

**YAPAY ZEKA TEMELLİ ÖĞRENME
YÖNTEMLERİNİN FİNANS ALANINDA
KULLANIMI: BİBLİYOMETRİK BİR ANALİZ**

USING OF ARTIFICIAL INTELLIGENCE-
BASED LEARNING METHODS IN FINANCE:
A BIBLIOMETRIC ANALYSIS

Erdi BAYRAM, Gökhan Berk ÖZBEK

18

YAPAY ZEKA TEMELLİ ÖĞRENME YÖNTEMLERİNİN FİNANS ALANINDA KULLANIMI: BİBLİYOMETRİK BİR ANALİZ

USING OF ARTIFICIAL INTELLIGENCE- BASED LEARNING METHODS IN FINANCE: A BIBLIOMETRIC ANALYSIS

Erdi BAYRAM ¹, Gökhan Berk ÖZBEK ²

Anahtar Kelimeler:

Makine Öğrenimi,
Derin Öğrenme,
Pekiştirmeli Öğrenme,
Bibliyometrik Analiz,
Kantitatif Finans.

Keywords:

Machine Learning,
Deep Learning,
Reinforcement
Learning,
Bibliometric Analysis,
Quantitative Finance.

¹ Arş. Gör. Dr., Manisa Celal Bayar Üniversitesi, İİBF, erdi.bayram@cbu.edu.tr, 0000-0003-4478-7231

² Öğr. Gör. Dr., Bursa Uludağ Üniversitesi, Harmançık MYO, gbozbek@uludag.edu.tr, 0000-0003-0288-069X

Alıntılanmak için/Cite as:
Bayram E. ve Özbek G. B. (2025). Yapay Zeka Temelli Öğrenme Yöntemlerinin Finans Alanında Kullanımı: Bibliyometrik Bir Analiz, Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 34 (Özel Sayı), 303-321

ÖZ

Çalışmada Makine Öğrenimi, Derin Öğrenme ve Pekiştirmeli Öğrenme ile ilgili finans alanındaki çalışmaların bibliyometrik incelemesi yapılmıştır. 2001-2025 periyodunu kapsayan araştırmada, Web of Science ve Scopus veri tabanlarında indekslenen, İngilizce yazılmış, yalnızca makale türündeki çalışmalar analiz edilmiştir. Her iki veri tabanındaki çalışmalar Rstudio ortamında özel bir kod dizini kullanılarak birleştirilmiş, tekrarlayanlar ayıklanmış ve tek bir veri setiyle çalışılmıştır. Çalışmalar yazar, dergi, anahtar kelimeler, tematik konular, atıf sayıları ve yazar ülkeleri bağlamında bibliyografik olarak araştırılmıştır. Çalışmaların görsel analizinde ise Biblioshiny programından yararlanılmıştır. Bu araştırmanın sonuçları olarak ilgili alandaki yayın sayısında özellikle 2018 sonrası ciddi bir artış olduğu izlenmektedir. Pay senedi fiyat tahminlemesi, volatilité öngörümlemesi, duygu analizi, sinir ağları ve optimizasyon gibi konuların ilgili alandaki temel temaları oluşturduğu tespit edilmiştir. En fazla yayının Expert Systems with Applications dergisinde yer aldığı ve Çin Halk Cumhuriyeti'nden araştırmacıların %29,8'lik bir oranla ilgili alanlarda en yüksek yayın üretme oranına sahip olduğu görülmektedir. Çalışılan veri setinde yer alan çalışmaların başlıklarında geçen en yaygın kelimeler ise pay senedi, öğrenme, tahmin, piyasa, öngörümleme, analiz, duygu, alım-satım ve portföydür. Araştırmanın yapay zekanın ilgili alt disiplinlerine dayalı modellerin finans literatürü açısından mevcut durumunu, etkisini ve potansiyel araştırma konularını ortaya koyması bakımından önemli olduğu düşünülmektedir.

ABSTRACT

The study presents a bibliometric analysis of research in finance focusing on machine learning, deep learning, and reinforcement learning. The analysis covers the period from 2001 to 2025 and includes only articles written in English and indexed in the Web of Science and Scopus databases. Using custom code in Rstudio environment, articles from both databases were merged, duplicates were removed, and a final dataset was prepared for analysis. The studies were examined bibliographically in terms of authors, journals, keywords, thematic areas, citation counts, and author affiliations. For visual analysis, the Biblioshiny software was used. The findings reveal a significant increase in the number of publications in this field, particularly after 2018. Key research themes identified include stock price prediction, volatility forecasting, sentiment analysis, neural networks, and optimization. The Journal Expert Systems with Applications was found to have the highest number of publications in the field. Researchers from the People's Republic of China contributed the largest share, accounting for 29.8% of all publications. The most frequently occurring terms in article titles include stock, learning, prediction, market, forecasting, analysis, sentiment, trading, and portfolio. This study is considered important for identifying the current state, academic impact, and future research directions of AI-based methods and models within the finance literature.

GİRİŞ

Gelişen teknoloji ve artan veri hacmi, finans sektöründeki karar alma süreçlerini köklü bir şekilde dönüşüme uğratma potansiyeli taşımaktadır. Özellikle yapay zeka tekniklerinin finansal analiz, finansal tahminleme ve yatırım stratejisi geliştirme süreçlerine entegre edilmesiyle, geleneksel yöntemlere kıyasla daha hızlı, doğru ve ölçeklenebilir çözümler üretilebilmektedir. Zira finansal zaman serisi verilerini geleneksel yöntemleri kullanarak doğru ve eksiksiz bir şekilde incelemek, bu serilerin çoğu zaman lineer olmayan ya da durağan olmayan nitelikleri sebebiyle mümkün olmayabilmektedir (Cheng vd., 2015). Finansal enstrümanların yıllar itibariyle giderek çeşitlenmesi ve piyasalara etki eden dinamiklerin giderek kompleks bir hal alması sonucu artış gösteren finansal piyasalardaki karmaşıklık ve belirsizlikler, geleneksel istatistiksel yaklaşımların sınırlarını zorlamakta, bu da daha gelişmiş hesaplama yöntemlerine olan ihtiyacı artırmaktadır. Bu bağlamda, Makine Öğrenimi (Machine Learning - ML), Derin Öğrenme (Deep Learning - DL), Pekiştirmeli Öğrenme (Reinforcement Learning - RL) ve Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) gibi modern yaklaşımlar, finans araştırmalarında giderek daha fazla kullanılmaktadır. Makine Öğrenimi, büyük veri (big data) kavramıyla yakından ilişkilidir. Büyük veri, çok sayıda gözlem, çok sayıda değişken veya her ikisini birden içermektedir. Gözlem sayısının fazlalaşması makine öğrenimi tahminlerinin doğruluğunu arttırmaktadır. Bu durum, en küçük kareler (OLS) modellerindeki parametre tahminlerinin hassasiyetini artırmaya benzer bir etki yaratır. Ancak değişken sayısı gözlem sayısına kıyasla fazla olduğunda, Makine Öğrenimi yöntemleri en küçük kareler gibi daha basit geleneksel yöntemlerden çok daha üstün performans göstermektedir (Hoang & Wiegatz, 2023). Büyük veri işlenmesinde sunduğu bu avantajların yanı sıra Makine Öğrenimi, geleneksel yöntemlerin işleyemediği görüntü ya da video gibi yüksek boyutlu verileri de analiz edebilecek bir kapasitededir. Bu tür verilerden ekonomik açıdan anlamlı bilgiler çıkarabilmekte ve bu sayede çok daha kapsamlı ve detaylı araştırmaların önünü açabilmektedir.

Makine Öğrenimi terimi ilk olarak 1959 yılında Arthur Samuel tarafından ortaya atılmıştır. Samuel, IBM için

çalıştığı bu dönemde, o dönemin öncü yapay zeka teknolojisini içeren sistemlere “öğrenme” faktörünü eklemek için örüntü tanıma görevlerini sisteme tanımlamaya dair bu kavramı geliştirmiştir (Gogas & Papadimitriou, 2021). Makine Öğreniminin finansal bağlamda ilk kullanıldığı çalışmalardan biri White (1988) tarafından gerçekleştirilmiştir. White, bu çalışmasında IBM’in günlük hisse senedi getirilerini tahminlemek için Yapay Sinir Ağları (Neural Networks - NN) uygulamasını kullanmıştır. Bu tarihten itibaren Makine Öğreniminin finans alanında kullanımı giderek yaygınlık göstermeye başlamıştır.

İlk yıllarda Makine Öğrenimi sistemleri yalnızca daha geniş kapsamlı bir yapay zeka sisteminin parçası olarak kabul edilmiştir. Ancak o günden bu yana, Makine Öğreniminin pratik uygulama alanları giderek genişlemiş ve yapay zeka çerçevesiyle tanımlanan sınırlamaları aşmıştır. Bu genişleme, özellikle hesaplama gücündeki artış, büyük veri kümelerine erişimin kolaylaşması ve algoritmik gelişmeler sayesinde ivme kazanmıştır. Finans alanında ise Makine Öğrenimi, yalnızca veri analizini otomatikleştiren bir araç olmaktan çıkarak, karmaşık piyasa dinamiklerini modelleme, risk yönetimi, algoritmik alım-satım ve dolandırıcılık tespiti gibi kritik işlevleri yerine getiren bir araç haline gelmiştir. Bu dönüşüm, geleneksel istatistiksel yöntemlerin sınırlı kaldığı noktalarda daha esnek ve doğru tahminler yapılmasını sağlamış, aynı zamanda karar alma süreçlerini hızlandırarak finansal piyasaların karmaşıklığına daha iyi uyum sağlayan modellerin geliştirilmesine olanak tanımıştır. Bugün Makine Öğrenimi sistemleri, tarihsel fiyat verilerinin analizinden duygu analizi yapılmasına, portföy optimizasyonundan kredi riskinin değerlendirilmesine kadar geniş bir yelpazede finansal analiz ve öngörü aracı olarak kullanılmaktadır.

Bu dönüşümde önemli bir rol oynayan Derin Öğrenme teknikleri, geleneksel Makine Öğrenimi yöntemlerinin sınırlamalarını da aşarak daha karmaşık ve doğrusal olmayan ilişkileri modelleme kapasitesine ulaşmıştır. Çok katmanlı yapay sinir ağlarına dayanan bu yöntemler, özellikle büyük ve karmaşık veri setlerinde daha doğru tahminler yapılmasına olanak tanımaktadır. Finansal piyasalarda Derin Öğrenme, yüksek frekanslı işlem modelleri geliştirme, piyasa duyarlılığı analizi ve

zaman serisi tahmini gibi alanlarda giderek daha fazla kullanılmaktadır. Destek Vektör Makineleri (SVM) ve En Yakın Komşu (kNN) gibi geleneksel Makine Öğrenimi teknikleriyle karşılaştırıldığında, Derin Öğrenme; denetimsiz özellik öğrenme kabiliyeti, genelleme yeteneğinin güçlü olması, büyük veri üzerinde sağlam ve etkili eğitim kapasitesi gibi avantajlara sahiptir (Huang vd., 2020). Bu dönüşümde önemli bir diğer adım da Pekiştirmeli Öğrenme yönteminin finansal alanda kullanımıdır. Pekiştirmeli Öğrenme, geleneksel denetimli ve denetimsiz öğrenme yöntemlerinin ötesine geçerek, bir ajanın çevresiyle etkileşime girerek ve ödül-maliyet ilişkilerine dayalı olarak en iyi stratejiyi öğrenmesini sağlar. Bu yöntem, deneme-yanılma yoluyla en uygun kararları almayı mümkün kılarak, dinamik ve belirsiz finansal ortamlarda etkili çözümler sunmaktadır. Pekiştirmeli Öğrenme, özellikle algoritmik alım-satım sistemlerinde ve portföy yönetimi uygulamalarında büyük bir potansiyele sahiptir. Bu yöntem, finansal piyasalarda risk ve getiri dengesini optimize etme konusunda üstün yeteneklere sahiptir. Bir ajanın, piyasa koşullarına göre değişen dinamiklerle etkileşime girerek her işlemde ödül toplama stratejisi geliştirmesi, zaman içinde daha verimli kararlar almasına olanak tanır (Charpentier vd., 2021; Hambly vd., 2023).

Pek çok bilim alanında ve disiplinde olduğu üzere finans bilimi açısından da geleceği şekillendirme potansiyeli taşıyan bu yöntemlerin ele alındığı çalışmaları irdelemek ve uygulama alanlarını incelemek bilimsel yazın açısından önem arz etmektedir. Çalışmanın temel motivasyon noktası ilgili konulardaki disiplinlerarası araştırmaları izlemek, incelemek ve ilgili konularda çalışma üretecek olan araştırmacılara literatürdeki potansiyel boşlukları tanıtmaktır. Web of Science ve Scopus gibi literatürü temsil gücü oldukça yüksek veritabanlarının her ikisini de aynı potada analize dahil etmek de bu çalışmanın daha sonra yapılacak olan bibliyometrik incelemeler açısından bir referans noktası olacağı düşünülmektedir. Bu çalışma gerek akademisyenler gerekse de finansal karar alıcı konumundaki tüm iktisadi kesimlere konuya ilişkin güncel bir izleni sunması açısından özgündür.

LİTERATÜR TARAMASI

2010'lu yılların sonuna dek bir emekleme döneminde olan, Makine Öğrenimi yöntemlerinin finans biliminde kullanımını konu edinen çalışmalar, özellikle 2020 sonrası dönemde önemli bir ivmelenme kazanmıştır. Bu çalışmalar genel olarak Makine Öğrenimi yöntemlerinin potansiyelleri ve finans alanında ne şekilde kullanılabilecekleri, finansal öngörü ve tahmin gerçekleştirme konusundaki kapasiteleri, risk ve portföy yönetimindeki başarıları gibi hususlara odaklanmaktadır. Çalışmanın bu kısmında Web of Science ve / veya Scopus endekslerinde dizinlenen ve en yüksek atıf sayılarına sahip olan bazı çalışmaların bulguları özetlenmiştir.

Helmbold ve ark. (1998) literatürdeki öncü çalışmalardan biri niteliğindeki çalışmalarında Makine Öğrenimi algoritmasını kullanan bir portföy seçim tekniği oluşturmuşlardır. Oluşturdukları algoritmayı NYSE üzerindeki 22 yıllık hisse getirileri üzerinde çalıştırmışlar ve oldukça başarılı sonuçlara ulaşmışlardır.

Brock ve ark. (2009) Pekiştirmeli Öğrenme yöntemini kullandıkları çalışmalarında riskten korunma (hedging) entrümanlarının artışının piyasaları istikrarsızlaştırabileceğini ve volatilité artışına yol açabileceği tespit etmişlerdir.

Patel ve ark. (2015) dört tahmin modelini (Yapay Sinir Ağı - ANN, Destek Vektör Makinesi - SVM, rastgele orman ve naive-Bayes) Hindistan hisse senedi piyasaları üzerinde sınamışlardır. CNX Nifty ve BSE Sensex endekslerinin fiyat hareketliliklerini tahmin etmede kullandıkları yöntemler içerisinde en başarılı olanın rastgele orman tekniği olduğunu tespit etmişlerdir.

Manela ve Moreira (2017) 1890-2009 yılları arasında Wall Street Journal'daki ön sayfa haberlerini kullanarak Makine Öğrenimi tekniğiyle bir belirsizlik ölçütü oluşturmuşlardır. Metinsel bilgileri kullanarak Makine Öğrenimi tekniğiyle oluşturdukları bu ölçütün ekonomik buhranlar öncesi yükseliş göstererek, etkili bir şekilde çalıştığını bulgulamışlardır.

Renault (2017) bir blog sitesi üzerindeki çevrimiçi

yatırımcı mesajlarını Makine Öğrenimi vasıtasıyla hisse senedi getirilerini tahmin etmede kullandığı çalışmada; S&P 500 borsa yatırım fonu (ETF) getirilerini tahmin etme konusunda başarılı sonuçlara ulaşmıştır.

De Spiegeleer ve ark. (2018) Makine Öğrenimi yöntemini opsiyon fiyatlaması alanında uygulamışlar ve kayda değer bir hız artışı raporlamışlardır.

Fischer ve Krauss (2018) S&P 500 üzerinde gerçekleştirdikleri ve 1992-2015 periyodunu kapsayan çalışmalarında Uzun Kısa Süreli Bellek tekniğinin finansal tahmin gücünü incelemişlerdir. Tekniğin genel piyasaya kıyasla oldukça başarılı sonuçlar verdiğini (0.46 günlük getiri ve 5.8'lik Sharpe Rasyosu ile) tespit etmişlerdir.

Kim ve Won (2018) hisse senedi fiyatlarındaki volatilité tahmini için Uzun Kısa Süreli Bellek yöntemiyle GARCH modellerini birleştiren hibrit bir metod kullanmışlardır. Araştırmacılar kullandıkları metodun geleneksel yöntemlere kıyasla daha iyi bir tahmin gücü taşıdığını ortaya koymuşlardır.

Li ve ark. (2019) yapay sinir ağları vasıtasıyla medya metin madenciliği gerçekleştirerek ham petrol fiyatındaki değişimleri tahminlemeye yönelik bir araştırma gerçekleştirmişler ve Derin Öğrenme tekniklerinin başarılı sonuçlar verdiğini raporlamışlardır.

Carmona ve ark. (2019) Makine Öğrenimi yöntemini banka iflaslarının önceden tespitinde kullanmışlardır. 2001-2015 döneminde 156 Amerikan bankası üzerinde gerçekleştirdikleri çalışmada ekstrem gradyan artırma yöntemiyle başarılı tahminler gerçekleştirmişlerdir.

Sirignano ve Cont (2019) Derin Öğrenme vasıtasıyla geçmiş emir akışlarını kullanarak fiyat hareketliliklerinin tahminlemesini gerçekleştirmişlerdir.

Zhong ve Enke (2019) derin sinir ağları vasıtasıyla S&P 500 borsa yatırım fonu getirilerini tahmin etmeye çalışmışlardır. 60 finansal ve ekonomik göstergiyi kapsayan büyük veri üzerinde çalışan araştırmacılar, derin sinir ağlarının, geleneksel yapay sinir ağlarına kıyasla daha iyi bir performans gösterdiğini bulmuşlardır.

Nikou ve ark. (2019) iShares MSCI UK'e ait borsa yatırım fonunun getirilerini tahmin etmede dört farklı Makine

Öğrenimi algoritmasını kullanmışlardır. Tahmin yeteneği bakımından Derin Öğrenme yönteminin üstün olduğunu tespit etmişlerdir.

Borovkova ve Tsiamas (2019) Uzun Kısa Süreli Bellek yöntemini hisse senedi getiri tahmininde kullanmışlardır. ABD'de faaliyet gösteren büyük ölçekli şirketlerin hisse getirilerini tahminlemede başarılı sonuçlara ulaşmışlardır.

Chen ve Ge (2019) Uzun Kısa Süreli Bellek yöntemini Hong Kong hisse senedi piyasasındaki getirilerin tahmininde kullanmışlar ve başarılı sonuçlara ulaşmışlardır.

Rasekhschaffe ve Jones (2019) çalışmalarında, hisse senedi seçiminde Makine Öğrenimi yöntemini kullanırken ortaya çıkabilecek aşırı uyum (overfitting) riskinin nasıl elimine edilebileceğini ve Makine Öğrenimi tekniklerinin nasıl etkili bir şekilde kullanılabileceğini açıklamışlardır.

Yürük ve Ekşi (2019) yapay sinir ağları ve destek vektör makineleri ile oluşturdukları modeller ile Borsa İstanbul Sınai endeksinde finansal başarısızlık tahmini uygulaması yapmıştır. Her iki yöntemle yapılan tahminlerin performansını ölçen araştırmacılar yapay sinir ağlarıyla eğitilen modellerin daha başarılı olduğunu tespit etmiştir.

Gu ve ark. (2020) Makine Öğrenimi yöntemlerini kullanarak oluşturdukları yatırımların klasik regresyon tabanlı stratejilere oranla yaklaşık iki kat fazla bir getiri sunduğunu kanıtlamışlardır.

Bucci (2020) yapay sinir ağlarını volatilité tahmininde kullanmış ve geleneksel tüm ekonometrik tahmin yöntemlerine kıyasla bariz bir üstünlük sağladığını tespit etmiştir. Özellikle Uzun Kısa Süreli Bellek modellerinin yüksek volatilité dönemlerinde dahi oldukça üstün tahmin yeteneğine sahip olduğunu belirtmiştir.

Baek ve ark. (2020) Makine Öğrenimi tekniğini Covid-19'un ABD hisse senedi piyasalarında yarattığı volatilité değişimini modellemek için kullanmışlardır.

Samitas ve ark. (2020) Makine Öğrenimi algoritmalarını finansal kriz tahminleyicisi olarak test etmişler ve algoritmaların %98.8 isabet gücüyle başarılı sonuçlar ortaya koyduğunu bulmuşlardır.

Arslankaya ve Toprak (2021) makine öğrenmesi ve derin öğrenme yöntemlerini kullanarak yaptıkları pay senedi fiyat

tahmini uygulaması sonucunda hata metrikleri en düşük yöntemleri Random Forest Regresyon modeli, LSTM, RNN ve Polinom Regresyon şeklinde sıralamıştır. Ayrıca yazarlar yapay zekanın alt disiplinlerine dayalı modellerin geleneksel tahmin yöntemlerinden daha iyi sonuçlar verdiğini ifade etmektedir.

Lin ve ark. (2021) Uzun Kısa Süreli Bellek yöntemini Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN) yöntemiyle birleştirerek oluşturdukları metot ile S&P 500 ve CSI300 getirilerini tahmin etmeye çalışmışlardır. Araştırmacılar metodun getiri tahminlerinde optimal sonuçlar verdiğini tespit etmişlerdir.

Leippold ve ark. (2022) Makine Öğrenimi algoritmalarını kullanarak oluşturdukları tahmin faktörleri ile Çin hisse senedi piyasasındaki hisse getirilerini tahmin etmeye çalışmışlardır. Algoritmanın özellikle büyük ölçekli şirket hisseleri ve kamu iktisadi işletmelerin hisselerini tahmin etmede yüksek başarı gösterdiğini tespit etmişlerdir.

YÖNTEM

Bu araştırmanın amacı finasta, spesifik olarak kantitatif finasta makine öğrenmesi, derin öğrenme ve pekiştirmeli öğrenmeye dayalı yöntemlerin kullanımına ilişkin literatürdeki eğilimleri incelemektir. İfade edilen yapay zeka mefhumuna ait alt disiplinlerin finans araştırmalarına entegrasyonunu incelemek araştırmanın güçlü bir motivasyon noktasını temsil etmekle birlikte ilgili yöntemlerin portföy yönetimi, varlık fiyatlama ve risk yönetimi alanlarındaki kullanımı araştırmanın temel odağı olarak ifade edilebilir.

Bibliyometrik analiz belirli bir zaman dilimi içerisinde üretilmiş makale ve benzeri bilimsel çıktıların ve bu çıktıların yazar, atıf, kaynak gibi unsurlarının bağımsız ve ilişkisel olarak farklı araştırma problemlerine dayalı sayısal

ve istatistiksel incelemesidir (Aslancı, 2022). Bu analiz türü yüksek hacimli yapılandırılmamış büyük verileri anlamlandırarak belirli bir disiplindeki çalışma alanının yığın bilimsel bilgisini ve evrimsel yapısını açığa çıkarmak ve görselleştirmek için kullanılmaktadır (Aydın, 2024). Bibliyometrik analizlerde özellikle güncel, gelişmekte olan araştırma konuları ve trenlerinin keşfi amaçlanmaktadır. Bu analizler başta VOSviewer olmak üzere Bibexcel, Citespace, Biblioshiny gibi yazılımlarla/programlarla yapılabilmekte, programlar sayesinde kullanışlı tablolar ve görseller elde edilebilmektedir (Moral-Munoz vd., 2020).

Bu çalışmada RStudio tabanında çalışan ve ilk kez Aria ve Cuccurollo (2017) tarafından ilgili makalede tanıtılan Biblioshiny programı tercih edilmiştir. Program muadillerine kıyasla arayüz kullanım kolaylığı, analiz ve görselleştirme kabiliyeti nedeniyle tercih edilmiştir. Ayrıca -bu araştırma özelinde- farklı veritabanlarından çekilerek RStudio ortamında birleştirilmiş ve ayıklanmış metadaların analizine olanak sağlaması da diğer bir önemli bir tercih sebebi olmuştur.

Bu araştırma Web of Science ve Scopus olmak üzere iki farklı veritabanından elde edilen metadalarla gerçekleştirilmiştir. Araştırma alanı açısından bakıldığında seçilen veritabanındaki toplam yayın sayısının alanı temsil kabiliyeti oldukça yüksektir. Tablo 1’de verilen kriter ve girdilere istinaden her iki veritabanındaki metadatalar indirilmiştir. Toplanan veriler tek bir dosyada RStudio ortamında birleştirilmiş, tekrarlayan çalışmalar ayıklanmış ve Biblioshiny modülünde açılmıştır. Kayıp veriler (missing counts) yazar kurum bilgileri ve referanslar için %1’in altında, DOI bilgisi için %3,72; anahtar kelimeler için %6,57; sorumlu yazar bilgileri için %10,7’dir Burada tür ve dil bakımından filtrelemeye uymayan çalışmalar ayıklanarak 3196 çalışmadan geriye kalan 3124 çalışmayla analize devam edilmiştir.

Tablo 1. Veri Toplama Kriterleri, Arama Terimleri ve Filtreler

Kriter	Girdi(ler)
Araştırma veritabanları	Web of Science ve Scopus
Araştırma veri aralığı	2001-2025
En son veri çekilen tarih	9 Mart 2025
Arama dizisi	Topic (Web of Science). Article title, Abstract, Keywords, Authors (Scopus).
Arama terimleri	(“ML” OR “machine learning” OR “DL” OR “deep learning” OR “reinforcement learning” OR “LSTM” OR “long short-term memory”) AND (“portfolio selection” OR “asset pricing” OR “quantitative financ*” OR “financ* markets” OR “stock market”)
Konu kapsamı	Business; Business Finance; Computer Science AI; Economics; Mathematics Interdisciplinary Applications (Web of Science). Computer Science; Mathematics; Economics, Econometrics and Finance; Business, Management and Accounting (Scopus).
Tür	Makale
Dil	İngilizce

Tablo 2’de 2001-2025 dönemi için analize dahil edilmiş olan 3124 makalenin özet (tanımlayıcı) istatistikleri sunulmuştur. Makalelerin yıllık büyüme hızının %23,35;


yazarların kullandığı toplam anahtar kelime sayısının (author’s keywords) 6644 olduğu görülmektedir. 228 makale tek yazarlıdır, makale başına düşen ortak yazar sayısı (co-authors per doc) 3,31’dir. Makalelerin ortalama yaşı program tarafından 3,21 olarak hesaplanmıştır.

Tablo 2. Özet İstatistikler

Tanım	Sayısal veri
Makale sayısı	3124
Yıllık büyüme hızı (%)	23,35
Ortalama atıf sayısı (her bir makale için)	19,61
Farklı anahtar sözcük sayısı (yazar)	6644
Toplam yazar sayısı	6210
Tek yazarlı çalışma sayısı	228
Makale başına düşen ortak yazar sayısı	3,31
Uluslararası iş birliği (%)	6,914
Toplam referans sayısı	117876

ARAŞTIRMA BULGULARI

Çalışmanın bu kısmında literatürdeki benzer araştırmaların raporlamaları takip edilerek önemli görülen analiz çıktıları ve bulgular sunulacak ve yorumlanacaktır. Aşağıda verilen Şekil 1’de yıllara göre yayın artış hızının trendi gösterilmiştir. Özellikle 2018 yılından itibaren yayınlarda belirgin bir biçimde artış izlenmektedir. 2024 yılında 814’e ulaşan yayınların artış eğilimini 2025 yılında da sürdürmesi beklenmektedir. Alana ilişkin akademik ilginin 2018’den sonra yükselmeye başladığı görülmektedir.



Şekil 1. Yayın Artış Hızı

Tablo 3. Yıllara Göre Ortalama Atıf Sayıları

Yıllar	Ortalama Atıf Sayısı	Yıllar	Ortalama Atıf Sayısı
2001	1,60	2014	2,24
2002	4,12	2015	7,65
2003	1,67	2016	5,49
2004	1,73	2017	9,08
2005	8,57	2018	10,43
2006	4,85	2019	6,74
2007	6,79	2020	7,75
2008	1,79	2021	4,75
2009	8,64	2022	3,73
2010	2,70	2023	2,67
2011	1,21	2024	1,16
2012	2,52	2025	0,14
2013	1,68	Ortalama	4,39

Tablo 3’te araştırma alanının paralelindeki çalışmaların aldığı ortalama atıf sayıları yıllar itibariyle verilmiştir. 25 yılın atıf ortalaması 4,39’dur. Veriler en yüksek atıf ortalamasına 2018 yılında ulaşıldığını göstermektedir, bu yılı 2017 (9,08), 2009 (8,64) ve 2005 (8,57) yıllarının takip ettiği izlenmektedir. 2010 yılı öncesi bazı yıllardaki ortalama atıf sayısının yüksekliği dikkat çekicidir, bu güncel araştırmaların alandaki temel makaleleri (veya ilgili yöntemleri araştıran ilk makaleleri) takip ettiği şeklinde değerlendirilebilir. Makine öğrenmesi, derin öğrenme ve pekiştirmeli öğrenmeye dayalı yöntemlerin kantitatif finasta kullanımına ilişkin (veya paralel) literatürün özellikle 2018 yılından itibaren gelişme kaydettiği, ilerleyen yıllarda bu büyümenin atıf performansına da yansıtacağı öngörülmektedir.

Tablo 4’te ilgili alanda en çok atıf alan 10 çalışma

verilmiştir. En yüksek atıf sayısına sahip çalışma Fischer ve Krauss (2018)’a aittir. Tabloda verilen çalışmalar incelendiğinde farklı yöntem ve modellerin finansal piyasalarda tahmin ve öngörü (prediction and forecasting) için kullanıldığı görülmektedir. 713 toplam atıf sayısına sahip Gu vd. (2020)’nin çalışmasında makine öğrenmesine dayalı yöntemlerle varlık risk primi ölçümü yapıldığı izlenmektedir. Schumarker ve Chen (2009) tarafından gerçekleştirilen ve 611 toplam atıf sayısına sahip çalışmada ise metin çözümlemesi yoluyla finansal haberler kullanılarak pay senedi fiyat tahmini yapılmıştır. Kim ve Won (2018)’un çalışmasında ise volatilité tahmini için yaygın olarak tercih edilen GARCH tipi modeller ile LSTM hibrit bir model oluşturularak kullanılmıştır. (Konuya ilişkin daha geniş bir literatür değerlendirmesi için “Literatür Taraması” başlığı incelenebilir.)


Tablo 4. En Çok Atıf Alan 10 Çalışma (Most Global Cited Documents)

No	Çalışmanın başlığı	Yazar(lar), yayın yılı	Dergi adı	Toplam atıf sayısı
1	Deep learning with long short-term memory networks for financial market predictions	Fischer ve Krauss (2018)	European Journal of Operational Research	1421
2	Time series prediction using support vector machines: A survey	Sapankevych ve Sankar (2009)	IEEE Computational Intelligence Magazine	923
3	A survey of deep learning and its applications: A new paradigm to machine learning	Dargan vd. (2019)	Archives of Computational Methods in Engineering	747
4	Empirical asset pricing via machine learning	Gu vd. (2020)	The Review of Financial Studies	713
5	Textual analysis of stock market prediction using breaking financial news: The AZFin text system	Schumaker ve Chen (2009)	ACM Transactions on Information Systems (TOIS)	611
6	Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques	Patel vd. (2015a)	Expert Systems with Applications	530
7	Financial time series forecasting model based on CEEMDAN and LSTM	Cao vd. (2019)	Physica A: Statistical Mechanics and its Applications	506
8	Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models	Kim ve Won (2018)	Expert System with Applications	429
9	Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500	Krauss vd. (2017)	European Journal of Operational Research	429
10	Predicting stock market index using fusion of machine learning techniques	Patel vd. (2015b)	Expert Systems with Applications	409

Veri setinde yer alan çalışmaların en çok atıf verdiği eserler (most local cited documents) arasında ise Fischer ve Krauss (2018), Patel ve ark. (2015b), Chong ve ark. (2017), Leippold ve ark. (2022), Baek ve Kim (2018), Hoseinzade ve Haratizadeh (2019), Krauss ve ark. (2017), Chen ve ark. (2021), Chen ve Ge (2019) ve Oliviera ve ark. (2017) yer almaktadır.

Aşağıda verilen Şekil 2’de yazarların belirlediği anahtar sözcüklerden türetilmiş birlikte bulunma ağı (co-occurrence network) sunulmuştur. Şekildeki mavi ağlarda makine öğrenmesinin (arasındalık derecesi 1) ve derin öğrenmenin (arasındalık derecesi 0,771) merkezi konumu görülmektedir. Arasındalık derecesi (betweenness)


yüksek diğer kelimeler long short-term memory (LSTM), stock market, sentiment analysis, prediction, artificial intelligence, neural networks, reinforcement learning ve forecasting’dir. (Detaylar için Ek 1 incelenebilir.) Mavi ağlar araştırılan konu bağlamında birbirleriyle daha sık kullanılan kelime gruplarını göstermektedir. Yeşil ve kırmızı ağlar ise daha zayıf bağlantılı fakat araştırma alanıyla ilgili alt konu başlıkları ve gruplarını ifade etmektedir. Şekilde örneğin prediction, forecasting gibi anahtar kelimelerin makine öğrenmesi ve derin öğrenmeyle daha güçlü bağlantılara sahip olduğu, portfolio optimization, asset pricing gibi kelimelerin/temaların ise daha az bağlantılı olduğu görülmektedir.



Şekil 3. Tematik Harita

Şekil 4’te ilgili temalarda en çok yayın yapılan ilk 10 dergi verilmiştir. Görüldüğü üzere en fazla makale Expert Systems with Applications tarafından yayımlanmıştır. Bu dergiyi IEEE Access, Applied Soft Computing, Computational Economics ve International Journal of Advanced Computer Science takip etmektedir. Buradaki dikkat çekici nokta makine öğrenmesi, derin öğrenme


ve pekiştirmeli öğrenme yöntemlerinin finans alanına entegrasyonunda farklı disiplinlere ait dergilerin ön plana çıkıyor oluşudur. Kuşkusuz veri toplama sürecinde bu öngörüyle hareket edilmiştir ancak kantitatif finans alanında çalışan araştırmacıların -disiplinlerarası- bu kaynakları ilgiyle takip etmelerinin önemli olduğu düşünülmektedir.




Şekil 4. En Fazla Yayın Yapılan Dergiler (Most Relevant Sources)

Şekil 5’te ise Biblioshiny modülünün kullanışlı bir görseli olan üçlü alan grafiği (three-field plot) verilmiştir. Farklı biçimlerde kurgulanabilen bu analiz bu araştırma özelinde çalışma başlıklarından sıklıkla kullanılan kelimeleri, çalışmalardaki anahtar sözcükleri ve bunları kullanan yazarları göstermektedir. Bu üç alan başlıklarda kullanılan kelime ve yazarların anahtar kelime havuzlarını incelemek açısından önemlidir. Başlıklarda geçen stock, learning, prediction, forecasting, sentiment, trading ve portfolio gibi kelimeler alanın genel çerçevesi hakkında bilgi sunmaktadır.

Üçlü alan grafiğinde yer alan yazarların kullanmış olduğu anahtar kelimeler ve başlıklarda sıklıkla geçen sözcükler Dirik ve ark. (2024)’nın ifadesiyle kilit kavramlardır. Araştırmacıların bu kilit kavramları çalışmalarında stratejik bir şekilde konumlandırmaları çalışmalarının atıf alma ve okunma potansiyelini artıracaktır. Diğer yandan başlıklarda yer alan kelimeler incelenerek potansiyel araştırma konuları belirlenebilir, kuşkusuz 3124 metadatanın gösterdiği eğilimler gelecek çalışmalar için referans noktası olacaktır.



Şekil 5. Üçlü Alan Grafiği (Three-Field Plot)



Şekil 6. Sorumlu Yazarların Ülkeleri

Bu çalışmada kullanılan veri setindeki sorumlu yazarların ülke mensubiyetleri baz alınarak alanla ilgili en çok yayın üreten ilk 10 ülkeye ilişkin veriler yukarıda Şekil 6'da sunulmuştur. Çin Halk Cumhuriyeti'nin %29,8'lik oranla en fazla üretim yapan ülke olduğu görülmekte, onu Hindistan (%9,6), Amerika Birleşik Devletleri (%6), Güney Kore (%4,6) ve Birleşik Krallık (%3,2) takip etmektedir. Şekilde yer almamakla birlikte Türkiye'den sorumlu yazar araştırmacıların oranı %1,4'tür. Veriler Çin Halk Cumhuriyeti'nin baskın görünümüne dikkat çekmektedir.

Bu çalışmanın bulguları paralelinde ilgili alanda çalışma üretecek olan araştırmacılar öncelikle Şekil 3'te yer alan niş temaları inceleyerek potansiyel araştırma konuları üzerine yoğunlaşabilir. Bu sayede araştırmacıların literatürdeki boşlukları keşfetmesi mümkün olacaktır. Örneğin investor sentiment yani yatırımcıların duygu değişkenini modellemek isteyen bir araştırmacı ampirik modeller tasarlama açısından literature özgün katkılar sunabilir. Yine aynı şekilde Şekil 3'teki öncü temaları potansiyel çalışmalar için oldukça güçlü bir anahtar kelime havuzu sunmaktadır. Ayrıca araştırmacılar Şekil 5'teki üçlü alan grafiğinde yer alan kelime gruplarını derinlemesine

inceleyerek teorik çerçeve geliştirebilir ve literatür açısından yeni açılımlar sağlayabilir.

SONUÇ

Günümüzün fenomen kavramı yapay zekanın alt disiplinleri olarak makine öğrenmesi, derin öğrenme ve pekiştirmeli öğrenme yöntemlerine dayalı modellerin sosyal bilimlere entegrasyonu alanyazının paradigmasını değiştirmiştir/değiştirmektedir. İşletmenin bütün alt disiplinlerinde, spesifik olarak ekonomi-finance alanındaki araştırma konularının bağlantı noktalarında yapay zeka temelli öğrenme yöntemlerinin yer aldığı görülmektedir. Burada hiç kuşkusuz ilgili yöntemlerin yığın ve/veya yüksek frekanslı veriyle çalışan araştırmacıların veriyi yönetme, analiz etme ve kullanışlı sonuçlar üretme kabiliyetini artırdığı söylenebilir. Zira Akay ve ark. (2020) tarafından da ifade edildiği üzere ekonomi, ekonometri alanlarında makine öğrenmesi konularına yönelim artmış ve yapılan çalışmalarda finans ile bağlantılı anahtar kelimeler sıklıkla kullanılmaya başlamıştır. Bu çalışma finasta, spesifik olarak ise kantitatif finasta (ve hesaplamalı finasta, computational finance) bahsi geçen üç öğrenme yöntemine dayalı modellerin kullanımına

ilişkilerin literatürdeki eğilimleri incelemeyi amaçlamıştır. Alan farketmeksizin bibliyometrik analiz içeren araştırmalara ilişkin okumalara istinaden bu çalışmada Web of Science ve Scopus veritabanlarında çalışılmış, ayrıca bu metadatalar tekrarlayan araştırmalar temizlenerek birlikte analiz edilmiştir. Bu teknik ayrıntının çalışmayı özgün kıldığı ifade edilebilir. Ayrıca işletme, ekonomi, finans disiplinlerine ait yayınların/dergilerin dışında bilgisayar bilimleri, matematik ve disiplinlerarası araştırmalar kapsama dahil edilmiştir. Buradaki amaç ilgili konulardaki disiplinlerarası araştırmaları izlemek ve incelemektir. Bu sayede ilgili anahtar kelimeleri içeren çalışmaların bütünüyle analiz edilmesi sağlanmıştır.

RStudio altyapısında çalışan Biblioshiny modülü kullanarak gerçekleştirilen analizler sonucunda -benzer bir araştırmada Manogna ve Anand (2023) tarafından da ifade edilmiş olan- konuya ilişkin çalışmaların artış hızının 2017-2018 yıllarında başladığı görülmüştür. 2024 yılında 814'e ulaşan yayın sayısının artan ilgiye koşut olarak 2025 yılında da yükselmesi beklenmektedir. Bu beklentiye paralel olarak 2017 sonrası yapılan yayınların atıf sayılarının da yıllar itibarıyla yükseleceği öngörülmektedir. Her ne kadar derin öğrenme odaklı bir araştırma olsa da Manogna ve Anand (2023) tarafından yapılan konu başlıklarının yoğunlaşmasına ilişkin raporlama bu çalışmadaki bulgularla uyumludur. Nitekim yazarlar neural networks and stock market simulations; portfolio optimization and risk management; time series analysis and forecasting konularının öne çıktığını ifade etmektedir ki ilgili başlıklar/anahtar kelimeler bu çalışmada verilen Şekil 2'deki birlikte bulunma ağı ile uyumludur. Ayrıca ilgili şekildeki niş sınıflandırmasında yer alan investor sentiment ve stock market volatility temalarının dikkat çekici olduğu ifade edilebilir. Yine bağlantılarda (düğümler, nodes) yer alan sentiment analysis, forecasting, algorithm, price prediction ve trading strategies gibi kavramların

ilgili alanda çalışma üretecek araştırmacılar açısından önemli olduğu düşünülmektedir. Analiz çıktılarında en fazla makalenin Expert Systems with Applications ve IEEE Access dergilerinde yayımlandığı görülmüştür. Bu da Ceyhan (2023)'ın çalışmasındaki konuyla ilgili sosyal bilimler alanında daha az üretkenlik olduğu çıkarımıyla örtüşmektedir. Sorumlu yazarların ülke mensubiyetleri baz alınarak elde edilen sonuçlarda Çin Halk Cumhuriyeti'nin en fazla üretim yapan ülke olduğu görülmüştür. İlgili istatistiki sonuç bu çalışmayla araştırma metodolojisi açısından benzerlik gösteren Meng ve ark. (2024) çalışmasındaki bulguları desteklemektedir.

Bu çalışma yapay zekanın alt disiplinleri olarak makine öğrenmesi, derin öğrenme ve pekiştirmeli öğrenme yöntemlerine dayalı modellerin finans literatürü açısından mevcut durumunu, etkisini ve potansiyel araştırma konularını ortaya koyması bakımından önemlidir. Hiç kuşkusuz bu araştırmanın kısıtları mevcuttur. Bunların başında döküman olarak sadece makalelere ait metadataların kullanılması gelmektedir. Web of Science ve Scopus veritabanlarında çok sayıda alt disiplin ve konu kapsamı bulunmaktadır, bu çalışmada yalnızca Tablo 1'deki disiplinlerin kapsamına giren makalelerle çalışılmıştır. Veri aralığı geniş olmasına karşın 2001 yılından önceki makaleler araştırmaya dahil edilmemiştir. Analiz sonuçları için tek bir bibliyometrik analiz programının görsel çıktıları kullanılmıştır.

Bu ve buna paralel bir konuda (veya tamamen farklı bir disiplin için) bibliyometrik analiz yapacak araştırmacılar makale dahil tüm dokümanları (kitap bölümleri, tezler, bildiriler vb.) analize dahil edebilir, farklı dillerdeki yayınların metadatasını kullanabilir ve veri setini farklı araştırma terimleri kullanarak oluşturabilir. Türkiye ölçeğinde özellikle Dergipark ve Ulusal Tez Merkezi gibi platformlar içinde yer alan akademik çalışmaları analiz etmek de mevcut alanyazın için faydalı olacaktır.

KAYNAKLAR

- Akay, E. C., Soydan, N. T. Y. ve Gacar, B. K. (2020). Makine öğrenmesi ve ekonomi: Bibliyometrik analiz. *PressAcademia Procedia*, 12(1), 104-109. <https://doi.org/10.17261/Pressacademia.2020.1367>
- Aria, M. ve Cuccurullo, C. (2017). bibliometrix: An R-tool for comprehensive science mapping analysis. *Journal of Informetrics*, 11(4), 959-975. <https://doi.org/10.1016/j.joi.2017.08.007>
- Arsllankaya, S. ve Toprak, Ş. (2021). Makine öğrenmesi ve derin öğrenme algoritmalarını kullanarak hisse senedi fiyat tahmini. *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 13(1), 178-192. <https://doi.org/10.29137/umagd.771671>
- Aslancı, S. (2022). Araştırma sorgulamaya dayalı öğrenme: bibliyometrik bir analiz. *Scientific Educational Studies*, 6(1), 1-25. <https://doi.org/10.1016/j.joi.2017.08.007>
- Aydın, N. (2024). Bibliyometrik analiz nasıl yapılır: Genel bir bakış. *Balkan ve Yakın Doğu Sosyal Bilimler Dergisi*. 19(Özel Sayı), 153-160.
- Baek, S., Mohanty, S. K., ve Glambosky, M. (2020). COVID-19 and stock market volatility: An industry level analysis. *Finance Research Letters*, 37, 101748. <https://doi.org/10.1016/j.frl.2020.101748>
- Baek, Y. ve Kim, H. Y. (2018). ModAugNet: A new forecasting framework for stock market index value with an overfitting prevention LSTM module and a prediction LSTM module. *Expert Systems with Applications*, 113, 457-480. <https://doi.org/10.1016/j.eswa.2018.07.019>
- Borovkova, S. ve Tsiamas, I. (2019). An ensemble of LSTM neural networks for high-frequency stock market classification. *Journal of Forecasting*, 38(6), 600-619. <https://doi.org/10.1002/for.2585>
- Brock, W. A., Hommes, C. H., ve Wagener, F. O. (2009). More hedging instruments may destabilize markets. *Journal of Economic Dynamics and Control*, 33(11), 1912-1928. <https://doi.org/10.1016/j.jedc.2009.05.004>
- Bucci, A. (2020). Realized volatility forecasting with neural networks. *Journal of Financial Econometrics*, 18(3), 502-531. <https://doi.org/10.1093/jfinec/nbaa008>
- Cao, J., Li, Z. ve Li, J. (2019). Financial time series forecasting model based on CEEMDAN and LSTM. *Physica A: Statistical Mechanics and Its Applications*, 519, 127-139. <https://doi.org/10.1016/j.physa.2018.11.061>
- Carmona, P., Climent, F., ve Momparler, A. (2019). Predicting failure in the US banking sector: An extreme gradient boosting approach. *International Review of Economics & Finance*, 61, 304-323. <https://doi.org/10.1016/j.iref.2018.03.008>
- Ceyhan, İ. F. (2023). Finans alanında makine ve derin öğrenmenin kullanılması: Lisansüstü tezlerde sistematik literatür taraması. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 12(3), 2187-2209. <https://doi.org/10.15869/itobiad.1329889>
- Charpentier, A., Elie, R. ve Remlinger, C. (2021). Reinforcement learning in economics and finance. *Computational Economics*, 62, 425-462. <https://doi.org/10.1007/s10614-021-10119-4>
- Chen, S. ve Ge, L. (2019). Exploring the attention mechanism in LSTM-based Hong Kong stock price movement prediction. *Quantitative Finance*, 19(9), 1507-1515. <https://doi.org/10.1080/14697688.2019.1622287>
- Chen, W., Zhang, H., Mehrlawat, M. K. ve Jia, L. (2021). Mean-variance portfolio optimization using machine learning-based stock price prediction. *Applied Soft Computing*, 100, 106943. <https://doi.org/10.1016/j.asoc.2020.106943>
- Cheng, C., Sa-Ngasoongsong, A., Beyca, O., Le, T., Yang, H., Kong, Z., ve Bukkapatnam, S. T. (2015). Time series forecasting for nonlinear and non-stationary processes: a review and comparative study. *Iie Transactions*, 47(10), 1053-1071. <https://doi.org/10.1080/0740817X.2014.999180>
- Chong, E., Han, C. ve Park, F. C. (2017). Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. *Expert Systems with Applications*, 83, 187-205. <https://doi.org/10.1016/j.eswa.2017.04.030>
- Dargan, S., Kumar, M., Ayyagari, M. R. ve Kumar, G. (2020). A survey of deep learning and its applications: A new paradigm to machine learning. *Archives of Computational Methods in Engineering*, 27(4), 1071-1092. <https://doi.org/10.1007/s11831-019-09344-w>
- De Spiegeleer, J., Madan, D. B., Reyners, S. ve Schoutens, W. (2018). Machine learning for quantitative finance: fast derivative pricing, hedging and fitting. *Quantitative Finance*, 18(10), 1635-1643. <https://doi.org/10.1080/14697688.2018.1495335>
- Dirik, D., Erhan, T. ve Eryılmaz, İ. (2024). Yapay zeka ve örgüt temelli araştırmaların potansiyel eğilimleri üzerine bibliyometrik bir analiz. *Bulletin of Economic Theory and Analysis*, 9(3), 669-698. <https://doi.org/10.25229/beta.1487924>
- 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. <https://doi.org/10.1016/j.ejor.2017.11.054>

- Gogas, P. ve Papadimitriou, T. (2021). Machine learning in economics and finance. *Computational Economics*, 57, 1-4. <https://doi.org/10.1007/s10614-021-10094-w>
- Gu, S., Kelly, B., ve Xiu, D. (2020). Empirical asset pricing via machine learning. *The Review of Financial Studies*, 33(5), 2223-2273. <https://doi.org/10.1093/rfs/hhaa009>
- Hambly, B., Xu, R., ve Yang, H. (2023). Recent advances in reinforcement learning in finance. *Mathematical Finance*, 33(3), 437-503. <https://doi.org/10.1111/mafi.12382>
- Helmbold, D. P., Schapire, R. E., Singer, Y., ve Warmuth, M. K. (1998). On-line portfolio selection using multiplicative updates. *Mathematical Finance*, 8(4), 325-347. <https://doi.org/10.1111/1467-9965.00058>
- Hoang, D. ve Wiegatz, K. (2023). Machine learning methods in finance: Recent applications and prospects. *European Financial Management*, 29(5), 1657-1701. <https://doi.org/10.1111/eufm.12408>
- Hoseinzade, E. ve Haratizadeh, S. (2019). CNNpred: CNN-based stock market prediction using a diverse set of variables. *Expert Systems with Applications*, 129, 273-285. <https://doi.org/10.1016/j.eswa.2019.03.029>
- Huang, J., Chai, J., ve Cho, S. (2020). Deep learning in finance and banking: A literature review and classification. *Frontiers of Business Research in China*, 14(1), 13. <https://doi.org/10.1186/s11782-020-00082-6>
- Kim, H. Y. ve Won, C. H. (2018). Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models. *Expert Systems with Applications*, 103, 25-37. <https://doi.org/10.1016/j.eswa.2018.03.002>
- Krauss, C., Do, X. A. ve Huck, N. (2017). Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. *European Journal of Operational Research*, 259(2), 689-702. <https://doi.org/10.1016/j.ejor.2016.10.031>
- Leippold, M., Wang, Q., ve Zhou, W. (2022). Machine learning in the Chinese stock market. *Journal of Financial Economics*, 145(2), 64-82. <https://doi.org/10.1016/j.jfineco.2021.08.017>
- Li, X., Shang, W. ve Wang, S. (2019). Text-based crude oil price forecasting: A deep learning approach. *International Journal of Forecasting*, 35(4), 1548-1560. <https://doi.org/10.1016/j.ijforecast.2018.07.006>
- Lin, Y., Yan, Y., Xu, J., Liao, Y., ve Ma, F. (2021). Forecasting stock index price using the CEEMDAN-LSTM model. *The North American Journal of Economics and Finance*, 57, 101421. <https://doi.org/10.1016/j.najef.2021.101421>
- Manela, A. ve Moreira, A. (2017). News implied volatility and disaster concerns. *Journal of Financial Economics*, 123(1), 137-162. <https://doi.org/10.1016/j.jfineco.2016.01.032>
- Manogna, R. L. ve Anand, A. (2024). A bibliometric analysis on the application of deep learning in finance: Status, development and future directions. *Kybernetes*, 53(12), 5951-5971. <https://doi.org/10.1108/K-04-2023-0637>
- Meng, C., Chen, C., Xu, H. ve Li, T. (2024). Asset pricing and portfolio investment management using machine learning: Research trend analysis using scientometrics. *Economics*, 18(1), 20220108. <https://doi.org/10.1515/econ-2022-0108>
- Moral-Munoz, J. A., Herrera-Viedma, E., Santisteban-Espejo, A. ve Cobo, M. J. (2020). Software tools for conducting bibliometric analysis in science: An up-to-date review. *El Profesional de La Información*, 29(1). <https://doi.org/10.3145/epi.2020.ene.03>
- Nikou, M., Mansourfar, G. ve Bagherzadeh, J. (2019). Stock price prediction using DEEP learning algorithm and its comparison with machine learning algorithms. *Intelligent Systems in Accounting, Finance and Management*, 26(4), 164-174. <https://doi.org/10.1002/isaf.1459>
- Oliveira, N., Cortez, P. ve Areal, N. (2017). The impact of microblogging data for stock market prediction: Using Twitter to predict returns, volatility, trading volume and survey sentiment indices. *Expert Systems with Applications*, 73, 125-144. <https://doi.org/10.1016/j.eswa.2016.12.036>
- Patel, J., Shah, S., Thakkar, P. ve Kotecha, K. (2015a). Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. *Expert Systems with Applications*, 42(1), 259-268. <https://doi.org/10.1016/j.eswa.2014.07.040>
- Patel, J., Shah, S., Thakkar, P. ve Kotecha, K. (2015b). Predicting stock market index using fusion of machine learning techniques. *Expert Systems with Applications*, 42(4), 2162-2172. <https://doi.org/10.1016/j.eswa.2014.10.031>
- Rasekhschaffe, K. C. ve Jones, R. C. (2019). Machine learning for stock selection. *Financial Analysts Journal*, 75(3), 70-88. <https://doi.org/10.1080/0015198X.2019.1596678>
- Renault, T. (2017). Intraday online investor sentiment and return patterns in the US stock market. *Journal of Banking & Finance*, 84, 25-40. <https://doi.org/10.1016/j.jbankfin.2017.07.002>
- Samitas, A., Kampouris, E. ve Kenourgios, D. (2020). Machine learning as an early warning system to predict financial crisis. *International Review of Financial Analysis*, 71, 101507. <https://doi.org/10.1016/j.irfa.2020.101507>
- Sapankevych, N. ve Sankar, R. (2009). Time series prediction us-

ing support vector machines: A survey. *IEEE Computational Intelligence Magazine*, 4(2), 24-38. <https://doi.org/10.1109/MCI.2009.932254>

Schumaker, R. P. ve Chen, H. (2009). Textual analysis of stock market prediction using breaking financial news: The AZ-Fin text system. *ACM Transactions on Information Systems*, 27(2), 1-19. <https://doi.org/10.1145/1462198.1462204>

Sirignano, J. ve Cont, R. (2021). Universal features of price formation in financial markets: perspectives from deep learning. G. Creamer, G. Kazantsev ve T. Aste (Eds.), *Machine Learning and AI in Finance* (s. 5-15). Routledge.

White, H. (1988, Temmuz). Economic prediction using neural networks: The case of IBM daily stock returns. [Konferans

sunumu özet]. *IEEE 1988 International Conference on Neural Networks*, San Diego, CA, Amerika Birleşik Devletleri

Yürük, M. F. ve Ekşi, İ. H. (2019). Yapay zeka yöntemleri ile işletmelerin finansal başarısızlığının tahmin edilmesi: BİST imalat sektörü uygulaması. *Mukaddime*, 10(1), 393-422. <https://doi.org/10.19059/mukaddime.533151>

Zhong, X. ve Enke, D. (2019). Predicting the daily return direction of the stock market using hybrid machine learning algorithms. *Financial Innovation*, 5(1), 1-20. <https://doi.org/10.1186/s40854-019-0138-0>

Yazar Katkı Oranları

Yazarlar çalışmaya eşit oranda katkı sağlamıştır.

EKLER

Ek 1. Ortak Kelime Ağlarına İlişkin Veriler

Bağlantılar (Nodes)	Küme (Cluster)	Arasındalık (Betweenness)	Yakınlık (Closeness)	Ağdaki önem seviyesi (PageRank)
machine learning	2	344.253	0.02	0.13
deep learning	2	238.614	0.02	0.112
lstm	2	34.554	0.016	0.054
stock market	2	22.381	0.016	0.052
sentiment analysis	2	16.784	0.016	0.042
prediction	2	10.743	0.015	0.033
artificial intelligence	3	9.319	0.016	0.028
long short-term memory	2	6.602	0.014	0.021
neural networks	3	6.455	0.016	0.027
reinforcement learning	1	6.283	0.014	0.021
forecasting	2	5.878	0.014	0.026
stock market prediction	2	5.091	0.015	0.025
stock price prediction	2	4.766	0.014	0.021
stock prediction	3	3.636	0.013	0.021
neural network	2	2.401	0.014	0.016
algorithmic trading	1	2.352	0.013	0.015
time series	2	2.027	0.013	0.018
random forest	2	1.56	0.013	0.017
finance	3	0.995	0.013	0.015
technical indicators	3	0.724	0.013	0.012
cryptocurrency	3	0.659	0.013	0.011
cnn	2	0.606	0.012	0.014
deep reinforcement learning	1	0.576	0.012	0.01
feature selection	2	0.558	0.013	0.011
financial markets	3	0.492	0.013	0.014
convolutional neural network	2	0.471	0.012	0.01
learning	2	0.429	0.013	0.01
gru	2	0.354	0.012	0.013
support vector machine	2	0.275	0.011	0.009
financial time series	2	0.26	0.011	0.008
portfolio management	1	0.235	0.011	0.009
time series forecasting	2	0.231	0.012	0.009
volatility	3	0.23	0.012	0.01
covid-19	2	0.224	0.012	0.009
portfolio optimization	1	0.215	0.012	0.01

natural language processing	3	0.208	0.012	0.013
text mining	2	0.207	0.012	0.01
technical analysis	3	0.185	0.012	0.012
stock price	2	0.171	0.012	0.009
stock	2	0.169	0.012	0.008
financial market	3	0.162	0.012	0.009
asset pricing	3	0.119	0.012	0.011
big data	3	0.099	0.011	0.01
classification	2	0.092	0.011	0.009
attention mechanism	2	0.085	0.012	0.009
stock markets	3	0.083	0.011	0.009
ensemble learning	3	0.072	0.011	0.007
portfolio selection	1	0.062	0.011	0.007
stock price forecasting	2	0.041	0.011	0.007
financial forecasting	3	0.011	0.011	0.008