



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**FİNANSAL ORANLI YAPAY SİNİR AĞI
MODELİ İLE HİSSE DEĞERİ DEĞİŞİMİ
TAHMİNİ**

Mustafa TANYER

YÜKSEK LİSANS TEZİ

Endüstri Mühendisliği Anabilim Dalı

Ağustos-2019

**KONYA
Her Hakkı Saklıdır**

TEZ KABUL VE ONAYI

Mustafa TANYER tarafından hazırlanan “FİNANSAL ORANLI YAPAY SİNİR AĞI MODELİ İLE HİSSE DEĞERİ DEĞİŞİMİ TAHMİNİ” adlı tez çalışması 26/08/2019 tarihinde aşağıdaki juri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Juri Üyeleri

Danışman

Doç. Dr. Ahmet SARUCAN

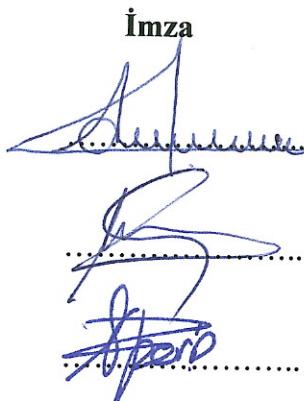
Üye

Doç. Dr. Hakan ÇERÇİOĞLU

Üye

Dr. Öğr. Üyesi Alper DÖYEN

İmza



Yukarıdaki sonucu onaylarım.

Prof. Dr. Hakan KARABÖRK
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağın eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all materials and results that are not original to this work.



Mustafa TANYER

ÖZET

YÜKSEK LİSANS TEZİ

FİNANSAL ORANLI YAPAY SİNİR AĞI MODELİ İLE HİSSE DEĞERİ DEĞİŞİMİ TAHMİNİ

Mustafa TANYER

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Ahmet SARUCAN

2019, 68 Sayfa

Jüri

Doç. Dr. Ahmet SARUCAN
Doç Dr. Hakan ÇERÇİOĞLU
Dr. Öğr. Üyesi Alper DÖYEN

Hisse senedi değerinin tahmin edilmesi, ekonomi piyasalarının barındırdığı belirsizlik, kaotik yapı ve gürültü nedeniyle oldukça güçtür. Ayrıca hisse senedi değerleri üzerindeki siyasi gelişmeler, ekonomik kırılganlıklar, küresel etkiler, teknolojik gelişmeler ve yatırımcı tercihleri gibi birçok faktörün etkisi de, değer tahminlerini oldukça zorlaştırmaktadır. Ancak bu alanda iyi bir tahmin modeli geliştirmenin zorlukları sebebiyle okuyucu doğası, başarılı bir modelin maddi getiriye somut katkısı gibi nedenler problemi araştırmacılar için bir o kadar da çekici kılmaktadır. Çok kaynaktan veri akışı olan borsa gibi kaotik ortamlarda geleceğe dönük tahminler üretmede makine öğrenme algoritmalarının başarılı oldukları bilinmektedir. Bu çalışmada ise Borsa İstanbul'da işlem gören farklı kriterlere göre seçilmiş üç hisse senedinin değer tahmini geliştirilen Yapay Sinir Ağrı modeli ile Destek Vektör Makineleri, Lojistik Regresyon, Rasgele Orman ve Naive Bayes Sınıflandırıcı makine öğrenmesi algoritmaları kullanılarak ele alınmış ve performansları kıyaslanmıştır. Şirket performanslarını değerlendirmede sıklıkla kullanılan 18 finansal oran ve 102 diğer bağımsız değişken girdi olarak kullanılarak 2009-2018 dönemi aylık hisse senedi getiri oranları sınıflandırılarak tahmin edilmiştir. Yapılan analizler önerilen yapay sinir ağrı algoritmasının belirlenen değişkenlerle ve dönemde diğer algoritmalarla alternatif olarak kullanılabilecek bir sınıflandırıcı olduğunu göstermiştir.

Anahtar kelimeler: Destek vektör makineleri, hisse senedi değer tahmini, lojistik regresyon, naive bayes sınıflandırıcı, rastgele orman algoritması, yapay sinir ağları

ABSTRACT

MS THESIS

STOCK PRICE FORECASTING WITH A FINANCIAL RATIO BASED NEURAL NETWORK ALGORITHM

Mustafa TANYER

**Konya Technical University
Institute of Graduate Studies
Department of Industrial Engineering**

Advisor: Assoc. Prof. Dr. Ahmet SARUCAN

2019, 68 Pages

Jury

**Assoc. Prof. Dr. Ahmet SARUCAN
Assoc. Prof. Dr. Hakan ÇERÇİOĞLU
Asst. Prof. Dr. Alper DÖYEN**

Forecasting stock prices is quite difficult due to uncertainty, chaotic nature and noise in financial markets. The aggregated impact of factors such as political instabilities, financial fragility, international financial integrity, technological developments and change in investor risk preferences make the estimation of stock prices harder. However, the challenge of developing a good estimation model in such an environment, the positive contribution of a successful model to the return of investment make the problem attractive for researchers. It is known that machine learning algorithms are useful in generating predictions in such chaotic environments as stock market, which have multiple sources of data flow. In this study, three stocks traded in Borsa İstanbul are selected according to different criteria and price estimation performances of proposed Artificial Neural Network model together with known Support Vector Machines, Logistic Regression, Random Forest and Naive Bayes Classifier machine learning algorithms are compared. 18 financial ratios frequently used in evaluation of company performances with 102 other independent variables are used as inputs and monthly rate of return of stocks in 2009-2018 period are classified and estimated. Analyses on given period have shown that the proposed artificial neural network algorithm is a classifier that can be used as an alternative to other algorithms for stock market forecasting.

Keywords: Artificial neural networks, logistics regression, naive bayes classifier, random forest, stock price forecasting, support vector machines

ÖNSÖZ

Bu çalışmayı yapmama fırsat veren, tez çalışmalarımı yönlendiren, bana araştırmalarımda bilgi ve tecrübeleri ile yol gösteren, her zaman destekleyen, karşılaştığım sorunların çözülmesinde yardımcılarını esirgemeyen saygıdeğer hocam Sayın Doç. Dr. Ahmet SARUCAN'a teşekkürlerimi sunmayı bir borç bilirim.

**Mustafa TANYER
KONYA-2019**

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
KISALTMALAR	ix
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
2.1. Yapay Sinir Ağları (YSA) Modelleri.....	4
2.2. Borsa Tahmin Modelleri ve Yapay Sinir Ağlarının Borsa Tahminlerinde Kullanımı	5
2.3. Finansal Oran Değişkenlerinin Belirlenmesi	8
3. MATERİYAL VE YÖNTEM.....	10
3.1. Karşılaştırmada Kullanılan Algoritmalar.....	10
3.1.1. Lojistik Regresyon Algoritması (LR)	10
3.1.2. Destek Vektör Makineleri (DVM).....	10
3.1.3. Naive Bayes Sınıflandırıcı Algoritması (NBS)	12
3.1.4. Rastgele Orman (RO) Algoritması	13
3.1.5. Önerilen YSA Algoritması	14
3.2. Çalışma Verilerinin Belirlenmesi	18
3.3. Veri Kaynakları.....	19
3.4. Çalışma Konusu Hisselerin Belirlenmesi	19
3.5. Değişken Olarak Kullanılan Finansal Oranlar	20
3.5.1. Likidite Oranları	21
3.5.2. Faaliyet Oranları	21
3.5.3. Finansal Yapı Oranları.....	22
3.5.4. Karlılık (Rantabilite) Oranları	22
3.5.5. Hisse Bazlı Oranlar	23
3.6. Algoritmada Kullanılan Diğer Değişkenler	24
3.7. Kayıp Verilerin Tamamlanması (Imputation)	24
3.8. Verilerin Normalleştirilmesi	25
3.9. Verilerin Uygulamaya Hazırlanması	26
3.10. Çapraz Doğrulama (k- Fold Cross Validation).....	27
3.11. Değerlendirme Kriterleri.....	28
3.12. Kullanılan Yazılımlar ve Çözüm Ortamı	30
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	31
4.1. GARAN Sonuçlar	33
4.2. PETKM Sonuçlar.....	36

4.3. THYAO Sonuçlar	39
4.4. Genel Sonuçlar.....	43
5. SONUÇLAR VE ÖNERİLER	44
KAYNAKLAR	45
EKLER	50
ÖZGEÇMİŞ	59

KISALTMALAR

- BHO: Basit Hareketli Ortalama (Simple Moving Average)
BIST: Borsa İstanbul
BÜD: Basit üstel düzgünleştirme (Simple Exponential Smoothing)
CNY: Çin Yuanı
ÇKA: Çok katmanlı algılayıcı (Multilayer Perceptron)
DOW 30: Dow Jones NYSE'de işlem gören en büyük 30 firma endeksi
DVM: Destek Vektör Makineleri (Support Vector Machines)
EUR: Avro
EVDS: Elektronik Veri Dağıtım Sistemi
FTSE 100: Londra Borsası Endeksi
GARAN: Garanti Bankası A.Ş. A Grubu Payı
LR: Lojistik Regresyon
NASDAQ 100: NASDAQ e-borsası endeksi
NBS: Naive Bayes Sınıflandırıcı
NYSE: New York Borsası Birleşik Endeksi (NYSE Composite)
PETKM: Petkim Petrokimya Holding A.Ş. A Grubu Payı
RO: Rastgele Orman (Random Forest)
SP 500: Standard & Poor 500 firma endeksi
SPK: Sermaye Piyasası Kurulu
TCMB: Türkiye Cumhuriyet Merkez Bankası
THYAO: Türk Hava Yolları Anonim Ortaklıği A Grubu Payı
TRY: Türk Lirası
USD: Amerikan Doları
YSA: Yapay Sinir Ağları (Artificial Neural Networks)

1. GİRİŞ

Borsa, çeşitli finansal yatırım ürünlerini kapsayan, birçok ürünü ortak olan piyasalar olarak tanımlanabilir. Birbirinden farklı borsalarda bono, tahvil, hisse senedi, döviz, emtia, yatırım fonları gibi çeşitli menkul kıymetlerin ticareti gerçekleşmekte ve bu ürünler alınıp satılmaktadır. Bu çalışmanın konusu hisse senedi alınıp satılan borsalar ve piyasalarıdır.

Hisse senedi piyasaları, 2009 yılından bu yana %320 büyüyerek 80 trilyon dolarlık bir büyüklüğe ulaşmıştır (Edwards, 2017). Ancak bu büyümeyenin beraberinde kendisine duyulan ilginin artmasına rağmen, hisse senedi fiyatlarındaki eğilimleri tahmin etmek ekonomideki değişimlerin değerleri, yatırımcıların belirli bir şirkete karşı hissiyatları, politik olaylar vb. gibi belirli bir dönemde piyasa değerini etkileyen birçok belirsizlik olması nedeniyle zorlu iştır. Borsalar rasgele dalgalanmaların neden olan hızlı değişikliklere en açık ekonomik kanallardan birisidir.

Borsa zaman serileri genel olarak dinamik, parametrik olmayan, kaotik ve gürültülüdür ve bu nedenle borsa fiyat hareketlerinin kısa süreli pencerelerde daha belirgin olarak görülen dalgalanmalarla rastgele bir süreç olduğunu düşünenler bulunmaktadır (Khaidem ve ark., 2016). Bununla birlikte, bazı hisse senetleri genellikle uzun vadeli zaman pencereleri üzerinde doğrusal eğilimler geliştirme eğilimindedir. Hisse davranışının kaotik ve yüksek düzeyde değişken olması nedeniyle, hisse senedi piyasasına yapılan yatırımlar büyük risk taşımaktadır. İlgili riski en aza indirmek için, gelecekte hisse senedi fiyatı hareketi konusunda ileri düzeyde bilgi gerekmektedir. Yatırımcıların, gelecekte değerlerinin artması beklenen bir hisse alması daha muhtemeldir. Öte yandan, trader'ların gelecekte değeri düşmesi beklenen bir hisse senedi almaktan kaçınmaları muhtemeldir. Dolayısıyla, sermaye kazancını en üst seviyeye çıkarmak ve zararı en aza indirmek için borsa fiyatlarındaki eğilimleri doğru bir şekilde tahmin etmeye ihtiyaç vardır.

Hisse senedi fiyat tahmini modelleri; tahmin teorilerindeki gelişmeler, bilgisayarların daha karmaşık işlemler yapabilir hale gelmesi ve bunların da etkisiyle uzun süreli kazanç beklentisinin kısa süreli dönüşmesiyle hisse bulundurma sürelerinin kısalması sonucunda önemini artırmıştır (Anonim, 2012). Günümüzde, hisse senedi piyasalarındaki toplam hacmin %90'ının teknik analiz kullananlarca oluşturulduğu, bu hacmin büyük kısmının ise bilgisayar tabanlı algoritmalarla geliştirilen tahmin modelleri yardımıyla yapıldığı düşünülmektedir (Cheng, 2017).

Dolayısıyla, tahmin modelinin kalitesi ile hisse senedi piyasasındaki kazanç doğrudan ilişkili olmaktadır. Hisse senedi fiyat davranışını tahmin etmek için kullanılan başlıca metodolojiler arasında, aşağıdakiler özellikle dikkat çekicidir: (1) Teknik Analiz, (2) Zaman Serileri Tahmini (3) Makine Öğrenimi ve Veri Madenciliği (Hellstrom ve Holmstromm, 1998) ve (4) istatistiksel modelleme ile hisse senedi oynaklığının diferansiyel denklemler kullanılarak tahmin edilmesi (Saha ve ark., 2014).

Makine öğrenmesi modellerinin borsa davranışında uygulanması görece yeni bir olgudur. Bu yaklaşım, geleneksel tahmin ve difüzyon modelleme yöntemlerden farklılaşmıştır. Hisse senedi tahmininde kullanılan öncü modeller, zaman serisi modeli ve çok değişkenli analiz gibi istatistiksel yöntemleri içermiştir (Gencay, 1999; Timmermann ve Granger, 2004; Bao ve Yang, 2008). Bu başlangıç modellemelerinde hisse senedi fiyat hareketi zaman serilerinin bir fonksiyonu olarak değerlendirilip bir regresyon problemi olarak çözümlenmiş ve problem sonuçlarındaki başarı hisse senedinin o dönemde gerçek değeriyle kıyaslanarak belirlenmiştir. Ancak, hisse senedi fiyatının kesin değerlerini tahmin etmek, kaotik yapısı ve yüksek oynaklığı nedeniyle oldukça zordur. Zaten daha sonra yapılan araştırmalarda, hisse senedi değeri tahminini, bir regresyon problemi yerine sınıflandırma problemi olarak değerlendirmenin daha iyi sonuçlar verdiği tespit edilmiştir. Bu kapsamda, son dönem çalışmalarında temel amaç, makine öğrenmesi tekniklerini kullanarak piyasa verilerinden elde ettiği bilgilerle hisse senedi fiyatının hareketinde gelecekteki eğilimleri tahmin eden akıllı bir model tasarlamaktır. Bu çalışmada da olduğu gibi genel modellerdeki öngörücü çıktılar, borsa yatırımcılarını karar verme süreçlerinde desteklemeyi amaçlamaktadır. Genel olarak araştırmacılar tahmin modellerinde Yapay Sinir Ağları (YSA), Naive Bayes Sınıflandırıcı (NBS), Destek Vektör Makineleri (DVM) vb. gibi çeşitli algoritmalar kullanmışlardır.

Hisse senedi değeri tahmini için özellikle piyasa belirsizliklerini yansıtabilecek algoritmaları çalıştırabilen teknolojik sistemlerin gelişmesi ile pek çok algoritma ve yöntem geliştirilmiş (Ek-1), algoritma içi farklılıklarla (üyelik fonksiyonu, katman sayısı, performans ölçütı gibi) farklı hisse senetleri veya borsa endeksleri üzerinde çalışmalar yapılmıştır. Araştırma değişkenlerinin sayıca çokluğu, kapsamlılığı ve etkilerinin karmaşıklığından ötürü bir makine öğrenmesi modellemesi olan YSA algoritmaları da hisse senedi değer tahminlerinde sıkılıkla kullanılmıştır.

Bu çalışma kapsamında da Borsa İstanbul'da (BİST) işlem gören seçili hisse senetlerinin 2009 Mart - 2018 Aralık tarihleri arasında aylık değer değişimlerinin

tahmin edilebilmesi için literatürdeki çalışmalara ek olarak finansal oran ağırlıklı değişkenler kullanan bir YSA algoritması önerilmiştir. Kaynaklarda yer alan çalışmalardan farklı olarak, önerilen YSA algoritması sadece hisse senedi yönünün belirlenmesi yerine, dört çıkış nöronu ile hisse senedi değer değişimlerinin örneklem sayısıyla belirlenen çok azalma - azalma - artma - çok artma şeklinde dört gruba yerleştirilmesini sağlayarak değer değişim miktarını, dolayısıyla getiri miktarını da dikkate almıştır. Önerilen algoritmanın sonuçları, tahmin modellerinde sıkılıkla kullanılan DVM, Lojistik Regresyon (LR) Algoritması, NBS Algoritması ve Rasgele Orman (RO) Algoritmasının aynı veri üzerindeki tahmin sonuçlarıyla karşılaştırılmış ve daha iyi sonuçlar elde edilmiştir.

Çalışma, yapılan gruplama ile getiri miktarındaki yüksek değişimli grupların düşük değişimli gruplara göre tahmin edilme başarı farkının algoritma kapsamında gözlenebilmesini sağlayarak şu ana kadar yapılan çalışmalardan ayırmaktadır. Ayrıca 120 girdi değişkeni kullanılan çalışma, borsa tahminine ilişkin literatürde yer alan en kapsamlı çalışmalardan birisidir.

Bahsedilen çerçeve içerisinde önerilen YSA modeli MATLAB programlama dili ve ortamında çözdürülmüş, kıyaslama yapılan modellerin çözümünde ise WEKA makine öğrenmesi programı kullanılmıştır.

Çalışmanın ikinci bölümünde, YSA algoritmalarının kullanım alanları, borsa tahmin modelleri ve finansal oranların borsa tahmin modellerinde kullanılmasına ilişkin kaynak araştırması yer almaktadır. Üçüncü bölümde, materyal ve metot tanıtımı yapılmış, önerilen YSA algoritmasına ilişkin detaylı bilgi sunulmuş ve kıyaslanan algoritmalaara ilişkin genel bilgi verilmiş, veri seti ve çalışma ortamı açıklanmıştır. Dördüncü bölümde araştırma bulgularına yer verilmiş ve yorumlaması yapılmış; beşinci ve son bölümde ise sonuç değerlendirmeleri yapılmış ve gelecekte yapılabilecek çalışmalara ilişkin öneriler sunulmuştur.

2. KAYNAK ARAŞTIRMASI

Bu bölümde kaynak araştırması üç başlık altında ele alınmıştır. İlk olarak araştırmada kullanılan YSA modeline ilişkin farklı alanlarda yapılan uygulamalar, ikinci olarak, borsa tahmini alanında YSA veya diğer yöntemlerle yapılmış kaynaklarda yer alan çalışmalar, son olarak da algoritma değişkeni olarak kullanılan finansal oranların hisse degeriyle ilişkisini araştıran çalışmalar incelenmiştir.

2.1. Yapay Sinir Ağları (YSA) Modelleri

Wellekens (1998), otomatik konuşma tanıma sistemlerinin kurulmasında yaşanan sorunları ifade etmiş ve YSA'nın bu sorumlara getirdiği başarılı çözümleri sıralamıştır.

Petersen ve ark. (2002) YSA ve görüntü işlemeyle ilgili 200'den fazla makaleyi incelemiş ve algoritmanın özellikle ileri beslemeli, Kohonen ve Hopfield modellerinin bu alanda gelecekte alabileceği rollere ilişkin araştırmalarda bulunmuşlardır. 6 tane alt uygulama alanı belirlemişler ve bu alanlardaki YSA kısıtları için geliştirmeler önermişlerdir.

On ve Teo (2009) makalelerinde 3D, fizik tabanlı bir ortamda simüle edilen sanal bir Khepera robotunun fototaxis ve radyo frekansı lokalizasyonu davranışları için bir denetleyici olarak işlev gören nöral ağın evrimleşmesinde, çok amaçlı evrimsel algoritmaların kullanılmasında yeni bir yaklaşım açıklamışlardır. Çalışmada Pareto-öncül Diferansiyel Evrim Algoritması, robot davranışının ve ağ karmaşıklığının birbiriley çelişen hedeflerini optimize eden 3 katmanlı ileri beslemeli YSA üzerinden Pareto optimal setlerini üretmek için kullanılmıştır. Test sonuçları, robotun ışık kaynağını takip edebildiğini ve aynı zamanda radyo frekans sinyal kaynağını doğru yönlendirdiğini göstermiştir.

On ve Teo (2010), bir grup E-puck robotuna kutu itme fonksiyonu yüklemek için radyo frekansı yayan robot kontrolcüsünü gelişmiş bir ileri beslemeli YSA algoritmasıyla çalışmışlardır. Sonuçlarda algoritmayı kurarken kullandıkları Pareto Diferansiyel Gelişme Algoritması (Pareto-frontier Differential Evolution) sayesinde az sayıda gizli nöron kullanıp robotların radyo frekanslarını daha verimli algılayabildiklerini ifade etmişlerdir ve Pareto Diferansiyel Gelişme Algoritması ile

kurulan YSA modellerinin robotik alanında başarılı uygulamalar yapabileceğini belirtmişlerdir.

Nirkhi (2010) gittikçe artan veri kayıtlarından karar destek sistemlerine katkıda bulunacak anlamlı veriler çekilmesi için karmaşık verilerle başka alanlarda başarıyla çalışıldığını ifade ettiği YSA tabanlı bir veri madenciliği tekniği önermiştir. Uygulama bulunmayan makalede yazar veri madenciliğine YSA'nın nasıl dahil edilebileceğini incelemiştir.

Dey ve ark. (2012), otomatik makine öğrenimini hedefleyen, konuşma tanımı yapan güvenlik sistemlerinde ses haritalaması için kullanılmak üzere Gizli Markov Modeline dayanan geri yayılmacı bir YSA algoritması önermişlerdir. Bu algoritmanın özellikle büyük veri bir girdi- çıktı konuşma haritası seti için uygun sonuçlar verdiği iddia etmişlerdir.

Alberto ve ark. (2012) görüntü işleme alanında YSA'ya ilişkin yaklaşık 160 makale olduğunu belirtmişler ve bu makalelerde yer alan uygulama konseptlerine değinmişlerdir. Ayrıca son zamanlarda yaygınlaştığını ifade ettikleri görsel korteks tabanlı YSA modellerinin önemli özelliklerini analiz etmişlerdir.

Amato ve ark. (2013) yanlış teşhisleri önlemek için klinik belirti verilerini, biyokimyasal verileri ve görselleştirme cihazlarının verilerini kullanan bir YSA uygulamasının sahip olması gereken özellikleri ve algoritmanın sahip olduğu kısıtları çeşitli örnekler üzerinden incelemiştir.

Khan ve ark. (2013) YSA'nın hastalıkların erken teşhisinde kullanılabilirliğini incelemiştir. Akut nefrit hastalık belirtileri ve kalp yetmezliği incelemesi için hasta tomografileri olarak iki ayrı vakayı ele almışlardır. Çıktı olarak hasta olma ve hasta olmama alınmış, ileri beslemeli ve geri yayılmış sinir ağlarını uygulamaları olarak yürütmüşlerdir. Akut nefrit hastalığı teşhisinde YSA'nın kullanılmasının belirti şablonlarını oluşturmada faydalı olduğunu belirtmişlerdir.

2.2. Borsa Tahmin Modelleri ve Yapay Sinir Ağlarının Borsa Tahminlerinde Kullanımı

Tsaih ve ark. (1998), S&P 500 hisse senetleri vadeli işlemler piyasası için hibrit yapay zeka tabanlı bir alım satım stratejisi yaklaşımı önermişlerdir. Önerilen hibrit yapay zeka yaklaşımında kural tabanlı sistemler teknigi (rule-based systems technique) ile YSA yaklaşımı beraber kullanılmıştır. Yazar, kural tabanlı sistemler teknigi ile YSA

kısıtlarını aşarak ve güçlü yanlarını kullanarak oluşturduklarını belirttikleri hibrit sistemle alım-satım işlemleri için güçlü bir karar destek sistemi oluşturduklarını ifade etmişlerdir. Çalışmalarının iki açıdan diğer çalışmalardan farklılaştığını ifade eden yazarlar, YSA eğitim kısmında kural tabanlı sistem yaklaşımını kullanmalarını birinci, Geri Yayılımlı Ağlar (Back Propagation Networks) yaklaşımı yerine de Muhakemeli YSA (Reasoning Neural Networks) yaklaşımı kullanmalarını ikinci neden olarak belirtmiştir. Deneysel çalışmalarında Muhakemeli YSA yaklaşımı ile algılayıcı (Perceptron Neural Networks) ve Geri Yayılımlı YSA yaklaşımlarından daha iyi sonuçlar elde edilmiştir. Oluşturulan hibrit bütünsel vadeli işlemler alım-satım sistemi 1988-93 arası dönem için yapılan deneylerde hem diğer YSA yaklaşımlarından hem de al ve tut stratejisinden (Buy and Hold Strategy) daha iyi sonuçlar vermiştir.

Grosan ve arkadaşları (2005) S&P hisse senedi endeksinin tahmini için bir genetik programlama tekniği uygulamışlardır. Tekniğin performansı, Levenberg – Marquardt algoritması, DVM, Takagi-Sugeno nöro-bulanık çıkarım sistemi kullanılarak eğitilmiş YSA ile karşılaştırılmıştır. Ampirik sonuçlar, genetik programlama tekniğinin fonksiyon yaklaşımı problemleri için iyi bir yöntem olduğunu göstermiştir. Genetik programlama tekniği hisse senedi endeksi için en düşük ortalama değerleri bulmuştur.

Quek (2005), ABD Menkul Kıymetler Borsası'nda yatırımcıların davranışlarını tahmin etmek için bir bulanık mantık YSA modeli kullanmıştır. Modelin ABD Menkul Kıymetler Borsası'nda hisse senedi fiyatlarını tahmin etmede başarılı olduğu görülmüştür.

Trinkle (2005), halka açık üç şirkete ait yıllık getirileri tahmin etmek için bulanık mantık YSA ve YSA kullanmıştır. Bu iki tekniğin öngörü yeteneği, otoregresif hareketli ortalama modeli ile karşılaştırılmıştır. Sonuçlar, bulanık mantık YSA istatistiksel olarak önemli derecede iyi tahminler üretebildiğini ortaya koymuştur.

Afolabi ve Olatoyosi (2007), Bulanık mantık, YSA ve Kohonen'in kendi kendini düzenleyen planını hisse senedi fiyatını tahmin etmek için kullanmıştır. Sonuçlar, Kohonen'in kendi kendini organize eden planındaki sapmanın diğer tekniklerden daha az olduğunu göstermiştir.

Tan ve ark. (2007) insan beynindeki biyoloji örtülü tanıma (sürekli tekrar eden şekillerin beyinde tanımlanması) ve gen seçim sürecinden esinlenen bir genetik tamamlayıcı öğrenme (Genetic complementary learning) sistemi önermiştir. Bu sistem hipokampal tamamlayıcı öğrenme (hippocampal complementary learning) ve evrimsel genetik algoritmanın (evolutionary genetic algorithm) bir birleşimidir.

Yazarlar genetik algoritmanın en iyi sonuca yakın değerleri sunması ve tamamlayıcı öğrenmenin örüntülü tanıma sistemi sayesinde önerilen sistemin YSA ve istatistik metodlar gibi diğer yaklaşımlardan daha iyi sonuçlar verdiği belirtmiştir. Ayrıca sistemin katmanlı ilerleyen ve otonom yapısı sayesinde manuel kural konulan modellere göre daha kısa sürede sonuca ulaşabildiğini belirtmişlerdir. Verinin sürekli değiştiği ve güncelleştirme ihtiyacı duyduğu finansal piyasalarda bu otonom yapının yarattığı hızın daha önemli hale geldiğini ifade etmişlerdir. Çalışma kapsamında genetik tamamlayıcı öğrenme sistemi, bir hisse senedi piyasası tahmin aracı ve banka zarar erken uyarı sistemi olarak incelenmiştir ve deneysel araştırmalar sonucunda yazarlar önerilen sistemin bu konularda kullanılabilir olduğunu ifade etmişlerdir.

Abbasi ve Abouec (2008), Tahran Menkul Kıymetler Borsası'nda İran Khodro Şirketi'nin mevcut hisse senedi fiyatını, Uyarlama Nöro-Bulanık Çıkarım Sistemi kullanarak araştırmışlardır. Araştırmacıların bulguları, hisse senedi fiyat eğiliminin düşük bir hata seviyesiyle tahmin edilebileceğini göstermiştir.

Yunos ve arkadaşları (2008), Kuala Lumpur Kompozit Endeksinin günlük hareketlerini tahmin etmek için bulanık mantık YSA ile melez bir nöro-bulanık model geliştirmiştir. Dört teknik gösterge verileri analiz etmek için seçmişler ve deneysel sonuçlara göre, bulanık mantık YSA yönteminin, Kuala Lumpur Kompozit İndeksini YSA'ya göre tahmin etmede daha yetkin olduğunu göstermişlerdir.

Atsalakis ve Valavanis (2009), bir sonraki günü New York Hisse Senedi Endeksi'nin hisse senedi fiyat trendlerini tahmin etmek için yansız bulanık bir adaptif kontrol sistemi geliştirmiştir. Deney sonuçları, önerilen sistemin ticaret simülasyonlarında çok iyi performans gösterdiğini ortaya koymuştur.

Boyacıoğlu ve Avcı (2010), Borsa tahmini sürecini çok karmaşık ve zor bir süreç olarak ifade edip bu konunun çözümü için bir Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (Adaptive Network-Based Fuzzy Inference System) önermişlerdir. Bu amaçla İMKB 100 indeksi üzerinde tahmin yapmak için altı makroekonomik ve üç diğer endeksi kullanan bir uygulama geliştirmiştir. Yapılan deneyler sonucunda İMKB 100 endeksinin ortalama aylık getirisinin t anındaki değerini t anındaki girdi değişkenleri ile %98.3 oranıyla doğru tespit ettiklerini belirtmişlerdir.

Kara ve ark. (2011), hisse senedi fiyat hareket yönünün tahmini için YSA ve DVM tabanlı iki model geliştirmiştir ve bu modellerle BİST 100 endeksinin günlük değerini tahmin etmişlerdir. Tahmin modelinde on adet teknik gösterge değişkeni girdi olarak kullanılmış ve iki ayrı veri seti üzerinde gözlem yapılmıştır. Yapılan çalışmada

YSA modelinin %75.74 doğruluk oranı ile DVM modelinin %71.52'lik doğruluk oranından önemli ölçüde daha iyi olduğu tespit edilmiştir.

Kaynaklarda çok sayıda çalışma makine öğrenme yöntemlerinin finansal zaman serileri tahminlerinde kullanıldığını göstermektedir. Bu çalışmalarla ilgili kapsamlı incelemeler Chun ve Kim (2004) ve Vanstone ve Finnie (2009) çalışmalarında yer almaktadır.

2.3. Finansal Oran Değişkenlerinin Belirlenmesi

Problemin çözümünde finansal oranlar da değişken olarak kullanılmıştır. Literatürde hisse senedi getirilerini yansitan finansal oranlara dair araştırmalar bulunmaktadır. Değişken belirlenmesinde bu araştırmalar da dikkate alınmıştır.

Ou ve Penman (1989) çalışmalarında hisse senedi piyasa değeri tahmini için aralarında aktif devir hızı, kaldıraç oranı, kısa vadeli yabancı kaynak oranı, uzun vadeli yabancı kaynak oranı, öz kaynak oranı ve yabancı kaynakların öz kaynaklara oranı da bulunan 68 finansal tablo değişkeninden katsayı etkisi 0.10'un üzerinde olanlarla bir regresyon modeli kurmuşlardır. Finansal tabloların hisse senedi değerine daha yansımamış etkileri bulunduğu dolayısıyla hisse senedi kazanç tahmininde kullanılabilceğini belirtmişlerdir.

Lewellen (2002), temettü oranı gibi finansal oranların hisse getirilerinde kullanılabilir olup olmadıklarını, kullandığı bir regresyon modeli ile araştırmıştır. 1946-2000 dönemi için temettü oranının; 1963 ve 2000 arasında ise piyasa değeri / defter değeri oranı ve fiyat / kazanç oranının hisse değerini tahmin edebildiğini tespit etmiştir.

Griffin ve Lemmon (2002), piyasa değeri / defter değeri oranı ve finansal sıkıntı olasılığının hisse değerlerine etkisini incelemiştir. Ohlson'un O-Score oranı ile finansal sıkıntı olasılığını hesaplayıp oranı yüksek firmaların 3 aylık kar-zarar tablosu açıklaması döneminde piyasa değerinin düşüğünü hesaplamışlardır.

Aktaş (2008), İstanbul Menkul Kıymetler Borsasında hisse senedi getirileri ile ilişkili olan finansal oranları tespit ederek yüksek performans gösteren hisse senetlerinin seçimiine katkı sağlayan bir araştırma yayımlamıştır. Araştırmada, hisse senedi getirileri ile finansal oranlar arasındaki ilişki orta vadeli olarak araştırılmıştır. 1995-1999 ve 2003-2006 olmak üzere iki ayrı analiz döneminin kullanıldığı bu çalışma sonucunda, 1995-1999 döneminde orta vadede hisse senedi getirileri ile ilişkili olan finansal oranlar

olarak, asit test ve faaliyetlerden sağlanan nakit akımı/öz sermaye bulunurken, 2003-2006 döneminde brüt kar/satış ve net kar/satış bulunmuştur.

3. MATERİYAL VE YÖNTEM

3.1. Karşılaştırmada Kullanılan Algoritmalar

Bilişim teknolojilerinin gelişimine paralel olarak daha çok veriyi daha kısa sürede işleyen algoritmaların ve karmaşık algoritmaların gerçek hayat problemlerine uygulanma imkânı artnmıştır. Ayrıca, hâlihazırda aritmetik işlem yapmaya yönelik programların da paket program desteklerinin özellikle algoritmaları işleyecek hale gelmesiyle programlama dili bilme ihtiyacı da azalmış, bu doğrultuda borsa tahmini için geliştirilen karar destek sistemi algoritma uygulamaları çoğalmıştır. Bu araştırma kapsamında önerilen algoritmaya ek olarak literatürde sıkılıkla kullanılan 4 algoritmanın sonuç değerleriyle kıyaslama yapılmıştır. Bu algoritmalar LR, DVM, NBS ve RO algoritmalarıdır.

3.1.1. Lojistik Regresyon Algoritması (LR)

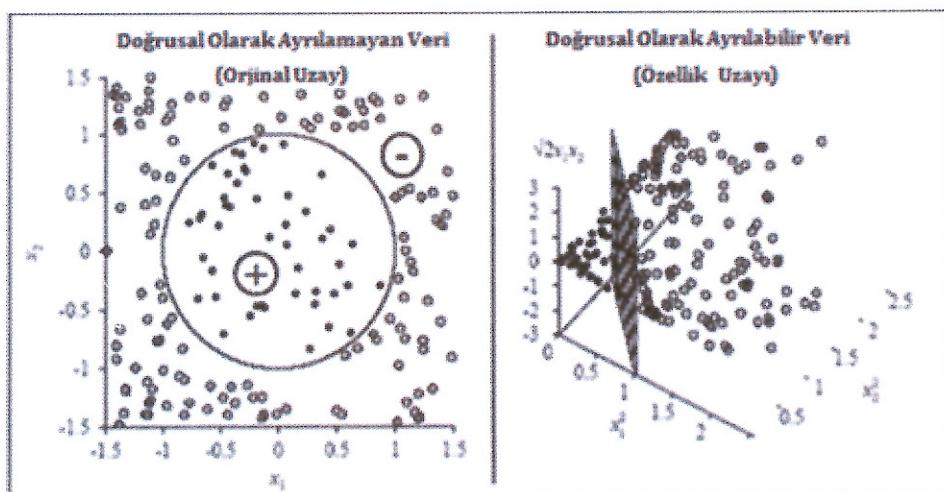
Sınıflandırma problemlerinde sıkılıkla kullanılır. Çoklu sınıflandırma yapabilen (multi class classification) bir algoritmadır. Çoklu sınıflandırma yapmak için bir-tüm (one vs all) yaklaşımıyla denetimli olarak çıktıda elde edilmek istenen veri grubuna doğru değer verilerek diğer gruplar ayrıştırılır. Her zaman $[0,1]$ aralığında çıkan hipotez fonksiyonu değerine göre karar alınır. Karar gruplarını ayırmak için veriler karar sınırı (decision boundry) denilen bir polinomsal fonksiyonla gruplara ayrırlar. Belirtilen aralıkta sonuç elde etmek ve sonuçları karar gruplarına atamak için YSA'da olduğu gibi sigmoid fonksiyonu (sigmoid (logistic) function) kullanılabilir. Daha sonra konveks olup minimum maliyet değerini verebilecek bir maliyet fonksiyonu aranır. Lineer regresyonda olduğu gibi LR'de de gradyant azaltma (gradient descent) yöntemleri ile belirlenen parametrelerle alınan başlangıç noktasından türev değerini 0 yapan minimum noktasına ulaşımaya çalışılır. İşlemlerin daha hızlı çalışması için özellik ölçeklendirme ve normalleştirme uygulamaları (Feature scaling) yapılabilir.

3.1.2. Destek Vektör Makineleri (DVM)

DVM yüksek boyutlu ve küçük sayıda eğitim verisinden öğrenebilen yeni nesil bir öğrenme metodu olarak Vladimir Vapnik tarafından 1995 yılında tanıtılmıştır.

(Vapnik, 1995) DVM temelde ikili sınıflandırmalar (başarılı - başarısız, artar - azalır) için kullanılırken basit değişikliklerle çoklu sınıflandırmalarda da uygulanmaktadır. Diğer makine öğrenmesi yöntemleri gibi eğitim veri kümesini kullanarak öğrenen ve öğrendiği bilgileri genelleştirmeye çalışan, sonrasında oluşturduğu model yardımıyla yeni veriler üzerinde doğru tahminler yapmaya çalışan bir algoritmadır. Sezgisel argümanları matematiksel çerçeveye yerleştirmeyi amaçlayan istatistiksel öğrenme teorisine dayanmaktadır.

DVM'de, genelleme yeteneğini en üst düzeye çıkarmak için veri gruplarını optimum hiper düzlemlere ayırmaya çalışır. Veri gruplarından hiper düzleme yakın verileri destek vektörü olarak belirler ve diğer verileri dışlayarak sadece bu eğitim verisi grupları üzerinden çalışma yürütür. Eğer veri grupları lineer olarak ayrılamıyorsa, üretilen bir polinomla veri boyutu artırılarak ayrıştırma sağlanır. Veri gruplarını ayırmada kullanılan uzay bölgümlendirme örnekleri Şekil 3.1.'de görülmektedir.



Şekil 3.1. Doğrusal Olarak Ayrılamayan Veri Gruplarının Dot Product Dağılımı (Grunescu, 2011)

Yeni işlem uzayının hesaplama yükünü artırması nedeniyle de kernel (çekirdek) fonksiyonu uygulanarak önceki uzayla yeni uzay arasında ilişki kurulur. Kernel fonksiyonunun sigmoid kernel, radyal kernel, polinomsal kernel gibi çeşitleri bulunmaktadır. En sık kullanılan kernel fonksiyonu türleri Çizelge 3.1.'de verilmektedir. Fonksiyon parametreleri çapraz doğrulama (k-fold cross validation) yöntemi yardımıyla bulunur.

Çizelge 3.1. DVM'de kullanılan temel kernel fonksiyonları (Kavzoglu ve Çölkesen, 2010)

Kernel Fonksiyonu	Matematiksel İfadesi	Parametre Bilgisi
Polinom	$K(x,y) = (1 + \sum a_j * b_j)^d$	Polinom Derecesi (d)
Normalleştirilmiş Polinom	$K(x,y) = \frac{(x*y+1))^d}{\sqrt{((x^2)+1)^d * ((y^2)+1)^d}}$	Polinom Derecesi (d)
Radyal Tabanlı	$K(x,y) = e^{-\gamma * x-x_i ^2}$	Kernel Boyutu (γ)

Yüksek boyutlarda, boyut büyülüğu örnek büyülüğünden yüksek olduğu durumlarda kullanılırken, özellik (feature) sayısı örnek sayısından yüksekse karar gücü zayıflar.

3.1.3. Naive Bayes Sınıflandırıcı Algoritması (NBS)

Sınıflandırma problemlerinde kullanılan NBS, büyük veri setlerine en hızlı uygulanabilecek, anlaması en kolay veri madenciliği algoritmalarındandır.

NBS, Bayes Teoremi üzerine geliştirilen bir sınıflandırma tekniğidir. Birbiriyle ilişkisi açık şekilde görülebilen tahmin edici değişkenlerin bile birbirinden bağımsız olması varsayımlı nedeniyle yalnız (naive) ismini alan NBS, birçok sofistike sınıflandırma modellerinden bile daha iyi sonuçlar verebilmektedir.

Bayes Teoremi, A olayının gerçekleşmesiyle gerçekleşen B olayının koşullu olasılığının ters koşullu olasılık ve A-B olaylarının marginal gerçekleşme olasılıklarından hesaplanabileceğini belirtir. Eşitlik 3.1'deki gibi gösterilir ve İki olaylı Bayes Teoremi diye adlandırılır.

$$P(A|B) = \frac{P(A)*P(B|A)}{P(B)} \quad (3.1)$$

Olay sayısının ikiden çok olması ve olayların karşılıklı bağımsız olduğu varsayımda tüm olay uzayını kaplayan k tane A_j olayının olasılıklar toplamı 1 olup Eşitlik 3.2'deki formül geçerlidir (Çoklu olaylı Bayes Teoremi).

$$P(A_i|B) = \frac{P(A_i)*P(B|A_i)}{\sum_{j=1}^k P(A_j)*P(B|A_j)} \quad (3.2)$$

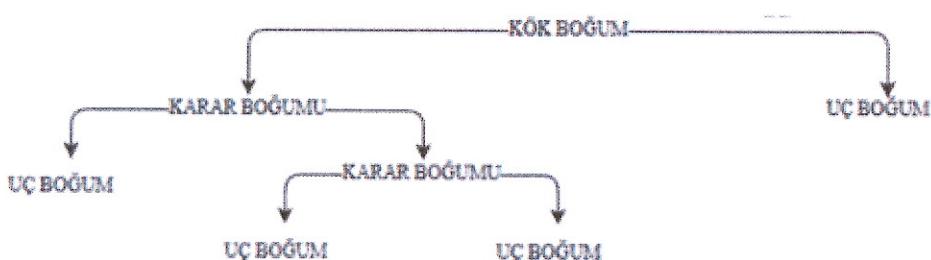
Dolayısıyla frekans tablosu ve olasılık tablosu oluşturulan bir sistemle hangi sınıfı ait olduğu bilinmeyen yeni bir gözlem sınıflandırılmak istendiğinde Bayes Teoremi yardımıyla test seti verilerinin olasılık değerleri göz önünde bulundurularak sınıflandırılabilir. (Cichosz, 2015)

NBS algoritması, çoklu sınıflandırma problemleri için iyi sonuçlar verebilmesinin yanında değişkenlerin birbirleri arasındaki bağımsızlık oranı arttıkça diğer algoritmalarдан daha iyi sonuç verebilmektedir. Kategorik değişkenlerin olduğu sistemlerde daha iyi çalışan NBS, veri değerlerin normal dağılıma yakın olduğu sürekli veri setlerinde de kullanılabilmektedir (Yıldırım ve Birant, 2014).

3.1.4. Rastgele Orman (RO) Algoritması

RO, denetimli (supervised) makine öğrenme yöntemlerinden birisidir. Regresyon sistemlerinde kullanılabildiği gibi, sınıflandırma sistemlerinde de kullanılabilir. Ağaç tabanlı (tree-based) bir yöntemdir. Ağaç tabanlı yöntemler özünde veri kümesini “eğer-öyleyse” önermeleriyle bölgerek tahmin değişken uzayını bölgelere ayıırlar. Regresyon durumunda tahmin hata kareleri toplamının; sınıflandırma durumunda hatalı sınıflandırma oranının minimizasyonuna çalışırlar.

Çalışmamızda hisse senedi tahmini problemi sonuçlar gruplandırılarak bir sınıflandırma problemi haline getirilmiştir. Ancak performans kriterleri hariç genel yaklaşım, regresyon ortamında da geçerlidir.



Şekil 3.2. Karar AĞacı Bileşenleri (Quinlan, 1986)

Genel karar ağacı yapısı Şekil 3.2'de gösterilmiştir. Kök ve karar boğumları, ağacı farklı sonuçlara bölen değişkenlerdir. Ayırma sonrası oluşan dallarla sonraki boğum noktalarına ulaşılır. Daha fazla ayırma yapılmayan boğum noktaları üç boğumlardır, bu boğumlar bu yapılanmayla oluşan karar bölgelerini gösterir. Karar

bölgelerinde, bağımlı değişkenin kategorik değer aldığı durumda hangi sınıfa ait olduğuna karar verilir. Karar ağacı yapılanmasının bir avantajı, hangi tahmin değişkeninin, bağımlı değişken üzerinde daha belirleyici olduğunu belirlenebilmesidir. Karar ağaçlarında yukarıya çıkıldıkça değişkenlerin sonuçlar üzerindeki etkisi artmaktadır.

Dallandırmanın durdurulması için oluşturulan her boğumda belirli sayıdan fazla gözlem kalmaması genellikle tercih edilir. Basit ve kolay anlaşılabilir algoritmalar olmaları nedeniyle tercih edilirler. Varyans, modelde kullanılan veri kümesi değiştiğinde tahminlerde gözlenen farklılaşma/saçılım ölçüsüdür. Yanlılık ise, karmaşık yapıdaki ilişkilerin gerçekçi olmayan düzeyde basit ya da yanlış olarak modellenmesi sonucu ortaya çıkan tahmin sapmasıdır. Modelin ve model parametrelerinin doğru seçimi; belirlenecek bir ayarlama parametresi ile yaprakların daha az sayıda olması sağlanarak, yanlılık, varyans ve aşırı uyum gösterme problemlerinin çözülmesi gereklidir (James ve ark., 2017).

Problem çözümünde kıyaslama amaçlı kullanılacak RO algoritmasının genel yapısı:

Her bir T_b , $b = 1 \dots b_{\text{mak.}}$ için:

Adım 1: Uç boğumlardaki gözlem sayısı kontrolü, tüm üç boğumlardaki gözlem sayısı, belirlenmiş minimum gözlem sayısına ulaştıysa Adım 5'e git,

Adım 2: Toplam p değişken arasından m tanesini rassal olarak seç,

Adım 3: Seçilmiş m değişken arasından, eğitim kümesinde en iyi ayırmayı yapanı seç,

Adım 4: Uç boğumu iki alt-boğuma ayır, Adım 1'e dön

Adım 5: Ağacı T_b olarak kaydet, maksimum ağaç sayısına ulaşılmışsa dur, ulaşılmamışsa Adım 1'e dön (Amrehn ve ark., 2018).

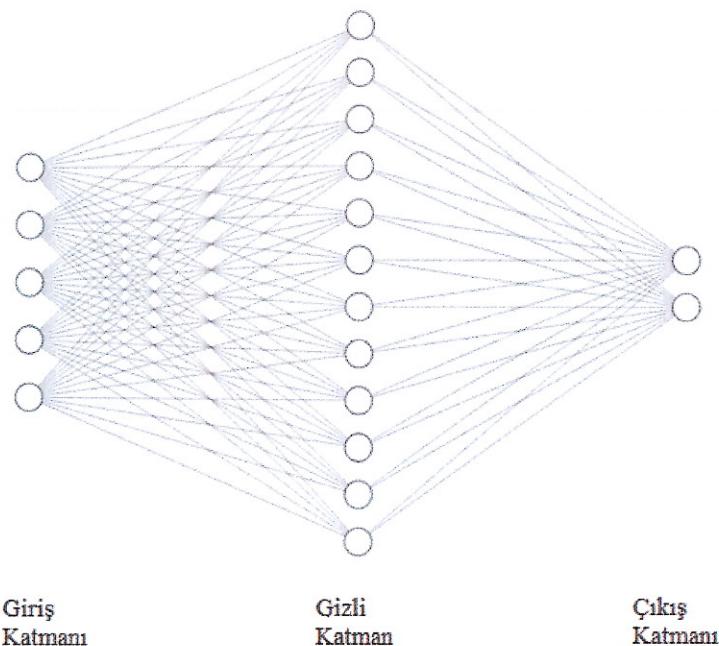
3.1.5. Önerilen YSA Algoritması

YSA, ilk olarak McCulloch ve Pitts tarafından geliştirilmiş, bilgisayarların hesaplama gücünün gelişmesi ile önemini artırmış, insan beynindeki nöron etkileşimlerinden esinlenen, veri içerisinde desen tanımlaması yaparak sınıflandırma yapan bir hesaplama algoritmasıdır (Clarence, 2001).

Çalışma kapsamında YSA algoritmalarından çok katmanlı algılayıcı (multilayer perceptron - ÇKA) kullanılmıştır. ÇKA, en bilinen ve en sık kullanılan sinir ağı türüdür.

Bunun haricinde tekrarlamalı (recurrent), artık değerli (residual), yarıçap temelli (residual basis) YSA algoritması türleri de bulunmaktadır.

Çoğu durumda ÇKA algoritmasında sinyaller ağ içinde giriş (input) nöronundan çıkış (output) nöronuna doğru olmak üzere bir yönde iletilir. Bu tarz YSA mimarisine ileri beslemeli (feedforward) mimari denir. Şekil 3.3'te bir ileri beslemeli ÇKA mimarisine yer verilmektedir.



Şekil 3.3. Çok Katmanlı Algılayıcı Mimarisi

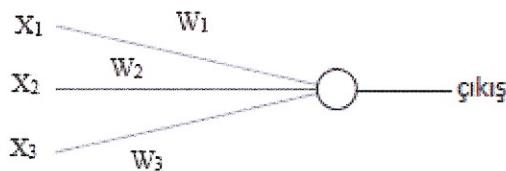
Şekil 3.3'te görüldüğü gibi, ÇKA katmanlı bir yapıdadır. Dış dünyadan alınan veriler giriş nöronları katmanından sisteme girerken, çıkış nöronları katmanı da algoritmanın ilgili verilere ilişkin bulduğu sonucu gösterir. Örneğin giriş nöronları bir gözleme yer alan değişkenlerin değerlerini gösterirken çıkış nöronları kurulan algoritmanın ilgili gözlem için bulduğu sonucu gösterir. Çok katmanlı yapıda olmayan algılayıcılar sonuç uzayını sadece doğrusal olarak ayırlabilirler (McCulloch ve Pitts, 1943). Dolayısıyla AND ve OR operatörlerinin işlevlerini yerine getirirlerken, sonuçları doğrusal olarak ayırlamayan XOR gibi daha karmaşık operatör işlevlerini başaramazlar. Bu nedenle YSA algoritmaları çok katmanlı yapıdadır.

Dış dünya ile ilişiği bulunmayan, giriş nöronlarından aldığı verileri işleme koyup bir sonuç değeri elde eden ve bu sonucu ileriki katmanlara iletten katman ise gizli (hidden) katmandır. Gizli katman birden fazla olabilir.

Nöronlar arası hareketin tek yönlü olduğu ileri beslemeli mimariden başka çift yönlü hareketin olduğu daha güçlü, dinamik ve karmaşık geri beslemeli (feedback) YSA'da vardır. Bu modellerde algoritma her girdi değişikliğinde bir denge noktasına ulaşana kadar bütün nöronları tekrar gözden geçirir.

Nöronlar arasında iletişimden kastedilen nöronun ateşlenmesidir (fire). Bir nöron kendisine bağlanan öncül nöronlardan aldığı ağırlıklı (weighted) değerleri işleme sokarak, eğer bir eşik değer (threshold) aşıldığında kendisinden sonraki katmanda bağlantılı olduğu nöronların tamamına ağırlıklandırarak iletir. Halihazırda makine öğrenmesinden kastedilen de yanlış sonuç veren algoritmanın bu ağırlık ve eşik değerlerinde yapılan ufak değişiklerle doğru sonucu ulaşmasını sağlanmasıdır.

Ağırlık ve eşik değerlerde yapılan ufak değişikliklerin algoritma sonucunu değişiklikle oransal olarak etkileyebilmesi için nöronların sadece ikili sistemde (0,1) değer almaması, ara değerler de alabiliyor ve ateşleyebiliyor olması gerekmektedir. Bu anlamda en sık kullanılan nöron yapısı, parametre değişikliklerinde ufak değişimler gösterebilen ve her zaman [0,1] aralığında değer alan bir nöron çeşidi sigmoid nöronudur.

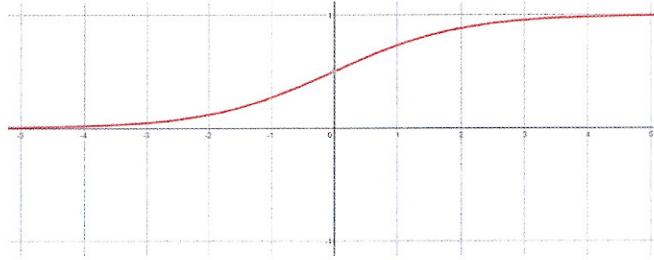


Şekil 3.4. Sigmoid Nöronu Yapısı

Çalışmada kullanıldığı üzere Şekil 3.4'teki gibi $x_1, x_2, x_3\dots$ değerlerini $w_1, w_2, w_3\dots$ ağırlıkları oranında girdi olarak alan b eşik değerli sigmoid nöron sistemlerinde nöronun ateşlenirken alacağı değeri belirleyen aktivasyon fonksiyonu (activation function) çıkış değeri Eşitlik 3.3 ile hesaplanır.

$$\frac{1}{1 + e^{(-\sum w_j * x_j - b)}} \quad (3.3)$$

Şekil 3.5'te grafiği yer alan sigmoid aktivasyon fonksiyonu her zaman [0,1] aralığında değer alması, türevinin kolay alınabilmesi ve hafif geçişli şekli nedeniyle YSA'da en sık kullanılan aktivasyon fonksiyonlarındandır.



Şekil 3.5. Sigmoid Fonksiyonu

YSA'da öğrenme, verinin bir kısmından alınan bir öğrenme setinden (training set) elde edilen nöronlar arası ağırlık değerlerinin bir test setine uygulanması ile yapılır. Daha sonra bu ağırlıklar revize edilerek algoritmanın test verileri için daha doğru sonuçlar vermesi amaçlanır. Algoritmanın performansını değerlendirmek için doğru tahmin edilen değerlere 0 atayacak, yanlış tahmin edilen değerlere maliyet atayacak, ağırlık ve nöron ateşleme eşik değerlerine (bias) bağlı bir maliyet fonksiyonuna (cost function) ihtiyaç duyulmaktadır. Öğrenme veri seti giriş değerlerinin x , gerçekleşmesi istenen çıkış değerlerinin $y(x)$ vektörü, (Örneğin 4 çıkışlı grüplamada 3 numaralı çıkış doğru ise $y(x) = (0,0,1,0)^T$ olmalıdır) algoritma ağırlıklarının w matrisi, ateşleme eşiklerinin b vektörü, öğrenme seti girdi sayısının n olduğu bir ortamda çıktı gerçekleştirmeleri α vektörü ise maliyet fonksiyonunun değeri Eşitlik 3.4 ile hesaplanır.

$$C(w, b) = \frac{1}{2n} \sum_x \|y(x) - \alpha\|^2 \quad (3.4)$$

Göründüğü üzere maliyet fonksiyonu ortalama hata karesidir (mean squared error).

Algoritmaya en uygun ağırlık ve eşik değerlerini bulma olan maliyet azaltma işlemi gradyant azaltma yöntemi ile yapılır. Bu yöntemde maliyet fonksiyonu her bir değişken için türev yönünde adım adım değiştirilerek global minimumuna ulaştırılmaya çalışılır. Gradyant vektörü iki değişkenli sistemde Eşitlik 3.5 ile hesaplanır.:

$$\nabla C \equiv \left(\frac{\partial C}{\partial v_1}, \frac{\partial C}{\partial v_2} \right)^T \quad (3.5)$$

$$\Delta v = -\eta \nabla C \quad (3.6)$$

Değişkenlerdeki değişimlerin gradyant vektörüne etkisi 0'dan büyük olup genelde (0,1) aralığında alır ve problemin ne hızda minimum noktasına yakınlaştığıını belirleyen Eşitlik 3.6'da yer alan η değerine de öğrenme hızı (learning rate) denir. Gradyant azaltma yönteminde maliyet fonksiyonu ortalama hata karesinin minimize edilmesi amaçlanmaktadır ve bir YSA algoritmasında ya belirli bir ortalama hata karesine ulaşılana kadar ya da epoch adı verilen eğitim seti üzerindeki belirli bir iterasyon sayısına ulaşılana kadar azaltma işlemeye devam edilir. (Egeli ve ark., 2003) yaptıkları çalışmada epoch limiti 2000 olarak kullanılmış, lokal minimuma ulaşıldıktan sonra gradyant azaltma işlemi momentum sabiti ile oranlanarak lokal minimumdan kaçınılmaya çalışılmış, kaçınılmadığı durumda hata oranı en düşük lokal minimum sonuç olarak atanmıştır.

3.2. Çalışma Verilerinin Belirlenmesi

Finansal verilerin tahminleri üzerine yapılan çalışmalar genel olarak borsa endeks değerlerinin günlük olarak veya aylık olarak tahmin edilmesine yoğunlaşmıştır (Taran ve ark., 2015). Günlük tahmin çalışmalarında girdi değişkenleri olarak döviz kuru, teknik analiz indikatörleri, geçmiş hisse verileri ve diğer borsaların endeks değerleri gibi günlük veri temini sağlanabilen göstergeler kullanılırken; makroekonomik göstergelerin ve şirket finansal raporlarının aylık – üç aylık gibi daha uzun dönemlerde açıklanması nedeniyle ilgili değişkenleri kullanan araştırmalardaki tahmin modelleri çoğunlukla aylık dönemlerden oluşmaktadır.

Yürüttülen çalışmanın literatüre en önemli katkılarından birisi, hisse değeri tahminlerinde kullanılan finansal oranlardır. Bu oranların üç aylık finansal tablolardan elde edilmesi bir yana, çalışmada kullanılan toplam 120 değişkenden 66'sının verisi aylık veya daha uzun periyotlarda yayımlanmaktadır. Bu nedenle çalışma aylık değerler üzerinden yürütülmüştür.

Çalışma verilerinin belirlenmesinde bir başka önemli konu da verilerin kaç aylık bir dönemi kapsayacağıdır. Bu noktada, geçmişe yönelik verilerin varlığı, geçmiş veriler verilerin kalitesi ve 2008 finansal krizinin veri zaman serilerinde yarattığı yapısal kırılma (structural break) dikkate alınmıştır.

Çalışma kapsamında kullanılan değişkenlerden Reel Kesim Güven Endeksi gibi bazı değişkenlerin 2007 öncesi verisi bulunmamakta, Tüketiciler Fiyat Endeksi gibi bazı değişkenlerin ilgili yıla yakın dönemde hesaplama yöntemi değiştiği için geçmiş

verileriyle kopukluk olmaktadır. Ayrıca TCMB ilgili birim çalışanlarından alınan görüşler doğrultusunda da 2007 yılında hesaplama yönteminde yapılan değişiklik öncesi para arzlarıyla ve ödemeler dengesiyle ilgili bazı değişkenlerin hesaplamalarının sorunlu olduğu ifade edilmiştir. Öte yandan 2009 finansal krizinin makroekonomik verilerde ve hisse senedi değeri serilerinde yapısal kırılmaya neden olduğu çeşitli araştırmalarda ifade edilmektedir (Ferreira ve ark., 2014).

Bu nedenlerle, çalışma 2009 yılından 2018 yılına kadar olan veriler üzerinden yürütülmüştür. Çalışma kapsamında basit üstel düzgünleştirme (Simple Exponential Smoothing - BÜD), basit hareketli ortalama (Simple Moving Average - BHO) gibi zaman seri değerleri de değişken olarak algoritmaya dahil edildiği için 2009 Mart döneminden 2018 Aralık dönemine kadar toplamda 118 aylık veri tahmin değeri olarak kullanılmıştır.

3.3. Veri Kaynakları

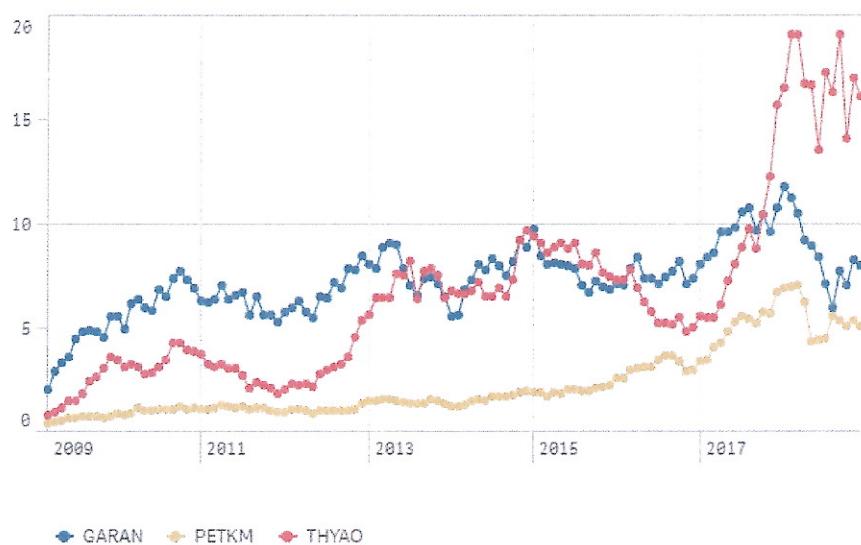
Sistem değişkeni verileri birkaç farklı kaynaktan temin edilmiştir. Faiz, beklenti, para arzı ve makro değişkenler Türkiye Cumhuriyet Merkez Bankası (TCMB) Elektronik Veri Dağıtım Sistemi' nden (EVDS); enflasyon rakamları Türkiye İstatistik Kurumundan; endeks değerleri ve emtia fiyatları investing.com web sitesinden, geçmiş hisse senedi değerleri ve teknik analiz indikatörleri yahoo finance web sitesinden, şirket finansal oranları ise Finnet Mali Analiz programından temin edilmiştir. Çalışmada kullanılan değişkenlerin temin edildiği kaynaklara Ek-2'de yer verilmiştir.

3.4. Çalışma Konusu Hisselerin Belirlenmesi

Çalışma kapsamında, Garanti Bankası A.Ş. A Grubu Payı (GARAN), Petkim Petrokimya Holding A.Ş. A Grubu Payı (PETKM) ve Türk Hava Yolları Anonim Ortaklığı A Grubu Payı (THYAO) hisse senedi değerleri tahminlerde kullanılmıştır.

31.01.2019 tarihli ve 7/168 sayılı Sermaye Piyasası Kurulu (SPK) Kararınca A grubu paylar, fili dolaşımındaki pay değeri bakımından BİST tarafından belirlenen değerlendirme dönemi ve kriterlerince 30 milyon TL ve üstü değeri olan paylardır. Bu paylar, sürekli müzayedede işlem yöntemine tabi olup, kredili alım, açığa satış, ödünç alma veya ödünç verme işlemlerine konu olabilir. (Anonim, 2019)

Çalışmada şirket özel durumuna ait (yönetim değişikliği, temettü dağıtımı) sisteme dahil edilmeyen hisse fiyat belirleyicilerin etkisini azaltmak için birden fazla firma üzerinde araştırmalar yürütülmüştür. Kullanılan hisseler spekülatif hareketlerin veri üzerindeki etkisinin azalması için likiditesi yüksek olan BİST-30 endeksinde yer alan A grubu paylardan seçilmiştir. Hisselerin çalışma dönemi başlangıcından uzun süre önce Borsa kotasyonunun yapılmış olmasına dikkat edilmiştir. Seçili hisselerden üçü de 1990 yılında Borsada işlem görmeye başlamıştır. Firmalar olası sektörel farkları görmek adına farklı sektörlerden seçilmiştir. Ayrıca hisselerin volatilitesi yüksek bir hisse THYAO, salınan bir hisse GARAN ve yönlü değer değişimi durağan bir hisse PETKM olmasına özen gösterilmiştir. İlgili hisselerin çalışma dönemindeki ay sonu değerleri Şekil 3.6'daki gibidir.



Şekil 3.6. 2009-2018 Hisse Senedi Ay Sonu Kapanış Değerleri

3.5. Değişken Olarak Kullanılan Finansal Oranlar

Değişken olarak kullanılan finansal oranlar, TCMB Sektör Bilançoları çalışmaları kapsamında sektör bilançosu değerlendirmede kullanılan oranlarla (Anonim, 2015) literatürde yer alan yatırımcıların sıkılıkla kullandığı oranlardan ilgili firma bilanço ve gelir tabloları kullanılarak temin edilmiştir.

Finansal şirketler ile reel sektör firmaları arasında bilanço farklılıklarından dolayı bazı finansal oranların hesaplanmasında ayırmalar bulunmaktadır. Örneğin cari oran sadece reel sektör firmaları için hesaplanır. Bu nedenle, çalışma kapsamında

incelenecek 3 firma hisse senedi GARAN, THYAO ve PETKM için hangi finansal oranların kullanıldığı Çizelge 3.2.-3.6. arasında ifade edilmiştir.

3.5.1. Likidite Oranları

Likidite oranları, işletmenin kısa süreli borçlarını ödeyebilme gücünün ve çalışma sermayesinin yeterli olup olmadığını tespitinde kullanılır. (Köse, 2005)

Çizelge 3.2. Likidite Oranları

Oran Adı	Formülü	Açıklaması	İlgili Hisse
Cari Oran	Dönen Varlıklar / Kısa Vadeli Yabancı Kaynaklar	Tüm dönen varlıkların kısa vadeli borçları karşılama gücünü gösterir.	THYAO, PETKM
Asit – Test Oranı	(Dönen Varlıklar - Stoklar) / Kısa Vadeli Yabancı Kaynaklar	Kısa vadeli borcu karşılama gücünü gösterir.	THYAO, PETKM
Nakit Oranı	(Hazır Değerler + Menkul Kıymetler) / Kısa Vadeli Yabancı Kaynaklar	Nakit girişi olmaksızın kısa vadeli borçların ödenebilme durumunu gösterir.	THYAO, PETKM

3.5.2. Faaliyet Oranları

Faaliyet oranları işletmeye ait olan satışlar ile varlık grupları arasındaki ilişkinin boyutunu incelemektedir. İşletmenin etkin çalışıp çalışmadığının gözlenmesinde kullanılırlar (Gümüş ve ark., 2017).

Çizelge 3.3. Faaliyet Oranları

Oran Adı	Formülü	Açıklaması	İlgili Hisse
Stok Devir Hızı	Satılan Ticari Malların Maliyeti / Ortalama Ticari Mal Stoku	Stokların bir yıl içinde kaç kez paraya dönüştürüldüğünü ifade eder.	THYAO, PETKM
Alacak Devir Hızı	Net Satışlar / Aktif Ortalama Ticari Alacaklar	İşletmenin alacaklarını ne kadar süre içinde tahsil ettiğini gösterir	THYAO, PETKM
Aktif Devir Hızı	Net Satışlar / Aktif Toplamı	İşletmenin varlıklarının satışlarıyla ilişkisini gösterir.	THYAO, PETKM

3.5.3. Finansal Yapı Oranları

Tamamen bilanço kalemleri ile hesaplanır, şirketin varlıklarını finanse ederken kullandığı kaynak hakkında bilgi verir. (Özkaynak – Borçlar ilişkisi)

Çizelge 3.4. Finansal Yapı Oranları

Oran Adı	Formülü	Açıklaması	İlgili Hisse
Kaldırıcı Oranı	Toplam Yabancı Kaynak / Pasif Toplamı	Varlıkların yüzde kaçının yabancı kaynakla finanse edildiğini gösterir.	THYAO, PETKM
Kısa Vadeli Yabancı Kaynak Oranı	Kısa Vadeli Yabancı Kaynaklar / Pasif Toplamı	İktisadi varlıkların kısa vadeli yabancı kaynaklarla karşılanan bölümünü gösterir.	THYAO, PETKM
Uzun Vadeli Yabancı Kaynak Oranı	Uzun Vadeli Yabancı Kaynaklar / Pasif Toplamı	İktisadi varlıkların uzun vadeli yabancı kaynaklarla karşılanan bölümünü gösterir.	GARAN, THYAO, PETKM
Öz Kaynak Oranı	Öz Kaynaklar / Pasif Toplamı	Varlıkların ne kadarının işletme sahipleri tarafından finanse edildiğini gösterir.	GARAN, THYAO, PETKM
Yabancı Kaynakların Öz Kaynaklara Oranı	Toplam Yabancı Kaynaklar / Öz Kaynaklar	Yabancı kaynaklar ile öz kaynaklar arasındaki ilişkiyi gösterir.	THYAO, PETKM

3.5.4. Karlılık (Rantabilite) Oranları

Kârlılık oranları, işletmenin faaliyetleri sonucunda ölçülebilir ve yeterli bir kâr elde etmediğini ölçmeye yarar. (Gümüş ve ark., 2017)

Çizelge 3.5. Karlılık Oranları

Oran Adı	Formülü	Açıklaması	İlgili Hisse
Ekonominik Rantabilite	Vergi ve Faiz Önceki Kar / Pasif Toplamı	Kaynak kullanımındaki verimi gösterir.	THYAO, PETKM
Hisse Başına Getiri	Net Kar / Dolaşımındaki Hisse Sayısı	Hisse senedi değerini gösterir.	GARAN, THYAO, PETKM
İş Hacmi Rantabilitesi	Faaliyet Kârı / Net Satışlar	İşletme faaliyetlerinin kârlılığı ne derece etkilediğini gösterir.	THYAO, PETKM
Dönen Varlık Rantabilitesi	Net Kâr / Dönen Varlıklar	Kaynak kullanımındaki verimi gösterir.	GARAN, THYAO, PETKM

3.5.5. Hisse Bazlı Oranlar

Şirket hissesinin piyasa performansını doğrudan gösteren, yatırımcılar tarafından yakından takip edilen oranlardır. (Korkmaz ve Karaca, 2013)

Çizelge 3.6. Hisse Bazlı Oranlar

Oran Adı	Formülü	Açıklaması	İlgili Hisse
Fiyat/Kazanç Oranı	Hisse Güncel Fiyatı / Hisse Başına Kar	Şirketin birim karı içi yatırımcının ödemeye razı olduğu fiyatı gösterir.	GARAN, THYAO, PETKM
Piyasa Fiyatı/Defter Değeri Oranı	Hisse Senedi Güncel Fiyatı / Hisse Senedi Defter Değeri	Hisse senedinin piyasa fiyatı ile muhasebe değeri farkını gösterir.	GARAN, THYAO, PETKM
Fiyat - Satış Oranı	Firma Değeri / Net Satışlar ((İşletmenin Piyasa Değeri + Net Nakitler) / Net Satışlar)	Firmanın değerinin iş hacminin kaç katı olduğunu gösterir.	THYAO, PETKM

3.6. Algoritmada Kullanılan Diğer Değişkenler

Çalışmada finansal oranlardan başka girdi değişkenleri de kullanılmıştır. Bu değişkenlerin tamamı Ek-2'de gösterilmiştir. Hangi değişken türünden kaç adet kullanıldığı Çizelge 3.7'de özetlenmiştir.

Çizelge 3.7. Değişken Grupları

Değişken Türü	Açıklama	Adet
Hisse Değişkenleri	Hisseye bağlı, hisse değeri ile değişen değerler	4
Teknik Analiz Değişkenleri	Yatırımcılarda sık kullanılan hareketli ortalamalar	5
Endeks Değişkenleri	BIST 100 ve bazı büyük piyasa endeksi değerleri	24
Para Birimi & Emtia Fiyat Değişkenleri	Parite ve altın fiyatları değerleri	18
BİST Detay Değişkenleri	BİST alt endeks değer ve getiri değerleri	10
Makro Değişkenler	Para arzı, rezerv, bütçe değerleri ve ulusal anket sonuçları	36
Enflasyon Değişkenleri	Genel ve özel kapsamlı enflasyon göstergeleri	5
TOPLAM		102

3.7. Kayıp Verilerin Tamamlanması (Imputation)

Çalışma kapsamında kullanılan 120 değişkenden 21'i üçer aylık periyotlarla yayına makta olup diğer aylara ait veriler bulunmamaktadır.

Yapılan literatür araştırmalarına kayıp verilerin mevcudiyeti durumunda araştırmacıların, yeni gözlem temini, kayıp verisi olan gözlemlerin veri setinden çıkarılması, veya kayıp verilere ilişkin diğer verilerden faydalananarak tahmin yapılması ve bu tahmin değerlerinin kayıp veriler yerine kullanılması yollarından birisini tercih ettiği görülmüştür (Roth, 1994). Veriye yeni gözlemler eklemek her zaman mümkün olmamaktadır, örneğin GARAN hisse senedine ait üç aylık oranların firmadan aylık temin edilmesi söz konusu değildir. Kayıp verili gözlemlerin veri setinin dışında bırakılması ise gözlem sayısını azaltabileceği gibi önemli değişkenlerin göz ardı edilmesine de neden olabilir. Bu nedenle çalışmada kayıp veriler için tahmini değerler belirlenerek bunların kullanılması yoluna gidilmiştir.

Çalışmada üç aylık verisi bulunan değişkenlere ait kayıp verilerin tahmin yöntemi olarak doğrusal extrapolasyon (linear extrapolasyon) kullanılmıştır. Birbirini takip eden $X_1, X_2, X_3, X_4, X_5, X_6, X_7$ aylarından X_1 ve X_4 'e ait verilerin olduğu X_2, X_3, X_5 ve X_6 'ya ait verilerin bulunmadığı düşünüldüğünde bu değerlerden X_5 'in bulunması Eşitlik 3.7 ile X_6 'nın bulunması Eşitlik 3.8 ile yapılmıştır.

$$X_5 = \frac{X_4 - X_1}{3} + X_4 \quad (3.7)$$

$$X_6 = \frac{2*(X_4 - X_1)}{3} + X_4 \quad (3.8)$$

Bu yöntemlerle kayıp verisi olan 21 değişkenin 2009 Mart – 2018 Aralık dönemi için 78'er verisi tamamlanmıştır. Bu rakam toplam verinin (118 gözlem x 120 değişken = 14160) yaklaşık %11'ine denk gelmektedir.

3.8. Verilerin Normalleştirilmesi

Veri setlerinde bulunan değişkenlerin aldıkları değerlerin birbirinden parametrik değerleri (ortalama ve varyans) olarak farklılaşmasından dolayı öğrenme aşamasını hızlandırmak için normalleştirme (normalizasyon) uygulamalarının kullanılmasına ihtiyaç duyulmuştur. Uygulama Eşitlik 3.9'da görüldüğü gibi yapılmıştır. Bu çalışmada, veri grubundaki en küçük değerin 0, en büyük değerin 1 değeri aldığı ve diğer verilerin [0,1] aralığına dağıtıldığı minimum-maksimum normalleştirme (min-max normalization) yöntemi kullanılmıştır. Bu yöntem zaman serilerinden gelen verilerde aykırı (outlier) veri olma oranının düşüklüğü nedeniyle dezavantajlı bir durum yaşanmayacağı öngörülerek çözüm hızını daha iyi artırdığı için Z-Skor normalleştirme yöntemine göre tercih edilmiştir.

$$\frac{\text{Değer} - \text{Minimum Değer}}{\text{Maksimum Değer} - \text{Minimum Değer}} \quad (3.9)$$

Normalleştirme süreçleri değerlendirildiğinde önemli bir konu olan normalleştirme prosedürünün eğitim ve test veri setlerine ayrı ayrı mı yoksa tüm veri setine aynı anda mı uygulanacağı problemi ortaya çıkmaktadır. Bu noktada, modeller oluşturulurken hiçbir şekilde kullanılmayan test veri setindeki gözlem değerlerinden genel popülasyon parametrelerinin etkilenmemesi için eğitim ve test veri setlerine ayrı

ayrı normalleştirme yapılmış, ancak eğitim ve test veri setlerinin popülasyon parametreleri olarak iki farklı grup elde edilmesinin önüne geçmek için (Hsu ve ark., 2003) önerdiği üzere eğitim veri setinden elde edilen μ ve σ parametreleri test veri setinin normalleştirilmesinde kullanılmıştır.

3.9. Verilerin Uygulamaya Hazırlanması

1. 120 değişkene ve tahmin edilecek 3 hisse değerine ait 2008 Haziran – 2018 Aralık arası aylık – 3 aylık veriler temin edilmiştir.
2. BÜD ve BHO 2-3-6 aylık olarak hesaplanmıştır.
3. Hisse değerine bağlı 9 değişken (Açılış GAP’ı, volatilite, tabana uzaklık, tavana uzaklık, 2-3-6 aylık BHO’lar ve 2-6 aylık BÜD’ler) ve firma finansal tablolarına bağlı 18 değişken (GARAN için 6) her firma için ayrı ayrı yazılmış, diğer 93 değişken her firmada ortak olarak gruplanmıştır.
4. Verileri 3’er aylık dönemler halinde mevcut olan 21 değişkenin (GARAN için 12) kayıp verileri doğrusal extrapolasyon yöntemi ile tamamlanmıştır.
5. Tahmin edilecek hisse değeri verisi dahil bütün değişkenlerin bir önceki aya yönelik yüzde değişimleri Eşitlik 3.10 ile bulunmuştur.

$$t \text{ zamanı değişim değeri} = \frac{t \text{ zamanı değeri} - (t-1) \text{ zamanı değeri}}{(t-1) \text{ zamanı değeri}} \quad (3.10)$$

6. Tahminler gelecek dönem hisse değerlerine yönelik yapıldığı için t-1 dönemini değişken değerleri ile t dönemini hisse değerleri eşleştirilmiştir.
7. Bütün hisse değeri değişimi bağımlı değişkenleri öğrenme grubu verisinin 1. çeyrek değeri, medyan ve 3. çeyrek değerlerine göre Çizelge 3.8’de görüldüğü gibi 4 gruba ayrılmıştır. Bu gruplara küçükten büyüğe 1, 2, 3, 4 değerleri atanmıştır.
8. Öğrenme grubunda yer alan gözlem değişkenlerinin her birine kendi içerisinde normalleştirme uygulanmış ve değerleri [0-1] aralığına getirilmiştir.

Çizelge 3.8. Bağımlı Değişken Hisse Senedi Değeri Gruplaması

Gruplar	1. Grup	2. Grup	3. Grup	4. Grup
---------	---------	---------	---------	---------

Grup Değer Aralığı	[Minimum Değer, 1. Çeyrek Değeri)	[1. Çeyrek Değeri, Medyan Değeri)	[Medyan Değeri, 3. Çeyrek Değeri]	(3. Çeyrek Değeri, Maksimum Değer]
Atanan Değer	1	2	3	4

3.10. Çapraz Doğrulama (k- Fold Cross Validation)

Denetimli makine öğrenmesi algoritmalarında yanlışlık ve yüksek varyans değerlerini engellemek için veriler öğrenme ve test verileri olarak iki gruba ayrılmıştır. Öğrenme verileriyle eğitilen algoritmanın kalitesi test verilerine uygulanarak ispatlanmaktadır. Gözlem sayısının yüksek olduğu durumlarda %80 öğrenme verisi sonucu elde edilen parametrelerin %20 test verisine uygulanması gibi yöntemler uygulanabilirken (Holdout yöntemi) veri sayısının az olduğu durumlarda örnekleme (sampling) yöntemlerinin uygulanması tercih edilmektedir. Bu çalışmada örnekleme metodu olarak, torbalama (bootstrap) metodu ile beraber literatürde en sık kullanılan k-katlı çapraz doğrulama metodu örnekleme metodu olarak tercih edilmiştir.

k katlı çapraz doğrulama metodunda veriler eşit büyüklükte k adet ayrık alt gruba ayrılır. Sonra, bu k adet alt gruptan birisi test grubu olarak seçilir ve diğer k-1 alt grup üzerinde makine öğrenmesi sınıflandırıcısının öğrenme işlemi yapılır. Bu öğrenme işlemi sonucu performans elde edilen parametreler test grubuna uygulanarak gösterilir. Bu işlemde k adet alt grubun her biri bir kez test grubu yapılarak tüm veri seti için tekrarlanarak k adet test grubunun performansı sınıflandırıcının eldeki veri seti üzerinde oluşan performansını gösterir (Kohavi, 2001).

Çalışmada k kat sayısı belirlenirken hesaplama zamanı, test verilerinde yeterince gözlemin kalması, literatürdeki genel kullanım durumu gibi kriterler göz önünde bulundurularak 5 katlı çapraz doğrulama Çizelge 3.9.'daki gibi uygulanmıştır (James ve ark., 2013).

Çizelge 3.9. 5 Katlı Çapraz Doğrulama

1. İterasyon	Öğrenme	Öğrenme	Öğrenme	Öğrenme	Test
2. İterasyon	Öğrenme	Öğrenme	Öğrenme	Test	Öğrenme
3. İterasyon	Öğrenme	Öğrenme	Test	Öğrenme	Öğrenme
4. İterasyon	Öğrenme	Test	Öğrenme	Öğrenme	Öğrenme
5. İterasyon	Test	Öğrenme	Öğrenme	Öğrenme	Öğrenme

3.11. Değerlendirme Kriterleri

Çalışma kapsamında değerlendirme kriteri olarak hata matrisi (confusion matrix) kullanılmıştır. Hata matrisi (Kohavi ve Provost, 1998), bir sınıflandırma probleminde gerçek değerlerle makine öğrenmesi algoritmasının tespit ettiği değerlerin sayısını bir arada gösteren, bir matris tablosudur. Hata matrisleri ikili (binary) sınıflandırma problemlerinde kullanılabildiği gibi çoklu sınıflandırma problemlerinde de kullanılabilir.

Çalışma kapsamında, önceki bölümde belirtildiği üzere 4 çıktılı bir yapı kurulmuş ve bu yapılar üzerinden tahmin yapılmıştır. Ayrıca örneklem medyan değerlerinin 0'a yakın olması nedeniyle hisse değerinin azalma grubu denilebilecek 1. ve 2. gruplar bir arada; artma grubu denilebilecek 3. ve 4. gruplar bir arada sınıflandırılarak algoritmaların hisse değeri artış-azalışlarını doğru tahmin etme yeteneği de araştırılmıştır.

Çizelge 3.10. 4 gruplu sınıflandırma hata matrisi

		Tahmin Edilen Değer			
		Grup 1	Grup 2	Grup 3	Grup 4
Gerçek Değer	Grup 1	X _{1,1}	X _{2,1}	X _{3,1}	X _{4,1}
	Grup 2	X _{1,2}	X _{2,2}	X _{3,2}	X _{4,2}
	Grup 3	X _{1,3}	X _{2,3}	X _{3,3}	X _{4,3}
	Grup 4	X _{1,4}	X _{2,4}	X _{3,4}	X _{4,4}

Çizelge 3.10'da verilen hata matrisinde gri renkli alanlar tahmin edilen değerin gerçek değer olduğunu, yani doğru tahmin yapılan değer sayılarını göstermektedir. Dolayısıyla doğruluk oranı (accuracy) Eşitlik 3.11 ile hesaplanır.

$$\text{Doğruluk Yüzdesi} = \frac{X_{1,1} + X_{2,2} + X_{3,3} + X_{4,4}}{\text{Toplam Örneklem Sayısı}} * 100 \quad (3.11)$$

Çizelge 3.11. Hisse yönü sınıflandırma hata matrisi

		Tahmin Edilen Değer			
		Grup 1	Grup 2	Grup 3	Grup 4
Gerçek Değer	Grup 1	X _{1,1}	X _{2,1}	X _{3,1}	X _{4,1}
	Grup 2	X _{1,2}	X _{2,2}	X _{3,2}	X _{4,2}
	Grup 3	X _{1,3}	X _{2,3}	X _{3,3}	X _{4,3}
	Grup 4	X _{1,4}	X _{2,4}	X _{3,4}	X _{4,4}

Çizelge 3.11'de verilen hata matrisinde de gri renkli verilen alanlar doğru kabul edilmiştir. Bu alanlar hisse değerinin grup olarak yanlış tahmin edildiği ancak yön olarak doğru tahmin edildiği grupları da kapsamaktadır. Dolayısıyla hisse senedi hareket yönünün doğru tahmin edilme oranı Eşitlik 3.12 ile hesaplanır.

$$\text{Doğruluk Yüzdesi} = \frac{X_{1,1} + X_{1,2} + X_{2,1} + X_{2,2} + X_{3,3} + X_{3,4} + X_{4,3} + X_{4,4}}{\text{Toplam Örneklem Sayısı}} * 100 \quad (3.12)$$

Doğruluk yüzdesi hesaplama yöntemlerini bir örnekle açıklamak gereklidir:

20 gözlem olan bir çalışma seti beşer elemandan oluşan dört gruba ayrılsın. Algoritma eğer grup 1'de yer olması gereken 5 elemandan 4'ünü; grup 2 için 3'ünü; grup 3 için 2'sini ve grup 4 için 3'ünü doğru tahmin etti ise:

Gruplama doğruluk yüzdesi $(4+3+2+3)/20 = \%60$ 'tir.

Yukarıdaki örneğin devamı olarak algoritma eğer grup 1'de yer olması gereken 5 elemandan 1'ini grup 2'de sınıflandırdıysa; aynı şekilde grup 2 için 1'ini grup 1'de; grup 3 için 2'sini grup 4'te ve grup 4 için 1'ini grup 3'te sınıflandırdıysa:

Yön tahmini doğruluk yüzdesi $((4+3+2+3)+(1+1+2+1))/20 = \%85$ 'tir.

Bu işlemler 10 iterasyonun her biri için yapılmış, bulunan doğruluk oranlarının gruplama ve yön tahmini için ayrı ayrı ortalaması alınarak gözlem sayıları ile çarpılmış, bulunan değerler en yakın tam sayıya yuvarlanarak hata matrislerine yazılmıştır.

Gruplanan verilerdeki veri sayısı dengesiz olan çalışmalarda doğruluk oranı yeterli bir değerlendirme kriteri olmadığı için pozitif tahminlerin gerçek değerlerinin pozitif olması ya da negatif tahminlerin gerçek değerlerinin negatif olması gibi daha detaylı değerlendirme kriterlerinin de belirlenmesi gerekmektedir (Kubat ve Matwin, 1997). Ancak çalışmada gruplara tahmin değerleri ve gerçek değerler eşit-yaklaşık dağıtıldığı için detay değerlendirme kriterlerine ihtiyaç duyulmamıştır.

3.12. Kullanılan Yazılımlar ve Çözüm Ortamı

Verileri düzenleme ve ham veri setini oluşturulması aşamalarında Microsoft Excel 2016 kullanılmıştır. Önerilen algoritmanın çözümü MATLAB programında (Versiyon 7.1) neural network toolbox eklentisi kullanılarak yapılmıştır. Kıyaslama yapılan algoritmalar ise WEKA programında (Versiyon 3) ilgili algoritmala- rına ilişkin makine öğrenmesi algoritmaları kullanılarak çözülmüştür.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

2009 Mart – 2018 Aralık arası 118 aya ait aylık hisse senedi kapanış fiyat yüzde değişimleri, üç hisse senedinin her biri için Çizelge 4.1.’de gösterildiği şekliyle en düşükten en yükseğe doğru sıralanarak gözlem sayılarına göre grüplanarak sınıflandırılmıştır. Örneğin PETKM hisse senedinin aylık değişimi en negatif olan -%30.96 ile -%2.39 arasında değişim yaşamış 30 aylık değeri o hisse senedinin 1. Grubu olarak seçilmiştir. Küçükten büyüğe dizilişte sıradaki 29 veri Grup 2, ardından gelen 29 veri Grup 3 ve sona kalan en yüksek aylık artış yüzdesi değerlerini gösterir 30 veri ise Grup 4’e atanmıştır.

Çizelge 4.1. Verilerin Grüplanması ve Değer Aralıkları

	Grup 1		Grup 2		Grup 3		Grup 4	
	MİNİMUM	MAKSİMUM	MİNİMUM	MAKSİMUM	MİNİMUM	MAKSİMUM	MİNİMUM	MAKSİMUM
PETKM	-30.96%	-2.39%	-2.20%	1.65%	1.67%	7.54%	7.72%	31.77%
THYAO	-26.40%	-5.08%	-5.00%	1.56%	1.58%	10.79%	10.87%	34.02%
GARAN	-16.32%	-5.19%	-5.12%	0.14%	0.18%	7.76%	8.52%	42.57%
Gözlem Sayıları	30		29		29		30	

YSA algoritması farklı parametre değerleri ve veri hazırlık yöntemleri ile test edilmiş, yapılan denemeler sonucunda en iyi sonuç veren YSA modeli çalışma kapsamında önerilmek üzere seçilmiştir. Deneme yapılan modellemelere dair parametre ve yöntemler Çizelge 4.2.’de verilmiştir.

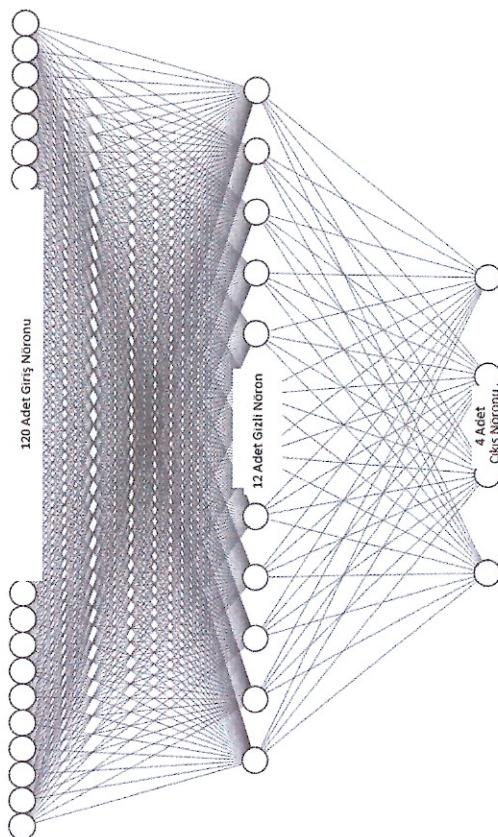
Çizelge 4.2. Denemesi Yapılan YSA Parametre Değerleri & Yöntemleri

Parametre Değeri & Yöntem	Deneme Değeri	Önerilen Değer
Gizli Katman Sayısı	1, 2	1
Gizli Katman Nöron Sayısı	6, 8, 10, 12, 16	12
Momentum Sabiti	0.1, 0.2, 0.3	0.2
Öğrenme Hızı	0.15, 0.2, 0.3, 0.4	0.3
Aktivasyon Fonksiyonu	Sigmoid RELU	Sigmoid
Normalleştirme Yöntemi	Min-Max, Z-Score	Min-Max
Epoch	2000	2000
Çapraz Doğrulama	5	5
İterasyon Sayısı	10	10

Önerilen denetimli YSA algoritmasında bir giriş katmanı, bir çıkış katmanı ve bir gizli katman kullanılmıştır. Giriş katmanında değişken sayısı kadar nöron (THYAO ve PETKM için 120; GARAN için 108), çıkış katmanında her grup için 1 olmak üzere 4

nöron ve gözlem sayısının azlığından validasyon seti (validation set) ayrıca oluşturulmayarak, yapılan ön çalışmalar sonucunda en iyi sonuçları verdiği için gizli katmanda 12 nöron kullanılmıştır. Önerilen YSA'nın genel yapısı Şekil 4.1.'de verilmiştir.

Yine deneysel çalışmalarında en iyi sonuçları verdiginden dolayı, öğrenme hızı parametresi 0.3, momentum sabiti 0.2 alınmıştır. Ağırlıkların başlangıç değerleri [0,1] aralığında rasgele belirlenmiş olup ağırlık güncellemede gradyant azaltma metodu kullanılmıştır. Öğrenme sürecinde epoch 2000 alınmıştır. Çıkış katmanı ağırlık değeri en yüksek çıkış nöronunu tahmin grubu olarak seçmektedir. Diğer algoritmalar WEKA programında yer alan varsayılan parametre değerleriyle hesaplanmıştır. İlgili algoritma varsayılan değerleri Ek-3'te verilmiştir. Dört algoritmada da 5 katlı çapraz doğrulama uygulanmıştır.



Şekil 4.1. Önerilen Algoritma Şeması

Bütün algoritmaların her bir hisse senedi için 10'ar defa tekrarlaması (iteration) yapılmış ve gruplar için bulunan sonuçların ortalama değeri alınıp en yakın tam sayıya yuvarlanarak grafiklere aktarılmıştır.

4.1. GARAN Sonuçlar

Çizelge 4.3. GARAN YSA Tahmin Sonuçları

		YAPAY SINİR AĞLARI			
		Tahmin Edilen Değer			
		Grup 1	Grup 2	Grup 3	Grup 4
Gerçek Değer	Grup 1	15	7	5	3
	Grup 2	5	13	8	3
	Grup 3	3	8	9	9
	Grup 4	4	6	7	13
		Tahmin Edilen Değer			
Gerçek Değer	Grup 1	Grup 1		19	67.80%
	Grup 2	40			
	Grup 3	21		38	64.41%
	Grup 4				

GARAN için Çizelge 4.3.'te sonuçlarına yer verilen YSA algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %50 ve %43,33 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%0,14 ve altı) değerlerden oluşan 1. ve 2. Grupları %67,80; artan değerlerden oluşan (%0,18 ve üstü) 3. ve 4. Grupları %64,41 oranında doğru tespit etmiştir.

Çizelge 4.4. GARAN LR Tahmin Sonuçları

		LOJİSTİK REGRESYON			
		Tahmin Edilen Değer			
		Grup 1	Grup 2	Grup 3	Grup 4
Gerçek Değer	Grup 1	14	5	9	2
	Grup 2	6	7	8	7
	Grup 3	6	5	8	10
	Grup 4	5	6	8	11
		Tahmin Edilen Değer			
Gerçek Değer	Grup 1	Grup 1		26	55.17%
	Grup 2	32			
	Grup 3	22		37	62.71%
	Grup 4				

GARAN için Çizelge 4.4.'te sonuçlarına yer verilen YSA algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %46,67 ve %36,67 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%0,14 ve altı) değerlerden oluşan 1. ve

2. Grupları %55,17; artan değerlerden oluşan (%0,18 ve üstü) 3. ve 4. Grupları %62,71 oranında doğru tespit etmiştir.

Çizelge 4.5. GARAN NBS Tahmin Sonuçları

		NAİVE BAYES			
		Tahmin Edilen Değer			
Gerçek Değer	Grup 1	6	10	9	5
	Grup 2	9	6	9	5
	Grup 3	5	6	14	4
	Grup 4	6	7	9	8
	Tahmin Edilen Değer				
Gerçek Değer	Grup 1	31		28	
	Grup 2	24		35	
	Grup 3				
	Grup 4				

GARAN için Çizelge 4.5.'te sonuçlarına yer verilen NBS algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %20 ve %26,67 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%0,14 ve altı) değerlerden oluşan 1. ve 2. Grupları %52,54; artan değerlerden oluşan (%0,18 ve üstü) 3. ve 4. Grupları %59,32 oranında doğru tespit etmiştir.

Çizelge 4.6. GARAN RO Tahmin Sonuçları

		RASTGELE ORMAN			
		Tahmin Edilen Değer			
Gerçek Değer	Grup 1	17	2	5	6
	Grup 2	7	8	8	6
	Grup 3	7	8	8	6
	Grup 4	4	5	10	11
	Tahmin Edilen Değer				
Gerçek Değer	Grup 1	34		25	
	Grup 2	24		35	
	Grup 3				
	Grup 4				

GARAN için Çizelge 4.6.'da sonuçlarına yer verilen RO algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %56,67 ve %36,67 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%0,14 ve altı) değerlerden oluşan 1. ve

2. Grupları %57,63; artan değerlerden oluşan (%0,18 ve üstü) 3. ve 4. Grupları %59,32 oranında doğru tespit etmiştir.

Çizelge 4.7. GARAN DVM Tahmin Sonuçları

		DESTEK VEKTÖR MAKİNELERİ				
		Tahmin Edilen Değer				
Gerçek Değer	Grup 1	14	5	9	2	46.67%
	Grup 2	6	10	6	7	34.48%
	Grup 3	5	5	9	10	31.03%
	Grup 4	5	5	8	12	40.00%
		Tahmin Edilen Değer				
Gerçek Değer	Grup 1	35		24		59.32%
	Grup 2	20		39		66.10%
	Grup 3					
	Grup 4					

GARAN için Çizelge 4.7.'de sonuçlarına yer verilen DVM algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %46,67 ve %40 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%0,14 ve altı) değerlerden oluşan 1. ve 2. Grupları %59,32; artan değerlerden oluşan (%0,18 ve üstü) 3. ve 4. Grupları %66,10 oranında doğru tespit etmiştir.

Çizelge 4.8. GARAN Genel Tahmin Sonuçları

GARAN		YSA	NB	LR	RO	SVM
Doğruluk Oranı	Gruplama	42.37%	28.81%	34.19%	37.29%	38.14%
	Grup 1,2 - Grup 3,4	66.10%	55.93%	58.97%	58.47%	62.71%
	Grup 1,4	46.67%	23.33%	41.67%	46.67%	43.33%
	Grup 1 ise, Grup 1,2	73.33%	53.33%	63.33%	63.33%	63.33%
	Grup 4 ise, Grup 3,4	66.67%	56.67%	63.33%	70.00%	66.67%

Sonuç olarak GARAN hisse senedi için belirlenen 2009 Mart – 2018 Aralık döneminde 118 gözlem üzerinde yapılan çalışmada; en iyi gruplamayı %42,37 ile 118 gözlemin ortalama 50'sini doğru sınıflandıran YSA algoritması yapmıştır. Azalan – artan değerler ayrimı olarak değerlendirebilecek Grup 1,2 ve Grup 3,4 ayrimını da en iyi %66,10 ile doğru sınıflandıran YSA yapmıştır. Üç gruplar olan grup 1 ve 4'ü %46,67 ile RO ile beraber en iyi YSA sınıflamıştır. 1. Grup verilerinin azalan olduğunu

%73,33 ile en iyi tahmin eden YSA'dır. 4. Grup verilerinin artan olduğunu ise %70 ile en iyi tahmin eden RO olmuştur.

Önerilen YSA algoritması gruplamayı, artan – azalan gruplarının tespitini, üç grupların tespitini, 1. Grubun azalan gözlemlerden oluştuğunu tespitini en iyi yapan algoritma olmuştur. 4. Grubun artan gözlemlerden oluştuğunu ise %66,67 ile tahmin etmiştir. Gözlem sonuçlarına göre önerilen YSA algoritması, GARAN hisse senedi için belirlenen dönemde genelde en iyi sonuçları veren algoritmadır.

4.2. PETKM Sonuçlar

Çizelge 4.9. PETKM YSA Tahmin Sonuçları

		Tahmin Edilen Değer				
		Grup 1	Grup 2	Grup 3	Grup 4	
Gerçek Değer	Grup 1	15	5	5	5	50.00%
	Grup 2	6	11	5	7	37.93%
	Grup 3	5	5	11	8	37.93%
	Grup 4	5	6	8	11	36.67%
Gerçek Değer		Tahmin Edilen Değer				
		Grup 1	Grup 2	Grup 3	Grup 4	
		Grup 1	37	22		62.71%
		Grup 2				
		Grup 3	21	38		64.41%
		Grup 4				

PETKM için Çizelge 4.9.'da sonuçlarına yer verilen YSA algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %50 ve %36,67 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%1,65 ve altı) değerlerden oluşan 1. ve 2. Grupları %62,71; artan değerlerden oluşan (%1,67 ve üstü) 3. ve 4. Grupları %64,41 oranda doğru tespit etmiştir.

Çizelge 4.10. PETKM LR Tahmin Sonuçları

		LOJİSTİK REGRESYON			
		Tahmin Edilen Değer			
		Grup 1	Grup 2	Grup 3	Grup 4
Gerçek Değer	Grup 1	14	5	6	5
	Grup 2	4	12	7	6
	Grup 3	3	8	7	11
	Grup 4	4	5	13	8
		Tahmin Edilen Değer			
Gerçek Değer	Grup 1	35		24	
	Grup 2	20		39	
	Grup 3				
	Grup 4				

PETKM için Çizelge 4.10.'da sonuçlarına yer verilen LR algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %46,67 ve %26,67 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%1,65 ve altı) değerlerden oluşan 1. ve 2. Grupları %59,32; artan değerlerden oluşan (%1,67 ve üstü) 3. ve 4. Grupları %66,10 oranda doğru tespit etmiştir.

Çizelge 4.11. PETKM NBS Tahmin Sonuçları

		NAİVE BAYES			
		Tahmin Edilen Değer			
		Grup 1	Grup 2	Grup 3	Grup 4
Gerçek Değer	Grup 1	7	7	10	6
	Grup 2	8	9	8	4
	Grup 3	6	6	14	3
	Grup 4	6	7	9	8
		Tahmin Edilen Değer			
Gerçek Değer	Grup 1	31		28	
	Grup 2	25		34	
	Grup 3				
	Grup 4				

PETKM için Çizelge 4.11.'de sonuçlarına yer verilen NBS algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %23,33 ve %26,67 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%1,65 ve altı) değerlerden oluşan 1. ve 2. Grupları %52,54; artan değerlerden oluşan (%1,67 ve üstü) 3. ve 4. Grupları %57,63 oranda doğru tespit etmiştir.

Çizelge 4.12. PETKM RO Tahmin Sonuçları

		RASTGELE ORMAN			
		Tahmin Edilen Değer			
		Grup 1	Grup 2	Grup 3	Grup 4
Gerçek Değer	Grup 1	16	4	4	6
	Grup 2	5	6	10	5
	Grup 3	7	6	10	6
	Grup 4	7	8	7	8
		Tahmin Edilen Değer			
Gerçek Değer	Grup 1	Grup 1		Grup 3	Grup 4
	Grup 2	31		25	55.36%
	Grup 3	28		31	52.54%
	Grup 4				

PETKM için Çizelge 4.12.'de sonuçlarına yer verilen RO algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %53,33 ve %26,67 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%1,65 ve altı) değerlerden oluşan 1. ve 2. Grupları %55,36; artan değerlerden oluşan (%1,67 ve üstü) 3. ve 4. Grupları %52,54 oranda doğru tespit etmiştir.

Çizelge 4.13. PETKM DVM Tahmin Sonuçları

		DESTEK VEKTÖR MAKİNELERİ			
		Tahmin Edilen Değer			
		Grup 1	Grup 2	Grup 3	Grup 4
Gerçek Değer	Grup 1	14	5	6	5
	Grup 2	4	13	6	6
	Grup 3	3	8	7	11
	Grup 4	5	5	12	8
		Tahmin Edilen Değer			
Gerçek Değer	Grup 1	Grup 1		Grup 3	Grup 4
	Grup 2	36		23	61.02%
	Grup 3	21		38	64.41%
	Grup 4				

PETKM için Çizelge 4.13.'te sonuçlarına yer verilen DVM algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %46,67 ve %26,67 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%1,65 ve altı) değerlerden oluşan 1. ve 2. Grupları %61,02; artan değerlerden oluşan (%1,67 ve üstü) 3. ve 4. Grupları %64,41 oranda doğru tespit etmiştir.

Çizelge 4.14. PETKM Genel Tahmin Sonuçları

PETKM		YSA	NB	LR	RO	SVM
Doğruluk Oranı	Gruplama	40.68%	32.20%	34.75%	34.78%	35.59%
	Grup 1,2 - Grup 3,4	63.56%	55.08%	62.71%	53.91%	62.71%
	Grup 1,4	43.33%	25.00%	36.67%	40.00%	36.67%
	Grup 1 ise, Grup 1,2	66.67%	46.67%	63.33%	66.67%	63.33%
	Grup 4 ise, Grup 3,4	63.33%	56.67%	70.00%	50.00%	66.67%

Sonuç olarak PETKM hisse senedi için belirlenen 2009 Mart – 2018 Aralık döneminde 118 gözlem üzerinde yapılan çalışmada; en iyi gruplamayı %40,68 ile 118 gözlemin ortalama 48'ini doğru sınıflandıran önerilen YSA algoritması yapmıştır. Azalan – artan değerler ayrimı olarak değerlendirilebilecek Grup 1,2 ve Grup 3,4 ayrimını da en iyi %63,56 ile doğru sınıflandıran YSA yapmıştır. Uç gruplar olan grup 1 ve 4'ü %43,33 ile en iyi YSA sınıflamıştır. 1. Grup verilerinin azalan olduğunu %66,67 ile en iyi tahmin eden YSA ve RO'dur. 4. Grup verilerinin artan olduğunu ise %70 ile en iyi tahmin eden LR olmuştur.

Önerilen YSA algoritması gruplamayı, artan – azalan gruplarının tespitini, üç grupların tespitini, 1. Grubun azalan gözlemlerden oluştuğunu tespitini en iyi yapan algoritma olmuştur. 4. Grubun artan gözlemlerden oluştuğunu ise %63,33 ile tahmin etmiştir. Gözlem sonuçlarına göre önerilen YSA algoritması, PETKM hisse senedi için belirlenen dönemde genelde en iyi sonuçları veren algoritmadır.

4.3. THYAO Sonuçlar

Çizelge 4.15. THYAO YSA Tahmin Sonuçları

		Tahmin Edilen Değer				
		Grup 1	Grup 2	Grup 3	Grup 4	
Gerçek Değer	Grup 1	15	5	8	2	50.00%
	Grup 2	7	10	7	5	34.48%
	Grup 3	8	7	10	4	34.48%
	Grup 4	3	7	6	14	46.67%
Gerçek Değer		Tahmin Edilen Değer				
		Grup 1	Grup 2	Grup 3	Grup 4	
Grup 1	37		22		62.71%	
Grup 2						
Grup 3	25		34		57.63%	
Grup 4						

THYAO için Çizelge 4.15.'te sonuçlarına yer verilen YSA algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %50 ve %46,67 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%1,56 ve altı) değerlerden oluşan 1. ve 2. Grupları %62,71; artan değerlerden oluşan (%1,58 ve üstü) 3. ve 4. Grupları %57,63 oranında doğru tespit etmiştir.

Çizelge 4.16. THYAO LR Tahmin Sonuçları

		LOJİSTİK REGRESYON				
		Tahmin Edilen Değer				
Gerçek Değer	Grup 1	15	3	6	6	50.00%
	Grup 2	8	9	6	6	31.03%
	Grup 3	5	6	10	8	34.48%
	Grup 4	3	4	6	17	56.67%
	Tahmin Edilen Değer					
Gerçek Değer	Grup 1	35		24		59.32%
	Grup 2	18		41		69.49%
	Grup 3					
	Grup 4					

THYAO için Çizelge 4.16.'da sonuçlarına yer verilen LR algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %50 ve %56,67 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%1,56 ve altı) değerlerden oluşan 1. ve 2. Grupları %59,32; artan değerlerden oluşan (%1,58 ve üstü) 3. ve 4. Grupları %69,49 oranında doğru tespit etmiştir.

Çizelge 4.17. THYAO NBS Tahmin Sonuçları

		NAİVE BAYES				
		Tahmin Edilen Değer				
Gerçek Değer	Grup 1	11	8	5	6	36.67%
	Grup 2	4	12	8	5	41.38%
	Grup 3	4	7	10	8	34.48%
	Grup 4	4	10	7	9	30.00%
	Tahmin Edilen Değer					
Gerçek Değer	Grup 1	35		24		59.32%
	Grup 2	25		34		57.63%
	Grup 3					
	Grup 4					

THYAO için Çizelge 4.17.'de sonuçlarına yer verilen NBS algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %36,67 ve %30 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%1,56 ve altı) değerlerden oluşan 1. ve 2. Grupları %59,32; artan değerlerden oluşan (%1,58 ve üstü) 3. ve 4. Grupları %57,63 oranında doğru tespit etmiştir.

Çizelge 4.18. THYAO RO Tahmin Sonuçları

		Tahmin Edilen Değer			
		Grup 1	Grup 2	Grup 3	Grup 4
Gerçek Değer	Grup 1	10	7	7	6
	Grup 2	8	10	7	4
	Grup 3	9	4	10	6
	Grup 4	3	6	3	18
Gerçek Değer		Tahmin Edilen Değer			
		Grup 1	Grup 2	Grup 3	Grup 4
		35		24	
		22		37	

THYAO için Çizelge 4.18.'de sonuçlarına yer verilen RO algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %33,33 ve %60 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%1,56 ve altı) değerlerden oluşan 1. ve 2. Grupları %59,32; artan değerlerden oluşan (%1,58 ve üstü) 3. ve 4. Grupları %62,71 oranında doğru tespit etmiştir.

Çizelge 4.19. THYAO DVM Tahmin Sonuçları

		DESTEK VEKTÖR MAKİNELERİ			
		Tahmin Edilen Değer			
		Grup 1	Grup 2	Grup 3	Grup 4
Gerçek Değer	Grup 1	15	4	8	3
	Grup 2	3	12	7	7
	Grup 3	5	7	10	7
	Grup 4	6	7	6	11
Gerçek Değer		Tahmin Edilen Değer			
		Grup 1	Grup 2	Grup 3	Grup 4
		34		25	
		25		34	

THYAO için Çizelge 4.19.'da sonuçlarına yer verilen DVM algoritması üç gruplar Grup 1 ve Grup 4 gruplarına ait gözlemleri sırasıyla %50 ve %36,67 oranında doğru sınıflandırmıştır. Algoritma azalan ve az artan (%1,56 ve altı) değerlerden oluşan 1. ve 2. Grupları %57,63; artan değerlerden oluşan (%1,58 ve üstü) 3. ve 4. Grupları %57,63 oranında doğru tespit etmiştir.

Çizelge 4.20. THYAO Genel Tahmin Sonuçları

THYAO		YSA	NB	LR	RO	SVM
Doğruluk Oranı	Gruplama	41.53%	35.59%	43.22%	40.68%	40.68%
	Grup 1,2 - Grup 3,4	60.17%	58.47%	64.41%	61.02%	57.63%
	Grup 1,4	48.33%	33.33%	53.33%	46.67%	43.33%
	Grup 1 ise, Grup 1,2	66.67%	63.33%	60.00%	56.67%	63.33%
	Grup 4 ise, Grup 3,4	66.67%	53.33%	76.67%	70.00%	56.67%

Sonuç olarak THYAO hisse senedi için belirlenen 2009 Mart – 2018 Aralık döneminde 118 gözlem üzerinde yapılan çalışmada; en iyi gruplamayı %43,22 ile 118 gözlemin ortalama 51'ini doğru sınıflandıran LR algoritması yapmıştır. Azalan – artan değerler ayrimı olarak değerlendirilebilecek Grup 1,2 ve Grup 3,4 ayrimını da en iyi %64,41 ile doğru sınıflandıran LR yapmıştır. Üç gruplar olan grup 1 ve 4'ü %53,33 ile en iyi LR sınıflamıştır. 1. Grup verilerinin azalan olduğunu %66,67 ile en iyi tahmin eden YSA'dır. 4. Grup verilerinin artan olduğunu ise %76,67 ile en iyi tahmin eden LR olmuştur.

Önerilen YSA algoritması %41,53 ile 118 gözlemin ortalama 49'unu doğru sınıflamıştır. Artan – azalan gruplarını %60,71, üç grupları %48,33 ile sınıflamıştır. 1. Grubun azalan gözlemlerden oluştuğunu en iyi YSA tahmin ederken; 4. Grubun artan gözlemlerden oluştuğunu ise %66,67 ile tahmin etmiştir. Gözlem sonuçlarına göre önerilen YSA algoritması, THYAO hisse senedi için belirlenen dönemde genelde en iyi sonuçları veren LR'nin en güçlü alternatifidir.

4.4. Genel Sonuçlar

Çizelge 4.21. En İyi Sonuç Veren Algoritmalar

		THYAO	GARAN	PETKM
Doğruluk Oranı	Gruplama	LR	YSA	YSA
	Grup 1,2 - Grup 3,4	LR	YSA	YSA
	Grup 1,4	LR	YSA, RO	YSA
	Grup 1 ise, Grup 1,2	YSA	YSA	YSA, RO
	Grup 4 ise, Grup 3,4	LR	RO	LR

Çizelge 4.21.'de görüldüğü üzere önerilen YSA algoritması gözlemleri gruppalaşımada GARAN ve PETKM hisseleri için en iyi sonuçları vermiştir. THYAO için ise en iyi gruplama sonucu veren ikinci algoritmadır. Çizelge 4.22.'ye bakıldığından ise göz önünde bulundurulan 15 kriter için ise YSA 9 durumda en iyi sonucu verdiği; 3 durumda en iyi ikinci sonucu, 3 durumda da en iyi üçüncü sonucu veren algoritma olduğu görülmektedir. Gözlenen başarı kriterleri içerisinde YSA'nın en iyi sonucu vermediği bir durumda en iyi sonucu 5 durumda LR ve 1 durumda RO vermiştir.

Çizelge 4.22. Algoritma Doğruluk Oranı Sıralaması

		YSA	NB	LR	RO	SVM
Doğruluk Oranı	THYAO	Gruplama	2	5	1	3
		Grup 1,2 - Grup 3,4	3	4	1	2
		Grup 1,4	2	5	1	3
		Grup 1 ise, Grup 1,2	1	2	4	5
		Grup 4 ise, Grup 3,4	3	5	1	2
Doğruluk Oranı	GARAN	Gruplama	1	5	4	3
		Grup 1,2 - Grup 3,4	1	5	3	4
		Grup 1,4	1	5	4	1
		Grup 1 ise, Grup 1,2	1	5	2	2
		Grup 4 ise, Grup 3,4	2	5	4	1
Doğruluk Oranı	PETKM	Gruplama	1	5	4	3
		Grup 1,2 - Grup 3,4	1	4	2	5
		Grup 1,4	1	5	3	2
		Grup 1 ise, Grup 1,2	1	5	3	1
		Grup 4 ise, Grup 3,4	3	4	1	5

5. SONUÇLAR VE ÖNERİLER

Çalışmada t zamanı hisse senedi değeri değişim yüzdesi tahmini t-1 zamanı değişken değerleri kullanarak yapılmıştır. Borsa İstanbul'da (BİST) işlem gören GARAN, THYAO ve PETKM hisse senetlerinin 2009 Mart - 2018 Aralık tarihleri arasındaki 118 aylık kapanış fiyat değer değişimleri 4 grupta toplanıp 18 adet finansal oran içeren 120 girdi değişkeni kullanılarak YSA ile tahmin edilmiştir. Önerilen algoritma sonuçları, DVM, LR, NBS ve RO algoritmaları sonuçları ile kıyaslanmış ve göz önünde bulundurulan 15 kriterden 9'unda en iyi sonuç, 3'ünde en iyi ikinci sonuç, 3'ünde ise en iyi üçüncü sonuç önerilen algoritma ile tahmin edilmiştir.

Önerilen algoritma çalışma kapsamında incelenen üç gruplar olan Grup 1 ve Grup 4'te yer alan gözlemlerin yarıya yakınında doğru tahmin sonucuna ulaşmıştır. Araştırma kapsamında, kaynaklarda üzerinde en çok araştırma yapılan artış-azalış ayrimının diğer araştırmalardan düşük olarak üç hisse senedi için %63 ortalama ile doğru tespit edilmesinin nedeni gözlemlerin 4 gruba ayrılip maliyet fonksiyonunun bu yapıyla kurulmasıdır. Aynı ağ modeli ile ve aynı gözlemlerle yapılan gözlemleri iki gruba ayıran bir başka çalışmada doğruluk oranı %78'e kadar çıkmaktadır. (Tanyer ve Sarucan, 2019)

Çalışmada, 1. ve 4. grupların tespitinde algoritmalar değer değişimlerinin daha ilimli olduğu 2. ve 3. gruplara göre daha iyi sonuçlar vermiştir. Karlılık ve zarardan kaçınma yaklaşımı göz önüne alındığında yatırımcıların da 1. ve 4. gruplarla daha yakından ilgileneceği muhakkaktır. Daha sonra yapılacak çalışmalarda, aynı yöntemle değişim değerleri küçükten büyüğe sıralanıp örneğin 3 gruba ayrılarak önemli olarak değişim gösteren 1 ve 3 numaralı 2 grup üzerinde tahmin yöntemleri geliştirilebilir. Çalışma kapsamında, YSA'nın girdi değişkeni sayısının gözlem sayısına oranla çok yüksek olması halinde aşırı uyum (overfitting) ihtimali oluşacağından (Liu ve ark., 2017) daha uzun süreli gecikmeli değişken değerleri kullanılmamıştır. İllerki çalışmalarda özellik seçimi (feature selection) yöntemleri kullanılarak bağımsız değişken sayısı azaltılıp t-2, t-3 gibi değişken değerleri de kullanılabilir. Ayrıca gelişmiş piyasalarda yer alan hisse senetleri, farklı sektörlerde yer alan firmalara ait hisse senetleri veya borsa endeks değerleri üstünde çalışmalar yürütülebilir.

Bu çalışmadan farklı olarak YSA algoritması kurulurken aktivasyon fonksiyonu olarak hiperbolik tanjant, düzeltilmiş doğrusal üniteler (rectified linear units) gibi diğer

yöntemler de denenebilir. Değişkenler üzerinde temel bileşen analizi (Principle Component Analysis) gibi yöntemler kullanılabilir, daha farklı değişkenlerle çalışmalar yürütülebilir.

KAYNAKLAR

- Abbasi, E. ve Abouec, A., 2008, Stock price forecast by using neuro-fuzzy inference system, *Proceedings of World Academy of Science, Engineering and Technology* (36), 320–323.
- Afolabi, M. ve Olatoyosi, O., 2007, Predicting stock prices using a hybrid Kohonen self-organizing map (SOM), *40th Annual Hawaii international conference on system sciences*, 1-8.
- Aktaş, M., 2008, İstanbul Menkul Kıymetler Borsasında hisse senedi getirileri ile ilişkili olan finansal oranların araştırılması, *Istanbul University Journal of the School of Business Administration*, 37 (2), 137-150.
- Alberto, R.-Q. J., Chacon, M. ve F. Chacon-Hinojos, J., 2012, Artificial Neural Image Processing Applications: A Survey, *Engineering Letters* (20).
- Amato, F., López-Rodríguez, A., Peña-Méndez, E., Vaňhara, P., Hampl, A. ve Havel, J., 2013, Artificial neural networks in medical diagnosis. , *J Appl Biomed*, 11, 47-58.
- Amrehn, M., Mualla, F., Angelopoulou, E., Steidl, S. ve Maier, A., 2018, The Random Forest Classifier in WEKA: Discussion and New Developments for Imbalanced Data.
- Anonim, 2012, Means, Ends and Dividends Dividend Investing in a New World of Lower Yields and Longer Lives.
- Anonim, 2015, Sektör Bilançoları 2013-2015 değerlendirme raporu, www3.tcmb.gov.tr/sektor/2017/Raporlar/oran.pdf:
- Anonim, 2019, Sermaye Piyasası Kurulu Bülteni, www.borsaistanbul.com/docs/default-source/piyasalar/spk-bulteni-31-01-2019.pdf?sfvrsn=4.: [31 Ocak 2019].
- Atsalakis, G. S. ve Valavanis, K. P., 2009, Forecasting stock market short-term trends using a neuro-fuzzy based methodology *Expert Systems with Applications*, 36(3), 10696–10707.
- Bao, D. ve Yang, Z., 2008, Intelligent stock trading system by turning point confirming and probabilistic reasoning *Expert Systems with Applications*, 34 (1), 620-627.
- Boyacioglu, M. ve Avci, D., 2010, An Adaptive Network-Based Fuzzy Inference System (ANFIS) for the prediction of stock market return: The case of the Istanbul Stock Exchange, *Expert Systems with Applications*, 37.
- Cheng, E., 2017, Just 10% of Trading Is Regular Stock Picking, JPMorgan Estimates. , www.cnbc.com/2017/06/13/death-of-the-human-investor-just-10-percent-of-trading-is-regular-stock-picking-jpmorgan-estimates.html,
- Chun, S.-H. ve Kim, S. H., 2004, Data Mining for Financial Prediction and Trading: Application to Single and Multiple Markets, *Expert Systems with Applications*, 26 (2), 131–139.
- Cichosz, P., 2015, Naïve Bayes classifier.
- Clarence, N. W., 2001, Artificial neural networks: Applications in Financial Distress Predictions and Foreign Exchange Hybrid Trading Systems, *Gold Coast, Wld.*
- Dey, N. S., Mohanty, R. ve Chugh, K. L., 2012, Speech and Speaker Recognition System Using Artificial Neural Networks and Hidden Markov Model, *International Conference on Communication Systems and Network Technologies*, 311-315.
- Edwards, J., 2017, Global Market Cap Is Heading toward \$100 Trillion and Goldman Sachs Thinks the Only Way Is Down Deutschland, www.businessinsider.de/global-market-cap-is-about-to-hit-100-trillion-2017-12?r=UK.:

- Egeli, B., Ozturan, M. ve Badur, B., 2003, Stock market prediction using artificial neural networks, *Third Hawaii international conference on business*, Honoluluu Hawaii.
- Ferreira, N., Menezes, R. ve Bentes, S., 2014, Cointegration and Structural Breaks in the EU Sovereign Debt Crisis, *The International Journal of Latest Trends in Finance and Economic Sciences*, 4, 680-690.
- Gencay, R., 1999, Linear, non-linear and essential foreign exchange rate prediction with simple technical trading rules, *Journal of International Economics*, 47, 91-107.
- Griffin , J. M. ve Lemmon, M., 2002, Book-to-Market Equity, Distress Risk, and Stock Returns, *Journal of Finance*, 57, 2317-2336.
- Grosan, C., Abraham, A., Ramos, V. ve Han, S. Y., 2005, Stock market prediction using multi expression programming, *Portuguese conference of artificial intelligence, workshop on artificial life and evolutionary algorithms*, 73-78.
- Grunescu, F., 2011, Data Mining, Springer-Verlag Berlin Heidelberg, p. 247.
- Gümüş, U. T., Şakar, Z., Akkın, G. ve Şahin, M., 2017, Finansal Analizde Kullanılan Oranlar Ve Firma Değer İlişkisi: BİST'De İşlem Gören Çimento Firmaları Üzerine Bir Analiz, *Karadeniz Sosyal Bilimler Dergisi*, 9 (16).
- Hellstrom, T. ve Holmstrom, K., 1998, Predictable Patterns in Stock Returns, *Technical Report Series*.
- Hsu, C., Chang, C. ve Lin, C.-J., 2003, A practical guide to support vector classification.
- James, G., Witten, D., Hastie, T. ve Tibshirani, R., 2013, An introduction to statistical learning, Springer, p. 194.
- James, G., Witten, D., Hastie, T. ve Tibshirani, R., 2017, An Introduction to Statistical Learning with Applications in R, Springer, p.
- Kara, Y., Boyacioglu, M. ve Baykan, O., 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, 5311-5319.
- Kavzoğlu, T. ve Çölkesen, İ., 2010, Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi *Harita Dergisi*, 144 (7), 73-82.
- Khaidem, L., Saha, S., Basak, S., Kar, S. ve Dey, S., 2016, Predicting the direction of stock market prices using random forest.
- Khan, I. Y., Zope, P. ve Suralkar, S. R., 2013, Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease, *Int. J. Eng. Sci. Innovat. Technol.*, 2, 210-217.
- Kohavi, R. ve Provost, F., 1998, Glossary of terms. Machine Learning, *Special Issue on Applications of Machine Learning and the Knowledge Discovery Process. Machine Learning*, 30, 271-274.
- Kohavi, R., 2001, A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection.
- Korkmaz, Ö. ve Karaca, S. S., 2013, Firma Performansını Etkileyen Faktörler ve Türkiye Örneği, *Ege Akademik Bakış*, 2 (13), 169-179.
- Köse, D. A., 2005, Finansal Tabloların Oranlar Yoluyla Analizi, *Meslek İçi Sürekli Eğitim Dergisi*, 39-44.
- Kubat, M. ve Matwin, S., 1997, Addressing the Curse of Imbalanced Training Sets: One Sided Selection, *Fourteenth International Conference on Machine Learning*, Nashville, Tennessee, 179-186.

- Lewellen, J., 2002, Predicting Returns with Financial Ratios *MIT Sloan Working Paper*, 4374-02.
- Liu, B., Wei, Y., Zhang, Y. ve Yang, Q., 2017, Deep neural networks for high dimension, low sample size data, *In Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence*, Melbourne, Australia, 2287–2293.
- McCulloch, W. S. ve Pitts, W., 1943, A Logical Calculus of the Ideas Immanent in Nervous Activity, *The Bulletin of Mathematical Biophysics*, 5, 115-133.
- Nirkhi, S., 2010, Potential use of Artificial Neural Network in Data Mining.
- On, C. ve Teo, J., 2009, Artificial Neural Controller Synthesis in Autonomous Mobile Cognition, *IAENG International Journal of Computer Science*, 36.
- On, C. ve Teo, J., 2010, Evolution and Analysis of Self-Synthesized Minimalist Neural Controllers for Collective Robotics using Pareto Multi-objective Optimization. World Congress on Computational Intelligence: 2172-2178.
- Ou, J. A. ve Penman, S. H., 1989, Financial statement analysis and the prediction of stock returns, *Journal of Accounting and Economics*, 11 (4), 295–329.
- Petersen, M. E., Ridder, D. ve Handels, H., 2002, Image processing with neural networks - a review, *Pattern Recognition*, 35, 2279-2301.
- Quek, C., 2005, Predicting the impact of anticipator action on US stock market – An event study using ANFIS (a neural fuzzy model), *Computational Intelligence*, 23, 117-141.
- Quinlan, J. R., 1986, Induction of decision trees, In: Machine Learning, Eds, *Boston: Kluwer Academic Publisher*, p. 81-106.
- Roth, P. L., 1994, Missing data: A conceptual review for applied psychologists, *Personnel Psychology*, 3 (1), 537-560.
- Saha, S., Routh, S. ve Goswami, B., 2014, Modeling Vanilla Option prices: A simulation study by an implicit method, *Journal of advances in Mathematics*, 6 (1), 834-848.
- Tan, T. Z., Quek, C. ve Geok, N., 2007, Biological Brain-Inspired Genetic Complementary Learning for Stock Market and Bank Failure Prediction, *Computational Intelligence*, 23, 236-261.
- Tanyer, M. and Sarucan, A. (2019). *Stock Price Forecasting with a Financial Ratio Based Neural Network Algorithm*. [online] Iseser.com. Available at: <https://iseser.com/doc/2019/ISESER2019-PROCEEDING-BOOK.pdf?e3> [Accessed 25 Aug 2019]
- Taran, C., Roy, D. ve Srinivasan, N., 2015, Stock price prediction - A novel survey, *International Journal of Applied Engineering Research*, 10, 11375-11383.
- Timmermann, A. ve Granger, C. W., 2004, Efficient market hypothesis and forecasting, *Interational Journal of Forecasting*, 20, 15-27.
- Trinkle, B., 2005, Forecasting annual excess stock returns via an adaptive network-based fuzzy inference system, *Int. Syst. in Accounting, Finance and Management*, 13, 165-177.
- Tsaih, R., Hsu, Y. ve C. Lai, C., 1998, Forecasting S&P 500 stock index futures with a hybrid AI system, *Decision Support Systems*, 23, 161-174.
- Vanstone, B. ve Finnie, G., 2009, An Empirical Methodology for Developing Stockmarket Trading Systems Using Artificial Neural Networks, *Expert Systems with Applications*, 36 (3), 6668–6680.
- Vapnik, V. N., 1995, The nature of statistical learning theory. SpringerVerlag. New York.

- Wellekens, C., 1998, Introduction to Speech Recognition Using Neural Networks, *European Symposium on Artificial Neural Networks*, Bruges, 227-236.
- Yildirim, P. ve Birant, D., 2014, Naive Bayes classifier for continuous variables using novel method (NBC4D) and distributions, *IEEE International Symposium on Innovations in Intelligent Systems and Applications*, 110-115.
- Yunos, Z. M., Shamsuddin, S. M. ve Sallehuddin, R., 2008, Data Modeling for Kuala Lumpur Composite Index with ANFIS. Second Asia international conference on modeling and simulation. Kuala Lumpur 609–614.

EKLER

EK-1 Hisse Senedi Değer Tahmininde Kullanılan Bazı Algoritmaları

1. Feedforward NN
2. Probabilistic NN
3. Radial Basis NN with Backpropagation
4. Elman Recurrent NN
5. Levenberg-Marquardt backpropagation algorithm in a three layered feedforward NN
6. Genetic Algorithm based backpropagation NN
7. Multi-branched NN
8. Reasoning NN
9. Random forest regression model
10. Efficient Market Hypothesis
11. Random Walk Theory
12. Technical Analysis: MA, momentum, RSI, stochastics K%, moving average convergence-divergence (MACD)
13. Fundamental Analysis
14. Generalized autoregressive conditional heteroskedasticity (GARCH)
15. Integrated Generalized Autoregressive Conditional Heteroskedasticity (IGARCH)
16. Glosten-Jagannathan-Runkle GARCH (GJR-GARCH)
17. Autoregressive integrated moving average (ARIMA)
18. Support vector machines (SVM)
19. Adaptive Evolutionary Algorithm
20. Linear regression model
21. Monte carlo simulation
22. Linear Discriminant Analysis
23. Quadratic Discriminant Analysis

EK-2 Modelde Kullanılan Değişkenler

	Değişken	Değişken Açıklaması	Kaynak	Veri Sıklığı
HİSSE DEĞİŞKENLERİ				
1	Açılış GAP'i	Aylık Hisse Açılmış Değerinin Önceki Ay Kapanış Değeriyle Farkı	yahoo finance	Aylık
2	Volatilite	Hisse Senedi Aylık Maksimum & Minimum Değer Farkı	yahoo finance	Aylık
3	Tabana Uzaklık	Hisse Senedi Kapanış & Minimum Değer Farkı	yahoo finance	Aylık
4	Tavana Uzaklık	Hisse Senedi Maksimum Değer & Kapanış Farkı	yahoo finance	Aylık
TEKNİK ANALİZ DEĞİŞKENLERİ				
5	6M BHO	6 Months Simple Moving Average (Uzun dönem yatırımcılar 200 gün kullandığı için)	yahoo finance	Aylık
6	3M BHO	3 Months Simple Moving Average (Uzun dönem yatırımcılar 100 gün kullandığı için)	yahoo finance	Aylık
7	2M BHO	2 Months Simple Moving Average (Uzun dönem yatırımcılar 50 gün kullandığı için)	yahoo finance	Aylık
8	6M BÜD	6 Months Exponential Smoothing (Uzun dönem yatırımcılar 200 gün kullandığı için (Smoothing Constant = 1-Damping Factor = $2/(1+6)=0,28$))	yahoo finance	Aylık
9	2M BÜD	2 Months Exponential Smoothing (Uzun dönem yatırımcılar 50 gün kullandığı için (Smoothing Constant = 1-Damping Factor = $2/(1+2)=0,66$))	yahoo finance	Aylık
ENDEKS DEĞİŞKENLERİ				
10	BIST 100 Kapanış	BIST 100 Endeksi Aylık Kapanış Fiyatı	investing	Aylık
11	BIST 100 Volatilite	BIST 100 Endeksi Aylık Maksimum & Minimum Değer Farkı	investing	Aylık
12	BIST 100 Tabana Uzaklık	BIST 100 Endeksi Kapanış & Minimum Değer Farkı	investing	Aylık
13	BIST 100 Tavana Uzaklık	BIST 100 Endeksi Maksimum Değer & Kapanış Farkı	investing	Aylık
14	NYSE Kapanış	NYSE Composite Endeksi Aylık Kapanış Fiyatı	investing	Aylık
15	NYSE Volatilite	NYSE Composite Endeksi Aylık Maksimum & Minimum Değer Farkı	investing	Aylık
16	NYSE Tabana Uzaklık	NYSE Composite Endeksi Kapanış & Minimum Değer Farkı	investing	Aylık
17	NYSE Tavana Uzaklık	NYSE Composite Endeksi Maksimum Değer & Kapanış Farkı	investing	Aylık
18	DOW 30 Kapanış	DOW 30 Endeksi Aylık Kapanış Fiyatı	investing	Aylık
19	DOW 30 Volatilite	DOW 30 Endeksi Aylık Maksimum & Minimum Değer Farkı	investing	Aylık
20	DOW 30 Tabana Uzaklık	DOW 30 Endeksi Kapanış & Minimum Değer Farkı	investing	Aylık

	Değişken	Değişken Açıklaması	Kaynak	Veri Sıklığı
21	DOW 30 Tavana Uzaklık	DOW 30 Endeksi Maksimum Değer & Kapanış Farkı	investing	Aylık
22	FTSE 100 Kapanış	FTSE 100 Endeksi Aylık Kapanış Fiyatı	investing	Aylık
23	FTSE 100 Volatilite	FTSE 100 Endeksi Aylık Maksimum & Minimum Değer Farkı	investing	Aylık
24	FTSE 100 Tabana Uzaklık	FTSE 100 Endeksi Kapanış & Minimum Değer Farkı	investing	Aylık
25	FTSE 100 Tavana Uzaklık	FTSE 100 Endeksi Maksimum Değer & Kapanış Farkı	investing	Aylık
26	NASDAQ 100 Kapanış	NASDAQ 100 Endeksi Aylık Kapanış Fiyatı	investing	Aylık
27	NASDAQ 100 Volatilite	NASDAQ 100 Endeksi Aylık Maksimum & Minimum Değer Farkı	investing	Aylık
28	NASDAQ 100 Tabana Uzaklık	NASDAQ 100 Endeksi Kapanış & Minimum Değer Farkı	investing	Aylık
29	NASDAQ 100 Tavana Uzaklık	NASDAQ 100 Endeksi Maksimum Değer & Kapanış Farkı	investing	Aylık
30	SP 500 Kapanış	SP 500 Endeksi Aylık Kapanış Fiyatı	investing	Aylık
31	SP 500 Volatilite	SP 500 Endeksi Aylık Maksimum & Minimum Değer Farkı	investing	Aylık
32	SP 500 Tabana Uzaklık	SP 500 Endeksi Kapanış & Minimum Değer Farkı	investing	Aylık
33	SP 500 Tavana Uzaklık	SP 500 Endeksi Maksimum Değer & Kapanış Farkı	investing	Aylık
PARA BİRİMİ & EMTİA FİYAT DEĞİŞKENLERİ				
34	USDTRY Kapanış	USDTRY Paritesi Aylık Kapanış Fiyatı	investing	Aylık
35	USDTRY Volatilite	USDTRY Paritesi Aylık Maksimum & Minimum Değer Farkı	investing	Aylık
36	USDTRY Tabana Uzaklık	USDTRY Paritesi Kapanış & Minimum Değer Farkı	investing	Aylık
37	USDTRY Tavana Uzaklık	USDTRY Paritesi Maksimum Değer & Kapanış Farkı	investing	Aylık
38	USDEUR Kapanış	USDEUR Paritesi Aylık Kapanış Fiyatı	investing	Aylık
39	USDEUR Volatilite	USDEUR Paritesi Aylık Maksimum & Minimum Değer Farkı	investing	Aylık
40	USDEUR Tabana Uzaklık	USDEUR Paritesi Kapanış & Minimum Değer Farkı	investing	Aylık
41	USDEUR Tavana Uzaklık	USDEUR Paritesi Maksimum Değer & Kapanış Farkı	investing	Aylık
42	USDCNY Kapanış	USDCNY Paritesi Aylık Kapanış Fiyatı	investing	Aylık
43	USDCNY Volatilite	USDCNY Paritesi Aylık Maksimum & Minimum Değer Farkı	investing	Aylık
44	USDCNY Tabana Uzaklık	USDCNY Paritesi Kapanış & Minimum Değer Farkı	investing	Aylık
45	USDCNY Tavana Uzaklık	USDCNY Paritesi Maksimum Değer & Kapanış Farkı	investing	Aylık
46	EURTRY Kapanış	EURTRY Paritesi Aylık Kapanış Fiyatı	investing	Aylık
47	EURTRY Volatilite	EURTRY Paritesi Aylık Maksimum & Minimum Değer Farkı	investing	Aylık
48	EURTRY Tabana Uzaklık	EURTRY Paritesi Kapanış & Minimum Değer Farkı	investing	Aylık

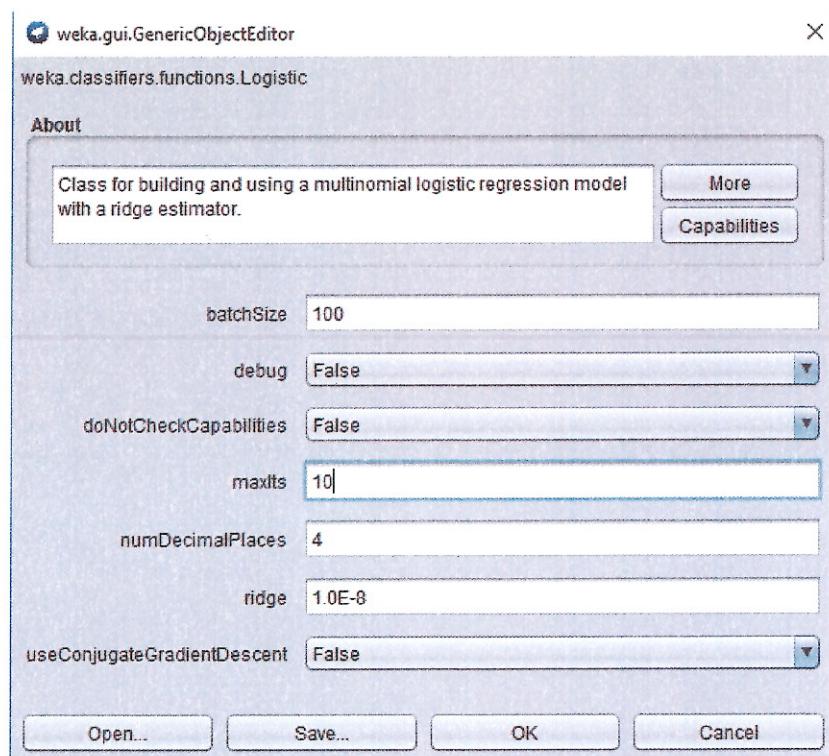
	Değişken	Değişken Açıklaması	Kaynak	Veri Sıklığı
49	EURTRY Tavana Uzaklık	EURTRY Paritesi Maksimum Değer & Kapanış Farkı	investing	Aylık
50	TP MK KUL YTL	Külçe Altın Satış Fiyatı (TL/Gr)	investing	Aylık
51	TP MK LON YTL	1 Ons Altın Londra Satış Fiyatı (ABD Doları/Ons)	investing	Aylık
BİST DETAY DEĞİŞKENLERİ				
52	TP MK F BILESIK TUM	(FİYAT) BİST 100 Tüm Endeksi, Kapanış Fiyatlarına Göre	EVDS	Aylık
53	TP MK F HİZMET	(FİYAT) BİST Hizmet Endeksi, Kapanış Fiyatlarına Göre (27-12-1996=1046)	EVDS	Aylık
54	TP MK F MALİ	(FİYAT) BİST Mali Endeks Kapanış Fiyatlarına Göre (31-12-1990=33)	EVDS	Aylık
55	TP MK F SINAI	(FİYAT) BİST Sinai Endeks, Kapanış Fiyatlarına Göre (31-12-1990=33)	EVDS	Aylık
56	TP MK G BILESIK TUM	(GETİRİ) BİST 100 Tüm Endeksi, Kapanış Fiyatlarına Göre	EVDS	Aylık
57	TP MK G HİZMET	(GETİRİ) BİST Hizmet Endeksi, Kapanış Fiyatlarına Göre (27-12-1996=1046)	EVDS	Aylık
58	TP MK G MALİ	(GETİRİ) BİST Mali Endeks, Kapanış Fiyatlarına Göre (27-12-1996=914)	EVDS	Aylık
59	TP MK G SINAI	(GETİRİ) BİST Sinai Endeks, Kapanış Fiyatlarına Göre (27-12-1996=1046)	EVDS	Aylık
60	TP MK ISL HC	Toplam İşlem Hacmi (Bin TL)	EVDS	Aylık
61	TP MK ISL MK	Toplam İşlem Miktarı (Bin Adet)	EVDS	Aylık
MAKRO DEĞİŞKENLER				
62	TP PR ARZ01	M1 Para Arzı (Bin TL) (Dolaşımdaki Para + Vadesiz Mevduat (YTL,YP))	EVDS	Aylık
63	TP PR ARZ13	M2 Para Arzı (Bin TL) (M1 + Vadeli Mevduat (YTL,YP))	EVDS	Aylık
64	TP PR ARZ22	M3 Para Arzı (Bin TL) (M2 + Repo + Para Piyasası Fonları)	EVDS	Aylık
65	TP BRENTPETROL EUBP	Avrupa Brent Petrol Spot FOB Fiyatı (Varil Başına Dolar)	EVDS	Aylık
66	TP DB B01	1:TÜRKİYE BRÜT DIŞ BORÇ STOKU	EVDS	Üç Aylık
67	TP DB B31	3C:ÖZEL SEKTÖR (Borçluya Göre)	EVDS	Aylık
68	TP KB GEN01	1.GENEL BÜTÇE GELİRLERİ	EVDS	Aylık
69	TP KB GEN03	1A1.Dolaysız Vergiler	EVDS	Aylık
70	TP KB GEN04	1A2.Dolaylı Vergiler	EVDS	Aylık
71	TP KB GEN12	2.GENEL BÜTÇE HARCAMALARI	EVDS	Aylık
72	TP KB GEN13	3.GENEL BÜTÇE FAİZ DIŞI HARCAMALARI	EVDS	Aylık
73	TP KB GEN42	8A.Diş Borçlanma (Net)	EVDS	Aylık
74	TP KB GEN45	8B.İç Borçlanma (Net)	EVDS	Aylık
75	TP GSYIH26 HY CF	Gayrisafi yurtıcı hasıla(Bin TL)	EVDS	Üç Aylık
76	TP KKO2 IS TOP	Kapasite Kullanım Oranı-İmalat Sanayi-Mevsimsellikten Arındırılmış	EVDS	Aylık
77	TP KKO MA	İmalat Sanayi Kapasite Kullanım Oranı	EVDS	Aylık
78	TP TIG07	İşsizlik oranı (%)	EVDS	Aylık

	Değişken	Değişken Açıklaması	Kaynak	Veri Sıklığı
79	TP AB C1	Altın(Milyon ABD Doları)	EVDS	Aylık
80	TP AB C2	Merkez Bankası Brüt Döviz Rezervleri(Milyon ABD Doları)	EVDS	Aylık
81	TP GY1 N2	Reel Kesim Güven Endeksi	EVDS	Aylık
82	TP GY1 N2 MA	Reel Kesim Güven Endeksi-MA	EVDS	Aylık
83	TP AB B2	Döviz Varlıklarları (Milyon ABD Doları)	EVDS	Aylık
84	TP AB B1	Altın (Milyon ABD Doları)	EVDS	Aylık
85	TP AB B6	Toplam Rezerv (Milyon ABD Doları)	EVDS	Aylık
86	TP KTF17	Ticari (TL Üzerinden Açılan)(Akım Veri,%)	EVDS	Aylık
87	TP KTF17 EUR	Ticari (EUR Üzerinden Açılan)(Akım Veri,%)	EVDS	Aylık
88	TP KTF17 USD	Ticari (USD Üzerinden Açılan)(Akım Veri,%)	EVDS	Aylık
89	TP DT GEN IH B	Toplam (İhracat)	EVDS	Aylık
90	TP DT GEN IT B	Toplam (İthalat)	EVDS	Aylık
91	TP SANAYREV4 Y1	Toplam sanayi	EVDS	Aylık
92	TP ODEMGZS AVRUPATOP	Milliyetlere Göre Ziyaretçi Sayısı AVRUPA TOPLAM	EVDS	Aylık
93	TP ODEMGZS ABD	Milliyetlere Göre Ziyaretçi Sayısı A.B.D.	EVDS	Aylık
94	TP ODEMGZS AMERIKATOP	Milliyetlere Göre Ziyaretçi Sayısı AMERİKA TOPLAM	EVDS	Aylık
95	TP ODEMGZS GTOPLAM	Milliyetlere Göre Ziyaretçi Sayısı GENEL TOPLAM	EVDS	Aylık
96	USONFFE	FED Faiz oranları aylık ortalaması	EVDS	Aylık
97	TP KM C11	2.3 Özel Sektör	EVDS	Aylık
ENFLASYON DEĞİŞKENLERİ				
98	TP FE OKTG01	Tüketiciler Fiyat Endeksi (Genel)	TÜİK	Aylık
99	TP FE OKTG02	A- Mevsimlik ürünler hariç TÜFE	TÜİK	Aylık
100	TP FE OKTG03	B- İşlenmemiş gıda ürünler, enerji, alkollü içkiler ve tütün ile altın hariç TÜFE	TÜİK	Aylık
101	TP FE OKTG04	C- Enerji, gıda ve alkolsüz içecekler, alkollü içkiler ile tütün ürünleri ve altın hariç TÜFE	TÜİK	Aylık
102	TP FE OKTG05	D- İşlenmemiş gıda, alkollü içecekler ve tütün ürünleri hariç TÜFE	TÜİK	Aylık
FINANSAL ORAN DEĞİŞKENLERİ				
103	Cari Oran	Dönen Varlıklar / Kısa Vadeli Yabancı Kaynaklar	Finnet	Üç Aylık
104	Asit - Test Oranı	(Dönen Varlıklar - Stoklar) / Kısa Vadeli Yabancı Kaynaklar	Finnet	Üç Aylık
105	Nakit Oranı	(Hazır Değerler + Menkul Kıymetler) / Kısa Vadeli Yabancı Kaynaklar	Finnet	Üç Aylık
106	Stok Devir Hızı	Satılan Ticari Malların Maliyeti / Ortalama Ticari Mal Stoku	Finnet	Üç Aylık
107	Alacak Devir Hızı	Net Satışlar / Aktif Ortalama Ticari Alacaklar	Finnet	Üç Aylık
108	Aktif Devir Hızı	Net Satışlar / Aktif Toplamı	Finnet	Üç Aylık

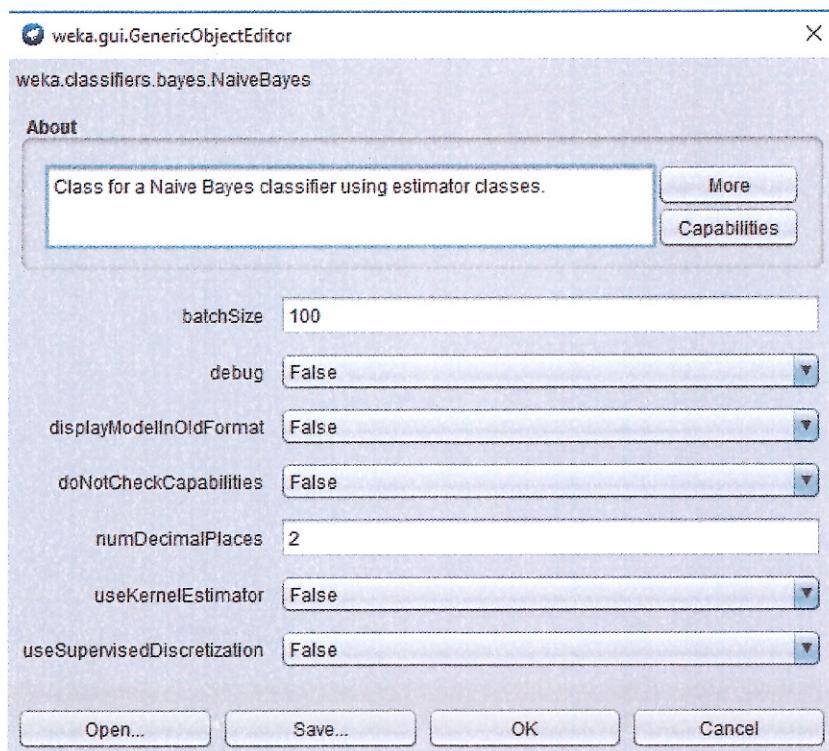
	Değişken	Değişken Açıklaması	Kaynak	Veri Sıklığı
109	Kaldırıcı Oranı	Toplam Yabancı Kaynak / Pasif Toplamı	Finnet	Üç Aylık
110	Kısa Vadeli Yabancı Kaynak Oranı	Kısa Vadeli Yabancı Kaynaklar / Pasif Toplamı	Finnet	Üç Aylık
111	Uzun Vadeli Yabancı Kaynak Oranı	Uzun Vadeli Yabancı Kaynaklar / Pasif Toplamı	Finnet	Üç Aylık
112	Öz Kaynak Oranı	Öz Kaynaklar / Pasif Toplamı	Finnet	Üç Aylık
113	Yabancı Kaynaklarının Öz Kaynaklara Oranı	Toplam Yabancı Kaynaklar / Öz Kaynaklar	Finnet	Üç Aylık
114	Ekonomik Rantabilite	Vergi ve Faiz Önceki Kar / Pasif Toplamı	Finnet	Üç Aylık
115	Hisse Başına Getiri	Net Kar / Dolaşımdaki Hisse Sayısı	Finnet	Üç Aylık
116	İş Hacmi Rantabilitesi	Faaliyet Kârı / Net Satışlar	Finnet	Üç Aylık
117	Dönen Varlık Rantabilitesi	Net Kâr / Dönen Varlıklar	Finnet	Üç Aylık
118	Fiyat/Kazanç Oranı	Hisse Güncel Fiyatı / Hisse Başına Kar	Finnet	Üç Aylık
119	Piyasa Fiyatı/Defter Değeri Oranı	Hisse Senedi Güncel Fiyatı / Hisse Senedi Defter Değeri	Finnet	Üç Aylık
120	Fiyat - Satış Oranı	Firma Değeri / Net Satışlar	Finnet	Üç Aylık

EK-3 Algoritma Varsayılan Değerleri

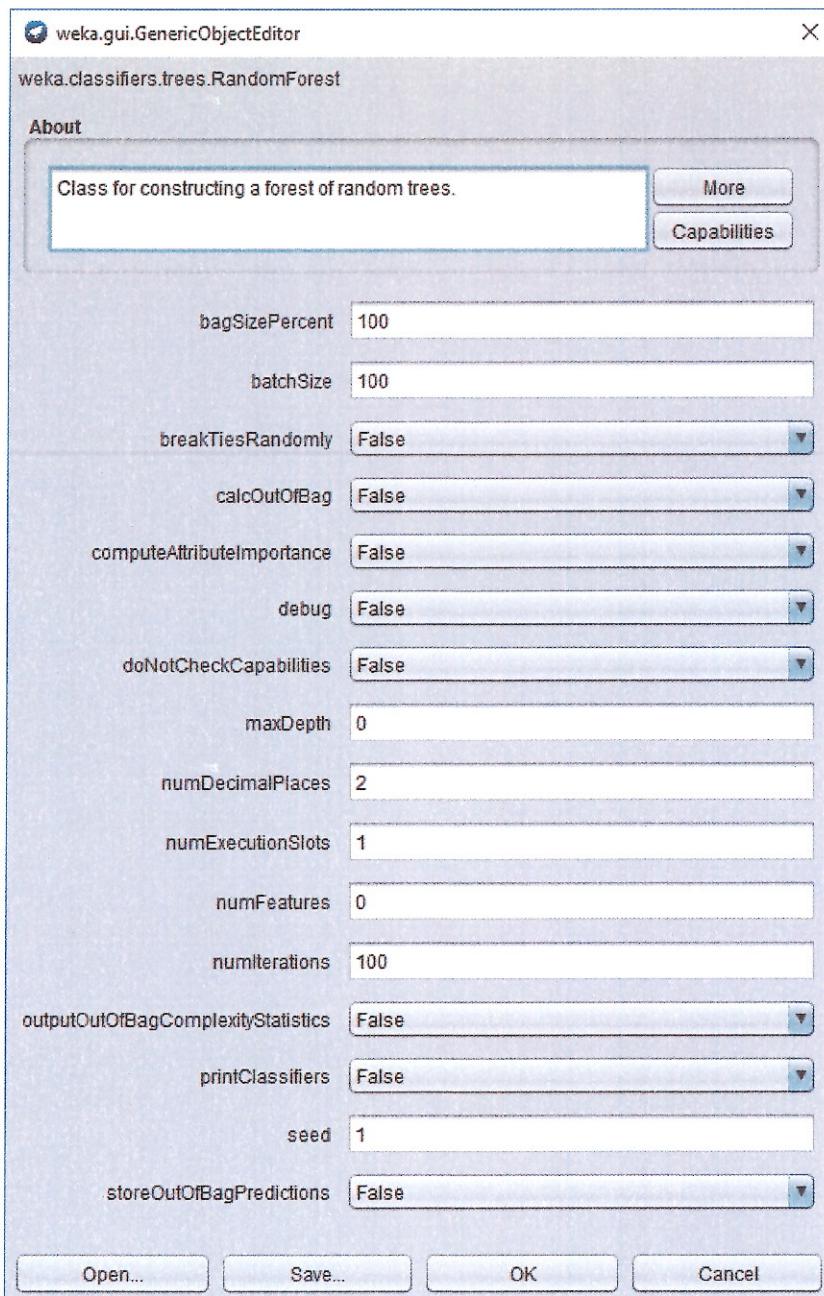
Lojistik Regresyon:



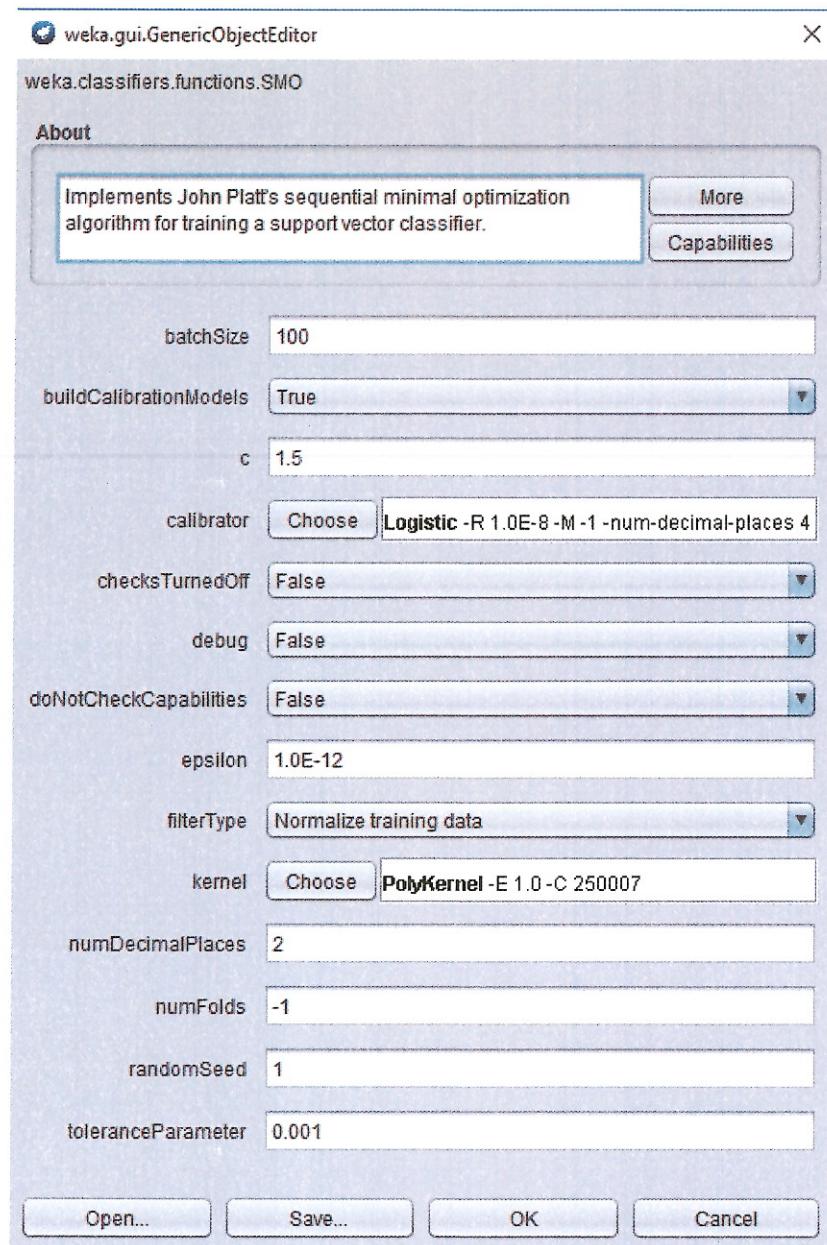
Naive Bayes:



Rasgele Orman:



Destek Vektör Makineleri:



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Mustafa Tanyer
Uyruğu : T.C.
Doğum Yeri ve Tarihi : 25.01.1987 /Konya
Telefon : 05556029192
Faks :
e-mail : mustafabotsali@hotmail.com

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	Meram Anadolu Lisesi / Meram / Konya	2005
Üniversite	Bilkent Üniversitesi / Çankaya / Ankara	2011
Yüksek Lisans :		
Doktora :		

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2012 - 2014	Mevlana Kalkınma Ajansı	Bölgesel Kalkınma Uzmanı
2014 - 2019	Türkiye Cumhuriyet Merkez Bankası	Uzman Yardımcısı

UZMANLIK ALANI

Ekonometrik modellemeler, veri görselleştirme

YABANCI DİLLER

İngilizce

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

YAYINLAR*

Tanyer, M. and Sarucan, A. (2019). *Stock Price Forecasting with a Financial Ratio Based Neural Network Algorithm.* [online] Iseser.com. Available at: <https://iseser.com/doc/2019/ISESER2019-ABSTRACT-BOOK.pdf?e6> [Accessed 25 May 2019]