

Derin Öğrenme ve ARIMA Yöntemlerinin Tahmin Performanslarının Kıyaslanması: Bir Borsa İstanbul Hissesi Örneği

Caner ERDEN*

ÖZ

Finansal zaman serisi verileri doğrusal olmayan, karmaşık, birçok ekonomik faktörden etkilenen ve tahmin edilmesi zor verilerdir. Çok boyutlu ilişkilerin tahminini gerektiren finansal zaman serisi modelleri için çeşitli istatistiksel yöntemler geliştirilmiştir. Ancak günümüzde büyük verilerin kaydedilmesi, analiz edilmesi ve anlamlı bilgiye dönüştürülmesi kolaylaştığından dolayı finansal tahmin geliştirmede makine öğrenmesi algoritmalarının kullanımı özellikle son yıllarda artmıştır. Bu çalışmada, Borsa İstanbul endeksinde metal ana pazarında işlem gören EREGL hissesine ait veriler zaman serisi yöntemleri ile analiz edilmiş ardından ARIMA ve derin öğrenme modelleri ile tahmin edilmiştir. Geliştirilen derin öğrenme yönteminde veri ön işleme aşamaları, özellik çıkarımı çalışmaları ve farklı zaman çerçeveleri ile tahmin performansı iyileştirilmiştir. Derin öğrenme algoritmalarının zaman serisi çalışmalarında kullanılabilmesi için zaman gecikmelerinden oluşan bir çerçeve kullanılmıştır. Bu çalışmada, farklı zaman gecikmeleri için senaryolar denenmiş ve performans kıyaslaması ARIMA modelleri ve uzun-kısa vadeli bellek (LSTM), geçitli tekrarlayan ünite (GRU) ve özyineli sinir ağları (RNN) algoritmalarını kullanan derin öğrenme modelleri arasında gerçekleştirilmiştir. Deneysel çalışmalar ile RNN algoritmasının diğerlerine göre daha iyi tahmin performansına sahip olduğu ve ele alınan test veri seti üzerinde ortalama %93'lük doğrulukla tahmin ettiği ortaya konulmuştur.

Anahtar Kelimeler: ARIMA, BIST, Derin Öğrenme, GRU, Hisse Senedi Tahmini, LSTM, RNN

JEL Sınıflandırması: E47, G17, E37

Performance Comparisons of Deep Learning and ARIMA: A Borsa Istanbul Stock Example

ABSTRACT

Financial time-series data are nonlinear, complex, influenced by many economic factors, and are difficult to predict. Several traditional statistical methods have been developed for financial time series modeling. However, because it is now easier to record, analyze, and transform big data into meaningful information, the use of machine learning algorithms in financial forecast development has increased in recent years. In this study, the data of EREGL stocks, which are among the stocks traded in the main metal market in the Borsa İstanbul index, are analyzed using time series methods and then modeled using ARIMA and deep models. In the developed deep learning method, the prediction performance improved with data preprocessing stages, feature extraction studies, and different time windows. For deep learning algorithms to be used in time-series studies, a framework of time delays must be used. In this study, scenarios for different time delays and performance comparisons are performed between ARIMA models and deep learning models using long-short term

* Dr. Öğr. Üyesi, Sakarya Uygulamalı Bilimler Üniversitesi, Uygulamalı Bilimler Fakültesi, Uluslararası Ticaret ve Finans Bölümü / Yapay Zekâ ve Veri Bilimi Uygulama ve Araştırma Merkezi, Sakarya, Türkiye email: cerden@subu.edu.tr, ORCID Bilgisi: 0000-0002-7311-862X

(Makale Gönderim Tarihi: 23.11.2022 / Yayına Kabul Tarihi: 13.04.2023)

Doi Number: 10.18657/yonveek.1208807

Makale Türü: Araştırma Makalesi

memory (LSTM), gated repeating unit (GRU), and recursive neural network (RNN) algorithms. Experimental studies demonstrate that the RNN algorithm has a better prediction performance than the others and predicts with an average accuracy of 93% on the test dataset.

Key Words: ARIMA, BIST, Deep Learning, GRU, LSTM, RNN, Stock Price Prediction

JEL Classification: E47, G17, E37

GİRİŞ

Hisse senetleri piyasası, işletmelerin halka açılarak sermayelerini artırmaları ve temettülerini (kâr paylarını) paylaşmalarının en önemli araçlarından. Bireysel veya kurumsal yatırımcılar hisse senetlerini alarak, güvendikleri şirketlere yatırım yapma imkanını elde ederler. Yatırımcıların maksadı, en yüksek getiriyi elde edecekleri hisse senetlerini belirlemek ve yatırım stratejisini bunun üzerine kurgulamaktır. Bilgisayar bilimlerindeki gelişmeler ile doğru hisse senedinin seçimi için çeşitli zeki algoritmaların kullanılması ve hisse senedinin gelecekteki fiyat tahminlerinin yapılması çalışmaları hızlanmıştır. Hisse senedi fiyatları ülkenin içinde bulunduğu mikro ve makro ekonomik göstergeler, tedarik zinciri yönetimindeki kararlar, şirketin stratejik kararları gibi birçok farklı boyuttaki faktörlerden etkilenmektedir. Bu nedenle geleneksel olarak geliştirilen otoregresif hareketli ortalamalar modelleri (İng. Autoregressive–moving-average-ARMA), otoregresif koşullu değişen varyans (İng. Autoregressive Conditional Heteroskedasticity-ARCH), genelleştirilmiş otoregresif koşullu değişen varyans (İng. Generalized Autoregressive Conditional Heteroskedasticity-GARCH) gibi yöntemler yerine hisse senedi tahmin çalışmalarında makine öğrenmesi ve derin öğrenmesi yöntemleri daha popüler hale gelmiştir (Hu vd., 2021; Ji vd., 2021; Y. Li & Pan, 2022). Günümüzde yapay sinir ağları (YSA), destek vektör makineleri (DVM), karar ağaçları, uzun-kısa vadeli bellek (İng. Long Short Term Memory-LSTM), özyineli sinir ağları (İng. Recurrent Neural Network-RNN), evrimsel sinir ağları (İng. Convolutional Neural Network-CNN), geçitli tekrarlayan ünite (İng. gated recurrent unit-GRU) ve ekstrem gradyan artırma (Extreme gradient boosting-XGBoost) gibi makine öğrenmesi yöntemleri ile hisse senedi tahminleri başarılı sonuçlara sahiptir. Bu yöntemler içerisinde özellikle tekrarlayan sinir ağlarının diğer algoritmalara göre zaman serisi modellerinde daha iyi performansla sahip olduğu düşünülmektedir. Çünkü hisse senetlerinin zaman serileri ile modellenmesi için birçok lineer olmayan ilişkilere sahip parametre ve ağırlığın tahmin edilmesi gereklidir (Sewell, 2011). Aynı zamanda zaman serilerinin özelliği gereği veriler arasında sıralı ilişkiler söz konusudur. Bu durumda sinir ağının hafıza özelliğinin olması tahmin kabiliyetini geliştirmektedir (DiPietro & Hager, 2020).

Hisse senetleri tahminleri için teknik ve temel analize dayalı tahminler söz konusudur. Teknik analiz ile hisse senedinin göstergeleri takip edilerek gizli ilişkiler ortaya çıkarılır (Fontanills & Gentile, 2002). Temel analizde ise şirketin sahip olduğu varlıklar, borçlar değerlendirilerek yatırım kararları verilir. Hisse senedine ait verimli fiyat tahmininin yapılmasının ardından alınacak yatırım kararları yatırımcının riskini yönetmesine imkân sağlayacaktır. Finansal market uzmanları finansal piyasalarda fiyat tahminlerinin öngörülmesinin zorluğuna vurgu yapsalar da günümüz büyük veri teknolojileri, bulut bilişim sistemleri ve zeki

algoritmalar sayesinde tahmin edilemez diye düşünülen veriler arasındaki ilişkilerin doğru modellenmesi mümkün hale gelmiştir (Heaton vd., 2016; Sezer vd., 2020). Bu anlamda, büyük teknoloji şirketleri zeki algoritmalara çok ciddi yatırımlar yapmaktadır. Sonuç olarak bilgisayarların herkese açık verileri hızla üretmesi, analiz etmesi ve anlamlı bilgilere dönüştürmesi, tahmin çalışmalarını da hızlı bir şekilde iyileştirmiştir (Fang & Zhang, 2016; Sun vd., 2019). Bu çalışmada Borsa İstanbul (BIST) endeksinde işlem gören bir hisse senedi üzerinde zaman serisi analizi ile ARIMA modelleri ve derin öğrenme yöntemleri uygulaması geliştirilmiştir. Elde edilen sonuçlara göre, ARIMA modellerinin ele alınan problem verisi için derin öğrenmedeki RNN, LSTM ve GRU modellerine göre daha düşük performans gösterdiği tespit edilmiştir. Bunun üzerine, RNN modellerinin ise diğer derin öğrenme modellerinden daha üstün olduğu sonucuna ulaşılmıştır. Çalışmanın sonraki bölümleri şu şekilde özetlenebilir: Birinci bölümde finansal verilerin analizi ile ilgili zaman serisi analiz yöntemleri ve derin öğrenme yöntemlerinden faydalanılan çalışmalar incelenmiştir. İkinci bölümde çalışmanın veri seti, metodolojisi ve yöntemlerinden bahsedilmiştir. Çalışmanın üçüncü bölümünde ARIMA ve derin öğrenme modellerine ait deneysel sonuçlar paylaşılmıştır. Son bölümünde ise elde edilen sonuçlar üzerine değerlendirmeler yapılmıştır.

I. LİTERATÜR ÖZETİ

Finansal verilerin zaman serisi analizleri ve tahminleme çalışmaları karmaşık ve kaotik birtakım özelliklerin keşfedilmesini gerektirir. Bu nedenle finansal zaman serileri ile gerçekleştirilen çalışmalar sürekli ilgi duyulan bir alan olmuştur. Günümüzde ise bu çalışmaların yöntem olarak yapay zekâ yöntemlerini sıklıkla kullandığı görülmektedir. Bu bölümde zaman serisi modelleri ve yapay zekâ modelleri ile gerçekleştirilen zaman serisi çalışmalarından bahsedilecektir.

A. Zaman Serisi Modelleri

Geleneksel zaman serisi analizleri ve tahmin çalışmaları ARIMA çalışmaları ve onun varyasyonları sezonsal ARIMA (Kihoro vd., 2004) veya keşifsel değişkenler ile ARIMA (Peter & Silvia, 2012; Wangdi vd., 2010) gibi çalışmalara dayanmaktadır (Mehrmolaei & Keyvanpour, 2016; G. P. Zhang, 2003). Finansal zaman serisi çalışmaları çok geniş bir literatüre sahiptir. Bu nedenle, bu literatür taramasında BIST hisse senetleri üzerinde gerçekleştirilen ARIMA modellerine odaklanılmıştır.

Vergil & Ozkan, (2007), Türkiye'nin döviz kurlarını tahmin etmede ARIMA modellerinin tahmin gücünü araştırmışlardır. Çalışma sonucunda satın alma paritesi teorisine göre ARIMA modellerinin daha iyi tahmin performansına sahip olduğu belirlenmiştir.

Tekin & Çanakoğlu, (2019), Borsa İstanbul 30 (Bist-30) hisselerine ait verileri kullanarak makine öğrenmesi, derin öğrenme ve ARIMA modellerinin sonuçlarını kıyaslamışlardır. Sonuçlara göre, performans ölçütleri olan RMSE ve MAE dikkate alınarak incelendiğinde ARIMA modellerinin zaman serisi analizlerinde iyi bir yöntem olduğu tespit edilmiştir. EREGL hisse senedine ait

tahmin çalışmasında, makine öğrenmesi ve derin öğrenme yöntemleri birbirleri ile kıyaslandığında birbirine yakın tahmin sonuçları elde edildiği belirtilmiştir.

Mashadihasanlı, (2022), 2009-2021 yılları arasındaki aylık bazda 147 gözlemden oluşan BIST endeks verilerini ARIMA ile modellemiştir. Çalışmada, en iyi performansa sahip olan ARIMA (3,1,5) modeli ile endeks değerleri tahmin edilmiş ve gerçek sonuçlar ile tahmin değerlerinin yakın olduğu belirtilmiştir.

Kurt & Senal, (2018), yaptıkları çalışmada BIST endeksinde işlem gören sigorta ve bireysel emeklilik şirketlerinin durumlarının tahmini için en uygun ARIMA modeli geliştirmişlerdir. Bu çalışmada, Aksigorta A.Ş., Anadolu Hayat Emeklilik A.Ş., Anadolu Anonim Türk Sigorta Şirketi, Güneş Sigorta A.Ş. ve Ray Sigorta A.Ş., Avisa Emeklilik ve Hayat A.Ş. ve Halk Sigorta A.Ş. hisselerine ait geçmiş verilerden yararlanılarak en uygun ARIMA modelinin araştırılması ile geçerli sonuçlara ulaşılmıştır.

Baykut & Veysel, (2018) BIST-50 endeksinin tahmini için ARCH ve GARCH modelleri geliştirilmiş ve sonuçları ARIMA modelleri ile kıyaslamışlardır. Çalışma sonucunda BIST-50 endeksinin volatilité ısrarcılığı 16 gün; volatilitésinin ise %1.76 olduğu hesaplanmıştır.

Alacahan & Akarsu, (2019), döviz kurlarının gelişmiş ekonomiler üzerindeki etkisine dikkat çekmiştir. Çalışmada BIST-100 endeksi üzerinde döviz kurlarının etkisinin olup olmadığı araştırılmış olup 2004-2018 arasındaki veriler için geliştirilen zaman serisinde en iyi modelin ARIMA (2,2,3) olduğu belirtilmiştir.

Aktas vd., (2022), BIST-50 endeksinin global finans krizinin yaşandığı 2008-2009 arasındaki 13 aylık süredeki durumunu ortaya koymak için zaman serisi analizi kullanmışlardır. Çalışmada ARIMA modellerinin güçlü yapısı vurgulanmış ve özellikle COVID-19 gibi kriz dönemlerinde kullanılan modelin avantajlı yanlarından bahsedilmiştir.

Chen vd., (2018), yaptıkları çalışmada yatırımcıların daha yüksek getiri elde edebilmeleri için bir takım yöntemler izlemeleri gerektiğini vurgulamıştır. Bunlar, (i) hisse senedi tahmini için teknik analizin yapılması, (ii) teknik analize göre hisse senedi takibinin yapılması, (iii) tahmin sonuçlarının değerlendirilmesi ve sunulması olarak verilmiştir.

ARIMA modelleri regresyon temelli yaklaşımlar olduğu için çok boyutlu, karmaşık ve lineer olmayan ilişkilerin keşfedilmesinde dezavantaja sahiptir. Aynı zamanda, ARIMA uygulanacak veri seti üzerinde bir takım istatistiksel varsayımlar yapılmalıdır. Bu nedenle de büyük veriler içerisindeki örüntülerin keşfedilmesinde zorluklar ile karşılaşılır (Hyndman, 2020). Bu sorunların çözümü için derin öğrenme algoritmaları iyi bir alternatif sunmaktadır (Najafabadi vd., 2015).

B. Yapay Zekâ Modelleri

Finans dünyasında yapay zekâ modelleri, portfolyo optimizasyonu (Day & Lin, 2019; Ferreira vd., 2021), hisse senedi fiyat tahmini (L. Chen vd., 2018; Navale vd., 2016), algoritmik al-sat sinyalleri (Beverungen, 2019; Chan, 2021), finans teknoloji uygulamaları (Belanche vd., 2019; Jakšič & Marinč, 2019), finansal risk değerlendirmeleri ve yönetimi (Giudici, 2018; Xie, 2019), sahte işlem tespiti (Choi

& Lee, 2018; Ngai vd., 2011), kredi skor kararları (Goh vd., 2020; Ince & Aktan, 2009), siber atakların engellenmesi (Khisamova vd., 2019; J. Li, 2018) gibi alanlarda kullanılmaktadır. Yapay zekâ uygulamaları ile geliştirilen zaman serisi uygulamaları için ise üç temel yöntem kullanılmaktadır. Bunlar, regresyon, makine öğrenmesi ve birleşik (İng. Ensemble) yöntemler tabanlıdır.

Qiu vd. (2014) birleşik derin öğrenme ağları (İng. ensemble deep learning belief network) yapısı kullanarak zaman serisi modeli geliştirmiştir. Çalışmada elektrik yükleri talebi veri seti üzerinde destek vektör makineleri, yapay sinir ağları ve derin sinir ağları karşılaştırması yapılarak en iyi sonucun derin öğrenme yöntemleri ile elde edildiği belirtilmiştir.

Gasparin vd. (2022) benzer şekilde elektrik tahmini problemini derin öğrenme zaman serisi modelleri ile çözmüşlerdir. Yöntemler arasında ileri beslemeli sinir ağı (İng. feed-forward neural network-FNN), daha derin ileri beslemeli sinir ağı varyantı (İng. deeper variant of a feed-forward neural network-DFNN), geçici evrişimli ağ (İng. temporal convolutional network-TCN), LSTM, GRU ve seq2seq modelleri bulunmaktadır. En iyi performansın ise LSTM modellerinde kaydedildiği belirtilmiştir.

Gamboa (2017) çalışmasında derin öğrenme ve zaman serisi uygulamalarını üç grup altında incelemiştir: (i) sınıflandırma (Långkvist, 2014; Zheng vd., 2014), (ii) tahmin (Kuremoto vd., 2014; Turner, 2014; Yalçın Kayacan, 2019), (iii) anomali tespiti (Feng & Han, 2015). Derin öğrenme algoritmalarının zaman serilerine uygulanması ile önceki klasik çalışmalara göre performanstaki iyileşmeler vurgulanmıştır.

Santur (2020) çalışmasında 2006-2018 aralığındaki günlük verileri kullanarak geliştirilen derin öğrenme modelinde %82 oranında doğru trend tahmini gerçekleştirilmiştir. Çalışmada trend yönü tahmini için çok katmanlı LSTM hücreleri kullanılmış ve performans ölçütü olarak doğruluk oranları tercih edilmiştir. Çalışma sonucunda 694 işlem gününe ait portföy büyüklüğü %39 oranında artırılarak başarılı sonuçlar elde edilmiştir.

Hasan vd. (2020) teknik indikatörlere dayalı bir tahmin modelini BİST-100 endeksi üzerinde gerçekleştirilmiştir. Endeksin tahmini için derin öğrenme, destek vektör makineleri, rassal orman ve lojistik regresyon modelleri kurulmuş ve performanslar karışıklık matrisi, geri dönüş oranı gibi ölçütler ile değerlendirilmiştir.

Gündüz vd. (2018) BİST 100 endeksinde işlem gören 9 banka hissesinin tahmini için LSTM modeli geliştirmişlerdir. Girdi özellikleri arasında finansal haberlerden elde edilen nitelikler de bulunmaktadır. Geliştirilen model, rastgele ve Naive yöntemleri ile kıyaslanmış ve sonuçların benzer performanslara sahip olduğu belirtilmiştir.

Aslan & Erdur (2020) yaptıkları çalışmada kamu aydınlatma platformu verileri ile üç spor kulübünün (Galatasaray, Fenerbahçe ve Beşiktaş) hisselerini tahmin etmişlerdir. Çalışmada, tahmin için LSTM modeli geliştirilmiş ve deneysel sonuçlara göre KAP verilerinin hisse senetleri üzerindeki etkileri vurgulanmıştır.

Verilen kısa literatür özetinden sonra bu çalışmada gerçekleştirilen farklı yaklaşım ve katkılar şu şekilde verilebilir:

- Bahsedilen çalışmalar incelendiğinde, hisse senedi tahmin çalışmalarının yoğunlukla zaman serilerindeki geleneksel modeller, makine öğrenmesi ya da derin öğrenme modellerinden LSTM ile geliştirildiği görülmektedir. Bu çalışmada ise derin öğrenme algoritmalarından LSTM, GRU ve RNN farklı tasarımlar ve parametreler ile denenmiştir.
- Zaman serileri modellerinin derin öğrenme ile tahmin edilebilmesi için zaman çerçevesi işleminin yapılması gereklidir. Modellerin performansları belirlenen zaman gecikmesi ile değişkenlik göstermektedir. Bu çalışmada farklı zaman gecikmeleri ile deneysel çalışmalar yapılarak en iyi zaman gecikmesi ve derin öğrenme modeli kombinasyonu belirlenmiştir.
- Makine öğrenmesinde bazı durumlarda en iyi öğrenme performansının tekil bir çalıştırmada elde edilmesi söz konusu olabilir. Bu modelin kaydedilerek yeniden çalıştırmalarda tekrarlı sonuçların elde edilmesi bilimsel olarak gerekli görülebilir. Ancak tekil çalıştırmalardan ziyade çoklu çalıştırmaların daha tutarlı sonuçlar üreteceği açıktır. Bu çalışmada, deneysel çalıştırmalar farklı sayıda gerçekleştirilmiş ve elde edilen sonuçlar ortalama ve standart sapma değerleri ile değerlendirilmiştir.
- Çalışmada ayrıca geleneksel yöntemlerden olan ARIMA modellerinin iyi sonuç veren tasarımı araştırılmış ve ARIMA ile derin öğrenme modellerinin kıyaslaması yapılmıştır.

II. MATERYAL VE YÖNTEM

A. ARIMA Zaman Serisi Modelleri

Zaman serilerinin modellenmesi ile ilgili akla gelen ilk çözümlerden birisi geçmişteki verilerin gelecekteki verileri tahmin etmedeki etkisinin yüksekliği ile alakalıdır. ARIMA modeli, Box-Jenkins modelleri olarak da bilinen ve durağan zaman serilerinde kullanılan standart bir yöntem olarak kabul edilmektedir (Box vd., 2015). Bu yöntemde öncelikle zaman serisinin tanınması ve yöntemle uygunluğu araştırılır. Ardından ARIMA modelinin parametreleri belirlenir. Son aşamada belirlenen parametreler ile zaman serisi modelleme sonuçları değerlendirilir. Zaman serilerinde durağanlık önemli bir özelliktir ve ARIMA modelleme çalışmasından önce kontrol edilmesi gereklidir. Eğer durağanlık sağlanamazsa fark alma işlemleri ile durağan zaman serisine ulaşılır. Çünkü ARIMA modellerinde zaman serisinin varyans ve ortalama değerlerinin zamanla sabit kaldığı varsayımı yapılır. ARIMA modellerinin genel matematiksel denklemi Denklem 1'deki gibi verilebilir (Hipel vd., 1977).

$$Y_t = \alpha + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \varphi_1 \varepsilon_{t-1} + \varphi_2 \varepsilon_{t-2} + \dots + \varphi_q \varepsilon_{q-1} \quad (1)$$

Burada, α sabit değeri, β gözlem değerleri için katsayılarını, Y_t t anındaki zaman serisinin değerini, φ hata terimlerinin katsayılarını, ε hata terimlerini, p oto regresif katsayısını yani gecikme değerlerini göstermektedir. q değeri ise hareketli ortalama parametresidir. Dolayısıyla ARIMA (p, d, q) ifadesi ile otoregresif

sıralama(p), fark alma işleminin kaç sefer yapılacağı (d) ve hareketli ortalama parametresi(q) bilgileri ortaya konulur.

B. Derin Öğrenme Algoritmaları

Makine öğrenmesi algoritmalarının ana amacı, girdi verileri ile çıktı verileri arasındaki gizli ilişkileri ortaya çıkararak eğitim algoritmasının görmediği verilerde genel bir başarıya ulaşması olarak verilebilir. Derin öğrenme algoritmaları, makine öğrenmesi algoritmalarının alt dalı olarak yüksek düzeyde öğrenme imkanı sunmaktadır (Bengio, 2009). Özellikle son yıllarda derin öğrenme, görüntü tanıma (Bengio vd., 2006; G. Dahl vd., 2010; Hinton vd., 2006), ses tanıma (G. E. Dahl vd., 2011; Krizhevsky vd., 2017), doğal dil işleme (Bordes vd., 2012; Deoras & Kombrink, 2011), büyük veri çalışmaları(X.-W. Chen & Lin, 2014; Q. Zhang vd., 2018) gibi birçok önemli uygulama alanlarına sahiptir. Büyük veri setlerindeki özellikler arasındaki lineer olmayan ilişkilerin keşfedilmesiyle insanların daha doğru kararlar almasında kolaylık sağlayan uygulamalar geliştirilmektedir. Klasik makine öğrenmesi algoritmaları, sıralı veri içeren zaman serisi analizi gibi uygulamalarda önceki verilerin sonraki veriyi önemli oranda etkilediği durumlarda iyi sonuçlar vermemektedir. Sıralı verilerin tahmini için derin öğrenme algoritmalarından RNN, LSTM ve GRU gibi sinir ağı yapıları geliştirilmiştir. Bu sinir hücrelerinin en önemli avantajı hafıza özelliklerinin olmasıdır (Sherstinsky, 2020). Aynı zamanda unutmaya özelliği de eklenerek şimdiki halini alan derin sinir hücreleri son yıllarda birçok alanda başarıyla uygulanmıştır. Klasik sinir ağları ile benzer girdi ve çıktı düzeneklerine sahip olan bir LSTM hücre yapısı

Diğer bir derin sinir hücresi olan GRU hücresi de LSTM hücreleri gibi RNN varyantı olarak geliştirilmiştir. GRU hücresinin yapısı LSTM hücresine göre daha az karmaşıktır. LSTM hücrelerdeki giriş, unutmaya ve çıkış hücreleri, Şekil 2'de gösterildiği gibi çıkış, güncelleme (İng. update- z_t) ve sıfırlama ya da yenileme (İng. reset- r_t) kapıları olarak burada güncelleştirilmiştir. Bu kapılar üzerinden mevcut durumun geçmişteki durumdan etkilenip etkilenmediği tespit edilmektedir. Sıfırlama kapısında, bellekteki girişin yeni girişle nasıl birleştirileceğine karar verilir. Bilgilerin bellekte ne kadar süre kalacağı güncelleştirme kapısı tarafından belirlenir. GRU hücresinin üç kapısı için hesaplamalar Denklem 4'te verilmiştir (Dey & Salem, 2017).

Şekil 1'de gösterilmiştir. Şekilde görülebileceği gibi derin sinir ağı içerisinde 3 farklı kapıdan bahsedilir. Birinci kapı unutmaya kapısıdır f_t . Bu kapı hangi bilginin unutulması gerektiğine karar verir. Sonraki kapıda giriş kapısı i_t ve çıkış kapısı o_t işlemleri gerçekleştirilir. Sonuçta kararlaştırılan çıktılar h_t bir sonraki sinir ağına verilir. İlgili kapılara ait işlemler Denklem 2 ve Denklem 3'te verilmiştir (Staudemeyer & Morris, 2019).

$$\sigma(t) = \frac{1}{1+e^{-t}} \quad \tanh(t) = \left(\frac{e^t - e^{-t}}{e^t + e^{-t}} \right) \quad (2)$$

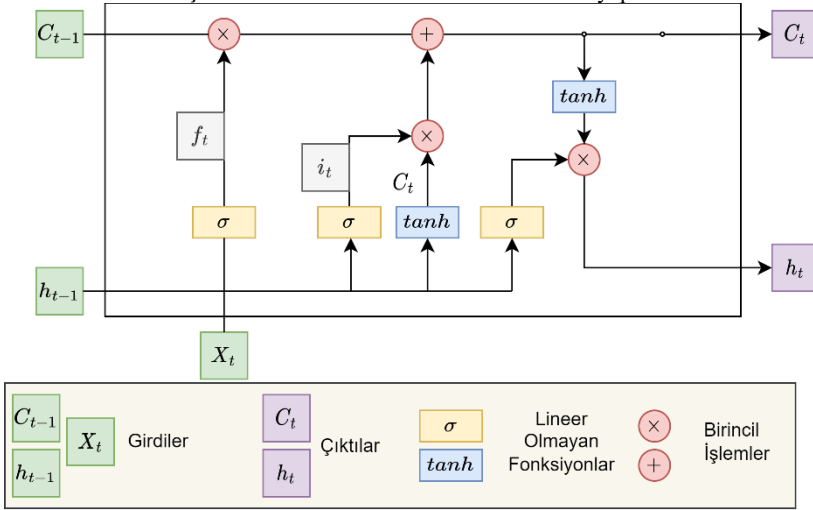
$$\text{Unutmaya kapısı: } f_t = \sigma(W_f(h_{t-1}, X_t) + B_f)$$

$$\text{Girdi kapısı: } i_t = \sigma(W_i(h_{t-1}, X_t) + B_i) \quad (3)$$

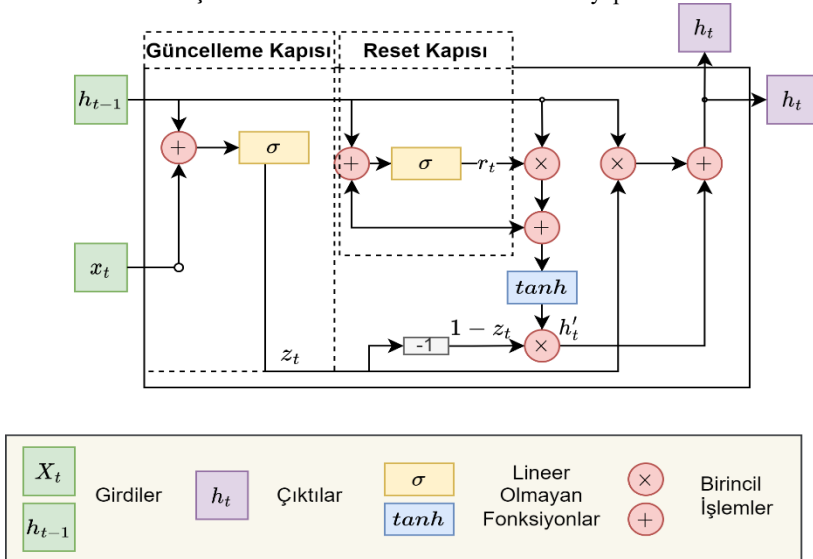
$$\text{Çıktı kapısı: } o_t = \sigma(W_o(h_{t-1}, X_t) + B_o)$$

Diğer bir derin sinir hücresi olan GRU hücresi de LSTM hücreleri gibi RNN varyantı olarak geliştirilmiştir. GRU hücresinin yapısı LSTM hücresine göre daha az karmaşıktır. LSTM hücrelerdeki giriş, unutma ve çıkış hücreleri, Şekil 2'de gösterildiği gibi çıkış, güncelleme (İng. update- z_t) ve sıfırlama ya da yenileme (İng. reset- r_t) kapıları olarak burada güncelleştirilmiştir. Bu kapılar üzerinden mevcut durumun geçmişteki durumdan etkilenip etkilenmediği tespit edilmektedir. Sıfırlama kapısında, bellekteki girişin yeni girişle nasıl birleştirileceğine karar verilir. Bilgilerin bellekte ne kadar süre kalacağı güncelleştirme kapısı tarafından belirlenir. GRU hücresinin üç kapısı için hesaplamalar Denklem 4'te verilmiştir (Dey & Salem, 2017).

Şekil 1. LSTM hücresinin bir hücreli blok yapısı



Şekil 2. GRU hücresinin bir hücreli blok yapısı



$$\begin{aligned}
\text{Sıfırlama kapısı: } r &= \sigma(W_r(h_{t-1}, X_t) + U_r X_t) \\
\text{Güncelleme kapısı: } z &= \sigma(W_z(h_{t-1}, X_t) + U_z X_t) \\
\text{Hatırlama hücresi: } c &= \tanh(W_c(h_{t-1} * r) + U_c X_t) \\
\text{Gizli durum: } h_t &= (z * c) + ((1 - z) * h_{t-1})
\end{aligned}
\tag{4}$$

III. DENEYSEL ÇALIŞMALAR VE BULGULAR

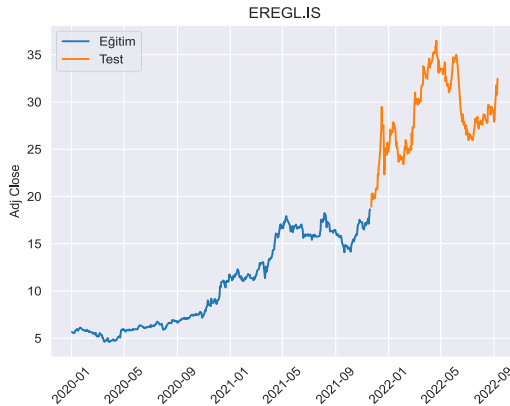
Bu çalışmada BIST-30 endeksinin önemli hisselerinden EREĞLİ DEMİR VE ÇELİK FABRİKALARI T.A.Ş. (EREGL) verileri kullanılmıştır. Veri seti, Yahoo finans web sayfasından çekilen '2020-01-01' tarihinden '2022-09-09' tarihine kadar olan 673 günlük verilerden oluşmaktadır. Başlangıç veri setinin tanımlayıcı istatistiksel bilgileri Tablo 1'de paylaşılmıştır. Veri setinde hisse senedine ait “yüksek (İng. high), düşük (İng. low), açılış (İng. open), kapanış (İng. close), ve ayarlanmış kapanış (İng. adj close)” değişkenleri bulunmaktadır. Burada veri setinin zaman serisi olarak modellenmesi için Box-Jenkins yöntemi kullanılacaktır. Bu nedenle “ayarlanmış kapanış” değerleri zaman serisi modellemede, ARIMA ve derin öğrenme modellerinin girdisi olarak verilecektir.

Tablo 1. Başlangıç veri seti tanımlayıcı istatistikler

	Yüksek	Düşük	Açılış	Kapanış	Hacim	Adj Kapanış
Adet	673	673	673	673	673	673.0
Ort.	18.5	17.9	18.2	18.2	42588376	16.0
Std	9.0	8.7	8.9	8.8	30688210	9.4
Min.	7.6	6.8	7.1	7.4	0	4.6
25%	9.4	9.2	9.3	9.3	23863676	6.9
50%	17.1	16.7	17.0	17.0	35431883	14.9
75%	27.8	26.8	27.2	27.2	51936818	24.9
Maks.	36.9	35.9	36.5	36.5	300368485	36.5

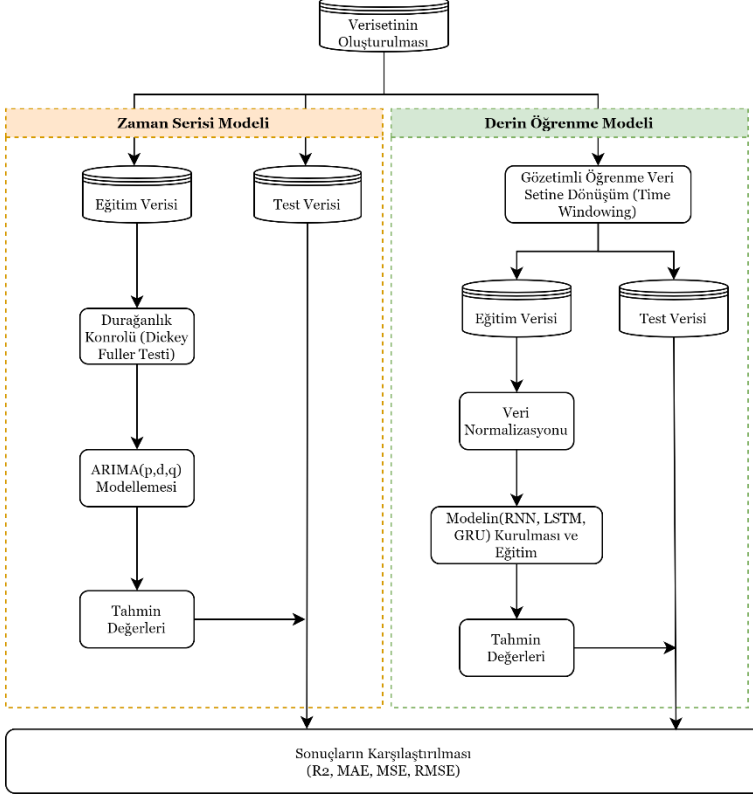
Veri seti performans kıyaslamalarının yapılabilmesi için %70-30 oranında eğitim (2020-01-02 ile 2021-11-19 tarihleri arası) ve test (2021-11-22 ile 2022-09-09 tarihleri arası) olarak Şekil 3'te gösterildiği gibi ikiye ayrılmıştır. Eğitim setinde gerçekleştirilen öğrenme performansı test veri seti üzerinde deneyerek algoritmaların görmediği verileri tahmin kapasitesi ortaya konulacaktır.

Şekil 3. EREGL hisse senedinin eğitim ve test veri seti



Bu çalışma temel olarak iki aşamadan oluşmaktadır. Birinci aşamada zaman serisi analizi yapılarak ARIMA modeli kurulmuştur. İkinci aşamada ise veri seti derin öğrenme yöntemleri ile modellenmiştir. Çalışmanın akış şeması Şekil 4'te verildiği gibidir.

Şekil 4. Çalışmanın akış şeması




A. ARIMA Modeline Ait Sonuçlar


ARIMA modelinin öncesinde durağanlık testinin yapılması gereklidir. Bunun için Augmented Dickey-Fuller (ADF) testi serinin durağan olup olmadığı hakkında bilgi verir (Mushtaq, 2011). Durağanlık serinin ortalama değerinin zamanla bağlı olarak değişmediği anlamına gelir. ADF testinin yokluk hipotezi serinin durağan olmadığını iddia eder. Eğer p değeri 0.05'ten küçük çıkarsa yokluk hipotezi reddedilir yani seri durağandır denilir. Eğer p değeri 0.05'ten büyük çıkarsa seride fark alma işlemleri yapılarak seri durağan hale getirilir. Bu çalışmada elde edilen ADF istatistiksel bilgileri Tablo 2'de verilmiştir. Buna göre p değeri 0.05'ten büyük çıktığı için seri durağan değildir. Serinin durağan olmadığına karar verildikten sonra otokorelasyon fonksiyonu grafiği (Şekil 6) (ACF) ve kısmi otokorelasyon fonksiyonu grafiği (Şekil 7) (PACF) çizilerek gecikme (p), fark alma (d), ve geçmişten etkilenme (q) değerleri tahmin edilir. PACF özellikle gecikmeler ile ilgili bilgileri, ACF ise özellikle geçmiş veriler ile şimdiki verinin ilişkisini ortaya koyar. PACF grafiğine bakıldığında birinci ve ikinci gecikmede uç durumu

söz konusudur. Sonra gelen gecikmelerin önemli olmadığı sonucuna varılır. Bu analizler ile ARIMA modeline giriş yapılır. ARIMA zaman serilerini modellemek için kullanılan istatistiksel bir yöntemdir. ARIMA modelinin unsurları şu şekilde verilebilir: Autoregressive (AR), önceki hataların lineer kombinasyonlarını, Integrated (I), durağanlığın sağlanması için yapılacak fark alma işlemini, Moving average (MA) ise geçmiş ağırlıklı ortalamaları göstermektedir. ARIMA modelinin seçim kriterlerinden en fazla kullanılan Akaike Bilgi Kriteri (AIC) kriteridir. AIC uygun ARIMA parametrelerinin seçiminde kullanılır ve düşük AIC değerine sahip modelin en uygun model olduğuna karar verilir.

Şekil 5. Zaman gecikme (Lag) değerlerine göre otokorelasyonlar



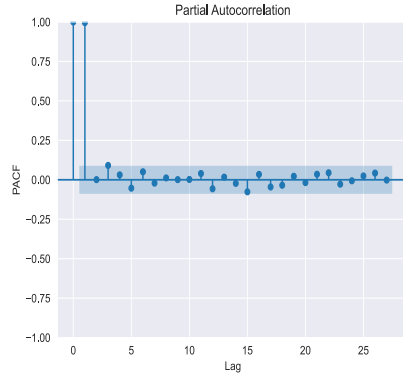
Şekil 6. Otokorelasyon ve lag değerleri



Tablo 2. ADF istatistik değerleri

	Değerler
ADF F% istatistiği	0.2427
P-değeri	0.9745

Şekil 7. Kısmi otokorelasyon ve lag değerleri



PACF ve ACF grafikleri ışığında deneme yapılan ARIMA modelleri ve AIC skorları Tablo 3'te paylaşıldığı gibidir. AIC skoru düşük olan ARIMA modelinin daha iyi tahmin potansiyeline sahip olduğu bilinmektedir. AIC skorlarına bakılarak seçilen ARIMA model parametreleri (0,1,0) olarak belirlenmiştir. Model eğitim setinde eğitildikten sonra test setinde tahmin performansı gerçekleştirildiğinde tahmin sonuçlarına ulaşılır.

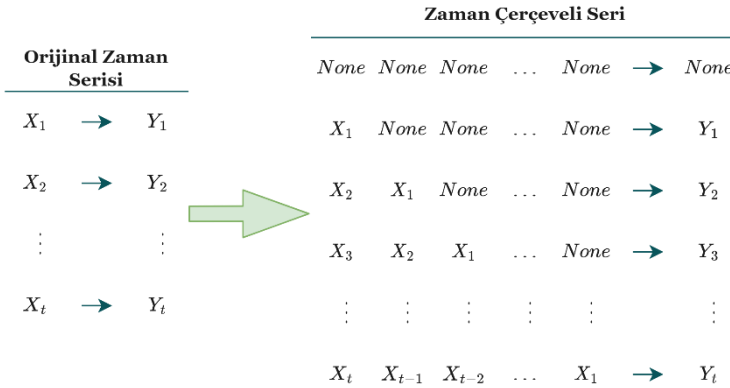
Tablo 3. ARIMA Parametreleri ve AIC Skorları

ARIMA Parametreleri	AIC
ARIMA (0, 0, 0)	2760.33
ARIMA (0, 0, 1)	2146.45
ARIMA (0, 1, 0)	45.8043
ARIMA (0, 1, 1)	47.4986
ARIMA (1, 0, 0)	56.1026
ARIMA (1, 0, 1)	57.7814
ARIMA (1, 1, 0)	47.5294
ARIMA (1, 1, 1)	46.2544

B. Derin Öğrenme Modellerine Ait Sonuçlar

Çalışmanın ikinci aşamasında derin öğrenme yöntemleri ile zaman serisi tahmin modeli çalıştırılmıştır. Zaman serisinin gözetimli öğrenmeye uygun hale gelebilmesi için tablo verisine dönüştürülmesi gerekmektedir. Bunun için önceki n adet veri girdi şimdiki zaman serisi değeri çıktı olacak şekilde bir tablo dönüşümü gerçekleştirilir. Bu durum zaman kaydırma olarak bilinir ve Şekil 8'deki gibi gösterilebilir.

Şekil 8. Zaman serisi çerçeveleme stratejisi



Gözetimli öğrenme problemine dönüştürülen veri seti üzerinde zaman serileri, konuşma verileri, görüntü verileri gibi sıralı verilerde iyi performans gösteren derin öğrenme yöntemleri uygulanabilir. Çalışmada gerçekleştirilen derin öğrenme parametreleri deneme yanılma yoluyla detaylı çalıştırmalar sonucunda Tablo 4'teki gibi belirlenmiştir. Hiper parametrelerin en iyi değerlerinin ayarlanması için tüm değişkenlerin birlikte katıldığı bir optimizasyon modeline ihtiyaç duyulur. Bu çalışmada hiper parametreler belirlendikten sonra hiper parametre değerleri sabit tutularak gecikme sayısı ve derin öğrenme algoritmalarının değişimi ve model performansına etkileri üzerinde durulacaktır. Buna göre kullanılan gizli katman sayısı ikidir. İki katmandan sonra bir dropout katmanı 0.25 oranı ile sisteme eklenmiştir. Dropout katmanı sayesinde ağız ezberleme ihtimalinin azalması hedeflenmiştir. Eğitimin gerçekleştirileceği veri setindeki performansların kontrol edilebilmesi için 0.15 oranında doğrulama seti, sonuçta eğitimde kullanılmayan test seti de 0.15 oranında alınmıştır. Bununla birlikte deneylerde 50 epoch sonrasında yatay gitme söz konusu olduğu için epoch değeri 50 olarak alınmıştır.

Tablo 4. Derin öğrenme algoritmalarında kullanılan hiper parametreler

Parametreler	Değerler
Ölçeklendirme	MinMax Normalizasyonu
Aktivasyon Fonksiyonu	'linear'
Dropout Oranı	0.25
Katmanlardaki nöron sayıları	32, 32
Test seti oranı	0.15
Doğrulama seti oranı	0.15
Batch boyutu	5
Epoch sayısı	50

Verilerin çekildiği kaynakta eksik verilerin olması mümkün olmadığından dolayı veri setinde eksik, hatalı ve aykırı veriler bulunmamaktadır. Bu nedenle veri ön işleme aşamasında verilerin aynı ölçekte davranabilmesi için normalizasyon aşaması uygulanmıştır. Kullanılan minmax ölçeklendirmesi ile veriler 0-1 aralığında normalize edilmiştir. Minmax normalizasyonu Denklem 5'te gösterildiği gibi uygulanmıştır.

$$X_{normal} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (5)$$

Tahmin aşamasında geliştirilen modellerin değerlendirilmesi ve karşılaştırılabilmesi için performans ölçütlerine ihtiyaç vardır. Bu çalışmada yaygın kullanılan hata metriklerinden ortalama karesel hataların karekökü (RMSE) ve ortalama mutlak hatalar (MAE) sırasıyla Denklem 6 ve Denklem 7'deki gibi hesaplanır.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}| \quad (6)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2} \quad (7)$$

Burada N veri sayısını, y_i gerçek değeri \hat{y} ise tahmin değerini göstermektedir. Determinasyon katsayısı ise R^2 olarak gösterilir ve regresyon modelinin verileri ne kadar açıkladığının ölçüsüdür. R^2 değeri Denklem 8'deki gibi hesaplanır ve 1'den küçük olmalıdır.

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y})^2}{\sum_{i=1}^N (y_i - \mu)^2} \quad (8)$$

Tüm deneysel çalıştırmalar Intel (R) Core (TM) i7-5600U CPU @ 2.60GHz 2.59 GHz kişisel laptopu üzerinde Python programlama dilinde temel olarak Keras kütüphanesi ve arka planda Tensorflow çerçevesi kullanılarak geliştirilmiştir. ARIMA ve derin öğrenme yöntemlerinin kıyaslanması için farklı zaman gecikmelerinde deneyler 30 farklı rassal sayı üretici ile çalıştırılmış ve sonuçlar **Tablo 5**'te paylaşılmıştır. Tabloya ilaveten, ARIMA sonuçları MAE 10.1731, MSE 105.1961, RMSE 10.2565 ve R^2 skoru 0.6436 olarak bulunmuştur. Tekil çalıştırmalar kimi zaman tutarlı olmayan iyi performans göstermektedir. Ancak daha tutarlı sonuçlar için çalıştırmaların tekrarlanması ve yeniden çalışma sonuçlarının istatistiksel olarak doğrulanması gereklidir. Bu anlamda, gerçekleştirilen farklı sayıda çalışma sonucunda elde edilen MAE, MSE, RMSE değerlerinin ortalama olarak en düşük olduğu ve R^2 değerinin de en yüksek olduğu kombinasyon RNN sinir ağının kullanıldığı ve 5 zaman gecikmesinin uygulandığı kombinasyon olmuştur. Buna göre R^2 değeri ortalama 0.9324, standart sapma


değeri ise 0.0061 olarak elde edilmiş ve yüksek oranda bir performans ile eğitim sonuçlandırılmıştır. Tekil çalıştırmalardaki maksimum R^2 değeri ise 0.9400 oranına ulaşmıştır.

Algoritmaların tüm zaman gecikmeleri için aldığı değerlerin ortalaması alınarak kutu grafikleri (box-plot) oluşturulmuştur. Kutu grafikleri sayesinde ortalama, medyan, standart sapma ve aykırı veriler ile ilgili bilgi edinilir. **Şekil 9-a**'da görüldüğü gibi R^2 değerlerinin farklı algoritmalar için ortalama RNN sinir ağı modeli diğer sinir ağlarına göre daha iyi bir performans göstermiştir. Şekilde 5-10-15 zaman gecikmeleri için ayrı kutu grafikleri ile temsil edilmiştir. Bu grafiğe göre yapılacak diğer bir değerlendirme, YSA katmanındaki R^2 değeri derin sinir ağlarından daha düşük kalması ile ilgilidir. Bunun yanında, en iyi öğrenme performanslarının 5 zaman gecikmesinde alındığı görülmektedir. **Şekil 9-b**'de ise hata performanslarına ait sonuçlar paylaşılmıştır. Buna göre en düşük hataların benzer şekilde RNN modellerinde elde edildiği sonucuna ulaşılmıştır.


Tablo 5. Model sonuçlarının zaman gecikmeli değerlerine göre ortalama performans sonuçları

Zaman Gecikmesi	Ortalama MAE			Ortalama MSE			Ortalama RMSE			Ortalama R^2		
	5	10	15	5	10	15	5	10	15	5	10	15
YSA	0.6518	0.7345	0.7289	0.6944	0.8389	0.8243	0.8713	0.9577	0.9508	0.8378	0.8243	0.8251
GRU	0.6103	0.6946	0.7017	0.6701	0.8163	0.8354	0.8183	0.9021	0.9133	0.9266	0.9100	0.9072
LSTM	0.6839	0.7441	0.7720	0.7905	0.9159	0.9892	0.8886	0.9557	0.9940	0.9134	0.8990	0.8901
RNN	0.5860	0.6765	0.6692	0.6175	0.7778	0.7670	0.7851	0.8788	0.8734	0.9324	0.9143	0.9148

Şekil 9. Farklı deneysel çalıştırmalar için ortalama a) R^2 oranları ve b) MAE, MSE, RMSE hatalarına ait performans sonuçları




b)




RNN ve 5 zaman gecikmeli modelin en iyi model olduğu sonucuna varıldıktan sonra en iyi modelin performans grafikleri **Şekil 10-Şekil 11**'de paylaşılmıştır. **Şekil 10** tahmin edilen hisse senedi fiyatları ile gerçekte olan hisse senedi fiyatlarının benzerliklerini göstermektedir. **Şekil 11**'de ise eğitim ve çapraz doğrulama hata değerlerinin eğitim boyunca değişimi gösterilmiştir.

Şekil 10. Test verilerinin 5 zaman gecikmeli RNN modeli ile tahmin edilmesine ilişkin tahmin ve gerçek değerleri



Şekil 11. Eğitim performansı



IV. SONUÇ

Bu çalışmada LSTM, GRU ve RNN gibi farklı derin öğrenme algoritmaları ile ARIMA modelinin kıyaslanması, bir BIST-30 hisse senedine ait zaman serisi tahmin çalışması için gerçekleştirilmiştir. Deneysel çalışmalar sonucunda, ARIMA modelinin YSA ve derin öğrenme modellerine göre performansının düşük olduğu gözlemlenmiştir. Derin öğrenme modelleri arasında farklı zaman gecikmeleri ile kıyaslama yapıldığında en iyi modelin 5 zaman gecikmeli RNN modeli olduğu ve bu modelin 0.9324 oranında doğru tahminde bulunduğu tespit edilmiştir (**Tablo 5**). **Şekil 9**'da gösterilen ortalama tahmin performanslarına göre, farklı sayıda çalıştırmalarda klasik YSA hücrelerinin derin öğrenme hücrelerine kıyasla düşük performans göstermektedir. Performanslara bakıldığında, RNN modelinin en iyi model olduğu, ardından GRU modellerinin geldiği sonucuna ulaşılır. Burada geliştirilen yaklaşım ile gerçekleştirilecek yatırım kararlarının daha yüksek getirili kazançlar sağlaması hedeflenmiştir. Finansal zaman serisi

uygulamaları için, geleneksel yöntemler olan ARIMA modelleri veya klasik makine öğrenmesi yöntemlerinden ziyade daha fazla derin öğrenme, derin takviyeli öğrenme, çoklu etmen sistemleri gibi lineer olmayan karmaşık ilişkilerin daha yüksek performans ile tahmin edildiği yöntemlere daha fazla başvurulmalıdır. Güncel çalışmalar ile teknik indikatörlere bakılarak yapılan tahmin çalışmaları popülerliğini korumaktadır. Bu çalışmanın ardından yapılacak çalışmada indikatör değerleri ile bir tahmin modeli düşünülmektedir. Ayrıca derin takviyeli öğrenme gibi dinamik programlama düşüncesi ile daha doğru tahmin çalışmaları yapılabileceği düşünülmektedir.

Araştırma ve Yayın Etiği Beyanı

Makalenin tüm süreçlerinde Yönetim ve Ekonomi Dergisi'nin araştırma ve yayın etiği ilkelerine uygun olarak hareket edilmiştir.

Yazarların Makaleye Katkı Oranları

Makalenin tamamı Dr. Caner Erden tarafından kaleme alınmıştır.

Çıkar Beyanı

Yazarın herhangi bir kişi ya da kuruluş ile çıkar çatışması yoktur.

KAYNAKÇA

- Aktas, O. U., Kryzanowski, L., & Zhang, J. (2022). Price-limit effectiveness: Evidence from the Borsa İstanbul (BIST). *International Journal of Islamic and Middle Eastern Finance and Management*, 15(3), 527-568. <https://doi.org/10.1108/IMEFM-04-2020-0151>
- Alaçahan, N. D., & Akarsu, Y. (2019). Döviz kuru riskinin Borsa İstanbul 100 endeksi üzerindeki etkisi zaman serisi analizi: Türkiye örneği. *Journal of Life Economics*, 6(2), 133-150. <https://doi.org/10.15637/jlecon.6.009>
- Aslan, B., & Erdur, R. C. (2020). Stock Market Prediction with Deep Learning Using Public Disclosure Platform Data. *2020 Innovations in Intelligent Systems and Applications Conference (ASYU)*, 1-5.
- Baykut, E., & Veysel, K. (2018). Borsa İstanbul pay endekslerinin volatilité yapısı: BİST-50 örneği (2007-2016 yılları). *Afyon Kocatepe Üniversitesi Sosyal Bilimler Dergisi*, 20(1), 279-303. <https://doi.org/10.5578/jss.66770>
- Belanche, D., Casaló, L. V., & Flavián, C. (2019). Artificial Intelligence in FinTech: Understanding robo-advisors adoption among customers. *Industrial Management & Data Systems*. <https://doi.org/10.1108/imds-08-2018-0368>
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and trends® in Machine Learning*, 2(1), 1-127. <https://doi.org/10.1561/2200000006>
- Bengio, Y., Lamblin, P., Popovici, D., & Larochelle, H. (2006). Greedy layer-wise training of deep networks. *Advances in neural information processing systems*, 19.
- Beverungen, A. (2019). *Algorithmic trading, artificial intelligence and the politics of cognition*. transcript.
- Bordes, A., Glorot, X., Weston, J., & Bengio, Y. (2012). Joint learning of words and meaning representations for open-text semantic parsing. *Artificial intelligence and statistics*, 127-135.
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control*. John Wiley & Sons.
- Chan, E. P. (2021). *Quantitative trading: How to build your own algorithmic trading business*. John Wiley & Sons.
- Chen, L., Qiao, Z., Wang, M., Wang, C., Du, R., & Stanley, H. E. (2018). Which artificial intelligence algorithm better predicts the Chinese stock market? *IEEE Access*, 6, 48625-48633. <https://doi.org/10.1109/ACCESS.2018.2859809>

- Chen, X.-W., & Lin, X. (2014). Big data deep learning: Challenges and perspectives. *IEEE access*, 2, 514-525. <https://doi.org/10.1109/ACCESS.2014.2325029>
- Chen, Y.-J., Chen, Y.-M., Tsao, S.-T., & Hsieh, S.-F. (2018). A novel technical analysis-based method for stock market forecasting. *Soft Computing*, 22(4), 1295-1312. <https://doi.org/10.1007/s00500-016-2417-2>
- Choi, D., & Lee, K. (2018). An artificial intelligence approach to financial fraud detection under IoT environment: A survey and implementation. *Security and Communication Networks*, 2018. <https://doi.org/10.1155/2018/5483472>
- Dahl, G. E., Yu, D., Deng, L., & Acero, A. (2011). Context-dependent pre-trained deep neural networks for large-vocabulary speech recognition. *IEEE Transactions on audio, speech, and language processing*, 20(1), 30-42. <https://doi.org/10.1109/TASL.2011.2134090>
- Dahl, G., Ranzato, M., Mohamed, A., & Hinton, G. E. (2010). Phone recognition with the mean-covariance restricted Boltzmann machine. *Advances in neural information processing systems*, 23.
- Day, M.-Y., & Lin, J.-T. (2019). Artificial intelligence for ETF market prediction and portfolio optimization. *Proceedings of the 2019 IEEE/ACM international conference on advances in social networks analysis and mining*, 1026-1033. <https://doi.org/10.1145/3341161.3344822>
- Deoras, A., & Kombrink, S. (2011). Empirical evaluation and combination of advanced language modeling techniques. *12th Annual Conference of the International Speech Communication Association*.
- Dey, R., & Salem, F. M. (2017). Gate-variants of gated recurrent unit (GRU) neural networks. *2017 IEEE 60th international midwest symposium on circuits and systems (MWSCAS)*, 1597-1600. <https://doi.org/10.1109/MWSCAS.2017.8053243>
- DiPietro, R., & Hager, G. D. (2020). Deep learning: RNNs and LSTM. İçinde *Handbook of medical image computing and computer assisted intervention* (ss. 503-519). Elsevier.
- Fang, B., & Zhang, P. (2016). Big data in finance. *Big data concepts, theories, and applications*, 391-412. https://doi.org/10.1007/978-3-319-27763-9_11
- Feng, W., & Han, C. (2015). A novel approach for trajectory feature representation and anomalous trajectory detection. *2015 18th International Conference on Information Fusion (Fusion)*, 1093-1099.
- Ferreira, F. G., Gandomi, A. H., & Cardoso, R. T. (2021). Artificial intelligence applied to stock market trading: A review. *IEEE Access*, 9, 30898-30917. <https://doi.org/10.1109/ACCESS.2021.3058133>
- Fontanills, G. A., & Gentile, T. (2002). *The volatility course* (C. 137). John Wiley & Sons.
- Gamboa, J. C. B. (2017). Deep learning for time-series analysis. *arXiv preprint arXiv:1701.01887*. <https://doi.org/10.48550/arXiv.1701.01887>
- Gasparin, A., Lukovic, S., & Alippi, C. (2022). Deep learning for time series forecasting: The electric load case. *CAAI Transactions on Intelligence Technology*, 7(1), 1-25. <https://doi.org/10.1049/cit2.12060>
- Giudici, P. (2018). Fintech risk management: A research challenge for artificial intelligence in finance. *Frontiers in Artificial Intelligence*, 1, 1. <https://doi.org/10.3389/frai.2018.00001>
- Goh, R. Y., Lee, L. S., Seow, H.-V., & Gopal, K. (2020). Hybrid harmony search-artificial intelligence models in credit scoring. *Entropy*, 22(9), 989. <https://doi.org/10.3390/e22090989>
- Gündüz, H., Yaslan, Y., & Çataltepe, Z. (2018). Stock market prediction with deep learning using financial news. *2018 26th Signal Processing and Communications Applications Conference (SIU)*, 1-4. <https://doi.org/10.1109/SIU.2018.8404616>
- Hasan, A., Kalipsız, O., & Akyokuş, S. (2020). Modeling traders' behavior with deep learning and machine learning methods: Evidence from BIST 100 index. *Complexity*, 2020. <https://doi.org/10.1155/2020/8285149>
- Heaton, J. B., Polson, N. G., & Witte, J. H. (2016). Deep learning in finance. *arXiv preprint arXiv:1602.06561*. <https://doi.org/10.48550/arXiv.1602.06561>
- Hinton, G. E., Osindero, S., & Teh, Y.-W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554. <https://doi.org/10.1162/neco.2006.18.7.1527>

- Hipel, K. W., McLeod, A. I., & Lennox, W. C. (1977). Advances in Box-Jenkins modeling: 1. Model construction. *Water Resources Research*, 13(3), 567-575. <https://doi.org/10.1029/WR013i003p00567>
- Hu, Z., Zhao, Y., & Khushi, M. (2021). A survey of forex and stock price prediction using deep learning. *Applied System Innovation*, 4(1), 9. <https://doi.org/10.3390/asi4010009>
- Hyndman, R. J. (2020). A brief history of forecasting competitions. *International Journal of Forecasting*, 36(1), 7-14. <https://doi.org/10.1016/j.ijforecast.2019.03.015>
- Ince, H., & Aktan, B. (2009). A comparison of data mining techniques for credit scoring in banking: A managerial perspective. *Journal of Business Economics and Management*, 10(3), 233-240. <https://doi.org/10.3846/1611-1699.2009.10.233-240>
- Jakšič, M., & Marinč, M. (2019). Relationship banking and information technology: The role of artificial intelligence and FinTech. *Risk Management*, 21(1), 1-18. <https://doi.org/10.1057/s41283-018-0039-y>
- Ji, X., Wang, J., & Yan, Z. (2021). A stock price prediction method based on deep learning technology. *International Journal of Crowd Science*, 5(1), 55-72. <https://doi.org/10.1108/IJCS-05-2020-0012>
- Khisamova, Z. I., Begishev, I. R., & Sidorenko, E. L. (2019). Artificial intelligence and problems of ensuring cyber security. *International Journal of Cyber Criminology*, 13(2), 564-577.
- Kihoro, J., Otieno, R. O., & Wafula, C. (2004). *Seasonal time series forecasting: A comparative study of ARIMA and ANN models*.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90. <https://doi.org/10.1145/3065386>
- Kuremoto, T., Kimura, S., Kobayashi, K., & Obayashi, M. (2014). Time series forecasting using a deep belief network with restricted Boltzmann machines. *Neurocomputing*, 137, 47-56. <https://doi.org/10.1016/j.neucom.2013.03.047>
- Kurt, F. E., & Senal, S. (2018). Borsa İstanbul'da Kote Bireysel Emeklilik, Hayat Ve Hayat-Dışı Sigorta Şirketlerinin Hisse Senedi Fiyat Tahmininde Box-Jenkins Yöntemi. *Muhasebe ve Finansman Dergisi*, 80, 233-252. <https://doi.org/10.25095/mufad.465942>
- Längkvist, M. (2014). *Modeling time-series with deep networks* [PhD Thesis]. Örebro university.
- Li, J. (2018). Cyber security meets artificial intelligence: A survey. *Frontiers of Information Technology & Electronic Engineering*, 19(12), 1462-1474. <https://doi.org/10.1631/FITEE.1800573>
- Li, Y., & Pan, Y. (2022). A novel ensemble deep learning model for stock prediction based on stock prices and news. *International Journal of Data Science and Analytics*, 1-11.
- Mashadihasanlı, T. (2022). Stock Market Price Forecasting Using the Arima Model: An Application to Istanbul, Türkiye. *Journal of Economic Policy Researches*, 9(2), 439-454.
- Mehrmolaei, S., & Keyvanpour, M. R. (2016). Time series forecasting using improved ARIMA. *2016 Artificial Intelligence and Robotics (IRANOPEN)*, 92-97. <https://doi.org/10.1109/RIOS.2016.7529496>
- Mushtaq, R. (2011). *Augmented dickey fuller test*. <https://doi.org/10.2139/ssrn.1911068>
- Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Seliya, N., Wald, R., & Muharemagic, E. (2015). Deep learning applications and challenges in big data analytics. *Journal of big data*, 2(1), 1-21. <https://doi.org/10.1186/s40537-014-0007-7>
- Navale, G. S., Dudhwala, N., Jadhav, K., Gabda, P., & Vihangam, B. K. (2016). Prediction of stock market using data mining and artificial intelligence. *International Journal of Computer Applications*, 134(12), 9-11. <https://doi.org/10.5120/ijca2016907635>
- Ngai, E. W., Hu, Y., Wong, Y. H., Chen, Y., & Sun, X. (2011). The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature. *Decision support systems*, 50(3), 559-569. <https://doi.org/10.1016/j.dss.2010.08.006>
- Peter, D., & Silvia, P. (2012). ARIMA vs. ARIMAX—which approach is better to analyze and forecast macroeconomic time series. *Proceedings of 30th international conference mathematical methods in economics*, 2, 136-140.

- Qiu, X., Zhang, L., Ren, Y., Suganthan, P. N., & Amaratunga, G. (2014). Ensemble deep learning for regression and time series forecasting. *2014 IEEE symposium on computational intelligence in ensemble learning (CIEL)*, 1-6. <https://doi.org/10.1109/CIEL.2014.7015739>
- Santur, Y. (2020). Deep learning based regression approach for algorithmic stock trading: A case study of the Bist30. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 10(4), 1195-1211.
- Sewell, M. (2011). Characterization of financial time series. *Rn*, 11(01), 01.
- Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied soft computing*, 90, 106181. <https://doi.org/10.1016/j.asoc.2020.106181>
- Sherstinsky, A. (2020). Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404, 132306. <https://doi.org/10.1016/j.physd.2019.132306>
- Staudemeyer, R. C., & Morris, E. R. (2019). Understanding LSTM—a tutorial into long short-term memory recurrent neural networks. *arXiv preprint arXiv:1909.09586*.
- Sun, Y., Shi, Y., & Zhang, Z. (2019). Finance big data: Management, analysis, and applications. İçinde *International Journal of Electronic Commerce* (C. 23, Sayı 1, ss. 9-11). Taylor & Francis.
- Tekin, S., & Çanakoğlu, E. (2019). Analysis of price models in istanbul stock exchange. *2019 27th Signal Processing and Communications Applications Conference (SIU)*, 1-4.
- Turner, J. T. (2014). *Time series analysis using deep feed forward neural networks*. University of Maryland, Baltimore County.
- Vergil, H., & Ozkan, F. (2007). Purchasing Power Parity and ARIMA Models in Forecasting Exchange Rates: The Case of Turkey. *Istanbul Stock Exchange Review*, 9(35), 37-50.
- Wangdi, K., Singhasivanon, P., Silawan, T., Lawpoolsri, S., White, N. J., & Kaewkungwal, J. (2010). Development of temporal modelling for forecasting and prediction of malaria infections using time-series and ARIMAX analyses: A case study in endemic districts of Bhutan. *Malaria Journal*, 9(1), 1-9. <https://doi.org/10.1186/1475-2875-9-251>
- Xie, M. (2019). Development of artificial intelligence and effects on financial system. *Journal of Physics: Conference Series*, 1187(3), 032084. <https://doi.org/10.1088/1742-6596/1187/3/032084>
- Yalçın Kayacan, E. (2019). *Deep learning for time series forecasting*.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)
- Zhang, Q., Yang, L. T., Chen, Z., & Li, P. (2018). A survey on deep learning for big data. *Information Fusion*, 42, 146-157. <https://doi.org/10.1016/j.inffus.2017.10.006>
- Zheng, Y., Liu, Q., Chen, E., Ge, Y., & Zhao, J. L. (2014). Time series classification using multi-channels deep convolutional neural networks. *International conference on web-age information management*, 298-310.

SUMMARY

In stock markets, companies share stock to raise funds and capital. Financing transactions arise through stock trading strategies. Individual and institutional investors are interested in buying and selling stocks that maximize their returns. At this point, trading strategies for stocks require to determine the right time and price. Thus, developing a successful strategy should contain effective and efficient use of time-series models and current high-end artificial intelligence technologies such as deep learning. Although time-series models such as ARIMA have been frequently used in recent decades, machine learning methods and deep learning have also offered a powerful alternative to ARIMA time-series models. Therefore, comparing ARIMA models and deep learning methods has become

popular. The main purpose of this study is to compare the performance of different ARIMA models and deep learning methods on a real sample dataset.

This study proposed ARIMA models for time series analysis on the data of a Borsa İstanbul stock (EREĞLİ DEMİR VE ÇELİK FABRİKALARI T.A.Ş.). The dataset consists of 673 days, from '2020-01-01' to '2022-09-09, ' taken from the Yahoo Finance website. The dataset is divided into training (2020-01-02 to 2021-11-19) and testing (2021-11-22 to 2022-09-09) to make performance benchmarks. Different ARIMA models were tested, and an ARIMA model with a low AIC score and prediction model development were performed. The ARIMA model parameters selected by using the AIC scores were determined as (0,1,0). The second part of the study focuses on deep learning algorithms. Deep learning algorithms offer special structures for studies on sequential data, such as image processing, voice recognition, natural language processing, and time-series analysis.

Time series analysis consists of highly correlated data. At the same time, nonlinear data with complex relationships are affected by many dimensions. Therefore, working with different combinations of deep learning algorithms is necessary to achieve a better learning performance. In this study, comparisons were made between long short-term memory (LSTM), recurrent neural networks (RNN), and gated recurrent units (GRU) deep learning algorithms, which are considered alternatives to the ARIMA model. A time series must be reframed using a time window to make it suitable for deep learning. In other words, the time lag value is an important parameter in deep learning when time series are studied. Accordingly, in this study, an appropriate time lag parameter was searched, and the results were shared to improve training performance. Better performance was achieved by training the deep learning algorithms with different parameters. When the results are compared with the deep learning methods of the ARIMA model, it was clearly concluded that the best result was obtained with deep learning methods. As a result, it can be stated that RNN gives the best performance with 0.5860 MAE, 0.6175 MSE, 0.9324 R2, and the GRU gives the second-best performance with 0.6103 MAE, 0.6701 MSE, 0.9266 R2.