

T.C.
AYDIN ADNAN MENDERES ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI
2021-YL-048

DERİN ÖĞRENME İLE HİSSE SENEDİ PİYASASI TAHMİNİ

HAZIRLAYAN
Cansu ALTUNBAŞ

TEZ DANIŞMANI
Dr. Öğr. Üyesi Elvan HAYAT
Dr. Öğr. Üyesi Olgun AYDIN

AYDIN- 2021

T.C.
AYDIN ADNAN MENDERES ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
AYDIN

Bu tezde sunulan tüm bilgi ve sonuçların, bilimsel yöntemlerle yürütülen gerçek deney ve gözlemler çerçevesinde tarafımdan elde edildiğini, çalışmada bana ait olmayan tüm veri, düşünce, sonuç ve bilgilere bilimsel etik kuralların gereği olarak eksiksiz şekilde uygun atıf yaptığımı ve kaynak göstererek belirttiğimi beyan ederim.

10 / 06 / 2021

Cansu ALTUNBAŞ

ÖZET

DERİN ÖĞRENME İLE HİSSE SENEDİ PİYASASI TAHMİNİ

Cansu ALTUNBAŞ

Yüksek Lisans Tezi, Ekonometri Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Elvan HAYAT

Dr. Öğr. Üyesi Olgun AYDIN

2021, XVIII+98 sayfa

Borsa, sermaye piyasası araçlarının alınıp satıldığı organize bir hisse senedi piyasasıdır. Yatırımcılar tarafından gerçekleştirilen bu alım satım işlemi sonrasında kar ya da zarar elde edilmektedir. Yatırımcıların piyasalar hakkında doğru bir öngörü sahibi olması ile zarar en az düzeyde gerçekleşebilir. Finansal piyasalar için öngöründe bulunmak akademik çalışmalarda ve iş dünyasında oldukça önemli bir yer tutmaktadır.

Bu tez çalışmasında XBANK olarak ifade edilen banka endeksinin bir sonraki günlük kapanış değerinin derin öğrenme metotları kullanılarak tahmin edilmesi amaçlanmıştır. Bu amaçla, 04.11.2015- 04.11.2019 tarihleri arasında banka endeksine ait günlük kapanış, açılış, en yüksek, en düşük değerler, çeşitli teknik göstergeler, çeşitli makroekonomik değişkenler ve metinsel veriler kullanılmıştır. Seçilen teknik göstergeler; RSI, MACD, Momentum, William, Basit Hareketli Ortalama, Stokastic K ve Stokastic D'dir. Seçilen makroekonomik göstergeler ise; euro kuru, dolar kuru, brent petrol ve gram altın fiyatlarıdır. Tüm bu değişkenlerin 10 gecikmeye kadarki değerleri de veri setine dahil edilmiştir. Ayrıca resmî tatillerde işlem görmeyen endeksin kapanış, açılış, en yüksek ve en düşük değerleri için bir önceki güne ait değerler kullanılmıştır. Veri setinde bu durumu ifade edebilmek için dummy değişken oluşturulmuş ve resmî tatil günlerine 0, işlem günlerine 1 değeri verilmiştir. Metinsel veriler, seçilen iki internet sitesinden web kazıma tekniği ile elde edilen haber başlıklarıdır. Seçilen internet siteleri ise www.investing.com ve www.dunya.com 'dur.

Analizde kullanılmak üzere üç farklı veri seti hazırlanmıştır. İlki finansal ve metinsel veri setlerinin birleşiminden oluşan, ikincisi finansal verilerle oluşturulan, üçüncüsü ise metinsel verilerle oluşturulan veri setidir. Her bir veri seti için veriler, %70'i eğitim seti, %30'u test seti olmak üzere ikiye ayrılarak analize devam edilmiştir. Veri setlerindeki değişkenlerden modele pozitif katkı sağlamayanlar eğitim setinden çıkarılmıştır. Bu işlem Boruta algoritması uygulanarak yapılmıştır. Ardından kullanılacak derin öğrenme modeli

belirlenmiştir. Analizde kullanılan derin öğrenme modeli ileri beslemeli derin sinir ağı modelidir.

Modelde kullanılan hiper parametreleri bulmak amacıyla optimizasyon işlemi gerçekleştirilmiştir. Hiper parametre optimizasyonu olarak adlandırılan bu işlem için ızgara arama yöntemi kullanılmıştır. Uygun değişkenlerin ve hiper parametrelerin belirlenmesinin ardından veri seti eğitilmiştir. Eğitim seti kullanılarak eğitilen model ile test setindeki veriler için tahmin sonuçları elde edilmiştir. Üç farklı veri setinden elde edilen tahmin sonuçları ile gerçek sonuçlar karşılaştırılmıştır. Bu sonuçlarda genel olarak endeksin yönü doğru tahmin edilebilir iken, kapanış değerinin tahmininde sapmalar gözlemlenmiştir. Özellikle test setindeki Haziran – Aralık 2019 arasındaki gerçek değerleri tahmin etmede modellerin başarılı olmadığı ve tahmin edilen değer ile gerçek değer arasındaki farkı ifade eden kalıntı değerinde negatif anlamda ayrışma olduğu gözlemlenmiştir. Bu dönemlerde yaşanan dalgalanmanın nedenini tespit etmek amacıyla, metinsel veri setindeki haber başlıkları incelenmiştir ve bu dönemdeki siyasi haber akışının banka endeksinin kapanış değerinde volatilité yarattığı, bu nedenle de model tarafından ilgili dönemde doğru tahmin yapılamadığı sonucuna varılmıştır.

Son olarak derin öğrenmede topluluk öğrenmesi metodolojisi kullanılarak veri setlerinden ayrı ayrı elde edilen tahmin sonuçlarının farklı kombinasyonlarda ortalama değerleri bulunarak gerçek değerlerle karşılaştırılmıştır. Tüm kombinasyonların endeksin yönünü tahmin etmede başarılı olduğu gözlemlenmiştir. Metinsel ve finansal veri setlerinden ayrı ayrı elde edilen tahminlerin ortalama değerinin gerçek değeri tahmin etmede oldukça başarılı olduğu görülmüştür.

Ulusal ve uluslararası literatürde, hisse senedi tahmini yapan çok sayıda çalışma mevcuttur ancak ulusal yazında XBANK endeksini tahmin eden çalışmaların sınırlı sayıda olduğu ve genellikle finansal göstergeler kullanılarak zaman serisi analizlerinin yapıldığı belirlenmiştir. Ulusal yazın incelendiğinde, XBANK endeksinin tahmininde derin öğrenme metotlarının kullanıldığı herhangi bir çalışmaya rastlanılmadığı, dahası metinsel veriler ve finansal verilerin birlikte ele alındığı çalışmaların olmadığı görülmektedir. Bu açıdan tezde yapılan araştırmanın ulusal literatüre katkı sağlayacağı düşünülmektedir.

ANAHTAR SÖZCÜKLER: Boruta Algoritması, Hiper parametre Optimizasyonu, İleri Beslemeli Derin Sinir Ağı, Izgara Arama Yöntemi, XBANK

ABSTRACT

PREDICTING STOCK MARKET BY USING DEEP LEARNING

Cansu ALTUNBAŞ

MSc Thesis at Econometrics

Supervisors: Asst. Prof. Elvan HAYAT,

Asst. Prof. Olgun AYDIN

2021, XVIII+98 pages

A stock market is an organized market where capital market instruments are bought and sold. Profit or loss is obtained after the investors carry out this trading process. With the investors having accurate predictions about the markets, the loss can be minimized. Predictions for financial markets are essential in the academic and business world.

In this thesis, deep neural networks were proposed to predict the closing value of the bank index (XBANK), which is traded in the stock exchange. For this purpose, daily closing, opening, highest and lowest values, various technical indicators, various macroeconomic variables, and textual data about the bank index between 04.11.2015-04.11.2019 were used. Textual data contains news headlines and it was obtained by web scraping technique from two selected web sources.

Three different data sets were prepared to be used in the analysis. The first is a combination of financial and textual data, the second is a data set created with financial data, and the third is a data set created only with textual data. The data sets were split into two parts: 70% as training and 30% as a test set. The features in the data sets that didn't have a positive effect on the model accuracy were excluded. This process is done by applying the Boruta algorithm.

An optimization process was performed to find the hyperparameters used in the model training phase. The grid search method was used for this process. After determining the appropriate features and hyperparameters, the neural network was trained. The predictions were obtained for the test. Then, a feed-forward deep neural network was trained using selected features.

The predictions for three different data sets were compared with the real values. The results show that, while the trend of the index is predicted correctly, there are deviations in point estimations. In particular, it was observed that the model is not able to provide accurate predictions for the time period between June and November 2019. There is a negative decomposition in the residuals which is the difference between the predicted values and the actual values. In order to understand the reason for the fluctuations in these periods, the news headlines in the textual data set were examined, and it was concluded that the political news in this period caused volatility, so the model could not provide accurate results for this time period.

Based on the ensemble learning methodology the average values of the predictions for different combinations of three models were calculated and results were compared with the actual values. It was observed that all combinations predict the trend accurately. However, the average value of predictions obtained using only textual and only the financial data sets provide the most accurate predictions.

There are many studies in the national and international literature that make forecasting of stocks, however studies that estimate the XBANK index in the national literature are limited. Studies estimating the XBANK index have generally made time series analysis using financial indicators. When the national literature is examined, there is no study in which deep learning methods are used in the estimation of the XBANK index also, it was observed that there were no studies in which textual and financial data were used together. Therefore it is thought that the research made in the thesis will contribute to the national literature.

KEYWORDS: Boruta Algorithm, Deep Learning, Deep Neural Networks, Grid Search, Hyperparameter Optimization, XBANK,

Türkiye Cumhuriyeti'nin kurucusu Mustafa Kemal Atatürk'e saygı, sevgi ve özlemlerle.

ÖNSÖZ

Tez çalışmam boyunca sevgilerini, sabırlarını, desteklerini üzerimden hiç eksik etmeyen, moralim her bozulduğunda beni sakinleştiren, çabamı her daim takdir eden, benimle heyecanlanan, benimle üzülen ve benimle çıkış yolu arayan canım tez hocalarım Dr. Öğretim Üyesi Elvan HAYAT'a ve Dr. Öğretim Üyesi Olgun AYDIN'a teşekkür ederim. Sadece tez hocası değil bana yol arkadaşı olduğunuz için varlığınıza minnettarım.

Benimle her zaman gurur duyan, desteklerini her zaman yanımda hissettiğim canım aileme; annem Mülkinaz ALTUNBAŞ, babam Ali Haydar ALTUNBAŞ'a teşekkür ederim. Ayrıca sürecin zorluklarıyla başa çıkmam konusunda bana her zaman destek olan gurur ve ilham kaynağım ablam Dr. Canan ALTUNBAŞ'a teşekkür ederim.

Cansu ALTUNBAŞ

İÇİNDEKİLER

KABUL VE ONAY	iii
BİLİMSEL ETİK BİLDİRİM SAYFASI.....	iv
ÖZET	v
ABSTRACT	vii
ÖNSÖZ.....	x
ŞEKİLLER DİZİNİ	xiii
TABLolar DİZİNİ.....	xvi
EKLER DİZİNİ	xvii
KISALTMALAR DİZİNİ	xviii
GİRİŞ.....	1
1. BÖLÜM.....	4
1. FİNANSAL PİYASALAR.....	4
1.1. Finansal Piyasaların Tanımı	4
1.2. Finansal Piyasalarda Kullanılan Analiz Yöntemleri	5
1.2.1. Temel Analiz	5
1.2.2. Teknik Analiz	5
1.2.2.1. İndikatörler	6
1.2.2.2. Osilatörler	8
2. BÖLÜM.....	12
2. DERİN ÖĞRENME KAVRAMLARI	12
2.1. Derin Öğrenmenin Tanımı	12
2.2. Derin Öğrenme Mimarileri.....	13
2.2.1. Konvolüsyonel Sinir Ağları (Convolutional Neural Network-CNN).....	13
2.2.2. Yinelemeli Sinir Ağları (Recurrent Neural Networks-RNN).....	20

2.2.3. Uzun Kısa Vadeli Bellek Ağları (Long Short Term Memory Networks-LSTM)	23
2.2.4. Sınırlı Boltzmann Makinesi (Restricted Boltzmann Machine-RBM)	24
2.2.5. Derin İnanç Ağları (Deep Belief Networks-DBN).....	25
2.2.6. Derin Oto Kodlayıcılar (Deep Autoencoder-DAE).....	26
2.3. Derin Öğrenmede Kullanılan Programlama Dilleri ve Kütüphaneler	26
2.4. Metin Madenciliği Tanımı.....	27
2.5. İlgili Literatür Taraması	29
3. BÖLÜM.....	35
3. UYGULAMA MODELLERİ VE BULGULAR.....	35
3.1. Çalışmanın Amacı ve Kapsamı	35
3.2. Çalışmada Kullanılan Yöntem ve Veriler	35
3.2.1. Endekse Ait Finansal Verilerin Elde Edilmesi ve Düzenlenmesi	36
3.2.2. Metinsel Verilerin Elde Edilmesi ve Düzenlenmesi.....	36
3.2.3. Boruta Algoritması	37
3.2.4. Hiper Parametre Optimizasyonu	44
3.2. Analiz	47
4. TARTIŞMA VE SONUÇ.....	61
5. EKLER	65
6. KAYNAKLAR.....	90
ÖZGEÇMİŞ.....	97

ŞEKİLLER DİZİNİ

Şekil 1.1. William % R Göstergesi, www.investing.com	6
Şekil 1.2. Basit Hareketli Ortalama, www.investing.com.....	7
Şekil 1.3. RSI Göstergesi, www.investing.com	8
Şekil 1.4. Stokastik Osilatör Göstergesi, www.investing.com.....	9
Şekil 1.5. MACD Göstergesi, www.investing.com.....	10
Şekil 1.6. Momentum Göstergesi, www.investing.com	11
Şekil 2.1. SEQ Şekil_2. * ARABIC 1. Yapay Zekâ, Makine Öğrenimi ve Derin Öğrenme İlişkisi	12
Şekil 2.2. Evrişimsel Sinir Ağları.....	13
Şekil 2.3. Evrişim Katmanı.....	14
Şekil 2.4. ReLU	15
Şekil 2.5. LReLU.....	15
Şekil 2.6. ELU	16
Şekil 2.7. Aktivasyon Fonksiyonları	16
Şekil 2.8. Havuzlama Katmanı	18
Şekil 2.9. İki Gizli Katmanlı Yapay Sinir Ağı Modeli.....	19
Şekil 2.10. Yinelemeli Sinir Ağı Yapısı,.....	21
Şekil 2.11. Jordan Ağ Yapısı	21
Şekil 2.12. Elman Ağ Yapısı	22
Şekil 2.13. Hopfield Ağ Yapısı	22
Şekil 2.14. Uzun Kısa Vadeli Bellek Ağ Yapısı	23
Şekil 2.15. Unut Kapısı	23
Şekil 2.16. Giriş Kapısı	24
Şekil 2.17. Çıkış Kapısı	24

Şekil 2.18. Sınırlı Boltzmann Ağ Yapısı	25
Şekil 2.19. Derin İnanç Ağ Yapısı.....	25
Şekil 2.20. Derin Oto Kodlayıcı Ağ Yapısı.....	26
Şekil 2.21. Süreçler Arasındaki İlişki.....	28
Şekil 3.1. LDA Sonuçları	40
Şekil 3.2. Finansal Verilerin Boruta Analizi	42
Şekil 3.3. Metinsel Verilerin Boruta Analizi.....	43
Şekil 3.4. Finansal ve Metinsel Verilerin Boruta Analizi	44
Şekil 3.5. Derin Sinir Ağ Modeli.....	45
Şekil 3.6. Finansal ve Metinsel Veriler İçin Eğitim Setinin Kayıp ve Doğruluğu.....	48
Şekil 3.7. Finansal ve Metinsel Veriler İçin Test Setinin Tahmin Edilen Değerleri ile Gerçek Değerler Arasındaki İlişki.....	49
Şekil 3. 8. Finansal ve Metinsel Veriler İçin Test Setinin Kalıntı Değeri.....	50
Şekil 3 9. Metinsel Veri İçin Eğitim Setinin Kayıp ve Doğruluğu.....	51
Şekil 3.10. Metinsel Veri İçin Test Setinin Tahmin Edilen Değerleri ile Gerçek Değerler Arasındaki İlişki	51
Şekil 3.11. Metinsel Veri İçin Test Setinin Kalıntı Değeri	52
Şekil 3.12. Finansal Veri Seti İçin Eğitim Setinin Kayıp ve Doğruluğu.....	53
Şekil 3.13. Finansal Veri İçin Test Setinin Tahmin Edilen Değerleri ile Gerçek Değerler Arasındaki İlişki	53
Şekil 3.14. Finansal Veri İçin Test Setinin Kalıntı Değeri.....	54
Şekil 3.15. Tüm Veri Setlerinin Tahmin Edilen Değerleri ile Gerçek Değerleri Arasındaki İlişki.....	55
Şekil 3.16. Haziran- Aralık 2019 Banka Endeksi Kapanış Değerleri Değişim Oranı (%)..	56
Şekil 3.17. Haziran- Aralık Hariç 2019 Banka Endeksi Kapanış Değerleri Değişim Oranı (%).....	57

Şekil 3.18. Gerçek Değerler ve Birleştirilmiş Tahminlerin Ortalaması	58
Şekil 3.19. Gerçek Değerler ve Finansal-Metinsel Veri Tahminlerinin Birleştirilmiş Ortalaması	59

TABLolar DİZİNİ

Tablo 2.1. Kütüphaneler	27
Tablo 3.1. www.investing.com ‘dan alınan haber başlıklarına örnek	38
Tablo 3.2. www.dunya.com ‘dan alınan haber başlıklarına örnek	39
Tablo 3.3. Örnek Veri Seti	41
Tablo 3.4. RMSE Sonuçları.....	59

EKLER DİZİNİ

Ek 1. Değişken Açıklamaları.....	65
Ek 2. Izgara Arama Yöntemi Analiz Sonuçları.....	70
Ek 3. Örnek Veri Seti	75

KISALTMALAR DİZİNİ

CNN	: Konvolüsyonel Sinir Ağları (Convolutional Neural Network)
CSS	: Basamaklı Stil Sayfası (Cascading Style Sheets)
DAE	: Derin Oto Kodlayıcılar (Deep Autoencoder)
DBN	: Derin İnanç Ağları (Deep Belief Networks)
ELU	: Üstel Doğrusal Birim (Exponential Linear Unit)
HTML	: Hiper Metin İşaretleme Dili (Hypertext Markup Language)
LDA	: Gizli Dirichlet Tahsisi (Latent Dirichlet Allocation)
LReLU	: Sızıntı Düzleştirilmiş Doğrusal Birim Katmanı (Leaky ReLU)
LSTM	: Uzun Kısa Vadeli Bellek Ağları (Long Short Term Memory Networks)
MA	: Basit Hareketli Ortalama (Moving Average)
MACD	: Hareketli Ortalama Yakınlaşma Uzaklaşma Göstergesi (Moving Average Convergence Divergence)
MOM	: Momentum
RBM	: Sınırlı Boltzmann Makinesi (Restricted Boltzmann Machine)
RELU	: Düzleştirilmiş Doğrusal Birim Katmanı (Rectifier Linear Unit Layer)
RMSE	: Hata Kareler Ortalamasının Karekökü (Root Mean Square Error)
RNN	: Yinelemeli Sinir Ağları (Recurrent Neural Networks)
RSI	: Göreceli Güç Endeksi (Relative Strength Index)
SELU	: Ölçekli Üstel Doğrusal Birim (Scaled Exponential Linear Unit)
SSE	: Hata Kareler Toplamı (Sum Of Square Error)
STOCH	: Stokastik Osilatör
Williams % R	: Williams %R Göstergesi
XBANK	: Borsa İstanbul Banka Endeksi

GİRİŞ

Yatırımcıların borsaya yatırım yapmasındaki en temel amaç, yatırımını büyütme fırsatıdır. İstikrarlı bir şekilde büyüyen şirketlere yapılan yatırımlar, yatırımın büyümesine olanak sağlar. Aynı şekilde birden fazla hisse senedine yatırım yapılması ya da birden fazla hisse senedini bünyesinde barındıran borsa endekslerine yatırım yapılması ekonominin farklı sektörlerdeki büyümesinden yararlanmayı sağlayacaktır. Türkiye borsasının da içinde bulunduğu gelişmekte olan piyasalarda sürekli bir yükseliş çoğu zaman mümkün olmamaktadır. Gelişmiş ülkelerin borsalarındaki işlem hacimleri ile karşılaştırıldığında, Borsa İstanbul'daki işlem hacmi daha düşüktür ve bu durum Borsa İstanbul'un ülke ve dünya genelinde yaşanan gelişmelerden daha fazla etkilenmesine, iniş ve çıkışların daha sert yaşanmasına sebep olmaktadır. Tüm bu koşullar göz önüne alındığında; Borsa İstanbul'a yatırım yapan yatırımcılar, yaşanabilecek bu sert hareketlerden daha az etkilenerek yatırımını koruma ve piyasada yaratılan fırsatları değerlendirme eğilimi içerisine girmektedir. Bu nedenle, yatırımcıların borsada oluşacak olası iniş ve çıkışları önceden öngörmesi oldukça önem arz etmektedir.

Yatırımcıların bu öngörüü edinebilmesi amacıyla çeşitli derin öğrenme modelleri kullanılarak özellikle hisse senedinin fiyat ve yön tahmini ile ilgili literatürde birçok çalışma bulunmaktadır ancak ulusal yazında banka endeksini ifade eden XBANK endeksini tahmin eden çalışmaların sınırlı sayıda olduğu ve genellikle finansal göstergeler kullanılarak zaman serisi analizlerinin yapıldığı belirlenmiştir. Son dönemlerde hisse senedinin fiyat ve yön tahmininin yanı sıra birçok hisse senedini içinde barındıran borsa endekslerinin fiyat ve yön tahmini oldukça önemli olarak görülmektedir. Borsa endeksleri oluşturulurken piyasayı en iyi şekilde temsil eden hisse senetleri kullanılmaktadır. Bu sayede oluşturulan endeksle piyasanın genel davranışı ölçülebilmektedir. Endeks yönünü doğru tahmin etmek, yatırımcılara elde edecekleri getiri ile ilgili beklentileri hakkında bilgi sağlayacaktır (Pathak, 2010: 202). Bankacılık sektörü süreklilik gösteren ve ülke ekonomisi için önemlilik arz eden bir sektördür. Bu nedenle bu tez çalışmasında, ülkemizde faaliyette bulunan bankaların Borsa İstanbul'da işlem gören hisse senetlerinden oluşan ve yüksek hacme sahip olan XBANK olarak ifade edilen banka endeksinin kapanış değerinin tahmin edilmesi amaçlanmıştır. Banka endeksi tahmin edilirken endekse ait değerler, teknik göstergeler, makroekonomik değişkenler ve metinsel veriler kullanılmıştır. Metinsel veriler seçilen iki farklı internet

sitesinden web kazıma tekniği ile elde edilmiştir.

Makine öğrenmesi ve derin öğrenme; görüntü işlemede, doğal dil işlemede, finansal modellemede ve karar verme süreçlerinde kullanılmaktadır. Geliştirilen algoritmalar sayesinde hisse senedi ya da endeks tahmini yaparken hesaplama gerektiren matematiksel modellemeler yapmak kolaylaşmıştır. Bu durum, daha başarılı finansal modeller elde edilmesini mümkün kılmaktadır. Çalışmada banka endeksinin kapanış değerinin tahmin edilmesinde 04.11.2015- 04.11.2019 arası günlük tarihsel veriler kullanılarak ileri beslemeli derin sinir ağı modeli oluşturulmuştur.

Literatürdeki çalışmalardan farklı olarak, bu çalışmada analiz öncesinde modele girdi olarak verilen veri setinde yer alan değişkenlerin önemlilik düzeyleri belirlenmiştir. Veri setleri genellikle çok fazla değişkenle tanımlanır ve bu değişkenlerin çoğu model ile ilgisizdir. Bu değişken ya da değişkenlerin analiz öncesinde tespit edilmesi ve veri setinden çıkarılması oldukça faydalı olacaktır. Bu amaca yönelik olarak Boruta algoritması kullanılmıştır. Boruta algoritması veri setindeki önemli ve önemli olmayan değişkenlerin seçilmesini sağlar (Kursa ve Rudnicki, 2010). Çalışmada hazırlanan veri setlerine Boruta algoritması uygulanmış ve değişkenlerin önemlilik düzeyleri belirlenmiştir. Böylece modelde ele alınan değişkenler rastgele seçilmemiş, önemli bulunan değişkenler modele dahil edilmiştir. Bu çalışmanın benzer diğer çalışmalardan ayrıldığı bir başka nokta ise, belirlenen değişkenlerle modelin eğitilmesinden önce, seçilen ileri beslemeli derin sinir ağı modelindeki hiper parametrelerin uygun değerleri tespit edilmiştir. Hiper parametre optimizasyonu bir modelin tahmin edilmesinde en uygun parametrelerin bulunmasını sağlayan bir optimizasyon işlemidir ve modelin tahmin doğruluğunu doğrudan etkilemektedir (Zheng, 2015: 28). Hiper parametre optimizasyonu sonucunda ileri beslemeli derin sinir ağı modeli için uygun parametre katsayıları belirlenmiştir. Böylece banka endeksinin kapanış değerinin tahmininde uygun değişkenler ve uygun hiper parametreler belirlenerek model eğitime hazır hale getirilmiştir.

Bu çalışma dört bölümden oluşmaktadır. Birinci bölümde, finansal piyasaların tanımı yapılmış ve finansal piyasalarda kullanılan analiz yöntemlerinden bahsedilmiştir. İkinci bölümde, derin öğrenmenin tanımı yapıлып, derin öğrenme mimarileri detaylı bir şekilde ele alınmıştır. Ayrıca, derin öğrenmede kullanılan programlama dilleri ve kütüphanelere değinilmiş ve metin madenciliği hakkında bilgi verilmiştir. Üçüncü bölüm uygulama modelleri ve bulguların yer aldığı bölümdür. Bu bölümde, araştırmanın amacı ve kapsamı

sunularak, analizde kullanılan veri setleri ve yöntemlerden bahsedilmiştir. Ayrıca verilerin elde edilme süreci detaylı olarak verilmiştir. Bu bölümün son kısmı analize ayrılmıştır. Analizde kullanılan yöntemlerden ve elde edilen sonuçların beklentiyi ne ölçüde ve hangi şartlar altında karşıladığından bahsedilmiştir. Dördüncü bölümde ise, tüm analizlerden elde edilen sonuçlar özetlenerek, genel bir değerlendirme yapılmış ve çalışmanın literatüre katkısına yer verilmiştir.

1. BÖLÜM

1. FİNANSAL PİYASALAR

1.1. Finansal Piyasaların Tanımı

Piyasa, “alıcı ve satıcıların bir araya gelerek karşılıklı mal ve hizmet aktarımı yaptıkları yer” olarak tanımlanmaktadır. Finansal araçların alım ve satımının gerçekleştiği yapıya da “finansal piyasa” denmektedir. Finansal piyasalar, amaç ve işlevlerine göre “sermaye piyasası” ve “para piyasası” olmak üzere ikiye ayrılmaktadır.

Para piyasası, vadesi bir günden bir yıla kadar olan hazine bonoları, devlet tahvilleri gibi araçların kullanıldığı piyasalardır. Risk ve getiri düzeyi sermaye piyasasına göre daha düşüktür. Para piyasasının en önemli kurumları bankalardır.

Sermaye piyasası, fonların belli oranda getiri beklentisi ile farklı yatırım araçlarında değerlendirildiği piyasalardır (Aytekin, 2018: 151). Sermaye piyasasında orta ve uzun vadeli yatırım araçları kullanılmaktadır. Türkiye’de sermaye piyasasının yasal çerçevesinin oluşturularak alt yapısının kurulması 1981 yılında Sermaye Piyasası Kanunu’nun çıkarılması ve Sermaye Piyasası Kurulu’nun kurulması ile olmuştur (Aytekin,2018: 155). Sermaye piyasasındaki bu düzenleme ile piyasaların işleyiş kuralları belirlenmiş, şeffaf, rekabetçi ve güvenilir bir ortam yaratılmıştır.

Sermaye piyasasının en önemli araçları hisse senetleridir. Hisse senedi; sermaye ve anonim şirketlerin ortaklarına paylarını belgelendirmek amacıyla verdiği kıymetli evraktır. Pay sahibine ortaklık hakkı, yönetim kurulunda oy hakkı tanıyan bu kıymetli evrak devlet tahvillerine göre daha fazla getiri imkânı sağlamaktadır (Kindik, 2019:39). Alımı, satımı, işlem göreceği pazarının kurallarla belirlendiği bu yatırım aracı Borsa İstanbul bünyesinde işlem görmektedir.

Sermaye piyasasına yatırım yapan kişi ve kurumlar yatırım yaptıkları piyasayı etkileyebilecek tüm ekonomik, finansal bilgileri takip ederek yatırım stratejisi kurmak zorundadır. Bu strateji yatırım yapılan enstrümanın gelecekteki fiyatını tahmin ederek bugünkü fiyatıyla karşılaştırma yapılması ve ilgili enstrümana yatırım yapılıp yapılmayacağı konusunda fikir edinme amacını taşır. Günümüzde bu amaca hizmet eden ve en sık kullanılan analizler temel analiz ve teknik analizdir.

1.2. Finansal Piyasalarda Kullanılan Analiz Yöntemleri

1.2.1. Temel Analiz

Temel analiz ülkenin ekonomik, sosyal ve politik yapısı gereği sahip olduğu risk yapısı, ülkenin makroekonomik verileri ile bu makroekonomik yapı içinde sektörlerin durumunu göz önüne alarak tüm mali tablolarının incelenmesi ve değerlendirme yapılmasını ifade etmektedir (Erdinç,2004: 48).

Temel analizde şirketlerin temel mali göstergelerinin temel argümanları analiz edildiğinde şirket yapısı hakkında detaylı bilgiye ulaşılabilmektedir (Krantz,2010: 254).

Temel analizin üç temel aşaması vardır. Bunlar; genel ekonomi analizi, sektör analizi ve firma analizidir. Analizin yapılma sırası ile ilgili bir kural olmamasına rağmen temel analiz genelden özele doğru yapılmaktadır (Ergin,2015: 40).

1.2.2. Teknik Analiz

Teknik analiz bir hisse senedinin geçmiş hareketlerinin grafikler aracılığıyla incelenerek analiz edilmesi ve geleceğe yönelik tahmin yapılması tekniğidir (Kirkpatrick ve Dahlquist, 2011: 10). Bu teknikte sadece borsada oluşan fiyatlar kullanılmaktadır ve fiyat hareketleri ile hisse senedinin karakteri belirlenebilmektedir (Çetinyokuş ve Gökçen, 2002: 48). Teknik analiz 3 varsayımla özetlenir:

- Tarih tekerrürden ibarettir, yani geçmişteki fiyat hareketleri gelecekte benzer hareketler üretir.
- Fiyat piyasadaki tüm bilgiyi yansıtır.
- Fiyatların hareketleri belirli ve anlamlı bir süre boyunca trend çizgileri üzerinde seyreder (Orçun, 2010: 31).

Teknik analiz için iki ana gösterge sınıfı vardır. Bunlar trend indikatörleri ve osilatörlerdir. Osilatörler, fiyatın zaman içerisinde değişmesi ile bir merkez çizginin altında veya üstünde ayarlanan seviyeler arasında dalgalanan bir göstergedir (Blanco vd., 2008: 198). İndikatörler, trendlerin devamlılığını belirlemede matematiksel ifadeler ortaya koyan göstergelerdir (Öztürk, 2016:471).

Teknik analizde kullanılan çok sayıda trend indikatörü ve osilatör vardır. Aşağıdaki bölümde tez çalışmasında girdi olarak kullanılan trend indikatörlerine ve osilatörlere yer verilmiştir.

1.2.2.1. İndikatörler

• William's %R Göstergesi (Williams %R)

William's %R göstergesi, bir dönem içindeki en düşük ve en yüksek seviyenin değişimini veren kısa vadeli gösterge niteliğinde kullanılan bir trend indikatörüdür (Çiftçi, 2002: 116). William's %R göstergesi eşitlik 1'de gösterildiği şekilde hesaplanmaktadır (Kara vd., 2011: 5314).


$$\text{William's \%R} = \frac{H_n - C_t}{H_n - L_n} * 100 \quad (1)$$

H_n : n gün içindeki en yüksek fiyat

C_t : Kapanış fiyatı

L_n : n gün içindeki en düşük fiyat

Şekil 1.1'de William's %R göstergesine ilişkin örnek bir grafik verilmiştir.



Şekil 1.1. William %R Göstergesi, www.investing.com

William's %R göstergesinin -20'nin üzerindeyken fiyatların düşeceği, -80'nin altındayken ise fiyatların yükseleceği öngörülmektedir (Çiftçi, 2002: 116).


• Basit Hareketli Ortalama (Moving Average, MA)

Basit hareketli ortalama, belirli bir zaman periyodunda kapanış fiyatlarının hareketli ortalamasını veren bir trend indikatörüdür (Özçam, 1996: 99). Basit hareketli ortalama eşitlik 2'de gösterildiği şekilde hesaplanmaktadır (Kara vd., 2011: 5314).

$$MA = \frac{C_t + C_{t-1} + C_{t-2} + \dots + C_{t-n}}{n} \quad (2)$$

□ □: Kapanış fiyatı

Şekil 1.2'de basit hareketli ortalamaya ilişkin örnek bir grafik verilmiştir.



Şekil 1.2. Basit Hareketli Ortalama, www.investing.com

Basit hareketli ortalamanın fiyat eğrisini yukarı doğru kesmesiyle alım, aşağı doğru kesmesiyle satım sinyali verdiği kabul edilir (Çiftçi, 2002: 107).

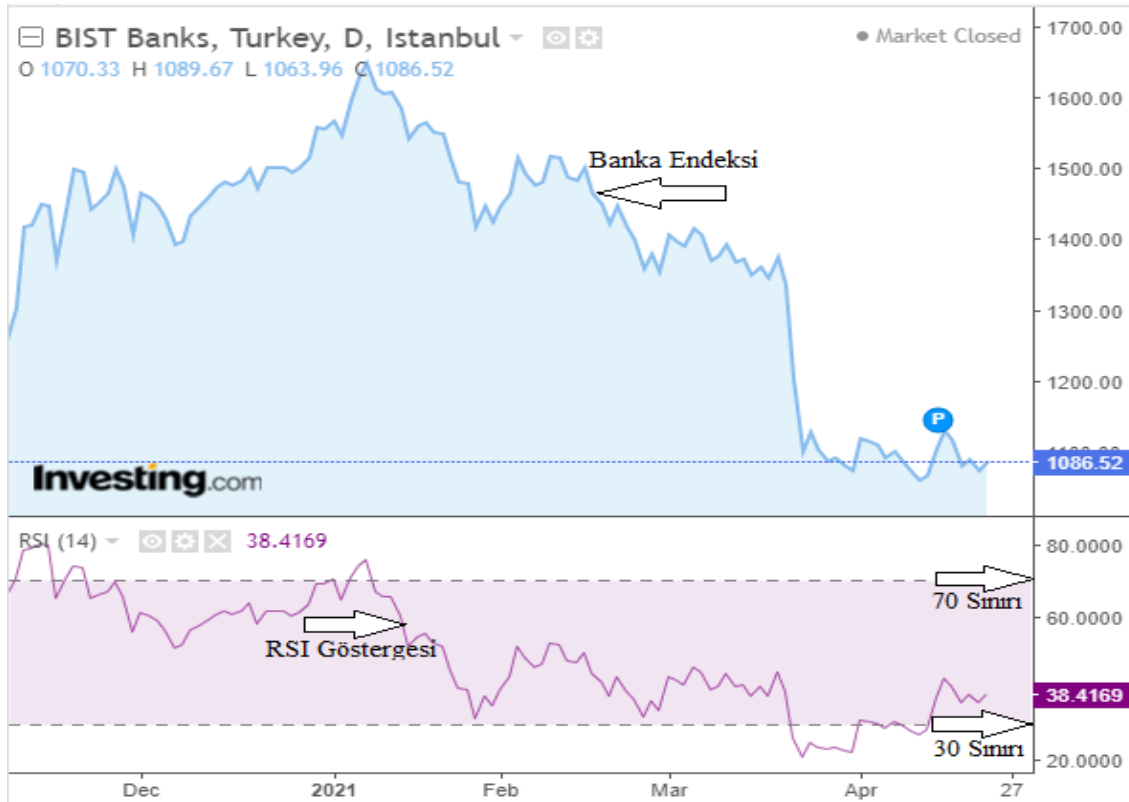
1.2.2.2. Osilatörler

• Göreceli Güç Endeksi (Relative Strength Index, RSI)

Göreceli Güç Endeksi, görsel olarak anlaşılması kolay ve geçerliliği yüksek ve en sık kullanılan bir osilatördür önerilen periyod aralığı 14 günlük olmalıdır (Günak,2007: 166). Göstergede referans aralığı olarak 30 ve 70 değerleri alınır. 70'in üzeri aşırı alım, 30'un altı aşırı satım bölgesini ifade eder (Thomsett, 2014: 193). RSI eşitlik 3'te gösterildiği şekilde hesaplanmaktadır.

$$RSI = 100 - \left[\frac{100}{1+RS} \right] \quad (3)$$

RS= Göreceli Güç= Hesaplanan periyod içinde mevcut fiyattan daha yüksek olan fiyatların ortalamasının mevcut fiyattan daha düşük olan fiyatların ortalamasına bölünerek hesaplanır (Schwager,1999: 317). Şekil 1.3'te RSI göstergesine ilişkin örnek bir grafik verilmiştir.



Şekil 1.3. RSI Göstergesi, www.investing.com

Göreceli güç endeksinin 30 çizgisini yukarı doğru kırdığında alım, 70 çizgisini aşağı doğru kırdığında satım sinyali verdiği kabul edilir (Günak, 2007: 166).

• Stokastik Osilatörü (Stochastic Oscillator, STOCH)

Stokastik Osilatörü, hisse fiyatını belirli bir süre boyunca fiyat aralığıyla karşılaştıran bir osilatördür ve önerilen süre 14 gündür (Raşo, 2019: 7). %K ve %D ile ifade edilen 0 ile 100 arasında hareket eden iki eğri bulunmaktadır. %K'nın hareketli ortalamasının alınmasıyla %D bulunur (Günak, 2007: 174). %K ve %D eşitlik 4'te gösterildiği şekilde hesaplanmaktadır (Kara vd., 2011: 5314).

$$\%K = \frac{C_t - LL_{t-n}}{HH_{t-n} - LL_{t-n}} * 100 \quad \%D = \sum_{i=0}^{n-1} \frac{\%K_{t-i}}{n} \quad (4)$$


C_t : Kapanış fiyatı

LL_{t-n} : Belirlenen dönem içindeki en düşük fiyat

HH_{t-n} : Belirlenen dönem içindeki en yüksek fiyat

$\%K$: %K

Şekil 1.4'te Stokastik osilatör göstergesine ilişkin örnek bir grafik verilmiştir.



Şekil 1.4. Stokastik Osilatör Göstergesi, www.investing.com

Stokastik osilatörünün 20 çizgisini yukarı doğru kırdığında alım, 80 çizgisini aşağı doğru kırdığında satım sinyali verdiği kabul edilir (Günak, 2007: 174).

• **Hareketli Ortalama Yakınlaşma Uzaklaşma Göstergesi (Moving Average Convergence Divergence, MACD)**

Hareketli ortalama yakınlaşma uzaklaşma göstergesi, hisse senedi fiyatlarının 26 günlük üssel hareketli ortalaması ile 12 günlük üssel hareketli ortalamasının arasındaki farkı gösteren bir osilatördür. Hareketli ortalama yakınlaşma uzaklaşma göstergesi eşitlik 5'te gösterildiği şekilde hesaplanmaktadır (Raşo, 2019: 14).

$$\text{MACD} = (EMA_{26} - EMA_{12}) \quad (5)$$

EMA_{26} : 26 günlük üssel hareketli ortalama

EMA_{12} : 12 günlük üssel hareketli ortalama

Şekil 1.5'te MACD göstergesine ilişkin örnek bir grafik gösterilmiştir.



Şekil 1.5. MACD Göstergesi, www.investing.com

Hareketli ortalama yakınlaşma uzaklaşma göstergesinin 9 günlük hareketli ortalamayı yukarı doğru kestiğinde alım, aşağı doğru kestiğinde satım sinyali verdiği kabul edilir (Günak, 2007: 135).

• Momentum Göstergesi (Momentum, MOM)


Momentum, fiyatların seçilen zaman periyodunda yönünü, kuvvetini ve hızını gösteren bir osilatördür (Perşembe,2013: 149). Momentum göstergesi eşitlik 6'da gösterildiği şekilde hesaplanmaktadır (Kara vd., 2011: 5314).

$$MOM = C_t - C_{t-n} \quad (6)$$

C_t : Kapanış fiyatı

C_{t-n} : n gün önceki kapanış fiyatı

Şekil 1.6'da Momentum göstergesine ilişkin örnek bir grafik gösterilmiştir.



Şekil 1.6. Momentum Göstergesi, www.investing.com

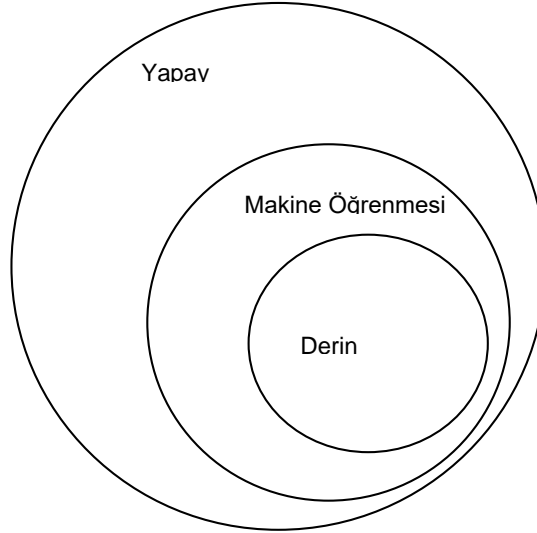
Momentum göstergesinde 100 referans değeri olarak kabul edilir (Tomakin,2007: 160). Gösterge değerinin referans çizgisini yukarı yönde kestiğinde alım, aşağı yönde kestiğinde satım sinyali verdiği kabul edilir (Perşembe, 2013: 152).

2. BÖLÜM

2. DERİN ÖĞRENME KAVRAMLARI

2.1. Derin Öğrenmenin Tanımı

Derin öğrenme, makine öğrenmesi ve yapay zekanın bir alt sınıfıdır ve birden çok düzeyde öğrenme gerçekleştirilmeye çalışan bir dizi algoritmadan oluşmaktadır (Deng ve Yu, 2014: 200). Derin öğrenmedeki derin ifadesi ardışık katmanları ifade etmektedir. Bir modelde ne kadar katman varsa modelin derinliği bu katman sayısı ile ifade edilir. Derin öğrenmede, birbiri ardına yapılandırılmış katmanlar yapay sinir ağı adı verilen yapılar aracılığıyla öğrenmeyi gerçekleştirir. Yapay sinir ağı terimi insan vücudundaki sinir ağlarından esinlenilerek ortaya atılmıştır. (Chollet ve Allaire, 2017:2). Şekil 2.1 yapay zeka, makine öğrenimi ve derin öğrenme arasındaki ilişkiyi göstermektedir.




Şekil 2.1. SEQ Şekil_2. * ARABIC 1. Yapay Zekâ, Makine Öğrenimi ve Derin Öğrenme İlişkisi (Chollet ve Allaire, 2017: 2)

Bu ilişki şu şekilde ifade edilebilir. Yapay zeka insan beyninin çalışma prensibinden ilham alınarak ortaya atılmış bir kuram olarak ifade edilmektedir (Pirim, 2006: 84). Makine öğrenimi, yapay zekaya ulaşmak için kullanılan bir yaklaşım iken derin öğrenme ise makine öğrenimini uygulamak için kullanılan bir tekniktir.

2.2. Derin Öğrenme Mimarileri

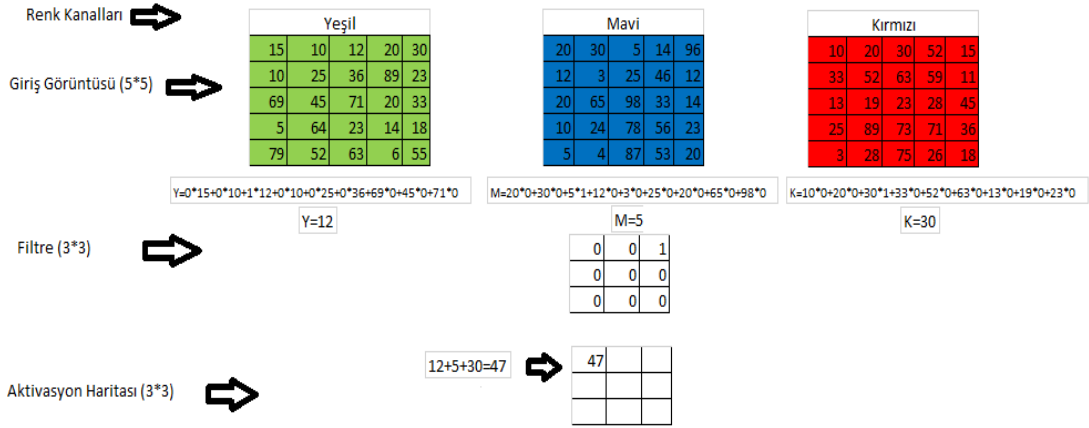
2.2.1. Konvolüsyonel Sinir Ağları (Convolutional Neural Network-CNN)

Konvolüsyonel (Evrışimsel) sinir ağları (CNN), çok katmanlı yapay sinir ağıdır. Hayvanların görme merkezinden esinlenerek oluşturulan CNN görüntü ve ses işleme, anlamsal ayrıştırma, sınıflandırma alanlarında oldukça başarılı sonuçlar vermektedir (Şeker vd., 2017: 50). CNN'nin geleneksel yapay sinir ağlarından farkı, öğrenilebilir tercihlere ve yanlılığa sahip olmasıdır. Genel hatlarıyla bu sinir ağları; evrişim, havuzlama (toparlama) ve ileri besleme (tam bağlantı) katmanlarından oluşan bir yapıya sahiptir (Aydın ve Yüksel, 2017). Aynı zamanda bu katmanlar da kendi içerisinde filtre katmanı, doğrusal olmayan katman ve havuzlama katmanını içermektedir (Arı, 2017: 8). Şekil 2.2 evrişimsel sinir ağının yapısını göstermektedir.



Şekil 2.2. Evrişimsel Sinir Ağları (İnik ve Ülker, 2017:89)

Evrışim Katmanı: Bu katman, CNN'nin en temel katmanıdır. Görüntü üzerinde belirli bir filtre dolaştırılır ve bu filtre bir önceki katmandan gelen görüntülere evrişim işlemi uygulayarak çıktı elde edilmesini sağlar. Evrişim işlemi ile görüntüye ait bir aktivasyon haritası çıkarılır. Aktivasyon haritası filtrele ilgili özelliklerin keşfedildiği alanlardır (İnik ve Ülker, 2017: 90). Bu katmanda gerçekleşen işlemler Şekil 1.2'de gösterilmiştir. Şekil 1.2 'de giriş görüntüsü kırmızı, yeşil, mavi olmak üzere renk uzayının en çok kullanılan renkleridir ve 5x5'lik matris şeklinde düşünülürse giriş verisinin boyutu 5x5x3 olacaktır. Evrişim işlemi için 3x3'lük filtre kullanılmış ve adım aralığı (S) sağa sola kaydırma yapılacak şekilde bir adım seçilmiştir. İşlem sonucunda aktivasyon haritası çıkarılmıştır. Şekil 2.3 evrişim katmanında meydana gelen işlemleri göstermektedir.




Şekil 2.3. Evrişim Katmanı

Filtre boyutu, filtre katsayıları, adım aralığı araştırmacı tarafından belirlenmektedir ve bu yapılar kullanıcının modeline uygun olacak şekilde tasarlanmalıdır. Aktivasyon haritasındaki girdi ve çıktılar aynı yoğunluk aralığına sahip olabilmesi için aktivasyon işlemi uygulanır.

Aktivasyon İşlemleri: Aktivasyon işlemlerinin amacı, girdi verilerindeki anlamları kaybetmeden bazı doğrusal değişkenleri değiştirmektir (Üzen ve Hanbay, 2019: 607). En sık kullanılan aktivasyon fonksiyonları şu şekilde özetlenebilir;


1) ReLU (Rectifier Linear Unit Layer- Düzleştirilmiş Doğrusal Birim Katmanı): Bu fonksiyon kendisinden önce ki katmanda matematiksel bir işleme tabi tutulup doğrusal hale gelmiş ağı doğrusal olmayan bir yapıya getirmek için kullanılır (İnik ve Ülker, 2017: 91). YSA' da sıklıkla kullanılan sigmoid fonksiyonunu kullanmak daha sığ yapılarda sorun yaratmaz iken, ağ mimarisinin derinleşmesi durumunda 1'den daha küçük ya da 1'den daha büyük değerlerde sorun yaşanır. ReLU bu sorunu ortadan kaldırmak için idealdir. Minimum değerın sıfır olması sorun olarak görülebilir ancak ReLU anlamlı bağlantıları ortadan kaldırmadan ağı seyrekleşmesine yardımcı olur (Pedamonti, 2018). Eşitlik 7'de ReLU fonksiyonu verilmiştir. Şekil 2.4 ise fonksiyonun grafiğini göstermektedir.

$$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases} \quad (7)$$




Şekil 2.4. ReLU, <https://pythondunyasi.com/derin-ogrenme-aktivasyon-fonksiyonlari/>

2) LReLU (Leaky ReLU): Sızıntı Düzleştirilmiş Doğrusal Birim Katmanı olarak adlandırılan bu fonksiyon negatif değerlerin ReLU’da kaybolmasını engellemek için kullanılmaktadır. Şekil 2.5 LReLU grafiğini göstermektedir.



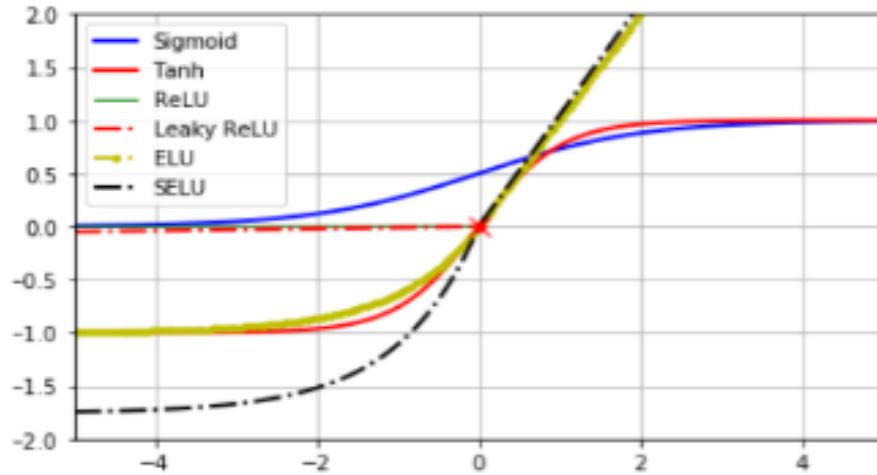
Şekil 2.5. LReLU, <https://pythondunyasi.com/derin-ogrenme-aktivasyon-fonksiyonlari/>

3) ELU (Exponential Linear Unit): Üstel Doğrusal Birim olarak adlandırılan bu fonksiyon ReLU’nun aksine aktivasyonların ortalamasını sifıra yaklaştıran negatif değerlere sahiptir (Clevert vd., 2016: 1). Şekil 2.6 ELU grafiğini göstermektedir.



Şekil 2.6. ELU, <https://pythondunyasi.com/derin-ogrenme-aktivasyon-fonksiyonlari/>

4) SELU (Scaled Exponential Linear Unit): Ölçekli Üstel Doğrusal Birim olarak adlandırılan bu fonksiyon ile ReLU arasında büyük bir fark yoktur. SELU'lar kendi başlarına diğer aktivasyon fonksiyonlarına göre daha hızlı ve daha iyi öğrenirler. Şekil 2.7 SELU grafiği ile diğer aktivasyon fonksiyonlarının grafiklerini karşılaştırmalı olarak göstermektedir.



Şekil 2.7. Aktivasyon Fonksiyonları, <https://medium.com/@kshitikhurana3010/activation-functions-in-neural-networks-ed88c56b611b>

5) Softmax Fonksiyonu: Sigmoid fonksiyonuna benzer yapıdadır. Derin öğrenme modellerinin genellikle çıkış katmanında yer alır ve bu durum softmax fonksiyonu ile sigmoid fonksiyonu arasındaki en önemli farktır.

Havuzlama (Toparlama) Katmanı (Pooling Layer): CNN'lerde bu katman isteğe bağlı olarak ve genellikle aktivasyon işlemlerinden sonra kullanılır. Havuzlama katmanının kullanılmasındaki amaç ağın parametre sayısını ve boyutlarını azaltmaktır (Pervan, 2019: 32).

Boyuttaki azalma bilgi kaybına yol açar ve ağ açısından bu kayıplar iki nedenden dolayı yararlıdır. Birincisi parametre ve boyut sayısının azalması sonraki ağ katmanlarının hesaplama yükünü azaltır, ikincisi ağın ezberleme durumu önlenmiş olur (İnik ve Ülker, 2017: 92).

İki tür havuzlama yöntemi vardır. Bunlardan ilki, filtrenin gezdiği piksellerdeki değerlerin ortalamasını alan ortalama havuzlama (average pooling) yöntemidir. İkincisi yöntem ise, piksellerdeki maksimum değeri alan maksimum havuzlama (maximum pooling) yöntemidir. Performansı daha iyi olduğu için genellikle maksimum havuzlama yöntemi kullanılır (İnik ve Ülker, 2017: 92). Şekil 1.8'de gösterildiği gibi 4×4'lük giriş görüntüsü 2×2'lik filtre ile adım sayısı bir olarak gezdirildiğinde elde edilen görüntünün 3×3'lük boyutta olması gerekir.

Bu hesaplama şu şekilde formüle edilmiştir (İnik ve Ülker, 2017: 93).

Üretilen Görüntünün Boyutu= $\square_2 \times \square_2 \times \square_2$

$$\square_2 = (\square_1 - \square) / \square + 1$$

$$\square_2 = (\square_1 - \square) / \square + 1$$

$$\square_2 = \square_1 \quad (8)$$

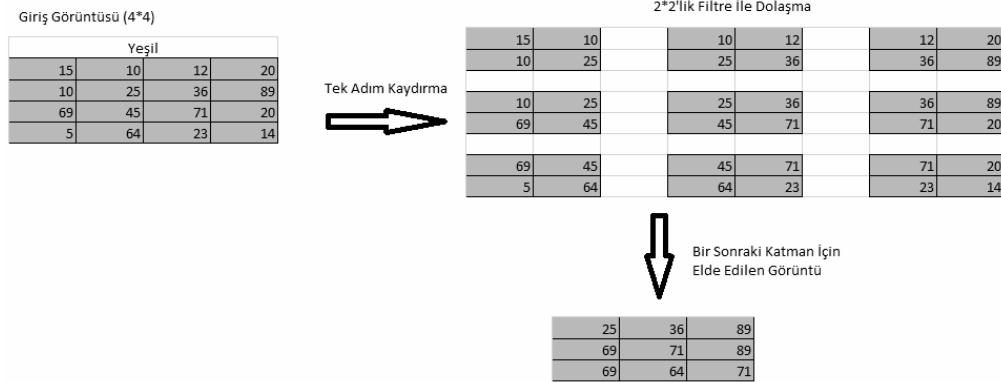
\square_1 : Giriş görüntüsünün genişlik değeri

\square_1 : Giriş görüntüsünün yükseklik değeri

\square_1 : Giriş görüntüsünün derinlik değeri

F : Filtre boyutu

A : Adım sayısı



Şekil 2.8. Havuzlama Katmanı (İnik ve Ülker, 2017: 93)

Tam Bağlantı Katmanı: Bu katmanda önceki katmanlardan gelen veriler ağırlıklandırılarak birleştirilir ve bir kayıp fonksiyonu sayesinde nöronlara eğitim boyunca verilecek en uygun ağırlık bulunur. Bu katmanda genellikle softmax aktivasyon fonksiyonu kullanılır ve olasılıksal olarak sınıflandırma yapılır (Üzen ve Hanbay, 2019: 607). Bu katmanın uygulanmasının ardından çıkış matrisinin satır ve sütun bilgisi 1'e eşit olursa bu katmana tam bağlantılı katman adı verilir.

Evrşimsel Sinir Ağının Eğitilmesi

İlk olarak CNN modeli oluşturulur. Bu modelde yer alacak katmanların sayısı ve sınıflandırılması kullanıcı tarafından belirlenir. Model belirlendikten sonra filtre boyutu, filtre sayısı, adım kayma miktarı belirlenir ve her bir filtreye 0 ile 1 arasında rastgele değer atanır (İnik ve Ülker, 2017: 95).

Oluşturulan modele, örnek giriş görüntüsü verilir ve belirlenen katmanlardan geçerek kaç farklı sınıflandırma yapılacaksa o kadar çıktı elde edilmesi beklenir. Buna ileri besleme denir. Üretilen veri ile gerçek veriler karşılaştırılarak toplam hata hesaplanır (İnik ve Ülker, 2017: 95). Toplam hata eşitlik 9'da gösterildiği şekilde hesaplanmaktadır.


$$T_{\text{toplam hata}} = \sum_{i=1}^n \frac{1}{2} \times (\text{Gözlemlenen Değer}_i - \text{Tahmini Değer}_i)^2 \quad (9)$$

Toplam hata (J) bulunduktan sonra hataya göre ağırlıkların güncellenmesi için Geri Yayılım Algoritması (Back Propagation Algorithm) kullanılır. Geri Yayılım Algoritmasının hesaplamasında sıklıkla Gradyan Stokastik Azaltma (Stochastic Gradient Descent) metodu kullanılmaktadır. Buradaki amaç hesaplanan toplam hatanın geriye doğru yayılmasını

sağlayarak her bir ağırlığın toplam hataya olan etkisini hesaplamaktır. Gradyan Stokastik Azaltma metodunda bu etki kısmi türev ve zincir kuralı kullanılarak bulunur (Kuş, 2019: 14).

Gradyan Stokastik Azaltma Metodu:

Şekil 2.9 iki katmanlı yapay sinir ağı modelini göstermektedir.



Şekil 2.9. İki Gizli Katmanlı Yapay Sinir Ağı Modeli (Kuş, 2019: 15)

X girdi matrisini, \square^l ilk gizli katmanın ağırlık matrisini, \square^2 ikinci gizli katmanın ağırlık matrisini, \square^0 özellik sayısını, \square^l ilk gizli katmanın nöron sayısını, \square^2 ikinci gizli katmanın nöron sayısını, m örnek sayısını ve \hat{y} çıktı değerini göstermektedir. Geriye doğru yayılma için toplam hata değerinin ağıdaki parametrelere göre kısmi türevinin zincir kuralına göre alınması gerekmektedir. Herhangi bir a katmanında hesaplanan gradyan değeri öğrenme oranı ile çarpılarak güncellenir (Kuş, 2019: 15). Gradyan stokastik azalma eşitlik 10'da gösterildiği şekilde hesaplanmaktadır.

$$\square^a = \square^a - \square \frac{\square^a(\square)}{\square^a} \quad (10)$$

Evrişimsel Sinir Ağı Modelleri

AlexNet: ImageNet yüzlerce obje kategorisi ve milyonlarca resimden obje sınıflandırmaya yönelik yapılan bir yarışmadır. 2012 yılında ImageNet yarışmasında en düşük hata ile sonuca ulaşan model AlexNet'tir Bilgisayarlı nesne tanımlama oranındaki hatayı %26.2'den %15.4'e düşüren bu model 5 evrişim katmanı, havuzlama katmanı ve 3 tam bağlantı katmanından oluşmaktadır. Modelde filtre katmanı 11×11, adım sayısı 4 olarak

belirlenmiştir (İnik ve Ülker, 2019: 97).


ZFNet: AlexNet'in ardından derin öğrenme ile yapılan modeller popülerlik kazanmaya başlamıştır. Öyle ki Alex Net'in gelişmiş hali olan ZFNet 2013 yılında ImageNet yarışmasında en yüksek doğruluk oranını veren model olmuştur. Modelde filtre katmanı 7×7 , adım sayısı 2 olarak belirlenmiştir. Filtre katmanının boyutunun küçültülmesinde yatan temel sebep ilk evrişim katmanına girecek olan fotoğraf piksellerinin orijinalliğinin korunabilecek olmasıdır (İnik ve Ülker, 2019: 98).

GoogleNet: ImageNet 2014 yarışmasının kazananı GoogleNet diğer modellerden önemli bir farkla ayrılmaktadır. Modelin yapısı diğer modellerdeki gibi arka arkaya gelen katmanlardan değil de birbirine paralel katmanlardan oluşmaktadır. Bu sayede bellek ve hesaplama maliyeti düşürülmüş olup ağın ezberleme durumu ortadan kalkmıştır. Ayrıca, bilgisayarlı nesne tanımlama oranındaki hatayı %5.7'ye düşürmüştür (İnik ve Ülker, 2019: 98).

RestNet: Kendinden önce geliştirilen tüm ağlardan daha derin bir yapıya sahip olan bu model 2015 yılında ImageNet yarışmasını kazanmıştır. 152 katmandan oluşan bu yapı bilgisayarlı nesne tanımlamadaki hatayı %3.6 oranına düşürmüştür (İnik ve Ülker, 2019: 99).

2.2.2. Yinelemeli Sinir Ağları (Recurrent Neural Networks-RNN)


RNN'ler diğer sinir ağlarından farklı olarak sıralı bilgi kullanır. Hesaplanmış verileri belleğinde tutarak bilgi akışının sürekliliğini sağlayan bir yapıya sahiptir (Pervan, 2019: 24). Özellikle doğal dil işlemede kullanılan bu ağların temel çalışma mantığı, çıktıyı önceden öğrenilmiş verilere göre üretmektir. Sıradan sinir ağlarına göre daha etkin gözükse de bu modelin dezavantajları da bulunmaktadır. Anlamsal çıkarımda bulunması zordur. Örneğin "ben İtalya'da yaşıyorum." cümlesinden sonra gelen "akıcı bir şekilde ... konuşurum" cümlesindeki boşluğa anlamsal çıkarımda bulunup "İtalyanca'yı" ekleyememektedir. Çünkü cümle akışı içerisinde farklı diller yer almış olabilir ve model hangisinin boşluk için uygun olacağına karar veremez (Kızrak ve Bolat, 2018: 269). Şekil 2.10 yinelemeli sinir ağı yapısını göstermektedir.



Şekil 2.10. Yinelemeli Sinir Ağı Yapısı, <https://ichi.pro/tr/rnn-ve-lstm-yi-anlamak-272463982215502>


Bir diğer dezavantajı ise çok fazla girdi boyutuna sahip olduğu için eğitime süresinin uzun olmasıdır. Bu sorun Jordan ve Elman ağları tarafından çözüme kavuşturulmuştur (Bayır, 2006: 64).

Jordan Ağı: Çok katmanlı yapay sinir ağlarına benzeyen bu ağda girdi, çıktı ve gizli katmanın dışında Durum Elemanları olarak adlandırılan yapılar bulunmaktadır. Bu yapılar, çıktı katmanındaki değerleri sonraki iterasyona girdi olarak taşımaktadır (Bayır, 2006: 64). Şekil 2.11 Jordan ağ yapısını göstermektedir.




Şekil 2.11. Jordan Ağ Yapısı (Lipton, 2015: 12)

Elman Ağı: Bu ağda girdi, çıktı ve gizli katmanının dışında İçerik Elemanları olarak adlandırılan yapılar bulunmaktadır. Bu yapılar gizli katmandaki değerleri bir sonraki iterasyona taşır (Bayır,2006: 65). Şekil 2.12 Elman ağ yapısını göstermektedir.



Şekil 2.12. Elman Ağ Yapısı (Lipton, 2015: 13)

Hopfield Ağı: ilk yinelemeli ağlardan biridir ve diğer ağlardan farklı olarak giriş ve çıkış katmanı aynıdır. Her bir hücre açık (+1) ve kapalı (-1) duruma sahiptir (Sezgin vd., 2012: 259). Şekil 2.13 Hopfield ağ yapısını göstermektedir.



Şekil 2.13. Hopfield Ağ Yapısı (Sezgin vd., 2012: 260)

Şekil 2.13'te gösterilen Hopfield ağ yapısında \square_{ij} , i-inci noktadan j hücresine olan bağlantının ağırlığını gösterir t zamanda ağın bu hücresinin girdisi eşitlik 11'da gösterildiği gibi

$$\square_{ij}(t) = \sum_{k \neq i} a_{ik} \zeta_{kj}(t-1) - \theta_i \quad (11)$$


olacaktır. $\zeta_{ij}(t-1)$ ile gösterilen ifade bir önceki elemanın çıktısını, θ_i ile gösterilen ifade ise eşik değeridir. Bu hücrenin çıktısı eşitlik 12'de gösterildiği gibi

$$C_{\square\square}(\square) = \{+I \square \checkmark \square \square \square \square \square(\square) > \square \square - I \square \checkmark \square \square \square \square \square(\square) < \square \square C_{\square\square}(\square - I) \square \checkmark \square \square \square \square \square(\square) = \square \square \quad (12)$$

şeklinde olur (Sezgin vd., 2012: 260).

2.2.3. Uzun Kısa Vadeli Bellek Ağları (Long Short Term Memory Networks-LSTM)


LSTM'ler, RNN'lerin gelişmiş halidir. Uzun vadeli bilgiyi hatırlamak için tasarlanmıştır. RNN'lerin aksine bilgiler modelin belleğinde uzun vadede tutulabilmektedir. Şekil 2.14 uzun kısa vadeli bellek ağ yapısını göstermektedir.



Şekil 2.14. Uzun Kısa Vadeli Bellek Ağ Yapısı,


<https://www.programmersought.com/article/78575166382>

Şekil 2.14'te görüldüğü gibi RNN'den farklı olarak gizli katmanda 4 tane sinir ağı katmanı vardır ve kapı(gate) adı verilen yapılar sayesinde hücrelerden bilgi silinebilir ya da hücrelerde bilgiler saklanabilir (Pervan, 2019: 28). Şekil 2.5'te gösterildiği gibi gizli katmanda girdi, çıktı, sigmoid (ve tanjant) ve unut kapıları katmanları bulunur (Kayaalp ve Süzen, 2018: 20). Şekil 2.15 unut kapısını göstermektedir.




Şekil 2.15. Unut Kapısı, <https://www.programmersought.com/article/78575166382>

İlk kapı olan unut kapısı hangi bilginin tutulması hangi bilginin unutulması gerektiğine karar verir. 0 ile 1 arasında bir çıkış değeri sunar. 0 değeri bilginin unutulması, 1 değeri ise bilginin tutulması gerektiği anlamına gelir. Şekil 2.16 giriş kapısını göstermektedir.



Şekil 2.16. Giriş Kapısı, <https://www.programmersought.com/article/78575166382>

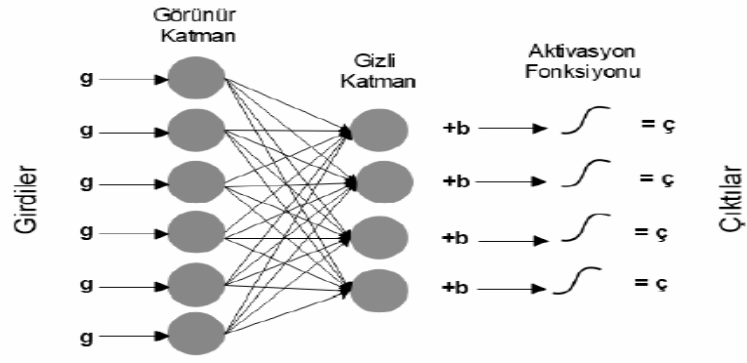
Giriş kapısı katmanı, hangi bilginin depolanacağına karar verir. Sigmoid ve tanjant katmanı olmak üzere iki bölümden oluşur. Sigmoid katmanı hangi bilgiyi güncellememiz gerektiğine karar verirken, tanjant katmanı yeni aday bilgilerini oluşturur. Şekil 2.17’de gösterilen çıkış kapısı çıkışa ne yollanacağı ile ilgili karar verir.



Şekil 2.17. Çıkış Kapısı <https://www.programmersought.com/article/78575166382>

2.2.4. Sınırlı Boltzmann Makinesi (Restricted Boltzmann Machine-RBM)

İki katmanlı olarak rastlantısal oluşturulan bu modelde, görünür katman ve gizli katman olmak üzere iki katman bulunmaktadır (Kayaalp ve Süzen, 2018: 22). Gizli ve görünür katmanlar kendi aralarında doğrudan bağlantılı olmadıkları için sınırlı veya kısıtlı denmektedir. Modele istenildiği kadar gizli katman eklenebilir. Şekil 2.18 sınırlı Boltzmann ağ yapısını göstermektedir.




Şekil 2.18. Sınırlı Boltzmann Ağ Yapısı

<https://devhunteryz.wordpress.com/2018/07/25/kisitli-boltzmann-makineleri>

Görünür katmandaki nöronlar girdi kümesinden bir bilgi alır ve bu bilgiyi gizli katmandaki nöronlara iletir. Gelen bilgiler gizli katmandaki nöronlarda aktivasyon fonksiyonlarından geçirilerek çıktı üretilir (Kayaalp ve Süzen, 2018: 22). RBM'ler problem türüne göre denetimli veya denetimsiz öğrenme ile eğitilebilir (Cengil ve Çınar, 2016: 100).

2.2.5. Derin İnanç Ağları (Deep Belief Networks-DBN)

DBN'ler RBM'lerin yığını olarak ifade edilmektedir ve daha çok görüntü tanıma ve üretmede kullanılmıştır (Şeker vd., 2017: 52). Bir katmanda yer alan değişkenlerin kendisinden önceki üst katmandaki değişkenlere bağıllığının öğrenilmesi için katman-katman prosedürü vardır. DBN'ler de öğrenmeyi gerçekleştirmek için bu katman-katman prosedürüne bir ağgözlülük algoritması uygulanır (Küçük ve Arıcı, 2018: 79). Şekil 2.19 derin inanç ağları yapısını göstermektedir.

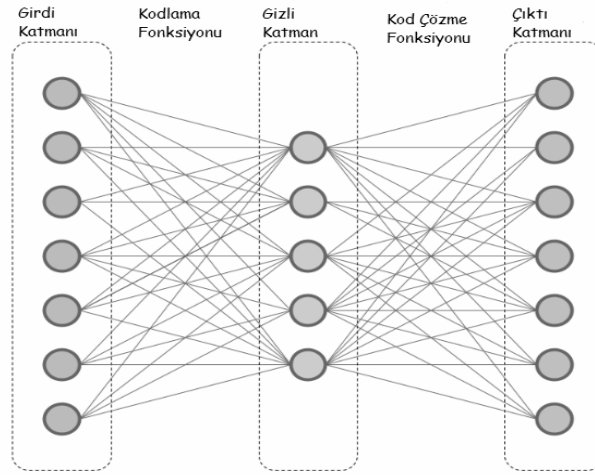


Şekil 2.19. Derin İnanç Ağ Yapısı

<https://devhunteryz.wordpress.com/2018/08/04/derin-inanc-aglarideep-belief-networks>

2.2.6. Derin Oto Kodlayıcılar (Deep Autoencoder-DAE)

DAE'ler girdileri mümkün olduğunca az miktarda bozulmayla çıktı olarak üretmeyi amaçlayan bir modeldir (Baldi, 2012: 41). Girdi, gizli, çıktı olmak üzere üç katmandan meydana gelmektedir. Amaç girdiye benzer bir çıktı elde etmek olduğu için bu iki katmandaki nöron sayıları aynıdır. Elde edilen çıktı girdiye ne kadar çok benziyorsa model o kadar başarılı demektir. (Kayaalp ve Süzen, 2018: 26). Şekil 2.20 derin oto kodlayıcıların yapısını göstermektedir.



Şekil 2.20. Derin Oto Kodlayıcı Ağ Yapısı,

<https://devhunteryz.wordpress.com/2018/05/27/otokodlayicilarautoencoder>

DAE kullanılarak oluşturulan bazı yapılar girdiye benzer çıktı elde etmeye çalışırken verileri ezberler ve test aşamasında kötü sonuçlar elde edilir. Bu durumun önüne geçmek için girdi katmanından sonra gürültü eklenerek çıktı katmanından gürültüsüz girdi elde edilir ve böylece model farklı örüntüleri öğrenir. Bu modele gürültü giderici (Denoising) oto kodlayıcı denir (Kayaalp ve Süzen, 2018: 27).

2.3. Derin Öğrenmede Kullanılan Programlama Dilleri ve Kütüphaneler

Derin öğrenme modellerinin eğitilmesi ve test edilmesi için birçok farklı açık kaynak kodlu yazılımlar mevcuttur. Günümüzde en sık kullanılan programlama dilleri Python, R, Java, Julia'dır. Python; kodlama, veri analizi, makine öğrenmesi için kullanılan son yıllarda oldukça popüler bir programlama dilidir. Kütüphane açısından oldukça zengin bir içeriğe sahiptir aynı zamanda kod okunabilirliği yüksektir. R programlama dili daha çok istatistiksel

veri içeren makine öğrenimi uygulamaları için tercih edilmektedir. Java Python'a benzer geliştirici bir programlama dilidir. Java; Python ya da R gibi programlama dili öğrenmeyi gerektirmediği için tercih edilmektedir. Julia; R ve Python'a rakip olarak ortaya çıkan yüksek performanslı bir programlama dilidir. Makine öğrenimi algoritmaları altında yatan matematiksel sorguları uyarlamak için geliştirilmiştir¹. Derin öğrenme için geliştirilen birden fazla kütüphane bulunmaktadır (Şeker vd., 2017: 57). Bu kütüphanelerden bazıları özellikleri ile birlikte Tablo 1.1'de verilmiştir.

Tablo 2.1. Kütüphaneler

Kütüphane	Yazıldığı Dil	Özellikleri
Theano ²	Python	*Çok boyutlu matematiksel ifadelerin tanımlanmasına, optimize edilmesine, analiz yapılmasını sağlayan bir kütüphanedir. *Katmanların GPU üzerinde çalışması kolaydır. *Hataların tespiti için birim testi araçları bulunmaktadır.
Caffe ³	Python	*Hız ve modülerlik göz önüne bulundurularak geliştirilen bir kütüphanedir. *GPU desteği vardır. *Berkeley lisansına sahiptir. *Özellikle görüntü işlemede oldukça hızlıdır.
Torch/PyTorch ⁴	Python	*Modüler parçaları birleştirmek kolaydır. *Katmanların GPU üzerinden çalıştırılması kolaydır.
Digits ⁵	C++	*Caffe, Torch ve TensorFlow kullanarak görüntü işleme için derin sinir ağları tasarlanabilir. *GPU desteği vardır. *Önceden eğitilmiş modeller vardır.
TensorFlow ⁶	Python	*İhtiyaç doğrultusunda model oluşturmak kolaydır. * GPU ve CPU'da paralel çalışabilmektedir. *Derleme hızı yüksektir.
Keras ⁷	Python	*TensorFlow üzerinden çalışan bir kütüphanedir. *CPU, GPU ve TPU paralel olarak çalışabilmektedir. *Hızlı gelişen bir yapısı vardır.

¹ <https://in.springboard.com/blog/best-language-for-machine-learning>

² <https://pypi.org/project/Theano/>

³ <https://caffe.berkeleyvision.org/>

⁴ <https://pytorch.org/>


⁵ <https://developer.nvidia.com/digits>

⁶ <https://www.tensorflow.org/>

⁷ <https://keras.io/>

2.4. Metin Madenciliği Tanımı

Metin madenciliği; metinlerden anlamlı ve nitelikli bilgilerin elde edilme sürecini ifade etmektedir (Dolgun vd., 2009: 50). Metin madenciliği veri madenciliğinin bir çeşididir ve veri madenciliği ile arasındaki fark, metin madenciliğinde verilerin doğal dil metinlerinden sağlanmasıdır (Hearts, 2003). Metin yazımında standart kurallar bulunmamaktadır bu nedenle modellerin doğrudan metni anlaması mümkün değildir. Metin madenciliği iki temel adımdan oluşmaktadır. Bunlardan ilki metnin anlaşılabilir anahtar kelimelerin elde edilmesi ikincisi ise elde edilen anahtar kelimelerin ilişkili olduğu kategorilere atanması ve model oluşturulmasıdır. Metnin anlaşılması anlamlı ve nitelikli bilginin elde edilmesi açısından önemlidir. Böylece metnin içerdiği anahtar kelimeler elde edilir. Elde edilen anahtar kelimeler model için girdi değişkeni olarak kullanılır ve öngörülse bir model geliştirilir (Dolgun vd., 2009: 50). Şekil 2.21 metin ve veri madenciliği arasındaki ilişkiyi göstermektedir.



Şekil 2.21. Süreçler Arasındaki İlişki (Dolgun vd., 2009: 51)

Metin ve veri madenciliği arasında etkileşimli bir ilişki bulunmaktadır. Bu ilişkiyi şu şekilde açıklamak mümkündür. Metin madenciliği ile elde edilen veriler veri madenciliğinde kullanılmakta, veri madenciliği sonucunda ortaya çıkan sonuçlar seçilen metnin yapısını yorumlamak için kullanılmaktadır (Dolgun vd., 2009: 51).

Metin madenciliğinin birçok kullanım alanı bulunmaktadır. En tipik örnek olarak tüketici satın alma modelleri verilebilir. Alışveriş merkezlerinde tüketicilerin birlikte alması muhtemel ürünler tahmin edilerek raf yerleştirilmesi buna göre yapılmaktadır. El feneri aldığınızda pile ihtiyaç duymanız ve birbirine yakın raflarda bu ürünleri bulmanız örnek olarak gösterilebilir. Bunun dışında harcama modelleri için de metin madenciliği kullanılır.

Çok sayıda kredi kartından yapılan harcamalar incelendiğinde normal harcama modelinden sapan harcamalar sahtekarlık riski taşımaktadır. Benzin alımı için kullanılan kredi kartından bir sonraki harcamada denizaşırı uçak bileti satın alınması sahtekarlık riskine örnek gösterilebilir (Hearts, 2003). Bilimsel ve akademik çalışmalarda, sağlık, istihbarat, müşteri yönetimi gibi birçok alanda metin madenciliği kullanılmaktadır (Dolgun vd., 2009: 51).

2.5. İlgili Literatür Taraması

Literatür taraması iki bölümden oluşmaktadır. İlk bölüm sadece sayısal veriler kullanılarak yapılan çalışmaları içermektedir. Bu bölümde yer alan çalışmalar daha çok teknik göstergeleri içermektedir. Bu sayede çalışma için kullanılması uygun olacak teknik göstergelere karar verilmiştir. İkinci bölüm ise hem sayısal hem metinsel veriler kullanılarak yapılan çalışmaları içermektedir.

Türkmen ve Cemgil (2015) NASDAQ’ da işlem gören beş teknoloji şirketine ait hisse senetlerinin hareket yönlerini tahmin etmeyi amaçlamıştır. 01.01.2010-30.06.2010 tarihleri arasında AAPL (Apple), GOOG (Google), INTC (Intel), MSFT (Microsoft), YHOO (Yahoo) hisselerinin günlük açılış, kapanış, en yüksek, en düşük fiyatları ve işlem hacimleri ham veri olarak kullanılmıştır. Bu fiyat ve hacim bilgisinden elde edilen 9 adet teknik indikatör modelleme için kullanılmıştır. Teknik indikatörler; SMA-10 -P (10 günlük basit hareketli ortalama ile son kapanış farkı), EMA-10-P (10 günlük üstel ağırlıklı hareketli ortalama ile son kapanış fiyat farkı), SMA-20-P, EMA-20-P, SMA-30-P, EMA-30-P, BBANDS-PCT Bollinger bantları ile kapanış fiyatının yüzdesel durumu), MACD, MACD-SIGNAL (MACD göstergesinden yine 9 günlük MACD ortalamasının farkı). Çalışmada tahmin edilmesi planlanan veri “sinyal” olarak tanımlanmıştır. Sinyal; zarar durdur seviyesi (u) ve belli bir fiyattan işlem yapıldıktan sonra kar al ve zarar durdur noktası olarak adlandırılan risk-ödül oranı ile oluşturulan fonksiyonla hesaplanmıştır. Risk-ödül oranı için 1:3, 1:4, u için 0.05 değeri kullanılmıştır. DVM (Destek Vektör Makineleri), RO100 (Rassal Ormanlar 100), ÇKA (Çok Katmanlı Algılayıcı) ve YOK (Yığılmış Oto-Kodlayıcı) sınıflandırma algoritmaları kullanılarak test edilen modellerden elde edilen sonuca göre; YOK modelinin daha sığ mimarideki ÇKA’ ya göre daha başarılı sonuçlar verdiği gözlemlenmiştir.

Gündüz vd. (2017) derin sinir ağı çeşidi olan Evrişimsel Sinir Ağı ile borsada en çok işlem gören Garanti Bankası (GARAN), Türk Hava Yolları (THYAO) ve İş Bankası (ISCTR)

hisselerinin günlük deęişim yönünü bulmayı amaçlamışlardır. Ocak 2011-Aralık 2015 tarihleri arasındaki hisselerin günlük açılış, kapanış, en yüksek, en düşük fiyat verileri, günlük ortalama fiyat, teknik göstergeler ile dolar ve altın fiyatından yararlanmışlardır. Teknik göstergeler; Stokastik K, Stokastik D, MA (Hareketli Ortalama), EMA (Üssel Hareketli Ortalama), momentum, MACD, TEMA (Üçlü Üssel Hareketli Ortalama), PPO (Yüzdesel Fiyat Osilatörü), CCI (Emtia Kanal İndeksi), Williams R, RSI (Görece Güç Endeksi), ULTOSC (Esas Osilatör), ATR (Ortalama Gerçek Aralık). Fiyat öznitelikleri kullanılarak oluşturulan modelde GARA, dolar-altın öznitelikleri kullanılarak oluşturulan modelde GARA ve ISCTR hissesinin yönü en yüksek oranda doğru tahmin edilmiştir. Fiyat ve dolar-altın öznitelikleri birlikte kullanıldığında GARA hissesinin yönünün en yüksek oranda doğru tahmin edildiđi görülmüştür.

Khare vd. (2017) New York borsasına ait 10 hisse senedinin kısa vadeli fiyat tahminini yapmıştır. Bu tahmin iki farklı model oluşturularak yapılmıştır, bu modeller; Çok Katmanlı Algılayıcılar (Multilayer Perceptron-MLP) ve Uzun Kısa Süreli Bellek (Long Short-Term Memory- LSTM)'tir. Veri seti olarak seçilen hisse senetlerinin 2017 yılına ait dakikalık fiyat verisini ve üç teknik göstergeyi kullanmışlardır. Elde ettikleri sonuca göre MLP kısa vadeli hisse senedi fiyat tahmininde LSTM'ye göre daha başarılı sonuçlar vermiştir.

Karaođlu (2018) çalışmasında, BİST 30 vadeli kontratının 01.01.2013-28.01.2014 tarihleri arasındaki fiyat ve hacim bilgilerini kullanarak 5 dakikalık alım satım sinyali veren bir model geliştirmeyi amaçlamıştır. Bunun için ilk olarak piyasa hareketlerini en doğru yansıtacak teknik göstergeleri kullanarak bir sistem geliştirmiştir. Bu teknik göstergeler; Ortalama Gerçek Aralık (ATR), Göreceli Güç Endeksi (RSI), Hareketli Ortalama Yakınsaması / Iraksaması (MACD)'tir. Daha sonra fiyatları doğrusal hale getirebilmek için PLR (Pseudo-Linear Regression) algoritması kullanmış ve iki haftada bir modeli eğitip test etmiştir. Test sonucunda elde edilen verilerle gerçek verileri karşılaştırarak kar-zarar hesaplaması yapmıştır. MACD stratejisi ile oluşturulan sistemin diđer iki sisteme (ATR, RSI) göre daha başarılı sonuç verdiđini ortaya koymuştur. Ayrıca bu üç sistemden yararlanarak oluşturulan ileri beslemeli yapay sinir ađının da başarılı olduđunu gözlemlemiştir.

Raşo (2019) çalışmasında BİST 30'un gelecekteki deđerini bulmak için bir derin sinir ađı modeli oluşturmayı amaçlamıştır. BİST30' un 01.01.2016-31.12.2018 tarihleri arasındaki günlük açılış, kapanış, en yüksek, en düşük fiyat ve işlem hacmi ile oluşturduđu modelde ađ

girdisi olarak 11 teknik göstergeden elde edilen 15 veriyi kullanmıştır. Bazı teknik göstergelerin birden fazla çıktısı bulunmakla birlikte kullanılan teknik göstergeler (indikatörler) RSI, BB, STOCH, Williams R, ROC, SMA, EMA, CCI, OBV, MACD, STOCHRSI' dir. Ağ eğitmek için Keras kullanılmıştır. Her bir işlem günü için oluşturulan beş farklı modelin performansını test etmek için MSE, MAE, MAPE, R2 Score ölçütlerini kullanmıştır. Aynı testi SVR ve ANN ile oluşturulan modellere de uygulamış ve modelleri birbirleri ile karşılaştırmıştır. Derin sinir ağı ile oluşturulan modelin SVR ve ANN 'ye göre daha başarılı olduğu sonucuna ulaşmıştır.

Fung vd. (2003) gerçek zamanlı metinsel veriler ile borsa değerlerini entegre ederek ileriye dönük tahmin yapmayı sağlayan bir sistem geliştirmeyi amaçlamışlardır. Öncelikle oluşturdukları sistemin adımlarının anlaşılması için zaman serilerini kullanmışlardır. Oluşturdukları sistemde metinsel ve sayısal verilerin birlikte kullanıldığı durumlarda daha doğru sonuçlar verdiği düşünülen SVM (Support Vector Machine- Destek Vektör Makinesi) yöntemini kullanmışlardır. 1 Ekim 2002 ile 30 Nisan 2003 tarihleri arasındaki HSI (Hang Seng Index) işlem gören 33 hissenin açılış ve kapanış fiyatı ile altı yüz bine yakın metinsel veriyi kullanarak oluşturdukları veri setinin performansını üç farklı stratejiyle değerlendirmişlerdir: sadece tekli zaman serisi kullanılarak, ikincisi geliştirdikleri kendi sistemlerini kullanarak, üçüncüsü basit al-sat yöntemini kullanarak. Kendi sistemlerinin diğer iki stratejiye göre daha başarılı sonuçlar verdiğini gözlemlemişlerdir.

Soni vd. (2007) kavram haritasını kullanarak hisse senedi fiyat hareketlerini tahmin etmeyi amaçlamıştır. New York Menkul Kıymetler Borsası (NYSE-New York Stock Exchange)'nda işlem gören Amex endeksindeki petrol ve doğalgaz sektörüne ait 11 şirketin 1 Ocak 1995- 15 Mayıs 2006 tarihleri arasındaki verilerini kullanmışlardır. Çalışmalarını dört adımda gerçekleştirmişlerdir. Bunlar sırasıyla; haberlerin toplanması ve etiketlenmesi, toplanan haberlerden özellik çıkarılması, sınıflandırıcıdan sonuç çıkarılması, sınıflandırıcının değerlendirilmesi şeklindedir. Financial Times web sitesinden topladıkları haberleri Data Stream yöntemi kullanarak etiketlemişlerdir. Bir sonraki günkü açılış fiyatı bir önceki günkü açılış fiyatından yüksekse haber pozitif, düşükse negatif olarak etiketlenmiştir. Haberlerden özellik çıkartılması için kavram haritasını oluşturmuşlardır. Kavram haritasının oluşturulması için VOS (Visualization of Similarities) metodunu kullanmışlardır. VOS, nesnelerin benzer nesne çiftlerine yakın bir şekilde yerleştirildiği düşük boyutlu görselleştirmeyi sağlayan metottur. Daha sonra haber ögesinde yer alan kavramların, kavram haritasındaki

konularının ortalamasını alarak bir doküman haritası oluşturmuşlardır. Eğitim setindeki haberlerin doküman haritasındaki yerleri ile haber öğelerinin etiketleri arasındaki ilişkiyi modellemişlerdir. Elde ettikleri sonuçları Naive Bayes sınıflandırıcı ve SVM ile yaptıkları analizlerin sonuçları ile karşılaştırmışlardır ve her bir sınıflandırıcı için doğruluk oranı hesaplamışlardır. Daha sonra sınıflandırıcılar arasındaki isabet farklılıklarının önemini test etmek için çift taraflı z testi kullanmışlardır. %1 düzeyde kendi oluşturdukları sınıflandırıcının isabet oranının diğer ikisine göre daha yüksek olduğunu gözlemlemişlerdir.

Rachlin vd. (2007) ADMIRAL adını verdikleri altı adımdan oluşan sayısal ve metinsel ifadeleri kullanarak tahminde bulunmayı sağlayan bir sistem geliştirmişlerdir. 7 Şubat 2006 ile 7 Mayıs 2006 tarihleri arasında farklı sektörlere ait NASDAQ (National Association of Securities Dealers Automated Quotations) borsasında işlem gören 5 şirket seçmişlerdir. Forbes ve Reuters finansal internet sitelerinden elde ettikleri metinsel ve sayısal verileri ADMIRAL ile işlemişlerdir. Geliştirdikleri sistemin performansını karşılaştırmak için 3 farklı alım-satım stratejisi kullanmışlardır. ADMIRAL'in hem metin madenciliği hem de veri madenciliği alanlarında gerçek zamanlı finansal verilerle ilgili karşılaşılan problemlerin çözümüne alternatif olabileceği sonucuna varmışlardır.

Mahajan vd. (2008) finansal haberlerin piyasaya olan etkilerini incelemişlerdir. Doğal dil işleme sürecinde kullanılan istatistiksel bir model olan LDA (Latent Dirichlet Allocation-Gizli Dirichlet Ayırımı)'yı kullanarak bir sistem geliştirmişlerdir. 700'e yakın haberden 25 konu çıkarmışlardır. Bu konuların piyasa üzerindeki davranışsal etkisini incelemek için Ağustos 2005 ile Temmuz 2008 arasında Bombay borsasında işlem gören en iyi 30 şirketi içeren Sensex endeksinin açılış ve kapanış değerlerini kullanmışlardır. Seçilen konuların; kapanış değerleriyle olan korelasyonunu hesaplamışlardır. Örneğin SEBI (Securities and Exchange Board of India) olarak adlandırılan Hindistan Menkul Kıymetler ve Borsalar Kurulu'nun faaliyete geçme haberi ile kapanış değerleri arasında pozitif korelasyon hesaplamışlardır. Daha sonra endeksin yükseliş ya da düşüşüne yönelik tahmin yapmaya çalışmışlardır. Bu tahmini sigmoid çekirdekli bir SVM ile birlikte karar ağacı kullanarak yapmışlardır. Sistemin ortalamada %60 oranında doğru tahmin yaptığı gözlemlenmiştir.

Eliaçık ve Erdoğan (2015) Bist100 endeksinin değeri ile Twitter'da yapılan yorumlar arasındaki ilişkiyi gözlemek için korelasyon analizi yapmıştır. 29 Eylül 2014 ile 14 Mart 2015 tarihleri arasındaki haftalık borsa verileri ile metinsel veriler kullanılarak hesaplanan

duygu polaritesini birleřtirerek yaptıkları analizden elde ettikleri sonuca göre fiyatlar ile yorumlar arasında 0,2283 korelasyon katsayısına sahip hassas bir iliřki bulunmaktadır.

Akita vd. (2016) hisse senedi piyasası tahmini için derin öğrenme modellerinden Paragraf Vektör (Paragraph Vector)'den ve Uzun Kısa Süreli Bellek (Long Short-Term Memory- LSTM)'den yararlanmışlardır. 2001-2008 yılları arasında Tokyo borsası Nikkei225 endeksinden 5 sektöre ait 10 řirkete ait hisse senedi fiyatları ve gazete haberleri veri olarak kullanılmıştır. Elde edilen sonuçlara göre; Paragraf Vektör modeli hisse senedi fiyat tahmini için daha efektif iken LSTM'in zaman serilerindeki deęişikliği yakalamada daha başarılı olduęu görülmüřtür.

Yıldırım ve Yüksel (2017) borsada işlem gören telekomünikasyon řirketleri için 15.03.2017-15.05.2017 tarihleri arasındaki açılıř ve kapanıř fiyatları ile Twitter'da ilgili řirketler için yapılan yorumlar arasındaki iliřkiyi incelemiřlerdir. Yorumlar için duygu analizi yaparak pozitif, negatif sınıflandırma yapmışlardır. Bu sınıflandırma ile řirketlerin hisseleri arasında korelasyon analizi yaparak veri setleri arasında negatif iliřki bulmuşlardır.

Oncharoen ve Vateekul (2018), borsa tahmini yapmak için fiyat verileri ve teknik göstergelere ek olarak haber başlıklarını da kullanarak üç farklı veri seti ile beř farklı model oluşturmuşlardır. Evriřimsel Sinir Aęı (Convolutional Neural Network-CNN) metinleri sınıflandırmak için, Uzun Kısa Süreli Bellek (Long Short-Term Memory- LSTM) indikatör ve fiyat verileri için kullanılmıştır. Veri setlerini Reuters, Reddit internet sitelerinde ve Intrinio uygulamasında yer alan haber başlıkları ile S&P500 ve DJIA endekslerinden oluşturmuşlardır. İlk veri seti S&P500 ve Reuters, ikinci veri seti DJIA ve Reddit, üçüncü veri seti ise DJIA ve Intrinio řeklinindedir. Bu veri setleri beř farklı modelde test edilmiştir. Elde edilen sonuç hem sayısal hem de metinsel bilgilerin modelin performansını arttıęı řeklinindedir.

Ceyhan vd. (2018) çalışmalarında metin madencilięini kullanarak Bitcoin'nin hareket yönünü tahmin etmeyi amaçlamışlardır. Lojistik regresyon, destek vektör makineleri, yapay sinir aęı, adaboost, rastgele orman modellerini kullanarak üç farklı analiz yapmışlardır. İlk birçok veri kaynaęından elde edilen metin verisi ile Bitcoin hareket yönü arasındaki iliřkiyi gösteren, ikincisi Bitcoin'e, teknik indikatörlere ait 26 veri ile Bitcoin hareket yönü arasındaki iliřkiyi gösteren, üçüncüsü ise ilk iki veri setinin birleřtirilmesiyle yapılan analizlerdir.

Birleřtirilen veri setinin adaboost modelinde olduka bařarılı performans gsterdięi sonucunu elde etmiřlerdir.

elikel (2018) borsada iřlem gren Trk Hava Yolları (THYAO) ve Pegasus Hava Yolları (PGSUS)'nın 1 Nisan 2014- 31 Mart 2018 tarihleri arasındaki gnlk veriler baęımlı deęisken; borsaya, řirketlere, teknik indikatrlere ait 18 deęiřken baęımsız deęiřken olarak modele dahil edilmistir. Bu tarihler arasında řirketler iin atılmıř tweetleri anlamsal baęlamda pozitif ve negatif olarak etiketleyerek szlk tabanlı duygu analizini gerekleřtirmiřtir. Duygu analizi ile elde ettięi sonular ile hisseler arasındaki iliřkiyi incelemek iin korelasyon analizi yapmıřtır. Sonuların gelecekteki alıřmalar iin bir destek sistemi temelini oluřturabileceęi sonucuna varmıřtır.

Atan ve ınar (2019) 2014 yılında Bist30 iin birok veri kaynaęından ekilen metinleri kullanarak duygu analizi yapmıř ve sonuları sayısal deęerlere dnřtrerek endekste bulunan řirketlerin deęerleri ile karřılařtırmıřlardır. Elde ettikleri sonu finansal piyasaların ynnn belirlenmesinde Trke metinlerin de kullanılması avantaj saęlayacaęıdır.

Kilimci (2020) řubat 2018- Aęustos 2018 tarihleri arasında Twitter kullanıcılarının Trke Bist100 ve İngilizce XU100 etiketiyle atmıř olduęu tweetleri finansal duygu analizi yapmak amacıyla incelemiřtir. Farklı dokman gsterimi tekniklerinden, topluluk ęrenme yaklařımlarından ve derin ęrenme modellerinden (Evriřimsel Sinir Aęı-CNN, Tekrarlayan Sinir Aęları-RNN, Uzun Kısa Vadeli Hafıza Aęları-LSTM) yararlanarak Derin Topluluk Modeli (DTM) geliřtirmiř ve borsa endeksinin ynn tahmin etmeye alıřmıřtır. Birok teknięi harmanlayarak oluřturduęu DTM'nin bařarılı olduęunu stelik bu modelin sınıflandırma performansı aısından olduka iyileřtirici olduęu gzlemlenmiřtir.

3. BÖLÜM

3. UYGULAMA MODELLERİ VE BULGULAR

3.1. Çalışmanın Amacı ve Kapsamı

Bu çalışmanın amacı veri ve metin madenciliği teknikleri kullanılarak Borsa İstanbul'da işlem gören banka endeksinin (XBANK) kapanış değerini tahmin etmektir. Çalışmada banka endeksinin tercih edilmesindeki sebep Borsa İstanbul bünyesinde işlem gören endeksler içinde işlem hacmi yüksek endekslerden biri olmasıdır (Özmerdivanlı ve Gülirmak, 2019). Bankacılık sektörünün devamlılık sağlayacağı ve topluma hizmette önemli bir yer tuttuğu göz önüne alındığında banka endeksinin işlem hacminin yüksek olması beklenen bir durumdur. Veri setinin tarih aralığı 04.11.2015- 04.11.2019 olarak seçilmiştir. Dünya genelinde pandemi ilan edilmesine neden olan Covid-19 salgını Mart 2020'den itibaren Türkiye'yi etkisi altına almıştır. Pandeminin ekonomik ve finansal göstergelerde yarattığı bozulma sebebiyle 2020 yılı veri setine dahil edilmemiştir. 04.11.2015-04.11.2019 tarihleri arasında banka endeksine ait günlük değerler (kapanış, açılış, en yüksek, en düşük) ile günlük dolar, altın, brent petrol, euro fiyatları, RSI, MACD, Momentum, William, Basit Hareketli Ortalama, Stokastic K ve Stokastic D teknik göstergeleri kullanılmıştır. Metinsel veri olarak www.dunya.com ve www.investing.com internet sitelerinden günlük haber başlıkları alınarak en yüksek frekansa sahip kelimeler belirlenmiştir. Veri setinde günlük veri tercih edilmesindeki amaç oluşacak kısa vadeli etkilerin modellenmesine olanak sağlamaktır (Erdoğan ve Baykut, 2016: 64).

Finansal ve metinsel veriler kullanılarak üç farklı veri seti oluşturulmuştur. Bu veri setlerinde yer alan değişkenlerden bağımlı değişkenin tahminine en uygun olanları Boruta algoritması ile saptanmıştır. İleri beslemeli derin sinir ağı modeli oluşturmak için kullanılacak parametreler Izgara Arama Yöntemi (Grid Search) optimizasyonu kullanılarak belirlenmiştir. Böylece en uygun değişkenlerle modellemeye en uygun parametreler kullanılarak kapanış değerinin tahmin edilmesi hedeflenmiştir.

3.2. Çalışmada Kullanılan Yöntem ve Veriler

Çalışma için veri toplama ve analiz R programlama dili kullanılarak yapılmıştır. R istatistiksel hesaplamalar ve grafiksel gösterimler için oluşturulan bir programlama dilidir.

İstatistiksel analiz yapmak amacıyla John Chambers ve arkadaşları tarafından geliştirilen S programlama dilini temel almaktadır. S için yazılan kodların birçoğu R altında doğrudan çalışabilmektedir. R dili kullanılarak çok çeşitli istatistiksel hesaplama ve grafikler yapılabilmekteyken S dili daha çok istatistiksel hesaplama için tercih edilmektedir. R dilinin en güçlü yönlerinden biri grafik üretilmesinin kolaylığıdır ⁸.

Analiz yapmak amacıyla üç farklı veri seti hazırlanmıştır. Bu veri setleri; finansal verilerden elde edilen finansal veri seti, metinsel verilerden elde edilen metinsel veri seti ve her iki veri setinin birleştirilmesiyle oluşturulan finansal ve metinsel veri setidir. Metinsel ve finansal veri setinin elde edilme süreci birbirinden farklı olup aşağıda ifade edilmiştir. Veri setinde kullanılan tüm değişkenlerin kısaltması ve açıklaması EK 1 'de gösterilmiştir.

3.2.1. Endekse Ait Finansal Verilerin Elde Edilmesi ve Düzenlenmesi

Finansal veriler www.investing.com adresinden alınmıştır. 04.11.2015-04.11.2019 tarihleri arasında banka endeksinin hafta içi günlük kapanış, açılış, en yüksek, en düşük değerleri ile aynı tarih aralığı baz alınarak euro kuru, dolar kuru, brent petrol ve gram altın fiyatları kullanılmıştır. Literatür taramasında görüldüğü gibi endeksin değerini etkileyeceği gözlemlenen teknik indikatörler ve osilatörler birinci bölümde bahsedildiği şekilde tek tek hesaplanarak veri setine dahil edilmiştir. Seçilen teknik göstergeler; RSI, MACD, Momentum, William, Basit Hareketli Ortalama, Stokastic K ve Stokastic D'dir. Finansal göstergelerin birbirini belirli bir gecikmeyle etkilemesi söz konusu olduğundan tüm bu değişkenlerin 10 gecikmeye kadarki değerleri de veri setine dahil edilmiştir. Ayrıca resmî tatillerde işlem görmeyen endeksin kapanış, açılış, en yüksek ve en düşük değerleri ve bu değerlerle hesaplanan teknik göstergeler için en son işlem görülen güne ait değerler kullanılmıştır. Veri setinde bu durumu ifade edebilmek için dummy değişken oluşturulmuş ve resmî tatil günlerine 0, işlem günlerine 1 değeri verilmiştir. Böylelikle toplamda 166 değişkenli bir veri seti elde edilmiştir. Örnek veri seti EK 3'te gösterilmiştir.

⁸ <https://www.r-project.org/about.html>

3.2.2. Metinsel Verilerin Elde Edilmesi ve Düzenlenmesi

Metinsel veriler www.investing.com ve www.dunya.com adreslerinden web kazıma (web scraping) tekniği kullanılarak elde edilmiştir. Web kazıma, ilgili web sitesinin içeriğinin alınması ve bu içeriğin ayrıştırılarak istenildiği gibi yapılandırılmasını ifade etmektedir (Pena vd., 2013). Birden fazla web kazıma tekniği vardır. Geleneksel kopyala yapıştır, HTTP programlama, HTML ayrıştırma, belge nesneli ayrıştırma vb. bunlara örnek olarak gösterilebilir (Sirisuriye, 2015:136).

Çalışmada seçilen internet sitelerindeki veriler HTML ayrıştırma yöntemi kullanılarak elde edilmiştir. Verilerin elde edilme süreci aşağıdaki gibidir. Çalışmaya uygun veri içerdiği düşünüldüğünden www.investing.com ve www.dunya.com adresleri seçilmiştir.

- Sitelerde 04.11.2015-04.11.2019 tarihleri arasında yayınlanan haberlerin başlıkları web kazıma tekniği ile alınmıştır.

Bir web sitesinden veri kazımadan önce web sitesinin nasıl yapılandırıldığını anlamak gerekmektedir. Web sayfaları oluşturmak için farklı diller kullanılsa da ana diller HTML (Hypertext Markup Language), Javascript ve CSS (Cascading Style Sheets)'tir. Temelde HTML, web sayfasının iskelet yapısının oluşturulmasını, CSS sayfadaki stil ve görünümü, Javascript ise web sayfasının işlevsellik kazanmasını sağlar. R programlama dilinde HTML ve CSS kullanılmış web sitelerinden veri kazımak için çeşitli kütüphaneler bulunmaktadır. Rvest bu kütüphanelerden biridir.

Rvest kütüphanesini kullanmadan önce kütüphanenin indirilmesi gerekmektedir. R'da ilgili kütüphanenin indirilmesi ve kurulması için gereken kodlar aşağıdaki gibidir.

```
install.packages("rvest")
```

```
library(rvest)
```

Kütüphanenin indirilip kurulmasından sonra seçtiğimiz web sitelerindeki verileri okumamız gerekmektedir. Bunun için rvest kütüphanesindeki `read_html()` fonksiyonu kullanılır. Örnek kullanım aşağıdaki gibidir.

```
read_html('https://www.dunya.com/gundem')
```

Böylece sayfa yapısını içeren bir liste elde edilir. Liste, sayfa yapısını ifade eden HTML ve CSS kodlarını içerir. Web sitesinden elde etmek istenen metinleri ayırtmak için `html_nodes()` fonksiyonu kullanılabilir.

Örnek kullanım aşağıdaki gibidir.

```
html_nodes("div.main-con")
```

Böylece `read_html()` fonksiyonu ile elde edilen liste içinde “div.main-con” ile belirtilen etiketin metnine ulaşılabilir.

Tablo 3.1. www.investing.com ‘dan alınan haber başlıklarına örnek

Takibe düşen krediler yabancıların ilgisini çekiyor

Kredi derecelendirme kuruluşu Fitch Türkiye'nin not görünümünü 'negatif'ten 'durağan'a yükseltti

Google Fitbit'i 2,1 milyar dolara satın aldı; Xiaomi'ye akıllı saat sektöründe rakip oldu

Cuma Günü Piyasalarda Bilmeniz Gereken 5 Önemli Gelişme

Eylül ayında 522 kuruluşa 7.2 milyar TL yatırım tutarlı teşvik belgesi verildi

EPDK, 2020 yılına mahsus spot doğalgaz ithalat miktarı yıllık talep çağrısı yapılmamasına karar verdi

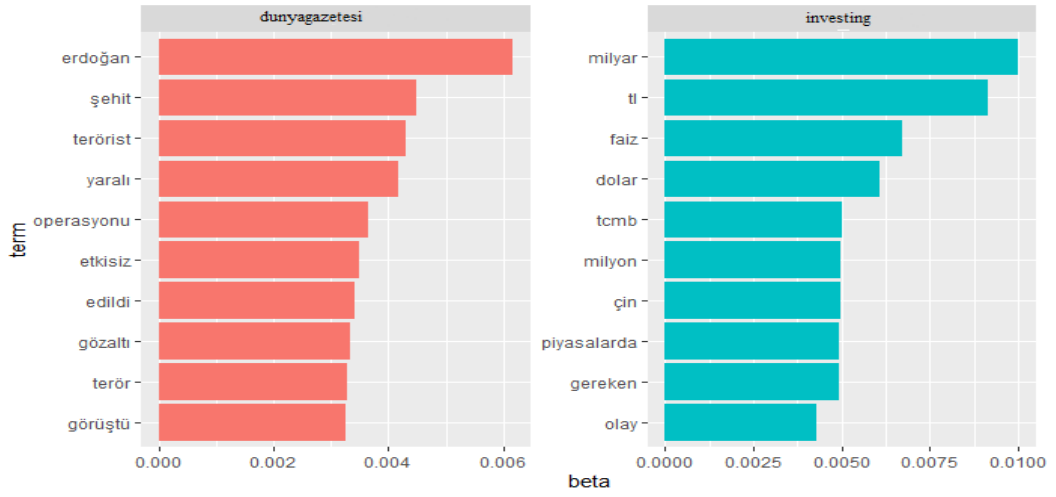
Önümüzdeki yıl 299.6 milyar TL iç borçlanma, uluslararası sermaye piyasalarından \$9 milyar finansman sağlanması öngörülmekte--Hazine

YENİLEME 1-Hazine yaklaşık 1 yılın ardından 5 yıl vadeli sabit kuponlu tahvil ihalelerine yeniden başlıyor

Tablo 3.2. www.dunya.com 'dan alınan haber başlıklarına örnek

Meteorolojiden kuvvetli rüzgâr ve sis uyarısı
CHP'den "kadın istihdamı" açıklaması
Terörle mücadele bünyesinde şube müdürlüğü kuruldu
"İspanak yedikten sonra hastaneye başvuranların sayısı 196"
İkinci Türk-Rus kara devriyesi gerçekleştirildi
Erdoğan, 2020 öğrenim kredisi tutarlarını açıkladı
Terör örgütü yöneticilerini ihbar edene 10 milyon TL ödül
"Sokaktaki enflasyonla TÜİK'in enflasyonu arasında fark var"
Mersin, Narenciye Festivali ile renklendi
Bariş Pınarı Harekâtı bölgesinde bir asker şehit oldu
Kabataş-Mecidiyeköy-Mahmutbey Metrosu 6 Kasım'da açılacak
CHP'den enflasyon eleştirisi

Tokenize işlemi bir metni anlamlı en küçük ifadelerle bölmektir. Web kazıma ile elde edilen haber başlıkları tokenize edilerek kelimelere ayrılmıştır. İki farklı internet sitesi için tokenize işleminin ardından, corpus olarak ifade edilen, kelimelerin bir araya getirildiği bir liste oluşturulmuştur. Stop words olarak adlandırılan ve tek başına bir anlam ifade etmeyen kelimeler (ve, veya, ya da, ile, oldu vb.) corpustan ayrıştırılmıştır. Haber başlıklarının konu modellemesi LDA ile gerçekleştirilmiştir. LDA; üç aşamalı Bayes modeli olarak tanımlanmaktadır ve bir dökümanı meydana getiren konu olasılıklarının ortaya çıkarılmasını sağlar (Blei vd.,2003: 993). Anlamsal bilgiyi dikkate almayan ve tamamen denetimsiz olarak oluşturulan konu modelleri, dökümanın geneli hakkında bilgi edinmeyi ve analiz yapmayı mümkün kılmaktadır. Haber başlıklarının belirgin konulara sahip olup olmadığının gözlemlenebilmesi için LDA kullanılmıştır ve sonuçlar Şekil 3.1'de gösterilmiştir.



Şekil 3.1. LDA Sonuçları

Şekil 3.1’de gösterilen grafikte dunyagazetesi başlıklı grafik www.dunya.com adresinden elde edilen haber başlıklarına, investing başlıklı grafik ise www.investing.com adresinden elde edilen haber başlıklarına aittir. Grafikte görülen beta katsayıları, kelimelerin konulara göre dağılım oranını gösterir ve bu parametre LDA modelinin hiper parametresi olarak adlandırılır (Chen, vd., 2016: 750).

Her iki grafik incelendiğinde ilk grafiğin siyasi içerikli ikinci grafiğin ise ekonomik içerikli anlam taşıdığı görülmüştür. Bu sayede banka endeksinin kapanış değerinin tahmininde kullanılacak metinsel veri setinin ekonomik ve siyasi içeriklere sahip olduğu sonucuna varılmıştır.

- Her bir listeden en yüksek beta değerine sahip beş kelime analizde kullanılmak üzere seçilmiştir. Bu kelimeler “Erdoğan, şehit, terörist, yaralı, operasyon” ve “milyar, TL, faiz, dolar, TCMB” ‘dir.

- Seçilen bu kelimelerin içinde geçtiği haber başlıklarının sayısı günlük bazda belirlenmiş ve tarih bilgisiyle birlikte analize hazır hale getirilmiştir. Örnek veri seti aşağıdaki gibidir.

Tablo 3.3. Örnek Veri Seti

tarih	erdogan_title	operasyon_title	sehit_title	yarali_title	terorist_title	milyar_title	dolar_title	faiz_title	tcmb_title	tl_title
04.11.2015	1	1	1	0	0	2	2	0	2	2
05.11.2015	0	2	2	0	1	5	4	4	4	4
06.11.2015	0	3	0	0	3	3	1	1	1	1
09.11.2015	1	2	0	1	1	3	1	1	1	1
10.11.2015	0	0	3	1	0	3	2	2	2	2
11.11.2015	0	1	3	0	1	4	5	4	5	5
12.11.2015	1	2	0	0	2	3	4	6	4	4
13.11.2015	0	2	1	0	0	4	1	1	1	1
16.11.2015	3	1	0	1	2	5	1	5	1	1

Analizde kullanılmak üzere üç farklı veri seti oluşturulmuştur. Bunlardan ilki sadece finansal verilerle, ikincisi finansal ve metinsel verilerin birleştirilmesiyle, üçüncüsü sadece metinsel verilerle oluşturulan veri setleridir.

3.2.3. Boruta Algoritması

Boruta algoritması Random Forest Algoritması (Rastgele Orman Algoritması) etrafında oluşturulan bir algoritmadır. Random Forest Algoritması nispeten hızlıdır ve parametrelerin model için önemini sayısal bir değer olarak verir. Boruta algoritması aşağıdaki adımlardan oluşur.

1. İlk olarak veri kümesine tüm değişkenlerin kopyasını ekleyerek veri kümesini genişletir. Eklenen bu değerlere gölge değerler denir.

2. Tüm bu veri kümesini Rastgele Orman Algoritması ile eğitir ve sonuçta Z puanlarını hesaplar. Z puanı ortalaması 0, standart sapması 1 olan ve evrende normal dağılım gösteren puanlardır. Z puanı; değerlerin ortalama değerden farkı alınarak standart sapmaya bölünmesiyle elde edilir⁹.

3. Ardından gölge değerleri arasındaki maksimum Z puanını hesaplar.

4. Hesaplanan Z puanına göre veri kümesindeki değişkenlerin önemli olup olmadığını

⁹ <http://web.hitit.edu.tr/dosyalar/duyurular/yetkinkamuk@hititedutr240420158G5R7B8D.pdf>

kontrol eder. Buna, değişkenlerin Z puanının gölge değerlerin maksimum Z puanından daha yüksek olup olmadığına göre karar verir.

5. Eğer değişken önemliyse bunu işaretler ve bir vektöre kaydeder, önemli değilse matristen kaldırır. Ardından başka bir değişken için bu işlemi yineler.


6. Bu şekilde algoritma rastgele karıştırılmış gölge değerlerle değişkenlerin önemini sağlam bir şekilde doğrulamaya çalışır.

Sonuç olarak Boruta algoritması sisteme rastgelelik ekleyerek ve rastgele örneklem topluluğundan sonuçlar toplayarak korelasyonun yanıltıcı etkisini azaltmaktadır (Kursa ve Rudnicki, 2010).

Çalışmada oluşturulan veri setlerinin her birisi için Boruta algoritması kullanılmıştır. Boruta algoritması sonu elde edilen grafikte mavi kutu grafikleri, bir gölge değerinin minimum, ortalama ve maksimum Z puanına karşılık gelir. Kırmızı ve yeşil kutu grafikleri, sırasıyla reddedilen ve onaylanan değişkenlerin Z puanlarını temsil eder (Kursa ve Rudnicki, 2010).

Finansal Verilerle Oluşturulmuş Veri Seti İçin Boruta Algoritması

Sadece finansal veri setine boruta algoritması uygulandığında elde edilen sonuçlar Şekil 3.2’de gösterilmiştir.




Şekil 3.2. Finansal Verilerin Boruta Analizi

Boruta analizi sonucu reddedilen parametreler; dummy,yuksek, k, k4, k5,k7,k8,k9,k10, d2, d3,d5, d6, d8, momentum, momentum2, momentum10, william1, william5, william7, william8, william9, brent6, brent9. Bu deęişkenler dıřındaki parametreler kapanıř deęerinin tahmin edilmesinde önemli olarak iřaretlenmiřtir.

Metinsel Verilerle Oluřturulmuř Veri Seti İin Boruta Algoritması

Sadece metinsel veri setine Boruta algoritması uygulandıęında elde edilen sonular Őekil 3.3'te gsterilmiřtir.




Őekil 3.3. Metinsel Verilerin Boruta Analizi

Őekil 3.3'de gsterilen sonular incelendięinde metinsel veri iin seilen parametrelerin tm kapanıř deęerinin tahmin edilmesinde önemli olarak iřaretlenmiřtir. Sadece metinsel verilerden oluřan veri setinde tm parametreler analize dahil olacaktır.

Finansal ve Metinsel Verilerle Oluřturulmuř Veri Seti İin Boruta Algoritması

Hem metinsel hem finansal veri setine Boruta algoritması uygulandıęında elde edilen sonular Őekil 3.4'te gsterilmiřtir.



Şekil 3.4. Finansal ve Metinsel Verilerin Boruta Analizi

Grafik incelendiğinde reddedilen parametreler; dummy, k1, k2, k3, k4, k5, k6, k7, k8, k10, d2, d5, momentum1, momentum2, momentum3, momentum4, momentum5, momentum6, momentum7, william, william1, william4, william7, william8, william9, erdogan_title, terorist_title, sehit_title, operasyon_title, yarali_title, dolar_title, faiz_title, tcmb_title'dir. Bu değişkenler dışındaki tüm değişkenler kapanış değerinin tahmin edilmesinde önemli olarak işaretlenmiştir.

3.2.4. Hiper Parametre Optimizasyonu

Hiper parametre kavramını anlayabilmek için öncelikle model parametresi ile hiper parametre arasındaki farkın anlaşılması gerekir. Araştırmacının önceden karar vermesine ihtiyaç duyulmadan modelde kullanılan verilerle öğrenmeyi gerçekleştiren parametrelere model parametresi denir. Hiper parametreler model parametrelerinden farklı olarak verilerle öğrenme gerçekleştirmez ve önceden belirlenmesi gerekmektedir. Optimizasyon, bir modelin en iyi şekilde tahmin edilmesi için en uygun parametreleri bulan bir prosedürdür ve modelin tahmin doğruluğu üzerinde büyük bir etkisi vardır (Zheng,2015: 28).

Literatürde birden fazla hiper parametre optimizasyon yöntemi bulunmaktadır. En sık kullanılan yöntemler; ızgara arama (grid search), rastgele arama (random search), evrimsel algoritmalarıdır. Çalışmada, hiper parametre optimizasyonu olarak ızgara arama yöntemi

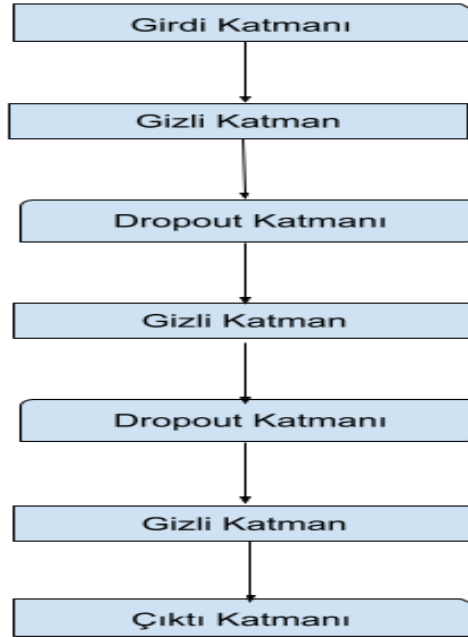
kullanılmıştır çünkü ızgara arama, diğer yöntemlere göre uygulaması kolay bir yöntemdir (Tanyıldızı ve Demirtaş, 2020).

Izgara Arama Yöntemi (Grid Search)

Modelde kullanılan hiper parametrelerden bazıları sonsuz sayıda değer alabilir. Bu yüzden bu parametreler için belirli aralıklar belirlenir. Belirlenen aralıklardaki değerlerle model eğitilir ve sonuçlar gözlemlenerek elde edilen en iyi kombinasyon grubu modelin hiper parametreleri olarak belirlenir (Zheng,2015: 31).

Bu yöntemin en büyük dezavantajı hesaplama süresinin uzun olmasıdır. Zaman tasarrufu sağlamak için hesaplama veri kümesinin bir alt kümesi üzerinde uygulanabilir. Böylece hiper parametrelerin hangi aralıklarda olabileceği hakkında bir öngörü sağlanmış olur (Tanyıldızı ve Demirtaş, 2020).

Analiz için kurulan ileri beslemeli derin sinir ağı modelini tanımlamak ve eğitmek için Bölüm 2’de bahsedilen Keras kütüphanesi kullanılmıştır. Derin sinir ağı modelinde kullanılan hiper parametrelerin ızgara arama yöntemiyle en uygun değeri belirlenmeye çalışılmıştır. Analizde kullanılacak ileri beslemeli derin sinir ağı modeli Şekil 3.5 ’de gösterilmiştir.



Şekil 3.5. Derin Sinir Ağı Modeli

Model; girdi katmanı, çıktı katmanı, iki dropout katman ve üç gizli katmandan meydana gelmektedir.

Çok fazla sayıda parametreye sahip olan derin öğrenme modellerinde aşırı uyum (overfitting) bir sorundur. Aşırı uyum, bir derin öğrenme modelinin en alt kırılıma kadar sonuçları ezberlemesi olarak ifade edilmektedir. Bu durum, modelin kendisine verilecek yeni verilere uyum sağlayamamasına neden olur.

Dropout katmanı bu sorunu ele alır ve aşırı uyumu engeller, bu katman unutma ya da bırakma katmanı olarak da ifade edilmektedir. Dropout katmanı ile belirli bir orana göre rastgele seçilen düğüme giren ve çıkan tüm bağlantılar geçici olarak kapatılır. Burada belirlenen dropout oranı modele göre değişkenlik gösterse de genel olarak 0.5 ile 0.8 değeri arasındadır (Srivastava vd., 2014: 1954).

Epoch (döngü) ve batch size (boyut) derin öğrenme modelinin iyileştirilmesinde kullanılan hiper parametrelerdir. Epoch eğitim sırasında ağa tüm veri setinin gösterilme sayısıdır ve genelde epoch ne kadar yüksek olursa sonuçlar o kadar iyi sonuçlanacaktır. Batch size ise her döngü sırasında ağa ne kadar veri gösterilmesi gerektiğini belirtir. Bu değer genelde 32, 64 ve 128 olmaktadır (Nazir vd., 2018: 406).

Izgara arama yöntemiyle modele uygun dropout oranları, epoch ve batch size hesaplanmış olup sonuçlar EK 2’de gösterilmiştir.

Hata Kareler Ortalaması bir tahmin doğruluğu ölçüsü olarak kullanılır. Tahmin doğruluğunun ölçülmesindeki amaç asıl olan ve tahmin edilen değerleri karşılaştırmak ve aralarındaki bozulma seviyesini gözlemlemektir. Eşitlik 12’de gösterildiği şekilde hesaplanmaktadır.

$$MSE_{(x,y)} = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2 \quad (12)$$

Öngörülen değerlerden tahmin edilen değerlerin çıkartılarak karesinin alınması ve örnek sayısına bölünmesi ile hesaplanan Hata Kareler Ortalamasında, $\square_{\square} = (\square_{\square} - \square_{\square})$ hata olarak ifade edilir. Bulunan değer her zaman pozitifdir ve sıfıra yakın olan değerler daha başarılı bir tahmin olduğu kabul edilir (Wang ve Bovik, 2009: 99). Hiper parametre optimizasyonu sonucunda bulunan sonuçlar hata kareler ortalamasına göre sıralanmış ve en

küçük değere sahip hata kare ortalama değerinin en başarılı tahmin olduğu kabul edilmiştir.

EK 2’de işaretlenmiş değerler hiper parametre optimizasyonu sonucu en düşük hata kareler ortalamasına sahip değerleri ifade etmektedir. Analiz için kullanılacak değerler sırasıyla ilk dropout oranı 0.4, ikinci dropout oranı 0.4, batch size 2 ve epoch 50’dir.


3.3. Analiz

Banka endeksinin kapanış verisinin tahmin edilmesi amacıyla toplanan veriler üç farklı veri seti olarak ele alınmıştır. Bunlar; sadece metinsel verilerle oluşturulmuş “metinsel veri seti,” sadece finansal verilerle oluşturulmuş “finansal veri seti” ve hem finansal hem de metinsel verilerin birlikte olduğu “birleştirilmiş veri seti” dir. Kapanış değeri hesaplamasında, veri setlerinde yer alan değişkenlerin önem sırasının belirlenmesi amacıyla Boruta algoritması uygulanmış ve elde edilen sonuçlara göre veri setleri yeniden düzenlenmiştir. Ardından, modelde kullanılacak hiper parametreler için optimizasyon işlemi uygulanmış ve elde edilen sonuçlara göre, modeldeki hiper parametre değerleri yeniden düzenlenmiştir. Verilerin %70’i eğitim, %30’u test seti olarak belirlenmiştir.

Verilerin analizi için Şekil 3.5’te görüldüğü gibi girdi katmanı, çıktı katmanı, iki dropout katman ve üç gizli katmandan meydana gelen ileri beslemeli derin sinir ağı modeli oluşturulmuş ve R programlama dili ile banka endeksinin kapanış değeri tahmin edilmeye çalışılmıştır. Oluşturulan modelde aktivasyon fonksiyonu olarak çok katmanlı ağlarda kullanışlı olduğu düşünülen ve ikinci bölümde bahsedilen ReLU aktivasyon fonksiyonu kullanılmıştır. Kayıp fonksiyonu olarak hata kareler ortalaması (MSE) kullanılmıştır. Kayıp fonksiyonu bir modeldeki hatayı tekrar tekrar tahmin etmeyi amaçlar. Bunun yapılmasındaki amaç bir sonraki değerlendirmedeki kaybı azaltmaktır.

Finansal ve Metinsel Verilerle Oluşturulmuş Veri Seti İçin Analiz

Boruta algoritması sonucunda banka endeksinin kapanış değerinin hesaplanmasında önemli olarak işaretlenen değişkenlerle oluşturulan veri setinin %70’i eğitim seti olarak belirlenmiştir. Veri seti, ızgara arama yöntemiyle belirlenen hiper parametreler kullanılarak eğitilmiştir. Şekil 3.6 finansal ve metinsel verilerin eğitim seti ile gerçekleştirilen eğitim sürecindeki kayıp fonksiyonunun değişimini göstermektedir.




Şekil 3.6. Finansal ve Metinsel Veriler İçin Eğitim Setinin Kayıp ve Doğruluğu

“Training” olarak gösterilen “eğitim veri seti”ni ifade etmektedir. “Validation” olarak gösterilen, “doğrulama veri seti”, eğitim seti içinden seçilen modelin doğruluğunu ve performansını nitelendirmek için kullanılan veri setidir (Kuhn ve Johnson, 2013). Epoch ile gösterilen ise modeldeki döngü sayısıdır. Yaklaşık 5. döngüden sonra doğrulama veri setini ifade eden eğri ile eğitim veri setini ifade eden eğrinin birlikte azalması modelde aşırı uyum sorununun olmadığını göstermektedir.

Model oluşturulduktan sonra, test setinin tahmin edilmesi gerekmektedir. Test seti modelin performansını değerlendirmek için kullanılan veri setidir (Ripley, 1996). Test seti kullanılmasındaki amaç, modelin daha önce görmediği veri seti üzerinde ne kadar doğrulukla tahmin yapabileceğinin gözlemlenmesidir.

Şekil 3.7 finansal ve metinsel veri için, eğitimi tamamlanmış olan modelin, test seti kullanılarak elde edilen tahmin değerleri ile gerçek değerler arasındaki ilişkiyi göstermektedir.




Şekil 3.7. Finansal ve Metinsel Veriler İçin Test Setinin Tahmin Edilen Değerleri ile Gerçek Değerler Arasındaki İlişki

Modelin Haziran 2019'a kadarki tahmin değerleri ile gerçek değerler birbirlerine yakın iken sonrasında değerlerin farklılaştığı ve birbirlerinden uzaklaştığı gözlemlenmektedir.

Kalıntı, tahmin edilen değerler ile gerçek değerler arasındaki farktır. Kurulan modellerde en temel amaç gerçek değerlere en yakın tahminin yapılmasıdır. Bu nedenle elde edilen kalıntı değerleri ile yapılan kalıntı analizi büyük önem taşır. Kalıntı analizi tahmin edilen değerler ile gerçek değerler arasındaki uyumu ya da uyumsuzluğu ortaya koyan analizdir (Şahinler, 1993: 1).

Şekil 3.8 finansal ve metinsel verilerin test setine ilişkin kalıntı değerlerine ait grafiktir.



Şekil 3.8. Finansal ve Metinsel Veriler İçin Test Setinin Kalıntı Değeri

İlgili değer bir önceki değere göre, yeni yüksekler yaparak sürekli bir şekilde yükseliyorsa yükselen trendden söz edilebilir¹⁰. Kalıntı değerleri Şekil 3.8’de görüldüğü gibi, yükselen trende sahiptir. Bu durum kalıntı değerlerinin sürekli arttığını ve tahmin edilen değerlerin gerçek değerlerden farklılaştığını ifade etmektedir. Bir başka deyişle, bu durum gerçek değerler ile tahmin edilen değerler arasında uyumun olmadığını göstermektedir.


Birleştirilmiş verinin test seti kullanılarak elde edilen kalıntı değerleri göz önünde bulundurularak, banka endeksinin kapanış değerinin tahmin edilmesinde birleştirilmiş veri setinin başarılı olmadığı sonucuna ulaşılmıştır.

Metinsel Verilerle Oluşturulmuş Veri Seti İçin Analiz

Boruta algoritması sonucunda banka endeksinin kapanış değerinin hesaplanmasında önemli olarak belirlenen değişkenlerle oluşturulan veri setinin %70’i eğitim seti olarak belirlenmiştir. Veri seti, ızgara arama yöntemiyle belirlenen hiper parametreler kullanılarak eğitilmiştir. Şekil 3.9 metinsel verilerden oluşan eğitim seti ile gerçekleştirilen eğitim sürecinde kayıp fonksiyonun değişimini göstermektedir.


¹⁰ <https://www.qnbf.com/forex/forex-terimler-sozlugu/trend-cesitleri->

nelerdir#:~:text=A1%C3%A7alan%20Trend%3A%20A1%C3%A7alan%20trend%20ilgili,olursa%20buna%20horizontal%20trend%20denir




Şekil 3.9. Metinsel Veri İçin Eğitim Setinin Kayıp ve Doğruluğu

10. döngüden sonra, doğrulama veri setini ifade eden eğri ile eğitim veri setini ifade eden eğrinin birlikte azalması modelde aşırı uyum sorununun olmadığını göstermektedir. Şekil 3.10 eğitimi tamamlanmış olan modelin test seti kullanılarak elde edilen tahmin değerleri ile gerçek değerler arasındaki ilişkiyi göstermektedir.



Şekil 3.10. Metinsel Veri İçin Test Setinin Tahmin Edilen Değerleri ile Gerçek Değerler Arasındaki İlişki

Modelin tahmin değerleri ile gerçek değerleri arasındaki farkın, bir önceki veri seti olan finansal ve metinsel veriler kullanılarak yapılan tahmindeki farka göre daha düşük olduğu gözlemlenmektedir. Şekil 3.11 metinsel verinin test seti için kalıntı değerlerine ait grafiktedir.




Şekil 3.11. Metinsel Veri İçin Test Setinin Kalıntı Değeri

Belirli bir veri setinde, zirveler ve dipler yaklaşık olarak hep aynı noktada oluşuyor ise yatay trend ortaya çıkar (Birgili, 2013: 12). Kalıntı değerleri Şekil 3.11’de görüldüğü gibi yatay trende sahiptir. Kalıntı değerlerinin yatay bir trend oluşturması, tahmin değerleri ile gerçek değerler arasındaki farkın belirli bir aralıkta olduğunu ifade etmektedir. Kalıntı grafiği incelendiğinde, özellikle 20 bin ve 40 bin puan farkla banka endeksini tahmin edebildiği görülmektedir. Banka endeksinin kapanış değerleri göz önüne alındığında tahmin için bu değer oldukça yüksektir.

Sonuç olarak, banka endeksinin kapanış değerinin tahmin edilmesinde metinsel verilerle oluşturulan veri setinin kullanılması ile başarılı sonuç elde edilemediği gözlemlenmiştir.


Finansal Verilerle Oluşturulmuş Veri Seti İçin Analiz

Boruta algoritması sonucunda banka endeksinin kapanış değerinin hesaplanmasında önemli olarak işaretlenen değişkenlerle oluşturulan veri setinin %70’i eğitim seti olarak belirlenmiştir. Veri seti, ızgara arama yöntemiyle belirlenen hiper parametreler kullanılarak eğitilmiştir. Şekil 3.12 finansal veri eğitim seti kullanılarak gerçekleştirilen eğitim sürecindeki kayıp fonksiyonunun değişimini göstermektedir.




Şekil 3.12. Finansal Veri Seti İçin Eğitim Setinin Kayıp ve Doğruluğu

Yaklaşık 8. döngüden sonra doğrulama veri setini ifade eden eğri ile eğitim veri setini ifade eden eğrinin birlikte azalması modelde aşırı uyum sorununun olmadığını göstermektedir. Şekil 3.13 eğitimi tamamlanmış olan modelin test seti kullanılarak elde edilen tahmin değerleri ile gerçek değerler arasındaki ilişkiyi göstermektedir.



Şekil 3.13. Finansal Veri İçin Test Setinin Tahmin Edilen Değerleri ile Gerçek Değerler Arasındaki İlişki

Modelin Haziran 2019'a kadarki tahmin değerleri ile gerçek değerler birbirlerine yakın iken sonrasında değerlerin farklılaştığı ve birbirlerinden uzaklaştığı gözlemlenmektedir. Benzer durum finansal ve metinsel verilerin birlikte kullanıldığı veri setinde de gözlemlenmiştir. Şekil 3.14 finansal verinin test seti için kalıntı değerlerine ait grafiktir.






Şekil 3.14. Finansal Veri İçin Test Setinin Kalıntı Değeri

Finansal veriler kullanılarak elde edilen kalıntı grafiğindeki dalgalanmalar, finansal ve metinsel veriler kullanılarak elde edilen kalıntı grafiğine benzerdir. Kalıntılar, yükselen bir trend izlemektedir. Kalıntı değerlerinin sürekli artması, tahmin edilen değerlerin gerçek değerlerden farklılaştığını ifade etmektedir. Bir başka deyişle, gerçek değerler ile tahmin edilen değerler arasında uyumun olmadığını göstermektedir.


Finansal verilerin test seti kullanılarak elde edilen kalıntı değerleri göz önünde bulundurularak, banka endeksinin kapanış değerinin tahmin edilmesinde finansal veri setinin başarılı olmadığı sonucuna ulaşılmıştır.

Şekil 3.15 tüm veri setlerinin tahmin edilen değerleri ile gerçek değerleri arasındaki ilişkiyi gösteren grafiklerin birleşimidir.




Şekil 3.15. Tüm Veri Setlerinin Tahmin Edilen Deęerleri ile Gerçek Deęerleri Arasındaki İlişki

Grafikler incelendiğinde özellikle birleştirilmiş veri seti ve finansal veri seti için tahmin edilen değerler ile gerçek değerler arasındaki farkın belirli bir tahminden sonra belirgin bir ayrışma gösterdiği gözlemlenmiştir. Bu ayrışmanın belirgin görüldüğü ilgili dönem Haziran-Aralık 2019 arasındadır. Bu döneme ait banka endeksinin kapanış değerleri arasındaki değişim Şekil 3.16’da gösterilmiştir. Şekil 3.16 banka endeksinin Haziran-Aralık 2019 tarihleri arasındaki günlük kapanış değerinde meydana gelen değişimi yüzdesel olarak göstermektedir.



Şekil 3.16. Haziran- Aralık 2019 Banka Endeksi Kapanış Değerleri Değişim Oranı (%)

Bu dönemde endekste meydana gelen en yüksek değişim oranı %8.20, en düşük değişim oranı %0.02’dir. Ortalama değişim oranı %0.189’dur. Şekil 3.17 analiz için kullanılan tüm kapanış değerlerinden ayrışmanın görüldüğü Haziran-Aralık 2019 tarihleri arasındaki kapanış değerleri çıkarıldığında günlük kapanış değerlerinde meydana gelen değişimi yüzdesel olarak göstermektedir.



Şekil 3.17. Haziran- Aralık Hariç 2019 Banka Endeksi Kapanış Değerleri Değişim Oranı (%)


Bu dönemde en yüksek değişim oranının %9.78 en düşük değişim oranının %0.01, ortalama değişim oranının -%0.012 olduğu görülmüştür.

Volatilite, bir veri setindeki değerlerin gösterdiği dalgalanmayı ifade etmektedir (Tuna ve İsaetli, 2014: 22). Değerler karşılaştırıldığında, tüm veri setine göre Haziran- Aralık 2019 tarihleri arasındaki banka endeksinin kapanış değerinde daha fazla volatilite mevcuttur. Bu dönemde piyasayı etkileyecek siyasi ya da ekonomik haberlerin olması muhtemeldir.

Metinsel veri setinin elde edildiği iki haber sitesinden ayrışmanın belirgin olduğu Haziran-Aralık 2019 tarihleri arasındaki haber başlıkları incelenmiştir. Bu tarihler arasında sınır ötesi operasyonlar, 2019 yerel seçimleri ve bu seçimlere itiraz süreçleri, ABD'nin Türkiye'ye uyguladığı yaptırımlar ile ilgili yoğun haber akışının olduğu gözlemlenmiştir. Ülkemizde yaşanan siyasi gerilim, borsa endekslerini doğrudan etkileyerek değerlerde volatilite yaşanmasına sebep olmaktadır (Dayı, 2020: 14).


Topluluk öğrenmesi (ensemble learning), bir modelin tek bir çıktı sonucu kullanılarak tahmin edilmesi yerine birden fazla çıktının sonuçlarının birleşimini kullanıp tahmin etme ilkesine dayanan ve böylece daha doğru bir sonuç elde edilmesini amaçlayan güncel bir derin öğrenme metodudur. Analiz sonuçları göz önüne alındığında, banka endeksi kapanış değerinin tahmin edilmesinde farklı veri setleri ile oluşturulan modellerin tek başlarına yeterli

olmadığı görülmüştür. Bu nedenle tahmin edilen değerler birleştirilip ortalamaları alınarak elde edilen sonuçlar gerçek değerlerle karşılaştırılmıştır. Şekil 3.18 eğitimi tamamlanmış olan modellerin test seti kullanılarak elde edilen tahmin değerlerinin ortalaması ile gerçek değerler arasındaki ilişkiyi göstermektedir.



Şekil 3.18. Gerçek Değerler ve Birleştirilmiş Tahminlerin Ortalaması

Grafikte, finansal ve metinsel olarak belirtilen seri finansal ve metinsel verilerin birleşiminden oluşan veri setini; finansal olarak belirtilen seri finansal veri setini; metinsel olarak belirtilen seri metinsel veri setini ifade etmektedir. Tahminlerin ortalaması incelendiğinde, metinsel ve finansal veri setinin ayrı ayrı tahmin sonuçlarının ortalaması alındığında gerçek değerlere daha yakın sonuç elde edildiği görülmüştür. Gerçek değerlere daha yakın tahmin sonucu oluşturduğu gözlemlenen finansal ve metinsel veri setleri için eğitilen modellerden ayrı ayrı elde edilen tahminlerin ortalaması ile gerçek değerler arasındaki ilişki Şekil 3.19’da görülmektedir.



Şekil 3.19. Gerçek Değerler ve Finansal-Metinsel Veri Tahminlerinin Birleştirilmiş Ortalaması

Tahmin değerlerinin gerçek değerlere yakın olduğu ve gerçek değerlerin oluşturduğu trendi tahmin etmede başarılı olduğu gözlemlenmiştir. Diğer veri setlerinde olduğu gibi, Haziran-Aralık 2019 tarih aralığında tahmin değerlerinde bir farklılaşma söz konusudur. Bu farklılığın daha net görülmesi amacıyla, tahmin değerlerinin çeşitli kombinasyonlarda Haziran-Aralık 2019 tarihi dahil ve hariç halleriyle Hata Kareler Ortalamasının Karekökü (RMSE) hesaplanmıştır ve sonuçlar Tablo 3.4'te gösterilmiştir.

Tablo 3.4. RMSE Sonuçları

	Haziran-Aralık 2019 Hariç	Haziran-Aralık 2019 Dahil
	rmse	rmse
finansal+metinsel	46308.96	89226.18
finansal+metinsel ortalaması	11203.49	24011.12
metinsel	19650.73	17725.52
finansal	20361.73	50362.44
finansal ve metinsel+metinsel ortalaması	23633.45	43349.14
finansal ve metinsel+ finansal ortalaması	30403.41	68676.27
finansal ve metinsel+metinsel+finansal	19686.17	44567.76

Hata Kareler Ortalamasının Karekökü (RMSE) bir hata ölçüsüdür bu nedenle analiz sonucu bu değere göre yorumlanmıştır. Hata ölçülerinin görece düşük değerler alması model performansının başarılı olduğunu işaret etmektedir. Hata Kareler Ortalama Karekökü'nün sıfıra eşit olması model performansının mükemmel performansa sahip olduğunu ifade etmektedir (Çınaroğlu, 2017: 184). Tablo 3.4 incelendiğinde metinsel ve finansal veri setinin ayrı ayrı tahmin sonuçlarının ortalamasının (finansal+ metinsel ortalaması) Haziran-Aralık 2019 döneminin hariç olduğu veri setiyle hesaplanan Hata Kareler Ortalama Karekökü, Haziran-Aralık 2019 döneminin dahil olduğu veri seti ile hesaplanan Hata Kareler Ortalama Karekökü'ne göre daha düşüktür. Ayrıca tablodaki tüm değerler ile karşılaştırıldığında en düşük Hata Kareler Ortalama Karekökü değerine sahip olduğu gözlemlenmektedir. Finansal veri seti incelendiğinde Haziran-Aralık 2019 döneminin hariç olduğu veri setiyle hesaplanan Hata Kareler Ortalama Karekökü, Haziran-Aralık 2019 döneminin dahil olduğu veri setiyle hesaplanana göre daha düşüktür. Finansal ve metinsel veri setinin birleştirildiği birleşmiş veri setinin (finansal ve metinsel) diğer iki veri setiyle ayrı ayrı ortalama değerleri de (finansal ve metinsel+ metinsel ortalaması, finansal ve metinsel+ finansal ortalaması) Haziran-Aralık 2019 döneminin hariç olduğu veri setiyle hesaplanan değerleri daha başarılı sonuçlar vermiştir. Metinsel veri setinde ise durum diğer veri setlerinden farklıdır. Metinsel veri setinde Haziran-Aralık 2019 döneminin dahil olduğu veri setindeki Hata Kareler Ortalama Karekökü bu dönemin hariç olduğu veri setindeki Hata Kareler Ortalama Karekökü'ne göre daha düşüktür.

Elde edilen sonuçlar siyasi gerginliklerin olduğu dönemlerin finansal araçların tümünün üzerinde etkili olduğunu göstermektedir. Bu etki, finansal araçların trendlerinde ani değişimler meydana getirmektedir. Trendlerde meydana gelen bu değişimler finansal verilerin kullanılmasıyla oluşturulan modeller ile doğru tahminlerin elde edilmesini mümkün kılmamaktadır. Siyasi gerginliklerin bulunmadığı durumlarda, finansal ve metinsel verilerin birlikte kullanılmasıyla oluşturulan modelin tahmin değerleri daha başarılı sonuçlar vermiştir. Siyasi gerginliklerin olduğu dönemlerde ise, metinsel verilerle oluşturulan modelin daha başarılı sonuç verdiği gözlemlenmektedir. Bu durum yatırımcıların, siyasi gerginliklerin olduğu dönemlerde yatırım kararlarını finansal göstergelerden daha çok metinsel içeriklere (haber, internet siteleri vb.) göre almayı tercih etmelerinin daha sağlıklı olacağını açıklamaktadır. Kapanış değerlerinin oluşturduğu trendi tahmin etmede bütün veri setleri oldukça başarılı performans göstermektedir. Bu durum trend tahmininde bulunmak için siyasi gerginliklerin mevcut olup olmasının bir önemi olmadığını göstermektedir.

4. TARTIŞMA VE SONUÇ

Bu çalışmada, derin öğrenme teknikleri kullanılarak Türkiye’de faaliyette bulunan bankaların Borsa İstanbul bünyesinde oluşturduğu endeks olan XBANK endeksinin kapanış değerinin tahmin edilmesi amaçlanmıştır. Bu amaçla 04.11.2015-04.11.2019 tarihleri arasında, 1044 günlük finansal ve metinsel veri ile üç farklı veri seti oluşturulmuştur. Finansal veriler www.investing.com adresinden, metinsel veriler www.investing.com ve www.dunya.com adreslerinden alınmıştır. İlk veri seti, finansal verilerle oluşturulan veri setidir. Bu veri setinde endeksin günlük kapanış, açılış, en yüksek ve en düşük değerleri ile teknik indikatörlerden; William’s %R, MA, RSI, STOCH, MACD, MOM ayrıca, euro ve dolar kuru, Brent petrol ve gram altın fiyatı gibi makro ekonomik veriler ve tüm bu değişkenlerin 10 gecikmeye kadarki değerleri yer almaktadır. Resmî tatil günlerini ifade etmek için kukla (dummy) değişken kullanılmıştır. Finansal verilerle oluşturulan veri setinde 166 değişken bulunmaktadır. İkinci veri seti, metinsel verilerle oluşturulan veri setidir. Bu veri seti için, iki farklı internet sitesi kullanılmıştır. Bu siteler www.investing.com ve www.dunya.com ‘dur. İnternet sitelerinden seçilen tarih aralığında yayınlanan haberlerin başlıkları web kazıma tekniği ile alınmıştır. Alınan veri setine metin madenciliği teknikleri uygulanarak, kelime frekansları elde edilmiş ve iki internet sitesi için frekansı en yüksek olan beş kelime analizde kullanılmak üzere seçilmiştir. Seçilen kelimeler sırasıyla “Erdoğan”, “şehit”, “terörist”, “yaralı”, “operasyon”, “milyar”, “TL”, “faiz”, “dolar”, “TCMB” ‘dir. Bu kelimelerin geçtiği haber başlıklarının sayısı, tarih bazında belirlenmiştir (04.11.2015 tarihinde haber başlıklarının içerisinde şehit kelimesinin geçtiği üç haber başlığı bulunmaktadır vb.). Metinsel verilerle oluşturulan veri setinde 10 değişken bulunmaktadır. Üçüncü veri seti ise, ilk iki veri seti olan finansal ve metinsel verilerin birleştirilmesiyle oluşturulmuştur. Bu veri setinde ise 176 değişken bulunmaktadır.

Veri setinde yer alan değişkenlerin tümü bağımlı değişkenin tahmininde önem arz etmemektedir. Önem arz edeceği düşünülen değişkenlerin saptanması, oluşturulan modeldeki hataları azaltacaktır. Bağımlı değişken olarak ifade edilen XBANK banka endeksinin kapanış değerinin tahmininde önemli olan değişkenlerin tespit edilmesi amacıyla her bir veri setine Boruta algoritması uygulanmıştır. Algoritma sonucunda önemli olarak ifade edilen değişkenler modele dahil edilmiştir.

Modelin tahmini için girdi katmanı, çıktı katmanı, iki dropout katman ve üç gizli katmandan meydana gelen ileri beslemeli derin sinir ağı modeli kullanılmıştır. Sinir ağı modelleri oluşturulurken hiper parametreler kullanılmaktadır. Bu hiper parametreler modelin tahmin gücünü doğrudan etkilemektedir. Bu nedenle, oluşturulan sinir ağında yer alan dört hiper parametrenin en uygun değerlerini bulmak için ızgara arama yöntemi kullanılmıştır. Bu hiper parametreler ilk dropout için oran, ikinci dropout için oran, boyut (batch size) ve döngüdür (epoch). Izgara arama yöntemi sonucunda elde edilen değerler, modelde kullanılacak hiper parametreler olarak belirlenmiştir.

Boruta algoritması sonucunda belirlenen değişkenler ile oluşturulan veri setinin, %70'i eğitim seti, %30'u test seti olarak ayrılmıştır. Uygun değişken ve uygun hiper parametrelerle oluşturulan ileri beslemeli derin sinir ağı eğitim seti ile eğitildikten sonra, test seti ile tahmin değerleri elde edilmiştir. Modelin uyumunu değerlendirmek için, tahmin edilen değerler ile gerçek değerler arasındaki ilişki ile kalıntı değerleri yorumlanmıştır.

Kapanış değerinin tahmin edilmesinde kullanılan ilk veri seti finansal ve metinsel verilerin birleştirilmesiyle oluşturulan birleştirilmiş veri setidir. Bu veri seti ile elde edilen tahmin değerleri gerçek değerler ile karşılaştırıldığında başarılı sonuç elde edilememiştir. Belirli bir tarihe kadar gerçek değerler ile tahmin değerleri birbirine oldukça yakın iken, daha sonra tahmin değerlerinde sapmalar meydana geldiği görülmüştür. İkinci veri seti sadece metinsel verilerin kullanıldığı veri setidir. Bu veri seti kullanılarak elde edilen tahmin değerleri ile gerçek değerler, birleştirilmiş veri setine göre daha başarılı sonuç vermiştir. Gerçek değerlerin oluşturduğu trendi tahmin etmede oldukça başarılı olduğu gözlemlenmiştir. Ancak tahmin hatasının 20 bin ile 40 bin arasında olması banka endeksi için başarılı bir sonuç oluşturmamaktadır. Banka endeksinin kapanış değerindeki değişiminin ortalama %1-%5 arasında olması göz önüne alındığında tahmin hatasının 20 bin ile 40 bin arasında olması yaklaşık %20- %30 arasında bir değişimi işaret edecektir. Bu nedenle, metinsel veri setinin de başarılı sonuç üretmediği gözlemlenmiştir. Son olarak, finansal veri seti ile tahmin değerleri incelendiğinde sonuçların birleştirilmiş veri seti kullanılarak elde edilen sonuçlara oldukça benzer olduğu görülmüştür. Birleştirilmiş veri seti ile elde edilen tahmin değerlerinde olduğu gibi, belirli bir dönemden sonra değerlerde bozulma meydana gelmiştir ve bu bozulmanın neden kaynaklandığının anlaşılması için test setinde ani değişimlerin gözlemlendiği tarih aralığı belirlenmiştir. Bu tarih aralığı Haziran-Aralık 2019'dur. Metinsel veri seti hazırlanırken yararlanılan iki farklı internet sitesinden bu tarih aralığına denk gelen

haberler incelenmiştir. Bu tarih aralığında sınır ötesi operasyonlar, yaptırım kararları ve yerel seçim haberlerinin oldukça yoğun bir gündem oluşturduğu gözlemlenmiştir. Gelişmekte olan piyasalarda siyasi ve ekonomik belirsizliklerin borsa üzerinde yarattığı negatif etki düşünüldüğünde, tahmin hatalarının yüksek olmasının bu haber akışından kaynaklanabileceği sonucuna varılmıştır.

Çalışmanın son kısmında, veri setlerinin tek başına banka endeksini tahmin etmede başarılı sonuç üretmediği gözlemlendiği için, derin öğrenmede kullanılan topluluk öğrenmesi metodundan yola çıkılarak tahmin değerlerinin ortalaması alınıp gerçek değerlerle arasındaki ilişki incelenmiş ve başarılı sonuçlar elde edilmiştir. Ancak tahmin değerlerinin ortalama değerlerini gösteren grafik incelendiğinde, veri setlerinin ilk halleriyle yapılan tahmin sonuçlarındakine benzer olarak Haziran-Aralık 2019 döneminde belirgin bir ayrışma olduğu görülmektedir. Bu ayrışmanın modelin tahmin gücünde neden olduğu olumsuz etkinin gözlemlenebilmesi için veri setlerinin farklı kombinasyonlarıyla Haziran-Aralık 2019 dönemi dahil ve Haziran-Aralık 2019 dönemi hariç olacak şekilde veri setleri düzenlenerek Hata Kareler Ortalamasının Karekökü (RMSE) hesaplanmıştır. Hesaplanan değerler siyasi gerginliklerin ve belirsizliklerin yol açtığı negatif etkinin model performansında önemli bir yere sahip olduğunu göstermektedir. Elde edilen sonuçlar oldukça önemlidir. Siyasi gerginliklerin olduğu dönemlerde, banka endeksine yatırım yapacak yatırımcılar için metinsel verilerden oluşturulmuş model daha başarılı sonuçlar verecektir. Siyasi gerginliklerin yaşanmadığı dönemlerde ise finansal ve metinsel verilerin birlikte oluşturduğu model daha başarılı sonuçlar verecektir.

Derin öğrenme alanında yapılan çalışmaların çoğunda Borsa İstanbul'da işlem gören hisse senetlerinin, çeşitli kripto paraların ya da yurtdışı piyasalarda işlem gören hisse senetlerinin değerleri tahmin edilmiştir. Ayrıca literatürde yer alan çalışmalar daha çok en başarılı tahmini yapacak derin öğrenme modelinin seçimine yoğunlaşmıştır. Bu çalışmada, banka endeksi kullanılmasındaki amaç Türkiye'de en fazla işlem gören endeksler arasında bulunması ve işlem hacminin oldukça yüksek olmasıdır. Ayrıca banka endeksi borsanın genel trendi hakkında fikir vermektedir. Bu nedenle tek bir hisse senedine bağlı kalmak yerine, birden fazla banka hissesinden oluşan banka endeksinin kapanış değerinin tahmin edilmesi amaçlanmıştır. Bu çalışmada modele girdi olarak verilen veri setinde yapılacak iyileştirmenin model başarısını doğrudan etkileyeceği öngörülmüş bu nedenle veri setindeki iyileştirmelere de önem verilmiştir. Bu amaçla, Boruta algoritması ve hiper parametre optimizasyonu

kullanılmıştır. Çalışma, ulusal literatürde Boruta algoritması ve hiper parametre optimizasyonunun birlikte kullanıldığı ilk çalışma olması açısından önem arz etmektedir. Ayrıca siyasi belirsizliklerin yaşandığı ve yaşanmadığı dönemler için kullanılacak veri setleri ve modelleme yaklaşımı hakkında öncü sayılabilecek bir öngörude bulunulmuştur.

Çalışmada kullanılan yöntemlerin gelecekteki çalışmalara öncülük edeceğine ve oluşturulacak derin öğrenme modelinin tahmin gücünde meydana getireceği iyileşme ile literatüre katkı sağlayacağına inanılmaktadır.

5. EKLER

Ek 1. Değişken Açıklamaları

Değişken Adı	Açıklama	Değişken Adı	Açıklama
dummy	resmi tatillerde 1, işlem günlerinde 0	acilis	XUBANK endeksinin açılış değeri
kapanis	XUBANK endeksinin kapanış değeri	acilis1	açılış değerinin 1 gecikmeli değeri
kapanis1	kapanış değerinin 1 gecikmeli değeri	acilis2	açılış değerinin 2 gecikmeli değeri
kapanis2	kapanış değerinin 2 gecikmeli değeri	acilis3	açılış değerinin 3 gecikmeli değeri
kapanis3	kapanış değerinin 3 gecikmeli değeri	acilis4	açılış değerinin 4 gecikmeli değeri
kapanis4	kapanış değerinin 4 gecikmeli değeri	acilis5	açılış değerinin 5 gecikmeli değeri
kapanis5	kapanış değerinin 5 gecikmeli değeri	acilis6	açılış değerinin 6 gecikmeli değeri
kapanis6	kapanış değerinin 6 gecikmeli değeri	acilis7	açılış değerinin 7 gecikmeli değeri
kapanis7	kapanış değerinin 7 gecikmeli değeri	acilis8	açılış değerinin 8 gecikmeli değeri
kapanis8	kapanış değerinin 8 gecikmeli değeri	acilis9	açılış değerinin 9 gecikmeli değeri
kapanis9	kapanış değerinin 9 gecikmeli değeri	acilis10	açılış değerinin 10 gecikmeli değeri
kapanis10	kapanış değerinin 10 gecikmeli değeri	dusuk	XUBANK endeksinin en düşük değeri
yukse	XUBANK endeksinin en yüksek değeri	dusuk1	en düşük değer 1 gecikmeli değeri
yukse1	en yüksek değer 1 gecikmeli değeri	dusuk2	en düşük değer 2 gecikmeli değeri
yukse2	en yüksek değer 2 gecikmeli değeri	dusuk3	en düşük değer 3 gecikmeli değeri
yukse3	en yüksek değer 3 gecikmeli değeri	dusuk4	en düşük değer 4 gecikmeli değeri
yukse4	en yüksek değer 4 gecikmeli değeri	dusuk5	en düşük değer 5 gecikmeli değeri

yukse5	en yüksek deęerin 5 gecikmeli deęeri	dusuk6	en düşük deęerin 6 gecikmeli deęeri
yukse6	en yüksek deęerin 6 gecikmeli deęeri	dusuk7	en düşük deęerin 7 gecikmeli deęeri
yukse7	en yüksek deęerin 7 gecikmeli deęeri	dusuk8	en düşük deęerin 8 gecikmeli deęeri
yukse8	en yüksek deęerin 8 gecikmeli deęeri	dusuk9	en düşük deęerin 9 gecikmeli deęeri
yukse9	en yüksek deęerin 9 gecikmeli deęeri	dusuk10	en düşük deęerin 10 gecikmeli deęeri
yukse10	en yüksek deęerin 10 gecikmeli deęeri	k	XUBANK endeksinin hesaplanmış Stokastik K deęeri
rsi	XUBANK endeksinin hesaplanmış RSI deęeri	k1	K deęerinin 1 gecikmeli deęeri
rsi1	RSI deęerinin 1 gecikmeli deęeri	k2	K deęerinin 2 gecikmeli deęeri
rsi2	RSI deęerinin 2 gecikmeli deęeri	k3	K deęerinin 3 gecikmeli deęeri
rsi3	RSI deęerinin 3 gecikmeli deęeri	k4	K deęerinin 4 gecikmeli deęeri
rsi4	RSI deęerinin 4 gecikmeli deęeri	k5	K deęerinin 5 gecikmeli deęeri
rsi5	RSI deęerinin 5 gecikmeli deęeri	k6	K deęerinin 6 gecikmeli deęeri
rsi6	RSI deęerinin 6 gecikmeli deęeri	k7	K deęerinin 7 gecikmeli deęeri
rsi7	RSI deęerinin 7 gecikmeli deęeri	k8	K deęerinin 8 gecikmeli deęeri
rsi8	RSI deęerinin 8 gecikmeli deęeri	k9	K deęerinin 9 gecikmeli deęeri
rsi9	RSI deęerinin 9 gecikmeli deęeri	k10	K deęerinin 10 gecikmeli deęeri
rsi10	RSI deęerinin 10 gecikmeli deęeri	d	XUBANK endeksinin hesaplanmış Stokastik D deęeri
macd	XUBANK endeksinin hesaplanmış MACD deęeri	d1	D deęerinin 1 gecikmeli deęeri

macd1	MACD değerinin 1 gecikmeli değeri	d2	D değerinin 2 gecikmeli değeri
macd2	MACD değerinin 2 gecikmeli değeri	d3	D değerinin 3 gecikmeli değeri
macd3	MACD değerinin 3 gecikmeli değeri	d4	D değerinin 4 gecikmeli değeri
macd4	MACD değerinin 4 gecikmeli değeri	d5	D değerinin 5 gecikmeli değeri
macd5	MACD değerinin 5 gecikmeli değeri	d6	D değerinin 6 gecikmeli değeri
macd6	MACD değerinin 6 gecikmeli değeri	d7	D değerinin 7 gecikmeli değeri
macd7	MACD değerinin 7 gecikmeli değeri	d8	D değerinin 8 gecikmeli değeri
macd8	MACD değerinin 8 gecikmeli değeri	d9	D değerinin 9 gecikmeli değeri
macd9	MACD değerinin 9 gecikmeli değeri	d10	D değerinin 10 gecikmeli değeri
macd10	MACD değerinin 10 gecikmeli değeri	basithareketli	XUBANK endeksinin hesaplanmış basit hareketli ortalaması
momentum	XUBANK endeksinin hesaplanmış Momentum değeri	basithareketli1	Basit hareketli ortalamasının 1 gecikmeli değeri
momentum1	Momentum değerinin 1 gecikmeli değeri	basithareketli2	Basit hareketli ortalamasının 2 gecikmeli değeri
momentum2	Momentum değerinin 2 gecikmeli değeri	basithareketli3	Basit hareketli ortalamasının 3 gecikmeli değeri
momentum3	Momentum değerinin 3 gecikmeli değeri	basithareketli4	Basit hareketli ortalamasının 4 gecikmeli değeri
momentum4	Momentum değerinin 4 gecikmeli değeri	basithareketli5	Basit hareketli ortalamasının 5 gecikmeli değeri
momentum5	Momentum değerinin 5 gecikmeli değeri	basithareketli6	Basit hareketli ortalamasının 6 gecikmeli değeri
momentum6	Momentum değerinin 6 gecikmeli değeri	basithareketli7	Basit hareketli ortalamasının 7 gecikmeli değeri
momentum7	Momentum değerinin 7 gecikmeli değeri	basithareketli8	Basit hareketli ortalamasının 8 gecikmeli değeri
momentum8	Momentum değerinin 8 gecikmeli değeri	basithareketli9	Basit hareketli ortalamasının 9 gecikmeli değeri

momentum9	Momentum değerinin 9 gecikmeli değeri	basithareketli10	Basit hareketli ortalamanın 10 gecikmeli değeri
momentum10	Momentum değerinin 10 gecikmeli değeri	dolar	Dolar fiyatı
william	XUBANK endeksinin hesaplanmış William değeri	dolar1	Dolar fiyatının 1 gecikmeli değeri
william1	William değerinin 1 gecikmeli değeri	dolar2	Dolar fiyatının 2 gecikmeli değeri
william2	William değerinin 2 gecikmeli değeri	dolar3	Dolar fiyatının 3 gecikmeli değeri
william3	William değerinin 3 gecikmeli değeri	dolar4	Dolar fiyatının 4 gecikmeli değeri
william4	William değerinin 4 gecikmeli değeri	dolar5	Dolar fiyatının 5 gecikmeli değeri
william5	William değerinin 5 gecikmeli değeri	dolar6	Dolar fiyatının 6 gecikmeli değeri
william6	William değerinin 6 gecikmeli değeri	dolar7	Dolar fiyatının 7 gecikmeli değeri
william7	William değerinin 7 gecikmeli değeri	dolar8	Dolar fiyatının 8 gecikmeli değeri
william8	William değerinin 8 gecikmeli değeri	dolar9	Dolar fiyatının 9 gecikmeli değeri
william9	William değerinin 9 gecikmeli değeri	dolar10	Dolar fiyatının 10 gecikmeli değeri
william10	William değerinin 10 gecikmeli değeri	euro	Euro fiyatı
brent	Brent Petrol fiyatı	euro1	Euro fiyatının 1 gecikmeli değeri
brent1	Brent Petrol fiyatının 1 gecikmeli değeri	euro2	Euro fiyatının 2 gecikmeli değeri
brent2	Brent Petrol fiyatının 2 gecikmeli değeri	euro3	Euro fiyatının 3 gecikmeli değeri
brent3	Brent Petrol fiyatının 3 gecikmeli değeri	euro4	Euro fiyatının 4 gecikmeli değeri
brent4	Brent Petrol fiyatının 4 gecikmeli değeri	euro5	Euro fiyatının 5 gecikmeli değeri
brent5	Brent Petrol fiyatının 5 gecikmeli değeri	euro6	Euro fiyatının 6 gecikmeli değeri

brent6	Brent Petrol fiyatının 6 gecikmeli değeri	euro7	Euro fiyatının 7 gecikmeli değeri
brent7	Brent Petrol fiyatının 7 gecikmeli değeri	euro8	Euro fiyatının 8 gecikmeli değeri
brent8	Brent Petrol fiyatının 8 gecikmeli değeri	euro9	Euro fiyatının 9 gecikmeli değeri
brent9	Brent Petrol fiyatının 9 gecikmeli değeri	euro10	Euro fiyatının 10 gecikmeli değeri
brent10	Brent Petrol fiyatının 10 gecikmeli değeri	erdogan_title	İçerisinde Erdoğan kelimesi geçen haberler
altin	Altın fiyatı	operasyon_title	İçerisinde operasyon kelimesi geçen haberler
altin1	Altın fiyatının 1 gecikmeli değeri	sehit_title	İçerisinde şehit kelimesi geçen haberler
altin2	Altın fiyatının 2 gecikmeli değeri	yarali_title	İçerisinde yaralı kelimesi geçen haberler
altin3	Altın fiyatının 3 gecikmeli değeri	terorist_title	İçerisinde terörist kelimesi geçen haberler
altin4	Altın fiyatının 4 gecikmeli değeri	milyar_title	İçerisinde milyar kelimesi geçen haberler
altin5	Altın fiyatının 5 gecikmeli değeri	dolar_title	İçerisinde dolar kelimesi geçen haberler
altin6	Altın fiyatının 6 gecikmeli değeri	faiz_title	İçerisinde faiz kelimesi geçen haberler
altin7	Altın fiyatının 7 gecikmeli değeri	tcmb_title	İçerisinde TCMB kelimesi geçen haberler
altin8	Altın fiyatının 8 gecikmeli değeri	tl_title	İçerisinde TL kelimesi geçen haberler
altin9	Altın fiyatının 9 gecikmeli değeri		
altin10	Altın fiyatının 10 gecikmeli değeri		

Ek 2. Izgara Arama Yöntemi Analiz Sonuçları

Hata Kareler Ortalama	Dropout	Dropout2	Batch	Epoch
8.176E+09	0.4	0.4	2	50
1.011E+10	0.4	0.4	2	100
1.167E+10	0.4	0.4	2	20
1.186E+10	0.4	0.4	2	30
1.252E+10	0.4	0.4	4	100
1.253E+10	0.4	0.4	4	100
1.256E+10	0.4	0.4	2	30
1.275E+10	0.4	0.6	4	100
1.276E+10	0.6	0.4	2	50
1.279E+10	0.4	0.6	2	100
1.284E+10	0.4	0.4	4	50
1.299E+10	0.6	0.4	2	100
1.302E+10	0.4	0.6	8	100
1.309E+10	0.4	0.4	4	20
1.314E+10	0.6	0.4	8	100
1.317E+10	0.4	0.6	2	50
1.325E+10	0.4	0.4	2	50
1.336E+10	0.4	0.4	2	100
1.343E+10	0.6	0.4	2	100
1.348E+10	0.4	0.6	2	20
1.349E+10	0.6	0.4	2	100
1.35E+10	0.4	0.4	2	20
1.358E+10	0.4	0.6	2	50
1.361E+10	0.6	0.6	2	100
1.362E+10	0.4	0.4	4	30
1.366E+10	0.6	0.4	4	100
1.369E+10	0.6	0.4	2	50
1.372E+10	0.6	0.4	2	30
1.372E+10	0.4	0.4	4	30

1.373E+10	0.6	0.4	4	100
1.375E+10	0.6	0.6	2	100
1.375E+10	0.6	0.6	4	50
1.381E+10	0.6	0.6	2	50
1.384E+10	0.4	0.6	4	30
1.385E+10	0.4	0.6	4	100
1.391E+10	0.6	0.4	2	30
1.392E+10	0.4	0.4	8	100
1.398E+10	0.4	0.6	8	30
1.398E+10	0.4	0.6	2	20
1.4E+10	0.4	0.6	4	50
1.404E+10	0.6	0.6	8	50
1.407E+10	0.4	0.4	4	50
1.408E+10	0.4	0.6	2	100
1.409E+10	0.6	0.6	2	20
1.412E+10	0.4	0.6	2	30
1.415E+10	0.4	0.4	8	50
1.416E+10	0.4	0.4	2	50
1.418E+10	0.6	0.6	8	100
1.429E+10	0.6	0.4	2	50
1.429E+10	0.6	0.6	4	100
1.432E+10	0.4	0.4	4	20
1.433E+10	0.4	0.4	4	30
1.433E+10	0.6	0.6	4	20
1.439E+10	0.6	0.4	2	20
1.441E+10	0.4	0.6	2	30
1.441E+10	0.4	0.6	4	50
1.449E+10	0.4	0.4	2	100
1.45E+10	0.6	0.6	4	100
1.451E+10	0.6	0.4	4	100
1.452E+10	0.4	0.6	2	100

1.453E+10	0.6	0.6	2	30
1.454E+10	0.4	0.6	4	100
1.455E+10	0.6	0.4	4	50
1.463E+10	0.6	0.4	4	50
1.464E+10	0.6	0.6	2	50
1.467E+10	0.6	0.6	4	30
1.468E+10	0.4	0.4	2	20
1.47E+10	0.6	0.4	8	50
1.471E+10	0.6	0.6	4	100
1.476E+10	0.6	0.6	2	20
1.48E+10	0.6	0.4	4	30
1.483E+10	0.4	0.6	2	50
1.487E+10	0.4	0.4	4	20
1.487E+10	0.4	0.4	8	100
1.49E+10	0.6	0.4	4	30
1.49E+10	0.4	0.4	4	50
1.492E+10	0.6	0.6	2	100
1.493E+10	0.6	0.4	8	30
1.493E+10	0.4	0.6	4	30
1.493E+10	0.6	0.6	4	50
1.496E+10	0.6	0.4	2	30
1.498E+10	0.4	0.6	4	50
1.498E+10	0.4	0.6	2	20
1.5E+10	0.4	0.6	8	50
1.5E+10	0.6	0.6	4	30
1.5E+10	0.6	0.4	4	50
1.504E+10	0.6	0.6	2	30
1.505E+10	0.4	0.4	8	50
1.507E+10	0.4	0.4	8	30
1.508E+10	0.4	0.4	8	100

1.51E+10	0.6	0.6	8	100
1.515E+10	0.4	0.4	2	30
1.516E+10	0.4	0.4	8	50
1.517E+10	0.4	0.4	4	100
1.517E+10	0.6	0.4	4	20
1.52E+10	0.6	0.6	8	30
1.527E+10	0.6	0.6	8	50
1.535E+10	0.6	0.6	2	50
1.539E+10	0.4	0.6	8	50
1.542E+10	0.4	0.6	8	50
1.544E+10	0.4	0.6	8	100
1.547E+10	0.4	0.6	4	30
1.547E+10	0.6	0.4	4	30
1.551E+10	0.6	0.4	2	20
1.553E+10	0.6	0.4	8	100
1.553E+10	0.6	0.6	4	20
1.554E+10	0.4	0.6	4	20
1.554E+10	0.4	0.6	4	20
1.556E+10	0.6	0.4	8	30
1.561E+10	0.6	0.6	4	30
1.568E+10	0.6	0.4	8	50
1.571E+10	0.4	0.6	8	100
1.582E+10	0.6	0.6	2	30
1.583E+10	0.6	0.6	8	100
1.588E+10	0.6	0.6	2	20
1.593E+10	0.4	0.6	8	30
1.595E+10	0.6	0.4	8	100
1.595E+10	0.6	0.4	8	30
1.599E+10	0.6	0.4	8	50
1.599E+10	0.6	0.4	2	20

1.615E+10	0.6	0.6	8	50
1.62E+10	0.6	0.6	8	30
1.635E+10	0.6	0.6	4	50
1.637E+10	0.6	0.4	4	20
1.65E+10	0.4	0.4	8	30
1.651E+10	0.4	0.4	8	30
1.653E+10	0.4	0.4	8	20
1.663E+10	0.4	0.4	8	20
1.671E+10	0.6	0.6	8	30
1.671E+10	0.6	0.4	8	20
1.672E+10	0.6	0.6	8	20
1.689E+10	0.4	0.6	8	20
1.704E+10	0.6	0.6	4	20
1.732E+10	0.6	0.4	4	20
1.736E+10	0.6	0.4	8	20
1.741E+10	0.4	0.6	8	30
1.743E+10	0.6	0.6	8	20
1.759E+10	0.4	0.6	4	20
1.762E+10	0.4	0.6	8	20
1.764E+10	0.6	0.4	8	20
1.764E+10	0.4	0.6	8	20
1.773E+10	0.4	0.6	2	30
1.78E+10	0.6	0.6	8	20
1.789E+10	0.4	0.4	8	20

Ek 3. Örnek Veri Seti

tarih	dummy	kapanis	kapanis1	kapanis2	kapanis3	kapanis4	kapanis5	kapanis6	kapanis7	kapanis8	kapanis9	kapanis10
04.11.2015	1	141185,63	139563,75	141581,56	129464,96	127339,83	127339,83	127628,65	128321,64	130880,68	131008,3	129863,57
05.11.2015	1	138684,42	141185,63	139563,75	141581,56	129464,96	127339,83	127339,83	127628,65	128321,64	130880,68	131008,30
06.11.2015	1	136734,31	138684,42	141185,63	139563,75	141581,56	129464,96	127339,83	127339,83	127628,65	128321,64	130880,68
09.11.2015	1	136527,52	136734,31	138684,42	141185,63	139563,75	141581,56	129464,96	127339,83	127339,83	127628,65	128321,64
10.11.2015	1	135675,2	136527,52	136734,31	138684,42	141185,63	139563,75	141581,56	129464,96	127339,83	127339,83	127628,65
11.11.2015	1	137043,13	135675,2	136527,52	136734,31	138684,42	141185,63	139563,75	141581,56	129464,96	127339,83	127339,83
12.11.2015	1	137873,13	137043,13	135675,2	136527,52	136734,31	138684,42	141185,63	139563,75	141581,56	129464,96	127339,83
13.11.2015	1	137596,86	137873,13	137043,13	135675,2	136527,52	136734,31	138684,42	141185,63	139563,75	141581,56	129464,96
16.11.2015	1	136195,13	137596,86	137873,13	137043,13	135675,2	136527,52	136734,31	138684,42	141185,63	139563,75	141581,56
17.11.2015	1	136512,5	136195,13	137596,86	137873,13	137043,13	135675,2	136527,52	136734,31	138684,42	141185,63	139563,75
18.11.2015	1	134908,42	136512,5	136195,13	137596,86	137873,13	137043,13	135675,2	136527,52	136734,31	138684,42	141185,63
19.11.2015	1	134516,84	134908,42	136512,5	136195,13	137596,86	137873,13	137043,13	135675,2	136527,52	136734,31	138684,42
20.11.2015	1	134874,05	134516,84	134908,42	136512,5	136195,13	137596,86	137873,13	137043,13	135675,2	136527,52	136734,31
23.11.2015	1	132239,78	134874,05	134516,84	134908,42	136512,5	136195,13	137596,86	137873,13	137043,13	135675,2	136527,52
24.11.2015	1	126397,06	132239,78	134874,05	134516,84	134908,42	136512,5	136195,13	137596,86	137873,13	137043,13	135675,20
25.11.2015	1	127012,03	126397,06	132239,78	134874,05	134516,84	134908,42	136512,5	136195,13	137596,86	137873,13	137043,13
26.11.2015	1	122378,45	127012,03	126397,06	132239,78	134874,05	134516,84	134908,42	136512,5	136195,13	137596,86	137873,13
27.11.2015	1	124045,52	122378,45	127012,03	126397,06	132239,78	134874,05	134516,84	134908,42	136512,5	136195,13	137596,86
30.11.2015	1	123642,42	124045,52	122378,45	127012,03	126397,06	132239,78	134874,05	134516,84	134908,42	136512,5	136195,13
01.12.2015	1	127484,74	123642,42	124045,52	122378,45	127012,03	126397,06	132239,78	134874,05	134516,84	134908,42	136512,50
02.12.2015	1	127003,86	127484,74	123642,42	124045,52	122378,45	127012,03	126397,06	132239,78	134874,05	134516,84	134908,42
03.12.2015	1	125137,88	127003,86	127484,74	123642,42	124045,52	122378,45	127012,03	126397,06	132239,78	134874,05	134516,84

acilis	acilis1	acilis2	acilis3	acilis4	acilis5	acilis6	acilis7	acilis8	acilis9	acilis10
140250,08	141849,02	140145,52	126807,23	127719,93	127719,93	128213,02	131088,97	132244,13	130019,60	131226,06
140151,63	140250,08	141849,02	140145,52	126807,23	127719,93	127719,93	128213,02	131088,97	132244,13	130019,60
138788,20	140151,63	140250,08	141849,02	140145,52	126807,23	127719,93	127719,93	128213,02	131088,97	132244,13
136732,02	138788,20	140151,63	140250,08	141849,02	140145,52	126807,23	127719,93	127719,93	128213,02	131088,97
137267,56	136732,02	138788,20	140151,63	140250,08	141849,02	140145,52	126807,23	127719,93	127719,93	128213,02
136280,42	137267,56	136732,02	138788,20	140151,63	140250,08	141849,02	140145,52	126807,23	127719,93	127719,93
138124,02	136280,42	137267,56	136732,02	138788,20	140151,63	140250,08	141849,02	140145,52	126807,23	127719,93
137642,33	138124,02	136280,42	137267,56	136732,02	138788,20	140151,63	140250,08	141849,02	140145,52	126807,23
136858,02	137642,33	138124,02	136280,42	137267,56	136732,02	138788,20	140151,63	140250,08	141849,02	140145,52
136718,55	136858,02	137642,33	138124,02	136280,42	137267,56	136732,02	138788,20	140151,63	140250,08	141849,02
136233,58	136718,55	136858,02	137642,33	138124,02	136280,42	137267,56	136732,02	138788,20	140151,63	140250,08
135904,03	136233,58	136718,55	136858,02	137642,33	138124,02	136280,42	137267,56	136732,02	138788,20	140151,63
134551,09	135904,03	136233,58	136718,55	136858,02	137642,33	138124,02	136280,42	137267,56	136732,02	138788,20
134765,52	134551,09	135904,03	136233,58	136718,55	136858,02	137642,33	138124,02	136280,42	137267,56	136732,02
132722,59	134765,52	134551,09	135904,03	136233,58	136718,55	136858,02	137642,33	138124,02	136280,42	137267,56
127592,59	132722,59	134765,52	134551,09	135904,03	136233,58	136718,55	136858,02	137642,33	138124,02	136280,42
126515,78	127592,59	132722,59	134765,52	134551,09	135904,03	136233,58	136718,55	136858,02	137642,33	138124,02
122081,81	126515,78	127592,59	132722,59	134765,52	134551,09	135904,03	136233,58	136718,55	136858,02	137642,33
124045,52	122081,81	126515,78	127592,59	132722,59	134765,52	134551,09	135904,03	136233,58	136718,55	136858,02
123642,42	124045,52	122081,81	126515,78	127592,59	132722,59	134765,52	134551,09	135904,03	136233,58	136718,55
127484,74	123642,42	124045,52	122081,81	126515,78	127592,59	132722,59	134765,52	134551,09	135904,03	136233,58
127003,86	127484,74	123642,42	124045,52	122081,81	126515,78	127592,59	132722,59	134765,52	134551,09	135904,03
125137,88	127003,86	127484,74	123642,42	124045,52	122081,81	126515,78	127592,59	132722,59	134765,52	134551,09
123630,66	125137,88	127003,86	127484,74	123642,42	124045,52	122081,81	126515,78	127592,59	132722,59	134765,52

yukse	yukse1	yukse2	yukse3	yukse4	yukse5	yukse6	yukse7	yukse8	yukse9	yukse10
141674,66	142376,45	141928,72	129520,38	128001,76	128001,76	128550,71	131654,45	132892,66	131440,97	131627,80
140406,44	141674,66	142376,45	141928,72	129520,38	128001,76	128001,76	128550,71	131654,45	132892,66	131440,97
138973,75	140406,44	141674,66	142376,45	141928,72	129520,38	128001,76	128001,76	128550,71	131654,45	132892,66
138117,34	138973,75	140406,44	141674,66	142376,45	141928,72	129520,38	128001,76	128001,76	128550,71	131654,45
138037,73	138117,34	138973,75	140406,44	141674,66	142376,45	141928,72	129520,38	128001,76	128001,76	128550,71
138477,77	138037,73	138117,34	138973,75	140406,44	141674,66	142376,45	141928,72	129520,38	128001,76	128001,76
138293,02	138477,77	138037,73	138117,34	138973,75	140406,44	141674,66	142376,45	141928,72	129520,38	128001,76
138319,52	138293,02	138477,77	138037,73	138117,34	138973,75	140406,44	141674,66	142376,45	141928,72	129520,38
137411,91	138319,52	138293,02	138477,77	138037,73	138117,34	138973,75	140406,44	141674,66	142376,45	141928,72
137902,31	137411,91	138319,52	138293,02	138477,77	138037,73	138117,34	138973,75	140406,44	141674,66	142376,45
137105,38	137902,31	137411,91	138319,52	138293,02	138477,77	138037,73	138117,34	138973,75	140406,44	141674,66
136372,91	137105,38	137902,31	137411,91	138319,52	138293,02	138477,77	138037,73	138117,34	138973,75	140406,44
136014,17	136372,91	137105,38	137902,31	137411,91	138319,52	138293,02	138477,77	138037,73	138117,34	138973,75
134867,94	136014,17	136372,91	137105,38	137902,31	137411,91	138319,52	138293,02	138477,77	138037,73	138117,34
133142,84	134867,94	136014,17	136372,91	137105,38	137902,31	137411,91	138319,52	138293,02	138477,77	138037,73
127955,29	133142,84	134867,94	136014,17	136372,91	137105,38	137902,31	137411,91	138319,52	138293,02	138477,77
126958,72	127955,29	133142,84	134867,94	136014,17	136372,91	137105,38	137902,31	137411,91	138319,52	138293,02
126287,62	126958,72	127955,29	133142,84	134867,94	136014,17	136372,91	137105,38	137902,31	137411,91	138319,52
125702,33	126287,62	126958,72	127955,29	133142,84	134867,94	136014,17	136372,91	137105,38	137902,31	137411,91
127524,55	125702,33	126287,62	126958,72	127955,29	133142,84	134867,94	136014,17	136372,91	137105,38	137902,31
129499,73	127524,55	125702,33	126287,62	126958,72	127955,29	133142,84	134867,94	136014,17	136372,91	137105,38
128554,85	129499,73	127524,55	125702,33	126287,62	126958,72	127955,29	133142,84	134867,94	136014,17	136372,91
126214,29	128554,85	129499,73	127524,55	125702,33	126287,62	126958,72	127955,29	133142,84	134867,94	136014,17
124636,88	126214,29	128554,85	129499,73	127524,55	125702,33	126287,62	126958,72	127955,29	133142,84	134867,94

dusuk	dusuk1	dusuk2	dusuk3	dusuk4	dusuk5	dusuk6	dusuk7	dusuk8	dusuk9	dusuk10
140250,08	139563,75	138428,36	125703,95	126577,04	126577,04	126652,94	128233,87	130703,31	129816,92	129020,84
138406,61	140250,08	139563,75	138428,36	125703,95	126577,04	126577,04	126652,94	128233,87	130703,31	129816,92
136202,59	138406,61	140250,08	139563,75	138428,36	125703,95	126577,04	126577,04	126652,94	128233,87	130703,31
136078,39	136202,59	138406,61	140250,08	139563,75	138428,36	125703,95	126577,04	126577,04	126652,94	128233,87
135406,19	136078,39	136202,59	138406,61	140250,08	139563,75	138428,36	125703,95	126577,04	126577,04	126652,94
136280,42	135406,19	136078,39	136202,59	138406,61	140250,08	139563,75	138428,36	125703,95	126577,04	126577,04
136326,58	136280,42	135406,19	136078,39	136202,59	138406,61	140250,08	139563,75	138428,36	125703,95	126577,04
136810,31	136326,58	136280,42	135406,19	136078,39	136202,59	138406,61	140250,08	139563,75	138428,36	125703,95
136097,27	136810,31	136326,58	136280,42	135406,19	136078,39	136202,59	138406,61	140250,08	139563,75	138428,36
136505,14	136097,27	136810,31	136326,58	136280,42	135406,19	136078,39	136202,59	138406,61	140250,08	139563,75
134624,00	136505,14	136097,27	136810,31	136326,58	136280,42	135406,19	136078,39	136202,59	138406,61	140250,08
134100,19	134624,00	136505,14	136097,27	136810,31	136326,58	136280,42	135406,19	136078,39	136202,59	138406,61
134274,98	134100,19	134624,00	136505,14	136097,27	136810,31	136326,58	136280,42	135406,19	136078,39	136202,59
132239,78	134274,98	134100,19	134624,00	136505,14	136097,27	136810,31	136326,58	136280,42	135406,19	136078,39
125770,80	132239,78	134274,98	134100,19	134624,00	136505,14	136097,27	136810,31	136326,58	136280,42	135406,19
125890,62	125770,80	132239,78	134274,98	134100,19	134624,00	136505,14	136097,27	136810,31	136326,58	136280,42
122378,45	125890,62	125770,80	132239,78	134274,98	134100,19	134624,00	136505,14	136097,27	136810,31	136326,58
122081,81	122378,45	125890,62	125770,80	132239,78	134274,98	134100,19	134624,00	136505,14	136097,27	136810,31
123463,84	122081,81	122378,45	125890,62	125770,80	132239,78	134274,98	134100,19	134624,00	136505,14	136097,27
123642,42	123463,84	122081,81	122378,45	125890,62	125770,80	132239,78	134274,98	134100,19	134624,00	136505,14
126506,63	123642,42	123463,84	122081,81	122378,45	125890,62	125770,80	132239,78	134274,98	134100,19	134624,00
124966,32	126506,63	123642,42	123463,84	122081,81	122378,45	125890,62	125770,80	132239,78	134274,98	134100,19
121853,31	124966,32	126506,63	123642,42	123463,84	122081,81	122378,45	125890,62	125770,80	132239,78	134274,98
122105,27	121853,31	124966,32	126506,63	123642,42	123463,84	122081,81	122378,45	125890,62	125770,80	132239,78

rsi	rsi1	rsi2	rsi3	rsi4	rsi5	rsi6	rsi7	rsi8	rsi9	rsi10
69,26	67,59	72,12	55,52	50,74	50,74	51,44	53,06	59,50	59,84	57,85
63,80	69,26	67,59	72,12	55,52	50,74	50,74	51,44	53,06	59,50	59,84
59,85	63,80	69,26	67,59	72,12	55,52	50,74	50,74	51,44	53,06	59,50
59,42	59,85	63,80	69,26	67,59	72,12	55,52	50,74	50,74	51,44	53,06
57,62	59,42	59,85	63,80	69,26	67,59	72,12	55,52	50,74	50,74	51,44
59,73	57,62	59,42	59,85	63,80	69,26	67,59	72,12	55,52	50,74	50,74
61,00	59,73	57,62	59,42	59,85	63,80	69,26	67,59	72,12	55,52	50,74
60,32	61,00	59,73	57,62	59,42	59,85	63,80	69,26	67,59	72,12	55,52
56,85	60,32	61,00	59,73	57,62	59,42	59,85	63,80	69,26	67,59	72,12
57,45	56,85	60,32	61,00	59,73	57,62	59,42	59,85	63,80	69,26	67,59
53,43	57,45	56,85	60,32	61,00	59,73	57,62	59,42	59,85	63,80	69,26
52,46	53,43	57,45	56,85	60,32	61,00	59,73	57,62	59,42	59,85	63,80
53,29	52,46	53,43	57,45	56,85	60,32	61,00	59,73	57,62	59,42	59,85
46,81	53,29	52,46	53,43	57,45	56,85	60,32	61,00	59,73	57,62	59,42
36,28	46,81	53,29	52,46	53,43	57,45	56,85	60,32	61,00	59,73	57,62
37,86	36,28	46,81	53,29	52,46	53,43	57,45	56,85	60,32	61,00	59,73
31,50	37,86	36,28	46,81	53,29	52,46	53,43	57,45	56,85	60,32	61,00
35,69	31,50	37,86	36,28	46,81	53,29	52,46	53,43	57,45	56,85	60,32
35,13	35,69	31,50	37,86	36,28	46,81	53,29	52,46	53,43	57,45	56,85
44,11	35,13	35,69	31,50	37,86	36,28	46,81	53,29	52,46	53,43	57,45
43,30	44,11	35,13	35,69	31,50	37,86	36,28	46,81	53,29	52,46	53,43
40,22	43,30	44,11	35,13	35,69	31,50	37,86	36,28	46,81	53,29	52,46
37,88	40,22	43,30	44,11	35,13	35,69	31,50	37,86	36,28	46,81	53,29
37,16	37,88	40,22	43,30	44,11	35,13	35,69	31,50	37,86	36,28	46,81

macd	macd1	macd2	macd3	macd4	macd5	macd6	macd7	macd8	macd9	macd10
3420,60	2911,09	2383,56	1470,12	1516,55	1516,55	1770,12	2038,62	2281,11	2296,88	2270,60
3581,29	3420,60	2911,09	2383,56	1470,12	1516,55	1516,55	1770,12	2038,62	2281,11	2296,88
3510,80	3581,29	3420,60	2911,09	2383,56	1470,12	1516,55	1516,55	1770,12	2038,62	2281,11
3399,07	3510,80	3581,29	3420,60	2911,09	2383,56	1470,12	1516,55	1516,55	1770,12	2038,62
3204,81	3399,07	3510,80	3581,29	3420,60	2911,09	2383,56	1470,12	1516,55	1516,55	1770,12
3125,21	3204,81	3399,07	3510,80	3581,29	3420,60	2911,09	2383,56	1470,12	1516,55	1516,55
3093,44	3125,21	3204,81	3399,07	3510,80	3581,29	3420,60	2911,09	2383,56	1470,12	1516,55
3011,26	3093,44	3125,21	3204,81	3399,07	3510,80	3581,29	3420,60	2911,09	2383,56	1470,12
2800,73	3011,26	3093,44	3125,21	3204,81	3399,07	3510,80	3581,29	3420,60	2911,09	2383,56
2629,19	2800,73	3011,26	3093,44	3125,21	3204,81	3399,07	3510,80	3581,29	3420,60	2911,09
2336,87	2629,19	2800,73	3011,26	3093,44	3125,21	3204,81	3399,07	3510,80	3581,29	3420,60
2049,98	2336,87	2629,19	2800,73	3011,26	3093,44	3125,21	3204,81	3399,07	3510,80	3581,29
1830,34	2049,98	2336,87	2629,19	2800,73	3011,26	3093,44	3125,21	3204,81	3399,07	3510,80
1427,26	1830,34	2049,98	2336,87	2629,19	2800,73	3011,26	3093,44	3125,21	3204,81	3399,07
629,10	1427,26	1830,34	2049,98	2336,87	2629,19	2800,73	3011,26	3093,44	3125,21	3204,81
45,65	629,10	1427,26	1830,34	2049,98	2336,87	2629,19	2800,73	3011,26	3093,44	3125,21
-781,62	45,65	629,10	1427,26	1830,34	2049,98	2336,87	2629,19	2800,73	3011,26	3093,44
-1287,87	-781,62	45,65	629,10	1427,26	1830,34	2049,98	2336,87	2629,19	2800,73	3011,26
-1701,98	-1287,87	-781,62	45,65	629,10	1427,26	1830,34	2049,98	2336,87	2629,19	2800,73
-1700,53	-1701,98	-1287,87	-781,62	45,65	629,10	1427,26	1830,34	2049,98	2336,87	2629,19
-1718,37	-1700,53	-1701,98	-1287,87	-781,62	45,65	629,10	1427,26	1830,34	2049,98	2336,87
-1861,62	-1718,37	-1700,53	-1701,98	-1287,87	-781,62	45,65	629,10	1427,26	1830,34	2049,98
-2072,87	-1861,62	-1718,37	-1700,53	-1701,98	-1287,87	-781,62	45,65	629,10	1427,26	1830,34
-2251,98	-2072,87	-1861,62	-1718,37	-1700,53	-1701,98	-1287,87	-781,62	45,65	629,10	1427,26

k	k1	k2	k3	k4	k5	k6	k7	k8	k9	k10
92,86	83,13	97,86	50,22	11,53	11,53	14,92	31,14	73,40	81,60	76,73
77,86	92,86	83,13	97,86	50,22	11,53	11,53	14,92	31,14	73,40	81,60
66,16	77,86	92,86	83,13	97,86	50,22	11,53	11,53	14,92	31,14	73,40
64,92	66,16	77,86	92,86	83,13	97,86	50,22	11,53	11,53	14,92	31,14
59,81	64,92	66,16	77,86	92,86	83,13	97,86	50,22	11,53	11,53	14,92
68,01	59,81	64,92	66,16	77,86	92,86	83,13	97,86	50,22	11,53	11,53
72,99	68,01	59,81	64,92	66,16	77,86	92,86	83,13	97,86	50,22	11,53
71,33	72,99	68,01	59,81	64,92	66,16	77,86	92,86	83,13	97,86	50,22
62,93	71,33	72,99	68,01	59,81	64,92	66,16	77,86	92,86	83,13	97,86
64,83	62,93	71,33	72,99	68,01	59,81	64,92	66,16	77,86	92,86	83,13
55,21	64,83	62,93	71,33	72,99	68,01	59,81	64,92	66,16	77,86	92,86
5,03	55,21	64,83	62,93	71,33	72,99	68,01	59,81	64,92	66,16	77,86
9,35	5,03	55,21	64,83	62,93	71,33	72,99	68,01	59,81	64,92	66,16
0,00	9,35	5,03	55,21	64,83	62,93	71,33	72,99	68,01	59,81	64,92
4,28	0,00	9,35	5,03	55,21	64,83	62,93	71,33	72,99	68,01	59,81
9,40	4,28	0,00	9,35	5,03	55,21	64,83	62,93	71,33	72,99	68,01
0,00	9,40	4,28	0,00	9,35	5,03	55,21	64,83	62,93	71,33	72,99
11,98	0,00	9,40	4,28	0,00	9,35	5,03	55,21	64,83	62,93	71,33
9,52	11,98	0,00	9,40	4,28	0,00	9,35	5,03	55,21	64,83	62,93
33,27	9,52	11,98	0,00	9,40	4,28	0,00	9,35	5,03	55,21	64,83
30,31	33,27	9,52	11,98	0,00	9,40	4,28	0,00	9,35	5,03	55,21
19,32	30,31	33,27	9,52	11,98	0,00	9,40	4,28	0,00	9,35	5,03
11,07	19,32	30,31	33,27	9,52	11,98	0,00	9,40	4,28	0,00	9,35
8,59	11,07	19,32	30,31	33,27	9,52	11,98	0,00	9,40	4,28	0,00

d	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
91,28	77,07	53,20	25,56	19,20	19,20	39,82	62,04	77,24	81,90	80,57
84,61	91,28	77,07	53,20	25,56	19,20	19,20	39,82	62,04	77,24	81,90
78,96	84,61	91,28	77,07	53,20	25,56	19,20	19,20	39,82	62,04	77,24
69,64	78,96	84,61	91,28	77,07	53,20	25,56	19,20	19,20	39,82	62,04
63,63	69,64	78,96	84,61	91,28	77,07	53,20	25,56	19,20	19,20	39,82
64,25	63,63	69,64	78,96	84,61	91,28	77,07	53,20	25,56	19,20	19,20
66,94	64,25	63,63	69,64	78,96	84,61	91,28	77,07	53,20	25,56	19,20
70,78	66,94	64,25	63,63	69,64	78,96	84,61	91,28	77,07	53,20	25,56
69,08	70,78	66,94	64,25	63,63	69,64	78,96	84,61	91,28	77,07	53,20
66,36	69,08	70,78	66,94	64,25	63,63	69,64	78,96	84,61	91,28	77,07
60,99	66,36	69,08	70,78	66,94	64,25	63,63	69,64	78,96	84,61	91,28
41,69	60,99	66,36	69,08	70,78	66,94	64,25	63,63	69,64	78,96	84,61
23,20	41,69	60,99	66,36	69,08	70,78	66,94	64,25	63,63	69,64	78,96
4,79	23,20	41,69	60,99	66,36	69,08	70,78	66,94	64,25	63,63	69,64
4,54	4,79	23,20	41,69	60,99	66,36	69,08	70,78	66,94	64,25	63,63
4,56	4,54	4,79	23,20	41,69	60,99	66,36	69,08	70,78	66,94	64,25
4,56	4,56	4,54	4,79	23,20	41,69	60,99	66,36	69,08	70,78	66,94
7,13	4,56	4,56	4,54	4,79	23,20	41,69	60,99	66,36	69,08	70,78
7,17	7,13	4,56	4,56	4,54	4,79	23,20	41,69	60,99	66,36	69,08
18,26	7,17	7,13	4,56	4,56	4,54	4,79	23,20	41,69	60,99	66,36
24,37	18,26	7,17	7,13	4,56	4,56	4,54	4,79	23,20	41,69	60,99
27,63	24,37	18,26	7,17	7,13	4,56	4,56	4,54	4,79	23,20	41,69
20,23	27,63	24,37	18,26	7,17	7,13	4,56	4,56	4,54	4,79	23,20
13,00	20,23	27,63	24,37	18,26	7,17	7,13	4,56	4,56	4,54	4,79

momentum	momentum1	momentum2	momentum3	momentum4	momentum5	momentum6	momentum7	momentum 8	momentum 9	momentum 10
9798,07	9583,20	13180,84	-253,73	-3490,73	-3490,73	-210,64	-1914,75	-341,09	1613,52	44,48
8820,85	9798,07	9583,20	13180,84	-253,73	-3490,73	-3490,73	-210,64	-1914,75	-341,09	1613,52
5726,01	8820,85	9798,07	9583,20	13180,84	-253,73	-3490,73	-3490,73	-210,64	-1914,75	-341,09
5646,84	5726,01	8820,85	9798,07	9583,20	13180,84	-253,73	-3490,73	-3490,73	-210,64	-1914,75
7353,56	5646,84	5726,01	8820,85	9798,07	9583,20	13180,84	-253,73	-3490,73	-3490,73	-210,64
9414,48	7353,56	5646,84	5726,01	8820,85	9798,07	9583,20	13180,84	-253,73	-3490,73	-3490,73
10533,30	9414,48	7353,56	5646,84	5726,01	8820,85	9798,07	9583,20	13180,84	-253,73	-3490,73
8131,90	10533,30	9414,48	7353,56	5646,84	5726,01	8820,85	9798,07	9583,20	13180,84	-253,73
-5386,43	8131,90	10533,30	9414,48	7353,56	5646,84	5726,01	8820,85	9798,07	9583,20	13180,84
-3051,25	-5386,43	8131,90	10533,30	9414,48	7353,56	5646,84	5726,01	8820,85	9798,07	9583,20
-6277,21	-3051,25	-5386,43	8131,90	10533,30	9414,48	7353,56	5646,84	5726,01	8820,85	9798,07
-4167,58	-6277,21	-3051,25	-5386,43	8131,90	10533,30	9414,48	7353,56	5646,84	5726,01	8820,85
-1860,26	-4167,58	-6277,21	-3051,25	-5386,43	8131,90	10533,30	9414,48	7353,56	5646,84	5726,01
-4287,74	-1860,26	-4167,58	-6277,21	-3051,25	-5386,43	8131,90	10533,30	9414,48	7353,56	5646,84
-9278,14	-4287,74	-1860,26	-4167,58	-6277,21	-3051,25	-5386,43	8131,90	10533,30	9414,48	7353,56
-10031,10	-9278,14	-4287,74	-1860,26	-4167,58	-6277,21	-3051,25	-5386,43	8131,90	10533,30	9414,48
-15494,68	-10031,10	-9278,14	-4287,74	-1860,26	-4167,58	-6277,21	-3051,25	-5386,43	8131,90	10533,30
-13551,34	-15494,68	-10031,10	-9278,14	-4287,74	-1860,26	-4167,58	-6277,21	-3051,25	-5386,43	8131,90
-12552,71	-13551,34	-15494,68	-10031,10	-9278,14	-4287,74	-1860,26	-4167,58	-6277,21	-3051,25	-5386,43
-9027,76	-12552,71	-13551,34	-15494,68	-10031,10	-9278,14	-4287,74	-1860,26	-4167,58	-6277,21	-3051,25
-7904,56	-9027,76	-12552,71	-13551,34	-15494,68	-10031,10	-9278,14	-4287,74	-1860,26	-4167,58	-6277,21
-9378,96	-7904,56	-9027,76	-12552,71	-13551,34	-15494,68	-10031,10	-9278,14	-4287,74	-1860,26	-4167,58
-11243,39	-9378,96	-7904,56	-9027,76	-12552,71	-13551,34	-15494,68	-10031,10	-9278,14	-4287,74	-1860,26
-9075,74	-11243,39	-9378,96	-7904,56	-9027,76	-12552,71	-13551,34	-15494,68	-10031,10	-9278,14	-4287,74

william	william1	william2	william3	william4	william5	william6	william7	william8	william9	william10
-7,14	-16,87	-2,14	-49,78	-88,47	-88,47	-85,08	-68,86	-26,60	-18,40	-23,27
-22,14	-7,14	-16,87	-2,14	-49,78	-88,47	-88,47	-85,08	-68,86	-26,60	-18,40
-33,84	-22,14	-7,14	-16,87	-2,14	-49,78	-88,47	-88,47	-85,08	-68,86	-26,60
-35,08	-33,84	-22,14	-7,14	-16,87	-2,14	-49,78	-88,47	-88,47	-85,08	-68,86
-40,19	-35,08	-33,84	-22,14	-7,14	-16,87	-2,14	-49,78	-88,47	-88,47	-85,08
-31,99	-40,19	-35,08	-33,84	-22,14	-7,14	-16,87	-2,14	-49,78	-88,47	-88,47
-27,01	-31,99	-40,19	-35,08	-33,84	-22,14	-7,14	-16,87	-2,14	-49,78	-88,47
-28,67	-27,01	-31,99	-40,19	-35,08	-33,84	-22,14	-7,14	-16,87	-2,14	-49,78
-37,07	-28,67	-27,01	-31,99	-40,19	-35,08	-33,84	-22,14	-7,14	-16,87	-2,14
-35,17	-37,07	-28,67	-27,01	-31,99	-40,19	-35,08	-33,84	-22,14	-7,14	-16,87
-44,79	-35,17	-37,07	-28,67	-27,01	-31,99	-40,19	-35,08	-33,84	-22,14	-7,14
-94,97	-44,79	-35,17	-37,07	-28,67	-27,01	-31,99	-40,19	-35,08	-33,84	-22,14
-90,65	-94,97	-44,79	-35,17	-37,07	-28,67	-27,01	-31,99	-40,19	-35,08	-33,84
-100,00	-90,65	-94,97	-44,79	-35,17	-37,07	-28,67	-27,01	-31,99	-40,19	-35,08
-95,72	-100,00	-90,65	-94,97	-44,79	-35,17	-37,07	-28,67	-27,01	-31,99	-40,19
-90,60	-95,72	-100,00	-90,65	-94,97	-44,79	-35,17	-37,07	-28,67	-27,01	-31,99
-100,00	-90,60	-95,72	-100,00	-90,65	-94,97	-44,79	-35,17	-37,07	-28,67	-27,01
-88,02	-100,00	-90,60	-95,72	-100,00	-90,65	-94,97	-44,79	-35,17	-37,07	-28,67
-90,48	-88,02	-100,00	-90,60	-95,72	-100,00	-90,65	-94,97	-44,79	-35,17	-37,07
-66,73	-90,48	-88,02	-100,00	-90,60	-95,72	-100,00	-90,65	-94,97	-44,79	-35,17
-69,69	-66,73	-90,48	-88,02	-100,00	-90,60	-95,72	-100,00	-90,65	-94,97	-44,79
-80,68	-69,69	-66,73	-90,48	-88,02	-100,00	-90,60	-95,72	-100,00	-90,65	-94,97
-88,93	-80,68	-69,69	-66,73	-90,48	-88,02	-100,00	-90,60	-95,72	-100,00	-90,65
-91,41	-88,93	-80,68	-69,69	-66,73	-90,48	-88,02	-100,00	-90,60	-95,72	-100,00

basithareketli	basithareketli 1	basithareketli2	basithareketli 3	basithareketli4	basithareketli 5	basithareketli6	basithareketli 7	basithareketli 8	basithareketli 9	basithareketli10
132683,86	131704,05	130745,73	129427,65	129453,02	129453,02	129802,09	129823,16	130014,63	130048,74	129887,39
133565,94	132683,86	131704,05	130745,73	129427,65	129453,02	129453,02	129802,09	129823,16	130014,63	130048,74
134138,54	133565,94	132683,86	131704,05	130745,73	129427,65	129453,02	129453,02	129802,09	129823,16	130014,63
134703,23	134138,54	133565,94	132683,86	131704,05	130745,73	129427,65	129453,02	129453,02	129802,09	129823,16
135438,58	134703,23	134138,54	133565,94	132683,86	131704,05	130745,73	129427,65	129453,02	129453,02	129802,09
136380,03	135438,58	134703,23	134138,54	133565,94	132683,86	131704,05	130745,73	129427,65	129453,02	129453,02
137433,36	136380,03	135438,58	134703,23	134138,54	133565,94	132683,86	131704,05	130745,73	129427,65	129453,02
138246,55	137433,36	136380,03	135438,58	134703,23	134138,54	133565,94	132683,86	131704,05	130745,73	129427,65
137707,91	138246,55	137433,36	136380,03	135438,58	134703,23	134138,54	133565,94	132683,86	131704,05	130745,73
137402,78	137707,91	138246,55	137433,36	136380,03	135438,58	134703,23	134138,54	133565,94	132683,86	131704,05
136775,06	137402,78	137707,91	138246,55	137433,36	136380,03	135438,58	134703,23	134138,54	133565,94	132683,86
136358,30	136775,06	137402,78	137707,91	138246,55	137433,36	136380,03	135438,58	134703,23	134138,54	133565,94
136172,28	136358,30	136775,06	137402,78	137707,91	138246,55	137433,36	136380,03	135438,58	134703,23	134138,54
135743,50	136172,28	136358,30	136775,06	137402,78	137707,91	138246,55	137433,36	136380,03	135438,58	134703,23
134815,69	135743,50	136172,28	136358,30	136775,06	137402,78	137707,91	138246,55	137433,36	136380,03	135438,58
133812,58	134815,69	135743,50	136172,28	136358,30	136775,06	137402,78	137707,91	138246,55	137433,36	136380,03
132263,11	133812,58	134815,69	135743,50	136172,28	136358,30	136775,06	137402,78	137707,91	138246,55	137433,36
130907,98	132263,11	133812,58	134815,69	135743,50	136172,28	136358,30	136775,06	137402,78	137707,91	138246,55
129652,71	130907,98	132263,11	133812,58	134815,69	135743,50	136172,28	136358,30	136775,06	137402,78	137707,91
128749,93	129652,71	130907,98	132263,11	133812,58	134815,69	135743,50	136172,28	136358,30	136775,06	137402,78
127959,48	128749,93	129652,71	130907,98	132263,11	133812,58	134815,69	135743,50	136172,28	136358,30	136775,06
127021,58	127959,48	128749,93	129652,71	130907,98	132263,11	133812,58	134815,69	135743,50	136172,28	136358,30
125897,24	127021,58	127959,48	128749,93	129652,71	130907,98	132263,11	133812,58	134815,69	135743,50	136172,28
124989,67	125897,24	127021,58	127959,48	128749,93	129652,71	130907,98	132263,11	133812,58	134815,69	135743,50

dolar	dolar1	dolar2	dolar3	dolar4	dolar5	dolar6	dolar7	dolar8	dolar9	dolar10
2,8631	2,8290	2,8239	2,9151	2,9375	2,9247	2,9041	2,8900	2,9078	2,8726	2,8954
2,8607	2,8631	2,8290	2,8239	2,9151	2,9375	2,9247	2,9041	2,8900	2,9078	2,8726
2,9152	2,8607	2,8631	2,8290	2,8239	2,9151	2,9375	2,9247	2,9041	2,8900	2,9078
2,9207	2,9152	2,8607	2,8631	2,8290	2,8239	2,9151	2,9375	2,9247	2,9041	2,8900
2,9158	2,9207	2,9152	2,8607	2,8631	2,8290	2,8239	2,9151	2,9375	2,9247	2,9041
2,8748	2,9158	2,9207	2,9152	2,8607	2,8631	2,8290	2,8239	2,9151	2,9375	2,9247
2,8651	2,8748	2,9158	2,9207	2,9152	2,8607	2,8631	2,8290	2,8239	2,9151	2,9375
2,8637	2,8651	2,8748	2,9158	2,9207	2,9152	2,8607	2,8631	2,8290	2,8239	2,9151
2,8834	2,8637	2,8651	2,8748	2,9158	2,9207	2,9152	2,8607	2,8631	2,8290	2,8239
2,8691	2,8834	2,8637	2,8651	2,8748	2,9158	2,9207	2,9152	2,8607	2,8631	2,8290
2,8619	2,8691	2,8834	2,8637	2,8651	2,8748	2,9158	2,9207	2,9152	2,8607	2,8631
2,8427	2,8619	2,8691	2,8834	2,8637	2,8651	2,8748	2,9158	2,9207	2,9152	2,8607
2,8317	2,8427	2,8619	2,8691	2,8834	2,8637	2,8651	2,8748	2,9158	2,9207	2,9152
2,8508	2,8317	2,8427	2,8619	2,8691	2,8834	2,8637	2,8651	2,8748	2,9158	2,9207
2,8773	2,8508	2,8317	2,8427	2,8619	2,8691	2,8834	2,8637	2,8651	2,8748	2,9158
2,8884	2,8773	2,8508	2,8317	2,8427	2,8619	2,8691	2,8834	2,8637	2,8651	2,8748
2,9211	2,8884	2,8773	2,8508	2,8317	2,8427	2,8619	2,8691	2,8834	2,8637	2,8651
2,9245	2,9211	2,8884	2,8773	2,8508	2,8317	2,8427	2,8619	2,8691	2,8834	2,8637
2,9131	2,9245	2,9211	2,8884	2,8773	2,8508	2,8317	2,8427	2,8619	2,8691	2,8834
2,8907	2,9131	2,9245	2,9211	2,8884	2,8773	2,8508	2,8317	2,8427	2,8619	2,8691
2,8893	2,8907	2,9131	2,9245	2,9211	2,8884	2,8773	2,8508	2,8317	2,8427	2,8619
2,8846	2,8893	2,8907	2,9131	2,9245	2,9211	2,8884	2,8773	2,8508	2,8317	2,8427
2,8950	2,8846	2,8893	2,8907	2,9131	2,9245	2,9211	2,8884	2,8773	2,8508	2,8317
2,9135	2,8950	2,8846	2,8893	2,8907	2,9131	2,9245	2,9211	2,8884	2,8773	2,8508

brent	brent1	brent2	brent3	brent4	brent5	brent6	brent7	brent8	brent9	brent10
46,96	48,00	47,91	48,00	48,04	47,60	45,54	46,57	46,30	46,59	46,72
47,19	46,96	48,00	47,91	48,00	48,04	47,60	45,54	46,57	46,30	46,59
46,09	47,19	46,96	48,00	47,91	48,00	48,04	47,60	45,54	46,57	46,30
45,38	46,09	47,19	46,96	48,00	47,91	48,00	48,04	47,60	45,54	46,57
46,44	45,38	46,09	47,19	46,96	48,00	47,91	48,00	48,04	47,60	45,54
44,98	46,44	45,38	46,09	47,19	46,96	48,00	47,91	48,00	48,04	47,60
44,98	44,98	46,44	45,38	46,09	47,19	46,96	48,00	47,91	48,00	48,04
41,98	44,98	44,98	46,44	45,38	46,09	47,19	46,96	48,00	47,91	48,00
40,28	41,98	44,98	44,98	46,44	45,38	46,09	47,19	46,96	48,00	47,91
41,28	40,28	41,98	44,98	44,98	46,44	45,38	46,09	47,19	46,96	48,00
41,45	41,28	40,28	41,98	44,98	44,98	46,44	45,38	46,09	47,19	46,96
42,22	41,45	41,28	40,28	41,98	44,98	44,98	46,44	45,38	46,09	47,19
42,49	42,22	41,45	41,28	40,28	41,98	44,98	44,98	46,44	45,38	46,09
43,70	42,49	42,22	41,45	41,28	40,28	41,98	44,98	44,98	46,44	45,38
44,38	43,70	42,49	42,22	41,45	41,28	40,28	41,98	44,98	44,98	46,44
43,56	44,38	43,70	42,49	42,22	41,45	41,28	40,28	41,98	44,98	44,98
43,55	43,56	44,38	43,70	42,49	42,22	41,45	41,28	40,28	41,98	44,98
43,07	43,55	43,56	44,38	43,70	42,49	42,22	41,45	41,28	40,28	41,98
43,73	43,07	43,55	43,56	44,38	43,70	42,49	42,22	41,45	41,28	40,28
42,97	43,73	43,07	43,55	43,56	44,38	43,70	42,49	42,22	41,45	41,28
41,92	42,97	43,73	43,07	43,55	43,56	44,38	43,70	42,49	42,22	41,45
42,00	41,92	42,97	43,73	43,07	43,55	43,56	44,38	43,70	42,49	42,22
41,44	42,00	41,92	42,97	43,73	43,07	43,55	43,56	44,38	43,70	42,49
39,69	41,44	42,00	41,92	42,97	43,73	43,07	43,55	43,56	44,38	43,70

altın	altın1	altın2	altın3	altın4	altın5	altın6	altın7	altın8	altın9	altın10
101,95	103,10	102,65	108,15	108,50	108,50	108,50	108,17	108,22	108,25	109,50
102,32	101,95	103,10	102,65	108,15	108,50	108,50	108,50	108,17	108,22	108,25
102,35	102,32	101,95	103,10	102,65	108,15	108,50	108,50	108,50	108,17	108,22
102,30	102,35	102,32	101,95	103,10	102,65	108,15	108,50	108,50	108,50	108,17
102,20	102,30	102,35	102,32	101,95	103,10	102,65	108,15	108,50	108,50	108,50
100,90	102,20	102,30	102,35	102,32	101,95	103,10	102,65	108,15	108,50	108,50
100,35	100,90	102,20	102,30	102,35	102,32	101,95	103,10	102,65	108,15	108,50
100,00	100,35	100,90	102,20	102,30	102,35	102,32	101,95	103,10	102,65	108,15
100,90	100,00	100,35	100,90	102,20	102,30	102,35	102,32	101,95	103,10	102,65
98,90	100,90	100,00	100,35	100,90	102,20	102,30	102,35	102,32	101,95	103,10
98,60	98,90	100,90	100,00	100,35	100,90	102,20	102,30	102,35	102,32	101,95
98,33	98,60	98,90	100,90	100,00	100,35	100,90	102,20	102,30	102,35	102,32
98,56	98,33	98,60	98,90	100,90	100,00	100,35	100,90	102,20	102,30	102,35
98,05	98,56	98,33	98,60	98,90	100,90	100,00	100,35	100,90	102,20	102,30
99,30	98,05	98,56	98,33	98,60	98,90	100,90	100,00	100,35	100,90	102,20
99,85	99,30	98,05	98,56	98,33	98,60	98,90	100,90	100,00	100,35	100,90
100,30	99,85	99,30	98,05	98,56	98,33	98,60	98,90	100,90	100,00	100,35
100,27	100,30	99,85	99,30	98,05	98,56	98,33	98,60	98,90	100,90	100,00
99,05	100,27	100,30	99,85	99,30	98,05	98,56	98,33	98,60	98,90	100,90
99,60	99,05	100,27	100,30	99,85	99,30	98,05	98,56	98,33	98,60	98,90
99,03	99,60	99,05	100,27	100,30	99,85	99,30	98,05	98,56	98,33	98,60
97,90	99,03	99,60	99,05	100,27	100,30	99,85	99,30	98,05	98,56	98,33
99,25	97,90	99,03	99,60	99,05	100,27	100,30	99,85	99,30	98,05	98,56
100,75	99,25	97,90	99,03	99,60	99,05	100,27	100,30	99,85	99,30	98,05

euro	euro1	euro2	euro3	euro4	euro5	euro6	euro7	euro8	euro9	euro10
3,1111	3,1027	3,1112	3,2082	3,2244	3,194	3,2085	3,1953	3,2037	3,1905	3,2831
3,1136	3,1111	3,1027	3,1112	3,2082	3,2244	3,194	3,2085	3,1953	3,2037	3,1905
3,1313	3,1136	3,1111	3,1027	3,1112	3,2082	3,2244	3,194	3,2085	3,1953	3,2037
3,1395	3,1313	3,1136	3,1111	3,1027	3,1112	3,2082	3,2244	3,194	3,2085	3,1953
3,1267	3,1395	3,1313	3,1136	3,1111	3,1027	3,1112	3,2082	3,2244	3,194	3,2085
3,0886	3,1267	3,1395	3,1313	3,1136	3,1111	3,1027	3,1112	3,2082	3,2244	3,194
3,0993	3,0886	3,1267	3,1395	3,1313	3,1136	3,1111	3,1027	3,1112	3,2082	3,2244
3,0869	3,0993	3,0886	3,1267	3,1395	3,1313	3,1136	3,1111	3,1027	3,1112	3,2082
3,0814	3,0869	3,0993	3,0886	3,1267	3,1395	3,1313	3,1136	3,1111	3,1027	3,1112
3,054	3,0814	3,0869	3,0993	3,0886	3,1267	3,1395	3,1313	3,1136	3,1111	3,1027
3,0506	3,054	3,0814	3,0869	3,0993	3,0886	3,1267	3,1395	3,1313	3,1136	3,1111
3,0514	3,0506	3,054	3,0814	3,0869	3,0993	3,0886	3,1267	3,1395	3,1313	3,1136
3,0147	3,0514	3,0506	3,054	3,0814	3,0869	3,0993	3,0886	3,1267	3,1395	3,1313
3,032	3,0147	3,0514	3,0506	3,054	3,0814	3,0869	3,0993	3,0886	3,1267	3,1395
3,0617	3,032	3,0147	3,0514	3,0506	3,054	3,0814	3,0869	3,0993	3,0886	3,1267
3,0694	3,0617	3,032	3,0147	3,0514	3,0506	3,054	3,0814	3,0869	3,0993	3,0886
3,0993	3,0694	3,0617	3,032	3,0147	3,0514	3,0506	3,054	3,0814	3,0869	3,0993
3,0979	3,0993	3,0694	3,0617	3,032	3,0147	3,0514	3,0506	3,054	3,0814	3,0869
3,0776	3,0979	3,0993	3,0694	3,0617	3,032	3,0147	3,0514	3,0506	3,054	3,0814
3,0732	3,0776	3,0979	3,0993	3,0694	3,0617	3,032	3,0147	3,0514	3,0506	3,054
3,067	3,0732	3,0776	3,0979	3,0993	3,0694	3,0617	3,032	3,0147	3,0514	3,0506
3,1551	3,067	3,0732	3,0776	3,0979	3,0993	3,0694	3,0617	3,032	3,0147	3,0514
3,1517	3,1551	3,067	3,0732	3,0776	3,0979	3,0993	3,0694	3,0617	3,032	3,0147
3,157	3,1517	3,1551	3,067	3,0732	3,0776	3,0979	3,0993	3,0694	3,0617	3,032

6. KAYNAKLAR

- Akita, R., Yoshihara, A., Matsubara, T., Uehara, K. (2016). Deep Learning For Stock Prediction Using Numerical and Textual Information. *2016 IEEE/ACIS 15th International Conference on Computer and Information Science (ICIS)*. 2016, 1-6, <https://doi.org/10.1109/ICIS.2016.7550882>.
- Arı, B. (2017). *Kayıt Yapraklarının Evrişimsel Sinir Ağları Kullanılarak Sınıflandırılması*. Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.
- Atan, S., & Çınar, Y. (2019). Borsa İstanbul'da Finansal Haberler ile Piyasa Değeri İlişkisinin Metin Madenciliği ve Duygu (Sentiment) Analizi ile İncelenmesi. *Ankara Üniversitesi SBF Dergisi*. 74(1), 1-34.
- Aydın, E., Yüksel, S.E. (2017). Derin Öğrenme Yöntemini Kullanarak Yere Nüfuz Eden Radar İle Gömülü Hedef Tespiti. *2017 25th Signal Processing and Communications Applications Conference (SIU)*. 2017, 1-4, <https://doi.org/10.1109/SIU.2017.7960299>.
- Aytekin, G. (2018). Türkiye'de Sermaye Piyasaları ve Borsaların Gelişim Süreci. *International Journal of Humanities and Education*, 4(9), 150-176.
- Baldi, P. (2012). Autoencoders, Unsupervised Learning, and Deep Architectures. *JMLR Workshop and Conference Proceedings*. 2012, 13(27), 37-50.
- Bayır, F. (2006). *Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama*. Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Blei, D. M., Ng, A. Y., Jordan, M. I. (2003). Latent Dirichlet Allocation. *Journal of Machine Learning Research*. 3, 993-1022.
- Birgili, M. E. (2013). *Teknik Analiz Yöntemini Kullanan Yatırımcıların Davranışsal Finans Modelleri ile Açıklanması Türkiye'de Bir Araştırma*. Yüksek Lisans Tezi, Sosyal Bilimler Enstitüsü, Aydın.

- Bodas, D. J., Sagi, P., Blanco, F. (2013). A Parallel Evolutionary Algorithm For Technical Market Indicators Optimization. 10 Mart 2021 tarihinde A parallel evolutionary algorithm for technical market indicators optimization adresinden alınmıştır.
- Cengil, E., Çınar, A. (2016). A New Approach For Image Classification: Convolutional Neural Network. *European Journal of Technique*. 6(2), 96-103.
- Ceyhan, K., Kurtulmaz, E., Sert, O. C., Ozyer, T. (2018). Bitcoin Movement Prediction With Text Mining. *26th IEEE Signal Processing and Communications Applications Conference, SIU*. 2018, 1-4, <https://doi.org/10.1109/SIU.2018.8404169>.
- Chen, Q., Yao, L., Yang, J. (2016). Short Text Classification Based On Lda Topic Model. *2016 International Conference on Audio, Language and Image Processing (ICALIP)*. 2016, 749-753, <https://doi.org/10.1109/ICALIP.2016.7846525>.
- Chollet, F., Allaire, J. J. (2017). *Deep Learning With R*. (Birinci baskı). Manning.
- Clevert, D. A., Unterthiner, T., Hochreiter, S. (2016). Fast And Accurate Deep Network Learning By Exponential Linear Units (ELUs). ICLR 2016, Puerto Rico. 10 Mart 2021 tarihinde (PDF) Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs) adresinden alınmıştır.
- Çelikel, A. D. (2018). *Stock Value Prediction Using Machine Learning And Text Mining*. Yüksek Lisans Tezi, Kadir Has Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Çetinyokuş, T., Gökçen, H. (2002). Borsada Göstergelerle Teknik Analiz İçin Bir Karar Destek Sistemi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 17(1), 43-58.
- Çınaroğlu, S. (2017). Sağlık Harcamasının Tahmininde Makine Öğrenmesi Regresyon Yöntemlerinin Karşılaştırılması. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*. 22(2), 179-200.
- Çiftçi, L. (2002). *İMKB’de Hisse Senedi Fiyat Hareketleri ve Teknik Analiz Yöntemleri*. Yüksek Lisans Tezi, Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü, Kocaeli.

- Dayı, F. (2020). Sistematik Riskin Hisse Senedi Getirisine Etkisi: Borsa İstanbul Örneği. *Optimum Ekonomi ve Yönetim Bilimleri Dergisi*. 7(1), 1-20.
- Deng, L., Yu, D. (2014). *Deep Learning Methods and Applications*. Now Publishers Inc.
- Dolgun, M. Ö., Özdemir, T. G., Oğuz, D. (2009). Veri Madenciliği'nde Yapısal Olmayan Verinin Analizi: Metin ve Web Madenciliği. *İstatistikçiler Dergisi*. 2(2), 48-58.
- Eliaçık, A.B., & Erdoğan, N. (2015). Mikro Bloglardaki Finans Toplulukları için Kullanıcı Ağırlıklandırılmış Duygu Analizi Yöntemi. *Ulusal Yazılım Mühendisliği Sempozyumu (UYSM)*.
- Erdoğan, Y. (Ed.), (2004). *Yatırımcı ve Teknik Analiz Sorguluyor*. Ankara: Siyasal Kitabevi.
- Erdoğan, H., Baykut, E. (2016). BIST Banka Endeksi'nin (XBANK) VIX ve MOVE Endeksleri ile İlişkinin Analizi. *Bankacılar Dergisi*. (98), 57-72.
- Ergin, E. (2015). *Hisse Senedi Piyasalarında Temel Analiz: 2008-2013 Yılları Arasında Bist'te İşlem Gören Sigorta Şirketleri Üzerine Bir Uygulama*. Yüksek Lisans Tezi, Osmaniye Korkut Ata Üniversitesi Sosyal Bilimler Enstitüsü, Osmaniye.
- Fung, G. P. C, Yu, J. X., Lam, W. (2003). Stock prediction: Integrating text mining approach using real-time news. *2003 IEEE International Conference on Computational Intelligence for Financial Engineering*. 2003, 395-402, <https://doi.org/10.1109/CIFER.2003.1196287>.
- Gündüz, H., Çataltepe, Z., & Yaslan, Y. (2017). Derin Sinir Ağları ile Borsa Yönü Tahmini, Stock Market Direction Prediction Using Deep Neural Networks, *Signal Processing and Communications Applications Conference (SIU)*, İzmir.
- Günak, M.N. (2007). *İleri Teknik Analiz Uygulamaları ve Bu Uygulamaların İmkb'de Test Edilmesi*. Yayımlanmamış Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul
- Hearts, M. (2003). What Is Text Mining. 10 Mart 2021 tarihinde Marti Hearst: What Is Text Mining? adresinden alınmıştır.

- İnik, Ö., Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD)*. 6(3), 85-104.
- 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 System with Applications*. 38, 5311-5319.
- Karaoğlu, H.S. (2018). *A Stock Trading Application Using Deep Learning*. Yüksek Lisans Tezi, Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Kayaalp, K., Süzen, A.A. (2018). *Derin Öğrenme ve Türkiye'deki Uygulamaları*. IKSAD Yayınevi.
- Khare, K., Darekar, O., Gupta, P., Attar, V.Z. (2017), Short Term Stock Price Prediction Using Deep Learning. *2017 2nd IEEE International Conference On Recent Trends in Electronics Information & Communication Technology (RTEICT)*, 2017, 482-486, <https://doi.org/10.1109/RTEICT.2017.8256643>.
- Kilimci, Z. H. (2020). Borsa Tahmini İçin Derin Topluluk Modelleri (DTM) ile Finansal Duygu Analizi. *Gazi Üniversitesi Mühendislik Mimarlık Fakülte Dergisi*. 35(2), 635-650.
- Kindik, N. (2019). *Türkiye'de Hisse Senedi Piyasasının Ekonomik Büyümeye Katkısı*. Yüksek Lisans Tezi, Nevşehir Hacı Bektaş Veli Üniversitesi Sosyal Bilimler Enstitüsü, Nevşehir.
- Kirkpatrick, C. D., Dahlquist, J. (2011). *Technical Analysis: The Complete Resource for Financial Market Technicians*. (İkinci Baskı). New Jersey: FT Press.
- Krantz, M. (Ed), (2010). *Fundamental Analysis For Dummies*. New Jersey: Wiley Publishing.
- Kuhn, M., J., K. (2013). *Applied Predictive Modeling*. (Birinci baskı). New York, Springer.
- Kursa, M. B., Rudnicki, W. R. (2010). Feature Selection With The Boruta Package. *Journal of Statistical Software*. 36(11), 1-13.

- Kuş, Z. (2019). *Mikrokanonikal Optimizasyon Algoritması ile Konvolüsyonel Sinir Ağlarında Hiperparametrelerin Optimize Edilmesi*. Yüksek Lisans Tezi, Fatih Sultan Mehmet Vakıf Üniversitesi Lisansüstü Eğitim Enstitüsü, İstanbul.
- Küçük, D., Arıcı, N. (2018). Doğal Dil İşlemede Derin Öğrenme Uygulamaları Üzerine Bir Literatür Çalışması. *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*. 2(2), 76-86.
- Lipton, Z. C. (2015). A Critical Review of Recurrent Neural Networks for Sequence Learning. *ResearchGate*. (PDF) A Critical Review of Recurrent Neural Networks for Sequence Learning
- Mahajan, A., Dey, L., Haque, S., M. (2008). Mining Financial News for Major Events and Their Impacts on the Market. *2008 IEEE / WIC / ACM International Conference on Web Intelligence*. 2008, 423-426, <https://doi.org/10.1109/WIIAT.2008.309>.
- Nazir, S., Patel, S., Patel, D. (2018). Hyper Parameters Selection for Image Classification in Convolutional Neural Networks. *17th Int'l Conf. on Cognitive Informatics & Cognitive Computing (ICCI*CC'18)*. 2018, 401-407, <https://doi.org/10.1109/ICCI-CC.2018.8482081>.
- Oncharen, P., Vateekul, P. (2018). Deep Learning for Stock Market Prediction Using Event Embedding and Technical Indicators. *2018 5th International Conference on Advanced Informatics: Concept Theory and Applications (ICAICTA)*. 2018, 19-24, <https://doi.org/10.1109/ICAICTA.2018.8541310>.
- Orçun, Ç. (2010). *Finansal Piyasalarda Alım Satım Kararlarında Teknik Analiz ve İMKB Uygulaması*. Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü, İzmir.
- Özmerdivanlı, A., Gülırmak, S. (2019). Borsa İstanbul Banka Endeks Getirilerinde Volatilite Modellemesi. *ICAIFR- 6. Uluslararası Muhasebe ve Finans Araştırmaları Kongresi*, Niğde.
- Öztürk, H. (2016). Teknik Analizde Alım-Satım Sistemi Oluşturma: Sistemin Geçmişe Yönelik Testleri. *Finansal Araştırmalar ve Çalışmalar Dergisi*. 8(15), 469-493.

- Özçam, F. (1996). *Teknik Analiz ve İstanbul Menkul Kıymetler Borsası*. (Birinci baskı). Ankara: Sermaye Piyasası Kurulu
- Pedamonti, D. (2018). Comparison Of Non-linear Activation Functions For Deep Neural Networks On MNIST Classification Task. *ResearchGate*. (PDF) Comparison of non-linear activation functions for deep neural networks on MNIST classification task
- Pervan, N. (2019). *Derin Öğrenme Yaklaşımları Kullanılarak Türkçe Metinlerden Anlamsal Çıkarım Yapma*. Yüksek Lisans Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Perşembe, A. (2013). *Teknik analiz mi dedin? Hadi canım sen de!*. (Beşinci baskı). İstanbul: Scala Yayıncılık.
- Pirim, H. (2006). Yapay Zeka. *Journal of Yaşar University*. 1(1),81-93.
- Rachlin, G., Last, M., Alberg, D., & Kandel, A. (2007). ADMIRAL: A Data Mining Based Financial Trading System. *Proceedings of the 2007 IEEE Symposium on Computational Intelligence and Data Mining, CIDM*. 2007, 720-725, <https://doi.org/10.1109/CIDM.2007.368947>.
- Raşo, H. (2019). *Deep Learning Based Stock Market Prediction Using Technical Indicators*. Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Ripley, B. D. (2008). *Pattern Recognition and Neural Networks*. (Birinci baskı). United Kingdom, Cambridge University Press.
- Schwager J. D. (1999). *Getting Started In Technical Analysis*. New Jersey: Wiley Publishing.
- Sezgin, N., Tekin, R., Çalışkan A. (2012). Örüntü Tanımda Hopfield Ağının Kullanılması. *Batman Üniversitesi Yaşam Bilimleri Dergisi*. 1(2), 257-266.
- Sirisuriya, SCM. D. S. (2015). A Comparative Study on Web Scraping. *Proceedings of 8th International Research Conference, KDU*. Sri Lanka.
- Soni, A., Eck, N. J., Kaymak, U. (2007). Prediction of Stock Price Movements Based on Concept Map Information. *2007 IEEE Symposium on Computational Intelligence in Multi-Criteria Decision-Making*. Honolulu, HI, USA.

- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*. 15(56), 1929-1958.
- Şahinler, S. (1993). *Regresyonda Kalıntı (Residual) Analizi*. Yüksek Lisans Tezi Fen Bilimleri Enstitüsü, Adana.
- Şeker, A., Diri, B., Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi*. 3(3), 47-64.
- Tanyıldızı, E., Demirtaş, F. (2019). Hiper Parametre Optimizasyonu. *2019 1st International Informatics and Software Engineering Conference (UBMYK)*. 2019, 1-5, <https://doi.org/10.1109/UBMYK48245.2019.8965609>.
- Tomakin, F. (2007). *Teknik Analiz ve MACD Göstergesinin İMKB'de Uygulanması*. Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Tuna, K., İsabetli İ. (2014). Finansal Piyasalarda Volatilite ve Bist-100 Örneği. *Kocaeli Üniversitesi Sosyal Bilimler Dergisi*. (27), 21-31.
- Türkmen, A.C., Cemgil, A.T. (2015). Finansal Piyasalarda Gösterge Sinyali Tahmini İçin Derin Öğrenme Uygulaması, An Application of Deep Learning for Trade Signal Prediction in Financial Markets, *2015 23rd Signal Processing and Communications Applications Conference (SIU)*, Malatya.
- Üzen, H., Hanbay, K. (2019). Yaya Özellik Tanıma İçin LM Filtre Temelli Derin Evrimsel Sinir Ağı. *Politeknik Dergisi*. 23(3), 605-613.
- Yıldırım, M., Yüksel, C. A. (2017). Sosyal Medya ile Hisse Senedi Fiyatının Günlük Hareket Yönü Arasındaki İlişkinin İncelenmesi: Duygu Analizi Uygulaması. *Uluslararası İktisadi ve İdari İncelemeler Dergisi* (22. UPK Ahmet Hamdi İslamoğlu Özel Sayısı).
- Zheng, A. (Ed), (2015). *Evaluating Machine Learning Models*. USA, O'reilly Media.
- Wang, Z., Bovik, A. C. (2009). Mean squared error: Love it or leave it? A new look at Signal Fidelity Measures. *IEEE Signal Processing Magazine*. 26(1), 98-117.