

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**HİSSE SENEDİ FİYAT TAHMİNİNDE
OTOKODLAYICI VE GRAF EVRİŞİMLİ AĞININ UYGULANMASI**

YÜKSEK LİSANS TEZİ

Mahmut Lutfullah ÖZBİLEN

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

HAZİRAN 2022

**HİSSE SENEDİ FİYAT TAHMİNİNDE
OTOKODLAYICI VE GRAF EVRİŞİMLİ AĞININ UYGULANMASI**

YÜKSEK LİSANS TEZİ

**Mahmut Lutfullah ÖZBİLEN
(504181522)**

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

Tez Danışmanı: Doç. Dr. Yusuf YASLAN

HAZİRAN 2022

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**APPLICATION OF AUTOENCODER AND
GRAPH CONVOLUTIONAL NETWORK
IN STOCK PRICE PREDICTION**

M.Sc. THESIS

**Mahmut Lutfullah ÖZBİLEN
(504181522)**

Department of Computer Engineering

Computer Engineering Programme

Thesis Advisor: Assoc. Prof. Dr. Yusuf YASLAN

HAZİRAN 2022

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 504181522 numaralı Yüksek Lisans öğrencisi Mahmut Lutfullah ÖZBİLEN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “HİSSE SENEDİ FİYAT TAHMİNİNDE OTOKODLAYICI VE GRAF EVRİŞİMLİ AĞININ UYGULANMASI” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Yusuf YASLAN**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Tolga Ovatman**
İstanbul Teknik Üniversitesi

Doç. Dr. Muhammed Ali AYDIN
İstanbul Üniversitesi-Cerrahpaşa

Teslim Tarihi : **02 Haziran 2022**

Savunma Tarihi : **01 Temmuz 2022**





Aileme,



ÖNSÖZ

Tez çalışmamda her türlü desteği gösteren ve araştırmamız boyunca kendisinden çok şey öğrendiğim danışman hocam Doç. Dr. Yusuf YASLAN'a teşekkür ederim. Araştırma boyunca değerli katkılarından dolayı Doç. Dr. Hakan GÜNDÜZ hocama teşekkür ederim.

Çalıştığım kurum TÜBİTAK BİLGEM B3LAB'a ve çalışma arkadaşlarıma ayrıca teşekkür etmek isterim. Bu çalışma boyunca modellerin eğitimi B3LAB GPU kaynaklarıyla yapılmıştır.

Her zaman yanımda olan ve her koşulda bana destek veren sevgili aileme en özel teşekkürlerimi iletirim.

Haziran 2022

Mahmut Lutfullah ÖZBİLEN
(Bilgisayar Mühendisi)

İÇİNDEKİLER

	Sayfa
ÖNSÖZ	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SEMBOLLER	xv
ÇİZELGE LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
1.1 Tezin Amacı	2
1.2 Tezin Yapısı	3
2. İLGİLİ ÇALIŞMALAR	5
2.1 Lineer İstatiksel Yöntemler	5
2.2 Klasik Makine Öğrenmesi	6
2.3 Derin Öğrenme	8
2.3.1 Yinelemeli sinir ağı	8
2.3.2 Evrişimli sinir ağı	9
2.3.3 Graf sinir ağı	10
3. DERİN ÖĞRENME YÖNTEMLERİ	13
3.1 Yapay Sinir Ağı	13
3.2 Evrişimli Sinir Ağı	14
3.3 Otokodlayıcı	15
3.4 Uzun-Kısa Süreli Bellek	16
3.5 Graf Evrişimli Ağı	17
4. HİSSE SENEDİ FİYAT TAHMİN YÖNTEMLERİNİN UYGULANMASI	21
4.1 Mum Grafiklerinden Öznitelik Çıkarımı ve Fiyat Tahmini	21
4.1.1 Mum grafiklerinin oluşturulması	21
4.1.2 Otokodlayıcı modeli	22
4.1.3 Otokodlayıcı ve UKSB ile fiyat tahmini	23
4.2 Borsa Grafından Öznitelik Çıkarımı ve Fiyat Tahmini	25
4.2.1 Borsa grafinin oluşturulması	25
4.2.1.1 Düğüm öznitelikleri	26
4.2.1.2 Kenarların oluşturulması	26
4.2.2 GEA ve UKSB ile fiyat tahmini	27
4.3 Otokodlayıcı, GEA ve UKSB ile fiyat tahmini	28
5. DENEYLER	31
5.1 Yöntemlerin Uygulanması	31
5.2 Veri Seti	31
5.3 Karşılaştırma Kriterleri	31
5.4 Deneysel Sonuçlar	33
6. SONUÇLAR	37
KAYNAKLAR	39
ÖZGEÇMİŞ	43



KISALTMALAR

YSA	: Yapay Sinir Ađı
ESA	: Evriřimli Sinir Ađı
UKSB	: Uzun-Kısa Süreli Bellek
GEA	: Graf Evriřimli Ađ
OMH	: Ortalama Mutlak Hata
OMYH	: Ortalama Mutlak Yüzde Hata
OKH	: Ortalama Kare Hata
GSA	: Graf Sinir Ađ
ORTHO	: Otoregresif Tümleriřik Hareketli Ortalama
ORHO	: Otoregresif Hareketli Ortalama
GTB	: Geçitli Tekrarlayan Birim
ÜHO	: Üssel Hareketli Ortalama
MOM	: Momentum Göstergesi



SEMBOLLER

σ	: Aktivasyon fonksiyonu
t	: Zaman
μ	: Örneklerin ortalaması
s	: Örneklerin standart sapması
σ_g	: Sigmoid fonksiyonu





ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 5.1 : Modellerin fiyat tahminleme performansları.	33
Çizelge 5.2 : Modellerin hisse bazında R^2 skoru performansları.....	34
Çizelge 5.3 : Modellerin hisse bazında OMH sonuçları.	34
Çizelge 5.4 : Modellerin hisse bazında OMYH sonuçları.	34
Çizelge 5.5 : Modellerin hisse bazında OKH sonuçları.....	35





ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 3.1 : Örnek Yapay Sinir Ağı.	14
Şekil 3.2 : Otokodlayıcı mimarisi.....	15
Şekil 3.3 : UKSB hücresinin yapısı.....	16
Şekil 3.4 : Basit graf yapısı.	17
Şekil 4.1 : Mum grafiği.	22
Şekil 4.2 : Veri kümesi içerisinde örnek 20 güne ait mum grafiği.	22
Şekil 4.3 : Önerilen Otokodlayıcı mimarisi.	23
Şekil 4.4 : Otokodlayıcı+UKSB 1 mimarisi.....	24
Şekil 4.5 : Otokodlayıcı+UKSB 2 mimarisi.....	25
Şekil 4.6 : GEA+UKSB 1 mimarisi.	28
Şekil 4.7 : GEA+UKSB 2 mimarisi.	28
Şekil 4.8 : Otokodlayıcı+GEA+UKSB mimarisi.	29



HİSSE SENEDİ FİYAT TAHMİNİNDE OTOKODLAYICI VE GRAF EVRİŞİMLİ AĞININ UYGULANMASI

ÖZET

Finans alanında makine öğrenmesi ve derin öğrenme modellerinin kullanımı son yıllarda artmıştır. Makine öğrenmesi ve derin öğrenme yöntemleri, içerisinde bulunan lineer olmayan aktivasyon fonksiyonları ile finans verilerindeki lineer olmayan ilişkileri öğrenebilmektedir. Finans alanındaki en popüler problemlerden biri de borsadaki hisse senedi fiyatlarının tahminlenmesidir.

Yapay Sinir Ağı (YSA) ve Karar Ağaçları Ormanı gibi klasik makine öğrenmesi yöntemleri özellikle 2000’li yıllarda sıklıkla kullanılmıştır. Derin öğrenme yöntemlerinin diğer alanlardaki başarısının artmasıyla birlikte başta yinelemeli sinir ağı modeli olan Uzun-Kısa Süreli Bellek (UKSB) olmak üzere birçok derin öğrenme yöntemi bu probleme çözüm olarak sunulmuştur. Hisse fiyatı serilerinin görüntülere dönüştürülmesiyle birlikte Otokodlayıcı gibi Evrişimli Sinir Ağı (ESA) tabanlı derin öğrenme yöntemleri de literatürde yer almaktadır. Hisselerin birbirleriyle ilişkilerinin kullanıldığı Graf Evrişimli Ağ (GEA) gibi graf tabanlı yöntemler de son yıllarda birçok çalışmada kullanılmıştır. Tez çalışmasında, gelecek hisse fiyatı tahminlemede Otokodlayıcı ve GEA yöntemlerinin ürettiği özniteliklerin UKSB ile birlikte kullanıldığı yöntemler sunulmuştur.

Yatırımcıların karar alırken mum grafiklerini incelemesinden yola çıkılarak Otokodlayıcı ile mum grafiği görüntülerinden öznitelikler üretilmiştir. Bunun için hisse fiyat bilgilerinden mum grafiği görüntüleri üretilmiştir. Otokodlayıcı modeli girdi olarak bu görüntüleri almakta, kodlayıcı ağı ile bir öznitelik vektörü üretmekte ve kod çözücü ağıyla da vektörü kullanarak mum grafiğini tekrar oluşturmaktadır. Otokodlayıcının girdi olarak alınan mum grafiklerini tekrar oluşturabilmesi, kodlayıcı kısmının ürettiği öznitelik vektörün mum grafiğinden anlamlı bilgiler çıkardığını göstermektedir. Tez çalışmasında da bu üretilen öznitelik vektörü, UKSB ile birlikte iki farklı yöntemde fiyat tahminlemede kullanılmıştır. Otokodlayıcı+UKSB 1 adı verilen ilk yöntemde kodlayıcı tarafından üretilen öznitelik vektörü son 20 günlük fiyat serisine eklenmiş ve UKSB ağına girdi olarak verilmiştir. UKSB ile bu zaman serisi üzerinden fiyat tahmini yapılmıştır. Otokodlayıcı+UKSB 2 adı verilen ikinci yöntemde UKSB girdi olarak sadece 20 günlük fiyat verisini almıştır. UKSB’nin ürettiği öznitelik vektörüyle kodlayıcının ürettiği öznitelik vektörü birleştirilmiş ve YSA’ya ertesi günün fiyatının tahminlemesi için verilmiştir.

Borsadaki firmaların gelecekteki fiyatlarının ilişkili olduğu diğer firmalarla bağlantılı olduğundan hareketle GEA ile öznitelik çıkarımı yapılmıştır. Düğümleri hisse senetleri ve kenarları firmaların ilişkileri olan bir graf oluşturulmuştur. Düğümlerin özniteliği olarak her firmanın geçmiş fiyatlarından elde edilen teknik göstergeler

APPLICATION OF AUTOENCODER AND GRAPH CONVOLUTIONAL NETWORK IN STOCK PRICE PREDICTION

SUMMARY

The use of machine learning and deep learning models in finance has increased in recent years. The main reason for this is that machine learning and deep learning algorithms are successful in learning nonlinear relationships in financial data. One of the most popular problems in finance is predicting stock prices in the stock market. Past studies stated that stock price movements are like random walks that cannot be predictable. Yet it has been the main focus of much study in this area. The motivation for these studies is the idea that predicting stock prices will help investors in their investments.

In the first studies on predicting stock prices, linear statistical methods such as autoregressive integrated moving average (ARIMA) were frequently used. Then, in the researches conducted in the 2000s, machine learning methods such as Artificial Neural Network (ANN), Random Forest and Support Vector Machine performed better as they were able to capture nonlinear information that linear statistical methods could not. With the increase in the success of deep learning methods in other fields, deep learning methods have been presented as a solution to this problem. Long-Short Term Memory (LSTM) and Gated Recurrent Unit (GRU), which are improved versions of Recurrent Neural Network (RNN), have been the primary choice for this problem since they are designed to perform on time series data. Convolutional Neural Network-based deep learning methods such as Autoencoder were also used to solve this problem, with the conversion of stock price series to images and extracting features from those images. Graph-based methods such as Graph Convolutional Network (GCN), in which the relations between stocks are used, have also been utilized in many studies in recent years.

In this thesis, several methods are presented in which using features extracted by Autoencoder and GCN. Autoencoder extracted the features from the candlestick charts while the GCN extracted the features from the stock graph. Additional features were used together with LSTM to predict the future stock price.

Candlestick charts are generated with opening, closing, minimum and maximum price of a stock. They are used by investors while making a decision about a stock. In this study, features were extracted from the images of the candlestick charts with the Autoencoder to get the semantic information. For this, candlestick images were generated from stock prices. Autoencoder model takes these images as input, generates feature vectors with the encoder, and creates candlestick charts by using the vector with the decoder. Autoencoder regenerating candlestick charts means that the feature vector produced by the encoder contains semantic information from the candlestick.

Encoder and decoder networks can be formed by ANNs or CNNs. In this study, 4 fully connected layered ANNs were used to construct the encoder and decoder network. Autoencoder was trained until it generates similar outputs to inputs.

In the next step, extracted feature vector was used in price prediction with LSTM in two different methods. In the first method called Autoencoder+LSTM 1, the feature vector produced by the encoder was added to the price series of the last 20 days and given as an input to the LSTM network. Price prediction was made with LSTM over this time series which contains historical price information and semantic information. In the second method, called Autoencoder+LSTM 2, LSTM took only last 20 days' price data as input. The feature vector produced by the LSTM and the feature vector produced by the encoder were combined and given to the ANN for prediction of the next day's price.

Graph convolutional networks can generate embeddings from graphs for each node, taking into account features at adjacent nodes. In the thesis, features were extracted from stock graph with the help of a GCN, considering that the future prices of the stocks are also related to other stocks. First, stock graph is constructed where nodes represent stocks and edges were the relationships between stocks. As a node feature, the Exponential Moving Average and Momentum Indicator technical indicators were used to provide additional information to the model apart from the historical raw prices. Edges between nodes were established by Pearson product-moment correlation of past stock prices. Since the correlation can take a value between -1 and 1, the edges are created with weights that are the absolute value of the correlation. Absolute values were taken since the high negative correlation between the nodes also indicates a strong connection. Features were created for each firm in the stock market with GCN with 3 graph convolutional layers.

Two methods have been proposed that uses features obtained from the stock market graph with GCN. In the GCN+LSTM 1 method, as in the Autoencoder+LSTM 1 method, the feature vector produced by GCN was added to the 20-day price series and fed to the LSTM. With this way, LSTM input would have both stock relations information and historical stock price information. The feature vector produced in the GCN+LSTM 2 method was combined with the feature produced by LSTM using only past prices and given as input to the ANN and the stock price was predicted.

In the last method proposed within the scope of the thesis, the features produced by Autoencoder, GCN and LSTM were combined. The combined rich feature vector was fed to the ANN and the price was predicted. This method was called Autoencoder+GCN+LSTM.

The performances of the proposed methods had been tested on data from the Standard & Poor 500 (S&P 500) exchange. Stock prices from 2013-02-08 to 2018-02-07 were used. Dataset contains stock prices of 470 firm for 1259 trading days. LSTM trained using only 20 days of price data was chosen as the benchmark method, to see if additional features improve the performance of LSTM in recommended methods. The prediction performances of the methods were evaluated according to the R^2 score, mean absolute error (MAE), mean absolute percentage error (MAPE), and mean square error (MSE). Autoencoder+GCN+LSTM method, which uses Autoencoder, GCN and LSTM features together, achieved the best results in terms of R^2 score and MSE.

Autoencoder+LSTM 1 method achieved the best results on the basis of MAE and GCN+LSTM 2 method achieved the best results on the basis of MAPE.

In this thesis, 5 stock price prediction methods are presented and evaluated on the S&P 500 dataset. In the experiments, the proposed methods achieve better results than the pure LSTM model. This shows that using LSTM models with features obtained from different sources such as candlestick charts and stock market graphs can increase the stock price prediction capacity of the models.





1. GİRİŞ

Makine öğrenmesi algoritmalarının finansal problemlerde aktif olarak kullanılması son dönemde önemli ölçüde artmıştır. Bunun temel nedeni makine öğrenmesi algoritmalarının finansal verilerdeki lineer olmayan ilişkileri kavramada son derece başarılı olmasıdır. Hisse senedi fiyatlarının, altın gibi değerli madenlerin fiyatlarının, petrol fiyatlarının, enflasyonun tahminlenmesi makine öğrenmesinin finansal problemlerde sık uygulandığı alanlardır. Hisse senedi fiyatlarının geçmiş verilerden bağımsız olduğu ve hisse senedi fiyatlarının değişimlerinin rastgele yürüyüşe benzetilmesine [1] rağmen finans alanındaki en popüler problemlerden birisi borsa hisse senetlerinin gelecekteki davranışlarının öngörülmesidir. Bu problemin popüler olmasının temel nedeni borsa hareketlerinin isabetli şekilde tahmin edilmesinin yatırımcılara alım-satım kararlarında yardımcı olacağı düşüncesidir. Hisse senedi fiyatının direkt olarak tahmin edilmesi [2-8] ve hisse fiyatlarının yönünün tespiti [9-13] en sık çalışma yapılan problemlerdendir. Hisse senedi fiyatlarının tahminlenmesinin popüler olmasının bir diğer sebebi de borsa verilerinin halka açık olması sayesinde zaman serisi algoritmaları tasarlayanlar için test verisi olarak da kullanılabilir olmasıdır.

Borsa hisse senetlerinin fiyat bilgileri zaman serisi verileridir. Zamana bağlı olarak değişen bir dizide bulunan tüm veriler zaman serisi verisi olarak tanımlanabilir. Zaman serisi verilerinde bir serinin üzerindeki bir veri noktasının kendisinden önceki verilerle ilişkili olduğu beklenmektedir. Hisse senedi fiyatlarının tahminlenmesiyle ilgili ilk çalışmalarda girdi olarak serinin önceki değerlerini kullanan Otoregresif Tümlleşik Hareketli Ortalama (ORTHO) (İng. Autoregressive Integrated Moving Average) gibi lineer istatistiksel yöntemler sıklıkla kullanılmıştır [2,3]. Ancak lineer metotların borsa verilerindeki lineer olmayan ilişkileri kaçırmasından ötürü Destek Vektör Makinesi (İng. Support Vector Machine), Yapay Sinir Ağı (YSA) (İng. Artificial Neural Networks) ve Karar Ağaçları Ormanı (İng. Random Forest) gibi makine öğrenmesi algoritmalarına sıkça başvurulmuştur [4,5,9,10,12]. Son yıllarda Evrişimli Sinir Ağı

(ESA) (İng. Convolutional Neural Networks) ve Uzun-Kısa Süreli Bellek (UKSB) (İng. Long-Short Term Memory) tabanlı derin öğrenme modelleri hisse fiyatı tahminlerinde istatistiksel yöntemlere ve klasik makine öğrenmesi yöntemlerine göre oldukça üstün performans göstermiştir [11,14].

Hisse senedi verilerindeki temel öznitelik serinin geçmiş fiyatları olsa da birçok çalışma veriye ilgili kullanılabilecek ekstra özniteliklerin başarıyı arttırdığını göstermiştir. Geçmiş çalışmalarda ham hisse fiyatları içerisinden anlamlı bilgiler çıkarıp öznitelik olarak kullanmak adına hisse bilgileri görüntülere çevrilmiş ve derin öğrenme algoritmalarına beslenmiştir [15-18]. Başka bir yaklaşımda da borsa şirketlerinin birbiriyle ilişkisi olduğundan yola çıkılarak oluşturulan graflar üzerinden Graf Sinir Ağlar (GSA) (İng. Graph Neural Network) ile öznitelikler üretilmiş ve hisse fiyatlarının tahminlenmesi gerçekleştirilmiştir [19-22].

Bu çalışmada derin öğrenme tabanlı öznitelik çıkarımı yöntemleri geliştirilmiştir. Çıkarılan öznitelikler daha sonra ham fiyat verileri ile birlikte UKSB modeliyle kullanılmış ve bir sonraki günün kapanış fiyatı tahminlenmiştir.

1.1 Tezin Amacı

Tez çalışmasının amacı derin öğrenme tabanlı öznitelik çıkarım yöntemlerini UKSB modeli ile birlikte kullanarak borsa hisse senedi fiyatı tahminlemesi yapmaktır. Bu amaçla temelde iki farklı öznitelik çıkarım yöntemi kullanılmıştır: Otokodlayıcı (İng. Autoencoder) ile mum grafiklerinden öznitelik vektörü ve Graf Evrişimli Ağ (GEA) (İng. Graph Convolutional Network) ile stok firma ilişkilerinden graf temsili çıkarılmıştır. Veri seti olarak Standard & Poor 500 (S&P 500) borsa endeksi üzerindeki borsa hisse senedi fiyatları kullanılmıştır.

Otokodlayıcı tabanlı öznitelik çıkarım yöntemindeki amaç yatırımcıların da hisse senedi fiyatlarını yorumlamak için kullandığı mum grafiklerinden anlamlı bilgiler çıkartmaktır. Bu amaçla ilk olarak fiyat bilgilerinden her gün için mum grafiği görüntüleri üretilmiştir. Üretilen mum grafikleri ile Otokodlayıcı modeli eğitilmiştir. Eğitilen modelin girdisi gerçek mum grafiği, çıktısı da üretilmiş mum grafiğidir. Modelin kodlayıcı kısmının ürettiği temsil vektörü mum grafiğine ait öznitelik olarak

kullanılmıştır. Hisse senedi fiyatı tahmininde üretilen temsil vektörü ham fiyat bilgileri ile birleştirilip UKSB modeline beslenmiş ve fiyat tahminlemesi yapılmıştır. Otokodlayıcı tabanlı ikinci yöntemde ise UKSB'ye girdi olarak kapanış fiyat serisi verilmiş ve ürettiği özniteliklerle Otokodlayıcının ürettiği öznitelikler birleştirilmiş ve YSA ile hisse senedi fiyatı tahmin edilmiştir.

GEA tabanlı öznitelik çıkarımı yöntemi için öncelikle her güne ait S&P 500 borsasının grafları üretilmiştir. Graftaki düğümler firmaları kenarlar ise firmaların arasındaki ilişkileri temsil etmektedir. Düğüm özniteliği olarak geçmiş fiyatlara ait teknik göstergeler kullanılmıştır. Firmaların arasındaki ilişki firmaların geçmişteki fiyatlarının korelasyonu ile hesaplanmıştır. GEA ile grafin temsil vektörü hesaplanmış ardından bu vektör ham fiyat verileri ile birleştirilip gelecek fiyat tahminlemesi yapılmıştır. Aynı zamanda UKSB'nin sadece geçmiş fiyatları ürettiği öznitelik vektörü ile graftan elde edilen öznitelik vektörü birlikte YSA'ya beslenerek ikinci bir graf tabanlı yöntemle bir gün sonranın fiyatları tahmin edilmiştir.

Otokodlayıcı ve Graf Evrişimli Ağlar ile elde edilen özniteliklerin birlikte kullanıldığı bir yöntem de tez kapsamında uygulanmıştır. Bu yöntemde Otokodlayıcı, Graf Evrişimli ağ ve UKSB ile elde edilen öznitelik vektörleri birleştirilerek tek bir öznitelik altında toplanmıştır. Elde edilen geniş öznitelik vektörü ile YSA kullanılarak gelecek fiyat tahminlemesi yapılmıştır.

Yöntemlerin regresyon performansları hem kendi aralarında hem de referans olarak kullanılan UKSB modeli ile karşılaştırılmıştır. Başarım ölçütü olarak R^2 skor, ortalama mutlak hata (OMH) (İng. Mean Absolute Error), ortalama mutlak yüzde hata (İng. Mean Absolute Percentage Error) (OMYH), ortalama kare hata (OKH) (İng. Mean Squared Error) kullanılmıştır.

1.2 Tezin Yapısı

İlk bölümde giriş yapılmış ve tezin amacından bahsedilmiştir. 2. Bölüm'de literatürde borsa hisse senedi tahminiyle ilgili çalışmalar irdelenmiştir. 3. Bölüm'de tezde kullanılan derin öğrenme yöntemlerinin temelleri anlatılmıştır. 4. Bölüm'de tezde önerilen yöntemlerin uygulaması detaylı olarak verilmiştir. Yöntemlerin test edildiği

deneylerden ve elde edilen sonuçlardan 5. Bölüm’de bahsedilmiştir. 6. Bölüm’de tezin sonucuyla ilgili değerlendirmelere yer verilmiştir.



2. İLGİLİ ÇALIŞMALAR

Finansal verilerin tahminlenmesinde yıllardır çeşitli yöntemler denenmiştir. Bu konudaki ilk çalışmalarda Otoregresif Tümlleşik Hareketli Ortalama gibi istatistiksel lineer metotlar uygulanmıştır. Ardından makine öğrenmesi yöntemlerinin etkinliğinin kanıtlanmasıyla birlikte Karar Ağaçları Ormanı, Destek Vektör Makinesi ve Yapay Sinir Ağları gibi yöntemlerin kullanımı artmıştır. Klasik makine öğrenme yöntemleri gerek tek başlarına gerekse istatistiksel yöntemlerle birlikte hibrid olarak kullanılmıştır. 2010'lu yıllarla birlikte zaman serisi verilerinde büyük başarılar gösteren UKSB ve öznitelik çıkarımında yetenekleri kanıtlanmış ESA modelleri bu problem için araştırmacılar tarafından daha sofistike çözümler üretmek adına kullanılmıştır. Borsa içerisindeki firmaların birbirleriyle ilişkilerinin kullanılabilmesi için de Graf Sinir Ağı tabanlı yöntemler son yıllarda sıkça kullanılmaya başlanmıştır. Bu bölümde borsa hisse senetlerinin tahminlenmesinde literatürdeki yöntemler irdelenecektir.

2.1 Lineer İstatiksel Yöntemler

Zaman serisi problemlerinde kullanılan en temel yöntemler lineer istatistiksel yöntemlerdir. Bu yöntemler zaman serisinin içerisindeki lineer ilişkileri yakalamaya çalışarak seriyi modellerler. En sık kullanılan lineer zaman serisi modelleri otoregresyon modelleri, hareketli ortalama, otoregresyon ve hareketli ortalamanın birlikte kullanıldığı Otoregresif Hareketli Ortalama (ORHO) (İng. Autoregressive Moving Average) ve son olarak ORHO'nun genişletilmiş versiyonu olan Otoregresif Tümlleşik Hareketli Ortalamadır. Bu modellerde gelecekteki değerler serinin geçmişteki değerlerine göre tahminlenir. Makine öğrenmesi yöntemlerinin kullanımının artmasıyla birlikte bir süre sonra karşılaştırılan veya referans olarak görülen yöntemler olarak da değerlendirilmişlerdir.

2012 yılında Anaghi ve Norouzi çalışmalarında, seçilen bir hisse senedi fiyatı serisinde ORHO modeliyle bir sonraki günün fiyatını hesaplayan modeller geliştirmiştir [2]. Modellerin farklı parametreleri için hatalar ölçülmüş ve ilgili seri için en uygun parametre kümesi seçilmiştir.

Ariyo ve diğ. New York Borsa'sındaki ve Nijerya Borsa'sındaki hisse senetlerinin kısa vadedeki fiyatlarının tahminlemesini ORTHO modeli ile gerçekleştirmiştir [3]. Bu çalışmada tatmin edici sonuçların elde edildiği ve diğer tahminleme yöntemleriyle birlikte kullanımının değerlendirilebileceği belirtilmiştir.

Borsa hisse senetlerinin tahminlenmesinin yanında enflasyon oranları, altın fiyatları, petrol fiyatları gibi diğer finansal verilerin tahminlenmesinde de istatistiksel yöntemler kullanılmıştır. Meyler ve diğ. 1998 yılında ORTHO yöntemi ile İrlanda enflasyon oranlarını modelleyerek gelecekteki oranları tahminlemiştir [23]. Çalışmada ORTHO modelinin kurulmasında Box-Jenkins yöntemi ve objektif ceza fonksiyonu kullanılmış ve performansları kıyaslanmıştır. Sonuç olarak iki yöntemin kendisine göre avantajları ve dezavantajları olduğu için tahminleme performansı açısından model seçiminde en gürbüz yöntemin birçok modeli ele almak olduğu çıkarımı yapılmıştır.

2.2 Klasik Makine Öğrenmesi

Makine öğrenmesi yöntemlerinde algoritmalar, var olan gözlemlerden yola çıkarak verinin içerisindeki ilişkileri saptayıp verilen çıktıları tahmin etmek için kullanılmaktadır. Finans alanında da benzer şekilde geçmişteki verileri kullanarak öğrenen makine öğrenmesi algoritmalarından yoğun bir şekilde istifade edilmiştir. En sık kullanılan yöntemler Karar Ağaçları Ormanı, Destek Vektör Makineleri ve Yapay Sinir Ağı olmakla birlikte hazır kütüphanelerin sağladığı kolaylıkla diğer makine öğrenmesi algoritmaları da birçok çalışmada test edilmiştir.

Zhang, 1999 yılında yayınladığı çalışmasında zaman serisi verilerinin tahminlenmesinde ORTHO ve YSA'yı birlikte kullanan bir yöntem sunmuştur [24]. ORTHO'nun serideki lineer ilişkileri YSA'nın da lineer olmayan ilişkileri yakalayabilmesi sayesinde bu yöntemle, iki yöntemin ayrı ayrı kullanılmasından daha iyi sonuçlar elde

edildiği belirtilmiştir. Geliştirdiği yöntemi birisi İngiltere sterlini ve Amerikan doları arasındaki kur oranı olmak üzere 3 farklı veri setinde test etmiştir.

Leung ve diğ. hisse senedi yönünün öngörülmesinde graf verilerini girdi olarak alan Yapısal Destek Vektör Makinesi algoritması tasarlamışlardır [9]. S&P 500 borsasındaki teknoloji firmalarının grafını oluştururken düğümleri firmaların özniteliği oluşturmuş, kenarlar da firmaların iş birliğine göre kurulmuştur. Düğümlerin öznitelikleri firmaların anlık ve geçmişe ait finansal özelliklerini içermektedir. Yapısal Destek Vektör Makinesi eğitilirken minimum graf kesitleri kullanılarak başarılı sonuçlar elde edildiği belirtilmiştir.

2015 yılında Ballings ve diğ. Topluluk Öğrenmesi (İng. Ensemble Learning) algoritmalarının hisse senedi fiyat trendinin tespitinde iyi bir performans göstereceğini öne sürmüş ve geniş bir makine öğrenmesi algoritma kümesiyle karşılaştırmıştır [10]. Topluluk öğrenmesi algoritmaları olarak Karar Ağaçları Ormanı, AdaBoost yöntemi ve Kernel Factory algoritmasını kullanmış ve diğer sınıflandırıcı algoritmalarından YSA, Lojistik Regresyon, Destek Vektör Makineleri ve K-en Yakın Komşu ile kıyaslanmıştır. Algoritmalar, Avrupa'daki 5767 adet firmanın yıllık hisse verisi üzerinde uygulanmıştır. Öznitelik olarak geçmiş yıla ait hisse fiyatının yanında o yıla ait finansal göstergeleri de içeren 81 adet değişken kullanılmıştır. Sonuç olarak en iyi performansı gösteren algoritmanın Karar Ağaçları Ormanı algoritması olduğu ortaya çıkmış ve en iyi performans gösteren dört algoritmadan üçü Topluluk Öğrenmesi algoritmaları olmuştur.

Temiz enerji kaynaklarının öneminin artmasıyla birlikte bu alanda çalışma yapan şirketlere olan yatırımlar da benzer ölçüde artmıştır. Bu sebeple Sadorsky, beş temiz enerji firmasının hisse senetlerinin 1 gün ve 20 gün sonraki yönünün tahminlenmesi üzerine çalışmıştır [12]. Çalışmasında ağaç tabanlı algoritmalar olan Karar Ağaçları Ormanı ve Karar Ağacı Torbalama (İng. Decision Tree Bagging) algoritmalarını kullanmış ve performansları Lojistik Regresyonla karşılaştırmıştır. Algoritmalara öznitelik olarak teknik göstergelerden göreceli güç endeksi, stokastik osilatör, yükseklik düşüş çizgisi, hareketli ortalamaların mesafesi, değişim yüzdesi, denge işleme hacmi ve 200 günlük hareketli ortalamayla beslemiştir. Yapılan deneyler

sonucunda Karar Ağaçları Ormanı ve Karar Ağacı Torbalama yöntemlerinin Lojistik Regresyona göre daha başarılı sonuçlar ürettiği ortaya çıkmıştır.

2.3 Derin Öğrenme

2010'lu yıllarda ESA tabanlı derin öğrenme algoritmalarının görüntü sınıflandırmada diğer metotlara göre çok üstün bir performans göstermesiyle birlikte derin öğrenme yöntemleri diğer alanlarda da sıklıkla kullanılmaya başlanmıştır. Yinelemeli Sinir Ağı (İng. Recurrent Neural Network) tabanlı yöntemler de özellikle zaman serisi verilerinde başarılı olduğu için borsa hisse senetlerinin öngörülmesinde sıkça kullanılmıştır. Hisse senetlerini graf yapısında ele alıp firmaların hisselerin arasındaki ilişkilerden GSA ile yararlanan çalışmalar da literatürde görülmektedir. Bu başlıkta literatürdeki Yinelemeli Sinir Ağı, ESA ve GSA tabanlı çalışmalardan bahsedilmiştir.

2.3.1 Yinelemeli sinir ağı

Fischer ve Krauss 2017 yılında yayınladıkları çalışmada S&P 500 borsasındaki hisselerin getirilerini tespit edebilmek adına UKSB algoritmasını kullanılmıştır [14]. Performansını karşılaştırmak adına aynı veri kümesinde Karar Ağaçları Ormanı, Derin Sinir Ağlar ve Lojistik Regresyonla da deneyler yapılmıştır. Öznitelik olarak son 240 günün getirilerini kullanan yazarlar problemi bir sınıflandırma problemi olarak ele almıştır. Bunu yapabilmek adına her hissenin getirisini bir dizide sıralamış ve medyandan büyük olanların etiketine pozitif sınıf atayıp küçük olanlara negatif sınıf atanmıştır. Eğitilen modellerle algoritmaları test edebilmek için test kümesinde modellerin tahminleriyle bir alım-satım simülasyonu uygulanmıştır. Sonuçta UKSB yöntemi hem tahminleme başarısı hem de getiriler bakımından her konfigürasyon için Derin Sinir Ağlarından ve Lojistik Regresyondan çok daha iyi performans gösterirken Karar Ağaçları Ormanı algoritmasından da çoğunlukla daha iyi sonuçlar elde etmiştir.

Yinelemeli Sinir Ağı yöntemlerinin hisse senedi fiyatlarının tahminlenmesindeki performanslarını kıyaslamak için Dey ve diğ. Yinelemeli Sinir Ağı, Geçitli Tekrarlayan Birim (GTB) (İng. Gated Recurrent Unit) ve UKSB metotlarını üç firmanın borsa verileri üzerinde test etmiştir [8]. Üç tane hisse senedi zaman

içinde çok, orta ve az dalgalanan olacak şekilde seçilmiştir. Ayrıca ertesi günün, üç gün sonrasının ve beş gün sonrasının fiyatları tahminlenmiştir. Bu sayede her yöntem 9 farklı konfigürasyonda test edilmiştir. Deneylerin sonucunda GTB ve UKSB genel olarak Yinelemeli Sinir Ağı modeline üstünlük kurmuştur. Bunun temel nedeni de Yinelemeli Sinir Ağı'nın maruz kaldığı kaybolan gradyanlar problemi olarak açıklanmıştır. GTB çok ve az dalgalanan hisse senedinde UKSB'den daha iyi performans gösterirken UKSB orta seviyede dalgalanan hisse senedinde daha başarılı olmuştur.

Shahi ve diğ. Nepal borsa hisse senetlerinin fiyatlarının regresyonunda UKSB ve GTB modellerini karşılaştırmış ve finansal özniteliklerin tahmin kapasitesi üzerindeki etkisini incelemiştir [7]. Karşılaştırmada öznitelik olarak geçmiş fiyat bilgileri ve finansal haberleri kullanılmıştır. Sadece geçmiş fiyat bilgilerinin kullanıldığı öznitelik kümesinde UKSB ve GTB modelleri çok yakın sonuçlar üretmiş ve GTB küçük bir farkla daha iyi bir sonuç göstermiştir. Finansal haberleri ek öznitelik olarak eklendiği zaman modellerinin performansları yüksek oranda artmış ve UKSB daha iyi sonuçlar üretmiştir. Tez çalışmasında da bahsedilen çalışmada olduğu gibi ekstra özniteliklerle modellerin öğrenme kapasitesi arttırılmaya çalışılmıştır.

2.3.2 Evrişimli sinir ağı

2010'lu yıllarda ESA modellerinin görüntü sınıflandırma yarışmalarında klasik metotlara üstünlük kurmasıyla birlikte birçok alanda ESA modellerinin kullanımı artmıştır. Son yıllarda hisse senedi tahminlemesinde de geçmiş fiyatları görüntülere dönüştürerek öznitelik çıkaran yöntemler kullanılmaya başlanmıştır.

2017 yılında Gündüz ve diğ. Borsa İstanbul 100 hisse fiyatlarının gün içi fiyat yönünü tespit edebilmek adına ESA tabanlı bir yöntem geliştirmiştir [13]. Fiyat bilgileri, teknik indikatörler ve zamansal bilgiler gibi öznitelikleri aralarındaki korelasyona göre düzenleyip ESA mimarileri beslenmiştir. Önerdikleri yöntemin performansını ölçmek için Lojistik Regresyon ve özniteliklerin rastgele sıralandığı girdiyi kullanan ESA modeli ile karşılaştırılmıştır. Önerilen ESA mimarisi karşılaştırılan yöntemlerden daha başarılı olmuştur.

Hu ve diğ. FTSE 100 borsasında portföy oluşturmada hisse senedi fiyatlarını mum grafiğine çevirip Otokodlayıcı ile öznitelik çıkarımı yapan bir yöntem sunmuştur [15]. Bu yöntemde ilk olarak hisse senetlerinin son 20 günlük fiyat verisinden mum grafikleri oluşturulmuştur. Ardından Evrişimli Otokodlayıcı ile mum grafiği görüntüleri tekrar oluşturulmuştur. Portföy oluşturmada Otokodlayıcı modelinin kodlayıcı kısmında üretilen öznitelikler alınmış ve hisseler graf haline getirilmiştir. Graf oluşturulurken her hisse bir düğüm olarak tanımlanmış düğümler arasındaki kenarların ağırlığı de Otokodlayıcı özniteliklerin arasındaki kosinüs benzerliği ile hesaplanmıştır. Oluşturulan graf, modülerite yöntemleriyle kümelere ayrılmıştır. Portföy oluşturulurken de her kümedeki en iyi Sharpe oranına sahip hisse seçilmiş ve bu şekilde risk azaltılmaya çalışılmıştır. Bu sayede Otokodlayıcı ile çıkarılan özniteliklerle kümeleme yapıp portföy oluşturulmuştur. Tez çalışmasında da bu çalışmadan esinlenilerek mum grafiğinden Otokodlayıcı ile öznitelik çıkarımı yapılmıştır.

Guo ve Kim benzer şekilde mum grafiklerin evrişimli Otokodlayıcı ile öznitelik çıkarmıştır [18]. Özniteliğin kosinüs benzerliği ile trend yönü değerini çarpıp bir benzerlik öznitelik vektörü oluşturmuştur. Aynı zamanda fiyat verileri ve teknik indikatörleri Pearson çarpım moment korelasyon katsayısı ile öznitelik seçimi yapıp ikinci öznitelik vektörünü oluşturmuştur. Bu iki öznitelik vektörü ile de UKSB modelini besleyip trend tahminlemesi yapmıştır. Model Şangay Kompozit Endeksi, SZSE, CSI 300, ve SSE 50 borsalarında test edilmiştir. Sunulan modelin performansını sadece teknik indikatörleri girdi olarak alan UKSB modeliyle karşılaştırılmış ve mum grafiğinden çıkarılan bilgileri de kullanan modelin daha iyi performans gösterdiği belirtilmiştir.

2.3.3 Graf sinir ağı

Graf halinde ifade edilebilen verilerden öznitelik çıkarmak için Graf Sinir Ağları ve Graf Evrişimli Ağlar sıklıkla kullanılmaktadır. Hisse senedi tahmininde de son yıllarda bu yöntemler çokça kullanılmaya başlanmıştır.

Peng hisse senedi yönünü tahminleyen bir dizi GSA tabanlı yöntem önermiştir [19]. Borsa grafının kenarları üç farklı şekilde oluşturmuştur: sektör ilişkileri, geçmiş

fiyatların korelasyonu ve dinamik zaman bükme yöntemi kullanılarak. Üç farklı graf deneylerde ayrı ayrı eğitilmiştir. Ayrıca üç grafi da birlikte kullanacak bir yöntem geliştirilmiştir. Graf tabanlı yöntemlere ek olarak borsa grafını bir maske olarak kullanan bir Transformer model de ayrıca tasarlanmıştır. Karşılaştırma yapabilmek adına saf UKSB modeli de eğitilmiştir. Yöntemler New York borsa verisi üzerinde test edilmiştir. Genel olarak grafları tahminlemede kullanmak performansı iyileştirmiştir. En iyi sonuç veren yöntem borsa grafını maske olarak kullanan Transformer modeli olmuştur.

Li ve diğ. hisse fiyat yönü problemini farklı bir şekilde ele almışlardır [20]. Genelde hisse yönü iki günün kapanış fiyatları arasından hesaplanırken bu çalışmada bir günün kapanış fiyatıyla bir sonraki günün açılış fiyatına göre hissenin yönünü tahminleme çalışılmıştır. Bunu yaparken de o gece yayınlanan haberler dikkate alınmıştır. Hisseleri graf olarak tanımlayan bu çalışmada da hisseler arasındaki ilişki geçmiş fiyatların korelasyonlarına göre kurulmuştur. Haberler Attention mekanizmalı UKSB ile kodlanarak düğümlerin öznitelik vektörünü oluşturmuştur. Grafın temsilini çıkarırken klasik GEA kullanmak yerine ara katmanlara UKSB'nin eklendiği LSTM-RGCN isimli bir metot öne sürülmüştür. Tokyo Hisse Senedi Fiyat Endeksi üzerinde yapılan deneylerde sunulan yöntem; makine öğrenmesi, Attention mekanizması ve UKSB tabanlı karşılaştırılan yöntemlerden daha iyi sonuçlar elde etmiştir. Ayrıca yöntem, hisse grafını kullanması sayesinde kendisiyle ilgili hiçbir haber bulunmayan hisseler için de başarılı tahminlerde bulunmuştur.

2021 yılında Chen ve diğ. hisse yönünü tahminlemek adına GEA tabanlı bir yöntem önermiştir [21]. Yöntemde graf üzerinden ve geçmiş hisse fiyatları üzerinden olacak şekilde 2 farklı öznitelik çıkarım yöntemi geliştirip yön tahminlemesi yapılmıştır. Graf tabanlı yöntemde hisseler arasındaki korelasyondan yola çıkılarak öznitelikler oluşturulmuştur. Hisselerle ilgili bilgiler Graf Evrişimli Ağ tarafından çıkarılmıştır. Diğer yandan hisselerle özel geçmiş fiyat bilgilerinden ve teknik indikatörlerden görüntüler üretilmiş ve İkili ESA (İng. Dual CNN) ile öznitelik çıkarılmıştır. Çıkarılan özniteliklerle hisselerin yönü tahmin edilmiştir. Çin borsasından rastgele seçilen 6 hisse üzerinden deneyler yapılmış ve modelin tahmin performansı klasik makine öğrenmesi ve derin öğrenme yöntemleri ile karşılaştırılmıştır. Ayrıca modelin

ıktıları ile alım-satım simle edilmiř ve sık kullanılan hisse alım-satım yntemleri ile karřılařtırılmıřtır. nerilen yntem genel olarak diğeryntemlerden daha bařarılı sonular elde etmiřtir.



3. DERİN ÖĞRENME YÖNTEMLERİ

Tez çalışmasında hisse senetlerinin gelecekteki değerlerinin tahmin edilmesi için çeşitli derin öğrenme yöntemleri kullanılmıştır. Bu bölümde kullanılan yöntemlerin temellerinden bahsedilecektir. İlk olarak derin öğrenmenin yapı taşı olarak adlandırılabilir Yapay Sinir Ağları hakkında bilgi verilecektir. Ardından Evrişimli Sinir Ağlarından, UKSB'den, Otokodlayıcı ağlarından ve Graf Evrişimli Ağlardan bahsedilecektir.


3.1 Yapay Sinir Ağı

Yapay Sinir Ağları temelleri 20. yüzyılın ortalarına dayanan, beynin nöron yapısından esinlenen bir makine öğrenmesi yöntemidir. Bu yönteme Çok Katmanlı Algılayıcı (İng. Multilayer Perceptron) da denmektedir. Yapay Sinir Ağı girdi katmanı, gizli katmanlar ve çıktı katmanından oluşur. Kaç katman olacağı ve katmanlardaki nöron sayısı probleme göre seçilen hiper parametrelerdir. Yapay Sinir Ağı en basit anlamda girdileri ağırlık parametreleriyle çarpıp, değerleri topladıktan sonra lineer olmayan fonksiyonlardan geçirme işlemidir. Şekil 3.1'da basit bir Yapay Sinir Ağı mimarisi gösterilmiştir.

Girdiler katmanlarda kendilerine atanmış olan öğrenilebilir parametrelere (ağırlıklar) çarpılıp toplanır. Çarpma ve toplama işlemlerinden sonra problemdeki lineer olmayan ilişkileri kavrayabilmek ve modelin öğrenebilme kapasitesini arttırmak için lineer olmayan aktivasyon fonksiyonlarından geçirilir. Denklem 3.1'de katmanlardaki temel işlemi göstermektedir.

$$Y' = \sigma(XW + b) \quad (3.1)$$

Y' katmanın çıktısını, X girdi vektörünü, W ağırlık vektörünü, b yanlılık değerini ve σ fonksiyonu da aktivasyon fonksiyonunu ifade eder. İleri yayılım (İng. Forward Propagation) olarak adlandırılan bu işlemler girdi katmanından başlayarak gizli katmanlar üzerinden son katmana kadar yapılmaktadır. Son katmana gelindiğinde



Şekil 3.1 : Örnek Yapay Sinir Ağı.

ağın girişinde verilen öznelik vektörüne ait sonucu üretir. Eğitim aşamasında üretilen değer ile gerçek değer arasındaki hata hesaplanır. Eğitim boyunca hataların minimize edilmesi adına geri yayılım (İng. Backpropagation) yöntemiyle hata fonksiyonunu minimize edecek şekilde gradyanlar hesaplanır ve parametreler güncellenir [25]. Parametreler güncellenirken gradyanların parametreleri ne kadar güncelleyeceği öğrenme oranı ile belirlenir (İng. Learning Rate). Bu sayede eğitim kümesindeki tarihsel verilerden modelin ağırlıkları hedefi doğru şekilde tahmin edebilecek şekilde güncellenir.

3.2 Evrişimli Sinir Ağı


Evrişimli Sinir Ağı girdinin içerisindeki uzaysal bilgilerini de öğrenebilme yeteneğine sahip bir derin öğrenme yöntemidir. Görüntülerin içerisindeki piksellerin komşularıyla ilişkileri öğrenebildiği için görüntü sınıflandırma gibi problemlerde oldukça başarılıdır. Yapay Sinir Ağlarındaki gibi tüm girdiyi katmandaki her nöron için bir parametre ile işlemek yerine içerisindeki ağırlıkların öğrenilebilir parametreler olduğu bir filtreyi girdinin üzerinde dolaştırır. Bu sayede model içerisindeki parametre sayısı azaltılmakta ve girdinin üzerindeki komşu verilerin arasındaki ilişkiler daha iyi bir şekilde yakalanmaktadır. Filtre içerisindeki parametrelerle üzerinde olduğu girdi değerleri üzerinde çarpma ve toplama işlemleri gerçekleştirilir ve sonuçlar lineer olmayan aktivasyon fonksiyonundan geçirilir. Filtre tüm girdi üzerindeki

dolaşımını tamamladığı zaman girdinin bir temsili olan öznitelik haritası ortaya çıkar. Birden fazla evrişimsel katmanlarla temsillerin de temsilleri çıkarılabilir ve öznitelik olarak kullanılabilir. Evrişimli Sinir Ağlarında parametrelerin güncellenmesi eğitim aşamasında geri beslemeyle sağlanmaktadır.

3.3 Otokodlayıcı

Otokodlayıcı sinir ağlarının özelleştirilmiş bir modeli olan denetimsiz öğrenme yöntemidir. Otokodlayıcılar kodlayıcı ağ ile girdinin boyutunu indirgeyip gizli vektör (İng. Latent Vector) oluşturur ve kod çözücü ağ ile tekrar aynı girdiyi oluşturmaya çalışır. Eğer Otokodlayıcı girdiye çok yakın çıktılar oluşturabiliyorsa gizli vektör girdiyi iyi bir şekilde temsil edebiliyor demektir [26]. Oluşturulan gizli vektör girdinin bir özniteliği olarak kullanılabilir.

Kodlayıcı ağı girdinin boyutunu giderek azaltırken kod çözücü ağ da gizli vektörün boyutunu arttırarak girdinin boyutuna çıkartır. Modelin çıktısında alınan hata oluşturulan çıktının girdiyle arasındaki fark üzerinden hesaplanır. Kodlayıcı ve kod çözücü ağ Yapay Sinir Ağı veya Evrişimli Sinir Ağı olabilmektedir. Şekil 3.2’de Otokodlayıcı mimarisi gösterilmektedir.




Şekil 3.2 : Otokodlayıcı mimarisi.

Otokodlayıcılar görüntülerin anlamsal bilgilerini taşıyan temsil vektörü oluşturmak adına sıkça kullanılmaktadır [15,18]. Tez çalışmasında da mum grafiğinden Otokodlayıcı ile öznitelik vektörü oluşturulmuş ve hisse senedi fiyatı tahminlenmesinde kullanılmıştır.

3.4 Uzun-Kısa Süreli Bellek

Uzun-Kısa Süreli Bellek Hochreiter ve Schmidhuber tarafından 1997 yılında sunulan Yinelemeli Sinir Ağlarının geliştirilmiş bir versiyonudur [27]. UKSB Yinelemeli Sinir Ağlarındaki kaybolan gradyanlar problemini çözmek için oluşturulmuştur. Yinelemeli Sinir Ağlarının hiperbolik tanjant fonksiyonu (tanh) içeren tek katmanlı basit bir yapısı bulunmaktadır. UKSB, içerisinde birçok sigmoid ve tanh katmanı içeren daha kompleks bir yapıdır. Şekil 3.3'te UKSB'nin genel yapısı gösterilmiştir.



Şekil 3.3 : UKSB hücresinin yapısı.

USKB'de hücreler arasındaki bilgi akışı hücre durumu (İng. Cell State) ve gizli durumu (İng. Hidden State) üzerinden gerçekleştirilir. UKSB hücresi sekansın her adımında girdiyi ve bir önceki hücreden hücre durumu ile gizli durumu alır. Hücre durumundaki hangi bilgilerin alınacağı unut kapısı ile belirlenir. Unut kapısındaki sigmoid fonksiyon 0 ile 1 arasında bir değer üretir ve hücre durumu ile element bazında çarpılır. Bu sayede önceki hücre durumundaki bilgilerden ne oranda alınacağı belirlenir. Giriş kapısında hangi bilgilerin hücre durumuna aktarılacağı benzer şekilde sigmoid katmanıyla belirlenir. Aday vektörü de girdinin ve gizli durumun tanh katmanından geçirilmesiyle oluşturulur. Giriş kapısı ile aday vektör element bazında çarpılır ve hücre durumuna eklenir. Çıkış kapısında da hangi değerlerin çıktı olarak verileceğine yine sigmoid katmanı ile karar verilmektedir. Denklem 3.2'de unut kapısı, giriş kapısı, aday vektörü ve çıkış kapısının hesaplanması gösterilmektedir.

$$\begin{aligned}
f_t &= \sigma_g(W_f x_t + U_f h_{t-1} + B_f) \\
i_t &= \sigma_g(W_i x_t + U_i h_{t-1} + B_i) \\
c'_t &= \tanh(W_{c'} x_t + U_{c'} h_{t-1} + B_{c'}) \\
o_t &= \sigma_g(W_o x_t + U_o h_{t-1} + B_o)
\end{aligned} \tag{3.2}$$

Denklem 3.2’de x_t t anındaki girdiyi ve h_{t-1} $t - 1$ anındaki gizli durumu ifade eder. f_t , i_t , o_t unut kapısı, giriş kapısı ve çıkış kapılarının çıktılarıdır. c'_t hesaplanan aday vektörüdür. W_p , U_p , B_p sembolleri de girdinin ağırlığı, gizli durumların ağırlığını ve yanlılık vektörünü temsil eder. σ_g sembolü de sigmoid aktivasyon fonksiyonudur.


Hücresinin t anı için hücre durumu (c_t) ve gizli durumu (h_t) Denklem 3.3’te gösterildiği şekilde hesaplanmaktadır:

$$\begin{aligned}
c_t &= (f_t \circ c_{t-1}) + (i_t \circ c'_t) \\
h_t &= o_t \circ \tanh(c_t)
\end{aligned} \tag{3.3}$$

Hücresinin t anı için oluşturulan gizli durum genelde sekanstan elde edilen öznitelik olarak kullanılmaktadır. Tez çalışmasında da borsa verilerinden gelecek hisse fiyatlarını tahminlemek adına UKSB’den çıkarılan öznitelikler kullanılmıştır.

3.5 Graf Evrişimli Ağı

Graflar içerisindeki elemanların aralarında ikili ilişkilerinin bulunduğu veri yapılarıdır. Graf üzerindeki elemanlara düğüm adı verilir. Düğümler arasındaki ilişkiler kenarlar ile sağlanır. Graf veri yapılarına örnek olarak sosyal medya ağları verilebilir. Sosyal medya kullanıcıları düğüm ve birbirleriyle bağlantı kurma/arkadaşlık durumları da kenarlar ile tanımlanabilir. Şekil 3.4’te basit bir graf verisi gösterilmiştir.



Şekil 3.4 : Basit graf yapısı.

Grafın içerisindeki düğümler ve kenarlar komşuluk matrisi (İng. Adjacency Matrix) ile ifade edilebilir. N düğüm sayısı olacak şekilde $N \times N$ 'lik kare bir matris olan komşuluk matrisinde A_{ij} değeri eğer i ve j düğümleri arasında kenar varsa 1 olmaktadır. Eğer kenarlar nicel bir değeri ifade ediyorsa ağırlıkla ifade edilebilir. Bu durumda komşuluk matrisindeki değerler kenarların ağırlığını ifade etmelidir.

Yapay Sinir Ağları ve Evrişimli Sinir Ağları graf yapılı veriler üzerinde çalışmadığı için Graf Sinir Ağları geliştirilmiştir. Tez çalışmasında Graf Sinir Ağlarının bir türü olan, Kipf ve Welling tarafından geliştirilen [28] Graf Evrişimli Ağı kullanılmıştır. GEA'da ESA'lardaki filtreye benzer şekilde tüm veride kullanılan ortak ağırlıklar kullanılmaktadır. Graf üzerindeki ilişkileri ve düğümlere ait olan öznitelikleri birlikte kullanabilmek adına komşuluk matrisi kullanılmaktadır. İleri yayılımında katman girdisini ve ağırlıkları komşuluk matrisi ile çarparak komşu düğümler arasındaki ilişkiler model tarafından kullanılmaktadır. GEA'da ileri doğru yayılım sonucu elde edilen temsil matrisi X' Denklem 3.4 ile hesaplanmaktadır:

$$X' = \sigma(\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} X W) \quad (3.4)$$

Denklemden X GEA'nın girdisini, W sinir ağına ağırlıklarını ifade etmektedir. $\tilde{A}$ grafın komşuluk matrisidir. Komşuluk matrisinde düğümlerin temsili oluşturulurken her düğümün kendi özniteliğini de ele alabilmesi için komşuluk matrisindeki diyagonale 1 atanmıştır. $\tilde{D}$ matrisi de düğümlerin derecesini bulundurmaktadır. Düğüm derecesi her düğüme ait kenar sayısıdır ve $\tilde{D}_{ii} = \sum_j \tilde{A}_{ij}$ ile hesaplanmaktadır. $\tilde{D}$ matrisi hesaplamada normalizasyonu sağlamak için kullanılmaktadır. σ lineer olmayan aktivasyon fonksiyonunu ifade etmektedir ve modele graftaki lineer olmayan ilişkileri öğrenme imkanı vermektedir.

Denklem 3.4 ile birden fazla GEA katmanı ile graf üzerinden düğümlerin temsili çıkartılabilir. Birden fazla katman kullanırken ilk katmanda X olarak düğümlerin öznitelik vektörleri kullanılırken daha sonraki katmanlarda bir önceki katmanın çıktısı kullanılmaktadır. Son katmanın çıktısı da modelin çıktısı olarak değerlendirilmektedir. GEA ile graflar üzerinde düğümlerin öznitelikleriyle birlikte düğümlerin aralarındaki ilişkileri de öğrenen derin öğrenme modelleri oluşturulabilmektedir. Bu tez

kapsamında da borsa bir graf olarak ele alınıp hisse senedi fiyatları hesaplanırken GEA'ların oluşturduğu özniteliklerden faydalanılmıştır.





4. HİSSE SENEDİ FİYAT TAHMİN YÖNTEMLERİNİN UYGULANMASI

Tez çalışmasında borsa hisse verilerinin tahminlenmesinde derin öğrenme tabanlı öznitelik çıkarım metotlarını tasarlanmış ve performansları karşılaştırılmıştır. Bu bölümde bir önceki bölümde teorik arka planı verilen yöntemlerin hisse senedi tahminlenmesinde uygulanmasından bahsedilmiştir. Temelde iki farklı öznitelik çıkarım yöntemi geliştirilmiştir: mum grafiklerinden Otokodlayıcı ile öznitelik çıkarımı ve Graf Evrişimli Ağlar ile borsa grafindan öznitelik çıkarımı.


Hisselerin öznitelikleri Otokodlayıcı ve GEA ile çıkartıldıktan sonra hisse senedi fiyatlarının tahminlenmesinde geçmiş 20 günlük kapanış fiyat bilgileri de UKSB ile iki yöntemde kullanılmıştır.

4.1 Mum Grafiklerinden Öznitelik Çıkarımı ve Fiyat Tahmini

Mum grafikleri hisse senedi fiyatlarının yorumlanması için yatırımcılar tarafından kullanılan grafiklerdir. İçerisinde hissenin davranışlarıyla ilgili anlamlar içermektedir. Bu anlamları hisse senedi fiyatlarının tahminlenmesinde kullanabilmek için Otokodlayıcı modeli kullanılmıştır.


4.1.1 Mum grafiklerinin oluşturulması

Mum grafiklerinin ilk olarak Japon pirinç tacirleri tarafından kullanıldığı tahmin edilmektedir [29]. Mum grafikleri hisselerin açılış, kapanış, en düşük ve en yüksek fiyatı kullanılarak oluşturulmaktadır. Grafiğin uç noktaları en yüksek ve en düşük fiyatı göstermektedir. Ortadaki dikdörtgenin rengi eğer kapanış fiyatı açılış fiyatından yüksekse yeşil düşük olursa kırmızı olmaktadır. Kapanış fiyatı yüksek olursa dikdörtgenin üst sınırı kapanış fiyatını, düşükse açılış fiyatını belirtmektedir. Şekil 4.1’de açılış fiyatı kapanıştan yüksek olan ve düşük olan iki adet mum grafiği gösterilmiştir.



Şekil 4.1 : Mum grafiği.

Mum grafiğinde geçmişe ait birden fazla güne ait grafikler oluşturulabilir. Tez çalışmasında geçmiş 20 güne ait hisse verisi mum grafiğine çevrilmiştir. Otokodlayıcı ağı da 20 güne ait mum grafiği görüntüleri üzerinde eğitilmiştir. Son 20 güne ait mum grafiklerinden örnek Şekil 4.2’de görülmektedir. Üretilen mum grafikleri 640x480 piksel boyutlarında oluşturulmuştur.




Şekil 4.2 : Veri kümesi içerisinde örnek 20 güne ait mum grafiği.

4.1.2 Otokodlayıcı modeli

Mum grafiklerinden anlamlı bilgiler çıkartabilmek amacıyla Otokodlayıcı modeli eğitilmiştir. Otokodlayıcının kodlayıcı ve kod çözücü ağıları Yapay Sinir Ağları ile oluşturulmuştur. Oluşturulan modelin mimarisi Şekil 4.3’te gösterilmektedir.

Otokodlayıcının eğitim aşamasında ilk olarak mum grafiği görüntülerinin boyutu 128x128 piksele düşürülmüştür. Görüntüler daha sonra Otokodlayıcının kodlayıcı ağına girdi olarak verilmiştir. Kodlayıcı içerisinde 4 adet tam bağlı katman (İng. Fully Connected Layer) bulundurmaktadır ve katmanların nöron sayıları sırasıyla 4096,



Şekil 4.3 : Önerilen Otokodlayıcı mimarisi.

2048, 1024 ve 512'dir. Katmanların nöron sayıları azalarak en sonunda 512 boyutlu bir gizli vektör oluşmuştur. Ağın kod çözücü kısmı da 4 katmandan oluşmaktadır ve nöron sayıları sırasıyla 1024, 2048, 4096 ve 49152 ($3 \times 128 \times 128$) olarak belirlenmiştir. Son katmandaki nöron sayısı görüntüleri tekrar aynı boyutta oluşturmak için 3 RGB kanalı ve girdi görüntüsünün boyutu şeklinde belirlenmiştir. Tam bağlı katmanların çıktılarına aktivasyon fonksiyonu olarak ReLU uygulanmıştır. Optimizasyon yöntemi olarak da Adam algoritması kullanılmıştır.

4.1.3 Otokodlayıcı ve UKSB ile fiyat tahmini


Otokodlayıcı ile elde edilen öznitelikler sayesinde mum grafiğinden anlamlı bilgiler çıkartılmıştır. Elde edilen öznitelikler ve UKSB ile tahmin yapan **Otokodlayıcı+UKSB 1** ve **Otokodlayıcı+UKSB 2** isimli iki farklı yöntem geliştirilmiştir. UKSB modellerinde geçmiş fiyat bilgileri kullanılmıştır.

Geçmiş fiyat bilgileri kullanılmadan önce normalizasyon için Z-skoru yöntemi uygulanmıştır. Z-skoru ile normalizasyonda ilk olarak örneklerin ortalaması ve standart sapması hesaplanır ve her örnek ortalamadan çıkartılıp standart sapmaya bölünür. Denklem 4.1'de Z-skor yöntemi gösterilmiştir:

$$x' = \frac{x - \mu}{s} \quad (4.1)$$

Denklemdede x normalize edilecek örnek, μ örneklerin ortalaması, s örneklerin standart sapması ve x' normalize edilmiş örnektir. Ortalama ve standart sapma sadece eğitim örnekleri kullanılarak hesaplanmıştır. Test sırasında model girdilerinin normalizasyonunda bu değerler kullanılmıştır.

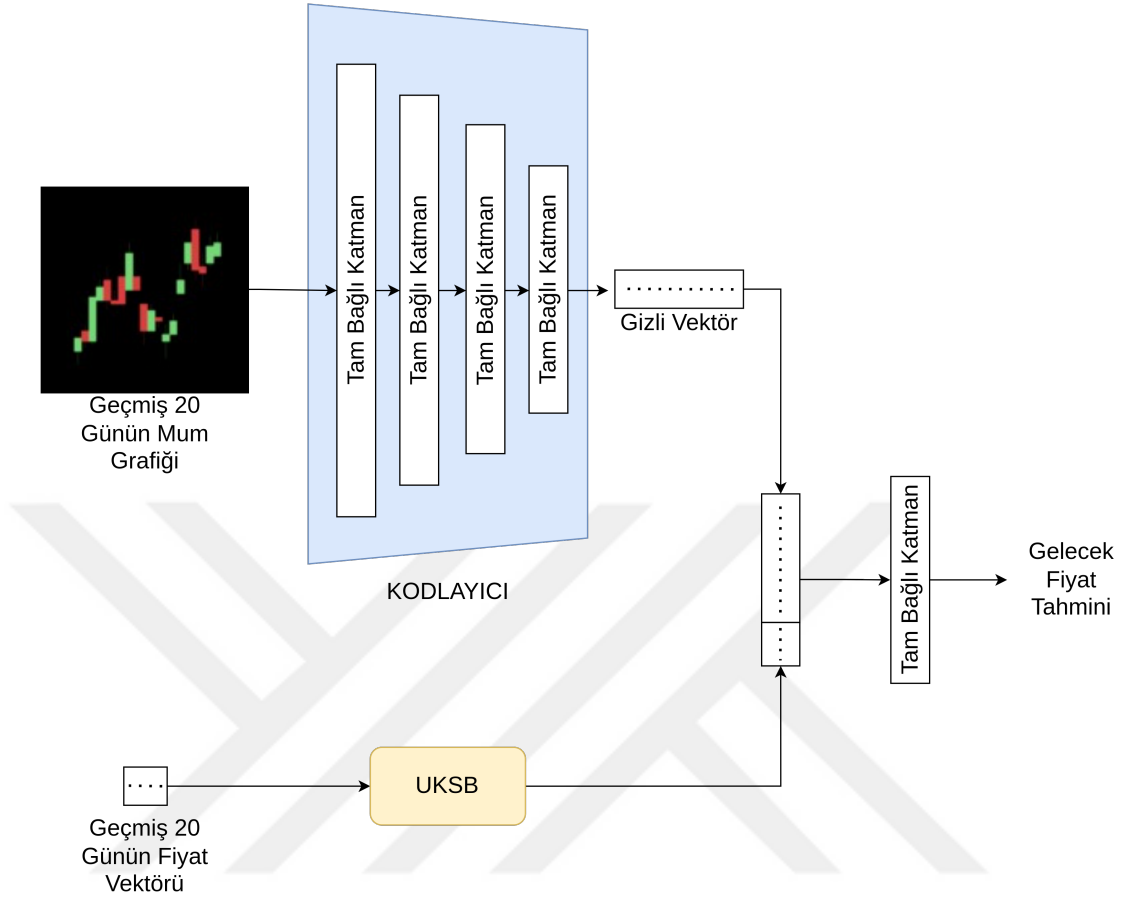
Otokodlayıcı+UKSB 1 yönteminde UKSB'nin hisse fiyatlarının geçmiş nicel verisiyle birlikte kodlayıcıdan elde edilen öznitelik vektörünün kullanılması hedeflenmiştir. Bunun için Otokodlayıcıyla üretilen 512 boyutlu vektör 20 günlük geçmiş fiyat vektörü ile birleştirilerek 532 boyutlu bir sekans vektörü oluşturulmuştur ve UKSB modeline beslenmiştir. UKSB modelinin gizli vektör boyutu 32 olarak belirlenmiştir. UKSB'nin oluşturduğu gizli vektör tahminleme işlemi için son olarak tam bağlı katmana eklenip ertesi günün kapanış fiyatı tahminlenmiştir. Önerilen yöntemin mimarisi Şekil 4.4'te gösterilmektedir.



Şekil 4.4 : Otokodlayıcı+UKSB 1 mimarisi.

Otokodlayıcı+UKSB 2 yönteminde benzer şekilde Otokodlayıcının kodlayıcı kısmından mum grafiğinin anlamsal bilgileri çıkarılmıştır. Aynı zamanda UKSB'ye sekans olarak sadece son 20 günlük fiyat bilgileri verilmiş ve UKSB'den hissenin geçmiş fiyatıyla ilgili bir öznitelik üretilmiştir. En sonda bu iki öznitelik birleştirilmiş ve

tam bağı katman üzerinden gelecek fiyat tahminlemesi yapılmıştır. Şekil 4.5'te Otokodlayıcı+UKSB 2 yönteminin mimarisi gösterilmektedir.



Şekil 4.5 : Otokodlayıcı+UKSB 2 mimarisi.

4.2 Borsa Grafından Öznitelik Çıkarımı ve Fiyat Tahmini

Borsadaki firmaların birbirleriyle ilişkisi olduğundan yola çıkılarak firmalar graf olarak ifade edilmiş ve hisselerle ait öznitelikler Graf Evrişimli Ağ ile çıkarılmıştır. Bunun için ilk olarak borsa grafi oluşturulmuştur. Ardından içerisinde Graf Evrişimli Ağlar ve UKSB içeren iki farklı yöntem geliştirilmiş ve gelecek hisse fiyatları tahminlenmiştir.

4.2.1 Borsa grafının oluşturulması

Borsa grafının oluşturulması iki aşamada gerçekleştirilmiştir. İlk olarak düğümlerin öznitelikleri daha sonra düğümler arasındaki kenar ilişkileri belirlenmiştir.

4.2.1.1 Dügüm öznitelikleri

Borsa grafindaki her düğüm bir firma hissesini temsil etmektedir. Geçmiş fiyat bilgileri UKSB ile kullanılacağı için düğüm özniteliği olarak üssel hareketli ortalama (ÜHO) (İng. Exponential Moving Avarage) ve momentum göstergesi (MOM) (İng. Momentum Indicator) teknik göstergeleri kullanılmıştır. Trendleri göstermede etkili olan ÜHO teknik göstergesi ile düğüm özniteliğinden hisse senedi fiyatının yönü hakkında bilgi elde edilmektedir. Momentum göstergesi kullanılarak da hisse senedi fiyatının geçmişe göre durumu bilgisi modele verilmektedir.

Üssel hareketli ortalama, fiyatın trendlerini anlayabilmek için kullanılan basit hareketli ortalamanın geliştirilmiş halidir. Basit hareketli ortalama alınırken geçmişteki N kadar fiyat bilgisinin ortalaması hesaplanmaktadır. ÜHO'da hesaplama yapılırken son günlere ağırlık daha fazla verilmektedir [30]. ÜHO'nun hesaplanması Denklem 4.2'de gösterilmiştir:

$$\begin{aligned} \dot{U}HO(x_t) &= x_t \times k + \dot{U}HO(x_{t-1}) \times (1 - k) \\ k &= 2/(N + 1) \end{aligned} \quad (4.2)$$

Denklem 4.2'de x_t , t anındaki hisse fiyatını ve N , ÜHO'nun hesaplandığı gün sayısını belirtmektedir.

Momentum göstergesi fiyatın geçmişe göre değişimini göstermektedir. Momentum ile fiyatın hangi yöne doğru ne kadar değiştiği gözlemlenmektedir [31]. Momentumun hesaplanma yöntemi Denklem 4.3'te belirtilmiştir:

$$MOM(x_t) = x_t - x_{t-N} \quad (4.3)$$

MOM momentum fonksiyonunda x_t , t anındaki fiyat ve x_{t-N} , N gün önceki fiyattır.

4.2.1.2 Kenarların oluşturulması

Graftaki düğümler arasındaki ilişkiler kenarlar aracılığıyla gösterilmektedir. Düğüm-lerin arasındaki kenarlar da fiyat geçmişleri arasındaki Pearson çarpım moment korelasyonu ile belirlenmiştir. Korelasyon sonucunda -1 ile 1 arasında bir değer üretilmektedir. 1 pozitif korelasyonu ve -1 negatif korelasyonu ifade etmektedir. İki düğümün geçmiş fiyatları arasındaki Pearson çarpım moment korelasyonu Denklem

4.4 ile hesaplanmaktadır:

$$R_{ij} = \frac{C_{ij}}{\sqrt{C_{ii} \times C_{jj}}} \quad (4.4)$$

R elde edilen korelasyon katsayısı matrisini ve C kovaryans matrisini ifade etmektedir. İkili hisseler arasındaki korelasyon matrisi hesaplandığı için 2×2 'lik matrisler oluşmuştur. Hisselerin aralarındaki korelasyon, matristeki birbirine eşit olan R_{10} veya R_{01} elemanlarından alınmaktadır.


Korelasyon -1 ile 1 arasında bir değer alabildiği için kenarlar ağırlıklı olarak oluşturulmuştur. Komşuluk matrisinde negatif değer olamayacağı için ve iki düğüm arasındaki güçlü negatif korelasyonun anlamlı bir bilgi olarak kabul edildiği için korelasyonun mutlak değeri alınarak kenarlara ağırlıklar atanmıştır. Sonuç olarak her ikili düğüm arasında bir kenar oluşturulmuş ve kenarların ağırlığına mutlak korelasyon olacak şekilde 0 ile 1 arasında bir değer atanmıştır.

4.2.2 GEA ve UKSB ile fiyat tahmini


Hisse senedi fiyatlarının tahminlenmesi için oluşturulan borsa grafi üzerinden GEA ile öznitelikler çıkarılmıştır. Bu öznitelikleri kullanan **GEA+UKSB 1** ve **GEA+UKSB 2** isiminde iki yöntem önerilmiştir. Otokodlayıcı ile yapılan yöntemden farklı olarak GEA, UKSB ile aynı model içinde eğitilmiştir. Dolayısıyla eğitim sırasında ağırlık parametreleri aynı gradyan akışı üzerinden eğitilmiştir.

GEA ile çıkarılan öznitelikler GEA+UKSB 1 yönteminde son 20 günlük fiyat bilgisinin arkasına eklenmiş ve UKSB'yi beslemiştir. Bu şekilde UKSB'nin girdi sekansında hem GEA ile edilen hisselerin birbirleriyle ilişkisini gösteren öznitelikler hem de tarihsel fiyat bilgileri bulunmaktadır. UKSB'nin çıktısı da tam bağlı katmana beslenmiş ve gelecek fiyat tahminlemesi yapılmıştır. Önerilen çözüm Şekil 4.6'da gösterilmektedir.

GEA ile gerçekleştirilen GEA+UKSB 2 çözümünde UKSB'ye sadece son 20 günlük kapanış fiyatları beslenmiştir. UKSB'nin ürettiği gizli vektör GEA'nin ürettiği öznitelik vektörü ile birleştirilmiştir. Birleştirilen öznitelik vektörü tam bağlı katmana iletilmiş ve hissenin gelecekteki fiyatı tahmin edilmiştir. Şekil 4.7 GEA+UKSB 2 yönteminin mimarisini göstermektedir.



Şekil 4.6 : GEA+UKSB 1 mimarisi.




Şekil 4.7 : GEA+UKSB 2 mimarisi.

4.3 Otokodlayıcı, GEA ve UKSB ile fiyat tahmini

Tez çalışmasında geliştirilen iki öznitelik çıkarım yöntemi bu çözümde birlikte kullanılmıştır. Otokodlayıcıyla mum grafiklerinden, GEA ile borsa grafindan ve UKSB ile geçmiş 20 günlük fiyat verisinden öznitelik vektörleri çıkarılmıştır. Öznitelik vektörleri tek vektörde birleştirilip tam bağlı katmana girdi olarak verilmiş ve fiyat

tahminlemesi yapılmıştır. Otokodlayıcı+GEA+UKSB adı verilen yöntemin mimarisi Şekil 4.8’de gösterilmektedir.



Şekil 4.8 : Otokodlayıcı+GEA+UKSB mimarisi.

Temelde iki farklı öznitelik çıkarım yöntemi önerilmiştir. Üretilen öznitelikler farklı şekillerde UKSB ile birlikte kullanılarak hisselerin gelecek fiyatları tahminlenmiştir. Modellerin test edildiği deneylerin sonuçları bir sonraki bölümde sunulmuştur.



5. DENEYLER

Bu bölüm kapsamında tez çalışmasında geliştirilen yöntemlerin uygulanmasından, kullanılan veri setinden ve deneylerin sonuçlarından bahsedilecektir. Deneyler sırasında modeller bir gün sonrasının kapanış fiyatını tahmin etmiştir.

5.1 Yöntemlerin Uygulanması

Tez çalışmasında yöntemler Otokodlayıcı için mum grafiği görüntülerinin oluşturulması, modellerin oluşturulması, modellerin eğitilmesi ve performansların test edilmesiyle tamamlanmıştır. Mum grafiği görüntülerinin hisse fiyat verileriyle oluşturulması için Python dilinde hazırlanmış mplfinance [32] kütüphanesi kullanılmıştır. Derin öğrenme modelleri PyTorch [33] kütüphanesiyle geliştirilmiştir. GEA katmanları PyTorch kütüphanesinin üzerine kurulmuş olan PyTorch Geometric [34] ile modellere eklenmiştir. PyTorch Geometric PyTorch üzerine kurulduğu için GEA katmanları, UKSB ve tam bağlı katmanlarla aynı model sınıfında tanımlanmıştır. Modeller Tesla V100 GPU ile eğitilmiştir.

5.2 Veri Seti

Modellerin performansının test edilebilmesi için S&P 500 borsasındaki firmaların 8 Şubat 2013 ile 7 Şubat 2018 arasındaki hisse senedi fiyatları kullanılmıştır. Tarihler arasında 1259 günün verisi bulunmaktadır. Veri setinin ilk %70'lik kısmı eğitim geri kalan kısmı testte kullanılmak üzere bölünmüştür. Toplamda 470 adet hisse senedi deneyler sırasında test edilmiştir.

5.3 Karşılaştırma Kriterleri

Modellerin tahminleme performansı 4 farklı kriter altında incelenmiştir: R^2 skoru, ortalama mutlak hata, ortalama mutlak yüzde hata ve ortalama kare hata. Eğitim

aşamasında fiyat verisi normalize edilmiş olsa da test sonuçlarındaki hatalar normalize edilmemiş değerler üzerinden hesaplanmıştır.

R^2 skor tahminlemenin ne kadar iyi yapıldığını tahminlenen değerin varyansını dikkate alarak hesaplamaktadır. R^2 skoru 1 olduğunda tahminlemenin hatasız olduğu anlaşılmaktadır. R^2 skorunun formülü Denklem 5.1’de verilmiştir:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y'_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5.1)$$

y_i gerçek değerleri, y'_i modelin tahminlerini ve $\bar{y}$ de gerçek değerlerin ortalamasını ifade etmektedir.

Ortalama mutlak hata kriterinde hatalı sonuçların gerçek sonuçlarla farkı alınıp mutlak değerlerinin ortalaması alınmaktadır. Model ne kadar iyi tahminlerse kriter 0’a o kadar yakın olur. Denklem 5.2’de formül gösterilmiştir:

$$OMH = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (5.2)$$

Ortalama mutlak yüzde hatada tahminle gerçek değer farkı gerçek değere oranla hesaplanmaktadır ve formül Denklem 5.3’te gösterilmiştir:

$$OMYH = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - y'_i}{y_i} \right| \quad (5.3)$$

Ortalama kare hata, tahminlerin hatalarının karelerinin ortalaması alınarak hesaplanmaktadır. Hatanın karesi alındığı için bu kriterde uç hatalar daha fazla cezalandırılmaktadır. Denklem 5.4’te OKH’nin hesaplanma formülü gösterilmektedir:

$$OKH = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \quad (5.4)$$

5.4 Deneyisel Sonuçlar

Yapılan deneylerdeki 470 hissenin test verisindeki tahminlerdeki R^2 skoru, OMH, OMYH ve OKH bazında sonuçları Çizelge 5.1’de gösterilmektedir. Genel olarak bakıldığında kıyaslanmak için eğitilen UKSB modeli de dahil olmak üzere tüm modeller minimum 0.98 R^2 skoru elde etmiştir. Otokodlayıcı ve GEA özniteliklerinin UKSB öznitelikleri ile birlikte kullanıldığı Otokodlayıcı+GEA+UKSB yöntemi R^2 skoru ve OKH kriterlerinde en iyi sonucu elde etmiştir. Tahmin hatalarının varyansının nispeten düşük olduğu yorumlanmaktadır. Otokodlayıcı+UKSB 1 yöntemi OMH ve GEA+UKSB 2 yöntemi OMYH bazında modeller arasında en iyi performansı göstermiştir. Sonuç olarak Otokodlayıcı ve GEA tabanlı modellerden elde edilen özniteliklerin borsa fiyat tahminlemesinde UKSB ile birlikte kullanılmasının tahmin performansını arttırdığı görülmektedir.

Çizelge 5.1 : Modellerin fiyat tahminleme performansları.

	R^2 Skoru	OMH	OMYH	OKH
UKSB	0,9909	1,4625	0,01284	129,1255
Otokodlayıcı+UKSB 1	0,9918	1,4417	0,01265	116,8640
Otokodlayıcı+UKSB 2	0,9864	2,8845	0,04092	193,5087
GEA+UKSB 1	0,9907	1,4760	0,01298	131,5213
GEA+UKSB 2	0,9902	1,5017	0,01095	139,5925
Otokodlayıcı+GEA+UKSB	0,9972	1,7732	0,02015	39,2396

Tüm hisselerin sonuçlarının yanında yüksek hacme sahip hisse senetleri üzerindeki sonuçlar ayrıca irdelenmiştir. Çizelge 5.2’de seçilen hisse senetlerine ait R^2 skorları gösterilmektedir. Genel performans bazında Otokodlayıcı+GEA+UKSB yöntemi en iyi sonuç verirken hisseler ayrı ayrı incelendiğinde belli hisselerde diğer modellerin daha üstün performans gösterdiği görülmektedir. Modellerin performansı R^2 skoru bazında değişkenlik göstermiştir.

Yüksek hacme sahip hisseler özelinde OMH sonuçları Çizelge 5.3’te gösterilmektedir. Hisse bazındaki R^2 skora benzer şekilde OMH için de genel sonuçlarda Otokodlayıcı+UKSB 1 modeli en iyi performansı gösterirken seçilen hisselerde genelde GEA+UKSB 2 modeli en iyi sonuçları vermiştir.

Çizelge 5.2 : Modellerin hisse bazında R^2 skoru performansları.

	AAL	AMD	AAPL	T	NVDA
UKSB	0,9535	0,9287	0,9932	0,9277	0,9941
Otokodlayıcı+UKSB 1	0,9545	0,9346	0,9932	0,9297	0,9941
Otokodlayıcı+UKSB 2	0,6852	0,04816	0,9880	-0,4279	0,9943
GEA+UKSB 1	0,9535	0,9289	0,9933	0,9262	0,9942
GEA+UKSB 2	0,9584	0,9381	0,9927	0,9573	0,9941
Otokodlayıcı+GEA+UKSB	0,9322	0,6241	0,9920	0,6981	0,9953

Çizelge 5.3 : Modellerin hisse bazında OMH sonuçları.

	AAL	AMD	AAPL	T	NVDA
UKSB	0,7814	0,5022	1,2055	0,4922	2,5377
Otokodlayıcı+UKSB 1	0,7712	0,4728	1,2073	0,4836	2,5404
Otokodlayıcı+UKSB 2	2,1617	1,8259	1,8426	2,1881	2,8464
GEA+UKSB 1	0,7810	0,4992	1,1972	0,4945	2,5247
GEA+UKSB 2	0,7065	0,3960	1,2637	0,3438	2,5143
Otokodlayıcı+GEA+UKSB	0,9361	1,0422	1,5006	1,0021	2,3613

Çizelge 5.4’te hisse bazında OMYH sonuçları sunulmuştur. Seçilen hisseler için modellerin elde ettiği sonuçlar OMH metriğine paralel şekilde oluşmuştur. Seçilen hisse senetleri özelinde en iyi sonuçları GEA+UKSB 2 modeli elde etmiştir.

Çizelge 5.4 : Modellerin hisse bazında OMYH sonuçları.

	AAL	AMD	AAPL	T	NVDA
UKSB	0,01676	0,04370	0,00838	0,01274	0,01868
Otokodlayıcı+UKSB 1	0,01656	0,04120	0,00839	0,01253	0,01868
Otokodlayıcı+UKSB 2	0,04728	0,16944	0,01303	0,05668	0,02219
GEA+UKSB 1	0,01677	0,04334	0,00831	0,01282	0,01859
GEA+UKSB 2	0,01510	0,03507	0,00874	0,00895	0,01853
Otokodlayıcı+GEA+UKSB	0,02019	0,10029	0,01041	0,02588	0,01736

Çizelge 5.5’te yüksek hacimli hisse senetleri için elde edilen OKH sonuçları gösterilmiştir. Modellerin OKH kriterine göre sonuçları OMH ve OMYH metriklerine benzer şekilde oluşmuştur.

Deneyler sonucunda modellerin performansları hem veri kümesi üzerindeki tüm hisse senetleri üzerinden hem de yüksek hacme sahip hisse senetleri üzerinden değerlendirilmiştir. Test edilen tüm hisse senetlerinin sonuçlarına göre Otokodlayıcı+GEA+UKSB, GEA+UKSB 2 ve Otokodlayıcı+UKSB 1 yöntemleri en iyi sonuçları elde etmiştir. Buna rağmen hisse senedi özelinde incelendiğinde

Çizelge 5.5 : Modellerin hisse bazında OKH sonuçları.

	AAL	AMD	AAPL	T	NVDA
UKSB	1,0260	0,3984	3,1193	0,3742	14,7883
Otokodlayıcı+UKSB 1	1,0045	0,3655	3,1272	0,3639	14,8078
Otokodlayıcı+UKSB 2	6,9475	5,3214	5,4838	7,3915	14,3578
GEA+UKSB 1	1,0267	0,3972	3,0921	0,3822	14,7219
GEA+UKSB 2	0,9189	0,3458	3,3288	0,2208	14,8129
Otokodlayıcı+GEA+UKSB	1,4955	2,1014	3,6731	1,5629	11,7994

her hisse senedinde en iyi performansı farklı modellerin gösterdiği görülmüştür.

Dolayısıyla, modellerin kullanımında genel performansın yanında hisseler özelindeki performansların da dikkate alınması gerekmektedir.





6. SONUÇLAR

Tez çalışması kapsamında borsa hisse fiyatlarının tahminlenmesinde UKSB ağıyla birlikte kullanılan geliştirilmiş özniteliklerin etkisi irdelenmiştir. Bu amaçla Otokodlayıcı ve GEA tabanlı öznitelik çıkarım yöntemleri UKSB ile birlikte kullanılmıştır. Yöntemlerin performansları S&P 500 borsasının verileri üzerinde test edilmiştir.

Otokodlayıcı tabanlı modelde yatırımcıların da sıkça kullandığı mum grafiklerinden öznitelik çıkarımı yapılmıştır. Aynı zamanda borsa içerisindeki firmaların birbirleriyle ilişkisi olduğundan borsanın graf halinde temsil edilip GEA ile öznitelikler çıkarılmıştır. Otokodlayıcı+UKSB 1 ve GEA+UKSB 1 isimli yöntemlerde üretilen öznitelikler fiyat bilgisi zaman serisine eklenmiş ve UKSB ağı eğitilmiştir. Otokodlayıcı+UKSB 2 ve GEA+UKSB 2 yöntemlerinde ise üretilen öznitelikler sadece fiyatları kullanan UKSB'nin ürettiği özniteliklerle birleştirilmiş ve tam bağlı katmanla fiyat tahmini yapılmıştır. Otokodlayıcı+GEA+UKSB adlı yöntemde Otokodlayıcı, GEA ve UKSB tarafından üretilen öznitelik vektörleri birleştirilmiş ve tam bağlı katman ile fiyat tahmini yapılmıştır. Otokodlayıcı ve GEA ile üretilen özniteliklerin UKSB ile önerilen şekilde kullanımına literatürde daha önce rastlanmamıştır.

Yöntemler S&P 500 borsasındaki 470 firma üzerinde test edilmiştir. Tahmin performansları R^2 skoru, OMH, OMYH ve OKH kriterleri üzerinden değerlendirilmiştir. Yöntemlerin performansının kıyaslanabilmesi için sadece son 20 günlük fiyat serisini kullanan UKSB modeli de eğitilmiştir. Deneylerin sonucunda 0,9972 R^2 skoru ve 39,2396 OKH ile genelde en başarılı yöntem Otokodlayıcı, GEA ve UKSB özniteliklerini birlikte kullanan Otokodlayıcı+GEA+UKSB yöntemi olmuştur. OMH kriterinde 1,4417 ile en başarılı yöntem Otokodlayıcı+UKSB 1 olurken OMYH kriterinde 0,01095 ile en başarılı yöntem GEA+UKSB 2 yöntemi olmuştur. Sonuç olarak tez çalışmasında Otokodlayıcı ve GEA tabanlı özgün borsa verisi tahminleme

yöntemleri geliştirilmiştir. S&P 500 borsasında yapılan deneyler sonucunda yeni özniteliklerin modellerin tahmin kapasitesini arttırdığı ve önerilen yöntemlerin saf UKSB modeline kıyasla daha başarılı olduğu görülmüştür. Borsa fiyatı tahminlemede farklı anlamlar içeren özniteliklerin UKSB ile birlikte kullanımının derin öğrenme modellerinin tahmin kapasitesini arttırdığı gözlemlenmiştir.

Tez çalışmasında farklı özniteliklerin birlikte kullanımının başarımı arttırdığı gözlemlendiği için gelecek çalışmalarda ekstra özniteliklerin kullanılması planlanmaktadır. Literatürde de kullanıldığı gibi borsa haberleri ve sosyal medyada firmalarla ilgili yazılar öznitelik çıkarımı için önemli adaylar olacaktır. Kullanılacak alternatif özniteliklerin yanında bu çalışmada kullanılan GEA tabanlı yöntemler farklı verilerle kullanılacaktır. Bu çalışmada borsa grafi fiyat korelasyonu ile oluşturulmuştur. Gelecek çalışmalarda graflar firmaların aralarındaki sektör bazında ilişkisi ile de oluşturulacaktır. Hisse senedi bazlı tahminlerde görüldüğü üzere tüm veri kümesinde başarılı olan modeller her hisse senedi için yüksek başarımlar yakalayamamıştır. Önerilen öznitelik çıkarım yöntemlerini kullanan farklı modellerin tahminlemede birlikte kullanıldığı topluluk öğrenmesi yaklaşımının gelecek çalışmalarda uygulanması planlanmaktadır.

KAYNAKLAR

- [1] **Fama, E.F.** (1965). The Behavior of Stock-Market Prices, *The Journal of Business*, 38(1), 34–105.
- [2] **Anaghi, M.F. ve Norouzi, Y.** (2012). A model for stock price forecasting based on ARMA systems, *2012 2nd International Conference on Advances in Computational Tools for Engineering Applications (ACTEA)*, s.265–268.
- [3] **Ariyo, A.A., Adewumi, A.O. ve Ayo, C.K.** (2014). Stock Price Prediction Using the ARIMA Model, *2014 UKSim-AMSS 16th International Conference on Computer Modelling and Simulation*, s.106–112.
- [4] **Atsalakis, G.S. ve Valavanis, K.P.** (2009). Surveying stock market forecasting techniques – Part II: Soft computing methods, *Expert Systems with Applications*, 36(3, Part 2), 5932–5941.
- [5] **Vui, C.S., Soon, G.K., On, C.K., Alfred, R. ve Anthony, P.** (2013). A review of stock market prediction with Artificial neural network (ANN), *2013 IEEE International Conference on Control System, Computing and Engineering*, s.477–482.
- [6] **Singh, R. ve Srivastava, S.** (2016). Stock prediction using deep learning, *Multimedia Tools and Applications*, 76, 18569–18584.
- [7] **Shahi, T.B., Shrestha, A., Neupane, A. ve Guo, W.** (2020). Stock Price Forecasting with Deep Learning: A Comparative Study, *Mathematics*, 8(9), <https://www.mdpi.com/2227-7390/8/9/1441>.
- [8] **Dey, P., Hossain, E., Hossain, M.I., Chowdhury, M.A., Alam, M.S., Hossain, M.S. ve Andersson, K.** (2021). Comparative Analysis of Recurrent Neural Networks in Stock Price Prediction for Different Frequency Domains, *Algorithms*, 14(8), <https://www.mdpi.com/1999-4893/14/8/251>.
- [9] **Leung, C.K.S., MacKinnon, R.K. ve Wang, Y.** (2014). A Machine Learning Approach for Stock Price Prediction, *Proceedings of the 18th International Database Engineering Applications Symposium, IDEAS '14*, Association for Computing Machinery, New York, NY, USA, s.274–277.
- [10] **Ballings, M., Van den Poel, D., Hespeels, N. ve Gryp, R.** (2015). Evaluating multiple classifiers for stock price direction prediction, *Expert Systems with Applications*, 42(20), 7046–7056.

- [11] **Ding, X., Zhang, Y., Liu, T. ve Duan, J.** (2015). Deep Learning for Event-Driven Stock Prediction, *IJCAI*.
- [12] **Sadorsky, P.** (2021). A Random Forests Approach to Predicting Clean Energy Stock Prices, *Journal of Risk and Financial Management*, 14(2).
- [13] **Gunduz, H., Yaslan, Y. ve Cataltepe, Z.** (2017). Intraday prediction of Borsa Istanbul using convolutional neural networks and feature correlations, *Knowledge-Based Systems*, 137, 138–148, <https://www.sciencedirect.com/science/article/pii/S0950705117304252>.
- [14] **Fischer, T. ve Krauss, C.** (2018). Deep learning with long short-term memory networks for financial market predictions, *European Journal of Operational Research*, 270(2), 654–669.
- [15] **Hu, G., Hu, Y., Yang, K., Yu, Z., Sung, F., Zhang, Z., Xie, F., Liu, J., Robertson, N., Hospedales, T.M. ve Miemie, Q.** (2018). Deep Stock Representation Learning: From Candlestick Charts to Investment Decisions, *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2706–2710.
- [16] **Kusuma, R.M.I., Ho, T.T., Kao, W.C., Ou, Y. ve Hua, K.L.** (2019). Using Deep Learning Neural Networks and Candlestick Chart Representation to Predict Stock Market, *ArXiv*, *abs/1903.12258*.
- [17] **Kim, T. ve Kim, H.Y.** (2019). Forecasting stock prices with a feature fusion LSTM-CNN model using different representations of the same data, *PLoS ONE*, 14.
- [18] **Guo, J. ve Li, X.** (2019). Prediction of Index Trend Based on LSTM Model for Extracting Image Similarity Feature, *Proceedings of the 2019 International Conference on Artificial Intelligence and Computer Science, AICS 2019*, Association for Computing Machinery, New York, NY, USA, s.335–340.
- [19] **Peng, S.**, (2021). Stock Forecasting using Neural Network with Graphs, (Yüksek Lisans Tezi), University of York.
- [20] **Li, W., Bao, R., Harimoto, K., Chen, D., Xu, J. ve Su, Q.** (2020). Modeling the Stock Relation with Graph Network for Overnight Stock Movement Prediction, **C. Bessiere**, (düzenleyen), *Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence, IJCAI-20*, International Joint Conferences on Artificial Intelligence Organization, s.4541–4547, <https://doi.org/10.24963/ijcai.2020/626>, special Track on AI in FinTech.
- [21] **Chen, W., Jiang, M., Zhang, W.G. ve Chen, Z.** (2021). A novel graph convolutional feature based convolutional neural network for stock trend prediction, *Information Sciences*, 556, 67–94,

<https://www.sciencedirect.com/science/article/pii/S0020025520312342>.

- [22] **Matsunaga, D., Suzumura, T. ve Takahashi, T.** (2019). Exploring Graph Neural Networks for Stock Market Predictions with Rolling Window Analysis, *CoRR, abs/1909.10660*, <http://arxiv.org/abs/1909.10660>, 1909.10660.
- [23] **Kenny, G., Meyler, A. ve Quinn, T.** (1998). Forecasting Irish inflation using ARIMA models, **Research Technical Papers 3/RT/98**, Central Bank of Ireland, <https://ideas.repec.org/p/cbi/wpaper/3-rt-98.html>.
- [24] **Zhang, G.** (2003). Time series forecasting using a hybrid ARIMA and neural network model, *Neurocomputing*, 50, 159–175.
- [25] **Rumelhart, D.E., Hinton, G.E. ve Williams, R.J.** (1986). Learning representations by back-propagating errors, *Nature*, 323(6088), 533–536, <https://doi.org/10.1038/323533a0>.
- [26] **Baldi, P.** (2012). Autoencoders, Unsupervised Learning, and Deep Architectures, *I. Guyon, G. Dror, V. Lemaire, G. Taylor ve D. Silver, (düzenleyenler), Proceedings of ICML Workshop on Unsupervised and Transfer Learning, cilt 27 of Proceedings of Machine Learning Research, PMLR, Bellevue, Washington, USA, s.37–49.*
- [27] **Hochreiter, S. ve Schmidhuber, J.** (1997). Long Short-Term Memory, *Neural Computation*, 9(8), 1735–1780.
- [28] **Kipf, T.N. ve Welling, M.** (2017). Semi-Supervised Classification with Graph Convolutional Networks, *5th International Conference on Learning Representations, ICLR 2017, Toulon, France, April 24-26, 2017, Conference Track Proceedings, OpenReview.net*, <https://openreview.net/forum?id=SJU4ayYgl>.
- [29] **Morris, G.L.** (2006). Candlestick Charting Explained: Timeless Techniques for Trading Stocks and Futures: Timeless Techniques for Trading stocks and Sutures.
- [30] How Is the Exponential Moving Average (EMA) Formula Calculated?, <https://www.investopedia.com/ask/answers/122314/what-exponential-moving-average-ema-formula-and-how-ema-calculated.asp>, erişim tarihi: 01.06.2022.
- [31] Momentum Indicator (MOM) Explained For Beginners, <https://www.warriortrading.com/momentum-indicator/>, erişim tarihi: 01.06.2022.
- [32] mplfinance, <https://github.com/matplotlib/mplfinance>, erişim tarihi: 01.06.2022.

- [33] **Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Killeen, T., Lin, Z., Gimelshein, N., Antiga, L., Desmaison, A., Kopf, A., Yang, E., DeVito, Z., Raison, M., Tejani, A., Chilamkurthy, S., Steiner, B., Fang, L., Bai, J. ve Chintala, S.** (2019). PyTorch: An Imperative Style, High-Performance Deep Learning Library, **H. Wallach, H. Larochelle, A. Beygelzimer, F. d'Alché-Buc, E. Fox ve R. Garnett**, (düzenleyenler), Advances in Neural Information Processing Systems 32, Curran Associates, Inc., s.8024–8035, <http://papers.neurips.cc/paper/9015-pytorch-an-imperative-style-high-performance-deep-learning-pdf>.
- [34] **Fey, M. ve Lenssen, J.E.** (2019). Fast Graph Representation Learning with PyTorch Geometric, *ICLR Workshop on Representation Learning on Graphs and Manifolds*.



ÖZGEÇMİŞ

Adı SOYADI: Mahmut Lutfullah Özbilen

ÖĞRENİM DURUMU:

- **Lisans:** 2018, İstanbul Teknik Üniversitesi, Bilgisayar ve Bilişim Fakültesi, Bilgisayar Mühendisliği Bölümü
- **Y. Lisans:** 2022, İstanbul Teknik Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programı.

MESLEKİ DENEYİMLER VE ÖDÜLLER:

- 2019 yılından beri TÜBİTAK BİLGEM B3LAB’da büyük veri ve derin öğrenme projeleri üzerine çalıştı.

YÜKSEK LİSANS TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Özbilen M. L.,** Yaslan Y. (2021). Portfolio Construction with Stock Prices Predicted by LSTM using Enhanced Features. *2021 6th International Conference on Computer Science and Engineering (UBMK)*, pp. 639-643.

DİĞER YAYINLAR, SUNUMLAR VE PATENTLER:

- **Özbilen M. L.,** Eğriboz E., Halepmollası R., Bilgen İ., Hakkıdır M. (2021). A Deep Reinforcement Learning Approach to Explore Optimal Policies for Covid-19 Pandemic Mitigation: Preliminary Analysis. *II. International Artificial Intelligence in Health Congress*
- **Özbilen M. L.,** Eğriboz E., Halepmollası R., Bilgen İ., Hakkıdır M. (2021). Deep Reinforcement Learning for Simulation-Based Determination of COVID-19 Pandemic Mitigation Policies. *Artificial Intelligence Theory and Applications*, Volume: 1, Number:3, Pages 30-39.