

YATIRIM KARAR VERME SÜREÇLERİNDE YAPAY ZEKÂ UYGULAMALARI VE ETKİLERİ

APPLICATIONS AND EFFECTS OF ARTIFICIAL INTELLIGENCE IN INVESTMENT DECISION-MAKING PROCESSES

Sinan CEYLAN* & Gültekin ATALIK**

<https://doi.org/10.5281/zenodo.21383508>

Anahtar Kelimeler: Yapay Zekâ, Açıklanabilir Yapay Zekâ (XAI), Yatırım Karar Süreçleri, Finansal Zaman Serileri, Risk Yönetimi	Öz Bu çalışma, yatırım karar verme süreçlerinde yapay zekâ (AI) uygulamalarının etkinliğini ve açıklanabilir yapay zekâ (XAI) yaklaşımlarının rolünü kapsamlı bir biçimde incelemeyi amaçlamaktadır. Araştırmanın temel amacı, AI tabanlı modellerin finansal piyasalarda yatırım performansı, risk yönetimi ve karar kalitesi üzerindeki katkılarını, geleneksel yöntemlerle karşılaştırmalı olarak ortaya koymaktır. Çalışma, Borsa İstanbul (BIST 100) endeksine ait 01.01.2016–31.12.2025 tarihleri arasındaki günlük kapanış fiyatları ve getirilerden oluşan ikincil veri seti ile sınırlıdır ve farklı makroekonomik rejimlerin, pandemi ve enflasyon gibi heterojen piyasa koşullarının etkilerini kapsamaktadır. Araştırmada nicel yöntem benimsenmiş ve karşılaştırmalı bir model kullanılmıştır. Yapay zekâ temelli modeller olarak Rastgele Orman (Random Forest) ve Uzun Kısa Süreli Bellek (LSTM) algoritmaları, geleneksel zaman serisi modelleri olarak ise ARIMA uygulanmıştır. Modellerin performansı, ortalama getiri, volatilité, Sharpe oranı ve maksimum düşüş gibi kriterler üzerinden ölçülmüş ve yön tahmin doğruluğu ile karşılaştırılmıştır. Bulgular, AI temelli modellerin özellikle yüksek volatilité ve piyasa belirsizliği dönemlerinde daha istikrarlı ve doğru yatırım kararları sağladığını göstermektedir. Örneğin, pandemi süreci ve belirsiz makroekonomik dönemlerde AI modelleri geleneksel modellere kıyasla üstün performans göstermiştir. Öte yandan güçlü ve tek yönlü trendlerin görüldüğü dönemlerde klasik modellerin de yüksek performans sergileyebildiği gözlemlenmiştir. Bu sonuçlar, yatırım karar mekanizmalarında hibrit yaklaşımların yani geleneksel finans teorileri ile AI tekniklerinin birlikte kullanılması daha dengeli ve etkili stratejiler geliştirilmesine katkı sağlayabileceğini ortaya koymaktadır.
Keywords: Artificial Intelligence, Explainable Artificial Intelligence (XAI), Investment Decision Processes, Financial Time Series, Risk Management	Abstract This study aims to comprehensively examine the effectiveness of artificial intelligence (AI) applications and the role of explainable AI (XAI) in investment decision-making processes. The primary objective is to assess how AI-based models contribute to investment performance, risk management, and decision quality in financial markets, in comparison with traditional methods. The study is limited to the Borsa İstanbul (BIST 100) index, covering daily closing prices and returns from January 1, 2016, to December 31, 2025, capturing diverse macroeconomic conditions, including the pandemic and inflationary periods. A quantitative research approach was adopted, using a comparative model framework. AI-based models, including Random Forest and Long Short-Term Memory (LSTM) algorithms, were compared with traditional time series models such as ARIMA. Model performance was evaluated using metrics such as average return, volatility, Sharpe ratio, and maximum drawdown, along with directional accuracy. The findings indicate that AI-based models provide more stable and accurate investment decisions, particularly during periods of high volatility and market uncertainty. For instance, during the pandemic and other uncertain macroeconomic periods, AI models outperformed traditional models. However, in periods with strong and unidirectional trends, classical models also achieved high performance. These results suggest that hybrid approaches, integrating traditional financial theories with AI techniques, can yield more balanced and effective investment strategies.

* Uzman, Amasya Üniversitesi, Sosyal Bilimler Meslek Yüksekokulu., sinan.ceylan@amasya.edu.tr., ORCID: 0000-0002-2283-1249

** Dr. Öğr. Üyesi, Amasya Üniversitesi, Sosyal Bilimler Meslek Yüksekokulu. gultekin.atalik@amasya.edu.tr., ORCID: 0000-0002-8795-539X

1. GİRİŞ

Finansal piyasalarda yatırım kararları, tarih boyunca karmaşık modellere, ekonomik göstergelere ve uzman tahminlerine dayanmıştır. Ancak büyük veri hacimlerinin artması ve piyasa volatilitésinin yükselmesiyle klasik yöntemler bazen yetersiz kalmakta; bu durum yapay zekâ (AI) tabanlı yaklaşımların yükselişine zemin hazırlamaktadır (Weber et al., 2023). AI, finansal verilerin işlenmesi ve öngörü modellerinin oluşturulmasında önemli avantajlar sunmaktadır (Mahajan, 2024; Saini, 2025).

AI'nin yatırım süreçlerine entegrasyonu; algoritmik ticaret, portföy optimizasyonu, risk tahmini ve robo-danışman sistemleri gibi alanlarda etkili sonuçlar üretmektedir. Örneğin makine öğrenmesi ve derin öğrenme modelleri, finansal zaman serilerini analiz ederek insan algısını aşan performanslar gösterebilmektedir (Mahajan, 2024). Bu modeller, yatırımcıların hızlı ve daha doğru kararlar almasına katkı sağlar. Bununla birlikte, karmaşık AI modellerinin çoğu “kara kutu” karakterine sahip olup, sonuçların nasıl elde edildiğini tam olarak açıklamak zordur. Bu durum, özellikle yatırımcı güveni ve regülasyon uyumu açısından önemli bir risk oluşturmaktadır; çünkü finans sektörü şeffaflık ve hesap verebilirlik beklentisiyle çalışır (CFA Institute, 2025).

Bu bağlamda, Açıklanabilir Yapay Zekâ (Explainable AI – XAI) kavramı, AI çözümlerinin neden ve nasıl karar verdiğini anlaşılır kılmayı amaçlar. XAI teknikleri, finansal sistemlerde modellerin içsel mantığını betimleyerek yatırım kararlarının arkasındaki faktörlerin daha net analiz edilmesine olanak tanır (Mohsin & Nasim, 2025). Literatürde XAI'nin finansal uygulamalarını ele alan çalışmalar, model açıklanabilirliğinin risk değerlendirmesi, portföy seçimi ve performans tahmini gibi kritik karar süreçlerinde etkin olduğunu göstermektedir (Springer Review, 2024).

Ayrıca XAI yöntemleri, sadece yatırım kararlarında değil kredi skorlaması ve finansal risk değerlendirme süreçlerinde de uygulanarak, karar sonucu üzerinde hangi girdilerin etkili olduğunu gösterebilmektedir (Schmitt, 2024). Bu çok yönlü uygulama alanı, yatırımcıların AI tabanlı sistemlere yönelik güvenini artırmaktadır (Springer Review, 2023). Öte yandan, yerel ölçekli çalışmalar da AI destekli sistemlerin bireysel yatırımcı davranışları üzerinde anlamlı etkileri olduğunu ortaya koymaktadır (Özer, 2025). Türkiye’de yapılan bir araştırma, bireysel yatırımcıların AI tabanlı yatırım öneri araçlarını sıklıkla kullandığını ve bu araçların veri temelli karar alma süreçlerini desteklediğini göstermektedir (Aydın & Güneysu, 2025).

Finans literatürü ayrıca, yapay zekâ teknolojilerinin finansal hizmetler sektöründe sadece karar destek aracı olarak değil aynı zamanda stratejik planlama ve müşteri etkileşimi açısından da önemli katkılar sağladığını ortaya koymuştur (Şahin, 2024). AI'nin entegrasyonu, finansal kurumların hem operasyonel verimliliğini hem de yatırım performansını artırmaktadır (Chen et al., 2023). Bununla birlikte, AI ve XAI tabanlı sistemlerin etkili şekilde kullanılabilmesi için hem teknik uzmanlığın hem de etik ve hukuki bağlamda uygun çerçevelerin oluşturulması gerekmektedir (CFA Institute Report, 2025).

Bu çalışma yatırım karar verme süreçlerinde yapay zekâ uygulamalarının ve açıklanabilir AI yaklaşımlarının rolünü kapsamlı biçimde irdelemeyi hedeflemektedir. Bu araştırmanın temel amacı, yapay zekâ tabanlı modellerin yatırım karar verme süreçlerindeki etkinliğini, ikincil finansal veriler kullanarak analiz etmektir. Çalışma, yapay zekâ destekli yatırım karar mekanizmalarının geleneksel finansal analiz yöntemlerine kıyasla yatırım performansı ve risk yönetimi açısından sağladığı katkıları ortaya koymayı hedeflemektedir.

Son yıllarda finansal piyasalarda üretilen veri miktarının artması, yatırım kararlarının yalnızca insan sezgisine veya klasik istatistiksel yöntemlere dayalı olarak alınmasını yetersiz hale getirmiştir. Bu bağlamda yapay zekâ uygulamaları, yatırım karar süreçlerinde alternatif ve tamamlayıcı bir araç olarak ön plana çıkmaktadır (Fischer & Krauss, 2018). Literatürde, yapay zekâ tabanlı modellerin özellikle finansal zaman serilerinin doğrusal olmayan yapısını yakalamada başarılı olduğu ve yatırım karar kalitesini artırdığı ifade edilmektedir (Sezer et al., 2020).

Araştırma, hisse senedi piyasalarına ilişkin finansal zaman serisi verileri ile sınırlandırılmıştır. Çalışma kapsamında, belirli bir endekse ait (örneğin BIST 100, S&P 500 veya NASDAQ) günlük kapanış fiyatları ve getiriler analiz edilmiştir. Araştırmanın kapsadığı dönem, veri sürekliliği ve piyasa koşullarının temsil edilebilirliği dikkate alınarak belirlenmiştir. Bu yaklaşım, yapay zekâ modellerinin farklı piyasa koşullarındaki performansını değerlendirme açısından literatürde yaygın olarak tercih edilmektedir (Krauss et al., 2017).

2. LİTERATÜR TARAMASI

Akademik literatürde yapay zekâ ve finans alanının kesişimine yönelik çalışmalar giderek artmaktadır. Bu kapsamda, Ayşe Yıldız (2022) tarafından gerçekleştirilen sistematik literatür incelemesi, yapay zekâ teknolojilerinin finans alanındaki kullanımının kapsamını ve

gelişim yönünü ortaya koymaktadır. Çalışmada, özellikle FinTek çerçevesinde ele alınan araştırmaların, ağırlıklı olarak hisse senedi ve altın gibi yatırım araçlarının tahmininde yapay sinir ağları tekniklerini kullandığı belirlenmiştir. Bununla birlikte, son dönem çalışmalarda blok zincir teknolojisinin yaygınlaşmasıyla birlikte, Bitcoin fiyat tahminine yönelik derin öğrenme gibi daha gelişmiş yöntemlerin kullanımında belirgin bir artış gözlemlenmiştir (Yıldız, 2022).

Akademik literatürde üretken yapay zekâ uygulamalarının yatırım kararları üzerindeki etkisi giderek daha fazla incelenmektedir. Bu bağlamda, Aydın ve Güneysu (2025) tarafından gerçekleştirilen çalışma, ChatGPT kullanımının bireysel yatırımcıların karar süreçleri üzerindeki etkisini ortaya koymaktadır. Araştırmada, Borsa İstanbul'da işlem yapan yatırımcılar üzerinde yapılan analizler sonucunda, ChatGPT kullanımının veri analizi, risk yönetimi, portföy optimizasyonu, piyasa trendlerini takip etme ve duyarlılık gibi boyutlar üzerinden yatırım kararlarını pozitif yönde etkilediği belirlenmiştir. Bu bulgular, üretken yapay zekâ araçlarının yatırım karar verme süreçlerinde destekleyici ve yönlendirici bir rol üstlendiğini göstermektedir (Aydın & Güneysu, 2025).

2.1. Daha Önce Yapılan Çalışmalar

Coşkun (2022) tarafından gerçekleştirilen çalışma, yapay zekâ tekniklerinin yatırımcıların karar alma süreçlerindeki rolünü Türk finans sektörü özelinde incelemektedir. Araştırmada, yapay zekâ uygulamalarının geleneksel finansal analiz yöntemlerine kıyasla daha yüksek performans sergilediği ve yatırım kararlarını daha etkin hale getirdiği vurgulanmaktadır. Ayrıca çalışma, Türkiye'deki mevcut uygulamaları Avrupa Birliği ile karşılaştırarak, yapay zekâ kullanımına yönelik politika çerçevesi ve sektörel uygulamalar hakkında değerlendirmelerde bulunmakta ve çeşitli politika önerileri sunmaktadır (Coşkun, 2022).

Benzer şekilde, Özer (2025) tarafından gerçekleştirilen çalışma, yapay zekâ destekli yatırım öneri araçlarının bireysel yatırımcıların karar alma süreçleri üzerindeki etkisini incelemektedir. Araştırmada, robo-danışmanlar ve algoritmik platformlar gibi yapay zekâ tabanlı araçların, yatırımcıların veri temelli karar alma eğilimlerini artırdığı ortaya konulmuştur. UTAUT 2 modeli çerçevesinde yapılan analizler, performans beklentisi, alışkanlık ve deneyim gibi faktörlerin yapay zekâ kullanımını pozitif yönde etkilediğini; buna karşın risk alma eğiliminin negatif etkisi olduğunu göstermektedir. Ayrıca, Türkiye örnekleminde gerçekleştirilen çalışmada finansal okuryazarlık ve yapay zekâ okuryazarlığının kullanım üzerinde anlamlı bir etkisinin bulunmadığı tespit edilmiştir. Bu bulgular, bireysel

yatırımcıların yapay zekâ destekli araçlara yöneliminin davranışsal ve beklenti temelli faktörlerle şekillendiğini ortaya koymaktadır (Özer, 2025).

Uluslararası düzeyde ise, Muhsin ve Nasim tarafından gerçekleştirilen sistematik inceleme, finans alanında Açıklanabilir Yapay Zekâ (XAI) uygulamalarının gelişimini kapsamlı bir şekilde ele almaktadır. Çalışmada, finans sektöründe kullanılan XAI yöntemlerinin büyük ölçüde sonradan yorumlanabilirlik sağlayan tekniklere dayandığı; özellikle dikkat mekanizmaları, özellik önem analizi ve SHAP gibi yöntemlerin öne çıktığı belirlenmiştir. Ayrıca araştırma, finansal karar süreçlerinde doğruluk ile şeffaflık arasında denge kurulmasının önemine vurgu yaparak, çok disiplinli yaklaşımların gerekliliğini ortaya koymakta ve mevcut XAI uygulamalarındaki temel eksikliklere dikkat çekmektedir (Muhsin & Nasim 2025).

3. YAPAY ZEKÂ VE YATIRIM İLİŞKİSİ

Yapay zekâ, finansal yatırım süreçlerine yönelik literatürde iki ana eksenle ele alınmaktadır:

Veriye Dayalı Analiz ve Tahmin: AI modelleri, büyük veri setlerini işleyerek piyasa trendlerini ve finansal göstergeleri daha hızlı ve doğru bir şekilde tahmin edebilir. Bu tahminler, yatırımcılara geleneksel yöntemlere kıyasla yüksek performanslı karar destek sistemleri sağlar.

Karar Otomasyonu ve Stratejik Hizmetler: AI, portföy yönetimi ve risk değerlendirme süreçlerinde otomatik karar alma mekanizmaları sunar. Bu, insan faktöründen kaynaklanabilecek hataları azaltırken karar alma hızını artırır ve farklı piyasa koşullarına esnek yanıt imkânı sağlar.

Yatırım karar süreçlerinde AI'nın rolü aynı zamanda yeni yatırım stratejilerinin ortaya çıkmasına da zemin hazırlamıştır. Derin öğrenme, makine öğrenmesi ve doğal dil işleme gibi teknikler, yalnızca sayısal verilere değil, sosyal medya, haber akışı ve piyasa duyarlılığı gibi karmaşık veri türlerine de erişerek yatırımcı kararlarını daha bütüncül biçimde modelleyebilmektedir (Vinotha et al., 2024).

AI tabanlı yöntemlerin temel avantajı, büyük veri analizi ve tahmin performansındaki üstünlüktür. Geleneksel istatistiksel tekniklere göre AI modelleri, karmaşık finansal ilişkileri daha etkin şekilde yakalayabilir ve örüntü tanıma yetenekleri sayesinde yatırımcılar için

değerli öngörüler sağlayabilir. Ayrıca, XAI yaklaşımları gibi gelişmeler, AI modellerinin açıklanabilirliğini artırarak yatırımcı güvenini yükseltmekte ve risk yönetimi süreçlerini daha şeffaf hale getirmektedir (Arsenault et al., 2024).

Ayrıca, AI modelleri büyük veri ihtiyacı nedeniyle veri kalite sorunlarına duyarlıdır; eksik veya hatalı veriler model çıktılarının güvenilirliğini düşürebilir (Goodell et al., 2021). Ayrıca finansal piyasalar sürekli değiştiği için geçmiş veriye dayalı modeller her zaman gelecek performansı doğru tahmin edemeyebilir (Mahajan, 2024). Bu nedenlerle, literatürde AI tabanlı finansal modellerin geliştirilmesi kadar, bu modellerin anlaşılabilir, güvenilir ve hesap verebilir olmasının sağlanması üzerinde de yoğunlaşmaktadır (Bakralalı & Öndeş, 2025).

Bu çalışmanın kavramsal çerçevesi, yapay zekâ uygulamalarının yatırım karar verme süreçleri üzerindeki etkilerini sistematik bir yaklaşımla açıklamayı amaçlamaktadır. Literatürde yapay zekânın finansal karar süreçlerine entegrasyonunun, veri işleme kapasitesini artırarak karar kalitesini yükselttiği vurgulanmaktadır.

4. YAPAY ZEKÂ KAVRAMI VE TEMEL BİLEŞENLERİ

Yapay zekâ, insan zekâsına özgü öğrenme, çıkarım ve problem çözme yeteneklerini taklit eden sistemler olarak tanımlanmaktadır. Finansal piyasalarda yapay zekâ; büyük veri kümelerinin analiz edilmesi, örüntülerin tespit edilmesi ve geleceğe yönelik tahminlerin üretilmesi amacıyla kullanılmaktadır (Chen et al., 2023). Yapay zekânın yatırım karar verme süreçlerinde kullanımı, klasik finansal analiz yöntemlerine kıyasla daha dinamik ve uyarlanabilir modellerin geliştirilmesini mümkün kılmaktadır (Bahoo et al., 2024). Makine öğrenmesi, derin öğrenme ve doğal dil işleme teknikleri, yatırım kararlarında kullanılan temel yapay zekâ bileşenleri arasında yer almaktadır (Ahmed et al., 2022).

4.1. Yatırım Karar Verme Süreci ve Büyük Veri

Yatırım karar verme süreci; bilgi toplama, analiz, alternatiflerin değerlendirilmesi, karar alma ve performans izleme aşamalarından oluşmaktadır. Geleneksel yaklaşımlar sınırlı veri setleri ve insan uzmanlığına dayanırken, yapay zekâ destekli sistemler bu süreci veri temelli hale getirmektedir (Yıldız, 2022). Yapay zekâ, özellikle analiz ve alternatif değerlendirme aşamalarında belirsizliği azaltarak daha rasyonel yatırım kararlarının alınmasına katkı sağlamaktadır (Manogna & Anand, 2023).

Finansal piyasalarda üretilen verinin hacmi ve çeşitliliği, yatırım kararlarının büyük veri analitiği ile desteklenmesini zorunlu kılmıştır. Büyük veri, yapay zekâ sistemlerinin temel girdisini oluşturmakta; bu veriler karar destek sistemleri aracılığıyla yatırımcıya anlamlı çıktılar sunmaktadır (Ahmed et al., 2022). Yapay zekâ tabanlı karar destek sistemleri, yatırımcıların hızlı ve tutarlı kararlar almasını sağlarken, insan kaynaklı duygusal önyargıların etkisini azaltmaktadır (Özer, 2025).

4.2. Algoritmik Yatırım Yaklaşımları ve Açıklanabilir Yapay Zekâ

Algoritmik ticaret ve robo-danışman uygulamaları, yapay zekânın yatırım süreçlerindeki en somut kullanım alanları arasında yer almaktadır. Bu sistemler, önceden tanımlanmış kurallar ve öğrenen algoritmalar aracılığıyla yatırım kararlarını otomatikleştirmektedir (Goodell et al., 2021). Literatürde bu yaklaşımların piyasa etkinliğini artırdığı, ancak aynı zamanda şeffaflık sorunlarını da beraberinde getirdiği ifade edilmektedir (Jankova, 2021).

Açıklanabilir yapay zekâ (XAI), yapay zekâ modellerinin karar verme süreçlerini kullanıcılar açısından anlaşılır hale getirmeyi amaçlamaktadır. Finansal karar süreçlerinde XAI, yatırımcı güveninin artırılması ve düzenleyici gerekliliklerin karşılanması açısından kritik bir role sahiptir (Mohsin & Nasim, 2025). XAI yaklaşımları, yatırımcıların model çıktılarının nedenlerini anlayabilmesini sağlayarak kararların kabul edilebilirliğini artırmaktadır (CFA Institute, 2025).

4.3. Yatırım Performansı, Risk ve Güven Boyutu

Yapay zekâ uygulamalarının yatırım karar süreçlerindeki başarısı; getiri, risk yönetimi ve portföy çeşitlendirme performansı üzerinden değerlendirilmektedir (; Pattnaik et al., 2024). Literatürde yapay zekâ destekli sistemlerin risk tahmini ve portföy optimizasyonunda önemli avantajlar sunduğu belirtilmektedir (Bahoo et al., 2024). Bununla birlikte yatırımcı güveni ve etik boyut, bu sistemlerin sürdürülebilirliği açısından belirleyici unsurlar olarak öne çıkmaktadır (CFA Institute, 2025).

4.4. Yapay Zekâ Uygulamalarının Avantajları

Yapay zekâ tabanlı sistemlerin yatırım karar süreçlerinde kullanılmasının en önemli avantajı, büyük ve karmaşık veri setlerini insan kapasitesinin ötesinde analiz edebilme yeteneğidir. Finansal piyasalarda saniyeler içerisinde üretilen yüksek hacimli verilerin anlamlandırılması, geleneksel yöntemlerle sınırlıyken, yapay zekâ algoritmaları bu verilerden örüntüler çıkarabilmektedir (Chen et al., 2023).

Literatürde, yapay zekâ destekli tahmin modellerinin hisse senedi fiyat tahmini, volatilité analizi ve portföy optimizasyonu gibi alanlarda daha yüksek doğruluk sunduğu vurgulanmaktadır (Manogna & Anand, 2023). Özellikle makine öğrenmesi algoritmaları, geçmiş piyasa davranışlarını öğrenerek geleceğe yönelik daha tutarlı öngörüler sunabilmektedir (Şahin, 2024).

Bir diğér önemli avantaj, duygusal önyargıların azaltılmasıdır. Geleneksel yatırım kararları çoğu zaman yatırımcı psikolojisinden etkilenirken, yapay zekâ tabanlı sistemler rasyonel ve veri temelli kararlar üretmektedir (Goodell et al., 2021). Bu durum, aşırı iyimserlik veya panik satışları gibi davranışsal finans kaynaklı hataların azaltılmasına katkı sağlamaktadır.

Ayrıca algoritmik ticaret ve robo-danışman uygulamaları, yatırım kararlarını otomatikleştirerek işlem hızını artırmakta ve işlem maliyetlerini düşürmektedir (Jankova, 2021). Bu sistemler, yatırımcılara daha geniş bir yatırım evrenine erişim imkânı sunmaktadır.

4.5. Yapay Zekâ Uygulamalarının Riskleri ve Sınırlılıkları

Yapay zekâ uygulamalarının sağladığı avantajlara rağmen, literatürde önemli risk ve sınırlılıklara da dikkat çekilmektedir. Özellikle derin öğrenme modellerinin karar süreçlerinin anlaşılabilir olmaması, yatırımcılar ve düzenleyici kurumlar açısından ciddi bir sorun oluşturmaktadır (Coşkun, 2022). Şeffaflık eksikliği, yatırımcı güvenini zayıflatmakta ve yapay zekâ sistemlerinin yaygın kullanımını sınırlayabilmektedir. Bu bağlamda açıklanabilir yapay zekâ (XAI) yaklaşımlarının geliştirilmesi, literatürde temel bir gereklilik olarak ifade edilmektedir (Mohsin & Nasim, 2025).

Bir diğér önemli risk, veri yanlışlığıdır. Yapay zekâ modellerinin eğitildiği veri setleri eksik veya hatalı olduğunda, üretilen yatırım kararları da yanıltıcı olabilmektedir (Bahoo et al., 2024). Bu durum özellikle kriz dönemlerinde model performansının düşmesine yol açabilmektedir. Ayrıca algoritmik sistemlerin yaygınlaşması, piyasalarda sistemik risk oluşturabilmektedir. Aynı veya benzer algoritmaların eş zamanlı olarak benzer kararlar alması, ani fiyat dalgalanmalarına ve likidite sorunlarına neden olabilmektedir (Pattnaik et al., 2024).

4.6. Etik ve Regülasyon Boyutu

Yapay zekâ uygulamalarının yatırım karar süreçlerinde kullanımı, etik ve düzenleyici tartışmaları da beraberinde getirmektedir. Literatürde veri gizliliği, algoritmik ayrımcılık ve sorumluluk paylaşımı gibi konular ön plana çıkmaktadır (CFA Institute, 2025). Özellikle finansal piyasalarda yapay zekâ sistemlerinin aldığı hatalı kararların sorumluluğunun kimde

olacağı konusu henüz netlik kazanmamıştır. Bu nedenle birçok çalışmada, yapay zekânın tam otomasyon yerine insan denetimi altında kullanılması gerektiği vurgulanmaktadır (Chen et al., 2023).

5. YÖNTEM

Bu çalışmada, yatırım karar verme süreçlerinde yapay zekâ temelli modellerin etkinliğini değerlendirmek amacıyla nicel (quantitative) araştırma yöntemi kullanılmıştır. Nicel araştırma yaklaşımı, sayısal veriler üzerinden objektif sonuçlara ulaşmayı mümkün kıldığı için finansal modelleme çalışmalarında yaygın olarak tercih edilmektedir. Araştırma tasarımı, finansal zaman serisi analizi ile makine öğrenmesi ve derin öğrenme tabanlı tahmin modellerinin karşılaştırmalı performans analizine dayanmaktadır. Bu kapsamda, geleneksel istatistiksel yöntemler ile yapay zekâ algoritmaları aynı veri seti üzerinde uygulanmış ve elde edilen sonuçlar karşılaştırmalı olarak analiz edilmiştir.

Ayrıca çalışma, yalnızca tahmin doğruluğunu değil, aynı zamanda yatırım karar süreçlerine etkisini de değerlendirmeyi amaçlamaktadır. Bu doğrultuda modellerin ürettiği sinyaller üzerinden teorik yatırım stratejileri oluşturularak performans farklılıkları risk ve getiri perspektifinden incelenmiştir. Böylece yapay zekâ tabanlı yaklaşımların finansal piyasalarda geleneksel yöntemlere kıyasla sağladığı potansiyel avantajlar daha kapsamlı bir şekilde ele alınmıştır.

5.1. Araştırma Modeli

Araştırmada karşılaştırmalı bir araştırma modeli benimsenmiştir. Bu model, yapay zekâ tabanlı yatırım karar modelleri ile geleneksel finansal analiz yöntemlerinin performanslarının karşılaştırılmasına dayanmaktadır. Model iki ana gruptan oluşmaktadır:

- Yapay zekâ tabanlı modeller
- Geleneksel zaman serisi modelleri

Bu karşılaştırmalı yaklaşım, yapay zekâ uygulamalarının yatırım karar süreçlerine sağladığı katkıların daha net bir şekilde ortaya konmasına imkân tanımaktadır (Manogna & Anand, 2023).

5.2. Veri Seti ve Veri Kaynakları

Araştırmada kullanılan veriler, kamuya açık ve güvenilir finansal veri sağlayıcılarından elde edilen ikincil verilerden oluşmaktadır. Veri seti; günlük kapanış fiyatları, günlük getiriler ve işlem hacmi gibi değişkenleri içermektedir. İkincil veri analizi, finans alanında yaygın olarak kullanılan bir yöntem olup, geniş zaman aralıklarını kapsayan veri setleriyle çalışma imkânı sunmaktadır (Atsalakis & Valavanis, 2009). Ayrıca bu yöntem, veri toplama sürecinde oluşabilecek yanlışlık riskini azaltmaktadır.

Çalışmada kullanılan veri seti, Borsa İstanbul (BIST 100) endeksine ait 01.01.2016 – 31.12.2025 tarihleri arasındaki günlük kapanış fiyatlarından oluşmaktadır. Bu dönem, Türkiye finansal piyasalarında kriz, toparlanma, pandemi ve enflasyonist süreçler gibi farklı ekonomik rejimlerin gözlemlenmesine imkân tanınması nedeniyle tercih edilmiştir.

Veriler;

- Borsa İstanbul
- Kamuyu Aydınlatma Platformu (KAP)
- Investing.com

gibi güvenilir kaynaklardan temin edilmiştir. Veri seti eksik gözlem içermeyecek şekilde düzenlenmiş ve yalnızca işlem günleri dikkate alınmıştır.

Veri ön işleme sürecinde, ham fiyat serileri doğrudan kullanılmak yerine geleneksel finansal yöntemlerden biri olan basit getiri hesaplaması ile günlük getiri serileri elde edilmiştir. Günlük getiri şu formül ile hesaplanmıştır:

$$R_t = \frac{P_t - P_{t-1}}{P_{t-1}} \quad (1)$$

Ayrıca model performansını artırmak amacıyla veriler Min-Max Normalizasyon yöntemi ile 0–1 aralığına ölçeklendirilmiştir. Bu işlem özellikle yapay sinir ağlarının daha stabil öğrenme gerçekleştirmesine katkı sağlamaktadır (Campbell, Lo, & MacKinlay, 1997).

5.3. Yapay Zekâ Modelleri

Araştırmada yapay zekâ tabanlı yatırım karar modelleri olarak makine öğrenmesi ve derin öğrenme yaklaşımları kullanılmıştır. Özellikle Uzun Kısa Süreli Bellek (LSTM) modeli, finansal zaman serilerinde uzun dönemli bağımlılıkları yakalayabilme yeteneği nedeniyle tercih edilmiştir (Fischer & Krauss, 2018). Bununla birlikte Random Forest algoritması, çoklu

karar ağaçlarına dayalı yapısı sayesinde finansal tahmin problemlerinde güçlü performans sergileyen yöntemlerden biri olarak literatürde yer almaktadır (Krauss et al., 2017).

LSTM modeli oluşturulurken veri seti belirli zaman pencerelerine (time window) bölünerek giriş dizileri oluşturulmuştur. Bu yaklaşımda model, geçmiş n günlük veriyi kullanarak bir sonraki günün yönünü tahmin edecek şekilde eğitilmiştir. Random Forest modeli ise çoklu karar ağaçlarının ortalaması alınarak tahmin üreten bir topluluk (ensemble) yöntemi olarak yapılandırılmıştır. Modelde ağaç sayısı ve maksimum derinlik gibi hiperparametreler çapraz doğrulama (cross-validation) yöntemi ile optimize edilmiştir (Hochreiter & Schmidhuber 1997).

5.4. Geleneksel Finansal Modeller

Karşılaştırma amacıyla çalışmada geleneksel finansal yöntemler, yani yapay zekâ tabanlı yaklaşımlardan farklı olarak istatistiksel ve ekonometrik temellere dayanan, uzun yıllardır finans literatüründe yaygın biçimde kullanılan modeller de ele alınmıştır. Bu yöntemler, genellikle tahminleme ve karşılaştırma analizlerinde referans (benchmark) olarak kullanılan klasik yaklaşımlar olup, veri yapısına ilişkin varsayımlara dayalı olarak çalışmaktadır (Atsalakis & Valavanis, 2009). Bu kapsamda çalışmada ARIMA modeli ve hareketli ortalama yöntemleri gibi geleneksel zaman serisi tekniklerine yer verilmiştir.

ARIMA modeli için uygun p , d ve q parametreleri ACF ve PACF grafikleri incelenerek belirlenmiş ve model performansı Akaike Bilgi Kriteri (AIC) en düşük olacak şekilde optimize edilmiştir. Bu geleneksel modeller, yapay zekâ tabanlı yaklaşımların tahmin performansını değerlendirmek amacıyla temel karşılaştırma grubu olarak kullanılmıştır (Box et. al, 2015).

5.5. Performans Değerlendirme Kriterleri

Modellerin başarısı, yatırım performansı ve risk temelli ölçütler kullanılarak değerlendirilmiştir. Literatürde yaygın olarak kullanılan performans kriterleri şunlardır:

- Ortalama getiri
- Volatilité
- Sharpe oranı
- Maksimum düşüş (Maximum Drawdown)

Bu ölçütler, yatırım stratejilerinin getiri-risk dengesi açısından değerlendirilmesine imkân tanımaktadır (Fischer & Krauss, 2018).

Sharpe oranı şu şekilde hesaplanmıştır:

$$S = \frac{R_p - R_f}{\sigma_p} \quad (2)$$

Burada R_p portföy getirisi, R_f risksiz getiri oranı ve σ_p portföyün standart sapmasını ifade etmektedir (Sharpe, 1966).

5.6. Veri Analizi Süreci

Veri analizi süreci, veri temizleme ve eksik gözlemlerin giderilmesi ile başlamıştır. Ardından veriler normalize edilerek modelleme sürecine uygun hale getirilmiştir. Veri seti eğitim ve test kümelerine ayrılarak modellerin genellenebilirliği test edilmiştir.

Eğitim ve test ayrımı %80 eğitim – %20 test olacak şekilde gerçekleştirilmiş, böylece modellerin geçmiş veriden öğrenip öğrenemediği ve yeni verilerdeki performansı değerlendirilmiştir. Model performansları test verisi üzerinde değerlendirilmiş ve elde edilen sonuçlar yatırım performansı kriterleri doğrultusunda karşılaştırılmıştır. Bu analiz yaklaşımı, finansal zaman serisi çalışmalarında yaygın olarak kullanılan standart bir yöntemdir (Sezer et al., 2020).

Ayrıca modellerin karşılaştırılması yalnızca tahmin doğruluğu üzerinden değil, aynı zamanda yatırım getirisi simülasyonu üzerinden de yapılmış; her modelin oluşturduğu sinyaller doğrultusunda teorik portföy getirileri hesaplanmıştır.

6. BULGULAR

Bu çalışmada yatırım karar verme süreçlerinde yapay zekâ temelli modellerin etkinliği, Borsa İstanbul (BIST 100) endeksinin 1 Ocak 2016–31 Aralık 2025 dönemine ait günlük kapanış verileri üzerinden incelenmiştir. On yıllık bu dönem; politik belirsizlikler, kur şokları, küresel COVID-19 pandemisi, genişleyici para politikaları ve yüksek enflasyonist süreçler gibi farklı makroekonomik rejimleri içermesi bakımından heterojen bir yapı sergilemektedir. Bu çeşitlilik, finansal zaman serilerinin farklı volatilité ve trend dinamikleri altında nasıl davrandığını gözlemlene ve farklı model yaklaşımlarının performansını karşılaştırma açısından uygun bir deneysel çerçeve sunmaktadır. Bu bağlamda, yalnızca model doğruluğu değil, aynı zamanda modelin kararlarını hangi değişkenlere dayandığına açıklanabilir olması (XAI yaklaşımı) da yatırım karar süreçlerinde kritik bir değerlendirme kriteri haline gelmiştir (Ribeiro et al., 2016).

Finansal zaman serileri genellikle durağan değildir ve varyansları zaman içinde değişkenlik gösterebilir. Bu nedenle analiz sürecinde fiyat seviyeleri yerine logaritmik getiriler kullanılmıştır. Logaritmik getiri dönüşümü, özellikle yüksek enflasyon ve hızlı fiyat artışı dönemlerinde serinin istatistiksel özelliklerini daha kararlı hale getirmekte ve parametrik modeller için uygun bir yapı oluşturmaktadır (Campbell, Lo & MacKinlay, 1997). Günlük logaritmik getiriler aşağıdaki şekilde hesaplanmıştır:

$$r_t = \ln \left(\frac{P_t}{P_{t-1}} \right) \quad (3)$$

Burada P_t ilgili günün kapanış fiyatını, P_{t-1} ise bir önceki günün kapanış fiyatını göstermektedir.

Günlük logaritmik getiriler hesaplandıktan sonra risk göstergesi olarak hareketli standart sapma (volatilite) ölçülmüştür:

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (r_i - \bar{r})^2} \quad (4)$$

Volatilite, modern portföy teorisinde riskin temel nicel göstergesi olarak kabul edilmektedir (Markowitz, 1952). Volatilite ve getiri gibi değişkenlerin model çıktıları üzerindeki etkisinin yorumlanabilir hale getirilmesi, XAI yöntemlerinin finansal analizlerde kullanımını zorunlu kılmaktadır. Özellikle SHAP (Shapley Additive Explanations) ve LIME gibi yöntemler, yapay zekâ modellerinin hangi piyasa koşullarında hangi değişkenlere ağırlık verdiğini açıklayarak “kara kutu” problemine çözüm sunmaktadır

6.1. BIST 100 Endeksinde Risk ve Getiri Dinamiklerinin Geleneksel İstatistiksel Analizi: 2016–2018 Dönemi Betimsel Göstergeleri

BIST 100 endeksinin 2016–2025 yılları arasındaki performansını geleneksel betimsel istatistik yöntemleriyle analiz etmektedir. Tabloda sunulan ortalama getiri ve standart sapma gibi veriler, piyasanın risk-getiri dengesini ortaya koyarken; analiz kısmı bu verileri finans literatüründeki Etkin Piyasa Hipotezi ve geleneksel risk yönetimi çerçevesinde yorumlamaktadır.

Tablo 1. 2016–2018: Volatilite ve Siyasi Risk Dönemi

Yıl	Ort. Getiri (%)	Standart Sapma (%)	Max Değer	Min Değer	Toplam Getiri (%)
2016	0,042	1,30	863,44	685,68	%10,81
2017	0,159	0,99	1.153,33	761,44	%48,33
2018	-0,084	1,39	1.208,45	871,43	%-22,34

Kaynak: Yazar tarafından oluşturulmuştur.

İncelenen dönemin ilk evresi olan 2016–2018 yılları, düşük bazlı fiyat seviyelerinden başlayan ancak artan jeopolitik ve makroekonomik risklerle şekillenen bir süreci temsil etmektedir.

2016 yılında BIST 100 endeksi, %1,30'luk bir standart sapma (volatilite) eşliğinde %10,81 toplam getiri sağlayarak yıla başlamıştır. Ortalama getirinin %0,042 gibi görece düşük bir seviyede kalması, piyasanın yıl boyu jeopolitik riskler ve makroekonomik belirsizlikler nedeniyle baskı altında kaldığını göstermektedir. Geleneksel analiz açısından bu durum, yüksek oynaklığa rağmen getiri oranının sınırlı kaldığı "riskli ama verimi düşük" bir piyasa yapısını yansıtır.

2017 yılında standart sapmanın (volatilite) dönem içindeki en düşük düzeye (%0,99) gerilemesi ve endeksin %48,33 toplam getiri sağlaması, piyasanın daha öngörülebilir bir yapıda olduğunu göstermektedir. Geleneksel finans teorisi çerçevesinde bu durum, düşük risk primine karşılık yüksek gerçekleşen getiri ile açıklanabilir. Fiyat hareketlerinin daha lineer bir seyir izlemesi, geçmiş fiyat verilerine dayalı geleneksel teknik analiz ve temel analiz yöntemlerinin başarısını artırmıştır. Bu istikrarlı rejim, yatırımcı güveninin yükseldiği ve piyasa etkinliğinin tartışıldığı bir döneme karşılık gelir.

Buna karşılık 2018 yılında yaşanan %-22,34'lük toplam kayıp ve standart sapmanın %1,39'a yükselmesi, piyasa yapısında keskin bir kırılmaya işaret etmektedir. Literatürde "Siyah Kuğu" (Black Swan) olarak adlandırılan düşük olasılıklı ancak yüksek etkili jeopolitik olaylar, piyasanın risk-getiri dengesini bozmuştur. Bu tür ekstrem dönemlerde, ani fiyat hareketleri ve artan oynaklık, geçmiş verilere dayalı geleneksel istatistiksel tahmin modellerinin performansını sınırlamaktadır.

Sonuç olarak; bu on yıllık kesitin başlangıcı, finansal piyasaların riskli yapısını doğrular niteliktedir. Artan volatilite (2018), geleneksel risk yönetimi araçlarının önemini ortaya koyarken; piyasadaki ani rejim değişimlerinin sadece istatistiksel verilerle değil, makroekonomik duyarlılıklarla birlikte analiz edilmesinin gerekliliğini vurgulamaktadır.

Tablo 2. 2019–2021: Pandemi ve İyileşme Süreci

Yıl	Ort. Getiri (%)	Standart Sapma (%)	Max Değer	Min Değer	Toplam Getiri (%)
2019	0,099	1,30	1.147,54	836,75	%28,76
2020	0,115	1,66	1.479,91	842,46	%27,38
2021	0,106	1,62	2.278,55	1.330,48	%24,22

Kaynak: Yazar tarafından oluşturulmuştur.

2019–2021 dönemi, küresel pandemi şokunun finansal piyasalar üzerindeki etkisini ve sonrasındaki toparlanma sürecini betimsel verilerle açıkça yansıtmaktadır. 2019 Yılı: Dengeli Büyüme: 2019 yılında endeks, %1,30’luk bir standart sapma ile %28,76 toplam getiri sağlayarak stabil bir büyüme performansı sergilemiştir. Bu dönemde fiyat hareketleri, geleneksel temel analiz değişkenleriyle daha uyumlu bir seyir izlemiştir.

2020 yılı, yüksek volatilité ve likidite etkisi pandeminin damga vurduğu 2020 yılında standart sapmanın %1,66’ya yükselmesi, piyasadaki sistematik riskin arttığını kanıtlamaktadır. Geleneksel risk-getiri teorisine göre riskin bu denli yükseldiği dönemlerde yatırımcıların güvenli limanlara yönelmesi beklense de endeksin %27,38 getiri sağlaması dikkat çekicidir. Bu durum, genişleyici para politikaları ve düşük faiz ortamının yarattığı likidite bolluğunun, artan riski dengeleyerek piyasayı desteklediğini göstermektedir.

2021 yılı, oynaklığın kalıcılığı ve nominal artış 2021 yılında volatilitenin (%1,62) yüksek seyretmeye devam etmesi, pandeminin piyasa üzerindeki belirsizlik etkisinin sürdüğüne işaret etmektedir. Buna rağmen endeksin nominal bazda yükselişini sürdürerek %24,22 toplam getiri sağlaması, yatırımcıların enflasyonist beklentilere karşı hisse senedi piyasasını bir korunma aracı olarak kullandığını düşündürmektedir.

Sonuç olarak; bu üç yıllık süreç, geleneksel istatistiksel modellerin sınırlarını zorlayan bir oynaklık sergilemiştir. Artan standart sapma değerleri, piyasa etkinliğinin azaldığı ve fiyat hareketlerinin doğrusal olmayan (non-linear) bir yapıya evrildiği dönemlerde, klasik risk yönetimi araçlarının makroekonomik verilerle desteklenmesinin kritik önemini ortaya koymaktadır

Tablo 3. 2022–2025: Hiper-Enflasyonist Dönem ve Nominal Zirveler

Yıl	Ort. Getiri (%)	Standart Sapma (%)	Max Değer	Min Değer	Toplam Getiri (%)
2022	0,448	1,80	5.509,16	1.851,38	%185,94
2023	0,150	2,37	8.513,54	4.400,76	%31,96
2024	0,121	1,45	11.172,75	7.412,04	%28,94
2025	0,066	1,53	11.529,81	9.008,87	%13,05

Kaynak: Yazar tarafından oluşturulmuştur.

2022–2025 dönemi, BIST 100 endeksinin makroekonomik rejim değişimlerine bağlı olarak tarihsel nominal zirvelere ulaştığı ve oynaklığın karakteristik bir yapı sergilediği süreci yansıtmaktadır. 2022 yılında kaydedilen %185,94'lük olağanüstü artış, yüksek enflasyonun nominal varlık fiyatları üzerindeki etkisini açıkça ortaya koymaktadır. Bu durum, yalnızca finansal bir yükseliş değil, aynı zamanda yatırımcıların satın alma güçlerini koruma amacıyla hisse senedi piyasasına yönelmesiyle oluşan bir reel varlık fiyatlaması olarak değerlendirilmelidir. Geleneksel analiz açısından bu süreç, düşük reel faiz ortamının hisse senedi çarpanları üzerindeki etkisini göstermektedir.


2023 yılında standart sapmanın %2,37 ile dönem zirvesine ulaşması, piyasanın "gürültülü" ve öngörülemez bir karaktere büründüğünü kanıtlamaktadır. Klasik finans teorisinde bu denli yüksek bir standart sapma, sistematik riskin (politika faizi, döviz kuru şokları vb.) fiyatlar üzerinde yarattığı baskıyı temsil eder. Bu durum, piyasa etkinliğinin azaldığı ve geleneksel istatistiksel tahmin modellerinin hata payının en yüksek seviyeye çıktığı döneme karşılık gelir.

2024 ve 2025 yıllarında toplam getirilerin sırasıyla %28,94 ve %13,05 seviyelerine gerilemesi, piyasanın nominal şok sonrası bir denge arayışına girdiğine işaret etmektedir. Standart sapmanın %1,50 bandına oturması, volatilitenin göreceli olarak stabilize olduğunu gösterse de getirilerdeki azalma "risksiz faiz oranının" alternatif bir maliyet olarak piyasa üzerindeki baskısını yansıtmaktadır. Sonuç olarak; bu dört yıllık süreç, geleneksel istatistiksel modellerin ve risk yönetimi araçlarının en çok zorlandığı "uç rejim" (outlier regime) dönemidir. Artan standart sapma değerleri, bilgi sinyallerinin gürültü içerisinde kaybolduğunu ve yatırım karar süreçlerinde geleneksel risk-getiri rasyolarının (Sharpe oranı vb.) yeniden değerlendirilmesi gerektiğini ortaya koymaktadır.

6.2. BİST 100 Endeksinin Yapay Zekâ Temelli Analizi: LSTM Derin Öğrenme Modeli ile Getiri ve Volatilite Öngörüsü

BIST 100 endeksinin 2016–2025 dönemindeki hareketlerini LSTM derin öğrenme mimarisiyle analiz ederek; geleneksel modellerin yetersiz kaldığı karmaşık piyasa koşullarında yapay zekânın geçmişini hatırlama ve adaptif öğrenme kabiliyetini ortaya koymaktadır. Temel amaç, yüksek belirsizlik dönemlerinde derin öğrenme modellerinin yatırım kararları için ne kadar güçlü bir bilimsel öngörü aracı olduğunu kanıtlamaktır.

Şekil 1. 2016- 2025 BİST 100 Endeksinin Derin Öğrenme Temelli Analizi: LSTM



Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 1, 2016–2025 dönemine ait BİST 100 endeksinin yıllık getiri ve volatilite dinamiklerini ortaya koymakta ve bu yapı yapay zekâ (YZ) tabanlı LSTM (Long Short-Term Memory) modeli ile analiz edilmektedir. Model, zaman serisi verilerinden geçmiş örüntüleri öğrenerek geleceğe yönelik tahminler üretmekte ve yatırım karar verme süreçlerinde belirsizlik ile öngörülebilirlik arasındaki ilişkiyi değerlendirmeye imkân sağlamaktadır. Şekilde görülen bulgular, piyasanın yüksek derecede doğrusal olmayan (non-linear) bir yapıya sahip olduğunu ve zaman içinde farklı rejimlere geçiş yaptığını göstermektedir. Özellikle 2022 yılında ortaya çıkan yaklaşık %186’lık ani yükseliş, belirgin bir rejim değişimini ifade etmekte ve piyasa yapısında güçlü bir kırılma yaşandığını ortaya koymaktadır. Bu durum, geleneksel lineer modellerin bu tür aşırı oynaklık ve ani değişimleri açıklamada yetersiz kaldığını, buna

karşılık yapay zekâ temelli LSTM modelinin adaptif öğrenme kapasitesi sayesinde bu tür yapısal değişimleri daha etkin biçimde yakalayabildiğini göstermektedir.

2023–2025 döneminde ise getirilerde gözlenen görece normalleşme, piyasanın şok sonrası denge arayışına girdiğini ve volatilitenin daha dengeli bir yapıya evrildiğini ortaya koymaktadır. Genel olarak şekil, finansal piyasalardaki karmaşık yapı, yüksek volatilité ve rejim değişimlerinin yatırım karar süreçlerini doğrudan etkilediğini; bu nedenle yapay zekâ tabanlı modellerin, özellikle LSTM gibi derin öğrenme yaklaşımlarının, geleneksel yöntemlere kıyasla daha güçlü bir analiz ve karar destek aracı olarak öne çıktığını göstermektedir. Öngörücü bir sistemden ziyade, sürekli öğrenen ve adaptif bir araç olarak değerlendirilmelidir.

6.3. Geleneksel ve Yapay Zekâ Modellerinin Karşılaştırmalı Analizi

Karar verme süreçlerinde kullanılan iki ana yöntem olan Doğrusal Regresyon (Geleneksel) ve Rastgele Orman (AI) modellerinin yıllık başarı oranları aşağıda karşılaştırılmıştır.

Tablo 4. Model Performans Matrisi (Directional Accuracy)

Yıl	Geleneksel Model (LR)	Yapay Zekâ (RF)	Fark (AI Avantajı)
2016	0,52	0,57	+0,05
2017	0,58	0,62	+0,04
2018	0,47	0,54	+0,07
2019	1,001	1,012	+0,11
2020	0,51	0,58	+0,07
2021	0,56	0,71	0,14
2022	0,72	0,62	-0,10
2023	0,42	0,46	+0,04
2024	0,33	0,35	+0,02
2025	0,37	0,44	+0,07

Kaynak: Yazar tarafından oluşturulmuştur.

Model performansları yön tahmin doğruluğu (Directional Accuracy) metriği ile karşılaştırılmıştır:

$$DA = \frac{\text{Doğru Yön Tahmini Sayısı}}{\text{Toplam Gözlem Sayısı}} \quad (5)$$

Tablo 4’te sunulan model performans matrisi incelendiğinde, bulgular genel olarak Rastgele Orman modelinin analiz edilen on yılın dokuzunda doğrusal regresyona kıyasla daha yüksek performans sergilediğini göstermektedir. Ancak analiz yalnızca tahmin başarısıyla sınırlı tutulmamış, XAI temelli değerlendirme yapılarak Rastgele Orman modelinin üstün performansının yanı sıra kararlarının hangi piyasa değişkenlerinden kaynaklandığı da şeffaf bir biçimde analiz edilmiştir.

SHAP (SHapley Additive exPlanations) analizleri, volatilite ve geçmiş getiri değişkenlerinin özellikle belirsizlik dönemlerinde model kararlarını domine ettiğini göstermektedir. Özellikle volatilitenin yükseldiği 2020 ve 2025 yıllarında, yapay zekâ modelinin doğrusal olmayan örüntüleri tanıma kabiliyeti sayesinde sağladığı avantaj belirginleşmiştir. Buna karşılık, 2022 gibi güçlü ve tek yönlü trend içeren yıllarda geleneksel doğrusal modelin %0,72 doğruluk oranı ile daha yüksek performans göstermesi dikkat çekicidir. Bu durum XAI açısından değerlendirildiğinde, doğrusal modellerin daha şeffaf ve deterministik karar yapısı sayesinde trend dönemlerinde daha “açıklanabilir ve izlenebilir” tahminler üretebildiğini, buna karşın makine öğrenmesi modellerinin bu tür keskin trendlerde aşırı uyum (overfitting) riski taşıyabildiğini ortaya koymaktadır.

Genel olarak değerlendirildiğinde, yapay zekâ temelli model özellikle volatilitenin yükseldiği ve piyasa yapısının karmaşıklaştığı dönemlerde daha istikrarlı performans sunmuştur. Bununla birlikte XAI bulguları, başarının sadece sayısal doğrulukla değil, aynı zamanda karar gerekçelerinin rasyonel ve anlaşılabilir olmasıyla ölçülmesi gerektiğini göstermektedir. Sonuç olarak, yatırım karar mekanizmalarında hibrit yaklaşımların kullanılması gerektiği vurgulanmıştır. Bu hibrit yapı, yalnızca geleneksel finansal modeller ve makine öğrenmesi algoritmalarının birleşimi değil, aynı zamanda XAI yöntemleri ile denetlenebilen şeffaf bir "Karar Destek Sistemi" olarak tasarlanmalıdır.


Sonuç olarak, BIST 100 endeksi üzerinden gerçekleştirilen bu on yıllık analiz, yapay zekâ modellerinin yatırım karar verme süreçlerinde özellikle belirsizlik ve yüksek volatilite dönemlerinde geleneksel yöntemlere göre anlamlı bir katma değer sağladığını göstermektedir. Ancak güçlü trend dönemlerinde geleneksel modellerin etkinliğini koruması, geleneksel finans teorileri ile modern makine öğrenmesi tekniklerinin birlikte kullanılmasının daha dengeli sonuçlar üretebileceğini kanıtlamaktadır. Bu bulgular, finans literatüründeki Zayıf Formda Etkin Piyasa Varsayımının, yapay zekâ algoritmalarının gizli örüntüleri tanıma kapasitesi ışığında yeniden değerlendirilmesi gerektiğini bilimsel bir temele oturtmaktadır.

6.4. BIST 100 Endeksinde Rejim Değişimlerinin Analizi: Geleneksel Modeller ve Yapay Zekâ Temelli Hibrit Bir Yaklaşım

Finansal piyasaların dinamik ve doğrusal olmayan yapısını anlamlandırmak amacıyla geleneksel istatistiksel yöntemler ile yapay zekâ tabanlı algoritmaları bir araya getiren hibrit bir analiz çerçevesi sunmaktadır. BIST 100 endeksinin 2016–2025 dönemine odaklanan analiz; düşük volatiliteli trend dönemlerinde geleneksel modellerin yüksek açıklama gücünden, kriz ve rejim değişimi gibi karmaşık dönemlerde ise yapay zekânın (LSTM,

Rastgele Orman vb.) adaptif öğrenme kapasitesinden yararlanmaktadır. Bu bütünleşik yaklaşım, tek yönlü modellerin eksikliklerini gidererek farklı piyasa koşullarında daha dayanıklı ve dengeli bir karar destek mekanizması oluşturmayı hedeflemektedir.

Şekil 2. 2016–2025 Dönemine Ait BIST 100 Endeksi Günlük Kapanış Fiyatları ve 30 Günlük Hareketli Volatilite Zaman Serisi



Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 2’de sunulan grafik, piyasa dinamiklerini hem fiyat hareketleri hem de risk göstergeleri üzerinden eş zamanlı sunduğu için hibrit bir veri setini temsil etmektedir. Grafikteki mavi çizgi (Fiyat), özellikle doğrusal trendlerin hâkim olduğu dönemlerde geleneksel modellerin (Doğrusal Regresyon vb.) çalışma alanını; kırmızı çizgi (Volatilite) ise piyasadaki karmaşıklığı ve risk değişimlerini temsil ederek yapay zekâ temelli modellerin (Rastgele Orman, LSTM vb.) çözümlemesi gereken doğrusal olmayan yapıyı simgelemektedir.

Şekil 2’de sunulan zaman serisi incelendiğinde, BIST 100 endeksinin 2016–2025 döneminde farklı makroekonomik koşullara bağlı olarak belirgin rejim değişimleri sergilediği görülmektedir. Özellikle 2020 yılında pandemi etkisiyle volatilitenin arttığı, 2022 sonrasında ise enflasyonist baskılarla birlikte fiyat seviyelerinde hızlı ve sürekli bir yükseliş trendinin olduğu dikkat çekmektedir. Bu durum, finansal zaman serilerinin durağan olmayan ve doğrusal olmayan bir yapı sergilediğini ortaya koymaktadır.

Zaman serisinde gözlemlenen bu dalgalı ve rejime bağılı yapı, kullanılan model türlerinin performansını doğrudan etkilemektedir. İstatistiki temellere dayanan geleneksel modeller, özellikle güçlü ve tek yönlü trendlerin hâkim olduğu dönemlerde daha başarılı sonuçlar üretmektedir. Nitekim 2022 yılında gözlemlenen yüksek doğrusal trend, geleneksel bir yaklaşım olan Doğrusal Regresyon modelinin daha yüksek doğruluk oranına ulaşmasını açıklamaktadır. Bu tür dönemlerde piyasa hareketlerinin belirgin bir yön izlemesi, basit doğrusal yapıların tahmin gücünü artırmaktadır.

Buna karşılık, volatilitenin yükseldiği ve piyasa dinamiklerinin karmaşıklaştığı dönemlerde yapay zekâ temelli modellerin üstünlüğü daha belirgin hale gelmektedir. Özellikle pandemi sürecini içeren 2020 yılı ve belirsizliğin yüksek olduğu dönemlerde, bir yapay zekâ disiplini olan Rastgele Orman gibi makine öğrenmesi algoritmaları, doğrusal olmayan ilişkileri ve karmaşık örüntüleri yakalayabilme kapasitesi sayesinde daha yüksek tahmin performansı sergilemiştir.

Genel olarak değerlendirildiğinde, Şekil 2’de ortaya konan zaman serisi yapısı, model performanslarına ilişkin bulgularla tutarlılık göstermektedir. Finansal piyasaların dönemsel olarak değişen yapısı, tek bir modelin tüm koşullarda üstün performans göstermesini engellemekte; bu durum, yatırım karar süreçlerinde hibrit yaklaşımların önemini ortaya koymaktadır. Dolayısıyla hem geleneksel finansal modellerin hem de yapay zekâ temelli yöntemlerin birlikte kullanılması, farklı piyasa rejimlerine uyum sağlayabilen daha dengeli ve etkili karar mekanizmalarının geliştirilmesine katkı sağlayacaktır.

7. SONUÇ

Bu çalışmada, Borsa İstanbul (BIST 100) endeksine ait 01.01.2016 – 31.12.2025 dönemini kapsayan günlük kapanış verileri kullanılarak yatırım karar verme süreçlerinde geleneksel istatistiksel yöntemler ile yapay zekâ temelli modellerin performansı karşılaştırmalı olarak analiz edilmiştir. On yıllık bu dönem; siyasi belirsizlikler, kur şokları, küresel pandemi, genişleyici para politikaları ve yüksek enflasyonist süreçler gibi farklı makroekonomik rejimleri içermesi bakımından oldukça heterojen bir yapı sergilemektedir. Bu durum, modellerin farklı piyasa koşulları altındaki davranışlarını gözlemlemek açısından önemli bir deneysel zemin oluşturmuştur. Ayrıca bu heterojenlik, finansal piyasalarda “tek model üstünlüğü” varsayımını zayıflatmakta ve model kararlarının yalnızca doğruluk değil, aynı zamanda açıklanabilirlik (XAI) boyutuyla değerlendirilmesini zorunlu kılmaktadır.

Çalışmada fiyat seviyeleri yerine logaritmik getirilerin kullanılması, finansal zaman serilerinin durağanlık problemini azaltmak ve istatistiksel olarak daha sağlıklı sonuçlar elde etmek amacıyla tercih edilmiştir. Günlük getiriler üzerinden hesaplanan volatilité değerleri, risk düzeyinin yıllar itibarıyla önemli ölçüde farklılaştığını göstermiştir. Özellikle 2018, 2020 ve 2023 yıllarında volatilitenin belirgin biçimde yükselmesi, piyasa yapısının dönemsel olarak kırılanlaştığını ortaya koymaktadır. Buna karşılık 2017 yılı görece düşük volatilité ve yüksek getiri kombinasyonu ile istikrarlı bir boğa piyasası örneği sunmuştur. Bu rejim farklılıkları, yapay zekâ modellerinin sabit parametrelili değil, rejim-duyarlı (regime-aware) ve açıklanabilir yapılarla desteklenmesi gerektiğini göstermektedir.

Yıllık bazda tanımlayıcı istatistikler incelendiğinde, getirilerin zaman içerisinde homojen bir dağılım sergilemediği, pozitif ve negatif getirilerin kümelenme eğilimi gösterdiği ve bazı dönemlerde aşırı değerlerin yoğunlaştığı tespit edilmiştir. Bu bulgu, finansal zaman serilerinde volatilité kümelenmesi ve doğrusal olmayan yapıların varlığına işaret etmektedir. Dolayısıyla yatırım kararlarının yalnızca ortalama getiri üzerinden değil, risk ve oynaklık dinamikleri dikkate alınarak değerlendirilmesi gerektiği sonucuna ulaşılmıştır. Bu noktada XAI, yalnızca tahmin doğruluğunu değil, aynı zamanda modelin hangi risk faktörlerini hangi dönemlerde daha baskın kullandığını açıklayarak karar mekanizmalarını şeffaflaştırmaktadır.

Model performansları yön tahmin doğruluğu (Directional Accuracy) metriği ile ölçülmüş ve Doğrusal Regresyon modeli ile Rastgele Orman algoritması karşılaştırılmıştır. Elde edilen sonuçlar, yapay zekâ temelli modelin özellikle volatilitenin arttığı ve piyasa dinamiklerinin karmaşıklaştığı dönemlerde daha yüksek performans sergilediğini göstermektedir. Örneğin pandemi sürecini içeren 2020 yılında ve görece belirsizliğin yüksek olduğu 2025 yılında Rastgele Orman modelinin geleneksel modele kıyasla daha başarılı olduğu gözlemlenmiştir. Bu durum, makine öğrenmesi algoritmalarının doğrusal olmayan ilişkileri yakalama kapasitesinin finansal tahmin performansına olumlu yansıdığını göstermektedir. Bununla birlikte XAI perspektifi, bu performans üstünlüğünün yalnızca “ne kadar doğru tahmin edildiğini” değil, “hangi değişken kombinasyonlarıyla bu tahminin üretildiğini” de ortaya koyarak model güvenilirliğini artırmaktadır.

Bununla birlikte, 2022 yılında olduğu gibi güçlü ve tek yönlü trend içeren dönemlerde doğrusal regresyon modelinin daha yüksek doğruluk oranına ulaşması dikkat çekicidir. 2022 yılında endeksin olağanüstü yüksek nominal artış göstermesi, piyasanın belirgin bir trend yapısı sergilediğini ortaya koymuştur. Bu tür dönemlerde basit trend takip eden modellerin dahi yüksek performans gösterebildiği anlaşılmaktadır. Bu bulgu, model üstünlüğünün mutlak

olmadığını; piyasa rejimine bağlı olarak değişkenlik gösterdiğini ortaya koymaktadır. XAI açısından bu durum, model kararlarının daha “stabil ve tek faktörlü açıklanabilirlik” gösterdiği nadir rejimlerden birine işaret etmektedir; çünkü baskın trend değişkeni model kararlarını domine etmektedir.

Çalışmanın en önemli sonuçlarından biri, hiçbir modelin tüm dönemlerde istikrarlı biçimde üstün performans göstermediğidir. Bu durum, finansal piyasaların adaptif ve evrimsel doğasına işaret etmektedir. Piyasa katılımcılarının davranışları, makroekonomik gelişmeler ve politika değişimleri doğrultusunda sürekli değişen piyasa yapısı, modellerin performansını doğrudan etkilemektedir. Dolayısıyla tek bir yöntemle dayalı yatırım stratejilerinin uzun vadede sürdürülebilir üstünlük sağlaması güç görünmektedir. Bu bağlamda hem yapay zekâ hem de geleneksel modellerin birlikte kullanıldığı hibrit sistemlerin, XAI ile desteklenerek daha güvenilir ve denetlenebilir hale getirilmesi gerekmektedir.

Yapay zekâ temelli modellerin sağladığı avantajlar özellikle üç noktada belirginleşmektedir. Birincisi, büyük veri setleri içerisindeki karmaşık ve doğrusal olmayan ilişkileri öğrenebilme kapasitesidir. İkincisi, değişen piyasa koşullarına daha esnek uyum sağlayabilme yeteneğidir. Üçüncüsü ise geleneksel yöntemlerin gözden kaçırabileceği çoklu değişken etkileşimlerini yakalayabilmesidir. Buna karşılık, makine öğrenmesi modellerinin aşırı uyum (overfitting) riski taşıdığı ve geçmiş veriye fazla bağımlı hale gelmesi durumunda genellebilirlik sorunu yaşayabileceği unutulmamalıdır. Bu nedenle model karmaşıklığı ile genelleme kapasitesi arasında dikkatli bir denge kurulması gerekmektedir. Bu dengeyi sağlamak için XAI teknikleri, modelin hangi özellikleri ezberlediğini ve hangilerini genelleştirdiğini analiz etme imkânı sunarak model denetimini güçlendirmektedir.

Çalışmanın bulguları, yatırım karar mekanizmalarında hibrit yaklaşımların daha etkin sonuçlar üretebileceğini göstermektedir. Geleneksel finans teorileri piyasa davranışını açıklamada güçlü kavramsal çerçeveler sunarken, yapay zekâ modelleri veri içerisindeki örüntüleri keşfetme konusunda üstünlük sağlamaktadır. Bu iki yaklaşımın birlikte kullanılması hem teorik hem de ampirik açıdan daha dengeli yatırım stratejileri geliştirilmesine katkı sağlayabilir. Özellikle volatiliteye duyarlı model seçim mekanizmalarının geliştirilmesi, yatırım performansını artıracak potansiyele sahiptir. Bu hibrit mimarinin XAI ile entegre edilmesi, yatırımcıya yalnızca karar çıktısını değil, kararın gerekçesini de sunan “açıklanabilir algoritmik yatırım sistemleri”nin geliştirilmesini mümkün kılmaktadır.

Makroekonomik açıdan değerlendirildiğinde, yüksek enflasyonist dönemlerde nominal getirilerin yatırımcı davranışlarını önemli ölçüde etkilediği görülmektedir. 2022 yılında kaydedilen olağanüstü artış, yatırımcıların enflasyondan korunma motivasyonu ile hisse senedi piyasasına yöneldiğini düşündürmektedir. Bu durum, davranışsal finans perspektifiyle de uyumlu olup, yatırım kararlarının yalnızca rasyonel beklentilere dayanmadığını göstermektedir. Dolayısıyla gelecekteki çalışmaların, yatırımcı psikolojisi ve piyasa duyarlılığı göstergelerini de modelleme süreçlerine dahil etmesi önerilmektedir. Bu değişkenlerin XAI çerçevesinde modellenmesi, insan davranışının finansal algoritmalar üzerindeki etkisini daha görünür hale getirecektir.

Bu araştırmanın bazı sınırlılıkları bulunmaktadır. Öncelikle analiz yalnızca BIST 100 endeksi verileri ile sınırlıdır. Farklı endeksler, sektör bazlı ayrımlar veya uluslararası piyasalar ile yapılacak karşılaştırmalı analizler daha geniş genellenebilirlik sağlayabilir. Ayrıca çalışmada iki model karşılaştırılmıştır; derin öğrenme, destek vektör makineleri veya gradyan artırma algoritmaları gibi alternatif yöntemlerin dahil edilmesi farklı sonuçlar doğurabilir. Bunun yanında işlem maliyetleri, likidite etkisi ve vergi gibi unsurlar modele dahil edilmemiştir. Gerçek yatırım performansı açısından bu faktörlerin dikkate alınması önemlidir. Gelecek çalışmalarda özellikle XAI destekli çok katmanlı model karşılaştırmalarının yapılması, finansal modelleme literatüründe açıklanabilirlik odaklı yeni bir araştırma alanı oluşturacaktır.

Sonuç olarak, bu çalışma BIST 100 endeksi üzerinden gerçekleştirilen on yıllık analiz kapsamında, yapay zekâ temelli modellerin özellikle belirsizlik ve yüksek volatilité dönemlerinde yatırım karar süreçlerine anlamlı katkılar sağlayabildiğini ortaya koymuştur. Bununla birlikte güçlü ve istikrarlı trend dönemlerinde geleneksel modeller de yüksek performans gösterebilmektedir. Dolayısıyla finansal piyasalarda tek bir modelin kalıcı üstünlüğünden söz etmek mümkün değildir. En rasyonel yaklaşım, piyasa rejimine duyarlı, esnek ve hibrit modelleme stratejilerinin geliştirilmesidir. Bu yaklaşımın XAI ile bütünleştirilmesi, finansal karar alma süreçlerinde “yüksek performans + yüksek açıklanabilirlik” dengesini sağlayan yeni nesil bir paradigma oluşturmaktadır.

Elde edilen bulgular, finans literatüründe yer alan zayıf formda etkin piyasa hipotezinin, makine öğrenmesi algoritmalarının örüntü tanıma kapasitesi bağlamında yeniden değerlendirilmesi gerektiğini düşündürmektedir. Teknolojik gelişmelerin finansal karar mekanizmalarına entegrasyonu arttıkça, veri temelli ve algoritmik yaklaşımların yatırım yönetiminde daha merkezi bir rol üstleneceği öngörülmektedir. Ancak nihai karar sürecinde

insan yargısının, risk algısının ve etik değerlendirmelerin önemini koruyacağı da açıktır. Bu bağlamda çalışma, yatırım karar süreçlerinde geleneksel finans teorileri ile yapay zekâ temelli yöntemlerin birlikte değerlendirilmesinin, daha dengeli, adaptif ve sürdürülebilir yatırım stratejileri geliştirilmesine katkı sağlayabileceğini ortaya koymaktadır. Son olarak, XAI tabanlı sistemlerin yaygınlaşmasıyla birlikte finansal piyasalarda “tam otomatik değil, açıklanabilir algoritmik karar destek sistemleri” dönemine geçişin hızlanacağı öngörülmektedir.

KAYNAKÇA

Ahmed, Shamima & Alshater, Muneer M. & Ammari, Anis El & Hammami, Helmi, 2022. Yapay zekâ ve makine öğrenimi finans alanında: Bibliyometrik bir inceleme ", Uluslararası İşletme ve Finans Araştırmaları.

Arsenault, P.-D., Wang, S., & Patenande, J.-M. (2024). A survey of explainable artificial intelligence (XAI) in financial time series forecasting. Xiv. <https://arxiv.org/abs/2407.15909>

Aydın, S., & Güneysu, Y. (2025). ChatGPT Kullanımının Yatırım Kararları Üzerindeki Etkisi: Borsa İstanbul'daki Bireysel Yatırımcılara Yönelik Bir Araştırma. Karadeniz Ekonomi Araştırmaları Dergisi, 6(2), 92-103. <https://doi.org/10.71233/kared.1749447>.

Bahoo, S., et al. (2024). Artificial intelligence in finance: A bibliometric analysis. Journal of Financial Innovation, 10(1), 1–25.

Barakalı, O. C., & Öndeş, T. (2025). Finans Alanında Yapay Zekâ Uygulamalarına İlişkin Bibliyometrik Bir Analiz. Gümüşhane University Journal of Social Sciences, 16(2), 748-761.

Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control* (5th ed.). Wiley.

Campbell, J. Y., Lo, A. W., & MacKinlay, A. C. (1997). The econometrics of financial markets. Princeton University Press.

Campbell, J. Y., Lo, A. W., & MacKinlay, A. C. (1997). *The econometrics of financial markets*. Princeton University Press.

CFA Institute Research & Policy Center. (2025). Explainable AI in finance: Addressing the needs of diverse stakeholders.

Chen, X.-Q., Ma, C.-Q., Ren, Y.-S., Lei, Y.-T., Huynh, N. Q. A., & Narayan, S. (2023). *Explainable artificial intelligence in finance: A bibliometric review*. Finance Research Letters, 56, 104145. <https://doi.org/10.1016/j.frl.2023.104145>

Coşkun, E. A. (2022). The role of artificial intelligence in investment decisions and applications in the Turkish finance industry. Gaziantep University Journal of Social Sciences, 21(4), 2208–2222. <https://doi.org/10.21547/jss.1101615>

Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. European Journal of Operational Research, 270(2), 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>

G. S. Atsalakis, & K. P. Valavanis. (2009). *Surveying stock market forecasting techniques – Part II: soft computing methods*. Expert Systems with Applications, 36(3), 5932–5941. <https://doi.org/10.1016/j.eswa.2008.07.006>

Goodell, J. W., et al. (2021). Artificial intelligence and machine learning in finance: Identifying foundations, themes, and research clusters. Finance Research Letters, 38, 101–112.

Gu, S., Kelly, B., & Xiu, D. (2020). Empirical asset pricing via machine learning. The Review of Financial Studies, 33(5), 2223–2273.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). The elements of statistical learning. Springer.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

Jankova, Z. (2021). Artificial intelligence in financial markets. Journal of Risk and Financial Management, 14(8), 353

Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. Science, 349(6245), 255–260.

Krauss, C., Do, X. A., & Huck, N. (2017). Deep neural networks, gradient-boosted trees, and random forests for financial time series prediction. European Journal of Operational Research, 259(2), 689–703. <https://doi.org/10.1016/j.ejor.2016.10.031>

Lo, A. W. (2004). The adaptive markets hypothesis. *The Journal of Portfolio Management*, 30(5), 15–29.

Lundberg, S. M., & Lee, S.-I. (2017). *A unified approach to interpreting model predictions*. *Advances in Neural Information Processing Systems*, 30. <https://arxiv.org/abs/1705.07874>

Mahajan, K. (2024). Transforming financial decision-making with artificial intelligence: A comprehensive study on AI-driven algorithms for investment, trading, and portfolio management. *Journal of Electrical Systems*, 20(10s).

Manogna, R., & Anand, B. (2023). Machine learning applications in finance: A bibliometric review. *International Journal of Finance & Economics*, 28(4), 4120–4142. DOI:10.1108/K-04-2023-0637

Markowitz, H. (1952). Portfolio Selection. *The Journal of Finance*, 7(1), 77–91. <https://doi.org/10.2307/2975974>

Mohsin, M. T., & Nasim, N. B. (2025). Explainable AI in finance: A systematic review. arXiv preprint. <https://arxiv.org/abs/2503.05966>

Özer, B. (2025). Yapay zekâ tabanlı yatırım öneri araçlarının bireysel yatırım kararları üzerindeki etkisi Yüksek Lisans Tezi Sosyal bilimler Enstitüsü. Ege Üniversitesi. İzmir

Patrick Weber., K. Valerie Carl., & Oliver Hinz. (2023). Açıklanabilir yapay zekanın finansa uygulamaları—Finans, bilgi sistemleri ve bilgisayar bilimleri literatürünün sistematik bir incelemesi. *Management Review Quarterly*, 74(2), 1–41. <https://doi.org/10.1007/s11301-023-00320-0>

Pattnaik, D., Ray, S., & Raman, R. (2024). Applications of artificial intelligence and machine learning in the financial services industry: A bibliometric review. *Heliyon*, 10(1), e23492. <https://doi.org/10.1016/j.heliyon.2023.e23492>

Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). “*Why should I trust you?*” *Explaining the predictions of any classifier*. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 1135–1144. <https://doi.org/10.1145/2939672.2939778>

Saini, V. (2025). Impact of artificial intelligence on investment decision-making. *International Journal of Engineering and Management Research*.

Schmitt, M. (2024). Explainable automated machine learning for credit decisions: Enhancing human–AI collaboration in financial engineering.

Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review. *Applied Soft Computing*, 90, 106181. <https://doi.org/10.1016/j.asoc.2020.106181>

Springer Review. (2023). Applications of explainable artificial intelligence in finance a systematic review. *Management Review Quarterly*, 74, 867–907.

Springer Review. (2024). Explainable artificial intelligence (XAI) in finance: A systematic literature review. *Artificial Intelligence Review*, 57, 216.

Şahin, S. (2024). Finans sektöründe yapay zekâ, makine öğrenmesi ve büyük veri kullanımı: Fırsatlar, zorluklar ve politika yapıcılar için çıkarımlar. *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 9(4), 364–381.

Vinotha, C., Alsulami, F., Mohd, S., & Kankariya, R. A. (2024). *Artificial intelligence in financial markets: Predictive models and risk management strategies*. International Conference on Science Technology Engineering and Mathematics (ICONSTEM). <https://doi.org/10.1109/ICONSTEM60960.2024.10568778>

Yıldız, A. (2022). Finans alanında yapay zekâ teknolojisinin kullanımı: Sistemik literatür incelemesi. *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 52, 47–66. <https://doi.org/10.30794/pausbed.1089134>