu çalışmada kullanımını destekleyen faktörlerdir. Bu nedenle, veri seti ETS modeline uygun şekilde düzenlenmiştir. Eğitim verisi kullanılarak model eğitilmiş ve test verisi üzerinde tahminler yapılmıştır.

Tablo 4. ETS Modeli Hiperparametreleri

Parametre	Kullanılan Değer
error	add
trend	add
seasonal	add
seasonal_periods	12

ETS modelinde, hata teriminin error parametresi 'add' olarak seçilerek modele eklenmiştir. Trend ve mevsimsel bileşenlerin türlerini ifade eden trend ve seasonal parametreleri de 'add' olarak belirlenmiştir. Mevsimsel döngünün periyot sayısını belirten seasonal_periods parametresi 12 olarak seçilmiştir. Bu değer, verideki aylık mevsimselliliği temsil etmektedir (Perktold v.d., 2024).

Veri seti, %80 eğitim ve %20 test olmak üzere ikiye ayrılmıştır. Eğitim verisi kullanılarak modeller eğitilmiş ve test verisi üzerinde tahminler yapılmıştır. Modellerin performansı, Ortalama Mutlak Hata (MAE), Ortalama Kare Hata (MSE) ve Kök Ortalama Kare Hata (RMSE) metrikleri ile değerlendirilmiştir.

4.3. Sonuçlar

Neural Prophet, zaman serisi tahminlerini özellikle uzun dönem bağımlı diziler ve periyodik veriler için geliştirmek amacıyla tasarlanmış bir derin öğrenme modelidir. Prophet modeli ile yapılan karşılaştırmalar, Neural Prophet'in MAE, MAPE ve MASE gibi performans göstergelerinde %70 iyileşme sağladığını göstermektedir. Bu iyileşme, Neural Prophet modelinin derin öğrenme bileşenlerine bağlanmaktadır (Chérif vd., 2023). Facebook Prophet'in derin öğrenme modelleri ile geliştirilmiş versiyonu olarak konumlandırılan Neural Prophet ile karmaşık zaman serisi tahminleri için klasik yöntemler ile sinir ağ modelleri arasındaki boşluğu doldurmak amaçlanmıştır (Wang & Gu, 2023).

Neural Prophet modeli, zaman serisi tahminlerinde mevsimsellik ve trend bileşenlerini dikkate alarak tahmin yapmaktadır. Ancak, bu çalışmada Neural Prophet modelinin performansı diğer iki modelle karşılaştırıldığında daha yüksek hata oranları göstermiştir. Bu sonuç, modelin daha karmaşık veri yapıları veya daha uzun dönemli verilerde daha iyi performans gösterebileceğine işaret edebilir.

Kalman Filtresi, uzay aracı navigasyonu, robotikte hareket planlaması, sinyal işleme ve kablosuz sensör ağları gibi çeşitli uygulamalarda kullanılan bir durum tahmin tekniğidir (Pei vd., 2019). Bu teknik, sürecin altında yatan makul bir durum uzayı modeline ve onun gürültü bileşenlerine dayalı olarak doğrusal sistemin durumunu tahmin etmeyi amaçlamaktır ve bir veya daha fazla sensörden elde edilen kusurlu (gürültülü) ölçümlerle çalışmaktadır (Lloyd, 2014). Bu yaklaşım, modelden gelen tahminleri düzelterek yeni sensör verileri kullanıdıkça sürecin mevcut durumunun güncel tahminlerini sağlayan bir tahmin-düzeltilci algoritma oluşturur. Kalman Filtresi, gürültülü verilerden yararlı bilgiler çıkarma kabiliyeti sayesinde, modeller ve ölçümler stokastik ve durağan olmadığına özellikle pratiktir (Pei vd., 2019; Lloyd, 2014).

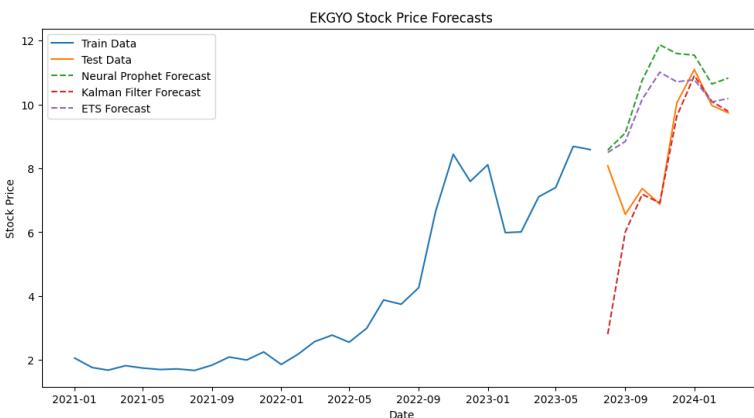
ETS modeli, Hata, Trend ve Mevsimsellik (Error, Trend, Seasonal) bileşenlerine odaklanan bir zaman serisi tahmin yöntemidir (Biswas vd., 2017; Zheng, 2023). Model, zaman serisi verilerinde trend ve mevsimsellik bileşenlerine odaklanmakta ve tek değişkenli tahmin yöntemleri kullanmaktadır (Jofipasi vd., 2018). ETS modelleri, verilerin hazırlanması ve veri deposuna yüklenmesi süreçlerine odaklanarak, yalnızca zaman serisi verilerini analiz etmeye odaklanan geleneksel zaman serisi modellerinden farklılık göstermektedir. Geleneksel zaman serisi modelleri, veri hazırlama ve yükleme sürecine belirgin bir vurgu yapmadan daha çok istatistiksel analiz ve tahmin üzerinde yoğunlaşabilmektedir (Oh & Seong, 2024).

Tablo 5. Model Performansları

Model	Set	MAE	MSE	RMSE
Neural Prophet	Test	1,899	5,927	2,4345
Neural Prophet	Eğitim	0,3529	0,1852	0,4304
Kalman Filter	Test	0,8539	3,5486	1,8838
Kalman Filter	Eğitim	0,0696	0,012	0,1094
ETS	Test	1,3978	3,8834	1,9706
ETS	Eğitim	0,4649	0,3471	0,5892

Tablo 5, farklı modelleme tekniklerinin (Neural Prophet, Kalman Filtresi ve ETS) performansını karşılaştırmaktadır. Neural Prophet modeli, eğitim veri seti üzerinde oldukça düşük hata değerleri ile iyi bir uyum sağlamasına rağmen, test veri setinde performansının önemli ölçüde düşüğü görülmektedir. Kalman Filtresi modeli ise, hem eğitim hem de test veri setlerinde daha tutarlı ve düşük hata değerleri ile istikrarlı bir performans sergilemektedir. ETS modeli, her iki veri setinde de orta düzeyde hata değerleri göstermeye olup, Kalman Filtresi modeline kıyasla daha yüksek hata paylarına sahiptir. Bu sonuçlar, Kalman Filtresi modelinin veri setindeki değişkenlikleri daha iyi yakaladığını ve bu modeller arasında genelleştirme yeteneğinin en güçlü olduğunu ortaya koymaktadır.

ETS modeli, hata, trend ve mevsimsel bileşenleri dikkate alarak tahmin yapmaktadır. Performans metrikleri, ETS modelinin Kalman Filtresi'ne yakın bir doğruluk sunduğunu göstermektedir. Ancak, Kalman Filtresi ile karşılaştırıldığında biraz daha yüksek hata oranlarına sahiptir.



Şekil 2. Model Tahminlerini Görselleştirilmesi

Şekil 2'de, eğitim verisi (Train Data), test verisi (Test Data) ve üç farklı modelin tahminleri (Neural Prophet Forecast, Kalman Filtresi Forecast, ETS Forecast) gösterilmektedir. Mavi çizgi, 2021-01-01 ile 2023-05-01 tarihleri arasındaki EKGYO hisse senedi fiyatlarını temsil etmektedir. Bu dönemde hisse senedi fiyatlarında genel bir artış trendi gözlemlenmektedir.

Test verisi, model tahminlerinin doğruluğunu değerlendirmek için kullanılmaktadır. Yeşil kesikli çizgi, Neural Prophet modelinin tahminlerini göstermektedir. Bu model, test verisi ile karşılaştırıldığında daha yüksek tahmin değerleri üretmiş ve performansı diğer modellere göre daha düşük olmuştur.

Kalman Filtresi, test verisi ile en uyumlu tahminleri yapmış ve en düşük hata oranlarını elde etmiştir. ETS modeli, test verisine yakın tahminler üretmiş ancak Kalman Filtresi ile karşılaştırıldığında daha yüksek hata oranlarına sahip olmuştur.

Genel olarak, Kalman Filtresi modelinin en iyi performansı gösterdiği ve EKGYO hisse senedi fiyatlarının tahmininde en doğru sonuçları verdiği gözlemlenmiştir. Neural Prophet modeli, daha yüksek hata oranları ile diğer modellere göre daha düşük performans sergilemiştir. ETS modeli ise, hata oranları bakımından Kalman Filtresi'ne yakın bir performans göstermiş ancak biraz daha yüksek hata oranlarına sahiptir.

5. Tartışma ve Sonuç

Bu çalışmada, Emlak Konut Gayrimenkul Yatırım OrtaklıĞının (EKGYO) hisse senedi fiyatlarını tahmin etmek amacıyla sektörel veriler ile Neural Prophet, Kalman Filtresi ve ETS (Hata, Trend, Mevsimsellik) modellerini içeren gelişmiş makine öğrenimi teknikleri kullanılmıştır. Analizde USD/TRY kuru, konut fiyat endeksi, yurt içi üretici fiyat endeksi (Yİ-ÜFE) ve ipotekli konut satışları gibi ekonomik göstergeler entegre edilerek, EKGYO hisse senedi fiyatları ile olan ilişkileri incelenmiştir.

Elde edilen bulgular, sektörel verilerin hisse senedi fiyat tahmin modellerine dahil edilmesinin faydalı olduğunu göstermektedir. Ampirik sonuçlar, en düşük MAE, MSE ve RMSE değerlerine sahip olan Kalman Filtresi modelinin, finansal verilerdeki gürültüyü etkili bir şekilde yöneterek en yüksek tahmin doğruluğunu sergilediğini ortaya koymaktadır. ETS modeli, Kalman Filtresi'ne kıyasla biraz daha yüksek hata oranlarına sahip olsa da tatmin edici bir performans göstermiştir. Buna karşılık, Neural Prophet modeli, mevsimsellik ve trendleri yakalama yeteneğine rağmen, karmaşık finansal veri setleri veya kısa vadeli tahminlerde daha yüksek hata oranlarıyla potansiyel sınırlamalar sergilemiştir.

EKGYO hisse senedi fiyatları ile ekonomik göstergeler arasında gözlemlenen güçlü ilişkiler, geniş ekonomik koşulların gayrimenkul sektörünün finansal performansı üzerindeki etkisini vurgulamaktadır. Özellikle, hisse senedi fiyatları ile USD/TRY kuru ve konut fiyat endeksi gibi göstergeler arasında tespit edilen pozitif eğilimler, (Gurav vd., 2018; Parisiana vd., 2022) bulgularına paralel olarak sektörün makroekonomik dalgalandırmalarla olan duyarlılığını göstermektedir. Döviz kuru ve konut fiyatlarındaki değişimlerin gayrimenkul hisse senedi getirilerinde önemli belirleyiciler olduğu görülmektedir.

Sektörel verilerin tahmin doğruluğunu artırmadaki etkinliğine rağmen, bu yaklaşımın doğasında bulunan zorluklar da göz önünde bulundurulmalıdır. Finansal piyasaların karmaşıklığı ve oynaklılığı, tahmin

performansını korumak ve iyileştirmek için modellerin sürekli geliştirilmesini ve daha sofistik özelliklerin eklenmesini gerektirir (Jiang & Subramanian, 2019). Özellikle finansal piyasaların dinamik yapısı, modellerin esnek ve uyumlu olmasını zorunlu kılmaktadır.

Bu araştırmanın sonuçları, yatırım karar verme ve finansal analiz alanlarında potansiyel uygulamalara sahiptir. Çalışma, doğru hisse senedi fiyat tahminleri sağlayarak yatırımcılar ve analistler için değerli bilgiler sunmakta ve daha bilinçli ve stratejik finansal kararlar alınmasına katkı sağlamaktadır. Makine öğrenimi modellerinin sektörel verilerle entegrasyonu, sadece tahmin doğruluğunu artırmakla kalmayıp, aynı zamanda gayrimenkul piyasaları ile daha geniş ekonomik göstergeler arasındaki dinamik etkileşimin anlaşılmasını da derinleştirmektedir (McMillan, 2021; Bounid vd., 2022).

Gelecekteki araştırmalar, tahmin doğruluğunu daha da artırmak için ek sektörel ve makroekonomik değişkenlerin dahil edilmesini değerlendirebilir. Gerçek zamanlı verilerin ve yüksek frekanslı işlem göstergelerinin entegrasyonu, hisse senedi fiyat hareketlerine ilişkin daha hızlı ve dinamik içgörüler sağlayabilir (Fan & Chen, 2022). Ayrıca, Uzun Kısa Süreli Bellek (LSTM) ağları ve Transformer mimarileri gibi gelişmiş derin öğrenme tekniklerinin uygulanması, daha karmaşık zamansal bağımlılıkları yakalayarak tahmin performansını artırabilir (Liu & Xu, 2023). Modelin sağlamlığını ve genelleştirilebilirliğini sağlamak amacıyla farklı zaman dilimleri ve piyasa koşulları altında çapraz doğrulama yapılması da faydalı olacaktır. Düzenleyici değişiklikler ve politika müdahalelerinin hisse senedi fiyatları üzerindeki etkisinin araştırılması, gayrimenkul piyasasını etkileyen faktörlerin daha kapsamlı anlaşılmamasına katkı sağlayabilir (Ooi & Liow, 2004).

6. Extended Abstract

The real estate sector, influenced by macroeconomic fundamentals, is critical in the broader stock market. This study uses sectoral data and advanced machine learning models to predict the stock prices of Real Estate Investment Trust (EKGYO). Understanding the intricate relationships between EKGYO stock prices and various economic indicators is essential for accurate predictions and informed investment decisions. The study integrates multiple economic indicators to elucidate their impact on EKGYO's financial performance, thus addressing the broader challenge of enhancing stock price prediction accuracy through sectoral data integration.

The primary objective of this study is to predict EKGYO's stock prices by leveraging sectoral data and advanced machine learning models, specifically Neural Prophet, Kalman Filter, and ETS (Error, Trend, Seasonal) models. The study aims to identify the most effective model for stock price prediction and to understand the relationships between EKGYO stock prices and various economic indicators such as USD/TRY exchange rate, housing price index, domestic producer price index (D-PPI), and mortgage sales.

The study utilizes three machine learning models: Neural Prophet, Kalman Filter, and ETS. Data collection includes EKGYO stock prices, USD/TRY exchange rate, housing price index, D-PPI, and mortgage sales, covering the period from January 2021 to January 2024. The data is sourced from reliable financial and statistical databases.

1. Feature Engineering: This involves creating new features from existing data to improve model performance. Features such as year, month, quarter, lagged values of stock prices, moving averages, and percentage changes in economic indicators are engineered to capture temporal dependencies and trends in the data.

2. Data Splitting: The data is split into 80% training and 20% testing datasets to evaluate the models' performance.

3. Model Training and Evaluation: Each model is trained on the training dataset and evaluated on the test dataset using performance metrics such as Mean Absolute Error (MAE), Mean Square Error (MSE), and Root Mean Square Error (RMSE).

The empirical results highlight significant findings regarding the performance of the models:

1. Kalman Filter Model: This model exhibited the highest forecasting accuracy with the lowest MAE, MSE, and RMSE values. Its superior ability to manage noise in financial data and provide accurate forecasts was evident.

2. ETS Model: The ETS model also performed well, showing slightly higher error metrics than the Kalman Filter. It effectively captured trend and seasonality components, contributing to accurate predictions.

3. Neural Prophet Model: Despite its advanced design for capturing seasonality and trends, it showed higher error rates. This indicates potential limitations when applied to complex financial datasets or short-term forecasting scenarios.

Data was collected from multiple sources, including investing.com and the Turkish Statistical Institute (TÜİK). The indicators included EKGYO stock prices, USD/TRY exchange rate, housing price index, D-PPI, and various mortgage sales metrics. This comprehensive data collection provided a robust foundation for the analysis.

The study's findings underscore the critical importance of integrating sectoral data into stock price prediction models. The Kalman Filter model's superior performance highlights its effectiveness in managing financial data noise. The ETS model's ability to capture trends and seasonality further supports the integration of economic indicators in prediction models. Conversely, the Neural Prophet model's higher error rates suggest additional complexity or data refinement for accurate predictions.

The strong correlations between EKGYO stock prices and economic indicators, particularly the USD/TRY exchange rate and housing price index, emphasize the sector's sensitivity to macroeconomic fluctuations. These relationships are vital for developing accurate stock price prediction strategies and enhancing investment decision-making processes.

This study demonstrates the effectiveness of sectoral data integration and advanced machine learning models in predicting EKGYO stock prices. The Kalman Filter model proved the most accurate, while the ETS model showed promising results. The findings highlight the importance of feature engineering and comprehensive data analysis in improving model performance. The study contributes to developing better stock price prediction strategies, providing valuable insights for investors and financial analysts.

Future research could include additional sectoral and macroeconomic variables, real-time data integration, and the application of advanced deep learning techniques such as Long Short-Term Memory (LSTM) networks and Transformer models. These approaches could enhance prediction accuracy and provide deeper insights into the dynamic interactions between real estate markets and broader economic indicators.

Çıkar Çatışması Beyanı / Conflict of Interest

Çalışmada herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır.
There is no conflict of interest with any institution or person in the study.

İntihal Politikası Beyanı / Plagiarism Policy

Bu makale İntihal programlarında taranmış ve İntihal tespit edilmemiştir.
This article was scanned in Plagiarism programs and Plagiarism was not detected.

Bilimsel Araştırma ve Yayın Etiği Beyanı / Scientific Research and Publication Ethics Statement

Bu çalışmada Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi kapsamında belirtilen kurallara uyulmuştur.

In this study, the rules specified within the scope of the Higher Education Institutions Scientific Research and Publication Ethics Directive were followed.

Kaynakça

- Alostath, M. H., Alsaber, A. R., & Setiya, P. (2022). Different statistical methods for predicting NASDAQ 100 using univariate time series approaches. *International Journal of Agricultural & Statistical Sciences*, 18(2), 507.
- Alp, S. Ö., Ozbek, L., & Canbaloglu, (2023). An Analysis Of Stock Market Prices By Using Extended Kalman Filter. The US and China cases. *Investment Analysts Journal*. 52. 1-16. doi:10.1080/10293523.2023.2179160.
- Aşık, B. (2023). Testing the asymmetric relationship between CPI, PPI, and exchange rates: An application of the ARDL and NARDL methods. *Pressacademia*.
- Agustina, I. A., & Permadi, I. (2023). The impact of the money supply, exchange rate and fuel prices on the inflation rate. *Ekonomin: Journal of Economics and Business*.
- Akopyan, D. (2023). Trends in the development of the domestic labor market. *Экономика и предпринимательство*, 9(146), 156-159. doi:https://doi.org/10.34925/EIP.2022.146.9.027.
- Balatsko, M. (2012). Kalman Filter, Smoother, and EM Algorithm for Python. *Github*.
- Baroni, M., Barthélémy, F., & Mokrane, M. (2009). Forecasting Real Estate Prices From a PCA Repeat Sales Index. *ERES*.
- Biswas, N., Chattpadhyay, S., Chatterjee, S., & Mondal, K. C. (2017). Sysml Based Conceptual ETL Process Modeling. *Communications In Computer And Information Science*, 776, 242-255. doi:10.1007/978-981-10-6430-2_19
- Bounid, O., Lamrini, S., & Charif, H. (2022). Enhancing stock price prediction accuracy using advanced data preprocessing methods and machine learning techniques. *Journal of Financial Data Science*, 4(2), 125–140.
- Bounid, S., Oughanem, M., & Bourkadi, S. N. (2022). Advanced Financial Data Processing And Labeling Methods For Machine Learning. *International Conference On Intelligent Systems And Computer Vision*. doi:10.1109/ISCV54655.2022.9806060
- Brooks, C., & Tsolacos, S. (2001). Forecasting real estate returns using financial spreads. *Journal of Property Research*, 18(3), 235–248. doi:doi.org/10.1080/09599910110060037
- Chérif, H., Snoun, H., Bellakhal, G., & Kanfoudi, H. (2023). Forecasting Of Ozone Concentrations Using The Neural Prophet Model: Application To The Tunisian Case. *Euro-Mediterranean Journal For Environmental Integration*, 8(4), 987–998. doi:Https://Doi.Org/10.1007/S41207-023-00414-X
- Conover, C. M., Farizo, J. D., Friday, H. S., & North, D. S. (2024). The Diversification Benefits Of Foreign Real Estate: Evidence From 40 Years Of Data. *Journal Of Risk And Financial Management*, 17(4), 160. doi:Https://Doi.Org/10.3390/Jrfm17040160
- Du Toit, A., Baadel, S., & Harguem, S. (2024). Predicting tesla: Stock market forecasting using facebook's prophet. *2024 IEEE International Conference on Artificial Intelligence and Mechatronics Systems (AIMS)*, 1-6. https://doi.org/10.1109/AIMS61812.2024.10513215
- Fan, X., & Chen, J. (2022). Stock Price Forecasting in Real Estate Industry Based on Investor Sentiment. *Frontiers in Business, Economics and Management*, 6(3), 54–59. doi:https://doi.org/10.54097/FBEM.V6I3.3311
- Gkorou, D., Larrañaga, M., Ypma, A., Hasibi, F., & Wijk, R. (2020). Get A Human-In-The-Loop: Feature Engineering Via Interactive Visualizations.
- Gurav, P., Verma, R. K., & Vijayvergia, S. (2018). Real Estate- The Sector with A Pool of Opportunities. *International Journal of Management Studies*, 4(3), 106. doi:https://doi.org/10.18843/ijms/v5i4(3)/14
- Hansun, S., Suryadibrata, A., & Sandi, D. R. (2022). Deep learning approach in predicting property and real estate indices. *International Journal of Advances in Soft Computing and its Applications*, 14(1).
- Hoesli, M., & Oikarinen, E. (2012). Are REITs real estate? Evidence from international sector level data. *Journal of International Money and Finance*, 31(7), 1823–1850. doi:https://doi.org/10.1016/j.jimfin.2012.05.017
- Hun, L. C., Yeng, O. L., Sze, L. T., & Koo, V. C. (2016). Kalman Filtering And Its Real-Time Applications. doi:Https://Doi.Org/10.5772/62352

- Hyndman, R. J., Koehler, A. B., Snyder, R. D., & Grose, S. D. (2002). A State Space Framework For Automatic Forecasting Using Exponential Smoothing Methods. *International Journal Of Forecasting*, 18(3), 439–454. doi:[Https://Doi.Org/10.1016/S0169-2070\(01\)00110-8](https://doi.org/10.1016/S0169-2070(01)00110-8)
- Jiang, L. C., & Subramanian, P. (2019). Forecasting Of Stock Price Using Autoregressive Integrated Moving Average Model. *Journal Of Computational And Theoretical Nanoscience*, 16(8). doi:[Https://Doi.Org/10.1166/Jctn.2019.8317](https://doi.org/10.1166/jctn.2019.8317)
- Jofipasi, C. A., Miftahuddin, & Hizir. (2018). Selection For The Best ETS (Error, Trend, Seasonal) Model To Forecast Weather In The Aceh Besar District. *IOP Conference Series: Materials Science And Engineering*, 352(1), 012055. doi:[Https://Doi.Org/10.1088/1757-899X/352/1/012055](https://doi.org/10.1088/1757-899X/352/1/012055)
- Khan, K., Su, C., Tao, R., & Chu, C. C. (2018). Is there any relationship between producer price index and consumer price index in the Czech Republic? . *Economic Research-Ekonomska Istraživanja*, 31(1), 1788–1806.
- Khurana, U., Samulowitz, H., & Turaga, D. (2018). Feature Engineering For Predictive Modeling Using Reinforcement Learning. *Proceedings Of The AAAI Conference On Artificial Intelligence*, 32(1), 3407–3414. doi:[Https://Doi.Org/10.1109/ICDMW.2016.0190](https://doi.org/10.1109/ICDMW.2016.0190)
- Khurana, U., Turaga, S. D., Samulowitz, H., & Parthasarathy, S. (2016). Cognito: Automated Feature Engineering For Supervised Learning. doi:[Https://Doi.Org/10.1609/AAAI.V32I1.11678](https://doi.org/10.1609/AAAI.V32I1.11678)
- Kocaoglu, D., Turgut, K., & Konyar, M. Z. (2022). Sector-Based Stock Price Prediction with Machine Learning Models. *Sakarya University Journal of Computer and Information Sciences*, 5(3), 415–426. doi:[Https://doi.org/10.35377/SAUCIS...1200151](https://doi.org/10.35377/SAUCIS...1200151)
- Kundieieva, H., & Martyniuk, L. (2021). Features of functioning and development trends of the domestic market of sausage products. *Theoretical and Applied Issues of Economics*, 42(2), 55–64.
- Lee, C. L., Stevenson, S., & Lee, M. L. (2018). Low-Frequency Volatility Of Real Estate Securities And Macroeconomic Risk. *Accounting And Finance*, 58, 311–342. doi:[Https://Doi.Org/10.1111/Acfi.12288](https://doi.org/10.1111/Acfi.12288)
- Lee, S., Lee, B., & Chiang, K. (2018). Macroeconomic risk influences on the low-frequency volatility of real estate securities. *Journal of Property Investment & Finance*, 36(1), 12–25.
- Lefebvre, T., Bruyninckx, H., & Schutter, J. D. (2004). Kalman Filters For Non-Linear Systems: A Comparison Of Performance. *International Journal Of Control*, 77(7), 639–653. doi:[Https://Doi.Org/10.1080/00207170410001704998](https://doi.org/10.1080/00207170410001704998)
- Liu, B., & Xu, C. (2023). Research on Stock Price Prediction of BP Neural Network Based on Factor Analysis. *Academic Journal of Business & Management*, 5(10), 140–145. doi:[Https://doi.org/10.25236/AJBM.2023.051021](https://doi.org/10.25236/AJBM.2023.051021)
- Lloyd, G. M., & Scientist, S. (2014). A Kalman Filter Framework For High-Dimensional Sensor Fusion Using Stochastic Non-Linear Networks. *ASME International Mechanical Engineering Congress And Exposition, Proceedings*. doi:[Https://Doi.Org/10.1115/IMECE2014-37834](https://doi.org/10.1115/IMECE2014-37834)
- Mcmillan, D. G. (2021). Forecasting Sector Stock Market Returns. *Journal Of Asset Management*, 22(4), 291–300. doi:[Https://Doi.Org/10.1057/S41260-021-00220-6](https://doi.org/10.1057/S41260-021-00220-6)
- Ntemi, M., Kotropoulos, C.. (2018). Prediction Methods for Time Evolving Dyadic Processes. 2588-2592. [10.23919/EUSIPCO.2018.8553475](https://doi.org/10.23919/EUSIPCO.2018.8553475).
- Noviandy, T. R., Maulana, A., Idroes, G. M., Suhendra, R., Adam, M., Rusyana, A., & Sofyan, H. (2023). Deep Learning-Based Bitcoin Price Forecasting Using Neural Prophet. *Ekonomikalia Journal Of Economics*, 1(1), 19–25. doi:[Https://Doi.Org/10.60084/Eje.V1i1.51](https://doi.org/10.60084/Eje.V1i1.51)
- Oh, J., & Seong, B. (2024). Forecasting With A Combined Model Of ETS And ARIMA. *Communications For Statistical Applications And Methods*, 31(1), 143–154. doi:[Https://Doi.Org/10.29220/CSAM.2024.31.1.143](https://doi.org/10.29220/CSAM.2024.31.1.143)
- Ooi, J. T., & Liow, K. H. (2004). Risk-Adjusted Performance of Real Estate Stocks: Evidence From Developing Markets. *Journal of Real Estate Research*, 26(4), 371–396. doi:[Https://ideas.repec.org/a/jre/issued/v26n42004p371-396.html](https://ideas.repec.org/a/jre/issued/v26n42004p371-396.html)
- Parisiana, M. A., Kamaliah, K., & Rasuli, M. (2022). Factors affecting the property and real estate sector stock return. *Jurnal Manajemen Dan Bisnis*, 11(2), 235–250. doi:[Https://doi.org/10.34006/jmbi.v11i2.459](https://doi.org/10.34006/jmbi.v11i2.459)

- Pei, Y., Biswas, S., Fussell, D. S., & Pingali, K. (2019). An Elementary Introduction To Kalman Filtering. *Communications Of The ACM*, 62(11), 122–133. doi:Https://Doi.Org/10.1145/3363294
- Perktold, J., Seabold, S., & Sheppard, K. (2024). Statsmodels.Zenodo. doi.org/10.5281/ZENODO.10984387
- Prapcoyo, H., & As'ad, M. (2022). The Forecasting Of Monthly Inflation In Yogyakarta City Uses An Exponential Smoothing-State Space Model. *International Journal Of Economics Business And Accounting Research (Ijebar)*, 6(2), 800. doi:Https://Doi.Org/10.29040/Ijebar.V6i2.4853
- Qi, L., Li, X., Wang, Q., & Jia, S. (2023). fETSmcs: Feature-based ETS model component selection. *International Journal of Forecasting*, 39(3), 1303–1317
- Ravikumar, A. (2017). Real Estate Price Prediction Using Machine Learning. doi:https://api.semanticscholar.org/CorpusID:57409779
- Sahay, A., & Amudha, J. (2020). Integration Of Prophet Model And Convolution Neural Network On Wikipedia Trend Data. *Journal Of Computational And Theoretical Nanoscience*, 17(1), 260–266. doi:Https://Doi.Org/10.1166/Jctn.2020.8660
- Salisu, A. A., Raheem, I. D., & Ndako, U. B. (2019). A Sectoral Analysis Of Asymmetric Nexus Between Oil Price And Stock Returns. *International Review Of Economics And Finance*, 61, 241–259. doi:Https://Doi.Org/10.1016/J.Iref.2019.02.005
- Shabbir, M., Said, L. R., Pelit, I., & Irmak, E. (2023). The dynamic relationship among domestic stock returns volatility, oil prices, exchange rate and macroeconomic factors of investment. *International Journal of Energy Economics and Policy*, 13(1), 85–92.
- Shakeel, A., Chong, D., & Wang, J. (2023). Load Forecasting Of District Heating System Based On Improved FB-Prophet Model. *Energy*, 278, 127637. doi:Https://Doi.Org/10.1016/J.Energy.2023.127637
- Shin, E., Kim, E., & Hong, T. (2022). The prediction of real estate price based on deep learning using news sentiment and expert knowledge. *The Journal of Internet Electronic Commerce Resarch*, 22(3), 61–73. doi:https://doi.org/10.37272/JIECR.2022.06.22.3.61
- Singh, H., Sahani, S., Maddhesiya, T., Prajapati, S. P., & Yadav, S. K. (2023). Stock Market Predictor Web Application. *International Journal for Research in Applied Science and Engineering Technology*, 11(5), 832–836. doi:https://doi.org/10.22214/ijraset.2023.51607
- Sofyani, N. W., & Wahyudi, S. (2016). Analisis Pengaruh Variabel Makro Ekonomi Global Dan Makro Ekonomi Domestik Terhadap Indeks Harga Saham Sektor Properti Dan Real Estate Dengan Metode GARCH (Periode Januari 2004-Desember 2014). *Diponegoro Journal of Management*, 286–299.
- Su, C. W., Yin, X. C., Chang, H. L., & Zhou, H. G. (2019). re The Stock And Real Estate Markets Integrated In China? *Journal Of Economic Interaction And Coordination*, 14(4), 741–760. doi:Https://Doi.Org/10.1007/S11403-018-0215-X
- Tang, H., Xie, K., & Xu, X. E. (2022). Real Estate As A New Equity Market Sector: Market Responses And Return Comovement. *Real Estate Economics*, 50(2), 431–467. doi:Https://Doi.Org/10.1111/1540-6229.12314
- Tribe, O., Hewamalage, H., Pilyugina, P., Laptev, N., Bergmeir, C., & Rajagopal, R. (2021). NeuralProphet: Explainable forecasting at scale. doi:https://arxiv.org/abs/2111.15397.
- Tsolacos, S., Brooks, C., & Nnejí, O. (2013). On the Predictive Content of Leading Indicators: The Case of U.S. Real Estate Markets. *SSRN Electronic Journal*. doi:https://doi.org/10.2139/SSRN.2233085
- Ustundag, A., Sivri, M., & Mengüç, K. (2022). Feature Engineering. *Business Analytics for Professionals*, 153–169. doi:Https://Doi.Org/10.1007/978-3-030-93823-9_6
- Usupbeyli, A., & Uçak, S. (2020). The effects of exchange rates on CPI and PPI. *Business and Economics Research Journal*, 11(2), 323–334.
- Wang, Z., & Gu, X. (2023). A Time Series Prediction Algorithm Based On Bilstm And Prophet Hybrid Model. *2023 4th International Conference On Computer Engineering And Application, ICCEA 2023*, 128–132. doi:Https://Doi.Org/10.1109/ICCEA58433.2023.10135221
- Wolski, R. (2018). Listing Of Developer Companies As A Predictor Of The Situation On The Residential Real Estate Market. *Real Estate Management And Valuation*, 26(4), 12–21. doi:Https://Doi.Org/10.2478/Remav-2018-0032

- Yılmaz, Y. (2022). Causality relationship between stock prices, exchange rate and house price index. *Akademik Yaklaşımlar Dergisi*, 13(1), 45–58.
- Yang, G., Yin, X., Sun, Z., Bi, P., & Ma, Q. (2024). The Spillover Effect Of Real Estate Boom On Stock Market Efficiency: Evidence From China. *Applied Economics*. doi:[Https://Doi.Org/10.1080/00036846.2024.2336884](https://doi.org/10.1080/00036846.2024.2336884)
- Yang, X., Li, Z., & Wu, C. (2024). The impact of local real estate prices on investor sentiment and stock mispricing. *Finance Research Letters*, 48.
- Zhang, W., Li, B., Liew, A. C., Roca, E., & Singh, T. (2023). Predicting the returns of the US real estate investment trust market: evidence from the group method of data handling neural network. *Financial Innovation*, 9(1), 1–33. doi:<https://doi.org/10.1186/S40854-023-00486-2/TABLES/10>
- Zheng, Q. (2023). ETL Based Data Integration Scheduling. *Proceedings Of SPIE - The International Society For Optical Engineering*, 12509. doi:[Https://Doi.Org/10.1117/12.2655919](https://doi.org/10.1117/12.2655919)