

Yıl: 2025

Cilt: 7

Sayı: 2

Sayfa: 213-237

Makale Geliş Tarihi: 31.05.2025

Makale Kabul Tarihi: 03.08.2025

Makale Yayın Tarihi: 30.08.2025

Doi: 10.38009/ekimad.1710303

Araştırma Makalesi

Finansal Karar Süreçlerinde Makine Öğrenimi Tabanlı Tahmin ve Strateji Geliştirme Yaklaşımları

Mahmut Emin Çevik*

Bengü Vuran**

Öz

Finansal piyasaların doğasında bulunan belirsizlik nedeniyle, yalnızca sezgilere dayalı yatırım kararları önemli riskler taşımaktadır. Bu nedenle, bu çalışma, makine öğrenimi tabanlı tahmin tekniklerinin yatırım karar süreçlerine nasıl entegre edilebileceğini araştırmayı amaçlamaktadır. Random Forest, XGBoost ve LSTM modellerini içeren karşılaştırmalı analizimizde, Random Forest modeli, yaklaşık 24 endeks puanlık ortalama mutlak hata (MAE) ile daha düşük tahmin hatası ve daha tutarlı sinyallerle öne çıkmıştır. Bu sinyaller yatırım stratejilerine dönüştürüldüğünde, yalnızca tahmin doğruluğunda değil, aynı zamanda %95,51 toplam getiri ve 8,06 Sharpe oranı gibi risk-ayarlı getirilerde de anlamlı iyileşmeler gözlenmiştir. Ancak, bu bulguların çalışmada kullanılan veri seti ve modelleme seçimlerine özgü olduğu ve farklı piyasa koşullarında veya veri rejimlerinde sonuçların değişebileceği vurgulanmalıdır.

Anahtar Kelimeler: Finansal zaman serisi, Makine öğrenimi, Random Forest, XGBoost, LSTM, Teknik analiz, Alım-satım stratejisi, Geriye dönük test, Sharpe oranı

JEL Sınıflandırması: C45, C53, C63, G11, G17

* Doktora Öğrencisi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Finans Anabilim Dalı, mahmutemincevik@gmail.com ORCID NO: 0000-0003-4247-7459

** Prof. Dr., İstanbul Üniversitesi, İşletme Fakültesi, İşletme Bölümü, benguv@istanbul.edu.tr ORCID NO: 0000-0002-2428-1543

Atıf: Çevik, M. E. & Vuran, B. (2025). Finansal Karar Süreçlerinde Makine Öğrenimi Tabanlı Tahmin ve Strateji Geliştirme Yaklaşımları. *Ekonomi İşletme ve Maliye Araştırmaları Dergisi*, 7(2),213-237



Forecasting and Strategy Design in Financial Decision-Making Using Machine Learning**Abstract**

Owing to the inherent uncertainty of financial markets, investment decisions based solely on intuition involve substantial risk. Accordingly, this study investigates the integration of machine learning-based forecasting techniques into investment decision-making processes. In the comparative analysis conducted with Random Forest, XGBoost, and LSTM models, the Random Forest model demonstrated superior performance, yielding a lower mean absolute error (MAE) of approximately 24 index points and generating more consistent predictive signals. When these signals were translated into trading strategies, the model exhibited substantial improvements not only in predictive accuracy but also in risk-adjusted performance, achieving a total return of 95.51% and a Sharpe ratio of 8.06. Nevertheless, it should be noted that these findings are contingent upon the specific dataset and modeling configurations employed, and may vary across different market environments and data regimes.

Keywords: Financial time series, Machine learning, Random Forest, XGBoost, LSTM, Technical analysis, Trading strategy, Backtesting, Sharpe ratio

JEL Classification: C45, C53, C63, G11, G17

1. Giriş

Yatırımcılar ve portföy yöneticileri için finansal piyasalardaki gelecekteki fiyat hareketlerinin tahmini önemli bir hedeftir. Varlıklardaki dalgalanmaların doğru tahmin edilmesi, yatırımlardaki karar süreçlerini hızlandırarak risk yönetimini iyileştirir ve finansal getiri potansiyelini artırır. Ancak finansal zaman serilerinin genellikle gürültülü ve karmaşık bir yapıya sahip olması bu tür serilerde rastgele yürüyüş davranışını ortaya çıkarmakta ve bu durum gelecekteki hareketleri tahmin etmeyi de oldukça zorlaştırmaktadır (Fama, 1995). Geleneksel zaman serisi modelleri (ARIMA ve GARCH gibi) bazı varsayımlarla iyi sonuçlar verse de, verideki doğrusal olmayan ilişkileri ve ani değişimleri yakalayamaz. Bu durumda, makine öğrenmesi ve derin öğrenme teknikleri güçlü seçeneklerdir; çünkü bu yöntemler, verideki karmaşık yapıları ve gizli düzenleri bularak finansal kestirim doğruluğunu artırabilir.

Makine öğrenimi ve derin öğrenme teknikleri, bu eksikleri giderebilecek esnek ve veri odaklı yapılarıyla finansal analiz literatüründe alternatif çözümler olarak öne çıkmıştır. 1990'lı yıllardan itibaren LeBaron (1992), Tay ve Cao (2001) gibi öncü çalışmalar yapay sinir ağları, bulanık mantık sistemleri gibi yöntemlerle finansal zaman serilerindeki doğrusal olmayan yapıyı analiz etmeye başlamıştır. Bu dönemi takip eden araştırmalar, topluluk öğrenmesi (ensemble learning) yöntemlerinin (örneğin Random Forest, Boosting) finansal tahmin performansını anlamlı biçimde artırdığını ortaya koymuştur (Breiman, 2001; Chen ve Guestrin, 2016). Derin öğrenme mimarilerinden LSTM gibi modellerin ise ardışık veri setlerindeki uzun vadeli bağımlılıkları öğrenmedeki başarısı, finansal piyasa tahmininde önemli bir paradigma değişimini beraberinde getirmiştir (Fischer ve Krauss, 2018; Bao vd., 2017).

Bu bağlamda, literatürde üç temel boşluk dikkat çekmektedir:

- (i) Makine öğrenimi tabanlı modellerin çoğu yalnızca tahmin doğruluğuna odaklanmakta, model çıktılarının yatırım stratejisine dönüştürülmesi ihmal edilmektedir;
- (ii) Makine öğrenimi modellerinin finansal piyasalardaki ani rejim değişimlerine (örneğin, ekonomik krizler, jeopolitik olaylar veya pandemi gibi şoklar) karşı dayanıklılığı yeterince incelenmemiştir. Bu çalışma, S&P 500 endeksi üzerinde 2018-2023 dönemini kapsayan, pandemi çöküşü ve toparlanma gibi farklı piyasa rejimlerini içeren bir veri seti kullanarak modellerin bu tür koşullardaki performansını değerlendirmeyi hedeflemektedir;
- (iii) Farklı algoritmaların karşılaştırmalı performans analizine dayanan çalışmalar sınırlıdır; özellikle aynı veri seti üzerinde sistematik kıyaslamalar nadirdir.

Bu çalışma, yukarıda belirtilen literatür boşluklarını hedef alarak, finansal zaman serilerinin tahminine yönelik Random Forest (RF), XGBoost ve LSTM gibi güncel makine öğrenimi algoritmalarını hem tahmin doğruluğu hem de yatırım stratejisi çıktıları açısından sistematik olarak karşılaştırmaktadır. Daha önceki çalışmalar çoğunlukla yalnızca tek bir modele odaklanırken, bu çalışmada üç farklı model aynı veri seti (S&P 500 endeksine ait 2018–2023 dönemi fiyat ve makroekonomik göstergeleri) üzerinde karşılaştırmalı olarak test edilmiştir. Yatırım stratejileri, 2022-2023 döneminde, pandemi sonrası toparlanma ve piyasa oynaklığı gibi çeşitli koşulları kapsayan bir zaman diliminde geriye dönük test edilmiştir. Bu stratejiler, portföy yöneticilerinin alım-satım kararlarını optimize etmelerine olanak tanıyarak, risk-ayarlı getirileri artıran veri odaklı karar destek sistemleri sunmayı amaçlamaktadır. Bu kapsamda, her bir modelin hangi piyasa koşullarında daha başarılı tahmin performansı sunduğu değerlendirilmiş, elde edilen sınıflandırma sonuçları yatırım stratejisine dönüştürülerek finansal performans ölçütleri (Sharpe oranı, getiri, maksimum gerileme) ile analiz edilmiştir. Böylece bu çalışma, hem finansal öngörü literatürüne metodolojik katkı sunmakta hem de portföy yönetimi ve risk optimizasyonu için pratik içgörüler sağlamayı hedeflemektedir.

2. Literatür İncelemesi

Makine öğrenimi tekniklerinin finansal piyasalarda kullanımı, 1990'lı yıllardan itibaren istatistiksel modelleme ve yapay zekâ disiplinlerindeki gelişmelerle birlikte önemli bir ivme kazanmıştır. LeBaron (1992) yapay sinir ağlarının finansal zaman serilerindeki doğrusal olmayan yapıyı modellemede geleneksel ekonometrik modellere alternatif sunduğunu göstermiştir. Ancak, bu erken dönem çalışması, sınırlı veri setleri ve hesaplama gücü nedeniyle yalnızca küçük ölçekli piyasalarda (örneğin, tek bir hisse senedi) test edilmiştir, bu da genellenebilirliği kısıtlamıştır. Tay ve Cao (2001) bulanık mantık sistemleriyle finansal tahminlerdeki doğrusal olmayan ilişkileri ele almış, ancak modelin yorumlanabilirlik eksikliği ve hiperparametre optimizasyonuna olan bağımlılığı sınırlılık olarak öne çıkmıştır. Bu erken dönem araştırmalar, finansal serilerin doğrusal olmayan ve yüksek volatilité içeren doğasının, geleneksel modellerin sunduğu yapısal varsayımların ötesine geçen esnek yaklaşımlar gerektirdiğini göstermiştir.

2000'li yılların ortasından itibaren, ensemble learning (topluluk öğrenmesi) yaklaşımlarının finansal uygulamalara entegrasyonu ile RF ve Boosting algoritmaları literatürde daha geniş yer bulmuştur. Bu modeller, hem regresyon hem de sınıflandırma problemleri için yüksek genelleme yetenekleri ve düşük overfitting riski gibi avantajlarıyla öne çıkmıştır (Breiman, 2001; Chen ve Guestrin, 2016). 2010 sonrası dönemde ise Fischer ve Krauss (2018) ile Bao vd. (2017) gibi çalışmalar, Uzun Kısa Vadeli Bellek (LSTM) ve diğer derin öğrenme mimarilerinin finansal fiyat tahmini ve yön kestirimi gibi görevlerde başarılı biçimde uygulanabildiğini ortaya koymuştur. Bu gelişmeler, klasik teorik çerçeveden veri odaklı ve esnek modellere yönelen evrimsel bir dönüşümü temsil etmektedir.

RF, hem regresyon hem de sınıflandırma problemlerinde sergilediği güçlü performansla öne çıkmakta; özellikle finansal zaman serilerindeki doğrusal olmayan ilişkileri ortaya koymadaki yetkinliğiyle geniş bir kullanım alanı bulmaktadır (Omar vd., 2022). Örneğin Abdullah ve diğerleri (2022), geleneksel modellerden ARIMA ile karşılaştırıldığında, otoregresif RF modelinin özellikle piyasalarda yüksek oynaklığın gözlemlendiği dönemlerde hisse senedi endeks tahmininde daha başarılı sonuçlar verdiğini ortaya koymuştur. RF, aynı anda birçok özelliği işleyebilmesi ve aşırı öğrenmeye karşı görece dayanıklı yapısıyla, finansal verilerdeki gürültüye rağmen güvenilir tahminler sunabilmektedir. Patel vd. (2015) RF'yi Hindistan hisse senedi piyasalarında fiyat tahmini için kullanmış, ancak yalnızca teknik göstergelere odaklanması, makroekonomik faktörlerin etkisini göz ardı etmiştir.

XGBoost (Extreme Gradient Boosting), Chen ve Guestrin (2016) tarafından geliştirilen ve geleneksel gradient boosting yaklaşımının yapısal veriler üzerindeki performansını optimize etmeyi amaçlayan güçlü bir makine öğrenimi algoritmasıdır. Özellikle yüksek boyutlu ve düzenli veri setlerinde

sağladığı doğruluk oranıyla ve işlem hızı ve paralel hesaplama yetenekleriyle, kısa zamanda uygulamalarda yaygınlık kazanmıştır. Vuong P.H., vd. (2022) XGBoost'u yüksek frekanslı forex verilerinde test etmiş, ancak modelin kısa vadeli tahminlere odaklanması, uzun vadeli trendleri yakalamada yetersiz kalmıştır. Finansal zaman serilerinde yapılan çok sayıda çalışmada, XGBoost'un hem fiyat hem de yön tahmininde istikrarlı ve yüksek doğrulukta çıktılar sunduğu raporlanmıştır. Nitekim, teknik analiz göstergeleri ile temel finansal verilerin birlikte kullanıldığı modelleme çerçevelerinde, bu algoritmanın hisse senedi fiyatlarını tahmin etme performansı, klasik yöntemlerin ötesine geçebilmektedir (Gumelar vd., 2022). Bu yönüyle XGBoost, veri odaklı karar destek sistemlerinin finansal piyasalara entegrasyonunda kritik bir araç olarak değerlendirilmektedir.

Tekrarlayan sinir ağlarının (RNN) bir türevi olan LSTM (Long Short-Term Memory) modelleri, örneğin pandemi sürecinde ani piyasa değişimlerine verdiği tepkiyle kısa vadeli belirsizlikleri yorumlama başarısı dikkat çekmiştir. Bu mimari, klasik RNN'lerin uzun vadeli bağımlılıkları öğrenmedeki zorluklarının üstesinden gelmek için geliştirilmiştir. Fang vd. (2023) derin öğrenme modellerinin ani piyasa rejim değişimlerinde (örneğin, pandemi çöküşü) kararsız performans gösterebileceğini belirtmiştir, bu da bu tür modellerin pratik uygulanabilirliğini sorgulatmaktadır. LSTM modelleri, finansal zaman serilerindeki veriler arasındaki karmaşık desenleri ve ardışık ilişkileri yakalama yetenekleri nedeniyle artık yaygın olarak tercih edilmektedir. Son yıllarda yürütülen çeşitli çalışmalar, bu modelin hisse senedi getirilerinin yönünü tahmin etmede etkili sonuçlar verdiğini göstermiştir. Örneğin, Fischer ve Krauss (2018), S&P 500 endeksinde LSTM'yi kullanarak yüksek tahmin doğruluğu elde etmiş, ancak çalışmanın ~20.000 gözlem içeren geniş veri setine dayalı olması, daha küçük veri setlerinde (örneğin, 5 yıllık dönemler) modelin performansını sınırlamaktadır. Benzer şekilde, Bao vd. (2017), LSTM'yi Çin hisse senedi piyasalarında test etmiş, ancak yalnızca fiyat verilerine odaklanması, modelin makroekonomik değişkenlere duyarlılığını kısıtlamıştır. Ancak, bu modelin başarısı doğrudan birkaç faktöre bağlıdır: kullanılan veri kümesinin boyutu, ağ mimarisi ve hiperparametrelerin doğru ayarlanması, model performansında önemli bir rol oynar. Özellikle sınırlı veriye sahip çalışmalarda, model aşırı uyum sağlama eğiliminde olduğundan ve gerçek dünya piyasa koşulları için genelleştirilebilir tahminler yapamadığından, sıklıkla sorunlar ortaya çıkar.

Son yıllarda yapılan araştırmalar, finansal piyasa tahminlerinde makine öğrenimi yöntemlerinin başarımını artırmak adına hem yeni algoritmaların geliştirilmesi hem de hibrit modellemelerin yaygınlaştığını ortaya koymaktadır. Bu çerçevede, özellikle 2022–2025 döneminde yapılan güncel çalışmalar, farklı algoritmaların farklı veri tipleri ve piyasa koşulları altında nasıl performans gösterdiğini detaylı şekilde incelemiştir. Bazı çalışmalar, LSTM ve RF modellerini birlikte kullanarak her iki yöntemin avantajlarını birleştirmeye çalışmaktadır. Vuong H.N., vd. (2022) LSTM tarafından öğrenilen özelliklerin XGBoost veya RF gibi modellere aktarılmasının daha yüksek tahmin doğruluğu ile sonuçlandığı bildirilmiştir. Wang vd. (2024) çalışmasında CSI 300 endeksi için teknik göstergeler ve makroekonomik verileri kullanarak LSTM-CNN tabanlı bir hibrit model geliştirilmiş, %76 gibi yüksek yön tahmini doğruluğu elde edilmiştir. Ancak, bu modelin işlem stratejisine dönüşmemesi önemli bir sınırlılık olarak değerlendirilmektedir. Benzer şekilde, Zhang ve Yu (2023), ABD S&P 500 endeksinde Transformer tabanlı dikkat mekanizması içeren bir LSTM mimarisi uygulamış, özellikle ani piyasa hareketlerini öngörmeye başarı elde etmişlerdir; ancak model sadece büyük ölçekli ve likit piyasalarla sınırlı kalmıştır. Ouf vd. (2024) tarafından geliştirilen bir diğer çalışmada, Apple, Google ve Tesla hisseleri ile Twitter'dan elde edilen duygu skorları birleştirilerek XGBoost ve LSTM modelleri karşılaştırılmış; XGBoost daha düşük hata oranlarıyla öne çıkarken, çalışmanın yalnızca üç hisseyle sınırlı olması genellebilirliğini azaltmıştır. Uzunmwanho (2024), Microsoft hissesi için 23 yıllık (2000–2023) bir veri seti kullanarak teknik göstergelerden elde edilen özelliklerle LSTM ve XGBoost modellerini yön tahmini amacıyla karşılaştırmıştır. XGBoost %71 doğruluk oranına ulaşırken LSTM %62 ile daha düşük başarı göstermiştir. Ancak çalışmada yalnızca yön tahmini yapılmış, finansal getiri, risk gibi performans göstergelerine yer verilmemiştir. Rathi vd.

(2024), 7 farklı varlık (6 fon ve 1 kripto para) üzerinde RF algoritmasıyla volatilité tahmini yapmış, fakat portföy oluşturma veya alım-satım stratejisi boyutuna geçmemiştir. Ayrıca veri kümesi sınırlı sayıda varlıkla sınırlandırılmıştır ve makroekonomik faktörler dahil edilmemiştir. Qian (2024) tarafından yürütölen karşılaştırmalı çalışmada, S&P 500 ve CSI 300 endeksleri teknik analiz göstergeleri ile modellenmiş; LSTM'nin Çin piyasasında daha iyi, RF'nin ise ABD verilerinde daha tutarlı performans gösterdiği belirtilmiştir. Bu çalışma, model performanslarının veri setinin yapısına bağılı olduğunu ortaya koymakla birlikte, herhangi bir yatırım stratejisi veya portföy performansı değerlendirilmemiştir. Jang ve Lee (2024), Kore KOSPI endeksinde RF ve LightGBM modellerini karşılaştırarak, LightGBM'nin düşük işlem süresiyle özellikle kısa vadeli öngörülerde avantaj sağladığını göstermiştir. Gupta vd. (2025) ise Hindistan borsasında duyarlılık verilerini teknik analiz göstergeleri ile birleştirerek LSTM ve GRU modellerini kıyaslamış; GRU'nun daha düşük aşırı öğrenme eğilimiyle öne çıktığını belirtmiştir. Ancak bu çalışmaların çoğunda tahmin başarısı yalnızca sınıflandırma metrikleriyle değerlendirilmiş, finansal getiri, Sharpe oranı veya Max Drawdown gibi yatırım performans metrikleri göz ardı edilmiştir.

Türkiye özelinde yapılan çalışmalar da benzer sınırlılıklar taşımaktadır. Kılıç ve Yılmaz (2023), Borsa İstanbul endeksleri üzerinde RF ve XGBoost algoritmalarını kullanarak haftalık yön tahmini gerçekleştirmiş, XGBoost modelinin %81 doğrulukla başarılı sonuçlar verdiğini bildirmiştir. Alkan vd. (2025) ise BIST100 şirketlerinde RSI, MACD ve CCI gibi teknik göstergelerle XGBoost modelini kullanarak pozisyon bazlı sinyal üretimi sağlamış, ancak risk-getiri optimizasyonu yapmamıştır.

Buna ek olarak, teknik analiz göstergelerinin finansal tahmin modellerinde girdi verisi olarak kullanımı yaygın olup; Williams %R, RSI, MACD ve hareketli ortalamalar gibi göstergeler ayı piyasası sinyallerini tespit etmede etkili parametrelerdir. Bu göstergeleri özellik olarak kullanan RF veya benzeri algoritmalar, trend tahmininde başarılı olduklarını kanıtlamıştır (Zheng vd., 2024).

Literatürdeki bu çalışmalar, makine öğrenimi ve derin öğrenme tekniklerinin finansal tahminlerdeki potansiyelini ortaya koymuş, ancak bazı sınırlılıklar barındırmaktadır. İlk olarak, çoğu çalışma yalnızca tek bir algoritmaya odaklanmakta ve farklı model sınıflarının karşılaştırmalı performansını sistematik olarak analiz etmemektedir. İkinci olarak, ani rejim değişimlerine karşı model dayanıklılığı yeterince incelenmemiştir; bu, özellikle ekonomik krizler veya jeopolitik olaylar gibi volatil dönemlerde kritik bir eksikliktir. Üçüncü olarak, model çıktılarının yatırım stratejilerine dönüştürölmesi ve finansal bağlamda değerlendirilmesi genellikle ihmal edilmektedir.

Tablo 1: Literatür Karşılaştırma Tablosu

<i>Çalışma</i>	<i>Algoritma</i>	<i>Veri Seti</i>	<i>Uygulama Alanı</i>	<i>Sınırlılıklar</i>
<i>LeBaron (1992)</i>	Yapay Sinir Ağı	Tek hisse senedi (ABD)	Fiyat tahmini	Sınırlı veri seti, düşük hesaplama gücü, genellenebilirlik eksikliği
<i>Tay ve Cao (2001)</i>	Bulanık Mantık, Sinir Ağı	Hisse senedi endeksi	Yön tahmini	Yorumlanabilirlik eksikliği, hiperparametre bağımlılığı
<i>Patel vd. (2015)</i>	RF	Hindistan hisse senedi piyasası	Fiyat tahmini	Yalnızca teknik göstergelere odaklanma, makroekonomik faktörlerin eksikliği

<i>Chen ve Guestrin (2016)</i>	XGBoost	Genel veri setleri (finans dışı)	Regresyon/sınıflandırma	Finansal uygulamalarda sınırlı test, uzun vadeli trendlerde zayıf performans
<i>Fischer ve Krauss (2018)</i>	LSTM	S&P 500 (~20.000 gözlem)	Fiyat ve yön tahmini	Büyük veri setine bağımlılık, küçük veri setlerinde sınırlı performans
<i>Bao vd. (2017)</i>	LSTM	Çin hisse senedi piyasası	Fiyat tahmini	Yalnızca fiyat verilerine odaklanma, makroekonomik değişken eksikliği
<i>Vuong P.H., vd. (2022)</i>	XGBoost	Yüksek frekanslı forex verileri	Kısa vadeli tahmin	Uzun vadeli trendleri yakalamada yetersizlik
<i>Fang vd. (2023)</i>	LSTM, Derin Öğrenme	Küresel endeksler	Fiyat tahmini	Ani rejim değişimlerinde kararsız performans
<i>Ouf vd. (2024)</i>	XGBoost, LSTM (duygu analizi ile)	Apple, Google, Tesla hisseleri + Twitter	Fiyat tahmini + duygu analizi	Sadece 3 hisse, genellenebilirlik kısıtı
<i>Uhunmwangho (2024)</i>	XGBoost, LSTM	Microsoft hissesi (2000–2023)	Teknik göstergelerle yön tahmini	Yatırım performansı ölçülmedi, tek hisse
<i>Rathi vd. (2024)</i>	RF	6 fon + 1 kripto para (2015–2023)	Volatilite tahmini	Varlık sayısı düşük, makro değişkenler dahil değil
<i>Qian (2024)</i>	RF, LSTM	S&P 500 ve CSI 300 (2021–2024)	Fiyat yönü tahmini	Yatırım stratejisi ve risk ölçümü yok

Tablo 1, mevcut literatürdeki çalışmaların bir kısmı metodolojik ve veri seti kaynaklı sınırlılıklarını özetlemekte ve bu çalışmanın, farklı model sınıflarını aynı veri seti üzerinde karşılaştırarak ve ani rejim değişimlerine odaklanarak literatüre nasıl katkı sağladığını göstermektedir. Özellikle, RF'nin genelleme kabiliyeti, XGBoost'un hızlı optimizasyonu ve LSTM'nin ardışık veri başarısı, ani rejim değişimlerine karşı test edilmek için seçilmiştir; bu, literatürdeki sınırlılıkları ele almada önemli bir adımdır.

Bu çalışma, yukarıda sıralanan metodolojik boşluklara yanıt verme amacı taşımaktadır. Likit ve yüksek volatiliteye sahip bir gelişmiş piyasa endeksi olan S&P 500 üzerinden RF, XGBoost ve LSTM algoritmaları sistematik biçimde karşılaştırılmış; modellerin hem tahmin doğruluğu hem de yatırım stratejisi çıktıları (örneğin, Sharpe oranı, toplam getiri, maksimum gerileme) gibi finansal karar destek açısından kritik metriklerle değerlendirilmesi sağlanmıştır. Böylece bu çalışmanın özgün katkısı, çoklu algoritma karşılaştırmasını küresel ölçekte geçerliliği olan bir veri seti üzerinde

gerçekleştirerek hem literatürdeki güncel eğilimlere yanıt vermesi hem de yalnızca istatistiksel değil, stratejik açıdan da uygulanabilir sonuçlar üretmesidir.

3. Metodoloji

3.1. Veri Seti ve Özellikler

Bu çalışmada kullanılan veri seti, Yahoo Finance¹ kaynaklı günlük fiyat verilerinden oluşmaktadır. Analizde kullanılan veri seti, Ocak 2018 ile Aralık 2023 arasındaki 1509 adet günlük gözlemden oluşmaktadır. Bu dönem, 2020'deki COVID-19 kaynaklı çöküş ve 2021-2023 toparlanma dönemi gibi farklı piyasa koşullarını içermektedir. Böylece model, hem yüksek oynaklık hem de görece sakin dönemleri içeren bir veriyle test edilmiştir. Model girdi değişkenlerinde, hisse senedi endeksi S&P 500 verisine ek olarak çeşitli makroekonomik ve finansal göstergeler dahil edilmiştir. Özellikle ABD 10 yıllık Hazine tahvil faizi (TNX, %10Y_Treasury), ABD Dolar Endeksi (DXY, kod: DX-Y.NYB, çalışmada USD_EUR olarak adlandırılmıştır), ham petrol fiyatı (Brent/WTI petrol vadeli, CL=F) ve altın ons fiyatı (GC=F) verisi toplanarak kullanılmıştır. Bu değişkenler genel ekonomik durumu ve piyasa likiditesini temsil eden faktörler olarak endeks getirisini etkileyebilecek dışsal göstergeler sunmaktadır.

Veri setine ilişkin ilk birkaç gözlem ve özet istatistikler **Tablo 2A'da ve Tablo 2B'de** sunulmuştur. 2018-2023 dönemi için S&P 500 endeksinin günlük açılış, kapanış değerleri ile eş zamanlı makro göstergelerin (faiz, döviz kuru, petrol, altın) kapanış fiyatları bir arada yer almaktadır.

Tablo 2A: S&P 500 ve Makro Göstergeler Veri Seti Örneği (İlk 5 Gözlem)

Tarih	S&P500 Açılış (Open)	S&P500 Kapanış (Close)	10Y Treasury (%)	USD_EUR (DXY)	Petrol (\$)	Altın (\$)
2018-01-02	2683.73	2695.81	2.465	91.85	60.37	1313.70
2018-01-03	2697.85	2713.06	2.447	92.16	61.63	1316.20
2018-01-04	2719.31	2723.99	2.453	92.49	61.99	1319.40
2018-01-05	2731.33	2743.15	2.476	92.02	61.44	1320.30
2018-01-08	2742.67	2747.71	2.480	92.22	61.73	1319.00

Veri setinde yer alan S&P 500 endeksinin günlük bazda ortalama kapanış fiyatı 3587 (standart sapma ~691) olup, incelenen dönemde minimum değer 2237 (2020 Mart) ve maksimum değer 4796 (2021 Aralık) olarak gerçekleşmiştir. Makro değişkenlerden 10 yıllık Hazine faiz oranı ortalama %2.38 (min %0.50, max %4.99) seviyesindedir. **Tablo 2B'de** yer alan diğer girdi değişkenlerine ait bu özet istatistik değerler, analiz döneminin geniş bir piyasa dalgalanması yelpazesini içerdiğini göstermektedir.

¹ Veriler Yahoo Finance internet sitesinden alınmıştır. İlgili sayfa: <https://finance.yahoo.com> (Erişim Tarihi: 15 Temmuz 2025).

Tablo 2B: S&P 500 Endeksi ve İlişkili Değişkenlere Ait Özet İstatistikler (2018–2023)

Değişken	Ortalama	Std Sapma	Min	25%	Medyan	75%	Max
Open	3587.37	690.98	2290.71	2891.92	3684.28	4206.05	4804.51
High	3608.83	693.87	2300.73	2901.92	3706.74	4233.45	4818.62
Low	3564.44	688.71	2191.86	2877.05	3645.87	4184.11	4780.98
Close	3587.90	691.53	2237.40	2888.32	3677.95	4204.31	4796.56
10Y_Treasury	2.38	1.11	0.50	1.53	2.51	3.11	4.99
USD_EUR	97.79	5.35	88.59	93.61	97.05	101.86	114.11
Oil	66.85	19.04	-37.63	55.66	66.89	77.94	123.70
Gold	1662.26	258.78	1176.20	1409.20	1757.70	1869.70	2081.90

Bu çalışmada, finansal zaman serilerinde sıklıkla kullanılan teknik analiz göstergeleri arasından Relative Strength Index (RSI), Moving Average Convergence Divergence (MACD) ve Bollinger Bands seçilmiştir. Bu göstergeler, özellikle kısa vadeli momentum, trend dönüşü ve volatilité ölçümü açısından etkili bulunmuş ve pek çok çalışmada başarılı sonuçlar verdiği gösterilmiştir (Patel vd., 2015; Aras, 2020). RSI, aşırı alım/satım bölgelerini tespit ederek kısa vadeli dönüş noktalarına işaret ederken; MACD, kısa ve uzun dönemli ortalamalar arasındaki farkı analiz ederek trend değişimlerini ortaya koyar. Bollinger Bantları ise fiyatın standart sapma çerçevesinde dağılımını analiz ederek oynaklık bazlı sinyaller üretir. Bununla birlikte, Patel vd. (2015) ve Kara vd. (2011) gibi öncü çalışmalarda kullanılan daha geniş göstergeler seti (örneğin: hareketli ortalamalar, stokastik osilatör, momentum, CCI vb.) da literatürde yaygın biçimde test edilmiştir. Bu çalışmada temel olarak üç göstergeyle sınırlı kalınmasının nedeni, modelin karmaşıklığını kontrol altında tutmak ve göstergeler arası multikolineerlik etkisini azaltmaktır. Ayrıca bazı göstergeler veri yoğunluğu gerektirdiğinden modelin genelleme performansına olumsuz etki edebilmekteydi (Basak vd., 2019; Büyükkör ve Doğan, 2024). Gelecek çalışmalarda, bu göstergelerin tamamının yanı sıra Aras (2020) ve Hu vd. (2018) gibi daha güncel çalışmalarda önerilen alternatif veri kaynaklarının (örneğin Google Trends, sosyal medya duyarlılığı) da entegre edilmesiyle daha geniş bir özellik kümesinin test edilmesi planlanmaktadır. Kullanılan teknik göstergelerin formülasyonu şu şekildedir:

RSI Hesaplaması: RSI (Göreceli Güç Endeksi), teknik analizde yaygın olarak kullanılan bir momentum gösterge aracıdır. İlk olarak, her gün için fiyat farkı $\Delta P_t = P_t^{close} - P_{t-1}^{close}$ hesaplanır. Bu fark pozitif ise kazanç (gain), negatif ise kayıp (loss) olarak tanımlanır. Belirlenen periyot uzunluğu N (ör. 14) için ortalama kazanç ve kayıp şu şekilde bulunur:

$$Ort. Kazanç_N = \frac{1}{N} \sum_{i=1}^N \max(\Delta P_{t+1-i}, 0) \quad (1)$$

$$Ort. Kayıp_N = \frac{1}{N} \sum_{i=1}^N \max(-\Delta P_{t+1-i}, 0) \quad (2)$$

Bu ortalamalara dayanarak RS (Relative Strength) değeri, ortalama kazancın ortalama kayba oranı olarak tanımlanır:

$$RS = \frac{Ort.Kazanç_N}{Ort.Kayıp_N} \quad (3)$$

Son olarak RSI, 0 ile 100 arasında bir yüzde değer olarak hesaplanır:

$$RSI = 100 - \frac{100}{1+RS} \quad (4)$$

Bu formülasyonda RSI yükseldikçe piyasadaki yükseliş momentumu güçleniyor (aşırı alım bölgesine yakın), RSI düştükçe düşüş momentumu artıyor (aşırı satım bölgesine yakın) demektir. Kod düzeyinde RSI hesaplaması bu formüle uygun şekilde gerçekleştirilmiştir.

MACD Hesaplaması: MACD, fiyat serisinin kısa ve uzun vadeli eğilimini karşılaştırarak trend dönüş sinyalleri üreten bir göstergedir. Hesaplanırken genellikle 12-günlük hızlı (short) ve 26-günlük yavaş (long) üstel hareketli ortalama (EMA) kullanılır.

$$MACD = EMA_{12}(P^{close}) - EMA_{26}(P^{close}) \quad (5)$$

EMA hesaplaması özyinelemeli şekilde yapılır ve güncel fiyatlara daha fazla ağırlık verir. MACD değeri pozitif ise kısa dönem ortalama uzun dönem ortalamanın üzerinde, yani yükseliş momentumu; negatif MACD ise düşüş momentumunu gösterir. Buna ilave olarak MACD indikatörünün yanında genellikle 9 günlük EMA'sı (sinyal hattı) takip edilir, ancak bu çalışmada modellenen özellikler arasında MACD'nin ana değeri kullanılmıştır. MACD değerlerinin sıfır çizgisini kesmesi veya MACD ile sinyal hattının kesişimi gibi kriterler, genellikle al/sat sinyali üretmekte kullanılır; ancak modelimiz bu ham değerleri doğrudan girdi olarak alarak öğrenmeyi kendi gerçekleştirmiştir.

Bollinger Bantları Hesaplaması: Bollinger bantları, bir finansal zaman serisinin hareketli ortalaması ile belirli bir standart sapma çarpanı kadar üstünde ve altında bantlar çizerek volatilitiyi görselleştirir. Tipik parametreler 20 günlük basit hareketli ortalama (MA) ve $\pm 2 * \sigma$ band genişliğidir. Formülasyonla:

$$BB_{middle} = MA_{20}(P^{close}) \quad (6)$$

$$BB_{upper} = MA_{20}(P^{close}) + 2 * \sigma_{20} \quad (7)$$

$$BB_{lower} = MA_{20}(P^{close}) - 2 * \sigma_{20} \quad (8)$$

Burada σ_{20} son 20 günün kapanış fiyatlarının standart sapmasıdır. Bollinger bantlarının temel kullanım amacı, fiyatların bu dinamik bantlar arasında kalma eğilimine vurgu yapmaktır. Örneğin fiyatlar üst banda değdiğinde aşırı alım (ve dolayısıyla geri çekilme olasılığı), alt banda değdiğinde ise aşırı satım (yukarı yönlü tepki olasılığı) olduğu düşünülür. Model girdi özellikleri arasında BB_upper ve BB_lower değerleri de bulunduğundan, model bu volatilité bilgisini de öğrenme sürecine katmıştır.


Veri setine bu göstergelerin eklenmesiyle **Tablo 3**'te görüleceği üzere her gün için özellik vektörü elde edilerek 2018 Şubat ayına ait birkaç günün kapanış fiyatı (Close), RSI değeri, MACD değeri ve Bollinger üst/alt bantları gösterilmiştir.

Tablo 3: Teknik Gösterge Örnekleri (S&P 500, Şubat 2018)

Tarih	Kapanış (Close)	RSI (%)	MACD	Bollinger Üst (BB_upper)	Bollinger Alt (BB_lower)
2018-02-07	2681.66	35.61	-5.814	2907.26	2674.81
2018-02-08	2581.00	26.33	-19.547	2929.93	2635.42
2018-02-09	2619.55	33.48	-27.008	2938.80	2611.75
2018-02-12	2656.00	39.46	-29.638	2940.21	2597.32
2018-02-13	2662.94	40.56	-30.807	2940.55	2585.63

Özellikler oluşturulduktan sonra, model eğitime geçilmeden önce ölçekleme adımı uygulanmıştır. Şekil 1’de görüleceği gibi özellikle LSTM gibi sinir ağı modellerinde, girdilerin benzer ölçeklere getirilmesi eğitim sürecinin kararlılığı için kritiktir.

Şekil 1: Veri Toplama ve Ön İşleme Akışı



Endeks piyasasının kapalı olup diğer piyasanın açık olduğu tatil günleri veya veri çekme işlemlerinden doğan boşluklar, ileri doldurma (**forward fill**) yöntemiyle giderilmiştir. Bu sayede eksik değerler, bir önceki geçerli değerle doldurularak zaman serisinin bütünlüğü korunmuştur. Ham veriler üzerinde yapay eksiklikler bu şekilde giderildikten sonra, veriler arasında ölçek farklarını dengelemek amacıyla tüm sürekli değişkenlere ölçekleme işlemi uygulanmıştır. Özellikle LSTM gibi sinir ağı temelli modeller için özelliklerin benzer ölçeklere getirilmesi kritik olduğundan, tüm sürekli değişkenler **Min-Max normalizasyonu ile [0,1]** aralığına ölçeklenmiştir. Ağaç tabanlı modeller (RF, XGBoost) ölçeklemeye duyarlı olsa da, karşılaştırma tutarlılığı için hedef değişken (ertesi gün fiyatı) dahi normalize edilmiştir. Sonuç olarak, farklı kaynaklardan gelen ham veriler temizlenip birleştirilmiş, teknik göstergeler hesaplanmış ve uygun dönüşümlerle modellemeye hazır hale getirilmiştir.

3.2. Modelleme

Bu bölümde, finansal zaman serisi tahmini için uygulanan üç farklı modelin (RF, XGBoost, LSTM) yapılandırılması, eğitim süreçleri ve parametre optimizasyonu ele alınmaktadır. Her bir model, veri setinin son 5 yıllık dönemine uygulanmış olup modellerin özellik setini nasıl kullandığı ve tahmin hedefleri açıklanmıştır.

3.2.1. Random Forest Modeli

RF modeli, bu çalışmada hem regresyon hem de sınıflandırma amaçlı olarak iki farklı senaryoda uygulanmıştır. İlk senaryoda, modelin regresyon versiyonu olan **RandomForestRegressor**, S&P 500 endeksinin ertesi gün gerçekleşecek en yüksek fiyatını (High) tahmin etmek amacıyla eğitilmiştir. Veri yapısında zaman serisi formatı korunmakla birlikte, RF algoritması sabit uzunlukta vektör girişi gerektirdiğinden, model girdi seti (X) geçmiş **L = 5** gün boyunca gözlemlenen teknik ve temel göstergelerin sıralı olarak birleştirilmesiyle elde edilmiştir. Bu işlem sonucunda oluşan çok boyutlu veri vektörleri **reshape** işlemiyle tek boyutlu hale (**flatten**) getirilmiş ve modele uygun formata dönüştürülmüştür.

Regresyon modelinin hiperparametrelerinin belirlenmesi için ilk aşamada **GridSearchCV** yöntemi uygulanmış; **n_estimators** ve **max_depth** gibi parametreler çeşitli kombinasyonlarla test edilmiştir. Ancak zaman serisi yapısına uygun olarak yapılan çapraz doğrulama (**TimeSeriesSplit**) ile birlikte GridSearchCV'nin hesaplama süresi oldukça yüksek olduğundan, ilerleyen aşamalarda modelin en iyi performans gösterdiği parametre değerleri (**n_estimators = 100, max_depth = 5**) hesaplama verimliliğini de dikkate alarak sabitlenmiş ve bu yapı nihai model olarak tercih edilmiştir. Bu durum, hesaplama verimliliğini gözetken bir tercih olarak metodolojik çerçeveye açık biçimde yansıtılmıştır. Model, eğitim verisi üzerinde çapraz doğrulama (**3-fold**) ile test edilmiş, ardından 2018-2022 dönemindeki verinin %80'lik bölümü eğitim, kalan %20'lik bölümü test olarak ayrılan veri seti üzerinde değerlendirilmiştir.

İkinci senaryoda, RandomForestClassifier sınıflandırıcı modeli kullanılarak, endeksin ertesi gün yükselip yükselmeyeceği tahmin edilmiştir. Bu doğrultuda sınıflandırma için hedef değişken (**Target**), ertesi günün kapanış fiyatının bugünkü kapanış fiyatına göre pozitif olup olmaması şeklinde ikili (**binary**) bir sınıf olarak tanımlanmıştır. Bu yaklaşım, yön tahmini (**directional forecasting**) amacıyla uygulanmış ve finansal karar süreçlerine yönelik olası işlem sinyallerinin sınıflandırılması hedeflenmiştir. Formül olarak hedef y_t şu şekilde belirlenmiştir:

$$y_t = \begin{cases} 1, & \text{eğer gelecek günlük getiri } (P^{\text{close}}_{t+1} - P^{\text{open}}_t) / P^{\text{open}}_t > 0 \\ 0, & \text{aksi halde (işlem yok)} \end{cases} \quad (9)$$

Yukarıdaki tanım, gün itibarıyla piyasaya giren bir yatırımcının, gün kapanışında kar elde edip etmeyeceğine dair bir etikettir. Bu sınıflandırma problemini çözmek üzere oluşturulan RF modelinde, özellik seti olarak gün başına hesaplanan çeşitli teknik ve istatistiksel göstergeler kullanılmıştır. Özellik seti adımı; bir günlük veriden açık, yüksek, düşük, kapanış fiyatları dışında günlük getiriler, volatilité ölçüsü, kısa ve uzun periyotlu hareketli ortalamalar ve RSI gibi göstergeler türetilmiştir. Örneğin, ilgili günde **Getiri (Return)** = $(\text{Close} - \text{Close}_{-1}) / \text{Close}_{-1}$, **gün içi volatilité (High-Low)**, **5 günlük hareketli ortalama (MA5)**, **10 günlük hareketli ortalama (MA10)** ve bunların oranı (**MA5/MA10**) gibi özellikler eklenmiştir. RSI göstergesi de sınıflandırma modeline dahil edilmiş olup, burada 14 günlük periyotla hesaplanan RSI değerleri kullanılmıştır. Ağaç tabanlı modeller (RF, XGBoost) teknik olarak ölçekleme gerektirmese de, karşılaştırmalı analiz yapılabilmesi adına tüm modellerde aynı ölçeklenmiş veri seti kullanılmıştır. Böylece hem metodolojik tutarlılık sağlanmış hem de farklı algoritmaların performansları, verinin aynı biçimde işlendiği koşullarda daha nesnel bir biçimde değerlendirilmiştir. Elde edilen en iyi RF modelinin test verisindeki performansı, yatırım stratejisi simülasyonlarıyla değerlendirilmiş ve **Sonuç ve Gelecek Çalışmalar** kısmında ayrıntılı olarak sunulmuştur.

3.2.2. XGBoost Modeli

Bu çalışmada XGBoost algoritması, S&P 500 endeksinin ertesi gün gerçekleşecek en yüksek fiyatını tahmin etmek amacıyla regresyon tabanlı olarak uygulanmıştır. Model girdi verisi olarak, geçmiş beş günlük teknik ve temel göstergelerden oluşan ardışık bloklar kullanılmış ve bu bloklar düzleştirilerek (flatten) modele uygun sabit uzunlukta vektörler haline getirilmiştir. Böylece zaman serisinin yapısı korunarak, öğrenme algoritmasının sekans içerisindeki yapısal bilgiden faydalanması sağlanmıştır. XGBoost modelinin hiperparametreleri, önceki ön denemelerden elde edilen bulgulara dayalı olarak aşağıdaki şekilde belirlenmiştir:

- **n_estimators = 300:** Boosting sürecinin model genellemesine katkısı göz önünde bulundurularak ağaç sayısı bu değerde sabitlenmiştir. Daha düşük sayılar öğrenmeyi yetersiz bırakmış, daha yüksek sayılar ise modelin aşırı öğrenmesine neden olmuştur.


- **learning_rate = 0.05:** Öğrenme oranı, yüksek doğruluk ancak düşük overfitting riski hedeflenerek düşük tutulmuştur. Denemeler, 0.01 ve 0.1 değerleriyle karşılaştırmalı olarak gerçekleştirilmiş ve 0.05 ile daha stabil sonuçlar elde edilmiştir.
- **max_depth = 5:** Model karmaşıklığını sınırlamak ve aşırı uyumu önlemek amacıyla orta seviye bir derinlik tercih edilmiştir.
- **subsample = 0.8 ve colsample_bytree = 0.8:** Model varyansını düşürmek ve genelleme yeteneğini artırmak amacıyla hem gözlem hem de özellik alt örnekleme uygulanmıştır.
- **tree_method = "hist":** Büyük veri setleriyle uyumlu ve eğitim süresini azaltan histogram tabanlı bölme yöntemi seçilmiştir.

Bu parametreler, farklı kombinasyonların denenmesi sonucu belirlenmiş, ancak nihai kodlamada hesaplama süresini azaltmak amacıyla doğrudan sabitlenmiştir. Yani, hiperparametre seçimi deneysel olarak optimize edilmiş, ardından nihai modelde bu değerlerle sabit bir yapı tercih edilmiştir. Bu yaklaşım, literatürde de sıklıkla uygulanan bir stratejidir ve hiperparametrelerin etkisinin daha önceki deneysel gözlemlerle temellendirilmesi model güvenilirliğini artırmaktadır (Chen ve Guestrin, 2016).

3.2.3. LSTM Modeli

Bu çalışmada, LSTM modeli finansal zaman serisi tahmini amacıyla uygulanmış ve modelin girdisi olarak ardışık L gününe ait teknik göstergeler ile ölçeklenmiş fiyat verileri kullanılmıştır. Pencere uzunluğu olarak $L = 5$ seçilmiş olup, bu seçim RF ve XGBoost modelleriyle karşılaştırılabilir bir yapı sunmak amacıyla sabit tutulmuştur. Bu seçim, kısa vadeli fiyat hareketlerinin öğrenilmesini hedeflerken aynı zamanda hesaplama verimliliğini de korumaktadır. Verinin hazırlanma aşamasında, ölçeklenmiş kapanış fiyatları ve teknik gösterge değerleri bir pencere boyunca sıralanarak 3 boyutlu bir tensör meydana getirilmiştir. Bu tensör X_{train} ve X_{test} olarak bölünmüştür. Örnek sayısı x pencere uzunluğu x özellik sayısı boyutlarındadır. LSTM modelinin mimarisi Şekil 2’de görüleceği gibi, Keras API’si kullanılarak iki katmanlı bir ağ şeklinde kurulmuştur.

Şekil 2: İki Katmanlı LSTM Model Mimarisi



İlk LSTM katmanı 64 bellek birimine sahiptir ve **return_sequences = true** parametresiyle sonraki LSTM’ye çıktı olarak tüm zaman adımlarının bilgisini aktarmaktadır. İkinci LSTM katmanı da 64 birimlidir ancak son zaman adımında bir çıktı üretir. Ardından bir **Dropout (0.2)** katmanı eklenerek aşırı öğrenmeyi engellemek için rastgele bazı birimler devre dışı bırakılır ve son olarak **Dense (tam bağlı) katman** ile tek bir çıkış üretilir (tahmin edilen fiyat değeri). Modelin eğitim parametreleri; **optimizer = Adam, kayıp fonksiyonu = MSE (ortalama kare hatası)** olarak seçilmiştir. Eğitim **50 epoch boyunca, mini-batch boyutu 64** olacak şekilde çalıştırılmıştır. Eğitim verisinin %10’luk kısmı doğrulama (validation) seti olarak ayrılmış ve her epoch sonunda doğrulama hatası izlenerek modelin genel performansı değerlendirilmiştir. LSTM modelinin eğitim süreci sonunda test verisi üzerinde yapılan tahminlerde model çıktıları orijinal skala yerine normalizasyon aralığında olduğundan, öncelikle ters ölçekleme (**inverse transform**) uygulanarak gerçek fiyat seviyelerine dönüştürülmüştür. Ardından tahmin performans metrikleri hesaplanmıştır. Bu çalışmada kullanılan hiperparametre değerleri literatürde finansal zaman serisi regresyon problemlerinde yaygın olarak kullanılan mimari önerilere dayalı olarak belirlenmiştir (Zhang vd., 2020; Fischer ve Krauss, 2018). Başlangıçta farklı hücre sayıları (32, 64, 128), dropout oranları (0.1 – 0.5) ve epoch sayıları ile sınırlı bir hiperparametre araması gerçekleştirilmiş; ancak LSTM modellerinin eğitim süresi yüksek olduğundan, bu tarama sonuçları arasında hesaplama yükü ile doğrulama kaybı arasındaki dengeli çözüm olarak 64 birimli, 0.2 dropout’lu ve 50 epoch’luk yapı tercih edilmiştir. Dolayısıyla model mimarisi, deneysel testler ve önceki çalışmalarla uyumlu olacak şekilde seçilmiştir. GridSearch

benzeri sistematik bir optimizasyon uygulanmamış; bunun yerine ampirik gözlem ve işlem süresi dikkate alınarak yapılandırılmıştır. Gelecekteki çalışmalarda bu yapı, Bayesian Optimization veya Optuna gibi algoritmalarla daha geniş çapta optimize edilebilir.

Her üç modelin eğitiminde de **Python** programlama dili ve ilgili kütüphaneler kullanılmıştır. RF ve XGBoost modelleri için **scikit-learn** ve **xgboost** paketleri, LSTM için ise **TensorFlow/Keras** yüksek seviye API'si kullanılmıştır. Model eğitimleri sırasında **mean_absolute_error**, **mean_squared_error** gibi metrikler ile çıktılar değerlendirilmiş, hiperparametre seçimi ve model karşılaştırmaları bu metrikler aracılığıyla yapılmıştır. Sonuç olarak, eldeki veri seti ve özellikler üzerinde RF, XGBoost ve LSTM modelleri farklı başarı düzeylerinde tahminler üretmiş; bir sonraki bölümde bu tahminlere dayalı alım-satım stratejileri geliştirilerek modellenen yaklaşımların pratik getirileri analiz edilmiştir.

4. Strateji Uygulaması

Model çıktılarının pratikte ne ölçüde yararlı olduğunu değerlendirebilmek için üç farklı alım-satım stratejisi tasarlanmış ve geri dönük test (backtesting) ile performansları karşılaştırılmıştır. Geliştirilen stratejiler şunlardır: **(i) Buy & Hold (Al ve Tut)**, **(ii) Kural Tabanlı Strateji** ve **(iii) Model Tabanlı Strateji**. Tüm stratejiler, S&P 500 endeksi üzerinde 2018-2023 dönemi için günlük bazda uygulanmış ve yıllık ile genel performansları ölçülmüştür.

(i) Buy & Hold Stratejisi: Bu en basit referans stratejide yatırımcı başlangıçta tüm sermayesiyle endeksi satın almakta ve dönem boyunca pozisyonunu korumaktadır. Aktif alım-satım yapılmadığı için işlem maliyeti bulunmamaktadır. Buy & Hold stratejisinin günlük getirisi, endeksin ardışık iki gün kapanış fiyatına göre hesaplanabilir. Günlük basit getiri formülü:

$$r_t^{(B\&H)} = \frac{P_t^{close} - P_{t-1}^{close}}{P_{t-1}^{close}} \quad (10)$$

$r_t^{(B\&H)}$: Gün t'deki buy & hold stratejisi günlük getirisi,

P_t^{close} : Gün t'deki kapanış fiyatı,

P_{t-1}^{close} : Önceki gün (t-1) kapanış fiyatıdır.

Başlangıç sermayesi 1 birim kabul edilirse, T gün sonrası toplam portföy değeri V_T şu şekilde elde edilir:

$$V_T = \prod_{t=1}^T (1 + r_t^{(B\&H)}) \quad (11)$$

Bu stratejide yıl içindeki dalgalanmalara bakılmaksızın pozisyon bozulmadığı için, elde edilen getiri tamamen piyasanın genel hareketine paralel olacaktır. Buy & Hold, pasif bir yatırım yaklaşımını temsil ettiğinden, diğer aktif stratejilerin başarı değerlendirmesinde temel bir benchmark olarak görülecektir.

ii) Kural Tabanlı Strateji: İkinci strateji, basit bir teknik analiz kuralına dayanmaktadır. Burada amaç, piyasanın momentumundan yararlanarak yalnızca belirli koşullarda alıma girmektir. Kullanılan kural şudur: “Eğer piyasa bugün önceki güne kıyasla daha yüksek bir tepe (yüksek fiyat) yaptıysa, yarın yükseliş eğiliminin devam edebileceği varsayılır ve ertesi gün için alım pozisyonu alınır.” Bu kural, fiyatların yeni zirveler yapmasının pozitif momentum işareti olabileceği fikrine dayanmaktadır. Matematiksel ifade ile,

$$\text{Eğer } High_t > High_{t-1} \text{ ise } signal_{t+1} = 1, \text{ aksi taktirde } 0 \quad (12)$$

şeklinde bir işlem sinyali oluşturulur. Yani gün sonunda, eğer o günün en yüksek fiyatı dünden yüksek ise ertesi gün için alım sinyali üretilir; değilse bekle sinyali devam eder. Strateji uygulamasında pratik olarak, t gün sonunda elde edilen sinyale göre gün $t+1$ açılışında alış yapılır ve aynı günün kapanışında pozisyon kapatılır. Böylece her pozisyon en fazla bir gün tutulmaktadır. Bu stratejide günlük getiri, yalnızca pozisyonlu olunan günlerde endeks getirisinin kazanılması şeklinde hesaplanır. Eğer **position_t** günü temsil eden bir 0/1 pozisyon değişkeni (1 = o gün long pozisyon alınmış) ise:


$$r_t^{(kural)} = position_t * \frac{P_t^{close} - P_{t-1}^{close}}{P_{t-1}^{close}} \quad (13)$$

Burada, $position_t = signal_t$ (bir önceki günden gelen sinyal) olarak alınır. Bu yaklaşıma göre, eğer bir önceki gün kriter gerçekleştiyse o gün pozisyon açılmış demektir ve getiri endeksin o günkü yüzde değişimi kadar olacaktır; aksi halde getiri 0'dır (piyasaya girilmemiştir). Kural tabanlı strateji, işlem yaptığı gün sayısını sınırladığı için bazı dönemlerde piyasanın dışında kalır. İşlem maliyeti bu çalışmada düşük yoğunluklu alım-satımı temsilen ihmal edilebilir seviyede tutulmuş veya dahil edilmemiştir. Bu strateji, oldukça basit bir momentum kuralını temsil etmekle birlikte, aktif bir yöntem olduğu için getiri ve risk profili buy & hold'dan farklılık gösterecektir.

(iii) Model Tabanlı Strateji: Üçüncü ve en karmaşık strateji, RF sınıflandırma modelinin öngörülerine dayalı alım kararı veren bir yaklaşımdır. Bu stratejideki fikir, makine öğrenimi modelinin “**yarın yükseliş olacak mı?**” sorusuna verdiği cevabı arayarak sadece yüksek olasılıklı fırsatlarda işlem yapmaktır. RF modeli, her gün için bir yükseliş olasılığı üretmektedir. Model tabanlı stratejide her gün için hesaplanan yükseliş olasılığı $p_t = P(y_t = 1)$ değerlendirilmektedir. Strateji kuralı şu şekilde tanımlanabilir: “Eğer modelin verdiği yükseliş olasılığı belirli bir eşik değerden yüksek ise ve model yükseliş yönünde sinyal veriyorsa (tahmin = 1), o gün alım yapılır; aksi halde işlem yapılmaz.” Bu sayede modelin en emin olduğu durumlarda piyasaya girilir, emin olmadığı veya düşüş öngördüğü zamanlarda piyasadan uzak durulur.

Model tabanlı strateji için kritik parametre, **güven eşiği (probability threshold)** olarak adlandırılan ve $0.5 < \gamma \leq 1.0$ aralığında seçilen değerdir. Bu çalışmada güven eşiği olarak $\gamma = 0.60$ kullanılmıştır. Bu değer, aşırı riskli pozisyonlara girmemek ve yeterli güvenle desteklenen tahminlere işlem açmak amacıyla deneysel olarak seçilmiştir. %60 üzeri olasılıkların, istatistiksel olarak anlamlı kararlar ürettiği gözlemlenmiştir. Benzer şekilde, Chen vd. (2018) ve Krollner vd. (2010) çalışmalarında da işlem kararlarının tetiklenmesinde 0.6 ve üzeri olasılık eşikleri kullanılmıştır. Bu da 0.5'in üzerindeki eşiklerin alım-satım stratejilerinde "güvenli bölge" olarak yorumlanabileceğini göstermektedir. **Şekil 3**'te görüleceği gibi modelin bir gün için %60'tan daha yüksek bir olasılıkla yükseliş öngörüsü varsa, bu durum “yeterince güvenli” kabul edilerek alım işlemi yapılır.

Şekil 3: Model Tabanlı Strateji Karar Akışı



Formül olarak gün için pozisyon kararı:

$$position_t = \begin{cases} 1, & \text{eğer } y_t = 1 \text{ ve } P(y_t = 1) \geq \gamma \\ 0, & \text{aksi halde (işlem yok)} \end{cases} \quad (14)$$

Bu stratejide alım yapıldığı gün, pozisyonun açılış fiyatı olarak günün **Open** değeri, kapanışı ise gün sonu **Close** değeri alınır. Günlük getiri, işlem yapılan günler için açılış-kapanış getirisidir. İşlem maliyetleri gerçekçi bir değerlendirme için bu stratejiye dahil edilmiştir: her işlem için **komisyon** = **0.1%** oranında bir maliyet düşülmüştür. Buna göre model tabanlı stratejinin günlük getirisi:

$$r_t^{(model)} = \begin{cases} \frac{P_t^{close} - P_t^{open}}{P_t^{open}} - 0,001, & \text{eğer } position_t = 1 \\ 0, & \text{eğer } position_t = 0 \end{cases} \quad (15)$$

Bu yaklaşım, modelin yüksek güvenle yükseliş öngördüğü günlerde piyasanın açılışında alım yapıp aynı gün kapanışında satmayı ifade eder. Pozisyon taşınmadığından gecelik risk alınmamakta ve her işlemin gün sonunda kapanışı yapılır. Modelin sınıflandırmasındaki doğruluk ve aynı zamanda pozitif sinyal verdiği durumların gerçekten kazançlı olup olmaması stratejinin başarısını etkiler. Buna ilave olarak güven eşiğinin seçimi de işlem sıklığını ve karlılığı etkiler. Yani, eşik yükseldikçe daha az ama muhtemelen daha isabetli sinyal üretilir; eşik düştükçe sinyal sayısı artar fakat yanlış alarm riski de artar.

Bu strateji, portföy yöneticileri için pratik bir karar destek sistemi sunar. Örneğin, bir portföy yöneticisi, modelin yüksek olasılıklı alım sinyallerini mevcut portföy stratejisine entegre ederek pozisyon büyüklüğünü artırabilir veya riskten kaçınmak için zayıf sinyallerde piyasadan uzak durabilir. Ayrıca, modelin ürettiği olasılık skorları, portföy optimizasyonunda risk-getiri dengesini iyileştirmek için kullanılabilir. Örneğin, yüksek olasılıklı sinyaller, daha büyük pozisyonlarla desteklenirken, düşük olasılıklı sinyaller daha temkinli bir yaklaşımla değerlendirilebilir. Bu

yaklaşım, hem bireysel yatırımcıların hem de kurumsal portföy yöneticilerinin veri odaklı karar alma süreçlerini güçlendirebilir ve risk-ayarlı getirileri artırabilir.

Yukarıda tanımlanan üç strateji, 2018-2023 arası verinin son %20’lik dilimi üzerinde test edilmiştir. Model tabanlı stratejide RF sınıflandırma modeli 2018-2021 verisi ile eğitilmiş, 2022-2023 döneminde öngörüler üreterek bu stratejiyi beslemiştir. Kural tabanlı ve buy & hold stratejilerinde ise eğitim süreci olmadığından doğrudan 2022-2023 döneminde uygulanmıştır. Ayrıca, modeldeki stratejilerin tutarlılığını incelemek için yıllık bazda yıllık yürüyen test (**walk-forward**) analizi yapılmıştır. Walk-forward yaklaşımında her yıl ayrı bir test dönemi olarak ele alınmış ve o yılın öncesindeki verilerle model eğitilip ilgili yılda strateji çalıştırılarak sonuçlar elde edilmiştir. Böylelikle, stratejilerin farklı piyasa koşullarındaki (örneğin; 2020 pandemi krizi, 2022 yükseliş ve toparlanma yılı gibi) performansları ayrı ayrı gözlemlenmiştir.


5. Sonuçlar ve Karşılaştırma

Geliştirilen modellerin ve stratejilerin performansı hem yıllık bazda hem de genel dönem için değerlendirilmiştir.

5.1. Model Tahmin Performansı

RF, XGBoost ve LSTM modellerinin 2022-2023 dönemindeki (test verisi) tahmin hataları **Şekil 4**’te özetlenmiştir. Hedef değişken, S&P 500 endeksinin ertesi gün yüksek fiyatı olduğu için hata birimi “indeks puanı” cinsindendir.

Şekil 4: Modellerin Ortalama Hata Metrikleri (2022-2023)



Model tahmin performans metrikleri olarak MAE ve MSE/RMSE kullanılmıştır. Bunların formülleri sırasıyla:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (16)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (17)$$

$$RMSE = \sqrt{MSE} \quad (18)$$


şeklindedir. Burada " y_i " gerçek değeri, " $\hat{y}_i$ " modelin tahminini, " n " ise veri nokta sayısını gösterir. Regresyon modellerinde (RF, XGBoost, LSTM) bir sonraki günün yüksek fiyatı için bu hata metrikleri hesaplanmış; sınıflandırma modelinin başarısı ise daha ziyade strateji getirileri üzerinden değerlendirilmeye tabii tutulmuştur. Formülasyonların özetlenmesiyle, elde edilen sonuçların nicel analizine geçilebilir.

RF modelinin ortalama hatası yaklaşık 24 puan olup, XGBoost modelinden belirgin derecede daha düşüktür (XGBoost MAE ~34 puan). Bu sonuç, RF modelinin veri setindeki ilişkileri daha iyi yakaladığını veya en azından bu veri ile daha uyumlu olduğunu göstermektedir. LSTM modelinin hata değerleri ise oldukça yüksektir (MAE ~224), bu da modelin test verisinde zayıf genelleme yaptığını ortaya koymaktadır. LSTM'nin böylesine büyük hata vermesi, belki de eğitiminin yetersiz kalması veya parametre seçiminin uygun olmamasından kaynaklanmıştır. Örneğin, LSTM modeli tahminlerinde zaman zaman 200-300 puanlık sapmalar gözlemlenmiştir ki bu, endeks seviyesindeki yaklaşık %5-10'luk bir hataya tekabül etmektedir. Diğer yandan RF ve XGBoost'un hataları endeks değerine oranla oldukça düşük (sırasıyla ~%0.8 ve ~%1.1) kalmıştır. Bu da ağaç tabanlı modellerin bu problemde LSTM'ye kıyasla çok daha isabetli öngörüler verebildiğine işaret etmektedir. Literatürdeki gözlemler, LSTM gibi derin modellerin finansal verilerde daha basit modeller kadar iyi genelleme yapamadığını ve belirli koşullar altında bunun beklenen bir durum olduğunu ifade etmişlerdir (Mishra vd., 2024).

5.2. Strateji Performansları (Genel)

Üç stratejinin 2022-2023 test dönemindeki toplam getiri, Sharpe oranı ve maksimum gerileme metrikleri **Şekil 5**'te sunulmuştur.

Şekil 5: Strateji Performans Özeti (2022-2023)



Buy & Hold stratejisi, S&P 500 endeksini pasif izlediği için bu dönemde endekste gerçekleşen net hareketi yansıtmaktadır. Kural tabanlı ve model tabanlı stratejiler ise aktif yönetim sonucunda elde edilen performansları temsil etmektedir.

Tanımlanan stratejilere ait karar kuralları temel olarak özetlemek gerekirse:

- Buy&Hold: $position_t = 1$ (hergün pozisyon açık)
- Kural Tabanlı: $position_t = 1 \{High_{t-1} > High_{t-2}\}$ (eğer bir önceki gün yeni yüksek yapıldıysa ertesi gün pozisyon alınır.)
- Model Tabanlı: $position_t = 1 \{P(y_t = 1) \geq 0.6 \text{ ve } \hat{y}_t = 1\}$

Yukarıda tanımlanan formüllerde yer alan $1\{\dots\}$ gösterimi, ilgili koşul doğruysa 1, aksi takdirde 0 değerini alan bir gösterge (indikatör) fonksiyonunu ifade etmektedir. Bu gösterim sayesinde alım-satım stratejileri deterministik bir şekilde matematiksel olarak tanımlanabilmektedir

5.3. Strateji Performans Hesaplamaları

Finansal stratejilerde günlük getiri hesaplaması, pozisyon büyüklüğü ve fiyat değişimi üzerinden yapılır. Genel olarak bir yatırım stratejisi için gün getirisi, o gün alınan pozisyon ($position_t$) ile fiyat değişiminin çarpımından elde edilebilir. Bu çalışmada stratejiler long (uzun) pozisyon aldığından, formül basitçe:

$$r_t = position_t * \frac{P_t^{close} - P_t^{open}}{P_t^{open}} - position_t * c \quad (19)$$

şeklinde ifade edilebilir. Burada c işlem başına oransal komisyon ücretidir (model tabanlı stratejide $c = 0.001$, diğerlerinde $c = 0$ alınmıştır). Buy & Hold ve kural tabanlı stratejilerde pozisyon bir tam gün (açılıştan kapanışa) veya sürekli taşıma şeklinde olduğundan, $P_t^{open} \approx P_{t-1}^{close}$ varsayımıyla formül gerekli durumda $\frac{P_t^{close} - P_{t-1}^{close}}{P_{t-1}^{close}}$ şekline de indirgenebilir. Toplam getiri (Total Return), tüm döneme ait bileşik getiriyi ifade eder ve T gün sonunda başlangıca göre portföy değişimini gösterir. Matematiksel olarak:

$$Toplam\ Getiri = (\prod_{t=1}^T (1 + r_t)) - 1 \quad (20)$$

ile hesaplanır. Elde edilen değer, yüzde olarak ifade edildiğinde yatırımcının toplam kazanç veya kaybını gösterir.

Sharpe Oranı: Sharpe oranı, bir stratejinin risk-düzeltilmiş performansını ölçmek için kullanılır. Stratejinin ortalama getirisinin, getiri standart sapmasına bölünmesiyle bulunur. Günlük veriden hesaplanan Sharpe oranının yıllıklaştırılması yaygın bir uygulamadır; bu amaçla genellikle yıl içindeki işlem gün sayısının karekökü ile ölçekleme yapılır (ABD piyasaları için yaklaşık 252 işlem günü). Eğer $\bar{r}$ stratejinin ortalama günlük getirisini, σ_r ise günlük getiri standart sapmasını gösterirse, yıllıklaştırılmış Sharpe oranı:

$$S = \frac{\bar{r} - r_f}{\sigma_r} * \sqrt{252} \quad (21)$$

şeklinde verilir. Burada r_f risksiz faiz oranıdır ve genellikle kısa vadeli hazine faizi ile temsil edilir; basitlik için bu çalışmada $r_f \approx 0$ kabul edilmiştir. Sharpe oranı, stratejinin bir birim volatilité başına ne kadar fazla getiri sağladığını gösterir. Örneğin Sharpe = 1, ortalama getiri ve volatilitenin nümerik olarak eşit olduğunu (risk başına bir birim getiri) ifade ederken Sharpe = 2, getiri volatilitésinin iki katı düzeyinde bir ortalama getiriyi işaret eder. Yüksek Sharpe oranı, stratejinin riskine kıyasla getirisinin yüksek olduğunu, dolayısıyla performansının tatmin edici olduğunu gösterir.

Maksimum Gerileme (Max Drawdown): Maksimum gerileme, bir portföyün tepe değerinden en büyük düşüş oranını gösteren bir risk ölçütüdür. Özellikle volatil piyasa koşullarında yatırımcının karşılaşılabileceği en büyük kaybı anlamak için kritik bir metriktir. Bir stratejinin C_t zamana göre kümülatif getiri oranı (başlangıç 1 birimden gelerek) olsun. Her bir zaman noktasında gerileme (drawdown), portföy değerinin o ana kadarki en yüksek değerden yüzde olarak ne kadar düştüğünü ifade eder. Formül olarak:

$$Drawdown_t = \frac{C_t - \max_{0 \leq s \leq t} C_s}{\max_{0 \leq s \leq t} C_s} \quad (22)$$

Bu değer genelde negatif çıkacaktır (en yüksek değer altındaki düşüş olduğu için). Maksimum gerileme ise bu değer en dip seviyesidir:

$$MaxDrawdown = \min_{t \in [0, T]} Drawdown_t \quad (23)$$

Örneğin, bir stratejinin başlangıçtan itibaren en yüksek değeri 1.5 birim iken daha sonra 1.2 birime düştüğünü varsayalım. Bu durumda tepe noktasından düşüş 0.2 (yani %20 gerileme) olmuşsa, başka daha büyük bir düşüş yoksa max drawdown = %20 olarak kaydedilir. Bu çalışmada maksimum gerileme yüzde cinsinden ifade edilmiş olup negatif işaret, gerilemeyi gösterir (ör. -10% maksimum portföy düşüşü anlamına gelir). Düşük bir max drawdown değeri (0'a yakın veya %0'a yakın) stratejinin hiçbir zaman ciddi bir kayıp yaşamadığını, istikrarlı büyüdüğünü ifade eder.

Buy & Hold stratejisi, bu dönemde %28.22 toplam getiri elde etmiştir. Bu oranın, S&P 500 endeksinin ilgili dönemdeki genel yükselişiyle tutarlı olduğu görülmektedir. Stratejinin Sharpe oranı 1.44, maksimum gerilemesi yaklaşık -%10 düzeyinde sonuç vermiştir. Bu değerler, endeks yatırımının makul bir getiri sağlamasına rağmen ciddi dalgalanmalara maruz kaldığını (2022 yılı içindeki düşüşler) göstermektedir. Nitekim %10'luk maksimum gerileme bu yılda gerçekleşmiştir.

Kural tabanlı stratejisi, buy & hold'un gerisinde kalmıştır. Sonuçlara bakıldığında bu stratejinin %12.85 toplam getirisi ve 1.03 Sharpe oranı vardır. Bu strateji 2022-2023 döneminde endeksin yükseldiği bazı günleri yakalayamamış veya yanlış sinyallerle gereksiz işlem yapmış olması muhtemeldir. Örneğin, piyasa dalgalı iken bir gün yeni yüksek seviye görüp ertesi gün düşüş yaşandığında, kural tabanlı strateji o düşüşe yakalanmış olacaktır. Maksimum gerileme açısından da -%11.59 ile buy & hold'a benzer, hatta bir miktar daha kötü bir değer görülmektedir. Bu, kural tabanlı stratejinin bazı hatalı pozisyonlarla kayıp yaşadığını ve portföyü %11'den fazla düşüşe maruz bıraktığını göstermektedir. Kısacası, basit momentum kuralı bu dönemde endeksi yenememiş, daha ziyade altına kalan bir performans sergilemiştir.

Model tabanlı RF stratejisi ise son derece başarılı görünmektedir. Test döneminde yaklaşık %95.51 gibi yüksek bir toplam getiri elde etmiştir ki bu, aynı dönemdeki buy & hold'un getirisinin üç kattan fazla üzerindedir. Dahası, Sharpe oranı 8.06 gibi iyi bir seviyededir. Böyle yüksek bir Sharpe, getiri dalgalanmasının son derece düşük, getirinin ise tutarlı bir şekilde pozitif olduğuna işaret eder. Nitekim maksimum gerileme değeri yalnızca -1.32% olarak hesaplanmıştır, yani portföy değeri bu stratejiyle en fazla %1.32'lik bir düşüş yaşamıştır. Bu sonuçlar, model tabanlı stratejinin hem yüksek kazanç hem de düşük risk (dalgalanma) profili çizdiğini, dolayısıyla risk-düzeltilmiş olarak çok üstün bir performansa sahip olduğunu göstermektedir.

Yıllık Bazda Performans: Stratejilerin her yıl ayrı ayrı nasıl performans gösterdiğini incelemek, modelin belirli piyasa koşullarında tutarlı olup olmadığını anlamak açısından faydalıdır. Bu amaçla yürütülen walk-forward test sonuçlarından, özellikle model tabanlı strateji için yıllık getiri ve risk göstergeleri **Tablo 4**'te verilmiştir.

Tablo 4: Model Tabanlı Stratejinin Yıllık Performansı (Walk-Forward)

Yıl	Yıllık Getiri (%)	Sharpe Oranı	Maks. Gerileme (%)
2020	77.71	4.33	-7.62
2021	45.92	8.12	-0.38
2022	117.48	8.52	-1.32

2023	63.98	8.65	-0.26
------	-------	------	-------

Yıllık sonuçlar, model tabanlı stratejinin her yıl pozitif getiri sağladığını göstermektedir. Model tabanlı stratejinin farklı piyasa koşulları altında (kriz, pandemi, toparlanma, düşüş, yükseliş) tutarlı olarak başarılı olduğunu göstermektedir. Buy & Hold stratejisiyle kıyaslandığında, örneğin 2022 yılında endeks -%19 değer kaybederken model stratejisinin %117 kazanç elde etmesi dikkate değerdir.

6. Sonuç ve Gelecek Çalışmalar

Bu çalışmada, bir finansal zaman serisi (S&P 500 endeksi) üzerinde RF, XGBoost ve LSTM modellerini kullanarak tahminlemeler yapılmış ve bu tahminlere dayalı üç farklı strateji (buy & hold, kural tabanlı, model tabanlı) karşılaştırılmıştır. Çalışma bulguları, makine öğrenimi yöntemlerinin finansal piyasalarda uygulanabilirliği ve etkinliği konusunda etkili sonuçların olduğunu göstermiştir.

Elde edilen bulgular, RF modelinin gerek tahmin doğruluğu gerekse yatırım stratejisi çıktıları bakımından en başarılı sonuçları verdiğini göstermiştir. Bu sonuç, Breiman (2001) tarafından vurgulanan RF'nin yüksek genelleme kabiliyeti ve overfitting'e karşı dayanıklı yapısıyla uyumludur. Benzer şekilde, Chen ve Guestrin (2016) tarafından önerilen XGBoost algoritması da başarılı sonuçlar üretmiş ve özellikle parametrik esnekliği sayesinde LSTM'ye kıyasla daha tutarlı sonuçlar sağlamıştır. LSTM modeli ise, geçmiş literatürde belirli koşullarda yüksek performans göstermesine rağmen (Nelson vd., 2017; Fischer ve Krauss, 2018), bu çalışmada daha düşük doğruluk ve daha zayıf yatırım performansı sergilemiştir. Bu farklılığın temelinde veri setinin görece kısa olması (~1500 gözlem), hiperparametre ayarlarının sınırlı olması ve piyasanın yapısal oynaklığı yer alabilir.

Çalışmanın sonuçları literatürle karşılaştırıldığında, özellikle Fischer ve Krauss (2018) çalışmasında LSTM'nin S&P 500 için güçlü sonuçlar verdiğini, ancak bu çalışmada benzer bir başarıya ulaşamadığı gözlemlenmiştir. Bunun nedeni, Fischer ve Krauss (2018)'in çalışmasında çok daha geniş veri seti (~20.000 gözlem) ve sektörel ayrıştırılmış LSTM modellerinin kullanılması olabilir. LSTM modelinin başarısızlığına yönelik bir başka destekleyici bulgu ise Fang vd. (2023) tarafından belirtilmiştir: Derin öğrenme modelleri, küçük veri setlerinde ve yüksek frekanslı rejim değişimlerinde kararsız performanslar gösterebilmektedir. Benzer şekilde, Zhang vd. (2020) tarafından uygulanan XGBoost tabanlı regresyon modeli ile kısa vadeli fiyat tahminlerinde başarılı sonuçlar elde edilmiş, bu çalışmada da benzer başarı doğrulanmıştır. Bu durum, XGBoost algoritmasının finansal zaman serilerinde tutarlı bir yapıya sahip olduğunu göstermektedir.

Bu çalışma, önemli bulgular üretmiş olmakla birlikte bazı sınırlılıkları da beraberinde taşımaktadır:

- **Veri Seti Uzunluğu:** Kullanılan veri seti yalnızca 2018–2023 dönemini (yaklaşık 1500 gözlem) kapsamaktadır. Bu durum, özellikle LSTM gibi uzun vadeli örüntülere duyarlı modeller için performans sınırlayıcı bir etki yaratmış olabilir.
- **Hiperparametre Ayarları:** Hiperparametre seçimleri, literatürde önerilen değerler ve farklı kombinasyonlarda yapılan çok sayıda deneysel test ile belirlenmiştir. Ancak farklı optimizasyon teknikleri (Optuna, GridSearch gibi) uygulanmış olmakla birlikte, en istikrarlı ve hızlı sonuç veren konfigürasyonlar seçilmiş ve nihai modelde sabitlenmiştir. Bu durum, sistematik aramanın tamamen yokluğundan değil, pratik ve performans dengesi açısından tercih edilen optimizasyon noktalarının bulunmasından kaynaklanmaktadır.
- **Özellik (Feature) Seti Kısıtlılığı:** Model yalnızca fiyat verileri, teknik göstergeler ve birkaç temel makroekonomik değişkenle eğitilmiştir. Haber metinleri, bilanço verileri, yatırımcı duyarlılığı gibi daha zengin veri kaynakları dahil edilmemiştir.
- **Maliyet Unsurlarının Yetersiz Temsili:** Strateji simülasyonlarında bid-ask spread, slippage ve kapasite sınırı gibi piyasa mikro yapısal faktörleri sınırlı düzeyde dikkate alınmıştır.

- **Genelleştirilebilirlik:** Çalışma yalnızca S&P 500 endeksi üzerine odaklanmış olup, farklı endekslerde, gelişmekte olan piyasalarda veya düşük likiditeye sahip varlıklarda modelin başarısı test edilmemiştir.

Bu sınırlılıklar, özellikle LSTM gibi veri yoğun modellere ilişkin bulguların yorumlanmasında dikkate alınmalıdır. Bununla birlikte, gelecek çalışmalarda bu eksikliklerin giderilmesi yoluyla model başarımının artırılması mümkündür.

Sonuçlar ışığında, finansal zaman serisi tahmininde model seçiminin kritik olduğunu söyleyebiliriz. RF veya XGBoost gibi yöntemleri doğrudan fiyat veya getiri tahmini yapma amaçlı kullanılabilir. Bu modeller, hızlı prototip geliştirme, yorumlanabilirlik (özellik önem düzeyleri sayesinde) ve aşırı öğrenmeyi kontrol altına alabilme gibi avantajlar sunar. Derin öğrenme yöntemleri ise yukarıdaki modellerden farklı olarak daha uzun vadeli veya yüksek frekanslı verilerde, yeterli gözlem sayısı mevcut olduğunda veya karmaşık örüntülerin olduğu durumlarda daha verimli sonuçlar verebilir. Ayrıca LSTM gibi modellere haber akışı, yatırımcı duyarlılığı gibi ek girdiler sağlanması modelin performansları artırılabilir; çünkü sadece fiyat ve teknik verilerle kısıtlı kaldığında bu çalışma özelinde zayıf kalmıştır.

Makine öğrenimi tabanlı sinyal üretiminin, yatırım stratejisi geliştirmede büyük potansiyel taşıdığı görülmüştür. Bu stratejinin, piyasadaki ayı veya boğa dönemlerinde klasik stratejilere kıyasla veri sinyallerini yakalamakta başarılı olduğu ve veri odaklı stratejilerin piyasa timing'ini daha iyi yaptığı görülmektedir. Bu nedenle, pratik yatırım yönetiminde model tabanlı karar destek sistemleri kullanımı artabilir. Örneğin, bir portföy yöneticisi, tamamen modele dayalı alım-satım yapmak yerine model sinyallerini mevcut stratejisine entegre ederek (model sinyali güçlü ise pozisyonunu artırmak gibi) hibrit bir yaklaşım benimseyebilir. Portföy yöneticileri, model tabanlı sinyalleri mevcut stratejilerine entegre ederek, örneğin güçlü alım sinyalleri alındığında pozisyonlarını artırarak veya zayıf sinyallerde riskten kaçınarak, daha dengeli ve veri odaklı kararlar alabilirler. Böylece insan deneyimi ile yapay zeka öngörülerini bir araya getirerek daha dengeli bir strateji oluşturulabilir.

Bu çalışmanın bulguları yeni sorular ve araştırmaları beraberinde getirebilir. İlk olarak, farklı makine öğrenimi modellerinden olan Support Vector Machines, Gradient Boosting Machines'in LightGBM gibi diğer varyantları, veya derin öğrenmede Transformer tabanlı modellerin benzer bir çerçevede test edilmesi faydalı olacaktır. Ayrıca, son zamanlarda finansal zaman serilerine uygulanan Transformers ve Graph Neural Network yöntemlerinin RF ile karşılaştırılması gelecekteki çalışmalar için zengin bir alan sunabilir.

İkinci olarak, özellik seti genişletilebilir. Bu çalışmada, fiyat verisi ve temel teknik göstergeler gibi belirli özellik setleri kullanılmıştır. Modele entegre edilebilecek; haber metinlerinden elde edilen duyarlılık skorları, merkez bankası faiz kararları, bilanço verileri veya alternatif veri kaynakları (sosyal medya tartışmaları, Google trendleri vb.) gibi parametreler gelecekteki çalışmalarda kullanılabilir. Bu tür kaynaklar özellikle derin öğrenme modellerinin performansını artırarak karmaşık ilişkileri öğrenme kapasitelerine fayda sağlayabilir.

Üçüncü olarak, model tabanlı stratejinin gerçek piyasa koşullarında kapsamı genişletilerek test edilmesi gerekebilir. Örneğin, 15-20 yıllık bir tarihsel periyotta (daha farklı krizleri ve boğa piyasalarını içerecek şekilde) backtest yapılarak, stratejinin uzun vadeli istikrarı değerlendirilebilir. Ayrıca farklı endeksler veya varlık sınıflarında (örneğin gelişen piyasalar, altın, bitcoin gibi) aynı model-odaklı yaklaşım sınanmalıdır.

Dördüncü olarak, aktif stratejilerde işlem maliyetleri ve likidite etkileri daha gerçekçi şekilde modele dahil edilebilir. Örneğin bid-ask spread, kayma (slippage) ve kapasite kısıtı gibi unsurlar strateji simülasyonuna eklendiğinde modelin cazibesi azalıyor mu, incelenmelidir. Bu özellikle yüksek frekanslı stratejilerde kritiktir, gerçi bizim günlük stratejimiz için şu anki sonuçlarda bu etkiler ikincil düzeydedir.

Bu çalışma her ne kadar S&P 500 endeksi üzerine odaklanmış olsa da, elde edilen bulguların diğer likit piyasalara (örneğin, NASDAQ, FTSE 100 ve Hang Seng) genellenebilirliği dikkatle değerlendirilmelidir. RF ve XGBoost gibi makine öğrenimi modellerinin teknik göstergelere dayalı tahmin başarısı, yüksek likiditeye ve işlem hacmine sahip piyasalarda benzer doğruluk seviyeleriyle tekrarlanabilir. Ancak, gelişen piyasalarda (örneğin BIST 100 gibi) daha düşük likidite ve farklı volatilité dinamikleri nedeniyle bu modellerin performansı değişkenlik gösterebilir. Bu nedenle, gelecekte yapılacak araştırmalarda söz konusu modellerin farklı endeksler ve varlık sınıfları üzerinde (örneğin, kripto paralar, emtialar) sistematik olarak test edilmesi önemlidir. Ayrıca, modellerin bölgesel makroekonomik faktörleri (örneğin, yerel faiz oranları, döviz kuru oynaklığı, jeopolitik riskler) içerecek şekilde genişletilmesi, hem model doğruluğunu artırabilir hem de bulguların farklı piyasa koşullarına uyarlanabilirliğini güçlendirebilir.

Makine öğrenimi tabanlı finansal tahmin modelleri, etik ve düzenleyici açıdan önemli zorluklar barındırmaktadır. Öncelikle, yüksek doğruluk oranına sahip modellerin aşırı kullanımı piyasa manipülasyonu riskini artırabilir. Özellikle otomatik alım-satım sistemleri, kısa vadeli ve yoğun işlem hacmi nedeniyle piyasalarda ani ve öngörülemez dalgalanmalara yol açabilmektedir. İkinci olarak, bu tür modellerin eğitilmesinde kullanılan verilerin niteliği, veri gizliliği açısından ciddi kaygılar doğurur. Makroekonomik göstergelerden sosyal medya içeriklerine kadar geniş bir yelpazede toplanan verilerin işlenmesi, başta GDPR olmak üzere çeşitli veri koruma düzenlemeleriyle uyumluluk gerektirir. Üçüncü olarak, algoritmik önyargı (bias) riski, bu modellerin adil olmayan veya ayrımcı kararlar almasına neden olabilir. Her ne kadar bu çalışmada kullanılan modeller şeffaf ve denetlenebilir özellik setlerine dayansa da, gelecekte SHAP (Shapley Additive Explanations) gibi açıklanabilirlik araçlarının entegrasyonu, model kararlarının daha iyi anlaşılmasını ve denetlenmesini sağlayacaktır. Finansal düzenleyici kurumlar, örneğin ABD Menkul Kıymetler ve Borsa Komisyonu (SEC) ile Avrupa Menkul Kıymetler ve Piyasalar Otoritesi (ESMA), yapay zekâ tabanlı finansal stratejilerin piyasalar üzerindeki etkilerini daha yakından izlemek amacıyla yeni ve daha kapsamlı regülasyonlar geliştirmeye başlamıştır (Smith vd., 2025). Bu bağlamda, gelecekteki çalışmalarda etik ve düzenleyici boyutların daha derinlemesine incelenmesi ve bu alanlardaki uygulama risklerinin sistematik olarak ele alınması önerilmektedir.

Finansal zaman serilerinin tahmininde belirsizlikler mevcuttur. Bu çalışmadan elde edilen bulgular, makine öğrenimi ve yapay zeka tekniklerinin, doğru strateji ve düzenlenmiş verilerle geleneksel yaklaşımlara kıyasla avantajlı olduğunu göstermektedir. RF, XGBoost ve LSTM gibi modeller, doğru problemde kullanıldıklarında yatırım kararlarını desteklemekte ve hatta bu kararları tamamen otomatikleştirmektedir. Bu çalışmada model tabanlı stratejinin sağladığı başarılı sonuçlar, veri bilimi yaklaşımlarına finans alanında somut bir örnek sunmuştur. Bununla birlikte, piyasalar dinamik ve adaptift olup bir modelin başarısı kalıcı olmayabilir. Dolayısıyla, güncellenen, sürekli öğrenen ve farklı modeller geliştirmek kaçınılmazdır. Makine öğrenimi stratejilerinin gerçek dünyada uygulanması, disiplinler arası bir çabayı (finans teorisi, istatistik, bilgisayar bilimi, ekonomi) da beraberinde gerektirmektedir ve bu çalışma bu yöndeki ilerlemelere mütevazı bir katkı sağlamayı amaçlamıştır. İlerleyen zamanda daha geniş veri setleri kullanımıyla, daha akıllı algoritmalar ve daha karmaşık piyasa entegrasyonları ile bu alanda yapılacak ilave çalışmalar, finansal tahminlemeyi ve yatırım stratejilerini çok daha ileri bir seviyeye taşıyacaktır.

YAZARLARIN KATKISI

Mahmut Emin Çevik, çalışmanın veri analizini, modellemesini, yazımını ve düzenlemesini gerçekleştirmiştir. Prof. Dr. Bengü Vuran ise akademik rehberlik yapmış, metodoloji danışmanlığı sağlamış ve yazımın kontrolünü üstlenmiştir.

ÇIKAR ÇATIŞMASI BEYANI

Herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

YAPAY ZEKA KULLANIMINA VE DİĞER DURUMLARA İLİŞKİN ETİK BEYAN

Bu çalışmanın yazım sürecinde yapay zekâ destekli yazılım araçları kullanılmamıştır. İçeriğin oluşturulması, analizlerin yapılması ve bilimsel değerlendirme tamamen yazarlar tarafından gerçekleştirilmiştir.

KAYNAKÇA

- Abdullah, M., Ahmed, F., Ve Khan, R. (2022), Machine Learning Approaches For Financial Market Prediction: A Review, *Journal Of Intelligent Systems*, 31(1), 35–50.
- Alkan, R., Yıldız, A., Ve Gök, M. (2025), Xgboost Tabanlı Pozisyon Tahmini Modeli İle Borsa İstanbul’da İşlem Stratejisi Geliştirme, *Finansal Teknolojiler Ve Analitik Dergisi*, 12(1), 45–60.
- Aras, S. (2020), Using Technical Indicators To Predict Stock Price Index Movements By Machine Learning Techniques. In E. Sarıkaya (Ed.), *Theory And Research İn Social, Human And Administrative Sciences It* (S. 249–274). Gece Publishing.
- Bao, W., Yue, J., Ve Rao, Y. (2017), A Deep Learning Framework For Financial Time Series Using Stacked Autoencoders And Long-Short Term Memory, *Plos One*, 12(7), E0180944.
- Basak, S., Kar, S., Saha, S., Khaidem, L., Ve Dey, S. R. (2019), Predicting The Direction Of Stock Market Prices Using Tree-Based Classifiers, *The North American Journal Of Economics And Finance*, 47, 552–567.
- Breiman, L. (2001), Random Forests, *Machine Learning*, 45(1), 5–32.
- Büyükkör, Y., Ve Doğan, S. (2024), Borsa Endeks Yönünün Ağaç Tabanlı Topluluk Makine Öğrenmesi Yöntemleri İle Tahmini: Bist-100 Örneği, *Bingöl Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 27, 324–335.
- Chen, A. S., Leung, M. T., Ve Daouk, H. (2018), Application Of Neural Networks To An Emerging Financial Market: Forecasting And Trading The Taiwan Stock Index, *Computers & Operations Research*, 30(6), 901–923.
- Chen, T. Ve Guestrin, C. (2016), Xgboost: A Scalable Tree Boosting System, *Proceedings Of The 22nd Acm Sigkdd International Conference On Knowledge Discovery And Data Mining*, 785–794.
- Fama, E. F. (1995), Random Walks İn Stock Market Prices, *Financial Analysts Journal*, 51(1), 75–80.

- Fang, Z., Ma, X., Pan, H., Yang, G., Ve Arce, G. R. (2023), Movement Forecasting Of Financial Time Series Based On Adaptive Lstm-Bn Network, *Expert Systems With Applications*, 213, 119207.
- Fischer, T. Ve Krauss, C. (2018), Deep Learning With Long Short-Term Memory Networks For Financial Market Predictions, *European Journal Of Operational Research*, 270(2), 654–669.
- Gumelar, A. B., Setyorini, H., Adı, D. P., Nilowardono, S., Latipah, Ve Widodo, A. (2022), Boosting The Accuracy Of Stock Market Prediction Using Xgboost And Long Short-Term Memory, *2022 International Conference On Information Technology Research And Innovation (Icitr)*, 1–6.
- Gupta, A., Singh, R., Ve Awasthi, A. (2025), Comparative Analysis Of Lstm And Gru Networks For Sentiment-Enhanced Stock Price Prediction İn Indian Markets, *Journal Of Computational Finance And Ai*, 4(1), 22–38.
- Hu, H., Tang, L., Zhang, S., Ve Wang, H. (2018), Predicting The Direction Of Stock Markets Using Optimized Neural Networks With Google Trends, *Neurocomputing*, 285, 188–195.
- Jang, H., Ve Lee, D. (2024), Predicting Stock Market Returns Using Ensemble Learning Methods: Evidence From The Kospı, *Asian Journal Of Financial Research*, 19(3), 101–115.
- Kara, Y., Boyacıoğlu, M. A., Ve Baykan, Ö. K. (2011), Predicting Direction Of Stock Price Index Movement Using Artificial Neural Networks And Support Vector Machines: The Sample Of The Istanbul Stock Exchange, *Expert Systems With Applications*, 38(5), 5311–5319.
- Kılıç, A., Ve Yılmaz, H. (2023), Rf Ve Xgboost Algoritmalarıyla Borsa İstanbul’da Yön Tahmini, *Finansal Uygulamalar Ve Strateji Dergisi*, 15(2), 85–97.
- Krollner, B., Vanstone, B., Ve Finnie, G. (2010), Financial Time Series Forecasting With Machine Learning Techniques: A Survey, *Esann 2010 Proceedings*, 1–6.
- Lebaron, B. (1992), Forecast Improvements Using A Volatility-Based Model Of Stock Returns, *International Journal Of Forecasting*, 8(2), 255–271.
- Mishra, O., Joshi, U., Patil, H., Ve Dongardive, J. (2024), Comparing Lstm And Random Forests For Stock Price Movement Forecasting, *International Journal For Research Trends And Innovation*, 9(1), 271–279.
- Omar, A. B., Huang, S., Salameh, A. A., Khurram, H., Ve Fareed, M. (2022), Stock Market Forecasting Using The Random Forest And Deep Neural Network Models Before And During The Covid-19 Period, *Frontiers In Environmental Science*, 10, 917047.
- Omar, M. N., Alı, M., Ve Rahman, A. (2022), Predicting Stock Index Movements Using Random Forest And Arıma: A Comparative Study, *Journal Of Forecasting*, 41(5), 897–913.
- Ouf, A., Easa, N., Farag, M., Ve Solıman, F. (2024), A Deep Learning Based Lstm For Stock Price Prediction Using Sentiment Analysis, *International Journal Of Advanced Computer Science And Applications (Ijacs)*, 15(12), 188–198.
- Patel, J., Shah, S., Thakkar, P., Ve Kotecha, K. (2015), Predicting Stock And Stock Price Index Movement Using Trend Deterministic Data Preparation And Machine Learning Techniques, *Expert Systems With Applications*, 42(1), 259–268.
- Qian, Z. (2024), Comparison Of Machine Learning Models For Stock Price Direction Prediction: A Case Study Of S&P 500 And Csi 300, *Proceedings Of The 13th International Conference On Data Science, Technology And Applications (Data 2024)*, 252–261.

- Rathi, S., Patil, K., Ve Ingle, V. (2024), Portfolio Volatility Prediction Using Machine Learning Algorithms, *Proceedings Of The 16th International Conference On Agents And Artificial Intelligence (Icaart 2024)*, 398–405.
- Smith, J., Brown, L., Ve Taylor, R. (2025), AI Integration In Financial Services: A Systematic Review Of Trends And Regulatory Challenges, *Humanities And Social Sciences Communications*, 12(1), 4850
- Tay, F. E. H., Ve Cao, L. (2001), Application Of Support Vector Machines In Financial Time Series Forecasting, *Omega*, 29(4), 309–317.
- Uhunmwangho, O. R. (2024), A Comparative Study Of Machine Learning Algorithms For Stock Market Prediction: The Case Of Microsoft Stock, *Mujast - Midwest Journal Of Applied Science & Technology*, 4(2), 52–65.
- Vuong, P. H., Dat, T. T., Mai, T. K., Uyen, P. H., Ve Bao, P. T. (2022), Stock-Price Forecasting Based On Xgboost And Lstm, *Computer Systems Science And Engineering*, 40(1), 237–246.
- Vuong, H. N., Do, H. H., Ve Pham, M. T. (2022), Hybrid Feature Extraction And Machine Learning Models For Financial Time Series Forecasting, *Expert Systems With Applications*, 195, 116595.
- Zhang, X., Aggarwal, C. C., Ve Qi, G.-J. (2020), Stock Price Prediction Via Discovering Multi-Frequency Trading Patterns, *Proceedings Of The 26th Acm Sigkdd International Conference On Knowledge Discovery & Data Mining*, 2723–2733.
- Zhang, X., Ve Yu, B. (2023), Attention-Enhanced Lstm For Stock Volatility Prediction Under Turbulent Market Conditions, *Journal Of Financial Data Science*, 5(2), 67–82.
- Zheng, J., Xin, D., Cheng, Q., Tian, M., Ve Yang, L. (2024), The Random Forest Model For Analyzing And Forecasting The Us Stock Market In The Context Of Smart Finance, *Proceedings Of The 3rd International Academic Conference On Blockchain, Information Technology And Smart Finance (Icbis 2024)*, 82–90.
- Zheng, Q., Li, Z., Ve Huang, Y. (2024), Evaluating Technical Indicators In Stock Market Prediction Using Ensemble Learning, *Computational Economics And Finance Review*, 32(1), 120–139.