



Araştırma Makalesi

## BIST 100 Firmalarının Hisse Senetlerinin Zaman Serisi Analitiği Hüseyin AKKAŞ<sup>1</sup>, Hamza EROL<sup>2</sup>

<sup>1</sup>Mersin Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği, Mersin, Türkiye

<sup>2</sup>Mersin Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, Mersin, Türkiye

### Anahtar Kelimeler:

Büyük Veri  
Derin Öğrenme  
BIST 100  
GRU  
RNN

### ÖZ

Borsa, günümüzde alınıp satılabilir menkul kıymetler, döviz, vadeli işlemler vb. içeren oldukça büyük bir piyasadır. Yatırımcılar, kendilerine uygun yatırım araçlarını seçerek bu pazara yatırım yapabilmektedirler. Fakat borsa, günümüzde birçok değişkene bağlı, oldukça hareketli bir pazardır. Faiz oranı, işsizlik, enflasyon oranı gibi etkenler borsayı etkileyen faktörlerden sadece bazılarıdır. Bu kadar çok veriyi ve etkeni içeren pazarda gerçekleşen bu hareketler de oldukça hızlı gelişmektedir. Yatırımcının bu hareketlere yetişmesi de zaman zaman zorlaşmaktadır. Dolayısıyla kafa karışıklıkları ve tereddütler meydana gelebilmektedir.

Genel olarak derin öğrenme mimarileri ve makine öğrenmesi yöntemleri günümüzde büyük veri analitiği konusunda oldukça başarılı sonuçlar vermektedir. Bu çalışmada da derin öğrenme mimarilerinden Kapılı Tekrarlayan Birimler (Gated Recurrent Units) ve Tekrarlayan Sinir Ağları (Recurrent Neural Networks) kullanılarak borsada işlem gören hisse senetlerinin zaman serisi analitiği gerçekleştirilmiş ve sonuçlar değerlendirilmiştir. Çalışmanın amacı bir yatırım tavsiyesi sunmak değil, kullanılan yöntemlerin büyük veri analitiğindeki başarısını test etmektir.

Bu çalışmada, BIST 100 içinde en çok işlem gören 3 hisse senetlerinden ODAS, YKBNK ve KARSN hisse senetlerinin geçmiş 7 yıllık verilerinin analitiği gerçekleştirilmiş ve değer hareketleri tahmin edilmeye çalışılmıştır.

## Time Series Analytics of BIST 100 Companies' Stocks

### Keywords:

Big Data  
Deep Learning  
BIST 100  
GRU  
RNN

### ABSTRACT

Today, the stock market is a fairly large market which includes tradable instruments, currency, futures etc. Investors can invest in this market by choosing the investment instruments suitable for them. But the stock market is a highly volatile market, dependent on many variables today. Factors such as bank rate, unemployment, inflation rate are just some of the factors that affect the stock market. These movements, which take place in the market, which contains so much data and factors, are also occurring quite rapidly. It is difficult for the investor to catch up with these movements sometimes. Therefore confusions and hesitations may occur.

In general, deep learning architectures and machine learning methods give very successful results in big data analytics lately. In this study, time series analytics of stocks traded in the stock market were performed by using Gated Recurrent Units and Recurrent Neural Networks, some of the deep learning architectures, and the results were evaluated. The purpose of the study is not to provide an investment recommendation, but to test the success of these architectures in big data analytics. In this study, the past 7 years data of ODAS, YKBNK and KARSN stocks, which are the 3 most traded stocks in BIST 100, were analyzed and their value movements were tried to be estimated.

### \*Sorumlu Yazar

[huseyin.akkas@agu.edu.tr](mailto:huseyin.akkas@agu.edu.tr) ORCID ID 0000-0002-6367-7823

[herol@mersin.edu.tr](mailto:herol@mersin.edu.tr) ORCID ID 0000-0001-8983-4797

e-ISSN: XXXXXXXXXXXX

Geliş Tarihi: Gün/Ay/Yıl; Kabul Tarihi: Gün/Ay/Yıl

Bilgisayar Bilimleri ve Teknolojileri Dergisi

## 1. GİRİŞ

Borsa, içinde hisse senetleri, dövizler ve menkul kıymetler gibi daha birçok ürünü barındıran ama aynı zamanda birçok faktörden etkilenen ve anlık olarak değişebilen oldukça büyük ve hareketli bir pazardır. Yatırımcıların yatırım araçlarını seçip yatırımlarını gerçekleştirmeden önce kapsamlı bir araştırma gerçekleştirmeleri ve bu araştırmalara göre hareket etmeleri gerekmektedir. Fakat yatırımcıların insan gözü ile bu kadar hızlı değişen bir büyük veriyi analiz edebilmesi oldukça zordur. Dolayısıyla yatırımcılar zaman zaman kar etme amacıyla gerçekleştirdikleri yatırımlarından zarar edebilmektedir. Bu da yatırımcılarda, yatırımlarını gerçekleştirmeden önce kafa karışıklıkları ve tereddütlerin oluşmasına sebep olabilmektedir.

Borsa içindeki ürünler göz önüne alındığında pazardaki tüm verilerin bir büyük veri oluşturacağı açıktır. Yatırımcıların tek başına bu kadar büyük ve hareketli geçmiş verileri analiz edip buna göre karar verebilmesi oldukça zordur. Hisse senedi zaman serisi değer tahminleri, son yıllarda en zorlu ve en önemli problemlerden biri olmuştur ve derin öğrenmenin en gözde uygulama alanlarından biri haline gelmiştir. Hisse senetlerinin değerlerini etkileyen birçok faktör bulunuyor olması bu konuda etkili olmuştur. Hisse senedi değer tahminlemesi geçmiş verilere bakılarak gerçekleştirilmektedir. Tahminleme uygulaması hem şirketler, hem de akademik çalışmalar için oldukça önem arz etmektedir.

Hisse senedi değerlerini etkileyen birçok faktör bulunsu ve değerlerde ani değişimler meydana gelebilse de bu değişimlerin tamamen rastgele gerçekleşmediği bilinmektedir. Uzmanlar, bu değişimlerin, geçmiş veriler aracılığı ile tahmin edilebildiğini belirtmektedir (Tekin ve Çanakoğlu, 2019). Ön bilgiye ihtiyaç duymadan ham veriden özellik çıkarabilmesi derin öğrenme yöntemlerini hisse senedi değer tahminleri için çekici hale getirmiştir (Chong vd., 2017). Derin öğrenme yöntemleri, son zamanlarda büyük veri analitiğinde oldukça başarılı sonuçlar vermektedir (Sakarya ve Yılmaz, 2019). Bu çalışmada da, derin öğrenme yöntemlerinden Kapılı Tekrarlayan Birimler ve Tekrarlayan Sinir Ağları kullanılarak Yahoo Finance üzerinden elde edilen BIST 100 şirketlerinden olan Yapı Kredi, Odaş ve Karsan firmalarına ait son 7 yıllık, büyük veri olarak nitelendirilebilecek veri seti analiz edilmeye çalışılmıştır. Bu firmaların seçilme sebebi BIST 100'de en çok işlem gören Bu veri setleri, zaman serisi analizine uygun veri setleridir. Analizler, Google Colab ortamında Python dilinin 3.7. versiyonu kullanılarak gerçekleştirilmiştir. Çalışmada hisse senetlerinin hareketleri, Kapılı Tekrarlayan Birimler ve Tekrarlayan Sinir Ağları derin öğrenme yöntemleri ile tahmin edilmeye çalışılmıştır. Daha sonra, kullanılan yöntemlerin performans sonuçları karşılaştırılmıştır. Çalışmanın

amacı yatırım tavsiyesi vermek değil, derin öğrenme ve makine öğrenmesi yöntemlerinin büyük veri analitiği üzerindeki başarısını test etmek ve elde edilen sonuçları ortalama hata karesi değerlerine göre karşılaştırmaktır.

## 2. YÖNTEM

Çalışmada kullanılan materyal ve yöntemler bu bölümde açıklanmıştır.

### 2.1. Veri Setleri

Bu tez çalışmasında kullanılan veri setleri Yahoo Finance üzerinden elde edilmiş BIST 100'de en çok işlem gören 3 firmanın 7 yıllık veri setleridir. BIST 100, Borsa İstanbul'a ait en çok işlem gören 100 hisse senedini ifade etmektedir. Bu veri setlerindeki özellikler ise "Date" (tarih), "Open" (açılış), "High" (en yüksek), "Low" (en düşük), "Close" (kapanış), "Adjusted Close" (ayarlanmış kapanış) ve "Volume" (hacim)'dir. Bu özelliklerden Date, hisse senedinin verilerinin alındığı tarihi; High, hisse senedinin o gün içindeki en yüksek değerini; Low, hisse senedinin o gün içindeki en düşük değerini; Close, o günkü kapanış değerini; Adjusted Close, o gün gerekli güncellemeler yapıldıktan sonraki kapanış değerini; Volume ise o günkü alış ve satış değerlerinin parasal değerini ifade etmektedir.

Bu çalışma için kullanılan veri setlerinin tarih aralığı ise 01.01.2014-31.12.2020 tarih aralığıdır. Yaklaşık 7 yıla ait bu veri setleri büyük veri ve zaman serisi verisi olarak nitelendirilebilmektedir.

### 2.2. Cihaz Özellikleri ve Yazılımlar

Bu çalışmada deneylerin gerçekleştirildiği cihazda Intel (R) Core (TM) i3-4030U CPU, 4 GB RAM VE 64 bit işletim sistemi bulunmaktadır. Kullanılan programlama dili Python 3.7. versiyonudur. Deneyler ise Google Colab ortamında gerçekleştirilmiştir.

### 2.3. Yöntemler

Bu çalışmada, borsada işlem gören hisse senetlerinin zaman serisi analitiği, derin öğrenme mimarilerinden Kapılı Tekrarlayan Birimler ve Tekrarlayan Sinir Ağları modelleri kullanılarak gerçekleştirilmiştir.


### 2.4. Derin Öğrenme

Derin öğrenme, makine öğrenmesinin bir alt alanıdır (Doğan ve Türkoğlu, 2019). Temel olarak üç veya daha fazla katmandan oluşan bir sinir ağı olarak tanımlanmaktadır. Bu yapay sinir ağları, çok büyük boyutlu verilerden öğrenmeyi ve eşleşmekten çok uzak olsa da insan beyni gibi çalışmayı

amaçlamaktadır. Tek katmanlı bir sinir ağı bile yaklaşık tahminler gerçekleştirebilirken eklenmiş diğer gizli katmanlar sonucu optimize etmeye ve doğruluk için hassaslaştırmaya fayda sağlamaktadır. Derin öğrenme, otomasyonları geliştirebilen, analitik ve fiziksel görevleri, insan müdahalesi olmadan yerine getirebilen birçok yapay zeka uygulamasını ve hizmetini yönlendirebilmektedir. Derin öğrenme teknolojisi; dijital asistanlar, ses etkileşimli uzaktan kumandalar, kredi kartı sahtekarlığı tespiti gibi günlük hayatta kullanılan birçok ürünün ve servisin yanında sürücüsüz arabalar gibi gelişmekte olan teknolojilerin de arka planında bulunmaktadır (URL-1).

#### 2.4.1. Tekrarlayan Sinir Ağları

Tekrarlayan sinir ağları, ardışık verileri veya zaman serisi verilerini kullanan sinir ağı yapısıdır. Çalışma mantığı, önceki çıktılarını girdi olarak kullanılmasına dayanmaktadır (URL-2). Bu derin öğrenme algoritmaları, dil çevirisi, doğal dil işleme, konuşma tanıma ve görsel açıklaması gibi sıralı veya zamansal sorunlar için yaygın olarak kullanılmaktadır. Siri, sesli arama ve Google çeviri gibi popüler uygulamalara dahil edilmektedir. İleri beslemeli ve evrişimsel sinir ağları gibi tekrarlayan sinir ağları da öğrenmek için eğitim verilerini kullanmaktadır. Mevcut girdi ve çıktıyı etkilemek için önceki girdilerden bilgi aldıkları için hafızaları ile ayırt edilmektedirler. Zaman serisi olayları ile ilgili hafızaları buna yardımcı olmaktadır (Staudemeyer ve Morris, 2019). Geleneksel derin sinir ağları, girdilerin ve çıktılarının birbirinden bağımsız olduğunu varsayarken, tekrarlayan sinir ağlarının çıktısı, dizi içerisindeki önceki öğelere bağlıdır. Gelecekteki olaylar, belirli bir dizinin çıktısının belirlenmesine de yardımcı olurken, tek yönlü tekrarlayan sinir ağları, bu olayları tahminlerinde açıklayamamaktadır (URL-3).



**Şekil 1.** Tekrarlayan Sinir Ağları (Sol) ve İleri Beslemeli Sinir Ağları (Sağ) Yapılarının Karşılaştırılması

Bu çalışmanın tekrarlayan sinir ağları deneylerinde en iyi sonucu veren parametrelerin şu şekilde olduğu gözlemlenmiştir: 4 girdi, 200 nöron, 4 çıktı ve 2 katman. Öğrenme oranı=0.001, grup boyutu=50, devir sayısı=100. İyileştirici olarak Adam Optimizer, hata ölçümü için ise MSE kullanılmıştır.


#### 2.4.2. Kapılı Tekrarlayan Birimler

Kapılı tekrarlayan birimler, Cho ve arkadaşları tarafından 2014 yılında, standart tekrarlayan sinir ağları ile birlikte gelen yok olan gradyan problemini çözmek amacı ile geliştirilmiştir. Kapılı tekrarlayan birimler ayrıca uzun kısa süreli bellek yapısının bir çeşidi olarak da değerlendirilebilmektedir (Kılınc ve Öztürk, 2022). Çünkü ikisi de benzer olarak tasarlanmış ve bazı durumlarda eşit derecede mükemmel sonuçlar üretebilmektedirler. Kapılı tekrarlayan birimlerin standart tekrarlayan sinir ağlarından temel farkı ise önceki veya o anki gizli durumları ve girdileri unutabilme veya üzerinde durabilme kapasitesine sahip olmasıdır (URL-4).

Kapılı tekrarlayan birimler birçok çalışmada tahmin uygulamalarında kullanılmaktadır. Bu çalışmalardan birisi H. Ç. Kılınc ve arkadaşlarının 2022’de gerçekleştirdiği çalışmadır. Bu çalışmada, kapılı tekrarlayan birimler, su kaynaklarının akış verilerini tahmin etmek için Gri Kurt algoritmasına entegre edilmiştir (Kılınc ve Öztürk, 2022).

Aynı zamanda kapılı tekrarlayan birimler, borsa tahmini çalışmalarında da kullanılan en popüler algoritmalarından birisidir. Bu çalışmalara örnek olarak da G. Şişmanoğlu ve arkadaşlarının 2020’de gerçekleştirdiği çalışma örnek olarak verilebilir. Bu çalışmada Şişmanoğlu ve arkadaşları, New York Borsasının hisse senedi zaman serisi değerlerini kullanmışlardır (Şişmanoğlu vd., 2020).

Kapılı tekrarlayan birimler için standart tekrarlayan sinir ağlarının geliştirilmiş versiyonu denenebilir. Standart tekrarlayan sinir ağlarının yok olan gradyan problemini çözmek için kapılı tekrarlayan birimler, sözde güncelleme kapısı ve sıfırlama kapısı yapılarını kullanmaktadır. Kısaca bu iki yapı, hangi bilginin çıktıya taşınacağına karar veren iki vektördür. Bu iki vektörü özel kılan şey, çok uzun zaman önceki bilgiyi, zamanla yok olmadan ya da tahminle ilgisiz verileri silmeden tutabilmeleri için eğitilebilmeleridir (URL-5).



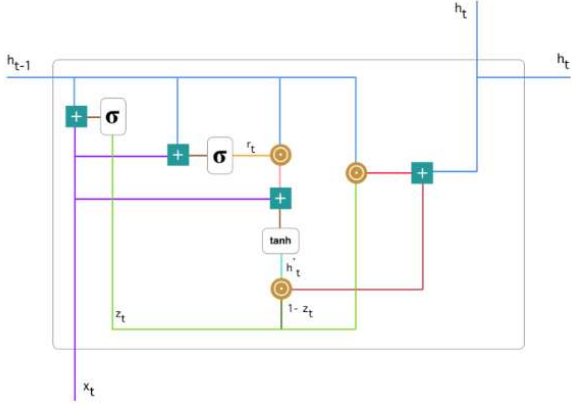
**Şekil 2.** Kapılı Tekrarlayan Birimler ile Tekrarlayan Sinir Ağı

Bu çalışmanın kapılı tekrarlayan birimler deneylerinde, en iyi sonucu veren parametrelerin şu şekilde olduğu gözlemlenmiştir: 4 girdi, 200 nöron, 4 çıktı ve 2 katman. Öğrenme oranı=0.001, grup


boyutu=50, devir sayısı=50. İyileştirici olarak Adam Optimizer, hata ölçümü için ise MSE kullanılmıştır.

### 3. BULGULAR

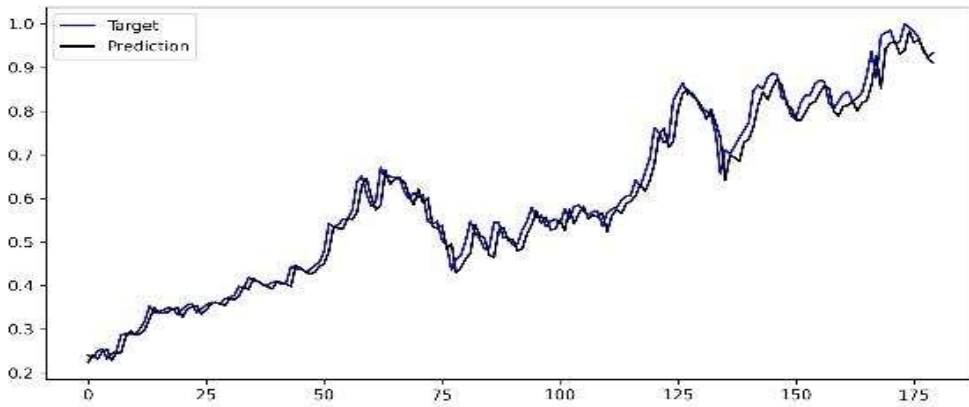
Çalışmada gerçekleştirilen deneylerin sonuçları bu bölümde gösterilmiştir.




Şekil 3. Kapılı Tekrarlayan Birim



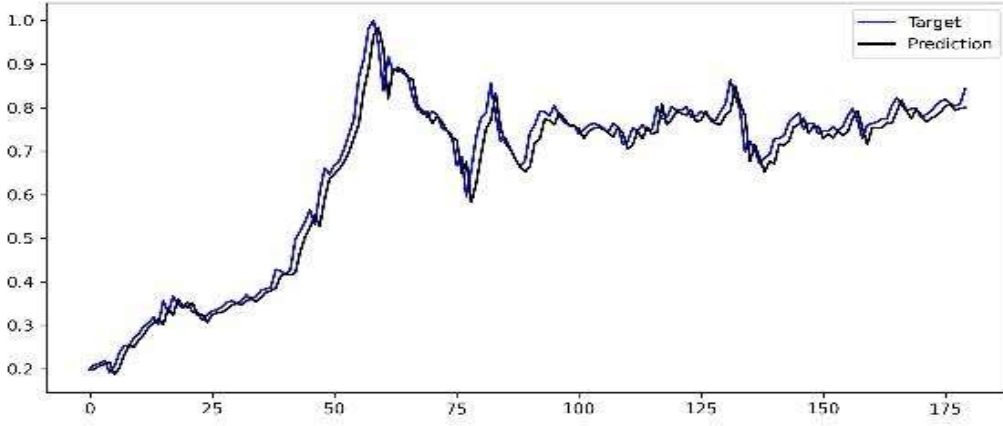
Şekil 4. KARSN.IS Veri Seti Üzerindeki Tekrarlayan Sinir Ağları Deneyinin Sonucu



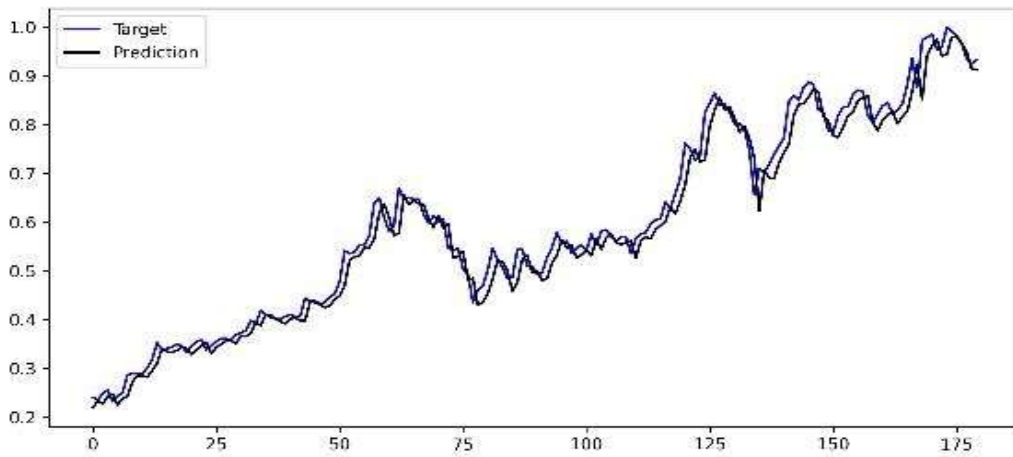
Şekil 5. ODAS.IS Veri Seti Üzerindeki Tekrarlayan Sinir Ağları Deneyinin Sonucu




Şekil 6. YKBNK.IS Veri Seti Üzerindeki Tekrarlayan Sinir Ağları Deneyinin Sonucu



Şekil 7. KARSN.IS Veri Seti Üzerindeki Kapılı Tekrarlayan Birimler Deneyinin Sonucu



Şekil 8. ODAS.IS Veri Seti Üzerindeki Kapılı Tekrarlayan Birimler Deneyinin Sonucu



**Şekil 9.** YKBNK.IS Veri Seti Üzerindeki Kapılı Tekrarlayan Birimler Deneyinin Sonucu

**Tablo 1.** Tekrarlayan Sinir Ağları Mimarisi için Deney Sonuçları

Firma	RNN		
	KARSN	ODAS	YKBNK
a	0.000250	0.000284	0.000755
MSE	0.000250	0.000284	0.000755

**Tablo 2.** Kapılı Tekrarlayan Birimler Mimarisi için Deney Sonuçları

Firma	GRU		
	KARSN	ODAS	YKBNK
a	0.000252	0.000294	0.000668
MSE	0.000252	0.000294	0.000668

Şekil 4, Şekil 5, Şekil 6, Şekil 7, Şekil 8 ve Şekil 9'da görülen grafikler hisse senetlerinin, kullanılan algoritmalarla tahmin edilen değerlerini ve gerçek değerlerini göstermektedir. Yatay eksen, zaman dilimini; dikey eksen ise hisse senedi değerlerinin ölçeğini ifade etmektedir. Grafiklerde siyah çizgi, tahmin değerlerini; mavi çizgi, gerçek değeri temsil etmektedir. Çizgilerin birbirine yakın ve hatta zaman zaman üst üste olması, tahminin ne kadar başarılı olduğunu göstermektedir. Ani ve büyük değişimlerde bile kullanılan modellerin tahminleri, gerçek değerler ile yakınlığını korumaktadır. En başarılı sonuçlar hem grafiklerden hem de tablolardan fark edildiği üzere KARSN.IS veri seti üzerindeki deneylerden

elde edilmiştir. Daha sonra ODAS.IS veri seti üzerinde gerçekleştirilen deneyler başarı anlamında KARSN.IS veri seti üzerinde gerçekleştirilen deneyleri takip etmektedir. Gerçek değer ile tahmin değerinin en belirgin farklı olduğu deney ise YKBNK.IS veri seti üzerinde gerçekleştirilen deneyler olmuştur. Tablo 1 ve Tablo 2'deki MSE değerlerinin ne kadar küçük olması, yöntemlerin başarısını bir kez daha göstermektedir.

#### 4. SONUÇLAR

Farklı veri setleri üzerinde farklı yöntemler ile gerçekleştirilen deneylerin sonucunda, MSE değerleri incelendiğinde oldukça başarılı sonuçlara ulaşılmıştır. Tekrarlayan Sinir Ağları, iki veri seti üzerinde Kapılı Tekrarlayan Birimler yöntemine göre daha başarılı sonuç verirken diğer veri seti üzerinde Kapılı Tekrarlayan Birimler yöntemi daha başarılı bulunmuştur. Bu farklılıklar da yöntemlerin bazı farklılıklarından ve veri setlerinin karmaşıklıklarının farklılıklarından kaynaklanabilmektedir. Kapılı Tekrarlayan Birimlerin Tekrarlayan Sinir Ağlarından farkı, güncelleme ve sıfırlama kapılarını içermesidir. Bu yapısal farklılıklar, performans farklarına sebep olan etkenlerden birisidir.

Kapılı Tekrarlayan Birimler, küçük veri setlerinde daha başarılı sonuçlar verebilmektedir (URL-6). Bu çalışmada kullanılan veri setlerinin boyutu büyük olduğu için ise Tekrarlayan Sinir Ağları, daha başarılı sonuçlar göstermiştir. YKBNK veri setinde ise farklı bir sonuç elde edilmesinin sebebi, karmaşıklığının diğer veri setlerinden daha farklı olmasıdır.

Sonuç olarak derin öğrenme, büyük veri analitiği konusunda oldukça başarılı bulunmuştur.

Bu çalışmanın literatüre katkıları ise şu şekilde özetlenebilir: İlk defa KARSN.IS, ODAS.IS ve YKBNK.IS veri setleri üzerinde kapılı tekrarlayan birimler ve tekrarlayan sinir ağları yöntemlerinin denenmesi ve sonuçlarının karşılaştırılması, deney sonuçlarında düşük MSE değerleri ile başarılı sonuçlar elde edilmesi, kullanılan algoritmaların hisse senedi değer tahmininde başarılarını bir kez daha gözler önüne sermesi.

Farklı derin öğrenme yöntemleri birleştirilerek ve veri miktarı artırılarak performans iyileştirmeleri gerçekleştirilebilir.

### BİLGİLENDİRME/TEŞEKKÜR

Bu çalışmanın hazırlanmasında değerli bilgileri ile bana yol gösteren, hiçbir zaman desteğini esirgemeyen saygıdeğer danışman hocam Prof. Dr. Hamza EROL'a, her zaman yanımda olan, beni destekleyen aileme ve arkadaşlarıma sonsuz teşekkürlerimi sunarım.

### KAYNAKÇA

Tekin, S., ve Çanakoğlu, E. (2019). Analysis of price models in Istanbul stock exchange. *Proceedings of The 27th Signal Processing and Communications Applications Conference (SIU)*, 1-4.

Chong, E., Han, C. & Park, F. C. (2017). Deep learning networks for stock market analysis and prediction: methodology, data representations and case studies. *Expert Systems with Applications*, 2017.

Sakarya, Ş., & Yılmaz, Ü. (2019). Derin Öğrenme Mimarisi Kullanarak BİST30 İndeksinin Tahmini. *European Journal of Educational and Social Sciences*, 2019.

Doğan, F. & Türkoğlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *DÜMF Mühendislik Dergisi*, 2019.

URL-1: <https://www.ibm.com/cloud/learn/deep-learning>  
[Erişim Tarihi: 29.05.2022]

URL-2: <https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-recurrent-neural-networks>  
[Erişim Tarihi: 15.12.2022]

Staudemeyer, R., C. & Morris, E., R. (2019). Understanding LSTM – a tutorial into Long Short-Term Memory Recurrent Neural Networks. *arXiv*. 2019.

URL-3: <https://www.ibm.com/cloud/learn/recurrent-neural-networks>  
[Erişim Tarihi: 08.06.2022]

Kılınç, H., Ç. & Öztürk, Y. (2022). Hibrit Gri Kurt Optimizasyonu ile Geçitli Tekrarlayan Birim Modeli Kullanılarak Zaman Serisi Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, 2022.

URL-4: <https://wandb.ai/renaudlesperance/INF8225%20-%20TP3%20-%20Final%20Run/reports/RNN-vs-GRU--VmlldzoxODEwNjg5>  
[Erişim Tarihi: 15.12.2022]

Şişmanoğlu, G., Koçer, F., Önde M., A. & Şahingöz, Ö., K. (2020). Derin Öğrenme Yöntemleri ile Borsada Fiyat Tahmini. *BEÜ Fen Bilimleri Dergisi BEU Journal of Science* 2020.

URL-5: <https://towardsdatascience.com/understanding-gru-networks-2ef37df6c9be>  
[Erişim Tarihi: 10.06.2022]

URL-6: <https://www.projectpro.io/recipes/what-is-difference-between-gru-and-lstm-explain-with-example>  
[Erişim Tarihi: 21.07.2022]