

LSTM MODELİ İLE VOLATİLİTE TEMELLİ BORSA TAHMİNİ

Volatility-Based Stock Market Forecasting with LSTM Model

Lütfiye SÖNMEZ* & Mihriban ÇOŞKUN ARSLAN**

*Öğr. Gör., Tokat Gaziosmanpaşa Üniversitesi, lutfiye.sonmez@gop.edu.tr, ORCID: 0000-0003-4369-2273.

**Prof. Dr., Tokat Gaziosmanpaşa Üniversitesi, mihriban.arслан@gop.edu.tr, ORCID: 0000-0002-6196-9304.

Araştırma Makalesi / Research Article

Geliş Tarihi: 20.10.2024	ÖZ Finansal piyasalarda yaşanan dalgalanmalar ve küresel ekonomik belirsizlikler, finansal kurumların ve yatırımcıların doğru ve güvenilir piyasa tahminlerine olan ihtiyacını artırmıştır. Özellikle borsa endeksinin karmaşık yapısı ve artan oynaklığı, geleneksel tahmin yöntemlerinin yetersiz kalmasına neden olmuştur. Bu durum ise daha gelişmiş ve esnek tahmin modellerinin gelişimini zorunlu kılmıştır. Bu kapsamda derin öğrenme modelleri, özellikle LSTM (Uzun Kısa Süreli Bellek) ağları, zaman serisi verilerindeki uzun vadeli ilişkileri başarılı bir şekilde modelleyerek borsa endeks tahmininde öne çıkmayı başarmıştır. Bu çalışmanın amacı, Borsa İstanbul'da işlem gören (BIST) 100 ve Frankfurt Menkul Kıymetler Borsasında işlem gören Deutscher Aktienindex (DAX) endekslerini tahmin etmek için VIX, OVX, EVZ ve GVZ oynaklık endekslerini girdi değişkeni olarak kullanarak bir Uzun Kısa Süreli Bellek (LSTM) modelinin tahmin performansını değerlendirmektir. Analizde kullanılan veri seti 30.01.2012- 26.06.2024 dönemine ait BIST 100, DAX endeksleriyle VIX, OVX, EVZ, GVZ oynaklık endekslerini içermektedir. LSTM modeli, uzun dönem bağımlılıkları modelleyebilme kabiliyeti ve yüksek tahmin doğruluğu nedeniyle tercih edilmiştir. Sonuçlar, LSTM modelinin her iki endeks için de yüksek doğrulukla tahminler yaptığını göstermektedir. BIST 100 için RMSE, MAE, MAPE ve R ² değerleri sırasıyla 0.0151, 0.0076, 0.04 ve 0.9948, DAX için ise 0.0273, 0.0193, 0.02 ve 0.9843 olarak bulunmuştur. Bu bulgular, modelin yatırım stratejileri ve risk yönetimi için değerli bir araç olabileceğini göstermektedir. Çalışma, LSTM modelinin farklı piyasa dinamiklerine sahip endekslerde başarılı tahminler yapabildiğini ortaya koymakta ve gelecekteki finansal tahmin çalışmalarını için güçlü bir temel sunmaktadır.
Kabul Tarihi: 23.11.2024	
Anahtar Kelimeler: Uzun Kısa Süreli Bellek (LSTM), BIST 100, DAX, Volatilite Endeksleri.	
JEL Kodları: C45, C13, G15	
Received Date: 20.10.2024	ABSTRACT Fluctuations in financial markets and global economic uncertainties have increased the need for accurate and reliable market forecasts among financial institutions and investors. The stock market index's complex structure and rising volatility have rendered traditional forecasting methods insufficient. This has led to the development of more advanced and flexible forecasting models. In this context, deep learning models—particularly LSTM (Long Short-Term Memory) networks—have gained prominence in stock market index forecasting by effectively modeling long-term dependencies in time series data. This study aims to assess the forecasting performance of an LSTM model, using VIX, OVX, EVZ, and GVZ volatility indices as input variables, to predict the Borsa Istanbul (BIST) 100 and Frankfurt Stock Exchange Deutscher Aktienindex (DAX) indices. The dataset used in the analysis includes BIST 100, DAX indices, and the aforementioned volatility indices covering the period from 30-01-2012, to 26-06-2024. The LSTM model was chosen due to its ability to capture long-term dependencies and its high forecast accuracy. The results show that the LSTM model forecasts both indices with high accuracy. The RMSE, MAE, MAPE, and R ² values for BIST 100 are 0.0151, 0.0076, 0.04, and 0.9948, respectively, while for DAX, they are 0.0273, 0.0193, 0.02, and 0.9843. These findings suggest that the model is a valuable tool for investment strategies and risk management. Furthermore, the study demonstrates that the LSTM model can successfully forecast indices with different market dynamics, laying a solid foundation for future financial forecasting research.
Acceptance Date: 23.11.2024	
Keywords Long Short-Term Memory (LSTM), BIST 100, DAX, Volatility Indices.	
JEL Codes: C45, C13, G15	

Atf / Citation: Sönmez, L. & Coşkun Arslan, M. (2024). LSTM Modeli İle Volatilite Temelli Borsa Tahmini. *Uluslararası Muhasebe ve Finans Araştırmaları Dergisi*, 6(2), 48-61.

1. GİRİŞ

Finansal piyasaların tahmini, yatırımcılar, politikacılar, araştırmacılar için her zaman büyük önem taşımıştır. Özellikle borsa endeksinin hareketlerini öngörmek risk yönetimi ve yatırım stratejilerinin oluşturulması açısından kritik bir rol oynamaktadır. Borsa tahmininde fiziksel psikolojik, rasyonel, irrasyonel davranışlar, piyasa dedikoduları gibi birçok faktör rol oynamaktadır. Bütün bu faktörler borsa oynaklığını yükseltmekte, tahmin edilebilirliği ise zorlaştırmaktadır.

Bir ülkenin borsa endeksi genel ekonomik durumun önemli bir göstergesidir. Ülke borsaları finans, tarım, enerji, iletişim, ulaşım, metal ve teknoloji gibi birçok sektörü bünyesinde bulundurmaktadır. Bu sektörlerle olan arz ve talep dengesi borsa endeksini de etkilemektedir. Dolayısıyla borsa endeksine ait fiyat hareketlerinin başarılı bir şekilde tahmin edilmesi hem finansal yazın hem de diğer aktörler açısından büyük öneme sahiptir.

Finansal zaman serilerinin tahmininde geleneksel istatistikî yöntemler ve makine öğrenimi modelleri yaygın olarak kullanılmaktadır. Son yıllarda bilişim teknolojilerindeki hızlı gelişmeler ve veri hacmindeki artış makine öğrenme yöntemlerinin tahmin kapasitesini ve uygulanabilirliğini önemli ölçüde artırmıştır. Bu gelişmeler büyük ölçekli nöral ağların, özellikle de uzun kısa süreli bellek Long Short-Term Memory (LSTM) modellerin zaman serisi analizinde etkin bir şekilde kullanılmasına olanak tanımıştır. Zaman serisi analizlerinde uzun dönem hafıza yeteneği ve başarısı göz önüne alındığında LSTM modeli öne çıkmaktadır. Çalışmada ele alınan BIST 100 ve DAX endekslerinin 30.01.2012 - 26.06.2024 tarihler arasındaki günlük kapanış değerleri uzun bir dönemi kapsadığı için LSTM modeli tercih edilmiştir.

Çalışmada kullanılan modelde giriş parametreleri belirlenirken literatürde sıklıkla kullanılan makroekonomik faktörler (Tektaş ve Karataş, 2004; Toraman, 2008; Kutlu ve Badur, 2009; Akcan ve Kartal, 2011; Aygören, Sarıtaş, Morali, 2012; Karymshakov ve Abdykaparon, 2012; Yakut vd., 2014; Siddiqui ve Abdullah, 2015; Çalışkan ve Deniz, 2015; Telli ve Coşkun, 2016; Kim ve Won, 2018; Dayı, 2018; Çınaroğlu ve Avcı, 2020; Kantar, 2020) ve teknik indikatörler (Diler, 2003; Kim, 2003; Yu vd., 2005; Lu, 2010; Hesieh vd., 2011; Kara, Boyacıoğlu ve Baykan, 2011; Dunis vd., 2013; Emir, 2013; Wang ve Shang, 2014; Anish ve Majhi, 2016; Li ve Tam, 2017; Rout vd., 2017; Dingli ve Fournier, 2017; Widegren, 2017; Lee ve Soo, 2017; Bao vd., 2017; Chen vd., 2018; Sakarya ve Yılmaz, 2019; Kara, 2019; Gündüz, 2019; Pabuçcu, 2019) tercih edilmemiştir. Bunun yerine çalışmada endeks tabanlı girdi değişkenleri tercih edilmiştir. Endeks tabanlı veriler, birçok finansal enstrümanın veya ekonomik göstergenin tek bir sayısal değerde ifade gücünü barındırmaktadır. Aynı zamanda endeks tabanlı veriler, bilgi yoğunluğunu artırırken, veri boyutundaki karmaşıklık önemli ölçüde azaltılmaktadır. Literatürde, borsa endeks tahmininde oynaklık endekslerini girdi değişkeni olarak kullanan sınırlı (Çetin ve Metlek 2021, Gürbüz, 2024) çalışmaların olduğu gözlemlenmiştir. Bu çalışmalar, endeks tabanlı yaklaşımların borsa tahmin modellerinde sunduğu avantajları ortaya koymakta, ancak mevcut araştırmaların bu alandaki potansiyelin tamamını yansıtmadığını göstermektedir. Volatilite endeksleri olarak da ifade edilen CBOE Oynaklık endeksi (VIX), Altın Oynaklık Endeksi (GVZ), Euro/Dolar Oynaklık Endeksi (EVZ), Petrol Oynaklık Endeksi (OVX) endeksleri LSTM modelinin girdi değişkenleri olarak belirlenmiştir.

Bu çalışma, LSTM modeli kullanarak ve volatilite endekslerini temel alarak BIST 100 ve DAX endekslerinin tahmin edilmesi için yenilikçi bir yaklaşım sunmaktadır. Literatürde mevcut olan çalışmalardan farklı olarak, bu araştırma endeks tahmininde teknik ve makroekonomik göstergeler yerine endeks tabanlı değişkenlerin kullanımının avantajlarını ortaya koymayı amaçlamaktadır. Çalışmanın temel hedefi, çeşitli volatilite endekslerinin

tahmin performansı üzerindeki etkilerini analiz ederek yatırımcılar ve finans kurumları için daha etkili tahmin modelleri geliştirilmesine katkıda bulunmaktadır. Ayrıca, geliştirilen modelin tahmin başarısı, gelişmekte olan ve gelişmiş iki farklı ülke borsasında karşılaştırmalı olarak değerlendirilerek, modelin genel geçerliliği ve etkinliği incelenecektir. Çalışmada, öncelikle literatürdeki ilgili araştırmalara yer verilecek, ardından analizde kullanılan veri seti ve yöntemler detaylandırılacaktır. Sonrasında, analiz süreci ve bu süreçte elde edilen bulgular sunulacak, nihayetinde ise sonuçlar kapsamlı bir şekilde değerlendirilecektir.

2. LİTERATÜR TARAMASI

Tahmin yöntemleri açısından, geleneksel yöntemlerin yanı sıra, teknolojideki ilerlemelerle birlikte makine öğrenme tekniklerinin kullanımının da yaygınlaştığı gözlemlenmektedir. Bu bölümde, tercih edilen model doğrultusunda literatürde yer alan bazı önemli çalışmalara değinilmiştir.

Fischer ve Krauss (2017), çalışmalarında LSTM modelini kullanarak Finansal piyasaları tahmin etmeye çalışmışlardır. Bu kapsamda S&P 500 endeksinin bileşenleri kullanılarak Ocak 1990 ve Eylül 2015 günlük verileri ile tahmin modeli geliştirmişlerdir. Uygulanan LSTM modeli finansal zaman serisi verilerinden anlamlı bilgi çıkarma ve yüksek doğrulukla tahmin yeteneği göstermiştir.

Shah vd. (2018), çalışmalarında Hint BSE Sensex endeksinin haftalık ve günlük hareketlerini tahmin etmek için LSTM, Tekrarlayan Sinir Ağı (RNN) ve Derin Sinir Ağı (DNN) modellerini kullanarak karşılaştırmalı bir çalışma sunmuşlardır. Çalışmada 1997-2017 yılları arası BSE Sensex günlük kapanış fiyatlarından oluşan veri setinden yararlanılmıştır. Modeller günlük tahminlerde iyi performans gösterirken LSTM ve RNN haftalık tahminlerde DNN modelinden daha başarılı sonuçlar vermiştir.

Yan ve Ouyang (2018), çalışmalarında Şangay Bileşik Endeksinin 4 Ocak 2012-31 Haziran 2017 tarihleri arasında yer alan günlük kapanış değerlerini kullanarak tahmin modeli geliştirmişlerdir. Finansal zaman serisini tahmin etmek için LSTM modelinin yanı sıra Çok Katmanlı Algılayıcı, Destek Vektör Makineleri, K-en Yakın Komşular gibi makine öğrenme yöntemleri kullanılarak modellerin tahmin performansları karşılaştırılmıştır. Elde edilen sonuçlara göre LSTM modelinin tahmin performansının diğer makine öğrenme yöntemlerinden daha yüksek olduğu tespit edilmiştir.

Ghosh vd.(2019), çalışmalarında Hindistan borsasında farklı sektörlere ait üst düzey şirketlerin hisse senetlerinin kapanış fiyatı tahminini geçmiş verilere dayanarak LSTM modeli yardımıyla gerçekleştirmişlerdir. 1 ay, 3 ay, 6 ay, 1 yıl ve 3 yıllık zaman dilimlerine ait geçmiş verilere dayanarak sektörel bazda gerçekleştirilen tahminde hata değerleri dikkate alınmıştır. Elde edilen sonuçlarda uzun dönemli geçmiş veriler üzerinde LSTM tabanlı modelin daha iyi sonuç verdiği tespit edilmiştir.

Hasan (2020), çalışmasında BİST 100 endeksinin yönünü tahmin etmek için derin öğrenme ve makine öğrenme yöntemlerini kullanmıştır. Girdi değişkeni olarak bir dizi teknik gösterge kullanan çalışmada sınıflandırma teknikleri olarak Derin Sinir Ağları, Destek Vektör Makineleri, Rasgele Orman ve Lojistik Regresyon kullanılmıştır. Model performans kriteri olarak karışıklık matrisi, bileşik getiri ve maksimum düşüm metrikleri kullanılmış ve önerilen derin sinir ağları modelinin daha düşük eşik değerleri ile daha küçük zaman periyotları üzerinde üstünlüğü ortaya koyulmuştur.

Taş vd. (2021), çalışmalarında S&P 500 borsa endeksine ait günlük fiyat verilerini kullanarak Çok Katmanlı Algılayıcı (MLP) ve LSTM yöntemleriyle borsa fiyat tahmini gerçekleştirmişlerdir. İlgili endekse ait 12.08.2000-13.08.2020 tarihleri arasında günlük

kapanış fiyatları ile gerçekleştirilen analizden elde edilen sonuçlara göre her iki modelinde birbirine yakın sonuçlar verdiği ve tahmin çalışmaları için uygun seçenekler olduğu ifade edilmiştir.

Çetin ve Metlek (2021), çalışmalarında BİST Katılım Endeksini yüksek doğruluk oranıyla tahmin etmek için LSTM modelini kullanmışlardır. Katılım endeksini tahmin ederken, BIST 100 endeksi, VIX, GVZ, DXY endeksleri girdi değişkenleri olarak belirlenmiştir. Tasarlanan modelde kullanılan başarı metriklerini MAE, RMSE, MAPE ve R^2 sırasıyla 0.06, 0.08, 0.02 ve 0.994 değerleriyle tahmin etmişlerdir.

Dalkıran ve Ozan (2022) çalışmalarında Borsa İstanbul' da işlem gören ISCTR hissesine ait günlük değer tahmini gerçekleştirmişlerdir. İlgili hisse senedine ait 31.12.2007-28.02.2021 dönemine ilişkin uzun dönem günlük veriler kullanılarak yapılan analizde ayrıca VAKBN, GARAN, QNBFB ve AKBANK hisse senetleri USD/TRY, BIST 30 VE BANKX endekslerinin geçmiş verileri de kullanılmıştır. LSTM modeli ile Adam ve RMSProp optimize edicileri birlikte kullanılarak ilgili modelin tahmin başarısının tatmin edici boyuta ulaştığı gözlemlenmiştir.


Bhandari vd.(2022), çalışmalarında S&P 500 endeksinin bir sonraki gün kapanış fiyatını tahmin etmek üzere özel bir sinir ağı mimari olan LSTM modeli kullanmışlardır. Çeşitli makroekonomik ve teknik göstergelerin girdi değişkeni olduğu çalışmada tek katmanlı ve çok katmanlı LSTM modeli geliştirilmiştir. Çalışmada değerlendirme ölçütleri olarak RMSE MAPE, R (Korelasyon katsayısı) kullanılmıştır. Buna göre tek katmanlı LSTM modelinin çok katmanlı LSTM modeline göre daha yüksek tahmin doğruluğu sağladığı ortaya koyulmuştur.

Akbulut ve Kemal (2023), yapmış oldukları çalışmada 2017-2021 yılları arasındaki döviz ve emtia piyasaları ile gelişmekte olan ülkelerin borsa endekslerinin verilerinden yararlanarak Makine Öğrenmesi ve Derin Öğrenme yöntemleriyle BİST 100 piyasa hareketlerini tahmin etmişlerdir. Makine Öğrenme yönteminin tahmin değeri ile LSTM yönteminin tahmin değeri karşılaştırıldığında LSTM modelinin tahmin performansı daha etkili olduğu sonucuna varılmıştır. Değerlendirme kriteri olarak kullanılan Ortalama Mutlak Hata (MAE), Bağıl Mutlak Hata (RAE), Ortalama Karesel Hata Karekökü (RMSE) kullanılmış ve ilgili değerler LSTM modeli için sırasıyla şöyle tespit edilmiştir: 10,27(MAE), 6,06(RAE), 14,15(RMSE).

Mevcut literatürde genellikle, endeks verilerinin tahmini için çeşitli yöntemler ve farklı girdi değişkenleri kullanılmaktadır. Bazı çalışmalar yalnızca ham zaman serisi verilerini veya endeks fiyat bilgilerini girdi olarak kullanırken, diğer çalışmalar teknik göstergeler ve makroekonomik değişkenler gibi ek verileri de tahmin sürecine dâhil etmektedir. Çalışma kapsamında kullanılan endeks tabanlı girdi değişkenlerinin ise tahmin sürecinde oldukça kısıtlı olarak kullanıldığı gözlemlenmiştir. Endeks tabanlı girdi değişkenleri, piyasa risk algılarını ve geleceğe yönelik beklentileri daha doğru yansıttığı için, tahmin performansını artırma potansiyeli de bulunmaktadır. Literatürde bu tür endekslerin kullanımının sınırlı olduğu göz önüne alındığında, çalışmanın sunduğu bu yeni yaklaşım ile literatüre önemli bir katkı sağlanması beklenmektedir.

3. VERİ SETİ VE YÖNTEM


Çalışmada BIST 100 endeksi ve DAX endeksini tahmin etmek için endeks tabanlı girdi değişkenleri (VIX, OVX, GVZ, EVZ) kullanılarak bir derin öğrenme modeli olan LSTM yöntemi uygulanmıştır. Çalışmanın odak noktası LSTM modeli kullanarak endeks tahminlerini gerçekleştirmektir. Uygulanan model, verileri doğrudan işleyerek ve LSTM katmanları oluşturarak gelecek verilere ilişkin bir dizi özellik vektörü oluşturacaktır. Uygulanan modelin akış şeması Şekil 1'de gösterilmektedir.



Şekil 1: Uygulanan modelin akış diyagramı

3.1 Veri Toplama ve Ön İşleme

Çalışmada 30.01.2012-26.06.2024 dönemi arasındaki günlük veriler kullanılmış olup veriler investing.com adresinden elde edilmiştir. Bağımlı değişken olarak BIST 100 ve DAX endeksi, oynaklık endeksleri (VIX, OVX, EVZ, GVZ) yardımıyla tahmin edilmeye çalışılmış ve ilgili platformdan elde edilen ve çalışmada kullanılan veriler aşağıda Şekil 2’de gösterilmektedir.



Şekil 2: Değişkenlere Ait veri Grafikleri

Çalışmada kullanılan girdi değişkenleri (VIX, OVX, EVZ, GVZ) ile tahmin edilen BIST 100 ve DAX endeksleri arasındaki sayısal ilişkiyi belirtmek amacıyla hesaplanan korelasyon katsayıları Tablo 1’de ayrıntılı olarak gösterilmiştir.

Tablo 1: Girdi Deęişkenlerin BIST 100 ve DAX Endeksiyle Korelasyon İliřkisi

BIST 100		DAX	
BIST 100	1	DAX	1
VIX	-0.008	VIX	-0.0330
OVX	-0.008	OVX	-0.0606
EVZ	-0.150	EVZ	-0.393
GVZ	-0.134	GVZ	-0.298


Tablo 1’ de görüldüğü üzere volatilité endeksleri ile borsa endeksleri arasında zıt yönde hareket eğilimi olduđu görülmektedir. Çalışmada kullanılan veri setindeki tatil günlerine ait eksik gözlemler, veri setinden çıkarılmıştır.

Sonraki aşamada ise Min-Max yöntemi kullanılarak veriler normalize edilmiştir. Böylece veri setindeki deęişkenlerin farklı ölçeklerde olmasının önüne geçilmiştir.

3.2. Yöntem

Literatürde zaman serilerinin analizinde derin öğrenme modellerinden geri dönüşümlü yapay sinir aęının Recurrent Neural Networks (RNN) sıklıkla kullanıldığı görülmektedir (Chen, Yeo, Lau ve Lee, 2018; Saud ve Shakya, 2020). Fakat literatürde belirtildiğı üzere RNN modelinin başlangıçtaki giriş bilgilerini unutması ve model parametrelerinin kontrolsüz şekilde güncellenmesi problemlerinden dolayı uzun dönem birliktelikleri öğrenmede zorluklar yaşamaktadır (Kong ve dięerleri, 2019). RNN modelinde yaşanan bu sorunların çözümü için LSTM modeli geliştirilmiştir. Hochreiter vd.(1997), çalışmalarında LSTM mimarisini hafıza yeteneğı sayesinde uzun zaman serilerinde kullanım için önermiştir. LSTM, zaman serisi verilerini ve sıralı bilgileri modellemek için tasarlanmış bir tür yapay sinir aęıdır. LSTM mimarisi, uzun vadeli bağımlılıkları daha iyi öğrenebilmek için özel olarak tasarlanmış hücre yapılarına ve kapı mekanizmalarına sahiptir.

LSTM Şekil 3’te gösterildiğı gibi, giriş kapısı X_t , unutma (hafıza) kapısı C_t ve çıkış H_t kapısı olmak üzere üç ana kapıdan oluşmaktadır. Bu kapılar bilgilerin aęda nasıl işleneceğini belirler; önemli bilgiler bir sonraki adıma aktarılırken önemsiz olanlar ise unutulur. Önceki katmandan unutma kapısına gelen bilgiler (h_{t-1} ve x_t) sigmoid fonksiyonundan geçirilerek ne kadar hatırlanacağına karar verilir. Giriş kapısında ise sigmoid fonksiyonu ile hangi bilginin iletileceğı seçilmektedir ve Tanh fonksiyonu ile (-1,1) aralığına indirgenmektedir. Sigmoid ve Tanh fonksiyonlarının çıktıları çarpılarak hangi bilginin güncelleneceğine karar verilmektedir. Çıkış kapısında ise sonraki hücreye hangi bilginin geçeceği belirlenmektedir. Mevcut deęer sigmoid fonksiyonundan geçirilirken taşınan bilgiyi tutan Cell-State hücresinden gelen deęer *Tanh* fonksiyonundan geçmektedir. Bu iki deęer çarpılarak bir sonraki katmana aktarılacak bilgiye dönüřtürülmektedir. (Olah, 2015).



Şekil 3: LSTM Mimarisi

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

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

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$


Denklemlerde f_t unutma kapısını, i_t giriş kapısını, o_t çıkış kapısını, x_t girdi vektörünü, W giriş değerlerinin ağırlıklarını, b bias terimini, C_t hücredeki bilgileri, h_t çıktıları, σ aktivasyon fonksiyonlarından sigmoid fonksiyonunu ve \tanh ise hiperbolik tanjant fonksiyonunu ifade etmektedir

4. BULGULAR

Çalışmada hem uzun dönem bağımlılıkları modelleyebilme hem de zaman serilerindeki tahmin başarısından dolayı LSTM modeli tercih edilmiştir. Modelde girdi değişkenleri olarak VIX, GVZ, OVX, EVZ endeksleri, çıktı olarak ise BIST 100 ve DAX endeksleri kullanılmıştır. 30.01.2012 - 26.06.2024 tarih aralığında 2957 günlük veri kullanılmıştır. Çalışmada modelin genelleme yeteneğini artırmak ve ezberleme (overfitting) riskini minimize etmek amacıyla K-kat çapraz doğrulama (K-fold cross-validation) tekniği uygulanmıştır. Bu yöntem, veri setinin tamamının hem eğitim hem de test süreçlerinde kullanılmasını sağlayarak, modelin performansının daha objektif ve güvenilir bir şekilde değerlendirilmesine olanak tanımıştır (Sönmez, 2023).

Modelin uygulama kısmında veri analizi ve istatistiksel yöntemlerin uygulanması için Python programlama dilinden yararlanılmıştır. Python açık kaynaklı programlama dili olup, makine öğrenmesi ve finansal analizler için yaygın olarak kullanılmaktadır. İçerik olarak birçok kütüphaneye sahip olan program, finansal hesaplamaları, istatistiksel analizleri ve veri görselleştirmelerini başarılı bir şekilde gerçekleştirmektedir.

Çalışmada uygulanan modelin mimarisi Şekil 4'te gösterilmektedir.



Şekil 4: Uygulanan LSTM Mimarisi

LSTM modeli 2 katmanlı ve her katmanı 100 gizli birimden oluşmaktadır. Optimizer olarak Adam algoritması kullanılırken model 140 epok boyunca eğitilmiştir. Modelin performansını değerlendirmek için 5 katlı çaprazlama kullanılmıştır. Bu şartlar altında en optimum sonuca ulaşılmıştır.

Bir yapay zekâ modelinin etkinliğini değerlendirirken, modelin performansını ölçmek için kullanılan hata fonksiyonları en az modelin kendisi kadar önemlidir. Bu çalışmada, geliştirilen LSTM modelinin tahmin performansını ölçmek amacıyla, çeşitli başarı metrikleri kullanılmıştır. Mutlak Hata Değeri (MAE), Ortalama Karekök Hata (RMSE), Ortalama Mutlak Yüzdese Hata (MAPE) ve R-Kare (R^2) çalışma kapsamında kullanılan değerlendirme ölçütleri olarak ele alınmıştır. Aşağıda ise ilgili başarı metriklerine ilişkin formüllere yer verilmiştir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{gerçek_i} - y_{tahmin_i}| \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{gerçek_i} - y_{tahmin_i})^2}{n}} \quad (8)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_{gerçek_i} - y_{tahmin_i}|}{|y_{meas_i}|} \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{gerçek_i} - y_{tahmin_i})^2}{\sum_{i=1}^n (y_{tahmin_i} - \underline{y}_{gerçek_ort})^2} \quad (10)$$

Denklem (7-10) yer alan y_{gercek_i} i zamandaki gerçek veri değerini, y_{tahmin_i} i zamandaki tahmin değerini $\underline{y}_{gercek_ort}$ gerçek verilerin ortalamasını temsil etmektedir. Her iki ülke için uygulanan modelin sonucunda elde edilen performans ölçütleri Tablo 2 ve Tablo 3'te verilmiştir.

Tablo 2: BIST 100 Performans ölçütleri

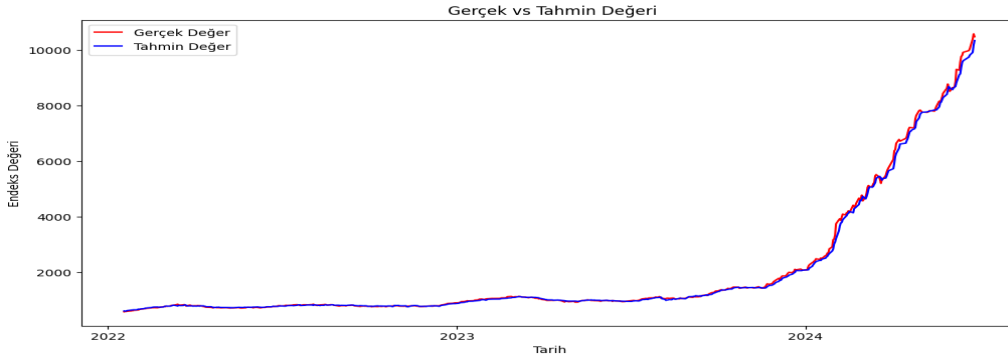

Ortalama RMSE:	0.0151
Ortalama MAE:	0.0076
Ortalama MAPE:	0.04
Ortalama R ² :	0.9948

Tablo 3: DAX Performans ölçütleri

Ortalama RMSE:	0.0273
Ortalama MAE:	0.0193
Ortalama MAPE:	0.02
Ortalama R ² :	0.9829

Modelin başarısı değerlendirilirken R², RMSE, MAPE ve MAE değerleri dikkate alınmıştır. R² değeri, bağımsız değişkenlerin bağımlı değişkeni açıklama gücünü ifade eden istatistiksel bir göstergedir. R² değeri, bağımsız değişkenlerin, bağımlı değişkendeki varyansının ne kadarını açıkladığını ifade eder. R² değeri, 0-1 arasında değişir ve 1'e yaklaştıkça modelin açıklayıcılığının arttığını gösterir. RMSE değeri, gerçek değer ile tahmin edilen değer arasındaki farkın mutlak halidir. 0 ile sonsuz arasında değer alır. Düşük bir RMSE değeri, model tahminin gerçek değere ne kadar yakın olduğunu gösterir. MAPE değeri gerçek değer ile tahmin edilen değer arasındaki ortalama farkı yüzdesel olarak ifade eder. MAE değeri, gerçek değer ile tahmin edilen değer arasındaki farkların mutlak değerlerin ortalamasıdır.

Ölçeklendirilmiş günlük endeks değerleri ve oynaklık endeksleri kullanılarak en uygun parametre değerleriyle gerçekleştirilen tahminler sonucunda elde edilen BIST 100 ve DAX endekslerinin tahmin edilen ve gerçek değerlerini karşılaştıran şekiller, sırasıyla Şekil 5 ve Şekil 6'da sunulmuştur.

**Şekil 5: BIST 100 Endeksine Ait Gerçek ve Tahmin Değerleri****Şekil 6: DAX Endeksine Ait Gerçek ve Tahmin Değerleri**

řekillerde kırmızı çizgiler gerçek değeri yansıtırken mavi çizgiler LSTM modeliyle üretilen tahmin değerlerini ifade etmektedir. řekil 5 ve řekil 6'da görüldüğü üzere gerçek ve tahmin değerinin büyük oranda örtüştüğü ifade edilebilir. Bu durum LSTM modelinin tahmin performansının yüksek doğrulukta olduğunu göstermektedir.

5. SONUÇ

Bu çalışmada, BIST 100 ve DAX endekslerinin tahmini, endeks tabanlı değişkenler kullanılarak gerçekleştirilmiştir. VIX, OVX, EVZ ve GVZ oynaklık endeksleri girdi parametresi olarak kabul edilmiştir. 30.01.2012 - 26.06.2024 dönemini kapsayan analizlerde uzun dönem bağımlılıkları modelleyebilme kabiliyeti ve tahmin başarısı nedeniyle LSTM modeli tercih edilmiştir.

Farklı ekonomik dinamiklere ve gelişmişlik düzeylerine sahip iki ülke borsa endeksi verileri kullanılarak yapılan analizlerde LSTM modelinin oldukça başarılı sonuçlar verdiği görülmektedir. Değerlendirme kriterleri olarak belirlenen RMSE, MAE, MAPE ve R² değerleri incelendiğinde BIST 100 endeksi için bu değerler sırasıyla 0.0151, 0.0076, 0.04 ve 0.9948 olarak bulunurken DAX endeksi için ise aynı kriterler sırasıyla 0.0273, 0.0193, 0.02 ve 0.9829 olarak bulunmuştur. Bu sonuçlar, LSTM modelinin her iki endeks için de yüksek doğrulukla tahminler yaptığını ortaya koymaktadır. BIST 100 endeksinde elde edilen R² değeri, modelin bağımsız değişkenlerin bağımlı değişken üzerindeki varyansın %99.48'ini açıkladığını gösterirken, DAX endeksi için bu oran %98.43 olarak hesaplanmıştır. Bu yüksek R² değerleri, modelin her iki endeksin gelecekteki hareketlerini tahmin etmede etkili olduğunu göstermektedir.

Ayrıca, RMSE ve MAE değerlerinin nispeten düşük olması, modelin tahmin hatalarının minimal düzeyde kaldığını ve tahminlerin gerçek değerlere oldukça yakın olduğunu göstermektedir. MAPE değerlerinin düşük olması ise, modelin tahmin doğruluğunun yüksek olduğunu ve yüzde olarak hataların kabul edilebilir seviyede olduğunu belirtmektedir.

Çalışmanın bulguları, yatırımcılar ve finans kurumları için önemli çıkarımlar sunmaktadır. LSTM modelinin volatilité endeksleri kullanılarak yapılan bu tahminlerdeki başarısı, yatırım stratejilerinin geliştirilmesinde ve risk yönetiminde kullanılabilecek potansiyel bir araç olduğunu göstermektedir. Ayrıca, bu yaklaşımın farklı ekonomik koşullara sahip piyasalar için genelleştirilebilir olması, modelin geniş bir uygulama alanına sahip olduğunu da ortaya koymaktadır.

Sonuç olarak, bu çalışmada LSTM modelinin hem gelişmiş bir piyasa olan DAX endeksi hem de gelişmekte olan bir piyasa olan BIST 100 endeksi üzerinde başarılı tahminler yapabildiği gösterilmiştir. Bu, modelin farklı piyasa dinamikleri ve oynaklık seviyeleri ile başa çıkabilme yeteneğini vurgulamakta ve gelecekteki finansal tahmin çalışmaları için güçlü bir temel oluşturmaktadır. Literatürde borsa endeks tahmininde LSTM modelini kullanan çalışmalar incelendiğinde, uzun dönem bağımlılıkları tahmin etmede başarılı sonuçlar elde edildiği görülmüştür. Çalışmada elde edilen bulgular, literatürdeki bu sonuçları destekler niteliktedir.

KAYNAKÇA

- Akbulut, S., & Adem, K. (2023). *Derin öğrenme ve makine öğrenmesi yöntemleri kullanılarak gelişmekte olan ülkelerin finansal enstrümanlarının etkileşimi ile Bist 100 tahmini*. Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 12(1), 1-1.
- Akcan, A., & Kartal, C. (2011). *İMKB Sigorta Endeksini Oluşturan Şirketlerin Hisse Senedi Fiyatlarının Yapay Sinir Ağları İle Tahmini*. Muhasebe ve Finansman Dergisi, (51), 27-40.
- Anish, C. M. & Majhi, B. (2016). *Hybrid Nonlinear Adaptive Scheme for Stock Market Prediction Using Feedback FLANN and Factor Analysis*. Journal of the Korean Statistical Society, 45(1), 64-76.
- Aygören, H., Saritaş, H., & Morali, T. (2012). *İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini*. Journal of Alanya Faculty of Business/Alanya İletme Fakültesi Dergisi, 4(1).
- Bao, W., Yue, J., & Rao, Y. (2017). *A deep learning framework for financial time series using stacked autoencoders and long-short term memory*. PloS one, 12(7), e0180944.
- Bhandari, H. N., Rimal, B., Pokhrel, N. R., Rimal, R., Dahal, K. R., & Khatri, R. K. (2022). *Predicting stock market index using LSTM*. Machine Learning with Applications, 9, 100320
- C. Olah, "Understanding lstm networks," (2015).
- Chen, W., Yeo, C. K., Lau, C. T. ve Lee, B. S. (2018). *Leveraging social media news to predict stock index movement using RNN-boost*. Data & Knowledge Engineering, 118, 14–24.
- Chen, Y., Wu, J., & Bu, H. (2018). *Stock market embedding and prediction: A deep learning method*. In 2018 15th International Conference on Service Systems and Service Management (ICSSSM) (pp. 1-6). IEEE.
- Çalışkan, Mmt ve Deniz, D. (2015). *Yapay Sinir Ağlarıyla Hisse Senedi Kodları ve Yönlerinin Tahmini*. Eskişehir Osmangazi Üniversitesi İİBF Dergisi, 10 (3), 177-194.
- Çetin, D. T., & Metlek, S. (2021). *Türkiye'deki İslami hisse senedi endeksinin, endeks tabanlı öznitelikler kullanılarak derin öğrenme yöntemi ile tahmini*. Acta Infologica, 5(2), 287-298.
- Çınaroğlu, E., & Avcı, T. (2020). *THY Hisse Senedi Değerinin Yapay Sinir Ağları İle Kestirimi*. Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi, 34 (1).
- Dalkıran, İ., & Ozan, M. (2022). *Derin Öğrenme Teknikleri Kullanılarak Borsadaki Hisse Değerlerinin Tahmin Edilmesi*. Avrupa Bilim ve Teknoloji Dergisi, (39), 143-148.
- Dayı, F. (2018). *Hisse Senedi Getirilerinin Tahmininde Yapay Sinir Ağı Modeli Kullanımı: İMKB'de Bir Uygulama*. Akademik Araştırmalar ve Çalışmalar Dergisi (AKAD), 10(19), 572-592.
- Diler, A. I. (2003). *Forecasting the Direction of the ISE National-100 Index By Neural Networks Backpropagation Algorithm*. Istanbul Stock Exchange Review, 7(25-26), 65-82.
- Dingli, A., & Fournier, K. S. (2017). *Financial time series forecasting—a deep learning approach*. International Journal of Machine Learning and Computing, 7(5), 118-122.

- Dunis, C. L., Rosillo, R., De La Fuente, D. & Pino, R. (2013). *Forecasting IBEX-35 Moves Using Support Vector Machines*. *Neural Computing and Applications*, 23(1), 229-236.
- Emir, Ő. (2013). *Yapay Sinir Ađları ve Destek Vektör Makineleri Yöntemlerinin Sınıflandırma Performanslarının Karşılaştırılması: Borsa Endeksi Yönünün Tahmini Üzerine Bir Uygulama*. (Yayınlanmamış Doktora Tezi). İstanbul Üniversitesi, İstanbul.
- Fischer, T., & Krauss, C. (2018). *Deep learning with long short-term memory networks for financial market predictions*. *European journal of operational research*, 270(2), 654-669.
- Ghosh, A., Bose, S., Maji, G., Debnath, N., & Sen, S. (2019). *Stock price prediction using LSTM on Indian share market*. In *Proceedings of 32nd international conference on* (Vol. 63, pp. 101-110).
- Gündüz, H. (2019). *Derin Öğrenme Yöntemleri ile Zaman Serisi Tahmini* (Doktora Tezi. İstanbul Teknik Üniversitesi, İstanbul).
- Gürbüz, A. (2024). *BIST 100 ve Katılım 50 Endekslerinin Döviz Kuru, CDS Risk Primi, CBOE Oynaklık Endeksi (VIX) ve Petrol Fiyatları Arasındaki İlişkinin İncelenmesi*. *Kahramanmaraş Sütçü İmam Üniversitesi Sosyal Bilimler Dergisi*, 21(2), 769-782.
- Hasan, A. (2020). *Derin Öğrenme ve Makine Öğrenmesi Yöntemleriyle Borsa Alım Satım Davranışlarının Modellenmesi*. İstanbul: Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Doktora Tezi.
- Hochreiter, S. ve Schmidhuber, J. "Long Short-Term Memory" *Neural Computation*, pp. 1735-1780, 1997.
- Hsieh, T. J., Hsiao, H. F., & Yeh, W. C. (2011). *Forecasting stock markets using wavelet transforms and recurrent neural networks: An integrated system based on artificial bee colony algorithm*. *Applied soft computing*, 11(2), 2510-2525.
- Kantar, L. (2020). *Bist 100 Endeksinin Yapay Sinir Ađları Ve Arma Modeli İle Tahmini*. *Muhasebe ve Finans İncelemeleri Dergisi*, 3(2), 121-131.
- Kara, Y., Acar Boyacıođlu, M., VE Baykan, Ö. K. (2011). *Predicting Direction of Stock Price Index Movement Using Artificial Neural Networks and Support Vector Machines: The Sample of the Istanbul Stock Exchange*. *Expert Systems with Applications*, 38(5), 5311–5319.
- Kara, İ. (2019). *Borsa Endeksi Hareket Yönünün Tahmininde Sınıflandırma Yöntemlerinin Performanslarının Karşılaştırılması: Bist 100 Örneđi*.
- Karymshakov, K & Abdykaparov, Y (2012). 'Forecasting Stock Index Movement with Artificial Neural Networks: The Case of Istanbul Stock Exchange', *Trakya Üniversitesi Sosyal Bilimler Dergisi*, vol. 14, no. 2, pp. 231-242.
- Kim, H. Y., & 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.
- Kim, K. J. (2003). *Financial Time Series Forecasting Using Support Vector Machines*. *Neurocomputing*, 55(1-2), 307-319

- Kong, W., Dong, Z. Y., Jia, Y., Hill, D. J., Xu, Y. ve Zhang, Y. (2019). *Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network*. IEEE Transactions on Smart Grid, 10(1), 841–851. doi:10.1109/TSG.2017.2753802
- Kutlu, B., & Badur, B. (2009). *Yapay Sinir Ağları İle Borsa Endeksi Tahmini*. Yönetim Dergisi, 20(63), 45-40.
- Lee, C. Y., & Soo, V. W. (2017). *Predict stock price with financial news based on recurrent convolutional neural networks*. In *2017 conference on technologies and applications of artificial intelligence (TAAI)* (pp. 160-165). IEEE.
- Lu, C. J. (2010). *Integrating Independent Component Analysis-Based Denoising Scheme with Neural Network for Stock Price Prediction*. Expert Systems with Applications, 37(10), 7056-7064.
- Pabuçcu, H. (2019). *Borsa Endeksi Hareketlerinin Makine Öğrenme Algoritmaları İle Tahmini*. Uluslararası İktisadi ve İdari İncelemeler Dergisi, (23), 179-190.
- Rout, A. K., Dash, P. K., Dash, R., & Bisoi, R. (2017). *Forecasting financial time series using a low complexity recurrent neural network and evolutionary learning approach*. Journal of King Saud University-Computer and Information Sciences, 29(4), 536-552.
- S. Hochreiter ve J. Schmidhuber, *Long Short-Term Memory*, Neural Computation, pp. 1735-1780, (1997).
- Sakarya, Ş., & Yılmaz, Ü. (2019). *Derin öğrenme yöntemiyle bist30 indeksinin tahmini*. Avrupa Eğitim ve Sosyal Bilimler Dergisi, 4 (2), 106-121.
- Saud, A. S. ve Shakya, S. (2020). *Analysis of look back period for stock price prediction with RNN variants: A case study on banking sector of NEPSE*. Procedia Computer Science, 167, 788–798.
- Shah, D., Campbell, W., & Zulkernine, F. H. (2018). *A comparative study of LSTM and DNN for stock market forecasting*. In *2018 IEEE international conference on big data (big data)* (pp. 4148-4155). IEEE.
- Siddiqui, TA & Abdullah, Y (2015). ‘*Developing A Nonlinear Model to Predict Stock Prices In India: An Artificial Neural Networks Approach*’, The IUP Journal of Applied Finance, vol. 21, no. 3, pp. 36-49.
- Sönmez, O. (2023). *Yinelemeli sinir ağlarında çok değişkenli zaman serisi analizi yöntemleri ile süt sığırcılığı üreme süreç yönetimi (Multivariate time series analysis with recurrent neural networks for dairy cattle breeding management)* (Doctoral dissertation, Tokat Gaziosmanpaşa University, Turkey).
- 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, 9(3), 446-460.
- Tektaş, A., & Karataş, A. (2004). *Yapay sinir ağları ve finans alanına uygulanması: Hisse senedi fiyat tahminlemesi*. Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi, 18(3-4).
- Telli, Ş. & Coşkun, M. (2016). *Forecasting The BIST 100 Index Using Artificial Neural Networks With Consideration Of The Economic Calendar*. International Review of Economics and Management, 4(3), 26-46.

- Toraman, C. (2008). *Demir-Çelik Sektöründe Yapay Sinir Ağları İle Hisse Senedi Fiyat Tahmini: Erdemir AŞ ve Kardemir AŞ Üzerine Bir Tahmin Uygulaması*. *Muhasebe ve Finansman Dergisi*, (39), 44-57.
- Wang, S. & Shang, W. (2014). *Forecasting Direction of China Security Index 300 Movement with Least Squares Support Vector Machine*. *Procedia Computer Science*, 31, 869-874.
- Widegren, P. (2017). *Deep learning-based forecasting of financial assets*.
- Yakut, E., Elmas, B. & Yavuz, S. (2014). *Yapay Sinir Ağları Ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini*. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 19(1), 139-157.
- Yan, H., & Ouyang, H. (2018). *Financial time series prediction based on deep learning*. *Wireless Personal Communications*, 102, 683-700.
- Yu, L., Wang, S. & Lai, K. K. (2005). *Mining Stock Market Tendency Using GA-Based Support Vector Machines*. In *International Workshop on Internet and Network Economics*, 336-345. Springer, Berlin, Heidelberg.

LSTM MODELİ İLE VOLATİLİTE TEMELLİ BORSA TAHMİNİ

Arařtırma ve Yayın Etięi Beyanı

Yazar(lar) verilerin toplanmasında, analizinde ve raporlařtırılmasında her türlü etik ilke ve kurala özen gösterdiklerini beyan ederler. Bu çalıřmanın yazar/yazarları kullanmıř oldukları resim, Őekil, fotoęraf ve benzeri belgelerin kullanımında tüm sorumlulukları kabul etmektedir.

Yazar Katkıları:

Yazar(lar) çalıřmanın gerek literatür gerekse veri toplama, analiz ve analiz bulgularının deęerlendirilmesinden oluřan tüm sürece eřit oranda katkı saęlamıřlardır.

Çıkar Çatıřması:

Yazar(lar) çıkar çatıřması bildirmemiřtir

Etik Kurul İzni:

Bu çalıřmanın yazar/yazarları, Etik Kurul İznine gerek olmadıęını beyan etmektedir.