

BIST100 ENDEKSİ FİYATININ LSTM, CNN-LSTM VE BILSTM MODELLERİ İLE TAHMİN EDİLMESİ

İrem VARÜNER¹

Özer ÖZAYDIN²

Fatih ÇEMREK³

Özet

Kendine birçok alanda yer bulan derin öğrenme günümüzün üzerine çalışılan en popüler konulardandır. Teknolojinin gelişip üzerine çalışıldıkça derin öğrenmenin yeni modelleri bulunmaktadır. Finans alanında da sıkça kullanılan derin öğrenme modelleri özellikle tahminleme çalışmalarında da ön plana çıkmaktadır. Bu çalışmada, Borsa İstanbul (BIST100) Endeksinin tahmini amacıyla derin öğrenme modelleri olan LSTM, BILSTM ve CNN-LSTM kullanılarak karşılaştırmalı bir analiz gerçekleştirilmiştir. 1 Ocak 2014 ile 28 Şubat 2025 tarihleri arasındaki günlük BIST100 verilerinin yanı sıra DAX, NASDAQ, S&P 500, NİKKEİ 225 ve FTSE 100 gibi global borsa endeksleri bağımsız değişkenler olarak modele dahil edilmiştir. Python programlama dili ve Keras kütüphanesi kullanılarak oluşturulan modellerin performansı RMSE (Root Mean Square Error) metriği ile değerlendirilmiştir. Elde edilen sonuçlara göre, en düşük RMSE değeri olan 170.8730 ile CNN-LSTM modeli en başarılı tahminleme performansını göstermiştir. BILSTM modeli 178.5661 RMSE değeriyle ikinci sırada yer alırken, LSTM modeli 308.5097 RMSE değeriyle en düşük performansı sergilemiştir. Bu bulgular, BIST100 endeksin tahmininde derin öğrenme tabanlı modellerin etkili bir şekilde kullanılabileceğini ve gelecekteki çalışmalarda farklı model kombinasyonlarının daha başarılı sonuçlar sağlayabileceğini ortaya koymaktadır.

Anahtar Kelimeler: BIST100, Derin Öğrenme, BILSTM, LSTM, CNN-LSTM

Jel Sınıflandırma Kodları: G14, G17

¹ Eskişehir Osmangazi Üniversitesi, Fen Fakültesi İstatistik Bölümü, ORCID: 0000-0001-9788-1729, irem.1997.rvr@gmail.com

² Dr. Öğr. Üyesi, Eskişehir Osmangazi Üniversitesi, Fen Fakültesi İstatistik Bölümü, ORCID: 0000-0001-6657-1162, oozaydin@ogu.edu.tr

³ Doç. Dr., Eskişehir Osmangazi Üniversitesi, Fen Fakültesi İstatistik Bölümü, ORCID: 0000-0002-6528-7159, fcemrek@ogu.edu.tr

PREDICTING THE BIST100 INDEX PRICE USING LSTM, CNN-LSTM, AND BILSTM MODELS

İrem VARÜNER⁴

Özer ÖZAYDIN⁵

Fatih ÇEMREK⁶

Abstract

Deep learning, which has found its place in many fields, is one of the most popular topics studied today. As the technology develops and studied, there are new models of deep learning. Deep learning models, which are frequently used in finance, come to the forefront especially in forecasting studies. In this study, a comparative analysis is carried out using deep learning models LSTM, BILSTM and CNN-LSTM to predict the Borsa Istanbul (BIST100) index. Daily BIST100 data between January 1, 2014 and February 28, 2025 as well as global indices such as DAX, NASDAQ, S&P 500, NIKKEI 225 and FTSE 100 are included in the model as independent variables. The performance of the models built using Python programming language and Keras library is evaluated with the RMSE metric. According to the results obtained, the CNN-LSTM model showed the most successful forecasting performance with the lowest RMSE value of 170.8730. The BILSTM model ranked second with an RMSE value of 178.5661, while the LSTM model showed the lowest performance with an RMSE value of 308.5097. These findings suggest that deep learning-based models can be used effectively in predicting the BIST100 index and that different model combinations may provide more successful results in future studies.

Keywords: BIST100, Deep Learning, BILSTM, LSTM, CNN-LSTM

Jel Classification Codes: G14, G17

⁴ Eskişehir Osmangazi University, Faculty of Science Department of Statistics, ORCID: 0000-0001-9788-1729, irem.1997.rvr@gmail.com

⁵ Assist.Prof., Eskişehir Osmangazi University, Faculty of Science Department of Science, ORCID: 0000-0001-6657-1162, oozaydin@ogu.edu.tr

⁶ Assoc. Prof. Dr., Eskişehir Osmangazi University, Faculty of Science Department of Science, ORCID: 0000-0002-6528-7159, fcemrek@ogu.edu.tr

GİRİŞ

Borsa, genel tanımı itibariyle alıcılar ile satıcıların ya da onların temsilcilerinin belirli düzenlemeler çerçevesinde karşı karşıya geldiği organize piyasalardır. Bu piyasalar; hisse senetleri, tahviller gibi menkul kıymetlerin ve bunlara benzer finansal araçların alım satım işlemlerinin gerçekleştirildiği ortamlardır. Bahsi geçen işlemler, belirli kurallar altında ve zaman sınırlamalarıyla işleyen merkezi piyasa yapıları içerisinde yürütülmektedir (Karşı,1994). Köken bilim olarak borsa kavramının 1531 yılında Belçika'nın Bruges kentinin isminden veya Anvers kentinde, "Van Der Buers" ailesinin soyadından türediği ileri sürülmektedir (Fertekligil,2000). Tarihsel gelişim süreci incelendiğinde 16.yüzyılda Paris ve Londra'da, 17.yüzyılda Berlin'de, 18.yüzyılda Viyana ve New York'ta, Brüksel, Roma, Milano, Madrid, Tokyo ve İstanbul'da ise 19.yüzyılda borsaların kurulduğu görülmektedir.

Borsalar üzerine yapılan çalışmalar hisse senedi fiyatlarının yalnızca ekonomik davranışları yansıtmadığını, aynı zamanda piyasada bulunan bilgi düzeyinin bir göstergesi olduğunu ortaya koymuştur. Hisse senedi fiyatlarının gelecekteki hareketlerinin tahmin edilebilirliği, yatırımcılar açısından son derece stratejik bir öneme sahiptir. Bu öngörülebilirlik, yatırım kararlarını yönlendirme ve finansal kazanç elde etme açısından uygulayıcılar için vazgeçilmez bir araç haline gelmiştir. Modern ekonomik sistemlerde finansal piyasalar sadece ekonomik yapıların değil aynı zamanda sosyal organizasyonların da temel bileşenlerinden biri olarak değerlendirilmektedir.

Finansal piyasalar, fon fazlası olan ekonomik birimler ile fon ihtiyacı duyan aktörlerin karşılaştığı yapılar olarak tanımlanmaktadır. Ulusal ekonomiler, yalnızca kendi iç finansal yapılarından değil, küresel ölçekte diğer ülke piyasalarından da etkilenmektedir. Bu nedenle finansal piyasalarda yaşanan gelişmeler doğrudan ülke ekonomilerinde çeşitli yansımalar doğurabilmektedir. Öte yandan, finansal sistemler sadece profesyonel yatırımcıların değil, bireysel tasarruf sahiplerinin de ilgi gösterdiği alanlar haline gelmiştir. Bu bağlamda para ve sermaye piyasalarında faaliyet gösteren yatırımcılar, piyasalardaki eğilimleri analiz ederek doğru tahminlerde bulunmayı ve bu doğrultuda yatırım kararlarını şekillendirmeyi hedeflenmektedir. Bu tür stratejik yaklaşımlarda hisse senedi hareketlerinin altında yatan yapısal dinamiklerin doğru anlaşılması büyük önem arz etmektedir. İlgili dinamiklerin geçmiş verilere dayalı analizlerle değerlendirilmesi ve çeşitli modelleme yöntemleriyle geleceğe yönelik

öngörüler oluşturulması karar alma süreçlerinde rehberlik edebilmektedir. Bu modellerin oluşturulma sürecinde ise günümüzün en popüler konularından olan yapay zekâ önemli bir yer tutmaktadır.

Yapay zekâ sunduğu yenilikçi çözümlerle günümüzde birçok sektörde vazgeçilmez hale gelmiştir. Bu doğrultuda, derin öğrenme ve makine öğrenmesi gibi alt alanlar da giderek daha fazla ilgi çekmektedir. Yapay zekâ uygulamaları bireylerin günlük yaşamını kolaylaştırdığı gibi iş dünyasında da verimliliği arttırmaktadır. Ancak bu teknolojilerin faydaları kadar olası riskleri de tartışılmaktadır. Bununla birlikte yapay zekanın günlük hayatta kullanım alanı genişlemekte ve farklı sektörlerle entegrasyonu hızlanmaktadır.

Bu çalışmada derin öğrenme modellerinden BILSTM, LSTM ve CNN-LSTM modelleri BIST100 endeksi tahminlemesi yapılması için seçilmiştir. 01.01.2014 tarihinden 28.02.2025 tarihine kadar günlük BIST100 endeksi değerleri kullanılmak üzere alınmıştır. BIST100 modeli tahminlemesinde bu endekse etkisi olduğu düşünülen DAX, NASDAQ, NIKKEI 225, S&P 500, FTSE 100 dünya endeksleri bağımsız değişkenler olarak çalışmaya dahil edilmek üzere seçilmiştir. Böylelikle dünyanın önde gelen borsalarının BIST100 üzerindeki etkisi altında modellerin tahminleme performansları karşılaştırılmış olacaktır.

1. Literatür taraması

Chalvatzis ve Hristu-Varsakelis (2019), derin öğrenmeye dayalı bir LSTM modelini kullanarak 2010-2018 zaman aralığı için hisse senedi fiyat tahmini yapmış ve modelin ticaret stratejileriyle entegrasyonunu incelemiştir. S&P 500, Dow Jones Industrial Average (DJIA), NASDAQ ve Russel 2000 endeksleri üzerinde test edilen model, geleneksel “al ve tut” stratejisine kıyasla önemli ölçüde daha yüksek getiri sağlamıştır. Bu çalışma LSTM’nin yalnızca tahmin doğruluğu açısından değil, aynı zamanda yatırım getirisi sağlama açısından da avantaj sunduğunu vurgulamaktadır.

Siame-Namini, Tavakoli ve Siame Namin (2019), finansal zaman serisi tahmininde geleneksel ARIMA modelini, LSTM ve BILSTM modelleriyle karşılaştırmıştır. Çalışmanın amacı, 2009-2019 zaman aralığı için BILSTM modelinin ek eğitim katmanları sayesinde daha iyi tahmin performansı gösterip göstermediğini belirlemektir. Sonuçlar, BILSTM’nin LSTM’ye kıyasla %37,78 daha düşük hata oranına sahip olduğunu ortaya koymuştur.

Taş, Gülüm ve Tulum (2021), S&P 500 endeksine ait verileri kullanarak derin öğrenme ve sığ öğrenme yöntemleriyle geleceğe yönelik fiyat tahminlemesi yapmıştır. Veriler 12.08.2000 ile 13.8.2020 tarihleri arasında alınmıştır. Çalışmada, LSTM ve Çok Katmanlı Algılayıcı (MLP) yöntemleri kullanılarak tahminler gerçekleştirilmiş ve bu iki yöntemin tahmin performansları karşılaştırılmıştır. Sonuç olarak, LSTM mimarisinin tahmin gücünün MLP yöntemine göre daha iyi olduğu görülmüştür.

Akbulut (2022), BIST100 endeksi ile emtia, döviz fiyatları ve gelişmekte olan ülkelerin borsa endeksleri arasındaki ilişkiyi makine öğrenmesi ve derin öğrenme yöntemleri kullanarak incelemiştir. Çalışma verisi Ocak 2017 ile Ekim 2021 arasındadır. Çalışmada, LSTM modelinin makine öğrenmesi modellerine göre daha iyi sonuç verdiği görülmüştür.

Güney (2022), yüksek lisans tezinde derin öğrenme modelleri olan Yinelemeli Sinir Ağı (RNN), Uzun Kısa Süreli Bellek (LSTM) ve Geçitli Tekrarlayan Birim (GRU) yöntemlerini karşılaştırarak bir şirketin hisse senedi günlük kapanış fiyatlarını 30, 60, 90 ve 120 günlük periyotlarla tahmin etmeyi amaçlamıştır. Çalışma verileri 02.01.2012 ile 31.12.2020 yılları arasındaki “Gölaş Çimento” hisse senetleridir. Çalışmanın sonucunda GRU modelinin, LSTM ve RNN’ye kıyasla daha başarılı tahmin performansı sergilediği gözlemlenmiştir.

Altuntaş ve Kocamaz (2023), BIST100 endeksinin yön tahmininde derin öğrenme tabanlı bir görüntü sınıflandırma yaklaşımı önermiştir. Veri aralığı Ocak 2006 ile 31 Aralık 2020’dir. Çalışmada, ön eğitilmiş evrişimsel sinir ağı (CNN) modelleri olan AlexNet, GoogleNet ve ResNet-50 kullanılmıştır. İnce ayarlı CNN modellerinin, diğer karşılaştırma yönteminden daha iyi sonuçlar elde ettiği gösterilmiştir.

Babu ve Sathyanarayana (2023), çalışmalarıyla hisse senedi fiyat tahmini doğruluğunu arttırmak amacıyla çok katmanlı Çift Yönlü Uzun Kısa Süreli Bellek (BILSTM) modelleri ile Dinamik Gösterge (DIF) özelliklerini birleştiren bir yaklaşım önermiştir. Veri seti Ocak 2001’den Aralık 2020’ye kadar olan zaman dilimidir. Teknik ve temel analiz verilerini birleştiren model, RSI, ROC ve ATR gibi göstergelerle zenginleştirilmiş ve performans ölçümleri doğrultusunda önerilen BILSTM-DIF modelinin geleneksel ve artımlı BILSTM modellerine kıyasla daha üstün bir tahmin başarısı gösterdiği ortaya konmuştur.

Zhang Ye ve Lai (2023), hisse senedi fiyatlarını ve endekslerini tahmin etmek için bir CNN-BILSTM-Attention modeli önermiştir. Çalışmada 4 Ocak 2011 ile 31 Aralık 2021 arasındaki veriler kullanılmıştır. Model, Çin ve uluslararası borsalardan alınan verilerle test edilmiş ve LSTM, CNN-LSTM ve CNN-LSTM-Attention gibi diğer yöntemlere göre daha yüksek doğruluk elde ettiği bulunmuştur.

Akusta ve Salur (2024), BIST100 endeksinde yer alan hisse senetlerinin alım satımı için derin öğrenme tabanlı metodolojilerin kullanılmasını ele almıştır. Çalışma verileri Ağustos 2022 ile Aralık 2023 olarak alınmıştır. Tahmine dayalı işlem algoritması (TDIA) adı verilen derin öğrenme esaslı bir işlem algoritması geliştirilmiş ve bu algoritmanın BIST100'de temsil edilen çeşitli sektörlerdeki hisse senedi hareketlerini tahmin etme ve işlem gerçekleştirme başarıları değerlendirilmiştir. Araştırmanın temel bulguları, TDIA'nın seçilen hisse senetlerinde ortalama %15,87 kar ile kayda değer bir başarı elde ettiğini göstermektedir.

Çelik (2024), BIST100 endeksi tahmini için bellek tabanlı makine öğrenmesi (MBML) modellerine dayalı bir yaklaşım sunmuştur. Bu amaçla, ardışık veri değerlendirmesinde popüler olan LSTM ve Geçitli Tekrarlayan Birim (GRU) mimarileri kullanılmıştır. Veriler Temmuz 1997 ile 1 Aralık 2023'e kadar olan tarih aralığıdır. Modellerin eğitim ve doğrulama aşamalarında düşük kayıplar gösterdiği ve BIST100 endeksinin genel eğilimlerini başarıyla takip ettiği gözlemlenmiştir. Ancak modellerin piyasa dalgalanmaları ve ani değişimlerde gerçek değerlerden sapmalar gösterdiği belirlenmiştir.

Sönmez ve Çoşkun Arslan (2024), finansal piyasalardaki volatilitenin etkilerini analiz ederek BIST100 ve DAX endekslerini tahmin etmek için LSTM modelini kullanmıştır. Veri seti 30.01.2012'den 26.06.2024 tarihine kadar olan süreyi kapsamaktadır. Çalışmada, VIX, OVX, EVZ ve GVZ volatilité endeksleri girdi değişkenleri olarak belirlenmiş ve modelin tahmin performansı değerlendirilmiştir. Sonuçlar, LSTM modelinin yüksek tahmin doğruluğuna sahip olduğunu göstermiştir. Özellikle modelin RMSE, MAE, MAPE ve R^2 değerlerinin her iki endeks içinde başarılı olduğu tespit edilmiştir. Bu bulgular, LSTM modelinin yatırım stratejileri ve risk yönetimi için etkili bir araç olabileceğini ortaya koymaktadır.

2. Materyal ve yöntem

Yapay zekâ günümüzde en sık karşılaşılan ve gelişimi hızla süren teknolojik kavramlardan birisidir. İnsan beyni karmaşık yapısı nedeniyle halen tam anlamıyla çözülememiş bir organ olarak kabul edilse de bilgisayar sistemlerinin insan benzeri düşünme ve karar alma süreçlerini simüle edebilmesi yapay zekâ çalışmalarının temel amacıdır.

Yapay zekâ, bilgisayarların ve bilgisayar destekli makinelerin insan zihnine benzer şekilde öğrenme, problem çözme ve karar alma gibi yetenekleri sergileyebilmesini sağlayan bir bilim dalıdır. Yapay zekâ kavramı ilk olarak 1955 yılında Dartmouth College’de düzenlenen bir konferansta ortaya atılmış ve o tarihten itibaren hızla gelişim göstermiştir. Bilgisayar donanımlarının güçlenmesi ve büyük veri setlerine erişimin kolaylaşması ile birlikte, yapay zekâ uygulamaları daha yaygın hale gelmiştir (Öztürk ve Şahin, 2018).

Yapay zekâ, sağlık sektöründen otonom araçlara kadar birçok alanda devrim niteliğinde gelişmelere yol açmıştır. Örneğin, tıp alanında teşhis koyma süreçlerinde yapay zekâ destekli sistemler doktorlara büyük kolaylık sağlamaktadır. Finans alanında ise algoritmik ticaret sistemleri yapay zekâ tabanlı tahmin modelleri ile yatırımcılara yön göstererek risk yönetimini optimize etmektedir. Bunun yanı sıra eğitim ve sanayi gibi sektörlerde de yapay zekanın etkinliğe giderek artmaktadır.

Yapay zekâ çalışmalarının önemli bir bileşeni olan yapay sinir ağları (YSA), insan beynindeki sinir hücrelerinden esinlenerek geliştirilmiştir. Yapay sinir ağları ile ilgili ilk çalışmalar, 1943 yılında McCulloch ve Pitts tarafından gerçekleştirilmiş olup bu araştırmalar neticesinde beyin nöronlarının basit yapısına dayalı matematiksel bir model geliştirilmiştir. Bu modeller girdi verilerini analiz ederek anlamı çıktılar üretir ve bu süreçte öğrenme mekanizmalarını kullanır. YSA, başlangıçta yalnızca akademik çalışmaların bir konusu iken günümüzde finans, sağlık, askeri vb. birçok alanda kendine geniş kullanım yeri bulmuştur. (McCulloch ve Pitts, 1943).

YSA, temel olarak 5 ana bileşenden oluşmaktadır: girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar. En basit sinir ağı yapısında giriş verileri ilgili ağırlık kat sayıları ile çarpılarak toplama fonksiyonuna tabi tutulur. Daha sonra hesaplanan bu toplam değere yanlılık eklenir ve aktivasyon fonksiyonu aracılığıyla işlenerek çıktı değeri elde edilir. Model üretilen çıktıların gerçek değerlere mümkün olduğunca yaklaşmasını

sağlamak amacıyla sürekli olarak güncellenir. Farklı denemeler sonucunda, tahmin edilen değerler ile gerçek değerlerin en yakın olduğu noktada öğrenme süreci tamamlanır (Çınar, 2018).

Yapay sinir ağlarının geliştirilmesi, makine öğrenmesi ve derin öğrenme gibi alt disiplinlerin doğmasına neden olmuştur. Makine öğrenmesi, bilgisayarların veri setleri aracılığıyla öğrenme yeteneği kazanmasını sağlarken, derin öğrenme ise çok katmanlı sinir ağları kullanarak daha karmaşık veri yapılarından öğrenmeyi hedefleyen bir yaklaşım olarak öne çıkmaktadır. Özellikle büyük veri setlerinin işlenmesi konusunda derin öğrenme modelleri, geleneksel makine öğrenmesi yöntemlerine kıyasla daha başarılı sonuçlar verebilmektedir (Gayhardt vd., 2024).

2.1. Derin öğrenme

Derin öğrenme, günümüzde veri biliminde en çok araştırılan ve geliştirilen alanlardan biri haline gelmiştir. Yapay zekâ teknolojilerinin ilerlemesi ve büyük veri kümelerine erişimin kolaylaşması, bu alandaki çalışmaların yoğunlaşmasına olanak tanımıştır. Derin öğrenme, çok katmanlı yapay sinir ağları (YSA) kullanarak verilerden öğrenme sağlayan ve yapay zekanın alt dallarından biri olarak kabul edilen bir yaklaşımdır (Karataş, 2020).

Derin öğrenme çalışmalarının temelleri, 1943 yılında McCulloch ve Pitts'in insan beyninin nöron yapısını modelleyen ilk yapay sinir ağları modelini geliştirmesi ile atılmıştır. Ancak, 1950'li yıllardan önce bilgisayar teknolojisinin sınırlı olması, hesaplama kapasitelerinin yetersizliği ve veri işleme ile ilgili kısıtlamalar nedeniyle bu alanda kayda değer bir ilerleme sağlanamamıştır.

Yapay zekâ çalışmaları, 1940'lardan itibaren gelişim göstermiş, 1980'lerin başında makine öğrenmesi popüler hale gelmiş ve 2010'lu yıllarda makine öğrenmesinin eksiklerini gideren derin öğrenme yaklaşımları ön plana çıkmıştır (Öztürk ve Şahin, 2018).

2.1.2. Derin öğrenme modelleri

Bilgisayar işlemcilerinin hızlanması ve veri setlerinin giderek büyümesi, derin öğrenme modellerinin birçok alanda yaygın olarak kullanılmasını sağlamıştır. Çok katmanlı yapay sinir ağları sayesinde görüntü, ses ve metin gibi farklı veri türleri üzerinde etkili analizler gerçekleştirilebilmektedir. Bu

gelişmeler, derin öğrenmenin farklı mimari yapılarını içeren çeşitli modellerin ortaya çıkmasını sağlamıştır.


Derin öğrenme modelleri, mimarilerine ve işlevlerine göre çeşitlilik göstermektedir. Bu modeller arasında Yapay Sinir Ağları (ANN), Evrişimli Sinir Ağları (CNN), Kapsül Ağlar (CN), Yinelemeli Sinir Ağları (RNN), Uzun Kısa Süreli Hafıza (LSTM), Üretken Çekişmeli Ağlar (GAN), Sınırlı Boltzmann Makineleri (RBM), Derin İnanç Ağları (DBN), Derin Oto-Kodlayıcılar (DAE) ve Kapılı Yinelemeli Birimler (GRU) gibi yapılar bulunmaktadır.

Son yıllarda, belirli sinir ağlarının birleştirilmesi ile oluşturulan hibrit modellerde yaygınlaşmıştır. Örneğin, CNN ve LSTM modellerinin birlikte kullanıldığı CNN-LSTM mimarisi veya çift yönlü sinir ağları olan Bidirectional (BIRNN, BIGRU, BILSTM) modelleri, çeşitli uygulama alanlarında yüksek performans sağlamaktadır (Çoban ve Özyurt, 2022).

2.1.3. Uzun kısa süreli bellek (LSTM) modeli

LSTM (Uzun Kısa Süreli Bellek), tekrarlayan sinir ağlarının özel bir türüdür. Bu model, uzun süreli bağımlılıkları öğrenme kapasitesine sahip olup belleğe dayalı yapısı ile zaman serisi verilerinin işlenmesinde büyük avantajlar sunmaktadır. LSTM, uzun süreli bellek mimarisini destekleyen ve hafıza hücreleri adı verilen özel birimler içeren bir yapıdır. Bu hafıza hücreleri, belirli bilgilerin uzun süre saklanmasına olanak tanırken hangi bilgilerin korunacağı veya unutulacağı da modelin iç mekanizmaları tarafından belirlenir. LSTM, üç temel kapı mekanizmasına sahiptir. Bunlar unutma kapısı, giriş kapısı ve çıkış kapısıdır. Bu kapılar, gelen verilerin nasıl işlendiğini ve modelin hangi bilgilere odaklanması gerektiğini belirleyerek öğrenme sürecini yönlendirir.

LSTM modelinde yer alan kapılar, girdileri işleyerek modelin hafızasında hangi bilgilerin saklanacağını ve hangilerinin eleneceğini belirlemek için aktivasyon fonksiyonları kullanır. En yaygın kullanılan aktivasyon fonksiyonlarından biri sigmoid fonksiyonudur. Sigmoid fonksiyonu verileri 0 ile 1 arasında bir değer aralığında sınırlayarak bilginin ne kadar önemli olduğunu belirler. Eğer bir bilgi için sigmoid fonksiyonunun çıktısı 0'a yakınsa bu bilgi unutulurken; 1'e yakın çıktılar ise ilgili bilginin korunmasını sağlar. (Şişmanoğlu vd., 2020)



Şekil 2. LSTM modeli temel yapısı (Varürer ve Özaydın, 2024)

LSTM modelinin temel yapısı Şekil 2’de gösterilmektedir. Modelin kullandığı kapılardan bir tanesi unutma kapısıdır (Varürer ve Özaydın, 2024).

Unutma kapısı, modelin hangi bilgilerin tutulacağına ve hangilerinin silineceğine karar veren mekanizmadır (Güney, 2022).

$$f_t = \sigma(w_f \cdot [H_{t-1}, X_t] + b_f) \quad (1)$$

Bu formül ile unutma vektörü hesaplanmaktadır. Burada X_t mevcut giriş verisini, H_{t-1} ise bir önceki gizli katman durumunu ifade etmektedir. Bu girdiler, sigmoid aktivasyon fonksiyonuna (σ) uygulanarak işlenir. Sigmoid fonksiyonu sıfır ile bir arasında değerler üreterek, hangi bilgilerin tutulacağına veya silineceğe karar verilmesini sağlar. Elde edilen f_t değeri, hücre durumunun güncellenmesi için kullanılır (Akbulut, 2022).

Modelde kullanılan bir diğer kapı giriş kapısıdır. Giriş kapısı yeni bilgilerin hücre durumuna nasıl dahil edileceğini belirleyen yapıdır. Modelin öğrenme süreci açısından kritik bir bileşen olup, hücre durumu güncellenirken hangi bilgilerin dahil edileceğini belirler.

$$i_t = \sigma(w_i \cdot [H_{t-1}, X_t] + b_i) \quad (2)$$

$$\tilde{c}_t = \tanh(w_c \cdot [H_{t-1}, X_t] + b_c) \quad (3)$$

İlk aşamada X_t ve H_{t-1} giriş değerleri, sigmoid aktivasyon fonksiyonuna uygulanarak 0 ile 1 arasında bir değere dönüştürülür. Daha sonra aynı girdiler hiperbolik tanjant fonksiyonundan geçirilerek, -1 ile 1 arasında değişen $\tilde{c}_t$

vektörü oluşturulur. Bu işlem modelin yeni bilgileri ağ içerisine nasıl entegre edeceğini belirlemek için kullanılmaktadır (Güney, 2022).

Model daha sonra hücre durumunu kapılardan aldığı son bilgilerle yeniler. Hücre durumu modelin uzun vadeli bağımlılıkları nasıl yöneteceğini belirleyen kritik bir bileşendir. Önceki hücre durumuna yapılan güncellemeler ile yeni bilgilerin ne kadarının mevcut duruma entegre edileceği belirlenir.

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (4)$$

Bu denklemde, C_{t-1} önceki hücre durumunu, f_t unutma vektörünü, i_t giriş vektörünü ve $\tilde{C}_t$ ise tanh fonksiyonundan geçirilmiş yeni hücre durumunu ifade etmektedir. Unutma vektörü, geçmiş bilgilerden hangilerinin korunacağını belirlerken, giriş vektörü ise yeni eklenen bilgilerin hangi oranda hücreye dahil edileceğini belirler. Bu işlemler sonucunda, ağı öğrenme süreci tamamlanır ve hücre durumu güncellenmiş olur (Akbulut, 2022).

Modelin kullandığı son kapı ise çıkış kapısıdır. Çıkış kapısı, modelin ürettiği yeni gizli durumun belirlenmesinde rol oynar. Önceki aşamalarda işlenen bilgiler, çıkış kapısı aracılığıyla bir sonraki adıma aktarılır.

$$O_t = \sigma(W_o \cdot [H_{t-1}, X_t] + b_o) \quad (5)$$

$$H_t = O_t \times \tanh(C_t) \quad (6)$$


Bu aşamada, mevcut giriş değerleri ve bir önceki gizli durum üçüncü sigmoid fonksiyonuna uygulanır. Daha sonra, güncellenmiş hücre durumu tanh fonksiyonundan geçirilerek, yeni bir çıktı değeri oluşturulur. Çıktı değeri ile hücre durumu noktadan noktaya çarpılarak, ağı bir sonraki zaman adımına taşıyacağı bilgi belirlenir. Bu süreç, modelin zaman serisi tahminleri veya sınıflandırma görevleri için kullanılacak çıktıyı oluşturmasını sağlar.

Sonuç olarak LSTM modeli, uzun vadeli bağımlılıkları öğrenme yeteneği sayesinde birçok farklı uygulama alanında kullanılmaktadır. Unutma kapısı, giriş kapısı ve çıkış kapısı gibi temel bileşenleri sayesinde, modelin hangi bilgileri saklayacağı ve hangi bilgileri unutacağı belirlenir. Bu sayede hem zaman serisi analizlerinde hem de doğal dil işleme (NLP) gibi alanlarda yüksek doğrulukta tahminler yapabilmektedir. Modelin eğitimi tamamlandığında elde edilen çıktı değeri, regresyon veya sınıflama gibi problemlerde kullanılmak üzere uygun hale getirilir (Akbulut, 2022).

2.1.4. Çift yönlü uzun kısa süreli bellek (BILSTM) modeli

LSTM modelinin geliştirilmiş bir versiyonu olarak kabul edilen BILSTM, veri işleme sürecinde önemli avantajlar sunmaktadır. LSTM, yalnızca ileri yönlü bilgi akışı sağladığı için, geçmiş bilgilere doğrudan erişemez ve bu durum zaman içindeki bağlamın eksik değerlendirilmesine yol açabilir. Bu eksikliği gidermek amacıyla geliştirilen BILSTM, girdilerin hem geçmiş hem de gelecek bağlamını kullanabilmesine olanak tanıyan bir yapıdadır. Bu sayede önceki ve sonraki zaman adımlarındaki bilgileri dikkate alarak daha kapsamlı bir öğrenme süreci geliştirmektedir.

BILSTM, temel olarak iki bağımsız LSTM katmanından oluşur. Bu katmanlardan biri veriyi ileri yönde işlerken, diğeri geriye doğru işlemektedir. Böylece model giriş verisini her iki yönde de analiz edebilir ve zaman içindeki ilişkileri daha güçlü bir şekilde öğrenebilir. Çift yönlü bilgi işleme mekanizması, özellikle bağlamsal bütünlüğün kritik olduğu doğal dil işleme (NLP) ve zaman serisi analizlerinde büyük bir avantaj sağlamaktadır.




Şekil 3. Üç defa katlanmış BILSTM modeli (Varürer ve Özaydın, 2024)

Şekil 3’de BILSTM modelinin yapısı gösterilmektedir. Şekilde, X_{t-1}, X_t, X_{t+1} sırasıyla $t - 1, t$ ve $t + 1$ zaman adımlarındaki giriş verilerini temsil etmektedir. Modelin ileri yönlü durumları $\vec{h}_{g(t-1)}, \vec{h}_{g(t)}, \vec{h}_{g(t+1)}$ ile gösterilirken, geri yönlü durumları ise $\overleftarrow{h}_{g(t-1)}, \overleftarrow{h}_{g(t)}, \overleftarrow{h}_{g(t+1)}$ şeklinde ifade edilmektedir. Ayrıca modelde kullanılan σ aktivasyon fonksiyonu ile Y_{t-1}, Y_t, Y_{t+1} çıktıları sırasıyla $t - 1, t, t + 1$ zaman adımlarına karşılık gelen çıkış değerlerini göstermektedir (Karataş, 2020).

2.1.5. CNN-LSTM hibrit modeli

Derin öğrenme alanında, farklı model mimarilerinin avantajlarından yararlanarak daha etkili tahmin ve analizler yapmak için hibrit modeller sıkça tercih edilmektedir. CNN-LSTM hibrit modeli, evrişimli sinir ağlarının (CNN) özellik çıkarma yeteneği ile uzun kısa dönemli bellek (LSTM) ağlarının zaman serisi verileri işleme becerisini birleştiren bir yaklaşım sunar. Bu model, görüntü ve zaman serisi verileri gibi ardışık yapıdaki verileri analiz etmek için özellikle etkili bir seçenektir. Şekil 4'te CNN-LSTM modelinin işleyiş biçimi gösterilmiştir.



Şekil 4. CNN-LSTM modeli işleyiş biçimi

CNN-LSTM modeli genellikle iki temel aşamada çalışır. Bunlar özellik çıkarma ve zaman içinde öğrenme aşamalarıdır.

Özellik çıkarma yani CNN katmanları, verilerdeki mekânsal ve yerel örüntüleri yakalamak için kullanılır. Evrişimsel katmanlar, girdi verisini filtreleyerek önemli özellikleri belirler. Ardından, havuzlama (pooling) katmanları sayesinde boyut azaltımı yapılır ve gereksiz bilgiler elimine edilir. Bu aşama görüntü işleme gibi uygulamalarda çok kritik olup zamansal verilerde de etkili özellik temsilleri oluşturulmasına yardımcı olur.

Zaman içinde öğrenme aşamasında ise CNN katmanlarından geçen ve boyutu azaltılan özellik haritaları, zaman içinde ardışık ilişkileri öğrenmek üzere LSTM katmanlarına girdi olarak verilir. LSTM, uzun vadeli bağlantıları koruyarak önceki zaman dilimlerindeki bilgilerin unutulmadan yeni bilgilerle birleştirilmesini sağlar. Bu sayede zaman serisi verilerindeki karmaşık bağıntılar etkili bir şekilde yakalanabilir. LSTM katmanlarından geçen veriler tam bağlantılı katmanlara iletilir ve nihai tahmin veya sınıflandırma işlemi gerçekleştirilir. Bu aşamada aktivasyon fonksiyonları kullanılarak modelin çıktısı optimize edilir.

CNN-LSTM modelleri, finansal zaman serisi tahminleri, görüntü ve video analizleri, doğal dil işleme gibi çeşitli uygulama alanlarında başarıyla

kullanılmaktadır. Modelin esnekliği ve derin öğrenme yaklaşımlarını birleştirme yeteneği karmaşık veri setlerinde üstün performans göstermesini sağlar (Livieris et al., 2020).

2.2. Borsa İstanbul endeksi (BIST100)


Borsa İstanbul 100 endeksi (BIST100), Türkiye sermaye piyasalarının en önemli göstergelerinden biri olup, Borsa İstanbul'da işlem gören en yüksek piyasa değerine ve işlem hacmine sahip 100 şirketin performansını yansıtmaktadır. Bu endeks, yatırımcılar için piyasanın genel eğilimlerini izlemek adına temel bir referans niteliği taşımaktadır. Günlük hesaplanan bir endeks olup, makroekonomik gelişmeler, küresel piyasa koşulları bu yatırımcı davranışları gibi faktörlerden etkilenmektedir.

Bu çalışmadaki amaç, BIST100'ün tahminini dünyadaki diğer önemli borsa endeksleri olan DAX, NASDAQ, NIKKEI225, S&P500 ve FTSE100 endeksleri yardımıyla gerçekleştirmektir. Bunun için 1 Ocak 2014-28 Şubat 2025 tarihleri arasında söz konusu borsaların günlük kapanış değerleri kullanılmıştır. BIST100 endeksinin tahminlenmesi için derin öğrenme içerisinde yer alan BILSTM, LSTM ve hibrit bir model olan CNN-LSTM modelleri kullanılmıştır. Çalışmada kullanılan bütün veriler <https://tr.investing.com> Türkiye sitesinden alınmıştır. Söz konusu modellerin analizi için Python programının Keras kütüphanesinden yararlanılmıştır. Yukarıda bahsi geçen her 3 model için de Min-Max normalizasyonu gerçekleştirilmiş ve veriler 0 ile 1 arasında dönüştürüldükten sonra tahminleme işlemi gerçekleştirilmiştir. Model kurulurken eğitim ve test verisi %80'e %20 olacak şekilde alınmıştır. BIST100 endeksinin son 10 günlük tahminlemesi ilgili modeller tarafından gerçekleştirilmiştir. Bulunan değerler gerçek değerlerle karşılaştırılmıştır.

Her bir kurulan modelin batch size (eğitim için kullanılan bir sayı) değeri 32, epochs (döngü sayısı) değeri 50 olarak verilmiştir. Her bir model en az 10 kez çalıştırılmıştır. Modellerin başarısı, her birinin tahmin doğruluğunu ölçmek için RMSE (Root Mean Squared Error) metriği kullanılarak değerlendirilmiştir.

3.Bulgular

Şekil 6'da 1 Ocak 2014 itibari ile 28 Şubat 2025 dahil olmak üzere çalışmada kullanılan dünya endekslerinin günlük verileri gösterilmektedir



Şekil 6. Ocak 2014 – Şubat 2025 dahil BIST100, DAX, NASDAQ, NIKKEI225, S&P500, FTSE100 endeksleri günlük verileri

Tüm değişkenlerin söz konusu tarih aralığındaki seyri şekil 6’da görülmektedir. Veri seti ile ilgili ön bilgi olması adına Tablo 2’de de veri setinin ilk on gözlem değeri verilmiştir.

Tablo 2. Veri setinin ilk on gözlem değeri

Tarih	BIST100	DAX	S&P 00	NASDAQ	NIKKEI225	FTSE100
02.01.2014	673.67	9598	1845	4160.03	14464.67	6749.09
03.01.2014	671.51	9409	1833	4148.56	14474.01	6717.91
06.01.2014	662.82	9419	1832	4137.03	14403.07	6730.67
07.01.2014	676.52	9446	1828	4128.57	14319.75	6730.73
08.01.2014	684.46	9512	1837	4154.28	14155.34	6755.45
09.01.2014	667.13	9492	1839	4179.04	14355.56	6721.78
10.01.2014	668.70	9473	1840	4168.94	14026.17	6691.34
13.01.2014	683.90	9497	1841	4167.41	14271.48	6739.94


14.01.2014	671.38	9391	1821	4129.60	14289.87	6757.15
15.01.2014	680.70	9590	1840	4196.53	14527.97	6766.86

Veri setinin bazı genel istatistiksel değerleri aşağıdaki Tablo 3'te verilmiştir.

Tablo 3. Veri setinin genel istatistikleri

	Veri sayısı	Ort.	Min.	%25	%50	%75	Max.	Std. Sapma
BIST100	2802	2560.80	611.78	846.71	1074.76	2445.87	11194.41	2948.27
DAX	2802	13036.15	8495	11044	12596	15115	20732	2629.18
NASDAQ	2802	9479.46	4015.07	5254.6	8005.72	13234.2	20114.9	4354.25
NIKKEI225	2802	24032.81	13887.2	19194	22339.9	28108.3	42343.7	6814.73
S&P500	2802	3259.30	1743	2172.2	2906	4167.75	6134	1146.50
FTSE100	2802	7108.94	4993.89	6730.7	7187.32	7509.27	8673.96	611.17

İlk olarak kurulan BILSTM modelinin tahmin sonuçları Şekil 7'deki grafikte gösterilmiştir.



Şekil 7. BIST100 BILSTM tahmin modeli

Şekil 7'de yeşil çizgi tahmin edilen değerleri, mavi çizgi gerçek değerleri ve turuncu çizgi ise eğitim verisini temsil etmektedir. Grafikten de fark

edileceği üzere gerçek değerler ve tahmin edilen değerler birbirine oldukça yakın seyretmektedir. Bu yüzden de değerlere daha açık bir şekilde aşağıda bakılmıştır.

Tablo 4. BILSTM modeli tahmin edilen değerler ve gerçek değerler

	BIST100 Gerçek	BIST100 Tahmin
2662	9976.68	9973.37
2663	9874.42	9935.97
2664	10041.43	9892.35
2665	9866.98	9885.80
2666	10038.19	9856.97
2667	9966.57	9862.62
2668	9979.48	9860.48
2669	9927.42	9863.56
2670	9739.80	9859.24
2671	9561.73	9824.19

Tablo 4’de ilk sütun gerçek değerleri temsil ederken, ikinci sütun model tarafından tahmin edilen değerleri göstermektedir. Model kimi değerleri oldukça yakın bir şekilde tahmin etmişken bazı değerleri ise çok yüksek sapmalarla tahmin ettiği görülmektedir. BILSTM modelinin RMSE değeri 178.5661 olarak bulunmuştur.


İkinci olarak kurulan model LSTM modeli olup BIST100 tahmin değerlerinin grafiği Şekil 8’de gösterilmiştir.



Şekil 8. BIST100 LSTM tahmin modeli

Şekil 8'deki grafikte açık bir şekilde gerçek değerler ile tahmin edilen değerler arasında bariz bir fark olduğu görülebilmektedir. Bu fark kurulan modelin RMSE değerinde de kendini göstermiştir. Kurulan LSTM modelinin RMSE değeri 308.5097 olarak bulunmuştur. RMSE değerinin yüksekliği sebebiyle değerlere ayrıntılı bir şekilde bakılmaya gerek görülmemiştir.

Son olarak kurulan model hibrit bir model olan CNN-LSTM modelidir. Şekil 9'da son 547 değer söz konusu model sonucunda elde edilen tahmin değerleri ile gerçek değerler arasındaki ilişki grafiği gösterilmiştir.



Şekil 9. BIST100 CNN-LSTM hibrit model tahmini

Şekil 9'da son 547 değer grafik üzerinde gösterilmesinin sebebi, görüldüğü üzere gerçek endeks değerleri ve model tarafından tahmin edilen endeks değerleri birbirine oldukça yakın seyretmekte, kimi noktalarda ise

çizgiler çıkmaktadır. Bununla birlikte gerçek ve tahmin verilerinin uyumunu görmek daha mümkün olmuştur. CNN-LSTM modeli ile tahmin edilen son 5 değer ve gerçek değerler Tablo 5'te görülmektedir.

Tablo 5. CNN-LSTM hibrit modeli ile tahmin edilen değerler ve gerçek değerler

	BIST100 Gerçek	BIST100 Tahmin
543	9815.92	9730.85
544	9694.37	9797.005
545	9583.73	9681.25
546	9467.96	9601.09
547	9565.61	9507.75

Tablo 5'te ilk sütun BIST100 gerçek değerlerini ikinci sütun ise çalıştırılan hibrit model tarafından tahmin edilen değerleri göstermektedir. Model bazı değerleri küçük sapmalar ile daha yakın tahmin edebilmiş iken diğer değerlerde sapmaların büyüdüğü gözlenmektedir. Kurulan bu hibrit CNN-LSTM modelinin RMSE değeri 170.8730 olarak bulunmuştur.

Her bir modelin karşılaştırmalı şekilde RMSE değeri Tablo 6'da gösterilmiştir.

Tablo 6. Kurulan modellerin RMSE değeri

Kriter	BILSTM modeli	LSTM modeli	CNN-LSTM modeli
RMSE değeri	178.5661	308.5097	170.8730

Her bir kurulan modelin RMSE değerine tek tek bakıldığı zaman içlerinde en başarılı tahminleme modelinin CNN-LSTM modeli olduğu belirlenmiştir. Bu sonuç kısa dönem tahminlemede CNN-LSTM modelinin diğer modellere göre daha başarılı olduğu anlamına gelmektedir. CNN-LSTM modeline yakın tahminleme yaptığı görülen BILSTM modelinin de nispeten başarılı tahminleme yaptığı söylenebilir. Kurulan üç model arasında LSTM modeli diğer modellere kıyasla daha zayıf tahminleme yapmıştır.

SONUÇ

Bu çalışmada, BIST100 endeksinin tahmin edilmesinde derin öğrenme teknikleri olan BILSTM, LSTM ve CNN-LSTM modelleri kullanılarak karşılaştırmalı bir analiz yapılmıştır.

CNN-LSTM modelinin, diğer modellerden daha düşük bir RMSE değeri olan 170.8730 ile en başarılı tahminleme modelini oluşturduğunu ortaya koymuştur. Kurulan bir diğer model olan BILSTM modeli de RMSE değeri 178.5661 ile nispeten başarılı sonuçlar elde etse de CNN-LSTM modeline göre zayıf kalmıştır. Kurulan bir diğer model olan LSTM modeli ise RMSE değeri 308.5097 ile tahmin gücü diğer iki modele kıyasla çok daha zayıftır.

Yapılan literatür taramasında yer alan çalışmalar, derin öğrenme modellerinin finansal zaman serisi tahminlerinde önemli başarılar elde ettiğini göstermektedir. Özellikle hibrit modeller ve BILSTM modellerinin, klasik ARIMA gibi yöntemlere kıyasla daha düşük hata oranları ve daha yüksek doğruluk sunduğu tespit edilmiştir. Örneğin Siami-Namini, Tavakoli ve Siami Namin (2019) BILSTM modelinin LSTM'ye göre daha düşük hata oranına sahip olduğunu ortaya koymuştur. Akbulut 2022'de yaptığı çalışmasında hem makine öğrenmesi yöntemlerini hem de derin öğrenme modeli olan LSTM modelini kullanmıştır. Bulduğu sonuçlarında derin öğrenme modeli olan LSTM'nin makine öğrenmesi modellerine göre daha iyi sonuç verdiğini gözlemlemiştir. Çelik ise 2024'te yaptığı çalışmasında LSTM ve GRU modellerini kullanmıştır. Modellerin doğrulama aşamalarında düşük kayıplar gösterdiği ve endeksin genel eğilimlerini başarıyla takip ettiğini bulmuştur. Fakat modeller piyasa dalgalanmaları ve ani şoklarda gerçek değerlerden saptığını gözlemlemiştir.

Özellikle geleneksel istatistiksel modelleme tekniklerinin kurulması için sağlanması gereken varsayımların derin öğrenme gibi tekniklerde geçerliliğine gerek duyulmaksızın tahminleme yapılabilmesi ve bu tahminlerden başarılı sonuçlar elde edilmesi derin öğrenme kavramını iyice önemli bir hale getirmiştir. Bu çalışmada kullanılan derin öğrenme modelleri BIST100 endeksinin tahmin etme konusunda başarılı sonuçlar sunmuş ve gelecekteki tahminleme çalışmalarına yönelik değerli bilgiler sağlamıştır. Farklı model kombinasyonları ve parametre ayarları ile tahmin doğruluğunun artırılması gelecekte yapılabilecek çalışmalar için daha iyi sonuçlar bulmayı mümkün kılacaktır.

KAYNAKÇA

- Akbulut, S. (2022, Mart). Makine Öğrenmesi ve Derin Öğrenme Yöntemleri Kullanılarak BIST100 Endeksi ile Emtia, Döviz Fiyatları ve Gelişmekte olan Ülkelerin Borsa Endeksleri Arasındaki İlişkinin İncelenmesi. *Yüksek Lisans Tezi*. Aksaray, Türkiye: AKSARAY ÜNİVERSİTESİ.
- Akusta, A., & Salur, M. N. (2024). Derin Öğrenme Tabanlı Fiyat Tahmini ve Algoritmik Ticaret: BIST100 Endeksinde Bir Uygulama . *Fiscoeconomia*, s. 8(3), 1194-1215.
- Altuntaş, Y., & Kocamaz, A. F. (2023, Aralık 20). Derin Öğrenme Tabanlı Görüntü Sınıflandırma Yaklaşımı ile Borsa İstanbul 100 Endeks Yönünün Tahmini . *Journal of Computer Science* , s. 93-101.
- Babu, D. R., & Sathyanarayana, B. (2023, Aralık). DESIGN OF MULTILAYERED BIDIRECTIONAL LSTM NETWORK FOR STOCK PRICE PREDICTION USING DIF FEATURES. *International Journal of Engineering Sciences & Research Technology*.
- Chalvatzis, C., & Hristu-Varsakelis, D. (2019). *High-performance stock index trading: making effective use of a deep long short-term memory network*. arXiv preprint arXiv:1902.03125v2. <https://doi.org/10.48550/arXiv.1902.03125>
- Çelik, Y. (2024, Mayıs). Bellek Tabanlı LSTM ve GRU Makine Öğrenmesi Algoritmaları Kullanarak BIST100 Endeks Tahmini . *Fırat Üniversitesi Müh. Bil. Dergisi*, s. 553-561.
- Çınar, U. K. (2018, Ağustos 13). *Yapay Sinir Ağları ve R Programıyla Uygulama*. Veri Bİlimi Okulu: <https://www.veribilimiokulu.com/yapay-sinir-aglari/> adresinden alındı
- Çoban, A., & Özyurt, F. (2022). Kapsül Ağları ile Yüz Verilerinin Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi* , 176-183.
- Fertekligil, A. (2000). *Türkiye’de borsanın tarihçisi*. İstanbul: İMKB Yayınları.
- Gayhardt, L., Garimella, A., Salgado, S., Gilley, S., Franks, L., Brizi, M., . . . Lu, P. (2024, 01 19). *Deep learning vs. machine learning in Azure Machine Learning*. Microsoft Laern: <https://learn.microsoft.com/en-us/azure/machine-learning/concept-deep-learning-vs-machine-learning?view=azureml-api-2> adresinden alındı

- Güney, E. N. (2022, Mart). Derin öğrenmede istatistiksel yöntemlerle hisse senedi fiyatı öngörüsü. *Yüksek Lisans Tezi*. Isparta: Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü.
- Karataş, G. (2020, Mayıs). Derin öğrenme tabanlı saldırı tespit sistemi. *Doktora Tezi*. İstanbul: Marmara Üniversitesi Fen Bilimleri Enstitüsü.
- Karlı, M., & Karaman, H. (1994). *İslam açısından borsa*. İstanbul.
- Livieris, I. E., Pintelas, E., & Pintelas, P. (2020, Nisan 13). A CNN-LSTM model for gold price time-series forecasting. *Neural Computing and Applications*, s. 32:17351-17360.
- McCulloch, W. S., & Pitts, W. (1943). A Logical Calculus of Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, 115-133.
- Öztürk, K., & Şahin, M. E. (2018). Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış. *Takvim-i Vekayi*, 25-36.
- Sen, J., Dutta, A., & Mehtab, S. (2021, Mayıs 21-23). Profitability Analysis in Stock Investment Using an LSTM-Based Deep Learning Model. *IEEE International Conference on Emerging Technologies*.
- Siami-Namini, S., Tavakoli, N., & Siami Namin, A. (2019). *A comparative analysis of forecasting financial time series using ARIMA, LSTM, and BILSTM*. arXiv preprint arXiv:1911.09512. <https://doi.org/10.48550/arXiv.1911.09512>
- Sönmez, L., & Çoşkun Arslan, M. (2024). LSTM MODELİ İLE VOLATİLİTE TEMELLİ BORSA TAHMİNİ . *International Journal of Accounting and Finance Researches*, s. 6(2), 48-61.
- Şişmanoğlu, G., Koçer, F., Önde, M. A., & Şahingöz, Ö. K. (2020). Derin Öğrenme Yöntemleri ile Borsada Fiyat Tahmini. *BEÜ Fen Bilimleri Dergisi*, s. 434-445.
- TAŞ, A. İ., Gülüm, P., & Tulum, G. (2021). Finansal Piyasalarda Hisse Fiyatlarının Derin Öğrenme ve Yapay Sinir Ağı Yöntemleri ile Tahmin Edilmesi; S&P 500 Endeksi Örneği. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, s. 446-460.
- Varürer, İ., & Özaydın, Ö. (2024). BILSTM Derin Öğrenme Modeli ile Gümüş Fiyatı Tahmini. Alpu, Ö. (Ed.). *İstatistikte Güncel Konular* (s. 123-145). Eğitim Yayınevi.

Zhang, J., Ye, L., & Lai, Y. (2023, Nisan 23). Stock Price Prediction Using CNN-BILSTM-Attention Model. *Mathematics*, s. 11, 1985.