



2024, 13 (3), 1277-1291 | Araştırma Makalesi

Bankacılık Sektörüne Derin Öğrenme Yöntemiyle Bakış: BIST Banka Endeksi Hareket Yönlerinin Tahmini

Nazif Ayyıldız¹

Öz

Finansal sistemdeki temel oyuncular olan bankalar, ekonominin sağlıklı işleminde kritik bir rol oynamaktadırlar. Banka endeksleri ise, genellikle bir ülkenin finansal sektöründeki performansı yansıtarak ekonomik sağlığın bir göstergesi olarak kabul edilmektedir. BIST Banka Endeksi, Türkiye'nin önde gelen banka hisselerini içeren bir endeks olup, bankacılık sektörünün performansını temsil etmektedir. Diğer yandan, hisse senedi fiyatlarının tahmin edilebilirliği, genellikle karmaşık ve değişken faktörlerle etkilenen bir konudur. Finansal piyasalarda tahmin amacıyla kullanılan temel analiz ve teknik analiz gibi geleneksel yöntemlere ek olarak, son dönemde çok sayıda makine öğrenimi yöntemi geliştirilmiştir. Makine öğrenimi yöntemleri, finansal serilerin doğrusal ve durağan olmayan özelliklerini ele alarak doğru tahminler yapabilmektedir. Tahmin uygulamalarındaki başarısı ile ön plana çıkan derin öğrenme yöntemi ise, büyük veri setlerini etkili bir şekilde işleyerek doğrusal olmayan ilişkileri belirlemede ve yüksek doğrulukla çıkarım yapabilmektedir. Bu çalışmanın amacı, Türkiye'nin önde gelen banka hisselerini içeren BIST Banka Endeksi'nin hareket yönlerinin derin öğrenme yöntemi ile tahmin edilmesidir. Analizde, BIST Banka Endeksi'nin 01.01.2013-31.12.2023 dönemindeki haftalık kapanış değerleriyle birlikte, yine haftalık bazda elde edilen mevduat ve kredi faiz oranları, gecelik faiz oranları, mevduat ve kredi hacimleri, bankacılık sektörü aktif toplamı, döviz kurları (Dolar ve Euro) ve BIST 100 endeksi kapanış değerleri girdi verisi olarak kullanılmıştır. Her bir girdi değişkeni için 574 haftalık veri elde edilmiş olup toplam 5.740 adet veri analizde kullanılmıştır. Gerçekleştirilen analiz sonucunda, derin öğrenme yöntemi ile BIST Banka Endeksi'nin hareket yönleri %88,70 doğrulukta tahmin edilmiştir. Elde edilen bulgular, derin öğrenme yöntemi kullanılarak banka endeks hareket yönlerinin belirli bir seviyede doğru tahmin edilebileceğini göstermektedir.

Anahtar Kelimeler: Finansal Piyasalar, Bankalar, BIST Banka Endeksi, Derin Öğrenme, Sınıflandırma

Ayyıldız, Nazif (2024). Bankacılık Sektörüne Derin Öğrenme Yöntemiyle Bakış: BIST Banka Endeksi Hareket Yönlerinin Tahmini, *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 13 (3), 1277-1291.

<https://doi.org/itobiad.1451709>

Geliş Tarihi	13.03.2024
Kabul Tarihi	08.08.2024
Yayın Tarihi	30.09.2024
*Bu CC BY-NC lisansı altında açık erişimli bir makaledir.	

¹ Öğr. Gör. Dr., Harran Üniversitesi, Suroç Meslek Yüksekokulu, Finans, Bankacılık ve Sigortacılık Bölümü, Şanlıurfa, Türkiye, nazifayyildiz@harran.edu.tr, ORCID: 0000-0002-7364-8436



2024, 13 (3), 1277-1291 | Research Article

A Perspective on the Banking Sector with Deep Learning Method: Prediction of BIST Banking Index Movements

Nazif Ayyıldız¹

Abstract

Banks, the fundamental players in the financial system, play a crucial role in ensuring the healthy functioning of the economy. Bank indices are generally considered indicators of economic health, reflecting the performance of a country's financial sector. The BIST Bank Index, comprising leading bank stocks in Türkiye, represents the performance of the banking sector. On the other hand, predicting stock prices is often a complex issue influenced by various and variable factors. In addition to traditional methods such as fundamental and technical analysis used for forecasting in financial markets, numerous machine learning methods have been developed in recent years. Machine learning methods can effectively handle the non-linear and non-stationary characteristics of financial series, providing accurate predictions. Particularly, the deep learning method has gained prominence in prediction applications by efficiently processing large datasets and identifying non-linear relationships with high accuracy. The aim of this study is to predict the directional movements of the BIST Bank Index, which includes the leading bank stocks in Türkiye, using the deep learning method. The analysis incorporates weekly closing values of the BIST Bank Index from January 1, 2013, to December 31, 2023, along with weekly data on deposit and loan interest rates, overnight interest rates, deposit and loan volumes, total assets of the banking sector, exchange rates (USD and Euro), and BIST 100 index closing values. A total of 574 weeks of data were obtained for each input variable, resulting in the utilization of 5,740 financial data points in the analysis. The analysis revealed that the directional movements of the BIST Bank Index were predicted with an accuracy of 88.70% using the deep learning method. These findings demonstrate that the deep learning method can be effectively employed to predict the directional movements of bank indices with a certain level of accuracy.

Keywords: Financial Markets, Banks, BIST Bank Index, Deep Learning, Classification

Ayyıldız, Nazif (2024). A Perspective on the Banking Sector with Deep Learning Method: Prediction of BIST Banking Index Movements, *Journal of the Human and Social Science Researches*, 13 (3), 1277-1291.
<https://doi.org/itobiad.1451709>

Date of Submission	13.03.2024
Date of Acceptance	08.08.2024
Date of Publication	30.09.2024
*This is an open access article under the CC BY-NC license.	

¹ Lecturer, Dr., Harran University, Suruç Vocational School, Department of Finance, Banking, and Insurance, Şanlıurfa, Türkiye, nazifayyildiz@harran.edu.tr, ORCID: 0000-0002-7364-8436

Giriş

Hisse senedi endeksleri, finansal piyasaların genel eğilimini ölçmek için kullanılan önemli bir referanstır. Borsa endekslerinin tahmin edilmesi yatırımcılar, karar vericiler ve ekonomi yöneticileri için yatırım kararını yönlendirmek, piyasa risklerini değerlendirmek ve makro düzeydeki maliye politikalarını analiz etmek açısından büyük önem taşımaktadır (Kanwal vd. 2022, s.1). Bu nedenle, borsa endekslerinin gelecekteki eğiliminin doğru bir şekilde öngörülmesi hem uygulayıcılar hem de araştırmacılar için sürekli olarak üzerinde durulan bir konudur. Bununla birlikte, hisse senedi fiyat hareketi, şirketlerin faaliyetleri ve bulunduğu sektör ve ülkedeki gelişmeler gibi çok sayıda faktörden etkilenir. Faktörlerin karmaşıklığı ve değişkenliği hisse senedi fiyat tahminini zorlu bir iş haline getirmektedir (Cui vd. 2023, s.1). Bununla birlikte, hisse senedi fiyatlarının hareket yönlerinin tahmin edilmesi, öncelikle piyasaya artan yatırım akışını teşvik ederek ekonomik büyüme katkı sağlayabilir. Ayrıca, yatırımcıların portföylerinde sağlıklı ayarlamalar yapmalarına ve en yüksek getiriye elde etmelerine yardımcı olacak etkili alım-satım stratejileri oluşturmalarına olanak tanıyabilir. Piyasa düzenleyicileri için doğru kararlar almak ve düzeltici önlemleri uygulamak konusunda rehberlik sağlayarak piyasanın adil ve etkin çalışmasına katkıda bulunabilir. Ayrıca, işletme yöneticilerine, firma değerlerini maksimize etme konusunda doğru adımları atma fırsatı sunabilir (Mallikarjuna ve Rao, 2019, s.1-2).

Hisse senedi piyasalarındaki fiyat eğilimlerinin öngörülebilmesi, en uygun analiz yönteminin belirlenmesi ve eğilimlerin maksimum doğrulukla tahmin edilebilmesi ile doğrudan ilgilidir. Ancak, hisse senedi fiyatlarının tahmin edilebilirliği konusu finans alanında hala tartışmalı bir konudur. Bu tartışma, 1970 yılında Eugene Fama tarafından ortaya atılan Etkin Piyasalar Hipotezi üzerinden yürütülmektedir. Etkin piyasalar hipotezine göre, hisse senedi fiyatları yeni bilgilerle belirlenmektedir, fiyatlar geçmiş bilgilerle tahmin edilememektedir ve rastgele bir yürüyüş izlemektedir. Ancak, bu hipotez ortaya atıldığından beri geçerliliği sorgulanmıştır. Diğer yandan sermaye piyasalarında, hisse senedi fiyatlarını tahmin etmek amacıyla temel analiz ve teknik analiz olmak üzere iki ana yöntem kullanılmaktadır. Temel analiz, finansal tabloların ve ekonomik göstergelerin detaylı bir şekilde analizini içerirken; teknik analiz, gelecekteki fiyatları tahmin etmek için geçmiş fiyat hareketlerini incelemeye dayanmaktadır. Temel ve teknik analiz yöntemlerine ek olarak, istatistiksel ve ekonometrik yöntemler arasında yer alan Otogresif Entegre Hareketli Ortalama, Mevsimsel Otogresif Entegre Hareketli Ortalama, Vektör Oto-Regresyon gibi modeller, menkul kıymet borsalarında zaman serilerinin tahmininde kullanılmaktadır. Ancak, bu doğrusal yöntemler, hisse senedi fiyatlarını etkileyen karmaşık ve doğrusal olmayan ilişkileri tam olarak yakalama konusunda birtakım sınırlamalarla karşılaştıkları için çok başarılı oldukları söylenemez. Son yıllarda, borsa analizinde kullanılmak üzere çok sayıda makine öğrenimi yöntemi geliştirilmiştir. Tahmine dayalı modeller oluşturan makine öğrenimi, finansal serilerin doğrusal olmayan ve durağan olmayan özelliklerini ele alarak yüksek doğruluk performansı sergilemektedir. Yakın zamanda yapılan literatür taraması çalışmalarına göre, sinir ağları borsa tahmininde en sık kullanılan yaklaşımlar arasında yer almaktadır (Kumbure vd. 2022, s.22; Ayyıldız, 2023, s.54). Borsa verilerinin analizi ve tahmininde en fazla ön plana çıkan sinir ağı çeşidi ise derin öğrenmedir. Derin öğrenme, çok sayıda doğrusal ve doğrusal olmayan dönüşümden oluşan birden çok işlem katmanına sahip

derin bir yapı kullanarak verilerdeki üst düzey ilişkileri modellemeye çalışan bir makine öğrenimi dalıdır (Zhong ve Enke, 2019, s.2). Derin öğrenme modelleri, büyük hacimli verileri etkili bir şekilde işleme ve karmaşık doğrusal olmayan ilişkileri belirleme yetenekleri sayesinde doğrusal modeller ve geleneksel makine öğrenimi modellerinden daha yüksek performans göstermektedir (Najafabadi vd. 2015, s.2; Beniwal vd. 2024, s.1-2).

Bankalar, finansal sistemdeki temel oyuncular ve ekonominin sağlıklı işlemesi için kritik bir rol oynamaktadırlar. Banka endeksleri ise, genellikle bir ülkenin finansal sektöründeki performansı yansıtarak ekonomik sağlığın bir göstergesi olarak kabul edilmektedir. BIST Banka Endeksi, Türkiye'nin önde gelen banka hisselerini içeren bir endeks olup, bankacılık sektörünün performansını temsil etmektedir. Bu çalışmada, derin öğrenme yöntemi ile BIST Banka Endeksi'nin hareket yönlerinin tahmin edilmesi amaçlanmıştır. Bu amaç doğrultusunda, BIST Banka Endeksi'nin 01.01.2013-31.12.2023 dönemindeki haftalık kapanış değerleriyle birlikte, yine haftalık bazda elde edilen para ve banka istatistikleri ile makroekonomik finansal göstergeleri girdi verisi olarak kullanılmıştır. Bu göstergeler arasında, mevduat ve kredi faiz oranları, gecelik faiz oranları, mevduat ve kredi hacimleri, bankacılık sektörü aktif toplamı, ile döviz kurları (Dolar ve Euro) ve BIST 100 endeksi kapanış değerleri yer almaktadır.

Literatür incelendiğinde, BIST Banka Endeksi'nde yer alan hisse senetlerinin gelecekteki hareket yönlerinin derin öğrenme yöntemi ile tahminine odaklanan sınırlı sayıda çalışma olduğu gözlemlenmiştir. Ancak, doğrudan endeks değerleri üzerinden konuyu araştıran bir çalışmaya rastlanmamıştır. Bankaların hisse senetlerinin ayrı ayrı incelendiği çalışmalarda, genellikle geçmiş veriler, teknik göstergeler veya finansal oranlar girdi verisi olarak kullanılmaktadır. Bu çalışmada, haftalık kapanış değerlerinin yanı sıra, sektör performansları ve ekonomik gösterge niteliğindeki değişkenler girdi verisi olarak alınmıştır. Dolayısıyla çalışmanın bu yönüyle literatüre katkı sağlayacağı düşünülmektedir.

Çalışmanın bir sonraki bölümünde, literatürde derin öğrenme modelleriyle banka hisse senetlerinin ve banka endekslerinin hareket yönlerinin tahminine odaklanan çalışmalar özetlenmiştir. Üçüncü bölümde araştırmada kullanılan veri seti ve uygulamada kullanılan derin öğrenme yöntemi tanıtılmıştır. Dördüncü bölümde, araştırmadan elde edilen bulgular açıklanarak literatürdeki benzer çalışmalarla karşılaştırılmıştır. Çalışmanın sonuç kısmında ise, genel olarak elde edilen sonuçlar değerlendirilerek piyasa katılımcılarına, piyasa düzenleyicilere ve gelecekte benzer çalışma yapabilecek araştırmacılara çeşitli öneriler yapılmıştır.

Literatür Taraması

Çalışma kapsamında, derin öğrenme yöntemiyle banka hisse senetlerinin ve banka endekslerinin hareket yönlerinin tahminine odaklanan çalışmalar incelenmiştir. Bu bölümde incelenen çalışmalar, iki kısma ayrılarak sunulmuştur. İlk kısımda yabancı ülkelerde faaliyet gösteren bankaların hisse senetlerinin hareket yönlerinin tahminine odaklanan çalışmalar; ikinci kısımda ise Türkiye'de faaliyet gösteren ve BIST Bankacılık Endeksi ve bileşenleri özelinde gerçekleştirilen çalışmalar gruplandırılarak özetlenmiştir.

Yabancı ülkelerde konuya odaklanan çalışmalar incelendiğinde; Çin, Hindistan ve Güney Afrika ülkelerinde uygulamaların yapıldığı görülmüştür. Söz konusu çalışmalardan biri olan Lin vd. (2009) çalışmasında, Çin’de 2000-2005 döneminde faaliyet gösteren 44 bankanın hisse senetlerinin hareket yönlerinin tahmini için iki farklı hibrit model önerilmiştir. Önerilen yaklaşımları doğrulamak için iki ayrı veri seti kullanılmıştır. Her iki veri kümesinde de finansal oranlardan oluşan giriş değişkenleri kullanılmıştır. Analiz bulgularına göre, önerilen modellerden %83 ile %98 arasında yön tahmin doğruluğu elde edilmiştir. Çin’de konunun incelendiği farklı bir çalışma olan Jin (2023) çalışmasında ise, BAIDU endeksi kullanılarak bankacılık endeksinin hareket yönleri Uzun Kısa Süreli Hafıza (LSTM) modeli ile tahmin edilmiştir. Analizde, iki farklı veri seti denenmiştir. İlkinde yalnızca geçmiş veriler, ikincisinde ise geçmiş verilere ilave olarak Baidu Endeksi kullanılmıştır. Elde edilen bulgular sonucunda, standart bir LSTM modeline kıyasla duyarlılığa dayalı LSTM modelinin daha iyi tahmin performansı gösterdiği tespit edilmiştir. Hindistan’da konunun incelendiği Mahajan (2023) çalışmasında, Hindistan Borsası (NSE)’nda faaliyet gösteren HDFC Bank’ın hisse senedi fiyat hareketlerinin tahmininde tekrarlayan sinir ağları (RNN) ve LSTM derin öğrenme modelleri kullanılmıştır. 18 Mart 2022 ile 18 Mart 2023 dönemindeki günlük verilere ilave olarak bankacılık, ilaç, petrol, yazılım ve tekstil dahil olmak üzere çeşitli sektörlerden hisse senedi verileri girdi verisi olarak kullanılmıştır. Deneysel sonuçlara göre, kullanılan modellerden %96,5 ve %98,74 doğruluk performansı elde edilmiştir. Güney Afrika’da konunun incelendiği Mcwera ve Mba (2023) çalışmasında ise, Ocak 2012 ile Mart 2022 arasındaki dönemde faaliyet gösteren beş büyük Güney Afrika bankasının günlük hisse senedi hareket yönleri topluluk (hibrit) sınıflandırıcılar ile tahmin edilmesi amaçlanmıştır. Günlük getirilerin yanı sıra finansal değişkenler (fiyat/kazanç oranları, temettü getirileri, piyasa değeri ve kazanç getirisi) girdi verisi olarak kullanılmıştır. Hibrit modellerin beş banka genelinde ortalama %92,4 doğruluk elde ettiği belirlenmiştir.

Türkiye’de Borsa İstanbul Banka Endeksi (BIST Banka) özelinde konuyu ele alan çalışmalar incelendiğinde; genellikle farklı derin öğrenme modelleri kullanıldığı ve belirli bankalar özelinde yön tahmin uygulamalarının yapıldığı görülmüştür. Söz konusu çalışmalardan biri olan Gündüz vd. (2017) çalışmasında, bir derin öğrenme modeli olan Evrişimsel Sinir Ağları (CNN) kullanılarak Garanti Bankası ve İş Bankası hisse senedi fiyatlarının günlük değişim yönlerinin tahmin edilmesi amaçlanmıştır. Girdi verisi olarak bireysel hisse senedi fiyatlarından ve dolar-altın fiyatlarından elde edilen teknik göstergeler kullanılmıştır. Hem fiyat hem de dolar-altın özellikleri kullanılarak yapılan deneylerde Garanti ve İş Bankası hisselerinin hareket yönleri sırasıyla %61 ve %57,4 doğruluk oranları ile tahmin edilmiştir. Borsa İstanbul’daki dokuz farklı banka hisse senedinin hareket yönlerine odaklanan Gündüz vd. (2018) çalışmasında, Uzun-Kısa Süreli Bellek (LSTM) modeli kullanılmıştır. Analiz sonucunda kullanılan modelin ortalama %54 doğrulukla tahmin yapabildiği tespit edilmiştir. İki farklı LSTM modelinin önerildiği Gündüz (2020) çalışmasında ise, Borsa İstanbul’da işlem gören dokuz farklı banka hissesinin saatlik hareket yönleri logaritmik ölçekli hisse senedi fiyatları ve on bir farklı teknik gösterge kullanılarak tahmin edilmiştir. Deneylere göre modellerin ortalama %57,3 doğrulukla tahmin yaptığı belirlenmiştir. Söz konusu dokuz bankaya odaklanan farklı bir çalışma olan Kilimci ve Duvar (2020) çalışmasında ise, Uzun Kısa Süreli Bellek, Tekrarlayan Sinir Ağları ve Evrişimsel Sinir Ağları modelleri kullanılmıştır. Deney

sonuçları, önerilen modellerle banka hisse senetlerinin yönlerinin %86,30, %77,82 ve %79,74 doğrulukla tahmin edilebileceğini göstermektedir.

Veri Seti ve Yöntem

Bu çalışmada BIST Banka Endeksi'nin hareket yönlerinin derin öğrenme yöntemiyle tahmin edilmesi amaçlanmıştır. BIST Banka Endeksi, Türkiye'nin önde gelen banka hisselerini içeren bir endeks olup, bankacılık sektörünün performansını temsil etmektedir. 2024 yılı itibarıyla BIST Banka Endeksi'nde dokuz bankaya ait on iki hisse senedi yer almaktadır. Söz konusu endekste bileşen olarak yer alan bankalar ve hisse senedi kodları Tablo 1'de yer almaktadır.

Tablo 1: BIST Banka Endeksi Bileşenleri

<i>Kodu</i>	<i>Bileşen Adı</i>
AKBNK	Akbank
ALBRK	Albaraka Türk
GARAN	Garanti Bankası
ICBCT	ICBC Türkiye Bank
SKBNK	Şekerbank
TSKB	Türkiye İsmail Kalkınma Bankası
HALKB	Halk Bankası
ISATR	İs Bankası
ISBTR	İs Bankası (B)
ISCTR	İs Bankası (C)
VAKBN	Vakıflar Bankası
YKBNK	Yapı ve Kredi Bankası

Kaynak: Borsa İstanbul (BIST).

Çalışma kapsamında, BIST Banka Endeksi'nin hareket yönleri tahmininde kullanılmak üzere; mevduat ve kredi faiz oranları, gecelik faiz oranları, mevduat ve kredi hacimleri, bankacılık sektörü aktif toplamı verileri ve döviz kurları (Dolar ve Euro) <https://evds2.tcmb.gov.tr> ve BIST Banka ile BIST 100 endekslerinin kapanış değerleri <https://tr.investing.com> adresinden çekilmiştir. Verilerin uyumu kontrol edilmiş ve değişkenlerin haftalık bazda ortak olarak yayınlandığı tarihsel dönem olarak, 01.01.2013-31.12.2023 dönemi uygun araştırma dönemi olarak belirlenmiştir. Söz konusu dönem içerisinde 574 haftalık veri bulunmaktadır. Uygulamada, her bir değişken için 574 veri kullanılmış olup çalışmanın toplam gözlem sayısı 5.740'tır. Veri setinin güvenilirliğini test etmek amacıyla; normallik, otokorelasyon, çoklu doğrusal bağıntı ve heteroskedasticity testleri gerçekleştirilmiştir. Normallik testi, verilerin normal dağıldığını; otokorelasyon analizi, hata terimlerinin bağımsız olduğunu; çoklu doğrusal bağıntı testi, bağımsız değişkenler arasında yüksek korelasyon olmadığını ve heteroskedasticity analizi, hata terimlerinin sabit varyansa sahip olduğunu göstermiştir.

Derin öğrenme modelinin uygulama aşamasında, veri setinin uygun bir oranda eğitim ve test veri seti olmak üzere iki ayrı parçaya ayrılması gerekmektedir. Eğitim veri seti üzerinden öğrenen derin öğrenme modelinin yaptığı tahminler test veri seti ile karşılaştırılmakta ve tahmin performansı ölçülmektedir. Literatürde veri setinin hangi oranlara bölüneceği konusunda genel bir görüş birliği olmamakla birlikte, büyük veri

setleri için sınıflandırma süreçlerinde genellikle 80:20 oranının kullanılması önerilmektedir Kilimci ve Duvar (2020) ve Mahajan (2023) gibi benzer çalışmalarda da 80:20 oranının kullanıldığı gözlemlenmiştir. Literatürdeki öneriler ve benzer çalışmalar dikkate alınarak veri seti %80'i eğitim ve %20'si ise test verisi olmak üzere iki parçaya bölünmüştür. Modelde kullanılan hiper parametrelerin bulunması amacıyla bir optimizasyon işlemi de gerçekleştirilmiştir. Optimizasyonun ardından önce oluşturulan model eğitilmiş sonrasında gerçekleştirilen tahminler test amacıyla ayrılan veri seti ile karşılaştırılarak kullanılan derin öğrenme modelinin tahmin doğruluk performansı ölçülmüştür.

Finansal zaman serileri kullanılarak tahmin yapabilen çeşitli derin öğrenme modelleri geliştirilmiştir. Söz konusu yöntemlerden biri olan H2O Derin Öğrenme Modeli, farklı algoritmaların iç içe kullanılması üzerine tasarlanmıştır. H2O Derin Öğrenme Modeli, karmaşık ilişkileri öğrenme yeteneği ve geniş veri setlerini etkili bir şekilde işleyebilme kapasitesiyle dikkat çekmektedir. H2O Derin Öğrenme Modeli; otomatik uyarlanabilir ağırlık başlatma, otomatik veri standardizasyonu, kategorik verilerin genişletilmesi, eksik değerlerin otomatik olarak işlenmesi, otomatik uyarlanabilir öğrenme oranları, çeşitli düzenleme teknikleri, otomatik performans ayarlama, yük dengeleme, ızgara arama, çapraz doğrulama, kontrol noktası oluşturma ve büyük veri kümeleri için farklı dağıtılmış eğitim modları gibi birçok farklı özelliğe sahiptir. Karmaşık yapılandırma işlemlerine ihtiyaç duymamakta ve maksimum performans alınması için modele optimizasyon işlemi uygulanabilmektedir (H2O, 2024).

H2O derin öğrenme modeli, ileri beslemeli bir mimariye sahiptir. Modeldeki temel birim, insan sinir hücrelerinin biyolojik olarak ilham aldığı bir model olan nörondur. İnsanlarda, nöronların çıkış sinyallerinin değişen güçleri sinaptik kavşaklar boyunca seyahat eder ve ardından bağlı bir nöronun etkinleştirilmesi için giriş olarak bir araya getirilir. Ağırlıklı kombinasyonların hesaplanmasında kullanılan formül Denklem (1)'de verilmiştir (Stetsenko, 2017, s.5).


$$\alpha = \sum_{i=1}^n w_i x_i + b \quad (1)$$

Denklem (1)'de de ifade edildiği üzere modelde, ağırlıklı kombinasyon giriş sinyalleri bir araya getirilir ve ardından bağlı nöron tarafından iletilen bir çıkış sinyali $f(\alpha)$ oluşturulur. Şekil 1'de yer alan görselde de ifade edilen f , ağ boyunca kullanılan doğrusal olmayan etkinleştirme fonksiyonunu ve bias b , nöronun etkinleştirme eşliğini temsil Şekil 1'de yer

alan görselde de ifade edilen f , ağ boyunca kullanılan doğrusal olmayan etkinleştirme fonksiyonunu ve bias b , nöronun etkinleştirme eşiğini temsil etmektedir (Arora vd. 2015).


Şekil 1: Etkinleştirme Fonksiyonu

Çok katmanlı, ileri beslemeli sinir ağları, bir giriş katmanı ile başlayarak özellik uzayını eşleştirmek için bir dizi bağlantılı nöron biriminden oluşur (aşağıdaki görselde gösterildiği gibi). Ardından, nonlinearity içeren çok katmanlı katmanlar gelir ve çıkış uzayını eşleştirmek için bir lineer regresyon veya sınıflandırma katmanı ile sona erer. Modelin birimlerinin girişleri ve çıkışları, yukarıda tanımlanan tek bir nöronun temel mantığına uyar (Stetsenko, 2017).



Şekil 2: Çok Katmanlı, İleri Beslemeli Sinir Ağları

Her bir çıktı katmanının altında bias birimleri bulunmaktadır. Nöronları ve diğer nöronlarla olan bağlantıları belirleyen ağırlıklar, tüm ağın çıktısını tamamen belirler. Öğrenme, bu ağırlıkların etiketli eğitim verilerindeki hatayı en aza indirmek amacıyla adapte edildiğinde gerçekleşir. Denklem (1)'de ifade edildiği üzere, her eğitim örneği j için, amaç bir kayıp fonksiyonunu en aza indirmektir (Arora vd. 2015, s.9).



$$L(W, B | j) \quad (2)$$

Burada, W , N katmana sahip bir ağ için i ve $i + 1$ arasındaki katmanları bağlayan ağırlık matrisini gösteren $\{W_i\}_{1:N-1}$ koleksiyonunu ifade etmektedir. Benzer şekilde, B , $i + 1$ katmanı için bias sütun vektörünü gösteren $\{b_i\}_{1:N-1}$ koleksiyonudur. Bu çok katmanlı sinir ağlarının temel çerçevesi, derin öğrenme görevlerini gerçekleştirmek için kullanılmaktadır (Candel ve Ledel, 2023, s.10).

Bulgular

Derin öğrenme yöntemleri ile ikili sınıflandırma yapıldığında, sınıflandırmanın değerlendirilmesinde karışıklık matrisine göre yapılmaktadır. İkili sınıflandırma için kullanılan karışıklık matrisi Tablo 2’de ifade edilmektedir (Han, Kamber ve Pei, 2012, s.364).

Tablo 2: İkili Sınıflandırma Karışıklık Matrisi

	Gerçek Pozitif Değer	Gerçek Negatif Değer
Öngörülen Pozitif Değer	Doğru Pozitif	Yanlış Negatif
Öngörülen Negatif Değer	Yanlış Pozitif	Doğru Negatif

Karışıklık matrisi tablosu, tahmin edilen sınıf ile gerçek sınıf arasındaki değerleri karşılaştırmak için kullanılmaktadır. Bu tablonun satırları, tahmin edilen sınıfları temsil ederken sütunlar gerçek sınıfları temsil eder. Doğru Pozitif ve Doğru Negatif, doğru bir şekilde sınıflandırılmış pozitif ve negatif örneklerin sayısını yansıtır. Yanlış Negatif ve Yanlış Pozitif ise sırasıyla yanlış bir şekilde sınıflandırılmış negatif ve pozitif örneklerin sayılarını gösterir. Bu matris, modelin performansını değerlendirmek için kullanılmaktadır (Chaurasia ve Tiwari, 2021, s.577).

Sınıflandırıcının performansının değerlendirilmesi, sınıflandırma modelinin oluşturulmasında ve seçiminde kritik bir rol oynamaktadır. Sınıflandırma performansının değerlendirilmesi amacıyla kullanılan en yaygın ölçüt doğruluk oranı olmakla beraber birçok farklı performans metriği de önerilmiştir. Bununla birlikte, bir sınıflandırıcının performansını değerlendirmek için hangi metriğin seçileceğine ilişkin uygulayıcılar arasında genel bir kılavuz bulunmamaktadır (Liu vd. 2014, s.4). Bu çalışma kapsamında performans değerlendirmesinde doğruluk metriği kullanılmış ancak diğer metriklerde hesaplanmıştır. Çalışma kapsamında kullanılan ve hesaplanan metrikler Tablo 3’te sunulmuştur.

Tablo 3: Sınıflandırma Performans Metrikleri

Metrik	Formül
Doğruluk	$\frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{\text{Pozitif} + \text{Negatif}}$
Hata Oranı	$\frac{\text{Yanlış Pozitif} + \text{Yanlış Negatif}}{\text{Pozitif} + \text{Negatif}}$
Kesinlik	$\frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}}$
Duyarlılık	$\frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}}$
F Ölçüsü	$2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$

Kaynak: Mcwera ve Mba (2023).

Sınıflandırma performansının değerlendirilmesinde en yaygın kullanılan ölçüt olan doğruluk metriği, toplam veri içindeki doğru sınıflandırılan örneklerin oranını ölçmektedir (Sokolova ve Lapalme, 2009, s.429). Sınıflandırma performansının değerlendirilmesinde kullanılan hata oranı metriği ise doğruluk oranının tersi olup, yanlış olarak sınıflandırılan örneklerin oranını ölçmektedir. Kesinlik metriği, pozitif olarak tahmin edilen örneklerin gerçekte pozitif olan örneklere oranını ölçmektedir.

Duyarlılık, doğru şekilde sınıflandırılan pozitif örneklerin doğru örneklere oranını ölçerken özgüllük, doğru şekilde sınıflandırılan negatif örneklerin oranını ölçmektedir. F Ölçüsü ise duyarlılık ve kesinlik değerleri arasındaki harmonik ortalamayı ifade etmektedir. 0 ile 1 arasında değer alan söz konusu metriklerinden hata oranının sıfıra yakın olması diğer metriklerin ise 1'e yakın olması performansın yüksekliğine işaret etmektedir (Gong, 2021, s.4). Derin öğrenme modeline ait tahmin performans sonuçları Tablo 4'te sunulmuştur.

Tablo 4: Karışıklık Matrisi ve Performans Sonuçları

Endeks	Hareket Yönü	Gerçek Yükseliş	Gerçek Düşüş	Toplam
BIST Banka	Öngörülen Yükseliş	51	12	63
	Öngörülen Düşüş	1	51	52
	Toplam	52	63	115
<i>Doğruluk</i>	<i>Hata Oranı</i>	<i>Kesinlik</i>	<i>Duyarlılık</i>	<i>F-Ölçüsü</i>
%88,70	%11,30%	%98,08	%80,95	%88,70

Tablo 4'te yer alan karışıklık matrisi incelendiğinde; derin öğrenme modelinin BIST Banka Endeksi'nin 115 günlük hareketinden 51 yükseliş ve 51 düşüş hareketini doğru tahmin ettiği görülmektedir. Dolayısıyla, derin öğrenme yöntemi kullanılarak BIST 100 endeksi %88,70 oranında doğrulukta tahmin edilmiştir. Derin öğrenme modeli 52 yükseliş hareketinden 51'ini; 63 düşüş hareketinden ise 51'ini doğru tahmin etmiştir. Dolayısıyla %98,08 kesinlik, %80,95 duyarlılık oranı elde edilmiştir. Kesinlik ve duyarlılık arasında bir denge sağlayan F-Ölçüsü ise %88,70 olarak hesaplanmıştır. Bu bağlamda "yükseliş" ve "düşüş" sınıf tahminleri arasında iyi bir dengenin olduğu da görülmektedir.

Elde edilen bulgular, yabancı ülkelerde bankalar üzerine odaklanan benzer çalışmalar olarak Lin vd.. (2009), Mahajan (2023), Mcwera ve Mba (2023) çalışmaları ile BIST Banka Endeksi'ne odaklanan Gündüz vd. (2017), Gündüz vd. (2018), Gündüz (2020), Kilimci ve Duvar (2020) çalışmaları ile girdi verileri, derin öğrenme modeli ve elde edilen doğruluk oranları açısından karşılaştırıldığında çalışmanın bulgularının literatüre katkısı daha iyi anlaşılabilir. Söz konusu benzer çalışmalardan Çin'de konunun incelendiği Lin vd. (2009) çalışmasında, 2000-2005 döneminde faaliyet gösteren 44 bankanın hisse senetlerinin hareket yönlerinin tahmininde iki farklı hibrit model kullanılmıştır. Finansal oranlardan oluşan girdi değişkenlerinin kullanıldığı söz konusu çalışmada %83 ile %98 arasında değişen tahmin doğrulukları elde edilmiştir. Hindistan'da konunun incelendiği Mahajan (2023) çalışmasında, HDFC Bank'ın hisse senedi fiyat hareketlerinin tahmininde tekrarlayan sinir ağları ve uzun kısa süreli bellek modelleri kullanılmıştır. Günlük verilere ilave olarak bankacılık, ilaç, petrol, yazılım ve tekstil dahil olmak üzere çeşitli sektörlerden hisse senedi verilerinin girdi verisi olarak kullanıldığı çalışmada kullanılan modellerden %96,5 ve %98,74 oranında doğruluk performansı elde edilmiştir. Güney Afrika'da beş bankanın günlük hisse senedi hareket yönlerinin tahminine odaklanan Mcwera ve Mba (2023) çalışmasında ise, günlük verilerin yanı sıra finansal değişkenler (fiyat/kazanç oranları, temettü getirileri, piyasa değeri ve kazanç getirisi) girdi verisi olarak kullanılmış ve topluluk (hibrit) sınıflandırıcılar ile tahmin yapılmıştır. Kullanılan hibrit model ile beş banka genelinde ortalama %92,4 doğruluk oranı elde edilmiştir. Bu çalışmalara kıyasla, BIST Banka Endeksi'nin yön tahmininde elde edilen %88,70 doğruluk

oranı, uluslararası benzer çalışmalarla yakın seviyelerde bir doğruluk oranının yakalandığını göstermektedir.

BIST Banka Endeksi özelinde konuyu ele alan çalışmalarda; genellikle farklı derin öğrenme modelleri kullanılarak belirli bankalar özelinde yön tahmin uygulamaları yapılmıştır. Söz konusu çalışmalardan biri olan Gündüz vd. (2017) çalışmasında, bir derin öğrenme modeli olan evrişimsel sinir ağı kullanılarak Garanti ve İş Bankası hisse senedi fiyatlarının günlük hareket yönleri tahmin edilmiştir. Girdi verisi olarak bireysel hisse senedi fiyatları ve dolar-altın fiyatlarından elde edilen teknik göstergeler kullanılarak Garanti ve İş Bankası hisselerinin hareket yönleri sırasıyla %61 ve %57,4 doğrulukla tahmin edilmiştir. BIST Banka Endeksi'ndeki dokuz farklı banka hisse senedinin hareket yönüne odaklanan Gündüz vd. (2018) çalışmasında, Uzun-Kısa Süreli Bellek (LSTM) modeli kullanılmış ve ortalama %54 doğruluk oranına elde edilmiştir. Söz konusu dokuz hisseye odaklanan Gündüz (2020) çalışmasında ise, iki farklı LSTM modelinde hisse senetlerinin saatlik hareket yönü logaritmik ölçekli hisse senedi fiyatları ve teknik göstergeler kullanılarak tahmin edilmiştir. Kullanılan modellerin ortalama %57,3 doğrulukla tahmin yaptığı belirlenmiştir. Söz konusu dokuz banka hisse senedine odaklanan farklı bir çalışma olan Kilimci ve Duvar (2020) çalışmasında ise, uzun kısa süreli bellek ağları, tekrarlayan sinir ağları, evrişimli sinir ağları modelleri kullanılmıştır. Kullanılan modellerle banka hisse senetlerinin yönü %86,30, %77,82 ve %79,74 doğrulukla tahmin edilmiştir. BIST Banka Endeksi bileşenlerinin incelendiği önceki çalışmalarda elde edilen ortalama doğruluk oranı %68'dir. Buna karşın, bu çalışmada, kullanılan girdi değişkenlerinin çeşitliliği ve derin öğrenme modellerinin optimizasyonu ile %88,70 doğruluk oranına ulaşılarak üstün bir tahmin performansı elde edilmiştir. Elde edilen bu yüksek doğruluk oranı, BIST Banka Endeksi'nin hareket yönlerinin tahmininde daha güvenilir ve etkili modellerin geliştirilmesi için önemli bir referans noktası olarak değerlendirilebilir.

Sonuç

Hisse senedi alım satımı, global bir borsa platformunda milyonlarca aktif yatırımcının katılımıyla gerçekleşen bir süreçtir. Bu süreç, halka açık şirketlerin hisselerinin işletme politikaları, makroekonomik etkiler, küresel dinamikler, teknolojik gelişmeler ve yatırımcı tercihleri gibi bir dizi faktör tarafından etkilendiği için oldukça karmaşıktır. Bununla birlikte sermaye piyasalarında, hisse senedi fiyatlarını tahmin etmek için kullanılan iki temel analiz yöntemi bulunmaktadır: temel analiz ve teknik analiz. Temel analizde, ekonomi, sektör ve firma analizleri ile gerçek değer belirlenmekte ve bu değer, piyasa fiyatı ile karşılaştırılarak alım veya satım kararı verilmektedir. Diğer taraftan, teknik analizde, ekonomi ve sektör analizi yapmadan, sadece geçmiş fiyat hareketleri ve işlem hacmi gibi verilere dayanılarak gelecekteki fiyat hareketleri tahmin edilmeye çalışılmaktadır. Son yıllarda bilgisayar ve yapay zekâ tabanlı makine öğrenmesi teknikleri de sermaye piyasalarında tahmin amacıyla kullanılmaktadır. Makine öğrenimi yöntemleri arasında ise, büyük miktarda veriye dayanarak karmaşık ilişkileri tespit etme ve öğrenme yeteneği ile derin öğrenme öne çıkmaktadır. Derin öğrenme, yüksek boyutlu zaman serilerindeki karmaşık ilişkileri ve eğilimleri tespit etme kapasitesinden dolayı finansal piyasalarda etkili bir analitik tahmin yöntemi olarak kullanılmaktadır.

Bu çalışmada, derin öğrenme yöntemi ile Türkiye'nin önde gelen banka hisselerini içeren BIST Banka Endeksi'nin hareket yönlerinin tahmin edilmesi amaçlanmıştır. Analizde, BIST Banka Endeksi'nin 01.01.2013-31.12.2023 dönemindeki haftalık kapanış değerleriyle birlikte, yine haftalık bazda elde edilen mevduat ve kredi faiz oranları, gecelik faiz oranları, mevduat ve kredi hacimleri, bankacılık sektörü aktif toplamı, döviz kurları (Dolar ve Euro) ve BIST 100 endeksi kapanış değerleri girdi verisi olarak kullanılmıştır. Analiz sonucunda, BIST Banka Endeksi'nin hareket yönleri %88,70 oranında doğrulukta tahmin edilmiştir. Ulaşılan bu sonuç, literatürdeki benzer araştırmaların sonuçlarıyla karşılaştırıldığında daha anlamlı hale gelebilir. Bu bağlamda, elde edilen %88,70 doğruluk oranıyla, yabancı ülkelerde banka endeksleri üzerine yapılan benzer çalışmalara yakın bir tahmin performansına ulaşılırken; BIST Banka Endeksi'ne odaklanan çalışmalardan daha üstün bir tahmin performansı elde edildiği görülmüştür. Bu durumun ise, kullanılan girdi değişkenleri ve derin öğrenme modellerinin farklılığından kaynaklandığı düşünülmektedir.

Bu çalışmada, derin öğrenme yöntemi kullanılarak Türkiye'nin önde gelen banka hisselerini içeren BIST Banka Endeksi'nin hareket yönlerinin tahmin edilmesi amaçlanmıştır. BIST Banka Endeksi'nin 01.01.2013-31.12.2023 dönemindeki haftalık kapanış değerleri ile birlikte, yine haftalık bazda elde edilen mevduat ve kredi faiz oranları, gecelik faiz oranları, mevduat ve kredi hacimleri, bankacılık sektörü aktif toplamı, döviz kurları (Dolar ve Euro) ve BIST 100 endeksi kapanış değerleri analizde girdi verisi olarak kullanılmıştır. Analiz sonucunda, BIST Banka Endeksi'nin hareket yönleri %88,70 doğruluk oranıyla tahmin edilmiştir. Elde edilen bu sonuç, literatürdeki benzer araştırmalarla karşılaştırıldığında daha anlamlı hale gelebilir. Bu bağlamda, elde edilen %88,70 doğruluk oranıyla, yabancı ülkelerde banka endeksleri üzerine yapılan benzer çalışmalara yakın bir tahmin performansına ulaşılırken; BIST Banka Endeksi'ne odaklanan çalışmalardan daha üstün bir tahmin performansı elde edildiği görülmüştür.

Elde edilen bulgular, derin öğrenme yöntemi ile banka endeks hareket yönlerinin belirli bir seviyede doğru tahmin edilebileceğini göstermektedir. Bu ise; banka yatırımcıları, banka yöneticileri ve devlet için çeşitli avantajlar sunabilir. Banka yatırımcıları için, doğru endeks tahminleri daha sağlam yatırım stratejileri oluşturmalarına yardımcı olabilir ve riskleri minimize etme konusunda rehberlik edebilir. Ayrıca, doğru tahminler, yatırımcılara hızlı karar alma yeteneği kazandırarak yatırımcıların piyasa koşullarına daha etkili bir şekilde adapte olmalarını sağlayabilir. Banka yöneticileri için, bu bulgular stratejik planlama süreçlerinde rehberlik ederek gelecekteki ekonomik koşulları daha iyi değerlendirme fırsatı sunabilir. Devlet açısından ise, doğru endeks tahminleri ekonomik büyümeyi destekleyebilir, düzenleyicilere rehberlik edebilir ve finans sektöründeki güçlü performans genel ekonomiye yansyarak ekonomik kalkınmaya katkı sağlayabilir.

Elde edilen sonuçlarla birlikte, çalışmanın belirli kısıtları da göz önüne alınmalıdır. Bu kısıtlar arasında, uygulamanın belirli bir dönem aralığına odaklanması, haftalık verilerin kullanılması, teknik göstergelerin ihmal edilmesi ve tek bir modelle tahmin yapılması gibi faktörler bulunmaktadır. Gelecekte yapılacak çalışmalarda, mevcut literatürde bulunan çeşitli teknik göstergelerle birlikte farklı sektörel verilerin girdi değişkenleri olarak entegre edilmesi, tahmin yönteminin doğruluk oranını artırabilir. Hibrit modellerin tahmin süreçlerinde kullanılması, daha etkili ticaret stratejilerinin oluşturulmasına katkı sağlayabilir. Ayrıca, sadece belirli bir dönem veya endeksle sınırlı

kalmaksızın, farklı dönemler ve/veya farklı borsa endeksleri üzerinde uygulamaların gerekleřtirilmesi önerilebilir. Bu önerilen yaklařımlar, finansal piyasalarda daha güvenilir ve kořullara uygun tahminler elde etme konusunda arařtırmacılara ve uygulayıcılara yeni perspektifler sunabilir.

Deęerlendirme	İki Dıř Hakem / ift Tarafı Krleme
Etik Beyan	Bu alıřmanın hazırlanma srecinde bilimsel ve etik ilkelere uyulduęu ve yararlanılan tm alıřmaların kaynakada belirtildięi beyan olunur.
Benzerlik Taraması	Yapıldı – Ithenticate
Etik Bildirim	itobiad@itobiad.com
ıkar atıřması	ıkar atıřması beyan edilmemiřtir.
Finansman	Bu arařtırmayı desteklemek iin dıř fon kullanılmamıřtır.
Peer-Review	Double anonymized - Two External
Ethical Statement	It is declared that scientific and ethical principles have been followed while carrying out and writing this study and that all the sources used have been properly cited.
Plagiarism Checks	Yes - Ithenticate
Conflicts of Interest	The author(s) has no conflict of interest to declare.
Complaints	itobiad@itobiad.com
Grant Support	The author(s) acknowledge that they received no external funding in support of this research.

Kaynakça

Arora, A., Candel, A., Lanford, J., Ledel, E., & Parmar, V. (2015). Deep Learning with H2O. H2O.ai, Erişim Tarihi:22.02.2024, DeepLearning_Vignette.pdf(h2o-release.s3.amazonaws.com)

Ayyıldız, N. (2023). *Prediction of Stock Market Index Movements with Machine Learning*. Özgür Publications. DOI: <https://doi.org/10.58830/ozgur.pub354>

Beniwal, M., Singh, A. & Kumar, N. (2024). Forecasting Multistep Daily Stock Prices for Long-Term Investment Decisions: A Study of Deep Learning Models on Global Indices", *Engineering Applications of Artificial Intelligence*, 129, DOI:10.1016/j.engappai.2023.107617

Borsa İstanbul-BIST (2024), BIST Banka Endeks Bileşenleri, Erişim Tarihi: 18.02.2024, <https://www.borsaistanbul.com/tr/endeks-detay/264/bist-banka>

Candel, A. & Ledel, E. (2015). Deep Learning with H2O. H2O.ai, Erişim Tarihi:27.02.2024, DeepLearning_Vignette.pdf (h2o-release.s3.amazonaws.com)

Chaurasia, A. & Tiwari, R.K. (2021). Stock Price Prediction using Various Machine Learning. *International Journal of Advances in Engineering and Management*. 3(1):573-581, DOI: 10.35629/5252-0301573581

Cui, C., Wang, P., Li, Y. & Zhang, Y. (2023), McVCsB: A New Hybrid Deep Learning Network for Stock Index Prediction, *Expert Systems with Applications*, 232, DOI:10.1016/j.eswa.2023.120902

Fama, E.F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *Journal of Finance*, 25 (2), 383-417, DOI:10.2307/2325486

Gong, M. (2021). A Novel Performance Measure for Machine Learning Classification. *International Journal of Managing Information Technology*, 13(1), 11-19. DOI:10.5121/IJMIT.2021.13101

Gündüz, H., Cataltepe, Z. & Yaslan, Y. (2017). Stock Market Direction Prediction using Deep Neural Networks, *25th Signal Processing and Communications Applications Conference (SIU)*, Antalya, Türkiye, 1-4, DOI:10.1109/SIU.2017.7960512

Gündüz, H., Yaslan, Y. & Çataltepe, Z (2018). Stock Market Prediction with Deep Learning Using Financial News, *26th IEEE Signal Processing and Communications Applications Conference (SIU)*, IEEE, New York, Amerika Birleşik Devletleri

Gündüz, H (2020). Stock Market Prediction with Stacked Autoencoder Based Feature Reduction. *28th Signal Processing and Communications Applications Conference (SIU)*. DOI:10.1109/siu49456.2020.9302391

H2O (2024), H2O Deep Learning (Neural Networks), Erişim Tarihi:25.02.2024, <https://docs.h2o.ai/h2o/latest-stable/h2o-docs/data-science/deep-learning.html>

Jin, S. (2023). Sentiment-Driven Forecasting LSTM Neural Networks for Stock Prediction-Case of China Bank Sector, *International Journal of Advanced Computer Science and Applications (IJACSA)*, 14(11), 2023. DOI:10.14569/IJACSA.2023.0141101

Lin,S.W., Shiue,Y.R, Chen,S.C. & Cheng,H.M. (2009), Applying Enhanced Data Mining Approaches In Predicting Bank Performance: A Case of Taiwanese Commercial Banks, *Expert Systems with Applications*, 36(9), 11543-11551, DOI:10.1016/j.eswa.2009.03.029.

Kanwal, A., Lau,M.F., P.H. Ng,S., Sim,K.Y. & Chandrasekaran,S. (2022). BiCuDNNLSTM-1dCNN-A Hybrid Deep Learning-Based Predictive Model for Stock Price Prediction, *Expert Systems with Applications*, 202, DOI:10.1016/j.eswa.2022.117123.

Kilimci Z. H. and Duvar, R. (2020). An Efficient Word Embedding and Deep Learning Based Model to Forecast the Direction of Stock Exchange Market Using Twitter and Financial News Sites: A Case of Istanbul Stock Exchange (BIST 100), *IEEE Access*, 8, 188186-188198, DOI:10.1109/ACCESS.2020.3029860

Kumbure, M.M., Lohrmann C., Luukka, P.& Porras, J. (2022). Machine Learning Techniques and Data for Stock Market Forecasting: A literature Review, *Expert Systems with Applications*, 197, DOI:10.1016/j.eswa.2022.116659.

Liu, Y, Zhou, Y. Wen, S. & Tang, C. (2014), A Strategy on Selecting Performance Metrics for Classifier Evaluation", *International Journal of Mobile Computing and Multimedia Communication*,, 6, 20-35 DOI:10.4018/IJMCMC.2014100102

Mahajan, S. Anand, P. K. Sarangi & A. K. Sahoo, (2023) Escalate the Returns With ML-Based Technical Analysis: Next Day Closing Price Prediction Using RNN and LSTM Models, *3rd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)*, 261-266, DOI:10.1109/ICACITE57410.

Mallikarjuna, M.& Rao, R.P. (2019), Evaluation of Forecasting Methods from Selected Stock Market Returns. *Financ Innov*, 5, 40. DOI:10.1186/s40854-019-0157-x

Mcwera, A. & Mba, J. C., (2023). Predicting Stock Market Direction in South African Banking Sector Using Ensemble Machine Learning Techniques. *Data Science in Finance and Economics*, 3(4): 401-426. DOI:10.3934/DSFE.2023023

Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Selhya, N., Wald, R., & Muharemagic, E. (2015). Deep Learning Applications and Challenges in Big Data Analytics. *Journal Of Big Data*, 2(1), 1-21. DOI:10.1186/s40537-014-0007-7

Sokolova, M. & Lapalme, G. (2009). A Systematic Analysis of Performance Measures For Classification Tasks. *Information Processing & Management*. 45. 427-437. DOI:10.1016/j.ipm.2009.03.002

Stetsenko, P. (2017), Machine Learning with Python and H2O, Fifth Edition, Erişim Tarihi: 28.02.2024, [DeepLearning_Vignette.pdf](https://www.deeplearning.vignette.pdf) (h2o-release.s3.amazonaws.com)

Türkiye Cumhuriyet Merkez Bankası. (2024). TCMB Bankacılık Verileri, Erişim Tarihi:20.02.2024,<https://www.tcmb.gov.tr/wps/wcm/connect/TR/TCMB+TR/Main+Menu/Istatistikler/Bankacilik+Verileri/>

Zhong, X., & Enke, D. (2019). Predicting the Daily Return Direction Of The Stock Market Using Hybrid Machine Learning Algorithms, *Financial Innovation*, 5. DOI:10.1186/s40854-019-0138-0.