

T.C.
SELÇUK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

İKTİSAT ANABİLİM DALI
İKTİSAT BİLİM DALI

YAPAY SİNİR AĞLARI İLE BORSA ENDEKSİ TAHMİNİ:
GANA BORSASI ÜZERİNE BİR UYGULAMA.

ABDUL-RAZAK BAWA YUSSIF

YÜKSEK LİSANS TEZİ

Danışman
Prof. Dr. Zeynep KARAÇOR

Konya 2020



T. C.
SELÇUK ÜNİVERSİTESİ
Sosyal Bilimler Enstitüsü Müdürlüğü



Bilimsel Etik Sayfası

| | | |
|------------|------------------------|--|
| Öğrencinin | Adı Soyadı | ABDUL-RAZAK BAWA YUSSIF |
| | Numarası | 174226001022 |
| | Ana Bilim / Bilim Dalı | İKTİSAT/İKTİSAT |
| | Programı | Tezli Yüksek Lisans <input checked="" type="checkbox"/> Doktora <input type="checkbox"/> |
| | Tezin Adı | YAPAY SİNİR AĞLARI İLE BORSA ENDEKSİ TAHMİNİ: GANA BORSASI ÜZERİNE BİR UYGULAMA. |

Bu tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel etiğe ve akademik kurallara özenle riayet edildiğini, tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada başkalarının eserlerinden yararlanılması durumunda bilimsel kurallara uygun olarak atıf yapıldığını bildiririm.

Öğrencinin imzası

TEŞEKKÜR

Yüksek lisans programımın sonunu belirleyen bu çalışmanın tamamlanmasının ardından, Türkiye'deki üniversite eğitimim boyunca bana destekleyen ve yardım eden insanlar birkaç kelimeyle teşekkür etmek isterim.

Öncelikle, bu tez çalışmam boyunca özen ve titizlikle takip eden, her zaman müsait gösteren, bilimsel birikimlerini benimle paylaşan Yüksek Lisan Danışmanım, Sam Prof. Dr. Zeynep Karaçor şükranlarımı sunarım.

Selçuk üniversitesinde ekonomi alanındaki araştırma ve bireysel araştırmalara bana yol gösteren değerli hocalarım Sayın Prof. Dr. Fatih Mangır, Sayın Prof. Savaş Çevik, Sayın Prof. Dr. Ahmet Ay, Sayın Prof. Dr. Orhan Çoban ve Doç Burcu Güvenek teşekkür ediyorum. Sizinle yaptığım çalışmalarını benim için her zaman faydalı olacağını inanıyorum.

Aynı zamanda, Türkçe öğretmenim Sayın Aydın Göktaş'ya şükretmem gerekir. Türkçe hazırladığım süre boyunca her zaman destek verdiği ve sabırlı gösterdiği için teşekkür ediyorum.

Türkiye'deki akademik kariyerim boyunca maddi ve manevi bana destek eden Yurtdışı Türkler ve Akraba Topluluklar Başkanlığı'na şükranlarımı sunarım.

En zor zamanlarda aramızdaki mesafeye rağmen her zaman bana destek gösteren ve attığım her adımda beni sürekli destekleyen canım aileme sonsuz teşekkürlerimi sunarım.

Türkiye'de üniversite kariyerim boyunca tanıdığım tüm arkadaşlarıma, Sayın Şükür Surucu, Asiye, Fatma Duman, Hakan Aşçı, Ngong Ivoline ve bana yardım eden tüm arkadaşlarıma teşekkür ediyorum.

Beni her zam destekleyen ve her zaman bana yol gösteren Yüce Tanrı'ya şükretmeden bitiremem. Bütün ihtişamı geri veren Allah'a atittir.



T. C.
SELÇUK ÜNİVERSİTESİ
Sosyal Bilimler Enstitüsü Müdürlüğü



| | | |
|-------------------|------------------------|--|
| Öğrencinin | Adı Soyadı | ABDUL-RAZAK BAWA YUSSIF |
| | Numarası | 174226001022 |
| | Ana Bilim / Bilim Dalı | İKTİSAT/İKTİSAT |
| | Programı | Tezli Yüksek Lisans <input checked="" type="checkbox"/> Doktora <input type="checkbox"/> |
| | Tez Danışmanı | Prof. Dr. Zeynep KARAÇOR |
| | Tezin Adı | YAPAY SİNİR AĞLARI İLE BORSA ENDEKSİ TAHMİNİ: GANA BORSASI ÜZERİNE BİR UYGULAMA. |

ÖZET

Gana Menkul Kıymetler Borsası 1989 yılında resmi olarak kurulmuştur. Gana'nın borsaları otuz yıllık bir kalkınma yolculuğu geçirmiştir. İstikrarsız borsa, bilimsel olmayan yatırımlar ve zararlı yatırımların ara sıra olan vakaları tüm piyasayı yüksek riskle karşılar ve kurumlara ve bireylere ciddi zorluklar öngörür. Bu tez, araştırma hedefi olarak GSE Kompozit Endeksini seçmektedir, yapay zeka metotlarının uygulamaları aracılığıyla ampirik analizi yönetir, bir ekonomik bakış açısından bu endeksin hatlarını oluşturur. Bu tezde, mevcut tarihsel verilere dayanarak Gana Menkul Kıymetler Borsası Kompozit endeksini tahmin etmek için Çok Katmanlı Algılayıcı (MLP), Evrişimli Sinir Ağları (CNN)ve Uzun Kısa Süreli Bellek (LSTM) olmak üzere üç tür derin öğrenme mimarisi kullanılmaktadır. Bu deneyin veri seti, 02 Ocak 2015 - 31 Aralık 2019 tarihleri arasında Gana Borsası'nın Kompozit Endeksinin günlük değerlerinden oluşmaktadır. İlk dört yılın

(2015-2018) gnlk deęerleri, her bir modeli eęitmek iin kullanılmakta ve son yıl yani 2019'a ait verilerin geri kalanı, modeller iin test veri kmesi olarak kullanılmaktadır. Egzersiz verileri ve test verileri sırasıyla% 80 ve% 20'ye karřılık gelmektedir. Sonular, CNN'nin GSE-CI tahminleri iin en iyi seim olduęunu gstermektedir. Bununla birlikte, MLP ve LSTM GSE-CI tahmininde kt performans gstermemektedir.

Anahtar Kelimeler: Gana Menkul Kıymetler Borsası, Kompozit endeks, Yapay Zeka, ok Katmanlı Algılayıcı, Evriřimli Sinir Aęı, Uzun Kısa Sreli Bellek.



T. C.
SELÇUK ÜNİVERSİTESİ
Sosyal Bilimler Enstitüsü Müdürlüğü



| | | | |
|-------------------|------------------------|---|----------------------------------|
| Öğrencinin | Adı Soyadı | ABDUL-RAZAK BAWA YUSSIF | |
| | Numarası | 174226001022 | |
| | Ana Bilim / Bilim Dalı | İKTİSAT/İKTİSAT | |
| | Programı | Tezli Yüksek Lisans <input checked="" type="checkbox"/> | Doktora <input type="checkbox"/> |
| | Tez Danışmanı | Prof. Dr. Zeynep KARAÇOR | |
| | Tezin İngilizce Adı | PREDICTING STOCK MARKET INDEX WITH ARTIFICIAL NEURAL NETWORKS: APPLICATION ON THE GHANA STOCK EXCHANGE. | |

ABSTRACT

The Ghana Stock Exchange was formally established in 1989, Ghana's stock market has gone through a development journey of three decades. The unstable stock market, unscientific investments and occasional event of malignant investment make the whole market full of high risk, and propose sever challenges to institutions and individuals. The thesis selects the GSE Composite Index as research objective, through the application of Artificial intelligence methods to conduct empirical analysis, carving the features of this index from an econometric perspective. In this thesis, we used three types of deep learning architectures namely Multilayer Perceptron (MLP), Convolution Neural Network (CNN) and Long Short-Term Memory (LSTM) for predicting the Ghana Stock Exchange composite index based on the historical data available. The dataset for this thesis consist of the daily values of the Composite Index of the Ghana stock Exchange from the 02 January 2015 to 31 December 2019. The daily values of the first four years (2015 - 2018) are used to train each model and the rest of the data for the last year, 2019, is used as the test dataset for the models. The training and test data correspond to 80% and 20% of the entire data respectively. The results indicate that CNN is the best choice

for the predictions of the GSE-CI. However, MLP and LSTM do not perform badly in predicting GSE-CI.

Keywords: Ghana Stock Exchange, Composite index, Artificial Intelligence, Multilayer Perceptron, Convolution Neural Network, Long Short-Term Memory.



İÇİNDEKİLER

| | |
|--|----|
| TABLolar LİSTESİ..... | ix |
| ŞEKİLLER LİSTESİ..... | x |
| KISALTMALAR..... | xi |
| GİRİŞ..... | 1 |
| BİRİNCİ BÖLÜM..... | 6 |
| SERMAYE PİYASASI VE GANA SERMAYE PİYASASI..... | 6 |
| 1.1. SERMAYE PİYASALARI..... | 6 |
| 1.2. SERMAYE PİYASASI ARAÇLARI ÇEŞİTLERİ..... | 7 |
| 1.2.1. Hisse Senetleri..... | 8 |
| 1.2.2. Tahviller..... | 8 |
| 1.2.4. Türev Ürünler..... | 9 |
| 1.2.6. Kira Sertifikaları..... | 9 |
| 1.2.7. Varlığa Dayalı Menkul Kıymetler..... | 10 |
| 1.2.8. Varlık Teminatlı Menkul Kıymetler..... | 10 |
| 1.3. GANA SERMAYE PİYASASI VE BORSASI..... | 10 |
| 1.4. GANA BORSASI GELİŞMELER VE ARAŞTIRMALAR..... | 15 |
| 1.5. SERMAYE VE BORSASI PİYASALARININ AMACI VE ÖNEMİ..... | 16 |
| 1.6. BORSA ENDEKSİ TAHMİNİ KULLANILAN İSTATİSTİKSEL MODELLER..... | 19 |
| İKİNCİ BÖLÜM..... | 22 |
| KURAMSAL ÇERÇEVE: YAPAY SİNİR AĞLARI MODELİ..... | 22 |
| 2.1. YAPAY SINIR AĞLARI MODELİ..... | 22 |
| 2.1.1. Derin Öğrenme Sinir Ağları..... | 26 |
| 2.2. YAPAY SINIR AĞ MİMARİSİNDE KULLANILAN TERMİNOLOJİLER..... | 27 |
| 2.2.1. Giriş Katmanı..... | 28 |
| 2.2.2. Gizli Katman..... | 28 |
| 2.2.3. Çıktı Katmanı..... | 29 |
| 2.2.4. Evrişimli Katman..... | 30 |
| 2.2.5. Havuzlama Katmanı (Pooling Layer)..... | 30 |

| | | |
|--|--|----|
| 2.2.6. | Geri Yayılım Algoritması | 31 |
| 2.2.7. | Ağırlık | 32 |
| 2.2.8. | Parametre Optimizasyonu (Parameter Optimization)..... | 32 |
| 2.2.9. | Dereceli alçalma (Gradient Descent)..... | 33 |
| 2.2.10. | Aktivasyon fonksiyonu | 33 |
| 2.2.10.1. | Doğrusal aktivasyon fonksiyonu..... | 33 |
| 2.2.10.2. | Rektifiye Doğrusal Aktivasyon Fonksiyonu..... | 34 |
| 2.2.10.3. | Sigmoid aktivasyon fonksiyonu..... | 35 |
| 2.2.10.4. | Tanh aktivasyon fonksiyonu | 36 |
| 2.3. | YAPAY SİNİR AĞLARININ ÖĞRENİLMESİ | 37 |
| 2.4. | YAPAY SİNİR AĞLARI VE SERMAYE PİYASASI İLİŞKİSİ | 38 |
| 2.5. | ZAMAN SERİSİ TAHMİNİ | 42 |
| 2.5.1. | Zaman Serisi İçin Çok Katmanlı Algılayıcılar | 43 |
| 2.5.2. | Zaman Serileri İçin Evrimsel Sinir Ağları | 47 |
| 2.5.3. | Tekrarlayan Sinir Ağı | 49 |
| 2.5.4. | Zaman Serisi İçin Uzun Kısa Süreli Bellek | 51 |
| 2.5.4.1. | Kapıyı unut (Forget Gate (f)): | 52 |
| 2.5.4.2. | Giriş Kapısı (Input Gate (i)):..... | 52 |
| 2.5.4.3. | Giriş Modülasyon Kapısı (Input Modulation Gate) (g): | 52 |
| 2.5.4.4. | Çıkış Kapısı (Output Gate (o)):..... | 53 |
| 2.6. | TEK DEĞİŞKENLİ LSTM MODELLERİ | 54 |
| ÜÇÜNCÜ BÖLÜM | | 55 |
| YAPAY SİNİR AĞLARI İLE BORSA ENDEKSİ TAHMİNİ: GANA BORSASI ÜZERİNE BİR UYGULAMA | | 55 |
| 3.1. | YAPAY SİNİR AĞLARI İLE TAHMİNLERİ | 55 |
| 3.1.1. | Yapay Sinir Ağı ve Döviz Kurları | 57 |
| 3.1.2. | Kredi Riski İçin İflas Tahmini | 58 |
| 3.1.3. | Yapay Sinir Ağı ile Finansal Kriz Tahmini | 58 |
| 3.1.4. | Yapay Sinir Ağına Dayalı Stok Tahmini | 59 |
| 3.2. | AMPİRİK LİTERATÜR..... | 60 |
| 3.3. | METODOLOJİ VE AMPİRİK UYGULAMA..... | 63 |

| | | |
|----------------|--|----|
| 3.3.1. | Derin öğrenme yöntemleri | 63 |
| 3.3.2. | Deneysel çerçeve | 67 |
| 3.3.3. | Veri kümesi ve veri ön işleme | 68 |
| 3.3.4. | Eğitim süreci | 71 |
| 3.4. | SİNİR AĞI MODELLERİ | 73 |
| 3.4.1. | MLP Sinir Ağı Modeli | 73 |
| 3.4.2. | LSTM Sinir Ağı Modeli | 74 |
| 3.4.3. | CNN Sinir Ağı Modeli | 74 |
| 3.5. | PERFORMANS ÖLÇÜLERİ | 75 |
| 3.6. | ANALYZ SONUÇLARI | 77 |
| 3.6.1. | Çok katmanlı algılayıcı (MLP) sonuçları | 77 |
| 3.6.2. | Uzun kısa süreli bellek (LSTM) sonuçları | 79 |
| 3.6.3. | Evrimsel sinir ağı (CNN) sonuçları | 80 |
| 3.7. | TEZ SONUÇ VE ÖNERİLERİ | 83 |
| KAYNAKÇA | | 86 |

TABLULAR LİSTESİ

| | <u>Sayfa No.</u> |
|--|-------------------------|
| Tablo 3.1. Modeller için Orijinal ve Sıralı Veriler Örneği | 70 |
| Tablo 3.2. MLP, LSTM ve CNN için Hiperparametreler..... | 75 |
| Tablo 3.3. MLP için Öngörülen ve Gerçek GSE-CI değerleri..... | 78 |
| Tablo 3.4. LSTM için Öngörülen ve Gerçek GSE-CI değerleri..... | 80 |
| Tablo 3.5. CNN için Öngörülen ve Gerçek GSE-CI değerleri..... | 82 |
| Tablo 3.6. MLP, LSTM, CNN performans sonuçları..... | 82 |

ŞEKİLLER LİSTESİ

| | |
|---|----|
| Şekil 1.1: Gana borsa Komposit endeksi (GSE-CI) grafiği..... | 13 |
| Şekil 2.1. Biyolojik nöronu ve Yapay bir nöronla ilişkisi..... | 26 |
| Şekil 2.2. Doğrusal aktivasyon fonksiyonu..... | 34 |
| Şekil 2.3. Rektifiye Doğrusal Aktivasyon Fonksiyonu..... | 35 |
| Şekil 2.4. Sigmoid aktivasyon fonksiyonu..... | 36 |
| Şekil 2.5. Tanh aktivasyon fonksiyonu..... | 37 |
| Şekil 2.6. Üç katmanlı bir MLP sinir ağı yapısı | 44 |
| Şekil 2.7. Evrimsel Sinir Ağı yapısı..... | 48 |
| Şekil 2.8. Uzun Kısa Süreli Bellek Sinir Ağı yapısı..... | 53 |
| Şekil 3.1. Zaman serilerinin tek adımlı öngörücüsü olarak kullanılan MLP ağı..... | 63 |
| Şekil 3.2. Geçitleme birimleriyle birlikte LSTM hücresi..... | 64 |
| Şekil 3.3. Geçici Evrişim Ağı görselleştirilmesi..... | 66 |
| Şekil 3.4. Test veri kümesinin MLP modeli tahmini..... | 78 |
| Şekil 3.5. Test veri kümesinin LSTM modeli tahmini..... | 79 |
| Şekil 3.6. Test veri kümesinin CNN modeli tahmini..... | 81 |

KISALTMALAR

| | |
|---------|--|
| ABD | Amerika Birleşik Devletleri |
| AIC | Akaike Bilgi Kriterleri |
| ANFIS | Uyarlanabilir Nöro-Bulanık Çıkarım Sistemini |
| ARCH | Otoregresif Şartlı Heteroskedastisite |
| ARIMA | Otoregresif Entegre Hareketli Ortalama |
| AUD | Avustralya Doları |
| BELEX15 | Belgrad Borsa Endeks |
| BIC | Bayesian Bilgi Kriteri |
| BIST | Borsa İstanbul |
| BMI | Dengeli Karşılıklı Bilgi |
| BPN | Geri Yayılım Ağı |
| CHF | İsviçre Frangı |
| CNN | Evrişimli Sinir Ağları |
| CPU | Merkezi İşlem Birimi |
| DT | Karar Ağaçları |
| EMH | Verimli Piyasa Hipotezi |
| ENN | Ensemble Sinir Ağı |
| FINSAP | Finansal Sektör Uyum Programı |
| GARCH | Genelleştirilmiş Otoregresif Koşullu Değişen Varyans |
| GBP | İngiliz Sterlini |
| GHS | Gana cedi |
| GPU | Grafik İşlem Birimi |
| GSE | Gana Menkul Kıymetler Borsası |
| GSE-CI | Gana Menkul Kıymetler Borsası Kompozit Endeksi |
| GSE-FSI | Gana Menkul Kıymetler Borsası Finansal Hizmetler Endeksi |
| IMF | Uluslararası Para Fonu |
| JPY | Japon Yeni |
| LR | Lojistik Regresyon |
| LSTM | Uzun Kısa Süreli Bellek |
| MACD | Hareketli Ortalama Yakınsama ve Iraksama |
| MAE | Ortalama Mutlak Hata |
| MAPE | Ortalama Mutlak Yüzde Hatası |
| MLE | Maksimum Olasılık Tahmini |
| MLP | Çok Katmanlı Algılayıcı |
| MSCI | Morgan Stanley Capital International |
| MSE | Ortalama Kare Hatası |
| NSE | Nijerya Menkul Kıymetler Borsası |

| | |
|--------|--|
| NYSE | New York Borsası |
| RBFNN | Radyal Temel Fonksiyon Sinir Ađı |
| ReLU | Rektifiye Doğrusal Birim |
| RMSE | Kök Ortalama Kare Hatası |
| RNN | Tekrarlayan Sinir Ađı |
| SA | Sinir Ađı |
| SAE | Stacked-Autoencoders |
| SAP | Yapısal Uyum Programları |
| SEC | Menkul Kıymetler ve Borsa Komisyonu |
| SGD | Stokastik Gradyan İnişı |
| STAR | Düzgün Geçiş Otoregresif |
| SVM | Destek Vektör Makineleri |
| USD | Amerikan Doları |
| WACMIC | Batı Afrika Sermaye Piyasası Entegrasyon Konseyi |
| WFE | Dünya Borsalar Federasyonu |
| YSA | Yapay Sinir Ađı |

GİRİŞ

Gana'nın finans piyasası son yıllarda giderek daha aktif hale gelmiştir. Varlık yönetimi kavramlarının yaygınlaşması ile insanlar paralarını yalnızca bir banka hesabına yatırmak yerine çeşitli finansal araçlara yatırım yapmaya yönelmişlerdir. Finansal piyasada, çok sayıda yatırım ürünü seçim için sunulmaktadır. Ancak borsa yatırımları çoğu insan için tercih edilen seçenek olmaya devam etmektedir. Bununla birlikte, önemli ölçüde değişen bir borsada istenen getiriye elde etmek için, yatırımcıların piyasa hareketlerini tam olarak kavramaları gerekmektedir. Böylelikle, araştırmacılar ve kamu yatırımcıları “borsa eğilimlerini doğru bir şekilde tahmin etme” yönteminin belirlenmesinde ortak bir ilgiyi paylaşmaktadırlar. Başarılı yatırımlarla istikrarlı ve yüksek kâr, şüphesiz tüm yatırımcılar için önemli bir hedeftir. Yatırımcılar borsalar dışında tahvil ve bono piyasasındaki finansal araçlara da erişebilmektedirler. Bu pazarlar sadece işletmeler için fon yaratma kanalları sağlamakla kalmamakta, aynı zamanda vadeli mevduatların üstünde halk için ek yatırım seçenekleri de sunmaktadır. Tahvil ve bono piyasası, işlem hacminin tamamı açısından çok büyük olup, borsadaki büyüklüğü birçok defa katlayabilmektedir. Öte yandan borsa, alışılmış miktardan az değerlerdeki yatırım tutarlarına izin vermektedir. Yatırımcılara fon mevcudiyetlerine bağlı olarak istedikleri zaman hisse senedi alma veya satın alma özgürlüğü verilmektedir.

Gana Menkul Kıymetler Borsası 1989 yılında resmi olarak kurulduğundan bu yana, Gana'nın borsaları otuz yıllık bir kalkınma yolculuğu geçirmiştir. İstikrarsız borsa,

bilimsel olmayan yatırımlar ve zararlı yatırımların ara sıra olan vakaları tüm piyasayı yüksek riskle karşılamakta ve kurumlara ve bireylere ciddi zorluklar öngörmektedir.

Daha iyi hisse senedi fiyatları yön tahmini, sıradan yatırımcılar ve finans uzmanları tarafından daha iyi ticaret stratejisi ve karar verme için önemli bir referanstır (Kao ve diğ., 2013). Hisse senedi fiyatı yön tahmininin yanı sıra, son finansal analiz çalışmalarında borsa endeksi yön tahmini de önemli konulardan biri olarak kabul edilmektedir. Borsa endeksi, piyasayı temsil eden seçilmiş hisse senetleriyle genel piyasa davranışını ölçmektedir. Doğru endeks yönü tahmini, yatırımcılara ekonominin hareket yönü ve belirli bir yatırım portföyü tarafından elde edilen getiri ile ilgili beklentiler hakkında bilgi sağlamaktadır (Pathak, 2010). Ayrıca, özellikle kısa vadeli yatırımcılar için, piyasadaki ani düşüslere karşı erken bir uyarı sistemidir.

Bu tezin amacı, çok büyük boyutlardan oluşan verileri verimli bir şekilde işleyerek büyük ölçekli uygulamalar için çıktılarını analiz edebilen ve tahmin edebilen bir sistem oluşturmaktır. Tahminlerin doğruluğunu artırmak için farklı öğrenme stratejileri ve veri ön işleme yöntemleri kullanılarak deneyler yapılacaktır.

Borsa belirsizliklerle sürekli değişmektedir. Hızlı bilgi dağıtımı ve hızlı sermaye akışı hisse senedi fiyatının dalgalanmasına yol açacak ve dalgalı fiyat karşılığında piyasayı etkileyecektir. Gelişmekte olan bir pazara ait olan Gana'nın borsaları, en başından beri keskin bir dalgalanma göstermiş ve çoğu zaman radikal iniş çıkışlar sergilemiştir. Bu tez, araştırma hedefi olarak GSE Kompozit Endeksini seçmekte, yapay zeka metotlarının uygulamaları aracılığıyla ampirik analizi yönetmekte, bir ekonomik

bakış açısından bu endeksin hatlarını oluşturmakta ve GSE Kompozit Endeksinin volatilitesinin mevcut durumuna bazı öneriler sunmaktadır.

Hisse senedi fiyatları, insani konular, siyasi nedenler, ekonomik durum, rekabet veya diğer olaylar gibi çeşitli faktörlerden etkilenmektedir. Borsa hareketlerini incelemek için temel analiz, teknik analiz veya psikolojik araştırma gibi farklı yaklaşımlar benimsenmiştir. Analitik süreç sayesinde, insanlar genellikle yatırım kararlarını desteklemek için iyi referans materyalleri belirleyebilmektedirler. Bununla birlikte borsa, hızlı bilgi alışverişleri olduğu sürece çok önemli değişiklikler ile karşı karşıya kalmaktadır. Bu nedenle yatırımcılar, öngörülemeyen bu piyasadaki yatırım getirilerini optimize etmek için etkili bir araca yönelmektedirler. Çoğu yatırımcı, pratikliği ve referans kabiliyeti nedeniyle borsada karar vermelerini desteklemek için teknik analizde büyük çaba sarf ederken, teknik endekslerin çeşitliliği ve tutarsızlığı bazen karar verme sürecinde tereddüt ve sonuç olarak en iyi eksikliğe neden olmaktadır.

Elektronik teknolojilerin gelişmesiyle birlikte, bilgisayarların hesaplama ve veri işleme yetenekleri de önemli ölçüde geliştirilmiştir. Yapay zeka ile entegre edildiğinde, bilgisayarlar büyük miktarlarda bilgi içeren karmaşık sorunlara çözümler sağlayabilmektedir. Yapay zekanın bir türü olan sinir ağları, iyi hata toleransları tarafından oluşturulmuş ve sonuç olarak, alakasız bilgilere rağmen doğru tahminleri ile öne çıkmıştır. Şimdiye kadar, sinir ağları doğrusal olmayan tahmin modelleri sağlamak için yeterince geliştirilmiştir. Ayrıca alınan yeni bilgilerle sürekli öğrenme yeteneğine de sahiptirler. Ağ işlemleri belirli bir ölçüde birleştikten sonra, sistem elde edilen yeni

bilgileri ezberleyecek ve kararlı bir duruma ulaşacaktır. Bu nedenle, istikrarlı ağı özel bilgi girildiğinde, gelecekte ilgili sonuçlar hakkında tahminler üretecektir.

Tezin konusu iki amaca hizmet etmektedir. Bunlardan ilki, Gana Menkul Kıymetler Borsası Kompozit Endeksi tarafından üretilmiş sonuçlara mümkün olan en yakın sonucu öngören sinir ağını üretmektir. Bu tez, Gana Menkul Kıymetler Borsası Kompozit Endeksinin volatilitisini modellemek ve tahmin etmek için yapay sinir ağını uygulamalarını ve makine öğrenme yöntemini kullanmaktadır. Bu yöntemlere dayanan ampirik analizler yoluyla endeksin oynaklığının özellikleri hakkında bilgi edinilebilmektedir. Ayrıca, GSE Kompozit Endeksi volatilitesi tüm Gana Menkul Kıymetler Borsası'nın belirsizlik hâli bilgilerini içerdiğinden, bu belirsizlikleri inceleyerek Gana'daki borsadaki bazı kurumsal sorunlar keşfedilebilmektedir. Daha sonra bazı öneriler sunmak için onların nedenlerini araştırılacaktır. Ayrıca, bu üç modele başvurarak GSE Endeksinin oynaklığı tahmin edilebilmektedir.

Yapay Sinir Ağları, inşaat denetimi, karakter tanıma, konuşma tanıma, görüntü işleme, uzman sistemlerin inşası ve karar verme süreci analizi gibi farklı amaçlarla yaygın olarak kullanılmaktadır. Borsanın analiz ve tahmininde, finans piyasasındaki vadeli işlemler ve bono değerlendirme usulünde kapsamlı şekilde kullanılmış ve yüksek hata toleransı ile güvenilir bir ürün olduğunu, büyük ve karmaşık bilginin baş edilebilir olduğunu ve tatmin edici tahmin sonuçlarını başardığını kanıtlamıştır. Sinir ağına dayalı hisse senedi fiyat tahmin modelleri sadece küçük yatırımcıların karar alma zamanlarından tasarruf etmelerini sağlamakla kalmamakta, aynı zamanda yatırım riskini ve piyasadaki

dalgalanmadan kaynaklanan kayıpları azaltmalarına yardımcı olmaktadır. Bu nedenle bu araştırmanın amacı, kullanıcıların yatırım hedeflerini belirlemeleri için ucuz ve verimli bir yol sağlamaktır. Genellikle küçük yatırımcılar, borsada ki yatırımlarının getirisini sağlama almaya ihtiyacı olan halktan bireysel yatırımcılardır. Bu çalışmada, Gana Borsası Kompozit analiz etmek için sinir ağı yaklaşımını benimsenmektedir. Tarihsel veri girişi yoluyla, yatırımcıların yatırım kararları için Genel Endeks trendini kavramasına yardımcı olmak amacıyla sistemi eğitmeye ve ticaret kararları için en iyi modeli oluşturmaya çalışılmaktadır. Araştırma sonuçları kamu yatırımcıları için iyi bir referans göstergesi sağlayıp böylece karlılığı artıracak ve riskleri azaltacaktır.

Makine öğrenmesi ve yapay zeka algoritmalarının ortaya çıkması, hisse senedi fiyatı yön tahmininde hesaplama gerektiren matematiksel modellerle başa çıkmayı mümkün kılmıştır. Bu tezde, mevcut tarihsel verilere dayanarak Gana Menkul Kıymetler Borsası Kompozit endeksini tahmin etmek için Çok Katmanlı Algılayıcı (MLP), Evrişimli Sinir Ağları (CNN)ve Uzun Kısa Süreli Bellek (LSTM) olmak üzere üç tür derin öğrenme mimarisi kullanılmaktadır.

BİRİNCİ BÖLÜM

SERMAYE PİYASASI VE GANA SERMAYE PİYASASI

Bu bölümde sermaye piyasaları ve sermaye piyasası araçlarının çeşitlerinin yanı sıra Gana sermaye piyasası, borsası ve Gana borsası gelişmeleri ve araştırmaları gözden geçirilecek ve son olarak da sermaye piyasaları ve borsasının amacı, önemi ve borsa endeksi tahmini kullanılan istatistiksel modeller gözden geçirilecektir.

1.1.SERMAYE PİYASALARI

Sermaye piyasaları, devlet ve kurumsal menkul kıymetler gibi önemli finansal araçlarda işlem gören finansal piyasaların bir diğer bölümüdür. Sermaye piyasalarının amacı, kurumların sermaye gereksinimlerini karşılamaları için uzun vadeli finansman ihtiyaçlarını arttırmaktır. Sermaye piyasalarında işlem gören en popüler menkul kıymetlerden bazıları hisse senetleri, bonolar ve tahvillerdir. Bu tür araçların ortak özelliği, bir yıldan uzun vadeli olmalarıdır. Bazı menkul kıymetlerin vadesi yoktur. Sermaye piyasaları, sermayenin ekonomideki dolaşımında önemli bir rol oynamaktadır. Sermaye piyasaları, fon arzı ile fon talebinin karşı karşıya geldiği bir kurumlardır. Tedarikçiler ve kullanıcılar olarak da bilinen borç verenler ve borçlular arasındaki ihtiyacı ortadan kaldıran kurumlardır.

Sermaye piyasasının işleyişi birincil ve ikincil piyasalardan oluşmaktadır. Birincil piyasalar, menkul kıymetlerin ilk kez ihraç edildiği pazarlardır. Yatırımcıların bu menkul kıymetlere abone olmaları gerekmektedir. 5 veya 10 yıllık devlet tahvillerinin halka arz

edilmesi ve bir şirketin ilk kez halka arz yoluyla arz edilmesi en yaygın örnekler arasında bulunmaktadır.

İkincil piyasalar, ilk ihraç edilen menkul kıymetlerin işlem gördüğü yerlerdir. Bunlar öncelikli olarak yatırımcılar arasında işlem görmektedir ve birincil piyasalardan daha likit olduğu düşünülmektedir. Genellikle birincil piyasasın aboneleri, birincil piyasadan elde ettikleri menkul kıymetleri almak ve satmak için ikincil piyasasın önemli bir parçası haline gelmektedirler.

1.2.SERMAYE PİYASASI ARAÇLARI ÇEŞİTLERİ

Sermaye piyasası araçları öncelikle sermayeyi yükseltmek için kullanılmaktadır. Toplanan sermaye türü öz kaynak veya borç olabilir. Bu nedenle, sermaye piyasaları hakkında konuşulduğunda, hisse senetleri veya tahviller olabilir. Sermaye piyasası araçlarının vadesi genellikle uzundur. Sonuç olarak, daha risklidirler ancak aynı zamanda bu tür araçlar da iyi geri dönüşler verebilmektedir. Kurumlar sermaye piyasalarını uzun vadeli finansal yükümlülükler için kullanmaktadır. Bu nedenle doğal riskler vardır. Birincisi, paranızı ödünç verdiğiniz vade ne kadar uzun olursa, kurumun iflas etmesine ilişkin belirsizlik o kadar büyük olmaktadır. Yine de sermaye piyasaları, verdikleri yüksek ödül veya getiriler nedeniyle çok popülerdir. Sermaye piyasaları da para piyasalarına göre çok daha likittir. Sermaye piyasası araçları hisse senedi, tahvil, özel sektör tahvilli, türev ürünler, özel sektör bonusu, kiro sertifikalar, varlığa doğal menkul kıymetleri, varlığa tavinatlı menkul kıymetlerden oluşmaktadır.

1.2.1. Hisse Senetleri

Şirketler uzun vadeli finansman ihtiyaçlarını karşılamak için hisse senetleri ihraç etmektedir. Finansman ihtiyaçları, satın almalardan vadelerini uzatmaya kadar çeşitlenebilmektedir. Tipik olarak, operasyonlar uzun vadeli ve bunun sonucunda hisse senetleri yatırımcının şirkette pay sahibi olmasını sağlamaktadır. Hisse senetleri öncelikli olarak hisse senedi piyasalarında kategorize edilebilmekte ve genellikle A Grubu hisseleri veya B Grubu hisseleri olarak bilinen genel hisse senedi olarak tercih edilmektedir.

1.2.2. Tahviller

Tahviller, bir kurum veya şirket taahhüt ya da borç olarak para toplamak istediğinde kullanılmaktadır. İhraç edilen tahviller her zaman bir yıldan daha uzundur. Bir tahvilin genel standart süresi beş yıl iken daha uzun vadeli tahvilleriniz de olabilmektedir. Tahviller hem hükümetler hem de şirketler tarafından çıkarılabilmektedir. Bir tahvilden elde edilebilecek getiri, kurumun veya şirketin finansal sağlığından enflasyona kadar çeşitli faktörlere bağlı olarak değişebilmektedir.

1.2.3. Özel Sektör Tahvilleri

Özel sektör tahvilleri bankalar veya diğer anonim şirketler tarafından çıkarılan borçlanma senetleridir. Tahviller en az bir yıl vadeli, iskontolu veya kuponlu olarak ihraç edilmektedir. İskontolu tahvillerde ihracatçı tarafından yatırımcıya vade sonunda tahvilin nominal tutarı ödenmektedir. Kuponlu tahvillerde yatırımcıya belli periyodlar ile (3 ay, 6 ay veya 1 yıl) kupon getirisi sağlanmakta ve anapara ödemesi vade sonunda yapılmaktadır.

1.2.4. Türev Ürünler

Türev finansal araçlar temel olarak hisse senedi veya bono piyasalarından türetilmektedir. Türev araçlar, değerlerini özkaynak veya borç olan dayanak varlıklardan almaktadır. Türev piyasalarda, kişinin kullanabileceği daha birçok finansal araç bulunmaktadır. Örneğin, opsiyonlar hisse senetleri için kullanılırken, bonolar için kredi temerrüt swapları gibi kredi türevi araçlarımız vardır. Türevler çoğunlukla temel piyasalardan elde edilen riskten korunmak için kullanılmaktadır.

1.2.5. Bonolar

Bono, devlet ve kurumsal firmalardan yatırımcıların sabit veya değişken faiz oranlarıyla belirlenen süre içerisinde kredi aldığını gösteren bir belgedir. Bonoların bilinen ilk özelliği vadeleridir. Bononun vadesi 2 aydan az veya 12 aydan fazla olamamakta ve. şirketler ya da devlet tarafından çıkarılmaktadır. Bonolar bu özellikleri sebebiyle hisse senetlerine benzemektedir. Sözleşmede belirtilen vadenin sonunda bonolar, paranın şirkette veya devlette bulunduğu süre için belirlenen faiz oranından elde edilen faiz kazancı eklenerek yatırımcıya geri ödenmektedir.

1.2.6. Kira Sertifikaları

Kira sertifikası, her türlü varlık ve hakkın finansmanını sağlamak amacıyla varlık kiralama şirketi tarafından ihraç edilen ve sahiplerinin bu varlık veya haktan elde edilen gelirlerden payları oranında hak sahibi olmalarını sağlayan menkul kıymettir. Tanımda yer alan hak; kira sertifikaları ihracına dayanak her türlü hakkı, varlık ise kira sertifikaları ihracına dayanak haklar dışındaki her türlü varlığı ifade etmektedir.

1.2.7. Varlığa Dayalı Menkul Kıymetler

Bankaların tüketici kredileri, konut kredileri, ihracat kredileri, finansman şirketlerinin kendi mevzuatları uyarınca açmış oldukları krediler, finansal kiralamaya yetkili kuruluşların finansal kiralama sözleşmelerinden doğan alacaklar, gayrimenkul yatırım ortaklıklarının portföylerindeki gayrimenkullerin satış veya satış vaadi sözleşmelerinden kaynaklanan senetli alacakları karşılığında doğrudan ihraç edecekleri kıymetli evraktır.

1.2.8. Varlık Teminatlı Menkul Kıymetler

Varlık teminatlı menkul kıymetlerin varlığa dayalı menkul kıymetlerden farkı, bu aracı çıkaran kurumların çeşitli alacaklarını güvence göstermeleridir. Bankalar ve benzer şirketlerin açtığı bazı krediler, finansal kiralama sözleşmelerinden doğan alacaklar, gayrimenkul yatırım ortaklıklarının portföylerindeki gayrimenkullerin satışından doğan alacakların yanı sıra TOKİ'nin alacakları da, bu menkul kıymetler için teminat olarak kullanılabilir. Teminatın olması, bu menkul kıymetlerin ödenmeme riskini azaltan bir etmendir.

1.3.GANA SERMAYE PİYASASI VE BORSASI

Gana Menkul Kıymetler Borsası (GSE) Gana'da 1989 yılında kurulan büyük borsadır. Borsa 1990 yılında teminatla sınırlı özel bir şirket olarak faaliyete başlamış ve daha sonra 1994 yılında teminatla sınırlı bir halka açık şirkete dönüşmüştür. Menkul Kıymetler ve Borsa Komisyonu (SEC) tarafından borsa gelişmekte olan bir ekonomi için esnek pazarlar inşa etmeyi amaçlamaktadır (Ghana Stock Exchange, 2016). Gana borsası şu anda üç

pazarı kontrol etmektedir: Hisse Senetleri Piyasası, Gana Alternatif Piyasası ve Sabit Getirili Piyasasıdır. Gana borsası aynı zamanda Batı Afrika Sermaye Piyasası Entegrasyon Konseyi (WACMIC) ve Dünya Borsalar Federasyonu'nun da (WFE) bir üyesidir.


GSE ilk olarak 1989 yılında kurulmuş ve bir şirket tahvili, üç devlet tahvili ve bir imtiyaz payı ile birlikte 35 şirketten toplam 40 hisse senedinden oluşmaktadır. Borsada listelenen başlıca sektör üretim olup bunu bankacılık takip etmektedir. Madencilik, sigorta ve petrol gibi diğer endüstriler de listelenmiştir.

2008 yılında, Borsa 2009 yılında tamamlanan bir otomasyon sürecine başlamıştır. Otomatik Ticaret Sisteminin uygulanmasını sağlamak için, Borsa 2008'de borsadaki tahvilleri toplamak ve paylaşmak için hızlı ve verimli tedarige olanak sağlamak adına bir Depo ve Gana Menkul Kıymetler Borsası Menkul Kıymetler Departmanı şirketini oluşturmuştur. Menkul Kıymetler Piyasası yıllar içinde toplam 2.1 milyar GHS özkaynak finansmanı sağlamıştır. Piyasa değeri de 1990 yılında 3,05 milyon GHS'den, 2015 yılında tüm zamanların en yüksek seviyesi olan 64,352,42 milyon GHS ile 2015 yılında 57,116,87 milyon GHS'ye yükselmiştir. Halen sermaye piyasasında 40 şirket ve 42 hisse senedi bulunmaktadır. Gana Menkul Kıymetler Borsası için ana piyasa endeksleri Gana Menkul Kıymetler Borsası Kompozit Endeksi (GSE-CI) ve Gana Menkul Kıymetler Borsası Finansal Hizmetler Endeksi (GSE-FSI) 'dir.

Gana borsa endeksi, 1993 yılında sermaye piyasasında% 116 değer kazanması ve 1994 yılında endeks seviyesinde% 124,3 artış ile gelişmekte olan borsalarda ilk altıncı

sırada yer alan endeksler arasında yer almıştır. Gana Menkul Kıymetler Borsası 1995 raporuna göre piyasadaki diğer GSE rakipleri yükselen hisse senetlerini onun piyasadaki daha iyi performansına borçludurlar. Veriler, toplam borsa kapitalizasyonunun 2006 yılında 11,2 milyar ABD Doları, Aralık 2007'de 13,2 milyar ABD Doları ve 2008'de 15,5 milyar ABD Doları olduğunu ortaya koymaktadır. Bu nedenle, GSE'nin 2007 raporunda bildirildiği üzere, pazar 2007'de% 31,84 oranında artmıştır. Her borsa güvenilir bir şekilde işlemekte ve bu nedenle piyasa güçleri performanslarını etkileyebilmektedir. Gana genel seçimlerinin borsa üzerinde olumsuz bir etkisi olabilmekte ve ilgili piyasa dalgalanmaları nedeniyle hisse senetlerinin performansına zarar verebilmektedir. Ayrıca rejim değişikliği, yatırımcıların karar alma süreçlerini etkileyebilecek çok önemli bir faktördür (Nortey ve ark. 2015). Farid'in (2013) belirttiği gibi, Afrika ülkelerindeki pazarların önemli bir özelliği, Afrika borsaları ile dünya genelindeki ana borsalar arasındaki zayıf ilişkidir. GSE bu kuralın bir istisnası değildir ve özellikle Gana borsası üzerinde yapılan araştırmalara göre, küresel finansal piyasalarda meydana gelen dış olaylardan etkilenmediği görülmektedir. GSE-CI, Gana'daki Menkul Kıymetler Piyasasının ana endeksidir ve borsada listelenen tüm adi hisseleri içermektedir. GSE-FSI ise sadece listelenen finansal stoklardan oluşmaktadır.

Şekil 1.1: Gana borsa Komposit endeksi (GSE-CI) grafiği



Kaynak: Gana Borsasi, 2019 (<https://gse.com.gh/>)

Gana borsası 1994 yılında dünyanın en iyi gelişmekte olan piyasası olarak belirlenmiş ve 1998, 2003 ve 2004 yıllarında GSE en iyi Afrika pazarı olmuştur. (Quartey ve Gaddah, 2007). Ayrıca, 2004 yılında Gana borsası, ABD doları bazında yıllık yüzde 144 getiri ile dünyanın en iyi performans gösteren piyasasına hükmetmiştir. Databank grubunun bir yan kuruluşu olan Databank Financial Services Ghana'nın dünya çapında 62 piyasa ile yaptığı çalışmada yıllık yüzde 30 getirisi olan Morgan Stanley Capital International (MSCI) Global Index ile karşılaştırılmıştır. 2002-2003 yılları arasında yapılan bir araştırma, Gana borsalarının dünyayı yüzde 256 ABD doları cinsinden bileşik endeks getirisiyle yönlendirdiğini bulmuştur. Ayrıca 2010 yılında Gana borsası ve New

York borsası (NYSE) ticaret katında düzenlenen yıllık Afrika Yatırımcı (AI) endeks serisi ödüllerinde Afrika'daki en yenilikçi borsa ilan edilmiştir. Ayrıca, Afrika'nın en iyilerinden biri olan ve tüm pazarın performansını ölçen Gana borsa bileşik endeksi, 2013 yılında% 78.81 oranında artmıştır (www.gse.com.gh). Gana borsasının geçmiş performansları, kazanılan getiriler sonucunda piyasanın verimli olduğu dönemler olduğunu göstermektedir. Bu durum yatırımcıları Gana Menkul Kıymetler Borsası'na yatırım yapma konusunda güvence altına almıştır.

Yıllar boyunca gösterdiği performansa rağmen, Gana borsası hala borsanın büyümesini engelleyecek bir takım zorluklarla karşı karşıyadır. Bu süreçte, Borsa'nın ekonomiye sağlayacağı potansiyel faydanın tam olarak toplanamayacağı düşünülmektedir. Bunun nedenleri düşük likidite ve yüksek volatilité problemidir. Mensah'a (2016) göre, Borsa'nın likiditesi Güney Afrika, Botswana, Nijerya ve Kenya gibi Afrika pazarlarının çok altındadır. Bu, Gana Borsasında işlem görmenin daha zor ve pahalı olduğu anlamına gelmektedir. İkinci sorun, sınırlı sayıda listedir. Her ne kadar borsanın girişi 25 yıl boyunca 11 hisse senedinden 42 hisse senedine yükselse de, bu yılda ortalama bir yeni girişi temsil etmektedir. Sınırlı sayıda finansal araç sorunu vardır ve hisse senetleri Borsa'da işlem gören en büyük güvenlidir. Son olarak, yatırımcının Piyasaya katılımı da çok düşüktür.

Yukarıdaki zorluklara ek olan bir diğer sorun ise, hükümetin başlangıçta Borsada alım satım için bir teşvik görevi gören sermaye kazancı vergi muafiyetini kaldırma arayışıdır. Quaye ve diğ.'ye (2016) göre, hükümet tarafından alınan bu karar, hem

yatırımcıları hem de şirketleri piyasaya girmekten vazgeçirerek Borsa'nın yıllar içindeki ilerlemesini engelleyebilecektir.

1.4.GANA BORSASI GELİŞMELER VE ARAŞTIRMALAR

1957'de Gana ekonomisinin sömürge politikalarından kurtulup bağımsız bir ekonomiye dönüşmesi ile yeni doğan Sahra altı ülkenin kişi başına geliri 400 dolar olan orta-üst sınıf bir ülkeye taşındığını görmüştür. Bununla birlikte, bağımsızlıktan birkaç yıl sonra, ekonomik yanlış yönetim ve birkaç darbe ile ekonomiyi Dünya Bankası'nın müdahalesini gerektiren bir kaosa sürüklemiştir. Hükümet, ekonominin serbestleştirilmesini amaçlayan Dünya Bankası'nın Yapısal Uyum Programı'nı (SAP) uygulayarak devletin piyasaya kalkınma yaklaşımını teşvik etmesini sağlamıştır. 1983'de SAP, Gana Menkul Kıymetler Borsası (GSE) 1989'da kurulduğunda Gana'da borsa ve ticaretin doğuşunu görmüştür. GSE'nin kurulması ile birlikte Gana ekonomisinde büyüme görülmüştür. Gana ekonomisi, ülke için bir başarı ve diğer Afrika ülkeleri için bir örnek model olarak nitelendirmiştir. Gana borsasının büyük başarısı ile araştırmacıların ve tüccarların piyasayı anlama merakları da büyük ölçüde artmıştır. Kuwornu ve Owusu-Nantwi (2011) bazı mikroekonomik değişkenler ile hisse senedi getirileri arasındaki ilişkiyi incelemişlerdir. Maksimum olasılık tahmin yöntemi kullanılarak yapılan çalışmada tüketici fiyat endeksi, döviz kuru ve hazine bonoları arasında anlamlı bir ilişki bulunurken, ham petrol fiyatının hisse senedi getirilerini etkilemediği bulunmuştur. Adu (2012), (Kuwornu ve Owusu-Nantwi, 2011) tarafından hisse senedi getirilerini etkileyen mikroekonomik faktörlerin yanı sıra ham petrol fiyatlarının borsa getirilerini de etkilediğini ortaya koymuştur. Bu sonuç, Gana borsalarındaki değişimi açıklamak için

arbitraj fiyatlama yöntemini kullandığında ve değişkenlerin hem kısa hem de uzun vadeli ilişkisini incelemek için ortak entegrasyonla birlikte sıradan en küçük kare regresyonunu kullandığında elde edilmiştir.

Kallah-Dagadu (2013), Gana borsasındaki haftalık endeks getirilerinin ampirik dağılımını, α -kararlı dağılım parametrelerini tahmin etmek için maksimum olasılık yaklaşımı dahil olmak üzere farklı parametre tahmin yöntemi kullanarak incelemiştir. Çalışma, haftalık geri dönüşün, verimli tahminler üreten MLE tahminine dayanarak ağır bir şekilde kuyruklandığı ve asimetric olduğu sonucuna varmıştır. Nortey ve diğ. (2015), Gana borsasındaki tüm hisse senedi endekslerinin günlük hisse senedi dönüş tails'na Extreme Values Theorem kullanarak bir model yerleştirmiştir. Günlük stok verilerinin fattailed ve asimetric olduğunu bulmuşlardır. Çalışma, aşırı Genelleştirilmiş Pareto Dağılımının modellenmesinde Eşik Üstü Piki yaklaşımının Gana borsasındaki aşırı olayın modellenmesinde çok etkili olduğu sonucuna varmıştır. Gana borsasındaki bazı seçilmiş hisse senetlerinin oynaklığı, GARCH modelini kullanan (Omari-Sasu ve diğ. 2015) tarafından incelenmiştir. Çalışma, geri dönüşlerde volatilité olmasına rağmen, analiz edilen geri dönüşlerin volatilitesinde kalıcılığın olmadığı sonucuna varmıştır.

1.5. SERMAYE VE BORSASI PİYASALARININ AMACI VE ÖNEMİ

Son on yılda Afrika ülkelerinde borsaların büyüme eğilimi, dünya ekonomisindeki büyüme ile aynı yönde gerçekleşmektedir. Afrika ekonomilerinde birçok gelişmiş finans piyasaları çok fazla değişim göstererek dünya ekonomileri ile daha entegre hale gelmiştir.

Bu varyasyonlar çeşitli faktörlerin bir sonucudur. (Cosh ve ark. 1992; Adjasi ve Yartey 2007):

- Büyük ekonomilerde ülke içinde ve dışında finansal piyasaların kademeli olarak tahsisi,
- Bu pazarların uluslararasılaşması,
- Daha riskli ve daha önemli yatırımlara katkıda bulunan bir dizi ürünün piyasaya sürülmesi,
- Özellikle kurumsal yatırımcı olmak üzere finansal piyasalarda yeni oyuncuların rolünün ortaya çıkışı ve büyümesi, olarak sıralanabilmektedir.

Gelişmiş ülkelerin finansal sistemlerindeki gelişmeler, uluslararası ticaret görüşmelerinde ticaretin düzenlenmesine katkıda bulunmuştur. Afrika gibi bölgelerde borsa oluşturulması ve sermaye mali kayıtlarının serbestleştirilmesi, küresel serbestleşme sürecinin bir parçası olabilmektedir. Afrika'da bir borsa oluşturma, yerel tasarrufları artırmalı ve yatırımın kalitesini ve miktarını artırmalıdır. Genel olarak, borsa ulusal finansal sistemin ve sermaye piyasasının performansını güçlendirmektedir (Piesse ve Hearn, 2005; Kenny ve Moss, 1998) ancak analistler, borsaların gelişmekte olan ülkelerde yararlı olabileceğine ve tüm Afrika pazarlarının yüksek maliyetler ve zayıf ekonomik yapılarda hisse senedi piyasalarını artıramayacağına inanmaktadır (Singh, 2013).

Temel olarak borsa, yerel tasarrufları teşvik ederek ve yatırımın kalitesini ve miktarını artırarak ekonomik büyümeyi hızlandırmalıdır (Singh, 2013). Bireylere risk ve likidite

ihtiyaçları için tercihlerini en iyi şekilde karşılayan ek bir finansal araç sağlayarak tasarruf sağlamalıdır. Tasarrufların daha iyi mobilize edilmesi tasarruf oranını artırabilmektedir (Saci 2011). Borsalar ayrıca gelişmekte olan şirketlere daha düşük maliyetle sermaye toplama fırsatı sunarak, bireysel tasarrufları artırarak ve şirketler için finansman fırsatları sağlayarak ekonomik büyümeyi olumlu yönde etkileyebilmektedir.

Sermaye piyasasının ekonomiye verdiği önem göz önüne alındığında, 1990'lar, Afrika kıtasında Uluslararası Para Fonu (IMF) ve Dünya Bankası'nın Yapısal Uyum Programları (SAP) kapsamında yeni bir borsa kuruluşları dalgası görmüştür ve Gana bir istisna değildir. 1988 yılında ülke, SAP kapsamında kapsamlı bir Finansal Sektör Uyum Programı (FINSAP) başlatmıştır. Bu karar, finans sektöründeki mevcut zorlukları ele almayı amaçlamıştır (Sowa, 2002: p4). Gana sermaye piyasası 1989 yılında FINSAP altında kurulmuştur. 1990 yılında 11 özkaynak ve işlemlerin başlangıcını gösteren özel bir tahvil ile faaliyete geçmiştir. Gana Borsası, 25 yıllık faaliyetlerden sonra şu anda 21 lisanslı işlem üyesi ile 42 hisse senedi ve 97 Devlet tahvili listelemektedir. Borsada ki şu ana kadar ki gelişmeler arasında, borcun otomasyonu, KOBİ'ler için alternatif bir pazar kurulması ve sabit gelirlili menkul kıymetlerde alım satım için sabit bir gelir piyasasının oluşturulması yer almaktadır. Borsa ayrıca, tarım sektörüne kolay erişimi sağlamak için 2017 yılındaki bir emtianın kuruluşunu düşünmektedir. Gana Menkul Kıymetler Borsası ve Batı Afrika bölgesindeki diğer üç pazar arasında da devam eden bir tartışma vardır ve Fildişi Sahili, Nijerya ve Liberya entegre bir sermaye piyasası arayışı içerisinde. Bu entegrasyon bölgedeki borsalara daha fazla yatırımcı ve ihraççı erişimi sağlayacaktır.

Böylece, bu durum borsadaki yatırım faaliyetlerini teşvik etmektedir (Central Securities Depository, 2016).

1.6.BORSA ENDEKSİ TAHMİNİ KULLANILAN İSTATİSTİKSEL MODELLER

Son yıllarda teknoloji, iletişim ve hatta insanların yaşam tarzı değiştikçe borsa davranışlarının faaliyetlerinde bazı zorunlu değişiklikler olmuştur. Hisse senedi piyasaları için istatistiksel modeller, hisse senedi piyasalarının sürekli değişen davranışlarına ayak uydurabilmek için temel varsayımların daha gelişmiş varsayımlara dönüştürülmesinden başka şekillerde de değişmiştir.

Akademisyenler ve araştırmacılar, piyasa dinamiklerine daha fazla ışık tuttuğundan hisse senedi endekslerinin ve fiyatların öngörülebilirliğini anlamaya çalışmışlardır. Borsa için istatistiksel modelin ilk uygulaması (Bachelier, 1900) tarafından, hisse senedi fiyatlarının matematiksel denklemler kullanarak davranışlarının rastgele özelliklerini tanımladığı ve o zamandan beri, borsaların farklı istatistiksel modellerle çalışıldığı zaman önerilmiştir. Genel olarak, stok verilerine uygulanan modeller, Zaman Serisi Tahmini, Teknik Analiz, Temel Analiz ve Makine Öğrenim Yöntemleri olarak kategorize edilebilmektedir. Temel olarak teknik analiz, hisse senedi fiyatları ve hacimlerinin öngörülmesinin, geçmiş verileri açıklamak için sohbetlerdeki kalıpları kullanarak geçmiş piyasa verilerini incelemeye dayandığı bir yöntemdir. Teknik analizin ilk kez Joseph dela Vega tarafından 17. yüzyılda Hollanda borsasının analizi hesabında kullanıldığı düşünülmektedir ("Döviz Piyasasında Teknik Analizin Kökenleri", 2017). Teknik analizde, teknisyenler, temel ve haber olayları gibi hisse senedi fiyatlarının diğer dış

etkenlerine bakmak yerine, pazar fiyatının, hisse senedi fiyatı tespiti ve dolayısıyla menkul kıymet alım satım tarihi ile ilgili tüm bilgilerin bir yansıması olduğuna inanmaktadırlar. Desenler stokların fiyatını bildirmek için kullanılmaktadır. Yatırımcıların ve tüccarların davranışları, fiyatların tekrarlanmasına neden olan tekrarlanan bir paterni takip etme eğiliminde olduğundan, teknisyenler tanımlanabilir eğilimler ve koşullara odaklanmaktadırlar. Son zamanlarda, Murphy ve diğ. (2014), bir uyarı stratejisi alan ve ekrandaki stratejinin bir diyagramını temsil eden ve stratejiyi doğrulayan önceden programlanmış bir bileşen sağlamak için bilgisayar tarafından uygulanan bir yöntemin kullanıldığı yeni teknik ticaret buluşunu gerçek zamanlı grafikler ve diyagram kullanarak açıklamışlardır. Bir alım satım aracı verildiğinde, program alım satım stratejisini yürütmektedir.

Temel analistler, tahmini akım değeri gerçek değerine göre daha düşükse, menkul kıymete yatırım yaptıkları bir hisse senedinin gerçek değerini kullanarak hisse senedi fiyatlarını incelemektedirler. Teorik çerçeve (Bernard, 1994) tarafından incelenmiş ve son yıllarda (Wafi ve diğ. 2015) tarafından uygulanmıştır. Figurska ve Wisniewski (2016), mevcut sermaye piyasası prensibine dayanarak emlak piyasalarına temel analiz uygulama olasılığını da incelemişlerdir. Makine öğrenim yöntemleri, verileri oluşturan temel fonksiyonun yakınlaştırılabilmesi için verilerdeki örnekleri ve iz kalıplarını kullanmaktadırlar. Modeller doğrusal olabilmekte ya da olmayabilmektedir. Pérez-Rodríguez ve diğ. (2005), Düzgün Geçiş Otoresgresif modellerini (STAR), En Yakın Komşu (Near Neighbour) ve Yapay Sinir Ağlarını (YSA) bir yıllık ufukta örnek dışı tahmin yapabilme yetenekleri açısından inceleyerek stok tahmini için doğrusal olmayan

modelleri incelemiřlerdir. alıřma, dođrusal olmayan modellerin dođrusal otoregresif ve rastgele yuruyuř modellerinden daha iyi performans gosterdiđi sonucuna varmıřtır. Jasemi ve diđ. (2011) borsa madenciliđi ve Japon řamdanının teknik analizi iin modern bir sinir ađı modeli uzerinde alıřmıřlardır. Yontemleri, bađımsız deđiřkenlerin teknik analiz modelleri olarak kullanılan hayati gostergerler ve faktorler olacađı bir regresyon modelini onermekte ve pazarın eđilimini bađımlı deđiřken olarak yakın gelecekte kullanmaktadır.

Geleneksel Zaman Serisi analizinde arařtırmacılar ve tucclarlar, gemiř verilerdeki kalıpları izleyebilen dođrusal tahmin modelleri elde etmeye alıřmaktadırlar. Bu modellerin sınıflandırılması, tek deđiřkenli veya ok deđiřkenli olarak incelenmekte olan stok verilerinin sayısına dayanmaktadır. Box-Jenkins ARIMA modelleri Ariyo ve diđ. (2014) tarafından Nijerya Menkul Kıymetler Borsası (NSE) ve New York Menkul Kıymetler Borsası (NYSE) tarafından yayınlanan veriler kullanılarak stok verilerine uygulanmıřtır. Mondal ve diđ. (2014) ayrıca ARIMA modelinin Hint hisse senedi piyasasından elli altı endeks kullanarak stok tahminindeki etkinliđini incelemiřtir. Son donemlerde ise yapay sinir ađları modelleri uygulamaya bařlamıřtır.

İKİNCİ BÖLÜM

KURAMSAL ÇERÇEVE: YAPAY SİNİR AĞLARI MODELİ

Bu bölümde yapay sinir ağı modeli ve yapay sinir ağı mimarisinde kullanılan terminolojilerin yanı sıra yapay sinir ağlarının öğrenilmesi, yapay sinir ağı ve sermaye piyasası ilişkisi gözden geçirilip son olarak da zaman serisi tahmini ve tek değişkenli lstm modelleri gözden geçirilecektir.

2.1.YAPAY SİNİR AĞLARI MODELİ

Yapay bir sinir ağı, ilk kez 1943'te McCulloch ve Pitts tarafından geliştirilen bir hesaplama modelidir (Tan, 2001). Modelin gelişiminde, insan beyninin faaliyetlerini temel olarak ele alınmıştır. Araştırmacılar, insan beyninin tüm sinir hücreleri arasında bulunan çok sayıda ara bağlantı ve ağı taklit ederek bir bilgisayar yapmayı düşünmüşlerdir. Amaç, beyni bir girdi verilerinden öğrenerek bilgi edinmesi ve tıpkı beynin yaptığı gibi verileri bilgiye dönüştürmesi anlamında taklit etmektedir.

Sinir ağı çok çeşitli amaçlar için kullanılmaktadır ancak hepsi model tanıma altında toplanmaktadır. Yapay Sinir Ağları, hem doğrusal hem de doğrusal olmayan modelleri tanıyarak, gelecekteki bir olguyu tahmin etmek için kullanılan öngörücü modellerin oluşturulmasına yardımcı olmaktadır. Yapay Sinir Ağları tarafından oluşturulan öngörücü modeller iki kategoriye ayrılmaktadır: Birincisi Sınıflandırma (kategorik bir sonuçla) ve ikincisi Regresyon (sürekli bir sonuçla) modelleridir.

Sınıflandırma modeli, etiketler ya da kategoriler olabilen ayrık çıktı değişkenlerini tanımlamak için girdi değişkenlerinden bir eşleme işlevine yaklaşan tahmini bir modeldir. Sınıflandırma algoritmalarının eşleme işlevi, verilen girdi değişkenlerinin etiketini ya da kategorisini tahmin etmekten sorumludur. Bir sınıflandırma algoritması hem ayrık hem de gerçek değerli değişkenlere sahip olabilmektedir ancak örneklerin iki veya daha fazla sınıftan birine sınıflandırılmasını gerektirmektedir.

Regresyon modeli, girdi değişkenlerine bağlı olarak sürekli bir değer öngörmektedir. Regresyon problemlerinin temel amacı, girdi ve çıktı değişkenlerine dayalı olarak bir eşleme fonksiyonunu tahmin etmektir. Hedef değişkeniniz gelir, puanlar, boy veya kilo gibi bir miktar veya bir ikili kategorinin olasılığı ise (belirli bölgelerde yağmur olasılığı gibi), o zaman regresyon modelini kullanmalısınız.

Yapay Sinir Ağları iki geniş kategoride sınıflandırılmaktadır. İleri beslemeli ve tekrarlayan ağlar olmak üzere Birimler (nöronlar) arasındaki bağlantılar doğrudan bir döngü oluşturuyorsa, yapay bir sinir ağı tekrarlayan olarak sınıflandırılmaktadır. Aksine, ileri beslemeli bir sinir ağı, bilgi / mesajların sadece ileri yönde (yani bir döngüde değil) aktarımını dikkate alan bir sinir ağı sınıfıdır. Demek ki giriş sinyalleri bir yönde hareket etmekte ve bu bir anlamda belirli bir katmandaki çıktının aynı katman üzerinde hiçbir etkisi olmadığı anlamına gelmektedir.

Bir sinir ağı giriş değişkenleriyle paralel çalışabilmekte ve sonuç olarak da büyük veri setlerini hızlı bir şekilde işleyebilmektedir. Yapay Sinir Ağları, aktivasyon fonksiyonları ve ağ mimarisi ile ince ayar yaparak doğrusal dönüş, ikili probit modeli ve

diğer birçok modeli kapsayabilmektedir. Tahmin, sınıflandırma ve kümeleme gibi bir dizi veri analizi görevi için kullanılan güçlü bir genel amaçlı yazılım aracıdır. Yapay Sinir Ağları, istatistiksel varsayımlar içermez ve teoride, verilerdeki herhangi bir karmaşık doğrusal olmayan yolu tespit edip çoğaltabilen eksik ve yanlış verilere daha dayanıklıdır.


Finansal veriler genellikle gürültü veya rasgele yollar için basit doğrusal yapısal modeller ile tanımlanmamaktadır. Durağan süreçlere dayanan geleneksel zaman serisi analizi finansal zaman serilerinde her zaman tatmin edici bir performans sergilememektedir (Harvey and Fernandes, 1989). Dönüş yöntemleri ve kendiliğinden ilerleyen entegre hareketli ortalama (ARIMA) modelleri, doğal gürültü yolları, yağ kuyrukları ve doğrusal olmayan bileşenler nedeniyle bazı finansal seri verilerini doğru olarak tahmin etmemektedir. Yapay sinir ağları, bilimsel yaklaşımlarla güvenilir bir karar verme sürecine ulaşmak için portföy yönetimi, kredi notu ve iflasın tahmin edilmesi, döviz kurlarının tahmini, hisse senedi değerlerinin tahmini, enflasyon ve nakit tahmini ve diğerleri gibi finasta büyük ölçüde kullanılmaktadır.

İşleyişi insan beyninin mantığına benzeyen yapay sinir ağlarına ilgi, oldukça doğrusal olmayan işlevlere yaklaşmak için yoğun veri işlemede kullanılabilmelerinden kaynaklanmaktadır. Öğrenme süreci, Yapay Sinir Ağlarının çeşitli eğitim süreçlerini kullanarak belirli bir hedefe ulaşmak için açıklayıcı değişkenleri birbirine bağlayan ağırlıkları ayarladığı “deneyime” dayanmaktadır. Yapay Sinir Ağlardaki temel birim, görevi giriş verilerini uygun ağırlıklar ve önyargılarla işlemek ve hedefi en iyi şekilde yeniden üretmek için bu dönüştürülmüş verilere bir işlev uygulamak olan nörondur.

Önyargı eğitimi, ağırlıkların art arda ayarlanmasından oluşmakta ve böylece belirli bir hata fonksiyonu açısından nöronun çıkışı ile hedef arasındaki mesafe en aza indirilmektedir. Tek bir nöron ve eşik aktivasyon fonksiyonuna sahip yapay sinir ağlara algılayıcı denmekte ve sıralı ve paralel olarak düzenlenmiş birden fazla algılayıcıya sahip yapay sinir ağlara çok katmanlı algılayıcılar veya geri yayılma ağları denmektedir.

Bir algılayıcı, Cornell bilim adamı Frank Rosenblatt tarafından önerilen basit bir ikili sınıflandırma algoritmasıdır. Bir dizi giriş sinyalini “evet” ve “hayır” olmak üzere iki kısma ayırmaya yardımcı olmaktadır. Ancak diğer birçok sınıflandırma algoritmasından farklı olarak, algılayıcı insan beyninin temel birimi olan nörondan sonra modellenmiştir ve karmaşık problemleri öğrenme ve çözme konusunda tuhaf bir yeteneğe sahiptir. Bir algılayıcı çok basit bir öğrenme makinesidir. Her birinin ne kadar önemli olduğunu belirtmek için bir ağırlığı olan birkaç girdi alabilmekte ve “0” veya “1” çıktı kararı üretebilmektedir. Bununla birlikte, diğer birçok algılayıcı ile birleştirildiğinde, yapay bir sinir ağı oluşturmaktadır. Bir sinir ağı, teorik olarak, yeterli eğitim verisi ve hesaplama gücü verildiğinde herhangi bir soruyu cevaplayabilmektedir.

Şekil 2.1. Biyolojik nöronu ve Yapay bir nöronla ilişkisi



Kayak: (Nastos ve diğ. 2011: p 559)

Şekil 2.1a, bilgiyi işleyen biyolojik nöronun yapısını göstermektedir. Dendritler yoluyla başka bir nöronun bilgi alınmasının ardından, bir nöron, alınan bilgileri bir akson yardımıyla başka bir nörona aktarmaktadır. Şekil 2.1b ayrıca nöron için bir matematiksel model vermektedir. Bu model, tıpkı biyolojik nöron gibi, bir girdi verisini almakta, bunu işlemekte ve bir çıktı üretmektedir. Bu nedenle, yapay nöronun formülasyonu, biyolojik nöronun bulunan ara bağlantıları taklit etme güdüsüyle ilgilidir.

2.1.1. Derin Öğrenme Sinir Ağları

Derin öğrenme sinir ağları, girdilerden çıktılara rastgele karmaşık eşleştirmeleri otomatik olarak öğrenebilmekte ve çoklu giriş ve çıkışları destekleyebilmektedir. Bunlar, özellikle karmaşık doğrusal olmayan bağımlılıklar, çok değerlikli girdiler ve çok adımlı tahmin ile ilgili problemler üzerinde zaman serisi tahmini için çok fazla umut vaat eden

güçlü özelliklerdir. Bu özellikler ve daha modern sinir ağlarının yetenekleri, evrişimli sinir ağları tarafından sağlanan otomatik özellik öğrenimi ve tekrarlayan sinir ağlarında dizi verileri için yerel destek gibi büyük vaatler sunabilmektedir.

Derin öğrenme sinir ağlarının yetenekleri, zaman serisi tahmini için iyi bir uyum olduğunu göstermektedir. Tanımı gereği ve yeterli kaynaklarla, sinir ağları, girdilerden çıktılara keyfi bir karmaşık haritalama öğrenme yetenekleri göz önüne alındığında, klasik lineer tahmin yöntemlerinin yeteneklerini kullanabilmelidir. Sorunun modellenmesini kolaylaştırmak (örneğin seriyi sabit hale getirmek) için zaman serisi verilerinden sistematik yapıları manuel olarak tanımlamak ve kaldırmak iyi bir uygulamadır ve tekrarlayan sinir ağları kullanılırken bu hala en iyi uygulama olabilmektedir ancak bu ağların genel kabiliyeti, bunun yetenekli bir model için bir gereklilik olamayabileceğini düşündürmektedir. Teknik olarak, girdi olarak sağlanan sekansın mevcut bağlamı, sinir ağı modellerinin hem eğilimi hem de mevsimsellikleri doğrudan öğrenmesine izin verebilmektedir.

2.2.YAPAY SINIR AĞ MİMARİSİNDE KULLANILAN TERMİNOLOJİLER

Sinir ağları esas olarak karmaşık bir öğrenilmiş algoritma oluşturmak için katmanları ve nöronları kullanarak girişleri çıkışlarla eşleştirmektedir. Yapay sinir hücreleri bir araya gelmekte, yapay sinir ağlarını oluşturmakta ve rastgele katılmamaktadır. Genellikle, sinir hücreleri her bir tabakada birbirine paralel olarak üç tabaka halinde bir araya gelmekte ve ağı oluşturmaktadırlar (Oztemel, 2003). Böylece,

katmanların her biri önceki ve sonraki katmanlardaki nöronlara bağlanan birçok nörondan oluşmaktadır.

2.2.1. Giriş Katmanı

Sinir ağı mimarisinin ara bağlantılarındaki, giriş sinyallerini gizli katmana dağıtan ilk katmandır. Bu, bir çıktı üretmek için ağdan geçen girdi kümesini (gerçek değerler olan girdi vektörü) alan katmandır. Alternatif olarak, giriş katmanı, giriş verilerinin ağa beslendiği katman olarak düşünülebilmektedir.

Giriş katmanı, sinir ağına bir model sunan dış ortamla iletişim kurmaktadır. Görevi sadece tüm girdilerle ilgilenmektir. Bu girdi, aşağıda açıklanan gizli katmanlara aktarılmaktadır. Giriş katmanı, sinir ağını eğittiğimiz koşulu temsil etmelidir. Her giriş nöronu, sinir ağının çıkışı üzerinde etkisi olan bazı bağımsız değişkenleri temsil etmelidir.

2.2.2. Gizli Katman

Gizli katman, üzerine aktivasyon fonksiyonu uygulanmış nöronların toplanmasıdır ve giriş katmanı ile çıkış katmanı arasında bulunan bir ara katmandır. Görevi, önceki katman tarafından elde edilen girdileri işlemektir. Bu yüzden, girdi verilerinden gerekli özelliklerin çıkarılmasından sorumlu olan katmandır. Gizli katmandaki nöron sayısını değerlendirmek için birçok araştırma yapılmıştır ancak yine de hiçbiri doğru sonucu bulmada başarılı olamamıştır. Ayrıca, bir Sinir Ağı'nda birden fazla gizli katman olabilmektedir. Bu nedenle, hangi tür problem için kaç gizli katmanın kullanılması gerektiği düşünülmelidir. Doğrusal olarak ayrılacak verilerimiz varsa, etkinleştirme işlevi sorunu çözebilecek giriş katmanına uygulanabileceğinden gizli bir katman

kullanmaya gerek yoktur. Ancak karmaşık kararlarla ilgili sorunlar olması durumunda, sorunun karmaşıklık derecesine veya gereken doğruluk derecesine göre 3 ila 5 gizli katman kullanılabilir. Bu durum katman sayısını artırmaya devam edersek sinir ağının kesinlikle yüksek doğruluk sağlayacağı anlamına gelmemektir. Ekstra bir katman eklenirse, doğruluk sabit olduğunda veya düştüğünde bir aşamaya gelmektedir. Ayrıca, her bir ağdaki nöron sayısı da hesaplanmalıdır. Nöronların sayısı, problem verilerinin karmaşıklığına kıyasla daha azsa, gizli katmanlarda karmaşık bir veri setindeki sinyalleri yeterince tespit etmek için çok az nöron olacaktır. Ağda gereksiz daha fazla nöron varsa, aşırı takılma meydana gelebilmektedir. Şimdiye kadar, gizli katmanların sayısını ve her bir gizli katmandaki nöron sayısını hesaplamak için kesin formülü sağlamayan çeşitli yöntemler kullanılmaktadır.

Gizli katman, eğer varsa sonraki gizli katmandan, aksi halde çıktı katmanından nöronlar ile iletişim kuran nöronlar içermektedir (Nastos ve diğ., 2011). Etkinleştirme / aktarım işlevlerini kullanarak, gizli katmandaki her nöron alınan girişleri toplamakta, işlemekte ve sonuçta çıktı katmanına göndermektedir.

2.2.3. Çıktı Katmanı

Sinir ağının çıkış katmanı, bilgileri vermek üzere tasarlandığı şekilde toplamakta ve iletmektedir. Çıktı katmanı tarafından sunulan desen doğrudan girdi katmanına kadar izlenebilmektedir. Çıktı katmanındaki nöronların sayısı, sinir ağının gerçekleştirdiği çalışma türüyle doğrudan ilişkili olmalıdır. Çıktı katmanındaki nöron sayısını belirlemek için, önce sinir ağının amaçlanan kullanımı düşünülmelidir. Bu katman, ağın çıktısını geri

döndürmek ve hedef çıktıyla karşılaştırmak amacıyla çıktı nöronları olarak bilinen nöronlardan oluşmaktadır. Bir dönüş modeliyle uğraşırken sadece bir nöron almakta ve sınıflandırmalarla uğraşırken bir veya daha fazla nöron almaktadır.

2.2.4. Evrişimli Katman

Evrişim tabakası CNN'nin anahtar tabakasıdır. Temelde girişten daha küçük bir görüntü olan filtreler veya çekirdekler kullanılmaktadır. Konvolüsyon giriş ve çekirdeğin bir kısmı ile yapılmaktadır. Her filtre bir özellik eşlemiyse sonuçlanmaktadır. Her filtre için aktivasyon haritası, 3 boyutlu bir tensör verecek şekilde istiflenmektedir. Filtreler eğitilirken, kenarları ve desenleri tanımayı öğrenmekte ve ağ içerisindeki daha derin ve daha gelişmiş şekilleri tanıyabilmektedirler. Bir evrişim katmanına giriş, sinir ağı girişi veya başka bir evrişim katmanından gelen özellik haritası çıktısıdır. CNN'lerde çok yaygın olarak kullanılan ise ReLU aktivasyon fonksiyonudur. Bu katman temel olarak tüm negatif girişleri almakta ve sıfıra ayarlamaktadır. ReLU katmanının hiperparametreleri yoktur. Yani, tasarımcı tarafından seçilen parametrelerdir.

2.2.5. Havuzlama Katmanı (Pooling Layer)

Havuzlama katmanı verilerin boyutunu azaltmaktadır. En yaygın sürüm, verilen pencere boyutunun maksimum değerini veren ve geri kalanını yok sayan maksimum havuzlamadır. Bu işlemi tüm girdi üzerinden yapmaktadır. Havuzlama bu pencerede ki maksimum değerin nerede olduğunu önemsememektedir ve bu da pozisyona biraz daha az duyarlı olmasını sağlamak ve aşırı takmayı kontrol etmeye yardımcı olmaktadır.

2.2.6. Geri Yayılım Algoritması

Geri yayılma, sinir ağlarını eğitmek için yaygın olarak kullanılan bir algoritmadır. Sinir ağı başlatıldığında, ağırlıklar nöron adı verilen kendi elemanları için ayarlanmaktadır. Girişler yüklenmekte, nöronlar ağından geçirilmekte ve ilk ağırlıklar göz önüne alındığında ağ her biri için bir çıkış sağlamaktadır. Geri yayılma, nöronların ağırlıklarının ayarlanmasına yardımcı olmakta ve böylece sonuç bilinen gerçek sonuca yaklaşmaktadır. Geri yayılımda, odak ağırlık ve sinir ağlardaki sapmaların maliyet fonksiyonunu (hata) nasıl etkilediğini anlamaktır. Gerçekte, maliyetlerin ağırlıklar ve yanlılıklara göre kısmi türevleri hesaplanmaktadır. Geri yayılım tekniği, girdilerin ağırlıklarının tek katmanlı bir sinir ağların nöronlarına güncellenmesi için kullanılan gradyanlı terbiyeli algoritmanın genelleştirilmesidir. Her adım, tüm eğitim örneklerinin ortalama maliyetini almaktadır.

Her aktivasyon, bir önceki katmanın tüm aktivasyonlarını ve bir sapmanın da ağırlıklı toplamını oluşturmaktadır. Etkinleştirmeler önceki katmana bağlı olduğundan ve doğrudan değiştirilemediğinden, ağırlıkları ayarlayarak ağ üzerinden geri çoğalabilmektedir. Her degrade iniş adımı için her eğitim örneğinin kullanılması ve hesaplanması için uzun zaman almaktadır. Stokastik gradyan inişi (SGD) bu işlemi daha hızlı hale getirmek için kullanılmaktadır. Temel olarak giriş verilerinin sırasını rastgele seçmekte, mini yığınlara bölmekte ve mini partiye göre de bir adım hesaplanmaktadır. Bu, tüm eğitim için uygun olmadığından yüksek boyutlu uzayda hareket etmek için tam olarak doğru yönü vermemekte ancak bir alt kümenin kullanılması için iyi bir yaklaşım sağlamaktadır.

2.2.7. *Ağırlık*

Sinir ağlarındaki katmanlar arasında, bir katmandaki nöronların çıkışı veya bu nöronların aktivasyonları arasında, her bir bağlantı bir ağırlıkla ilişkili olan bir sonraki katmandaki nöronların girişine bağlanmaktadır. Bu ağırlıklar ağırlık ayar düğmeleridir. Ağırlığın iki nöron arasındaki bağlantının gücü olduğunu söylenebilmektedir. Sinir ağlarındaki ağırlıklar, girdinin çıktıya yaptığı katkıları (dolayısıyla gücü) tanımlamak için girdi değişkenlerine katsayı olarak atanan gerçek değerli sayılardır.

2.2.8. *Parametre Optimizasyonu (Parameter Optimization)*

Bir sinir ağındaki parametreler, ağırlıklar ve yanlılıklar bir eğitim veri seti kullanılarak güncellenmektedir. Başlangıçta, ağırlık parametreleri rastgele atanabilmektedir. Daha fazla eğitim verisi ile model gerçek sisteme daha doğru bir şekilde benzeyecektir. Makine öğrenmesi (ML), eğitim setine dayalı verileri temsil etmenin bir yolunu bulmakta ve verileri matematiksel bir modelle eşleştirmeye de çalışmamaktadır. Ağırlıklar ve yanlılıklar, tüm eğitim örneğinin ortalama maliyetini en aza indirilecek şekilde güncellenmektedir.

Modelin parametrelerini güncelleme işlemine parametre optimizasyonu denilmekte ve temel olarak ağırlıkları maliyet işlevine göre ayarlamaktadır. Ağırlıklar, maliyet fonksiyonu en verimli biçimde azalacak şekilde ayarlanmaktadır. Popüler bir yöntem, örneğin ikinci dereceden optimizasyon için kendiri kullanmaktan daha kolay olup daha az zaman alan ve hesaplama açısından ağır olduğu için gradyan inişini kullanan birinci dereceden optimizasyondur.

2.2.9. Dereceli alçalma (Gradient Descent)

Degrade iniş temel olarak ağırlık öğrenmesidir. Eğitim verileri eğitimsiz ağırlıklardan beslenmekte ve ağırlıklar ile sapmalar ayarlanır. Daha sonra ağırlık görünmeyen verilerle test edilmektedir. Çalışma şekli bir fonksiyonun minimumunu bulmaktır. Degradeyi hesaplamak için kullanılan algoritmaya geri çoğaltma denmektedir. Öğrenme hızı, parametrelerin yineleme başına ne kadar güncelleneceğine karar vermektedir. Çok büyük ayarlanması, işlevin iyi bir değere yerleşememesine ve ağırlık daha da kötüleşmesine neden olabilmektedir. Öğrenme oranı çok düşük olan bir ağırlık eğitilmesi çok uzun zaman almaktadır. Eğilimle orantılı bir öğrenme oranı seçmek, aşmayı engellemektedir.

2.2.10. Aktivasyon fonksiyonu


Bu, doğrusal veya doğrusal olmayan bir işlevdir ve SA'daki rolü, ağırlıklı girdilerin hesaplanan kombinasyonları ile doğrusal olmayan bir karar sınırı sağlamaktır. Farklı problemler için farklı aktivasyon fonksiyonları kullanılmaktadır. Aşağıdaki alt bölümler en yaygın olanlara kısa bir genel bakış sunmaktadır. Her fonksiyon hakkında bilgi Patterson, (2017: s. 65) ve Gupta, (2017)'den alınmıştır. Aşağıdaki aktivasyon fonksiyonlarının tüm grafikleri Python'da yapılmaktadır.

2.2.10.1. Doğrusal aktivasyon fonksiyonu

Fonksiyonun ağırlıklı nöron veya girdilerin toplamıyla doğru orantılı olduğu basit bir düz çizgi aktivasyon fonksiyonudur. Doğrusal aktivasyon fonksiyonları, geniş bir aktivasyon aralığı vermede daha iyidir ve pozitif bir eğim çizgisi, girdi hızı arttıkça ateşleme oranını artırabilmektedir.

Doğrusal işlevi: $f(x) = x$ (2.1)

Şekil 2.2. Doğrusal aktivasyon fonksiyonu




Şekil 2.2, doğrusal aktivasyon fonksiyonunu göstermektedir $f(x) = x$. Bu etkinleştirme işlevini kullanırken, çıktı yalnızca girdiyle orantılıdır ve temel olarak sinyalin geçmesine izin vermektedir.

2.2.10.2. Rektifiye Doğrusal Aktivasyon Fonksiyonu

Rektifiye Doğrusal birim veya ReLU, şu anda 0 ile sonsuz arasında değişen en yaygın olarak kullanılan aktivasyon fonksiyonudur. Tüm negatif değerler sıfıra dönüştürülmekte ve bu dönüşüm oranı o kadar hızlı olmaktadır ki, verileri düzgün bir şekilde eşleyememekte veya sığdıramamaktadır ve bu da bir sorun oluşturmaktadır. Sorun, tüm negatif değerlerin anında sıfırlanmasıdır ve bu da modelin verilere uygun şekilde uyması veya eğitilmesi yeteneğini azaltmaktadır. Bu, ReLU aktivasyon fonksiyonuna verilen herhangi bir negatif girdinin, değeri grafikte hemen sıfıra çevirdiği anlamına gelmekte ve bu da negatif değerleri uygun şekilde eşlemeyerek sonuç grafiğini etkilemektedir.

$$\text{Rektifiye Doğrusal işlevi: } f(x) = \max(0; x) \quad (2.2)$$

Şekil 2.3. Rektifiye Doğrusal Aktivasyon Fonksiyonu




Denklem 2.2'de gösterilen ve Şekil 2.3'te gösterilen Rektifiye Doğrusal Birim (ReLU) işlevi, basitliği ve iyi sonuçları nedeniyle en yaygın aktivasyon işlevidir. Bir nöron alt kümesi aynı anda ateş etmekte ve bu da ağı daha verimli hale getirerek verimliliği artırmaktadır.

2.2.10.3. Sigmoid aktivasyon fonksiyonu

Sigmoid fonksiyonu de çok popüler bir etkinleştirme işlevidir. Çıkışı 0 ile 1 arasında sıkıştırılmaktadır. Sürekli olarak ayırt edilebilmektedir. Bu işlevin gradyanı 0 civarında en yüksektir ve daha yüksek veya daha düşük giriş değerleri içinde düzleşmektedir. Ağ, grafiğin bu bölgesine düştüğünde gitgide daha yavaş öğrenmekte, yani yok olan gradyan problemini öğrenmektedir. Sigmoid işlevi Şekil 2.4'de gösterilmiştir.

$$\text{Sigmoid işlevi: } f(x) = \frac{1}{1 + e^{-x}} \quad (2.3)$$

Şekil 2.4. Sigmoid aktivasyon fonksiyonu




Sigmoid aktivasyon işlevi çoğunlukla görevini büyük bir verimlilikle yerine getirdiği için kullanılmaktadır. Temelde karar vermeye yönelik olasılıklı bir yaklaşımdır ve 0 ile 1 arasında değişmektedir. Dolayısıyla, bir karar verilmesi veya bir çıktının tahmin edilmesi gerektiğinde, bu etkinleştirme işlevini kullanılmaktadır. Çünkü, aralık minimumdur ve bu nedenle tahmin daha doğru olmaktadır. Sigmoid işlevi, temelde kaybolan gradyan problemi olarak adlandırılan bir soruna neden olmaktadır. Çünkü 0 ile 1 aralığı arasında büyük girdileri dönüştürülmekte ve bu nedenle türevleri çok daha küçük hale gelmekte ve bu da tatmin edici çıktı vermemektedir. Bu problemi çözmek için, küçük bir türev problemimizin olmadığı durumlarda ReLU gibi başka bir aktivasyon fonksiyonu kullanılmaktadır.

2.2.10.4. Tanh aktivasyon fonksiyonu

Bu etkinleştirme işlevi, aynı zamanda iki sınıfı tahmin etmek veya ayırt etmek için kullanılan sigmoid işlevi gibi sigmoid işlevinden biraz daha iyidir fakat negatif girdiyi yalnızca negatif miktara eşlemekte ve -1 ile 1 arasında değişmektedir.

$$\text{Tanh işlevi: } g(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.4)$$

Şekil 2.5. Tanh aktivasyon fonksiyonu



Şekil 2.5'te gösterilen Tanh, sigmoid fonksiyonuna benzemekte ve sadece -1 ile 1 arasında değerler vermektedir.

2.3.YAPAY SİNİR AĞLARININ ÖĞRENİLMESİ

Öğrenme, bir dış girdi verildiğinde bir Yapay sinir ağlar nöronları arasındaki ara bağlantıların ağırlık ayarlaması sürecini içermektedir. Öğrenme sürecinin temel amacı, tüm eğitilmiş vakalarda toplanan hatayı en aza indirmektir. Yapay sinir ağlar öğrenimi ikiye ayrılabilir: Denetimli ve Denetimsiz. Denetimli bir öğrenme sürecinde, ağırlık eğitiminde bir dizi veri çifti (giriş değerleri - istenen çıkış / hedef değerler) kullanılmaktadır. Her eğitimde ağ tarafından, verilen girdi setini kullanarak istenen / hedef çıktıyı hesaplama girişiminde bulunmaktadır. Ağdan hesaplanan çıktı, hedef çıktıyla karşılaştırılmaktadır. Hesaplanan çıktı ile hedef değer arasındaki fark hatadır. Böyle bir

hatanın meydana geldiği göz önüne alındığında, ağ, minimum hata elde edilene kadar, bağlantılarının ağırlıklarını yinelemeli bir şekilde sürekli olarak ayarlayarak hatayı en aza indirmeye çalışmaktadır. Birçok denetimli öğrenme algoritması vardır ancak en yaygın olarak kullanılanlar, delta kuralı ve yaygın olarak geri yayılım algoritması olarak bilinen delta kuralının geliştirilmesidir (Tan, 2001). Denetimli öğrenmenin aksine, denetimsiz öğrenmede açık hedef değerleri yoktur. Ağırlık ayarlamaları bazı parametrelere ve ağ parametrelerinin değişiklik boyutuna (Veri ve Baba, 2013) göre yapılmaktadır.

2.4.YAPAY SINIR AĞLARI VE SERMAYE PİYASASI İLİŞKİSİ

İktisatta, sinir ağları temel olarak ekonomik ajanların sınıflandırılması ve zaman serisi tahminlerinde kullanılmıştır. Sınıflandırmada, Yapay Sinir Ağlar iflas tahmini için yaygın olarak kullanılırken, çok az sayıda uygulama finansal krizlere odaklanmaktadır. Yapay Sinir Ağı, aktivasyon fonksiyonlarını ve ağ mimarisini düzenleyerek doğrusal regresyon, ikili probit modeli ve diğerleri gibi birçok modeli kapsayabilmektedir. Öngörü, sınıflandırma ve kümeleme gibi birçok veri analizi görevi için kullanılan güçlü bir genel amaçlı yazılım aracıdır. Dalgalanan veya rastgele yürüyüşler için basit doğrusal yapısal modeller genellikle finansal verileri tanımlamamaktadırlar. Durağan süreçlere dayanan geleneksel zaman serileri analizi, finansal zaman serilerinde her zaman tatmin edici bir şekilde performans göstermemektedirler. Regresyon yöntemleri ve Otoregresif Entegre Hareketli Ortalama (ARIMA) modelleri, kendisinden kaynaklı dalgalanma kalıpları, fat tails ve doğrusal olmayanlık (nonlinearity) nedeniyle bazı finansal seri verilerini doğru şekilde tahmin edememektedir.

Yapay sinir ağıları, portföy yönetimi, kredi derecelendirme ve iflasın öngörülmesi, döviz kurlarının tahmin edilmesi, hisse senedi değerlerinin tahmin edilmesi, enflasyon ve nakit tahmini ve diğerleri gibi finansta bilimsel yaklaşımlarla güvenilir bir karar alma süreci elde etmek için büyük ölçüde kullanılmıştır. En önemlisi, verilerden öğrenme yeteneği ve dolayısıyla genelleme potansiyeli, daha önce görülmemiş girdi verileri için kabul edilebilir bir çıktı üretmesidir. Yapay sinir ağlarının finansal tahminlerde umut verici sonuçlar sağladığı gösterilmiştir. Yapay sinir ağlarının girdi verilerinde doğrusal olmayan ilişkileri keşfetme yeteneği, onları borsa ve döviz piyasası gibi doğrusal olmayan dinamik sistemlerin modellenmesi için ideal kılmaktadır.

Yapay Sinir Ağı, istatistiksel varsayımlardan muaftır ve teorik olarak verilerdeki herhangi bir karmaşık doğrusal olmayan modeli tespit edip çoğaltabilmekte ve aynı zamanda eksik ve yanlış verilere karşı daha dayanıklıdır. Yapay sinir ağlarının en büyük işlevi, sınırlı sayıda gizli sinir ağı olmasına rağmen istenen herhangi bir doğruluk derecesine yaklaştırabilmesidir. Kendisi için konuşulmasını sağlayan, sorunla ilgili önceden varsayımlar gerektirmeyen, parametrik olmayan regresyon modellerini oluşturur. Yapay Sinir Ağlarının tahmin doğruluğu, köklü bir doğrusal regresyon modeline göre daha iyi olma eğilimindedir (Fadlalla ve Lin, 2001).

Yapay sinir ağları, biyolojik sinir sistemlerinde gözlenen özelliklerin bir kısmını taklit eden ve biyolojik uyarlanabilir öğrenme ve analogiyle tasarlanan matematiksel modellerin koleksiyonları olarak tanımlanabilmektedir. Özellikle seri tahmini ve veri madenciliği gibi bir dizi adım olarak ifade edilemeyen sorunları çözmek için kullanışlıdır.

Sinir ađları ok fazla veri, bilgi ve deneysel bilgi olduđunda en iyi seenektir ve algoritmalar iřleme iin yeterince hızlı ve dođru olamamaktadırlar. İstatistiksel yntemler aısından, basit fonksiyonlar tarihsel ekonomik deđerlere, ekonomi alanındaki ok karmařık srelerin ngrlmesi iin ok iyi bir ilk yaklařım olarak kullanılabilirler istatistiksel kamu verilerine dayanarak kullanılabilirler.

İnsan beyninin yapısını ve iřlevlerini taklit etmek ve modellemek amacıyla, eřitli bilim alanlarından ok sayıda arařtırmacının sinir ađları ile ilgilendiđi bilinmektedir. Bir sinir ađı, insan sinir sisteminden sonra modellenen, ğrenebilen bir sistemdir. ok fazla pratikten sonra, sinir ađları insan mdahalesi olmadan kalıpları tanıyabilmektedir. Sinir Ađları, fonksiyon yaklařımı, zaman serisi tahmini, sınıflandırma vb. iin kullanılan uyarlamalı dođrusal olmayan paralel dađıtılmış bir sistemdir. Sinir ađı modelinin gcl yanlarından biri, dođrusal olmayan trendlerin altında yatan kalıpları yakalama kabiliyeti ile karakterize edilebilmektedir. İnsan beyninden ve sinir sisteminden sonra tasarlanan bir sinir ađı, paralellikten yararlanarak ve iřleme ğelerinin verilerini iřlemden geirme gcnden yararlanarak borsa verilerine benzer karmařık verileri iřleme yeteneđine sahiptir. Yapay sinir ađları evrensel yaklařımlardır ve teoride herhangi bir iřlevi keyfi olarak yaklařtırabilmektedirler. Bununla birlikte, bir ađın temsil ettiđi haritalama fonksiyonu, sinirsel ađ eđitimindeki yerel minimal problem, alt-ađ ađ mimarisi ve sonlu rnek verilerden dolayı mkemmelenmez deđildir. Bu nedenle, sinir ađlarının gerekte arka olasılıklarla ilgili tahminler sundukları aıktır.

Cybenko (1989) 'ya göre, makroekonomik göstergeler öngörmede yararlıdır ancak finansal kriz için altta yatan nedenler sağlamazlar ve bu nedenler sonsuz olabilmektedirler. Krizler genellikle ekonomiyi zorlayan birden fazla dış ve iç faktörün birleşmesiyle ortaya çıkmaktadırlar. Bazı nedenler krize diğerlerinden daha fazla yol açma eğilimindedir ancak çoğu krizde ortak bazı piyasa başarısızlık nedenleri vardır. Bir finansal müdahale planı hazırlarken, çeşitli nedenlerin anlaşılması bu çaba için çok önemlidir. Gelişmiş krizler için son birkaç on yıldaki birçok krizin ana nedenlerinden biri düzenleme veya finansal serbestleşme eksikliği olmuştur (Allen ve Gale, 1999).

Bankacılık ve finansal kurumların ve diğer düzenleme araçlarının gevşek hükümet düzenlemelerinin bir sonucu olarak gelmiştir. Birçok ülke, ekonomilerini geliştirmek için tüm ülkelerde kolay kredi ve para yaratma konusunda liberal finansal düzenlemeyi destekleyen “Washington Consensus” u takip etmekteydiler. Yakın zamana kadar, bu politika işe yarayacak gibi gözükse de, son olaylar serbestleşmenin çok ileri gidebileceğini göstermiştir. Sorun, kuralsızlaştırmanın etkilerini görmenin yıllar sürmesidir. Bu nedenle herhangi bir uyarı veya olumsuzluk görülmemiştir. İskandinav ve Japon krizleri söz konusu olduğunda, bu hükümetler birkaç haftadan birkaç yıla kadar sürebilen varlıklar kabarcıklarına ve finansal krizlere yol açan bazı serbestleşme örneklerinden bahsetmektedir. Ekonomik tahminler, politika ve stratejiyi formüle etmeye yardımcı olmak için işletme ve devlette yaygın olarak kullanılmaktadır.

Ekonomik tahminin gelecekteki olayları tahmin etme süreci olduğu söylenebilmekte ve nicel analiz, nitel analiz veya her ikisinin birleşimine dayanan finansal

ve ekonomik süreçlerin tüm yönleri için esastır. Zamana dayalı girdi verileri dizisi, nitel veya nicel veriler göz önüne alındığında, sinir ağı gelecekteki değerleri öngörecektir. Bu tahmin sürecinin doğruluğu, girdi verilerinin miktarı ve alaka düzeyi gibi birçok faktöre bağlı olacaktır. Tahmin etmenin amaçları belirsiz bir şekilde azaltmak ve gerçek ve gelecekteki performansın izlenmesi için kriterler sağlamaktır. Elde edilen tahminleri gerçek sonuçlarla karşılaştırarak değerlendirmektedir.

Bu değerlendirme, hata terimlerinin incelenmesiyle gerçekleştirilmektedir. Bir hata terimi, öngörü ile gerçek sonuç arasındaki farktır. Bir hata değerlendirmesine dayanarak, tahminler model girdilerinin ayarlanması ile sürekli güncellenmektedirler. Yapay zeka teknikleri ve ortaya çıkan bilgi teknolojileri, tahminlerin doğruluğunu arttırmak için kullanılmakta ve bu sayede sonuçların artmasına olumlu katkıda bulunmaktadır. Zaman içinde, ekonomik krizi analiz etmek için öngörücü modeller iki ana sorunu ortaya çıkarmıştır: İstatistiksel veri analizi sonucunda tahminlerin doğruluğu ve ekonomik modellerin açıklayıcı gücü;

2.5.ZAMAN SERİSİ TAHMİNİ

Zaman serisi tahmini zordur. Sınıflandırma ve dönüşün daha basit problemlerinden farklı olarak, zaman serisi problemleri gözlemler arasındaki düzenin veya zamansal bağımlılığın karmaşıklığını arttırmaktadır. Modellerin takılması ve değerlendirilmesi sırasında verilerin özel olarak ele alınması gerektiğinden bu zor olabilmektedir. Bu zamansal yapı, model becerisini geliştirmek için kullanılabilir trendler ve mevsimsellik gibi ek yapı sağlayarak modellemeye de yardımcı

olabilmektedir. Geleneksel olarak, zaman serisi tahminine ARIMA gibi doğrusal yöntemler hakimdir. Çünkü birçok problem üzerinde iyi anlaşılır ve etkilidirler (Gamboa, 2017)


Makine öğrenimi ve derin öğrenme yöntemlerinin genellikle tüm öngörücü modelleme sorunlarına anahtar çözüm olduğu bildirilmektedir. Son zamanlarda yapılan önemli bir çalışma, birçok klasik ve modern makine öğrenimi ve derin öğrenme yönteminin performansını, 1000'den fazla tek değişkenli zaman serisi tahmin probleminde büyük ve çeşitli bir dizi üzerinde değerlendirmiş ve karşılaştırmıştır. Bu çalışmanın sonuçları, doğrusal yöntemler ve üstel yumuşatma gibi basit klasik yöntemlerin, karar ağaçları, Çok Katmanlı Algılayıcılar (MLP) ve Uzun Kısa Süreli Bellek (LSTM) ağ modelleri gibi karmaşık ve karmaşık yöntemlerden daha iyi performans göstermektedir. Bu bulgular, ek karmaşıklıklarının tahminlere beceri kazandığını göstermek için, zamana dayalı tahminler için herhangi bir makine öğrenimi ve derin öğrenme yöntemini değerlendirirken hem klasik yöntemleri değerlendirme hem de sonuçlarını temel olarak kullanma gereğini vurgulamaktadır (Makridakis ve diğ., 2018).

2.5.1. Zaman Serisi İçin Çok Katmanlı Algılayıcılar

Çok katmanlı bir algılayıcı (MLP), karmaşık sorunları çözmek için çeşitli katmanlarda istiflenmiş ek algılayıcılarla bir araya gelen bir algılayıcıdır. Aşağıdaki semada üç katmanlı bir MLP gösterilmektedir. Soldaki ilk katmandaki (giriş katmanı) her algılayıcı, ikinci katmandaki (gizli katman) tüm algılayıcılara çıktılar göndermekte ve

ikinci katmandaki tüm algılayıcılar, sağdaki son katmana (çıkıktı katman) çıktıları göndermektedir. Her sinyal için, algılayıcı farklı ağırlıklar kullanmaktadır.

Şekil 2.6. Üç katmanlı bir MLP sinir ağı yapısı.



Kaynak: (Al-Fattah ve Al-Naim, 2009: s 37)

Yukarıdaki şemada, bir katmandaki bir algılayıcıdan bir sonraki katmana giden her çizgi farklı bir çıktıyı temsil etmektedir. Her katman çok sayıda algılayıcıya sahip olabilmekte ve birden fazla katman olabilmektedir. Bu nedenle çok katmanlı algılayıcı hızla çok karmaşık bir sistem haline gelebilmektedir. Çok katmanlı algılayıcının başka, daha yaygın bir adı vardır - sinir ağı. Yukarıdaki şekilde olduğu gibi üç katmanlı bir MLP, Derin Olmayan veya Sığ Sinir Ağı olarak adlandırılmaktadır. Dört veya daha fazla katmana sahip bir MLP'ye Derin Sinir Ağı denmektedir. Bir MLP ve bir sinir ağı arasındaki bir fark, klasik algılamada karar fonksiyonunun bir adım fonksiyonu olması ve çıktının ikili olmasıdır. MLP'lerden evrilen sinir ağlarında, genellikle 0 ile 1 veya -1 ile 1

arasında gerçek değerlerin çıkışıyla sonuçlanan başka aktivasyon fonksiyonları kullanılabilir. Bu, öğelerin olasılık temelli tahminlere veya birden çok etikette sınıflandırılmasına olanak tanımaktadır.

Gizli bir katmanı olmayan bir algılayıcı modeli sadece doğrusal olarak ayrılabilir bir problemle uğraşırken etkilidir (Tan, 2001). Bu sınırlamanın üstesinden gelmek için (doğrusal olmayan sorunları ele almak) MLP kullanılmaktadır. Çok katmanlı, gizli katman(lar) olarak bilinen ek katmanları hesaba katması bakımından bir algılayıcı modelinden farklıdır. Çok katmanlı algılayıcı, çok katmanlı ileri beslemeli ağ olarak da bilinmektedir. Yoğun bir alanda tanımlanan sürekli bir işlev için, altta yatan aktivasyon fonksiyonuna bakılmaksızın, tek bir gizli katman ileri beslemesi yaklaşık olarak hesaplanabilmektedir (Hornik ve ark. 1989). Çok Katmanlı bir algılayıcı, yalnızca bir girdi katmanı ve bir çıktı katmanı alma özelliğine sahiptir. Bununla birlikte, MLP, öğrenme algoritmasına veya modellenecek temel olguya bağlı olarak birden fazla gizli katman alabilmektedir. Giriş katmanı hariç, her katmandaki her nöron, alınan giriş bilgilerinin toplamını hesaplamakta ve çıktı olarak aktivasyona bağlı olarak ölçeklendirilmiş bir gerçek değer vermektedir ([0,1] veya [-1,1] aralığında olabilir).

Çok Katmanlı Algılayıcı veya MLP gibi daha basit sinir ağları, giriş değişkenlerinden çıkış değişkenlerine bir haritalama fonksiyonuna yakındır. Bu genel yetenek zaman serisi için birkaç nedenden dolayı değerlidir.

- Gürültüye Sağlam: Sinir ağıları giriş verilerinde ve haritalama fonksiyonunda gürültüye karşı dayanıklıdır ve hatta eksik değerlerin varlığında öğrenmeyi ve tahmini bile destekleyebilmektedir.
- Doğrusal Olmayan: Sinir ağıları haritalama işlevi hakkında güçlü varsayımlar yapmaz ve doğrusal ve doğrusal olmayan ilişkileri kolayca öğrenmektedir (Dorffner, 1996).

Yalnızca bu yetenekler için, ileri beslemeli sinir ağıları zaman serisi tahmini için yararlı olabilmektedir. Sinir ağlarının kullanımında örtük olmak, girdilerden çıktılara öğrenmek için gerçekten anlamlı bir eşleme olması şarttır. Rastgele bir yürüyüşün eşlenmesinin modellenmesi bir kalıcılık modelinden daha iyi sonuç vermeyecektir (örneğin, son görülen gözlemin tahmin olarak kullanılması). Öğrenilebilir bir haritalama işlevinin bu beklentisi de sınırlamalardan birini netleştirir: Haritalama işlevi sabit veya statiktir (Sutskever ve diğ., 2014)

Tek değişkenli bir seri modellenmeden önce hazırlanmalıdır. MLP modeli, geçmiş gözlemlerin bir dizisini çıktı gözlemine girdi olarak eşleyen bir işlevi öğrenecektir. MLP'ler, gecikme gözlemleri adı verilen önceki zaman adımlarında çoklu gözlemler olarak ve bunları girdi özellikleri olarak kullanarak ve bu gözlemlerden bir veya daha fazla zaman adımını tahmin ederek zaman serisi tahmini için kullanılabilir. Basit bir MLP modelinde tek bir gizli düğüm katmanı ve bir öngörü yapmak için kullanılan çıkış katmanı bulunmaktadır.


2.5.2. Zaman Serileri İçin Evrimsel Sinir Ağları

Evrimsel Sinir Ağları veya CNN'ler, görüntü verilerini verimli bir şekilde işlemek için tasarlanmış bir tür sinir ağıdır. Hem görüntü sınıflandırması gibi görevlerde son teknoloji sonuçlar elde etmek hem de nesne yerelleştirme, görüntü altyazısı ve daha fazlası gibi tamamen yeni problemler için hibrit modellerde bir bileşen sağlamak için zorlu bilgisayar görme problemleri üzerinde etkili olduklarını kanıtlamışlardır. Bunu, ham verilerden elde edilen alana özgü veya el işi özellikler yerine doğrudan ham piksel değerleri gibi ham veriler üzerinde çalışarak başarmaktadırlar. Daha sonra model, ele alınan sorun için doğrudan yararlı olan ham verilerden özelliklerin otomatik olarak nasıl çıkarılacağını öğrenmektedir. Evrimsel ağlar, bir dereceye kadar kayma ve bozulma değişmezliği sağlamak için üç mimari fikri birleştirir: Yerel alıcı alanlar, paylaşılan ağırlıklar (veya ağırlık replikasyonu) ve bazen uzamsal veya zamansal alt örnekleme (LeCun ve diğ., 2015).

CNN'ler zaman serisi tahmini için Çok Katmanlı Algılayıcıların avantajlarından yararlanmakta, yani çok değişkenli girdi, çok değişkenli çıktı ancak karmaşık fonksiyonel ilişkiler öğrenmeyi desteklemektedir ancak modelin gecikme gözlemlerinden doğrudan öğrenmesini gerektirmemektedir. Bunun yerine, model, tahmin problemiyle en alakalı olan büyük bir girdi dizisinden bir temsili öğrenebilmektedir. İki boyutlu görüntü verileri için geleneksel olarak geliştirilmiş olmasına rağmen, CNN'ler tek değişkenli zaman serisi tahmin problemlerini modellemek için kullanılabilirler. Tek değişkenli zaman serileri, geçici sıralı tek bir dizi gözlemden oluşan veri kümeleridir ve dizideki bir sonraki değeri tahmin etmek için geçmiş gözlem serisinden bir model öğrenmek gerekmektedir.

CNN modeli, geçmiş gözlemlerin bir dizisini çıktı gözlemine girdi olarak eşleyen bir işlevi öğrenecektir.

Şekil 2.7. Evrimsel Sinir Ağı yapısı.



Kaynak: <https://aryamccarthy.github.io/images/borovykh2017conditional-dilated.png>

CNN'lerin ham girdi verilerinden özellikleri otomatik olarak öğrenme ve çıkarma yeteneği zaman serisi tahmin problemlerine uygulanabilmektedir. Bir dizi gözlem, bir CNN modelinin okuyabileceği ve en belirgin unsurlara damıtılabileceği tek boyutlu bir görüntü gibi ele alınabilmektedir.

CNN'lerin bu yeteneğinin, fitness cihazlarından ve akıllı telefonlardan gelen ham hızlandırıcı sensör verilerine dayalı olarak insan aktivitelerini otomatik olarak tespit etmek gibi zaman serisi sınıflandırma görevleri üzerinde büyük etkisi olduğu gösterilmiştir. CNN'lerin Aktif tanıma için temel avantajları şunlardır:

- i) Özellik çıkarma, göreve bağlı ve el yapımı olmayan şekillerde gerçekleştirilmektedir.
- ii) Çıkarılan özelliklerin insan faaliyetlerine göre sınıfları;
- iii) Özellik çıkarma ve sınıflandırma tek bir modelde birleştirilmekte ve böylece performansları karşılıklı olarak artmaktadır (Ji ve diğ., 2012).

2.5.3. *Tekrarlayan Sinir Ağı*

Tekrarlayan Sinir Ağı (RNN), önceki adımdaki çıktının geçerli adıma girdi olarak beslendiği bir Sinir Ağı türüdür. Geleneksel sinir ağlarında, tüm girdiler ve çıktılar birbirinden bağımsızdır ancak bir cümlenin bir sonraki kelimesinin tahmin edilmesi gerektiği gibi durumlarda, önceki kelimeler gereklidir ve bu nedenle önceki kelimeleri hatırlamaya ihtiyaç vardır. Böylece Gizli Katman yardımıyla bu sorunu çözen RNN ortaya çıkmıştır. RNN'nin ana ve en önemli özelliği, bir dizi hakkında bazı bilgileri hatırlayan Gizli durumudur. RNN, hesaplananla ilgili tüm bilgileri hatırlayan bir “belleğe” sahiptir. Çıktıyı üretmek için tüm girdilerde veya gizli katmanlarda aynı görevi gerçekleştirdiğinden, her girdi için aynı parametreleri kullanmaktadır. Bu, diğer sinir ağlarının aksine parametrelerin karmaşıklığını azaltmaktadır.

Günümüzde farklı veri türlerini işlemek için farklı Makine Öğrenimi teknikleri kullanılmaktadır. İşlenmesi ve tahmin edilmesi en zor veri türlerinden biri sıralı verilerdir. Sıralı veriler, tipik bir veri kümesinin tüm özelliklerinin sıradan bağımsız olduğu varsayılabilirken, bunun sıralı bir veri kümesi için varsayılmayacağı anlamında diğer veri türlerinden farklıdır. Bu tür verileri ele almak için Tekrarlayan Sinir Ağları kavramı

tasarlanmıştır. Yapısındaki diğer Yapay Sinir Ağlarından farklıdır. Diğer ağlar, ileri besleme işlemi veya geri yayılma işlemi sırasında doğrusal bir yönde "yolculuk" yaparken, Tekrarlayan Ağ, ileri besleme geçişi yerine bir yineleme ilişkisini izler ve öğrenmek için zaman içinde Geri Yayılım'ı kullanmaktadır.

Tekrarlayan Sinir Ağı, her zaman adımı için bir tane olmak üzere birden fazla sabit aktivasyon fonksiyon ünitesinden oluşmaktadır. Her birimin, birimin gizli durumu olarak adlandırılan bir iç durumu vardır. Bu gizli durum, ağın belirli bir zaman adımında sahip olduğu geçmiş bilgileri göstermektedir. Bu gizli durum, ağın geçmiş hakkındaki bilgisindeki değişikliği belirtmek için her adımda güncellenmektedir. Gizli durum aşağıdaki yineleme ilişkisi kullanılarak güncellenmektedir: -

$$h_t = f_w(x_t, h_{t-1}) \quad (2.5)$$

h_t yeni gizli durum olduğunda; h_{t-1} eski gizli durumdur; x_t geçerli giriştir; ve f_w , eğitilebilir ağırlıklarına sahip sabit bir fonksiyondur. Temel Tekrarlayan Sinir Ağı oldukça etkili olmasına rağmen, önemli bir sorundan muzdarip olabilmektedir. Derin ağlar için Geri Yayılma işlemi aşağıdaki sorunlara yol açabilir: -

Yok Olan Degradeler (Vanishing Gradients): Bu, degradeler çok küçük olduğunda ve sifıra doğru eğilim gösterdiğinde ortaya çıkmaktadır.

Patlayan Degradeler (Exploding Gradients): Bu, degradeler geri yayılma nedeniyle çok büyük olduğunda ortaya çıkmaktadır.

Degradeleri Patlatma sorunu bir hack kullanılarak çözülebilmektedir. - Zamanda geri gönderilen degradelere bir eşik koyarak- Ancak bu çözüm, soruna bir çözüm olarak görülmez ve ağın verimliliğini de düşürebilmektedir. Bu tür sorunlarla başa çıkmak için, Tekrarlayan Sinir Ağlarının iki ana çeşidi geliştirilmiştir - Uzun Kısa Süreli Bellek Ağları ve Geçitli Tekrarlanan Birim Ağları.

2.5.4. Zaman Serisi İçin Uzun Kısa Süreli Bellek

Uzun Kısa Süreli Bellek veya LSTM ağı, RNN'lerin kararlı bir modelle sonuçlanan dizi verileri üzerinde eğitilmesindeki genel zorlukları ele alan bir RNN türüdür. Bunu, her bir düğüm içindeki tekrarlayan bağlantıları kontrol eden iç kapılar için ağırlıkları öğrenerek başarmaktadır. Dizi verileri için geliştirilmiş olmasına rağmen, LSTM'lerin, çıktının son gözlemlerin bir fonksiyonu olduğu zaman serisi tahmin problemleri üzerinde etkili olduğu kanıtlanmamıştır.

Uzun Kısa Süreli Bellek ağı veya LSTM gibi tekrarlayan sinir ağları, MLP'ler veya CNN'ler tarafından sunulmayan girdilerden çıktılara bir eşleme işlevi öğrenirken gözlemler arasında açık bir şekilde işlem yapılmasını eklemektedir. Bunlar, gözlem dizilerinden oluşan girdi verileri için yerel destek ekleyen bir sinir ağı türüdür. Dizinin eklenmesi, yaklaşmakta olan işleve yeni bir boyuttur. Girişleri sadece çıkışlarla eşlemek yerine, ağ zaman içinde bir çıkışla girişler için bir eşleme fonksiyonu öğrenebilmektedir.

Derin Tekrarlayan Bir Sinir Ağında Degradelerin Yok Olması ve Patlatılması sorununu çözmek için birçok varyasyon geliştirilmiştir. Bunlardan en ünlülerinden biri Uzun Kısa Süreli Bellek Ağıdır (LSTM). Kavram olarak, bir LSTM tekrarlayan birim,

ağın şimdiye kadar gördüğü tüm bilgileri “hatırlamaya” ve alakasız verileri “unutmaya” çalışmaktadır. Bu, farklı amaçlar için "kapılar" olarak adlandırılan farklı aktivasyon fonksiyon katmanları eklenerek yapılmaktadır. Her LSTM tekrarlayan birim, aynı zamanda, önceki LSTM tekrarlayan birim tarafından tutulması için seçilen bilgileri kavramsal olarak açıklayan Dahili Hücre Durumu adı verilen bir vektörü de muhafaza etmektedir. Uzun Kısa Süreli Bellek Ağı, aşağıda açıklanan farklı amaçlar için dört farklı kapıdan oluşmaktadır:

2.5.4.1. Kapıyı unut (Forget Gate (f)):

LSTM'lerin kendisini sıfırlamanın etkili bir yolunun bulunmaması, ağa unutmaya girişini getirerek çözülmüştür (Gers ve diğ., 1999). Unutmaya kapısı, x_t girişinden ve son çıkış olan h_{t-1} 'den ne kadar bilgi tutulacağını söylemektedir. 1 her şeye tutunmakta ve 0 her şeyi unutmaktadır. Önceki verilerin ne ölçüde unutulacağını belirlemektedir.

2.5.4.2. Giriş Kapısı (Input Gate (i)):

Giriş kapısı, hücre durumunda saklanması gereken bilgilerin ne kadar olduğunu belirtmekte ve hücrenin gereksiz verileri depolamasını önlemektedir. Dahili Hücre Durumu üzerine yazılacak bilginin kapsamını belirlemektedir.

2.5.4.3. Giriş Modülasyon Kapısı (Input Modulation Gate (g)):


Genellikle giriş kapısının bir alt parçası olarak kabul edilmekte ve LSTM'lerdeki birçok literatür bundan bahsetmez bile ve Giriş kapısının içinde olduğunu varsaymaktadır. Giriş kapısının, Bilgiye doğrusallık ekleyerek ve bilgiyi Sıfır-orta yaparak, Dahili Hücre Durumuna yazacağı bilgileri modüle etmek için kullanılmaktadır. Sıfır-orta girdisi daha

hızlı yakınsaklığa sahip olduğundan öğrenme süresini azaltmak için yapılmaktadır. Bu kapının eylemleri diğerlerinden daha az önemli olmasına ve genellikle incelik sağlayan bir kavram olarak görülmesine rağmen, bu kapıyı LSTM biriminin yapısına dahil etmek iyi bir uygulamadır.

2.5.4.4. Çıkış Kapısı (Output Gate (o)):

Son olarak çıkış kapısı, bellek hücresindeki içeriğin ne kadarının blok çıktısına maruz kalacağına karar vermektedir. Geçerli Dahili Hücre Durumundan hangi çıkışın (bir sonraki Gizli Durum) üretileceğini belirlemektedir. Uzun Kısa Süreli Bellek Ağının temel iş akışı, Tekrarlayan Sinir Ağının iş akışına benzemektedir ve tek fark Dahili Hücre Durumunun Gizli Durum ile birlikte ileriye doğru iletilmesidir.

Şekil 2.8. Uzun Kısa Süreli Bellek Sinir Ağı yapısı



Kaynak: <https://lilianweng.github.io/lil-log/2017/07/08/predict-stock-prices-using-RNN-part-1.html>

2.6.TEK DEĞİŞKENLİ LSTM MODELLERİ

LSTM sinir ağı, tek deęişkenli zaman serisi tahmini için kullanılabilir. Bir RNN olarak, bir giriş dizisinin her bir zaman adımını birer birer okuyacaktır. LSTM, belirli bir giriş dizisinin adımları boyunca okurken dahili durumu biriktirmesine izin veren dahili bir belleęe sahiptir. Dizinin sonunda, gizli LSTM birimleri katmanındaki her düęüm tek bir deęer verecektir. Bu deęerler vektörü, LSTM'nin giriş dizisinden öğrendiklerini veya çıkardıklarını özetlemektedirler. CNN gibi, LSTM her zaman adımında birden çok deęişkeni veya özellięi destekleyebilir. LSTM'ler, tek deęişkenli zaman serisi tahmin problemlerini modellemek için kullanılabilirler. Bunlar tek bir gözlem serisinden oluşan problemlerdir ve dizideki bir sonraki deęeri tahmin etmek için geçmiş gözlem serisinden bir model öğrenmek gerekmektedir.

Dizi verilerini adım adım okumayan MLP ve CNN'den farklı olarak, veriler sabitse LSTM daha iyi performans göstermektedir. Bu, trend ve mevsimsel yapıyı ortadan kaldırmak için fark operasyonlarının yapıldığı anlamına gelmektedir. Tek deęişkenli bir seri modellenmeden önce hazırlanmalıdır. LSTM modeli, geçmiş gözlemlerin bir dizisini çıktı gözlemine girdi olarak eşleyen bir işlevi öğrenecektir. Bu nedenle, gözlem dizisi, LSTM'nin öğrenebileceęi çok sayıda örneęe dönüştürülmelidir.

ÜÇÜNCÜ BÖLÜM

YAPAY SİNİR AĞLARI İLE BORSA ENDEKSİ TAHMİNİ: GANA BORSASI ÜZERİNE BİR UYGULAMA

Bu bölümde yapay sinir ağlarının yanı sıra finansal ekonomideki yapay sinir ağları gözden geçirilecek ve son olarak da yapay sinir ağları kullanarak çeşitli borsa getirilerinin tahminleri üzerine bazı ampirik literatürü gözden geçirilecektir.

3.1. YAPAY SİNİR AĞLARI İLE TAHMİNLERİ

Sinir ağları, son yıllarda hisse senedi fiyatlarının hesaplanmasına ve tahminine kapsamlı bir şekilde uygulanmıştır. Tsai ve diğ. (1999), örneğin, çeşitli teknik endeksleri entegre ederek ve sinir ağlarına dayalı bir stok tahmin modeli oluşturarak yatırım için en iyi zamanlamayı tahmin etmeye çalışmışlardır. Sonuç olarak, sinir ağı ve stop-loss stratejilerinin çapraz kullanımı sayesinde, hisse senedi alımı için en iyi zamanlamayı etkili bir şekilde tahmin edebilmekte ve yatırımdan daha iyi getiri elde edebilmektedir. Ma (2003), Tayvan'ın borsalarına yaptığı simüle yatırımında bulanık sinir ağı teknolojisini de uygulamıştır. Ampirik çalışmasında girdi değişkenleri olarak Tayvan Genel Endeksi'nin genel teknik endekslerini kullanmıştır. Daha sonra sonuçları sadece 12 günlük hareketli ortalamanın gerçek sonuçlarıyla karşılaştırmıştır. Keşif, bulanık sinir ağı yaklaşımını benimseyerek, sadece hareketli ortalama yaklaşımı kullanıldığında daha olası olan hile hatlarının yanıltıcı etkisinden kaçınılabilecek olmasıydı. Yatırım getirisi de, alış-satış stratejisi veya geleneksel hareketli ortalama stratejisi ile elde edilen getiriden önemli ölçüde daha iyidir. Lee (2003), Tayvan Hisse Senedi Endeksi Vadeli Gecelik kapanış

endekslerini tahmin etme ve en uygun tahmin modelini belirleme çabalarında, 21 Aralık 2000 - 18 Aralık 2002 örneklerinden itibaren Tayvan Ağırlıklı Endeksinin günlük bilgilerini kullanarak sinir ağını ve regresyon analizinin istatistiksel yaklaşımını uygulamıştır. Wu (2004) işlem hacmine, işlem fiyatına ve Genel Endeks'in teknik endekslerine dayanarak hisse senedi fiyatı araştırması için Geri Yayılım Sinir ağını (BPN) benimsemiştir. Sonuç, çapraz MACD (Hareketli Ortalama Yakınsama ve Iraksama) uygulanarak alınan yatırım getirisinin, sadece bireysel teknik endeksleri kullanmanın getirisinden daha iyi olduğunu göstermektedir. Sinir ağı yoluyla Kimoto ve ark. (1990) da tahmin modellerini Nikkei Stock Price Index'e göre oluşturmuşlardır.

Modelin Japon hisse senedi fiyatını tahmin etmede etkili olduğu ortaya çıkmış ve aşırı yatırım getirisine katkıda bulunmuştur. Fernandez-Rodríguez ve diğ. (2000) BPN'yi Madrid Menkul Kıymetler Borsası Genel Endeksleri için tahmin modelini oluşturmak üzere kullanmışlardır. Ampirik çalışmasının sonucu, modelin Madrid Menkul Kıymetler Borsası Genel Endeksleri için etkili bir tahmin modeli olduğunu ve daha iyi yatırım getirileri elde edilmesine yardımcı olduğunu göstermiştir. Bengoechea ve diğ. (1996), araştırmalarında, San Diego Hisse Senedi'nin sinir ağı yaklaşımı yoluyla gecelik kapanış endekslerini tahmin etmeye çalışırken, Santiago Borsası'nın 240 günlük ticaret bilgilerini numune olarak ve önceki 10 günün endekslerini ve işlem hacmini girdi verileri olarak kullanmışlardır. Sonuç, sinir ağı yaklaşımı ile borsadaki yükselen aralıktaki yönleri tahmin etmede % 63.3'lük bir doğruluk oranı elde ettiğini göstermiş ve düşme aralığında % 74.7 doğruluk oranı çıkmıştır.

3.1.1. Yapay Sinir Ağı ve Döviz Kurları

Döviz piyasası bugüne kadar en büyük finansal piyasadır. Döviz kurlarındaki hareketleri doğru bir şekilde tahmin edebilen büyük çok uluslu şirketler, toplam kârlılıkta önemli iyileşmeler sağlayabilmektedirler. Teorik döviz kuru belirleme modellerinin tahmin yeteneği çok zayıf kalmıştır. Geleneksel ekonometrik modellerin çoğu, naif rastgele yürüyüş modelinden ve lineer modellerden önemli ölçüde daha yüksek doğrulukta döviz kurları tahmin edemediğinden, döviz hareketlerini önceden belirlemek her zaman sorunlu bir iş olmuştur (Sarantis ve Stewart, 1995).

Yapay Sinir Ağı, sadece örnek dışı tahminlerde değil, aynı zamanda kısa vadeli döviz kurundaki değişimin yönünü öngörme durumunda da güçlüdür (Zhang ve Hu, 1998). Dolayısıyla, YSA'nın kısa vadeli para birimi davranışına uygulanması birçok durumda başarılı olmuştur. Bellgard ve Goldschmidt (1999), Avustralya Doları ile ABD Doları (AUD / USD) bazında tekrarlayan sinir ağı (RNN) modelleri olan rastgele yürüyüş, üssel düzeltme ve ARIMA modelleri dahil olmak üzere 1996 yılında yarım saatlik döviz kuru verileri kullanılarak birçok geleneksel tekniğin tahmin doğruluğunu ve alım satım performansını incelemişlerdir.

Yao ve diğ. (1996), GBP, JPY, CHF ve AUD'nın USD karşısında tahmin edilebilirliğini 1984-1995 arasında haftalık verileri kullanarak ve bir ARIMA modelini referans alarak ANN modellerinin ARIMA modellerinden daha yüksek getiri sağladıkları sonucuna varmışlardır. GRNN'in performansı, İngiliz Sterlini, Kanada Doları ve Japon

Yeni'nin aylık döviz kurlarını tahmin etmede diğer sinir ağı ve ekonometrik tekniklerden daha iyidir (Leung ve diğ., 2000).

3.1.2. Kredi Riski İçin İflas Tahmini

Son kriz ile erken kriz modellerinin, bankacılık krizlerini tahmin etmede ve bireysel bankaların sağlamlığını değerlendirmede önemli olduğu sonucuna varılmıştır. Kredi uygulamaları iyi uygulamalar ve kötü uygulamalar olarak sınıflandırılabilir ve iflasların tahmini sınıflandırma sorunları ile ilişkilendirilmektedir. Bankalar, sinir ağlarını, iflas olasılıklarını tahmin eden kredi ve kredi uygulamalarını taramak için kullanmaktadırlar.

3.1.3. Yapay Sinir Ağı ile Finansal Kriz Tahmini

Gelişmekte olan ülkelerde 20. yüzyılın son on yılında, gelişmiş ülkelerde ise 21. yüzyılın ilk on yılında meydana gelen finansal krizler, bir finansal krizin oluşumunu zamanında gösterebilecek istatistik ve ekonometrik modeller geliştirmek için konuyla ilgili teorik ve ampirik ilginin artmasına neden olmuştur. Bu istatistiksel ve ekonometrik modeller, finansal krizlerin olasılığını iç ve dış faktörlerin yanı sıra sosyal ve politik koşullarla ilgili çok sayıda göstergeler kullanarak tahmin etmek için uygulanmaktadırlar (Frankel ve Rose, 1996). Malezya, Tayland ve Endonezya para birimi krizlerini tahmin etmedeki performansını test etmek için sinyal yaklaşımı olan KLR'den daha iyi bir yaklaşım olan YSA modeli kullanmışlardır. (Nag ve Mitra, 1999). Doğu Asya ülkelerinden gelen verileri kullanarak, optimize edilmiş bir YSA, özellikle 90'lı yılların sonlarında Rusya ve Brezilya'yı vuran para birimi krizlerinin sinyalini vermek amacıyla,

döviz krizlerini tahmin etmede logit'ten daha iyi bir sonuç elde etmiştir (Franck ve Schmied, 2004). İyi gelişmiş bir YSA zamanında sinyal krizleri bölümlerinde hem parametrik hem de parametrik olmayan geleneksel yöntemlerden daha iyi performans gösterebilmektedir.

3.1.4. Yapay Sinir Ağına Dayalı Stok Tahmini

Yapay Sinir Ağı, borsa tahmininde ve analizinde kullanıldığında, iyi hata toleransı, büyük ve karmaşık bilgilerin ele alınması ve tatmin edici tahmin sonuçları nedeniyle güvenilir bir araç olduğunu kanıtlamıştır. Yapay sinir ağlarına uyan belirli bir stoğu açıklamak için genellikle çok sayıda etkileşimli giriş serisi gerekmektedir. Her bir nöron, bir pazar katılımcısının karar sürecini temsil etmektedir. Bu nedenle bir sinir ağı, piyasadaki tüm katılımcılar arasındaki etkileşimli kararları temsil etmektedir. Böylece bir sinir ağı, finansal piyasaların kendi başlarına eksiksiz bir tanımıdır (Zimmermann ve diğ., 2002). Bu nedenle, yalnızca karar alma zamanından tasarruf etmekle kalmaz, aynı zamanda küçük yatırımcıların risk ve zararı azaltmalarına yardımcı olur. Lin ve Yu (2009), YSA tahminlerini basit bir satın alma stratejisine karşı basit bir ticaret stratejisine dönüştürmüş ve Tayvan Ağırlıklı Endeksini ve S&P 500'ü ABD için analiz etmiştir. Sonuç olarak, YSA'ya dayanan ticaret kuralının alım-satım stratejisinden daha yüksek getiri sağladığını bulmuşlardır. YSA modelleri, stok fiyat performansını, gelecekteki tahvillerin faizlerini ve Standard ve Poor'un 500 endeks vadeli işlemlerini öngörmede diskriminant analizinden daha iyi performans göstermiştir (Trippi ve DeSieno, 1992).

Londra, New York, Tokyo ve Toronto'daki hisse senedi endekslerinden elde edilen verileri kullanarak, hisse senedi getirisi verilerindeki fat tail'in ve heteroskedastisitesini inceleyerek ENN modelleri, leptokurtosis ve kemik erimesini gidermek için otoregresif şartlı heteroskedastisite (ARCH) modelini de içeren birçok geleneksel modelden daha iyi performans göstermişlerdir (Donaldson ve diğ., 1993).

3.2. AMPİRİK LİTERATÜR

Son finans literatüründe, borsa hareketlerini ve getirileri tahmin etmek için çeşitli makine öğrenme algoritmaları uygulanmaktadır. Finansal zaman serilerini karakterize eden doğrusal olmamaları nedeniyle yapay sinir ağları (YSA) (Kayal, 2010; Vui ve diğ., 2013; ve Di Persio ve Honchar, 2016) ve Destek Vektör makineleri (SVM) (Sapankevych ve Sankar, 2009; ve Marković ve diğ., 2014) kullanılmıştır (Atsalakis ve Valavanis, 2009).

Martinez ve ark. (2009), günlük minimum ve maksimum hisse senedi fiyatları Çok Katmanlı Algılayıcı (MPL) kullanılarak tahmin edilmiştir. Hangi teknik göstergelerin tahmin için en önemli göstergeler olduğuna karar vermek amacıyla tüm teknik göstergeler ağ için girdi olarak kullanılmış ve daha sonra MLP sınıflandırma algoritması kullanılmıştır. Kayal (2010) da hareketli ortalamalar ve rastgele seçimle karşılaştırılan zaman gecikmeli standart sapmalar gibi en temel teknik göstergeleri kullanarak döviz piyasasını tahmin etmek için MPL kullanmıştır.

Guo ve ark. (2015) tarafından Shanghai Borsa endeksi üzerine gerçekleştirilen bir çalışmada, Ertesi gün için Shanghai Borsa endeksini tahmin etmek amacıyla Radyal Temel Fonksiyon Sinir Ağını (RBFNN) borsadaki farklı teknik değişkenleri eğitmek için

kullanmışlardır. Ayrıca, veri özellik kümesi boyutunu azaltmak için Temel Bileşen Analizi (PCA) kullanmışlardır. Marković ve diğ. (2014) ise, Belgrad borsa endeksinin (BELEX15) trend özellikli Destek Vektör Makinelerini kullanarak eğilimini tahmin etmişlerdir. Diğer bazı çalışmalar Karar ağaçları (DT) (Bastı ve diğ., 2015), Lojistik Regresyon (LR) (Dutta ve diğ., 2015), Naive Bayes (NB) (Gündüz ve Çataltepe, 2015) ve çeşitli borsaların endeksleri ve hisse senedi fiyatları ile ilgili Random Forest (RF) (Ballings ve diğ., 2015)'i kullanmışlardır.

Borsa İstanbul (BIST 100) üzerinde yapılan çalışmalar genellikle son zamanlarda tarihsel endeks fiyatlarını ve teknik göstergeleri kullanmaktadır. Bildirici ve Ersin (2009), BIST 100 endeksinin günlük getirilerini tahmin etmek için Otoregresif modeller ve Yapay Sinir Ağları'nın (YSA) bir kombinasyonunu uygulamışlardır. Boyacıoğlu ve Avcı (2010) BIST 100 endeksinin tahmini için Uyarlanabilir Nöro-Bulanık Çıkarım Sistemini (ANFIS) kullanmıştır. Yapay Sinir Ağları (YSA) ve Destek Vektör Makinelerini (SVM) sınıflandırıcılar olarak birleştiren bir çalışma, girdi olarak teknik göstergeleri kullanarak BIST 100 endeksinin yönünü öngörmüştür ve her iki sınıflandırıcının performansının tahmin sürecinde dikkate değer olduğu sonucuna varılmıştır. (Kara ve diğ., 2011).

Gündüz ve Çataltepe (2015), günlük BIST 100 endeksinin yönünü tahmin etmek için Naive Bayes (NB) algoritmasını kullanmıştır. Çalışmaları, gelecekteki piyasa hareketlerini tahmin etmek için Dengeli Karşılıklı Bilgi (BMI) adlı bir özellik seçme yöntemi kullanarak haber makalelerinin analizini önermişlerdir.

Pehlivanlı ve ark. (2016), ertesi gün fiyatını tahmin etmek amacıyla, filtre tabanlı özellik seçim yöntemlerini birleştirerek, SMV sınıflandırıcılarını eğiterek ve nihayetinde oylama şemasını uygulayarak, alakasız ve gereksiz sayılan göstergeleri veri kümesinden çıkarmışlardır. Daha sonra bu süreçlerin simülasyonu için Borsa İstanbul'dan alınan gerçek bir veri setinin yanı sıra teknik ve makroekonomik göstergeler kullanmışlardır. Sonuçlar, uygulanan özellik seçim yöntemlerinin bir sonucu olarak tahmin performansının iyileştiğini göstermektedir.

Peng ve Jiang (2015) Derin Sinir Ağlarını kullanarak stok hareketlerinin yönünü tahmin etmişlerdir. Çalışma ağında hem haberleri hem de fiyat verilerini kullanmışlardır. Derin sinir ağında sınıflandırmada 1024 gizli katman kullanmışlardır. Çalışma sonucunda, fiyat özelliklerine haber makalelerinden özellikler eklendiğinde tahmin performansında önemli bir iyileşme olduğunu bulmuşlardır.

Türkmen ve Cemgil (2015), NASDAQ Borsasında işlem gören hisse fiyatlarının yönünü araştırmak için denetimsiz derin öğrenme yapısı olan Stacked-Autoencoders (SAE) uygulamışlardır. Derin öğrenme modelinin girdileri, fiyat verilerinden hesaplanan teknik göstergelerdir. Model performansının doğruluk ve F-ölçü metriklerine göre değerlendirilmesi sonucunda Yığılmış-Otomatik Enkoderler (SAE) modelinin SMV yöntemiyle en iyi performansı verdiğini tespit etmişlerdir.

Chen ve diğ. (2015), Çin'in Hisse senedi getirilerini tahmin etmek için Uzun Kısa Süreli Bellek (LSTM) ağını uygulamışlardır. Çalışmada, Çin'in Borsa geçmiş verilerinden elde edilen 10 özelliğe sahip 30 günlük dizilerle iki boyutlu veri noktaları kullanmışlardır.

Ayrıca, 3 günlük kazanç oranı, veri noktaları için sınıf etiketi olarak kullanmışlardır. Sonuçlar, LSTM'nin rastgele tahmin modellerine kıyasla sınıflandırma performansını geliştirdiğini göstermektedir.

3.3.METODOLOJİ VE AMPİRİK UYGULAMA


Bu bölümde deneysel çerçeve, farklı derin öğrenme yöntemleri, veri setleri, öğrenme algoritmaları ve bu çalışmada kullanılan performans ölçütleri sunulmaktadır. Çalışma, Gana Borsası'nın bileşik endeksinin tahmini için aşağıdaki üç derin öğrenme yöntemini seçmiştir.

3.3.1. Derin öğrenme yöntemleri

Sabit zaman serilerini MLP ağları ile modellemenin geleneksel bir yolu Şekil 3.1'de sunulmaktadır. Ağa giriş vektörü, zaman serisinin geçmiş örneklerinden aşağıdaki gibi oluşur:

$$x = [x(n-1), x(n-2), \dots, x(n-p)]^T \quad (3.1)$$

Şekil 3.1. Zaman serilerinin tek adımlı öngörüsü olarak kullanılan MLP ağı

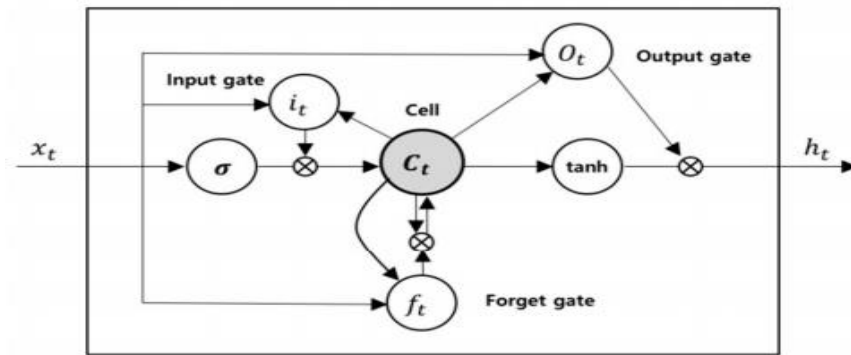


Kaynak:(Koskela ve ark. 1996)

Burada p parametresi tahmin sırasındır. MLP ağının skaler çıkışı $y(n)$ tek adımlı tahmine eşittir. Serinin gerçek değeri $x(n)$ istenen çıktıyı temsil etmektedir. Ağ, mekansal bir temsil vererek zamanı modellemeye çalışmaktadır. Buna rağmen, zamanla değişen dizilerle başa çıkamamaktadır. Daha iyi bir çözüm, zamanın ek girdi boyutuna göre temsil edilmesinden ziyade ağın tepkisi üzerinde etkili olmasını sağlamaktır (Koskela ve ark. 1996).

LSTM ağı, LSTM birimlerinden oluşan bir tür derin RNN modelidir. LSTM bloğu bir bellek hücresi ve üç çarpımsal geçitleme ünitesi içermektedir; bir girdi, bir çıktı ve bir unutmama kapısı. Hücreler arasında tekrarlayan bağlantılar vardır ve her geçit hücreler için sürekli işlemler sağlamaktadır. Hücre, “durum” değerlerinin keyfi zaman aralıklarıyla iletilmesinden sorumludur ve her kapı hücreler için yazma, okuma ve sıfırlama işlemlerini yürütmektedir (Goodfellow ve ark., 2016).

Şekil 3.2. Geçitleme birimleriyle birlikte LSTM hücresi



Kaynak: (Chung ve Shin 2018: s 7).

Bir LSTM bloğu içindeki hesaplama süreci aşağıdaki gibidir: Giriş değeri, yalnızca giriş kapısı izin veriyorsa hücrenin durumunda korunabilmektedir. i_t 'nin giriş

değeri ve bellek hücrelerinin aday değeri olan \tilde{C}_t , t zaman adımında aşağıdaki gibi hesaplanmaktadır (Chung ve Shin 2018):

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i), \quad (3.2)$$

$$\tilde{C}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c), \quad (3.3)$$

burada W , U , b sırasıyla ağırlık matrislerini ve sapmasını temsil etmektedir.

Durum(state) biriminin ağırlığı unutmaya kapısı tarafından yönetilmekte ve unutmaya kapısının değeri şu şekilde hesaplanmaktadır (Chung ve Shin 2018):

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f). \quad (3.4)$$

Bu işlem sayesinde bellek hücresinin yeni durumu şu şekilde güncellenmektedir (Chung ve Shin 2018):

$$C_t = i_t \times \tilde{C}_t + f_t \times C_{t-1}. \quad (3.5)$$

Bellek hücresinin yeni durumu ile geçidin çıkış değeri aşağıdaki gibi hesaplanmaktadır (Chung ve Shin 2018):

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + V_o C_t + b_o). \quad (3.6)$$

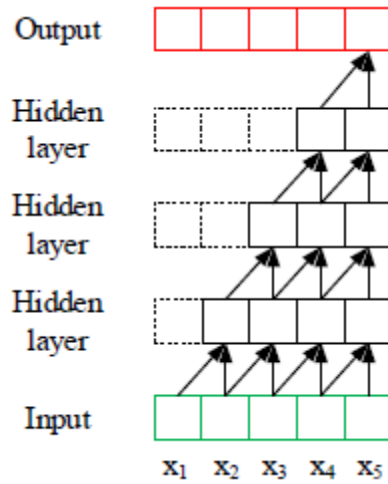
Hücrenin son çıkış değeri şu şekilde tanımlanmaktadır (Chung ve Shin 2018):

$$h_t = o_t \times \tanh(C_t). \quad (3.7)$$

Hücrenin çıkışı çıkış kapısı tarafından bloke edilebilmekte ve tüm kapılar sigmoidal doğrusal olmayanlık kullanmakta ve durum birimi diğer kapı ünitelerine ekstra giriş olarak çalışabilmektedir (Hochreiter ve Schmidhuber, 1997). Bu süreç sayesinde LSTM mimarisi, küçük hesaplama maliyetlerinde uzun vadeli bağımlılıklar sorununu çözebilmektedir (Kim ve diğ., 2018).

Son zamanlarda, dizi modelleme görevleri üzerinde kıvrımlı ve tekrarlayan mimari ile öngörücü bir dizi modeli için genel bir mimari olan Temporal Convolution Network (Geçici Evrişim Ağı) (Bai ve diğ., 2018) önerilmektedir. Geçici Evrişim Ağı nedensel evrişim kullanmakta, burada t zamanındaki bir çıktı yalnızca bir önceki katmandaki t ve önceki zamanlardaki elemanlarla kıvrılmaktadır. Şekil 4.3'te, tüm verilerin kronolojik sırada bire bir nedensel ilişkiye sahip olması gerektiğini varsaymak için nedensel evrişim kullanılmaktadır. Bir giriş dizisi zaman serisi sinyali verildiğinde $X = (x_1, x_2, x_3, x_4, x_5)$.

Şekil 3.3. Geçici Evrişim Ağı görselleştirilmesi



Kaynak: (Wan ve ark. 2019: p 6)

3.3.2. *Deneyisel çerçeve*

Bu tezde kullanılan modeller, NVIDIA GPU Hesaplama Araç Seti 10.1 GPU'yu destekleyen bir Intel® Core™ i7-4720HQ CPU @ 2.60GHz × 8 işlemci, NVIDIA GeForce GTX 960M / PCIe / SSE2 grafik kartı üzerinde geliştirilmiştir. Uygulama Ubuntu 18.0.4 platformunda uygulanmıştır.

Bu tezde kullanılan uygulama dili Python programıdır. Python, nesne yönelimli destekleyici bir sınıf yapısı), çoklu paradigma (birçok programlama dilini destekler) ve üst düzey bir programlama dilidir. Dilin yapısı günlük dile çok yakındır ve diğer programlama dillerinden farklı olarak, girinti hatalarını sözdizimi hataları olarak kabul etmektedir. Python programlama dili 1991 yılında Guido van Rossum tarafından geliştirilmiştir. Şu anda Python, Python yazılım kuruluşu tarafından geliştirilmektedir. En son kararlı sürüm 3.6.0 ve 2.7.13'tür.

Tez, Tensorflow 1.15.0 adlı açık kaynaklı bir makine öğrenimi kütüphanesi üzerinde geliştirilmiştir. TensorFlow ilk olarak, makine öğrenimi ve derin sinir ağları araştırmaları yapmak için Google'ın Makine İstihbarat Araştırma organizasyonu içinde Google Beyin ekibi üzerinde çalışan araştırmacılar ve mühendisler tarafından geliştirilmiştir (Abadi ve diğ., 2015). Python'da yazılan ve Tensorflow'un üstünde çalışan üst düzey bir sinir ağları API'sı olan Keras da kullanılmıştır. Keras kolay ve hızlı prototip oluşturmaya izin vermekte ve hem kıvrımlı hem de tekrarlayan sinir ağlarını ve bu ikisinin kombinasyonlarını desteklemektedir. CPU (Merkezi İşlem Birimi) ve GPU (Grafik İşlem Birimi) üzerinde sorunsuz bir şekilde çalışmaktadır.

Keras, zaman serilerinin verilerini tahmin etmede farklı sinir ağı mimarilerini test etmek için yazılım çerçevesi olarak seçilmiştir. Bu yazılım çerçevesi, daha düşük düzeyli bir çerçeve kullanmaya kıyasla farklı modellerin daha hızlı oluşturulmasını sağlayan yüksek düzeyli kullanıcı arabirimi nedeniyle seçilmiştir- ancak yine de ince ayar ve modifikasyonlar için birçok seçenek bulunmaktadır. Keras fonksiyonel API'sı hakkında başka bir yerde değinilmeyen tüm bilgiler resmi Keras Belgeleri'nden alınmıştır (Chollet, 2015). Keras arka uç olarak Tensorflow veya Theano kullanmaktadır. Bu tezde ise Tensorflow kullanılmıştır.

3.3.3. Veri kümesi ve veri ön işleme

Bu tezin veri seti, 02 Ocak 2015 - 31 Aralık 2019 tarihleri arasında Gana Borsası'nın Kompozit Endeksinin günlük değerlerinden oluşmaktadır. Böylece toplam 1232 zaman adımı GSE-CI'nin Gana Borsası'nın beş iş gününde kaydedilmesini sağlamaktadır. İlk dört yılın (2015-2018) günlük değerleri, her bir modeli eğitmek için kullanılmakta ve son yıl yani 2019'a ait verilerin geri kalanı, modeller için test veri kümesi olarak kullanılmaktadır. Egzersiz verileri ve test verileri sırasıyla% 80 ve% 20'ye karşılık gelmektedir.

Bu verileri eğitim modellerine beslemeden önce, değerleri modellere daha uygun hale getirmek için veri kümesine ön işleme adımlarının uygulanması gerekmektedir. Ön işleme, verilerin temizlenmesi, verilerin gözetimli bir öğrenme problemine dönüştürülmesi ve farkların uygulanmasını içermektedir. Verilerin temizlenmesi, tüm tarihlerin aynı biçimde olduğundan emin olmak ve eksik değerleri kontrol etmeyi

içermektedir. Veri kümesinde eksik değerler bulunmadığından işlem daha hızlı hale gelmektedir. Sinir ağı modellerinin başarılı bir şekilde eğitilebildiğinden emin olmak için veri serileri denetimli bir öğrenme problemi olarak çerçevenmiştir. Bu, verilerin, modelin öğrenebileceği ve her bir örneğin bir dizi giriş değeri dizisine karşılık gelen bir çıkış değerine sahip olduğu genelleme yapabileceği birkaç örneğe ayrıldığı anlamına gelmektedir. Girdi, önceki 20 günün kompozit endeksinin (bir aydaki Gana Menkul Kıymetler Borsası'nın toplam çalışma günü sayısı) bir dizisidir ve çıktı ertesi günün bileşik endeksidir. Çünkü modeller tek adımlık tahmin yapabilecek bir performans gösterecek şekilde tasarlanmıştır. Veriler, önceki 20 günün girdi olarak kullanıldığı ve bir sonraki günün gözleminin, tek adımlı tahmin için çıktı olarak kullanıldığı birden fazla girdi / çıktı modeline ayrılmıştır. Şekil 1, verileri denetimli bir öğrenme problemi olarak çerçevelemeden önce ve sonra göstermektedir.

Tablo 3.1. Modeller için Orijinal ve Sıralı Veriler Örneği

| Original Data | Input | Output |
|---------------|---|---------|
| 2287.32 | [2287.32 2282.46 2274.18 2272.42 2272.42] | 2261.09 |
| 2282.46 | [2282.46 2274.18 2272.42 2272.42 2261.09] | 2260.14 |
| 2274.18 | [2274.18 2272.42 2272.42 2261.09 2260.14] | 2259.78 |
| 2272.42 | [2272.42 2272.42 2261.09 2260.14 2259.78] | 2228.43 |
| 2272.42 | [2272.42 2261.09 2260.14 2259.78 2228.43] | 2228.48 |
| 2261.09 | [2261.09 2260.14 2259.78 2228.43 2228.48] | 2233.39 |
| 2260.14 | [2260.14 2259.78 2228.43 2228.48 2233.39] | 2225.73 |
| 2259.78 | [2260.14 2259.78 2228.43 2228.48 2233.39] | 2225.73 |
| 2228.43 | [2259.78 2228.43 2228.48 2233.39 2225.73] | 2220.32 |
| 2228.48 | [2228.43 2228.48 2233.39 2225.73 2220.32] | 2216.03 |
| 2233.39 | [2228.48 2233.39 2225.73 2220.32 2216.03] | 2208.02 |
| 2225.73 | [2233.39 2225.73 2220.32 2216.03 2208.02] | 2183.24 |
| 2220.32 | [2225.73 2220.32 2216.03 2208.02 2183.24] | 2183.68 |
| 2216.03 | [2220.32 2216.03 2208.02 2183.24 2183.68] | 2164.06 |
| 2208.02 | [2216.03 2208.02 2183.24 2183.68 2164.06] | 2166.76 |
| 2183.24 | [2208.02 2183.24 2183.68 2164.06 2166.76] | 2161.14 |
| 2183.68 | [2183.24 2183.68 2164.06 2166.76 2161.14] | 2173.95 |
| 2164.06 | [2183.68 2164.06 2166.76 2161.14 2173.95] | 2155.66 |
| 2166.76 | | |
| 2161.14 | | |

Orijinal Veriler

Denetimli öğrenme problemine çerçeveselenen veriler

Bir sonraki ön işleme adımı günlük farklılık uygulanmaktadır. Bu, korkunç modellere sahip olmaktan kaçınmak için verilerdeki durağanlığı ve eğilimi gidermek için yapılmıştır.

Verilerin normalleştirilmesi gerekir. Bu, sinir ağı eğitiminin verimliliğini artıracaktır. Tüm değerler eğitim problemlerinden kaçınmak için normalize edilmiş ve ayrıca kilo kaybı ve Bayes kestirimi de standart girdilerle daha rahat yapılabilmektedir. Normalizasyon formülü aşağıdaki gibidir:

$$Z_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (3.8)$$

Z_i ; normalizasyondan önce ham verileri temsil etmekte; $\min(x)$ normalizasyondan önce minimum ham veri değerini temsil etmekte ve $\max(x)$ normalizasyondan önce ham verilerin maksimum değerini temsil etmektedir.

3.3.4. Eğitim süreci

Eğitim süreci, eğitim veri kümesinin kullanılmasını ve üç derin öğrenme sinir ağının geliştirilmesinde kullanılacak bir dizi hiperparametrenin dikkatle seçilmesini içermektedir. Bu Hiperparametreler şunları içermektedir:

- Dönem Sayısı
- Yığın Boyutu
- Öğrenme Oranı
- Gizli Katman Sayısı
- Aktivasyon Fonksiyonları
- Kayıp Fonksiyonları
- Optimizasyon fonksiyonları

Tüm veri kümesinden bir tam ileri ve geri geçişi belirtmektedir. Bu nedenle, dönem sayısı, her bir sinir ağı modelinin optimum eğitimi için veri kümesinden bu kadar geçişin gerekli olduğunu göstermektedir. Bir veri yığını, eğitim veri kümesinden, ağınlıkların güncellemeden önce kaç patern işleneceğini tanımlayan sabit boyutlu bir satırdır. Yığın büyüklüğü genellikle toplam numune sayısından çok daha küçüktür. Dönemlerin sayısıyla birlikte, ağınlıkların ne kadar hızlı öğrendiğini (ağırlıkların ne sıklıkla güncellendiğini) tanımlamaktadır.

Aktivasyon fonksiyonu, girdiyi bir sonraki nöron veya çıkış katmanına göndermeden önce yaptığımız doğrusal olmayan bir dönüşümdür. Temel olarak bir nöronun aktive edilip edilmeyeceğine karar vermektedir. Böylece ağ girişinin değerini sınırlamaktadır. Böyle bir aktivasyon fonksiyonu, düzeltilmiş doğrusal aktivasyon ünitesi, kısaca ReLU'dur. Relu, sinir ağlarında kullanılan en yaygın aktivasyon fonksiyonlarından biridir. Çünkü sigmoid veya tanh gibi diğer aktivasyon fonksiyonlarının maruz kaldığı yok edici gradyan problemi (gradyanlar hemen kullanışlı olmak için çok küçük olduğunda ortaya çıkar) yoktur.

Kayıp fonksiyonu, tasarlanan modelin hata oranını ve performansını ölçen fonksiyondur. Kayıp fonksiyonu temel olarak modelin tahmininin gerçeklerden ne kadar farklı olduğunu hesaplamaktadır. Bu nedenle, iyi tahmin edilmiş bir model oluşturulmaz ise, zemin değeri ile öngörülen değer arasındaki fark yüksek olacaktır. Bu nedenle kayıp değeri yüksek olacak ve iyi bir model varsa kayıp değeri daha az olacaktır. Tam olarak aynı ise, kayıp 0 olacaktır. İyi bir modelin, 0'a yakın bir kayıp değerine sahip olmasını beklenmektedir. Kayıp fonksiyonunun çıkışı, normalleştirme hatası nedeniyle asla sıfır olmayacaktır.

Kayıp fonksiyonunu en aza indirmek ve modeldeki ağırlık ve sapmaları güncellemek için bir optimizasyon stratejisi kullanılmaktadır. Parametreler olarak öğrenme oranı (η) ve momentuma sahip olan Adam (Uyarlamalı Moment Tahmini) optimizasyonu kullanılmıştır. Adam optimizasyonu hızlı bir şekilde ağ parametrelerinin optimal durumuna yakınsaması için öğrenme hızının uygun şekilde ayarlanmasını

gerektirmektedir. "Öğrenme oranı" parametresi, momentum değerine veya uyarlanabilir algoritmalar kullanılarak nasıl öğrenileceğine bağlı olarak adım adım artan değer (0.001'den sonra 0.01 gibi) olarak sabit bir değer olarak belirtilebilmektedir.

3.4. SİNİR AĞI MODELLERİ

Modeller ilk önce tüm veri kümesinin bir aralıklı farklı bir serisini oluşturarak geliştirilmiştir. Yani bir önceki zaman adımından (t-1) gözlem mevcut gözlemden (t) çıkarılmaktadır. Bu, veri kümesini sabit hale getirmek için yapılmaktadır. Sabit verilerin modellenmesi daha kolaydır ve büyük olasılıkla daha yetenekli tahminlerle sonuçlanacaktır. Eğilim gözlemlerden kaldırılabilen ve daha sonra tahmini orijinal ölçüğe döndürmek için tahminlere geri eklenebilmektedir. Tek değişkenli bir zaman serisi tahmininde, veriler daha sonra denetimli bir öğrenme problemine dönüştürülmektedir. Dolayısıyla, önceki 20 zaman aşamasından gelen gözlem, mevcut gözlem için girdi olarak kullanılmaktadır.

Bir sinir ağının tasarımı, soruna bağlı olarak çok farklıdır. Çoğunlukla deneme yanılma temelli olduğu için tasarımı gerçekleştirmenin belirli bir yolu yoktur. Bununla birlikte, bu makalede, sinir ağı oluşturmak için yönergeleri özetleyen InfoWorld (2018) 'ten görülebileceği gibi birkaç ipucu ve püf noktası vardır. Aşağıdaki bölüm, modeller için kullanılan farklı mimarilerin detaylarını sunmaktadır.

3.4.1. MLP Sinir Ağı Modeli

MLP modeli bir Giriş katmanı ve üç gizli katmandan oluşmaktadır. Modeller, bir sonraki zaman adımında GSE-CI'yi tahmin etmek için çıkış katmanında doğrusal bir

aktivasyon ile tek bir nöron gerektirmektedir. Birinci gizli katman 100 nörona sahipken, ikinci ve üçüncü gizli katmanlar sırasıyla 64 ve 32 nörondan oluşmaktadır. Model, 0.0001 öğrenme oranına sahip Adam optimizer ve Kayıp fonksiyonu olarak Ortalama Kare Hatası (MSE) kullanılarak geliştirilmiştir. Giriş katmanı dahil üç katman için aktivasyon fonksiyonları ReLU fonksiyonudur. Bir yığın büyüklüğü kullanılmakta ve model 1000 dönem için eğitilmektedir. Ek olarak, aşırı sığmayı azaltmak için 0.1 olasılıklı bir bırakma katmanı eklenmiştir.

3.4.2. LSTM Sinir Ağı Modeli

LSTM modeli, bir giriş katmanı ve iki istiflenmiş LSTM katmanı, bir doğrusal katman ve tek bir nöronlu bir çıkış katmanından oluşmaktadır. Yığılmış LSTM tabakalarının her ikisinde de 100 nöron bulunmakta ve son gizli tabaka 10 nöronlu bir MLP tabakasıdır. 0.001 öğrenme hızına sahip Adam optimizer ve kayıp fonksiyonu olarak ortalama kare hatası (MSE). ReLU aktivasyon fonksiyonu LSTM katmanlarında kullanılmaktadır. LSTM modeli, seri büyüklüğü bir olan 1000 dönem için eğitilmiştir. Bunun nedeni, test verileri hakkında tek adımlı tahminler yapmakla ilgilenmemiz ve ayrıca yığın boyutunun, eğitim ve test veri kümelerinin boyutunu etkileyen bir faktör olması gerektiğidir.

3.4.3. CNN Sinir Ağı Modeli

CNN modeli, 512 nöronlu bir giriş katmanına, birinci, ikinci ve üçüncü gizli katmanlarda sırasıyla 256, 128 ve 64 nöronlu üç kıvrımlı gizli katmana sahiptir. Her kıvrımlı katmana 2 boyutlu bir çekirdek uygulanır ve CNN modelindeki tüm katmanlarda

ReLU aktivasyon fonksiyonu kullanılmaktadır. Model, çıkış katmanından önce 50 nöronluk doğrusal bir katmana sahiptir. Model, 0.0001 öğrenme oranına sahip Adam optimizier ve Kayıp fonksiyonu olarak Ortalama Kare Hatası (MSE) kullanılarak geliştirilmiştir. CNN modeli 1000 dönem için eğitilmiştir.

Tablo 3.2. MLP, LSTM ve CNN için Hiperparametreler

| Model | Öğrenme oranı | Optimizier | Yığın boyutu | Gizli Katmanlar | Aktivasyon Fonksiyonu | Kayıp Fonksiyonu | Dönemleri |
|-------|---------------|------------|--------------|-----------------|-----------------------|------------------|-----------|
| MLP | 0.0001 | Adam | 100 | 3 | ReLU | MSE | 1000 |
| LSTM | 0.001 | Adam | 1 | 3 | ReLU | MSE | 1000 |
| CNN | 0.001 | Adam | 100 | 4 | ReLU | MSE | 1000 |

3.5. PERFORMANS ÖLÇÜLERİ

Dikkate alınan dört tahmin modelinin öngörme performansını derinlemesine analiz etmek için aşağıdaki hata değerlendirme kriterleri kullanılmaktadır. MAE (ortalama mutlak hata) ve RMSE (kök ortalama kare hatası), MAPE (ortalama mutlak yüzde hatası), belirleme katsayısı ve AIC ve BIC bilgi Kriterleri. Karşılık gelen tanımlar ve formüller aşağıdaki gibidir:

$$MAPE = \frac{100\%}{n} \sum \left| \frac{y - \hat{y}}{y} \right|$$

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

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

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

$$R^2 = 1 - \frac{\sum (y_i - \hat{y})^2}{\sum (y_i - \bar{y})^2}$$

Where,

\hat{y} – predicted value of y
 \bar{y} – mean value of y

MAE, adındaki gibi mutlak hataların ortalamasını önerdiği için basittir. Mutlak hata, öngörülen değer ile gerçek değer arasındaki farkın mutlak değeridir. MAE bize ortalamadan tahminimizden ne kadar büyük bir hata bekleyebileceğimizi söylemektedir.

MAE ile ilgili bir problem, hatanın göreceli boyutunun her zaman belirgin olmamasıdır. Bazen küçük bir hatadan büyük bir hata söylemek zordur. Bu sorunu çözmek için ortalama mutlak yüzde hatasını (MAPE) bulmak gereklidir.

Tahmin modellemesinde hem ortalama kare hatası (MSE) hem de ortalama mutlak hata (MAE) kullanılmaktadır. Bu nedenle MAE, kareden faydalanmadığı için aykırı değerlere karşı daha sağlamdır. Öte yandan, sonuçları eşdeğer küçük hatalardan çok daha

büyük olan büyük hatalardan endişe edersek MSE daha yararlıdır. MSE ayrıca Gauss rastgele değişkenlerinin olasılığını en üst düzeye çıkarmaya karşılık gelmektedir.

3.6. ANALYZ SONUÇLARI


Bu bölüm, bu tezde kullanılan makine öğrenme yöntemlerinin sonuçlarını sunmaktadır. Bu sonuçlar, modeller için test (görünmeyen) verilerini temsil eden GSE-CT'nin son 246 günlük tahminini içermektedir. Sonuçlar ve Çok Katmanlı Perceptron, Uzun-Kısa vadeli bellek ve Evrimsel modellerin performansı aşağıda tartışılmıştır:

3.6.1. Çok katmanlı algılayıcı (MLP) sonuçları

MLP modeli, test veri kümesi için iyi tahmin yeteneği göstermektedir. Modelin kök ortalama kare hatası 14.394 ve R kare ölçüsü yüzde 98.7'dir. MLP modelinin diğer performans ölçümü ve diğer modelle karşılaştırılması tablo 3.6'da verilmiştir. Gerçek test verilerinin grafiği ve öngörülen değerler şekil 3.4'te gösterilmiştir. Tablo 3.3, test veri kümesinin ilk 20 günü için bu değerleri göstermiştir.

Şekil 3.4. Test veri kümesinin MLP modeli tahmini

Test MSE: 207.184
Test RMSE: 14.394
Test MAE: 9.779
Test MAPE: 6.320
Test R squared: 0.987
AIC Score: 1352.068
BIC Score: 1422.174



Tablo 3.3. MLP için Öngörülen ve Gerçek GSE-CI değerleri

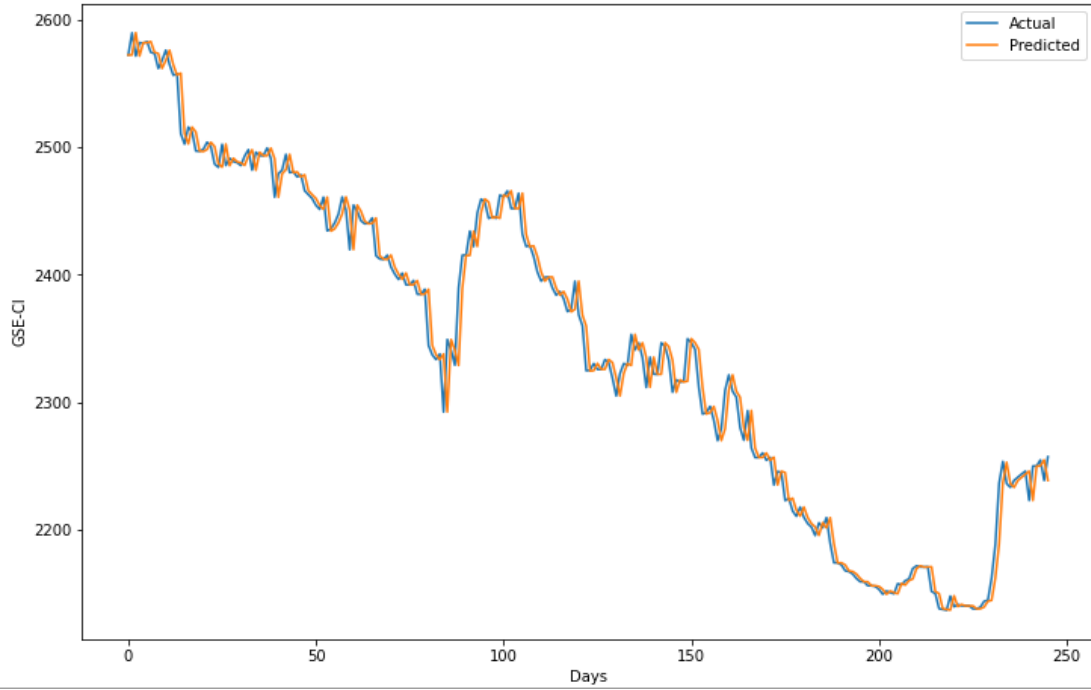
| Gün | Actual(Gerçek) | Predicted(Öngörülen) |
|-----|----------------|----------------------|
| 1 | 2572.220000 | 2572.936933 |
| 2 | 2589.550000 | 2572.936933 |
| 3 | 2571.350000 | 2590.166588 |
| 4 | 2581.850000 | 2572.096666 |
| 5 | 2581.460000 | 2582.348650 |
| 6 | 2582.700000 | 2582.385832 |
| 7 | 2574.280000 | 2583.382782 |
| 8 | 2573.420000 | 2575.003405 |
| 9 | 2561.630000 | 2574.153838 |
| 10 | 2567.880000 | 2562.281847 |
| 11 | 2575.990000 | 2568.681762 |
| 12 | 2564.660000 | 2576.750334 |
| 13 | 2556.280000 | 2565.330726 |
| 14 | 2557.620000 | 2556.898641 |
| 15 | 2510.380000 | 2558.565889 |
| 16 | 2502.330000 | 2510.700257 |
| 17 | 2515.700000 | 2502.542550 |

3.6.2. Uzun kısa süreli bellek (LSTM) sonuçları

LSTM modeli MLP'den daha iyi bir tahmin vermiştir. LSTM modeli yüzde 14.296 daha düşük ortalama kare hatası ve yüzde 98.7 R kare elde etmiştir. LSTM modelinin diğer performans ölçümlerinin sonuçları ve MLP ve CNN ile karşılaştırmaları tablo 3.6'da verilmiştir. Gerçek test verilerinin grafiği ve öngörülen değerler şekil 3.5'te gösterilmiştir. Ayrıca tablo 3.4'te test veri kümesinin ilk 20 günü için gerçek ve tahmin edilen sonuçları gösterilmiştir.

Şekil 3.5. Test veri kümesinin LSTM modeli tahmini

Test MSE: 204.378
Test RMSE: 14.296
Test MAE: 9.604
Test MAPE: 6.320
Test R squared: 0.987
AIC Score: 1348.713
BIC Score: 1418.820



Tablo 3.4. LSTM için Öngörülen ve Gerçek GSE-CI değerleri


| Gün | Actual(Gerçek) | Predicted(Öngörülen) |
|-----|----------------|----------------------|
| 1 | 2572.220000 | 2572.183773 |
| 2 | 2589.550000 | 2572.208591 |
| 3 | 2571.350000 | 2589.673658 |
| 4 | 2581.850000 | 2571.362946 |
| 5 | 2581.460000 | 2581.867539 |
| 6 | 2582.700000 | 2581.729148 |
| 7 | 2574.280000 | 2582.785950 |
| 8 | 2573.420000 | 2574.329034 |
| 9 | 2561.630000 | 2573.434912 |
| 10 | 2567.880000 | 2561.653649 |
| 11 | 2575.990000 | 2567.876600 |
| 12 | 2564.660000 | 2576.016048 |
| 13 | 2556.280000 | 2564.590140 |
| 14 | 2557.620000 | 2556.373061 |
| 15 | 2510.380000 | 2557.978426 |
| 16 | 2502.330000 | 2510.575864 |
| 17 | 2515.700000 | 2502.467628 |
| 18 | 2511.840000 | 2515.673454 |
| 19 | 2496.910000 | 2511.788794 |
| 20 | 2496.710000 | 2496.903378 |

3.6.3. Evrimsel sinir ağı (CNN) sonuçları

CNN modeli, bu tezde uygulanan üç derin öğrenme yöntemi arasında GSE-CI veri kümesini tahmin etmenin en iyi sonuçlarını göstermektedir. Bu model, 14.282'lik bir kök ortalama kare hatasını ve R'nin yüzde 98.8'in karesini göstermektedir. CNN modelinin diğer performans ölçümlerinin sonuçları ve MLP ve LSTM ile karşılaştırmaları tablo 3.6'da verilmiştir. Gerçek test verilerinin grafiği ve tahmin edilen değerler şekil 3.6'da gösterilmiştir. Ayrıca, tablo 3.5'da test veri kümesinin ilk 20 günü için gerçek ve tahmin edilen sonuçları gösterilmiştir.

Şekil 3.6. Test veri kümesinin CNN modeli tahmini

Test MSE: 203.965
Test RMSE: 14.282
Test MAE: 9.585
Test MAPE: 6.320
Test R squared: 0.988
AIC Score: 1348.215
BIC Score: 1418.322



Tablo 3.5. CNN için Öngörülen ve Gerçek GSE-CI değerleri

| Gün | Actual(Gerçek) | Predicted(Öngörülen) |
|-----|----------------|----------------------|
| 1 | 2572.220000 | 2572.232048 |
| 2 | 2589.550000 | 2572.318767 |
| 3 | 2571.350000 | 2589.580597 |
| 4 | 2581.850000 | 2571.396893 |
| 5 | 2581.460000 | 2581.875642 |
| 6 | 2582.700000 | 2581.568402 |
| 7 | 2574.280000 | 2582.693186 |
| 8 | 2573.420000 | 2574.279438 |
| 9 | 2561.630000 | 2573.377454 |
| 10 | 2567.880000 | 2561.643010 |
| 11 | 2575.990000 | 2567.907532 |
| 12 | 2564.660000 | 2575.982022 |
| 13 | 2556.280000 | 2564.674094 |
| 14 | 2557.620000 | 2556.293163 |
| 15 | 2510.380000 | 2557.614692 |
| 16 | 2502.330000 | 2510.372021 |
| 17 | 2515.700000 | 2502.434999 |
| 18 | 2511.840000 | 2515.693641 |
| 19 | 2496.910000 | 2511.82467 |
| 20 | 2496.710000 | 2496.857560 |

Tablo 3.6. MLP, LSTM, CNN performans sonuçları

| Modeli | MSE | MAE | MAPE | AIC | BIC | RMSE | R squared |
|-------------|---------|-------|-------|----------|----------|--------|-----------|
| MLP | 207.184 | 9.779 | 6.320 | 1352.068 | 1422.174 | 14.394 | 0.987 |
| LSTM | 204.378 | 9.604 | 6.320 | 1348.713 | 1418.820 | 14.296 | 0.987 |
| CNN | 203.965 | 9.585 | 6.320 | 1348.215 | 1418.322 | 14.282 | 0.988 |

3.7. TEZ SONUÇ VE ÖNERİLERİ

Makine öğrenmesi ve yapay zeka algoritmalarının ortaya çıkması, hisse senedi fiyatı yön tahmininde hesaplama gerektiren matematiksel modellerle başa çıkmayı mümkün kılmıştır. Bu tezde, mevcut tarihsel verilere dayanarak Gana Menkul Kıymetler Borsası Kompozit endeksini tahmin etmek için Çok Katmanlı Algılayıcı (MLP), Evrişimli Sinir Ağları (CNN) ve Uzun Kısa Süreli Bellek (LSTM) olmak üzere üç tür derin öğrenme mimarisi kullanılmıştır. GSE-CI, Gana'daki Menkul Kıymetler Piyasasının ana endeksidir ve borsada listelenen tüm adi hisseleri içermektedir. Gana Menkul Kıymetler Borsası Gana'da 1989 yılında kurulan büyük borsadır. Borsa 1990 yılında teminatla sınırlı özel bir şirket olarak faaliyete başlamış ve daha sonra 1994 yılında teminatla sınırlı bir halka açık şirkete dönüşmüştür.

Bu tezde kullanılan uygulama dili Python programıdır. Python, (nesne yönelimli destekleyici bir sınıf yapısı), çoklu paradigma (birçok programlama dilini desteklemekte) ve üst düzey bir programlama dilidir. Tensorflow 1.15.0 adlı açık kaynaklı bir makine öğrenimi kütüphanesi üzerinde geliştirilmiştir. TensorFlow ilk olarak, makine öğrenimi ve derin sinir ağları araştırmaları yapmak için Google'ın Makine İstihbarat Araştırma organizasyonu içinde Google Beyin ekibi üzerinde çalışan araştırmacılar ve mühendisler tarafından geliştirilmiştir. Bu tezin veri seti, 02 Ocak 2015 - 31 Aralık 2019 tarihleri arasında Gana Borsası'nın Kompozit Endeksinin günlük değerlerinden oluşmaktadır. Böylece toplam 1232 zaman adımı GSE-CI'nin Gana Borsası'nın beş iş gününde kaydedilmesini sağlamaktadır. İlk dört yılın (2015-2018) günlük değerleri, her bir modeli eğitmek için kullanılmakta ve son yıl yani 2019'a ait verilerin geri kalanı, modeller için

test veri kümesi olarak kullanılmaktadır. Egzersiz verileri ve test verileri sırasıyla% 80 ve% 20'ye karşılık gelmektedir.

Bu tez, Gana Menkul Kıymetler Borsası'nın bileşik endeksinde tek adımlı öngörmede kullanılan farklı sinir ağı yöntemlerinin uygulanmasını araştırmıştır. Farklı makine öğrenme yöntemlerini test etmek için geliştirme platformu, Python'da Keras adı verilen serbestçe mevcut bir derin öğrenme kütüphanesi etrafında yapılmıştır. Tezin amacı, Gana Borsası'nın bileşik endeksinin tahminini Çok Katmanlı Algılayıcı (MLP), Uzun Kısa Süreli Bellek (LSTM) ve Evrişimli Sinir Ağı (CNN) modellerini kullanarak gerçekleştirmektir. MLP modeli, test veri kümesi için iyi tahmin yeteneği göstermektedir. Modelin kök ortalama kare hatası 14.394 ve R kare ölçüsü yüzde 98.7'dir. LSTM modeli MLP'den daha iyi bir tahmin vermiştir. LSTM modeli yüzde 14.296 daha düşük ortalama kare hatası ve yüzde 98.7 R kare elde etmiştir. CNN modeli, bu tezde uygulanan üç derin öğrenme yöntemi arasında GSE-CI veri kümesini tahmin etmenin en iyi sonuçlarını göstermektedir. Bu model, 14.282'lik bir kök ortalama kare hatasını ve R'nin yüzde 98.8'in karesini göstermektedir.

Bu tezin sonuçları, verilerde yapılar ve örüntü bulunduğunu göstermektedir. Bu modellerin daha fazla optimizasyonla daha iyi performans göstermesi çok muhtemeldir. Bahsetmek gerekirse, muhtemelen bu tez sırasında deneme ve yanılmaya dayanan hiperparametrelerin ön işleminde ve seçiminde kazanılacak çok şey vardır. Her ne kadar bu tezin sonuçları CNN'lerin GSE_CI tahminleri için muhtemelen en iyi seçim olduğunu

gösterse de, bu tez en uygun çözümü sunmamakta, daha ileri araştırma ve geliştirme için başlangıç noktası vermektedir.

LSTM'ler uzun süreli bağımlılıklar bulabildiklerinden, genişletilmiş Konvolüsyonlar alıcı alanını genişletmekte ve CNN'nin daha uzun bağımlılıklar kullanmasını sağlamaktadır. Bu, veri setindeki LSTM'lerin yanı sıra CNN'lerin çalışmamasının bazı nedenleri olabilmektedir. Ayrıca, sadece aynı örnekleme frekansına sahip daha fazla örnek kullanılarak testlerin alınması ve yürütülmesi ilginç olacaktır. Bundan yararlanarak örneğin, görüntüde birbirine daha yakın olan pikseller, uzaktaki piksellerden daha fazla ilişkilidir. Bu, söz konusu sorun için de geçerli gibi görünmekte, bu da CNN'nin MLP ve LSTM'den çok daha iyi çalışmasının kısmi bir nedeni olabilmektedir.

Canlı bir uygulamada, hatta bir yerde, modelin yeni gelen veriler üzerinde yeniden eğitilmesi gerekmektedir. Bu noktada doğruluk azalmaya başlamıştır. Çünkü model eski ve daha az temsili verilere takılmıştır. Canlı uygulamada, bu muhtemelen hareketli bir pencere kullanılarak yapılacak ve verilen her sayıdaki modeli yeniden eğitecektir. Bu tez, Gana Menkul Kıymetler Borsası'nın bileşik endeksinin bir sonraki değerini tahmin etmek için sinir ağlarının kullanımını değerlendirmektedir.

Gelecekteki çalışmalar aşağıdakileri içerecek şekilde özetlenebilir; daha yüksek örnekleme frekansıyla veri seti elde etmek ve farklı ön işleme yöntemlerini denemek. Ayrıca, diğer denetimli makine öğrenme algoritmalarının kullanılması da Gana Menkul Kıymetler Borsası Kompozit endeksi için Çok adımlı öngörme kullanılarak test edilebilir.

KAYNAKÇA

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., ... & Ghemawat, S. (2015). TensorFlow: Large-scale machine learning on heterogeneous systems.
- Addai, S. (2016). *Financial forecasting using machine learning* (Doctoral dissertation, University of Cape Town).
- Adjasi, C. K., & Yartey, C. A. (2007). *Stock market development in Sub-Saharan Africa: Critical issues and challenges* (No. 7-209). International Monetary Fund.
- Adu, D. A. (2012). *Effect of Macroeconomic Variables on Stock Market Returns Ghana: An Analysis Using Arbitrage Pricing Model* (Doctoral dissertation).
- Al-Fattah, S. M., & Al-Naim, H. A. (2009). Artificial-intelligence technology predicts relative permeability of giant carbonate reservoirs. *SPE Reservoir Evaluation & Engineering*, 12(01), 96-103.
- Allen, F., & Gale, D. (1999). Bubbles, crises, and policy. *Oxford Review of Economic Policy*, 15(3), 9-18.
- Alnus Yatirim <https://www.alnusyatirim.com/bono-nedir> 20.03.2020 alındı
- Ariyo, A. A., Adewumi, A. O., & Ayo, C. K. (2014, March). Stock price prediction using the ARIMA model. In *2014 UKSim-AMSS 16th International Conference on Computer Modelling and Simulation* (pp. 106-112). IEEE.
- Atsalakis, G. S., & Valavanis, K. P. (2009). Surveying stock market forecasting techniques—Part II: Soft computing methods. *Expert Systems with Applications*, 36(3), 5932-5941.
- Bachelier, L. (1900). *Theorie de la Speculation*, Gauthier-Villars, Paris, w: P. Cootner, *The Random Character of Stock Market Prices*.
- Bai, S., Kolter, J. Z., & Koltun, V. (2018). An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *arXiv preprint arXiv:1803.01271*.
- Ballings, M., Van den Poel, D., Hespeels, N., & Gryp, R. (2015). Evaluating multiple classifiers for stock price direction prediction. *Expert Systems with Applications*, 42(20), 7046-7056.
- Bastı, E., Kuzey, C., & Delen, D. (2015). Analyzing initial public offerings' short-term performance using decision trees and SVMs. *Decision Support Systems*, 73, 15-27.

- Bellgard, C., & Goldschmidt, P. (1999). Forecasting across frequencies: Linearity and non-linearity. In *Forecasting across frequencies: Linearity and non-linearity* (pp. 41-48). School of Information Technology, Bond University.
- Bengoechea, A. G., Uretaz, C. O., Saavedra, M. M., & Medina, N. O. (1996, June). Stock market indices in Santiago de Chile: Forecasting using neural networks. In *Proceedings of International Conference on Neural Networks (ICNN'96)* (Vol. 4, pp. 2172-2175). IEEE.
- Bernard, V. L. (1994). Accounting-based valuation methods, determinants of market-to-book ratios, and implications for financial statement analysis.
- Bildirici, M., & Ersin, Ö. Ö. (2009). Improving forecasts of GARCH family models with the artificial neural networks: An application to the daily returns in Istanbul Stock Exchange. *Expert Systems with Applications*, 36(4), 7355-7362.
- Borsa Istanbul https://borsaistabul.com/files/Kira_Sertifikalari.pdf 20.03.2020 alındı
- Boyacıoğlu, M. A., & Avcı, D. (2010). An adaptive network-based fuzzy inference system (ANFIS) for the prediction of stock market return: the case of the Istanbul stock exchange. *Expert Systems with Applications*, 37(12), 7908-7912.
- Central Securities Depository. (2016). Ghana Stock Exchange launches 25th anniversary celebrations. Accra, Ghana. <https://www.csd.com.gh/market-info/market-news/5247-launches.html> 23.03.2020 alındı.
- Chen, K., Zhou, Y., & Dai, F. (2015, October). A LSTM-based method for stock returns prediction: A case study of China stock market. In *2015 IEEE international conference on big data (big data)* (pp. 2823-2824). IEEE.
- Chollet, F. (2015). Keras: Deep learning library for theano and tensorflow. URL: <https://keras.io/k>, 7(8), T1.
- Chung, H., & Shin, K. S. (2018). Genetic algorithm-optimized long short-term memory network for stock market prediction. *Sustainability*, 10(10), 3765.
- Cosh, A. D., Hughes, A., & Singh, A. (1992). Openness, financial innovation, changing patterns of ownership, and the structure of financial markets. *Financial Openness and National Autonomy: Constraints and Opportunities*, 19-42.
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems*, 2(4), 303-314.
- Di Persio, L., & Honchar, O. (2016). Artificial neural networks architectures for stock price prediction: Comparisons and applications. *International journal of circuits, systems and signal processing*, 10(2016), 403-413.

- Donaldson, R. G., & Kim, K. H. Y. (1993). *Evaluating alternative models for conditional stock volatility: Evidence from international data* (No. dp93-06).
- Dorffner, G. (1996). Neural networks for time series processing. In *Neural network world*.
- Dutta, A., Bandopadhyay, G., & Sengupta, S. (2012). Prediction of stock performance in indian stock market using logistic regression. *International Journal of Business and Information*, 7(1).
- Fadlalla, A., & Lin, C. H. (2001). An analysis of the applications of neural networks in finance. *Interfaces*, 31(4), 112-122.
- Farid, S. (2013, October). Financial integration in African emerging markets. In *African Economic Conference* (Vol. 10, No. 3, pp. 1-18).
- Fernandez-Rodriguez, F., Gonzalez-Martel, C., & Sosvilla-Rivero, S. (2000). On the profitability of technical trading rules based on artificial neural networks:: Evidence from the Madrid stock market. *Economics letters*, 69(1), 89-94.
- Figurska, M., & Wisniewski, R. (2016). Fundamental Analysis–Possibility of Application on the Real Estate Market. *Real Estate Management and Valuation*, 24(4), 35-46.
- Franck, R., & Schmied, A. (2004). Predicting currency crisis contagion from East Asia to Russia and Brazil: an artificial neural network approach. Available at SSRN 535402.
- Frankel, J. A., & Rose, A. K. (1996). Currency crashes in emerging markets: An empirical treatment.
- Gamboa, J. C. B. (2017). Deep Learning for Time-Series Analysis. arXiv 2017. *arXiv preprint arXiv:1701.01887*.
- Gers, F. A., Schmidhuber, J., & Cummins, F. (1999). Learning to forget: Continual prediction with LSTM. *Neural Computation* 12, 2451–2471
- Ghana Stock Exchange. (2016). The Past, Present and Future of Stock Exchange Operations in Ghana. Accra, Ghana. https://gse.com.gh/docs/2015/GSE_Anniversary_Handout.pdf 23.03.2020 alundi
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press: Cambridge, MA, USA, 2016; pp. 373–418. 46.
- Gunduz, H., & Cataltepe, Z. (2015). Borsa Istanbul (BIST) daily prediction using financial news and balanced feature selection. *Expert Systems with Applications*, 42(22), 9001-9011.

- Guo, Z., Wang, H., Yang, J., & Miller, D. J. (2015). A stock market forecasting model combining two-directional two-dimensional principal component analysis and radial basis function neural network. *PloS one*, 10(4).
- Gupta, D. (2017). Fundamentals of Deep Learning-Activation Functions and their use. *Analytics Vidhya*. Accessed from: <https://www.analyticsvidhya.com/blog/2020/01/fundamentals-deep-learning-activation-functions-when-to-use-them/> on 23.03.2020.
- Harvey, A. C., & Fernandes, C. (1989). Time series models for insurance claims. *Journal of the Institute of Actuaries*, 116(3), 513-528.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5), 359-366.
- Jasemi, M., Kimiagari, A. M., & Memariani, A. (2011). A modern neural network model to do stock market timing on the basis of the ancient investment technique of Japanese Candlestick. *Expert Systems with Applications*, 38(4), 3884-3890.
- Ji, S., Xu, W., Yang, M., & Yu, K. (2012). 3D convolutional neural networks for human action recognition. *IEEE transactions on pattern analysis and machine intelligence*, 35(1), 221-231.
- Kallah-Dagadu, G. (2013). *Modelling Ghana Stock Exchange Indices and Exchange Rates with Stable Distributions* (Doctoral dissertation, University of Ghana).
- Kao, L. J., Chiu, C. C., Lu, C. J., & Yang, J. L. (2013). Integration of nonlinear independent component analysis and support vector regression for stock price forecasting. *Neurocomputing*, 99, 534-542.
- Kara, Y., Boyacıoğlu, M. A., & 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.
- Kayal, A. (2010, October). A neural networks filtering mechanism for foreign exchange trading signals. In *2010 IEEE International Conference on Intelligent Computing and Intelligent Systems* (Vol. 3, pp. 159-167). IEEE.
- Kenny, C. J., & Moss, T. J. (1998). Stock markets in Africa: emerging lions or white elephants?. *World Development*, 26(5), 829-843.

- Kim, Y., Roh, J. H., & Kim, H. Y. (2018). Early forecasting of Rice blast disease using long short-term memory recurrent neural networks. *Sustainability*, 10(1), 34.
- Kimoto, T., Asakawa, K., Yoda, M., & Takeoka, M. (1990, June). Stock market prediction system with modular neural networks. In *1990 IJCNN international joint conference on neural networks* (pp. 1-6). IEEE.
- Koskela, T., Lehtokangas, M., Saarinen, J., & Kaski, K. (1996, September). Time series prediction with multilayer perceptron, FIR and Elman neural networks. In *Proceedings of the World Congress on Neural Networks* (pp. 491-496). INNS Press San Diego, USA.
- Kuwornu, J. K., & Owusu-Nantwi, V. (2011). Macroeconomic variables and stock market returns: Full information maximum likelihood estimation. *Research Journal of Finance and Accounting*, 2(4), 49-63.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lee, H.Y., (2003). The Application of Artificial Neural Network and Regression Model for Studying the Taiwan Stock Index Future. *Master's thesis, Department Of Business Administration, National Cheng Kung University, Taiwan.*
- Leung, M. T., Chen, A. S., & Daouk, H. (2000). Forecasting exchange rates using general regression neural networks. *Computers & Operations Research*, 27(11-12), 1093-1110.
- Lin, T. W., & Yu, C. C. (2009). Forecasting stock market with neural networks. *Available at SSRN: <http://ssrn.com/abstract=1327544>*, accessed April 15, 2020
- Ma, T.H. (2003). The Application of Neuron—Fuzzy to Emulate the Investment in TAIEX. *Master's thesis, department of finance, Chaoyang University of Technology, Taiwan.*
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PloS one*, 13(3).
- Malkiel, B. G., & Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The journal of Finance*, 25(2), 383-417.
- Marković, I. P., Stojanović, M. B., Stanković, J. Z., & Božić, M. M. (2014). Stock market trend prediction using support vector machines. *Facta Universitatis, Series: Automatic Control and Robotics*, 13(3), 147-158.
- Martinez, L. C., da Hora, D. N., Palotti, J. R. D. M., Meira, W., & Pappa, G. L. (2009, June). From an artificial neural network to a stock market day-trading system: A

- case study on the bm&f bovespa. In *2009 International Joint Conference on Neural Networks* (pp. 2006-2013). IEEE.
- Mensah S.(2016). The Past, Present and Future of Stock Exchange Operations in Ghana. Accessed on 23rd march, 2020 from https://gse.com.gh/docs/2015/GSE_Anniversary_Handout.pdf
- Mondal, P., Shit, L., & Goswami, S. (2014). Study of effectiveness of time series modeling (ARIMA) in forecasting stock prices. *International Journal of Computer Science, Engineering and Applications*, 4(2), 13.
- Murphy, J., Scott, D. H., & Kalayjian, S. (2014). *U.S. Patent No. 8,682,773*. Washington, DC: U.S. Patent and Trademark Office.
- Nag, A., & Mitra, A. (1999). Neural networks and early warning indicators of currency crisis. *Reserve Bank of India Occasional Papers*, 20(2), 183-222.
- Nastos, P., Moustris, K., Larissi, I., & Paliatsos, A. (2011). Air Quality and Bioclimatic Conditions within the Greater Athens Area, Greece-Development and Applications of Artificial Neural Networks. In *Advanced Air Pollution*. IntechOpen.
- Nortey, E. N., Asare, K., & Mettle, F. O. (2015). Extreme value modelling of Ghana stock exchange index. *SpringerPlus*, 4(1), 696.
- Omari-Sasu, A. Y., Frempong, N. K., Boateng, M. A., & Boadi, R. K. (2015). Modeling Stock Market Volatility Using GARCH Approach on the Ghana Stock Exchange. *International Journal of Business and Management*, 10(11), 169.
- Oztemel, E. (2003). *Yapay Sinir Aglari*. Istanbul: Papatya Publishing.
- Para ve ben <http://paramveben.org/varliga-dayali-menkul-kiymet-ve-varlik-teminatli-menkul-kiymet-nedir/> 20.03.2020 alındı
- Para ve Borsa <https://www.paraborsa.net/i/varliga-dayali-menkul-kiymetler/> 20.03.2020 alındı
- Pathak, B. V. (2010). *The Indian financial system: markets, institutions and services*. Pearson Education India.
- Patterson, J. (2017). *Deep learning : a practitioner's approach*.

- Pehlivanlı, A. Ç., Aşıkil, B., & Gülay, G. (2016). Indicator selection with committee decision of filter methods for stock market price trend in ISE. *Applied Soft Computing*, 49, 792-800.
- Peng, Y., & Jiang, H. (2015). Leverage financial news to predict stock price movements using word embeddings and deep neural networks. *arXiv preprint arXiv:1506.07220*.
- Pérez-Rodríguez, J. V., Torra, S., & Andrada-Felix, J. (2005). Are Spanish Ibex35 stock future index returns forecasted with non-linear models?. *Applied financial economics*, 15(14), 963-975.
- Piesse, J., & Hearn, B. (2005). Regional integration of equity markets in sub-Saharan Africa. *South African Journal of Economics*, 73(1), 36-52.
- Quartey, P., & Gaddah, M. (2007). Long run determinants of stock market development in Ghana. *Journal of African Business*, 8(2), 105-125.
- Quaye, I., Mu, Y., Abudu, B., & Agyare, R. (2016). Review of Stock Markets' Reaction to New Events: Evidence from Brexit. *Journal of financial risk management*, 5(04), 281.
- Saci, K. (2011). Stock markets, banks and economic growth. *Journal of International Real Estate and Construction Studies* 1: 189.
- Sapankevych, N. I., & Sankar, R. (2009). Time series prediction using support vector machines: a survey. *IEEE Computational Intelligence Magazine*, 4(2), 24-38.
- Sarantis, N., & Stewart, C. (1995). Structural, VAR and BVAR models of exchange rate determination: a comparison of their forecasting performance. *Journal of Forecasting*, 14(3), 201-215.
- Sekerbank <https://www.sekerbank.com.tr/yatirimurunleri/yatirim-urunleri/ozelsektorborclanmaaraclari> 20.03.2020 alındı
- Singh, A. 2013. Financial liberalisation, stockmarkets and economic development. *The Economic Journal* 107: 771–82.
- Sowa, N. K. (2002). *An assessment of poverty reducing policies and programmes in Ghana*. Centre for Policy Analysis. Pp 4 – 7.
- Sutskever, I., Vinyals, O., & Le, Q. V. (2014). Sequence to sequence learning with neural networks. In *Advances in neural information processing systems* (pp. 3104-3112).

- Tan, C. N. (2001). *Artificial neural networks: applications in financial distress prediction & foreign exchange trading*. Wilberto.
- Trippi, R. R., & DeSieno, D. (1992). Trading equity index futures with a neural network. *Journal of Portfolio Management*, 19, 27-27.
- Tsai, Y. C., Chen, T. M., Yang, T. Y., & Wang, C. Y. (1999). Neural network used in the investment strategy of stock research. *Web Journal of Chinese Management Review*, 2(5), 25-48.
- Türkmen, A. C., & Cemgil, A. T. (2015, May). An application of deep learning for trade signal prediction in financial markets. In *2015 23rd Signal Processing and Communications Applications Conference (SIU)* (pp. 2521-2524). IEEE.
- Veri, J., & Baba, M. S. (2013). Intelligent Decision Support System For Prediction Of Indonesia Stock Exchanges. Accessed on 22.03.2020 from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.736.4648&rep=rep1&type=pdf>
- Vui, C. S., Soon, G. K., On, C. K., Alfred, R., & Anthony, P. (2013, November). A review of stock market prediction with Artificial neural network (ANN). In *2013 IEEE international conference on control system, computing and engineering* (pp. 477-482). IEEE.
- Wafi, A. S., Hassan, H., & Mabrouk, A. (2015). Fundamental analysis models in financial markets—Review study. *Procedia economics and finance*, 30, 939-947.
- Wan, R., Mei, S., Wang, J., Liu, M., & Yang, F. (2019). Multivariate temporal convolutional network: A deep neural networks approach for multivariate time series forecasting. *Electronics*, 8(8), 876.
- World, I. (2018). 5 guidelines for building a neural network architecture. <https://www.infoworld.com/article/3155052/technologybusiness/5-guidelines-for-building-a-neural-networkarchitecture.html> 25.03.2020 alndi.
- Wu, S.H., (2004). Applying Technical Analysis of Stock Trends to Trading Strategy of Dynamic Portfolio Insurance, *Master's thesis, Department Of Department of Computer Science & Information Management, National Chiao Tung University, Taiwan*.
- Yao, J., Poh, H. L., & Jasic, T. (1996). Foreign exchange rates forecasting with neural networks. In *International Conference on Neural Information Processing (Hong Kong)*.

Zhang, G., & Hu, M. Y. (1998). Neural network forecasting of the British pound/US dollar exchange rate. *Omega*, 26(4), 495-506.

Zimmermann, H. G., Neuneier, R., & Grothmann, R. (2002). Modeling dynamical systems by error correction neural networks. In *Modelling and Forecasting Financial Data* (pp. 237-263). Springer, Boston, MA.

