

GÜMÜŞHANE ÜNİVERSİTESİ * SOSYAL BİLİMLER ENSTİTÜSÜ

İŞLETME ANA BİLİM DALI

İŞLETME PROGRAMI

**HİSSE SENEDİ FİYATLARININ MAKİNE ÖĞRENMESİ YÖNTEMLERİ VE
DERİN ÖĞRENME ALGORİTMALARI İLE TAHMİNİ**

YÜKSEK LİSANS TEZİ

Uğur DEMİREL

HAZİRAN-2019

GÜMÜŞHANE



GÜMÜŞHANE ÜNİVERSİTESİ * SOSYAL BİLİMLER ENSTİTÜSÜ

İŞLETME ANA BİLİM DALI

İŞLETME PROGRAMI

**HİSSE SENEDİ FİYATLARININ MAKİNE ÖĞRENMESİ YÖNTEMLERİ VE
DERİN ÖĞRENME ALGORİTMALARI İLE TAHMİNİ**

YÜKSEK LİSANS TEZİ

Uğur DEMİREL

Tez Danışmanı: Doç. Dr. Handan ÇAM

2. Danışman: Dr. Öğr. Ramazan Ünlü

HAZİRAN-2019

GÜMÜŞHANE

KABUL VE ONAY

Doç. Dr. Handan ÇAM danışmanlığında, Uğur DEMİREL tarafından hazırlanan “Hisse Senedi Fiyatlarının Makine Öğrenmesi Yöntemleri ve Derin Öğrenme Algoritmaları İle Tahmini” isimli bu çalışma, ... / / tarihinde yapılan savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

[İmza]

Unvanı Adı SOYADI (Başkan)

[İmza]

Unvanı Adı SOYADI (Danışman)

[İmza]

Unvanı Adı SOYADI (Üye)

[İmza]

Unvanı Adı SOYADI (Üye) (Varsa)

[İmza]

Unvanı Adı SOYADI (Üye) (Varsa)

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylarım.

.... / / 2019

[imza]

Prof. Dr. Ekrem CENGİZ, Enstitü Müdürü

BİLDİRİM

Yüksek Lisans Tezi olarak hazırlamış olduğum “Hisse Senedi Fiyatlarının Makine Öğrenmesi Yöntemleri ve Derin Öğrenme Algoritmaları İle Tahmini” isimli bu çalışmanın, tamamen kendi çalışmam olduğunu, her alıntıya kaynak gösterdiğimi ve alıntı yaptığım tüm çalışmaların kaynakçada yer aldığını taahhüt eder, tezimin kâğıt ve elektronik kopyalarının Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü arşivlerinde aşağıda belirttiğim koşullarda saklanmasına izin verdiğimi onaylarım.

Lisansüstü Eğitim-Öğretim yönetmeliğinin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim.

☒	Tezimin tamamı her yerden erişime açılabilir.
☐	Tezim sadece Gümüşhane Üniversitesi yerleşkelerinden erişime açılabilir.
☐	Tezimin yıl süreyle erişime açılmasını istemiyorum. Bu sürenin sonunda uzatma için başvuruda bulunmadığım takdirde, tezimin tamamı her yerden erişime açılabilir.

.... / /

[İmza]

Uğur DEMİREL

ÖNSÖZ

Çalışmalarım boyunca bana yol gösteren ve geniş birikimlerini bana aktararak, belirttiği önerilerle bu çalışmanın yönlendirilmesinde yardımcı olan, çalışma süresince bilgi, görüş ve yardımlarını esirgemeyen ve gösterdiği üstün anlayıştan ötürü değerli hocam Doç. Dr. Handan ÇAM'a teşekkür ederim.

Yaptığım çalışmada sorduğum soruları sabırla cevaplayan üniversitemiz Yönetim Bilişim Sistemleri Bölümü Dr. Öğr. Üyesi Ramazan ÜNLÜ'ye, bu çalışmanın temelini oluşturan finans konusunda yardımlarını esirgemeyen üniversitemiz İşletme Bölümü Öğretim Üyesi Doç. Dr. Alper Veli ÇAM'a çok teşekkür ederim.

Tez hazırlık ve yazım aşamasında bana sonsuz destek veren arkadaşlarıma ve aileme sonsuz sevgilerimi sunarım.

Gümüşhane - 2019

Uğur DEMİREL

ÖZET

[DEMİREL, Uğur]. Hisse Senedi Fiyatlarının Makine Öğrenmesi Yöntemleri ve Derin Öğrenme Algoritmaları İle Tahmini, Yüksek Lisans Tezi, 2019, (XVIII+127)

Türkiye gibi gelişmekte olan ekonomiler açısından menkul kıymetler piyasasının fiyat tahminlerinin yapılması oldukça önemlidir, ancak piyasalarda her türlü spekülasyon hareketin yaşanması bu borsalarda iniş ve çıkışların çok yüksek olmasına neden olmaktadır. Bu durum yatırımcıların hisse senedi fiyat hareketlerini tahmin edebilmelerini güçleştirmekte ve dolayısıyla yatırımlarını doğru değerlendiremedikleri için kayıplar yaşamalarına sebep olmaktadır. Bu nedenle yatırımcılar gelecekteki hisse senedi fiyatlarını doğru tahmin edebilmek için çeşitli yöntem ve metotlar kullanma ihtiyacı hissetmektedirler. Son zamanlarda bu tahminlerin elde edilmesinde makine öğrenmesi yöntemleri ve derin öğrenme algoritmaları diğer alanlarda olduğu gibi finans alanında da sıkça kullanılmaya başlanmıştır.

Bu çalışmada, veri seti olarak Borsa İstanbul Ulusal-100 Endeksi (BIST 100)'de işlem gören firmaların hisse senetlerinin günlük 2. seans açılış ve kapanış fiyatlarına ilişkin Ocak 2010 ile Ocak 2019 tarihleri arasındaki veriler kullanılmıştır. Çalışmada makine öğrenmesi ve derin öğrenme ışığında bu hisse senetlerinin açılış ve kapanış fiyatlarının tahmin edilmesi amaçlanmaktadır. Bu kapsamda tahminleme modeli oluşturabilmek adına Çok Katmanlı Algılayıcılar (ÇKA) ve Destek Vektör Makineleri (DVM) gibi klasik makine öğrenimi yöntemleri ve Uzun Kısa Dönemli Hafıza (UKVH) yöntemi gibi derin öğrenme algoritmaları kullanılmaktadır. Çalışmanın sonucunda ÇKA ve UKVH ağlarının DVM'lerine göre daha tutarlı tahminler yaptığı tespit edilmiştir. Bu sonuç analizlerde gruplar arasında fark olup olmadığını gösteren çift kuyruklu t-testi analizi ile de desteklenmiştir.

Anahtar Kelimeler: Borsa İstanbul, BİST (100), Makine Öğrenmesi, Derin Öğrenme

ABSTRACT

[DEMİREL, Uğur]. Estimations Of Opening and Closing Stock Prices Through Machine Learning Methods And Deep Learning Algorithms, 2019, (XVIII+127)

Forecasting the stock markets' prices in emerging economies such as Turkey is quite important, however, the existence of all kinds of speculative movements in the markets causes ups and downs to be very high in these stock markets. This situation makes it difficult for investors to predict stock price movements and thus cause losses since they cannot evaluate their investments correctly. For this reason, investors feel the need to use various practices and methods to predict future stock prices. In order to gain these forecasts, machine learning methods and deep learning algorithms have been recently used frequently in the field of finance as well as other fields.

In this study, data between January 2010 and January 2019 were used as the data set for the second session opening and closing prices of the stocks of the companies traded on the Borsa İstanbul National-100 Index (BIST 100). In the light of machine learning methods and deep learning algorithms, it is aimed to estimate the opening and closing prices of these stocks. In this context, in order to create a prediction model, machine learning methods such as Multilayer Perceptrons (MLP) and Support Vector Machines (SVMs) as well as deep learning algorithm, Long Short Term Memory (LSTM) method have been used. As a result of the study, it has been observed that MLP and LSTM networks make more consistent estimates than SVMs. This result has been supported by two-tailed t test analysis, which shows whether there is a difference between the groups in the analyzes.

Keywords: Borsa İstanbul, BİST (100), Machine Learning, Deep Learning

İÇİNDEKİLER

DIŞ KAPAK

İÇ KAPAK

KABUL VE ONAY II

BİLDİRİM III

ÖNSÖZ..... IV

ÖZET..... V

ABSTRACT VI

İÇİNDEKİLER VII

TABLolar LİSTESİ..... XII

ŞEKİLLER LİSTESİ..... XIII

GRAFİKLER LİSTESİ..... XV

KISALTMALAR VE SİMGELER LİSTESİ..... XVII

GİRİŞ 1

BİRİNCİ BÖLÜM

1. FİNANSAL PİYASALAR VE BORSA.....4-26

1.1. Finansal Piyasaların Tanım ve İşlevleri 4

1.2. Finansal Piyasaların Sınıflandırılması..... 6

1.2.1. Vadelerine Göre Finansal Piyasalar 7

1.2.1.1. Para Piyasaları..... 8

1.2.1.2. Sermaye Piyasaları..... 9

1.2.2. İşlemlerine Göre Finansal Piyasalar.....	10
1.2.2.1. Birincil Piyasalar.....	11
1.2.2.2. İkincil Piyasalar	11
1.2.3. Örgütlenme Şekillerine Göre Finansal Piyasalar	12
1.2.4. Spot ve Vadeli Piyasalar	13
1.3. Menkul Kıymetlerin Tanımı ve Unsurları.....	13
1.4. Menkul Kıymet Borsaları ve Borsa İstanbul.....	13
1.4.1. Borsa Tanımı ve Faaliyetleri	14
1.4.1.1. Borsanın Tanımı	14
1.4.1.2. Borsanın Faaliyetleri.....	14
1.4.1.3. Hukuki Çerçeve	15
1.4.2. Hisse Senetleri.....	16
1.4.2.1. Hisse senedi çeşitleri.....	17
1.4.2.2. Hisse Senedi Değer Kavramları.....	18
1.4.2.3. Hisse Senedi Fiyat Tanımlamaları	19
1.4.3. Hisse Senedi İşlemleri.....	19
1.4.3.1. İkincil Piyasa İle İlgili Temel Kavramlar	20
1.4.3.2. Hisse Senedi Pazarları	21
1.4.3.3. Emirler	22
1.5. Menkul Kıymetler Analiz Yöntemleri	22
1.5.1. Temel Analiz	23
1.5.2. Teknik Analiz.....	25
1.5.3. Portföy Analizi	25
1.5.4. İstatistikî Tahmin Yöntemleri	26

İKİNCİ BÖLÜM

2. MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME KAVRAMLARI VE İLGİLİ LİTERATÜR TARAMASI.....27-81

2.1. Yapay Zekâ Kavramı	27
-------------------------------	----

2.2. Yapay Zekâ Teknolojileri	30
2.3. Yapay Sinir Ağları	30
2.3.1. YSA'nın Tanımı	30
2.3.1.1. Biyolojik Sinir Hücresi	31
2.3.1.2. Yapay Sinir Hücresi	32
2.3.1.3. YSA'nın Temel Elemanları	34
2.3.1.4. YSA'nın Katmanları	38
2.3.1.5. YSA Uygulamaları Geliştirme Aşamaları	40
2.3.2. YSA'nın Tarihsel Gelişimi.....	41
2.3.3. YSA'nın Sınıflandırılması.....	42
2.3.3.1. Bağlantı Yapılarına Göre YSA	43
2.3.3.2. Öğrenme Stratejilerine Göre YSA	43
2.3.3.3. Öğrenme Kurallarına Göre YSA	44
2.3.3.4. Öğrenme Algoritmalarına Göre Ağlar	45
2.3.4. YSA'nın Genel Özellikleri.....	46
2.3.5. YSA'nın Uygulama Alanları.....	48
2.4. Çok Katmanlı Algılayıcılar (ÇKA).....	49
2.4.1. ÇKA'nın Tanımı	50
2.4.2. ÇKA Modelinin Yapısı	51
2.4.3. ÇKA Ağının Öğrenme Kuralı	52
2.4.3.1. İleri Besleme (Feed Forward)	53
2.4.3.2. Geriye Yayılma (Backpropagation).....	53
2.4.4. ÇKA Ağının Oluşturulmasında Dikkat Edilmesi Gereken Noktalar	54
2.4.5. ÇKA ile Zaman Serisi Tahmini.....	55
2.4.6. ÇKA'nın İstatistik Tekniklere Göre Güçlü ve Zayıf Yanları.....	56
2.4.7. ÇKA Ağının Uygulama Alanları.....	57
2.5. Destek Vektör Makineleri	57
2.5.1. DVM'in Tanımı.....	57
2.5.2. DVM ile Sınıflama	58
2.5.2.1. Doğrusal Destek Vektör Makineleri	58

2.5.2.2. Doğrusal Olmayan Destek Vektör Makineleri	61
2.5.3. DVM'in Üstünlükleri ve Kısıtları	62
2.6. Derin Öğrenme.....	63
2.6.1. Derin Öğrenme'nin Tanımı	63
2.6.2. Derin Öğrenme'nin Tarihçesi.....	64
2.6.3. Derin Öğrenme Kütüphaneleri/Yazılımları.....	67
2.6.4. Derin Öğrenme Uygulamaları.....	69
2.6.5. Uzun Kısa Vadeli Hafıza.....	69
2.7. İlgili Literatür Taraması	75

ÜÇÜNCÜ BÖLÜM

3. UYGULAMA MODELLERİ VE TAHMİNE AİT BULGULAR.....	82-92
3.1. Çalışmanın Amacı ve Kapsamı	82
3.2. Çalışmanın Yöntemi ve Veriler	82
3.3. Verilerin Temizlenmesi ve Düzenlenmesi	82
3.4. Eğitim ve Test Setlerinin Oluşturulması	83
3.5. Bist100 Endeksinin ÇKA, DVM ve UKVH ile Tahmini.....	83
3.5.1. Çok Katmanlı Algılayıcı (ÇKA) İle Tahmin.....	84
3.5.2. Destek Vektör Makineleri (DVM) İle Tahmin	85
3.5.3. Uzun Kısa Vadeli Hafıza (UKVH) İle Tahmin.....	85
3.6. Model Performansları ve Bulguların Karşılaştırılması	86
SONUÇ VE DEĞERLENDİRME.....	93
KAYNAKÇA	95
ÖZGEÇMİŞ.....	1077
Ek 1. Analizlerde Kullanılan Şirketler.....	109
Ek 2. Çalışmada Kullanılan Veriler (Akbank T.A.Ş.).....	111

Ek 3. Modellerin Tahminleme Doğruluk Ölçüleri	118
Ek 4. Modellerin Ürettiği Grafikler	122



TABLÖLAR LİSTESİ

Tablo 1.1. Para Piyasası Araçları	8
Tablo 1.2. Sermaye Piyasası Araçları	10
Tablo 1.3. Pay Piyasasında İşlemlerin Gerçekleştiği Pazarlar	21
Tablo 2.1. Biyolojik Sinir Sistemi ile Yapay Sinir Hücresinin Karşılaştırılması	32
Tablo 2.2. Toplama Fonksiyonu Örnekleri	35
Tablo 2.3. Aktivasyon Fonksiyonları	37
Tablo 2.4. Yapay Sinir Ağları ve Kullanım Alanları	49
Tablo 2.5. Çekirdek Fonksiyonları	62
Tablo 3.1. Çalışmada Kullanılan Bilgisayarın Özellikleri	84
Tablo 3.2. ÇKA Modeli Çift Kuyruklu T-Testi Sonuçları	86
Tablo 3.3. DVM Modeli Çift Kuyruklu T-Testi Sonuçları	87
Tablo 3.4. UKVH modeli Çift Kuyruklu T-Testi Sonuçları	89
Tablo 3.5. Kurulan Modellerin Ortalama P Değerleri	91
Tablo 3.6. ÇKA, DVM ve UKVH Modelleri R^2 Sonuçları Ortalamaları	94

ŞEKİLLER LİSTESİ

Şekil 1.1. Finansal Sistem Aracılığı ile Fon Akımı	5
Şekil 1.2. Piyasalar ve Türleri	7
Şekil 1.3. Temel Analizin Aşamaları	24
Şekil 2.1. Yapay Zekânın Süreçleri	29
Şekil 2.2. Biyolojik Sinir Hücresi ve Bileşenleri	32
Şekil 2.3. Yapay Sinir Hücresi	33
Şekil 2.4. Bir Yapay Sinir Ağı Örneği	39
Şekil 2.5. Yapay Sinir Ağlarının Tarihsel Gelişimi	41
Şekil 2.6. Geri Yayılımlı Öğrenme Algoritması Akış Diyagramı	46
Şekil 2.7. Tek Katmanlı Algılayıcı Modeli	51
Şekil 2.8. Çok Katmanlı Algılayıcı Modeli	51
Şekil 2.9. Zaman Serisi Tahmini Amacı ile Kurulan Tipik Bir ÇKA	56
Şekil 2.10. İki Boyutlu Uzayda Doğrusal Olarak Ayrılabilen Verilerin Görünümü ve Veriler Arasındaki Muhtemel En Büyük Boşluk	59
Şekil 2.11. Birbirinden Doğrusal Olarak Ayrılamayan Veriler ve Gevşek Değişkenler	60
Şekil 2.12. Kernel Fonksiyonu ile Verinin Daha Yüksek Bir Boyuta Dönüştürülmesi	61
Şekil 2.13. Görüntü İşleme	64
Şekil 2.14. Ivankhnenko A. Tarafından Eğitilen Bilinen İlk Derin Ağ Mimarisi	65
Şekil 2.15. Yıllara Göre Yapay Zekâ Başlangıç Şirketlerin Satın Alınması	66
Şekil 2.16. Derin Öğrenme Çerçeve Güç Puanları 2018	67
Şekil 2.17. Derin Öğrenme Kütüphanelerinin Karşılaştırılması	68
Şekil 2.18. RNN İçerisindeki Döngü	70
Şekil 2.19. Standard RNN’de Tekrarlayan Tek Katman	70
Şekil 2.20. UKVH’daki Dört Etkileşimli Katman	71
Şekil 2.21. UKVH Mimarisinde Kullanılan Semboller	71
Şekil 2.22. RNN’de kullanılan SRN birimi (Solda) ve LSTM (sağda) ayrıntılı şeması	72
Şekil 2.23. Kilit Noktası Olan Hücresinin Durumu	73
Şekil 2.24. Unutma Kapısı Katmanı ve Formülü	73

Şekil 2.25. Giriş Kapısı Katmanı ve Tanjant Kapılarının Formülleri	74
Şekil 2.26. Hücre Durumundaki Eski İle Yeni Verinin Güncellenmesi	74
Şekil 2.27. Çıkış Kapısı ve Formülleri.....	75
Şekil 3.1. Spyder (Phyton 3.6) Platformunun Ekran Görüntüsü.....	83



GRAFİKLER LİSTESİ

Grafik Ek 4.1. Koç Holding A.Ş.	122
Grafik Ek 4.2. Netaş Telekomünikasyon A.Ş.	122
Grafik Ek 4.3. Gübre Fabrikaları T.A.Ş.	122
Grafik Ek 4.4. Türkiye Halk Bankası A.Ş.	122
Grafik Ek 4.5. Galatasaray Sportif A.Ş.	122
Grafik Ek 4.6. Turkcell İletişim A.Ş.	122
Grafik Ek 4.7. Gübre Fabrikaları T.A.Ş.	123
Grafik Ek 4.8. Türkiye İş Bankası	123
Grafik Ek 4.9. Akbank T.A.Ş.	123
Grafik Ek 4.10. TSKB Gayrimenkul A.Ş.	123
Grafik Ek 4.11. Anadolu Efes Biracılık A.Ş.	123
Grafik Ek 4.12. Trakya Cam Sanayii A.Ş.	123
Grafik Ek 4.13. Sabancı Holding A.Ş.	124
Grafik Ek 4.14. Doğuş Otomotiv A.Ş.	124
Grafik Ek 4.15. Karsan Otomotiv A.Ş.	124
Grafik Ek 4.16. Anadolu Efes Biracılık A.Ş.	124
Grafik Ek 4.17. Doğan Holding A.Ş.	124
Grafik Ek 4.18. Metro Holding A.Ş.	124
Grafik Ek 4.19. Anadolu Efes Biracılık A.Ş.	125
Grafik Ek 4.20. Sabancı Holding A.Ş.	125
Grafik Ek 4.21. Doğuş Otomotiv A.Ş.	125
Grafik Ek 4.22. Karsan Otomotiv A.Ş.	125
Grafik Ek 4.23. Doğan Holding A.Ş.	125
Grafik Ek 4.24. Metro Holding A.Ş.	125
Grafik Ek 4.25. Petkim Holding A.Ş.	126
Grafik Ek 4.26. Koç Holding A.Ş.	126
Grafik Ek 4.27. Bim Mağazalar A.Ş.	126
Grafik Ek 4.28. Türkiye Vakıflar Bankası	126

Grafik Ek 4.29. Türkiye Petrol Rafineleri A.Ş.....	126
Grafik Ek 4.30. Akbank T.A.Ş.....	126
Grafik Ek 4.31. Eczacıbaşı Holding A.Ş.	127
Grafik Ek 4.32. Türkiye Garanti Bankası A.Ş.	127
Grafik Ek 4.33. Migros Ticaret A.Ş.....	127
Grafik Ek 4.34. Aselsan San. ve Tic. A.Ş.....	127
Grafik Ek 4.35. Türkiye İş Bankası A.Ş.	127
Grafik Ek 4.36. Koza İşletmeleri A.Ş.	127



KISALTMALAR ve SİMGELER LİSTESİ

ANN	: Artificial Neural Networks
ADALINE	: ADaptive LInear Neuron (Adaptif Doğrusal Sinir)
BİST	: Borsa İstanbul
ÇKA	: Çok Katmanlı Algılayıcılar
DPT	: Devlet Planlama Teşkilatı
DVM	: Destek Vektör Makinesi
İMKB	: İstanbul Menkul Kıymetler Borsası
IEEE	: Elektrik Elektronik Mühendisleri Enstitüsü
GPU	: Grafik İşlemci Birimi
LSTM	: Long Short Term memory (Uzun Kısa Vadeli Hafıza)
MADALINE	: Multiple ADaptive LInear Neuron (Çoklu Adaptif Doğrusal Sinir)
MLP	: Multilayer Perceptron
MSE	: Hata Kareleri Ortalaması (Mean Squared Error)
R²	: Korelasyon Katsayısı
RBF	: Radial Basis Functions
RNN	: Recurrent Neural Network
RMSE	: Ortalama Hata Karelerinin Karekökü (Root Mean Squared Error)
SOM	: Self Organizing Maps (Özörgütlemeli Haritalar)
S&P-500	: Standart & Poor 500 Index
SPK	: Sermaye Piyasası Kurulu
SPSS	: Statistical Package for the Social Sciences. (Sosyal Bilimler için İstatistik Paketi.)
SVM	: Support Vector Machine (Destek Vektör Makineleri)
TTK	: Türk Ticaret Kanunu
UKVH	: Uzun Kısa Vadeli Hafıza
WWW	: World Wide Web
YSA	: Yapay Sinir Ağları
ξ	: Gevşek Değişken

Σ : Toplama Fonksiyonu

x_i : Girdi Değeri

y_i : Çıktı Değeri

w_i : Ağırlıklar



GİRİŞ

Günümüzün finans dünyasında en önemli amaçlardan biri hisse senetlerinin fiyatlarını tahmin ederek uygun yatırımlar yapmak ve sonuç olarak da para kazanmaktır. Dolayısıyla hisse senetleri ile fonlar, uzun zamandır yatırımcılar, araştırmacılar ve bilim dünyası için çok önemli ve gizemini koruyan bir konu haline gelmiştir. Borsa sayesinde, yatırımlarını doğru değerlendirebilenler büyük kazançlar elde edebilirken yanlış değerlendirmeler sonucunda büyük kayıplar yaşayabilmektedirler.

Yatırımcıların doğru tahmin yaparak, yükselecek olan hisse senedini almaları (veya elde tutmaları) ve düşecek olan hisse senetlerinden kaçınmaları (veya satmaları), hangi hisse senedini veya fonu ne zaman alacağı borsada doğru hamle yapma açısından hayati önem taşımaktadır. Ancak, bu tahmin işlemi borsanın kendilerini önceden yeteri kadar göstermeyen hem politik hem de ekonomik olaylardan etkilenmesinden dolayı bu oldukça zor hale gelmektedir. Dolayısıyla bu tür olaylar tahmin yapılırken yatırımcı açısından sık ve etkili bir şekilde kullanılamamaktadır.

Finansal tahminler üzerinde birçok araştırmacı uzun yıllardır çalışmaktadır. Bu çalışmalarda hedeflenen amaç, bir finansal değer gelecekteki değerinin önceden öngörülüp öngörülemeyeceğidir ancak hisse senedi piyasaları her gün çok sayıda işlemin yapıldığı büyük sistemler olduğundan böyle dinamik, doğrusal olmayan ve hayli karmaşık sistemlerde öngörü yapmak kolay olmamaktadır.

Öngörü kavramı, belirli varsayımlar altında bir değişkenin gelecekte alabileceği değerlerin önceden yaklaşık olarak belirlenmesi şeklinde tanımlanmaktadır. Zaman serisi çözümlemesi ile öngörü ise, incelenen bir değişkenin şimdiki ve geçmiş dönemdeki gözlem değerlerini kullanarak öngörü değerlerinin hangi sınırlar arasında gerçekleşebileceğini birtakım varsayımlar altında ortaya koyan çalışmalardır. Doğru öngörünün (tahminin) başarılı kararları beraberinde getireceği ve bu şekilde fayda sağlamanın en üst düzeye çıkartılabileceği gerçeği, öngörü modellemesine olan ilgiyi artırarak bu alanda her geçen gün önemli gelişmelerin yaşanmasına ön ayak olmaktadır.

Önceden matematiksel ve istatistiksel yöntemlerle yapılan tahmin denemeleri, özellikle bilgisayar teknolojisinin gelişimiyle birlikte daha başarılı sonuçlar vermiştir.

Son yıllarda gelişen yapay zekâ kavramı ve öğrenmeye dayalı algoritmalar bu sürece önemli katkılar sağlamıştır. Özellikle son yıllarda yoğunlaşan makine öğrenmesi metotlarının ve derin öğrenme algoritmalarının finansal tahminlerde kullanımı ve alınan olumlu sonuçlar araştırmacıların bu alana olan ilgisini artırmaktadır; ancak buna rağmen piyasalardaki fiyat davranışlarını tam olarak öngörebilen bir yöntem bulunamadığından bu alandaki çalışmalar aktif olarak devam etmektedir.

Son yıllarda, genelleme yeteneğine sahip ve istatistiksel yöntemlere göre daha az varsayımları olan, örneklerden öğrenme yapabilen, makine öğrenmesi yöntemlerinin ve derin öğrenme algoritmalarının kullanımı artmıştır. Tezde incelenen Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (DVM) ve Uzun Kısa Vadeli Hafıza (UKVH) ağları bu alanda yaygın olarak kullanılan yöntemlerdir.

Biyolojik sinir ağlarındaki öğrenme sürecinden esinlenerek oluşturulmuş, borsa gibi dinamik sistemlerin modellenmesinde kullanılabilmesini sağlayan verideki örüntüleri keşfedebilen, gürültülü verilerle çalışabilme, doğrusal olmama, esnek olma gibi özelliklere sahip matematiksel modeller olan YSA'lar birbirine bağlı basit hesaplama birimlerinden oluşmaktadır. Bilginin işlenmesi bu birimlerin arasındaki bağlantılar kullanılarak yapılmaktadır. Günümüzde YSA'lar birçok alanda yaygın ve etkin bir şekilde kullanılmaktadır. Ekonomik tahmin de bu alanlardan bir tanesidir. Literatürde özellikle finansal değişkenlerin modellenmesi ve tahmini konusunda birçok çalışma bulunmaktadır.

Yapay sinir ağları ile yapılan finansal tahmin çalışmalarında en sık kullanılan model Çok Katmanlı Algılayıcılar (ÇKA) modelidir. ÇKA modeli, ileri beslemeli (Feed Forward) bir modeldir. Bu model Geriye Yayılma Algoritması (Backpropagation Algorithm) veya bu algoritmanın çeşitli türevleri kullanılarak eğitilmektedir. En küçük karelerin ortalaması yöntemini temel alan Genelleştirilmiş Delta Kuralı, geriye yayılma algoritmasının en yaygın kullanılan türüdür. ÇKA ağının eğitilmesinde bununla birlikte uygulamalarda Geriye Yayılma Algoritmasına alternatif öğrenme yöntemleri de kullanılmaktadır.

Vladimir Vapnik tarafından geliştirilen ileri yönde beslemeli yeni bir ağ kategorisi olan DVM de, İstatistiksel Öğrenme Teorisi'ne dayanan, sınıflandırma, regresyon problemlerine uygulanabilen ve gittikçe yaygınlaşan bir makine öğrenmesi yöntemidir. DVM, sınıfların doğrusal ayrılabilir olduğu durumdaki ikili sınıflandırma

probleminin çözümünde kullanılmaktadır. Optimal karar sınırını bulmak için oluşturulan optimizasyon problemi standart kuadratik programlama teknikleri ile çözülebilmekteyken sınıfların doğrusal olarak ayrılamadığı durumda ise optimizasyon probleminde çeşitli değişiklikler yapılarak sonuca varılmaktadır. Doğrusal olmayan karar sınırları oluşturmak için de kullanılabilen DVM, kernel fonksiyonları yoluyla girdileri daha yüksek boyutlu bir uzaya eşleyerek doğrusal sınıflandırma problemi bu yüksek boyutlu uzayda çözmektedir.

Zaman serilerinde kullanılan bir diğer yöntem bir çeşit RNN (Recurrent Neural Network – Tekrarlayan Sinir ağı) yapısında bir sinir ağı modeli olan UKVH'dır. Bu modelde bir hafıza hücresi kullanılarak bir önceki zamandan gelen bilgi bir sonrakine aktarılabilmektedir. Zaman serilerinde de zamana bağlı bir değişkenin önceki değerlerine bakarak geleceği tahmin etmek amaçlanmaktadır.

Bu çalışmada özellikle bilgisayar teknolojisindeki ilerlemeye paralel olarak uygulama sahası hızla genişleyen yapay sinir ağlarının bir türü olan çok katmanlı algılayıcılar ağı, destek vektör makineleri ve uzun kısa vadeli hafıza ağları kullanılarak BİST-100 endeksi üzerinde tahminler yapılmış ve sonuçlar karşılaştırılmıştır.

Çalışma üç bölümden oluşmaktadır. Birinci bölümde finansal piyasaların tanımı ve işlevleri, sınıflandırılması; menkul kıymetlerin tanımı ve unsurları, menkul kıymet borsaları / Borsa İstanbul ve son olarak menkul kıymetler analiz yöntemleri ele alınmıştır. İkinci bölümde makine öğrenmesi ve derin öğrenme kapsamında yapay zekâ kavramı, yapay zekâ teknolojileri, yapay sinir ağları, çok katmanlı algılayıcılar, destek vektör makineleri ve uzun kısa vadeli hafıza ile ilgili teorik bilgilere ve literatür taramasına yer verilmiştir. Üçüncü ve son bölümde ise uygulama modelleri ve tahmine ait bulgular değerlendirilmiş ve bu sonuçlara bağlı olarak çeşitli çıkarımlar yapılmıştır.

BİRİNCİ BÖLÜM

1. FİNANSAL PİYASALAR VE BORSA

1.1. Finansal Piyasaların Tanım ve İşlevleri

Alıcı ve satıcıların mal ve hizmetlerinin transferlerinin yapıldığı yer olarak tanımlanan piyasa, herhangi bir şeyin alıcı ve satıcılarını karşı karşıya getiren her türlü kolaylık olarak da ifade edilebilmektedir. Ekonomik yönden ifade edilecek olursa, piyasa alıcı ve satıcıların birbirleri ile karşılıklı iletişim içinde oldukları ve değişimin gerçekleştiği yer olarak tanımlanmaktadır. Piyasa için geleneksel Pazar yerleri gibi fiziksel bir yere ihtiyaç duyulmamaktadır. Alım-satım işinin gerçekleşmesi için alıcı ve satıcının karşı karşıya gelmesi, alım satıma hazır olan mal ve hizmetler hakkında iletişim kurması yeterli olmaktadır (Civan, 2007: 3; Kılınç, 1991: 15).

Piyasaların etkin bir şekilde çalışabilmesi için finansal bir sisteme gereksinim duyulmaktadır. Bu sistem, tahvil, bono veya hisse senedi gibi menkul kıymetlerin alınıp satıldığı finansal piyasalar ile alım satım işlemlerine aracılık eden finansal kuruluşlardan oluşmaktadır. Hane halkı, özel kesim şirketleri ve aracı kurumlar ile hükümetler finansal piyasalardaki alım-satım yapan katılımcılardır. Bu piyasalara fon sunan katılımcılar fazla veren birimler, fon talep edenler de açık veren birimler olarak adlandırılmaktadırlar (Günel, 2007: 19).


Finansal araçların alınıp satıldığı finansal piyasaların temel işlevi, ekonomide, zaman ve mekân açısından fon sıkışıklığı sorununu gidermektir. Fon sunan katılımcılar ve fon talep edenler arasındaki bağlantının gösterildiği şekil 1.1’de görüldüğü üzere finansal piyasalar, ellerinde fon fazlalığı olan katılımcılardan fon ihtiyacı hisseden katılımcılara doğru fon aktarımı işlevini üstlenmektedir (Orhan ve Erdoğan, 2007: 27).

Finansal piyasa aşağıdaki unsurlardan oluşmaktadır (Kılınç, 1991: 15).

- a) Tasarruf Sahipleri (fon arz edenler)
- b) Yatırımcılar/Tüketiciler (fon talep edenler)
- c) Yatırım ve finansman araçları (Para, mevduat, tahvil ve hisse senetleri gibi)

- d) Yardımcı kuruluşlar (Bankalar, aracı kurumlar, menkul kıymetler yatırım ortaklıkları ve menkul kıymetler yatırım fonları gibi)
- e) Hukuki ve idari düzen (Çalışmayı düzenleyen ilkeler ve kurallar gibi)

Şekil 1.1. Finansal Sistem Aracılığı ile Fon Akımı



Kaynak: (Orhan ve Erdoğan, 2007: 28)

Fon talep edenler ile fon arz edenlerin karşı karşıya gelerek fonlama işlevinin gerçekleştiği finansal piyasalarda sermaye ihtiyacı olanlar ile tasarruf sahipleri arasındaki sermaye transferi üç şekilde gerçekleşmektedir (Civan, 2007: 4-5; Orhan ve Erdoğan, 2007: 28):

- a) **Direk transfer**, işletmeler ve kurumların hiçbir aracı kurumu kullanmadan tahvil veya hisse senetlerini direkt olarak tasarruf sahiplerine satıldığı transfer türüdür.
- b) **Finansal kurumlar aracılığıyla doğrudan (dolaysız) transfer**, fon ihtiyacı duyan kesimlere, fon fazlası tasarruf sahiplerine yatırım bankası veya yatırım ortaklıkları gibi finansal araçlar sunularak gerçekleşmektedir. Finansal araçlar burada transfere konu olan fonun aktarılmasında sadece aracı rol oynamaktadırlar.
- c) **Finansal kurumlar aracılığıyla dolaylı transfer** de ise fon gereksinimi içinde bulunan kesimlerin sahip olduğu menkul kıymetler finansal araçlar tarafından satın alınarak değeri karşılığında kendi menkul değerlerini tasarruf sahiplerine satarak sermaye transferi gerçekleşmektedir.

Finansal piyasalar iktisadi hayatta bir takım roller üstlenmektedir. Bunlar (Hacıoğlu ve Dinçer, 2009: 34; Orhan ve Erdoğan, 2007: 29–30);

- Finansal piyasalar iktisadi hayatta, finansal araç sahiplerinin, düşük maliyetlere katlanarak söz konusu araçları nakde dönüştürüp fon talep edenlerin likidite gereksinimlerini kolaylıkla karşılayabilmelerini sağlamak
- Tasarruf sahiplerinin bilgi ve iletişim teknolojilerindeki gelişmelerden yararlanmalarını sağlayarak finansal piyasalardan finansal aracını almayı düşündükleri firmanın karlılık oranı ve borç geri ödeme gücüne ilişkin enformasyona çok düşük maliyet ile kısa sürede ulaşabilmelerine imkân tanımak
- Tasarruf sahiplerinin portföyünü oluştururken çok sayıda taşınır ve taşınmaz yatırım aracını tercih etmesi halinde, bireye risk dağıtma (risk paylaşma) kolaylığı sağlamak
- Düzenleyici ve denetleyici kuruluşların varlığının olması ortaya çıkan yatırım ilişkisinin yasal ve güvenilir olmasını sağlamak
- Küreselleşme ile birlikte artan risk ve belirsizlikler karşısında yatırımcılara hedge (korunma) imkânı sağlamak
- Vade, miktar ve cins açısından çeşitli finansal araçların bulunmasıyla yatırımcılara geniş bir alanda yatırım olanağı tanımak


Finansal piyasaların yukarıda bahsedilen rollerinin yanı sıra tasarruf yapabilme yeteneğine sahip ekonomik birimleri daha fazla tasarrufa özendirmek ve sermaye birikimini sağlamak, ulusal fonların etkin kullanımını olanaklı kılmak, fonlarını optimal dağılımını sağlamak, gömüleme etkisini ortadan kaldırmak ve finansal piyasaların gelişmesi ile yatırım tasarruf dengesini sağlamak gibi işlevleri bulunmaktadır (www.alonot.com, 2016; Hacıoğlu ve Dinçer, 2009: 34–35).

1.2. Finansal Piyasaların Sınıflandırılması

Finansal piyasalar işlevlerine ve amaçlarına göre farklı şekilde sınıflandırılmaktadır. Bu bağlamda; vadelerine göre finansal piyasalar, işlemlerine göre finansal piyasalar, örgütlenme şekillerine göre finansal piyasalar ve alıcı-satıcı bakımından finansal piyasalar olarak sınıflandırmalar yapılabilmektedir ancak daha farklı

sınıflandırmalar yapmak mümkündür ve bir piyasa birden çok sınıflandırmada yer alabilmektedir (Şekil 1.2).

Şekil 1.2. Piyasalar ve Türleri



Kaynak: (Moralı, 2011: 6)

1.2.1. Vadelerine Göre Finansal Piyasalar

Vade bakımından finansal piyasalar paraya piyasaları ve sermaye piyasaları olarak ikiye ayrılmaktadır.

1.2.1.1. Para Piyasaları

Para piyasası, hazine bonoları, devlet tahvilleri, finansman bonoları, ticari senetler, banka kredileri gibi bir günden bir yıla kadar olan fonların yani kısa vadeli kredi araçların kullanıldığı piyasadır (Civan, 2007: 7).

Para piyasasının ana kurumu ticari bankalardır. Bankalar da halktan toplanan mevduat hesabı biçimindeki fonlara göre likiditeye ihtiyacı olan işletmelere dönen varlıklarının finansmanında kullanılmak üzere kredi sağlamaktadırlar. Bankaların dışında çeşitli finansman kurumları, büyük şirketler, bankerler ve hazine de para piyasasının önemli kurumları arasındadır (Civan, 2007: 7; Kılınç, 1991: 15).

Uzun dönemli risklerin üstlenilmemiş olması kısa süreli bu piyasalarda işlem yapmanın en önemli avantajlarından biridir. Dolayısıyla bu piyasada işlem gören yatırım araçlarının risk ve getiri düzeyi sermaye piyasası araçlarına göre daha düşük olmasına rağmen daha güvenilirdir. Para piyasasındaki işlemler genelde sermaye piyasası işlemlerine göre daha geniş kapsamlıdır ve sermaye piyasasından işlem gören araçlara göre daha likittir. Bu nedenle kısa vadeli harcamalar finanse edilmek istenildiğinde, nakde çok kısa sürede çevrilebilmesi özelliğine sahip bu araçlar kullanılmaktadır (Hacıoğlu ve Dinçer, 2009: 35; Orhan ve Erdoğan, 2007: 32).

Tablo 1.1’de başlıca para piyasası araçları ve bu araçları ihraç eden kurumlar gösterilmektedir.

Tablo 1.1. Para Piyasası Araçları

ARAÇLAR	İHRAÇ EDEN
Hazine Bonoları	Hükümetler
Mevduat Sertifikaları	Bankalar ve Tasarruf Kuruluşları
Finansman Bonosu	Bankalar, Finansman Şirketleri ve Diğer Şirketler
Eurodolar Mevduat	Uluslararası Bankalar
Kabul Kredisi	Bankalar
Merkez Bankası Fonları (Bankalararası Piyasa)	Mevduat Kurumları
Repo Sözleşmeleri	Firmalar ve Finansal Kuruluşlar

Kaynak: (Günel, 2007: 25)

1.2.1.2. Sermaye Piyasaları

Sermaye piyasası, orta ve uzun vadeli fon arz ve talebinin karşılaştığı piyasadır. Söz konusu piyasa için hisse senedi, tahvil ve benzeri pazarlanabilir menkul kıymetlerin alınıp satıldığı yerler tanımı da yapılabilmektedir. Sermaye piyasası daha dar çerçevelidir ve esas finansal piyasanın bir alt bölümü olarak görülmektedir. Bu piyasanın temel özelliği orta ve uzun vadeli (bir yıldan fazla) fonlardan oluşmasıdır (Kılınç, 1991: 15–16; Moralı, 2011: 8).

Sermaye piyasasında, fonlar genellikle hisse senedi, tahvil gibi uzun ya da sonsuz vadeli finansal varlıklar karşılığında el değiştirir (Haznedaroğlu, 2009: 5). Sermaye piyasasından sağlanan krediler, işletmelerin bina, makine ve teçhizat gibi duran varlıklarının finansmanında kullanılmaktadır. Para piyasalarında olduğu gibi, sermaye piyasasının kaynakları da tasarruf sahiplerinin birikimleridir (Sermaye Piyasası Lisanslama, 2017: 2; Kılınç, 1991: 15–16).

İşletmeler para piyasasına genellikle işletme sermayesi gereksinimlerini karşılamak üzere başvururken, sermaye piyasasına, uzun süreli yatırım projelerini finanse etmek, sermayelerini arttırmak üzere başvurumaktadırlar. Kaynakların uzun süre devamlılık arz eden kişisel ve kurumsal tasarruflardan oluşması ve bunların vadelerinin uzun olması nedeniyle sermaye piyasasında risk ve buna bağlı olarak faiz oranları para piyasasına göre daha yüksektir (Haznedaroğlu, 2009: 5–6; Moralı, 2011: 8).

Sermaye piyasasında tasarrufların direkt olarak ihtiyaç sahiplerine aktarılması güç olduğundan fon arz ve talebi yardımcı kuruluşlar aracılığı ile yapılmaktadır. Tasarrufların değerlendirilmesinde hem tasarruf sahiplerinin hem de tasarruf ihtiyacı olanların risk ve karlılık konusundaki tercihleri birbirinde farklı olabilmektedir. Aynı tercihleri olan kimselerin ise birbirlerini bulmaları ve fon alışverişi yapmaları oldukça zordur. Bu durumda iki tarafın da, risk ve karlılık konusundaki tercihlerini bağdaştıracak ve tasarrufların en etkin şekilde ihtiyaç duyulan alanlara yönltilmesini sağlayacak bir mekanizmaya ihtiyaç duyulmaktadır. Bu mekanizmaya finansal aracılık “Financial Intermediation” denilmektedir (Çapanoğlu, 1993: 4).

Sermaye piyasası, yetkilerini kendi sorumluluğu altında bağımsız olarak kullanan, idari ve mali özerkliğe sahip düzenleyici bir kamu kurumu olan Sermaye Piyasası Kurulu (SPK) tarafından düzenlenmekte ve denetlenmektedir. Hiçbir organ, makam, merci veya kişi SPK’nın kararlarını etkilemek amacıyla emir ve talimat veremez. SPK’nın para,

evrak ve her türlü malları devlet malı hükmündedir, haczedilemez ve rehnedilemez. Başbakan tarafından görevlendirilen Devlet Bakanlığına bağlıdır (Borsa İstanbul, 2014: 6).

Sermaye piyasasındaki bu düzenlemelerin amacı sermaye piyasalarının işleyiş kurallarının belirlenmesi, sermaye piyasasının güvenilir, şeffaf, etkin, istikrarlı, adil ve rekabetçi bir ortamda işleyişinin ve gelişmesinin sağlanması, yatırımcıların hak ve menfaatlerinin korunmasını sağlamaktır (Borsa İstanbul, 2014: 4-5). Sermaye piyasasının (Borsa İstanbul, 2014: 4);

- Halkı tasarrufa teşvik ederek tasarrufların menkul kıymetlere yatırılması suretiyle halkın ekonomik kalkınmaya etkin bir şekilde katılımını sağlamak,
- Mal ve hizmet üreten sanayiciye ve girişimciye düşük maliyetle kaynak elde tutma imkânı sunmak,
- Sermayenin tabana yayılmasını sağlamak ve yapılan yatırımlarla işsizlik sorununun çözümüne katkıda bulunmak,
- Özel sektörü güçlendirmek ve gayri safi milli hasılayı büyütmek,
- Özelleştirmelerin daha kolay ve istenilen düzeyde yapılmasına imkân sağlamak,
- Halka arzları nicelik ve nitelik bakımından artırmak,

gibi faydaları bulunmaktadır.

Bu piyasanın en önemli araçları hisse senetleri ve tahvillerdir. Tablo 1.2’de başlıca sermaye piyasası araçları, vadesi ve bu araçları ihraç eden kurumlar görülmektedir.

Tablo 1.2. Sermaye Piyasası Araçları

ARAÇLAR	İHRAÇ EDEN	VADESİ
Devlet Tahvilleri	Hükümetler	1-30 yıl
Belediye Tahvilleri	Belediyeler	10-30 yıl
Şirket Tahvilleri	Şirketleri	10-30 yıl
İpotek Senetleri	Bireyler ve Şirketler	15-30 yıl
Hisse Senetleri	Şirketler	

Kaynak: (Günel, 2007: 29)

1.2.2. İşlemlerine Göre Finansal Piyasalar

Para ve sermaye piyasası araçlarına ilişkin olarak yapılan işlemlerin hangi piyasada yapıldığına göre birincil piyasa ve ikincil piyasa olmak üzere ikiye ayrılmaktadır.

1.2.2.1. Birincil Piyasalar

Birincil piyasalar, firmaların ve kamunun fon tedarik etmek amacıyla hisse senedi ve tahvil gibi menkul değerleri ilk defa ihraç ettikleri ve fon arz edenlerle yani tasarruf sahipleri ile doğrudan doğruya karşılaştıkları piyasalardır (Civan, 2007: 20; Günal, 2007: 20; Kılınç, 1991: 16; Orhan ve Erdoğan, 2007: 31). Diğer bir ifade ile birincil piyasalar, borçlanmak isteyenlerin ihraç ettikleri yen (birinci el) borçlanma senetlerini, ödünç vermek isteyenlere satmak suretiyle fon ihtiyaçlarını karşılayabildikleri piyasalardır (Orhan ve Erdoğan, 2007: 31). Bu piyasaya ayrıca hisse senetleri ile tahvillerin ilk kez sürülüp “ihraçtan alındığı piyasa” da denilmektedir (Civan, 2007: 20; Kılınç, 1991: 16).

Birincil piyasalarda, üretim kapasitelerini genişletmek isteyen firmaların yanı sıra hükümetler de borçlanma talebinde bulunabilmektedirler. Bu piyasalarda bulunan menkul değerlerin satışına yatırım bankaları yardım etmektedirler (Orhan ve Erdoğan, 2007: 31). Arada şirketin bizzat bulunmayıp bir banka ya da aracı kurumun bulunması bu alımın birincil piyasadan olmasına engel taşımamaktadır (Kılınç, 1991: 16). Menkul değerler ilk defa işlemi burada görürler ve ikincil, üçüncül piyasalara, genellikle transfer edilir (Civan, 2007: 20).

Birincil piyasalardaki işlemler, menkul kıymeti ilk ihraç edene fon sağlamaktadır. Hazinesinin yeni bir bono veya tahvil ihraç etmesi veya bir şirketin yeni hisse senedi ihraç etmesi bir birincil piyasa işlemidir (Günal, 2007: 20).

1.2.2.2. İkincil Piyasalar

İkincil piyasalar, birincil sermaye piyasalarına daha önce sunulmuş ve halen dolaşımda bulunan menkul kıymetlerin işlem gördüğü, alınıp satıldığı piyasalardır. Menkul kıymetleri ihraçtan satın alanlar bunları likite döndürmek için satmak istediklerinde ikincil piyasada işlem gerçekleştirirler. İkincil piyasaların en önemli kurumları menkul kıymetler borsaları ve finansal aracı kuruluşlardır.

İkincil piyasalar, sermaye piyasasına yeni menkul kıymet arzı ile değil, fakat mevcutlarının el değiştirmesi ile var olmaktadır. İkincil piyasaların iyi çalışabilmesi, fiyat ve işlem hacmi ile ilgili olarak geçmişe ilişkin ve mevcut arz ve talebe ilişkin zamanında ve doğru bilgilerin sağlanmasına, likiditenin varlığına, işlem maliyetlerinin mümkün

olduğunca düşük olmasına ve fiyatların yeni bilgiler ışığında güncellenmesine bağlıdır (Civan, 2007: 21; Moralı, 2011: 9).

Kişilerin ikincil piyasalarda işlem görmesinin iki temel nedeni vardır. Bunlardan biri bilgi diğeri ise likiditedir. İkincil piyasalarda işlem gören menkul kıymetler hakkında diğeri piyasalara göre daha iyi bilgi alınır. Bu piyasalar, finansal araçların satışını kolaylaştırarak, nakit sıkışıklığının giderilmesine katkı sağlamaktadır (Orhan ve Erdoğan, 2007: 31). Ayrıca, İkincil piyasa menkul değerlerin likiditesini artırarak, birincil piyasaya talep yaratır ve gelişmesini sağlar (Kılınç, 1991: 16).

Mevcut hisse senetleri veya hazine kâğıtlarının bireyler veya kurumlar tarafından alım-satımı bir ikincil piyasa işlemidir (Günel, 2007: 20).

1.2.3. Örgütlenme Şekillerine Göre Finansal Piyasalar

Örgütlenme şekillerine göre finansal piyasalar; para piyasalarında örgütlenmiş para piyasaları ve örgütlenmemiş para piyasaları, sermaye piyasalarında ise organize ve organize olmamış sermaye piyasaları olarak sınıflandırılmaktadır.

Örgütlenmiş para piyasaları işlemlerin belirli kurallara göre yapıldığı piyasalardır. Ticari bankalar bu piyasalar örnek olarak gösterilebilir çünkü işletmelerin nakit ihtiyaçları çoğunlukla tasarruf sahiplerinin fonları ile borçlanarak piyasaya fon oluşturan ticari bankalar tarafından karşılanmaktadır. Örgütlenmemiş para piyasaları ise yasal düzenlemelerin ve bankalar sisteminin dışında kalan piyasalardır. Bankalar dışındaki para piyasaları kurumları poliçe, çek, bono gibi yatırım araçlarını kullanarak işletmelere fon temin etmektedirler (Moralı, 2011: 7).

Organize sermaye piyasaları belirli bir mekânın olduğu, belirli kurallar dâhilinde finansal varlıkların el değiştirdiği, kişi ve kurumların doğrudan doğruya menkul kıymet alım satımı yapamadığı piyasalardır. Bu piyasalara en iyi örnek alım ve satımların aracı kurumlar aracılığı ile belirli kurallara göre borsa yönetiminin kontrolü altında yapılan menkul kıymet borsaları verilebilir. Organize olmamış piyasalar ise menkul kıymetlerin alım ve satımında belirli bir mekânın, belirli kural ve düzenlemelerin söz konusu olmadığı piyasalardır (Moralı, 2011: 10).

1.2.4. Spot ve Vadeli Piyasalar

İşlemlerin anında gerçekleştiği piyasalar spot piyasa, gelecekte bir tarihte gerçekleştiği piyasalar da vadeli piyasalar olarak adlandırılmaktadır. Hisse Senetleri Piyasası ve Tahvil, Bono piyasaları spot piyasalara; forward, swap, futures ve opsiyon işlemleri de vadeli piyasalara örnek olarak gösterilebilir (Moralı, 2011: 8).

1.3. Menkul Kıymetlerin Tanımı ve Unsurları

Menkul kıymetler, SPKn'nun 3 üncü maddesinin (o) bendinde; para, çek, poliçe ve bono hariç olmak üzere; paylar, pay benzeri diğer kıymetler ile söz konusu paylara ilişkin depo sertifikaları ve borçlanma araçları veya menkul kıymetleştirilmiş varlık ve gelirlere dayalı borçlanma araçları ile söz konusu kıymetlere ilişkin depo sertifikaları olarak tanımlanmaktadır. Kanunda "pay"ın tanımı yapılmamıştır; ancak, Sermaye Piyasası Kurulu (Kurul)'nun VII-128.1 sayılı "Pay Tebliği"nde ortaklığın sermayesini temsil eden ve sahibine ortaklık hakkı veren menkul kıymet olarak tanımlanmaktadır (Sermaye Piyasası Lisanslama, 2018: 2).

Yukarıdaki tanımla birlikte menkul kıymetlerin unsurları aşağıda maddeler halinde sunulmaktadır (Hacıoğlu ve Dinçer, 2009: 51; Moralı, 2011: 10–11).

- Yasal açıdan kıymetli evrak niteliğindedirler
- Belirli şekil şartlarına uygun düzenlenirler
- Çok sayıda ihraç edilebilirler
- Halka arz edilen kitle senetleridir
- Ticari senetler gibi tek bir ticari ilişki için düzenlenmezler
- Devamlılık gösterirler
- Alacak ya da ortaklık haklarını temsil ederler
- Dönemsel getiri sağlarlar
- Her birinin bir itibari değeri, bir de piyasa değeri vardır
- Nama (registered) ve hamiline (bearer) yazılı olabilirler
- Yatırım amacı için kullanılırlar

1.4. Menkul Kıymet Borsaları ve Borsa İstanbul

Borsalar, finansal piyasalara işlerlik kazandıran kurumların hiç kuşkusuz en önemlisidir. Menkul kıymet borsaları, kote edilmiş pay senetleriyle, tahvillerin, devlet

tahvillerinin ve diğ er finansal varlıkların alım satım iřlem lerinin ger ekleřtiđi, finansal varlıkların ger ek piyasa fiyatlarının saptanmaya  alıřıldıđı, fiyatların tespit ve ilan iřleriyle yetkili olan t zel kiřiliđe haiz kuruluřlardır. Menkul kıymet borsaları, kuruluřlarındaki yasal  zellikleri a ısından kanunla kurulan resmi kuruluřlar olan devlet borsaları ve anonim řirket stat s nde olup  zel hukuk h k mlerine g re oluřturulan  zel borsalar olarak iki grupta deđerlendirilebilir (Haznedarođlu, 2009: 7). Menkul kıymet borsalarının devamlı ve d zenli iřleyen bir pazarın oluřması, ekonomiye kaynak yaratması, sermaye m lkiyetini geniř bir toplum tabanına yayması, ekonominin g stergesi olması, uzun vadeli yatırımların kısa vadeli tasarruflarla finansmanını sađlaması, menkul kıymetlerle ilgili bilgilere kolay ulařılması ve g ven yaratması gibi ekonomik iřlevleri bulunmaktadır (Borsa İstanbul, 2014: 5).

1.4.1. Borsa Tanımı ve Faaliyetleri

1.4.1.1. Borsanın Tanımı

Borsa, 6362 Sayılı Sermaye Piyasası Kanunu'na (Kanun) g re řu řekilde ifade edilmektedir. Anonim řirket řeklinde kurulan, sermaye piyasası ara ları, kambiyo ve kıymetli madenler ile kıymetli tařların ve Kurulca uygun g r len diğ er s zleřmelerin, belgelerin ve kıymetlerin serbest rekabet řartları altında kolay ve g venli bir řekilde alınıp satılabilmesini sađlayan, oluřan fiyatları tespit ve ilan etmek  zere kendisi veya piyasa iřleticisi tarafından iřletilen ve/veya y netilen, alım-satım emirlerini sonu landıracak řekilde bir araya getiren veya bu emirlerin bir araya gelmesini kolaylařtıran, Kanuna uygun olarak yetkilendirilen ve d zeni faaliyet g steren sistemler ve pazar yerleridir. Borsaların ve piyasa iřleticilerinin kuruluřuna Sermaye Piyasası Kurulu'nun (Kurul) uygun g r ř   zerine Bakanlar Kurulu tarafından izin verilmekte ve bu kuruluřların faaliyete ge mesi Kurulun iznine tabi olmaktadır (Sermaye Piyasası Lisanslama, 2017: 4).

1.4.1.2. Borsanın Faaliyetleri

Borsalar, Kanunun 67'nci maddesine g re, sermaye piyasası ara larının, kambiyo ve kıymetli madenler ile kıymetli tařların ve Kurulca uygun g r len diğ er s zleřmelerin, belgelerin ve kıymetlerin g venilir, řeffaf, etkin, istikrarlı, adil ve rekabet i bir ortamda

kolay ve güvenli bir şekilde işlem görmesini sağlamak üzere aşağıdaki konularla ilgili faaliyetlerde bulunmaktadır (Borsa İstanbul, 2014: 6, Sermaye Piyasası Lisanslama, 2017: 4);

- Borsaların işletim, denetim ve gözetim sistemleri,
- Piyasa oluşturma, işletme ve yönetilmesi,
- Kota alınma, kottan çıkarılma ile borsada işlem görme ve işlem görmenin durdurulması,
- Emirlerin iletilmesi ve eşleştirilmesi,
- Borsada işlem yapma yetkisi verilmesi ve gerçekleştirilen işlemlere ilişkin yükümlülüklerin zamanında yerine getirilmesi,
- Borsa gelirleri ile bunların tahsili,
- Disiplin düzenlemelerinin yürütülmesi, uyuşmazlıkların çözülmesi ve borsa, borsanın pay sahipleri ve/veya piyasa işleticisi arasındaki muhtemel çıkar çatışmalarının önüne geçilmesi

1.4.1.3. Hukuki Çerçeve

Borsa İstanbul Anonim Şirketi (Borsa İstanbul veya Borsa), 30/12/2012 tarihli ve 6362 sayılı Sermaye Piyasası Kanunu'nun 67'nci maddesinde belirtilen borsacılık faaliyetlerinde bulunmak üzere Kanunun 138 inci maddesi ile kurulmuştur. Aynı hükümdeki düzenlemeye göre Borsa İstanbul A.Ş.'nin, esas sözleşmesinin ticaret siciline tescil edilmesiyle birlikte borsaların ve piyasa işleticilerinin kuruluşuna ve faaliyetine ilişkin izni alabileceği addedilmiştir (Sermaye Piyasası Lisanslama, 2017: 4).

Borsa İstanbul A.Ş. esas sözleşmesinin tescili ile İstanbul Menkul Kıymetler Borsasının (İMKB) ve İstanbul Altın Borsasının (İAB) tüzel kişilikleri sona ermiştir. İMKB ve İAB'nin her türlü varlıkları, borç ve alacakları, hak ve yükümlülükleri ile her türlü kayıtları ve belgeleri, herhangi bir işleme gerek kalmaksızın anılan Kanun gereğince Borsa İstanbul A.Ş.'ye devrolunmuştur. 03/04/2013 tarihinde de esas sözleşmesinin tescili ile faaliyete geçtikten sonra Vadeli İşlem ve Opsiyon Borsası A.Ş.'nin paylarının tamamını devralmıştır (Sermaye Piyasası Lisanslama, 2017: 5).

Borsa İstanbul'un başlıca kuruluş amacı, borsanın tanımı ve borsaların faaliyetleri alt konu başlıklarında da ifade edildiği üzere, Sermaye Piyasası Kanunu hükümleri ve ilgili mevzuat çerçevesinde (Borsa İstanbul, 2014: 6),

- Sermaye piyasası araçlarının, kambiyo ve kıymetli madenler ile taşların ve SPK'ca uygun görülen diğer sözleşmelerin, belgelerin ve kıymetlerin serbest rekabet şartları altında kolay ve güvenli bir şekilde, şeffaf, etkin, rekabetçi, dürüst ve istikrarlı bir ortamda alınıp satılabilmesini sağlamak,
- Sermaye piyasası araçlarına ilişkin alım-satım emirlerini sonuçlandıracak şekilde bir araya getirmek veya bu emirlerin bir araya gelmesini kolaylaştırmak,
- Oluşan fiyatları tespit ve ilan etmek üzere piyasalar, pazarlar, platformlar ve sistemler ile teşkilatlanmış diğer Pazar yerleri oluşturmak, kurmak ve geliştirmek,
- Pazar yerlerini ve başka borsaları ya da borsaların piyasalarını yönetmek ve/veya işletmektir

1.4.2. Hisse Senetleri

Hisse senetleri, anonim ortaklıklar tarafından çıkarılan ve belirli ortaklık sermayesine katılma payını temsil eden yasal şekil şartlarına uygun olarak düzenlenmiş, literatürde esham, aksiyon, pay senedi veya sadece hisse adı altında kullanılan kıymetli evraktır. Geniş ve bilimsel bir tanımlama ise şöyle yapılabilmektedir (Apak, 1995: 29).

Hisse senedi, sermayesi paylara bölünmüş ve karşılığında kıymetli evrak niteliğinde hisse senedi çıkarabilen Anonim ortaklık veya sermaye paylara bölünmüş Komandit ortaklıkların kanuni şekillere uygun olarak düzenledikleri belgeler olup, sermayesinin belirli bir oranını temsil eden sahiplerine o oranda ortaklık hakkı sağlayan senetlerdir.

Basitçe ifade edecek olursak sermaye piyasası araçları arasında özel bir yeri olan hisse senetleri şirketin iktisadi varlıkları üzerindeki mülkiyet hakkını temsil eden bir menkul kıymettir. Hisse senedi ihraç etme hakkına sahip sermaye şirketinin sermayesi belli paylara bölünür ve her bir pay karşılığında bu sermayeyi sağlayanlara hisse senedi verilir. Bir şirketin esas sermayesi ya da çıkarılmış sermayesi dolanımında bulunan hisse senetlerinin üzerinde yazılı olan nominal değerler toplamına eşittir. Herhangi bir şirketin hisse senedini alan yatırımcı şirketin bütün faaliyet ve finansal risklerine katlanmakla beraber otomatik olarak aşağıdaki standart haklardan yararlanma imkânına kavuşurlar (Dağlı, 2009: 5–6).

Kardan pay alma hakkı: Şirketin kar elde etmesi ve gerekli karşılıkları ayırdıktan sonra belli bir bölümünü dağıtmaya karar vermesi durumunda hisse senedi sahipleri ortaklık oranı kadar bu kardan pay alırlar.

Şirketin yönetimine katılma ve oy kullanma hakkı: Hisse senedi sahipleri genel kurul toplantılarına katılırlar ve her bir hisse için bir oy kullanma hakkına sahip olurlar. Genel kurulda oy kullanarak aldıkları kararlarla yönetim kurulun oluştururlar ve böylece yönetime katılmış olurlar.

Rüçhan hakkı: Şirketteki sermayeye katılma oranının korunması için hisse senedi sahibine rüçhan hakkı tanınarak sermaye artırımlarında yeni çıkarılacak hisse senetlerinin öncelikle mevcut ortaklara satılması öngörülür. Ancak mevcut ortakların bu satışa katılmak istememeleri durumunda dışarıdaki diğer gruplara müracaat edilebilir.

Tasfiyeden pay alma hakkı: Şirketin tasfiye olması durumunda, diğer yükümlülükler karşılandıktan sonra geriye bir bakiye kalırsa, her ortak, sermaye oranında bundan pay alma hakkı bulunmaktadır.

Bilgi edinme hakkı: Ticari sırlar dışında, her hissedar şirketin faaliyetleri hakkında bilgi edinme hakkına sahiptir. Şirket faaliyet sonuçlarını, verdiği önemli yatırım, finansman ve kar dağıtım kararlarını ve diğer önemli kararları kamuyla paylaşarak bu olanağı sağlamaktadır.

Standart nitelikte bütün adi hisse senedi sahipleri için geçerli olan bu haklar şirketin özellikle imtiyazlı hisse senetleri ve oydan yoksun hisse senetleri gibi değişik tipte ve türde hisse senedi ihraç ederek bu hakların bir bölümünde sınırlama ve iyileştirme yapabilmektedir.

1.4.2.1. Hisse senedi çeşitleri

Hisse senetleri eski Türk Ticaret Kanunu'nun 409. Maddesine göre hamiline ve nama yazılı olmak üzere ikiye ayrılırlar. Bu ayrımın dışında hisse senetleri imtiyazlı ve adi hisse senetleri ile kurucu ve intifa hisse senetleri şeklinde başka bir şekilde de sınıflandırılırlar (Apak, 1995: 31). Ancak, dolanım kabiliyeti, satış şekli ve karşılığının ödenme şekli gibi konular açısından aşağıdaki gibi bir sınıflandırma yapmak da mümkündür (Dağlı, 2009: 9).

- Adi ve imtiyazlı hisse senetleri

- Nama yazılı ve hamiline ait hisse senetleri
- Bedelli ve bedelsiz hisse senetleri
- Primli ve primsiz hisse senetleri
- Nakit karşılığı ve aynı sermaye karşılığı çıkarılan hisse senetleri
- Oydan yoksun hisse senetleri

6102 sayılı yeni TTK'ya göre anonim şirketlerde “ortak”, pay sahiplerini ifade etmektedir ve pay sahipliği hamiline ya da nama yazılı “pay senetleri” ile geçerlilik kazanmaktadır. Pay senedi ifadesi, 01.07.2012 tarihinden itibaren “hisse senedi” ifadesi yerine kullanılmaya başlanmıştır (www.orhansarigene.com, 2019) ancak çalışmada hala yaygın olarak kullanılan hisse senedi ifadesi tercih edilmiştir.

1.4.2.2. Hisse Senedi Değer Kavramları

Hisse senedinin değer tanımlamaları hisse senedi verimliliğinin saptanmasında kullanılan ölçümlerde ve analizlerde ele alınan tanımlamalardır. Bunların başlıcaları aşağıda maddeler halinde tanımlamaları ile birlikte verilmiştir (Apak, 1995: 32–33).

Net Aktif Değeri: Hisse senedinin belirli bir faaliyet dönemi sonunda (genellikle bir yıl sonunda) düzenlenen bilançoadaki net aktif tutarıdır.

Öz Sermaye Değeri: Şirket özsermayesinin ödenmiş sermayeye göre hisse senedi adedine bölünmesi ile ortaya çıkan değerdir.

Defter Değeri: Belli bir dönemdeki şirket mal varlığına göre hesaplanmış değeri ifade etmektedir.

Tasfiye Değeri: Şirketin iktisadi varlıklarının belirli bir süre içinde zorunlu olarak teker teker satışı ile sağlanabilecek değerden tüm borçlar ödendikten sonra kalan miktarın hisse senedi sayısına bölünmesi ile bulunan değerdir (Dağlı, 2009: 14).

Borç Değeri: Şirketin belli bir anda (borç değerinin anlamı olması için birbirini izleyen yıllar itibarıyla değerlendirme yapmak gerekir) yabancı kaynaklar (Borçlar) toplamının hisse senedi sayısına bölünmesi ile bulunan değerdir.

Alternatif Gelir Değeri: Ortaklar tarafından oluşturulan sermayenin, şirket içinde şirket sermayesi şeklinde kullanılıp başka bir yatırım alanında değerlendirilmiş olması halinde, hisse senetlerine yatırılan sermaye miktarı ile elde edilebilecek alternatif gelirden bir hisseye düşen gelir tutarını gösteren değerdir.

İşleyen Teşebbüs Değeri (Going concern value): Bir şirketin çalışır vaziyette bir bütün olarak satılması veya devredilmesi durumunda elde edilen satış gelirinden borçların düşülmesi sonucu kalan meblağın hisse senedi sayısına bölünmesi suretiyle hesaplanan değerdir (Dağlı, 2009: 15).

1.4.2.3. Hisse Senedi Fiyat Tanımlamaları

Hisse senedi fiyat tanımlamalarında başlıca tanımlamalar, nominal fiyat (itibari fiyat), ihraç fiyatı (emisyon fiyatı), piyasa fiyatı ve borsa fiyatıdır (Apak, 1995: 33–34).

Nominal fiyat: Bir hisse senedinin nominal fiyatı üzerinde yazılı olan ve muhasebe kayıtlarına geçirilen değerdir. İtibari değer, yazılı değer, kayıtlı değer, saymaca değer veya başabaş değer olarak da adlandırılmaktadır (Dağlı, 2009: 12).

İhraç fiyatı: Hisse senetlerinin şirket tarafından çıkarılışı aşamasında satışa sunulduğu fiyatıdır. Hisse senetleri SPK onayı ile nominal fiyatla ihraç edebileceği gibi serbest fiyatlarda ihraç edilebilmektedir.

Piyasa fiyatı: Piyasadaki arz ve talep koşullarına göre belirlenen ve borsa mevcutsa borsa fiyatı ile eş anlamlı olarak kullanılan fiyattır.

Borsa Fiyatı: Borsada işlem görmeye başlayan hisse senetlerinin borsadaki arz ve talep koşullarına göre oluşan fiyatlarıdır. Borsanın işleyişine göre fiyatlar günlük olarak belirlenmekte ve en yüksek, ortalama, günlük fiyat gibi türlere ayrılmaktadır.

1.4.3. Hisse Senedi İşlemleri

Borsalarda hisse senetlerinin birincil ve ikincil piyasa işlemleri yapılabilmektedir. Ancak, esas ağırlık ikincil piyasa işlemlerine verilmektedir. Borsalar, hisse senetlerinin şirketler tarafından ihraç edildikten sonra yatırımcılar arasında işlem görmelerine imkân sağlayan ve dolayısıyla hisse senetlerine likidite sağlayan yerlerdir. Borsalarda ikincil piyasanın işleyişi yatırımcılar açısından büyük önem arz etmektedir (Dağlı, 2009: 82). Bu nedenle, bu bölümde İMKB’de hisse senedi piyasasının işleyişi hakkında bilgi verilecektir.

1.4.3.1. İkincil Piyasa İle İlgili Temel Kavramlar

İkincil piyasa işlemleri ile ilgili önemli bazı kavramlardan aşağıda maddeler halinde açıklamalarıyla birlikte sunulmaktadır (Dağlı, 2009: 82–87).

Borsa seansı: Hisse senetleri her işgünü borsada belirli saatler arasında işlem görebilirler. Hisse senetlerinin işlem görmeye başladığı zaman ile işlemlerin bitirildiği zaman arasında geçen süreye borsa seansı denilmektedir. Hisse senedi alım satım işlemleri sadece seans içinde yapılabilir. Borsa seansının süresi ve adedi hisse senetlerinin işlem gördüğü pazara göre değişir. Örneğin, ulusal pazarda bir günde iki seans vardır. İlki öğleden önce saat 09:30'da başlar ve 12:30'da sona erer. İkincisi ise öğleden sonra 14:00'da başlar ve 17:00'da sona erer. Aynı pazarda işlem gören bütün hisse senetlerinin seansı aynı anda başlar ve biter.

İşlem miktarı: Bir seansta ya da belirli bir dönemde (gün, hafta, ay gibi) işlem gören (alım-satıma konu olan) hisse senedi sayısıdır.

İşlem hacmi: Hisse senedi ile işlem gördüğü fiyatın çarpımı sonucu elde edilen değerdir.

Sözleşme sayısı: İki taraf (alıcı-satıcı) arasında gerçekleşen her işlem için ayrı bir sözleşme düzenlenir. Bu anlamda, verilen alış ya da satış emirleri en az bir olmak üzere çok sayıda sözleşme ile gerçekleştirilebilir. Hisse senetleri için belli bir dönemde düzenlenen sözleşmelerin toplamına sözleşme sayısı adı verilir.

En yüksek fiyat: Belli bir dönemde hisse senedinin gerçekleşen en yüksek fiyatıdır.

En düşük fiyat: Belli bir dönemde hisse senedinin gerçekleşen en düşük fiyatıdır.

Kapanış fiyatı: Belli bir dönemde hisse senedinin en son gerçekleşen fiyatıdır.

Açılış fiyatı: Hisse senedinin açılış seansında belirlenen fiyatıdır.

Ağırlıklı ortalama fiyat: Değişik fiyat ve miktarlardan gerçekleşen ve fiyatı tescil edilen normal emirler dikkate alınarak belirli bir dönem için miktar ağırlıklı ve küsuratsız (küsurlar yukarı ya da aşağıya doğru düzeltilerek tam sayıya dönüştürülür) olarak hesaplanan hisse senedinin ortalama fiyatıdır.

Baz fiyat: Hisse senedinin seans içinde işlem göreceği fiyat aralıklarının ve fiyat adımlarının (kademe) belirlenmesinde esas alınan fiyattır.

Fiyat adımı: Her hisse senedi için artış ya da azalış yönünde bir defada gerçekleşebilecek en küçük fiyat değişimidir.

Fiyat aralığı (marjı): Hisse senedi fiyatlarının aşırı dalgalanmasını önlemek amacıyla. Bir hisse senedi için seans içinde oluşabilecek en düşük(taban) fiyat ile en yüksek (tavan) fiyat arasındaki farktır. Seans içinde fiyatların belli bir aralık dâhilinde işlem görmesine izin verilerek hisse senedi fiyatlarının aşırı dalgalanması önlenmiş olur.

1.4.3.2. Hisse Senedi Pazarları

İMKB’de hisse senetleri ulusal pazar, ikinci ulusal pazar, yeni ekonomi pazarı, toptan satışlar pazarı ve diğer pazarlar gibi değişik pazarlarda işlem görmektedirler (Dağlı, 2009: 88); ancak Sermaye Piyasası Kurulu tarafından 14/07/2015 tarihinde onaylanan Kotasyon Yönergesi (Yönerge) ile Pay Piyasasında yer alan mevcut pazar yapısı ve isimleri değiştirilmiştir. Gelişen İşletmeler Piyasası, Pay Piyasası bünyesine Gelişen İşletmeler Pazarı (BIST Emerging Companies) olarak alınmıştır. Pay Piyasası altında yer alan Ulusal Pazar ve İkinci Ulusal Pazar kaldırılmış, **Yıldız Pazar** (BIST Star) ve **Ana Pazar** (BIST Main) adında yeni iki Pazar oluşturulmuştur. (Borsa İstanbul, 2015). Pay piyasasında işlemlerin gerçekleştiği bu pazarlar ve diğer pazarlar Tablo 1.3’de tanım ve sembolleriyle birlikte gösterilmektedir.

Tablo 1.3. Pay Piyasasında İşlemlerin Gerçekleştiği Pazarlar

PAZAR	TANIM	SEMBOL
YILDIZ PAZAR	Halka açık piyasa değeri 100 M TL’nin üstünde olan şirketler ya da BIST100 kapsamındaki şirketlerin Borsa İstanbul bünyesinde işlem görebileceği pazardır.	Z
ANA PAZAR	Halka açık piyasa değeri 25 milyon TL’nin üzerinde ve 100 M TL’nin altında olan şirketlerin Borsa İstanbul bünyesinde işlem görebileceği pazardır.	N
GELİŞEN İŞLETMELER PAZARI	Gelişme ve büyüme potansiyeline sahip, halka açık piyasa değeri 25 M TL’nin altında olan şirketlerin Borsa İstanbul bünyesinde işlem görebileceği pazardır.	G

YAKIN İZLEME PAZARI	Belirli gelişmelerin oluşması halinde Yıldız Pazar, Ana Pazar, Gelişen İşletmeler Pazarı ve Kolektif Yatırım Ürünleri ve Yapılandırılmış Ürünler Pazarı'ndan çıkarılan şirketlerin paylarının Borsa İstanbul bünyesinde işlem görebileceği pazardır.	W
KOLEKTİF YATIRIM ÜRÜNLERİ VE YAPILANDIRILMIŞ ÜRÜNLER PAZARI	Menkul kıymet yatırım ortaklıkları, gayrimenkul yatırım ortaklıkları ve girişim sermayesi yatırım ortaklıkları payları ile borsa yatırım fonları katılma belgeleri, aracı kuruluş varantları ve sertifikalar kot içi pazar niteliğindeki Kurumsal Ürünler Pazarı'nda işlem görmektedir.	K
NİTELİKLİ YATIRIMCI İŞLEM PAZARI	Halka arz olmadan sadece nitelikli yatırımcılara ihraç yapan şirketlerin paylarının sadece nitelikli yatırımcılar arasında işlem görebileceği pazardır.	Q
PİYASA ÖNCESİ İŞLEM PLATFORMU	Halka açık statüde olup, payları Borsada işlem görmeyen şirketlerden, SPK tarafından bu Platformda işlem görmesine karar verilenlerin payları Piyasa öncesi işlem platformunda işlem görecektir (eski uygulamadaki Serbest işlem platformu).	S

Kaynak: (Borsa İstanbul, 2019)

1.4.3.3. Emirler

Hisse senedi piyasasında ikincil piyasa işlemleri verilen **emirler** vasıtasıyla yapılmaktadır. Emirler müşteri emirleri ve borsa emirleri olmak üzere iki ana gruba ayrılabilir. Hisse senedinin alım ve satımıyla ilgili olarak müşteri tarafından borsa üyesi aracı kuruma iletilen emir **müşteri emri** adını almaktadır. Müşterinin aracı kuruma ilettiği alış ya da satış emrini (müşteri emri) serbest fiyatlı ya da limit fiyatlı olarak aracı kurumun borsadaki temsilcisine aktarması ve temsilcinin de bunu seans içinde bilgisayar sistemine girmesi durumunda müşteri emri **borsa emri** haline gelmektedir. Bu emirlerin dışında **limit fiyatlı emir** ve **serbest fiyatlı emir (pazar emri)** gibi emirlerde verilmektedir (Dağlı, 2009: 93).

1.5. Menkul Kıymetler Analiz Yöntemleri

Sermaye pazarında yatırım yapan kişi ve kuruluşlar yatırım yaptıkları pazarı iyi tanımak ve takip etmek zorunda olduklarından bireysel ve kurumsal tüm yatırımcılar genel ekonomi, sektörler ve yatırım yaptıkları kuruluşlar ile ilgili olarak tüm ekonomik

ve finansal bilgileri doğru ve hızlı bir şekilde temin ederek piyasa tahmininde bulunmaları gerekmektedir (Moralı, 2011: 13–14); ancak insanların duygu ve beklentilerini önceden tahmin etmenin zorlukları, düşünülebilecek her türlü analiz sisteminin tamamen (%100) başarılı olma şansını azaltmakla beraber fiyatları belirleyen insanların (piyasa profesyonelleri, kurumsal yatırımcılar, spekülâtörler, manipülâtörler ve her kesimden yatırımcılar) değişik kültür, eğitim, bilgi yapılarınsa sahip olması durumu daha da zorlaştırmaktadır (Haznedaroğlu, 2009: 11).


Bu bölümde piyasa tahmini yapabilecek literatürde tartışılmış ve denenmiş temel analiz, teknik analiz, portföy analizi ve istatistiki tahmin yöntemi gibi en sık kullanılan yöntemlerden bahsedilecektir (Moralı, 2011: 14).

1.5.1. Temel Analiz

Hisse senetlerinin değerlendirilmesinde kullanılan en geniş kapsamlı yöntem olan temel analizde hisse senetlerinin değerine etki edebilecek bütün olası faktörler dikkate alınarak hisse senedinin gerçek değerinin hesaplanmasına çalışılır. Hisse senedinin değerini etkileyebilecek faktörler ekonomi analizi, endüstri analizi ve firma analizi olmak üzere üç ana başlık altında toplanarak incelenebilir. Bu analizlerin sonucunda hisse senedinin risk ve getiri ilişkisi ortaya konarak çeşitli yöntemler yardımıyla gerçek değeri hesaplanmaktadır. Hesaplanan gerçek değer piyasa değerinden daha yüksek ise hisse senedi satın alınır; aksi takdirde satın alınmaz veya satılır (Dağlı, 2009: 189).

Temel analizde sırasıyla ekonomi analizi, endüstri analizi, firma analizi, risk ve getiri tahmini gibi aşamalar bulunmaktadır. Temel analizin ilk aşamasını ekonomi analizi oluşturur. Bu analiz ile genel ekonomik koşullardan etkilenen hisse senetlerine yatırım için genel ekonomik konjonktürün uygun olup olunmadığına bakılır. Ekonomi analizinden hisse senedi yatırımı için olumlu bir sonuç çıktığında temel analizin ikinci aşaması olan endüstri analizine geçilir. Bu aşamada da, ekonomideki çok sayıda endüstriler arasında hangisi veya hangilerine yatırım yapılması gerektiği belirlenmeye çalışılır (Dağlı, 2009: 189–208). Şekil 1.3’de temel analizin aşamaları şematik olarak görülmektedir.

Şekil 1.3. Temel Analizin Aşamaları



Kaynak: (Dağlı, 2009: 190)

Ekonomi, endüstri ve firma analizi aşamalarından sonra çeşitli yöntemler kullanılarak hisse senedinin gerçek değerinin hesaplanması aşamasına geçilmektedir. Hisse senedinin gerçek değerinin belirlenmesinde dört ana yaklaşımdan yararlanılmakta ve bu yaklaşımların büyük ölçüde birbiriyle uyumlu sonuçlar verdiği gözlenmektedir. Bu yaklaşımlar (Dağlı, 2009: 209–258);

Kar payı iskontosu modeli: Gelecekte sağlanacak kar paylarının belirli bir iskonto üzerinden bugüne indirgenmesini esas alan bir yöntemdir.

Fiyat-kazanç oranı modeli: Hisse senedi fiyatının bu hisse senedinden elde edilen kaza nca oranıdır. Buradaki kazanç, tüm giderlerin ve verginin ödenmesinden sonra hissedarlara kalan net karı göstermektedir.

Piyasa değeri defter oranı modeli: Firmanın toplam öz sermaye tutarının dolanımdaki hisse senedi sayısına oranıdır.

Piyasa değeri nakit akış oranı modeli: Hisse başına gelirin hesaplanmasında kullanılan net kara amortismanlar gibi gerçekte nakit çıkışı gerektirmeyen bir takım giderlerin düşülmesiyle ulaşılan orandır.

1.5.2. Teknik Analiz

Teknik analiz, belirli piyasa verilerini kullanarak hisse senedi fiyatlarının ve piyasasının yönünü belirlemeyi amaçlayan bir analiz türüdür. Teknik analizde kullanılan piyasa verileri, hisse senedi piyasa endeksi veya hisse senetleri ile ilgili fiyat işlem hacmi bilgilerinden oluşmaktadır. Teknik analizciler geçmişteki piyasa verilerine dayanarak hisse senedi fiyatlarının gelecekteki yönünü kestirmeye çalışırlar. Teknik analizin hisse senedi fiyatlarının tahmininde kullanılabilmesi için aşağıdaki varsayımların kabul edilmesi gerekmektedir (Dağlı, 2009: 259–260):

- Hisse senedinin piyasa fiyatı sadece kendisiyle ilgili arz ve talebin karşılıklı etkisiyle oluşur
- Hisse senedi arz ve talebi bir kısmı rasyonel, bir kısmı irrasyonel pek çok faktörün etkisi altında şekillenir.
- Piyasadaki küçük dalgalanmalar dikkate alınmadığında, hisse senedi fiyatları uzun süre devam eden belirli bir trend doğrultusunda hareket ederler
- Trenddeki kesintiler, arz ve talepteki kavramlar sonucu meydana gelir
- Kaynağına bakılmaksızın, arz ve talepteki kaymalar er veya geç piyasa verilerini işaretlediği grafikler vasıtasıyla tespit edilebilir.
- Çoğu grafiklerdeki fiyat hareketleri zaman içinde aynen tekrarlanır. Yani hisse senedi fiyatlarının bir hafızası bulunmaktadır.

Teknik analizde esas itibarıyla destek ve direnç seviyeleri, işlem hacmi, baş ve omuz formasyonu, çubuk çizgi, mum, nokta ve şekil grafikler ve hareketli ortalamalar, nispi güç analizi, fiyatı artan ve azalanlar, güven endeksi, açığa satış oranı ve lot altı işlemleri teorisi gibi teknik göstergeler olmak üzere iki grup araçtan yararlanılmaktadır. Bunlar (Dağlı, 2009: 259–282);

1.5.3. Portföy Analizi

Portföy analizi basitçe riski az getirisi yüksek portföylerin belirlenmesi konusunu kapsayan bir risk-getiri analizidir. Birden fazla ekonomik gelişme şartlarında bir hisse

senedinin getirisi deęişiklik göstermektedir. Portföy analizinde, risk ve getiri doğru orantılı olup her bir ekonomik durumun o yıl için meydana geliş olasılığı geçmişteki veriye bakarak tahmin edilmektedir. Ancak portföy birden fazla menkul kıymetten oluştuğundan dolayı öncelikle portföye giren menkul kıymetlerin (yatırım araçlarının) risk ve getirilerinin birbirlerinden bağımsız olarak incelenmesi gerekmektedir. Daha sonra ise menkul kıymetlerin birbirleri arasındaki ilişkiler dikkate alınarak uygun bir portföy oluşturulmakta veya mevcut bir portföyün risk ve getirisi belirlenmektedir (Apak, 1995: 186; Dağı, 2009: 291).

1.5.4. İstatistiki Tahmin Yöntemleri

Geleceęi öngörmeye yönelik olarak kullanılan zaman serileri analizi ile serilerin tahmin dönemi dışında geleceęe yönelik tavırlarının belirlenmesine çalışılmaktadır. Geleneksel zaman serisi tarihi veriyi analiz ederek bu tarihi verinin doğrusal kombinasyon biçiminde gelecekteki yaklaşık deęerini hesap etmeye çalışmaktadır. Diğer bir ifadeyle bir deęişkene ait doğrusal olmayan deęerlerinin sürekli olarak geçmiş deęerleri ile bağlantılı olarak bir model kurmaya çalışılmaktadır. Ekonometride temel olarak tek deęişkenli ve çok deęişkenli olmak üzere 2 türde zaman serisi tahmin yöntemi bulunmaktadır (Moralı, 2011: 16).

İKİNCİ BÖLÜM

2. MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME KAVRAMLARI VE İLGİLİ LİTERATÜR TARAMASI

Makine öğrenmesi kavramına geçmeden önce değişik şekillerde tanımlanmakta olan öğrenme kavramına bakmak gerekmektedir. Bu tanımlardan geniş kabul gören tanım Simon tarafından önerilmektedir. Bu tanıma göre öğrenme, “Zaman içinde yeni bilgilerin keşfedilmesi yoluyla davranışların iyileştirilmesi sürecidir”. Makine öğrenmesi ise “Bilgisayarların bir olay ile ilgili bilgileri ve tecrübeleri öğrenerek, gelecekte oluşacak benzeri olaylar hakkında kararlar verebilmesi ve çözümler üretebilmesidir” (Öztemel, 2012: 21). Yapay zekânın temel yapı taşlarından biri olan makine öğrenmesi diğer bir ifadeyle açıkça programlamaya gerek duymaksızın makineler öğrenme yetisi kazdırmak için kullanılan bilgisayar bilimi teknikleridir (Birer, 2018: 30).

2.1. Yapay Zekâ Kavramı

Yapay zekâ kavramına geçmeden önce hayatımızın en gizemli ve belki de en değerli kavramı olan zekânın anlaşılması gerekmektedir. Zekâyı açıklamak için yapılan tanımlar her ne kadar birbirine benzese de çoğu zaman farklılıklar gösterdiğinden zekânın açık ve net olarak bir tarifini yapmak zordur. Türk Dil Kurumu zekâyı insanın düşünme, akıl yürütme, objektif gerçekleri algılama, yargılama ve sonuç çıkarma yeteneklerinin tamamı, anlık, sezgi, zeyreklik, feraset olarak tanımlamaktadır. Bireysel bilgi birikimi ve deneyimlerle ilişkili olan zekâ, bir şeyi anlama, kavrama veya önemini anlama olarak da ifade edilebilmektedir (Ataseven, 2007: 1; www.tdk.gov.tr, 2019).

Doğuştan bir zekâyâ sahip olan her insan ilk kez karşılaşılan ya da ani olarak gelişen bir olaya uyum sağlayabilmekte; anlama, öğrenme, analiz yeteneği, beş duyunun, dikkatin ve düşüncenin yoğunlaştırılmasını gerçekleştirebilmektedir (Elmas, 2007: 21). Bu bakımdan zekâ insanoğlu için her zaman merak konusu haline gelmiştir ve dolayısıyla zekânın kaynağı binlerce yıldır araştırma konusu olmuştur. Bunun neticesinde zekânın ihtiyaç duyduğu beynin nasıl çalıştığını bulabilmek için bilim insanları tarafından çok sayıda çalışmalar yapılmış ve bu çalışmalar ışığında insan gibi düşünen makineler

yapmak için arařtırmalar yapılmıřtır. “Yapay Zekâ” ismini verdiđimiz bu kavram da bu řekilde řekillenmeye bařlamıřtır (Güngör, 2007: 2; Yıldız, 2006: 35).

Zekâ ve düşünme gerektiren işlemlerin bilgisayarlar tarafından yapılmasını sađlayacak arařtırmaların yapılması ve yeni yöntemlerin geliştirilmesi hususunda çalışılan bir bilim dalı olan yapay zekâ; “düşünme, anlama, kavrama, yorumlama ve öğrenme yapılarının programlamayla taklit edilerek problemlerin çözümüne uygulanması” olarak ifade edilmektedir (Ataseven, 2007: 2).

Yapay zekâ konusunda ayrıntılı bir tanım yapacak olursak:

“Yapay zekâ, bilgi edinme, algılama, görme, düşünme ve karar verme gibi insan zekâsına özgü zekâ davranıřlarının otomasyonunu arařtıran, insanın düşünüş sürecini çeřitli makineler kullanarak taklit etmeyi amaçlayan, insanın düşünme yapısını anlama, bunun benzerini ortaya çıkaracak bilgisayar işlemlerini geliřtirmeye çalışan, bilgilerin saklanması ve işlenmesinde bilgi işlem yöntemlerinin kullanan, bilgisayar biliminin bir alt dalıdır”. Kısaca yapay zekâ, programlanmış bir bilgisayarın düşünme giriřimi olarak tarif edilebilmektedir (Ataseven, 2007: 2; Güngör, 2007: 2). Diđer bir ifadeyle bir makinenin ya da bilgisayarın insan gibi düşünmesini, karar vermesini, tahminde bulunmasını ve insanımsı davranıřlar sergilemesini sađlayabilmektir (Yıldız, 2006: 36).

Peki, makineler gerçekten düşünebilir mi? Bu soruya yanıt verebilmek için 1950’lerin bařında bilgisayar biliminin kurucusu sayılan İngiliz matematikçi, bilgisayar bilimcisi ve kriptolog Alan Mathison Turing, taklit oyunu adında bir test tasarlamıřtır. Sonraları Turing testi olarak anılacak olan bu test için yapay zekâ içeren sohbet (chat) programı denilebilir. Bu bilgisayar programı ile sohbet eden kiři karřısındakinin bir insan mı yoksa bir bilgisayar mı olduđunu, yani bu yazılımın yapay zekâ olup olmadıđını belirlemeye çalışmaktadır. Testi yapan kiři eđer bařarısız olursa makinelerin de bir insan kadar zihinsel yeteneđe sahip olduđu söylenebilmektedir (Birer, 2018: 34–35; Yıldız, 2006: 38)

Alan Turing yapay zekânın kuramsal öncüleri arasında gösterilmesine rađmen yapay zekâ terimi ilk defa 1956’daki Dartmouth Konferansı’nda Prof. John McCarthy tarafından kullanılmış ve sonraki yıllarda çeřitli alanlarda yapay zekâ geliştirilmesi için birçok çalışma yapılmıřtır. İnsanların yapay zekâya bakışını deđiřtiren önemli olaylardan biri IBM’in geliřtirdiđi Deep Blue adlı bilgisayarın 1997’de dünya satranç şampiyonu Garry Kasparov’u yenmesi olmuřtur. Yapay zekânın matematiksel olmayan alanlarda da

insanları yenebileceğinin sinyali 2011’de IBM’in Watson adlı yapay zekâ bilgisayarının *Ben Bilirim* adlı bir televizyon yarışmasında rakiplerini yenerek verilmiş oldu. 2016’da ise Google Deepmind’in dünya go şampiyonunu yenmesiyle birlikte yapay zekânın satrançtan daha karmaşık oyunlarda da başarılı olabileceği görüldü (Birer, 2018: 26).

Yapay zekâ kavramının doğduğu zamandan bu yana 2012 yılına kadar yapay zekâ inişli çıkışlı dönemler yaşadı. Son birkaç yıldır ise özellikle 2015 yılından beri bu alanda ciddi bir çıkış yakalandı. Bu süreçte makine öğrenmesinin gelişmesi ve paralel işlemeyi daha hızlı, daha ucuz ve daha güçlü hale getiren GPU’ların kullanımının yaygınlaşmasıyla birlikte derin öğrenme alanında da büyük bir sıçrama yaşanmıştır (Detmers, 2015). Yapay zekânın geçirmiş olduğu bu süreçler ve yapay zekâyla birlikte ortaya çıkan makine öğrenmesi, derin öğrenme kavramlarının birbirinden ayrımı şekil 2.1.’de görselleştirilmiştir (Nvidia, 2019).

Şekil 2.1. Yapay Zekânın Süreçleri



Kaynak: (Nvidia, 2019)

Yapay zekâ, makine öğrenimi, yapay sinir ağları ve derin öğrenme kavramları son yıllarda oldukça sık kullanılan ve popüler hale gelen terimlerdir. Bu kavramlar genellikle aynı bağlamda kullanılmaktadırlar, ancak aralarında görünür farklar bulunmaktadır (www.aiso-lab.com, 2017). Çalışmanın ilerleyen bölümlerinde bu kavramların tanımlarına ve birbirleriyle olan ilişkilerine detaylı olarak yer verilecektir.

2.2. Yapay Zekâ Teknolojileri

Yapay zekâ kavramının gündeme gelmesinden sonra bu alanda yapılan çalışmalar değişik teknolojilerin doğmasına neden olmuştur. Çünkü günlük olaylar ve problemler, içerisinde bulundukları kültür ve çevreye bağlı olarak insanlar tarafından değişik şekillerde yorumlanmakta ve çözülebilmektedir. Dolayısıyla insan beynini taklit etmeye çalışarak üretilen yapay zekâ teknolojileri de geliştirildiği çevreye göre değişiklik göstermektedir (Öztemel, 2012: 15; Yıldız, 2006: 38–39). Bu nedenle insandan ayırt edilemeyecek bir yapay zekâ yapabilmek için her biri bilgisayar biliminin alt dalı olan bilgi mühendisliği, konuşma tanıma, doğal dil işleme, doğal dil üretimi, görebilme gibi alanlarda ciddi ilerlemeler kaydedilmesi gerekmektedir (Birer, 2018: 35).

Öztemel (2012)'e göre günümüzde 60'dan fazla yapay zekâ teknolojisinden bahsedildiğini belirtmektedir. Bunlar arasında; uzman sistemler, yapay sinir ağları, genetik algoritmalar, bulanık mantık, zeki etmenler, görme, karınca kolonisi, vb. yapay zekânın alt konuları yer almaktadır. Bunların her biri çok uzun ve ayrıntılı inceleme gerektiren konular olduğundan bu çalışmada bunlardan sadece çalışmada kullanılan yöntemlerden biri olan yapay sinir ağlarına detaylı olarak incelenmiştir.

2.3. Yapay Sinir Ağları

Bu bölümde YSA ile ilgili kavramsal çerçeve çizilmiş olup bu bağlamda YSA'nın tarihsel gelişimi, sınıflandırılması, genel özellikleri ve uygulama alanları ele alınmış olup bir YSA modeli olan çok katmanlı sinir ağı (ÇKA), orijinal adıyla MLP (Multilayer Perceptron) incelenmiştir.

2.3.1. YSA'nın Tanımı

Turing makineleriyle temeli atılan yapay zekâ üzerinde en fazla araştırma yapılan konu olan YSA'lar temelde tamamen insan beyni örneklenerek geliştirilmiş bir teknolojidir (Ergezer, Dikmen ve Özdemir, 2003: 14). YSA'lar yeni bilgiler oluşturabilme ve keşfedebilme yeteneklerini herhangi bir yardım olmadan otomatik olarak gerçekleştirmek amacı ile geliştirilen, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilen bilgisayar sistemleridir. Geleneksel programlama yöntemleri ile bu yetenekleri gerçekleştirmek oldukça zor olduğundan veya mümkün

olmadığından yapay sinir ağlarının, programlanması çok zor veya mümkün olmayan olaylar için geliştirilmiş uyarların bilgi işleme ile ilgilenen bir bilgisayar bilim dalı olduğu söylenebilir (Öztemel, 2012: 29).

Matematiksel olarak ifade edilecek olursa, YSA'lar ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem elemanlarından (nöronlar) oluşan sistemlerdir. Transfer fonksiyonu olarak da anılan bir denklem olan işlem elemanı, diğer nöronlardan sinyalleri almakta; bunları birleştirmekte, dönüştürmekte ve sayısal bir sonuç ortaya çıkartmaktadır. İnsan beynindeki gerçek nöronlara karşılık gelen bu işlem elemanları bir ağ içinde birbirlerine bağlanarak sinir ağlarını oluşturmaktadırlar (Yurtoğlu, 2005: 5).


İnsan beyninin fonksiyonel özelliklerine benzer şekilde öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda başarılı bir şekilde uygulanmakta olan YSA'lar örneklerden elde ettikleri bilgiler ile kendi deneyimlerini oluşturmakta; ve daha sonra, benzer konularda benzer kararlar verebilmektedirler (Öztemel, 2012: 29).

2.3.1.1. Biyolojik Sinir Hücresi

İnsanlarda sinir sistemi, sinir adı verilen hücrelerden meydana gelmektedir. Canlıların hayati fonksiyonlarının yürütüldüğü en küçük birimler olan bu sinir hücreleri merkezi sinir sistemi üzerinden tüm vücuda yayılmaktadır (Yüksel ve Akkoç, 2016: 42). Sinir hücreleri bir araya gelerek aralarında çeşitli bağlantılar kurmakta ve bu şekilde biyolojik sinir ağları ortaya çıkmaktadır. İnsan beyninde yaklaşık 10^{10} adet sinir hücresi ve bu sinir hücrelerinin de birbiriyle $6 \cdot 10^{23}$ 'ten fazla bağlantısının olduğundan bahsedilmektedir (Öztemel, 2012: 45).

Beynin haberleşme sistemini oluşturan sinirlerin görevleri sinyal alma, işlem yapma ve elektrokimyasal sinyallerin sinir ağları içinde iletimini sağlamaktır. Canlı sinir sisteminde sinir hücreleri sinyal alır, aldığı sinyale göre işlem yaparak sinyalin iletimini gerçekleştirir. Şekil 2.2'de görüldüğü gibi bir sinir hücresi yapısal olarak 4 bölümden oluşmaktadır. Bunlar; dentritler, soma, akson, ve sinapstır. Biyolojik sinir hücresi diğer kaynaklardan girişleri alır ve alınan girişler hücre merkezi olan somaya ileterek burada doğrusal olmayan bir şekilde işlenmektedir. Akson ise işlenmiş bu girişleri çıkışa aktararak sinapslar aracılığıyla diğer sinirlere göndermektedir (Akkaya, 2007: 196; Ç. Elmas, 2007: 29).

Şekil 2.2. Biyolojik Sinir Hücresi ve Bileşenleri



Kaynak: (Garip, 2011: 76)

Araştırmacılar beynin çalışma sistemini incelerken, biyolojik sinir hücrelerinden esinlenerek YSA'nın ağ şeklini ve algoritmasını düşünmüşlerdir. Her ne kadar biyolojik olarak çok benzemese de, YSA ile beyin arasında bir takım benzerlikler bulunmaktadır (Tablo 2.1).

Tablo 2.1. Biyolojik Sinir Sistemi ile Yapay Sinir Hücresinin Karşılaştırılması

Biyolojik Sinir Sistemi	Yapay Sinir Ağları
Nöron	Yapay Nöron (İşlemci Elemanı)
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu (Eşik)
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar
Uyarıcı giriş	Pozitif Ara Bağlantı Ağırlığı
Engelleyici giriş	Negatif Ara Bağlantı Ağırlığı

Kaynak: (Bayru, 2007: 15; Ç. Elmas, 2007: 33; Garip, 2011: 76)


2.3.1.2. Yapay Sinir Hücresi

Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. Yapay sinir hücreleri mühendislik biliminde işlem (proses) elemanları olarak da adlandırılmaktadır. Şekil 2.3'de gösterildiği gibi her işlem elemanı

girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve hücrenin çıktısı olmak üzere beş bölümden oluşmaktadır (Öztemel, 2012: 48–51).

Biyolojik sinir hücresinin, girdi, işlem ve çıktı karakteristiğini taklit etmek için tasarlanan yapay sinir hücresinde (Şekil 2.3) her bir girdi kendi ağırlığı ile çarpılmakta ve sinir hücresinin seviyesini belirlemek için bu çarpımların hepsi toplanmaktadır (Akkaya, 2007: 196).

Şekil 2.3. Yapay Sinir Hücresi



Kaynak: (Kaynar, Taştan ve Demirkoparan, 2010: 562)

Şekil 2.3’de görüldüğü gibi bir yapay sinir hücresinde, girdiler ($x_1, x_2, \dots, x_n$), diğer hücrelerden ya da dış ortamdan hücreye giren verilerdir. Bunlar ağırlık öğrenmesi istenen veri seti tarafından belirlenir. Ağırlıklar ($w_1, w_2, \dots, w_n$), girdi kümesi veya kendinden önceki bir tabakadaki başka bir işlem elemanının bu işlem elemanı üzerindeki etkisini gösteren değerlerdir. Her bir girdi, o girdiyi işlem elemanına bağlayan ağırlık değeriyle çarpılarak, Denklem 2.1’de gösterilen toplam fonksiyonu aracılığıyla birleştirilir (Kaynar ve diğerleri, 2010: 562).

$$\text{net} = \sum_{i=1}^n w_i x_i + b \quad (2.1)$$

Denklem 2.2’de de toplam fonksiyonunda elde edilen değer doğrusal ya da doğrusal olmayan türevlenebilir bir transfer fonksiyonundan geçirilerek işlem elemanının çıktı değerinin nasıl hesaplandığı gösterilmektedir.

$$y = f(\text{net}) = f(\sum_{i=1}^n w_i x_i + b) \quad (2.2)$$

Basitçe ifade edecek olursak girdilerin her biri ağırlık w ile çarpılarak eşik değeri ile toplanır ve sonucu oluşturmak için etkinlik işlevi ile işlem yapıp y_i çıktı değeri alınır. Tüm YSA'lar bu temel yapıdan türetilmiştir ve bu yapıdaki farklılıklar yapay sinir ağlarının farklı sınıflandırılmalarını sağlamaktadır (Elmas, 2007: 31). Bu çalışmada YSA'nın danışmanlı öğrenme olarak sınıflandırılan mimarisi kullanılmıştır ve YSA'nın sınıflandırılması konusuna çalışmanın bu bölümünün ilerleyen aşamasında değinilecektir.

2.3.1.3. YSA'nın Temel Elemanları

Biyolojik sinir ağlarındaki hücrelerin yapay sinir ağlarındaki karşılığı yapay sinir hücreleri ve bu hücre elemanlarına işlem elemanı denilmektedir. İşlem elemanları girdiler, ağırlıklar, toplam fonksiyonu, aktivasyon fonksiyonu ve hücre çıktısı olmak üzere beş esas elemandan oluşmaktadır (Okutkan, 2014: 14).

Girdiler: Bir yapay sinir hücresi (işlem elemanı) birçok bilgiyi dış dünyadan alır ve bu bilgileri işleme tabi tutar. Gelen bilgiler o sinir hücresi için girdi durumundadır. Girdiler $(x_1, x_2, \dots, x_n)$, dış dünyadan olduğu gibi kendinden ya da kendinden önceki bir katmandaki işlem elemanının da çıkışı olabilir (Elmas, 2007: 31; Öztemel, 2012: 49). Girdiler yapay sinir ağlarının sensörleri durumundadır. Girdilerin sayısı, yapay sinir ağının çevreyi algılamasına bağlı olarak değişiklik göstermektedir ve bu çevre yapay sinir ağının işleyeceği verilerden oluşuyorsa, girdiler de sözü edilen veri değişkeninin yapısıyla tutarlı olmalıdırlar (Buscema, 2002: 1108).

Ağırlıklar: Ağırlıklar $(w_1, w_2, \dots, w_n)$, bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Her bir giriş kendine ait bir ağırlığa sahiptir. Şekil 2.3'deki Ağırlık 1 (w_1), Girdi 1 (x_1)'in hücre üzerindeki etkisini göstermektedir. Bir ağırlığın büyük ya da küçük olması önemli veya önemsiz olduğu anlamına gelmez. Bir ağırlığın değerinin artı veya eksi olması durumunda etkisinin pozitif veya negatif olduğu anlaşılmaktadır. Sıfır olması ise herhangi bir

etkinin olmadığını gösterir. Ağırlıklar değişken veya sabit değerler olabilirler (Elmas, 2007: 31; Öztemel, 2012: 49).

Toplama Fonksiyonu: Bu fonksiyon bir hücreye gelen net girdiyi hesaplar ve bu hesaplamayı yaparken farklı fonksiyonlar kullanılabilir. En sık kullanılan ağırlıklı toplamı bulma yöntemidir. Burada her gelen girdi değeri kendi ağırlığı ile çarpılıp toplanarak ağa gelen net girdi bulunmaktadır. Denklem (2.3)'de gösterilmiştir.

$$\text{net} = \sum_i^n w_i x_i \quad (2.3)$$

Burada w_i ağırlıkları, x_i ise girdileri, n ise bir hücreye gelen toplam girdi (işlem elemanı) sayısını göstermektedir. Toplama fonksiyonu seçimi probleme göre değişkenlik gösterebilmektedir. Bir problem için en uygun toplama fonksiyonunu belirlemek için bulunmuş bir formül olmadığından ideal toplama fonksiyonu tespitinde deneme yanılma yöntemi kullanılmaktadır. Toplama fonksiyonu YSA'nın tamamında tek bir fonksiyon kullanılabileceği gibi ağır bazı nöronları farklı toplama fonksiyonu da kullanabilmektedir (Öztemel, 2012: 49). Çeşitli toplama fonksiyonu örnekleri Tablo 2.2'de gösterilmiştir.

Tablo 2.2. Toplama Fonksiyonu Örnekleri

Net Giriş	Açıklama
Çarpım $s = \sum_i w_i x_i$	Ağırlık değerleri (w_i) girdiler (x_i) ile çarpılır ve daha sonra bulunan değerler birbirleri ile çarpılarak net girdi (s) hesaplanır.
Maksimum $s = \text{Max}(w_i x_i), i=1 \dots N$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en büyüğü yapay sinir hücresinin net girdisi olarak belirlenir.
Minimum $s = \text{Min}(w_i x_i), i=1 \dots N$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en küçüğü yapay sinir hücresinin net girdisi olarak belirlenir.
Çoğunluk	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur.




$s = \sum_i \text{sgn } w_i x_i$	Büyük olan sayı hücrenin net girdisi olarak belirlenir.
Kümülatif toplam $s = s(\text{eski}) + \sum_i w_i x_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.



Kaynak: (Akay, 2009: 25; Güngör, 2007: 21; Öztemel, 2012: 50)

Aktivasyon Fonksiyonu: Bir girdi katmanı, bir çıktı katmanı ve bir veya daha fazla sayıda birbirine paralel gizli katmanlardan oluşan yapay sinir hücresinin çıktı değerlerinin aralığının belirlenmesinde kullanılan fonksiyonlar aktivasyon fonksiyonu olarak adlandırılmaktadır (Boyacıoğlu ve Kara, 2007: 211). Bu fonksiyon, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da çıktıyı hesaplamak içinde değişik formüller kullanılmaktadır. Örneğin çok katmanlı algılayıcı gibi bazı modeller, bu fonksiyonun türevinin alınabilir bir fonksiyon olmasını şart koşmaktadır. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da ağırlık işlem elemanlarının hepsinin aynı fonksiyonu kullanması gerekmez. Bazı elemanlar aynı fonksiyonu diğerleri farklı fonksiyonları kullanabilirler. Bir problem için en uygun fonksiyonda yine tasarımcının denemeleri sonucunda belirleyebileceği bir durumdur.

Girdi ve çıktı birimleri arasındaki eğrisel eşleşmeyi sağlayan aktivasyon fonksiyonunun doğru seçilmesi, ağırlık performansını önemli derecede etkilemektedir (Erilli, Eğrioğlu, Yolcu, Aladağ ve Uslu, 2010: 46) ancak uygun fonksiyonu gösteren bir formül bulunmuş değildir (Öztemel, 2012: 50). Yaygın olarak kullanılan aktivasyon fonksiyonları Tablo 2.3’de gösterilmiştir:

Tablo 2.3. Aktivasyon Fonksiyonları

Aktivasyon Fonksiyonu	Açıklama
Lineer fonksiyon $F(s)=s$	 Gelen girdiler olduğu gibi hücrenin çıktısı olarak kabul edilir.
Step fonksiyonu $F(s)=\begin{cases} 1 & \text{if } s > \text{eşik_değer} \\ 0 & \text{if } s \leq \text{eşik_değer} \end{cases}$	 Gelen NET (s) girdi değerinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır.
Sinüs fonksiyonu $F(s)=\sin(s)$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.
Eşik değer fonksiyonu $F(s)=\begin{cases} 0 & \text{if } s \leq 0 \\ s & \text{if } 0 < s < 1 \\ 1 & \text{if } s \geq 1 \end{cases}$	 Gelen bilgilerin 0 veya 1'den büyük veya küçük olmasına göre değerler alır. 0 ve 1 arasında değerler alabilir. Bunların dışında değerler alamaz.

Sigmoid Fonksiyonu, $F(Net) = \frac{1}{1+e^{-Net}}$	 Doğrusal ve doğrusal olmayan davranışlar arasında denge sağlayan sürekli artan bir fonksiyon olarak tanımlanır.
Hiperbolik tanjant fonksiyonu $F(s) = \frac{e^{Net} - e^{-Net}}{e^{Net} + e^{-Net}}$	 Gelen NET girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanır

Kaynak: (Akay, 2009: 26; Güngör, 2007: 23; Öztemel, 2012: 51)

Çıktılar: Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Bu değer dış dünyaya veya başka bir hücreye gönderilir. Hücre ürettiği çıktıyı kendisine girdi olarak da gönderebilir (Öztemel, 2012: 51).

2.3.1.4. YSA'nın Katmanları


YSA, yapay sinir hücrelerinin bir araya gelmesiyle oluşur. Sinir hücrelerinin bir araya gelmesi rasgele olmaz. Genel olarak hücreler katmanlar halinde ve her katman içinde paralel bir şekilde bir araya gelerek ağı oluştururlar. Tek katman ya da tek eleman içeren bazı başarılı ağlar oluşturulabilmesine rağmen çoğu uygulamalar girdi katmanı, gizli katman ve çıktı katmanı olmak üzere en az üç katman içeren ağlara ihtiyaç duymaktadır. Bu katmanlar (Bayır, 2006: 19; Öztemel, 2012: 52–53);

Girdi Katmanı: Bu katmandaki işlem elemanları dış dünyadan bilgileri alarak girdi değerleri üzerinde bir işlem uygulamadan ara katmanlara transfer etmekle sorumludurlar.

Ara (Gizli) katmanlar: Girdi ve çıktı katmanı arasında bir ve ya birden fazla gizli katman bulunabilmektedir. Bu gizli katmanlarda bulunan çok sayıdaki işlem elemanı, girdi katmanından gelen bilgileri işleyerek çıktı katmanına gönderirler. Çoğu ağ türünde gizli katmanda bulunan bir işlem elemanı bir önceki katmanın tüm işlem elemanlarından sinyal alır ve işlem yaptıktan sonra elde edilen çıktıyı bir sonraki katmanın tüm işlem elemanlarına gönderir.

Çıktı katmanı: Bu katmanda ara katmandan gelen bilgiler işlem elemanları tarafından işlendikten sonra ağın girdi katmanından sunulan girdi seti (örnek) için üretilmesi gereken çıktı üretilerek dış dünyaya gönderilir.

Şekil 2.4. Bir Yapay Sinir Ağı Örneği



Kaynak: (Akkaya, 2007: 197; Öztemel, 2012: 53)

Bu üç katmanın her birinde bulunan işlem elemanları ve katmanlar arası ilişkiler şematik olarak Şekil 2.4’de gösterilmektedir. Şekilde, her katmanda birbirine paralel bir biçimde duran yuvarlaklar işlem elemanlarını ve bu işlem elemanlarını birbirine bağlayan

çizgiler ise ağıın bağlantılarını göstermektedir. İşlem elemanları ve bağlantıları bir YSA'yı oluşturmaktadırlar (Öztemel, 2012: 54).

2.3.1.5. YSA Uygulamaları Geliştirme Aşamaları

Yapay sinir ağı uygulamalarının geliştirilmesi, tasarım, eğitim ve test olmak üzere üç aşamadan oluşmaktadır.

Tasarım: Bu aşamada geliştirilmekte olan uygulamanın veya problemin tamamı ile kavranması ve anlaşılması sağlandıktan sonra ele alınan problemin YSA ile çözüme uygun olup olmadığına bakılmaktadır. Problemin girdi ve çıktı katmanlarında yer alacak parametreler tanımlanarak kullanılacak ağ mimarisinin gereklerine uygun değerlere dönüştürülmektedir. Daha sonra ağıın mimarisinde gerekli olacak olan optimum veya optimuma yakın gizli katman sayısı ve bu katmanlardaki işlem elemanı sayıları deneme yanılma yöntemi kullanılarak belirlenmektedir (Garip, 2011: 85).

Eğitim: YSA modelinde mimari yapı, girdi sayısı, katman sayısı ve bu katmanlarda ki işlem elemanlarının sayıları belirlendikten sonra ağda eğitim aşamasına geçilebilir. YSA'da katmanlardaki işlem elemanları arasında bağlantı ağırlıklarının belirlenmesi işlemi “ağıın eğitilmesi” olarak adlandırılmaktadır. Ağırlık değerleri başlangıçta rastgele seçilir. Ağa giriş verileri ve çıkış verileri defalarca verilere ağırlıkların problemi temsil edecek ideal değerlere ulaşması sağlanır. Ağıın bu şekilde genelleştirme yapacak duruma gelmesi ağıın öğrendiğini göstermektedir. Ağırlıkların eğitim esnasında güncellenmesi farklı farklı yaklaşımlarla gerçekleşmektedir. Bu yaklaşımlara öğrenme kuralları denilmektedir (Öztemel, 2012: 55).


Test: Eğitim süreci tamamlandıktan sonra geliştirilen YSA modelinin öğrenip öğrenmediğini ölçmek için denemeler (ağıın test edilmesi) yapılmaktadır. Ağıın test edilmesi şu şekilde gerçekleştirilmektedir:

Ağıın daha önce karşılaşmadığı örnekler ağa girdi olarak verilerek ağıın çıktı üretmesi sağlanır. Test verileriyle üretilen çıktılar olması gereken çıktılarla yeterli oranda örtüşüyorsa, geliştirilen modelin güvenilir olduğu kabul edilmektedir. Test verileriyle üretilen çıktılar olması gereken çıktılarla yeterli oranda örtüşmüyorsa eğitim ve test sürecinin tekrarlanması gerekmektedir (Garip, 2011: 87).

2.3.2. YSA'nın Tarihsel Gelişimi

İnsan beyni binlerce yıldır araştırma konusu olmuştur ancak insan beyninin yaptığı işlemleri yapabilecek sinir ağlarının oluşturulabilmesi elektronik alanda ortaya çıkan büyük gelişmelerle birlikte mümkün hale gelmiştir. Dolayısıyla yapay sinir ağları, 1950'li yılların sonlarından itibaren yeni bir yaklaşım olarak görülmeye başlanmıştır. 1970'lerde yaşanan durgunluğa rağmen, bilgisayar teknolojisinde yaşanan gelişmelerle birlikte bu bilimi tarihinde önemli bir dönüm noktası başlamış ve o zamana kadar olmaz diye düşünülen birçok sorun çözülmüş ve 1980'li yıllardan itibaren yapılmış olan araştırmalar ve yeni gelişmeler sayesinde, yapay sinir ağları en popüler konulardan biri haline gelmiştir. Dolayısıyla yapay sinir ağı ile ilgili çalışmaları 1970 öncesi ve sonrası diye ikiye ayırmak mümkündür (Ataseven, 2007: 7–8; Öztemel, 2012: 37).

Şekil 2.5. Yapay Sinir Ağlarının Tarihsel Gelişimi



Kaynak: (Kong, 2016)

1943 yılında, ilk yapay sinir ağı modelini gerçekleştiren sinir hekimi Warren McCulloch ile matematikçi Walter Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleri ile basit bir sinir ağını modellemişlerdir (McCulloch ve Pitts, 1943). 1958 yılında Frank Rosenblatt çok katmanlı algılayıcıların temelini oluşturan tek katmanlı lineer algılayıcı modelini (perceptron) geliştirerek ağlara öğrenme yeteneği

kazandırmıştır (Rosenblatt, 1958). 1959 yılında, Bernard Widrow ve Marcian Hoff (Stanford Üniversitesinde) ADALINE ve MADALINE diye adlandırdıkları ağ modellerini geliştirdiler. Gerçek dünya sorunlarına uygulanmış ilk sinir ağı olan MADALINE, telefon hatlarında oluşan yankıları yok eden bir uyarlanabilir süzgeç olarak kullanılmış ve hala kullanılmaktadır (Elmas, 2007: 27). 1969 yılında Minsky ve Papert yazdıkları ‘Algılayıcılar’ adlı kitapta YSA’nın doğrusal olmayan problemlere çözüm üretemediğini meşhur XOR probleminin çözilememesine dayandırarak iddia etmeleri YSA çalışmalarında önemli bir durgun dönem yaşanmasına ve YSA ile ilgili çalışmaların bitme noktasına gelmesine neden olmuştur (Minsky ve Papert, 1988; Öztemel, 2012: 38)

1986 Yılında Rumelhart ve arkadaşları geri yayılımda girdi ve çıktı örüntü çiftlerinin sunulduğu yeni bir öğrenme yapısı geliştirmişlerdir. Bu yapıda önce girdileri kullanarak kendi çıktılarının üretmektedir. Daha sonra beklenen değer ile gerçekleşen çıktı değerleri arasındaki fark kullanılmaktadır. Eğer bu değerler arasında fark yok ise öğrenme gerçekleşmemiştir ve bu farkı azaltmak için ağıdaki bağlantı ağırlıkları hızlı bir şekilde değiştirilmektedir. Bu işlem yapılırken beklenen değer ile gerçekleşen çıktı değerleri arasındaki fark kullanılmaktadır. Kısaca hatanın geri yayılımda kullanılmasını sağlamışlardır (Rumelhart, McClelland ve Group, 1986: 322).

1995’de Vapnik ve Cortes eğitim verilerindeki herhangi bir noktadan en uzak olan iki sınıf arasında bir karar sınırı bulan vektör uzayı tabanlı bir makine öğrenmesi metodunu sunmuşlardır (Cortes ve Vapnik, 1995). “İstatiksel Öğrenme Teoremi” ne dayanan Destek Vektör Makineleri, 1963 yılında Rusya’da Vapnik ve Lerner, 1964 yılında Vapnik ve Chervonenkis tarafından önerilmiştir (Smola ve Schölkopf, 2004: 199).

2007 yılında Geoffrey E. Hinton çok katmanlı ileri beslemeli bir sinir ağının her iterasyonda bir katmanı etkili şekilde nasıl eğitilebildiğini, ardından denetimli bir geri yayılım yöntemi ile ince ayar yapabileceklerini göstermiştir (Hinton, 2007).

2.3.3. YSA’nın Sınıflandırılması

Yapay sinir ağları bağlantı yapılarına, öğrenme stratejilerine, öğrenme kurallarına ve öğrenme algoritmalarına göre sınıflandırılmaktadır.

2.3.3.1. Bağlantı Yapılarına Göre YSA

Yapay sinir ağları, bağlantı yapılarına göre iki sınıfta incelenmektedirler. Bunlar, ileri beslemeli ve geri beslemeli ağlardır (Garip, 2011: 82–83; Hamzaçebi, 2011: 20).

İleri Beslemeli Ağlar: Verilerin giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletildiği ağ yapısıdır. İşlem elemanları bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. İleri beslemeli ağlara örnek olarak çok katmanlı perseptron (Multi Layer Perseptron-MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir.

Geri Beslemeli Ağlar: Çıkış ve ara katmanlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslenmesinden oluşan ağ yapısıdır. Böylece girişler hem ileri yönde hem de geri yönde aktarılmış olur. Bu çeşit sinir ağlarının dinamik hafızaları vardır. Bu ağlarda bir andaki çıkış, hem o andaki hem de önceki girişleri yansıttığından dolayı özellikle önceden tahmin uygulamaları için uygundur. Bu ağlar çeşitli tipteki zaman-serilerinin tahmininde oldukça başarı sağlamışlardır. Geri beslemeli YSA'na örnek olarak Hopfield, SOM (Self Organizing Map), Elman ve Jordan ağları verilebilir.

2.3.3.2. Öğrenme Stratejilerine Göre YSA

En ayırt edici özelliklerinden birisi öğrenme yeteneği olan yapay sinir ağlarında öğrenme, bağlantı ağırlıklarının hesaplanması olarak tanımlanmaktadır. Elde bulunan örnekler arasındaki yapının iyi bir davranış sergileyebilmesi bağlantı ağırlıklarının hesaplanmasına bağlıdır. Bağlantı ağırlıkları yapay sinir ağlarının verileri başarılı bir şekilde işleyebilmesi için ağırlık öğrenme esnasında elde ettiği gerekli bilgileri içermektedir (Okutkan, 2014: 25).

Yapay sinir ağları gibi örneklerden öğrenen sistemlerde farklı öğrenme stratejileri kullanılmaktadır ve bu stratejilere bağlı olarak öğrenmeyi gerçekleştirecek olan sistem ve kullanılan öğrenme algoritma değişiklik göstermektedir. Yapay sinir ağlarının genel olarak danışmanlı (supervised) öğrenme, danışmansız (unsupervised) öğrenme ve destekleyici (reinforcement) öğrenme gibi üç öğrenme stratejisi bulunmaktadır (Anderson ve McNeill, 1992: 10; Öztemel, 2012: 25).

Danışmanlı Öğrenme: Yapay sinir ağlarında en fazla kullanılan öğrenme metodu olan danışmanlı öğrenmede, ağ önce eğitilmektedir. Eğitim işlemi, yapay sinir

ağına örnek olarak bir çıktı (beklenen çıktı) verilere ve daha sonra bu çıktıyla ağın ürettiği çıktı karşılaştırılarak gerçekleşmektedir. İki çıktı arasındaki fark hata olarak alınır. Bu hata ağda geriye doğru bir yayılım göstermekte ve bu süreçte ağırlıklar ağ tarafından hata minimize edilene kadar döngüler halinde değiştirilmektedir (Anderson ve McNeill, 1992: 10; Elmas, 2007: 88).

Danışmansız Öğrenme: Günümüzde tam olarak anlaşılamayan, sınırlı kullanım alanları bulan ve hala yoğun araştırma konusu olan bu danışmansız öğrenme metodu, gelecekte bilgisayarların insan yardımı olmadan öğrenebileceklerinin göstergesidir. Sistemin öğrenmesine yardımcı olan herhangi bir danışmanın bulunmadığı bu öğrenme türünde sisteme sadece girdi değerleri gösterilmekte ve sistemin parametreler arasındaki ilişkileri kendi kendisine öğrenmesi beklenmektedir ancak öğrenme işlemi bittikten sonra çıktıların ne anlama geldiğini gösteren etiketlendirmenin ise kullanıcı tarafından yapılması gerekmektedir. Bu öğrenme stratejisi daha çok sınıflandırma problemleri için kullanılmaktadır (Anderson ve McNeill, 1992: 11; Öztemel, 2012: 25)

Destekleyici Öğrenme: Yukarıda bahsedilen bu iki temel öğrenme metodundan başka takviyeli öğrenme (reinforcement learning) adı verilen bir metod daha bulunmaktadır. Danışmanlı öğrenmenin bir alt türü olan bu metoda göre, yapay sinir ağına sadece girdiler verilmekte ve ağdan bu girdilere karşılık çıktıları üretmesi beklenmektedir. Sisteme bu çıktıların ne derece doğru olduğunu belirten bir sinyal bildirilmektedir (Jain, Mao ve Mohiuddin, 1996: 35; Öztemel, 2012: 25).

2.3.3.3. Öğrenme Kurallarına Göre YSA

Yapay sinir ağlarında girdi değerlerine dayanarak ağırlıkları değiştiren bir matematik denklemi olan öğrenme kuralı, ağa ilave veri girdikçe sinir ağlarının daha güvenilir çıktılar üretmesini sağlamaktadır (Bayru, 2007: 34). Yukarıda bahsedilen öğrenme stratejilerinden hangisi uygulanırsa uygulansın öğrenme bazı kurallara göre gerçekleştirilmektedir. Öğrenme kurallarının çoğu temelde Hebb öğrenme kuralını esas almaktadır. Bu kurala göre bir işlem elamanı kendisi aktif ise bağlı olduğu hücreyi aktif yapmaya, pasif ise pasif yapmaya yani matematiksel olarak aynı işareti taşımasını


sağlamaya çalışmaktadır. Temel öğrenme kuralları Hebb, Hopfield, Delta ve Kohonen kurallarıdır (Öztemel, 2012: 26).

Bu çalışmada kullanılan yöntemlerden biri olan ÇKA, delta kuralının genelleştirilmiş şeklini kullanarak öğrenme işlemini gerçekleştirirler. Bu yüzden öğrenme kuralına “Genelleştirilmiş Delta Kuralı” da denmektedir (Öztemel, 2012: 77). Bu kural dışındaki öğrenme kurallarının açıklamalarına bu çalışmada yer verilmemiştir. Genelleştirilmiş Delta Kuralı ise Bölüm 2.4.3’de Çok Katmanlı Algılayıcılar (ÇKA) konusu içerisinde değinilecektir.

2.3.3.4. Öğrenme Algoritmalarına Göre Ağlar

Yapay sinir ağlarında birçok öğrenme algoritması kullanılmaktadır. Bu algoritmalar problemin türüne göre ve kullanılan ağ yapısına göre değişiklik gösterebilmektedir. En sık kullanılan öğrenme algoritmaları geri yayılım algoritması, Levenberg Marquardt algoritması, momentum geri yayılım algoritması, esnek yayılım algoritması, hızlı yayılım algoritması, delta bar delta algoritması, geliştirilmiş delta bar delta algoritması ve genetik algoritmadır.

Şekil 2.6. Geri Yayımlı Öğrenme Algoritması Akış Diyagramı



Kaynak: (Haznedaroğlu, 2009: 61)

2.3.4. YSA'nın Genel Özellikleri

Bu bölümde, uygulanan ağı modeline göre özellikleri değişiklik gösteren yapay sinir ağlarının bütün modelleri için geçerli olan genel özelliklerine açıklamalarıyla birlikte yer verilmektedir (Öztemel, 2012: 31–33).

- **Makine öğrenmesi gerçekleştirmektedirler:** Bilgisayarların öğrenmesini sağlayarak olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışmaktadırlar.
- **Bilginin saklanması:** Yapay sinir ağlarında bilgi, diğer programlarda olduğu gibi veri depolanması veya programın içerisine gömülmeyip, ağı bağlantılarının

değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Dolayısıyla bilgiler ağın üzerinde saklı olup, ortaya çıkarılması ve yorumlanması zordur.

- **Örnekler kullanarak öğrenmektedirler:** Gerçekleşmiş olayları kullanarak problemle ilgili genelleme yeteneğine kavuşurlar. Ağa olay bütün yönleri ile gösterilmez ise başarılı sonuçlar elde edilemez. Bu ağın sorunlu olduğundan değil, olayı ağa iyi gösterilmediğinden kaynaklandığı için örneklerin oluşturulması ve toplanması önem arz etmektedir.
- **Güvenle çalışabilmeleri için önce eğitimleri ve performansları test edilmektedir:** Ağın eğitilebilmesi için mevcut örnekler ağa tek tek gösterilir ve ağ kendi çalışma prensibi içinde örnekteki olaylar arasındaki ilişkileri kurar. Mevcut örnekler iki ayrı sete bölünmekte ve birincisi ağın eğitimi için (eğitim seti) diğeri ise ağın performansının sınanması için (test seti) kullanılmaktadır.
- **Görülmemiş örnekler hakkında bilgi üretebilir ve algılamaya yönelik olaylarda kullanılabilirler:** Ağ kendisine gösterilen örneklerden genelleme yaparak bilgi üretebilir ve bilgiye dayalı çözümlemelerde uzman sistemlerle birleştirilerek kullanılabilirler.
- **Sınıflandırma, örüntü (patern) ilişkilendirme ve tamamlama yapabilmektedirler:** Sınıflandırma yapabilir böylelikle verilen örneklerin kümelendirilmesi ve belirli sınıflara ayrıştırılarak daha sonra gelen bir örneğin hangi sınıfa gireceğine karar verebilmektedirler. Ayrıca örnekler halinde verilen örüntüleri kendisi veya diğerleri ile ilişkilendirebilir ve ağa eksik bilgilerin yer aldığı bir şekil verildiğinde ağ bu eksik bilgileri tamamlayabilmektedir.
- **Kendi kendini organize etme ve öğrenebilme, eksik bilgi ile çalışabilme yetenekleri vardır:** Örnekler ile kendisine gösterilen yeni durumlara adapte olabilmekte ve sürekli yeni olaylar öğrenebilmektedirler. Eğitildikten sonra gelen yeni örneklerde eksik bilgiler olmasına rağmen sonuç üretebilmektedirler. Eksik bilginin olması tek başına performans düşmesi anlamına gelmemektedir. Performans düşmesi eksik bilginin önem derecesine bağlıdır ve bu ancak sonuçtaki performansa bakılarak anlaşılabilir.
- **Hata toleransına sahiptirler, belirsiz ya da tam olmayan bilgileri işleyebilmekte ve dereceli bozulma (graceful degradation) göstermektedirler:** Eksik bilgilerle çalışabilme yetenekleri sayesinde hatalara karşı toleranslı

oldukları gibi belirsiz ya da tam olmayan bilgileri işleyebilme yeteneklerine de sahiptirler. Bu yetenekleri ağların bozulmalarının dereceli (göreceli) olmasını sağlamaktadır.

- **Dağıtık belleğe sahiptirler ve sadece nümerik bilgiler ile çalışabilmektedirler:** Bilgi ağı yayılmış olup, hücrelerin birbirleri ile bağlantılarının değerleri ağı bilgisini göstermektedir. Ağı tamamı öğrendiği olayın bütünü karakterize ettiğinden bilgiler ağı dağıtılmış durumdadır ve bu durum dağıtık bir belleğin doğmasına neden olmaktadır. Ağlar sadece sayısal bilgilerle çalışabilmektedir ve sembolik ifadelerle gösterilen bilgilerin sayısal gösterime çevrilmesi gerekmektedir.

Karmaşık problemleri çözebilme yeteneğini sağlayan bu özellikler yanı sıra, YSA doğrusal olmama ve uyarlanabilir olması bakımından günümüzde birçok bilim alanında etkin olmuş ve uygulama yeri bulmuştur (Ergezer ve diğerleri, 2003: 14).

2.3.5. YSA'nın Uygulama Alanları

Eksik bilgilerle çalışabilme ve normal olmayan veriler çözüm üretebilme yeteneklerinden dolayı, yapay sinir ağları farklı türdeki sorunları çözmek için pek çok alanda kullanılmaktadırlar. Bu uygulamalar aşağıdaki gibi sınıflandırılarak incelebilmektedir (Bayır, 2006: 13; Elmas, 2007: 161–164; Öztemel, 2012: 203);

- Endüstriyel Uygulamalar
- Arıza Analizi ve Tespiti
- Ulaştırma ve Havacılık Uygulamaları
- Finans, Borsa ve Kredi Kartı Uygulamaları
- Tıp, Biomedikal ve İlaç Sanayi Uygulamaları
- İletişim ve Haberleşme Uygulamaları
- Savunma Sanayi Uygulamaları
- Otomasyon ve Kontrol Uygulamaları

Çalışmanın konusu itibarıyla burada sadece yapay sinir ağlarının finans dünyasındaki uygulamalarından bahsedilecektir. Kullanım alanlarına örnekler şu şekilde listelenebilir (Anderson ve McNeill, 1992: 65; Öztemel, 2012: 205).

- Makro ekonomik tahminler

- Borsa benzetim çalışmaları endekslerinin tahmin edilmesi
- Sahtekârlıkları önlemek amacıyla el yazısı ve imza tanımlaması
- Kredi kartı hilelerinin tespiti
- Kredi kartı kurumlarında iflas tahminleri
- Banka kredilerinin değerlendirilmesi
- Emlak kredilerinin yönetilmesi
- Döviz kuru tahminleri
- Risk analizleri

Bu alanlardaki uygulamalar incelendiğinde yapay sinir ağlarının genel olarak tahmin, sınıflandırma, veri ilişkilendirme, veri filtreleme, tanıma ve eşleştirme, teşhis ve yorumlama gibi fonksiyonları gerçekleştirmek için uygulandıkları görülmektedir (Jain ve diğerleri, 1996: 32; Öztemel, 2012: 204). Aşağıdaki tablo 2.4’de hangi tip problemlerin çözümünde hangi YSA’ların kullanılabileceği özet olarak sunulmaktadır.

Tablo 2.4. Yapay Sinir Ağları ve Kullanım Alanları

Problem türü	Ağ kullanımı	Örnekler	Uygun YSA tipleri
Tahminleme	Ağ girdileriyle bir çıktı değerinin tahmin edilmesi	Finansal tahminleme Yağış ve hava tahmini	Çok Katmanlı Ağlar
Sınıflandırma	Girdilerin hangi sınıfa ait olduklarının belirlenmesi	Makine hataları sınıflama	LVQ, ART, Olasılık Sinir Ağları (PNN)
Veri İlişkilendirme Veri Filtreleme Tanıma ve eşleştirme	Girdilerin içindeki hatalı bilgilerin bulunması, eksik bilgilerin tamamlanması	Resim tamamlama Telefonda gürültü azaltma	Hopfield, Kohonen, Boltzmann makinası, Grosberg, Çift yönlü birliksel hafıza (BAM)
Teşhis		Arazi durumlarının teşhisi tıpta hastalık tanımlama	Kendini organize eden ağlar (SOM), LVQ, ART

Kaynak: (Haznedaroğlu, 2009: 59)

2.4. Çok Katmanlı Algılayıcılar (ÇKA)

Tek katmanlı ya da çok katmanlı olarak sınıflandırılan sinir ağlarındaki katman sayısı belirlenirken girdi birimi üzerinde hiçbir hesaplama işlemi yapılmadığından bu birim katman olarak sayılmamaktadır. Bir ağ içindeki katman sayısı nöronları bağlayan ağırlıklı bağlantı sayısına eşittir. Tek katmanlı ve çok katmanlı sinir ağlarının farklı iki

örneği şekil 2.7’de ve şekil 2.8’de verilmektedir. Bu çeşit ağlarda girdi sinyalleri girdi biriminden çıktı birimine doğru ilerlemektedir (Ocakoglu, 2006: 7).

Literatürde birçok farklı Yapay Sinir Ağı modeli bulunmaktadır. En yaygın olarak kullanılan modeller çok katmanlı algılayıcılar, radyal tabanlı YSA, vektör kuantalamalı YSA, olasılık tabanlı YSA ve genelleştirilmiş regresyon YSA, ileri beslemeli danışmanlı ağlardır (Duman, 2016: 26). Bu bölümde çalışmada kullanılan yöntemlerden biri olan Çok Katmanlı Algılayıcılardan bahsedilecektir.


2.4.1. ÇKA’nın Tanımı

Tek katmanlı algılayıcıların genelleştirilmiş hali olan, çok katmanlı algılayıcı (ÇKA), girdi katmanı, çıktı katmanı ve bu iki katman arasında genellikle bir, bazen de iki ya da daha fazla katmandan oluşan ileri beslemeli bir yapıya sahip YSA çeşididir. ÇKA, öğrenme algoritması olarak kullandığı geri yayılım algoritmasından dolayı geri yayılım ağları olarak da adlandırılmaktadırlar (Hamzaçebi, 2011: 43).

Yapay sinir ağlarının bir türü olan çok katmanlı algılayıcıların (ÇKA) temeli 1961’de Caianiello tarafından atılmıştır. Finansal piyasalara yönelik ilk uygulama ise 1988’de, White tarafından IBM hisse senedi üzerinde geliştirilmiştir. YSA modelleri finansal tahminleme konulu bilimsel çalışmalarda yoğun olarak kullanıldığı gibi, gelişmiş tahmin araç ve modelleri adıyla ticarileştirilerek çeşitli kurum ve enstitüler tarafından da kullanılmaktadır (Haznedaroğlu, 2009: 25–26) .

Tek bir katmandan oluşan bir algılayıcı sadece doğrusal fonksiyonları tahmin edebilmektedir ancak şekil 2.7’de örnek bir modeli gösterilen tek katmanlı algılayıcıların karşılaştıkları sınırlamalar, giriş ve çıkış katmanı arasında gizli katmanlara sahip olan ileri beslemeli çok katmanlı algılayıcılar için geçerli olmamaktadır (Alpaydın, 2010: 245–246).

Şekil 2.7. Tek Katmanlı Algılayıcı Modeli




Kaynak: (Öztemel, 2012: 59)

2.4.2. ÇKA Modelinin Yapısı

Çok Katmanlı Algılayıcı (ÇKA), eğitim aşamasında girdilerin ve bu girdilere karşılık üretilmesi beklenen çıktılarının gösterildiği modeldir. Oluşturulan ağ verilen girdiye göre çıktıyı bulmaktadır. Ağ yapısı ise Şekil 2.8’de verildiği üzere girdi katmanı, ara katman ve çıktı katmanı olmak üzere 3 farklı katmandan oluşur. Gelen bilgilerin ara katmana iletildiği katman girdi katmanıdır. Ara katman ise bir veya birden çok sayıda olabilir. Burada girdi katmanında alınan bilgiler işlenir. Çıktı katmanında ise ara katmandan alınan bilgilere karşılık her bir girdi için çıktı değerleri saptanır. Tüm katmanlar arasında işlem elemanları birbiriyle bağlantılıdır (Öztemel, 2012: 76-77).

Şekil 2.8. Çok Katmanlı Algılayıcı Modeli



Kaynak: (Öztemel, 2012: 76)

İleri beslemeli geri yayılım ağlarında katman sayısı ve katmanlardaki işlemci eleman sayısının ne olacağına karar vermek ağın başarılı sonuçlar üretebilmesi için oldukça önemlidir. Bu sayıların neler olacağına ilişkin net seçim kriterleri bulunmadığından bu tamamen ağı modelleyen kişinin deneme yanılma yöntemiyle varacağı bir karar olup sadece zamanla ortaya çıkmış, araştırmacılar ve mühendisler tarafından kabul görmüş referans alınabilecek bazı kurallar mevcuttur. Bu kurallar şu şekilde özetlenebilmektedir (Anderson ve McNeill, 1992: 33).

Kural 1: Girdi ve çıktı veriler arasındaki ilişkinin karmaşıklık derecesi arttıkça gizli katmandaki işlemci eleman sayısı da arttırılmalıdır.

Kural 2: Eğer modellenen işlem birçok aşamaya ayrılabilirse, fazla sayıda ara katman gerekebilmektedir. Eğer işlem aşamalara ayrılamıyorsa, gereğinden fazla ara katman kullanılması ağın ezberlemesine (Memorization) ve ağın gerçek bir genelleme yapamamasına sebep olmaktadır.

Kural 3: Yapay sinir ağının eğitilmesinde kullanılan örnek veri setinin genişliği, ara katmanlardaki işlemci elemanların sayısı için bir üst limit kriteri oluşturmaktadır. Bu üst limiti bulmak için önce eğitim setindeki girdi-çıkı çiftlerinin sayısı bulunmalı ve bulunan bu sayı ağdaki toplam girdi ve çıktı işlemci elemanlarının sayısına bölünmelidir. Daha sonra çıkan sonuç genellikle 5 ile 10 arasında bir değer alan bir ölçeklendirme katsayısına tekrar bölünmelidir. Fazla hata içeren veri setleri için bu ölçeklendirme katsayısı 20 ile 50 arasında değerler alabilmektedir.

Yukarıdaki kurallar dikkate alındıktan sonra artık ağın öğrenme aşamasına geçilebilmektedir.

2.4.3. ÇKA Ağının Öğrenme Kuralı

Çok katmanlı algılayıcılar, delta kuralının genelleştirilmiş şeklini kullanarak öğrenme işlemini gerçekleştirirler. Bu nedenle çok katmanlı ağların öğrenme kuralına Genelleştirilmiş Delta Kuralı da denmektedir. Çok Katmanlı Algılayıcıların öğrenmesi ileri besleme (feed forward) ve geri yayılma (backpropagation) olmak üzere iki aşamada gerçekleşmektedir. Aşağıda bu aşamaların açıklamalarına yer verilmektedir (Öztemel, 2012: 77–79).

2.4.3.1. İleri Besleme (Feed Forward)

ÇKA modelinde ağın çıktısının hesaplandığı İleri Doğru Hesaplama ve ağırlıkların güncellemesinin yer aldığı Geriye Doğru Hesaplama olmak üzere iki aşama bulunmaktadır. İleri doğru hesaplama aşamasında girdi katmanında k tane işlem elemanının olduğunu düşünelim. Buna bağlı olarak girdi katmanındaki işlem elemanlarının çıktısı denklem 2.4 ile tespit edilmektedir.

$$\zeta_k^i = G_k \quad (2.4)$$

Ara katmanda süreç elemanları için NET girdi değerlerinin hesaplanması, A_{kj} k . girdi elemanının j . ara katman elemanına bağlandığı ağırlık değeri olmak üzere, aşağıdaki denklem aracılığı ile hesaplanmaktadır.

$$NET_j^a = \sum_{k=1}^n A_{kj} \zeta_k^i \quad (2.5)$$

Ara katmandaki NET girdi değerleri ve aktivasyon fonksiyonu kullanılarak j ara katman elemanının çıktı değeri bulunur. Aktivasyon fonksiyonu olarak genellikle sigmoid fonksiyonu kullanılmaktadır. Sigmoid fonksiyonun tercih edilmesi durumunda ara katmandaki j elemanın çıktı değeri Denklem 2.6 aracılığıyla verilmiştir.

$$\zeta_j^a = \frac{1}{1 + e^{-(Net_j^a + \beta_j^a)}} \quad (2.6)$$

Denklem 2.6'de β_j^a olarak verilen değer, j . elemana bağlı eşik değer elemanının ağırlığını gösterir. Bu eşik değer elemanının çıktısı 1'e eşittir ve bu değer sabittir.

2.4.3.2. Geriye Yayılma (Backpropagation)

Geriye doğru hesaplama aşamasında ise hata değerinin hesaplama işlemi ile başlar. $(B_1, B_2, B_3 \dots)$ değerleri beklenen değer ve $(\zeta_1, \zeta_2, \zeta_3 \dots)$ değerleri çıktı değerleri olsun. Buna göre oluşan $(E_1, E_2, E_3 \dots)$ hata değerleri Denklem 2.7 ile hesaplanmaktadır.

$$E_m = B_m - \zeta_m \quad (2.7)$$

Ağda oluşan toplam hata (TH) ise E_m değerlerinin kullanılması ile aşağıdaki denklem aracılığıyla hesaplanmaktadır.

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (2.8)$$

ÇKA ağı eğitilirken hatanın en aza indirgenmesi amaçlanmaktadır.

Bu hesaplamanın ardından oluşan hata ağırlık değerlerine dağıtılmaktadır. Hem ara katman ile çıktı katmanları arasındaki ağırlıklar değiştirilir, hem de ara katmanlar arası veya ara katman ile girdi katmanları arasındaki ağırlıklar değiştirilir. Böylece ağırlıklarının tamamı değişecektir. İlk iterasyon ileriye ve geriye doğru hesaplamaları içermektedir. İkinci iterasyon için yeni bir örnek ağı gösterilmekte ve aynı işlemler ikinci örnek için de tekrar edilmektedir.

İleri beslemeli bir ağı, geri yayılım algoritmasıyla eğitime süreci, basitleştirilmiş olarak aşağıda maddeler halinde anlatılmaktadır (Portia, 2011: 4).

- Girdi verileri ağı sunularak çıkış katmanına ulaşana kadar ağı boyunca yayılır. İleriye doğru gerçekleşen bu süreç hesaplanan çıktıyı üretir.
- Tahmini çıktı, asıl çıktıyla karşılaştırılır ve ağı için bir hata değeri hesaplanır.
- Ağı eğitmek için, çoğu durumunda denetimli öğrenme algoritmalarından geri yayılım algoritması kullanılır. Bu algoritma, çıkış katmanları düğümleri ile en son gizli katman düğümleri arasındaki ağırlıklardan başlamak üzere ağı boyunca geriye doğru yayılır.
- Geri yayılım bittiğinde, ileri doğru süreç tekrar başlar ve bu döngü hesaplanan çıktı ile hedef çıktı arasındaki hata minimize edilene kadar devam eder.

2.4.4. ÇKA Ağı Oluşturulmasında Dikkat Edilmesi Gereken Noktalar

Tahmin amaçlı kurulan bir ÇKA modeline başlamadan önce dikkat edilmesi gereken önemli faktör ilgili probleme ilişkin verinin çalışılmasıdır. ÇKA'nın başarısında önemli bir yer tutan veriler belirlendikten sonra modellemeye geçilebilir. Ağı modellenmesinde katman sayısı ve her katmandaki nöron sayısının belirlenmesi gereken önemli kararlardan biridir. Gizli katman ve çıktı katmanındaki aktivasyon fonksiyonun


seçimi, eğitim algoritması, veri normalleştirme metodu, performans ölçütleri ve veri kümesinin belirlenmesi diğer önemli kararlar arasında yer almaktadır (Hamzaçebi, 2011: 70). ÇKA ağının performansını etkileyen diğer birçok unsur bulunmaktadır. Bir ÇKA ağı oluşturulurken bu unsurlara dikkat edilmesi gerekmektedir (Öztemel, 2012: 91).

- Örneklerin seçilmesi
- Girdi ve çıktıların ağı gösterimi
- Girdi ve çıktıların nümerik gösterimi
- Başlangıç değerlerinin atanması
- Öğrenme ve momentum katsayılarının belirlenmesi
- Örneklerin ağı sunulması
- Ağırlıkların değiştirilme zamanları
- Girdi ve çıktıların ölçeklendirilmesi
- Durdurma Kriterinin belirlenmesi
- Ara katmanların ve her katmandaki süreç elemanlarının sayısının belirlenmesi
- Ağların büyütülmesi veya budanması.

2.4.5. ÇKA ile Zaman Serisi Tahmini

Zaman serisi analizine dayalı tahmin probleminde, Şekil 2.9'da görüleceği üzere girdiler veri serisinin geçmiş gözlemlerinden oluşurken, çıktı gelecekteki tahmin değeridir. Bu ağ yapısı ile birden fazla dönem tahmin edilmek istendiğinde t dönemi için tahminde bulunulur, bulunan değer ağı girdi olarak sokulur ve $t + 1$ dönemi için tahminde bulunur. Bu yaklaşım ötelemeli (iteratif) tahmin olarak bilinmektedir. Zaman serileri tahmininde ÇKA ile başarılı sonuçlar elde edebilmek için girdi ve çıktı nöron sayılarının tespiti, gizli ve çıktı nöronu aktivasyon fonksiyonlarının seçimi çok önemlidir. Şekil 2.9'da zaman serisi tahmini amacı ile kurulan genel bir ÇKA modelini göstermektedir. (Hamzaçebi, 2011: 96–97).

Şekil 2.9. Zaman Serisi Tahmini Amacı ile Kurulan Tipik Bir ÇKA



Kaynak: (Hamzaçebi, 2011: 96)

2.4.6. ÇKA'nın İstatistik Tekniklere Göre Güçlü ve Zayıf Yanları

Tahmin amaçlı kullanılan ÇKA'lar, istatistik tekniklerle karşılaştırıldığında bazı üstünlükleri ve zayıf yanları olduğu görülmektedir. ÇKA'nın güçlü ve zayıf yanları aşağıda kısaca özetlenmektedir (Hamzaçebi, 2011: 79–81).

Güçlü Yanları:

- Doğrusal olmayan aktivasyon fonksiyonuna sahip olan ÇKA, doğrusal olmayan ilişkiyi başarı ile modelleyebilmektedir.
- Veri yapısındaki fonksiyonel ilişki için herhangi bir ön bilgiye ihtiyaç duymamaktadır.
- ÇKA, seriyi durağanlaştırmak için fark alma gibi bir işlem yapmadığından herhangi bir veri kaybına sebep olmamaktadır.
- İstatistik tekniklerin (doğrusal regresyon, ikili probit model, otoregresif modeller vb.) büyük bir çoğunluğu, ağırlık aktivasyon fonksiyonunda yapılacak çok küçük değişikliklerle ÇKA için kullanılabilir hale getirilmesi ağ yapısının esnek olmasını sağlamaktadır.

Zayıf Yanları:

- Doğrusal regresyon modelinde bağımsız değişkenlerin katsayıları bağımlı değişken üzerindeki etkilerini açık olarak gösterilirken ÇKA'da girdi değişkenlerinin çıktı üzerindeki etkilerini analitik olarak belirlemek çok zordur.
- Ağ ağırlıklarının en iyi değerleri bulması hata fonksiyonunu minimum kılmaktadır. Bu nedenle doğrusal olmayan tahmin metotlarında olduğu gibi ÇKA'da da genel minimumu bulamama riski bulunmaktadır.
- ÇKA'nın tam olarak genelleştirme yapabilmesi için yeterli miktarda örnekle ağ eğitilmediği takdirde veri yapısındaki ilişkiyi ortaya çıkartamama ya da yanlış eğitime (overfitting – ezberleme) durumları ortaya çıkabilmektedir.
- Bir araştırmacı için zaman çok önemlidir ancak ÇKA'nın kurulumu ve eğitimi verinin büyüklüğüne göre çok zaman alabilmektedir.

2.4.7. ÇKA Ağının Uygulama Alanları

Hayatın hemen hemen her alanında örnekleri görülen ÇKA genel olarak sınıflandırma, tahmin etme, tanıma, yorumlama ve teşhis etme problemlerinde başarı ile kullanılmaktadır. ÇKA ağı yatırımların planlanması, imza analizi, süreç kontrolü, pazarlama ve imalat sektörü gibi değişik alanlarda görülmektedir. Borsadaki bazı şirketlerin durumları yapay sinir ağları tarafından takip edilmektedir ve geleceğe yönelik tahminler yapılmasında özellikle ÇKA ağlarından faydalanılmaktadır (Öztemel, 2012: 105–106). Bölüm 2.7.'de ÇKA ile ilgili literatür araştırması ve ÇKA kullanılarak yapılan borsa tahmin çalışmalarına yer verilmektedir.

2.5. Destek Vektör Makineleri

Bu bölümde, Destek Vektör Makineleri (DVM) kavramı, DVM ile sınıflama ve DVM'in üstünlükleri ve kısıtları üzerinde durulacaktır.

2.5.1. DVM'in Tanımı

Destek vektör makineleri, orijinal ismiyle “Support Vector Machines (SVM)”, Vapnik tarafından geliştirilmiş istatistikî öğrenme teorisine dayanan bir metottur. Destek Vektör Makineleri (DVM), tarihsel olarak 1963 yılında Rusya'da Vapnik ve Lerner, 1964 yılında Vapnik ve Chervonenkis tarafından yürütülen çalışmalara dayanmaktadır. Destek Vektör Makineleri (DVM) bugünkü haline, büyük oranda Vapnik ve arkadaşları

tarafından AT&T Bell laboratuvarlarındaki geliřtirmeler sonucunda gelmiřtir. Endüstrideki bu geliřme, DVM arařtırmalarının günlük hayattaki uygulamalara yönlenmesine zemin hazırlamıřtır. Kısa zaman içerisinde, Destek Vektör Sınıflayıcıları hem OCR (Optical Character Recognition – Optik Karakter Tanıma) hem de nesne tanıma görevleri için mevcut en iyi sistemlerle rekabet eder hale geldi (Smola ve Schölkopf, 2004: 199).

2.5.2. DVM ile Sınıflama

Destek Vektör Makineleri, Doğrusal Destek Vektör Makineleri ve Doğrusal Olmayan Destek Vektör Makineleri olarak ikiye ayrılmaktadır.


2.5.2.1. Doğrusal Destek Vektör Makineleri

Doğrusal Destek Vektör Makineleri de kendi arasında doğrusal olarak ayrılabilme ve kendi arasında doğrusal olarak ayrılamama durumuna göre iki şekilde değerlendirilmektedir.

Doğrusal Olarak Ayrılabilme Durumu:

Şekil 2.10’da gösterilen D veri kümesinin $(x_1, y_1), (x_2, y_2) \dots (x_n, y_n)$ biçiminde olduğunu var sayacak olursak burada **n** veri kümesinin eleman sayısıdır ve $y \in \{+1, -1\}$ olarak kabul edilmektedir. Söz konusu şekilde solda görüleceğİ üzere veri farklı ve çok sayıda doğru ile ayrılabilir. Çok boyutlu uzayda bu doğruların yerini hiper düzlemler almaktadır.

Şekil 2.10. İki Boyutlu Uzayda Doğrusal Olarak Ayrılabilen Verilerin Görünümü ve Veriler Arasındaki Muhtemel En Büyük Boşluk



Kaynak: (Özkan, 2013: 185–186)

Veri kümelerini birbirinden ayırmak için birçok hiper düzlem kullanılabilir. Ancak iki hiper düzlem arasında en büyük boşluğa sahip olanları seçmek gerekmektedir. Şekil 2.10'da H_1 ve H_2 hiper düzlemler arasındaki en büyük boşluk ve bu iki hiper düzlemin ortasını oluşturan H_0 hiper düzlem görülmektedir. H_0 düzlemi iki sınıf veriyi birbirinden ayıran doğrusal hiper düzlemdir ve *optimal ayırma hiper düzlemi* adı verilmektedir (Özkan, 2013: 185–186).

Bir hiper düzlem üzerindeki noktalar cinsinden H_0 düzlemi denklem 2.9'da gösterildiği gibi ifade edilmektedir.

$$H_0: W^T X + b = 0 \quad \text{diğer bir ifadeyle} \quad H_0: \sum_{i=1}^n w_i x_i + b = 0 \quad (2.9)$$

Burada W ağırlık vektörünü $W = \{ w_1, w_2, \dots, w_n \}$; n ise niteliklerin sayısını göstermektedir. İfade içerisinde yer alan b ise sabit bir sayıyı göstermektedir. Eğitim kümesi ise, iki boyutlu uzay söz konusu olduğu içinde $X = (x_1, x_2)$ biçimindedir. Burada x_1 ve x_2 değerleri X için A_1 ve A_2 nin değerleri olarak gözönüne alınmaktadır. H_1 ve H_2 düzlemlerinin ifade şekli sırasıyla denklem 2.10 ve 2.11'de gösterilmektedir.

2.9'da belirtilen hiper düzlemin üst tarafında kalan noktalar $W^T X + b > 0$, $y_1 = +1$ eşitsizliğine uyduğunda H_1 hiper düzlemi;

$$H_1 : W^T X + b = 1 \quad (2.10)$$

2.9’da belirtilen hiper düzlemin alt tarafında kalan noktalar $W^T X + b < 0$, $y_2 = -1$ eşitsizliğine uyduğunda H_2 hiper düzlemi;


$$H_2 : W^T X + b = -1 \quad (2.11)$$

şeklinde gösterilmektedir (Özkan, 2013: 187).

Verilerin Doğrusal Olarak Ayrılama Durumu:

Bazı verileri doğrusal bir düzlem ile ayırmak mümkün değildir. Böyle bir durumda negatif olmayan ve hataları ifade eden ξ_i gevşek değişkenlerin optimizasyon modeline eklenmesi sağlanarak bu soruna çözüm bulunmaktadır (Özkan, 2013: 195). Birbirinden doğrusal olarak ayrılamayan verilere örnek Şekil 2.11’de solda gösterilmektedir.

Şekil 2.11. Birbirinden Doğrusal Olarak Ayrılama Veriler ve Gevşek Değişkenler



Kaynak: (Özkan, 2013: 195–196)

Veriler doğrusal olarak tamamen ayrılabilir durumda değilse problemin çözümü için pozitif gevşek değişkenleri, ξ_i , $i = 1, 2, \dots, l$ kullanılmaktadır. Gevşek değişkenler yardımı ile yeni ifadeler:

$$w^T x_i + b \geq +1 - \xi_i, y_i = +1 \text{ için} \quad (2.12)$$


$$w^T x_i + b \geq -1 + \xi_i, y_i = -1 \text{ için} \quad (2.13)$$

şeklinde yazılabilmektedir (Burges, 1998: 135). Burada, $\xi_i > 1$ olan veriler doğrusal olarak ayrılmayı önleyen bölgedeki gözlem değerleridir. $0 < \xi_i < 1$ olması durumunda hiper düzlemin doğru yanında yer alan, ancak en büyük boşluk alanı içinde kalan gözlem değerlerini ifade etmektedir (Özkan, 2013: 196).

2.5.2.2. Doğrusal Olmayan Destek Vektör Makineleri

Bir önceki bölümde, veri kümelerinin bir doğrusal hiper düzlem ile ayrılabilirdiğinden ve verilerin doğrusal olarak ayrılamadığı durumlarda gevşek değişkenlerin modele koyularak çözüm aranılması gerektiğinden bahsedilmişti. Ancak gerçek dünyada verilerin doğrusal olarak ayrılamadığı örneklerle de karşılaşilmektedir. Bu durumlarda doğrusal destek vektör makineleri yerine doğrusal olmayan destek vektör makineleri kullanılmaktadır (Özkan, 2013: 199).

Şekil 2.12. Kernel Fonksiyonu ile Verinin Daha Yüksek Bir Boyuta Dönüştürülmesi



Kaynak: (Tekin, 2013: 32)

Şekil 2.12’de görüldüğü üzere girdi uzayında doğrusal olarak ayrılamayan veriler doğrusal olarak ayrılacakları özellik uzayı olarak tanımlanan yüksek boyutlu başka bir uzaya taşınmakta ve sınıflandırma o uzayda yapılmaktadır. Bunun için önce, doğrusal

olarak ayrılamayan verileri Φ olarak adlandırılan bir taşıma fonksiyonu kullanılarak, (2.14)'de gösterildiği gibi daha yüksek boyutlu başka bir H Euclid uzayına taşındığını varsayacak olursak:

$$\Phi : \mathcal{R}^d \rightarrow H \quad (2.14)$$

Girdi uzayı $\mathcal{R}^d$ 'de doğrusal olarak ayrılamayan örneklerin, özellik uzayı H 'de doğrusal olarak ayrılabilmesi beklenmektedir. $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ şeklinde ifade edilen bir çekirdek fonksiyonu kullanılarak doğrusal olarak ayrılamayan verinin, doğrusal olarak ayrılabilceği bir özellik uzayına rahatlıkla taşınabilmektedir (Tekin, 2013: 196–199). Çekirdek fonksiyonu olarak çeşitli fonksiyonlar kullanılabilir. Tablo 2.5’de yaygın olarak kullanılan çekirdek fonksiyonları gösterilmektedir:

Tablo 2.5. Çekirdek Fonksiyonları

Çekirdek	Çekirdek Fonksiyonları
Doğrusal Çekirdek Fonksiyonu	$K(x_i, x_j) = x_i^T x_j$
Polinom Çekirdek Fonksiyonu	$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$
Sigmoid Çekirdek Fonksiyonu	$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$
Radyal Tabanlı Çekirdek Fonksiyonu (RBF)	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$

Kaynak: (Hsu, Hsieh, Chih ve Hsu, 2009: 7950; Tayyar ve Tekin, 2013: 200)

2.5.3. DVM’in Üstünlükleri ve Kısıtları

Destek Vektör Makinelerinin başlıca üstünlükleri ve kısıtları aşağıda listelenmektedir (Elmas, 2012: 18–19).

Destek Vektör Makinelerinin Üstünlükleri;

- Karmaşık karar sınırlarını modelleyebilmekte ve çok daha kolay yüksek doğrulukta tahmin elde edilmektedir.
- Çok sayıda bağımsız değişkenle çalışabilmektedir. Genelleme yeteneği yüksektir.
- Optimizasyon işleminde dışbükey amaç fonksiyonu kullanılarak evrensel minimum garanti edilir.

- Hem doğrusal olarak ayrılabilen hem de doğrusal olarak ayrılamayan verilere uygulanabilmektedir.
- Uygun bir dönüşüm ile her zaman veri bir hiper düzlem ile iki sınıfa ayrılabilir.

Destek Vektör Makinelerinin Kısıtları;

- Doğru çekirdek seçimini yapmak en büyük kısıtlarından biridir.
- Eğitim ve test verilerinin boyutları yükseldikçe hızı azalmaktadır

2.6. Derin Öğrenme

Bu bölümde derin öğrenmenin tanımı, tarihçesi, kullanılan kütüphaneler/yazılımlar, derin öğrenme uygulamaları ve çalışmada kullanılan bir diğer model uzun kısa vadeli hafıza konularından bahsedilecektir.


2.6.1. Derin Öğrenme'nin Tanımı

Derin öğrenme, çok sayıda katman içeren ve her katmanın kendinden önceki daha basit verileri birleştirerek daha karmaşık ve anlamlı bütünler üreten bir yapay sinir ağı türüdür (Birer, 2018: 58). Deng ve Yu çalışmalarında derin öğrenmenin çeşitli tanımlamalarına yer vermektedirler. Bu tanımlarda çoklu katmanlardan oluşan modeller veya doğrusal olmayan bilgi işlem aşamaları ve art arda daha yüksek, daha soyut katmanlarda özellik temsilinin denetimli veya denetimsiz bir şekilde öğrenilmesine yönelik yöntemler gibi ortak iki önemli hususa değinilmektedir (Deng, Yu ve others, 2014: 200–201).

Derin öğrenme yöntemleri, düşük seviyeli özelliklerin bileşimi ile oluşan yüksek seviyeli hiyerarşinin özelliklerinden oluşan özellik hiyerarşilerini öğrenmeyi amaçlamaktadır. Bir soyutlamanın çoklu seviyelerindeki özelliklerini otomatik olarak öğrenmek; bir sistemin, tamamen insan yapımı özelliklere bağlı olmadan girişi doğrudan veriden eşleştiren karmaşık işlevlerini öğrenmesini sağlamaktadır (Bengio, 2009: 5–6).

Verinin temsilinden öğrenmeye dayalı derin öğrenme yönteminin görevlerinden biri olan görüntü işleme örneği Şekil 2.13'de gösterilmektedir. Söz konusu şekilde ham girdi görüntüsünün kenarlar, yerel şekiller, nesne parçaları gibi daha soyut fonksiyonları yansıtan daha yüksek temsil seviyelerine kademeli olarak dönüştürülmesi gösterilmektedir (Bengio, 2009: 3).

Şekil 2.13. Görüntü İşleme




Kaynak: (Bengio, 2009: 3)

2.6.2. Derin Öğrenme'nin Tarihçesi

Çoklu doğrusal olmayan özellik katmanlarına sahip olan en eski derin öğrenmeye benzer algoritmalar Ivakhnenko ve Lapa tarafından 1965 yılında yayınlanmıştır (Şekil 2.14). Her katmanda en iyi özellikleri istatistiksel yöntemlerle seçilip bir sonraki katmana iletilen bu çalışmada, Ivakhnenko ve Lapa ağlarını uçtan uca eğitmek için geri yayılımı (backpropagation) kullanmamış, önceki katmanlardan sonraki katmanlara en küçük kareler yöntemi kullanmışlardır (Şeker, Diri ve Balık, 2017: 48).

Şekil 2.14. Ivankhnenko A. Tarafından Eğitilen Bilinen İlk Derin Ağ Mimarisi



Kaynak: (Şeker ve diğerleri, 2017: 48)

1979 yılında Fukushima, görsel örüntü tanıma mekanizması için bir sinir ağı önermiş ve "denetimsiz öğrenme" ile kendi kendini organize eden bir ağ geliştirmiştir. Omurgalı canlıların görsel sinir sistemlerinden esinlenerek ortaya atılan bu ağa "Neocognitron" adı verilmiştir (Fukushima, 1980). 1989 yılında Yann LeCun ve arkadaşları ilk başarılı derin sinir ağı uygulamasını posta kutusu yazıları üzerinde gerçekleştirmişlerdir (LeCun ve diğerleri, 1989). Başka bir çalışmada Yann LeCun "LeNet" ağını kullanarak el yazısı rakamlarını (MNIST) sınıflandırmak için kıvrımlı ağlarla geri yayılımı birlikte kullanmıştır (LeCun ve diğerleri, 1990). Daha sonra bu sistem Amerika Birleşik Devletleri'nde çok sayıda elle yazılan çekleri okumak için kullanıldı. Bu başarılarla rağmen, sinir ağları üzerine yapılan araştırmalar için yeterli finansman bulunmamaktaydı. Yapay Zekâ Kışı olarak adlandırılan bu dönemde çalışmalar neredeyse durma noktasına gelmiş ve tekrar iyileşmesi için biraz zamana ihtiyaç duyulmaktaydı (Detmers, 2015).

1997'de, Hochreiter ve Schmidhuber'in ortaya attığı tekrarlayan sinir ağları (recurrent neural networks) için Uzun Kısa Vadeli Bellek (long short-term memory) gibi bazı önemli gelişmeler kaydetmişlerdir (Hochreiter ve Schmidhuber, 1997) ancak bu gelişmeler (Cortes ve Vapnik, 1995) tarafından geliştirilen destek vektör makinesi ile gölgede bırakıldığından dolayı belli bir zamana kadar fark edilmedi. Diğer bir büyük gelişme bilgisayarların çalışma hızlarının artması ve sonrasında grafik işlemci

birimlerinin (GPUs) hesaplamalarda kullanılması ile gerçekleşmiş; hesaplama hızı, 10 yıllık bir sürede yaklaşık 1000 kat artmıştır. Bu dönemde, YSA yeniden, destek vektör makinelerine rakip olmaya başlamıştır (Detmers, 2015).

Bu gelişmelere rağmen ağıdaki ilk katmanlara hiçbir öğrenme sinyalinin ulaşamadığı büyük ve derin ağları eğitmek hala sorun olmaktaydı. Bu probleme çözüm olarak ilk katmanlardaki özelliklerin hali hazırda başlatılabilmesi ya da bazı uygun özelliklerle “önceden eğitilebilmesi” için denetimsiz öğrenme kullanarak katman katman kurulan ön-eğitim modeli sunulmuştur. İlk ön-eğitim (pre-training) yaklaşımları 1992 yılında tekrarlayan sinir ağları için (Jürgen Schmidhuber, 1992) ve ileri beslemeli ağlar için 2006 yılında (Hinton ve Salakhutdinov, 2006) tarafından geliştirilmiştir. GPU hızlarının artmasıyla birlikte derin ağların ön-eğitim (pre-training) olmaksızın eğitilebilmesi mümkün hale gelmiştir. Cireşan ve arkadaşları trafik işaretleri (Cireşan, Meier, Masci ve Schmidhuber, 2012), medikal görüntüleme (D. Cireşan, Giusti, Gambardella ve Schmidhuber, 2012) ve karakter tanıma (D. C. Cireşan, Meier, Gambardella ve Schmidhuber, 2011) konularını elen alan çalışmalarında da bu yaklaşımı kullanmışlardır. (Hinton, Srivastava, Krizhevsky, Sutskever ve Salakhutdinov, 2012) benzer mimariler tasarlamışlar ve GPU destekli yaptıkları çalışmalarında, ezberlemeyi (overfitting) azaltmak için ise, “dropout” adı verilen normalleştirme yöntemini kullanmışlardır.

Şekil 2.15. Yıllara Göre Yapay Zekâ Başlangıç Şirketlerin Satın Alınması




Kaynak: (Şeker ve diğerleri, 2017: 49)

Bu gelişmelerden sonra bu trendi fark eden Google, Facebook, Apple ve Microsoft gibi teknoloji firmaları derin öğrenme alanına yatırım yapmaya başlamışlardır. Şekil 2.15’den bazı örnekler vermek gerekirse; facebook “face.com” u satın alarak fotoğraf etiketleme işinde başarıyı artırmayı hedeflenmiştir. Apple “Novauris” şirketini satın alarak SİRİ üzerinde iyileştirmeler yapmıştır. Microsoft, doğal dil işleme ve yapay zekâ çalışmaları da bulunan yaklaşık 100 dil için çalışan klavye uygulaması şirketi “SwiftKey” satın almıştır. Şekil 2.15’te görüldüğü gibi, 2012-2017 yıllarında çalışma grupları ve başlangıç (startup) şirketleri satın alınmasıyla başlayan süreçte derin öğrenme alanındaki gelişmeler bir hayli hızlanmıştır (Şeker ve diğerleri, 2017: 50).

2.6.3. Derin Öğrenme Kütüphaneleri/Yazılımları

Derin öğrenme için geliştirilen çok farklı çerçeve ve kütüphaneler bulunmaktadır. Şekil 2.16’da bu kütüphanelerin güç skorları ve Şekil 2.17’de bazı özelliklerine göre üstünlükleri gösterilmektedir. Şekil 2.16’da yer alan grafiğe göre %96.77 ile TensorFlow en güçlü kütüphane ve %51.55 ile Keras ikinci en güçlü kütüphane olarak görülmektedir. Çalışmada kütüphane olarak TensorFlow kullanıldığı için aşağıda kısaca bu kütüphaneye değinilecektir.

Şekil 2.16. Derin Öğrenme Çerçeve Güç Puanları 2018



Kaynak: (Hale, 2018)

TensorFlow, veri akış grafikleri kullanarak sayısal hesaplama için kullanılan açık kaynaklı bir yazılım kütüphanesidir. Grafik düğümleri matematiksel işlemleri temsil ederken, grafik kenarları aralarında akan çok boyutlu veri dizilerini (tensörler) temsil etmektedir. Esnek mimarisi sayesinde, hesaplama kodu yeniden yazılmadan bir masaüstü bilgisayar, sunucu veya mobil cihazdaki bir veya daha fazla CPU'ya veya GPU'ya dağıtılmasına olanak tanımaktadır.

TensorFlow, makine öğrenimi ve derin sinir ağları araştırması yürütmek amacıyla Google'ın Makine İstihbarat araştırma organizasyonu bünyesindeki Google Beyin Ekibinde çalışan araştırmacılar ve mühendisler tarafından geliştirildi. Sistem, diğer birçok alanlarda da kullanılmaya başlanmıştır. Eğitim ve öğretim materyalleri, CNN modelleme yeteneği, RNN modelleme yeteneği, mimari, hız, çoklu GPU desteği ve Keras ile uyumlu olması bakımından diğer kütüphanelere kıyasla daha güçlü olduğu Şekil 2.17'de görülmektedir. TensorFlow, Python ve C API'lerinin yanı sıra C++, Go, Java, JavaScript ve Swift için geriye dönük uyumlu API'ler de sunmaktadır (www.github.com, 2019).

Şekil 2.17. Derin Öğrenme Kütüphanelerinin Karşılaştırılması

	Diller	Eğitim ve Öğretim Materyalleri	CNN Modelleme Yeteneği	RNN Modelleme Yeteneği	Mimari: Kullanımı Kolay ve Modüler Ön Uç	Hız	Çoklu GPU Desteği	Keras Uyumlu
Theano	Python, C++	++	++	++	+	++	+	+
Tensor-Flow	Python	+++	+++	++	+++	++	++	+
Torch	Lua, Python (new)	+	+++	++	++	+++	++	
Caffe	C++	+	++		+	+	+	
MXNet	R, Python, Julia, Scala	++	++	+	++	++	+++	
Neon	Python	+	++	+	+	++	+	
CNTK	C++	+	+	+++	+	++	+	

Kaynak: (Rubashkin, 2017)

2.6.4. Derin Öğrenme Uygulamaları

Derin öğrenme, doğal dil işleme, görüntü ve video işleme, biyomedikal görüntü/bilgi işleme gibi alanlarda sıklıkla kullanılmaktadır. Bunların dışında derin öğrenme, insan aktivite tanıma ve insan hareket tespiti, bilgisayar-insan etkileşimi, CRM (Müşteri İlişkileri Yönetimi), sağlık hizmetleri, araç otonom sistemleri ve multimedya yönetimi gibi konularda da denenmektedir (Şeker ve diğerleri, 2017: 53–56).


2.6.5. Uzun Kısa Vadeli Hafıza

Yapay sinir ağlarında katman sayılarının artırılmasıyla kurulan çok farklı türde derin öğrenme mimarileri bulunmaktadır. En sık kullanılan mimariler; Konvolüsyonel Sinir Ağları, Tekrarlanan Sinir Ağı, Uzun Kısa Vadeli Hafıza, Kısıtlanmış (Derin) Boltzmann Makineleri, Derin İnanç Ağları ve Derin Oto-kodlayıcılarıdır (Şeker ve diğerleri, 2017: 50–52). Bu bölümde çalışmada kullanılan mimarilerden biri olan Uzun Kısa Vadeli Hafıza (UKVH) üzerinde durulacaktır ancak öncesinde tekrarlayan yapay sinir ağlarına (RNN) değinmek UKVH'nın anlaşılmasında yarar sağlayacaktır.

Tekrarlayan yapay sinir ağları (RNN), birimler arasındaki bağlantıların, yönlendirilmiş bir döngü oluşturduğu ağlardır. Bu ağların ileri beslemeli sinir ağlarından farklı yanı kendi giriş belleklerini, girdileri işlemek için kullanabilmeleridir bu da onları el yazısı tanıma ve konuşma tanımada, kullanılabilir bir yöntem yapmaktadır (Alp, 2018). Örneğin, bir filmin her noktasında ne tür bir olay olduğu sınıflandırmak istendiğinde, geleneksel sinir ağları filmdeki daha önce gerçekleşen olaylar hakkındaki muhakemesini daha sonra bilgilendirmek için nasıl kullanabileceğini insanlar gibi anlamlandıramadığından, sınıflandırma yapamayacaktır. Bilginin devam etmesine izin veren döngüler içeren tekrarlayan sinir ağları bu sorunu ele almaktadır (Alp, 2018; Gündoğmuş, 2019).

Aşağıdaki şekilde basit bir tekrarlayan sinir ağ görüntülenmektedir. A ismi verilen dikdörtgen, bir yapay sinir ağındaki hücreyi temsil etmektedir. X sinir ağının girdi değeri ve h ise ağın çıktı değeridir (Olah, 2015).


Şekil 2.18. RNN İçerisindeki Döngü



Kaynak: (Olah, 2015)

Tüm tekrarlayan sinir ağıları, sinir ağının tekrarlayan modüllerinin bir zinciridir. Standart RNN’lerde, Şekil 2.18’de gösterilen bu tekrarlayan modül, tek bir tanh tabası gibi çok basit bir yapıya sahiptir.


Şekil 2.19. Standard RNN’de Tekrarlayan Tek Katman



Kaynak: (Olah, 2015)

Geleneksel RNN’lerde, tekrarlayan kısımda tek bir tanjant fonksiyonu (katmanı) bulunmaktadır. Şekilde bu tek bir tanjant fonksiyonu (katmanı) gösterilmektedir. UKVH’larda tek bir sinir katmanı yerine tekrarlayan zincir şeklinde dört farklı katman bulunmaktadır. Aşağıdaki şekilde, UKVH’da bulunan 4 farklı katman gösterilmektedir.


Şekil 2.20. UKVH'daki Dört Etkileşimli Katman



Kaynak: (Olah, 2015)

UKVH mimarisinin görselleştirildiği resimlerde, birçok sembol bulunmaktadır. Şekil 2.21’de okların çizgi kısmı düğümdeki çıkışları, baş kısımları ise diğer düğümlere girdi olarak veriyi taşımaktadır. Okun yönü, verinin taşındığı düğümü göstermektedir. Vektör eklemesi gibi noktasal operasyonları pembe daire ile simgelenmektedir. Yapay sinir katmanları sarı dikdörtgen ile gösterilmektedir. İki okun birleşmesi, iki farklı vektörün birleşip, başka bir düğüme girdi oluşturmaktadır. Düğümden çıkan bir vektörün, birden fazla düğüme girdi olarak kopyalanmakta olduğu ise çatal şeklindeki ok ile gösterilmektedir

Şekil 2.21. UKVH Mimarisinde Kullanılan Semboller




Kaynak: (Olah, 2015)

Uzun vadeli bağımlılıkları öğrenen özel bir RNN türü olan Uzun Kısa Vadeli Bellek (Long Short Term Memory – LSTM) ağları 1997 yılında Hochreiter ve Schmidhuber tarafından tanıtılmıştır (Hochreiter ve Schmidhuber, 1997). Şekil 3.7’de görüldüğü üzere LSTM mimarisi üç kapı (giriş, unutma, çıkış), blok girişi, tek bir hücre (Sabit Hata Döngüsü), bir çıkış aktivasyon fonksiyonu ve gözetleme (peephole)

bağlantılarına sahiptir (Greff, Srivastava, Koutnik, Steunebrink ve Schmidhuber, 2017: 2222). Bloğun çıktısı tekrar tekrar bloğun girişine ve tüm kapılara bağlanmaktadır. Gözetleme bağlantıları ve unutma kapısı ilk geliştirilen mimaride bulunmaktadır. LSTM'in kendi durumunu sıfırlamak için bellek bloklarının içeriğinin güncelliğini yitirdiği ve bu nedenle geçersiz hale geldiğinde bellek bloklarının sıfırlamayı öğrenen unutma kapısı (Gers, Schmidhuber ve Cummins, 2000: 2455), kesin zamanlamaları öğrenmeyi kolaylaştırmak hücrelerin kendi mevcut durumlarını denetlemek için ise gözetleme bağlantıları eklenmiştir (Gers ve Schmidhuber, 2000: 193).


Şekil 2.22. RNN’de kullanılan SRN birimi (Solda) ve LSTM (sağda) ayrıntılı şeması



Kaynak: (Greff ve diğerleri, 2017: 2223)

Şekil 2.22’de solda hücrenin üst tarafında gösterilen yata çizgi UKVH’ların kilit noktası hücrenin durumudur (cell state). Bir çeşit taşıma bandı gibi olan hücrenin durumunda bilgi genellikle soldan sağa ilerlemektedir ancak bazı küçük doğrusal etkileşimlerde, zincirin alt tarafına doğru da ilerleyebilmektedir. UKVH’lar kapılar (gate) yardımıyla, hücre durumundan, bilgi silme ve hücre durumuna bilgi ekleme yeteneğine sahiptirler. Bu kapılar, isteğe bağlı olarak bilginin geçmesine imkân tanımaktadır. Bu hücre, Şekil 2.22’de sağda gösterilen noktasal çarpma işlemi ve sigmoid sinir katmanından oluşmaktadır.

Şekil 2.23. Kilit Noktası Olan Hücresinin Durumu




Kaynak: (Olah, 2015)

Hücre durumunu korumak ve kontrol etmek için bulunan bu kapıların aşamalarına aşağıda kısaca değinilecektir (Alpaydın, 2010; Gündoğmuş, 2019; Olah, 2015).

LSTM ağının ilk aşaması Şekil 2.24’de gösterilen unutma kapısı ile hücre durumundan hangi bilgilerin atılıp atılmayacağını (saklanıp saklanmayacağını) karar verilmesi aşamasıdır. Bu karar “forget gate layer (unuturucu geçit katmanı)” adı verilen sigmoid bir katman tarafından yapılmaktadır. Bu katman h_{t-1} ve x_t ’ye baktıktan sonra hücre durumundaki C_{t-1} her bir sayı için 0 ile 1 arasında bir sayı üretmektedir. Eğer 1 çıkarsa tamamen bunu tut, 0 çıkarsa bunu tutmana gerek yok anlamına gelmektedir.

Şekil 2.24. Unutma Kapısı Katmanı ve Formülü




Kaynak: (Olah, 2015)

UKVH’ların bir sonraki aşaması, giriş kapısı ile yapılan hangi bilginin hücrede tutulacağı bilgisinin belirlenmesidir. Giriş kapısı, sigmoid sinir ağı ve tanjant katmanı olmak üzere ikiye ayrılmaktadır. Sigmoid sinir katmanında, hangi değerlerin

güncelleneceğine karar verilirken, tanjant katmanda ise saklanması gereken yeni vektör, C_t oluşturulmaktadır. Giriş katmanında, iki farklı değer birleşerek, yeni saklanacak olan değeri oluşturmaktadır. Şekil 2.25'te giriş kapısı katmanı ve tanjant kapısı katmanı ile bu kapıların formülleri gösterilmiştir.


Şekil 2.25. Giriş Kapısı Katmanı ve Tanjant Kapıların Formülleri



Kaynak: (Olah, 2015)

Yeni saklanan değerin ne olacağına, giriş katmanında tanjant katmanı ile karar verilmektedir. Giriş kapısından gelen vektör, sigmoid sinir katmanından gelen değer olan, i_t değeri ile tanjant katmanından gelen değer olan C_t 'nin çarpılması ile belirlenmektedir. Giriş kapısından çıkan vektör, bir önceki aşamada belirlenmiş olan ($f_t * C_{t-1}$) değeri ile toplanmaktadır. Şekil 2.26'de bellekte bekleyen veri ile bellekte saklanacak yeni verinin, yer değiştirilmesi işlemi ve formülleri gösterilmiştir.

Şekil 2.26. Hücre Durumundaki Eski İle Yeni Verinin Güncellenmesi




Kaynak: (Olah, 2015)

Çıkış katmanı, tanjant ve sigmoid katmanı olmak üzere iki katmandan

oluşmaktadır. Tanjant katmanında, -1 ile 1 arasında değer çıkmakta ve saklanan bilginin ne kadarının kullanılacağı tanjant katmanı ile hesaplanmaktadır. Sigmoid katmanının çıktısı ise 0 ile 1 arasında çıkmakta ve yeni gelen bilginin kullanılıp kullanılmayacağına bu katmanda karar verilmektedir. Çıkış katmanı, sigmoid ve tanjant katmanlarından gelen değerlerini çarparak oluşan değeri çıktı değeri olarak belirlemektedir. Şekil 2.27’de UKVH hücresinde bulunan çıkış katmanı ve formülü gösterilmiştir.

Şekil 2.27. Çıkış Kapısı ve Formülleri



Kaynak: (Olah, 2015)

2.7. İlgili Literatür Taraması

Bu bölümde makine öğrenmesi yöntemlerinden çok katmanlı sinir ağları, destek vektör makineleri ve derin öğrenme yöntemi olan uzun kısa vadeli hafıza ile ilgili literatür taramasına yer verilmektedir. Günümüzde borsa tahmin modellemelerinde yaygın olarak kullanılan makine öğrenmesi yöntemlerinden olan Sinir Ağları (SA), Destek Vektör Makineleri ve ya bunları diğer algoritmalar ile birleştiren modeller ve son zamanlarda Uzun Kısa Vadeli Hafıza gibi derin öğrenme yöntemleri kullanılmaktadır. Zaman serisi modelleme ve tahminde yapay sinir ağlarının (YSA) kullanıldığı birçok araştırma yapılmış Zhang, Patuwo ve Hu (1998) ve YSA modelleri birçok disiplinde öngörme ve ya tahmin çalışmalarında başarıyla kullanılmıştır. İlk olarak, tahmin dâhil birçok uygulamada kullanılan YSA'nın en popüler ve yaygın kullanılan bir çeşidi çok katmanlı ileri beslemeli ağlar ile ilgili literatüre yer verilecektir.

Çok katmanlı algılayıcıların ilk başarılı uygulamalarından biri Lapedes ve Farber (1987) tarafından sunulmuştur ve takip eden yıllarda öğrenci not ortalamaları Gorr, Nagin ve Szczypula (1994), ozon seviyesi Ruiz-Suarez, Mayora-Ibarra, Torres-Jimenez ve Ruiz-Suarez (1995), emtia fiyatları Kohzadi, Boyd, Kermanshahi ve Kaastra (1996),

reklam Poh, Yao ve Jašic (1998), elektrik yük tüketimi Darbellay ve Slama (2000), makroekonomik verilerin tahmin edilmesi Aminian, Suarez, Aminian ve Walz (2006), demiryolu trafiği tahminleri Zhuo, Li-Min, Yong ve Yan-Hui (2007) ve finansal zaman serisi tahminleri Yu, Wang ve Lai (2009) gibi birçok başka problem çözülmüştür.

Kaastra ve Boyd (1996), çalışmalarında borsalar gibi finansal piyasaların tahmin edilmesini derinlemesine araştırmışlardır. Aynı yıl içerisinde, Schierholt ve Dagli (1996) eğitilebilecek farklı sinir ağı yapıları kullanarak Standard & Poors 500 Endeksini modellemişlerdir, fakat olasılıksal sinir ağı çok katmanlı algılayıcıdan biraz daha iyi bir performans sergilemiştir.

Mostafa (2010), 2001-2003 dönemine ilişkin verileri kullanarak Kuveyt Borsası (KSE) kapanış fiyat hareketlerini tahmin etmek için iki sinir ağı mimarisini, çok katmanlı algılayıcı (ÇKA) ve genelleştirilmiş regresyon sinir ağlarını kullanmıştır ve sinir ağlarının gelişmekte olan piyasalardaki borsa hareketlerini tahmin etmede iyi bir performans gösterdiği sonucuna varmıştır.

Naeini, Taremian ve Hashemi (2010), çalışmalarında bir şirketin hisse senedi değeri geçmişine dayanarak hisse senedinin değerini tahmin etmek için iki tür sinir ağı, Çok Katmanlı Algılayıcı (ÇKA) ve Elman tekrarlayan ağı kullanmışlardır. Deneysel sonuçlar, ÇKA'nın Elman tekrarlayan ağı ve doğrusal regresyon yönteminden daha iyi performans sergilediğini göstermiştir.

Başka bir çalışmada, Devadoss ve Ligor (2013) piyasalardaki oynaklığa rağmen, Bombay Borsası'nın (BSE) hisse senedi fiyatını tahmin etmek için geri yayımlı çok katmanlı ağların başarılı bir şekilde kullanıldığını belirtmişlerdir.

Kutlu, Ozturan ve Badur (2003), Türkiye Cumhuriyet Merkez Bankasının 1 Temmuz 2001 – 28 Şubat 2003 tarihleri arasında toplanan verilerle İstanbul Menkul Kıymetler Borsası (İMKB) piyasa endeksi değerini tahmin etmek için hareketli ortalamalara göre daha iyi performans gösteren çok katmanlı algılayıcı ve genelleştirilmiş ileri beslemeli ağlarını kullanmışlardır.

Yumlu, Gurgen ve Okay (2005), 1990-2002 yılları arasındaki İstanbul Menkul Kıymetler Borsası (İMKB) UX100 endeksinin 12 yıllık verilerini kullanarak çok katmanlı algılayıcı (ÇKA), tekrarlayan sinir ağı (TSA) ve Uzman Karışımı modellerinin karşılaştırmasını yapmışlardır. Her model isabet oranı (H_R), pozitif isabet oranı (H_R^+), negatif isabet oranı (H_R^-), ortalama kare hatası (MSE), ortalama mutlak hata ve korelasyon

(ξ) gibi piyasa endeks getiri serisinin bilinen kriterlerine göre karşılaştırılmıştır. Sonuç olarak, Uzman Karışım modelinin diğer modeller göre daha üstün olduğunu gözlemlemişlerdir.

Guresen, Kayakutlu ve Daim (2011), sinir ağı modellerinin borsa tahminlerinde etkinliğini değerlendirmişlerdir. Analiz edilen modeller çok katmanlı algılayıcı (ÇKA), dinamik sanatsal sinir ağı (DAN2) ve yeni girdi değişkenlerin çıkarmak için genelleştirilmiş otoregressif koşullu heteroscedastisite (GARCH) kullanan hibrit sinir ağlarıdır. Her bir model, NASDAQ Menkul Kıymetler Borsası endeksinin günlük gerçek döviz kuru değerlerini kullanarak Ortalama Kare Hatası (MSE) ve Ortalama Mutlak Sapma (MAD) ile karşılaştırılmıştır.

Yapay sinir ağı, finansal zaman serileri tahmini alanında, üstün öğrenme kabiliyeti ve birçok işletme sorununa geniş uygulanabilirliği nedeniyle geniş çapta kullanılmaktadır. Ancak gizli katman sayısı, gizli düğüm sayısı, öğrenme hızı, devirler, momentum terimi, transfer fonksiyonları, ağırlıkları başlatma yöntemleri, katmandaki işlem elementlerinin sayısı ve aşırı uyum tehlikesi gibi kontrol parametrelerinin değerini belirlemede birçok dezavantaja sahiptir. Son zamanlarda destek vektör makineleri (DVM), hisse senedi fiyat endeksi ve hareketlerinin öngörülmesinde başarıyla uygulanmaktadır (Borges, 1998; Mukherjee, Osuna ve Girosi, 1997; Müller ve diğerleri, 1997; Smola ve Schölkopf, 2004). Vapnik ve çalışma arkadaşları tarafından geliştirilen yeni bir sinir ağı algoritması olan destek vektör makinelerinin (DVM), sınıflandırma görevlerinde, regresyon ve zaman serisi tahminlerinde iyi bir performans sergilediğini göstermişlerdir.

(Cao ve Tay, 2001; Tay ve Cao, 2001 a) çalışmalarında DVM'nin finansal zaman serisi tahmininde uygulanabilirliğini çok katmanlı bir geri yayılım sinir ağı ile karşılaştırarak incelemişlerdir. Veri seti için, Chicago Ticaret Piyasası'ndan ve birkaç dış tahvil endeksinden harmanlanan beş gerçek vadeli işlem kullanmışlardır. Çalışmanın sonucuna göre DVM'lerin normalize edilmiş ortalama kare hata, ortalama mutlak hata, yönlü simetri ve ağırlıklı yönlü simetri gerçekleştirildiği çok katmanlı geri yayılım ağlarından daha iyi performans gösterdiğini belirtmişlerdir.

Finansal verilere özgü dinamik girdi-çıktı ilişkilerin daha iyi yakalamak için kendi kendini düzenleyen bir haritayı (SOM) ve DVM'sini birleştiren iki aşamalı bir mimari (Tay ve Cao, 2001 b) tarafından sunulmuştur. C ve ε gibi kullanılan çekirdek fonksiyonlar

için parametreler temel olarak türetilmekte ve genel yaklaşım göstermektedir ki tek bir DVM yaklaşımına kıyasla sadece daha iyi bir tahmin performansına sahip olmayıp, aynı zamanda üstün yakınsama hızına sahiptir.

Tay ve Cao (2002) daha sonra finansal seri tahmini için C-artan DVM'ler olarak adlandırılan DVM'lerinin değiştirilmiş bir versiyonunu önermişlerdir. Bu yaklaşımın amacı, en güncel (zaman içinde) ε -duyarsız hataları ve indirgenmiş en küçük kareler yaklaşımına benzer şekilde daha uzak olanları ağırlıklandırmaktır. Hem doğrusal hem de üstel ağırlık fonksiyonları, S&P 500 de dâhil olmak üzere çeşitli stok endekslerine karşı test edilmiştir. Standart bir DVM uygulamasına kıyasla bu yöntem kullanılarak daha iyi bir performansın (beş örnek tahmin ufku için) elde edilebileceği sonucuna varılmıştır.

Kore kompozit hisse senedi fiyat endeksindeki (KOS-PI) günlük hisse senedi fiyat değişiminin yönünü tahmin etmek amacıyla Kim (2003), başlangıç özelliklerini oluştururken kullanılan stokastik K%, stokastik D%, stokastik, stokastik yavaş D%, momentum, ROC, Williams R, A / D osilatörü, eşitsizlik 5, eşitsizlik 10, OSCP, CCI ve RSI gibi 12 teknik göstergenin olduğu DVM kullanmışlardır. Deneysel sonuçların analizi, bir geri yayılımlı sinir ağı (BPN) ve vaka temelli akıl yürütme (CBR) ile karşılaştırılarak uygulanan DVM'nin finansal tahminlemede uygulanabilir ve avantajlı olduğunu kanıtlamıştır.

Pai ve Lin (2005) on şirketin günlük kapanış fiyatlarını tahmin etmek için yaygın olarak kullanılan otoregressif hareketli ortalama (ARIMA) ve doğrusal zaman serisi tahmininde yaygın olarak kullanılan DVM modellerini birleştiren bir tahmin modeli geliştirmiştir. ARIMA ve DVM ile entegre hibrid modelin, sadece ARIMA ve DVM kullanan modellerle karşılaştırıldığında tüm tahmin hatalarını önemli ölçüde azalttığı gözlemlenmiştir.

Kumar ve Thenmozhi (2006) çalışmalarında, Ulusal Menkul Kıymetler Borsası S&P CNX NIFTy Piyasa Endeksi yöneliminin günlük hareketini tahmin etmek için DVM'si ve Rassal Orman'ı (Random Forest) geleneksel diskriminant ve logit modellerinin ve YSA'nın sonuçları ile karşılaştırarak sunmuşlardır. Elde ettikleri sonuçlar, DVM'lerinin rassal orman, sinir ağları ve diğer geleneksel modeller gibi yöntemlerden daha iyi performans sergilediğini göstermiştir. Ertesi yıl, Kumar ve Thenmozhi (2007) ARIMA, ANN, DVM ve Rassal Orman regresyon modellerinin S&P CNX NIFTY Endeksi geri dönüşünü tahmin etmedeki kullanışlılığını, performanslarını

istatistiki ve finansal olarak ölçtükleri ticari bir deney ile araştırmışlardır. Sonuç olarak, DVM modelinin çalışmada kullanılan diğer modellerden daha iyi performans sergilediği görülmüştür.

Hsu vd. (2009) hisse senedi fiyat tahmini için kendi kendini organize eden harita ve destek vektör regresyonunu birleştirerek iki aşamalı bir mimari geliştirmişlerdir. Yedi büyük borsa endeksini incelemiş ve sonuçlar iki aşamalı mimarinin hisse senedi fiyat tahmini için ümit vaat eden bir alternatif sunduğunu ortaya koymuşlardır.

Kara, Boyacioglu ve Baykan (2011) çalışmalarında, İMKB-100 Endeksini tahmin etmek amacıyla YSA ve DVM'nin performanslarını karşılaştırmışlar. Analiz için 2 Ocak 1997 – 31 Aralık 2007 dönemindeki kapanış fiyatlarını kapsayan veriler, basit hareketli ortalama (SMA), ağırlıklı hareketli ortalama (WMA), momentum, stokastik K%, stokastik D%, RSI, MACD, Williams %R, A/D osilatör ve CCI gibi 10 teknik gösterge ile birlikte kullanılmıştır. Her iki yöntemde de sonuçlar başarılı olmasına rağmen, YSA'nın %75.74 ve DVM'nin %71.52 tahmin performansına sahip olduğu bulunmuştur. Aynı yıl yayınlanan bir başka çalışmada Özdemir, Tolun ve Demirci (2011) Şubat 1997 – Aralık 2010 dönemini kapsayan aylık verilerde hem Lojistik Regresyon (LR) hem de Destek Vektör Makineleri (DVM) kullanarak İMKB-100 Endeks getirisinin hareket yönünü tahmin etmişlerdir. Toplam 167 veri seti, modellerin kurulu olduğu 138 ver eğitim setine ve modellerin geçerliliğine dair 29 veri setine ayrılmıştır. Çalışmanın sonuçlarına göre, hisse senedi getirilerini tahmin etmede destek vektör makineler alternatif bir yöntem olarak yatırımcılar ve araştırmacılar tarafından etkili bir şekilde kullanılabilir.

Tayyar ve Tekin (2013) İstanbul Menkul Kıymetler Borsası Ulusal 100 Endeksinin (İMKB-100) hareket yönünü tahmin etmek için Destek Vektör Makinelerini (DVM) kullanmışlardır. Analiz, 03.04.1995 – 19.03.2013 tarihleri arasında günlük, haftalık ve aylık olarak ayarlanan 4226 veri setini içermektedir. Her veri seti için 4 model oluşturmuş ve her model için farklı kriterler uygulayarak bu yöntemlerin performansını tahmin eden endeks hareket yönünü değerlendirmişlerdir. İMKB-100 endeksi hareket yönünü en iyi tahminleyen modelin %82.89 artış ve %54,68 azalış yönü ile diğer modeller arasından model 1 olduğunu gözlemlemişlerdir.

Yakut, Elmas ve Yavuz, (2014) ileri beslemeli yapay sinir ağları ve destek vektör makineleri yöntemleri ile BIST endeks değerini tahmin etmeye çalışmışlardır. Çalışmada

BIST endeksinin bir, iki ve üç gün öncesine ait değerleri yanında Amerikan dolar kuru, gecelik faiz oranı ve NIKKEI (Japonya Borsası), BOVESPA (Brezilya Borsası), FTSE (İngiltere Borsası), CAC (Fransa Borsası), DAX (Almanya Borsası) internet sitelerinden elde edilen 2005-2012 tarihleri arasındaki borsa endeksi değerleri kullanılmıştır. Çalışmanın sonucuna göre borsa endeksinin tahmin edilmesinde yapay sinir ağları ve destek vektör makineleri yöntemlerinin kullanılabileceği görülmüştür.

Son yıllarda, tekrarlayan ağlar için uzun kısa vadeli hafıza (UKVH) ağları Hochreiter ve Schmidhuber (1997) tarafından tanıtılmıştır ve çeşitli makine öğrenme problemleri için kullanılabilecek en gelişkin teknolojik modeller haline gelmiştir. En gelişmiş derin öğrenme mimarilerinden bir olan LSTM ağları, el yazısı tanıma, konuşma tanıma ve insan hareketleri tanıma ve ya zaman serisi gibi sıralı öğrenme görevlerinde büyük performans göstermiştir (Baccouche, Mamalet, Wolf, Garcia ve Baskurt, 2011; Fernandez, Graves ve Schmidhuber, 2007; Graves, Mohamed ve Hinton, 2013; Graves ve Schmidhuber, 2009, 2005; Jürgen Schmidhuber, 2015). Yukarıda belirtilen görevlerin yanı sıra UKVH ağları müzikal kompozisyonların üretilmesi Eck ve Schmidhuber (2002), uyumsuz protein homolojisinin saptanması Hochreiter, Heusel ve Obermayer (2007), kalp ameliyatında dikiş atmayı öğrenen bir sistemin tasarlanması Mayer vd, (2008) ve düzenli olmayan diller öğrenme Jürgen Schmidhuber, Gers ve Eck (2002) gibi pek çok farklı konuda kullanılmıştır. Ancak literatüre bakıldığında finansal piyasa tahmin görevlerinde UKVH'yı uygulamaya yönelik girişimlerin pek fazla olmadığı görülmektedir.

Giles, Lawrence ve Tsoi (2001), RNN modelini günlük döviz kurlarının tahmin edilmesinde kullanmışlar ve %47,1 hata oranıyla bir sonraki gün için değişim yönünü doğru tahmin eden kapsamlı deneylerde tahmin edilebilirliğini anlamlı bulmuşlardır. Xiong, Nichols ve Shen (2015), Google'ın yerel eğilimlerini toplumsal ruh halinin ve makroekonomik faktörlerin bir göstergesi olarak dâhil ederek, S&P 500 hareketliliğini modellemek için %24.2'lik bir mutlak yüzde hatası ile doğrusal Ridge / Lasso ve en az %31 ile otoregresif GARCH kriterlerini geride bırakan Uzun Kısa Vadeli Hafıza sinir ağını uygulamışlardır. Roondiwalla, Patel ve Varma (2015) borsa endekslerini tahmin etmek için tekrarlayan bir sinir ağı (RNN) ve Uzun Kısa Vadeli Hafıza (LSTM) yaklaşımlarını sunmuşlardır. Shen, Chao ve Zhao (2015) madeni para fiyat tahmin etmede %52'lik bir doğruluğa ulaşan Bayesian tarafından optimize edilmiş tekrarlayan

sinir ağı – LSTM kullanmışlardır. Pang, Zhou, Wang, Lin ve Chang (2018) borsa tahmininde bulunmak için verileri vektörelleştiren gömülü bir katmana sahip, uzun kısa vadeli derin sinir ağını (LSMN) önermişlerdir. Deneysel sonuçlar, gömülü katmana sahip uzun kısa vadeli derin sinir ağına Şangay A-hisse senetleri için %57.2 ve bireysel hisse senedi için %52.4 doğruluk oranıyla en gelişkin teknoloji olduğunu göstermektedir. Fischer ve Krauss (2018) 1992’den 2015’e kadarki S&P 500’in kurucu hisse senetlerinin örnek dışı yönel hareketleri tahmin etmek için LSTM ağlarını kullanmış ve LSTM ağlarının günlük % 0.45 getiriler ve işlem maliyetlerinden önce %5.8’lik bir Sharpe oranı ile hafızasız sınıflandırma yöntemlerinden daha iyi performans gösterdiğini tespit etmişlerdir.

Makine öğrenimi tekniklerini, artan öğrenme ve genelleme yeteneklerinden dolayı, istatistiksel yöntemlere bir alternatif olarak finansal zaman serisi tahmininde giderek daha fazla kullanıldığı görülmektedir. Bölüm 3’te bu çalışmanın amacı ve kapsamı, çalışmanın yöntemi ve veriler, bu verilerin temizlenmesi ve düzenlenmesi, eğitim ve test setlerinin oluşturulması ve model performansları ve bulgulara yer verilecektir.

ÜÇÜNCÜ BÖLÜM

3. UYGULAMA MODELLERİ VE TAHMİNE AİT BULGULAR

3.1. Çalışmanın Amacı ve Kapsamı

Bu çalışmanın temel amacı, günlük Borsa İstanbul Ulusal 100 Endeksi'nde (BIST100) çok katmanlı algılayıcı sinir ağları (ÇKA), destek vektöre makineleri (DVM) ve uzun kısa vadeli hafıza (UKVH) modellerini kullanarak hisse senedi fiyatların tahmin etmektir. Bu kapsamda 01.01.2010 – 01.01.2019 tarihleri arasında BIST 100'ün 9 yıllık geçmiş verilerini eğitim ve test amaçlı kullandık. Yapılan literatür taramasında, yukarıda belirtilen bu üç modelin bir arada kullanılarak borsa fiyatı tahmin etmeye yönelik çalışmalar yapılmadığını gördük. Bu çalışmada, borsa fiyatlarını tahmin etmek için bu üç modeli karşılaştırarak bu araştırma açığını doldurmayı hedefledik.

3.2. Çalışmanın Yöntemi ve Veriler

Bu çalışmada kullanılan veriler, Borsa İstanbul'un web sitesinden elde edilmiştir. Her bir firma için 01.01.2010 – 01.01.2019 tarihleri arasındaki 2. Seans açılış ve kapanış hisse senedi günlük fiyat verilerine yer verilmiştir. Bir firma için bu tarih aralığındaki kullanılan veri sayısı açılış fiyatları için 2249 ve kapanış fiyatları için 2249 olmak üzere toplam 4498 veri kullanılmıştır. Analize konu olan firma sayısı 42'dir ve toplam veri sayısı 188,196'dır. BIST 100 içerisinde yer alan firmalardan sadece 42 adet firmanın verileri bütünlük sağladığı için tercih edilmiştir. Çalışmada kullanılan veriler çok sayıda olduğu için bu firmalardan sadece AKBANK için kullanılan örnek veriler Ek-1'de verilmiştir. Tüm modeller tüm hisseler için tahmin yapabilecek şekilde tasarlanmıştır.

3.3. Verilerin Temizlenmesi ve Düzenlenmesi

Borsa İstanbul'un internet sitesinden elde edilen veriler yıllara göre gün gün Excel dosyası olarak kaydedildikten sonra tüm firmalar içerisinde BİST-100 endeksi içerisinde yer alan firmalar filtrelenmiştir. Daha sonra veriler firma bazında analiz edilebilmesi isim sırasına göre sıralanarak her firma ayrı bir Excel dosyasında ayrıştırılmıştır. Son olarak

firmalara ait veriler en eski tarihten en yeni tarihe göre sınıflandırılarak analize hazır hale getirilmiştir.

3.4. Eğitim ve Test Setlerinin Oluşturulması


Elde edilen verilerin %80'i eğitim için %20'si ise test için kullanılmıştır. Eğitim verilerin ve test verilerinin dengeli bir dağılıma sahip olmasına dikkat edilmiştir.

3.5. Bist100 Endeksinin ÇKA, DVM ve UKVH ile Tahmini

Uygulama 01.01.2010 – 01.01.2019 tarihleri arasında BIST 100'ün 9 yıllık geçmiş verileri ile gerçekleştirilmiştir. Veriler Borsa İstanbul'un internet sitesinden elde edilmiştir. Modellerin geliştirilmesinde Python adlı programlama dilinden yararlanılmıştır. Bu programlama dili makine öğrenmesi ve derin öğrenme modelleri geliştirmede yaygın olarak kullanılmaktadır. Eğitim sırasında geliştirilen ağın hatasının eş zamanlı olarak hesaplanarak ekranda gösterilmesi ve ağın test veriler üzerindeki performansı grafiksel olarak gösterilmesi sayesinde ağın verileri ezberleyip ezberlemediği kolaylıkla izlenebilmektedir. Her firma için 42 firma içerisinde sadece en iyi sonuç elde edilen 6 firmaya ait grafikler Ek-3'te sunulmaktadır.

Modeller Python adlı programlama dilinden yararlanarak bir IDE (Integrated Development Environment – Tümüleşik Geliştirme Ortamı) olan Spyder yazılımında (Şekil 3.1) geliştirilmiştir. IDE bilgisayar programcılarının hızlı ve rahat bir şekilde program geliştirebilmesini amaçlayan debugging, versiyon kontrolü, kodlama hataları veya otomatik tamamlama gibi birçok özelliği sahip yazılımlardır.

Şekil 3.1. Spyder (Python 3.6) Platformunun Ekran Görüntüsü



Modellerin geliştirilmesinde ve istatistiki analizlerin yapılmasında LENOVO ideapad 320 model bir diz üstü bilgisayar kullanılmıştır. Bilgisayar özellikleri Tablo 3.1’de gösterilmektedir.

Tablo 3.1. Çalışmada Kullanılan Bilgisayarın Özellikleri

Windows Sürümü	Windows 10 Home
İşlemci	Intel® Core™ i7-8550U CPU @ 1.80GHz 1.99 GHz
Yüklü bellek (RAM)	8,00 GB(kullanılabilir miktar: 7,88 GB)
Sistem türü	64 bit İşletim Sistemi, x64 tabanlı işlemci
Grafik İşlemci	NVIDIA GeForce MX150 (2 GB)

3.5.1. Çok Katmanlı Algılayıcı (ÇKA) İle Tahmin

Öncelikle oluşturulacak yapay sinir ağının mimarisi, kullanılacak öğrenme kuralı ve hatanın nasıl hesaplanacağı, girdi ve çıktı katmanındaki neuron sayısı, gizli katman sayısı, katmanlardaki geçiş fonksiyonu ve öğrenme algoritmasına ilişkin öğrenme katsayısı, momentum terimi seçilerek bir yapay sinir ağı modeli oluşturulmuştur.

Ağın Mimarisi	: İleri Beslemeli Çok Katmanlı
Hata Hesaplaması	: Ortalama Karesel Hata
Training Set Gözlem Adedi	:1798
Test Set Gözlem Adedi	: 449
İterasyon Adedi (epoch)	: 1000
Katman Sayısı	: 5
Gizli Katman Sayısı	: 4 (Katmanlarda sırasıyla 16, 8, 4, 4 nöron bulunmaktadır)
Transfer fonksiyonu	: ReLU (Rectified Linear Unit) Fonksiyonu

Uygulamada kullanılan YSA modeli, Bölüm 2.4.3’de anlatılan ileri beslemeli geri yayılım (Back-Propagation) ağıdır. Çok katmanlı ileri beslemeli (multilayer feed forward) ağ birden fazla katmandan oluşmaktadır. Her katman bir önceki katmandaki çıktı vektörü aynı zamanda bir sonraki katman için girdi vektörünü oluşturmaktadır.

Katmanlar doğrusal bir düzende sıralanmaktadır. Son katmandaki çıktı vektörü aynı zamanda ağırlık çıktısını temsil etmektedir. Girdi ve çıktı katmanları arasındaki katmanlar ise gizli katman olarak isimlendirilmektedir. Gizli katman sayısının artırılması daha karmaşık problemleri çözümüne yardımcı olmaktadır.

Daha önce de belirtildiği gibi, veri setleri ağına sunulmadan önce bir normalizasyon işleminden geçirilmelidirler. Bu amaçla, model kurulumundan önce verilerin analizi program tarafından otomatik olarak yapılmış, varsa eksik veriler veri setinin ortalamasıyla değiştirildikten sonra veri seti $[-1, 1]$ aralığına indirgenerek normalizasyon işlemi yapılmıştır. Ardından verilerin eğitim, doğrulama ve test işlemleri için bölünmesi işlemi yapılmıştır.

3.5.2. Destek Vektör Makineleri (DVM) İle Tahmin

Oluşturulan DVM mimarisi için en iyi sonucu ortaya çıkaracak parametrelerin seçiminde birçok deneme yapılmış olup en iyi tahmini veren DVM parametreleri şu şekilde kararlaştırılmıştır. Karmaşıklık parametresi (the complexity parameter) “ $C=1.5$ ” seçilmiştir. Veri normalize edilmiştir. Çekirdek fonksiyonu olarak radyal taban fonksiyonu (the radial basis function) ve çekirdeğin üstellik değeri (the exponenet value) ise “ $e=0.1$ ” seçilmiştir.

3.5.3. Uzun Kısa Vadeli Hafıza (UKVH) İle Tahmin

Diğer modellerde olduğu gibi en iyi sonucu ortaya çıkaracak parametrelerin seçiminde birçok deneme yapılmış olup en iyi tahmin veren parametreler seçilmiştir. Oluşturulan UKVH mimarisine ait bilgilere aşağıda yer verilmektedir.

Ağın Mimarisi	: Uzun Kısa Vadeli Hafıza
Hata Hesaplaması	: Ortalama Karesel Hata
Training Set Gözlem Adedi	: 1798
Test Set Gözlem Adedi	: 449
İterasyon Adedi (epoch)	: 100
Katman Sayısı	: 5
Gizli Katman Sayısı	: 4 (Katmanlarda sırasıyla 8, 8, 4, 2 nöron bulunmaktadır)

Transfer fonksiyonu : Tanh (Tanjant Hiberbolik) Fonksiyonu

3.6. Model Performansları ve Bulguların Karşılaştırılması

Modellere ait tahminlemeler için hesaplanan doğruluk ölçülerinin sonuçları Ek 3'te gösterilmektedir. Sunulan ölçülerden çıkan en önemli sonuç, bütün ölçülerin ÇKA ve UKVH modellerinin en doğru öngörülere sahip model olarak göstermesidir. Bu sonuçlar bazı temel istatistikler kullanılarak desteklenmektedir. Tablo 3.2, Tablo 3.3 ve Tablo 3.4 öngörü hatalarına ait temel istatistikleri göstermektedir. İstatistiki analizler IBM SPSS Statistics 25 hazır paket programı yardımıyla gerçekleştirildi ve analizlerde gruplar arasında fark olup olmadığını gösteren çift kuyruklu t-testi analizi kullanılmıştır.

Tablo 3.2. ÇKA Modeli Çift Kuyruklu T-Testi Sonuçları

Şirketler	Hisse Senedi Açılış Fiyatları Sonuçları						Hisse Senedi Kapanış Fiyatları Sonuçları					
	N	Corr.	Sig.	t	df	Sig. (2-tailed)	N	Corr.	Sig.	t	df	Sig. (2-tailed)
AKBNK	449	,982	,000	-,360	448	,719	449	,993	,000	-,003	448	,998
AKSA	449	,920	,000	1,043	448	,297	450	,991	,000	-,593	449	,553
ALARK	449	,962	,000	,369	448	,712	448	,995	,000	-,012	447	,991
AEFES	449	,972	,000	-,753	448	,452	449	,985	,000	-,005	448	,996
ARCLK	449	,984	,000	-,471	448	,638	449	,985	,000	,101	448	,920
ASELS	449	,952	,000	-,322	448	,748	449	,981	,000	,409	448	,683
BIMAS	449	,976	,000	,372	448	,710	449	,989	,000	1,387	448	,166
DOHOL	449	,968	,000	1,062	448	,289	449	,983	,000	,348	448	,728
DOAS	449	,963	,000	,357	448	,721	449	,996	,000	-,324	448	,746
ECZYT	449	,952	,000	1,241	448	,215	449	,988	,000	,094	448	,925
ENKAI	449	,972	,000	-,157	448	,875	449	,985	,000	-,012	448	,991
*EREGL	449	,941	,000	-,149	448	,882	448	,993	,000	,355	447	,723
FENER	449	,977	,000	-,993	448	,321	449	,996	,000	-,088	448	,930
FROTO	449	,925	,000	,167	448	,867	449	,990	,000	,371	448	,711
GSRAY	449	,487	,000	,008	448	,994	449	,992	,000	,008	448	,994
GARAN	449	,981	,000	-,132	448	,895	449	,991	,000	-,164	448	,870
GSDHO	449	,671	,000	,323	448	,747	449	,982	,000	,316	448	,752
GUBRF	449	,596	,000	,007	448	,994	448	,995	,000	,001	447	,999
HALKB	449	,974	,000	-,015	448	,988	449	,996	,000	,642	448	,521
ISCTR	449	,986	,000	-,383	448	,702	449	,995	,000	-,002	448	,998
*ISGSY	449	,967	,000	-1,837	448	,067	449	,997	,000	,026	448	,979
KRDMD	449	,974	,000	,229	448	,819	449	,996	,000	,145	448	,885
KARSN	449	,989	,000	-1,166	448	,244	449	,988	,000	-,268	448	,789
KCHOL	449	,890	,000	,001	448	,999	448	,983	,000	-,590	447	,555
KOZAA	449	,975	,000	1,274	448	,203	449	,991	,000	1,240	448	,216
METRO	449	,945	,000	,448	448	,655	448	,981	,000	-,148	447	,883
MGROS	449	,980	,000	,704	448	,482	449	,995	,000	-,274	448	,784
NETAS	449	,187	,000	,004	448	,997	448	,994	,000	,143	447	,886
PETKM	449	,984	,000	,414	448	,679	449	,993	,000	,146	448	,884
SAHOL	449	,983	,000	-,236	448	,814	449	,993	,000	-,584	448	,559
SISE	449	,871	,000	,268	448	,788	448	,914	,000	,024	447	,981
*TSGYO	449	,944	,000	-1,347	448	,179	449	,997	,000	-,005	448	,996
TAVHL	449	,958	,000	-,804	448	,422	449	,990	,000	,199	448	,843
TKFEN	448	,976	,000	,910	447	,363	449	,996	,000	,938	448	,349
TOASO	449	,929	,000	,175	448	,861	449	,995	,000	-,179	448	,858

TRKCM	449	,964	,000	,137	448	,891	449	,987	,000	-,008	448	,994
TUPRS	449	,910	,000	-,980	448	,328	449	,983	,000	,209	448	,834
THYAO	449	,976	,000	,733	448	,464	449	,987	,000	,580	448	,562
TTKOM	449	,980	,000	-,177	448	,860	449	,995	,000	,170	448	,865
TCELL	449	,980	,000	-,019	448	,985	449	,984	,000	-,084	448	,933
VAKBN	449	,985	,000	-,501	448	,616	449	,995	,000	-,288	448	,773
YKBNK	449	,982	,000	-,193	448	,847	449	,997	,000	-,107	448	,915

Şirketlerin gerçek ve tahmin değerleri arasındaki fark analizleri sonucunda elde edilen t değerleri ve P değerleri incelendiği zaman tamamında farklılık olmadığını niteleyen H_0 hipotezlerinin desteklendiği görülmektedir. Buna ek olarak korelasyon değerleri 1'e yakın değerlerle bu farksızlığı ayrıca teyit etmektedir. ÇKA analizleri sonucunda elde edilen tahmin değerlerinin tutarlılığı istatistiksel olarak fark analizleriyle de desteklenmiştir. ÇKA modeli için kurulan hipotezler Tablo 5.5'den elde edilen bilgilere göre aşağıdaki gibidir;

$$H_0: \mu_1 - \mu_2 = 0$$

$$H_1: \mu_1 - \mu_2 \neq 0$$

Açılış Fiyatları İçin

$$p\text{-değeri} = \text{Sig. (2-tailed)} = 0,650690$$

$$p\text{-değeri} = 0,650690 > 0.05 = \alpha, \text{ olduğundan yokluk hipotezi kabul edilir.}$$

Kapanış Fiyatları İçin

$$p\text{-değeri} = \text{Sig. (2-tailed)} = 0,798048$$

$$p\text{-değeri} = 0,798048 > 0.05 = \alpha, \text{ olduğundan yokluk hipotezi kabul edilir.}$$

Tablo 3.3. DVM Modeli Çift Kuyruklu T-Testi Sonuçları

Şirketler	Hisse Senedi Açılış Fiyatları Sonuçları						Hisse Senedi Kapanış Fiyatları Sonuçları					
	N	Corr.	Sig.	t	df	Sig. (2-tailed)	N	Corr.	Sig.	t	df	Sig. (2-tailed)
AKBNK	449	,996	,000	7,585	448	,000	449	,998	,000	8,864	448	,000
AKSA	449	,978	,000	25,395	448	,000	450	,997	,000	33,420	449	,000
ALARK	449	,990	,000	4,918	448	,000	450	,999	,000	9,053	449	,000
AEFES	449	,994	,000	3,113	448	,002	450	,996	,000	1,578	449	,115
ARCLK	449	,995	,000	9,986	448	,000	450	,999	,000	17,408	449	,000

ASELS	449	,986	,000	46,057	448	,000	449	,990	,000	48,903	448	,000
BIMAS	449	,994	,000	3,927	448	,000	450	,997	,000	8,208	449	,000
DOHOL	449	,990	,000	3,231	448	,001	449	,994	,000	3,869	448	,000
DOAS	449	,994	,000	-2,230	448	,026	449	,999	,000	5,850	448	,000
ECZYT	449	,989	,000	29,291	448	,000	449	,996	,000	24,452	448	,000
ENKAI	449	,993	,000	9,272	448	,000	450	,996	,000	8,205	449	,000
ERGLI	450	,984	,000	49,738	449	,000	450	,998	,000	52,801	449	,000
FENER	450	,993	,000	-23,727	449	,000	450	,999	,000	-50,404	449	,000
FROTO	449	,981	,000	49,131	448	,000	450	,997	,000	57,502	449	,000
GSRAY	449	,867	,000	-53,655	448	,000	449	,998	,000	-139,394	448	,000
GARAN	449	,994	,000	7,886	448	,000	449	,997	,000	7,087	448	,000
GSDHO	449	,933	,000	-11,423	448	,000	449	,995	,000	-36,323	448	,000
GUBRF	449	,908	,000	-23,317	448	,000	448	,998	,000	-36,094	447	,000
HALKB	449	,994	,000	-18,908	448	,000	449	,998	,000	-23,457	448	,000
ISCTR	449	,997	,000	11,393	448	,000	449	,998	,000	12,315	448	,000
ISGSY	449	,992	,000	-12,565	448	,000	449	,999	,000	-23,074	448	,000
KRDMD	450	,993	,000	25,255	449	,000	450	,999	,000	25,903	449	,000
KARSN	449	,996	,000	2,614	448	,009	449	,997	,000	-6,288	448	,000
KCHOL	449	,975	,000	38,681	448	,000	450	,995	,000	52,421	449	,000
KOZAA	449	,993	,000	27,365	448	,000	449	,996	,000	27,211	448	,000
METRO	449	,988	,000	-3,232	448	,001	449	,995	,000	-7,636	448	,000
MGROS	449	,995	,000	-7,075	448	,000	449	,998	,000	-16,813	448	,000
NETAS	450	,768	,000	-9,310	449	,000	449	,998	,000	-78,313	448	,000
PETKM	449	,996	,000	16,091	448	,000	450	,998	,000	-15,301	449	,000
SAHOL	449	,996	,000	-2,081	448	,038	449	,998	,000	2,194	448	,029
SISE	449	,966	,000	31,914	448	,000	449	,975	,000	17,693	448	,000
TSGYO	450	,985	,000	-35,265	449	,000	450	,999	,000	-30,383	449	,000
TAVHL	449	,986	,000	15,200	448	,000	449	,996	,000	19,488	448	,000
TKFEN	450	,993	,000	42,328	449	,000	450	,999	,000	42,083	449	,000
TOASO	449	,983	,000	28,790	448	,000	449	,996	,000	26,835	448	,000
TRKCM	450	,990	,000	37,150	449	,000	449	,995	,000	33,213	448	,000
TUPRS	450	,970	,000	55,089	449	,000	450	,996	,000	68,724	449	,000
THYAO	450	,994	,000	30,643	449	,000	450	,997	,000	31,174	449	,000
TTKOM	450	,994	,000	-13,613	449	,000	450	,999	,000	-17,802	449	,000
TCELL	449	,994	,000	14,965	448	,000	450	,996	,000	18,816	449	,000
VAKBN	449	,996	,000	8,239	448	,000	449	,998	,000	13,909	448	,000
YKBNK	450	,995	,000	-11,394	449	,000	450	,999	,000	-13,912	449	,000

Şirketlerin gerçek ve tahmin değerleri arasındaki fark analizleri sonucunda elde edilen t değerleri ve P değerleri incelendiği zaman tamamında farklılık olmadığını niteleyen H_0 hipotezlerinin desteklenmediği görülmektedir. DVM analizleri sonucunda

elde edilen tahmin değerlerinin tutarsızlığı istatistiksel olarak fark analizleriyle de desteklenmiştir. DVM modeli için kurulan hipotezler Tablo 3.5’den elde edilen bilgilere göre aşağıdaki gibidir;

$$H_0: \mu_1 - \mu_2 = 0$$

$$H_1: \mu_1 - \mu_2 \neq 0$$

Hisse Senedi Açılış Fiyatları İçin

$$p\text{-değeri} = \text{Sig. (2-tailed)} = 0,001833$$

$p\text{-değeri} = 0,001833 < 0.05 = \alpha$, olduğundan yokluk hipotezi reddedilir.

Hisse senedi kapanış fiyatları için

$$p\text{-değeri} = \text{Sig. (2-tailed)} = 0,003429$$

$p\text{-değeri} = 0,003429 < 0.05 = \alpha$, olduğundan yokluk hipotezi reddedilir.

Tablo 3.4. UKVH modeli Çift Kuyruklu T-Testi Sonuçları

Şirketler	Hisse Senedi Açılış Fiyatları Sonuçları						Hisse Senedi Kapanış Fiyatları Sonuçları					
	N	Corr.	Sig.	t	df	Sig. (2-tailed)	N	Corr.	Sig.	t	df	Sig. (2-tailed)
AKBNK	449	,981	,000	-,139	448	,889	449	,993	,000	,122	448	,903
AKSA	449	,925	,000	-1,538	448	,125	449	,991	,000	-,064	448	,949
ALARK	449	,973	,000	-,553	448	,580	448	,995	,000	-,155	447	,877
AEFES	449	,976	,000	,469	448	,640	449	,985	,000	,073	448	,942
ARCLK	449	,989	,000	,334	448	,738	448	,997	,000	-,660	447	,510
ASELS	449	,951	,000	,584	448	,559	449	,981	,000	,025	448	,980
BIMAS	449	,979	,000	,088	448	,930	449	,989	,000	-,059	448	,953
DOHOL	449	,965	,000	-,410	448	,682	448	,983	,000	,165	447	,869
DOAS	449	,976	,000	,964	448	,336	449	,996	,000	,208	448	,835
ECZYT	448	,958	,000	-,398	447	,691	449	,988	,000	-,001	448	,999
ENKAI	449	,979	,000	,652	448	,515	449	,985	,000	-,067	448	,947
ERGLI	449	,941	,000	,366	448	,715	449	,993	,000	-,115	448	,909
FENER	449	,981	,000	-,379	448	,705	449	,996	,000	,121	448	,904
FROTO	449	,929	,000	1,244	448	,214	449	,990	,000	,129	448	,898
GSRAY	449	,694	,000	-,151	448	,880	449	,992	,000	,204	448	,838
GARAN	449	,981	,000	,452	448	,651	449	,991	,000	,012	448	,990
GSDHO	448	,790	,000	1,678	447	,094	449	,982	,000	-,200	448	,842
GUBRF	449	,757	,000	2,275	448	,023	448	,995	,000	-,079	447	,937

HALKB	449	,980	,000	,652	448	,515	449	,996	,000	,060	448	,952
ISCTR	449	,988	,000	-,314	448	,754	449	,995	,000	,026	448	,979
ISGSY	449	,974	,000	,345	448	,730	449	,997	,000	-,306	448	,760
KRDMD	449	,974	,000	,550	448	,583	449	,996	,000	,066	448	,947
KARSN	449	,989	,000	-,458	448	,647	449	,988	,000	,132	448	,895
KCHOL	449	,900	,000	-,084	448	,933	449	,983	,000	-,212	448	,832
KOZAA	449	,974	,000	,737	448	,461	449	,991	,000	-,028	448	,978
METRO	448	,951	,000	1,258	447	,209	449	,982	,000	,494	448	,622
MGROS	449	,985	,000	-,597	448	,551	449	,995	,000	-,020	448	,984
NETAS	448	,362	,000	-,721	447	,471	449	,994	,000	,243	448	,808
PETKM	449	,983	,000	-,030	448	,976	449	,993	,000	,073	448	,942
SAHOL	449	,984	,000	-,887	448	,376	449	,993	,000	-,339	448	,735
SISE	449	,872	,000	,508	448	,612	449	,913	,000	-,163	448	,871
TSGYO	449	,958	,000	-,325	448	,745	449	,997	,000	-,114	448	,909
TAVHL	449	,960	,000	-,211	448	,833	449	,989	,000	,115	448	,908
TKFEN	449	,976	,000	1,101	448	,272	449	,996	,000	,763	448	,446
TOASO	448	,935	,000	,833	447	,405	449	,995	,000	-1,537	448	,125
TRKCM	448	,970	,000	-2,712	447	,007	449	,987	,000	,160	448	,873
TUPRS	449	,892	,000	,099	448	,921	448	,983	,000	,135	447	,893
THYAO	449	,978	,000	,579	448	,563	449	,987	,000	,346	448	,729
TTKOM	449	,979	,000	-,400	448	,690	449	,995	,000	-,174	448	,862
TCELL	449	,980	,000	,173	448	,862	449	,984	,000	-,202	448	,840
VAKBN	449	,985	,000	,093	448	,926	449	,995	,000	,197	448	,844
YKBNK	448	,982	,000	-,282	447	,778	449	,997	,000	,124	448	,901

Şirketlerin gerçek ve tahmin değerleri arasındaki fark analizleri sonucunda elde edilen t değerleri ve P değerleri incelendiği zaman tamamında farklılık olmadığını niteleyen H_0 hipotezlerinin desteklendiği görülmektedir. Buna ek olarak korelasyon değerleri 1'e yakın değerlerle bu farksızlığı ayrıca teyit etmektedir. UKVH analizleri sonucunda elde edilen tahmin değerlerinin tutarlılığı istatistiksel olarak fark analizleriyle de desteklenmiştir. UKVH modeli için kurulan hipotezler Tablo 3.5'den elde edilen bilgilere göre aşağıdaki gibidir;

$$H_0: \mu_1 - \mu_2 = 0$$

$$H_1: \mu_1 - \mu_2 \neq 0$$

Hisse senedi açılış fiyatları için

$$p\text{-değeri} = \text{Sig. (2-tailed)} = 0,590167$$

$p\text{-değeri} = 0,590167 > 0.05 = \alpha$, olduğundan yokluk hipotezi kabul edilir.

Hisse senedi kapanış fiyatları için

$p\text{-değeri} = \text{Sig. (2-tailed)} = 0,850405$

$p\text{-değeri} = 0,850405 > 0.05 = \alpha$, olduğundan yokluk hipotezi kabul edilir.

Tablo 3.5. Kurulan Modellerin Ortalama P Değerleri

Kurulan Modeller	Ortalama P Değerleri	
	Açılış Fiyatları İçin	Kapanış Fiyatları İçin
ÇKA	0,650690	0,798048
DVM	0,001833	0,003429
UKVH	0,590167	0,850405

Hipotezler daha iyi kıyas yapabilmek açısından aşağıda hem hisse senedi açılış hem de kapanış fiyatları için ayrı ayrı tekrar gösterilmektedir.

$H_0: \mu_1 - \mu_2 = 0$

$H_1: \mu_1 - \mu_2 \neq 0$

Hisse Senedi Açılış Fiyatları İçin;

ÇKA Modeli

$p\text{-değeri} = \text{Sig. (2-tailed)} = 0,650690$

$p\text{-değeri} = 0,650690 > 0.05 = \alpha$, olduğundan yokluk hipotezi kabul edilir.

DVM Modeli

$p\text{-değeri} = \text{Sig. (2-tailed)} = 0,001833$

$p\text{-değeri} = 0,001833 < 0.05 = \alpha$, olduğundan yokluk hipotezi reddedilir.

UKVH Modeli

$p\text{-değeri} = \text{Sig. (2-tailed)} = 0,590167$

$p\text{-değeri} = 0,590167 > 0.05 = \alpha$, olduğundan yokluk hipotezi kabul edilir.

Hisse Senedi Kapanış Fiyatları İçin;

ÇKA Modeli

p -değeri = Sig. (2-tailed) = 0,798048

p -değeri = 0,798048 > 0.05 = α , olduğundan yokluk hipotezi kabul edilir.

DVM Modeli

p -değeri = Sig. (2-tailed) = 0,003429

p -değeri = 0,003429 < 0.05 = α , olduğundan yokluk hipotezi reddedilir.

UKVH Modeli

p -değeri = Sig. (2-tailed) = 0,850405

p -değeri = 0,850405 > 0.05 = α , olduğundan yokluk hipotezi kabul edilir.



SONUÇ VE DEĞERLENDİRME

Bu çalışmada, İstanbul Menkul Kıymetler Borsası Ulusal 100 Endeksinde (BİST-100) listelenen 42 firmanın hisse senetleri açılış ve kapanış fiyatları makine öğrenme yöntemleri ve derin öğrenme algoritmaları kullanılarak tahmin edilmeye çalışılmıştır. Bu amaçla, yaygın olarak kullanılan makine öğrenme yöntemlerinden Çok Katmanlı Algılayıcılar (ÇKA) ve Destek Vektör Makineleri (DVM) modelleri ve derin öğrenme yöntemlerinden, Uzun Kısa Vadeli Hafıza (UKVH) modeli kuruldu ve 2010-2019 yılları arasındaki günlük verilere uygulandı. Analiz, 01.01.2010 ile 01.01.2019 tarihleri arasında 9 yıllık günlük verileri içermektedir. Her firma için hisse senedi açılış fiyatları için 2249, kapanış hisse senedi fiyatlarına ilişkin 2249 veri günlük olmak üzere toplam 188.196 adet veri kullanılmıştır.

Bir tür yapay sinir ağı metodu olan Çok Katmanlı Algılayıcılar (ÇKA) modeli birçok alanda uygulanmış ve tahminleme çalışmalarında başarı sonuçlar elde edildiği görülmüştür. YSA yöntemi olarak bu modelin tercih edilmesinin nedeni kolay, hızlı, esnek ve tutarlı sonuçlar vermesidir. Bu çalışmada, diğer bir model olarak kullanılan Destek Vektör Makineleri (DVM) de sınıflandırma, regresyon ve zaman serisi tahmin uygulamalarında yakın zamanda başarıyla uygulanmıştır. Çalışmada kullanılan son model UKVH (Uzun Kısa Vadeli Hafıza) ise sensörler, borsa ve kamu kuruluşlarından elde edilen metin, el yazısı, konuşma ya da zaman serileri gibi veri dizisindeki kalıpları tanımak için tasarlanmış en güçlü ve kullanışlı RNN (Recurrent Neural Network – Tekrarlayan Sinir Ağı) türünden biridir.

Sonuçlar, ÇKA modelinin hisse senedi açılış fiyatlarının tahmininde DVM ve UKVH modellerinden daha iyi performans sergilediğini, UKVH modelinin de hisse senedi kapanış fiyatlarının tahmininde ÇKA ve DVM modellerinden daha iyi performans sergilediğini göstermektedir. DVM modelinin hem açılış hem de kapanış hisse senedi fiyatlarının öngörülmesinde bu çalışmada kullanılan diğer modeller arasında en kötü tahmin performansına sahip olduğu görülmektedir.

Modellerin istatistiksel uyum derecelerine baktığımızda, ÇKA ve UKVH modellerinin iyi bir uyuma sahip olduğu gözlenmektedir. Tablo 3.6’da görüldüğü üzere

ÇKA modeli hisse senedi açılış fiyatlarında (0,831719 %) ve kapanış hisse senedi fiyatlarında (0,977674%) en yüksek (R^2) değerine; UKVH modeli hisse senedi açılış fiyatlarında (0,796815%) ve kapanış hisse senedi fiyatlarında (0,978206 %) en yüksek (R^2) değerine; DVM modeli ise hem hisse senedi açılış hem de kapanış fiyatlarından en düşük (R^2) değerine (sırasıyla 0,66195 %, 0,580348 %) sahiptir.

Tablo 3.6. ÇKA, DVM ve UKVH Modelleri R^2 Sonuçları Ortalamaları

Modeller	Ortalama R^2 Değerleri	
	Açılış Fiyatları İçin	Kapanış Fiyatları İçin
ÇKA	0,831719	0,977674
DVM	0,661956	0,580348
UKVH	0,796815	0,978206

Bu çalışmada istatistiksel analiz için çift kuyruklu t-testi kullanılmış ve p-değeri olarak adlandırılan Sig (2-Tailed) değeri 0.005 olarak tercih edilmiştir. % 95 güven aralığında ÇKA ve UKVH modellerinden elde edilen istatistiksel sonuç tablo 3.5'e göre hem hisse senedi açılış hem de kapanış fiyatları için gerçek değerler ile öngörülen değerler arasında istatistiksel olarak anlamlı bir fark olmadığı gözlenmektedir.

Genel olarak, hem ÇKA hem de UKVH modellerinin zaman serilerinde hisse senedi fiyatlarının tahmininde kullanışlı olduğunu söyleyebiliriz. Bununla birlikte, DVM'nin finansal zaman serisi tahminleri için alternatif bir model olduğunu öne süren önceki çalışmaların aksine, bu çalışmada DVM'nin tahmin uygulamaları için hala geliştirilmesinin gerektiği sonucuna varılmıştır. Sonuçlar ayrıca, ne kadar çok eğitim vakası kullanılırsa, zaman serileri tahmininde o kadar iyi sonuçlar alındığını göstermektedir.

Gelecekteki çalışmalarda, ÇKA ve UKVH modellerinin çeşitli sektörlerden toplanan diğer büyük ölçekli verilerle ve zaman serisi tahmin uygulamalarında kullanılan diğer yöntemlerle karşılaştırmalı analizlerinin, ÇKA ve UKVH modellerinin etkinliğinin belirlenmesinde literatüre katkı sağlayacağına inanılmaktadır. Bu ileri çalışmaların sonuçları bizi birçok güçlü finansal zaman serisi tahmin modeline götürecektir.

KAYNAKÇA

- AISOLAB; (2017), "**Intro to AI #1: Artificial Intelligence, Machine Learning, Neural Networks and Deep Learning: What are the differences?**" <https://aiso-lab.com/intro-to-ai-1-artificial-intelligence-machine-learning-neural-networks-and-deep-learning-what-are-the-differences/> , Erişim Tarihi: 28.03.2019
- ALONOT; (2016), "**Finansal Sistemin Temel Unsurlar Nelerdir?**" <https://alonor.com/finansal-sistemin-temel-unsurlari-nelerdir/> Erişim Tarihi: 18.01.2019.
- AKAY Ali; (2009), Yapay Sinir Ağları ile İMKB-100 Endeksi Gelecek Değer Öngörüsü, Karadeniz Teknik Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Trabzon.
- AKKAYA Gökay; (2007), "Yapay Sinir Ağları Ve Tarım Alanındaki Uygulamaları", **Atatürk Üniversitesi Ziraat Fakültesi Dergisi**, 38(2), 195–202.
- ALP Elit C.; (2018), "**Recurrent Neural Network**", <http://elitcenkalp.blogspot.com/>, Erişim Tarihi: 18.01.2019
- ALPAYDIN Ethem; (2010), **Introduction to Machine Learning**. The MIT Press.
- AMINIAN Farzan, SUAREZ E. Dante, AMINIAN Mehran ve WALZ Daniel T.; (2006), "Forecasting Economic Data With Neural Networks", **Computational Economics**, 28(1), pp. 71–88.
- ANDERSON Dave and MCNEILL George; (1992), "Artificial Neural Networks Technology", **Kaman Sciences Corporation**, 258(6), pp. 1–83.
- APAK Sudi; (1995), **Sermaye Piyasaları ve Borsa**. Bilim Teknik Yayınevi.
- ATASEVEN Burçin; (2007), Satış Öngörü Modellemesi Tekniği Olarak Yapay Sinir Ağlarının Kullanımı: “Petkim’de Uygulanması, Celal Bayar Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Manisa.
- BACCOUCHE Moez, MAMALET Franck, WOLF Christian, GARCIA Christophe and BASKURT Atila; (2011), "Sequential Deep Learning For Human Action Recognition". **International Workshop On Human Behavior Understanding, Springer**, pp. 29–39.

- BAYIR Fırat; (2006), Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- BAYRU Pınar; (2007), Elektronik Basında Tüketici Tercihleri Analizi: Yapay Sinir Ağları İle Lojit Modelin Performans Değerlendirilmesi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, İstanbul.
- BENGIO Yoshua; (2009), "Learning Deep Architectures For AI", **Foundations and trends® in Machine Learning**, 2(1), pp. 1–127.
- BİRER Gürkan Caner; (2018), **Yapay Zeka**, Bilim ve Teknik.
- BORSA İSTANBUL; (2015), "**30 Kasım 2015 Tarihinden İtibaren Borsamız Pazarlarında İşlem Görecek Şirketler hk.**" <https://www.borsaistanbul.com/duyurular/2015/11/27/30-kasim-2015-tarihinden-ittibaren-borsamiz-pazarlarinda-islem-gorecek-sirketler-hk> , Erişim Tarihi: 18.01.2019.
- BORSA İSTANBUL; (2019), "**Pay Piyasası**". <https://www.borsaistanbul.com/urunler-ve-piyasalar/piyasalar/pay-piyasasi> , Erişim Tarihi: 18.01.2019.
- BORSA İSTANBUL; (2014), "**Cevaplarla Borsa ve Sermaye Piyasası**" https://www.borsaistanbul.com/data/kilavuzlar/Cevaplarla_Borsa_ve_Sermaye_Piyasasi.pdf, Erişim Tarihi: 18.01.2019
- BOYACIOĞLU Melek Acar ve KARA Yakup; (2007), "Türk Bankacılık Sektöründe Finansal Güç Derecelerinin Tahmininde Yapay Sinir Ağları Ve Çok Değişkenli İstatistiksel Analiz Tekniklerinin Performanslarının Karşılaştırılması", **Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, 22(2).
- BURGES Christopher J.C.; (1998), "A Tutorial On Support Vector Machines For Pattern Recognition", **Data Mining And Knowledge Discovery**, 2(2), pp. 121–167.
- BUSCEMA Massimo; (2002), "A Brief Overview And Introduction To Artificial Neural Networks", **Substance Use & Misuse**, 37(8-10), pp. 1093–1148.
- CAO Lijuan ve TAY Francis E.H.; (2001), "Financial Forecasting Using Support Vector Machines", **Neural Computing & Applications**, 10(2), pp. 184–192.
- CIRESAN Dan Claudiu, MEIER Ueli, GAMBARDELLA Luca Maria and SCHMİDHUBER Jürgen; (2011), "Convolutional Neural Network Committees For Handwritten Character Classification", **International Conference on**

- Document Analysis and Recognition, IEEE**, pp. 1135–1139
- CIRESAN Dan, GIUSTI Alessandro, GAMBARDELLA Luca M. ve SCHMIDHUBER Jürgen; (2012), "Deep Neural Networks Segment Neuronal Membranes İn Electron Microscopy Images", **Advances In Neural Information Processing Systems**, pp. 2843–2851.
- CIRESAN Dan, MEIER Ueli, MASCI, Jonathan ve SCHMIDHUBER, Jürgen; (2012), "Multi-Column Deep Neural Network For Traffic Sign Classification", **Neural Networks**, 32, pp. 333–338.
- CİVAN Mehmet; (2007), **Sermaye Piyasası Analizleri ve Portföy Yönetimi**, Gazi Kitapevi, Ankara.
- CORTES Corinna ve VAPNIK Vladimir; (1995), "Support-vector Networks", **Machine Learning**, 20(3), pp. 273–297.
- ÇAPANOĞLU Mustafa Birol; (1993), **Türkiye ve Dış Ülkelerde Sermaye Piyasası Özelleştirme Uygulamaları ve Genel Olarak Menkul Kıymet Borsaları**, Beta, İstanbul.
- DAĞLI Hüseyin; (2009), **Sermaye Piyasası ve Portföy Analizi** (3. bs.). Derya Kitabevi, Trabzon.
- DARBELLAY Georges A. ve SLAMA Marek; (2000), "Forecasting The Short-Term Demand For Electricity: Do Neural Networks Stand A Better Chance?", **International Journal of Forecasting**, 16(1), pp. 71–83.
- DENG Li and YU Dong; (2014), "Deep Learning: Methods And Applications", **Foundations and Trends in Signal Processing**, 7(3–4), pp. 197–387.
- DETMERS Tim; (2015), "**Deep Learning in a Nutshell: History and Training**", <https://devblogs.nvidia.com/deep-learning-nutshell-history-training/> Erişim Tarihi: 18.01.2019.
- DEVADOSS A. Victor and LIGORI T. Antony Alphonnse; (2013), "Forecasting Of Stock Prices Using Multi Layer Perceptron". **International Journal Of Computing Algorithm**, 2, 440–449.
- DUMAN Osman; (2016), Batı Anadolu Bölgesindeki Depremlerin Yapay Sinir Ağı Yöntemiyle Tahmini, Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Gümüşhane.
- ECK Douglas and SCHMIDHUBER Jurgen; (2002), "Learning The Long-Term

- Structure Of The Blues", **International Conference on Artificial Neural Networks, Springer**, pp. 284–289.
- ELMAS Çetin; (2007), **Yapay Zekâ Uygulamaları**, Seçkin Yayıncılık, Ankara.
- ELMAS Münevver; (2012), Destek Vektör Makineleri ile Fiyat Tahminleri Ve Kuyumculuk Sektöründe Bir Uygulama, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- ERGEZER Halit, DİKMEN Mehmet ve ÖZDEMİR Erkan; (2003), "Yapay Sinir Ağları Ve Tanıma Sistemleri", **Pivolka**, 2(6), ss. 14–17.
- ERİLLİ N. Alp, EĞRİOĞLU Erol, YOLCU Ufuk, ALADAĞ Ç. Hakan ve USLU V. Rezzan; (2010), "Türkiye’de Enflasyonun İleri Ve Geri Beslemeli Yapay Sinir Ağlarının Melez Yaklaşımı İle Öngörüsü", **Doğuş Üniversitesi Dergisi**, 11 (1), ss. 42-55.
- FERNANDEZ Santiago, GRAVES Alex ve SCHMIDHUBER Jurgen; (2007), "An Application Of Recurrent Neural Networks To Discriminative Keyword Spotting", **International Conference on Artificial Neural Networks, Springer**, pp. 220–229.
- FISCHER Thomas ve KRAUSS Christopher; (2018), "Deep Learning With Long Short-Term Memory Networks For Financial Market Predictions", **European Journal of Operational Research**, 270(2), pp. 654–669.
- FUKUSHIMA Kunihiko; (1980), "Neocognitron: A Self-Organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift In Position", **Biological cybernetics**, 36(4), pp. 193–202.
- GARİP Zehra Şule.; (2011), Yapay Sinir Ağları ile Mevcut Yapıların Deprem Riski Açısından Durum Tespiti, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, Sakarya.
- GERS Felix A. and SCHMIDHUBER Jurgen; (2000), "Recurrent Nets That Time And Count", **IJCNN 2000, IEEE**, pp. 189-194
- GERS Felix A., SCHMIDHUBER Jurgen and CUMMINS, Fred A.; (2000), "Learning to Forget: Continual Prediction with LSTM", **Neural Computation**, 12, pp. 2451–2471.
- GILES C. Lee, LAWRENCE Steve and TSOI Ah Chung; (2001), "Noisy Time Series Prediction Using Recurrent Neural Networks and Grammatical Inference",

- Machine Learning**, 44(1-2), pp. 161–183.
- GITHUB; (2019), "**An Open Source Machine Learning Framework for Everyone**".
<https://github.com/tensorflow/tensorflow>, Erişim Tarihi: 18.03.2019
- GORR Wilpen L., NAGIN Daniel and SZCZYPULA Janusz; (1994), "Comparative Study of Artificial Neural Network and Statistical Models for Predicting Student Grade Point Averages" **International Journal of Forecasting**, 10(1), pp. 17–34.
- GRAVES Alex, MOHAMED Abdel-rahman and HINTON Geoffrey; (2013), "Speech Recognition With Deep Recurrent Neural Networks", **2013 IEEE International Conference On Acoustics, Speech And Signal Processing, IEEE**, pp. 6645–6649).
- GRAVES Alex and SCHMIDHUBER Jurgen; (2009), "Offline Handwriting Recognition With Multidimensional Recurrent Neural Networks", **Advances in Neural information Processing Systems**, pp. 545–552.
- GRAVES Alex and SCHMIDHUBER Jürgen; (2005), "Framewise Phoneme Classification with Bidirectional LSTM And Other Neural Network Architectures" **Neural Networks**, 18(5-6), pp. 602–610.
- GREFF Klaus, SRIVASTAVA Rupesh K., KOUTNIK Jan, STEUNEBRINK Bas R. and SCHMIDHUBER, Jurgen; (2017), "LSTM: A Search Space Odyssey", **IEEE transactions on neural networks and learning systems**, 28(10), pp. 2222–2232.
- GURESEN Erkam, KAYAKUTLU Gulgun and DAIM Tugrul U; (2011), "Using Artificial Neural Network Models in Stock Market index Prediction", **Expert Systems with Applications**, 38(8), pp. 10389–10397.
- GÜNAL Mehmet; (2007), **Para Banka ve Finansal Sistem, Yeni Dönem Yayınları, 2.** Baskı, Ankara.
- GÜNDOĞMUŞ Yunus E.; (2019), "**LSTM ile Dolar/TL Kuru Tahmini.**"
<https://www.veribilimi.co/lstm-ile-dolartl-kuru-tahmini/> Erişim Tarihi: 28.03.2018
- GÜNGÖR Erkan; (2007), Yapay Sinir Ağları Yardımı İle Makine Arızalarının Önceden Tahmin Edilmesi, Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Kocaeli.
- HACIOĞLU Ümit ve DİNÇER Hasan; (2009), **Finansa Giriş Teorisi Ve Uygulama**, Beta Basım Yayım, İstanbul.

- HALE Jeff; (2018), "**Deep Learning Framework Power Scores 2018**".
<https://towardsdatascience.com/deep-learning-framework-power-scores-2018-23607ddf297a>, Eriřim Tarihi: 28.03.2019
- HAMZAÇEBİ Cořkun; (2011), **Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı MATLAB ve Neurosolutions Uygulamalı**, Ekin Basım Yayın Dağıtım, Bursa.
- HAZNEDAROĞLU Feyzi; (2009), Makro Ekonomik Ve Finansal Verilerin İmkb Endeksleri Üzerinde Etkisini Belirleyen Bir Tahmin Sistemi Geliřtirilmesi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, İstanbul.
- HINTON Geoffrey E.; (2007), "Learning Multiple Layers Of Representation", **Trends in Cognitive Cciences**, 11(10), pp. 428–434.
- HINTON Geoffrey E., SRIVASTAVA Nitish, KRIZHEVSKY Alex, SUTSKEVER Ilya and SALAKHUTDINOV Ruslan R.; (2012), "Improving Neural Networks By Preventing Co-Adaptation Of Feature Detectors", **arXiv preprint arXiv:1207.0580**.
- HINTON Geoffrey E. and SALAKHUTDINOV Ruslan R.; (2006), "Reducing The Dimensionality Of Data With Neural Networks", **Science**, 313(5786) pp. 504–507.
- HOCHREITER Sepp, HEUSEL Martin and OBERMAYER Klaus; (2007), "Fast Model-Based Protein Homology Detection Without Alignment", **Bioinformatics**, 23(14), pp. 1728–1736.
- HOCHREITER Sepp ve SCHMIDHUBER Jürgen; (1997), "Long Short-term Memory", **Neural Computation**, 9(8), pp. 1735–1780.
- HSU Sheng-Hsun, HSIEH JJ Po-An, CHIH Ting-Chih and HSU Kuei-Chu; (2009), "A Two-Stage Architecture For Stock Price Forecasting By Integrating Self-Organizing Map And Support Vector Regression", **Expert Systems with Applications**, 36(4), pp. 7947–7951.
- JAIN Anil K., MAO Jianchang and MOHIUDDIN K.M.; (1996), "Artificial Neural Networks: A Tutorial", **Computer**, (3), pp. 31–44.
- KAASTRA Iebling and BOYD Milton; (1996), "Designing a Neural Network for Forecasting Financial and Economic Time Series", **Neurocomputing**, 10(3), pp. 215–236.
- KARA Yakup, BOYACIOGLU Melek Acar and BAYKAN Omer Kaan; (2011),

- "Predicting Direction Of Stock Price Index Movement Using Artificial Neural Networks And Support Vector Machines: The Sample Of The Istanbul Stock Exchange", **Expert Systems with Applications**, 38(5), pp. 5311–5319.
- KAYNAR Oğuz, TAŞTAN Serkan and DEMİRKOPARAN Ferhan; (2010), "Ham Petrol Fiyatlarının Yapay Sinir Ağları İle Tahmini", **Ege Akademik Bakış**, 10(2), ss. 559–573.
- KILINÇ Kazım; (1991), **200 Soruda: A'dan Z'ye Borsa**, Egemen Matbaası, İstanbul.
- KIM Kyoung-jae; (2003), "Financial Time Series Forecasting Using Support Vector Machines", **Neurocomputing**, 55(1-2), pp. 307–319.
- KOHZADI Nowrouz, BOYD Milton S., KERMANSHAHI Bahman and KAASTRA, Ieabeling; (1996), "A Comparison Of Artificial Neural Network And Time Series Models For Forecasting Commodity Prices", **Neurocomputing**, 10(2), pp.169–181.
- KONG Qingkai; (2016), "**Machine learning 3 - Artificial Neural Networks - part 1-Basics**". <http://qingkaikong.blogspot.com/2016/11/machine-learning-3-artificial-neural.html>, Erişim Tarihi: 28.03.2019
- KUMAR Manish and THENMOZHI M.; (2006), "Forecasting Stock Index Movement: A Comparison Of Support Vector Machines And Random Forest" Indian Institute Of Capital Markets 9th Capital Markets Conference Paper
- KUMAR Manish ve THENMOZHİ M.; (2007), "Support Vector Machines Approach to Predict the S&P CNX NIFTY Index Returns", Indian Institute Of Capital Markets 10th Capital Markets Conference Paper.
- KUTLU Birgul, OZTURAN Meltem and BADUR Bertan; (2003), "Stock Market Prediction Using Artificial Neural Networks", Proceedings of the 3rd International Conference on Business, Hawaii .
- LAPEDES Alan and FARBER Robert; (1987), "Nonlinear Signal Processing Using Neural Networks: Prediction And System Modelling", No. LA-UR-87-2662; CONF-8706130-4.
- LECUN Yann, BOSER Bernhard, DENKER John S., HENDERSON Donnie, HOWARD Richard E., HUBBARD Wayne and JACKEL, Lawrence D.; (1989), "Backpropagation Applied to Handwritten Zip Code Recognition", **Neural Computation**, 1(4), pp. 541–551.

- LECUN Yann, BOSER Bernhard E., DENKER John S., HENDERSON Donnie, HOWARD Richard E., HUBBARD Wayne E. and JACKEL Lawrence D.; (1990), "Handwritten Digit Recognition with a Back-Propagation Network", **Advances In Neural Information Processing Systems** pp. 396–404.
- MAYER Hermann, GOMEZ Faustino, WIERSTRA Daan, NAGY Istvan, KNOLL Alois and SCHMIDHUBER Jürgen; (2008), "A System For Robotic Heart Surgery That Learns to Tie Knots Using Recurrent Neural Networks", **Advanced Robotics**, 22(13-14), pp. 1521–1537.
- MCCULLOCH Warren S. and PITTS Walter; (1943), "A Logical Calculus Of The Ideas Immanent In Nervous Activity", **The Bulletin Of Mathematical Biophysics**, 5(4), pp. 115–133.
- MINSKY Marvin and PAPERT Seymour; (1988), **Perceptrons: An Introduction to Computational Geometry** (Expanded.). Cambridge, MA: MIT Press.
- MORALI Tuncay; (2011), **İMKB 100 Endeksinin Yapay Sinir Ağları Ve Newton Nümerik Arama Modelleri İle Tahmini Ve Sonuçların Karşılaştırılması**, Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Yüksek Lisans Tezi, Denizli.
- MOSTAFA Mohamed M.; (2010), "Forecasting Stock Exchange Movements Using Neural Networks: Empirical Evidence From Kuwait", **Expert Systems with Applications**, 37(9), pp. 6302–6309.
- MUKHERJEE Sayan, OSUNA Edgar and GIROSI Federico; (1997), "Nonlinear Prediction Of Chaotic Time Series Using Support Vector Machines", Neural Networks for Signal Processing VII. Proceedings of the 1997 IEEE Signal Processing Society Workshop, IEEE, pp. 511–520).
- MULLER K.-R., SMOLA Alexander J., RÄTSCH Gunnar, SCHÖLKOPF Bernhard, KOHLMORGEN Jens and VAPNIK Vladimir; (1997), "Predicting Time Series With Support Vector Machines", International Conference on Artificial Neural Networks, Springer, pp. 999–1004.
- NAEINI Mahdi Pakdaman, TAREMIAN Hamidreza and HASHEMI Homa Baradaran; (2010), "Stock Market Value Prediction Using Neural Networks", 2010 International Conference on Computer Information Systems and Industrial Management Applications (CISIM), IEEE pp. 132–136.
- NVIDIA; (2019), "**Deep Learning**". <https://developer.nvidia.com/deep-learning>, Erişim

Tarihi: 28.03.2019

- OCAKOĞLU Gökhan; (2006), Lojistik Regresyon Analizi Ve Yapay Sinir Ağları Tekniklerinin Sınıflama Özelliklerinin Karşılaştırılması ve Bir Uygulama, Uludağ Üniversitesi Sağlık Bilimleri Enstitüsü, Yüksek Lisans Tezi, Bursa.
- OKUTKAN Caner; (2014), Borsa İstanbul Şirketlerinin Hisse Senedi Getirilerinin Yapay Sinir Ağları Ve Çoklu Regresyon Yöntemleri Kullanarak Analizi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kocaeli.
- OLAH Christopher; (2015), "**Understanding LSTM Networks**", <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>, Erişim Tarihi: 29.03.2019
- ORHAN SARIGENE; (2019), **Yeni Türk Ticaret Kanunu'nda Pay (Hisse) Senedi Yerine Geçen İlmuhaber**, [http://orhansarigene.com/Yeni-Turk-Ticaret-Kanununda-Pay-\(Hisse\)-Senedi-Yerine-Gecen-ilmuhaber/13](http://orhansarigene.com/Yeni-Turk-Ticaret-Kanununda-Pay-(Hisse)-Senedi-Yerine-Gecen-ilmuhaber/13), Erişim Tarihi: 25.01.2019.
- ORHAN Osman Z. ve ERDOĞAN Seyfettin; (2007), **Para Politikası (4. Baskı)**. Ankara: Yazıt Yayın Dağıtım.
- ÖZDEMİR A. Kerem, TOLUN Seda ve DEMİRCİ Ebru; (2011), "Endeks Getirisi Yönünün İkili Sınıflandırma Yöntemiyle Tahmin Edilmesi: İMKB 100 Endeksi Örneği", **Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, 4(2), ss. 45-59.
- ÖZKAN Yalçın; (2013), **Veri Madenciliği Yöntemleri** (2. bs.), Papatya Yayıncılık Eğitim, İstanbul.
- ÖZTEMEL Ercan; (2012), **Yapay Sinir Ağları**, Papatya Yayıncılık, İstanbul.
- PAI Ping-Feng and LIN Chih-Sheng; (2005), "A Hybrid ARIMA and Support Vector Machines Model In Stock Price Forecasting" **Omega**, 33(6), 497–505.
- PANG Xiongwen, ZHOU Yanqiang, WANG Pan, LIN Weiwei and CHANG, Victor; (2018), "Stock Market Prediction based on Deep Long Short Term Memory Neural Network", **Complexis**, ss. 102–108.
- POH Hean-Lee, YAO Jingtao ve JAŠIĆ Teo; (1998), "Neural Networks For The Analysis and Forecasting of Advertising and Promotion Impact", **Intelligent Systems in Accounting, Finance & Management**, 7(4), ss. 253–268.
- PORTIA A. Cerny; (2011), Data Mining and Neural Networks from a Commercial

- Perspective, ORSNZ Conference Twenty Naught One (pp. 1-10).
- ROONDIWALA Murtaza, PATEL Harshal and VARMA Shraddha; (2015), "Predicting Stock Prices Using LSTM", **International Journal of Science and Research (IJSR)**, 6(4), ss. 1754–1756.
- ROSENBLATT Frank; (1958), "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain", **Psychological Review**, 65(6), 386.
- RUBASHKIN Matthew; (2017), "**Getting Started with Deep Learning**", <https://www.kdnuggets.com/2017/03/getting-started-deep-learning.html> , Eriřim Tarihi: 28.03.2019
- RUIZ-SUAREZ J.C., MAYORA-IBARRA O.A., TORRES-JIMENEZ, J. and RUIZ-SUAREZ, L.G.; (1995), "Short-Term Ozone Forecasting By Artificial Neural Networks", **Advances in Engineering Software**, 23(3), pp. 143–149.
- RUMELHART David E. MCCLELLAND James L. and PDP Research Group; (1986), **Parallel Distributed Processing: Exploration in the Microstructure of Cognition, Vol. 1. Cambridge, MA: MIT Press.**
- SCHIERHOLT Karsten ve DAGLI Cihan H.; (1996), "Stock Market Prediction Using Different Neural Network Classification Architectures", IEEE/IAFE 1996 Conference on Computational Intelligence for Financial Engineering (CIFEr), IEEE, pp. 72–78.
- SCHMIDHUBER Jürgen; (2015), "Deep Learning in Neural Networks: An Overview". **Neural Networks**, 61, pp. 85–117.
- SCHMIDHUBER Jürgen; (1992), "Learning Complex, Extended Sequences Using The Principle Of History Compression" **Neural Computation**, 4(2), pp. 234–242.
- SCHMIDHUBER Jürgen, GERS F. and ECK Douglas; (2002), "Learning Nonregular Languages: A Comparison Of Simple Recurrent Networks and LSTM", **Neural Computation**, 14(9), pp. 2039–2041.
- SERMAYE PİYASASI LİSANSLAMA; (2017), "**Lisanslama Sınavları Çalışma Notları, Finansal Piyasalar, Ders Kodu: 1006**", https://www.spl.com.tr/spl/eep/Specific/OEP/Upload/SINAV/CalismaNotlari/MKT_31%20Aral%C4%B1k%202017/1006-Finansal%20Piyasalar_31122017.pdf, Eriřim Tarihi: 25.01.2019
- SERMAYE PİYASASI LİSANSLAMA; (2018), "**Lisanslama Sınavları Çalışma**

- Notları, Sermaye Piyasası Araçları 1, Ders Kodu: 1003",**
https://www.spl.com.tr/spl/eep/Specific/OEP/Upload/SINAV/CalismaNotlari/MKT_31%20Aral%C4%B1k%202017/1003-Sermaye%20Piyasas%C4%B1%20Ara%C3%A7lar%C4%B1%201_31122017.pdf, Erişim Tarihi: 25.01.2019
- SHEN Furao, CHAO Jing and ZHAO Jinxi; (2015), "Forecasting Exchange Rate Using Deep Belief Networks and Conjugate Gradient Method", **Neurocomputing**, 167, pp. 243–253.
- SMOLA Alex J. and SCHÖLKOPF Bernhard; (2004), "A Tutorial on Support Vector Regression" **Statistics and Computing**, 14(3), pp. 199–222.
- ŞEKER Abdulkadir, DİRİ Banu ve BALIK Hasan Hüseyin; (2017), "Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme", **Gazi Mühendislik Bilimleri Dergisi (GMBD)**, 3(3), pp. 47–64.
- TAY Francis E. H. and CAO Lijuan; (2001a), "Application Of Support Vector Machines in Financial Time Series Forecasting", **Omega**, 29(4), pp. 309–317.
- TAY Francis E. H. and CAO Lijuan; (2001b), "Improved Financial Time Series Forecasting By Combining Support Vector Machines With Self-Organizing Feature Map", **Intelligent Data Analysis**, 5(4), pp. 339–354.
- TAY Francis E. H. and CAO, L.J.; (2002), "Modified Support Vector Machines İn Financial Time Series Forecasting", **Neurocomputing**, 48(1-4), pp. 847–861.
- TAYYAR Nezih ve TEKİN Selin; (2013), "İMKB-100 Endeksinin Destek Vektör Makineleri İle Günlük, Haftalık Ve Aylık Veriler Kullanarak Tahmin Edilmesi", **Abant İzzet Baysal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi**, 26(26), ss. 189-218.
- TEKİN Selin; (2013), Destek Vektör Makineleri Yöntemi İle İMKB 100 Endeksi Hareket Yönü Tahmini, Uşak Üniversitesi Sosyal Bilimler Enstitüsü Yüksek Lisans Tezi, Uşak.
- TÜRK DİL KURUMU; (2019), "**Güncel Türkçe Sözlük**" <http://www.tdk.gov.tr/>, Erişim Tarihi: 15.01.2019.
- XIONG Ruoxuan, NICHOLS Eric P. and SHEN Yuan; (2015), "Deep Learning Stock Volatility With Google Domestic Trends", **arXiv preprint arXiv:1512.04916**, pp. 1-6.

- YAKUT Emre, ELMAS Bekir and YAVUZ Selahattin; (2014), "Yapay Sinir Ağları Ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini", **Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, 19(1), ss. 139–157.
- YILDIZ Ömür; (2006), Döviz Kuru Tahmininde Yapay Sinir Ağlarının Kullanımı, Osmangazi Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Eskişehir.
- YU Lean, WANG Shouyang ve LAI Kin Keung; (2009), "A Neural-Network-Based Nonlinear Metamodeling Approach To Financial Time Series Forecasting", **Applied Soft Computing**, 9(2), ss. 563–574.
- YUMLU Serdar, GURGEN Fikret S. ve OKAY Nesrin; (2005), "A Comparison Of Global, Recurrent and Smoothed-Piecewise Neural Models for Istanbul Stock Exchange (ISE) Prediction", **Pattern Recognition Letters**, 26(13), ss. 2093–2103.
- YURTOĞLU Hasan; (2005), Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği. DPT Uzmanlık Tezleri.
- YÜKSEL Rıdvan ve AKKOÇ Soner; (2016), "Altın Fiyatlarının Yapay Sinir Ağları İle Tahmini ve Bir Uygulama", **Doğuş Üniversitesi Dergisi**, 17 (1), ss. 39-50.
- ZHANG Guoqiang, PATUWO B. Eddy and HU Michael Y.; (1998), "Forecasting With Artificial Neural Networks: The State Of The Art", **International Journal Of Forecasting**, 14(1), ss. 35–62.
- ZHUO Wang, LI-MIN Jia, YONG Qin and YAN-HUI Wang; (2007), "Railway Passenger Traffic Volume Prediction Based on Neural Network", **Applied Artificial Intelligence**, 21(1), ss. 1–10.

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Uğur Demirel
Doğum Yeri ve Tarihi : Gümüşhane / 16.04.1987

Eğitim Durumu

Lisans Öğrenimi : University of Arkansas at Little Rock
Yüksek Lisans Öğrenimi : Gümüşhane Üniversitesi - Devam ediyor
Bildiği Yabancı Diller : İngilizce, İspanyolca
Bilimsel Faaliyetler : -

İş Deneyimi

Stajlar : -
Projeler : -
Çalıştığı Kurumlar : -

İletişim

Telefon : 0 (543) 272 3113
e-posta Adresi : uxdemirel@gmail.com

Tarih : 13.06.2019



EKLER

Ek. 1: Analizlerde Kullanılan Şirketler

Kodlar	Şirket İsimleri
AKBNK	AKBANK T.A.Ş.
AKSA	AKSA AKRİLİK KİMYA SANAYİİ A.Ş.
ALARK	ALARKO HOLDİNG A.Ş.
AEFES	ANADOLU EFES BİRACILIK VE MALT SANAYİİ A.Ş.
ARCLK	ARÇELİK A.Ş.
ASELS	ASELSAN ELEKTRONİK SANAYİ VE TİCARET A.Ş.
BIMAS	BİM BİRLEŞİK MAĞAZALAR A.Ş.
DOHOL	DOĞAN ŞİRKETLER GRUBU HOLDİNG A.Ş.
DOAS	DOĞUŞ OTOMOTİV SERVİS VE TİCARET A.Ş.
ECZYT	ECZACIBAŞI YATIRIM HOLDİNG ORTAKLIĞI A.Ş.
ENKAI	ENKA İNŞAAT VE SAYAI A.Ş.
ERGLI	EREĞLİ DEMİR VE ÇELİK FABRİKALARI T.A.Ş.
FENER	FENERBAHÇE FUTBOL A.Ş.
FROTO	FORD OTOMOTİV SANAYİ A.Ş.
GSRAY	GALATASARAY SPORİF SİNAİ VE TİCARİ YATIRIMLAR A.Ş.
GARAN	TÜRKİYE GARANTİ BANKASI A.Ş.
GSDHO	GSD HOLDİNG A.Ş.
GUBRF	GÜBRE FABRİKALARI T.A.Ş.
HALKB	TÜRKİYE HALK BANKASI A.Ş.
ISCTR	TÜRKİYE İŞ BANKASI A.Ş.
ISGSY	İŞ GAYRİMENKUL YATIRIM ORTAKLIĞI A.Ş.
KRDMD	KARDEMİR KARABÜK DEMİR ÇELİK SANAYİ VE TİCARET A.Ş.
KARSN	KARSAN OTOMOTİV SANAYİİ VE TİCARET A.Ş.
KCHOL	KOÇ HOLDİNG A.Ş.
KOZAA	KOZA ANADOLU METAL MADENCİLİK İŞLETMELERİ A.Ş.
METRO	METRO TİCARİ VE MALİ YATIRIMLAR HOLDİNG A.Ş.
MGROS	MİGROS TİCARET A.Ş.
NETAS	NETAŞ TELEKOMÜNİKASYON A.Ş.
PETKM	PETKİM PETROKİMYA HOLDİNG A.Ş.
SAHOL	HACI ÖMER SABANCI HOLDİNG A.Ş.
SISE	TÜRKİYE ŞİŞE VE CAM FABRİKALARI A.Ş.
TSGYO	TSKB GAYRİMENKUL YATIRIM ORTAKLIĞI A.Ş.
TAVHL	TAV HAVALİMANLARI HOLDİNG A.Ş.
TKFEN	TEKFEN HOLDİNG A.Ş.

TOASO	TOFAŞ TÜRK OTOMOBİL FABRİKASI A.Ş.
TRKCM	TRAKYA CAM SANAYİİ A.Ş.
TUPRS	TÜPRAŞ-TÜRKİYE PETROL RAFİNERİLERİ A.Ş.
THYAO	TÜRK HAVA YOLLARI A.O.
TTKOM	TÜRK TELEKOMÜNİKASYON A.Ş.
TCELL	TURKCELL İLETİŞİM HİZMETLERİ A.Ş.
VAKBN	TÜRKİYE VAKIFLAR BANKASI T.A.O
YKBNK	YAPI VE KREDİ BANKASI A.Ş.



Ek 2: Çalışmada Kullanılan Veriler (Akbank T.A.Ş.)

2010	A.F.	K.F.	2011	A.F.	K.F.	2012	A.F.	K.F.	2013	A.F.	K.F.	2014	A.F.	K.F.	2015	A.F.	K.F.	2016	A.F.	K.F.	2017	A.F.	K.F.	2018	A. F.	K. F.
4.1	9,45	9,55	3.1	8,66	8,68	2.1	6,02	6,04	2.1	8,90	8,96	2.1	6,53	6,56	2.1	8,62	8,69	4.1	6,59	6,58	2.1	7,80	7,77	2.1	10,08	10,09
5.1	9,60	9,70	4.1	8,74	8,74	3.1	6,12	6,26	3.1	8,98	9,04	3.1	6,54	6,45	5.1	8,73	8,75	5.1	6,49	6,54	3.1	7,81	7,61	3.1	10,20	9,94
6.1	9,55	9,65	5.1	8,62	8,62	4.1	6,12	6,02	4.1	9,02	8,98	6.1	6,53	6,80	6.1	8,73	8,80	6.1	6,51	6,64	4.1	7,63	7,50	4.1	10,10	9,84
7.1	9,50	9,60	6.1	8,70	8,64	5.1	5,94	5,92	7.1	9,00	9,02	7.1	6,82	6,87	7.1	8,80	8,77	7.1	6,54	6,68	5.1	7,53	7,50	5.1	9,94	10,05
8.1	9,55	9,55	7.1	8,58	8,52	6.1	6,02	5,76	8.1	9,08	9,04	8.1	6,78	6,65	8.1	8,83	8,84	8.1	6,87	6,71	6.1	7,54	7,65	8.1	10,11	9,94
11.1	9,35	9,30	10.1	8,32	8,34	9.1	5,64	5,66	9.1	8,98	9,02	9.1	6,56	6,53	9.1	8,88	8,94	11.1	6,78	6,77	9.1	7,61	7,66	9.1	9,89	9,81
12.1	9,30	9,25	11.1	8,42	8,38	10.1	5,72	5,84	10.1	9,04	9,08	10.1	6,57	6,69	12.1	9,07	8,92	12.1	6,80	6,84	10.1	7,63	7,47	10.1	9,58	9,63
13.1	9,25	9,30	12.1	8,48	8,42	11.1	5,90	5,96	11.1	9,06	9,00	13.1	6,76	6,69	13.1	8,98	9,01	13.1	7,01	6,99	11.1	7,40	7,43	11.1	9,54	9,69
14.1	9,35	9,30	13.1	8,58	8,64	12.1	6,12	6,10	14.1	9,12	9,16	14.1	6,60	6,78	14.1	8,95	8,85	14.1	7,02	7,02	12.1	7,61	7,85	12.1	9,82	9,80
15.1	9,20	9,20	14.1	8,50	8,46	13.1	6,10	5,96	15.1	9,16	9,20	15.1	6,75	6,72	15.1	9,02	9,03	15.1	6,99	6,91	13.1	7,81	7,80	15.1	9,84	9,58
18.1	9,20	9,20	17.1	8,40	8,34	16.1	6,06	6,22	16.1	9,30	9,48	16.1	6,64	6,58	16.1	8,98	9,00	18.1	6,91	6,91	16.1	7,75	7,73	16.1	9,50	9,84
19.1	9,05	9,25	18.1	8,44	8,24	17.1	6,40	6,38	17.1	9,78	9,80	17.1	6,59	6,37	19.1	9,02	9,00	19.1	6,96	6,87	17.1	7,78	7,83	17.1	9,76	10,10
20.1	9,20	9,30	19.1	8,28	8,14	18.1	6,38	6,50	18.1	9,76	9,86	20.1	6,44	6,42	20.1	9,10	9,18	20.1	6,71	6,65	18.1	7,89	7,88	18.1	10,12	10,15
21.1	9,15	9,05	20.1	8,00	7,86	19.1	6,64	6,60	21.1	9,92	9,88	21.1	6,45	6,48	21.1	9,29	9,29	21.1	6,57	6,55	19.1	7,90	7,78	19.1	10,03	10,01
22.1	9,00	8,90	21.1	7,76	8,06	20.1	6,60	6,74	22.1	9,90	10,00	22.1	6,55	6,59	22.1	9,34	9,50	22.1	6,67	6,78	20.1	7,80	7,92	22.1	10,09	10,22
25.1	8,90	8,85	24.1	7,86	7,76	23.1	6,66	6,64	23.1	10,08	10,08	23.1	6,52	6,29	23.1	9,41	9,26	25.1	6,85	6,80	23.1	7,87	7,84	23.1	10,27	10,34
26.1	8,75	8,90	25.1	7,68	7,68	24.1	6,50	6,52	24.1	10,05	10,25	24.1	6,10	6,10	26.1	9,27	9,40	26.1	6,86	7,05	24.1	7,87	7,97	24.1	10,47	10,77
27.1	9,00	8,85	26.1	7,78	7,84	25.1	6,54	6,50	25.1	9,94	9,86	27.1	6,22	6,27	27.1	9,33	9,40	27.1	7,07	7,00	25.1	7,89	7,86	25.1	10,78	10,65
28.1	8,90	8,85	27.1	7,82	7,66	26.1	6,90	6,94	28.1	9,66	9,30	28.1	6,24	6,05	28.1	9,30	9,17	28.1	7,06	6,98	26.1	7,90	8,03	26.1	10,88	11,08
29.1	8,75	8,80	28.1	7,46	7,48	27.1	6,92	6,90	29.1	9,32	9,42	29.1	5,90	5,86	29.1	9,10	8,93	29.1	7,10	7,19	27.1	7,99	7,92	29.1	10,88	11,08
1.2	8,85	9,00	31.1	7,50	7,52	30.1	6,94	7,00	30.1	9,26	8,88	30.1	5,77	5,96	30.1	8,89	8,96	1.2	7,14	7,19	30.1	8,14	8,34	30.1	10,94	10,79
2.2	9,00	8,95	1.2	7,74	7,78	31.1	7,06	6,68	31.1	8,96	8,90	31.1	5,76	5,76	2.2	9,05	9,18	2.2	7,16	7,03	31.1	8,36	8,40	31.1	10,90	10,92
3.2	9,05	8,95	2.2	7,98	7,96	1.2	6,82	7,08	1.2	9,00	9,10	3.2	5,77	5,80	3.2	9,12	8,76	3.2	7,10	7,24	1.2	8,38	8,45	1.2	10,99	10,58
4.2	8,75	8,70	3.2	7,92	7,64	2.2	7,14	7,30	4.2	9,18	9,18	4.2	5,81	5,83	4.2	8,61	8,44	4.2	7,46	7,45	2.2	8,51	8,66	2.2	10,63	10,65
5.2	8,50	8,45	4.2	7,60	7,92	3.2	7,34	7,24	5.2	9,26	8,98	5.2	5,92	5,83	5.2	8,56	8,54	5.2	7,43	7,34	3.2	8,68	8,81	5.2	10,69	10,60
8.2	8,35	8,10	7.2	7,98	7,88	6.2	7,22	7,26	6.2	9,00	9,10	6.2	5,94	6,10	6.2	8,55	8,41	8.2	7,27	7,12	6.2	8,75	8,63	6.2	10,41	10,49
9.2	8,20	8,15	8.2	7,94	7,94	7.2	7,22	7,22	7.2	8,98	8,72	7.2	6,11	6,12	9.2	8,25	8,35	9.2	7,13	7,20	7.2	8,64	8,68	7.2	10,48	10,40
10.2	8,35	8,10	9.2	8,02	7,96	8.2	7,32	7,30	8.2	8,64	8,84	10.2	6,04	6,07	10.2	8,38	8,11	10.2	7,21	7,16	8.2	8,70	8,81	8.2	10,25	10,15
11.2	8,35	8,35	10.2	7,88	7,86	9.2	7,30	7,04	11.2	8,70	8,54	11.2	6,13	6,13	11.2	8,25	8,11	11.2	7,09	7,13	9.2	8,87	8,87	9.2	10,10	10,25
12.2	8,25	8,25	11.2	7,72	7,84	10.2	6,96	6,82	12.2	8,62	8,64	12.2	6,16	6,08	12.2	8,36	8,55	12.2	7,21	7,16	10.2	8,85	8,63	12.2	10,37	10,39

15.2	8,15	8,15	14.2	7,90	7,76	13.2	6,92	6,98	13.2	8,78	8,56	13.2	6,00	5,94	13.2	8,52	8,52	15.2	7,09	7,12	13.2	8,79	8,87	13.2	10,50	10,34
16.2	8,20	8,20	15.2	7,96	7,84	14.2	7,00	6,88	14.2	8,44	8,50	14.2	6,05	6,10	16.2	8,59	8,57	16.2	7,13	7,04	14.2	8,78	8,91	14.2	10,45	10,15
17.2	8,35	8,55	16.2	7,80	7,88	15.2	6,96	6,88	15.2	8,56	8,60	17.2	6,21	6,26	17.2	8,51	8,39	17.2	7,16	7,22	15.2	8,91	8,78	15.2	10,45	10,56
18.2	8,45	8,40	17.2	7,94	8,14	16.2	6,92	7,02	18.2	8,60	8,60	18.2	6,17	6,07	18.2	8,39	8,54	18.2	7,24	7,24	16.2	8,87	8,85	16.2	10,63	10,57
19.2	8,25	8,60	18.2	8,04	8,04	17.2	7,04	7,10	19.2	8,64	8,76	19.2	6,00	5,92	19.2	8,66	8,63	19.2	7,17	7,14	17.2	8,92	8,98	19.2	10,54	10,42
22.2	8,55	8,40	21.2	8,00	8,00	20.2	7,20	7,10	20.2	8,72	8,72	20.2	5,87	5,90	20.2	8,57	8,48	22.2	7,31	7,37	20.2	8,96	8,94	20.2	10,36	10,23
23.2	8,30	8,20	22.2	7,92	7,94	21.2	7,12	7,08	21.2	8,74	8,58	21.2	5,92	5,89	23.2	8,46	8,58	23.2	7,44	7,51	21.2	9,04	8,96	21.2	10,38	10,50
24.2	8,05	7,95	23.2	7,90	7,76	22.2	7,08	6,98	22.2	8,48	8,38	24.2	5,88	5,92	24.2	8,46	8,58	24.2	7,42	7,32	22.2	8,88	8,79	22.2	10,41	10,51
25.2	8,05	7,70	24.2	7,60	7,58	23.2	6,90	6,70	25.2	8,46	8,46	25.2	5,74	5,69	25.2	8,64	8,63	25.2	7,42	7,41	23.2	8,89	8,82	23.2	10,59	10,53
26.2	7,85	7,80	25.2	7,66	7,60	24.2	6,78	6,78	26.2	8,38	8,58	26.2	5,71	5,60	26.2	8,73	8,62	26.2	7,53	7,45	24.2	8,81	8,77	26.2	10,63	10,63
1.3	7,95	8,10	28.2	7,52	7,48	27.2	6,70	6,62	27.2	8,50	8,60	27.2	5,62	5,65	27.2	8,69	8,49	29.2	7,35	7,39	27.2	8,80	8,74	27.2	10,76	10,74
2.3	8,20	8,20	1.3	7,38	7,00	28.2	6,78	6,82	28.2	8,66	8,74	28.2	5,73	5,72	2.3	8,31	8,21	1.3	7,40	7,40	28.2	8,74	8,69	28.2	10,59	10,63
3.3	8,25	8,30	2.3	7,02	6,86	29.2	6,90	7,02	1.3	8,76	8,78	3.3	5,66	5,66	3.3	8,21	8,23	2.3	7,50	7,53	1.3	8,92	8,94	1.3	10,53	10,52
4.3	8,30	8,25	3.3	7,06	7,04	1.3	7,04	7,02	4.3	8,80	8,88	4.3	5,80	5,82	4.3	8,16	8,00	3.3	7,56	7,50	2.3	8,99	9,01	2.3	10,49	10,47
5.3	8,30	8,45	4.3	7,10	7,10	5.3	6,98	6,86	5.3	8,96	8,90	5.3	5,86	5,88	5.3	7,62	7,67	4.3	7,50	7,52	3.3	9,01	8,99	5.3	10,50	10,38
8.3	8,50	8,70	7.3	7,06	6,96	6.3	6,80	6,80	6.3	8,96	9,16	6.3	5,93	5,94	6.3	7,75	7,51	7.3	7,49	7,51	6.3	9,23	9,26	6.3	10,53	10,55
9.3	8,70	8,70	8.3	7,06	7,10	7.3	6,82	6,82	7.3	9,10	9,04	7.3	5,93	5,83	9.3	7,54	7,61	8.3	7,55	7,66	7.3	9,25	9,13	7.3	10,51	10,57
10.3	8,75	8,85	9.3	7,18	7,42	8.3	6,94	6,86	8.3	9,10	9,42	10.3	5,80	5,83	10.3	7,35	7,19	9.3	7,70	7,87	8.3	9,00	8,93	8.3	10,52	10,48
11.3	8,80	8,75	10.3	7,38	7,74	9.3	6,94	6,86	11.3	9,46	9,44	11.3	5,83	5,79	11.3	7,34	7,41	10.3	7,84	7,95	9.3	8,82	8,79	9.3	10,49	10,39
12.3	8,80	8,75	11.3	7,74	7,84	12.3	6,86	6,84	12.3	9,52	9,42	12.3	5,76	5,97	12.3	7,50	7,44	11.3	7,97	7,95	10.3	8,88	8,87	12.3	10,60	10,60
15.3	8,75	8,70	14.3	7,78	7,78	13.3	6,92	6,78	13.3	9,34	9,28	13.3	6,07	5,98	13.3	7,36	7,41	14.3	8,04	8,04	13.3	8,84	8,88	13.3	10,48	10,44
16.3	8,85	8,90	15.3	7,48	7,80	14.3	6,94	6,92	14.3	9,28	9,18	14.3	5,98	6,00	16.3	7,55	7,61	15.3	7,90	7,78	14.3	8,83	8,76	14.3	10,48	10,28
17.3	9,15	9,15	16.3	7,74	7,56	15.3	7,02	7,08	15.3	9,34	9,30	17.3	6,09	6,12	17.3	7,78	7,77	16.3	7,80	7,73	15.3	8,86	8,84	15.3	10,31	10,17
18.3	9,05	9,10	17.3	7,50	7,50	16.3	7,32	7,38	18.3	9,32	9,34	18.3	6,18	6,36	18.3	7,70	7,67	17.3	7,90	8,10	16.3	8,98	8,92	16.3	10,15	10,11
19.3	9,10	9,10	18.3	7,40	7,58	19.3	7,44	7,42	19.3	9,36	9,14	19.03	6,27	6,27	19.3	8,03	8,06	18.3	8,09	8,21	17.3	8,95	8,91	19.3	9,98	9,86
22.3	9,05	9,15	21.3	7,58	7,60	20.3	7,26	7,40	20.3	9,16	9,04	20.3	6,28	6,23	20.3	8,08	8,15	21.3	8,14	8,15	20.3	8,91	8,95	20.3	9,98	10,05
23.3	9,20	9,25	22.3	7,68	7,78	21.3	7,48	7,40	21.3	9,12	9,12	21.3	6,17	6,18	23.3	8,27	8,25	22.3	7,97	7,87	21.3	8,95	8,86	21.3	10,18	10,18
24.3	9,30	9,55	23.3	7,60	7,38	22.3	7,36	7,40	22.3	9,12	9,06	24.3	6,18	6,11	24.3	8,00	7,97	23.3	7,90	7,87	22.3	8,83	8,78	22.3	10,23	10,07
25.3	9,80	10,25	24.3	7,38	7,58	23.3	7,34	7,26	25.3	9,14	9,12	25.3	6,17	6,27	25.3	8,04	8,01	24.3	7,92	8,07	23.3	8,77	8,72	23.3	9,93	9,92
26.3	10,10	10,10	25.3	7,62	7,48	26.3	6,96	7,02	26.3	9,16	9,34	26.3	6,50	6,68	26.3	7,82	7,94	25.3	8,07	8,02	24.3	8,79	8,89	26.3	9,81	9,77
29.3	10,20	10,10	28.3	7,48	7,52	27.3	7,04	6,96	27.3	9,28	9,34	27.3	6,71	6,53	27.3	7,83	7,84	28.3	7,97	7,95	27.3	8,83	8,81	27.3	9,90	9,70
30.3	9,95	9,95	29.3	7,40	7,44	28.3	7,00	6,90	28.3	9,44	9,50	28.3	6,73	6,90	30.3	7,87	7,88	29.3	7,99	7,93	28.3	8,84	8,86	28.3	9,41	9,38
31.3	10,00	9,80	30.3	7,58	7,64	29.3	6,92	6,98	29.3	9,44	9,46	31.3	6,84	6,80	31.3	7,70	7,65	30.3	7,98	8,00	28.3	8,84	8,86	29.3	9,46	9,56
1.4	10,00	10,25	31.3	7,58	7,50	30.3	7,08	7,00	1.4	9,52	9,50	1.4	6,87	7,09	1.4	7,69	7,69	31.3	8,01	8,02	29.3	8,77	8,78	30.3	9,61	9,55
2.4	10,50	10,50	1.4	7,56	7,74	2.4	7,00	7,06	2.4	9,46	9,44	2.4	7,10	7,07	2.4	7,73	7,73	1.4	7,95	7,87	30.3	8,61	8,55	2.4	9,50	9,48
5.4	10,60	10,70	4.4	7,92	8,12	3.4	7,10	7,10	3.4	9,40	9,28	3.4	7,14	7,16	3.4	7,72	7,97	4.4	8,01	8,07	31.3	8,59	8,53	3.4	9,52	9,51
6.4	10,70	10,60	5.4	8,14	8,16	4.4	6,98	6,90	4.4	9,28	9,12	4.4	7,12	7,24	6.4	8,07	8,14	5.4	7,93	7,98	3.4	8,54	8,47	4.4	9,47	9,58
7.4	10,60	10,70	6.4	8,36	8,42	5.4	6,94	6,90	5.4	9,08	8,98	7.4	7,23	7,29	7.4	8,03	7,93	6.4	7,91	7,84	4.4	8,51	8,53	5.4	9,62	9,73
8.4	10,30	10,40	7.4	8,36	8,64	6.4	6,90	6,90	8.4	8,98	9,14	8.4	7,46	7,59	8.4	7,99	8,02	7.4	7,83	7,85	5.4	8,57	8,65	6.4	9,70	9,63

9.4	10,50	10,50	8.4	8,64	8,36	9.4	6,90	6,86	9.4	9,14	9,04	9.4	7,46	7,36	9.4	7,98	8,08	8.4	7,86	7,96	6.4	8,63	8,60	9.4	9,62	9,53
12.4	10,50	10,30	11.4	8,40	8,36	10.4	6,86	6,80	10.4	9,14	9,06	10.4	7,40	7,42	10.4	8,00	7,92	11.4	8,05	8,12	7.4	8,57	8,56	10.4	9,22	9,17
13.4	10,10	10,10	12.4	8,36	8,40	11.4	6,80	6,86	11.4	9,28	9,36	11.4	7,35	7,35	13.4	7,88	7,74	12.4	8,19	8,12	10.4	8,95	9,07	11.4	9,28	8,99
14.4	10,40	10,50	13.4	8,44	8,36	12.4	6,84	6,86	12.4	9,40	9,48	14.4	7,23	7,39	14.4	7,62	7,89	13.4	8,30	8,43	11.4	9,11	9,03	12.4	9,19	9,21
15.4	10,40	10,50	14.4	8,34	8,36	13.4	6,88	6,82	15.4	9,42	9,56	15.4	7,46	7,15	15.4	7,77	7,68	14.4	8,45	8,46	12.4	9,10	9,10	13.4	9,11	9,16
16.4	7,70	7,45	15.4	8,34	8,36	16.4	6,80	6,82	16.4	9,54	9,44	16.4	7,19	7,16	16.4	7,76	7,75	15.4	8,42	8,49	13.4	9,07	8,95	16.4	9,25	9,16
19.4	7,25	7,40	18.4	8,38	8,06	17.4	6,84	6,84	17.4	9,40	9,24	17.4	7,21	7,29	17.4	7,80	7,74	15.4	8,42	8,49	14.4	8,94	9,09	17.4	9,03	9,14
20.4	7,45	7,45	19.4	8,16	8,16	18.4	6,84	6,74	18.4	9,26	9,10	18.4	7,30	7,29	20.4	7,73	7,65	18.4	8,64	8,71	17.4	9,15	9,09	18.4	9,04	9,51
21.4	7,25	7,30	20.4	8,28	8,12	19.4	6,76	6,64	19.4	9,10	9,12	21.4	7,28	7,27	21.4	7,75	7,90	19.4	8,71	8,69	18.4	9,15	9,26	19.4	9,35	9,33
22.4	7,20	7,25	21.4	8,06	8,10	20.4	6,66	6,66	22.4	9,20	9,28	22.4	7,27	7,19	22.4	7,90	7,77	20.4	8,72	8,51	19.4	9,26	9,12	20.4	9,30	9,21
26.4	7,30	7,35	22.4	8,10	8,06	24.4	6,62	6,56	24.4	9,44	9,34	24.4	7,18	7,04	24.4	7,81	7,90	21.4	8,59	8,54	20.4	9,14	9,27	24.4	9,27	9,39
27.4	7,20	7,25	25.4	8,08	8,10	25.4	6,64	6,72	25.4	9,42	9,34	25.4	6,93	6,83	27.4	7,99	8,07	22.4	8,51	8,49	21.4	9,30	9,31	25.4	9,27	8,96
28.4	7,20	7,30	26.4	8,06	8,04	26.4	6,66	6,76	26.4	9,28	9,36	28.4	6,99	7,01	28.4	8,12	8,11	25.4	8,37	8,35	24.4	9,44	9,61	26.4	8,97	8,76
29.4	7,35	7,35	27.4	7,90	7,80	27.4	6,72	6,70	29.4	9,38	9,36	29.4	7,08	6,97	29.4	8,14	8,12	26.4	8,40	8,57	25.4	9,62	9,70	27.4	8,80	8,81
30.4	7,35	7,45	28.4	7,70	7,80	30.4	6,60	6,52	30.4	9,38	9,42	30.4	7,17	7,37	30.4	8,01	7,79	27.4	8,67	8,56	26.4	9,67	9,56	30.4	8,82	8,46
3.5	7,50	7,40	29.4	7,78	7,90	2.5	6,48	6,50	2.5	9,64	9,82	2.5	7,49	7,49	4.5	7,80	7,79	28.4	8,54	8,62	27.4	9,63	9,44	2.5	8,40	8,44
4.5	7,40	7,35	2.5	7,96	7,98	3.5	6,60	6,60	3.5	9,94	9,92	5.5	7,45	7,40	5.5	7,82	7,70	29.4	8,61	8,60	28.4	9,41	9,51	3.5	8,50	8,15
5.5	7,35	7,30	3.5	7,92	8,02	4.5	6,64	6,54	6.5	10,02	10,02	6.5	7,46	7,55	6.5	7,65	7,63	2.5	8,47	8,40	2.5	9,55	9,43	4.5	8,23	8,33
6.5	7,35	7,30	4.5	8,06	7,96	7.5	6,44	6,52	7.5	10,10	10,00	7.5	7,54	7,45	7.5	7,61	7,64	3.5	8,28	8,06	3.5	9,43	9,40	7.5	8,29	8,19
7.5	7,05	6,95	5.5	8,02	8,06	8.5	6,50	6,50	8.5	10,10	10,16	8.5	7,59	7,56	8.5	7,76	7,89	4.5	7,94	7,78	4.5	9,50	9,27	8.5	8,14	8,17
10.5	7,45	7,40	6.5	8,04	7,86	9.5	6,48	6,40	9.5	10,15	10,10	9.5	7,51	7,54	11.5	8,00	7,98	5.5	7,65	7,64	5.5	9,31	9,30	9.5	8,34	8,35
11.5	7,30	7,45	9.5	7,84	7,76	10.5	6,42	6,44	10.5	9,92	9,98	12.5	7,74	7,68	12.5	7,91	7,99	6.5	7,54	7,63	8.5	9,31	9,24	10.5	8,41	8,74
12.5	7,70	7,85	10.5	7,80	7,62	11.5	6,36	6,38	13.5	10,00	10,02	13.5	7,71	7,62	13.5	8,07	8,25	9.5	7,73	7,75	9.5	9,29	9,38	11.5	8,66	8,55
13.5	7,80	7,95	11.5	7,48	7,30	14.5	6,28	6,30	14.5	10,15	10,20	14.5	7,68	7,66	14.5	8,31	8,37	10.5	7,79	7,66	10.5	9,28	9,43	14.5	8,56	8,57
14.5	7,75	7,60	12.5	7,34	7,52	15.5	6,24	6,26	15.5	10,30	10,35	15.5	7,69	7,58	15.5	8,45	8,40	11.5	7,60	7,73	11.5	9,32	9,25	15.5	8,36	8,35
17.5	7,70	7,85	13.5	7,40	7,44	16.5	6,22	6,40	16.5	10,35	10,30	16.5	7,56	7,54	18.5	8,52	8,61	12.5	7,82	7,70	12.5	9,26	9,19	16.5	8,31	8,44
18.5	8,00	8,05	16.5	7,44	7,76	17.5	6,34	6,18	17.5	10,35	10,25	20.5	7,54	7,60	20.5	8,45	8,44	13.5	7,72	7,69	15.5	9,26	9,23	17.5	8,42	8,39
20.5	7,85	7,65	17.5	7,62	7,58	18.5	6,16	6,22	20.5	10,10	9,90	21.5	7,71	7,75	21.5	8,50	8,30	16.5	7,63	7,50	16.5	9,24	9,30	18.5	8,48	8,52
21.5	7,60	7,55	18.5	7,58	7,28	21.5	6,22	6,10	21.5	10,00	10,10	22.5	7,78	8,02	22.5	8,19	8,15	17.5	0,00	7,61	17.5	9,35	9,33	21.5	8,55	8,47
24.5	7,55	7,70	20.5	7,40	7,38	22.5	6,10	6,08	22.5	10,20	10,45	23.5	8,09	8,09	25.5	8,09	8,02	18.5	7,61	7,71	18.5	9,22	9,25	22.5	8,62	8,55
25.5	7,40	7,30	23.5	7,42	7,40	23.5	5,94	5,84	23.5	10,15	10,10	26.5	8,16	8,20	26.5	8,09	7,95	20.5	7,66	7,50	22.5	9,35	9,35	23.5	8,55	8,48
26.5	7,55	7,85	24.5	7,42	7,62	24.5	5,96	5,80	24.5	10,10	9,95	27.5	8,10	8,05	27.5	7,97	8,09	23.5	7,56	7,66	23.5	9,40	9,51	24.5	8,80	8,53
27.5	7,75	7,70	25.5	7,62	7,38	25.5	5,46	5,44	27.5	9,76	9,76	28.5	8,16	8,07	28.5	8,13	8,06	24.5	7,92	8,05	24.5	9,74	9,68	25.5	8,68	8,61
28.5	7,80	7,95	26.5	7,48	7,38	28.5	5,38	5,32	28.5	9,74	9,56	29.5	8,17	8,26	29.5	8,11	7,93	25.5	8,02	7,93	25.5	9,57	9,67	28.5	8,84	8,80
31.5	7,75	7,80	27.5	7,18	7,14	29.5	5,52	5,50	29.5	9,26	9,14	30.5	8,26	8,18	1.6	7,86	7,63	26.5	7,88	7,89	26.5	9,58	9,56	29.5	8,64	8,58
1.6	7,65	7,70	30.5	7,22	7,10	30.5	5,38	5,42	30.5	9,12	9,10	2.6	8,14	7,98	2.6	7,70	7,82	27.5	7,98	7,95	29.5	9,62	9,63	30.5	8,61	8,42
2.6	7,80	7,90	31.5	7,22	7,40	31.5	5,46	5,70	31.5	8,96	8,94	3.6	7,94	7,88	3.6	7,86	7,99	30.5	8,03	8,00	30.5	9,55	9,50	31.5	8,24	8,03
3.6	8,10	8,00	1.6	7,40	7,42	1.6	5,56	5,80	3.6	8,30	8,10	4.6	7,85	7,78	4.6	7,76	7,83	31.5	8,06	7,97	31.5	9,67	9,53	1.6	7,78	7,71
4.6	7,95	7,90	2.6	7,38	7,42	4.6	5,76	5,70	4.6	8,48	8,52	5.6	7,85	7,97	5.6	7,90	7,76	1.6	7,91	7,90	1.6	9,52	9,53	4.6	7,89	7,75

7.6	7,80	7,75	3.6	7,34	7,14	5.6	5,68	5,56	5.6	8,28	8,38	6.6	8,08	8,05	8.6	7,18	7,35	2.6	7,86	7,79	2.6	9,57	9,66	5.6	7,72	7,56
8.6	7,80	7,70	6.6	7,18	7,26	6.6	5,68	5,68	6.6	8,34	8,00	9.6	8,18	8,15	9.6	7,45	7,47	3.6	7,83	8,00	5.6	9,69	9,61	6.6	7,36	7,45
9.6	7,60	7,70	7.6	7,46	7,58	7.6	5,76	5,80	7.6	8,24	8,28	10.6	8,21	8,30	10.6	7,65	7,75	6.6	8,09	8,07	6.6	9,59	9,63	7.6	7,52	7,64
10.6	7,85	7,90	8.6	7,54	7,54	8.6	5,80	5,98	10.6	8,26	8,14	11.6	8,25	8,05	11.6	7,78	7,92	7.6	8,10	7,89	7.6	9,64	9,56	8.6	7,50	7,43
11.6	7,95	7,90	9.6	7,60	7,56	11.6	6,06	6,04	11.6	8,20	8,10	12.6	8,10	8,12	12.6	7,97	7,85	8.6	7,97	8,05	8.6	9,52	9,51	11.6	7,28	7,44
14.6	8,05	8,05	10.6	7,62	7,60	12.6	6,04	6,12	12.6	8,30	8,40	13.6	8,02	8,01	15.6	7,79	7,67	9.6	8,01	7,92	9.6	9,64	9,61	12.6	7,43	7,38
15.6	8,10	8,20	13.6	7,60	7,58	13.6	6,08	6,06	13.6	8,42	8,20	16.6	7,87	7,72	16.6	7,79	7,80	10.6	7,89	7,85	12.6	9,70	9,79	13.6	7,38	7,31
16.6	8,20	8,05	14.6	7,42	7,32	14.6	6,04	6,08	14.6	8,46	8,72	17.6	7,78	7,75	17.6	7,88	7,85	13.6	7,75	7,83	13.6	9,76	9,80	14.6	0,00	7,25
17.6	8,30	8,10	15.6	7,08	7,14	15.6	6,10	6,12	17.6	8,64	8,42	18.6	7,79	7,73	18.6	7,95	7,96	15.6	7,90	7,85	14.6	9,80	9,86	18.6	7,23	7,19
18.6	8,20	8,15	16.6	7,22	7,32	18.6	6,12	6,04	18.6	8,50	8,28	19.6	7,88	7,88	19.6	8,00	8,02	16.6	7,80	7,69	15.6	9,76	9,76	19.6	7,21	7,29
21.6	8,20	8,35	17.6	7,38	7,48	19.6	6,12	6,18	19.6	8,42	8,44	20.6	7,86	7,82	22.6	8,15	8,16	17.6	7,88	7,93	16.6	9,78	9,75	20.6	7,27	7,27
22.6	8,20	8,25	20.6	7,26	7,26	20.6	6,28	6,20	20.6	8,02	7,90	23.6	7,88	8,05	23.6	8,06	7,99	20.6	8,15	8,20	19.6	9,89	10,01	21.6	7,26	7,25
23.6	8,15	8,05	21.6	7,38	7,46	21.6	6,28	6,36	21.6	7,82	7,62	24.6	8,12	7,91	24.6	8,06	8,12	21.6	8,25	8,23	20.6	9,95	9,97	22.6	7,32	7,37
24.6	7,90	7,90	22.6	7,40	7,30	22.6	6,36	6,34	24.6	7,52	7,26	25.6	7,83	7,98	25.6	8,10	7,95	22.6	8,20	8,18	21.6	9,92	9,98	25.6	7,20	7,06
25.6	7,90	7,85	23.6	7,30	7,40	25.6	6,24	6,16	25.6	7,42	7,16	26.6	7,92	7,80	26.6	7,97	7,94	23.6	8,38	8,38	22.6	9,96	10,06	26.6	7,20	7,25
28.6	8,00	8,00	24.6	7,66	7,54	26.6	6,22	6,30	26.6	7,38	7,54	27.6	7,83	7,83	29.6	7,84	7,77	24.6	8,03	8,17	23.6	9,95	9,94	27.6	7,48	7,51
29.6	7,85	7,80	27.6	7,52	7,46	27.6	6,44	6,44	27.6	7,72	7,72	30.6	7,90	7,79	30.6	7,80	7,75	27.6	8,18	8,11	28.6	9,88	9,98	28.6	7,49	7,48
30.6	7,80	7,65	28.6	7,54	7,50	28.6	6,44	6,40	28.6	7,94	7,86	1.7	7,80	7,58	1.7	7,81	7,61	28.6	8,22	8,21	29.6	9,99	9,89	29.6	7,59	7,52
1.7	7,60	7,55	29.6	7,50	7,52	29.6	6,52	6,62	1.7	7,78	7,90	2.7	7,51	7,59	2.7	7,56	7,67	29.6	8,16	8,14	30.6	9,89	9,80	2.7	7,53	7,52
2.7	7,70	7,90	30.6	7,52	7,50	2.7	6,60	6,52	2.7	7,88	7,90	3.7	7,54	7,64	3.7	7,65	7,58	30.6	8,23	8,23	3.7	9,81	9,83	3.7	7,46	7,40
5.7	8,00	7,95	1.7	7,46	7,46	3.7	6,60	6,68	3.7	7,54	7,54	4.7	7,60	7,57	6.7	7,68	7,77	1.7	8,27	8,38	4.7	9,93	9,99	4.7	7,46	7,50
6.7	8,05	8,15	4.7	7,48	7,56	4.7	6,74	6,76	4.7	7,52	7,74	7.7	7,66	7,84	7.7	7,74	7,62	4.7	0,00	8,43	5.7	9,90	9,86	5.7	7,60	7,62
7.7	8,05	8,15	5.7	7,54	7,50	5.7	6,78	6,58	5.7	7,82	7,34	8.7	7,93	7,95	8.7	7,58	7,39	8.7	8,38	8,32	6.7	9,91	9,93	6.7	7,57	7,60
8.7	8,20	8,20	6.7	7,44	7,40	6.7	6,62	6,72	8.7	7,24	7,08	9.7	8,00	8,00	9.7	7,57	7,70	11.7	8,39	8,39	7.7	9,90	9,86	9.7	7,71	7,67
9.7	8,10	8,15	7.7	7,38	7,52	9.7	6,68	6,70	9.7	7,16	7,12	10.7	7,93	7,79	10.7	7,84	7,77	12.7	8,68	8,83	10.7	9,92	9,91	10.7	7,40	7,25
12.7	8,05	8,20	8.7	7,58	7,44	10.7	6,80	6,76	10.7	6,92	6,86	11.7	7,85	7,92	13.7	7,86	7,82	13.7	8,84	8,83	11.7	10,07	10,25	11.7	7,03	6,67
13.7	8,30	8,35	11.7	7,44	7,26	11.7	6,80	6,74	11.7	7,02	6,88	14.7	7,99	8,19	14.7	7,89	7,75	14.7	8,83	8,84	12.7	10,36	10,38	12.7	6,85	6,62
14.7	8,55	8,55	12.7	7,24	7,36	12.7	6,66	6,60	12.7	6,98	7,28	15.7	8,18	8,27	15.7	7,72	7,71	15.7	8,87	8,92	13.7	10,26	10,22	13.7	6,60	6,55
15.7	8,55	8,30	13.7	7,40	7,40	13.7	6,68	6,66	15.7	7,50	7,64	16.7	8,29	8,30	20.7	7,55	7,51	18.7	8,41	8,22	14.7	10,29	10,38	16.7	6,61	6,50
16.7	8,40	8,30	14.7	7,34	7,30	16.7	6,68	6,72	16.7	7,76	7,68	17.7	8,22	8,14	21.7	7,46	7,45	19.7	8,17	7,97	17.7	10,38	10,52	17.7	6,62	6,64
19.7	8,45	8,40	15.7	7,32	7,28	17.7	6,74	6,70	17.7	7,74	8,04	18.7	8,13	8,28	22.7	7,38	7,43	20.7	7,87	7,71	18.7	10,41	10,38	18.7	6,51	6,64
20.7	8,40	8,45	18.7	7,26	7,20	18.7	6,76	6,68	18.7	8,16	8,06	21.7	8,33	8,23	23.7	7,35	7,23	21.7	7,57	7,42	19.7	10,50	10,60	19.7	6,64	6,57
21.7	8,55	8,65	19.7	7,26	7,24	19.7	6,70	6,62	19.7	7,94	7,88	22.7	8,34	8,29	24.7	7,22	7,34	22.7	7,43	7,44	20.7	10,52	10,46	20.7	6,60	6,62
22.7	8,65	8,55	20.7	7,26	7,26	20.7	6,50	6,52	22.7	7,88	7,82	23.7	8,31	8,36	27.7	7,21	7,19	25.7	7,65	7,65	21.7	10,35	10,42	23.7	6,87	6,85
23.7	8,50	8,50	21.7	7,08	7,18	23.7	6,40	6,38	23.7	7,94	7,76	24.7	8,53	8,56	28.7	7,29	7,18	26.7	7,56	7,47	24.7	10,43	10,40	24.7	6,96	6,53
26.7	8,45	8,35	22.7	7,14	6,98	24.7	6,42	6,44	24.7	7,80	7,62	25.7	8,53	8,72	29.7	7,20	7,21	27.7	7,56	7,65	25.7	10,44	10,37	25.7	6,67	7,04
27.7	8,50	8,35	25.7	7,06	7,24	25.7	6,48	6,50	25.7	7,42	7,58	31.7	8,60	8,53	30.7	7,24	7,29	28.7	7,68	7,60	26.7	10,44	10,43	26.7	7,19	7,02
28.7	8,25	8,25	26.7	7,18	7,22	26.7	6,62	6,72	26.7	7,40	7,26	1.8	8,41	8,60	31.7	7,32	7,42	29.7	7,64	7,70	27.7	10,54	10,53	27.7	7,00	7,10
29.7	8,35	8,40	27.7	7,28	7,18	27.7	6,76	6,78	29.7	7,26	7,42	4.8	8,60	8,53	3.8	7,30	7,20	1.8	7,84	7,81	28.7	10,43	10,41	30.7	7,03	7,17

30.7	8,25	8,35	28.7	7,26	7,38	30.7	6,78	6,82	30.7	7,64	7,66	5.8	8,56	8,29	4.8	7,23	7,20	2.8	7,72	7,65	31.7	10,40	10,46	31.7	7,25	7,23
2.8	8,40	8,50	29.7	7,32	7,38	31.7	6,82	6,76	31.7	7,64	7,44	6.8	8,15	8,09	5.8	7,19	7,18	3.8	7,56	7,52	1.8	10,40	10,32	1.8	7,12	7,10
3.8	8,35	8,20	2.8	7,22	7,22	1.8	6,76	6,78	1.8	7,56	7,40	7.8	8,16	8,09	6.8	7,25	7,29	4.8	7,63	7,76	2.8	10,38	10,39	2.8	6,83	6,74
4.8	8,20	8,05	3.8	7,20	7,34	2.8	6,80	6,68	2.8	7,24	7,34	8.8	8,00	8,18	7.8	7,29	7,29	5.8	7,78	7,72	3.8	10,36	10,37	3.8	6,84	6,91
5.8	8,05	7,95	4.8	7,22	6,94	3.8	6,70	6,82	5.8	7,40	7,30	11.8	8,06	7,79	10.8	7,16	7,21	8.8	7,94	8,02	4.8	10,48	10,56	6.8	6,77	6,69
6.8	7,90	7,85	5.8	6,78	6,54	6.8	6,90	6,84	6.8	7,26	7,20	12.8	7,88	7,95	11.8	7,44	7,51	9.8	8,09	8,10	7.8	10,61	10,63	7.8	6,78	6,97
9.8	7,95	7,90	8.8	6,20	6,00	7.8	6,82	6,78	12.8	7,20	7,46	13.8	7,87	7,86	12.8	7,36	7,27	10.8	8,10	8,05	8.8	10,66	10,61	8.8	7,05	7,12
10.8	7,90	7,95	9.8	6,10	6,16	8.8	6,80	6,76	13.8	7,54	7,50	14.8	7,86	7,86	13.8	7,15	7,09	11.8	8,06	8,18	9.8	10,43	10,42	9.8	7,25	7,12
11.8	7,75	7,80	10.8	6,20	5,60	9.8	6,82	6,72	14.8	7,54	7,52	15.8	7,80	7,67	14.8	7,06	7,08	12.8	8,11	8,12	10.8	10,40	10,33	10.8	6,96	6,71
12.8	7,80	7,95	11.8	5,80	5,98	10.8	6,68	6,78	15.8	7,54	7,36	18.8	7,72	7,78	17.8	7,02	7,00	15.8	8,19	8,16	11.8	10,22	10,17	13.8	5,97	6,16
13.8	7,95	7,95	12.8	5,98	6,14	13.8	6,84	6,80	16.8	7,34	7,44	19.8	8,01	8,14	18.8	6,89	6,76	16.8	8,09	7,99	14.8	10,36	10,47	14.8	6,38	6,17
16.8	7,95	8,00	15.8	6,20	6,22	14.8	6,76	6,72	19.8	7,22	7,10	20.8	8,00	8,05	19.8	6,79	6,76	17.8	8,07	8,08	15.8	10,36	10,22	15.8	6,11	5,82
17.8	8,05	8,15	16.8	6,12	6,28	15.8	6,76	6,82	20.8	7,10	7,08	21.8	8,05	8,08	20.8	6,64	6,65	18.8	8,17	8,13	16.8	10,14	10,22	16.8	5,76	5,62
18.8	8,10	8,15	17.8	6,38	6,26	16.8	6,96	6,94	21.8	7,00	6,88	22.8	8,03	8,06	21.8	6,60	6,54	19.8	8,11	8,20	17.8	10,22	10,15	17.8	5,57	5,82
19.8	8,20	8,00	18.8	6,10	6,02	17.8	7,04	7,10	22.8	6,72	6,68	25.8	8,05	8,08	24.8	6,43	6,35	22.8	8,13	8,13	18.8	10,08	10,11	20.8	0,00	5,94
20.8	7,90	7,95	19.8	5,80	6,22	22.8	7,02	7,16	23.8	6,82	6,74	26.8	8,28	8,40	25.8	6,53	6,61	23.8	8,15	8,03	21.8	10,15	10,20	27.8	5,82	5,89
23.8	7,95	7,95	22.8	6,30	6,32	23.8	7,20	7,10	26.8	6,74	6,88	27.8	8,41	8,38	26.8	6,61	6,66	24.8	7,81	7,76	22.8	10,20	10,20	28.8	6,01	6,07
24.8	7,80	7,85	23.8	6,32	6,20	24.8	7,22	7,08	27.8	6,66	6,54	28.8	8,32	8,37	27.8	6,76	6,77	25.8	7,87	7,83	23.8	10,24	10,25	29.8	6,00	5,96
25.8	7,75	7,75	24.8	6,28	6,44	27.8	7,10	7,08	28.8	6,64	6,78	29.8	8,41	8,24	28.8	6,78	6,83	26.8	7,84	7,99	24.8	10,36	10,34	31.8	5,77	5,76
26.8	7,80	7,85	25.8	6,46	6,38	28.8	7,14	7,10	29.8	6,82	6,78	1.9	8,24	8,25	31.8	6,79	6,82	29.8	7,89	7,84	25.8	10,43	10,45	3.9	5,82	5,85
27.8	7,95	8,00	26.8	6,44	6,38	29.8	7,10	7,10	2.9	6,98	7,04	2.9	8,23	8,23	1.9	6,71	6,62	31.8	7,91	7,82	28.8	10,50	10,50	4.9	5,86	5,81
31.8	7,95	8,10	2.9	6,48	6,44	31.8	7,08	7,18	3.9	6,90	6,80	3.9	8,32	8,28	2.9	6,65	6,70	1.9	7,90	7,89	29.8	10,41	10,46	5.9	5,65	5,65
1.9	8,10	8,15	5.9	6,38	6,32	3.9	7,14	7,14	4.9	6,84	6,86	4.9	8,33	8,45	3.9	6,72	6,70	2.9	7,89	8,02	31.8	0,00	10,34	6.9	5,68	5,60
2.9	8,05	8,15	6.9	6,46	6,48	4.9	7,12	7,10	5.9	6,84	6,82	5.9	8,37	8,40	4.9	6,62	6,56	5.9	8,12	8,19	5.9	10,27	10,34	7.9	5,63	5,70
3.9	8,10	8,20	7.9	6,58	6,50	5.9	7,14	7,20	6.9	6,88	6,92	8.9	8,45	8,45	7.9	6,47	6,48	6.9	8,20	8,22	6.9	10,28	10,26	10.9	5,66	5,58
6.9	8,10	8,15	8.9	6,64	6,82	6.9	7,22	7,24	9.9	7,16	7,30	9.9	8,29	8,10	8.9	6,51	6,52	7.9	8,17	8,17	7.9	10,26	10,15	11.9	5,61	5,55
7.9	8,15	8,15	9.9	6,74	6,68	7.9	7,26	7,22	10.9	7,34	7,40	10.9	8,02	7,96	9.9	6,56	6,51	8.9	8,26	8,24	8.9	10,05	10,03	12.9	5,56	5,44
13.9	8,25	8,35	12.9	6,56	6,58	10.9	7,26	7,24	11.9	7,36	7,28	11.9	7,93	7,86	10.9	6,44	6,49	9.9	8,16	8,05	11.9	10,15	10,14	13.9	5,45	5,70
14.9	8,30	8,30	13.9	6,62	6,68	11.9	7,24	7,22	12.9	7,28	7,44	12.9	7,91	7,72	11.9	6,48	6,40	16.9	8,10	8,03	12.9	10,20	10,19	14.9	6,00	5,86
15.9	8,30	8,35	14.9	6,76	6,62	12.9	7,26	7,24	13.9	7,40	7,30	15.9	7,77	7,68	14.9	6,35	6,29	19.9	8,16	8,28	13.9	10,21	10,08	17.9	5,82	5,84
16.9	8,25	8,40	15.9	6,68	6,74	13.9	7,22	7,14	16.9	7,64	7,74	16.9	7,72	7,86	15.9	6,45	6,59	20.9	8,19	8,20	14.9	10,19	10,20	18.9	5,87	5,85
17.9	8,40	8,25	16.9	6,84	6,86	14.9	7,26	7,22	17.9	7,78	7,88	17.9	7,87	7,85	16.9	6,65	6,78	21.9	8,24	8,25	15.9	10,21	10,23	19.9	5,91	6,28
20.9	8,30	8,35	19.9	6,90	6,90	17.9	7,24	7,18	18.9	7,92	7,84	18.9	7,69	7,62	17.9	6,73	6,86	22.9	8,41	8,42	18.9	10,24	10,17	20.9	6,28	6,13
21.9	8,25	8,25	20.9	6,94	7,40	18.9	7,10	7,04	19.9	8,68	8,60	19.9	7,66	7,62	18.9	6,72	6,82	23.9	8,39	8,40	19.9	10,10	9,91	21.9	6,30	6,35
22.9	8,30	8,35	21.9	7,50	7,46	19.9	7,00	6,96	20.9	8,40	8,26	22.9	7,69	7,64	21.9	6,82	6,91	26.9	7,94	7,96	20.9	9,85	9,85	24.9	6,52	6,76
23.9	8,25	8,25	22.9	7,10	7,00	20.9	6,92	6,98	23.9	8,18	8,06	23.9	7,76	7,68	22.9	6,82	6,85	27.9	8,05	8,13	21.9	9,88	9,71	25.9	6,72	6,63
24.9	8,30	8,35	23.9	6,80	6,78	21.9	7,10	7,16	24.9	8,04	7,96	24.9	7,72	7,54	28.9	6,71	6,63	28.9	8,19	8,31	22.9	9,83	9,93	26.9	6,66	6,63
27.9	8,45	8,55	26.9	6,86	6,72	24.9	7,10	7,06	25.9	7,80	7,88	25.9	7,55	7,42	29.9	6,70	6,78	29.9	8,13	8,13	25.9	9,81	9,80	27.9	6,69	6,94
28.9	8,60	8,70	27.9	6,88	6,88	25.9	7,08	7,18	26.9	7,84	7,88	26.9	7,44	7,37	30.9	6,71	6,78	30.9	7,99	8,04	26.9	9,78	9,91	28.9	7,03	6,92

29.9	8,75	8,80	28.9	7,14	7,04	26.9	7,22	7,06	27.9	7,76	7,64	29.9	7,37	7,42	1.10	6,81	6,87	3.10	8,15	8,18	27.9	9,76	9,34	1.10	6,94	6,70
30.9	8,70	8,85	29.9	7,26	7,34	27.9	7,10	7,10	30.9	7,48	7,44	30.9	7,44	7,42	2.10	6,79	6,74	4.10	8,09	8,09	28.9	9,41	9,45	2.10	6,56	6,50
1.10	8,70	8,65	30.9	7,28	7,34	28.9	7,06	7,10	1.10	7,64	7,74	1.10	7,37	7,20	5.10	6,97	7,12	5.10	8,00	8,13	29.9	9,45	9,40	3.10	6,51	6,38
4.10	8,65	8,75	3.10	7,30	7,20	1.10	7,10	7,20	2.10	7,60	7,54	2.10	7,24	7,19	6.10	7,13	7,12	6.10	8,16	8,13	2.10	9,42	9,46	4.10	6,09	5,87
5.10	8,80	8,80	4.10	7,02	6,76	2.10	7,42	7,50	3.10	7,60	7,70	8.10	7,08	7,14	7.10	7,39	7,36	7.10	8,09	8,10	3.10	9,46	9,45	5.10	5,91	5,99
6.10	8,90	8,80	5.10	6,98	6,82	3.10	7,48	7,38	4.10	7,66	7,66	9.10	7,42	7,44	8.10	7,32	7,34	10.10	8,11	8,12	4.10	9,60	9,62	8.10	6,18	6,41
7.10	8,80	8,75	6.10	6,94	6,82	4.10	7,30	7,54	7.10	7,54	7,54	10.10	7,31	7,24	9.10	7,43	7,50	11.10	8,10	8,13	5.10	9,57	9,52	9.10	6,34	6,43
8.10	8,75	8,90	7.10	6,76	6,74	5.10	7,66	7,72	8.10	7,60	7,46	13.10	7,41	7,61	12.10	7,41	7,44	12.10	8,09	8,11	6.10	9,46	9,46	10.10	6,46	6,31
11.10	9,05	9,30	10.10	6,88	7,00	8.10	7,80	7,88	9.10	7,34	7,44	14.10	7,45	7,45	12.10	7,28	7,29	13.10	7,95	7,94	9.10	9,09	9,19	11.10	6,30	6,43
12.10	9,30	9,45	11.10	7,02	7,04	9.10	7,72	7,82	10.10	7,50	7,60	15.10	7,57	7,44	14.10	7,33	7,50	14.10	7,97	8,05	10.10	9,27	9,47	12.10	6,59	6,61
13.10	9,60	9,60	12.10	7,10	7,12	10.10	7,86	7,86	11.10	7,64	7,64	16.10	7,40	7,45	15.10	7,60	7,49	17.10	8,01	8,05	11.10	9,49	9,43	15.10	6,95	7,05
14.10	9,50	9,55	13.10	7,18	7,02	11.10	8,08	8,16	21.10	7,92	8,06	17.10	7,60	7,63	16.10	7,39	7,41	18.10	8,17	8,31	12.10	9,49	9,69	16.10	7,05	7,02
15.10	9,65	9,70	14.10	7,06	7,16	12.10	8,18	8,16	22.10	8,08	8,20	20.10	7,73	7,69	19.10	7,55	7,47	19.10	8,39	8,40	13.10	9,56	9,70	17.10	7,18	7,34
18.10	9,75	9,65	17.10	7,12	7,00	15.10	8,10	8,20	23.10	8,14	8,06	21.10	7,73	7,84	20.10	7,54	7,54	20.10	8,41	8,42	16.10	9,68	9,63	18.10	7,26	7,19
19.10	9,70	9,50	18.10	7,00	7,08	16.10	8,32	8,28	24.10	8,10	7,98	22.10	7,84	7,86	21.10	7,47	7,50	21.10	8,40	8,37	17.10	9,69	9,61	19.10	7,11	7,15
20.10	9,55	9,40	19.10	7,04	6,86	17.10	8,32	8,38	25.10	7,94	7,98	23.10	8,00	8,11	22.10	7,52	7,52	24.10	8,46	8,44	18.10	9,62	9,59	22.10	7,21	7,08
21.10	9,45	9,55	20.10	6,70	6,48	18.10	8,34	8,26	30.10	8,16	8,02	24.10	8,02	7,95	23.10	7,58	7,47	25.10	8,44	8,30	19.10	9,71	9,84	23.10	6,92	6,89
22.10	9,60	9,70	21.10	6,44	6,62	19.10	8,30	8,34	31.10	7,94	7,84	27.10	7,90	7,92	26.10	7,48	7,30	26.10	8,29	8,33	20.10	9,87	9,79	24.10	6,92	6,81
25.10	9,75	9,55	24.10	6,56	6,58	22.10	8,42	8,40	1.11	7,68	7,56	30.10	7,85	7,88	27.10	7,31	7,30	27.10	8,31	8,19	23.10	9,61	9,52	25.10	6,70	6,76
26.10	9,45	9,50	25.10	6,76	6,62	23.10	8,32	8,32	4.11	7,62	7,46	31.10	8,04	8,03	30.10	7,37	7,49	28.10	0,00	8,19	24.10	9,54	9,51	26.10	6,66	6,39
27.10	9,30	9,10	26.10	6,52	6,34	30.10	8,36	8,44	5.11	7,50	7,18	3.11	7,97	7,84	2.11	8,15	8,06	31.10	8,27	8,27	25.10	9,59	9,81	30.10	6,50	6,60
1.11	9,14	9,14	27.10	6,48	6,52	31.10	8,60	8,64	6.11	7,24	7,40	4.11	7,89	7,88	3.11	7,96	7,94	1.11	8,32	8,14	26.10	9,72	9,63	31.10	6,66	6,61
2.11	9,06	9,12	31.10	6,56	6,46	1.11	8,68	8,68	7.11	7,36	7,42	5.11	7,86	7,74	4.11	8,03	8,02	2.11	8,16	8,09	27.10	9,56	9,59	1.11	6,74	6,97
3.11	9,10	9,14	1.11	6,34	6,42	2.11	8,58	8,54	8.11	7,36	7,16	6.11	7,72	7,52	5.11	7,95	7,91	3.11	8,12	7,96	30.10	9,72	9,70	2.11	6,97	7,09
4.11	9,28	9,48	2.11	6,52	6,58	5.11	8,86	8,78	11.11	7,08	6,96	7.11	7,56	7,59	6.11	7,90	7,85	4.11	7,75	7,70	31.10	9,84	10,01	5.11	7,30	7,40
5.11	9,48	9,38	3.11	6,66	6,64	6.11	8,76	8,58	12.11	6,90	6,92	10.11	7,68	7,59	9.11	7,80	7,72	7.11	7,86	7,83	1.11	10,38	10,40	6.11	7,27	7,28
8.11	9,30	9,30	4.11	6,54	6,56	7.11	8,64	8,48	13.11	7,02	7,06	11.11	7,66	7,66	10.11	7,71	7,65	8.11	7,83	7,90	2.11	10,48	10,36	7.11	7,48	7,39
9.11	9,34	9,30	10.11	6,50	6,46	8.11	8,56	8,72	14.11	7,26	7,26	12.11	7,91	8,04	11.11	7,76	7,71	9.11	7,82	7,91	3.11	10,21	9,98	8.11	7,30	7,30
10.11	9,30	9,28	11.11	6,62	6,60	9.11	8,68	8,56	15.11	7,36	7,28	13.11	8,07	8,08	12.11	7,75	7,76	10.11	7,97	7,94	6.11	10,01	10,31	9.11	7,24	7,23
11.11	9,12	8,98	14.11	6,62	6,52	12.11	8,42	8,32	18.11	7,46	7,50	14.11	8,11	8,16	13.11	7,75	7,73	11.11	7,77	7,74	7.11	10,24	10,05	12.11	7,15	7,01
12.11	8,78	8,78	15.11	6,42	6,46	13.11	8,30	8,42	19.11	7,40	7,34	17.11	8,17	8,05	16.11	7,67	7,65	14.11	7,77	7,73	8.11	9,90	9,83	13.11	7,17	7,16
22.11	8,90	8,60	16.11	6,50	6,52	14.11	8,50	8,36	20.11	7,24	7,38	18.11	8,16	8,17	17.11	7,72	7,65	15.11	7,86	7,89	9.11	9,78	9,64	14.11	7,32	7,30
23.11	8,70	8,66	17.11	6,42	6,50	15.11	8,36	8,40	21.11	7,34	7,34	19.11	8,22	8,10	18.11	7,70	7,57	16.11	7,85	7,78	10.11	9,57	9,64	15.11	7,20	7,20
24.11	8,60	8,66	18.11	6,44	6,40	16.11	8,38	8,28	22.11	7,40	7,40	20.11	8,17	8,25	19.11	7,62	7,51	17.11	7,85	7,78	13.11	9,64	9,79	16.11	7,25	7,36
25.11	8,50	8,52	21.11	6,24	6,22	19.11	8,12	8,14	25.11	7,56	7,48	21.11	8,43	8,48	20.11	7,56	7,48	18.11	7,73	7,88	14.11	9,85	9,90	19.11	7,41	7,49
26.11	8,34	8,36	22.11	6,14	5,96	20.11	8,08	8,02	26.11	7,44	7,36	24.11	8,36	8,44	23.11	7,45	7,37	21.11	7,82	7,82	15.11	9,89	9,63	20.11	7,36	7,29
29.11	8,10	8,04	23.11	5,86	5,86	21.11	8,00	7,90	27.11	7,32	7,26	25.11	8,37	8,42	24.11	7,34	7,08	22.11	7,96	7,97	16.11	9,82	9,60	21.11	7,36	7,32
30.11	8,22	8,50	24.11	5,92	5,74	22.11	7,94	7,86	28.11	7,30	7,30	26.11	8,45	8,54	25.11	7,16	7,09	23.11	7,89	7,79	17.11	9,55	9,56	22.11	7,30	7,32
1.12	8,40	8,40	25.11	5,74	5,96	23.11	7,96	8,04	29.11	7,32	7,40	27.11	8,56	8,62	26.11	7,06	6,87	24.11	7,78	7,64	20.11	9,51	9,09	23.11	7,30	7,42

2.12	8,54	8,52	28.11	6,12	6,14	26.11	8,16	8,16	2.12	7,40	7,22	28.11	8,77	8,99	27.11	7,02	6,90	25.11	7,62	7,67	21.11	9,05	9,06	26.11	7,61	7,58	
3.12	8,60	8,52	29.11	6,16	6,16	27.11	8,26	8,22	3.12	7,12	7,06	1.12	9,04	9,00	30.11	6,96	6,93	28.11	7,79	7,76	22.11	9,16	9,29	27.11	7,51	7,46	
6.12	8,48	8,56	30.11	6,26	6,46	28.11	8,34	8,30	4.12	7,04	7,08	2.12	8,79	8,62	1.12	7,03	7,13	29.11	7,71	7,65	23.11	9,32	8,99	28.11	7,52	7,47	
7.12	8,68	8,74	1.12	6,48	6,30	29.11	8,44	8,44	5.12	7,04	6,94	3.12	8,70	8,60	2.12	7,23	7,10	30.11	7,65	7,55	24.11	8,96	8,87	29.11	7,56	7,54	
8.12	8,86	8,86	2.12	6,42	6,58	30.11	8,32	8,38	6.12	6,96	7,12	4.12	8,72	8,82	3.12	7,15	7,00	1.12	7,48	7,46	27.11	8,98	8,90	3.12	7,73	7,57	
9.12	8,64	8,44	5.12	6,62	6,64	3.12	8,42	8,50	9.12	7,10	7,08	5.12	8,88	8,73	4.12	6,91	6,89	2.12	7,43	7,43	28.11	8,96	8,75	4.12	7,53	7,33	
10.12	8,40	8,32	6.12	6,56	6,44	4.12	8,62	8,70	10.12	7,08	7,08	8.12	8,69	8,71	7.12	6,89	6,91	5.12	7,40	7,37	29.11	8,79	8,91	5.12	6,91	7	
13.12	8,46	8,52	7.12	6,54	6,60	5.12	8,76	8,74	11.12	7,14	7,02	9.12	8,72	8,51	8.12	6,92	6,81	6.12	7,48	7,58	30.11	8,90	8,99	6.12	6,68	6,65	
14.12	8,54	8,48	8.12	6,58	6,26	6.12	8,74	8,70	12.12	7,00	6,96	10.12	8,60	8,57	9.12	6,92	7,01	7.12	7,64	7,69	1.12	8,86	8,82	7.12	6,76	6,89	
15.12	8,26	8,22	9.12	6,34	6,38	7.12	8,66	8,72	13.12	7,02	7,04	11.12	8,74	8,58	10.12	6,96	6,80	8.12	7,73	7,64	4.12	8,92	8,99	10.12	6,74	6,75	
16.12	8,22	8,04	12.12	6,28	6,20	10.12	8,72	8,78	16.12	7,12	7,14	12.12	8,30	8,27	11.12	6,55	6,48	9.12	7,64	7,58	5.12	9,02	9,08	11.12	6,74	6,7	
17.12	8,22	8,00	13.12	6,22	6,18	11.12	8,84	8,78	17.12	7,02	6,84	15.12	8,25	8,27	14.12	6,59	6,45	12.12	7,48	7,63	6.12	9,00	8,89	12.12	6,64	6,44	
20.12	7,80	8,04	14.12	6,14	6,14	12.12	8,80	8,94	18.12	6,70	6,92	16.12	8,00	7,81	15.12	6,67	6,72	13.12	7,73	7,81	7.12	8,89	8,92	13.12	6,5	6,42	
21.12	8,18	8,26	15.12	6,10	6,24	13.12	8,98	8,84	19.12	6,90	6,82	17.12	7,85	8,07	16.12	6,80	6,85	14.12	7,79	7,88	8.12	8,96	9,14	14.12	6,33	6,35	
22.12	8,40	8,38	16.12	6,22	6,24	14.12	8,90	8,70	20.12	6,90	7,10	18.12	8,27	8,48	17.12	6,91	6,90	15.12	7,87	7,96	11.12	9,31	9,35	17.12	6,46	6,41	
23.12	8,40	8,56	19.12	6,24	6,06	17.12	8,74	8,80	23.12	6,98	6,84	19.12	8,41	8,49	18.12	6,86	6,77	16.12	7,91	7,85	12.12	9,32	9,35	18.12	6,49	6,66	
24.12	8,56	8,56	20.12	6,12	6,22	18.12	8,90	8,84	24.12	6,94	6,96	22.12	8,67	8,80	21.12	6,91	6,88	19.12	7,87	7,79	13.12	9,35	9,29	19.12	6,6	6,81	
27.12	8,52	8,66	21.12	6,10	6,14	19.12	8,86	8,76	25.12	6,88	6,66	23.12	8,69	8,66	22.12	6,82	6,87	20.12	7,83	7,85	14.12	9,38	9,46	20.12	6,74	6,78	
28.12	8,78	8,72	22.12	6,16	6,10	20.12	8,82	8,70	26.12	6,50	6,30	24.12	8,65	8,63	23.12	6,98	7,05	21.12	7,85	7,81	15.12	9,37	9,35	21.12	6,78	6,88	
29.12	8,74	8,76	23.12	6,18	6,08	21.12	8,66	8,68	27.12	6,02	6,12	25.12	8,65	8,63	24.12	7,06	7,12	22.12	7,82	7,78	18.12	9,40	9,44	24.12	6,89	6,81	
30.12	8,76	8,82	26.12	6,14	6,14	24.12	8,76	8,76	30.12	6,24	6,54	26.12	8,65	8,63	25.12	7,14	7,14	23.12	7,76	7,72	19.12	9,46	9,37	25.12	6,72	6,74	
31.12	8,90	8,58	27.12	6,16	6,16	25.12	8,82	8,78	31.12	6,52	6,70	29.12	8,58	8,55	28.12	7,16	7,11	26.12	7,73	7,73	20.12	9,35	9,37	26.12	6,74	6,8	
			28.12	6,16	6,06	26.12	8,84	8,84				30.12	8,60	8,52	29.12	7,11	7,08	27.12	7,67	7,67	21.12	9,44	9,40	27.12	6,87	6,83	
			29.12	6,04	6,14	27.12	8,92	8,84				31.12	8,56	8,66	30.12	7,03	6,93	28.12	7,78	7,79	22.12	9,43	9,35	28.12	6,88	6,84	
			30.12	6,14	6,02	28.12	8,84	8,88							31.12	6,84	6,70	29.12	7,77	7,77	25.12	9,38	9,39	31.12	6,85	6,86	
						31.12	8,84	8,80										30.12	7,78	7,82	26.12	9,41	9,41				
																						27.12	9,42	9,40			
																						28.12	9,50	9,73			
																						29.12	9,81	9,85			

Ek 3. Modellerin Tahminleme Doğruluk Ölçüleri

	ÇKA					DVM				UKVH			
	Ölçüt		Açılış		Kapanış		Açılış		Kapanış		Açılış		Kapanış
AKBNK	RMSE	Lag2	0,27463	Lag2	0,17431	Lag3	0,31276	Lag2	0,24007	Lag2	0,28089	Lag2	0,17424
	MSE		0,07542		0,03038		0,09782		0,05763		0,07890		0,03036
	R-square		0,96449		0,98588		0,98738		0,99267		0,96291		0,98589
AKSA	RMSE	Lag5	0,90378	Lag3	0,28569	Lag2	1,69791	Lag2	1,61261	Lag6	0,86830	Lag4	0,28526
	MSE		0,81682		0,08162		2,88291		2,60050		0,75394		0,08137
	R-square		0,83902		0,98269		0,79320		0,77006		0,83863		0,98277
ALARK	RMSE	Lag1	0,46026	Lag6	0,16701	Lag2	0,74782	Lag2	0,58869	Lag2	0,41068	Lag6	0,16709
	MSE		0,21184		0,02789		0,55923		0,34655		0,16866		0,02792
	R-square		0,92431		0,99002		0,92489		0,95663		0,93770		0,99001
AEFES	RMSE	Lag3	0,58495	Lag1	0,42600	Lag2	0,59701	Lag1	0,43512	Lag3	0,53085	Lag5	0,42310
	MSE		0,34216		0,18148		0,35642		0,18933		0,28181		0,17902
	R-square		0,94304		0,97033		0,98330		0,99181		0,95248		0,97061
ARCLK	RMSE	Lag1	0,75585	Lag5	0,42596	Lag2	1,60018	Lag1	1,26149	Lag2	0,62609	Lag6	0,33090
	MSE		0,57131		0,18144		2,56058		1,59135		0,39199		0,10949
	R-square		0,96799		0,97034		0,95080		0,97203		0,97796		0,99389
ASELS	RMSE	Lag2	1,59523	Lag1	0,98026	Lag3	7,17062	Lag4	6,49366	Lag5	1,60745	Lag2	0,97990
	MSE		2,54475		0,96091		51,41780		42,16761		2,58390		0,96021
	R-square		0,90443		0,96212		0,10905		0,30025		0,90181		0,96209
BIMAS	RMSE	Lag1	1,61346	Lag2	1,09490	Lag3	1,59721	Lag1	1,36570	Lag3	1,49377	Lag5	1,09323
	MSE		2,60325		1,19881		2,55107		1,86513		2,23134		1,19516
	R-square		0,95155		0,97731		0,98760		0,99030		0,95784		0,97740
DOHOL	RMSE	Lag1	0,04382	Lag4	0,03157	Lag2	0,04856	Lag2	0,03839	Lag4	0,04499	Lag6	0,03150
	MSE		0,00192		0,00100		0,00236		0,00147		0,00202		0,00099
	R-square		0,93516		0,96638		0,97915		0,98668		0,93074		0,96670
DOAS	RMSE	Lag3	0,43450	Lag3	0,13622	Lag3	0,44497	Lag2	0,36828	Lag2	0,34798	Lag4	0,13633
	MSE		0,18879		0,01856		0,19800		0,13563		0,12109		0,01859
	R-square		0,92594		0,99276		0,97615		0,98372		0,95221		0,99275
ECZYT	RMSE	Lag3	0,18222	Lag5	0,08816	Lag2	0,34586	Lag2	0,33619	Lag6	0,16916	Lag2	0,08814
	MSE		0,03321		0,00777		0,11962		0,11302		0,02862		0,00777

ENKAI	R-square	Lag4	0,90289	Lag1	0,97565	Lag6	0,88959	Lag1	0,86961	Lag5	0,90958	Lag4	0,97563
	RMSE		0,11063		0,08353		0,12070		0,09202		0,09761		0,08344
	MSE		0,01224		0,00698		0,01457		0,00847		0,00953		0,00696
	R-square		0,94476		0,96922		0,98224		0,99013		0,95711		0,96927
ERGLI	RMSE	Lag5	0,62450	Lag6	0,21762	Lag1	2,97532	Lag1	2,86993	Lag1	0,62420	Lag4	0,21824
	MSE		0,39000		0,04736		8,85253		8,23647		0,38962		0,04763
	R-square		0,88302		0,98536		-0,34481		-0,27215		0,88258		0,98529
FENER	RMSE	Lag2	2,10802	Lag1	0,86059	Lag1	5,20650	Lag1	8,23015	Lag4	1,88869	Lag5	0,85964
	MSE		4,44374		0,74062		27,10768		67,73531		3,56716		0,73899
	R-square		0,95265		0,99186		0,90069		0,73611		0,96165		0,99188
FROTO	RMSE	Lag5	3,52338	Lag3	1,25739	Lag2	9,87562	Lag1	13,40055	Lag4	3,42740	Lag4	1,25897
	MSE		12,41422		1,58104		97,52794		179,57475		11,74708		1,58500
	R-square		0,85115		0,97974		0,60282		-0,04225		0,85565		0,97966
GSRAY	RMSE	Lag2	13,88379	Lag4	1,10785	Lag2	32,44558	Lag2	26,65017	Lag5	9,86357	Lag1	1,10774
	MSE		192,75972		1,22732		1052,71533		710,23163		97,28993		1,22710
	R-square		-0,02478		0,98478		-1,95721		-2,60928		-0,13029		0,98478
GARAN	RMSE	Lag1	0,29616	Lag3	0,20367	Lag3	0,07923	Lag2	0,31701	Lag3	0,29623	Lag3	0,20241
	MSE		0,08771		0,04148		0,00628		0,10049		0,08775		0,04097
	R-square		0,96250		0,98246		0,75958		0,98786		0,96252		0,98271
GSDHO	RMSE	Lag5	0,08387	Lag4	0,01751	Lag4	0,07923	Lag5	0,04821	Lag6	0,06394	Lag4	0,01749
	MSE		0,00703		0,00031		0,00628		0,00232		0,00409		0,00031
	R-square		0,34252		0,96321		0,75958		0,91500		0,48164		0,96331
GUBRF	RMSE	Lag3	0,89998	Lag4	0,07696	Lag3	1,12782	Lag6	0,80037	Lag5	0,65931	Lag6	0,07664
	MSE		0,80997		0,00592		1,27198		0,64060		0,43470		0,00587
	R-square		0,19014		0,99032		0,43540		0,52902		0,30812		0,99042
HALKB	RMSE	Lag1	0,59764	Lag5	0,24096	Lag2	1,13610	Lag2	1,07685	Lag2	0,52225	Lag5	0,24129
	MSE		0,35717		0,05806		1,29072		1,15960		0,27274		0,05822
	R-square		0,94718		0,99152		0,93686		0,94471		0,95945		0,99150
ISCTR	RMSE	Lag5	0,20884	Lag4	0,12609	Lag6	0,29297	Lag4	0,23080	Lag5	0,19783	Lag3	0,12607
	MSE		0,04361		0,01590		0,08583		0,05327		0,03914		0,01589
	R-square		0,97279		0,99012		0,98455		0,99082		0,97563		0,99013
ISGSY	RMSE	Lag2	0,05672	Lag4	0,01755	Lag6	0,09196	Lag5	0,15950	Lag4	0,04993	Lag2	0,01753
	MSE		0,00322		0,00031		0,00846		0,02544		0,00249		0,00031
	R-square		0,93389		0,99372		0,93975		0,77494		0,94814		0,99374
KRDMD	RMSE	Lag1	0,25388	Lag1	0,10073	Lag1	0,98249	Lag1	0,95262	Lag5	0,25203	Lag1	0,10046

KARSN	MSE	Lag4	0,06445	Lag3	0,01015	Lag2	0,96529	Lag2	0,90749	Lag3	0,06352	Lag1	0,01009
	R-square		0,94765		0,99163		0,63021		0,64835		0,94828		0,99168
	RMSE		0,04874		0,05036		0,05813		0,05794		0,04889		0,05014
KCHOL	MSE	Lag4	0,00238	Lag6	0,00254	Lag2	0,00338	Lag1	0,00336	Lag4	0,00239	Lag1	0,00251
	R-square		0,97820		0,97631		0,99180		0,99163		0,97808		0,97637
	RMSE		0,71500		0,27121		1,51273		1,49492		0,67628		0,27044
KOZAA	MSE	Lag2	0,51122	Lag2	0,07355	Lag3	2,28835	Lag3	2,23479	Lag3	0,45736	Lag4	0,07314
	R-square		0,77940		0,96498		0,65723		0,60659		0,79324		0,96505
	RMSE		0,38706		0,22504		0,82797		0,80473		0,39341		0,22452
METRO	MSE	Lag1	0,14982	Lag6	0,05064	Lag3	0,68554	Lag3	0,64759	Lag6	0,15477	Lag3	0,05041
	R-square		0,94926		0,98257		0,92782		0,92776		0,94722		0,98266
	RMSE		0,04854		0,02837		0,04489		0,03158		0,04550		0,02826
MGROS	MSE	Lag3	0,00236	Lag2	0,00080	Lag6	0,00201	Lag3	0,00100	Lag2	0,00207	Lag3	0,00080
	R-square		0,89042		0,96265		0,97626		0,98840		0,90079		0,96317
	RMSE		0,93954		0,46614		1,05315		0,76614		0,83635		0,46568
NETAS	MSE	Lag1	0,88274	Lag6	0,21728	Lag1	1,10911	Lag5	0,58697	Lag6	0,69948	Lag2	0,21686
	R-square		0,96079		0,99056		0,98650		0,99345		0,96878		0,99059
	RMSE		7,77737		0,32402		7,69263		7,77190		5,77036		0,32366
PETKM	MSE	Lag5	60,48748	Lag1	0,10499	Lag2	59,17651	Lag1	60,40237	Lag5	33,29710	Lag1	0,10476
	R-square		-0,62799		0,98871		0,49865		-2,62104		-2,40533		0,98869
	RMSE		0,20671		0,13671		0,26157		0,22806		0,20697		0,13715
SAHOL	MSE	Lag1	0,04273	Lag3	0,01869	Lag3	0,06842	Lag3	0,05201	Lag5	0,04284	Lag5	0,01881
	R-square		0,96706		0,98528		0,98591		0,98843		0,96700		0,98520
	RMSE		0,25282		0,15625		0,24520		0,17673		0,24244		0,15542
SISE	MSE	Lag2	0,06392	Lag6	0,02441	Lag2	0,06012	Lag4	0,03123	Lag4	0,05877	Lag5	0,02415
	R-square		0,96535		0,98679		0,99148		0,99571		0,96821		0,98691
	RMSE		0,26250		0,20919		0,62501		0,42362		0,26001		0,21045
TSGYO	MSE	Lag1	0,06891	Lag2	0,04376	Lag1	0,39064	Lag1	0,17946	Lag5	0,06761	Lag4	0,04429
	R-square		0,74140		0,82766		0,28107		0,65576		0,74117		0,82445
	RMSE		0,10308		0,02545		0,29031		0,20924		0,08905		0,02544
TAVHL	MSE	Lag3	0,01063	Lag5	0,00065	Lag4	0,08428	Lag2	0,04378	Lag5	0,00793	Lag4	0,00065
	R-square		0,88816		0,99308		0,65187		0,82113		0,91191		0,99310
	RMSE		1,19369		0,59178		2,01652		2,02184		1,16661		0,59295
	MSE	Lag3	1,42489	Lag5	0,35021	Lag4	4,06635	Lag2	4,08782	Lag5	1,36098	Lag4	0,35159
	R-square		0,91663		0,97905		0,92029		0,91248		0,91913		0,97895

TKFEN	RMSE	Lag6	0,94140	Lag1	0,40458	Lag1	7,82695	Lag1	7,46973	Lag4	0,95855	Lag3	0,40448
	MSE		0,88623		0,16369		61,26110		55,79687		0,91881		0,16360
	R-square		0,95289		0,99122		-1,23969		-0,99053		0,95064		0,99123
TOASO	RMSE	Lag2	1,81918	Lag5	0,47735	Lag2	3,08997	Lag3	3,11582	Lag6	1,72115	Lag4	0,47403
	MSE		3,30940		0,22786		9,54790		9,70834		2,96236		0,22471
	R-square		0,85766		0,98974		0,87800		0,83419		0,86375		0,98982
TRKCM	RMSE	Lag1	0,15569	Lag2	0,09227	Lag1	0,55595	Lag2	0,46875	Lag6	0,14212	Lag1	0,09229
	MSE		0,02424		0,00851		0,30908		0,21972		0,02020		0,00852
	R-square		0,92784		0,97408		0,63393		0,73563		0,93835		0,97408
TUPRS	RMSE	Lag4	5,92613	Lag4	2,45314	Lag1	23,51079	Lag1	23,22553	Lag4	6,53149	Lag6	2,44413
	MSE		35,11898		6,01791		552,75745		539,42505		42,66032		5,97379
	R-square		0,81766		0,96634		-0,21035		-0,32792		0,78397		0,96633
THYAO	RMSE	Lag1	0,95290	Lag1	0,70796	Lag1	4,15745	Lag1	4,10337	Lag3	0,91524	Lag1	0,70845
	MSE		0,90802		0,50120		17,28437		16,83765		0,83766		0,50190
	R-square		0,95217		0,97318		0,58631		0,58923		0,95554		0,97314
TTKOM	RMSE	Lag3	0,23473	Lag1	0,11734	Lag1	0,47836	Lag1	0,46584	Lag1	0,23717	Lag3	0,11733
	MSE		0,05510		0,01377		0,22883		0,21700		0,05625		0,01377
	R-square		0,95904		0,98985		0,94111		0,94517		0,95795		0,98985
TCELL	RMSE	Lag1	0,29766	Lag2	0,26035	Lag2	0,44667	Lag1	0,43790	Lag5	0,29662	Lag5	0,26003
	MSE		0,08860		0,06778		0,19951		0,19175		0,08798		0,06761
	R-square		0,95939		0,96857		0,97382		0,97397		0,95945		0,96858
VAKBN	RMSE	Lag4	0,22085	Lag4	0,12277	Lag4	0,29220	Lag4	0,25462	Lag2	0,22263	Lag3	0,12226
	MSE		0,04878		0,01507		0,08538		0,06483		0,04956		0,01495
	R-square		0,96996		0,99076		0,98495		0,98893		0,96948		0,99085
YKBNK	RMSE	Lag1	0,22209	Lag1	0,09537	Lag1	0,42522	Lag1	0,41442	Lag6	0,22301	Lag3	0,09540
	MSE		0,04932		0,00910		0,18081		0,17175		0,04973		0,00910
	R-square		0,96465		0,99353		0,95679		0,95862		0,96453		0,99353


Ek 4. Modellerin Ürettiği Grafikler

ÇKA Modelinin Ürettiği Hisse Senedi Açılış Fiyatı Tahminleri


Grafik 1. Koç Holding A.Ş.




Grafik 2. Netaş Telekomünikasyon A.Ş.




Grafik 3. Gübre Fabrikaları T.A.Ş.




Grafik 4. Türkiye Halk Bankası A.Ş.



Grafik 5. Galatasaray Sportif A.Ş.




Grafik 6. Turkcell İletişim A.Ş.




ÇKA Modelinin Ürettiği Hisse Senedi Kapanış Fiyatı Tahminleri


Grafik 7. Gübre Fabrikaları T.A.Ş.




Grafik 8. Türkiye İş Bankası




Grafik 9. Akbank T.A.Ş




Grafik 10. TSKB Gayrimenkul A.Ş.



Grafik 11. Anadolu Efes Biracılık A.Ş.




Grafik 12. Trakya Cam Sanayii A.Ş.




DVM Modelinin Ürettiği Hisse Senedi Açılış Fiyatı Tahminleri


Grafik 13. Sabancı Holding A.Ş.




Grafik 14. Doğuş Otomotiv A.Ş.




Grafik 15. Karsan Otomotiv A.Ş.




Grafik 16. Anadolu Efes Biracılık A.Ş.



Grafik 17. Doğan Holding A.Ş.




Grafik 18. Metro Holding A.Ş.




DVM Modelinin Ürettiği Hisse Senedi Kapanış Fiyatı Tahminleri


Grafik 19. Anadolu Efes Biracılık A.Ş.




Grafik 20. Sabancı Holding A.Ş.




Grafik 21. Doğuş Otomotiv A.Ş.




Grafik 22. Karsan Otomotiv A.Ş.



Grafik 23. Doğan Holding A.Ş.



Grafik 24. Metro Holding A.Ş.




UKVH Modelinin Ürettiği Hisse Senedi Açılış Fiyatı Tahminleri


Grafik 25. Petkim Holding A.Ş.




Grafik 26. Koç Holding A.Ş.



Grafik 27. Bim Mağazalar A.Ş.




Grafik 28. Türkiye Vakıflar Bankası



Grafik 29. Türkiye Petrol Rafineleri A.Ş




Grafik 30. Akbank T.A.Ş.




UKVH Modelinin Ürettiği Hisse Senedi Kapanış Fiyatı Tahminleri


Grafik 31. Eczacıbaşı Holding A.Ş.




Grafik 32. Türkiye Garanti Bankası A.Ş.




Grafik 33. Migros Ticaret A.Ş.



Grafik 34. Aselsan San. ve Tic. A.Ş.



Grafik 35. Türkiye İş Bankası A.Ş.



Grafik 36. Koza İşletmeleri A.Ş.

