

T.C.
BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

VOLATİLİTE AKTİVASYON FONKSİYONU İLE ZAMAN SERİSİ TAHMİNİ

Doktora Tezi

Tezi Hazırlayan:

Furkan KAYIM

İSTANBUL, 2022

T.C.
BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

VOLATİLİTE AKTİVASYON FONKSİYONU İLE ZAMAN SERİSİ TAHMİNİ

Doktora Tezi

Tezi Hazırlayan:

Furkan KAYIM

Öğrenci No:
160821002

ORCID :
0000-0002-9721-1554

Danışman:
Dr. Öğr. Üyesi Atınç YILMAZ

İSTANBUL, 2022

YEMİN METNİ

Doktora Tezi olarak sunduđum “Volatilite Aktivasyon Fonksiyonu ile Zaman Serisi Tahmini” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere uygun şekilde tarafımdan yazıldığını, yararlandığım eserlerin tamamının kaynaklarda gösterildiğini ve çalışmamın içinde kullanıldıkları her yerde bunlara atıf yapıldığını belirtir ve bunu onurumla doğrularım.12.10.2022

Furkan KAYIM

TEZ ONAYI

Beykent Üniversitesi Lisansüstü Eğitim Enstitüsü **Bilgisayar Mühendisliği Doktora** öğrencisi **160821002** numaralı **Furkan KAYIM**'ın hazırladığı **“Veri Madenciliği Kollektif Sınıflandırma İle Döviz Kuru Tahmini”** konulu DOKTORA TEZİ ile ilgili TEZ SAVUNMA SINAVI Lisansüstü Öğretim ve Sınav Yönetmeliğinin ilgili maddesi uyarınca 24.06.2022 günü saat 15:00’de Zoom programı aracılığıyla on-line olarak yapılmış, sorulan sorulara alınan cevaplar sonucunda adayın tezinin **KABUL**’üne **OYBİRLİĞİ**’yle karar verilmiştir.

JÜRİ ÜYESİ	KANAATI	İMZA
Dr. Öğr. Üyesi At*** YI*** (Danışman) (Beykent Üniversitesi)		
Dr. Öğr. Üyesi Ed*** ŞA*** (Üye) (Beykent Üniversitesi)		
Dr. Öğr. Üyesi Tu*** KA*** (Üye) (Beykent Üniversitesi)		
Doç. Dr. Yü*** Ba*** SA*** (Üye) (Bahçeşehir Üniversitesi)		
Dr. Öğr. Üyesi Se*** AY*** (Üye) (Yıldız Teknik Üniversitesi)		

Adı ve Soyadı : Furkan KAYIM
Danışmanı : Dr. Öğr. Üyesi Atınç YILMAZ
Türü ve Tarihi : Doktora, 2022
Alanı : Bilgisayar Mühendisliği
Anahtar Kelimeler : Veri Madenciliği, Ensemble Metot, Zaman Serisi Tahmini, Aktivasyon Fonksiyonu, Yapay Zeka, Zaman Serileri

ÖZ

VOLATİLİTE AKTİVASYON FONKSİYONU İLE ZAMAN SERİSİ TAHMİNİ

Zaman serisi analizi zor bir o kadarda kritik bir konudur. Zaman serisi analizi toplumun birçok kesimi tarafından kullanılmakta kritik kararlarda önemli bir rol oynamaktadır. Bununla birlikte zaman serisi analizi ile ilgili modern çalışmalar çok kısıtlı ve yeterli değildir. Çalışma kapsamında zaman serisi analizi için yapay zeka tekniklerinden yararlanılmıştır. Yapay zeka teknikleri kullanılırken hiper parametrelerin belirlenmesi, verilere göre farklı aktivasyon fonksiyonlarının kullanılması ihtiyacı, aktivasyon fonksiyonlarındaki problemler, modelin farklı noktalarında aktivasyon fonksiyonu kullanılması, aktivasyon fonksiyonun veri türüne yakınsamaması gibi problemler bulunmaktadır. Çalışma kapsamında bu problemlerin çözümü ve zaman serisi analizi üzerine önerilerde bulunulmuş bu öneriler ispatlanmıştır.

Problemlerin çözümü için modifiye aktivasyon fonksiyonları ve kolektif sınıflandırma ile yapay zeka algoritmalarının yarıştırılması yöntemleri kullanılmıştır. Leaky ReLU ve Sigmoid fonksiyonu üzerine modifiye işlemi yapılmak suretiyle Modifiye Sigmoid ve Modifiye Leaky ReLU fonksiyonları önerilmiştir. Modifiye sigmoid fonksiyonu ile vanishing gradyan ve ReLU fonksiyonunda bulunan linear olma problemleri çözülmüştür. Literatürde önerilen finansal enstrüman tahmin modellerini kapsayıcı bir mimari oluşturularak bu kapsamda bir uygulama geliştirilmiştir.

Önerilen yöntemler literatür çalışmaları ile kıyaslanarak yöntemlerin doğrulukları ve uygulanabilirlikleri ispatlanmıştır. Yapılan çalışma sonucunda literatüre yeni aktivasyon fonksiyonları ve yapay zeka algoritmaları katkılarında bulunulmakla birlikte problemlerin çözümüne alternatif yöntemler sunulmuştur. Bu çalışmalar sonucu göstermiştir ki önerilen yöntemler uygulanabilir ve tutarlıdır.

Name and Surname : Furkan KAYIM
Supervisor : Dr. Lecturer Atınç YILMAZ
Degree and Date : PhD., 2022
Major : Computer Engineer
Key Words : Data Mining, Ensemble Method, Exchange rate forecast,
Artificial intelligence, Activation function , Time series

ABSTRACT

TIME SERIES FORECASTING WITH VOLATILITY ACTIVATION FUNCTION

Time series analysis is a difficult and critical issue. Time series analysis is used by many parts of the society and plays an important role in critical decisions. However, modern studies on time series analysis are very limited and not sufficient. Within the scope of the study, artificial intelligence techniques were used for time series analysis. When using artificial intelligence techniques, there are problems such as the determination of hyperparameters, the need to use different activation functions according to the data, the problems in the activation functions, the use of the activation function at different points in the model, the activation function not converging to the data type. Within the scope of the study, suggestions were made on the solution of these problems and time series analysis and these suggestions were proven.

For the solution of the problems, modified activation functions and collective classification and artificial intelligence algorithms competing methods are used. Modified Sigmoid and Modified Leaky ReLU functions have been proposed by modifying the Leaky ReLU and Sigmoid functions. With the modified sigmoid function, the vanishing gradient and linearity problems in the ReLU function are solved. An application has been developed in this context by creating an architecture that covers the financial instrument forecasting models suggested in the literature.

The accuracy and applicability of the methods have been proven by comparing the proposed methods with the literature studies. As a result of the study, new activation functions and artificial intelligence algorithms were contributed to the literature, and alternative methods were presented for the solution of the problems. The results of these studies have shown that the proposed methods are applicable and consistent.

İÇİNDEKİLER

Sayfa No.

ÖZ

ABSTRACT

TABLolar LİSTESİ.....	iv
ŞEKİLLER LİSTESİ	vi
KISALTMALAR	viii
SÖZLÜK.....	ix
GİRİŞ	1

BİRİNCİ BÖLÜM

ALAN ARAŞTIRMASI ve ZAMAN SERİSİ ANALİZİ

1.1. Alan Araştırması.....	7
1.2. Zaman Serisi Analizi	15
1.3. Finansal Enstrüman Tahmini.....	16
1.3.1. Finansal Enstrüman Tahmininde Kullanılan Yöntemler	17
1.3.1.1. Faiz Oranları Paritesi.....	18
1.3.1.2. Uluslararası Fisher Etkisi	19
1.3.2. Finansal Enstrümanları Etkileyen Dış Etmenler.....	19
1.4. Veri Madenciliği.....	25
1.4.1. Veri Düzenleme	26
1.4.2. Finansal Enstrüman Özellikleri.....	26
1.4.3. Veri Yaşam Döngüsü	29
1.4.4. Veri Yapısı.....	32
1.4.5. Bayesyen Sınıflandırma	33
1.4.6. Karar Ağaçları	38
1.5. Kolektif Sınıflandırma.....	39
1.5.1. Bagging (Majority Vote) – Çoğunluk Oyu	39
1.5.2. Boosting – Güçlendirme Yöntemi.....	40
1.5.3. Random Forests.....	42
1.5.4. Long Short Term Memory (LSTM)	43
1.5.5. RNN.....	43
1.5.6. Autoregressive Integrated Moving Average (ARIMA).....	44
1.6. Aktivasyon Fonksiyonu Problemleri	45

1.6.1. Lineer Olma	45
1.6.2. Gradyan Koruma	46
1.6.3. Vanishing Gradyan (Kaybolan Gradyan)	46

İKİNCİ BÖLÜM

MATERYAL ve YÖNTEMLER

1. MODİFİYE AKTİVASYON FONKSİYONLARI YÖNTEMİ.....	47
1.1. ReLU	48
1.2. Sigmoid	49
1.3. Önerilen Aktivasyon Fonksiyonları	50
1.3.1. Volatilité.....	51
1.3.2. Modifiye Aktivasyon Fonksiyonu	54
1.3.3. Modifiye Sigmoid Fonksiyonu	56
1.3.4. Modifiye Leaky ReLU Fonksiyonu	57
1.4. Önerilen Aktivasyon Fonksiyonlarının İspatı	58
1.4.1. Tanım ve Değer Kümesine Göre Fonksiyon Olma Şartı.....	59
1.4.2. Lineer Olmama.....	60
1.4.3. Türevi Alınabilir Olmalı	63
1.4.4. Sınırların Olması.....	64
1.4.5. Süreklilik.....	64
1.4.6. Gradyan koruma.....	65
1.4.7. Vanishing Gradyan	66
2. KOLEKTİF SINIFLANDIRMA İLE YAPAY ZEKA ALGORİTMALARININ YARIŞTIRILMASI YÖNTEMİ.....	66
2.1. Boost Fonksiyonel Kümeleme Algoritması	66
2.2. Vote Fonksiyonel Kümeleme Algoritması.....	68
3. KORELASYONLAR.....	69

ÜÇÜNCÜ BÖLÜM

ÖNERİLEN YÖNTEMLERİN UYGULAMASI ve DEĞERLENDİRİLMESİ

1. UYGULAMANIN GELİŞTİRİLMESİ	74
1.1. Uygulama Mimarisi	75
2. MODİFİYE AKTİVASYON FONKSİYONLARI'NIN UYGULAMASI VE TARTIŞILMASI.....	80
2.1. Avustralya'da Ertesi Gün Yağmur Tahmin Örneği	80

2.2. Twitter Verileri ile Test.....	83
2.3. Elektrik Trafo Sıcaklık Verileri ile Volatilite Aktivasyon Fonksiyonu Uygulaması.....	84
2.4. EUR/USD İki Yıllık Verisi ile Test	85
3. KOLLEKTİF SINIFLANDIRMA YÖNTEMLERİ.....	87
3.1. Boost Fonksiyonel Kümeleme Algoritması Uygulaması.....	87
3.2. Vote Fonksiyonel Kümeleme Algoritması Uygulaması	92
3.3. Uygulamanın Test Edilmesi	93
3.3.1. Test Verileri	94
3.3.2. 14-05-2018 ile 15-06-2018 Tarihleri Arası Test Sonuçları.....	97
3.3.3. 2019 USD/TRY Uygulama Test Sonuçları	102
3.3.4. 2003-2020 USD/TRY Test Sonuçları	103
3.3.5. 2017 Ons Altın Test Sonuçları.....	105
4. KORELASYON SONUÇLARI	106
SONUÇ ve TARTIŞMA	108
KAYNAKÇA	112
EKLER.....	130
EK 1: Uygulama pom.xml.....	130

TABLÖLAR LİSTESİ

Sayfa No.

Tablo 1. Örnek Döviz Kuru Verisi.....	33
Tablo 2. 2019 Ocak Şubat USD/TRY Döviz Satış Kuru	34
Tablo 3. 2019 Şubat Ayı USD/TRY Kuru Artış Değerleri	35
Tablo 4. 2019 Şubat Ayı USD/TRY Kuru Artış Azalış ve Değiş Verilerine İndirgeme	36
Tablo 5. 2019 Ocak Şubat Usd/Try Döviz Satış Kuru	53
Tablo 6. Aktivasyon Fonksiyonları Denklemi	55
Tablo 7. Ocak Nisan EUR/USD Volatilite Verisi.....	60
Tablo 8. EUR/USD 5 günlük volatite değerleri	62
Tablo 9. TÜFE, Tüketici Güven Endeksi, Ekonomik Güven Endeksi ve USD/TRY 2018-2020 yılları arası tablo	71
Tablo 10. 2018-2020 Yılları Arası Finansal Enstrüman Verileri.....	72
Tablo 11. Yağmur Verisi Kolon Özellikleri.....	81
Tablo 12. Zaman Serisi Yağmur Tahmini.....	82
Tablo 13. Twitter veri seti özellikleri.....	83
Tablo 14. Zaman Serisi Duygu Tahmini Doğrulama Sonuçları.....	84
Tablo 15. Zaman Serisi Ett Doğrulama Sonuçları	84
Tablo 16. Aktivasyon Fonksiyonlarının Doğrulama Sonuçları	85
Tablo 17. Yatay Trend Algoritmaların 2019 USD/TRY Kuru Sonuçları	88
Tablo 18. 28.01.2020 USD/TRY için Boost Fonksiyonel Kümeleme Ağırlıklandırma	88
Tablo 19. 2019 USD/TRY Uygulama Test Sonuçları.....	89
Tablo 20. 2003-2020 2019 USD/TRY Uygulama Test Sonuçları	90
Tablo 21. 2007 Yılı Ons Altın Uygulama Test Sonuçları.....	90
Tablo 22. Yatay Trend Algoritmaların 2019 USD/TRY Kuru Sonuçları	91
Tablo 23. 28.01.2020 USD/TRY için Boost Fonksiyonel Kümeleme Ağırlıklandırma	91
Tablo 24. 14-05-2018 ile 15-06-2018 USD/TRY, CDS, FAİZ Verileri	95
Tablo 25. DTA, Amerikan 10 yıllık Faiz, USD Endeks TÜFE verileri.....	96
Tablo 26. Tüketici ve Ekonomik Güven Endeksi, EUR/USD, Ons Altın, EUR/TRY Verileri.....	97
Tablo 27. 14-05-2018 İle 15-06-2018 Tarihleri Arası USD/TRY Sonuçları.....	98
Tablo 28. 14-05-2018 İle 15-06-2018 Tarihleri Arası Ons Altın Sonuçları	98
Tablo 29. 14-05-2018 İle 15-06-2018 Tarihleri Arası EUR/USD Sonuçları.....	99

Tablo 30. 14-05-2018 İle 15-06-2018 Tarihleri Arası GARAN Sonuçları.....	100
Tablo 31. 14-05-2018 İle 15-06-2018 Tarihleri Arası BIST100 Sonuçları	100
Tablo 32. 14-05-2018 İle 15-06-2018 Tarihleri Arası USD Endeks Sonuçları	101
Tablo 33. 14-05-2018 İle 15-06-2018 Tarihleri Arası EUR/TRY Sonuçları.....	101
Tablo 34. 2019 USD/TRY Uygulama Test Sonuçları.....	102
Tablo 35. 2003-2020 2019 USD/TRY uygulama test sonuçları	103
Tablo 36. 2007 Yılı Ons Altın Uygulama Test Sonuçları.....	105



ŞEKİLLER LİSTESİ

Sayfa No.

Şekil 1. Türkiye 2 Yıllık Tahvil Faizi 2012 2022 Yılları Arası.....	20
Şekil 2. Türkiye İmalat Satın Alma Yöneticileri Endeksi (PMI) 2013 ile 2022 Yılları.....	21
Şekil 3. 2002 2019 Yılları Arası Türkiye Dış Ticaret Açığı.....	22
Şekil 4. 2020 ile 2022 Yılları Arası Türkiye Tüketici Güven Endeksi	24
Şekil 5. Trend Çizgileri ile Trend Analiz	28
Şekil 6. Hareketli Ortalamalara Göre Trend Belirleme	28
Şekil 7. Finansal Enstrüman Verisi Yaşam Döngüsü.....	30
Şekil 8. Finansal Enstrüman ile Karar Ağacı.....	38
Şekil 9. Çoğunluk Oyu Yöntemi Örneği	39
Şekil 10. Kolektif Sınıflandırma Çalışma Mekanizması	41
Şekil 11. Temel RNN Tasarımı	44
Şekil 12. ARIMA Model	45
Şekil 13. ReLU ve Türevi.....	49
Şekil 14. Sigmoid Fonksiyonu ve Türevi	50
Şekil 15. Sigmoid Fonksiyonu ve Modifiye Sigmoid Fonksiyonu	50
Şekil 16. Modifiye Aktivasyon Fonksiyonu Akış Diyagramı	54
Şekil 17. Modifiye Edilmiş bir Fonksiyonun Gösterimi	55
Şekil 18. Modifiye Sigmoid ve Türevi için Artış Yönü	57
Şekil 19. Modifiye Sigmoid Fonksiyonun Grafiği	57
Şekil 20. Modifiye Leaky ReLU Fonksiyonu.....	58
Şekil 21. 2022 Ocak-Nisan EUR/USD Volatilite.....	59
Şekil 22. 2021 EUR/USD Volatilite	61
Şekil 23. EUR/USD Günlük Volatilite Grafiği	62
Şekil 24. 10 günlük volatilite değeri.....	65
Şekil 25. Boost Fonksiyonel Kümeleme Algoritması Akış Diyagramı.....	67
Şekil 26. Vote Fonksiyonel Kümeleme Algoritması Akış Diyagramı	68
Şekil 27. TÜFE ve USD/TRY 2018-2020 Yılları Arası Grafik	70
Şekil 28. 10 Yıllık Faizler ve USD/TRY Grafiği	73
Şekil 29. Uygulama Mimari Yapısı	76
Şekil 30. Uygulama Mimarisi Hava Durumu Örneği	77
Şekil 31. Mimari Yapı Finansal Enstrümanlar Örneği	79

Şekil 32. Modifiye Aktivasyon Fonksiyonları Training Loss	85
Şekil 33. Modifiye Aktivasyon Fonksiyonları Training Accuracy	86
Şekil 34. Modifiye Aktivasyon Fonksiyonları Validation Loss	86
Şekil 35. Modifiye Aktivasyon Fonksiyonları Validation Accuracy	87
Şekil 36. Boost Fonksiyonel Kümeleme Algoritması Akış Diyagramı.....	88
Şekil 37. Vote Fonksiyonel Kümeleme Algoritması Akış Diyagramı	92
Şekil 38. EUR/USD 2020 Test Sonuçları Ekran Görüntüsü	99
Şekil 39. 2019 USD/TRY Test Sonuçları Ekran Görüntüsü	102
Şekil 40. 2003-2020 2019 USD/TRY uygulama test sonuçları ekran görüntüsü.....	104
Şekil 41. USD/TRY 2018-2020 Test Sonuçları Ekran Görüntüsü	104
Şekil 42. USD/TRY 2018-2020 Test Sonuçları CDS Etkisi	105
Şekil 43. 2007 yılı ons altın uygulama test sonuçları ekran görüntüsü	106

KISALTMALAR

A	: Artış
ABD	: Amerika Birleşik Devletleri
AF	: Aktivasyon Fonksiyonu
BIST100	: Borsa İstanbul 100 Endeksi
CNY	: Çin Yuan
D	: Değişmemiş
DBMS	: Database Management System (Veri tabanı yönetim sistemi)
DMÖ	: Dünya Meteoroloji Örgütü
E	: Eksilme
EUR	: Euro
FOREX	: Foreign Exchange Rate – Ülkelerin para birimleri arası para transferinin yapıldığı uluslararası piyasadır.
GARAN	: Garanti BBVA bankası hisse sendedi
GBP	: İngiliz Sterlini
IDE	: Entegre Geliştirme Ortamı (integrated development environment)
JDK	: Java Development Kit
JPY	: Yapon Yeni
JSF	: Java Server Faces
MA	: Moving Average – Hareketli ortalama
MACD	: Moving Average Convergence Divergence - Hareketli Ortalamaların Mesafesi
ORM	: Object-Relational Mapping
PMI	: Purchasing Managers' Index) –Satın alma Müdürleri Endeksi
RSI	: Relative Strenght Index - Göreceli Güç Endeksi-
RUB	: Rus Ruble
SPA	: Single Page Application
TCMB	: Türkiye Cumhuriyet Merkez Bankası
TDK	: Türk Dil Kurumu
TRY	: Türk Lirası
USD	: ABD Doları
XML	: (Extensible Markup Language) ya da Türkçesiyle Genişletilebilir İşaretleme Dili

SÖZLÜK

Finansal Enstrüman: Yabancı para birimleri, altın gümüş gibi emtialar ve yatırım yapılan bilen bütün araçlara denir.

Volatilité: Zaman serisi içerisindeki oynaklık, dalgalanmalara denir.

Zaman Serisi Tahmini: Zaman serisi geçmiş verilerine bakılarak gelecek verilerin tespiti işlemidir.



GİRİŞ

Bu çalışma kapsamında yapay zeka yöntemleri ile zaman serisi tahmini yapılacaktır. Bu tahminlerin gerçekleştirilmesi için çalışma kapsamında üç farklı öneri bulunmaktadır. Önerilen yöntemlerin ilki aktivasyon fonksiyonlarının modifiye edilmesi üzerinedir. Kolektif sınıflandırma yöntemleri ile yapay zeka algoritmalarının yarışdırılması ise önerilen ikinci yöntemdir. Üçüncü önerilen yöntem korelasyonların çıkarılması için yapay zeka algoritmalarında değişkenlerin, indikatörlerin, formüllerin girdi değeri olarak kullanılmasıdır.

Çalışma kapsamında yer verilen ilk konu modifiye aktivasyon fonksiyonlarıdır. Yapay sinir ağlarının performansı öğrenme oranı, başlangıç ağırlıkları, verilerin normalizasyonu ve uygun aktivasyon fonksiyonu gibi hiper parametrelere göre değişim göstermektedir. Yapay zekâ algoritmaların çalışmasında en önemli problemlerden biri de bu hiper parametrelerin belirlenmesi problemidir. Günümüzde bu problem için hiper parametre optimizasyonları yapılmaktadır. Fakat her problemin yapısı farklı olması sebebiyle ortak hiper parametrelerin kullanılması zordur. Bu değişkenler içinde en önemlilerinden biri uygun aktivasyon fonksiyonunun seçimidir. İyi bir performans için aktivasyon fonksiyonlarının önemini anlamak çok önemlidir. Aktivasyon fonksiyonları verilerin türüne, kurulan mimari yapıya veya ağı farklı katmanlarına göre değişiklik göstere bildiği gibi farklı veriler için yeni aktivasyon çalışmaları da yapılmaktadır. Farklı veriler üzerinde aynı aktivasyon fonksiyonlarının uygulanıp benzer başarı oranlarının beklenmesi de yapay zekâ çalışmalarındaki bir başka problemidir. Bu problem veri türüne aktivasyon fonksiyonun yakınsamamış olması olarak adlandırılabilir. ReLU, Sigmoid ve Tanh fonksiyonları en yaygın ve bilindik aktivasyon fonksiyonları olmakla birlikte hataları da bulunmaktadır. Bu problemlerle ilgili literatürde pek çok çalışma yapılmasına rağmen henüz kapsayıcı ve yaygın bir çözüm bulunamamıştır. Bu problemleri çözümü için bu çalışmada aktivasyon fonksiyonlarının zaman serileri üzerinde daha verimli çalışma yapmasını sağlayan modifiye aktivasyon fonksiyonları önerilmektedir. Çalışma kapsamında lstm, rnn, cnn algoritmaları ile yapılan zaman serisi tahminini daha güçlü hale getirmek için modifiye aktivasyon fonksiyonları tasarlanmak suretiyle bu algoritmalarda uygulanmıştır. Önerilerin matematiksel olarak ispatı ve uygulanabilirliği için zaman serisi problemleri üzerinden modellemeler çalışmada ortaya konacaktır. Testler Avusturalya yağmur verileri, twitter verileri ve EUR/USD verileri yapılmıştır. Önerilen yöntemin farklı zaman serisi verileri ile testleri sonucunda twitter verileri Avusturalya yağmur verileri sonucunda literatür çalışmalarına göre yaklaşık olarak aynı doğruluk sonuçları çıkarken, finansal enstrüman verilerinde literatür

sonuçlarından daha yüksek tahminler elde edilmiştir. Bu sonuçlar ile önerilen yöntemin ispatı yapılmakla birlikte, önerilen yöntemin tutarlı sonuç alabildiği ve yöntemin uygulanabilir olduğu ortaya konulmuştur. Bu çalışma neticesinde literatüre zaman serileri üzerinde çalışacak yeni aktivasyon fonksiyonları kazandırmakla birlikte aktivasyon fonksiyonlarının veri türene yakınsayabileceği yaklaşımı da kazandırılacaktır.

Çalışma kapsamında önerilen bir diğer yöntem bir zaman serisi olan finansal enstrümanların tahmini üzerinedir. Finansal tahminler gerçekten zor bir iştir ve çok aktif bir araştırma alanı olmaya devam etmektedir. Garg çalışmasında geçtiğimiz uzun yıllar boyunca, zaman serilerini farklı yönlerden tahmin etme çabaları incelenmiştir. Doğru bir finansal tahminde bulunmak için birçok değişkeni göz önünde bulundurmak gerekmektedir. Göz önünde bulundurulması gereken değişkenlerin sürekli olarak değişmesi ve yeni değişkenleri ekleniyor olması tahminin zorluğunu doğurmaktadır ve literatürdeki çalışmalarda kayda değer bir başarı gözlemlenememiştir. Bu çalışma kapsamında zaman serisi verilerini tahmin üzerine birden fazla yöntem önerilmiştir. Bu öneriler ile zaman serilerin başarılı tahmin oranını artırılmıştır. Döviz kuru ise bir finansal enstrüman olup ülkeler arası alış verişte kullanılan finansal araçlardır. Finansal enstrümanlar ise döviz kuru(USD/TRY, EUR/USD, EUR/TRY), emtia(altın, gümüş, paladyum), menkul kıymet, kripto para(Bitcoin, Ethereum), endeksler, fonlar olabilir. Gerek iç piyasada gerekse dış piyasada ekonomide ki en önemli araçlardan biri olan finansal enstrümanların gelecekte ne olacağını bilmek çok önemlidir. Toplumsal yaşamın önemli bir parçası olan para hemen hemen her alış verişte kullanıla gelmektedir. Uluslararası ticaretin öneminin arttığı şu günlerde ülkeler arası para birimi oranlarını gösteren döviz kurları da yoğun bir şekilde kullanılmaktadır. Ayrıca finansal pazarlar ve ürün pazarlarının uluslararası piyasaya uyumu her geçen gün artması sebebiyle de döviz kuru hareketlerine duyarlı olması gerekmektedir.

Finansal enstrümanlar finansal piyasa araçları taraflardan finansal varlık ve finansal yükümlülük doğuran sözleşmeler olarak tanımlamaktadır. Finansal piyasa araçları bir ödeme aracı, finansal hak ve bunlarla yakından ilişkili olan ekonomik varlıklar, şeklindedir. Döviz kuru, emtia, menkul kıymet, kripto para, endeks ve fon şeklinde karşımıza çıkan finansal enstrümanlar ekonomik yaşantımızın olmazsa olmazları arasındadır. Finansal enstrümanlara yönelik geleceğe dair tahminlemenin doğru bir şekilde yapılabilmesi ise gerek kişisel, gerek kurumsal, gerekse de ülke ekonomisinin etkin bir şekilde yönetiminin sağlanması noktasında önem arz etmektedir. Çünkü doğru yapılan tahminleme bireylerin daha verimli yerlere

yatırım yapması sonucunda refahlarının artması; fon arz edenler ile fon talep edenler arasındaki vade ayarlamasının sağlanması; küçük tasarruflar bir araya getirerek büyük finansmanların oluşması; alternatif finansmanlar arası dengenin kurularak riskin minimize edilmesi; küçük tasarruf sahiplerinin sermaye piyasalarına dahil olması ile mülkiyetin tabana yayılması; rekabet artışı ile fon kullanım maliyetlerinin düşmesi ve daha dengeli bir gelir dağılımı anlamına gelmektedir. Gittikçe komplike bir hal alan piyasaları doğru yorumlamak finans çalışanları için bile oldukça zor iken, finansal okuryazarlık konusunda eksik bilgiye sahip bireylerin piyasaları doğru yorumlayabilmeleri her geçen gün daha zor bir hal almaktadır.

Çalışma kapsamında finansal enstrüman tahminlerinde kullanılabilecek yapay zeka algoritmaları olan BoostFK ve VoteFK algoritmaları önerilmiştir. Bu noktada düzenli ve ardışık zaman verisinden oluşan geçmiş veri setine bakılarak gelecekteki verinin tahmin edilebileceği zaman serisi kanalıyla doğru bir tahminleme yapılabilmektedir. Ancak zaman serisi verilerinin son derece kapsamlı olması ve her geçen saniyede artması, bunun yanı sıra zaman serisi içerisinde dönemsel alt kırılımların oluşması gibi nedenler dolayısıyla söz konusunun tahminleme'nin finansal kökenli büyük veri analizinde başarı gösteren bir yapay zekâ kanalıyla analiz edilmesi en doğru yaklaşım olacaktır. Nitekim yapay zeka ile finansal enstrüman tahmini, finansal enstrüman tahmin yöntemleri içinde en güncel olanıdır. Yapay zeka ile finansal enstrüman tahmininin yapıldığı benzer çalışmalar da mevcuttur. Örneğin Safiullin ve Qi çalışmalarında BTC/USD döviz çifti verilerinden oluşan zaman serileri analizi LSTM, RNN sinir ağını kullanarak finansal zaman serisi trend tahmini yapılmıştır. Yine benzer şekilde forex piyasalarında EUR/GBP, USD/EUR, USD/JPY, USD/GBP, USD/AUD, USD/CAD, USD/CHF ve USD/CNY çalışmalarda mevcuttur. Öte yandan literatürde kolektif sınıflandırma algoritmalarının ve hibrid yöntemin de finansal enstrüman tahmininde kullanılmış olduğuna rastlanmaktadır.

Çalışma kapsamında RNN ve LSTM'den bir ağ oluşturulacak; buna paralel olarak CNN ve LSTM'den hibrid bir model oluşturulup, ARIMA algoritmasının da eş zamanlı olarak çalıştırılması sağlanarak elde edilen sonuçlar kolektif sınıflandırma yöntemlerinden boosting kanalıyla sunulacaktır. Paralel de kolektif sınıflandırma ve yapay zeka algoritması çalışması suretiyle sonuçlar yarıştırlacak ve en başarılı tahmin sonuçları elde edilmeye çalışılacaktır. Bu sayede daha önce yapılan çalışmalardan farklı olarak aynı anda birden fazla tekniğin paralel kullanımı ve kolektif bir şekilde sunumu ile çok daha doğru bir tahmin

sonucunun ortaya koyulması sağlanacaktır. Tahmini yapılacak finansal enstrümanlar ise Türkiye’de en fazla işlem yapılan finansal enstrüman olması nedeniyle USD/TRY kuru, ons altın ve diğer finansal enstrümanlar olarak belirlenmiştir. Elde edilen çıktılar sayesinde literatüre finansal enstrüman tahminine dair kapsayıcı bir bakış açısı sunulurken finansal okuryazarlık noktasında da katma değer oluşması beklenmektedir.

Bu tez kapsamında, toplumun hemen her kesimi tarafından önemli olan zaman serileri ve finansal enstrüman tahmini konusu ele alınmıştır. Zaman serisi tahmini üzerinde çalışırken veri madenciliği algoritmalarından yararlanılmıştır. Finansal enstrüman tahmini konusu zaman serisi tahmininin bir alt konusu olup finansal enstrüman tahmini küreselleşen dünyamız da, ticaret ile uğraşanlar, finans uzmanları, bankacılar ve daha birçok kişinin ilgi alanına girmektedir. Ayrıca ülke içinde ve ülke dışında hedeflenen makroekonomik seviyelere ulaşılabilmesi amacıyla uygulanması gereken iktisat politikaları için büyük önem oluşturur. Bu çalışma kapsamında zaman serisi analizi için farklı zaman serisi verilerinden yararlanılmıştır. İlave olarak çalışmada veri madenciliği kolektif algoritmaları ile farklı finansal enstrümanlar kullanılarak gelecekte ilgili finansal enstrümanın değerinin ne yönde olacağı tahmin edilmeye çalışılmıştır.

Çalışma kapsamında zaman serisi analizi ve daha özelinde finansal enstrüman tahminine yönelik farklı yaklaşımlar ile konu ele alınmıştır. Önerilen ilk yöntem olan modifiye aktivasyon fonksiyonları yöntemi için farklı zaman serileri ile tahminler gerçekleştirilmiş ve önerilen yöntemin doğruluğu ve uygulanabilirliği ispat edilmiştir. İkinci önerilen yöntem olan BoostFK ve VoteFK algoritmalarının ispatı ve uygulanabilirliğinin gösterimi için finansal enstrüman verilerinden yararlanılmıştır. Önerilen yöntemleri ele alırken farklı zaman serisi verilerinden yararlanılarak önerilen yöntemlerin doğrulukları ve uygulanabilirlikleri ispatlanmıştır. Önerilen yöntemler adım adım açıklanarak ve ispatlanarak ele alınmıştır.

Bu tez çalışması zaman serisi tahmini yöntemlerine farklı birden fazla yöntem katmak amacıyla yapılmıştır. Zaman serisi tahmini yapılırken veri madenciliği yöntemlerinden yararlanılmıştır. Ekonomide geleceği öngörebilmek önemli olduğundan son yıllarda bu konuda sayısız çalışma ortaya konmuş ve dolayısı ile zaman serilerini çözümleyerek geleceği tahmin edebilmek için onlarca değişik yöntem geliştirilmiştir. Geleceği öngörebilmek tarihin her bir döneminde önemli olmuştur. Günümüz ekonomik sisteminin en önemli parçalarından biri olan finansal enstrüman tahmini de ekonomi hayatı için çok önem arz etmektedir. Bu tez

kapsamında zaman serisi tahmini ve finansal enstrüman tahmini veri madenciliği teknikleri ile gerçekleştirilmiştir.

Zaman serisi verileri için Avusturalya yağmur verilerinden ve twitter verilerden yararlanılmıştır. Finansal enstrüman tahmini için öncelikli olarak TCMB sitesinden elde edilen kuralar üzerin de düzenleme yapılır. Yapılan bu düzenlemede kurlar sistemin analiz edileceği veri tabanına aktarılır ve hafta sonları temizlenir. Bu işlemlerden sonra veri madenciliği algoritmaları kullanılarak döviz kurunun bir sonraki gün olacağı değer tahmin edilir. Eldeki verilerde son gün hariç bir sonraki günün değeri de olduğu için yapılan tahmin doğruluğu kontrol edilir. Bu kontroller sonucunda ilgili algoritmanın doğruluk oranı belli olur. Farklı bir şekilde anlatılacak olursa geçmişten bir gün için algoritmalar kullanılarak tahmin yapılmakta, tahminin doğruluğu ise geçmişten bir günün ertesi gününe bakılarak kıyaslanmaktadır. Sonraki aşamada ise Kolektif Sınıflandırma ile finansal enstrüman tahmini yapılır ve çıkan sonuçların doğruluk oranı tespit edilir. Her iki çalışma sonucunda oluşan doğruluk oranları kıyaslanır. Aktivasyon fonksiyonlarının modifiyesi ise önerilen bir diğer yöntemdir. Modifiye işleminden sonra tahminler yapılır. Kıyaslama sonucunda oluşan değerler değerlendirilerek tez sonuçlanır.

Bu çalışma zaman serilerinin ilerleyen zamanlarda hareket yönlerinin ne olacağını tahmin etmek için yapılmış bir çalışma olmakla birlikte Bilgisayar Mühendisliğine algoritmalar üzerine yapılan çalışmalar ile katkıda bulunan bir çalışmadır. Çalışma kapsamında benzer çalışmalar incelendikten sonra tezin kapsamı belirlenmiştir. Çalışma yöntemi olarak izlenen yol önerilen yöntemlerin adım adım açıklanması ve ispatlanması üzerinedir. Adım adım açıklanan yöntemler zaman serisi verileri ile test edilmiştir. Test sonuçları literatür çalışmaları ile kıyaslanmış ve önerilen yöntemlerin doğrulukları ispat edilmiştir. Önerilen yöntemlerin matematiksel ispatları gerçekleştirilmiştir.

Bu tez içeriğinde piyasanın bütün oyuncuları için önemli olan zaman serilerinin gelecekte ne olacağı yani tahmini ile ilgili çalışmalar yapılmıştır. Çalışma içeriğinde zaman serisi analizi, finansal enstrüman tahmini üzerine önerilen yöntemler, bu kapsamada geliştirilen uygulama ve bu uygulama ile yapılan test sonuçları bulunmaktadır. Bu tezde izlenen yöntem beş bölümden oluşmaktadır.

Tezin giriş kısmında tezin konusu, önemi, amacı, ele alınış biçimi, içeriği, yöntemi gibi konulara değinilmiştir.

Birinci bölüm ise yöntem ve alan araştırması üzerinedir. Bu bölümde zaman serisi analizi, finansal enstrüman tahminin önemi, finansal enstrüman tahmininde kullanılan yöntemler, literatür taraması gibi konulardan bahsedilmiştir. Finansal enstrüman tahmininde kullanılan yöntemler hakkında kısaca bilgi verildikten sonra bu yöntemlerin en önemlilerinden olan teknik analiz konusu ele alınmıştır. Teknik analizin önemi ve çalışma mantığı üzerinde durularak konunun önemi pekiştirilmiştir. Bu bölümde ayrıca veri madenciliği bölümüdür ve veri madenciliği teknikleri, bu tekniklerden kolektif sınıflandırma yöntemlerinden bahsedilmiştir. Bu yöntemlerden anlatılırken verilen örnekler de finansal enstrüman verileri kullanılmıştır. Veri madenciliği algoritmaları anlatılırken finansal enstrüman verileri ile örnekler oluşturularak konuya farklı bir bakış açısı katılmıştır. Veri madenciliği algoritmalarının birlikte kullanılması yöntemi olan Kolektif Sınıflandırma incelendikten sonra finansal enstrüman verileri ile Kolektif Sınıflandırma örneklendirilmiştir.

İkinci bölüm ise önerilen yöntemlerden bahsedilen bölümdür. Bu bölümde modifiye aktivasyon fonksiyonları, kolektif sınıflandırma ile finansal enstrüman tahmini önerileri üzerine detaylı bilgi verilmiştir. Bu bölümde diğer bölümlerde bahsedilen yöntemler zaman serisi verisi ile bir uygulama üzerinde detaylı bir şekilde anlatılmıştır. İlave olarak ikinci bölümde korelasyonlara değinilmiştir.

Üçüncü bölüm önerilen yöntemin uygulaması ve değerlendirmesi üzerinedir. Çalışmanın üçüncü bölümünde ikinci bölümde anlatılan algoritmalar ve öneriler ile uygulamalar geliştirilmiştir. Geliştirilen bu uygulamalarda zaman serisi tahminlerinde algoritmaların sonuçlarının doğruluk oranları test edilmiştir. Önerilen yöntem hakkında ve uygulaması hakkında detaylı bilgi verilmiştir. Önerilen yöntemlerin gerçekleştirilebilmesi için nasıl bir uygulama olması gerektiği ve bu uygulamanın geliştirilme adımları anlatılmıştır. Önerilen yöntemlerin sonuçları tartışılmıştır.

Dördüncü bölüm sonuç kısmıdır. Bu bölümde üzerinde çalışılan uygulamanın sonuçları değerlendirilmiştir. Çıkan sonuçların başarı oranları gözlemlenerek geçmişte yapılan zaman serisi tahminleri ve finansal enstrüman tahminleri ile kıyaslanacaktır.

BİRİNCİ BÖLÜM

ALAN ARAŞTIRMASI ve ZAMAN SERİSİ ANALİZİ

Bu bölüm dört ana başlıktan oluşmaktadır. İlk kısım zaman serileri ve zaman serileri analizi hakkındadır. İkinci kısımda ise bir zaman serisi olan finansal enstrümanlar hakkında bilgi verilecek, finansal enstrüman tahminin önemine değinilecektir. Finansal enstrümanların tahmini için literatürde kullanılan yöntemlere değinilecektir. Üçüncü kısımda ise veri madenciliği teknikleri ve veri yaşam döngüsü hakkında bilgi verilecektir. Dördüncü bölümde ise kolektif sınıflandırma ve diğer yapay zeka teknikleri hakkında bilgi verilecektir. Beşinci kısımda ise literatür araştırmalarına yer verilecektir.

1.1. Alan Araştırması

Bu bölümde literatürdeki zaman serisi analizi, aktivasyon fonksiyonları, finansal enstrüman tahmini, bu tahminlerde kullanılan yöntemler ile ilgili literatür taraması hakkında bilgi verilecektir. Bu çalışmaların önerilen yöntem ile benzerliklerine farklılıklarına değinilecektir.

Literatürdeki finansal enstrüman tahminleri ve kolektif sınıflandırma çalışmaları hakkında bilgi verilmiştir. Prokop Finansal Araçlarda Piyasalar Direktifinin (MiFID) finansal analistlerin kazanç tahminleri üzerindeki etkisini incelemiştir, çalışması sonucunda MiFID'in finansal araçların davranışları üzerindeki etkisinin ve finansal analistlerin kazanç tahminlerinin çıkar çatışmaları tarafından ne ölçüde yanıltılabileceğinin bir değerlendirmesini oluşturması bakımından öz sermaye yatırımcıları, finansal hizmet firmaları ve düzenleyiciler için benzerdir. Kim USD/EUR, USD/JPY ve USD/BRL para birimlerinden oluşan bir döviz portföyü için günlük koşullu riske maruz değer (C-VaR) tahminleri sunmaktadır. Bunu yapmak için, bir Bayesian Markov zinciri Monte Carlo algoritması kullanarak zamanla değişen koşullu korelasyonlarla çok değişkenli stokastik oynaklık modellerini tahmin etmiştir. Jiang çalışmasında yeni bir boosting yöntemi önermiş ve isimlendirmesi FESBoost şeklinde olmuştur. Çalışmada önerilen algoritmanın üstünlüğü, 9 sentetik veri seti ve 34 KEEL veri seti üzerinde deneysel olarak doğrulanmıştır ve önerilen algoritma ayrıca yedi algoritma ile karşılaştırılmıştır ve sonuçlar önerilen algoritmanın diğer karşılaştırılan algoritmalarından daha iyi genelleme performansına sahip olduğunu göstermiştir. Zheng çalışması kamyon kazaları üzerinedir ve gradient boosting

yöntemini kullanmıştır. Çalışması sonucunda yirmi beş değişken test etmiş ve bunların 22'si yaralanma şiddetine katkıda bulunan önemli değişkenler olarak belirlemiştir, ancak İlk 11 değişken, yaralanma tahminlerinin %80'inden fazlasını oluşturduğunu tespit etmiştir. Fathian çalışmasında kümeleme ve kollektif sınıflandırıcılarına dayalı birleşik bir model örneklendirmiş ve bagging boosting yöntemlerini kıyaslamıştır.

Bu çalışmada yapay sinir ağları için en önemli hiper parametrelerden olan aktivasyon fonksiyonlarının modifiyesi üzerine çalışma yapılmıştır. Literatürdeki pek çok aktivasyon fonksiyonu başka bir aktivasyon fonksiyonunun modifiyesi ile oluşturulmuştur. Modifiye aktivasyon fonksiyonu örneğini çalışmasında sunan Anireh sinir ağları için Hiperbolik Tanjant Aktivasyon Fonksiyonunun değiştirilmiş bir versiyonunu sunmuştur. İşlev, ikinci dereceden bir Gerçek Sayı Formülü (RNF) algoritmasına ve vanishing gradient önlemek için giriş etkinleştirmelerinde uyarlanabilir bir normalleştirme kısıtlamasına dayalı olarak Euler sayısına (e) yaklaşık olarak bir tamsayı kalibrasyon sabiti kullanmıştır. Bir varsayımsal ve gerçek dünya veri seti kullanarak önerilen değişikliğin etkinliğini göstermiştir ve bu işlevi kullanan öğrenme algoritmaları ile daha düşük çalışma sürelerinin elde edilebileceğini ve bu da eğitim sırasında gelişmiş hızlanmalara ve öğrenme doğruluklarına yol açabileceğini göstermiştir. Son zamanlarda, derin öğrenme, görüntüleri, sesleri ve doğal dilleri vb. işlemede büyük başarı elde ettiği gibi aktivasyon fonksiyonlarının derin öğrenmedeki kilit faktörlerden biri olduğuda aşıkardır. Shan , ReLU LReLU'nin sınırsız sağ el tepkisi için biyolojik nöronların özelliklerine göre geliştirilmiş bir Sızdıran Tek Tepeli Üçgen Doğrusal Birim (LSPTLU) aktivasyon fonksiyonu sunulmaktadır. LSPTLU, biyolojik nöron özü ile daha uyumludur ve farklı veri setlerinde, örneğin MNIST, Fashion-MNIST, SVHN, IMAGENET, CALTECH101 ve CIFAR10 veri setlerinde ReLU ve LReLU'nun eşdeğeri veya ötesinde mükemmel performansa ulaştığı bir makale yayınlamıştır. Rulmanlar, endüstriyel döner makinelerde kritik bileşenlerdir olmakla birlikte rulman arızaları makine performansının düşmesine ve hatta bir felakete neden olabilmektedir. Rulman arızaları ile ilgili yapay zeka çalışmaları yapılabilmekte ve bu arıza tespitinde kullanılabilmektedir. Niu, Parametrik Düzeltilmiş Doğrusal Birim(PReLU) aktivasyon katmanları ile temel bileşen analizine ve uyarlanabilir derin inanç ağına dayalı bir yuvarlanan eleman taşıyan arıza teşhisi yaklaşımı önermektedir. Bir diğer modifiye aktivasyon fonksiyonu örneğini Abubakar 2014 yılında ortaya koymuştur. Abubakar sinir ağının performansını iyileştirmek için Sinir Ağı aktivasyon fonksiyonunun modifikasyonunu sunmuştur. Değiştirilen aktivasyon fonksiyonu, SigHyper olarak kod adı verilmiştir. SigHyper'ın performansı, ham petrol fiyat veri setinde

son teknoloji aktivasyon fonksiyonuna göre deęerlenmesi sonucunda önerilen SigHyper'in Sınır Ağının doğruluęunu iyileştirdięini göstermiştir. Bu konudaki dięer alıřmalar için (Alqatawneh, Rabeyee ve Zhang 2021), (Mercioni ve Tiron 2019) bakılabilir.

Tanaka zaman serileri analizi üzerine yaptıęı alıřma ile zaman serileri analizinde ortaya ıkan problemlere özüm setleri sunmuřtur. Palma yaptıęı alıřmada zaman serileri analizi ARMA ve ARIMA gibi bir dizi iyi bilinen modeli örnekleyerek tek deęiřkenli zaman serilerinin ele alınmasına odaklanmakla birlikte Bayes yöntemleri, Gauss olmayan veriler, yerel duraęanlık, kayıp deęerler ve aykırı deęerler ve eřik modelleri gibi birçok yararlı ve yeni geliřtirilmiř teknik sunmuřtur. Box zaman serileri analizi ile ilgili alıřmasında ileri istatistik, matematik, ekonomi, finans, mühendislik ve fizik alanlarında alıřmalar yapmakla birlikte ok deęiřkenli zaman serisi analizi, ARCH ve GARCH gibi zamanla deęiřen oynaklık modelleri, doęrusal olmayan zaman serisi modelleri ve uzun bellek modellerini kapsayan özel konular hakkında alıřma yapmıřtır. Avishek alıřmasında zaman serilerinin istatistiklerini, teorisini ve uygulamasını anlatmıř, alıřmasında zaman serisi tahmini yapmıřtır. Zaman serisi verilerini yükleme keřfetme, tahmin etme ve görselleřtirme konusunda detaylı bilgi vermekle birlikte zaman serisi tahminlerini regresyon ve hareketli ortalamalar ile örneklemiřtir. Koenda alıřmasında ekonomi alanında zaman serileri tahmini yaparken tek deęiřkenli zaman serileri ve ok deęiřkenli zaman serilerine deęinmiřtir. Shabir alıřmasında sıcaklık zaman serisi üzerine yaparken yeni bir stokastik zaman serisi modeli ortaya koymuřtur ve tahmin sonularını bir adım ödeye tařımıřtır. Angus zaman serileri üzerine yaptıęı alıřmada hiper parametre ayarlama konusuna deęinmiřtir ve yeni modeller ortaya koymuřtur. William ekonomik zaman serileri üzerine yaptıęı alıřmada Spektrum Teorisine ve haberleřme mühendislięi ile ilgili yapılan alıřmalara deęinmiřtir. Peiyuan zaman serileri üzerine önerdięi yeni modelde rastgele matris topluluklarından deęerler almıř teorik özümle ve istatistiksel özellikler üretmiřtir. alıřması sonucunda rastgele matris diferansiyel denklemleri ve zaman serisi modelinin potansiyel uygulamaları önerilmiřtir. Yanga alıřmasında finansal zaman serilerinde derin öğrenmede ift yönlü uzun kısa süreli bellek sınır aęı (BiLSTM) uygulamıř, LSTM destek vektör regresyonu (SVR) ve diferansiyel otoregresif hareketli ortalama modelinin (ARIMA) tahmin performansları karřılařtırmıřtır. alıřması sonucunda gemiř ve gelecekteki veri bilgilerini aynı anda tam olarak yakalayabilen, verilerin ters iliřkisini hesaba katan BiLSTM modelinin en yüksek tahmin doğruluęuna sahip olduęunu göstermiřtir. Jastrzebska alıřmasında zaman serisi sınıflandırma problemi görsel örüntü tanıma problemine dönüřtürecekle yeni bir yöntem

önermiş, bu öneriyle farklı uzunluklardaki zaman serileri için çalışır ve genişletilebilir olmuştur ve standart kümeleme algoritmaları zaman serileri üzerinde uygulanmıştır. Khalil çalışmasında zamana serisi analizi yaparak stok fiyatlarını ve talep tahmin etmek için makine öğrenme modelleri kullanmıştır. Hegui çalışmasında derin öğrenme ile zaman serisi tahmini üzerine TCRAN adında yeni bir yöntem önermiştir. Animas'ın çalışması yağış tahmini üzerine olup zaman serisi tahmini için modern makine öğrenimi algoritmalarının karşılaştırmalı analizini yapmıştır ve LSTM, Stacked-LSTM, Çift Yönlü-LSTM Ağlarına dayalı modeller, XGBoost ve Gradient Boosting Regressor, Linear Support Vector Regresyon ve Extra-trees Regresyon kullanmıştır. Çalışması sonucunda LSTM ile tahmin sonuçlarını daha başarılı bulmuştur.

Marques çalışmasında zaman serisi tahmini için gelişen bulanık modelleme yaklaşımının yeni bir sınıfı olan ePL-KRLS-FSM'yi önermiştir. Bu yöntem ile verilerdeki yanlışlıkların daha iyi ele alınmasını sağlayarak, kaotik verileri daha kesin bir şekilde tahmin edebilen bir model önermiştir. Modelde farklı zaman serileri ile kıyaslamalar yapmış ilave olarak geleneksel tahmin modelleri ile kıyaslamalar yapılmıştır. Sonuçta önerilen modelin rekabetçi ve karşılaştırılan modellerden daha tutarlı olduğu gösterilmiştir.

Fanjiang çalışmasında Web hizmetleri (WS'ler) için hizmet kalitesi (QoS) zaman serisi tahmini üzerine yapmıştır ve çok adımlı QoS zaman serisi tahmin problemini çözmek için genetik programlama tabanlı bir yaklaşım önermiştir. QoS zaman serisi veri setine dayalı olarak, önerilen yaklaşım doğrulamış ve doğruluk açısından üstünlüğünü göstermek için birkaç geleneksel yöntemle karşılaştırmıştır.

Başa çalışmasında Hindistan tropikal ıslak ve kuru bölgede yer alır ve muson mevsiminde yıllık yağışları tahmin eden bir çalışma ortaya koymuştur. Çalışmasında yağış miktarını tahmin etmek için Mevsimsel Oto-regresif Entegre Hareketli Ortalama (SARIMA), Holt's Winter Seasonal Method (HWSM), Generalized Auto-Regressive Conditional Heteroskedasticity (GARCH) ve Holt's Linear Trend Method (HLTM) gibi çeşitli zaman serisi tahmin modelleri kullanmıştır. Farklı Zaman Serisi tahmin modellerinin karşılaştırmalı bir analizini gerçekleştirmek için kullanılan değerlendirme parametrelerinden RMSE (Kök Ortalama Kare Hata), Ortalama Mutlak Hata (MAE) ve Ortalama Kare Hatadır (MSE) yöntemleri ile modelleri değerlendirmiş ve diğer modeller ile karşılaştırıldığında HWSM modelinin en başarılı yöntem olduğunu ortaya koymuştur.

Saad çalışmasında koronavirüsün neden olduğu COVID-19 vaka sayısı tahmini yapmıştır. Avustralya, Kanada, Mısır, Hindistan, Amerika Birleşik Devletleri ve Birleşik Krallık verileri üzerine çalışmasını yaparken Lineer Olmayan L-BFGS-B Fitted SEIRD olarak adlandırılan bölümlü çok değişkenli epidemiyolojik model SEIRD'nin optimize edilmiş bir versiyonunun aksine Mevsimsel Oto Regresif Entegre Hareketli Ortalama (SARIMA) yöntemlerinden yararlanmıştır. Çalışmaları sonucunda SEIRD ile daha başarılı tahmin sonuçları ortaya koymuştur.

Liu ve Zhang, sıkıştırılmış algılama perspektifinden zaman serisi tahmininin oldukça zorlu problemini incelediler ve Convolution Nuclear Norm Minimization (CNNM) adlı öğrenmesiz bir yöntem önerdiler. Guangcan ise çalışmasında ilgili yapı dizilerini evrimsel olarak düşük dereceli düzenli sinyallere dönüştürmek amacıyla CNNM'ye öğrenilebilir, ortonormal bir dönüşümü entegre ederek sorunlara yaklaşmaya çalışır ve Öğrenmeye Dayalı CNNM (LbCNNM) yöntemini önerir. Time Series Data Library (TSDL) ve M4 Competition'dan (M4) 100,452 gerçek dünya zaman serisi üzerinde yapılan kapsamlı deneyler sonucunda LbCNNM'nin üstün performansını gösterdiğini ortaya koymuştur.

Gupta enerji sektöründe gün geçtikçe artan güneş enerjisi santrali sayısı ve fosil yakıtlara olan bağımlılığın azalması nedeniyle, akıllı şebeke entegrasyonu için geleceğe yönelik planlamalar için güneş enerjisi üretiminin tahmini ile ilgili çalışma ortaya koymuştur. Aylık ve haftalık olarak güneş enerjisi üretimini tahmin etmek için Facebook (FB) Prophet ve Extreme Gradient Boost (XGB) gibi Makine Öğrenimi algoritmaları kullanılmakla birlikte çalışmasında, XGB modelinin, FB modelinden daha iyi tahmin ve daha iyi uyum açısından tahminde etkili olduğu sonucuna varmıştır. Çalışmasında ortaya koyduğu zaman serisi modelinin performansını kontrol etmek için RMSE, MAPE ve MAE parametreleri hesaplamıştır.

Malhan rüzgar enerjisinin çok adımlı tek değişkenli zaman serisi tahminindeki performanslarını değerlendirmek için üç ayrıştırma tabanlı makine öğrenme algoritmasını karşılaştırmaktadır ve seçtiği modeller STL-ARIMA, CEEMD-BiLSTM ve CEEMDAN-BiLSTM'dir. Bu modellerin doğruluğu, kısa vadeli yani bir gün öncesi ile uzun vadeli üç yıl öncesi arasında değişen farklı zaman dilimleri için test etmiştir. Sonuçlar, CEEMDAN-BiLSTM'nin kısa vadeli rüzgar enerjisi üretim tahmini için en uygun model olduğunu ortaya koymuştur. Bulduğu bir diğer sonuç ise STL-ARIMA uzun vadede daha iyi rüzgar enerjisi tahminleri veriyor olmasıdır.

Maya zaman serisi tahminindeki kayıp veri problemini çözmek için meta-öğrenme ve transfer-öğrenme yöntemlerini birleştirerek sinir ağlarına dayalı zaman serisi tahminlerinin ortak sorunlarını başarıyla çözen bir çalışma ortaya koymuştur. Önerdiği algoritmaların güçlü ve zayıf yakınsaklıkları analiz ederek eksik verilerle Mexico City'nin hava kirliliğini tahmin etmiştir. Yaptığı çalışma sonucunda meta-aktarım öğreniminin çok iyi tahmin doğruluğuna sahip olduğunu göstermiştir.

Demidova çalışmasında Uzun kısa süreli bellek (LSTM) kayıp fonksiyon optimizasyonuna biyolojiden ilham alan bir yaklaşımı ele almış ve geri yayılımla eğitilmiş ve Genetik Algoritma, Parçacık Sürüşü optimizasyonu ve Balık Okulu Araması(FSS) dahil olmak üzere biyolojiden ilham alan algoritmalar kullanılarak farklı LSTM ağlarının performansını karşılaştırmıştır. Sonuçta üstel adım bozulması(ETFSS) ve FSS algoritmaları, çoğu optimizasyon probleminde GA ve PSO'ya kıyasla üstün sonuçlar ortaya koyduğunu göstermiştir.

Sarıkaa çalışmasında bulut kaynaklarının tahminleri zamana bağlı olduğu için zaman serisi tahmin modelleri kullanmış ve birbirini izleyen saatler için kaynak kullanımını tahmin etmek için farklı zaman serisi modelleri ve topluluk teknikleri yerleştirilmiştir. Veri setini incelemek ve uygun modeli seçmek için farklı zaman serisi analiz teknikleri uygulanmıştır. Çalışması sonucunda CPU kullanımı, disk okuma süreleri, disk yazma süreleri ve bellek kullanımı gibi çeşitli kaynak türleri tahmin etmiştir.

Mouine belirli bir zaman aralığı verilen oyun oturumu iş yükleri üzerinde etkili bir tahmin modelinin tanımlanması üzerine yaptığı çalışmada bulut kaynak izleme verilerine ihtiyaç duyan sanal makinelerin sayısını tahmin etmek için ARIMA, Prophet ve LSTM kullanarak zaman serisi tahmin modellerini analiz etmiştir. Çalışması sonucunda LSTM modelinin RMSE ve MAE açısından sanal makinelerin talebini tahmin etmede en doğru model olduğunu sonucunu ortaya koymuştur.

Carpenter çalışmasında COVID-19 pandemi verilerini kullanarak zaman serisi tahmini yapmıştır. Bunu yaparken salgının yalnızca ilk dört haftasından sonra küresel ölçekte tahminler yapabilen bir model önermektedir. Çalışmasında LSTM, GRU algoritmalarından yararlanmıştır. LSTM ve GRU'nun farklı düzenleyiciler kullanarak nasıl performans gösterdiğini karşılaştırmıştır. Sonuçta yalnızca 28 günlük eğitim verisi içeren veri kümelerinde RMSE'yi %3 oranında azalttığını göstermiştir.

Lin çalışmasında zaman serisi tahmini için yeni bir derin öğrenme yaklaşımı olan SSDNet'i sunmuştur. SSDNet, trend ve mevsimsellik bileşenleri ve tahmin için önemli olan önceki zaman adımları dahil olmak üzere olasılıklı ve yorumlanabilir tahminler sağlamak için Transformer mimarisini durum uzay modelleriyle birleştirmektedir. Çalışma ile SSDNet'in performansını beş veri setinde değerlendirerek, SSDNet'in doğruluk ve hız açısından değerlendirmiş, derin öğrenme ve istatistiksel yöntemlerden daha iyi performans gösterdiğini ve anlamlı eğilim ve mevsimsellik bileşenleri sağlayabildiğini ispatlamıştır.

Zúñiga çalışmasında ForGAN adında yeni bir zaman serisi tahmin yöntemi önermiştir. hasım üretici ağı olarak adlandırılan zaman serisinin olasılıksal bir tahmininin, bir adım ileri tahminler için başarıyla kullanıldığı göstermek istemiştir. Çalışması ile çok adımlı tahminleri gerçekleştirmek için birden fazla çıktıya sahip değiştirilmiş bir ForGAN mimarisi önerilmiştir.

Kellerman çalışmasında makinelerden gelen büyük miktarda sensör verisinin zaman alanında analiz etmiştir. Çalışmasında “temporal Resolution warping” (TRW) olarak adlandırdığı bir önişleme yöntemini tanıtmış ve yöntemlerinin doğrulanması için, farklı uygulamaların referans zaman serilerini tahmin etmek için artık katmanlara sahip ileri beslemeli ve evrişimli sinir ağları kullanmıştır. Teknikleri ile eğitimin %26'dan fazla hızlandığını göstermiştir.

Arporn çalışmasında orijinal seriyi farklı frekans ufkunda benzersiz özellikler içeren birkaç alt seriye ayırtmak için ampirik dalgacık dönüşümü (EWT) uygulanmıştır. Alt seri daha sonra tahmin görevlerini gerçekleştirmek için hareketli ortalama filtresi (MA), ARIMA ve ANN ile birlikte kullanmakla birlikte, dört halka açık gerçek dünya veri seti üzerinde gerçekleştirmiş ve diğer altı kıyaslama modeliyle karşılaştırmıştır. Sonuçta, önerdiği modelin yüksek tahmin doğruluğu sağladığını göstermiştir.

Jacoby çalışmasında Ticari Mikrodalga bağlantılarındaki (CML'ler) zayıflama zaman serileri için bir Uyarlamalı Bulanık Tahmin (AFP) yöntemi önermektedir. Zaman serisi tahmin modelleri düzenli olarak tüm veri setinin aynı Veri Üretme Sürecini (DGP) takip ettiği varsayımına dayandırdığı çalışmasında Tekrarlayan Sinir Ağı (RNN) ve Otoregresif Entegre Hareketli Ortalama (ARIMA) varyasyonları ile model kullanmıştır. Sonuçta önerilen yöntemlerin, belirli modele ve veri kullanılabilirliğine bağlı olarak, tahmin modelinin performansını %30-40 oranında arttırdığı göstermiştir.

Samal çalışmasında hava kirliliği tahmininde bulunmuştur. Bu yaparken derin öğrenme kullanmış ve birden fazla değişkeni aynı anda tahmin etmeyi amaçlamıştır. Pekin'in kirli şehirlerinden biri olan Gucheng konumu hava kirliliği tahmini yapmış ve yaptığı çalışmanın sonucuna göre hava kirliliği tahmininde etkili olmuştur.

Choi çalışmasında metinden bağımsız konuşmacı doğrulaması yapmıştır. Çalışmasında veri seti olarak VoxCeleb ve Speakers in the Wild veri kümelerini kullanmıştır. Önerdiği yöntemin kısa ifade koşulu altında metinden bağımsız konuşmacı doğrulama performansını iyileştirdiğini göstermiştir.

Liao çalışmasında derin öğrenme ile sıcaklık zaman serisi tahmini yapmıştır. Çalışmasında orijinal hava durumu verilerini sayısal zaman serileri olarak görüntüleyerek, olasılıksal tahminler üretmiştir. Çalışmasında LSTM algoritmasını kullanmış ve çalışmasını diğer modeller ile kıyaslamıştır.

Literatürdeki finansal enstrüman tahmini ile ilgili örnekler genellikle geleneksel yöntemler veya istatistiksel yöntemler üzerinedir. Formüller ve indikatörler kullanılarak yapılan çalışmalarda bulunmaktadır. Bu çalışma kapsamında önerilen mimarinin literatürdeki çalışmalardan farklı olan noktası indikatörlerin ve formüllerin yapay zeka algoritmalarında değişken olarak kullanılmasıdır. Bir diğer farklı nokta ise kolektif sınıflandırma ile yeni bir algoritma sunuluyor olması ve bu algoritmanın diğer yapay zeka algoritmalarından daha başarılı tahminler elde ediyor olmasıdır. Literatürdeki veri madenciliği ve yapay zeka ile finansal enstrüman tahmini üzerine yapılan çalışmalar genellikle birden fazla algoritmanın sonuçlarını kıyaslanması üzerinedir. Bu çalışmada algoritma sonuçları kıyaslanmakla kalmamış yarıştırmış ve en başarılı tahmin sonuçları bir adım öteye taşınmıştır.

Literatürde zaman serisi tahmini için istatistiksel, regresyon ve makine öğrenmesi yöntemleri kullanılmıştır. Farklı mimari yaklaşımlarda bulunan çok az çalışma bulunmaktadır. Çalışmalar genellikle tek bir veri seti üzerine uygulanmıştır. Çalışmamız kapsamında yapılan zaman serisi tahmini modeli makine öğrenmesi ile yapılan zaman serisi tahmini modeli kapsamında girmektedir ve literatürdeki bu tür çalışmalara benzerlik göstermektedir. Literatürdeki çalışmalardan farklı olarak yapay sinir ağlarının en önemli hiper parametrelerinden olan aktivasyon fonksiyonlarına yeni aktivasyon fonksiyonları önerilmiştir. Bu çalışma kapsamında önerilen aktivasyon fonksiyonları ile hem yapay sinir ağlarına katkıda bulunulmuş hem de fonksiyonlar zaman serileri üzerinde uygulanarak

tutarlılıkları ispatlanmıştır. İlave olarak farklı veriler üzerindeki davranışları gözlemlemek için testler yapılmak suretiyle literatürdeki çalışmalarla kıyaslamalar yapılmıştır.

1.2. Zaman Serisi Analizi

Bu çalışma kapsamında zaman serisi analizi yapmak suretiyle zaman serisi tahmini üzerine çalışmalar yapılmıştır. Zaman serisi istatistiksel bir bakış açısından zaman içinde değişen stokastik sürecin kayıtları olarak kabul edilir.

Genellikle zaman serisi analizinde gözlemlerin eşit aralıklı ayırık zamanlarda yapıldığı duruma odaklanılarak çalışmalar yapılmaktadır. Zaman serilerinin ayırt edici özelliği, zamansal bağımlılıktır: Serinin önceki değerine bağlı olarak belirli bir zaman noktasındaki bir gözlemin dağılımı, bu önceki gözlemlerin sonucuna bağlıdır, yani sonuçlar bağımsız değildir.

Bir zaman serisini analiz etmek amacıyla, zaman serilerini genellikle tüm negatif olmayan tamsayılar üzerinden modellenmekle birlikte gözlemlenen zaman serisi değerlerinin, stokastik bir sürecin parçası olan $Y_1, Y_2, \dots, Y_T$ rastgele değişkenlerinin gerçekleşmeleri olduğunu varsayılır. Diğer bir deyişle $Y_1, Y_2, \dots, Y_T$, değeri kesin olarak tahmin edilemeyen rastgele değişkenlerdir. Bunun yerine, değişkenin, Y 'nin hangi değerleri alabileceğini ve bu değerleri hangi olasılıkla üstlendiğini tanımlayan bir olasılık dağılımına göre değiştiği söylenir (Charlton ve Caimo 2012).

Bir zaman serisi, zaman içinde birbirini izleyen eşit aralıklı noktalarda alınan bir dizidir. Zaman serisi analizi, anlamlı istatistikleri ve verilerin diğer özelliklerini çıkarmak için zaman serisi verilerini analiz etme yöntemlerini içerir. Zaman serisi tahmini, önceden gözlemlenen değerlere dayalı olarak gelecekteki değerleri tahmin etmek için bir modelin kullanılmasıdır. Zaman serisi örnekleri:

- Finansal enstrümanlar
- Havaalanı yolcu sayısı
- Video, film, diziler ve ses kayıtları
- Müzik üretimi
- Doğal dil çevrimleri (İngilizce- Türkçe vs.)
- Google voice search, sri
- Anamoli yakalama, kriz tahmini

- Mevsimsel analizler, sezonsal analizler
- Eksik veri tahmini, hata düzeltme
- Hava durumu tahmini
- Sosyal medya verileri

Bu çalışma kapsamında zaman serilerinden finansal enstrümanlar, hava durumu verileri, sosyal medya verileri ile çalışmalar yapılmıştır. Özellikle finansal enstrümanlar konusunda detaylara yer verilmiştir. Bu veriler ile önerilen yöntemler üzerine çalışmalar yapılarak önerilen yöntemlerin doğrulukları ve tutarlılıkları ispat edilmiştir.

1.3. Finansal Enstrüman Tahmini

Toplumun bütün kesimleri bireyler, işletmeler, devlet kurumları tarafından alış veriş için kullanılan araçlara finansal enstrümanlar denir. Bu finansal enstrümanlar aşağıdaki gibidir.

- Döviz Kuru (USD/TRY, EUR/USD, EUR/TRY)
- Emtia (Altın, Gümüş, Paladyum)
- Menkul Kıymet (Bist 100)
- Kripto Para(Bitcoin, Ethereum, Ripple)
- Endeksler
- Fonlar

Ekonomide finansal enstrüman tahmini para politikasına yön verebilmek, kişisel yatırımların şekillenmesi ve işletmelerin gelecek planlamaları için çok önemlidir. Finansal enstrümanın doğru tahmin edilmesi kişiler ve kurumlar için çok önemli avantajlar ortaya çıkarabilir. Tam tersi yönden bakacak olursak finansal enstrümanı yanlış tahmin eden kişi ve kuruluşlar çok zor durumda kalabilmektedirler. Finansal enstrüman tahmini üzerine birçok model ve fikir geliştirilmiş olsa da, hem uygulama açısından hem de teorik açıdan gelişmiş bir model bulmak zordur (Çolpan 2005).

Döviz kurları, bir ülkenin ekonomik sağlık düzeyini belirlemek için kullanılan bir göstergedir. Bir ülkenin döviz kurları, ekonomik istikrar için sürekli gözlemlenmesi ve sürekli analiz edilmesi gereken göstergeleri tanımlar. Bir ülkeden diğerine para alım satımı

nedeniyle deęişen finansal piyasaların etkisiyle döviz kuru günlük dalgalanabilir. Döviz kurları, açık bir ekonomi çağında ve entegre bir küresel ekonomide artan rekabet çağında dünya ticareti için kilit faktörlerden biri haline gelmiştir (Agus Kartono 2020). Döviz tüccarları, arz ve talepteki dalgalanmalara göre deęişen fiyatları bilirlerse, döviz alım satımından faydalanacaklardır (Markova 2019). Uluslararası ticarete, ihracat / ithalat mallarının maliyeti doğrudan döviz kurlarına baęlı olacaktır çünkü iki farklı ülkeyi kapsamaktadır. Döviz kurlarının işlem saatleri boyunca sürekli deęişmesi nedeniyle, doğru döviz kuru tahminleri, finans kuruluşlarının birçok işletmesinin başarısı için önemli bir faktördür. Günlük trilyon dolardan fazla dolaşıma sahip döviz piyasası, dünyanın en büyük finans piyasasıdır. Bu pazar, dünya çapında döviz işlemlerine katılan uluslararası kurumları birbirine bağlar ve dünyada gerçekleşen tüm işlemleri kapsar.

1.3.1. Finansal Enstrüman Tahmininde Kullanılan Yöntemler

Kur tahmini için birçok farklı yöntem kullanılmaktadır. Fakat bu modeller içinde gelişmiş bir model bulmak oldukça zordur. Kullanılan yöntemlerden bazıları; indikatörler aracılığı ile döviz kuru tahmini, veri madencilięi algoritmaları ile döviz kuru tahmini, faiz oranları paritesi ile döviz kuru tahmini, Uluslararası Fisher etkisi ile döviz kuru tahmini gibi birçok yöntemle döviz kuru tahmini yapılabilmektedir.

Forex(foreign exchange rate) döviz piyasası, döviz ticareti için küresel bir merkezi olmayan veya tezgah üstü piyasasıdır. Bu piyasa her para birimi için döviz kurunu belirler. Geçerli veya belirlenmiş fiyatlarla para alım, satım ve takas işlemlerinin tüm yönlerini içerir. Forex piyasasının tahmin metodu uygulamasının iki temel adımı vardır: ilk olarak veri setinin analiz edilmesi sonrasında ise veri setine en uygun tahmin metodunun seçilmesidir (Tutal 2011). Karlarını artırmak isteyen tüccarlar daha iyi tahmin metodları kullanmaktadırlar. Piyasanın geleceęi hakkında bilgi sahibi olmak isteyen tüccarlar tek bir teknięe baęlı kalmayıp, deęişik işaretleri yakalayabilmek için çok deęişik teknikler kullanmaktadırlar (YAO 1996).

Ortaya çıkan ilk soru şudur: Farklı para birimlerini tahmin etmek için kullanılan farklı yöntemler var mı? Döviz kurlarını tahmin etmenin farklı yöntemleri vardır (Znaczko 2013).

Bir yaklaşım, uzun vadeli döngü artışına özgü çeşitli faktörleri dikkate alabilir. Örneğin, belirli bir ülke için verilere verimlilik endeksleri, enflasyon, işsizlik oranı, ticaret dengesi ve daha fazlası temel alınarak bakılabilir.

Farklı bir yaklaşım, döviz kurunun mevcut ve geçmişteki gerçek değerine odaklanır. Tahmin, yatırımcıya göre yapılabilir, böylece orandaki değişiklikler belirlenebilir ve kalıplar çizilebilir. Döviz kurunun eğilimini tahmin etmeye çalışmak için kullanılan herhangi bir sayıda yöntem ve aşağıdaki gibi bilgiler olabilir: siyasi istikrarsızlık, doğal afetler ve spekülasyon.

Uluslararası işlemler genellikle yakın gelecekte gerçekleştirilir. Uluslararası işlemlerde yer alan yabancı para akışını değerlendirmek için döviz kuru tahminleri gereklidir. Bu nedenle, uluslararası iş ortamında faydaları ve riskleri değerlendirmek için döviz kuru tahmini çok önemlidir. Kur tahmini ayrıca yatırımcılar ve toplumun birçok kesimi içinde önem arz etmektedir. Kur tahmini ile birlikte finansal enstrümanlar da toplum içinde ve uluslararası toplumda büyük önem arz etmektedir. Toplumsal yapılar ve bireyler için finansal enstrümanları tahmini ekonomik yaşantılarının olmazsa olmazı durumundadır. Bir tahmin, gelecekteki bir değer veya değişkenin değerleri hakkında bir beklentidir. Beklenti, tahminci tarafından seçilen bir bilgi seti kullanılarak oluşturulur. Tahminci tarafından kullanılan bilgilere dayanarak, finansal enstrüman tahmin etmek için iki saf yaklaşım vardır (Susmel 2016):

1.3.1.1. Faiz Oranları Paritesi

Bu çalışma kapsamında önerilen yöntemlerden biride indikatör ve formüllerin yapay zeka algoritmalarına giriş değeri olarak verilmesidir. Faiz oranları paritesi de döviz kurlarında gelecek tahmini için kullanılan formüllerden biridir. Bu formül bu çalışma kapsamında yapay zeka algoritmalarına giriş değeri olarak kullanılması suretiyle döviz kuru tahmini başarı oranı artırılmıştır. Faiz oranı paritesi, farklı ülkelerde yer alan para birimlerinin getirileri arasındaki ilişkiyi açıklayan önemli bir formüldür (Melvin ve Norrbın 2013). Genel bir tanım yapılacak olursa farklı ülkelerin para birimleri ile fiyatlandırılmış menkul kıymetler aynı getiriye elde etmesi gerektiğini savunmaktadır (Krugman ve Obstfeld 2009). Ülkeler arasında beklenen getiri oranları arasındaki farklılıklardaki değişiklikler, büyük ölçüde ulusal faiz oranları arasındaki farklılıklardaki değişikliklere tekabül etmektedir (Harvey 2006).

1.3.1.2. Uluslararası Fisher Etkisi

Uluslararası Fisher Etkisi hipotezi, ülkelerin nominal faiz oranları arasındaki farkların ülkeler arasında geçerli olan döviz kurundaki değişime eşit olduğunu savunmaktadır (Telek 2018). Uluslararası Fisher Etkisi formülünü aşağıdaki Şekilde ifade etmek mümkündür (Denklem 1.1):

$$r_t = i_t + \pi_t e \quad (1.1)$$

Fisher denklemi olarak bilinen yukarda formülü yer alan r , nominal faiz oranını göstermektedir. i , reel faiz oranı ve π , ise enflasyon oranıdır (Örüş 2016).

1.3.2. Finansal Enstrümanları Etkileyen Dış Etmenler

Finansal enstrümanların fiyatlarını arz ve talep dengesi belirlemektedir. Bununla birlikte insanların arz ve talep durumlarını bazı dış faktörler etkileyebilmektedir. Bu dış faktörlere finans piyasalarında değişkenler denilmektedir. Bu değişkenler 5 ana başlık altında toplanabilir. Bu değişken başlıkları; reel, kamu, fiyat ödemeler, iş gücü şeklindedir.

1. Reel: GSYİH, Özel Tüketim, Özel Kesim, Kamu Kesim, Stock, İthalat, İhracat şeklinde örnek verilebilir.
2. Kamu: Vergi Gelirleri, Bütçe Gelirleri, Faiz Dışı Harcamalar, Bütçe Dengesi şeklindedir.
3. Fiyat: TÜFE, ÜFE, Enflasyon, Üretici Fiyat Endeksi
4. Ödemeler: Cari İşlem Dengesi, Altın İhracatı, Enerji İhracatı, Dış Ticaret Dengesi
5. İş gücü: Tarım İstihdamı, Sanayi İstihdamı, İnşaat İstihdamı, Hizmet İstihdamı

Bu çalışma kapsamında bu değişkenler yapay zeka algoritmalarına giriş değeri olarak kullanılmıştır. Tahmin sonuçlarına göre değişkenler arasındaki kolerasyon olarak sunulmuştur.


Çalışma kapsamında yapay zeka algoritmalarına giriş değeri olarak kullanılan değişkenler aşağıdaki gibidir.

- Türkiye 1, 5, 10 Yıllık Bono Faizi
- Türkiye CDS 1, 5, 10 Yıllık
- CDS- Credit default swap (Kredi risk primi)
- PMI (Purchasing Managers' Index) – Satın alma Müdürleri Endeksi
- Dış Ticaret Açığı

- Amerikan 10 yıllık tahvil faizleri
- BİST100 Endeksi
- USD Endeks
- TÜFE (Tüketici Fiyat Endeksi)
- Tüketici güven endeksi
- Ekonomik güven endeksi
- Formüller: Uluslar arası fisher etkisi, UIP (exchange rate equation)
- İndikatörler: MA, Trend Analiz, 1,5,20 günlük farklar, MACD
- Defter değeri/piyasa değeri

Faiz

Faizler piyasada bulunan finansal enstrümanlar üzerindeki en etkili araçlar arasında yer almaktadır. Türkiye de etkili olan TCMB gösterge faizleri, reeskont kredisi faizleri, FED faizleri, Avrupa Merkez Bankası faizleri yer almaktadır. Faizlerin finansal enstrümanları etkilemesinin sebebi doğrudan yatırımcıları ilgilendiren mevduat hesapları ve kredilerle ilişkilidir. Örneğin FED faizlerinin düşmesi yatırımcıların ve hane halkının altına olan talebini artırmakta ve ons altın fiyatlarında yükseliş olmaktadır.



Şekil 1. Türkiye 2 Yıllık Tahvil Faizi 2012 2022 Yılları Arası


Kaynak: TCMB EVDS.. <https://evds2.tcmb.gov.tr/index.php? ET:03.03.2021>

Şekil 1 üzerinde Türkiye'nin 2 yıllık tahvil faizi oranları 2012 ile 2022 yılları arasındaki grafiği bulunmaktadır. Şekil üzerinde X ekseninde 10 yıllık zaman aralığı bulunmaktadır, Y ekseninde 2 yıllık tahvil faizi bulunmaktadır. Grafik üzerinde görülen faiz verileri ve bahsi geçen diğer faiz verileri hem formüller üzerinde kullanılmış hem de yapay zeka algoritmalarında giriş değeri olarak kullanılmıştır.

PMI (Purchasing Managers' Index) –Satın alma Müdürleri Endeksi

Bir ankettir aslında İstanbul sanayi odası, müsiat ve markit yaptığı bir anket. 400 adet firmanın satın alma müdürlerine yapılan bir ankettir. İmalat, yapı-inşaat ve hizmet sektörleri için ayrı yapılmaktadır. Bu ikisinin birleşimine kompozit pmi denir. Mevcut veriler ışığında yapılan bir ankettir. Şirketlerin satın alma müdürlerinin mal ve hizmetleri satın alma eğilimlerini gösteren anketlere dayanan öncü bir göstergedir. Ülkelerin ekonomik gidişatını büyümelerini en önemli makro ekonomik verilerden biridir.

Sonuçlar 3 e ayrılır; 50 nötr, 50 üstü ekonomik aktivitede iyileşme var, 50 altında ise ekonomik aktivitede kötüleşme var demektir. Yüksek frekanslı bir veri olduğu ve öncü bir gösterge olduğu için tercih edilmiştir. Önümüzdeki ayın gelen siparişleri ile ilgili bilgiler vermektedir. Bu nedenle öncü bir göstergedir. PMI endeksi ile ekonomik durum tahmini yapmak mümkündür (Radoslaw ve Maria 2021).




Şekil 2. Türkiye İmalat Satın Alma Yöneticileri Endeksi (PMI) 2013 ile 2022 Yılları

Kaynak: TCMB EVDS.. <https://evds2.tcmb.gov.tr/index.php?ET:03.03.2021>

Şekil 2 üzerinde Türkiye İmalat Satın Alma Yöneticileri Endeksi (PMI) 2013 ile 2022 yılları arası grafiği gösterilmiştir. Grafik üzerinde X ekseninde 9 yıllık zaman aralığı bulunmaktadır, Y ekseninde PMI değerleri bulunmaktadır.

Dış Ticaret Açığı

Dışarıdan alınan mallar ile dışarıya satılan mallar arasındaki farktan oluşan açığa denilmektedir. Açık oluşması için dışarıdan alınan mal ve hizmetlerin toplam tutarının satılan mal ve hizmetlerin toplam tutarından fazla olması gerekmektedir. Dış ticaret açığı hesaplaması yapılırken mevsimsel durumlar göz önünde bulundurulmadan hesaplanmalıdır. Çünkü mevsim etkisi geçici etki oluşturmaktadır. Gerçek artış ve azalışı bulabilmek için mevsimsel etkiler göz önünde bulundurulmamalıdır. Çalışma kapsamında dış ticaret dengesi bir önceki yılın aynı ayına göre yüzdelik değişim verileri kullanılmıştır. Döviz kuru ile ters yönlü ilişki mevcuttur. Yani dış ticaret verileri pozitif olması durumunda döviz kuru negatif dış ticaret verileri negatif olması durumunda döviz kuru pozitif etkilenmiştir. Dış ticaret dengesi yüzdelik değişim kullanılmıştır. Bir önceki yılın aynı ayına göre yüzdelik fark hesaplanması sonucunda oluşan değerler kullanılmıştır. Eksisi olması önceki yılın aynı ayına göre azalış olduğu anlamına gelmektedir. Dış ticaret açığında azalış olduğu için olumlu olarak düşünülebilir. Artı olması geçmiş yılın aynı ayına göre daha fazla dış ticaret açığı verildiği anlamına geldiği için olumsuz düşünülebilir.



Şekil 3. 2002 2019 Yılları Arası Türkiye Dış Ticaret Açığı

Kaynak: TCMB EVDS.. <https://evds2.tcmb.gov.tr/index.php? ET:03.03.2021>

Şekil 3 üzerinde 2002 2019 yılları arası Türkiye'nin dış ticaret açığı verilerinin grafiği bulunmaktadır. Şekil üzerinde X ekseninde 17 yıllık zaman aralığı bulunmaktadır, Y ekseninde dış ticaret açığı bulunmaktadır.

Amerikan 10 Yıllık Tahvil Faizleri

Tahvil devletin borç para sağlamak amacıyla çıkardığı yıllık alınıp satılan bilen faiz getirisi olan değerli kağıtlara denir. Amerikan 10 yıllık tahvil faizleri Amerika Birleşik Devletlerinin tahvil karşılığında ödediği faizlerdir.

DTH, yurt içinde yada yurt dışında bulunan kişilerin, tüm yabancı para biriminden olan hesaplarına verilen isimdir. Türkiye'deki DTH hesaplarında biriken mevduatın toplam mevduata oranı her geçen gün artış göstermektedir. Günümüzde DTH hesapları içinde Amerikan dolarının oranı %65 civarında olması sebebiyle Amerikan 10 yıllık tahvil faizleri seçilmiştir.

BİST100 Endeksi

Bist 100 Endeksi borsa İstanbul'da işlem yapan 100 hissenin değerini ölçmek için kullanılan performans ölçüm endeksidir. Bu endeksin hesaplamasındaki ilk 100 endekste ki hisseler performans ve işlem hacmi açısından ilk 100 hisse senedidir. Tez çalışmasında bu endeksin kullanılmasının sebebi Türkiye içerisinde Türk lirası ile işlem yatırım yapılabilecek en büyük enstrümanların başlarında gelmesidir.

USD Endeks

Amerikan dolar endeksi, doların 6 farklı para birimine göre geometrik ortalama yöntemi ile hesaplanan endeks değeridir. Bu para birimleri; Japon Yeni, Euro, Kanada Doları, İngiliz Sterlini, İsveç Kronu ve İsviçre Frangı'dır. Uluslararası ticarete en fazla kullanılan para birimi dolar olması sebebiyle ve usd dolar endeksi en çok kullanılan para birimlerine karşı değerini gösterdiği için önemli bir endekstir. Bu sebeplerden dolayı usd endeks seçilmiştir.

TÜFE (Tüketici Fiyat Endeksi)


TÜFE genel bir tüketicinin satın aldığı hizmet ve malların fiyatlarındaki değişimi gösteren endekse tüketici fiyat endeksi denir. TÜFE yıllık olarak artış göstermesi enflasyon

olarak adlandırılırken, azalış göstermesi ise deflasyon olarak adlandırılır. Türkiye genel olarak enflasyondan söz edilmektedir. Değişken olarak TÜFE nin seçilmesinin sebebi TÜFE'nin değişimi yatırımcıların para harcama oranını etkilemesi sebebiyle birikimlerini ve finansal enstrüman tercihlerini etkiliyor olmasıdır.

Tüketici Güven Endeksi

Tüketici güven endekisi tcmb ile tuik'in birlikte hazırladığı tüketicilerin tasarruf eğilimlerini, ekonomiye hakkında durum değerlendirmelerini, mali durumlarını, gelecek döneme dair beklentilerini ölçmeyi amaçlayan bir endekstir. Endeks 0 ile 200 arasında bir değer almakla birlikte 100 üzeri tüketici güveninde olumlu 100 altında ise olumsuz bir durum olduğunu göstermektedir.

Tez çalışmasında yer verilmesinin sebebi yatırımcılar ve tüketiciler için öncü bir gösterge olması ve geleceğe dair bakışın insanların tüketim alışkanlıklarını ve birikim alışkanlıklarını etkilemek suretiyle finansal enstrüman tercihinin etkiliyor olmasıdır.



Şekil 4. 2020 ile 2022 Yılları Arası Türkiye Tüketici Güven Endeksi

Kaynak: data.tuik. <https://data.tuik.gov.tr/Kategori/GetKategori?p=enflasyon-ve-fiyat-106&dil=1>. ET: 10.01.2021

Şekil 4 üzerinde 2020 ile 2022 yılları arası Türkiye tüketici güven endeksi grafiği bulunmaktadır (data.tuik 2022). Şekil üzerinde X ekseninde 2 yıllık zaman aralığı bulunmaktadır, Y ekseninde Tüketici güven endeksi verileri bulunmaktadır.

Ekonomik Güven Endeksi

Üretici ve tüketicilerin genel ekonomik durumları ile ilgili eğilim, beklenti ve değerlendirmelerini ölçmeyi amaçlayan birleşik bir endekstir. Endeks 0 ile 200 arasında değer almakla birlikte 100 üzeri ekonomik güvenin olumlu 100 altında ise ekonomik güvenin olumsuz olduğu yönde yorumlanır.

1.4. Veri Madenciliği

Bilgisayarlar her geçen gün hayatımıza daha fazla girmesiyle birlikte, artık her yapılan işlem sayısal ortamda kayıt altına alınıyor (Silahtaroglu 2013). Marketlerde, eczanelerde, hastanelerde, alış veriş merkezlerinde, toplu taşımalarda hemen hemen hayatımızda dokunduğumuz her bir nokta bilgisayarlar tarafından kayıt altına alınmaktadır. Bütün bu bilgiler bir yığın halinde tutulmaktadır ve içlerinden çok değerli bilgiler çıkabilmektedir. Yani kısaca özetlemek gerekirse etrafımızda bir sürü veri var ve bu veriler bilgiye dönüşmeyi beklemektedir. Bilginin güçle eşdeğer olduğu çağımızda işte bu verilerde bilgiye dönüşmeyi bekleyen madenler gibidir. Veri madenciliği le veri yığınlarında saklı olan ve önceden bilinmeyen bilgilerin elde edilmesi amaçlanmaktadır (Boran 2012).

Verinin yönetimi günümüzde çok önemli bir duruma gelmiştir hata bazı bilim insanları durumu şu şekilde özetlemektedir; veri çağımızın petrolüdür. Veri yönetimi, veri ve bilgi varlıklarının değerini elde eden, kontrol eden, koruyan, teslim eden ve artıran politikaların, uygulamaların ve projelerin planlanması, yürütülmesi ve gözetimidir (Mosley 2009).

Verinin bilgiye dönüşümünde birçok paydaş bulunmaktadır. Bu paydaşlar yazılımcılar, iş birimleri, test ekipleri, üst yönetim vs. olabilir. Tüm paydaşların veri kullanılabilirliğini, kalitesini ve güvenlik ihtiyaçlarını karşılamak için aşağıdaki adımlara dikkat etmek gerekmektedir.

- İşletme'nin tüm paydaşlarının bilgi ihtiyaçlarını anlamak.
- Veri testlerinin entegrasyonunu yakalamak, veri saklamak, veri korumak.
- Veri ve bilgilerin kalitesini sürekli artırmak
- Gizlilik ve güvenilirliği sağlamak ve veri ve bilgiler için yetkisiz veya uygunsuz kullanımı önlemek.
- Veri ve bilgi testlerinin etkin kullanımını ve değerini en üst düzeye çıkarmak

Kümeleme analizi eldeki veriler gruplara ayırma işlemidir. Eldeki verilerin birbirlerine olan benzerliklerine bakarak hangi gruplara, kaç değişik guruba ayrılacağı belirlenir. Kümeleme veya kümeleme analizi ver nesnelerini önceden bilmeyen gruplara veya bir başka ifadeyle kümelere bölme işlemidir (Akşehirli 2011).

Sınıflandırma eldeki verilere dayanarak gelecekteki durumlarla ilgili öngörü yapılmasında ve yeni eklenen veri elemanın daha önceden belirlenmiş sınıflara atamak için kullanılır (İnan 2015). Sınıflandırma işleminin kümeleme den farklı sınıflandırmada oluşturulacak grup sayısı bilinmemektedir, kümelemede ise oluşacak grup sayısı bilinmemektedir. Bu tez kapsamında yer alan çalışmalarda kur tahminlerinde bulunacaktır, bu tahminlerde sınıflandırma algoritmalarından yararlanılacaktır. Kur tahmininde oluşacak sınıflar önceden bellidir bu gruplar; değişmez, artar ve azalır şeklinde olacaktır.

1.4.1. Veri Düzenleme

Veri analizi çalışmalarında verinin bilgiye dönüşüm aşamaları bulunmaktadır. Bir günlük yayınlanan finansal enstrüman verisinde tarih ve finansal enstrüman o gün ki satış alış değerleri, parite, çapraz kur değerleri bulunabilmektedir. Bu çalışma kapsamında bu özelliklerde tarih, satış değerinden yararlanılacaktır. Ayrıca tarih ve satış değerine göre bir gün öncesine göre fark, bir hafta öncesine göre fark, bir ay öncesine göre fark değerleri hesaplanacaktır. Fark değerleri 3 farklı veri alabilecektir; artış, azalış ve değişmeme durumu. Bir diğer veri özelliği ise trend olacaktır. Trend belirli zaman aralığındaki gidiş doğrultu demektir. Finansal piyasalarda 3 çeşit trend bulunmaktadır. Yükselen, alçalan ve yatay trendler.

1.4.2. Finansal Enstrüman Özellikleri

Tarih: Bu tez kapsamında tarih olarak günlük değerler alınmıştır. Döviz kurunda çok fazla ham veri bulunmamaktadır. Veri madenciliği çalışmalarında genellikle veri temizleme işlemleri yapılmaktadır fakat döviz kuru çalışmalarında temizlenecek özellik bulunmadığı için yeni veriler üretilerek doğru bilgiye ulaşılmaya çalışılmaktadır.

Para birimi: Bu tez kapsamında yoğunluklu olarak USD/TRY, EUR/USD, BTC/USD, GARA, Ons Altın gibi finansal enstrümanlar üzerinde çalışmalar yapılmaktadır.

Değer: İlgili finansal enstrüman o an ki değerini ifade etmektedir. Bu tez kapsamında yapılan çalışmalarda USD/TRY, EUR/USD, BTC/USD, GARA, Ons altın kurunun satış

değeri baz alınmıştır. Satış değeri para birimi satıcılarının satış işlemlerinde uyguladıkları değerdir.

1 günlük fark: İlgili finansal enstrümanın bir gün önceki değeri ile o gün ki değeri arasındaki farkı ifade etmektedir. $Fark = Bu\ gün\ ki\ değer - 1\ Gün\ önceki\ değer$ şeklinde işlem yapılarak bulunmaktadır.

1 haftalık fark: İlgili finansal enstrümanın bir hafta önceki değeri ile o gün ki değeri arasındaki farkı ifade etmektedir. $Fark = Bu\ gün\ ki\ değer - 1\ Hafta\ önceki\ değer$ şeklinde işlem yapılarak bulunmaktadır.

1 aylık fark: İlgili finansal enstrümanın bir ay önceki değeri ile o gün ki değeri arasındaki farkı ifade etmektedir. $Fark = Bu\ gün\ ki\ değer - 1\ Ay\ önceki\ değer$ şeklinde işlem yapılarak bulunmaktadır.

Ertesi gün değeri: İlgili tarihten bir sonraki gün gerçekleşen para değerini ifade eder.

Trend: Trend TDK sözlük anlamı ile eğilim demektir. Finansal piyasalarda da menkul kıymetin gelecekteki eğilimini tahmin etmeye trend denmektedir. Trend belirlenirken geleneksel yöntem olarak zirve ve çukurların belirlenmesinden geçmektedir (John M. Maheu 2012).

Formüller: Finansal enstrüman tahminin klasik yöntem olarak tahmin formülleri kullanılabilmektedir. Bu formüller ile finansal enstrüman tahmini yapmak mümkündür. Örneğin uluslararası Fisher indeksi ile iki ülke para birimi arasındaki artış ve azalışlar enflasyon veya faizlere göre tahmin hesaplaması yapılabilmektedir. Bu çalışma kapsamında bu ve çalışmada geçen diğer formüller finansal enstrüman tahmini için yapay zeka algoritmalarına giriş değeri olarak kullanılmıştır.

İndikatörler: Finansal enstrüman tahmininde kullanılan bir diğer klasik yöntem ise indikatörler kullanılarak yapılan tahmin yöntemidir. Bu yöntemin yaygın kullanımı olmakla birlikte, doğruluk oranı ise kısmen daha azdır. Bu çalışma kapsamında indikatörden gelen tahmin verileri yapay zeka algoritmalarına giriş değeri olarak kullanılmıştır. Çalışmada MACD, RSI, MA indikatörlerinden yararlanılmıştır.

Değişkenler: Finansal enstrümanların değerlerini etkileyen dış faktörler değişkenler olarak adlandırılmaktadır. Bu çalışma kapsamında faiz, CDS gibi 20 farklı değişken yapay zeka algoritmalarına giriş değeri olarak kullanılmıştır.



Şekil 5. Trend Çizgileri ile Trend Analiz

Kaynak: TCMB EVDS <https://evds2.tcmb.gov.tr/index.php?ET:03.03.2021>

Şekil 5 te geleneksel yöntemler ile trend analizi yapılmıştır. Bu yöntem ile analiz yapılırken tepe ve çukur noktaları belirlenmektedir. 3 tepe bir çizgi ile birleştirilir ve eğilim aşağı doğru ise ayı trendi yani düşüş trendi olarak belirlenir. Eğer tepe noktaları arasında çizilen çizgi yatay bir eğilimde ise yatay trend olarak isimlendirilir. Eğer tepe noktaları birleştirildiğinde yükseliş eğiliminde ise Boğa trendi yani artış trendi olarak adlandırılır.




Şekil 6. Hareketli Ortalamalara Göre Trend Belirleme

Kaynak: investing.com. <http://tr.investing.com.tr/ET:03.03.2021>

Şekil 6 de hareketli ortalama ile nasıl trend belirleneceği gösterilmiştir. Bu tez kapsamında yapılan çalışmalar da hareketli ortalamaya göre trend belirlenmektedir. Şekil 5 mavi çizgi ile gösterilen grafik 5 günlük hareketli ortalamadır. Kırmızı çizgi ise 21 günlük hareketli ortalamadır. Mavi çizginin kırmızı çizgi üzerine geçtiği yerler yükselen trendin başladığı noktalar kabul edilmektedir. Kırmızı çizginin mavi çizgi üzerine geçtiği noktalar ise alçalan trendin başladığı noktalar kabul edilmektedir.

1.4.3. Veri Yaşam Döngüsü

Veri yönetimi, özellikle Büyük Veri çağının ortaya çıkmasıyla birlikte giderek daha karmaşık hale geliyor. Bu verileri yönetmenin en iyi yolu, bir veri yaşam döngüsünü oluşturularak ham veriden verinin imhasına kadar süreci çizmektir (Arass 2018). Veri yaşam döngüsü günümüzde büyük verinin bu kadar arttığı bir dönemde çok önem arz etmektedir. Özellikle ham veriden veri'nin yok edildiği son aşamaya kadar olan süreçleri gözlemleyebilmesi için büyük önem arz etmektedir.



Şekil 7. Finansal Enstrüman Verisi Yaşam Döngüsü

Şekil 7 üzerinden bir finansal enstrüman verisinin yaşam döngüsü şekillendirilmiştir. Ham olarak gelen menkul kıymet değerinin çok fazla özelliği bulunmamaktadır. Bu da finansal enstrüman verilerinin analiz edilmesini zorlaştıran bir noktadır. Veri madenciliği çalışmalarında genellikle büyük veriler bulunmakta bu verileri temizleme işlemi ile uğraşilmektedir. Örneğin bir hasta ile ilgili yapılacak veri madenciliği çalışmasında hastanın binlerce verisini anlık olarak değerlendirilebilmesi için bazı verilerin ayıklanarak işleme devam edilmesi gerekliliği doğmaktadır. Fakat menkul kıymetler ile ilgili yapılan çalışmalarda diğer çalışmalardan bu noktada ayrılmaktadır. Menkul kıymetlerin ham verisindeki özellikler sınırlıdır. Bu özellikler; zaman, alış değeri, satış değeri, açılış değeri,

kapanış değeri olabilmektedir. Bu verilerden zaman ve satış değeri bu tez kapsamında kullanılmıştır.

Finansal enstrüman ile ilgili özelliklerin sadece ve zaman ve satış değerinin olması analizi zorlaştıran bir durumdur. Bu duruma ortadan kaldırmak için döviz kuruna bazı özelliklerin eklenmesi zorunluluğu doğmaktadır. Bu tez kapsamında finansal enstrümana eklenen özellikler; Bir gün fark, bir hafta fark, bir ay fark, trend, indikatörler, değişkenler, formüller, tahmin sonuç şeklindedir. Aşağıda bu değerlerin nasıl hesaplandığı açıklanmıştır.

Bir Gün Fark: Bir gün önceki menkul kıymetin değeri ile o gün ki değeri arasındaki farkı göstermektedir. Çıkarma işleminden sonra işleminden sonra ne kadarlık bir değişim olduğunun tespiti için fark değerinin yüzdesine bakılır. Çıkan yüzde daha önce hesaplaması yapılan makas aralığına göre 3 sınıfa ayrılır. Bu değerler; Artı Eksi Nötr. Makas aralığı hesaplanırken Türkiye de bankaların alış satış değerleri arasındaki farkın yüzdesi hesaplanmıştır. Bu değer günlük olarak değişmekle birlikte ortalama değer olarak yüzde 1 kabul edilmiştir.

Bir Hafta Fark: Bir hafta önceki menkul kıymetin değeri ile o gün ki değeri arasındaki farkı göstermektedir. Bir hafta önceki değer için iş günleri baz alınarak 5 gün olarak hesaplama yapılmıştır. Çıkarma işleminden sonra işleminden sonra ne kadarlık bir değişim olduğunun tespiti için fark değerinin yüzdesine bakılır. Çıkan yüzde daha önce hesaplaması yapılan makas aralığına göre 3 sınıfa ayrılır. Bu değerler; Artı Eksi Nötr.

Bir Ay Fark: Bir ay önceki menkul kıymetin değeri ile o gün ki değeri arasındaki farkı göstermektedir. Bir ay önceki değer için iş günleri baz alınarak 21 gün olarak hesaplama yapılmıştır. Çıkarma işleminden sonra işleminden sonra ne kadarlık bir değişim olduğunun tespiti için fark değerinin yüzdesine bakılır. Çıkan yüzde daha önce hesaplaması yapılan makas aralığına göre 3 sınıfa ayrılır. Bu değerler; Artı Eksi Nötr.

Trend: Trend değeri çok önemli bir değerdir. Bu tez kapsamında da 2 farklı noktada kullanılmıştır. Bu çalışma kapsamında trend hesaplanırken hareketli ortalamalar kullanılmıştır. Hesaplama yöntemi konusunda Teknik analiz konusunda detaylara değinilmiştir. Trend sonuçları; Yükselen, Alçalan, Yatay olabilmektedir.

Tahmin Sonuç: T zamanındaki menkul kıymetin T+1 zamanındaki değerine göre nasıl sonuç verdiğini göstermektedir. T zamanı geçmişte yaşamış bir gün ise t zamanındaki

yapılan tahminlerin doğruluğu $t+1$ zamanına bakılarak tespit edilebilir. Bu özellik çok önemlidir çünkü bu değere bakarak algoritmaların ne kadar doğrulukla çalıştığını bulmak mümkündür. Al, Sat, Oynama değerlerini alabilmektedir. Makas aralığına bakılarak bu değerler hesaplanmaktadır.

Menkul kıymete yukardaki özellikler kazandırıldıktan sonra veri üzerinde veri madenciliği algoritmaları çalıştırılabilir duruma gelmektedir. Veri madenciliği algoritmaları çalıştırılarak sonuçları tahmin sonuç değeri ile kıyaslanarak algoritmaların ne kadar doğrulukla tahmin ettiği sonuçları bulunabilir.

Bu aşamadan sonra pek çok algoritmanın tahmin sonuçları elde farklı tahmin sonuçları elde edilmiş olacaktır. Farklı tahmin sonuçları içinden hangisinin doğru olduğunu nasıl bilebiliriz? Bu tez kapsamında yapılan çalışma bu sorunun çözümünü aramaktadır. Bu sorunun çözümü için Boost Fonksiyonel Kümeleme algoritması ve Vote Fonksiyonel Kümeleme algoritmasının sonucuna bakmaktadır. Bu algoritmalar ile ilgili detay bilgiler ilerleyen bölümlerde verilecektir.

1.4.4. Veri Yapısı

Veri yaşam döngüsü yönetimi, verilerin sonuç üretmek için kullanıldığı ve işlendiği herhangi bir işletme veya uygulama için çok yararlıdır. Verilerin belirli bir süre için görünmesi, sistemde erişilebilirliği ve kullanılabilirliği sağlar. Farklı kaynaklardan üretilen veriler ve erişilebilirlik için çeşitli biçimlerde mevcuttur. Sağlık sektörü gibi büyük veriye dayalı bir uygulama, sensörler ve diğer elektronik cihazlar aracılığıyla çok sayıda veri üretir ve bu veriler, hasta ve hastanelerin yararları için çeşitli amaçlara yönelik rapor oluşturma ve tahminler için bir model olarak sınıflandırılabilir. Veri yaşam döngüsü, sistemdeki tüm veri sürecini sunar. Verilerin yaşam döngüsü, sistem ve uygulamalarda oluşturma, depolama, kullanılabilirlik, paylaşma ve arşivleme ve yok etme ile başlar. Bir organizasyondaki veri akışını tanımlar. Modelin başarılı bir şekilde uygulanması için, verilerin yaşam döngüsünü güvenli bir veri yönetimi sistemi altında sürdürme ihtiyacı vardır. Veriler, günümüz senaryosunda sektörlerde değerli bir nesne olarak kabul edilmektedir (Banyal 2020). Bu tez kapsamındaki çalışmalarda da menkul kıymetler verileri ile işlemler yapılacaktır. Bu verilerin ilk hali çok sadedir, üzerinde çalışma yapıldıktan sonraki veri yapısı aşağıda gösterilmiştir.

Sistemi giriři yapılan dvız kurunda tarih ve dvız kurunun o tarihteki deęeri bulunmaktadır. Dvız kurunun o anki deęeri veri analizi iin yeterli olmayacaktır. Veri analizi alıřmaları iin bir gnlk kur bilgisi iin zellikleri:

BirGunFark: {Arti,Eksi,Notr}

BirHaftaFark: {Arti,Eksi,Notr}

BirAyFark: {Arti,Eksi,Notr}

Trend: {yükselen,alcalan,yatay}

Tahmin: {Al,Sat,Oynama}

Tablo 1. rnek Dvız Kuru Verisi

BirGunFark	BirHaftaFark	BirAyFark	trend	tahmin
Notr	Notr	Notr	yatay	Al
Arti	Notr	Notr	yatay	Oynama
Notr	Notr	Notr	yatay	Al
Arti	Notr	Notr	alcalan	Al
Arti	Notr	Notr	yükselen	Al
Arti	Arti	Notr	yükselen	Sat
Eksi	Arti	Notr	yükselen	Sat
Eksi	Arti	Notr	alcalan	Oynama
Notr	Arti	Notr	alcalan	Oynama
Notr	Eksi	Notr	alcalan	Oynama
Notr	Eksi	Notr	yükselen	Sat
Eksi	Eksi	Notr	yükselen	Oynama

Tablo1 zerinde rnek dvız kuru verisi bulunmaktadır.

Kaynak: Yazar tarafından oluřturulmuřtur.

1.4.5. Bayesyen Sınıflandırma

İlk olarak Bayes tarafından ortaya atılan, daha sonra Laplace ve 19.yzyıldaki dięer bilim adamları tarafından da kabul edilen Bayesyen yaklařım, 20.yzyılın ortalarında De Finetti, Jeffreys, Savage ve Lindley gibi bilim adamları tarafından geliřtirilmiřtir (Zeytinoęlu ve akir 2015). Klasik istatistik yaklařımlarından farklı olarak tmevarım yntemini benimsemiřtir. Klasik yntemlerde tmdengelim yntemi benimsenmiřtir. Bayesyen yaklařımında olasılık klasik ynteme gre daha aęır basmaktadır. Naive Bayes sınıflandırıcılar, Bayes Teoremine dayalı ortak ilkeleri paylařan bir algoritmalar koleksiyonudur (zdemir , Yavuz ve Fares 2019). Naive Bayes sınıflandırıcıları, Weka

yazılımında kullanılan veri sınıflandırma tekniklerinden biridir veya farklı yazılımlar kullanarak diğer veri işleme alanlarında kullanılabilir (Kaur 2017).

Bayesyen Sınıflandırma Algoritması Uygulaması

Bayesyen Sınıflandırma uygulamasında 2019 Ocak ve Şubat ayları USD/TRY kuru verilerinden yararlanılmıştır. Aşağıdaki tabloda USD/TRY Döviz Satış 2 aylık verileri bulunmaktadır. Bu veriler Türkiye Cumhuriyet Merkez Bankası sayfasından elde edilmiştir. (TCMB, Türkiye Cumhuriyet Merkez Bankası 2019). Merkez bankası EVDS seri market sayfasından efektif satış USD seçilerek istenilen tarih aralığında kur raporları alınabilmektedir.

Tablo 2. 2019 Ocak Şubat USD/TRY Döviz Satış Kuru

Tarih	USD/TRY Döviz Satış
02-01-2019	5,2905
03-01-2019	5,3412
04-01-2019	5,4686
07-01-2019	5,4186
08-01-2019	5,3693
09-01-2019	5,4362
10-01-2019	5,5072
11-01-2019	5,4724
14-01-2019	5,4340
15-01-2019	5,5203
16-01-2019	5,4499
17-01-2019	5,4134
18-01-2019	5,3659
21-01-2019	5,3526
22-01-2019	5,3465
23-01-2019	5,3551
24-01-2019	5,3238
25-01-2019	5,2835
28-01-2019	5,2736
29-01-2019	5,2858
30-01-2019	5,3436
31-01-2019	5,2876
01-02-2019	5,2203
04-02-2019	5,2038
05-02-2019	5,2288
06-02-2019	5,2073
07-02-2019	5,2183
08-02-2019	5,2502

11-02-2019	5,2532
12-02-2019	5,2651
13-02-2019	5,2733
14-02-2019	5,2523
15-02-2019	5,2962
18-02-2019	5,2696
19-02-2019	5,3018
20-02-2019	5,3147
21-02-2019	5,3059
22-02-2019	5,3236
25-02-2019	5,3264
26-02-2019	5,3154
27-02-2019	5,3044
28-02-2019	5,3000

Kaynak: TCMB EVDS <https://evds2.tcmb.gov.tr/index.php?> ET:03.03.2021

Tablo 2 üzerindeki veriler üzerinde çalışarak 2019 Şubat ayı USD/TRY kuru verilerinin 1 gün önceki, 1 hafta önceki ve 1 ay önceki değerine göre değişim miktarı aşağıdaki tabloda gösterilmiştir.

Tablo 3. 2019 Şubat Ayı USD/TRY Kuru Artış Değerleri

Tarih	USD/TRY Döviz Satış	1 gün Önce	1 Hafta Önce	1 Ay Önce
01-02-2019	5,2203	-0,0560	-0,0362	-0,0029
04-02-2019	5,2038	-0,0673	-0,0632	-0,1209
05-02-2019	5,2288	-0,0165	-0,0698	-0,2648
06-02-2019	5,2073	0,0250	-0,0570	-0,1898
07-02-2019	5,2183	-0,0215	-0,1363	-0,1620
08-02-2019	5,2502	0,0110	-0,0693	-0,2179
11-02-2019	5,2532	0,0319	0,0299	-0,2570
12-02-2019	5,2651	0,0030	0,0494	-0,2192
13-02-2019	5,2733	0,0119	0,0363	-0,1689
14-02-2019	5,2523	0,0082	0,0660	-0,2470
15-02-2019	5,2962	-0,0210	0,0340	-0,1976
18-02-2019	5,2696	0,0439	0,0460	-0,1172
19-02-2019	5,3018	-0,0266	0,0164	-0,0963
20-02-2019	5,3147	0,0322	0,0367	-0,0508
21-02-2019	5,3059	0,0129	0,0414	-0,0318
22-02-2019	5,3236	-0,0088	0,0536	-0,0492
25-02-2019	5,3264	0,0177	0,0274	-0,0002
26-02-2019	5,3154	0,0028	0,0568	0,0429
27-02-2019	5,3044	-0,0110	0,0136	0,0418
28-02-2019	5,3000	-0,0110	-0,0103	0,0186

Kaynak: TCMB EVDS <https://evds2.tcmb.gov.tr/index.php?> ET:03.03.2021

Tablo3 deki verilerin daha iyi anlaşılabilmesi için 01-02-2019 tarihi için 1 gün önce, 1 hafta önce ve 1 ay önceki değerlerinin hesaplaması aşağıda yapılmıştır. Hafta sonları kur verileri sabit kaldığı için hafta sonu verileri hesaplamalara katılmamıştır.

01-02-2019 için;

1 gün önce = 31.01.2019 USD/TRY – 30.01.2019 USD/TRY → 5,2876-5,3436=-0,0560 yapar.

1 hafta önce = 31.01.2019 USD/TRY – 24.01.2019 USD/TRY → 5,2876-5,3238=-0,0362 yapar.

1 ay önce = 31.01.2019 USD/TRY – 30.01.2019 USD/TRY → 5,2876-5,2905=-0,0029 yapar.

Bir sonraki aşama kuruş artış, azalış veya değişim göstermediği şeklinde verileri üçe ayıracağız. Kurun bir önceki zamana göre artış azalış veya değişim göstermediğine karar verirken 0,02 kuruş referans alınmıştır. Bu değer farklı kurlar göre değişkenlik gösterebilir sadece bu tablo özelinde bu değer referans alınmıştır.

Tablo 4. 2019 Şubat Ayı USD/TRY Kuru Artış Azalış ve Değiş Verilerine İndirgeme

Tarih	USD/TRY Döviz Satış	1 gün Önce	1 Hafta Önce	1 Ay Önce	Yarın
01-02-2019	5,2203	E	E	E	A
04-02-2019	5,2038	E	E	E	E
05-02-2019	5,2288	E	E	E	A
06-02-2019	5,2073	A	E	E	E
07-02-2019	5,2183	E	E	E	E
08-02-2019	5,2502	A	E	E	E
11-02-2019	5,2532	A	A	E	E
12-02-2019	5,2651	A	A	E	E
13-02-2019	5,2733	A	A	E	A
14-02-2019	5,2523	A	A	E	E
15-02-2019	5,2962	E	A	E	A
18-02-2019	5,2696	A	A	E	E
19-02-2019	5,3018	E	A	E	E
20-02-2019	5,3147	A	A	E	A
21-02-2019	5,3059	A	A	E	E
22-02-2019	5,3236	E	A	E	E
25-02-2019	5,3264	A	A	E	A
26-02-2019	5,3154	A	A	A	A
27-02-2019	5,3044	E	A	A	A
28-02-2019	5,3000	E	E	A	E
01.03.2019	5,3273	E	E	E	

Kaynak: TCMB EVDS <https://evds2.tcmb.gov.tr/index.php?ET:03.03.2021>

Tablo 4 te kullanılan kısaltmalar;

A – Artı, bir önceki zamana göre kurun artış gösterdiği anlamına gelir.

E – Eksi, bir önceki zamana göre kurun azalış gösterdiği anlamına gelir.

D – Değişmemiş, bir önceki zamana göre kurun değişim göstermediği anlamına gelir.

Tablo 4 deki veriler kullanılarak 01-03-2019 tarihinde USD/TRY kurunun yönünün ne olacağını hesaplanmıştır. Tablo 4 te 01-03-2019 tarihe yönelik tahmin 02-03-2019 tarihinde gerçekleşecek kurdur. 01-03-2019 tarihi için yarın olan alanı bayesyen algoritmasına göre hesaplayarak bulacaktır. Ve algoritmanın kur değeri üzerindeki doğruluğunu tespit edilmiştir. Dolayısıyla aslında elimiz de, $x = \{E, E, E\}$ olarak bulunan veri setine göre yarın kur ne olurunu bulunur.

Şimdi $P(C_j)$ değerleri hesaplanırsa;

$$P(\text{Artı}) = 8/20 = 0,4$$

$$P(\text{Eksi}) = 12/20 = 0,6$$

Olarak bulunur. Sonrasında ise her bir kategoriye (A,E) göre koşullu olasılık bulunur.

$$P(x|\text{artı}) = 2/8 = 0,25$$

$$P(x|\text{eksi}) = 2/12 = 0,166$$

Tablo incelendiğinde $\{E, E, E\}$ olan 4 veri bulunmaktadır. Bunlardan 2 tanesi artı 2 tanesi de eksi olarak gerçekleşmiştir. Şimdi $P(X_i)$ değerini hesaplayalım.

$$P(X_i) = (0,4*0,25) + (0,6*0,166) = 0,1996 \text{ olur.}$$

$X = \{E, E, E\}$ nin artı sınıfında olma olasılığı

$$P(\text{artı}|x) = (0,4*0,25) / 0,1996 = 0.51 \text{ yani yüzde 51 dir.}$$


$X = \{E, E, E\}$ nin eksi sınıfında olma olasılığı

$$P(\text{eksi}|x) = (0,6*0,166) / 0,1996 = 0.49 \text{ yani \%49 dur.}$$

Sonuç: {E,E,E} olarak gelen 01-03-2019 USD/TRY kurunu bayesyen algoritmasına göre ertesi gün yani 04-03-2019 tahmin ettiğimizde %51 ihtimalle artacak %49 ihtimalle azalacak sonucu çıkmıştır. Merkez bankası verilerinden elde ettiğimiz 04-03-2019 USD/TRY satış kuruna baktığımızda 5,3538 olarak gerçekleşmiş ve bir önceki güne göre artış göstermiştir. Yani Bayes algoritması ile tahmin sonucu uyumuştur.

1.4.6. Karar Ağaçları

Karar ağaçları sınıflandırma problemlerinde en fazla kullanılan algoritmalarındandır. Karar ağaçları sınıflandırma algoritmaları incinde anlaşılması da kolay olan algoritmalar içine girmektedir. Klasik sınıflandırma yöntemlerinden biri olan karar ağaçları, tıbbi teşhis (Pereira ve Pinto 2018), saldırı tespiti (S. Benferhat 2013) ve sinyal işleme (N.D. Vanli 2019) gibi çeşitli alanlara uygulanmıştır. Bu çalışma kapsamında Döviz Kuru tahmininde kullanılacaktır. Karar ağaçları, belirli bir modelin hangi sınıfa ait olduğunu belirlemek için çok düzeyli ayrımcılığa ihtiyaç duydukları için hiyerarşik sınıflandırıcılar olarak da adlandırılabilir (Fei Wang 2020).



Şekil 8. Finansal Enstrüman ile Karar Ağacı

Şekil 8 verisi Tablo 3 ten alınarak oluşturulmuş bir karar ağacı bulunmaktadır. Bu ağaç örnek teşkil etmesi adına temsili olarak oluşturulmuştur.


1.5. Kolektif Sınıflandırma

Ensemble Metot en iyi Türkçe ifadesi Kolektif Sınıflandırma olacaktır. Tezin geri kalan bölümlerinde Ensemble Metot ifadesi yerine Kolektif Sınıflandırma ifadesini kullanacaktır. Kolektif sınıflandırma yöntemleri son 10 yılda veri madenciliği alanındaki en etkili gelişmelerden biri olarak tanımlanmıştır (Giovanni ve Seni 2010).

1.5.1. Bagging (Majority Vote) – Çoğunluk Oyu

Bagging yönteminden majority vote olarak da bahsedilmektedir. Bagging bootstrap aggregating kelimelerinin kısaltılmasından oluşmaktadır. Türkçesi ise çoğunluğun oyu yöntemi denilebilir ve bu tezde bagging yönteminden çoğunluğun oyu yöntemi olarak bahsedilecektir. Çoğunluğun oyu yöntemi bir tahminin daha başarılı olabilmesi için algoritmalar üzerinde ortalama alır ve sonucu öngörürken çoğunluk oyu referans alır (L. Breiman 1994).

Çoğunluğun oyu yöntemi birden fazla sınıflandırma algoritmasını çalıştırarak bu sınıflandırma algoritmalarının ortalama başarısını elde etmeyi amaçlamaktadır. Breiman karar ağaçları ya da doğrusal bir modelde değişken seçim ve uydurma yapan yöntemler gibi belirli bir temel prosedür için bir varyans azaltma tekniği olarak çoğunluğun oyu yöntemini geliştirdi (Bühlmann 2012). Örnek verilecek olursa, sonuçlandırma sonuçlarının $\{X,Y\}$ olduğu bir örnek düşünelim. Çoğunluğun oyu yöntemi de 3 sınıflandırma algoritması ile çalışsın. S1 sonuç - X, S2 sonuç - Y, S3 sonuç - X olsun. Sonuçlarda 2 adet X, 1 adet Y olduğundan, sonuç X olacaktır. Bagging yönteminin bir diğer adı da majority vote olduğu söylenmişti. Yani çoğunluğun oyu hangi sonucu gösterirse sonuç olarak o tahmin edilmektedir. Örnek üzerinde de sonuç X daha fazla oy aldığı için sonuç X olarak tahmin edilmektedir.



Şekil 9. Çoğunluk Oyu Yöntemi Örneği

Şekil 9 Çoğunluk oyu yöntemi N adet algoritmaya göre gösterilmiştir.

Çoğunluk Oyu Yöntemi Uygulaması

Çoğunluk oyu yöntemini farklı bir örnek ile açıklayalım. Bu örnek üzerinde çoğunluk oyu yönteminin nasıl doğruluğu artırmaya çalıştığını anlayacağız. Hasta olduğunuzu ve belirtilerinize dayanarak tanı koymak istediğinizi varsayalım. Çoğunluk oyu yöntemine göre birden fazla doktora muayene olmanız gerekmektedir. Karar vermekte kolaylık olması içinde muayene olunan doktor sayısı tek olmalıdır. Muayene sonuçlarında konulan tanılardan bir tanı diğerlerinden fazla ise en iyi tanı olarak seçilecektir. Yani kesin teşhis bütün doktorların eşit oya sahip olduğu varsayımına göre en fazla teşhisin en iyi olduğu sonucudur. Sezgisel olarak bu örneğe bakacak olursak birden fazla doktora görünmek daha iyi sonuç erecek gibi görünmektedir(Han 2012). Fakat çoğunluğunun oyu yönteminde profesör de pratisyen hekimde aynı oy hakkına sahiptir, bu bir dezavantajdır.


1.5.2. Boosting – Güçlendirme Yöntemi

Kolektif sınıflandırma yöntemleri birden fazla sınıflandırma algoritmasının aynı anda çalıştırılması sonucunda daha başarılı sonuçlar almayı hedeflemektedir. Birlikte kullanılan sınıflandırma algoritmalarının başarı oranlarından daha da başarılı bir sonuç elde edilmek istenmektedir. Kolektif sınıflandırma yöntemleri son 10 yılda veri madenciliği alanındaki etkili gelişmelerden biri olarak tanımlanmıştır (Giovanni ve Seni 2010).

Kolektif Sınıflandırma tanımlayacak olursak, Kolektif Sınıflandırma adında anlaşılaçağı üzere birden fazla veri madenciliği algoritmasının bir arada kullanılması ile oluşan yeni bir metot dur. Birden fazla metodun birleştirilmesinde en doğru sonucu tahmin etme amacı yatmaktadır. Kolektif Sınıflandırma kullanarak birden fazla metod bir arada kullanılarak daha iyi performansa sahip genel bir metot oluşturulmak istenir. Bagging, boosting, ve random forest kolektif sınıflandırmanın örnekleridir. Kolektif sınıflandırmada temel amaç daha önceden farklı sınıflandırma algoritmaları ile elde edilmiş sonuçları bir araya getirmek ve bu sonuçların en iyisinden daha iyi bir sonuç elde etmektir(Barandağ, Kılınç 2015).

Örneğin 10 uzmandan tahminler topladığını varsayarsak, Kolektif Sınıflandırma, her bir uzman tarafından tahmin edilenden daha doğru ve sağlam bir tahmin ortaya çıkarmak için 10 uzman tarafından bu öngörülerini stratejik olarak birleştirmesini sağlayacaktır. Bu bölümde daha sonra görüleceğı gibi Kolektif Sınıflandırma oluşturmak için birkaç farklı yöntem

bulunmaktadır. Bu bölümden Kolektif Sınıflandırmanın nasıl çalıştığı ve neden iyi bir genelleme performansı elde etmek için tipik olarak tanındıkları hakkında temel bilgi anlatılacaktır.



Şekil 10. Kolektif Sınıflandırma Çalışma Mekanizması

Şekil 10 üzerinden Kolektif Sınıflandırma anlatılacak olursa; Kolektif Sınıflandırma birden fazla sınıflandırma algoritmasını bir arada kullanarak daha doğru tahmini elde etmek istemektedir. Bu sınıflandırma algoritmaları; karar ağaçları, destek vektör, lojistik regresyon, gibi farklı algoritmalarlardır.

Kolektif sınıflandırmanın amacı en başarılı algoritmadan daha başarılı sonuç elde etmektir. Örneğin S1 algoritması %60 S2 algoritması %70 doğruluk oranına sahipse kolektif sınıflandırma %70 den daha başarılı tahmin sonucu elde etmeyi amaçlar. Bu örneğe göre Kolektif Sınıflandırma kullanarak %70 üzerinde tahmin mümkündür.

Boosting yöntemi birden fazla sınıflandırma algoritmasının sonuçlarına bakar. Sınıflandırma algoritmalarının sonuçlarına ağırlık vererek yeni bir sonuç elde eder. Elde edilen sonucun diğer sınıflandırma algoritmalarının sonucundan daha güçlü olması amaçlanmıştır. Bu sebeple en iyi Türkçe ifade Güçlendirme Yöntemi olacaktır. Çalışmanın geri kalan kısmında boosting yönteminden güçlendirme yöntemi adıyla bahsedilecektir. Güçlendirme terimi, zayıf sınıflandırma algoritmalarını güçlü algoritmalara dönüştürebilen algoritmalar ailesini ifade eder (Hua ve Zhou 2012).

Güçlendirme algoritmasının da birden fazla sınıflandırma algoritmasının sonucu değerlendirilerek yeni bir sonuç elde edilir. Bu elde edilen sonucu bulurken kullanılan sınıflandırma algoritmalarının sonuçlarına ağırlık verilir. Verilen ağırlıklar sınıflandırma algoritmalarının daha önceki başarılarına göre belirlenir. Bu ağırlıklar yeni sonuçlar ile

güncellenecektir. Güçlendirme yöntemi daha önce yanlış sınıflandırılmış kayıtlara daha fazla odaklanarak yenilemeli bir prosedür şeklinde çalışır.

Örnek üzerinden güçlendirme yöntemini değerlendirecek olunursa; bir hastada belirli bulguların olduğu varsayılın. Birden fazla doktora danışılın, her doktorun değerlendirilmesine belirli bir ağırlık verilsin. Bu ağırlık daha önceki tanılarına göre verilecektir. Son tanı ise ağırlık verilerek oluşturulan yeni tanıların sonucudur. Bu çalışma kapsamında algoritma sonuçları boosting yöntemi ile daha başarılı hale getirilmiştir.

1.5.3. Random Forests

Regresyon için klasik yöntemler, ilgilenilen niceliğin aşırı olduğu ve yalnızca birkaç eğitim veri noktasının onu aşmadığı veya hiç olmadığı durumlarda başarısız olur (Gnecco, Terefe ve Enge 2022). Rastgele Orman Algoritması, verilerin analizinde en güçlü yöntemlerden biridir ve birçok araştırma çalışmasında uygulanmıştır. Rastgele orman algoritmasının yüksek ve istikrarlı tahmin sonuçları sağlayabilmesi, parametrelerini ayarlamak için minimum çaba sarf etmesi ve hem sınıflandırma hem de regresyon durumları için uygulanabilmesi nedeniyle olmuştur(Liao, vd. 2020), (Hidayat ve Astsauri 2021).

Rasgele ormanlar algoritmasının özellikleri şu şekildedir:

- Duruma göre şartlara göre hangi algoritmanın çalışacağını söyleyen bir yöntemdir.
- Sınıflandırma algoritmalarının birlikte kullanılmasını söyleyen bir yöntemdir.
- Rasgele ormanlar karar ağaçlarından yapılmıştır.
- Karar ağaçlarının oluşturulması, kullanılması ve anlaşılması kolaydır. Fakat pratikte müthiş değillerdir.
- Rasgele ormanlar algoritması karar ağaçlarının sadeliği ile birlikte karar ağaçları sonuçlarında büyük bir iyileştirme yapmaktadır.
- Rasgele ormanlar bir sınıflandırma algoritmasıdır.
- Rasgele ormanlar karar ağaçlarından oluşan kolektif sınıflandırma yöntemidir.
- Çoğunluğun oyu yöntemini kullanır. Yöntem bagging ve rasgele seçim yöntemlerini birleştirir.

1.5.4. Long Short Term Memory (LSTM)

LSTM, Tekrarlayan Sinir Ağları (RNN)'nın özelleşmiş bir halidir. Zaman serisi verilerindeki sıralı kalıpları öğrenmek için tekrarlayan sinir ağları (RNN'ler) kullanılmıştır (Yua, Fangcao ve Hu 2020). LSTM tipik bir RNN türüdür ve basit bir RNN'den daha uzun bir süre öğrenebilir (Schmidhuber ve Hochreiter 1996). LSTM de RNN den farklı olarak uzun süreli hafıza vardır. Uzun süreli bilgiyi hatırlamak en önemli özelliğidir.

LSTM algoritması çalışırken hafızadaki bilginin unutulması veya tutulması ile ilgili işlemler yapılmaktadır. Forget gate, input gate ve output gate bulunmaktadır. Forget gate geçmişin unutulması ile ilgili karar alınmaktadır. Input gate hangi bilginin hafızada tutulup tutulmayacağı ile ilgili karar verilir. Output gate ise hangi bilginin output olup olmayacağı kararı veriliyor. (Olah 2015)

Kısaca LSTM bilgiyi uzun süreli hafızada tutabilen özel bir RNN türüdür. Bu çalışma kapsamında bir LSTM katmanından ve bir RNN çıktı katmanından oluşan bir ağ oluşturularak finansal enstrüman analizi yapılmıştır.


1.5.5. RNN

RNN kısa süreli, belleğe sahiptir ve uzun vadeli veri bağımlılıklarını işleyemez (Schmidhuber ve Hochreiter 2019). Sinir ağları işledikleri verilere göre tasarlanmaktadır. RNN modelini diğer modellerden ayıran farkı zaman serileri ve dizi verileri işlemek için üretilmiş olmasıdır. Birçok uygulama alanı vardır; ses işleme, görüntü işleme, video görüntüleri, finansal veri analizi , doğal dil işleme, hava tahmini, dna verileri, ilaç verileri, duygu analizi, film önerileri örnek verilebilir. Zaman serisi tahmini geçmiş veriler bakarak gelecekteki veriyi tahmin etme yöntemine denir.

RNN geçmiş verileri hatırlayarak gelecek verileri tahmin ve sınıflandırma yapabilmektedir. Bunu geçmiş verilerdeki önemli verileri hatırlayarak yapmaktadır. Önemli noktaları bularak tahmin yapıldığı için doğru tahminler yapılabilir. Geleneksel tekrarlayan sinir ağları (RNN'ler), önceki ve mevcut hesaplamalar arasında tekrarlayan bağlantılar kurarak geçmişini hatırlamaktadır (Goodfellow ve Bengio 2016).

Şekil 11 üzerinde RNN algoritmasının mimari yapısı bulunmaktadır. RNN algoritmasında girdiler birbirine bağlı olarak ele alınır. Hidden layerda bulunan node lar

kendi kendini besleyen temporal lollar bulunmaktadır. Kendi küçük hafızası bulunmaktadır. Bu temporal lollar sayesinde kendini beslemektedir. Aldığı bir inputu outputu vermesine rağmen inputu unutmamaktadır. Bir sonraki layer a geçtiğinde aklında tutmaktadır. Her bir layer hem input verisi almaktadır hem de geçmiş verileri almaktadır.



Şekil 11. Temel RNN Tasarımı

Şekil 11 üzerinde temel RNN çalışma yapısı anlatılmaktadır.

1.5.6. Autoregressive Integrated Moving Average (ARIMA)


Bütünleşik Otoresif Hareketli Ortalama kısaca ARIMA olarak bahsedilecektir. İlk olarak Box ve Jenkins tarafından bulundukları için Box-Jenkins modeli olarakda bilinmektedir. Zaman serisi modelleri arasında en çok bilinen ve yaygın olarak kullanılan ARIMA modelleri, zaman serisini oluşturan veriler arasında doğrusal bir ilişkinin olduğunu varsayan ve bu doğrusal ilişkiyi modelleyebilen ARIMA modelleri durağan ya da çeşitli istatistiksel yöntemlerle durağan hale getirilen zaman serilerine başarıyla uygulanabilmektedir (Kaynar ve Taştan 2009). Zaman serisi modelleri içinde ARIMA doğrusal tahminde başarılı bir model olarak öne çıkmaktadır (Lifei Yao 2020).

Tek değişkenli zaman serilerinde kullanılan bir zaman serisi modelidir. Aslında Autoregressive ve Moving Average yöntemlerinin bir arada kullanıldığı entegre bir modeldir. 3 parametreden oluşmaktadır bunlar $AR(p)$, $I(d)$, $MA(q)$ dır. Şekil3 üzerindeki kısaltmalar ve açıklamaları aşağıdaki gibidir.

p: aoutoregresyon derecesidir.

d: fark alma derecesidir.

q: hareketli ortalama derecesidir.



Şekil 12. ARIMA Model

Örneğin (1,1,0) aoutoregresyon derecesi bir 1 kere fark almış ve moving average yapmamış demektir. Bu çalışma kapsamında ARIMA model ile finansal enstrüman tahmini yapılarak diğer modellerin sonuçları ile kıyaslanmıştır.

1.6. Aktivasyon Fonksiyonu Problemleri

Aktivasyon fonksiyonları veriye göre özel bir şekilde çalışmamaktadır. Bütün veriler için çalışmaktadır. Oysa biyolojik nöronlar işlevlerine göre üçe ayrılırlar: Duyusal nöronlar, motor nöronlar ve internöronlar (ara nöronlar)

- a- Duyusal nöronlar denilen özelleşmiş hücreler çevreden koku, tat, dokunma ve ses vasıtasıyla aldıkları bilgiyi beyne iletir.
- b- Motor nöronlar kasların kasılmasını kontrol ederek hareketi sağlar. Tamamen sinir sistemi içinde bulunan internöronlar (ara nöronlar) ise yanlarındaki nöronların yanında circuit (döngü) oluşturur. (circuit lokal internöronlar tarafından gerçekleştirilir).
- c- Nakilci internöronlar ise beynin bir bölgesinde bulunan lokal internöronun oluşturduğu döngüyü (circuit) başka bir yerdeki döngüye bağlar.

Beyindeki nöron döngüleri bu bağlantılardan yararlanarak öğrenme, algı için gereken işlevleri gerçekleştirir. Gerçek sinir ağlarında bulunan bu özelliklerin yapay sinir ağlarında bulunmamasına veriye yakınsamama problemi denir. Bu problem sistem çalışmasını analiz edemiyor olması ve sistemin öğrenmesinde başarısız olma ihtimalini doğurmaktadır.

1.6.1. Lineer Olma

ReLU ve Türevi üzerinde bulunan ReLU aktivasyon fonksiyonunda lineer olma problemi bulunmaktadır. Karmaşık değerli sistemler için lineer aktivasyon fonksiyonları

uygun bulunmamaktadır. Bu konuyla ilgili literatürde pek çok çalışma bulunmaktadır. Detaylı bir şekilde literatür taraması kısmında yer verilmiştir.

1.6.2. Gradyan Koruma

ReLU'nun gradyan koruma özelliğinin, $x > 0$ olduğunda 1 türevine sahip olması modern mimarilerde artık belirgin bir avantaj olmayacağı literatürdeki çalışmalar ile ortaya konulmuştur. Şekil 1 üzerinden ReLU aktivasyon fonksiyonun türevi bulunmaktadır. ReLU'nun türevi her bir durum için 1 değerini üretmektedir. Buda büyük bir dezavantaj ve problem ortaya koymaktadır.

1.6.3. Vanishing Gradyan (Kaybolan Gradyan)

Sigmoid, tanh gibi aktivasyon fonksiyonlarında sonuçlar $[-1,1]$ aralığında çıkmaktadır. backpropagation algoritması kullanımı sonucunda sifıra yakınsama olmaktadır. Sinir Ağları, süreç gradyan inişi kullanılarak eğitilir. Gradyan inişi, her çağdan sonra kaybı azaltmak için ağırlıklardaki değişimi elde etmek için temelde zincir kuralı olan geriye doğru yayılma adımından oluşur. İki katmanlı bir ağ düşünün ve ilk katman $f_1(x)$ olarak temsil edilir ve ikinci katman $f_2(x)$ olarak temsil edilir. Genel ağ $o(x) = f_2(f_1(x))$ şeklindedir. Geri geçiş sırasında ağırlıkları hesaplırsak, $o'(x) = f_2(x) * f_1'(x)$ elde ederiz. Burada $f_1(x)$ 'in kendisi $Act(W_1 * x_1 + b_1)$ 'den oluşan bir bileşik fonksiyondur, burada Act katman 1'den sonraki aktivasyon fonksiyonudur. Zincir kuralını tekrar uygularsak, $f_1'(x) = Act$ olduğunu açıkça görürüz. $(W_1 * x_1 + b_1) * x_1$, bu da doğrudan aktivasyon değerine bağlı olduğu anlamına gelir. Şimdi böyle bir zincir kuralının geri yayılım sırasında birden çok katmandan geçtiğini hayal edin. Act () değeri 0 ile 1 arasındaysa, ilk katmanların gradyanını hesaplamak için bu tür birkaç değer çarpılacaktır. Bu, ilk katmanlar için gradyan değerini azaltır ve bu katmanlar düzgün bir şekilde öğrenemez. Başka bir deyişle, ağın derinliği ve aktivasyonun değeri sifıra kaydırması nedeniyle gradyanları kaybolma eğilimindedir. Buna kaybolan gradyan problemi denir. Bu yüzden aktivasyon fonksiyonumuzun gradyanı sifıra kaydırmamasını istenmektedir.

İKİNCİ BÖLÜM

MATERYAL ve YÖNTEMLER

Bu çalışma kapsamında birden fazla yöntem önerilmiştir. Bu yöntemlerde ilki aktivasyon fonksiyonlarının modifiye edilmesi üzerinedir. İkinci önerilen yöntem ise kolektif sınıflandırma yöntemleri ile yapay zeka algoritmalarının yarışdırılmasıdır. Üçüncü önerilen yöntem ise yapay zeka algoritmalarında değişkenlerin, indikatörlerin, formüllerin girdi değeri olarak kullanılmasıyla kolerasyonların çıkarılmasıdır.

1. MODİFİYE AKTİVASYON FONKSİYONLARI YÖNTEMİ

Modifiye aktivasyon fonksiyonları çalışma kapsamında önerilen yöntemlerden biridir. Bu çalışma yapay zeka yöntemleri ile zaman serileri analizi hakkındadır. Zaman serileri ardışık ve düzenli zaman aralıklarında matematik, finans, ekonomi, istatistik gibi alanlardaki veri noktalarıdır. Zaman serisi tahmini ise bilenen geçmiş veriler ve olaylar baz alınarak geleceğin tahmin edilmesidir. Literatürde, farklı uygulama alanlarında zaman serisi tahmini yapmak için pek çok farklı model kullanılmıştır (Aladag 2017). Bu çalışma kapsamında zaman serisi tahmini yaparken yapay zekanın bir yöntemi olan derin öğrenme teknikleri kullanılmıştır. Derin öğrenme, yapay sinir ağlarından ilham alan bir makine öğrenimi dalıdır. Son zamanlarda, derin öğrenme çalışmaları, çeşitli pratik uygulamalardaki mükemmel performansı (hızlı ve verimli) nedeniyle birçok araştırmacı için ilgi çekici bir alan olmuştur (Cao ve Liu 2018), (Bengio ve Courville 2016), (LeCun ve Bengio 2015), (Raissi 2018)- (Seonwoo ve Byunghan 2017). Genel olarak, bir sinir ağı, birbirine bağlı düğümlerin katmanlarını (giriş, gizli, çıkış) içerir ve bu bağlantılar ağırlıklar olarak bilinir. Gizli katmanlar, doğrusal olmayan bir aktivasyon fonksiyonu yardımıyla bir önceki katmandan gelen ağırlıkları iyileştirir. Optimizasyon açısından, bir ağı ana amacı, kayıp fonksiyonunu en aza indirerek ağırlıkları optimize etmektir (Vinesha 2021). Bu nedenle, aktivasyon fonksiyonunun seçimi, kayıp fonksiyonunun formatı ve kayıp fonksiyonunu en aza indiren öğrenme algoritması ağı verimliliği üzerinde önemli bir etkiye sahiptir. Aktivasyon fonksiyonları Sigmoid, Tanh, Softmax, ArcTan, Relu, Swish, LRelu, PReLU, Elu, Selu, CRelu, FRelu, RRelu şeklindedir (Parisi ve Neagu 2020).

Bir yapay sinir ağındaki bir aktivasyon fonksiyonu, girdinin ağırlıklı toplamının, ağı bir katmanındaki bir düğümden veya düğümlerden bir çıktıya nasıl dönüştürüleceğini tanımlar. Bazen aktivasyon fonksiyonları aktarım fonksiyonları olarak adlandırılır.

Aktivasyon fonksiyonunun seçimi, sinir ağının kapasitesi ve performansı üzerinde büyük bir etkiye sahiptir ve modelin farklı bölümlerinde farklı aktivasyon fonksiyonları kullanılabilir.

Aktivasyon fonksiyonları da tipik olarak türevlene bilirdir, verilen bir girdi değeri için birinci dereceden türev hesaplanabilir. Bu, sinir ağlarının tipik olarak, modelin ağırlıklarını güncellemek için tahmin hatasının türevini gerektiren hata algoritmasının backpropagation kullanılarak eğitildiği için gereklidir.

Bu çalışma kapsamında en yaygın kullanıma sahip ReLU üzerinde geliştirilmiş Leaky Relu ve Sigmoid fonksiyonlarının modifiyesi üzerine çalışma yapılmıştır. Bu çalışma ile aktivasyon fonksiyonlarının problemlerine alternatif çözüm yolları sunulacak ve aktivasyon fonksiyonlarının zaman serisi verisine yakınsamasını sağlanacaktır. Aktivasyon fonksiyonları modifiye edilerek zaman serisi tahminlerini daha başarılı yapılması sağlanacak ve aktivasyon fonksiyonları üzerindeki problemlere alternatif çözümler sunulmuş olacaktır. Çalışma dört bölümden oluşmaktadır. İlk bölümde literatürdeki ilişkili çalışmalara değinilmiştir. İkinci bölümde ise aktivasyon fonksiyonları ve önerilen yöntem hakkında detaylı bilgi verilmiştir. Üçüncü bölümde ise önerilen yöntemin uygulanabilirliğini ve tutarlılığını gösterilmiş ve literatürdeki benzer çalışmalarla kıyaslaması yapılmıştır. Sonuç kısmında elde edilen sonuçlara ve çalışmanın literatüre katkısına değinilmiştir.


Bu bölümde uygulanan yöntem hakkında detaylı bir şekilde bilgi verilecektir. Uygulanan yöntemde kullanılan fonksiyonlar hakkında bilgi verdikten sonra, önerilen yöntemin gerçekleştirilmesi işleminin nasıl yapıldığı aktarılmaktadır. Çalışma kapsamında ReLU, Sigmoid, Leaky ReLU aktivasyon fonksiyonlarının modifiyesi üzerine çalışma yapılmıştır. Modifiye işleminde volatilitate fonksiyonundan yararlanıldığı için volatilitate fonksiyonu da açıklanmıştır. Bu bölüm üç kısımdan oluşmaktadır. İlk kısımda ReLU aktivasyon fonksiyonu açıklanmaktadır. İkinci kısımda Sigmoid aktivasyon fonksiyonu açıklanmaktadır. Üçüncü kısımda ise önerilen yöntem olan modifiye aktivasyon fonksiyonları açıklanmıştır.

1.1. ReLU

Rectified linear activation function (ReLU) en yaygın kullanılan aktivasyon fonksiyonudur. Sigmoid ve Tanh gibi daha önce popüler olan etkinleştirme işlevlerinin sınırlamalarının üstesinden gelmede hem uygulanması basit hem de etkili olduğu için

yaygındır. ReLU'nun gradyanı veya eğimi, pozitif girdiler için bir veya negatif olanlar için sıfırdır, böylece vanishing gradyan sorununu çözer. Şu anda en başarılı ve yaygın olarak kullanılan aktivasyon fonksiyonu ReLU (Ramachandran ve Zoph 2017) dur. Basitliği ve etkinliği sayesinde ReLU, derin öğrenme topluluğu genelinde kullanılan varsayılan aktivasyon fonksiyonu haline geldi. ReLU'nun yerini alması için çok sayıda etkinleştirme işlevi önerilmiş olsa da (Maas ve Hannun 2013), (He ve Zhang 2015), (Clevert ve Unterthiner 2015) hiçbir ReLU'nun yaygın olarak benimsenmesini sağlamayı başaramadı.

Bununla birlikte ReLU'nun gradyan koruma özelliğinin, $x > 0$ olduğunda 1 türevine sahip olması modern mimarilerde artık belirgin bir avantaj olmayabileceği anlamına gelir. İlaveten yapay sinir ağları doğrusal olmaması nedeniyle karmaşık problemleri doğrusal tekniklerden daha doğru çözebilirler. Doğrusal olmayan davranışlar hissedilir, algılanır ve bilinebilir (Tolon ve Tosunoğlu 2008). Genellikle bir yapay sinir ağından deterministik bir karar isteriz ve bu da yine lineer olmaya yol açar.




Şekil 13. ReLU ve Türevi

Şekil 13 üzerinde ReLU aktivasyon fonksiyonu ve bu fonksiyonun türevinin grafiği gösterilmiştir.


1.2. Sigmoid

Bu fonksiyon $y \in \{0,1\}$ arası değer almaktadır. X in 2 ve sonrasındaki değerlerine bakacak olursak y 'nin çok az tepki verdiğini görebiliriz. Buda vanishing gradient problemini doğurmaktadır. Bu problem ile birlikte yapay sinir ağından maksimum performans alınamamaktadır. Bu problemin zaman serisi üzerinde de gözlemlenmesi sebebiyle aktivasyon fonksiyonu modifiye edilmiştir.



Şekil 14. Sigmoid Fonksiyonu ve Türevi

Şekil 14 üzerinde sigmoid fonksiyonu ve türevi gösterilmiştir.



Şekil 15. Sigmoid Fonksiyonu ve Modifiye Sigmoid Fonksiyonu

Şekil 15 üzerinde sigmoid fonksiyonu ve modifiye sigmoid fonksiyonu gösterilmiştir. Bu fonksiyonlar $\{-3,3\}$ aralığındaki değerler için gösterilmiştir.

1.3. Önerilen Aktivasyon Fonksiyonları

Çalışma kapsamında aktivasyon fonksiyonlarından sigmoid ve leaky ReLU fonksiyonları modifiye edilerek zaman serilerinde uygulanmıştır. Sigmoid, Tanh aktivasyon fonksiyonları back-propagation ile bir ağı eğitirken vanishing gradyan sorununa yol açar (Cui 2018), 1'den küçük gradyanlar ile sonuçlanır, bu gradyanlar çoklu farklılaşmalarla küçülür ve nihayetinde 0 veya yok olur.

Sigmoid ve Tanh fonksiyonunda görülen vanishing gradyan ReLU'nun gradyanı veya eğimi, pozitif girdiler için bir veya negatif olanlar için sıfırdır, böylece ReLU vanishing gradyan sorununu çözer.

Vanishing gradyan problemini çözse de ReLU'nun $x > 0$ olduğunda 1 türevine sahip olması modern mimarilerde artık belirgin bir avantaj olmaktan çıkmıştır. İlaveten yapay sinir ağları doğrusal olmaması nedeniyle karmaşık problemleri doğrusal tekniklerden daha doğru çözebilirler. ReLU başlığı altında daha detaylı açıklanan bu 2 problem bulunmaktadır. Bunlara ilaveten bu iki fonksiyon zaman serilerine duyarlı değildir ve bütün problemlerde uygulandığı gibi bu problem üzerinde de standart bir şekilde uygulanmaktadır. Bu problemlerin çözümü için modifiye aktivasyon fonksiyonlarını önerilmektedir.

Yapay zeka algoritmalarının uygulandığı problemler farklılık göstermektedir. Her problem üzerinde aynı aktivasyon fonksiyonunun uygulanması doğru bir yaklaşım olamamakla birlikte yapay sinir ağının her bir katmanında da farklı bir aktivasyon fonksiyonu kullanılabilir. Çalışma kapsamında zaman serileri verileri ile çalışmalar yapılmıştır. Zaman serisi verilerinin aktivasyon fonksiyonları üzerinde duyarlı olabilmesi adına volatilitate fonksiyonu üzerine modifiye işlemi yapılmıştır.

1.3.1. Volatilitate

Volatilitate zaman serileri için belirli bir süre boyunca verinin dağılımının istatistiksel ölçüsünü ifade eder. Volatilitate, zaman serisi verisinin standart sapması veya varyansı kullanılarak hesaplanır. Çalışma kapsamında volatilitate aktivasyon fonksiyonlarının zaman serisine yakınsaması için kullanılmaktadır. Peryodik volatilitate formülü, periyodik zaman serisi verisinin varyansının karekökü bulunarak hesaplanır. Formülde geçen periyod yerine, gün, hafta, ay, yıl, saat, dakika gibi zaman değeri kullanılabilir. Volatilitate formülünü aşağıdaki şekilde ifade etmek mümkündür (Denklem 2.1):

$$\text{Volatilitate} = f(x) = \sqrt{\frac{\sum (P_{ortalama} - P_i)^2}{n}} \text{ şeklindedir.} \quad (2.1)$$

$P_i = x_i$ varsayılır.

P_{mean} x_i ye bağlıdır.. Sonuçta $P_{\text{mean}} = \bar{x}$.

$$f(x_1, \dots, x_n) = \sqrt{\frac{\sum (\bar{x} - x_i)^2}{n}} \quad (2.2)$$

Denklem 2.2 de volatilitate aktivasyon fonksiyonu formülü gösterilmektedir.

Periyod = Başlangıç ve bitiş zamanları arasında kalan zaman aralığı.

P_i = i zamanın daki zaman serisi verisi

$P_{ortalama}$ = Periyod içerisindeki zaman serisi verisinin ortalama değeri.

P_{toplam} = Periyod içerisindeki zaman serisi verilerinin toplam değeri.

n = Periyod içerisinde bulunan zaman serisi adeti.

$P_{karesektoplam}$ = Periyod içerisindeki zaman serisi verilerinin kareli toplam değeri.

Varyans = Zaman serisi varyansı.

Volatilite = Periyod için volatilite değeri.

Dışardan beklenen başlangıç ve bitiş zamanları ve zaman serisi verisidir.

Belirli bir zaman serisi verisinin volatilite formülü aşağıdaki adımlar kullanılarak elde edilebilir:

1. İlk olarak P_{toplam} hesaplanır, periyod içerisindeki zaman serisi verisi toplanır.
2. Ardından zaman serisi verisinin ortalamasını belirlenerek $P_{ortalama}$ hesaplanır.
 $P_{ortalama} = P_{toplam} / n$ şeklindedir.
3. Ardından, her periyod değeri ile ortalama değer, $P_i - P_{ortalama}$ arasındaki farkı hesaplanır.
4. Ardından, tüm sapmaların karesini hesaplanır,
 $(P_{ortalama} - P_i)^2$.
5. Ardından, $P_{karesektoplam}$ tüm kareli sapmaların toplamını bulunur, $\sum (P_{ortalama} - P_i)^2$.
6. Varyans = $P_{karesektoplam} / n = \sum (P_{ortalama} - P_i)^2 / n$
7. Ardından, zaman serisi varyansının karekökünü hesaplayarak periyod volatilite veya standart sapmayı hesaplanır.
8. Volatilite = $\sqrt{\text{Varyans}} = \sqrt{(\sum (P_{ortalama} - P_i)^2 / n)}$
Genişletilmiş volatilite = $\sqrt{\text{Farklı Periyod}} * \sqrt{(\sum (P_{ortalama} - P_i)^2 / n)}$

Volatilite aktivasyon fonksiyonunun örnek veriler üzerinde açıklaması aşağıdaki gibidir.

Tablo 5. 2019 Ocak Şubat Usd/Try Döviz Satış Kuru

Tarih	USD/TRY Döviz Satış
02-01-2019	5,2905
03-01-2019	5,3412
04-01-2019	5,4686
07-01-2019	5,4186
08-01-2019	5,3693
09-01-2019	5,4362
10-01-2019	5,5072
11-01-2019	5,4724
14-01-2019	5,4340
15-01-2019	5,5203

Kaynak: TCMB EVDS.. <https://evds2.tcmb.gov.tr/index.php? ET:03.03.2021>

Tablo 4 üzerinde 2019 Ocak USD/TRY örnek verileri bulunmaktadır.

$$P_{\text{toplam}} = 54,25$$

$$P_{\text{ortalama}} = P_{\text{toplam}} / n = 54,25 / 10 = 5,42$$

$$P_{\text{kareseletoptlam}} = \sum (P_{\text{ortalama}} - P_i)^2 = 0,04$$

$$\text{Varyans} = P_{\text{kareseletoptlam}} / n = 0,04 / 10 = 0,004$$

$$\text{Volatilite} = \sqrt{\text{Varyans}} = 0,0632$$


Daha yüksek volatilite zaman serisi değerinin daha geniş bir değer aralığına yayılabileceğini gösterir; bu, nihayetinde zaman serisi değerinin kısa bir süre içinde potansiyel olarak her iki yönde de önemli ölçüde hareket edebileceği anlamına gelir. Öte yandan, düşük volatilite, zaman serisi değerinin fazla dalgalanmayacağını ve dönem boyunca sabit kalmaya devam edeceğini gösteriyor (Thakuri ve Vaidya 2022).

Bir X girdisi için diğer girdilerle scale ine bakılarak stokastik düzenlenmesi ile lineer olmama sağlanır. Performans iyileştirmesi için weights inputs değerleri lineer olmayan yöntemlerle ağırlıklandırılmıştır (Hendrycks ve Gimpel 2020). Benzer şekilde karmaşık değerli lineer denklem sistemlerini çözmek için bir tür yeni lineer olmayan aktivasyon

fonksiyonu kullanılarak geliştirilmiş bir Zhang sinir ağı (IZNN) önerilmiştir(Ding 2018). Yapılan araştırmalar sonucunda son yıllarda, karmaşık değerli lineer denklem sistemleri (CVSLE) problemi birçok alanda kullanıldığı gözlemlenmiştir (Zhang ve Xiao 2016), (LXiao 2015), (Babu ve Suresh Jul. 2012), (Xiao ve Liao, A finite-time convergent dynamic system for solving online simultaneous linear equations 2017), (Xiao 2016). Sigmoid fonksiyonun modifiye edilerek linear olmasının önüne geçilmiş en yaygın kullanılan ReLU aktivasyon fonksiyonuna alternatif önerilmiştir.

1.3.2. Modifiye Aktivasyon Fonksiyonu

Aktivasyon fonksiyonları modifiye hale getirilerek zaman serisi problemlerine daha uygun hale getirilmesi amaçlanmıştır. Modifiye aktivasyon fonksiyonu çalışmasını yaparken temelde iki fonksiyondan yararlanılmıştır. İlk fonksiyon zaman serisi üzerinde üretilen bir fonksiyondur. Bu fonksiyon zaman serisinin durumuna göre volatilité belirlemektedir. Bu fonksiyondan çıkan sonuç ile aktivasyon fonksiyonunun sonucunda çıkan sonuç modifiye edilerek yeni sonuç elde edilmektedir. Elde edilen sonuçlar karşılaştırılarak yapılan çalışmanın önemi ortaya konulmuştur.



Şekil 16. Modifiye Aktivasyon Fonksiyonu Akış Diyagramı

Şekil 16 üzerinde modifiye aktivasyon fonksiyonunun akış diyagramı gösterilmiştir. Bir aktivasyon fonksiyonu modifiye olurken geçeceği adımlar bulunmaktadır. İlk olarak zaman serisi verisi girişi yapılır. Sonrasın da zaman aralığı belirlenmesi gerekmektedir. Bu aralık zaman serisi verisinin özelliğine göre değişebilir örneğin günlük haftalık aylık aralıklar seçilebileceği gibi saatlik dakikalık aralıklarda seçilebilir. Paralelde aktivasyon fonksiyonlarının belirlenmesi ve volatilité hesaplaması adımları gelmektedir. Bu çalışma kapsamında sigmoid, ReLU ve leaky ReLU aktivasyon fonksiyonları belirlenir ve belirlenen

aktivasyon fonksiyonu zaman serisi verisi ile çalıştırılır. Volatilite hesaplaması sonucu ve aktivasyon fonksiyonu sonucu çarpılmak suretiyle aktivasyon fonksiyonun modifiye işlemi yapılmış ve zaman serisi verisine yakınsaması sağlanmış olur. Bu işlemden sonra sonuç olarak tahmin verisine ulaşılır.


Çarpma işleminin birleşme özelliği ile aktivasyon fonksiyonunun yakınsaması sağlanmış oluyor. Farklı verilerin tek bir yerde toplanıp düzenli bir şekilde yürütülmesi için çarpma işlemin birleştirme özelliğinden yararlanılır. Sigmoid, ReLU, Leak Relu fonksiyonları modifiye fonksiyonu ile çarpılması sonucunda modifiye fonksiyonun bu fonksiyonlar etkilemesi sağlanmaktadır.

Tablo 6. Aktivasyon Fonksiyonları Denklemi

Aktivasyon Fonksiyonu	Denklem	Aralık
Modifiye Fonksiyonu	$m(x) = 1 / \text{ oynaklık endeksi}$	(0,1)
Sigmoid	$s(x) = 1 / (1 + e^{-x})$	(0,1)
Modifiye Sigmoid	$ms(x) = s(x) * m(x)$	(0, ∞)
ReLU	$r(x) = \begin{cases} 0 & \text{ için } x < 0 \\ x & \text{ için } x \geq 0 \end{cases}$	[0, ∞)
Modifiye ReLU	$mr(x) = m(x) * r(x)$	[0, ∞)
Leaky(Sızıntı) ReLU	$f(x) = \begin{cases} 0.01 & \text{ için } x < 0 \\ x & \text{ için } x \geq 0 \end{cases}$	($-\infty, \infty$)
Modifiye Leaky ReLU	$f(x) = \begin{cases} 0.01 * m(x) & \text{ için } x < 0 \\ m(x) * x & \text{ için } x \geq 0 \end{cases}$	($-\infty, \infty$)

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 5 üzerinde aktivasyon fonksiyonlarının denklemleri ve tanım aralığı bulunmaktadır.



Şekil 17. Modifiye Edilmiş bir Fonksiyonun Gösterimi

Şekil 17 üzerinde aktivasyon fonksiyonun bir nöron yapısı gösterilmiştir.

Aktivasyon fonksiyonları modifiye edilerek üzerinde çalışılan veriye daha uygun çıktılar elde edilmesi amaçlanmaktadır. Bu çalışma kapsamında zaman serisi verilerinden

yararlanılmıştır. Zaman serisi analizinde risk ve belirsizliğin ölçümünde kullanılan volatilité fonksiyonu ile aktivasyon fonksiyonları modifiye edilmiştir.

1.3.3. Modifiye Sigmoid Fonksiyonu

Modifiye sigmoid fonksiyonu, sigmoid fonksiyonun volatilité fonksiyonu ile modifiye edilmesi sonucunda oluşmaktadır. Sigmoid fonksiyonu modifiye edilerek daha önceki bölümlerde bahsedilen dezavantajlarından kurtulmak ve zaman serisine daha uygun çıktılar üretilmesi sağlanmıştır.

Sigmoid fonksiyonun modifiye edilmesi işlemi aşağıdaki adımlar ile ispatlanmıştır. Modifiye Sigmoid fonksiyonu formülünü aşağıdaki Şekilde ifade etmek mümkündür (Denklem 2.2):

$$f(x) = 1 / (1 + \sqrt{(\sum (P_{av} - P_i)^2 / n)}) * (1 / (1 + e^{-x})) \quad (2.2)$$

burada çarpımın ilk kısmı 1/volatilité den gelmekte ikinci kısım ise sigmoid fonksiyonundan gelmektedir.

İlk olarak tanım kümesi bulunur.

İlk kısım k gibi bir değér kabul ederek ifademizi ispatlayacak olursak $f(x) = k/(1 + e^{-x})$ olacaktır.

$f(0) \Rightarrow k/2$ olur.

Fonksiyonda paydanın 0 olduđu herhangi bir yer olmadığı için fonksiyonun tanımsız olduđu bir yer bulunmamaktadır.

Fonksiyonun eğilimini(aşağı veya yukarı) bulmak için fonksiyonun türevini alırız.


$f(x) = k/(1 + e^{-x}) \Rightarrow f'(x) = (0 - k \cdot (-e^{-x})) / (1 + e^{-x})^2$ olur.

$f'(x) = (k \cdot e^{-x}) / (1 + e^{-x})^2 > 0$ olduđu için $f(x)$ fonksiyonu devamlı artan bir fonksiyondur.

Fonksiyonun yönü bulunduktan sonra limiti alınarak nasıl bir artış gösterdiği bulunur.

$\lim_{x \rightarrow +\infty} f(x) = \lim_{x \rightarrow +\infty} \left(\frac{k}{1 + e^{-x}} \right) = k$ x sonsuza giderken limiti alınır.


$x \rightarrow -\infty \Rightarrow e^{-x} \rightarrow \infty \lim_{x \rightarrow -\infty} f(x) = \lim_{x \rightarrow -\infty} \left(\frac{k}{1 + e^{-x}} \right) = 0$ ise x eksi sonsuza giderken limiti alınır.



Şekil 18. Modifiye Sigmoid ve Türevi için Artış Yönü

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 18 de modifiye sigmoid ve türevi için grafiğin yönü hesaplanan değerlere göre belirlenmiştir.



Şekil 19. Modifiye Sigmoid Fonksiyonun Grafiği


Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 19 üzerinde modifiye sigmoid fonksiyonun grafiği çizilmiştir. k değerinin farklı değerleri için grafik eğimi değişmektedir.

1.3.4. Modifiye Leaky ReLU Fonksiyonu

Çalışma kapsamında Leaky ReLU fonksiyonu üzerine modifiye çalışması yapılmıştır. Bunun sebebi leaky ReLU fonksiyonunun ReLU üzerindeki eksi değerler problemini çözüyor olmasıdır. Modifiye Leaky ReLU formülünü aşağıdaki Şekilde ifade etmek mümkündür (Denklem 2.3):

$$f(x)=\begin{cases} 0,01*m(x) & \text{ için } x<0, \\ m(x)*x & \text{ için } x\geq 0 \end{cases} \text{ şeklindedir.} \quad (2.3)$$



Şekil 20. Modifiye Leaky ReLU Fonksiyonu

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 20 üzerinde Modifiye Leaky ReLU fonksiyonun grafiği bulunmaktadır. X ekseninde giriş değerleri bulunurken Y ekseninde fonksiyonun çıkış değerleri yer almaktadır.

1.4. Önerilen Aktivasyon Fonksiyonlarının İspatı

Bu çalışmada diğer aktivasyon fonksiyonları ile kıyaslamalara ilave olarak önerilen aktivasyon fonksiyonların aşağıdaki doğruluk, uygulanabilirlik ve ispat yöntemleri uygulanmıştır. Bu doğruluk, uygulanabilirlik ve ispat yöntemleri ilerleyen bölümlerde açıklanmış burada başlıkları belirtilmiştir.

İspat için;

- Türevlerin alınabilir olduğu gösterilmiştir.
- Tanım kümesinde boşta eleman kalmaması.
- Tanım kümesindeki bir elemanın değer kümesinde iki karşılığı olmaması

İspat için türev alınmasının nedeni, katmanı güncellemek için aktivasyon fonksiyonunun gradyanını gerektiren ANN parametre güncellemelerini belirlemek için geri yayılım hatasının hesaplanmasının kullanılmasıdır (Alfonso 2022).

Doğruluk ve uygulanabilirlik için;

- Literatürdeki çalışmalar ile kıyaslama yapılmıştır.
- Simülasyonlar üzerinden doğrulama yapılmıştır.
- Doğruluk ve kayıp değerleri kıyaslanmıştır.
- MAE ile ispat yapılmıştır.
- Diğer aktivasyon fonksiyonları ile kıyaslama yapılmıştır.

Aktivasyon fonksiyonu özellikleri

Doğrusal olmayan fonksiyonlar en çok kullanılan aktivasyon fonksiyonları olarak bilinmektedir. Bir sinir ağı modelinin lineer olmaması çeşitli verilerle uyum sağlamasını ve sonuçlar arasında ayırım yapmasını kolaylaştırır (Panneerselvam 2022). Karmaşık değerli sistemler için aktivasyon fonksiyonu aşağıdaki özelliklere sahip olmalıdır.

- Karmaşık değerli sistemler için lineer olmamalıdır.
- Türevinin alınabiliyor olması gerekmektedir.
- Alt ve üst sınırı olmalıdır.
- Sürekli olması gerekmektedir.
- Monoton artan veya monoton azalan olması

Önerilen modifiye aktivasyon fonksiyonun iyi bir aktivasyon fonksiyonunda bulunması gereken özelliklere sahiptir.


1.4.1. Tanım ve Değer Kümesine Göre Fonksiyon Olma Şartı

Bir önerinin fonksiyon olabilmesi için uyması gereken kurallar bulunmaktadır (math 2009), (Radcliffe 2020). Bu kurallar;

Bir fonksiyonun tanım kümesinde boşta eleman kalmaması gerekmektedir.

Tanım kümesindeki her elemana karşılık değer kümesinde sadece bir görüntüsü olması gerekmektedir.

Modifiye aktivasyon fonksiyonun fonksiyon olduğunu ispat için fonksiyon olma kurallarına göre ispatı aşağıdaki gibidir. Bu özelliklerin ispatı için grafikte dikey doğru testi yapılmaktadır.



Şekil 21. 2022 Ocak-Nisan EUR/USD Volatilite

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 21 üzerinde 2022 Ocak Nisan ayları volatilité grafiđi bulunmaktadır. Grafik üzerinde X1, X2 ve X3 dikey dođruları ile volatilité fonksiyonun dikey dođruluk testi yapılmıřtır. Bu teste göre volatilité fonksiyonun x eksenindeki her bir deđerinin y ekseninde bir karřılıđı bulunmaktadır. X eksenindeki her bir elemana karřılık sadece y ekseninde yani görüntü kümesinde sadece bir karřılıđı bulunmaktadır.

Tablo 7. Ocak Nisan EUR/USD Volatilité Verisi

Tarih	Toplam Gün	İlk Gün Deđer	Son Gün Deđer	Formül	Volatilité Deđer
2022.01	21	1,129	1,123	$f(x_1^1, \dots, x_{21}^1)$	7
2022.02	20	1,126	1,121	$f(x_1^2, \dots, x_{20}^2)$	10
2022.03	23	1,112	1,106	$f(x_1^3, \dots, x_{23}^3)$	9
2022.04	21	1,105	1,054	$f(x_1^4, \dots, x_{20}^3)$	9

Kaynak: Yazar tarafından oluřturulmuřtur.

Tablo 7, 2022 Ocak-Nisan EUR/USD Volatilité deđerlerinin hesaplanmıř halini göstermektedir. Ayda yaklařık 22 iř günü vardır. Tablo 7 özet tablodur, tablonun aslı 88 gündür. Bu tablo, her aydaki EUR/USD deđerini, bu aydaki oynaklık deđerini ve oynaklık deđerini hesaplamak için kullanılan formülü içerir.

1.4.2. Lineer Olmama

Önerilen aktivasyon fonksiyonun omurgasını volatilité fonksiyonu oluřturmaktadır. Bir fonksiyonun lineer olması için iki řartı sađlaması gerekmektedir.

$$F: R^n \rightarrow R^m$$

- 1- $F(u+v) = F(u)+F(v)$ olmalı.
- 2- $F(c.u) = c.F(u)$ olmalı, burada c sabit bir deđer.

Denklem 2.4, 2.5, 2.6, 2.7 ve 2.8, oynaklık fonksiyonunun bir aylık deđerlerini göstermektedir.

$$F(1) = f(x_1^1, \dots, x_{21}^1) \quad (2.4)$$

$$F(2) = f(x_1^2, \dots, x_{20}^2) \quad (2.5)$$

$$F(3) = f(x_1^3, \dots, x_{23}^3) \quad (2.6)$$

$$F(4) = f(x_1^4, \dots, x_{20}^3) \quad (2.7)$$

$$F(i) = f(x_1^i, \dots, x_{22}^i) \quad (2.8)$$

Ayda yaklaşık 22 iş günü vardır. Şekil 22'teki veriler üzerinden limitlere bakacak olursak,

$$F(x_1^1, \dots, x_{21}^1) = \text{January} = 7$$

$$F(x_1^2, \dots, x_{20}^2) = \text{February} = 10$$


$$F(x_1^3, \dots, x_{23}^3) = \text{March} = 9$$

$$F(x_1^4, \dots, x_{20}^4) = \text{April} = 9$$

Aşağıda kullanılan veriler Tablo 7'den alınmıştır.

Volatilite fonksiyonun bu iki şartı sağlayıp sağlamadığı kontrol edilecek olursa:

- 1- Şekil 1 üzerindeki değerler ile bakılacak olursa $F(1)=\text{Ocak}=7$, $F(2)=\text{Şubat}=10$, $F(3)=\text{Mart}=9$, $F(4)=\text{Nisan}=9$ olarak kabul edelim.
 $F(1+2) = F(1) + F(2)$ lineer olması için olmalı. $F(1+2) = F(3) = 9$,
 $F(1) + F(2) = 7 + 10 = 17$
 $17 \neq 9$ olduğundan volatilite fonksiyonu lineer değildir.
- 2- c değeri 2 alınacak olursa $F(c.u) = F(2.1) = F(2) = 10$ dur.
 $c.F(u) = 2.F(1) = 2.7 = 14$ olur.
 $14 \neq 10$ olduğundan volatilite fonksiyonu lineer değildir.



Şekil 22. 2021 EUR/USD Volatilite

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 22 üzerinde EUR/USD 2020 yılı günlük grafiği ve altında ise 10 günlük periyod ile volatilite grafiği bulunmaktadır. Şekil 1 üzerinden volatilite nin lineer olmadığı görülmektedir.

Bir X girdisi için diğer girdilerle scale ine bakılarak stokastik düzenlenmesi ile lineer olmama sağlanabilir. Lineer olmamanın ispatı için volatilité aktivasyon fonksiyonuna bakılacak olursa:



Şekil 23. EUR/USD Günlük Volatilite Grafiği

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 23 üzerinde EUR/USD günlük volatilité grafiği bulunmaktadır.

Tablo 8. EUR/USD 5 günlük volatilité değerleri

2022.03.07	12.75
2022.03.08	32.00
2022.03.09	44.70
2022.03.10	35.90
2022.03.11	32.06

Kaynak: TCMB EVDS.. <https://evds2.tcmb.gov.tr/index.php?ET:03.03.2021>

Tablo 6 üzerindeki EUR/USD 5 günlük volatilité değerlerine göre volatilité fonksiyonun lineer olmadığı ispatlanacak olursa:

Günler için volatilité değerleri V1, V2, V3, V4, V5 şeklinde ifade edilmiştir. $V2 - V1 = 32 - 12,75 = 19,25$ tir.

$19,25 + V2 = 19,25 + 32 = 51,25$ olur.

51,25 eşit midir v3? 51,25 !=44,70 buda göstermektedir ki volatilité fonksiyonu lineer deęildir.

1.4.3. Türevi Alınabilir Olmalı

Volatilité aktivasyon fonksiyonunun türevi alınabilir. Aktivasyon fonksiyonlarında modelin öğrenilmesi için türevin alınabilmesi önemlidir. Yapay Sinir Aęı (YSA) modelleri oluşturulurken, önemli hususlardan biri, türevlenebilir olan gizli ve çıktı katmanları için bir aktivasyon fonksiyonu seçmektir. Bunun nedeni, katmanı güncellemek için aktivasyon fonksiyonunun gradyanını gerektiren ANN parametre güncellemelerini belirlemek için geri yayılım hatasının hesaplanmasının kullanılmasıdır (TCMB 2022 Mart).

Toplam fonksiyonu dikkate almadan volatilité fonksiyonunun türevine bakılırsa, bu fonksiyon Pmean ve Pi deęişkenlerini içerir, n sabittir, dolayısıyla türev için n'yi dikkate almaya gerek yoktur.

İkinci ve daha yüksek mertebeden kısmi türevler, tek deęişkenli fonksiyonların yüksek mertebeden türevlerine benzer şekilde tanımlanır. x ve y'ye göre çapraz kısmi türev f'nin x'e göre kısmi türevi alınarak ve ardından sonucun y'ye göre kısmi türevi alınarak elde edilir (Chiang 1984).

Volatilité aktivasyon fonksiyonu formülü denklem(4)'te gösterildięi gibidir. Volatilité fonksiyonu n deęişkendenden oluşur. Bunlar x1, x2, ... xn'dir. xi'ye göre kısmen türevlenebilirse, türevlenebileceęi kanıtlanacaktır. Denklem 2.4, volatilité aktivasyon fonksiyonunu göstermektedir. Daha sonra, volatilité fonksiyonunun türevi denklem 2.5 ve 2.6'da gösterilmiştir.

$$f(x_1, \dots, x_n) = \sqrt{\frac{\sum (\bar{x} - x_i)^2}{n}} = \frac{1}{\sqrt{n}} \cdot \sqrt{\sum (\bar{x} - x_i)^2} \quad (2.4)$$

Volatilité fonksiyonunun kısmi türevi denklem(2.5) ve denklem(2.6)'da gösterildięi gibidir.

$$\frac{\partial f}{\partial x_i} = \frac{1}{\sqrt{n}} \cdot \frac{2 \cdot (\bar{x} - x_i)}{2 \cdot \sqrt{\sum (\bar{x} - x_i)^2}} \quad (2.5)$$

$$\frac{\partial f}{\partial x_i} = \frac{1}{\sqrt{n}} \cdot \frac{(\bar{x} - x_i)}{\sqrt{\sum (\bar{x} - x_i)^2}} \quad (2.6)$$

Volatilite fonksiyonunun kısmi türevi, x_i değişkenine göre alınabilir. Bu şekilde volatilite aktivasyon fonksiyonunun türevinin alınabileceği görülmektedir.

1.4.4. Sınırların Olması

Eğer bir aktivasyon fonksiyonun sınırları yoksa bazı koşullarda sonuç alınamaz. Bu nedenle aktivasyon fonksiyonun sınırlarının olması da önemlidir (Hayou , Doucet ve Rousseau 2019).

Modifiye aktivasyon fonksiyonları normalizasyon yöntemlerinden min-maks yöntemi ile belirli aralıklar içerisinde değerler üretmektedir.

Şekil 2 üzerindeki grafikte 10 günlük periyod için yapılan hesaplamalara göre de bu sınırlar 20 - 80 arasındadır. Min –maks fonksiyonu formülünü aşağıdaki Şekilde ifade etmek mümkündür (Topçu 2014) (Denklem 2.4):

$$S' = \frac{s - \min}{\max - \min} \quad (2.4)$$

Min bir verinin alabileceği en küçük değerdir. Maks bir verinin alabileceği en yüksek değerdir. S verinin orijinal değerini S' ise normalize edilmiş veriyi göstermektedir. Bu yöntem ile volatilite fonksiyon sonuçları 0-1 aralığına indirgenmiştir. S=60 için hesaplama yapılacak olursa $(60-20)/(80-20) = 0,66$ sonucu elde edilmiştir. Bu sonuç 0 ile 1 arasındadır.

1.4.5. Süreklilik

İyi bir aktivasyon fonksiyonun süreklilik arz etmesi gerekmektedir (Szandala 2020). Süreklilik demek aslında devamlılık anlamı da gelmektedir. Grafik üzerinden süreklilik ve süreksiz noktaları tespit etmek mümkündür. Grafik üzerinden kesik her hangi bir nokta bulunmadığı durumda fonksiyon süreklidir denilir.

Grafik üzerinden süreklilik tespit edilebileceği gibi limitine bakılarak süreklilik tespit edilebilir. $F : \mathbb{R} \rightarrow \mathbb{R}$ biçiminde olan volatilite fonksiyonu için $f(x)=f(a)$ eşitliği sağlanıyorsa f fonksiyonuna $x=a$ noktasında süreklidir denir. F fonksiyonu tanım kümesinin her noktasında sürekli ise f fonksiyonu süreklidir.

Şekil üzerindeki veriler üzerinden limitlere bakılacak olursa $F(1)=\text{Ocak}=7$, $F(2)=\text{Şubat}=10$, $F(3)=\text{Mart}=9$, $F(4)=\text{Nisan}=9$


$\lim_{x \rightarrow 1} f(1) = 7 = f(1) = 7$ olduğu için 1 noktasında volatilité fonksiyonu sürekli.

$\lim_{x \rightarrow 2} f(2) = 10 = f(2) = 10$ olduğu için 2 noktasında volatilité fonksiyonu sürekli.

Volatilité fonksiyonu için diğer noktaların hepsinde benzer şekilde sürekli olduğu için $[-R, +R]$ arası bütün sayılar için sürekli.

1.4.6. Gradyan koruma

Volatilité fonksiyonun gradyan koruma özelliği bulunmakta mı incelenecek olursa



Şekil 24. 10 Günlük Volatilité Değeri

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 24 üzerindeki 2022-03-07 ile 2022-03-25 arasındaki volatilité değerleri üzerinden incelenecek olursa. Volatilitenin türevi;

2022-03-07 ile 2022-03-09 arası $f' > 0$ olur.

2022-03-09 ile 2022-03-11 arası $f' < 0$ olur.

2022-03-11 ile 2022-03-17 arası $f' > 0$ olur.

2022-03-17 ile 2022-03-21 arası $f' < 0$ olur.

ReLU'nun türevi her bir durum için 1 değerini üretmesi problemi volatilité fonksiyonun 2022-03-07 ile 2022-03-25 arasındaki türev değerlerinin farklılık gösterdiği gösterilerek ispatlanmıştır.

1.4.7. Vanishing Gradyan

Sigmoid ve tanh aktivasyon fonksiyonları $[-1,1]$ aralığında değerler ürettiği için türevleri sıfıra yakınsamaktadır (Hu 2021). Şekil 6 üzerinde 10 günlük volatilité fonksiyonu bulunmaktadır. Fonksiyonun türevinin farklı noktalar için farklı değerler oluşturduğu gösterilmişti. Buradan da anlaşılacağı üzere volatilité fonksiyonun türevi sıfıra yakınsamamaktadır. Bu nedenle vanishing gradyan problemine çözüm üretilmiştir.

2. KOLEKTİF SINIFLANDIRMA İLE YAPAY ZEKA ALGORİTMALARININ YARIŞTIRILMASI YÖNTEMİ


Çalışma kapsamında önerilen yöntemlerden bir diğeri ise yapay zeka algoritmalarının kolektif sınıflandırma yöntemleri kullanılmak suretiyle yarışdırılması ve sonuç olarak en başarılı tahmin sonuçlarından daha başarılı tahmin sonuçları elde edilmesidir. Bu kapsamda iki adet yapay zeka algoritması önerilmektedir. Bu algoritmalar Boost Fonksiyonel Kümeleme ve Vote Fonksiyonel Kümeleme şeklindedir.

2.1. Boost Fonksiyonel Kümeleme Algoritması

Çalışma kapsamında önerilen yapay zeka algoritmalarından ilki Boost Fonksiyonel Kümeleme (BoostFK) algoritmasıdır. Bu algoritmanın çalışma prensibi kolektif sınıflandırma yöntemlerinden boosting e dayanmaktadır. Boosting algoritmaları, yüksek doğrulukta veya güçlü modeller oluşturmak için birden çok düşük doğruluklu veya zayıf modeli birleştirir. Kredi, sigorta, pazarlama ve satış gibi çeşitli alanlarda kullanılabilir. Boosting algoritmaları, yüksek doğrulukta bir sınıflandırıcı oluşturmak için düşük doğruluğa sahip bir sınıflandırıcı kümesidir (Billah 2020).

Önerilen BoostFK algoritmasının literatürden farklı olarak veriye yakınsama ile öne çıkmaktadır. Veri üzerinde etkili olan indikatör formül ve değişkenlerin yapay zeka

algoritmalarına girdi olarak alınması suretiyle ve yapay zeka algoritmalarının paralel çalışması ile en başarılı tahmin eden algorithmadan daha başarılı tahminler ortaya koymaktadır.



Şekil 25. Boost Fonksiyonel Kümeleme Algoritması Akış Diyagramı

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 25 üzerinde Boost FK algoritmasının akış diyagramı bulunmaktadır. Boost Fonksiyonel Kümeleme Algoritması Akış Diyagramını açıklanacak olursa öncelikli olarak trend belirlenmektedir. Trend belirleme yöntemlerine ve bu tez kapsamında trend nasıl belirlendiği konularını daha önceki bölümlerde işlemiştir. Trend belirleme işleminden sonra içinde bulunulan trende göre her bir algoritmanın başarısı belirlenir. Başarılar belirlendikten sonra başarı oranına paralel bir şekilde algoritmalar ağırlıklandırma yapılır. Ağırlıklı sonuçlara göre tahmin sonuçları toplanır. Tahmin sonuçları toplama işlemi yapıldıktan sonra içinden en büyük olan sonuç boost fonksiyonel kümeleme algoritması sonucu kabul edilir.


Sözde kod(Pseudocode), program tasarımının bir metin taslağıdır. Ana işlemler, fonksiyonel bloklar olarak düzenlenen tanımlayıcı ifadeler olarak yazılır. Yapı ve sıra, üst düzey diller için olduğu gibi, blokların uygun girintileriyle temsil edilir (Bates 2011). Sözde kod adımları aşağıdaki gibidir.

- TrendBelirle (Date now)

- While (algoritma Algoritmalar)
- Ağırlık Belirle
- Tahmin sonuçları hesapla
- En Büyük tahmin sonuç bul

2.2. Vote Fonksiyonel Kümeleme Algoritması

Çalışma kapsamında önerilen yapay zeka algoritmalarından ilki Vote Fonksiyonel Kümele Algoritması kısaca VoteFK algoritmasıdır. Bu algoritmanın çalışma prensibi kollektif sınıflandırma yöntemlerinden voting e dayanmaktadır. Bagging ve AdaBoost gibi oylama sınıflandırma algoritmalarına yönelik yöntemlerin, yapay ve gerçek dünya veri kümeleri için belirli sınıflandırıcıların doğruluğunu geliştirmede çok başarılı olduğu gösterilmiştir (L. Breiman 1997), (Freund ve Schapire 1996). Kullanılan farklı oylama algoritmaları açıklanacak olursa: her algoritma girdi olarak bir uyarıcı ve bir eğitim seti alır ve eğitim seti örneklerinin dağılımını değiştirerek uyarıcıyı birden çok kez çalıştırır. Üretilen sınıflandırıcılar daha sonra test setini sınıflandırmak için kullanılan son bir sınıflandırıcı oluşturmak için birleştirilir (Eric ve Kohavi 1998).



Şekil 26. Vote Fonksiyonel Kümeleme Algoritması Akış Diyagramı

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil26 üzerinde Vote Fonksiyonel Kümeleme algoritmasının akış diyagramı bulunmaktadır. Vote Fonksiyonel Kümeleme Algoritması Akış Diyagramını açıklayacak olursak her bir algoritma tek tek çalıştırılır ve sonuçları alınır. Alınan sonuçlar tahmin sonuçlarına göre gruplanır. Grup sayılarına bakılır en büyük olan grup sonucu sonuç kabul edilir. Örnek verecek olursak Uygulama içinde son gün verisi 27.01.2020 USD/TRY kuru bulunmaktadır. 28.01.2020 USD/TRY kuru için tahminleri Tablo 6 da gösterilmiştir. Sonuç Al(6) Sat(0) Oynama(1) şeklindedir. Bu sonuçlara bakacak olursak sonuçlar içinden en büyük değer Al sonucuna aittir. Bu durumda Vote Fonksiyonel Kümele algoritması da en büyük değere sahip olan sonucu kabul etmektedir ve sonuç Al olacaktır.

3. KORELASYONLAR

Korelasyon iki farklı değişkenin arasındaki ilişkiyi çıkarmaya yarayan istatistiksel yöntemlerdir. Bu çalışma kapsamında yapay zeka algoritmalarının ve önerilen yöntemlerin giriş değeri olarak kullanılan verilerin (indikatörler, formüller ve değişkenler) arasındaki korelasyonlar çıkarılmıştır.

En geniş anlamıyla korelasyon, değişkenler arasındaki ilişkinin bir ölçüsü olup ilişkili verilerde, bir değişkenin büyüklüğündeki değişiklik, aynı (pozitif korelasyon) veya zıt (negatif korelasyon) yönde başka bir değişkenin büyüklüğündeki bir değişiklikle ilişkilidir. Çoğu zaman, korelasyon terimi, iki sürekli değişken arasındaki doğrusal bir ilişki bağlamında kullanılır ve Pearson çarpım-moment korelasyonu olarak ifade edilir. Pearson korelasyon katsayısı tipik olarak ortaklaşa normal olarak dağıtılan veriler (iki değişkenli normal dağılımı izleyen veriler) için kullanılır (Schober ve Christa 2018), (Pearson 1895). Pearson formülünü aşağıdaki Şekilde ifade etmek mümkündür (Denklem 2.5):

$$r = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum(X_i - \bar{X})^2 \sum(Y_i - \bar{Y})^2}} \quad (2.5)$$

Pearson formülü açıklayacak olursak:

r = korelasyon katsayısı

X_i = bir örnekteki x değişkeninin değerleri


$\bar{X}$ = x değişkeninin değerlerinin ortalaması

Y_i = bir örnekteki y değişkeninin değerleri

$\bar{Y}$ = y değişkeninin değerlerinin ortalaması

Normal olmayan dağılmış sürekli veriler için, sıralı veriler için veya ilgili aykırı değerlere sahip veriler için, monotonik bir ilişkinin ölçüsü olarak bir Spearman sıra korelasyonu kullanılabilir. Her iki korelasyon katsayısı da -1 ile +1 arasında değişecek şekilde ölçeklendirilir; burada 0, doğrusal veya monotonik bir ilişki olmadığını gösterir ve ilişki güçlenir ve nihayetinde düz bir çizgiye (Pearson korelasyonu) veya sürekli artan veya azalan bir eğriye yaklaşır. (Spearman korelasyonu) katsayı mutlak 1 değerine yaklaştığından, sonuçların istatistiksel önemini belirtmek ve verilerin örneklendiği popülasyondaki ilişkinin gücünü tahmin etmek için hipotez testleri ve güven aralıkları kullanılabilir.

İkili korelasyonlar çıkarılırken kullanılan veriler hakkındaki bilgiler aşağıdaki gibidir.



Şekil 27. TÜFE ve USD/TRY 2018-2020 Yılları Arası Grafik

Kaynak: TCMB EVDS.. <https://evds2.tcmb.gov.tr/index.php? ET:03.03.2021>

Şekil 27 üzerinde 04-06-2018 ile 04-11-2020 arasındaki özet bir grafik gösterilmiş olup çalışma kapsamında günlük veriler üzerin işlem yapılmıştır. X eksenin de 2 yıllık tarih aralığı belirtilmiştir, Y ekseninde USD/TRY, Tüfe, Tüketici Güven Endeksi, Ekonomik Güven Endeksi verileri gösterilmiştir. Grafikte TÜFE Tüketici Güven Endeksi, Ekonomik Güven Endeksi verileri ve USD/TRY kuru bulunmaktadır. Veriler Tuik (data.tuik 2021-01-10) ve TCMB evds (TCMB EVDS 2020-02) sayfalarından alınmıştır.

**Tablo 9. TÜFE, Tüketici Güven Endeksi, Ekonomik Güven Endeksi ve USD/TRY
2018-2020 yılları arası tablo**

Tarih	USD/TRY	TÜFE	Tüketici Güven Endeksi	Ekonomik Güven Endeksi
04-06-2018	4,65	12,15	90,60	99,29
04-07-2018	4,67	15,39	92,07	99,55
06-08-2018	5,08	15,85	88,19	94,20
04-09-2018	6,62	17,9	81,15	86,93
04-10-2018	6,04	24,52	78,80	85,27
05-11-2018	5,43	25,24	81,22	89,56
04-12-2018	5,26	21,62	80,09	90,41
04-01-2019	5,46	20,3	80,50	88,65
04-02-2019	5,20	20,35	79,22	88,69
04-03-2019	5,38	19,67	81,31	91,29
04-04-2019	5,63	19,71	83,62	92,61
06-05-2019	5,97	19,5	76,89	87,73
04-06-2019	5,84	18,71	79,75	92,36
04-07-2019	5,62	15,72	78,26	90,06
05-08-2019	5,56	16,65	79,14	93,71
04-09-2019	5,73	15,01	77,66	92,83
04-10-2019	5,69	9,26	78,47	96,07
04-11-2019	5,71	8,55	81,28	96,90
04-12-2019	5,74	10,56	80,73	99,18
04-02-2020	5,98	12,15	79,62	98,45
04-03-2020	6,11	12,37	81,12	94,82
06-04-2020	6,73	11,86	78,14	58,44
04-05-2020	7,02	10,94	82,67	69,04
04-06-2020	6,74	11,39	82,67	81,21
06-07-2020	6,86	12,62	82,28	90,12
04-08-2020	6,96	11,76	79,43	92,29
04-09-2020	7,44	11,77	81,99	94,26
05-10-2020	7,77	11,75	81,94	97,20
04-11-2020	8,40	11,89	80,13	95,89

Kaynak: TCMB EVDS.. [https://evds2.tcmb.gov.tr/index.php? ET:03.03.2021](https://evds2.tcmb.gov.tr/index.php?ET:03.03.2021)


Tablo 9 üzerinden şekil 24 üzerinde grafiği gösterilen 04-06-2018 ile 04-11-2020 arasındaki TÜFE, Tüketici Güven Endeksi, Ekonomik Güven Endeksi verileri ve USD/TRY kuru bulunmaktadır.

Tablo 10. 2018-2020 Yılları Arası Finansal Enstrüman Verileri

Tarih	USD/TRY	10-CDS	10-FAİZ	PMI	DTA-Dış Ticaret Açığı	Amerikan 10 yıllık Tahvil Faiz	BIST100	USD Endeks
04-06-2018	4,65	363,26	14,38	46,40	-0,2	2,94	992,64	94,17
04-07-2018	4,67	379,73	16,73	46,80	-28,9	2,84	967,96	94,32
06-08-2018	5,08	395,93	18,36	49,00	-52,5	2,95	952,9	95,05
04-09-2018	6,62	525,19	20,37	46,40	-80,0	2,90	942,54	95,11
04-10-2018	6,04	430,65	19,14	42,70	-102,7	3,19	970,43	95,72
05-11-2018	5,43	403,22	17,16	44,30	-101,5	3,20	945,24	96,28
04-12-2018	5,26	415,73	16,70	44,70	-75,8	2,92	946,5	96,89
04-01-2019	5,46	404,80	16,61	44,20	-74,8	2,67	878,94	95,80
04-02-2019	5,20	367,42	13,92	44,20	-71,3	2,73	1.030,78	95,31
04-03-2019	5,38	373,10	14,85	46,40	-67,7	2,72	1.035,64	96,30
04-04-2019	5,63	428,25	17,25	47,20	-59,0	2,51	944,78	96,62
06-05-2019	5,97	454,49	18,90	46,80	-79,0	2,50	930,26	97,34
04-06-2019	5,84	490,42	17,60	45,30	-41,7	2,12	905,66	97,14
04-07-2019	5,62	400,62	15,59	47,90	-46,7	1,95	997,31	96,29
05-08-2019	5,56	394,34	14,91	46,70	-11,3	1,72	994,07	97,90
04-09-2019	5,73	420,37	14,84	48,00	-1,0	1,47	996,57	98,89
04-10-2019	5,69	398,19	13,61	50,00	-1039,3	1,53	1.031,77	98,56
04-11-2019	5,71	371,93	12,25	49,00	-2270,6	1,78	992,67	97,03
04-12-2019	5,74	359,79	11,89	49,50	122,4	1,78	1.072,54	97,67
04-02-2020	5,98	300,70	10,19	51,30	75,1	1,60	1.204,76	97,65
04-03-2020	6,11	388,63	11,62	52,40	185,6	1,06	1.109,59	97,15
06-04-2020	6,73	693,38	14,21	48,10	67,6	0,68	909,89	100,87
04-05-2020	7,02	646,01	11,62	33,40	103,6	0,63	1.002,54	99,10
04-06-2020	6,74	485,41	11,41	40,90	-16,7	0,83	1.093,84	97,32
06-07-2020	6,86	485,60	11,95	53,90	-14,3	0,68	1.166,74	97,19
04-08-2020	6,96	551,79	12,64	56,90	169,1	0,51	1.140,39	93,51
04-09-2020	7,44	530,95	13,43	54,30	191,2	0,72	1.075,57	92,83
05-10-2020	7,77	522,66	12,71	52,80	35,6	0,78	1.150,79	93,92
04-11-2020	8,40	564,80	13,46	53,90	154,4	0,77	1.155,48	93,66

Kaynak: TCMB EVDS.. <https://evds2.tcmb.gov.tr/index.php?ET:03.03.2021>

Tablo 10 üzerinde 04-06-2018 ile 04-11-2020 arasındaki USD/TRY, 10 yıllık Türkiye CDS, Türkiye 10 yıllık faiz, PMI, Dış Ticaret Açığı, Amerikan 10 yıllık tahvil faizleri, BIST 100 ve USD endeks verileri bulunmaktadır.



Şekil 28. 10 Yıllık Faizler ve USD/TRY Grafiği

Kaynak: TCMB EVDS.. <https://evds2.tcmb.gov.tr/index.php? ET:03.03.2021>

Şekil 28 üzerinde 04-06-2018 ile 04-11-2020 arasındaki Türkiye 10 yıllık faizleri, Amerikan 10 yıllık faizleri ve USD/TRY grafiği bulunmaktadır. X ekseninde 2 yıllık tarih verisi bulunurken Y ekseninde USD/TRY, 10 yıllık faiz ve Amerikan 10 yıllık tahvil faizi bulunmaktadır.

Grafiklerde ve tablolar da gösterilen veriler ve çok daha fazlası önerilen yöntemlere giriş verisi olarak kullanılmıştır. Önerilen yöntemlere bu verilerin uygulanması ile birlikte 2 li veriler arasındaki korelasyonlar çıkarılmıştır.

ÜÇÜNCÜ BÖLÜM

ÖNERİLEN YÖNTEMLERİN UYGULAMASI ve DEĞERLENDİRİLMESİ

Bu çalışma kapsamında temelde üç farklı öneri bulunmaktadır. Bunlardan ilki modifiye aktivasyon fonksiyonlarıdır. İkinci öneri ise kollektif sınıflandırma ile yapay zeka algoritmalarının yarışdırılması ve bu kapsamadaki BoostFK ve VoteFK algoritmalarının uygulanmasıdır. Üçüncü yöntem ise fonksiyon, indikatör ve değışkenlerin yapay zeka algoritmalarında giriş değeri olarak uygulanması suretiyle korelasyonların tespit edilmesi yöntemidir. Bu önerilerin uygulanması, doğruluklarının ve uygulanabilirliklerinin gösterilmesi adına bir uygulama geliştirilmiştir. Bu bölümde ilk olarak bu uygulamanın geliştirilmesi için gerekli adımlar anlatılacak ikinci kısımda ise modifiye aktivasyon fonksiyonlarının uygulanması ve değerdendirilmesi anlatılacaktır. Üçüncü kısımda BoostFK ve VoteFK algoritmalarının uygulamasına değinilecektir. Dördüncü kısımda ise korelasyonların sonuçları anlatılacaktır.

1. UYGULAMANIN GELİŞTİRİLMESİ

Uygulama geliştirilirken en güncel teknolojiler ile geliştirilmiştir. Uygulama mimarisi genel olarak single page application (SPA) ve responsive web uygulaması olacak şekilde tasarlanmıştır. SPA grafik modellemedeki çoklu etkileşim olanakları, tek sayfalık bir uygulama olarak gerçekleştirilen zengin bir istemci kullanılarak elde edilmesini sağlayan sunucu ve istemci arasındaki değışiklikleri yayan çift yönlü iletişim kanalları kullanılarak eşzamanlı işbirliği sağlayan uygulama yaklaşımıdır (Gavrilă., Băjenaru ve Dobre 2019). Responsive web uygulaması Farklı teknolojilere ve cihazlara uyum sağlayabilen ve aynı zamanda bir web sitesi tasarımcısı veya programcısının onu sürdürmesi ve düzenlemesi için gereken zaman ve çabayı azaltmaya odaklanan farklı duyarlı web sitesi tasarım teknikleri uygulanan mimari yapıdır (Hammori 2016).

Uygulama geliştirilirken kullanılan teknolojiler aşağıdaki gibidir;

- Java
- Maven
- Primefaces
- Spring
- Apache Tomcat


- Derby Client
- Netbeans
- Apache Poi
- Hibernate
- weka-stable jar
- Netbeans

Uygulamada yapılabilen işlemler;

- Toplu kur girişi; testlerde zaman serisi verileri, 17 yıllık usd/try, eur/try, ons altın ve diğer finansal enstrüman verileri kullanılmıştır.
- Günlük kur girişi
- Kur Görüntüleme
- Veri Düzenleme
- Kur Tahmin (Bagging, Boosting, AdaBoost, Random Forest, Neural Network, SVM, Vote, Stacking)
- Yeni tahmin işlemi (Fonksiyonel Kümeleme)
- Son gün analiz işlemleri

1.1. Uygulama Mimarisi


Önerilen yöntemin gerçekleştirilebilmesi için bu çalışma kapsamında bir uygulama geliştirilmiştir. Bu bölümde geliştirilen uygulamanın mimari yapısı detaylı bir şekilde anlatılmıştır. Genel olarak geliştirilen uygulama zaman serisi verileri üzerine çalışmaktadır. Zaman serisi verilerin giriş verileri olarak almakta ve önerilen yöntemlerle zaman serisi analizi yapmaktadır. Uygulamada genel parametrik bir yapı kullanılarak uygulama içerisinde farklı veri tipleri ve farklı zaman aralıkları ile çalışma yapması sağlanmıştır. Bir diğer özelliği ise uygulama içerisinde farklı algoritmaların parametrik bir şekilde adapte edilmesi sağlanabilmektedir.



Şekil 29. Uygulama Mimari Yapısı

Şekil 29 üzerinde uygulamanın genel mimarisi gösterilmiştir. Uygulama 7 adımda bilgiye ulaşmaktadır. Bu adımlar;

1. Veri Girişi: Zaman serisi verileri farklı api ler üzerinden yapılmaktadır.
2. Veri Düzenleme: Veriler üzerindeki bozuk veriler temizlenmekte ve sisteme uygun bir hale getirilmektedir.
3. Giriş değerlerinin belirlenmesi: İndikatörler, formüller, değişkenler, parametreler, zaman aralıkları giriş değeri olarak kullanılmıştır.
4. Algoritmalar çalıştırılır: Önerilen algoritmalarla birlikte modifiye aktivasyon fonksiyonları da çalıştırılır.
5. Başarı belirle: Algoritma sonuçlarına göre başarı oranları belirlenir.
6. Ağırlık hesapla: Başarı oranlarına göre ağırlıklar belirlenir.
7. Sonuç: Ağırlıklara göre sonuçlar hesaplanır ve sisteme kaydedilir.



Şekil 30. Uygulama Mimarisi Hava Durumu Örneği

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 30 üzerinde uygulama mimari yapısı hava durumu örneği üzerinden anlatılmıştır. Hava durumu verisi bir zaman serisi olduğu için çalışma kapsamında hava durumu verisinden yararlanılmıştır. Dünya Meteoroloji Örgütü (DMÖ), hava olaylarını gözlemleyen, atmosfer hareketlerinin su kaynaklarının dağılımı ve okyanuslar üzerindeki etkilerini inceleyen, 185'i ülke, altısı toprak parçası (territory) olmak üzere 191 üyeli bir BM uzman kuruluşudur. Çalışma kapsamındaki bilgiler Meteoroloji genel müdürlüğü (mgm 2021) web sayfasından alınmıştır. Hava durumda kullanılabilen veriler:

- Rüzgar,
- Sıcaklık,
- Nem,
- Yükseklik,
- Basınç,
- Kontur,
- İzoterm,
- İzoteks,

- Jet Akışları

Otomatik meteoroloji gözlem istasyonu Türkiye de 1636 tane İstanbul da 44 adet bulunmaktadır. Yer seviyesindeki meteoroloji parametrelerini ölçmeleri sağlamaktadır. Parametreler; sıcaklık, rüzgar yönü, rüzgar hızı, basınç, yağış, hava, toprak sıcaklığıdır. Bu cihazlar bu parametreleri dakika dakika ölçmektedir.

Meteoroloji balonları sıcaklık, rüzgar yönü, rüzgar hızı, nemi ve basınç gibi parametrelerin ölçümünü yapmaktadır. Balon üzerinde bulunan sensörler sayesinde bu ölçümler yapılarak uydular üzerinden ölçüm istasyonuna bilgileri aktarmaktadır. Meteoroloji balonları Türkiye de 19 merkez de uçurulmaktadır. Günde 2 kere uçurulmaktadır, 12 ve 24 saatlerinde. Atmosferi dikine olarak ölçün yapılması sağlanmaktadır. 35 kilometrelik mesefade ölçüm yapmak mümkündür. 2 saatlik ölçüm yapmaktadır.

Havaalanı ölçüm istasyonları Türkiye de 74 adet bulunmaktadır. Ölçüm istasyonlarına bezer ölçümler yapılmaktadır. Farklı olarak hava ulaşımına hizmet etmek için kurulmuşlardır. Uçakların iniş ve kalkışlarında uçaklar için gerekli olan parametreler ölçülmektedir. Uçakların güvenli bir şekilde inip kalkabilmesine hizmet etmek amaçlanmaktadır.

Deniz hava ölçüm istasyonları deniz ulaşımına hizmet etmek için kurulmuştur. 74 adet bulunmaktadır. Deniz yüzeyi ve kıyıların meteorolojik parametreleri ölçülmektedir.

Meteoroloji radarı Türkiye de 20 adet bulunmaktadır. Anlık yağışların ölçmek için kullanılmaktadır. Özellikle anlık tahminlerde başarılı sonuçlar vermektedir.

Yıldırım takip sistemleri Türkiye de 41 adet bulunmaktadır. Anlık olarak bütün yıldırımların şimşeklerin tespiti için kullanılmaktadır.

Buharlaştırma havuzu bölgedeki atmosferde olan buharlaşmayı ölçmek için kullanılmaktadır. Havuz içinde bulunan suyun 24 saat içinde azalmasına bakılarak tespit yapılmaktadır. Eksilen su kadar buharlaşma olduğu tespit edilmektedir.

Türkiye'de Kullanılan Sayısal Hava Tahmin Modelleri

- Kısa Vadeli Hava Tahminine Yönelik Kullanılan Modeller
- Mm5 Modeli (5 th Generation Mesoscale Model)


- Aire Limite Adaptation dynamique Developpement International (ALADIN)
- WRF Modeli (Weather Research Forecasting)

Orta Vadeli Hava Tahminine Yönelik Kullanılan Modeller

- Avrupa Orta Vadeli Hava Tahmin Merkezi (ECMWF) Deterministik Model
- ECMWF'nin Operasyonel Demet Yöntemi (Clustering)
- Grup Ortalaması (Ensemble mean) ve Farklar
- Meteogramlar, Tüp Yöntemi, EPS Olasılık Haritaları.

Denizlerimize Yönelik Tahmin Modelleri

- ECMWF Dalga Modeli
- METU3 Yerel Dalga Tahmin Modeli:
- Model Sonuçlarına Uygulanan İstatistiksel İşlemler (Kalman Filtresi) Verifikasyon



Şekil 31. Mimari Yapı Finansal Enstrümanlar Örneği

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 31 üzerinde çalışma kapsamında kullanılan zaman serisi verilerinden biri olan finansal enstrümanlar üzerine mimari yapı anlatılmıştır. Uygulama mimari adımları finansal enstrümanlar üzerindeki adımları aşağıdaki gibidir.

1. Veri Giriş: Finansal enstrüman verileri TCMB evds sisteminden ve Avrupa merkez bankası sisteminden yapılmaktadır.
2. Veri Düzenleme: Veriler üzerindeki bozuk veriler temizlenmekte ve sisteme uygun bir hale getirilmektedir.
3. Giriş değerlerinin belirlenmesi: Finansal enstrüman verileri ile indikatörler, formüller, değişkenler, parametreler, zaman aralıklar giriş değeri olarak kullanılmıştır.
4. Algoritmalar çalıştırılır: Önerilen algoritmalarla birlikte modifiye aktivasyon fonksiyonları da çalıştırılır.
5. Başarı belirle: Algoritma sonuçlarına göre başarı oranları belirlenir.
6. Ağırlık hesaplama: Başarı oranlarına göre ağırlıklar belirlenir.
7. Sonuç: Ağırlıklara göre sonuçlar hesaplanır ve sisteme kaydedilir.

2. MODİFİYE AKTİVASYON FONKSİYONLARI'NIN UYGULAMASI VE TARTIŞILMASI

Önerilen yöntemin tutarlılığının ve uygulanabilirliğinin gösterimi için literatürdeki çalışmalarla kıyaslaması yapılmıştır. İlk olarak zaman serisi olarak Avusturalya daki yağmur verileri üzerine önerilen yöntem literatürdeki çalışmalar ile kıyaslanmıştır. İkinci olarak twitter verileri ile önerilen yöntemin uygulaması test edilmiş ve literatür çalışmaları ile kıyaslanmıştır. Üçüncü zaman serisi verisi olarak finansal enstrüman verisi ile önerilen yöntemin testi yapılmış ve literatür kıyaslaması yapılmıştır.

2.1. Avustralya'da Ertesi Gün Yağmur Tahmin Örneği

Önerilen yöntemlerin uygunluğunun çıkarılması için literatürdeki zaman serisi problemi üzerine uygulanmış çalışmaların doğruluk oranları karşılaştırılmıştır. İlk olarak hava durumu tahmini için Avustralya'da ertesi gün yağmur tahmin örneği incelenmiştir (Young 2021).

İlk olarak hava durumu hakkında kısaca bilgi verilecek olunursa, hava tahmini, önümüzdeki günlerde havanın nasıl olacağının bir tahminidir. Hava basıncı, sıcaklık, nem, rüzgar ve diğer ölçümler meteorologlar tarafından hava durumunu tahmin etmek için diğer yöntemlerle birlikte kullanılır. Hava durumunu tahmin etmek, keskin gözlem becerileri ve

hava durumu kalıpları hakkında bilgi gerektirir. Eğitimli derin öğrenme modelleri ile verilerdeki kalıpları belirleyerek önümüzdeki günlere yönelik tahminlerde bulunabiliyoruz.

Bu çalışmada önerilen yöntemi kıyaslanabilmesi adına, ertesini gün yağmuru tahmin etmek için Avustralya'nın farklı şehirlerindeki günümüz hava koşulları verilerini içeren Avustralya'nın birçok yerinden yaklaşık 10 yıllık günlük hava durumu gözlemlerini içeren bir CSV dosyasıdır. Veri kümesindeki çeşitli özellikler, belirli bir gün için hava durumuyla ilgili bilgileri gösterir ve Rain Tomorrow, hedef niteliklidir. Veri seti literatürdeki pek çok çalışmada yer almakla birlikte Common wealth of Australia 2010, Bureau of Meteorology kaynağı temellidir.

Veri seti 145460 satır $\times$ 23 sütun dan oluşmaktadır.

Tablo 11. Yağmur Verisi Kolon Özellikleri

#	Column	Dtype	Açıklama
0	Date	object	Gözlem tarihi
1	Location	object	Konum, hava durumu istasyonunun bulunduğu yerin ortak adı
2	MinTemp	float64	Minimum sıcaklık Santigrat derece cinsinden minimum sıcaklık
3	MaxTemp	float64	Maksimum sıcaklık, Santigrat derece cinsinden maksimum sıcaklık
4	Rainfall	float64	Yağış, gün için kaydedilen yağış miktarı mm olarak
5	Evaporation	float64	Buharlaşma, 24 saatte sabah 9'a kadar A Sınıfı tava buharlaşması (mm)
6	Sunshine	float64	Güneş ışığı, Gün içindeki parlak güneş ışığının saat sayısı.
7	WindGustDir	object	24 saatte gece yarısına kadar en kuvvetli rüzgar esintisinin yönü
8	WindGustSpeed	float64	24 saatte gece yarısına kadar en kuvvetli rüzgar esintisinin hızı (km/sa)
9	WindDir9am	object	Sabah 9'da rüzgarın yönü
10	WindDir3pm	object	Saat 3'te rüzgarın yönü
11	WindSpeed9am	float64	Sabah 9'da rüzgarın hızı
12	WindSpeed3pm	float64	Saat 3'te rüzgarın hızı
13	Humidity9am	float64	Sabah 9 da nem
14	Humidity3pm	float64	Saat 3 te nem
15	Pressure9am	float64	Sabah 9 da basınç
16	Pressure3pm	float64	Saat 3 te basınç
17	Cloud9am	float64	Sabah 9 da bulut
18	Cloud3pm	float64	Saat 3 te bulut
19	Temp9am	float64	Saat 9 da sıcaklık
20	Temp3pm	float64	Saat 3 te sıcaklık
21	RainToday	object	Bugün yağmur
22	RainTomorrow	object	Hedef niteliklidir.

Tablo 11 de yağmur verisi kolonları hakkında bilgiler bulunmaktadır. Bu çalışmada önerilen yöntemin yağmur tahmini veri setinde uygulanması için sıcaklık ve basınç değerlerinden yararlanılmıştır. Doğada suyun üç durumu vardır, ancak her bir durum esas olarak sıcaklığa ve basınca bağlıdır (Hou ve Kong 2013). Suyun katıdan sıvıya dönüşümü füzyon noktası olarak bilinir ve katıdan gazıya geçişe süblimleşme denir (Wang ve Gaffen 2001). Uygulama memory kullanımı: 25.5+ MB şeklindedir.

Sıvıdan gazıya buhar basıncı denir ve bu dönüşüm belirli bir sıcaklıkta gerçekleşir buna da kaynama noktası denir (Suparta ve Alhasa 2017). Nem terimi, atmosferdeki mevcut nemden bahsederken çok kullanılır. Su molekülleri tarafından uygulanan kısmi basınç, belirli bir sınıra ulaşılan kadar artabilir. Atmosferden dönen, buharlaşma ve yoğunlaşma arasında dinamik bir denge kurulmasına doygunluk denir. Doyma eşiği, T sıcaklığı tarafından belirlenir, ancak bağımsızdır (Camuffo 2014). Sıcaklık basınç değişimi formülünü aşağıdaki şekilde ifade etmek mümkündür (Denklem 1.1):

$$\Delta W = C \frac{\Delta T}{T} \quad (3.1)$$

$$W = \Delta P (V_g - V_l)$$

Öte yandan, herhangi bir hal değişiminin gerçekleşmesi için, belirli hacmi, gazdan (V_g) sıvıya (V_l) hacimlerin bir farkını değiştirmek gerekir (Dussen ve Roode 2014) , (Romps 2016), (Gutierrez ve Cruz 2019). ΔP basınçtaki değişim, ΔT sıcaklıktaki değişimi ifade etmektedir.

Tablo 12. Zaman Serisi Yağmur Tahmini

Aktivasyon Fonksiyonu	Validation Accuracy	Validation Loss
Sigmoid	0,8159	0,3676
Modifiye Sigmoid	0,8362	0,3568
Leaky ReLU	0,8213	0,3593
Modifiye Leaky ReLU	0,8412	0,3427

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 12 üzerinde yağmur tahmini üzerine yapılan çalışmanın sonuçları bulunmaktadır. Literatür çalışması sonuçları val_loss: 0.3563 - val_accuracy: 0.8425 şeklindedir. Önerilen yöntemin aynı test verileri üzerinde uygulaması sonucunda yaklaşık

olarak aynı doğruluk sonuçları çıkmıştır. Bu sonuçlar önerilen yöntemin tutarlı sonuç alabildiğini ve yöntemin uygulanabilirliğini göstermiştir.

145460 satırdan oluşan yağmur verisi sonucuna göre kayıp 1 sn altında gerçekleşmiştir. Yağmur veriler ile yapılan çalışma 10 dakika 20 saniye olmuştur. Literatür çalışmasında bu süre 9 dakika 58 saniyedir. Toplan süre olarak 145460 satırdan oluşan bir veri için 22 saniyelik bir kayıp söz konusudur. 145460 kere volatilité hesabı yapıldığı göz önünde bulundurulursa bu süre göz ardı edilebilir. Bir volatilité hesaplaması için geçen süre 1saniye'nin çok altındadır. Diğer veriler içinde ölçümlerde aynı kayıp söz konusudur. Böylece bu durumda yüksek doğruluk için küçük zaman kayıpları kabul edilebilir.

2.2. Twitter Verileri ile Test

Yapay sinir ağlarında amaç, girdi setinden alınan bilgileri çıktı setine çevirmektir. Ağın kendisine gösterilen girdiler için doğru çıktıları üretecek hale gelmesi gerekmektedir (A. Yılmaz 2019). Modifiye aktivasyon fonksiyonları ile ilgili önerdiğimiz yöntemin testi için ilk örnek twitter verileri üzerinden duygu tahmini üzerinedir. Twitter verileri üzerine olan bu verilerin tercih edilme sebebi bu verilerin bir zaman serisi olmasıdır. Çalışma kapsamında önerilen yöntemleri zaman serileri üzerine uygulayarak test edilmiştir. Twitter verileri üzerinde pek çok çalışma bulunmaktadır (Fioka ve Karwowskia 2021), (Nezhad ve Deihimi 2021). Twitter geçmiş verilere bakılarak duygu tahmini yapmak mümkündür. Önerilen yöntemler twitter verileri de bir zaman serisi olduğu için mümkündür. Twitter verilerindeki yoğunluğu da aktivasyon fonksiyonun modifiye edilmesinde kullanılmıştır.

Twitter veri seti Veri boyutu: 1600000 olup ikiye ayrılmıştır. Train boyutu: 1280000 ve Test boyutu: 320000 şeklindedir.

Tablo 13. Twitter veri seti özellikleri

target	tweet lerin polaritesi (0 = negatif, 1 = nötr, 2 = pozitif)
ids	tweet lerin id si (2087)
date	tweet lerin tarihleri (Sat May 16 23)
user	tweet atan kullanıcı (robotickilldozr)
text	tweet metni (Lyx is cool)

Tablo 13 üzerinde twitter veri seti özellikleri yer almaktadır.

Tablo 14. Zaman Serisi Duygu Tahmini Doğrulama Sonuçları

Aktivasyon Fonksiyonu	Validation Accuracy	Validation Loss
Sigmoid	0,7861	0,4691
Modifiye Sigmoid	0,7948	0,4514
Leaky ReLU	0,7932	0,4493
Modifiye Leaky ReLU	0,8123	0,4419

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 14 üzerinden twitter verileri ile duygu tahminine yönelik yapılan çalışmanın sonuçları bulunmaktadır. Önerilen yöntem ile yapılan bu çalışmanın sonuçları literatür deki çalışma sonuçlarına benzer sonuçlar ortaya koymuştur.

2.3. Elektrik Trafo Sıcaklık Verileri ile Volatilite Aktivasyon Fonksiyonu

Uygulaması

Elektrik dağıtımının önemli göstergelerinden biride Elektrik Trafo Sıcaklığı (ETT) dır. Bu çalışma kapsamında önerilen volatilite aktivasyon fonksiyonun doğruluğu ve uygulanabilirliğinin gösterimi için Çin'deki iki ayrı ilçeden alınan ETT verileri üzerine tahmin çalışması yapılmıştır. Bir saat düzeyi için ETTh1 verisinden yararlanılmıştır. Temmuz 2016 ile Temmuz 2018 arasında her 15 dakikada bir kaydedilen yük ve yağ sıcaklığı dahil olmak üzere elektrik trafolarından toplanan verileri içerir (Zhou, ve diğerleri 2021). Wu (Wu , Xu , ve diğerleri 2021) çalışmasında ETT verilerinden yararlanarak uzun süreli tahmini üzerine çalışma yapmıştır.

Tablo 15. Zaman Serisi Ett Doğrulama Sonuçları

Aktivasyon Fonksiyonu	Validation Accuracy	Validation Loss
Sigmoid	0,882	0,2693
ReLU	0,895	0,2512
Volatilite	0,923	0,2415

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 15 üzerinden ETT verileri ile sıcaklık tahminine yönelik yapılan çalışmanın sonuçları bulunmaktadır. Önerilen yöntemin MSE=0,362 ve MAE= 0,448 olarak bulunmuştur. Önerilen yöntem ile yapılan bu çalışmanın sonuçları literature (Liu, Zeng ve Xu

2021), (Wu, Xu, ve diğerleri 2022), (Zeng1, ve diğerleri 2022) , (Liu, ve diğerleri 2022) deki çalışma sonuçlarına benzer sonuçlar ortaya koymuştur.

2.4. EUR/USD İki Yıllık Verisi ile Test


Çalışma kapsamında önerilen yöntemler için bir uygulama geliştirilmiştir. Geliştirilen uygulama üzerinden yapılan EUR/USD 18-11-2019 ile 16-12-2020 tarihleri arasında finansal enstrüman verisi ile aktivasyon fonksiyonlarında önerilen yöntemler ve yaygın kullanılan aktivasyon fonksiyonları test sonuçları hesaplanmıştır.

Tablo 16. Aktivasyon Fonksiyonlarının Doğrulama Sonuçları

Aktivasyon Fonksiyonu	Validation Accuracy	Validation Loss
Sigmoid	0,992	0,0469
Modifiye Sigmoid	0,992992	0,04421
Leaky ReLU	0,9929	0,0402
Modifiye Leaky ReLU	0,9938929	0,03618

Kaynak: Yazar tarafından oluşturulmuştur.


Tablo 16 üzerinde yaygın kullanılan aktivasyon fonksiyonları ile önerilen aktivasyon fonksiyonlarının sonuçları gösterilmiştir. Sonuçlara göre doğrulama oranlarında artış olmakla birlikte kayıp değerlerine düşüş gözlemlenmiştir.



Şekil 32. Modifiye Aktivasyon Fonksiyonları Training Loss

Kaynak: Yazar tarafından oluşturulmuştur.


Şekil 32 üzerinde çalışma kapsamında oluşturmuş 2 aktivasyon fonksiyonu ve en yaygın şekilde kullanılan 2 aktivasyon fonksiyonunun training loss değerleri epoch 20 ye kadar yukardaki grafikteki gibidir.



Şekil 33. Modifiye Aktivasyon Fonksiyonları Training Accuracy

Kaynak: Yazar tarafından oluşturulmuştur.


Şekil 33 üzerinde çalışma kapsamında oluşturmuş 2 aktivasyon fonksiyonu ve en yaygın şekilde kullanılan 2 aktivasyon fonksiyonunun training accuracy değerleri epoch 20 ye kadar yukardaki grafikteki gibidir.



Şekil 34. Modifiye Aktivasyon Fonksiyonları Validation Loss

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 34 üzerinde çalışma kapsamında oluşturmuş 2 aktivasyon fonksiyonu ve en yaygın şekilde kullanılan 2 aktivasyon fonksiyonunun validation loss değerleri epoch 20 ye kadar yukardaki grafikteki gibidir.



Şekil 35. Modifiye Aktivasyon Fonksiyonları Validation Accuracy

Kaynak: Yazar tarafından oluşturulmuştur.


Şekil 35 üzerinde çalışma kapsamında oluşturmuş 2 aktivasyon fonksiyonu ve en yaygın şekilde kullanılan 2 aktivasyon fonksiyonunun validation accuracy değerleri epoch 20 ye kadar yukardaki grafikteki gibidir.

3. KOLLEKTİF SINIFLANDIRMA YÖNTEMLERİ

Çalışma kapsamında bir diğer önerilen yöntem ise kollektif sınıflandırma yöntemleri ile yapay zeka algoritmalarının yarışdırılması yöntemidir. Önerilen çözümün uygulanması için öncelikli olarak veri madenciliği algoritmalarından bazılarının çalıştırılması ve sonuçlarının görülmesi gerekmektedir. Sonuçlar alındıktan sonra kolektif bir şekilde sonuçlar değerlendirilmesi işlemine fonksiyonel kümeleme denir. Fonksiyonel kümele algoritmaları zaman serisi verileri üzerinde çalışmaktadır. Bu çalışma kapsamında zaman serisi verilerinden olan finansal enstrümanlar üzerinden ispatlar ve testler yapılmıştır.

3.1. Boost Fonksiyonel Kümeleme Algoritması Uygulaması

Önerilen çözümün uygulanması için öncelikli olarak veri madenciliği algoritmalarından bazılarının çalıştırılması ve sonuçlarının görülmesi gerekmektedir. Şekil 52 üzerinde Boost Fonksiyonel Kümeleme Algoritması Akış Diyagramını açıklanacak olursa öncelikli olarak trend belirlenmektedir. Trend belirleme işleminden sonra içinde bulunan trende göre her bir algoritmanın başarısı belirlenir. Başarılar belirlendikten sonra başarı oranına paralel bir şekilde algoritmalarda ağırlıklandırma yapılır. Ağırlıklı sonuçlara göre tahmin sonuçları toplanır. Tahmin sonuçları toplama işlemi yapıldıktan sonra içinden en büyük olan sonuç boost fonksiyonel kümeleme algoritması sonucu kabul edilir.



Şekil 36. Boost Fonksiyonel Kümeleme Algoritması Akış Diyagramı

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 36 üzerinde Yatay trend içerisindeki algoritmaların başarı oranlarına bakılır Toplamda 2019 USD/TRY kuru içerisinde 98 gün yatay trend içerisinde. LSTM yatay trend içerisinde 32 gün başarısız tahmin 66 gün başarılı tahminde bulunmuştur.

Tablo 17. Yatay Trend Algoritmaların 2019 USD/TRY Kuru Sonuçları

	Başarı	Başarısız
LSTM	66	32
CNN	63	35
ARIMA	51	47

Kaynak: Yazar tarafından oluşturulmuştur.

LSTM:1.1, CNN:1 , ARIMA:0.9

Tablo 17 de yatay trende göre algoritmaların tahmin sonuçları görülmektedir. Bu sonuçlara göre sıralama yapacak olursak LSTM, CNN, ARIMA şeklinde sıralanacaktır. Ağırlık puanlarını da bu sıraya göre verebiliriz.

Tablo 18. 28.01.2020 USD/TRY için Boost Fonksiyonel Kümeleme Ağırlıklandırma

Algoritmalar	Tahmin Sonuçları	Ağırlık Oranları	Ağırlık Tahmin Çarpımları
LSTM	Al	1.1	1.1Al
CNN	Al	1	1Al
ARIMA	Sat	0.9	0.8Sat

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 18 de 28.01.2020 tarihine ait bir günlük boost fonksiyonel kümeleme algoritmasının ağırlıklandırma sonuçları yer almaktadır. Sonuç ise hepsinin grup şeklinde

toplanmasından çıkar. 2.1Al , 0.8Sat. 2,1 ile 0,8 kıyaslanır 2,1 daha büyük olduğu için boost fonksiyonel kümeleme algoritması sonucu Al olacaktır.

Sözde kod(Pseudocode), program tasarımının bir metin taslağıdır. Ana işlemler, fonksiyonel bloklar olarak düzenlenen tanımlayıcı ifadeler olarak yazılır. Yapı ve sıra, üst düzey diller için olduğu gibi, blokların uygun girintileriyle temsil edilir (Martin 2011). Sözde kod adımları aşağıdaki gibidir.

- TrendBelirle(Date now)
- While(algoritma Algoritmalar)
- Ağırlık Belirle
- Tahmin sonuçları hesapla
- En Büyük tahmin sonuç bul

Uygulamanın test edilebilmesi için öncelikli olarak sisteme bir finansal enstrümanın verilerinin yüklenmesi gerekmektedir. Bu işlemten sonra veriler tahmin edilebilir duruma gelecektir.

Bu bölümde USD/TRY ve ons altın verilerin uygulama üzerindeki test sonuçları bulunmaktadır. Farklı finansal enstrüman ve farklı zaman aralıklarında uygulamanın test sonuçlarını kıyaslamak mümkün olmaktadır.

1 yıllık USD/TRY kuru ile orta vade de bir menkul kıymetin hareketleri analiz edilmiştir. Tablo IV de 2019 yılı USD/TRY kuru uygulama test sonuçları bulunmaktadır. Önerilen çözüm olan Boost Fk algoritmasının daha başarılı sonuçlar verdiği görülmüştür.

Tablo 19. 2019 USD/TRY Uygulama Test Sonuçları

	Başarı Adet	Başarı Yüzde	Başarısız Adet	Başarısız Yüzde
Boost Fonksiyonel Kümeleme	180	67	86	33
ARIMA	93	34	173	66
LSTM	174	65	92	35

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 19 üzerinde 17 yıllık USD/TRY kuru ile uzun vade de bir menkul kıymetin hareketleri analiz edilmiştir. Tablo 18 de 17 yıllık (2003-2020) USD/TRY kurunu uygulama üzerinde çalıştırdığında 1 yıllık verilere göre farklı sonuçlar vermektedir. Bu tarihler arasında toplamda 4293 adet gün analiz edilmiştir. Bir yıllık sonuçlara göre başarı oranı düşmüştür.

Tablo 20. 2003-2020 2019 USD/TRY Uygulama Test Sonuçları

	Başarı Adet	Başarı Yüzde	Başarısız Adet	Başarısız Yüzde
Boost Fonksiyonel Kümeleme	765	64	1528	36
LSTM	2763	64	1530	36
CNN	2724	63	1569	37
ARIMA	1972	45	2321	55

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 20 da 1 yıllık ons altın kuru ile orta vade de bir menkul kıymetin hareketleri analiz edilmiştir. Tablo 19 de 250 günlük ons altın verisi test sonuçları bulunmaktadır. USD-TRY kurundan farklı olarak ons altın daha az oynaklığa sahiptir.

Tablo 21. 2007 Yılı Ons Altın Uygulama Test Sonuçları

	Başarı Adet	Başarı Yüzde	Başarısız Adet	Başarısız Yüzde
Boost Fonksiyonel Kümeleme	179	71	71	29
LSTM	176	70	74	30
CNN	171	68	79	32
ARIMA	167	55	83	34

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 21 de örnek ile açıklanırsa 28.01.2020 USD/TRY günü trend yatay durumdadır. Yatay trend içerisindeki algoritmaların başarı oranlarına bakalım. Başarı sonuçlarına aşağıdaki 2 sorgu ile bakılabilir. Toplamda 2019 USD/TRY kuru içerisinde 98 gün yatay trend içerisinde dir.

Başarılı yatay trendler aşağıdaki sorgu ile bulunabilir.

```
SELECT count(*) FROM APP.DOVIZ_KUR where
TAHMIN_SONUC=RF_TAHMIN and trend='yatay'
```

Başarısız yatay trendler aşağıdaki sorgu ile bulunabilir.

SELECT count(*) FROM APP.DOVIZ_KUR where
TAHMIN_SONUC!=RF_TAHMIN and trend='yatay'

Yukardaki sorgular random forest algoritmasına göredir. Diğer algoritmalar için rf_tahmin alanı değiştirilerek sonuçlar elde edilebilir. Random forest yatay trend içerisinde 32 gün başarısız tahmin 66 gün başarılı tahminde bulunmuştur.

Tablo 22. Yatay Trend Algoritmaların 2019 USD/TRY Kuru Sonuçları

	Başarı	Başarısız
Random Forest	66	32
Bagging	63	35
Stacking	51	47
AdaBoost	63	35
Neural Network	64	34
Vote	46	32
Naive Bayes	61	37

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 22 de yatay trende göre algoritmaların tahmin sonuçları görölmektedir. Bu sonuçlara göre sıralama yapacak olursak Random Forest, Neural Network, AdaBoost, Bagging, Naive Bayes, Stacking, Vote şeklinde sıralanacaktır. Ağırlık puanlarını da bu sıraya göre verebiliriz.

Random Forest : 1.3 , Neural Network:1.2 , AdaBoost:1.1, Bagging:1 , Naive Bayes:0.9, Stacking:0.8, Vote:0.7

Tablo 23. 28.01.2020 USD/TRY için Boost Fonksiyonel Kümeleme Ağırlıklandırma

Algoritmalar	Tahmin Sonuçları	Ağırlık Oranları	Ağırlık Tahmin Çarpımları
Random Forest	Oynama	1.3	1.3Oynama
Ada Boost	Al	1.1	1.1Al
Bagging	Al	1	1Al
Stacking	Al	0.8	0.8Al
Vote	Al	0.7	0.7Al
Neural Network	Al	1.2	1.2Al
Naive Bayes	Al	0.9	0.9Al


Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 23 de 28.01.200 tarihi için USD/TRY kurunun Boost Fonksiyonel Kümeleme için Ağırlıklandırma sonuçları yer almaktadır. Sonuç ise hepsinin grup şeklinde

toplanmasından çıkar. 1,3 Oynama 5.7Al. 5,7 ile 1,3 kıyaslanır 5,7 daha büyük olduğu için boost fonksiyonel kümeleme algoritması sonucu A1 olacaktır.

3.2. Vote Fonksiyonel Kümele Algoritması Uygulaması

Çalışma kapsamında önerilen algoritmalarından bir diğeri ise Vote Fonksiyonel Kümele kısaca VoteFK algoritmasıdır. Bu algoritma ile de zaman serisi verilerine yakınsama yapılmakla birlikte kollektif sınıflandırma yöntemlerinden voting uygulanmaktadır.



Şekil 37. Vote Fonksiyonel Kümeleme Algoritması Akış Diyagramı

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 37 üzerinde Vote Fonksiyonel Kümeleme Algoritması Akış Diyagramını açıklanacak olursa öncelikli olarak trend belirlenmektedir. Trend belirleme işleminden sonra içinde bulunulan trende göre her bir algoritmanın başarısı belirlenir. Başarılar belirlendikten sonra algoritma sonuçlarına göre oylama yapılır. Oylama sonuçlarına göre tahmin sonuçları toplanır. Tahmin sonuçları toplama işlemi yapıldıktan sonra içinden en büyük olan sonuç vote fonksiyonel kümeleme algoritması sonucu kabul edilir.

Sözde kod adımları aşağıdaki gibidir.

- TrendBelirle(Date now)
- While(algoritma Algoritmalar)
- Oylama sonuçları başarılarla göre belirlenir
- Tahmin sonuçları hesapla
- En Büyük tahmin sonuç bul

Tablo 21 üzerindeki örnek üzerindeki sonuçlardan VoteFK algoritması sonuçları:

5 Adet Al ve 1 adet Oynama olduđu için VoteFK sonucu Al şeklinde olacaktır. Önerilen yöntem ile ilgili diğerk test sonuçları bir sonraki bölümde detaylı bir şekilde gösterilecektir.

3.3. Uygulamanın Test Edilmesi

Çalışma kapsamında önerilen Kollektif sınıflandırma yöntemi ile ilgili algoritmaların doğruluklarının ve uygulanabilirliklerinin ispatı için farklı zaman aralıklarındaki finansal enstrüman verileri ile testler yapılmıştır. Farklı zaman aralıklarındaki ve farklı finansal enstrümanlarla yapılan testler ile önerilerin değişik zaman aralıkları ve farklı finansal enstrümanlar ile uygulanabilirliği gösterilmiştir.

Uygulamanın test edilebilmesi için öncelikli olarak sisteme bir finansal enstrüman verilerinin yüklenmesi gerekmektedir. Finansal enstrüman verilerinin yüklemek için Kur Yükle sayfası kullanılmaktadır. Bu sayfa ile ilgili detay bilgiye Uygulama Ekranları Oluşturulması bölümüne bakılabilir. Finansal enstrüman verileri yüklendikten sonra yine aynı ekranda bulunan Verileri Düzenle butonu ile verileri düzenleme işlemi yapılmalıdır. Bu işlemten sonra veriler tahmin edilebilir duruma gelecektir.

Algoritmaların tahmin sonuçları için Kur Tahmin sayfası kullanılmalıdır. Bu sayfada bulunan Kolektif Sınıflandırmaya göre Tahmin Et butonu ile algoritma tahminleri çalışacaktır. Yine aynı sayfada tahmin sonuçlarını görmek mümkündür. Bu ekran da yine Uygulama Ekranları bölümünde anlatılmıştır.

Bu bölümde çeşitli menkul kıymet verilerin uygulama üzerindeki test sonuçları bulunmaktadır. Farklı finansal enstrüman ve farklı zaman aralıklarında uygulamanın test sonuçlarını kıyaslamak mümkün olmaktadır. İlave olarak korelasyonların ortaya konulması ve finansal enstrüman verilerin test sonuçlarının kıyaslanabilmesi için aynı zaman diliminde de test sonuçları gerekmektedir. Bu sonuçları ortaya konulabilmesi adına 14-05-2018 - 27-11-2020 tarihleri arasında detaylı test yapılmıştır.

Yapılan testlerin genel özellikleri:

- Farklı vade seçenekleri ile testler yapılmıştır. Bu vade seçenekleri uzun, kısa ve orta vade şeklindedir.
- Farklı finansal enstrümanlar ile testler yapılmıştır. Bu finansal enstrümanlar USD/TRY, EUR/USD, Ons Altın, GARAN

- Farklı giriş değerleri ile testler yapılmıştır. Bu giriş değerleri: formüller, indikatörler, USD/TRY, 1-CDS, 5-CDS, 10-CDS, 1-FAIZ, 5-FAIZ, 10-FAIZ, PMI, DTA-Dış Ticaret Açığı, Amerikan 10 yıllık Tahvil Faiz, BIST100, USD Endeks, TÜFE, Tüketici Güven Endeksi, Ekonomik Güven Endeksi, EUR/USD, Ons Altın, GARAN, EUR/TRY

3.3.1. Test Verileri

Çalışma kapsamında farklı finansal enstrümanlar farklı zaman serileri ile testler yapılmıştır. Bu bölümde önerilen fonksiyonel kümeleme algoritmalarının ispatı ve uygulanabilirliğinin ispatı için farklı zaman aralıkları ve aynı zaman aralığında farklı veri türleri için testler yapılmıştır. 14-05-2018 ile 15-06-2018 tarihindeki veriler üzerinden detaylı bir şekilde test verileri açıklanmıştır. Bu tarihler arasındaki testler de Tüketici ve Ekonomik Güven Endeksi, EUR/USD, Ons Altın, EUR/TRY, Türkiye'nin dış ticaret açığı, Amerikan 10 yıllık tahvil faizleri, BIST 100 endeksi, USD endeksi, TÜFE, Türkiye'nin 1, 5, 10 yıllık CDS verileri, Türkiye'nin 1, 5, 10 yıllık Faiz verileri, GARAN ile USD/TRY kuru verilerinden yararlanılmıştır. Bu veriler arası korelasyonlar çıkarılmakla birlikte tahmin sonuçları da değerlendirilmiştir. USD/TRY, Ons altın, EUR/USD, GARAN, BIST100, USD Endeks, EUR/TRY ile test sonuçları ortaya konulmuştur.

Tablo 24. 14-05-2018 ile 15-06-2018 USD/TRY, CDS, FAİZ Verileri

Tarih	USD/TRY	1-CDS	5-CDS	10-CDS	1-FAİZ	5-FAİZ	10-FAİZ
14-05-2018	4,31	115,92	233,68	319,60	14,00	14,66	13,41
15-05-2018	4,37	115,92	233,78	320,09	14,00	14,58	14,46
16-05-2018	4,44	147,78	264,95	350,14	14,00	15,01	14,26
17-05-2018	4,41	137,83	255,20	340,75	15,50	15,16	14,17
18-05-2018	4,46	150,79	267,89	353,01	15,06	15,41	14,42
21-05-2018	4,49	160,75	277,71	362,58	15,20	15,74	15,33
22-05-2018	4,57	168,72	285,46	369,99	15,26	15,69	15,35
23-05-2018	4,67	159,75	276,62	361,30	15,20	15,65	14,27
24-05-2018	4,58	163,72	280,35	364,62	15,20	15,65	14,27
25-05-2018	4,71	148,79	265,92	351,04	15,00	15,45	14,28
28-05-2018	4,71	145,80	263,05	348,30	16,00	15,40	14,09
29-05-2018	4,58	145,80	262,89	347,86	15,00	15,36	13,71
30-05-2018	4,55	133,85	251,31	336,88	15,06	15,26	13,54
31-05-2018	4,46	134,85	252,24	337,69	17,00	14,79	14,38
01-06-2018	4,52	151,79	268,89	353,99	17,00	14,79	14,38
04-06-2018	4,65	161,75	278,61	363,26	17,00	14,79	14,38
05-06-2018	4,59	155,77	272,68	357,30	17,00	14,79	14,38
06-06-2018	4,60	158,77	275,68	360,46	18,30	15,44	14,69
07-06-2018	4,55	158,77	275,68	360,46	18,47	15,47	14,51
08-06-2018	4,48	147,81	264,94	349,98	18,47	15,47	14,51
11-06-2018	4,48	153,79	270,84	355,80	18,25	15,61	14,64
12-06-2018	4,52	160,76	277,62	362,18	18,25	15,44	14,77
13-06-2018	4,60	175,71	292,34	376,73	19,30	15,62	15,87
14-06-2018	4,63	182,69	299,05	382,84	19,30	15,62	15,87
15-06-2018	4,73	179,70	296,20	380,32	19,30	15,62	15,87

Kaynak: TCMB EVDS.. <https://evds2.tcmb.gov.tr/index.php? ET:03.03.2021>

Tablo 24 üzerinde Türkiye'nin 1, 5, 10 yıllık CDS verileri, Türkiye'nin 1, 5, 10 yıllık Faiz verileri ile USD/TRY kuru verileri bulunmaktadır. Bu tablodaki veriler 14-05-2018 ile 15-06-2018 tarihleri arasında kapsamaktadır.

Tablo 25. DTA, Amerikan 10 yıllık Faiz, USD Endeks TÜFE verileri

Tarih	DTA-Dış Ticaret Açığı	Amerikan 10 yıllık Tahvil Faiz	BIST100	USD Endeks	TÜFE
14-05-2018	12,6	3,00	1.017,38	92,43	10,85
15-05-2018	12,6	3,07	1.022,65	92,53	10,85
16-05-2018	12,6	3,10	1.016,12	93,22	10,85
17-05-2018	12,6	3,12	1.026,11	93,20	10,85
18-05-2018	12,6	3,06	1.020,33	93,44	10,85
21-05-2018	12,6	3,06	1.021,67	93,59	10,85
22-05-2018	12,6	3,06	1.027,18	93,46	10,85
23-05-2018	12,6	2,99	1.028,06	93,45	10,85
24-05-2018	12,6	2,98	1.030,27	93,85	10,85
25-05-2018	12,6	2,93	1.017,86	93,74	10,85
28-05-2018	12,6	2,90	1.044,81	94,06	10,85
29-05-2018	12,6	2,79	1.059,30	94,35	10,85
30-05-2018	12,6	2,86	1.049,79	94,80	10,85
31-05-2018	12,6	2,86	1.042,64	94,05	10,85
01-06-2018	-0,2	2,90	1.007,07	93,96	10,85
04-06-2018	-0,2	2,94	992,64	94,17	12,15
05-06-2018	-0,2	2,93	996	93,99	12,15
06-06-2018	-0,2	2,97	982,7	93,81	12,15
07-06-2018	-0,2	2,92	964,42	93,59	12,15
08-06-2018	-0,2	2,95	981,91	93,47	12,15
11-06-2018	-0,2	2,95	959,22	93,51	12,15
12-06-2018	-0,2	2,97	964,74	93,68	12,15
13-06-2018	-0,2	2,97	948,26	93,82	12,15
14-06-2018	-0,2	2,94	932,96	93,49	12,15
15-06-2018	-0,2	2,92	942,36	94,96	12,15

Kaynak: TCMB EVDS.. <https://evds2.tcmb.gov.tr/index.php?ET:03.03.2021>

Tablo 25 üzerinde Türkiye'nin dış ticaret açığı, Amerikan 10 yıllık tahvil faizleri, BIST 100 endeksi, USD endeksi, TÜFE verileri bulunmaktadır. Bu tablodaki veriler 14-05-2018 ile 15-06-2018 tarihleri arasında kapsamaktadır.

Tablo 26. Tüketici ve Ekonomik Güven Endeksi, EUR/USD, Ons Altın, EUR/TRY Verileri

Tarih	Tüketici Güven Endeksi	Ekonomik Güven Endeksi	EUR/USD Açılış	Ons Altın	GARAN	EUR/TRY
14-05-2018	90,67	101,75	1,1947	1.417,90	8,96	5,1536
15-05-2018	90,67	101,75	1,1925	1.405,30	8,92	5,21
16-05-2018	90,67	101,75	1,1837	1.392,10	8,79	5,2594
17-05-2018	90,67	101,75	1,1808	1.390,00	8,87	5,2089
18-05-2018	90,67	101,75	1,1796	1.391,30	8,71	5,2615
21-05-2018	90,67	101,75	1,1764	1.391,10	8,73	5,2821
22-05-2018	90,67	101,75	1,1792	1.392,10	8,79	5,3948
23-05-2018	90,67	101,75	1,1778	1.389,20	8,99	5,5004
24-05-2018	90,67	101,75	1,1695	1.404,20	9,03	5,3517
25-05-2018	90,67	101,75	1,172	1.403,20	8,94	5,5194
28-05-2018	90,67	101,75	1,1651	1.298,40	9,24	5,4913
29-05-2018	90,67	101,75	1,1625	1.393,70	9,31	5,3202
30-05-2018	90,67	101,75	1,154	1.396,70	9,13	5,2493
31-05-2018	90,67	101,75	1,1665	1.395,00	9,36	5,2085
01-06-2018	90,60	99,29	1,1691	1.392,40	8,76	5,2898
04-06-2018	90,60	99,29	1,1656	1.389,60	8,25	5,4192
05-06-2018	90,60	99,29	1,1698	1.394,50	8,41	5,3719
06-06-2018	90,60	99,29	1,1717	1.393,90	8,27	5,3878
07-06-2018	90,60	99,29	1,1774	1.394,80	8,3	5,3635
08-06-2018	90,60	99,29	1,18	1.394,80	8,46	5,2916
11-06-2018	90,60	99,29	1,1766	1.395,90	8,24	5,2611
12-06-2018	90,60	99,29	1,1784	1.392,20	8,2	5,3311
13-06-2018	90,60	99,29	1,1745	1.393,90	8,14	5,3971
14-06-2018	90,60	99,29	1,1791	1.401,00	7,99	5,4746
15-06-2018	90,60	99,29	1,1568	1.369,70	7,99	5,4669

Kaynak: TCMB EVDS.. <https://evds2.tcmb.gov.tr/index.php?ET:03.03.2021>

Tablo 25 üzerinde Tüketici ve Ekonomik Güven Endeksi, EUR/USD, Ons Altın, EUR/TRY, GARAN verileri bulunmaktadır. Bu tablodaki veriler 14-05-2018 ile 15-06-2018 tarihleri arasını kapsamaktadır.

3.3.2. 14-05-2018 ile 15-06-2018 Tarihleri Arası Test Sonuçları

14-05-2018 ile 15-06-2018 tarihleri arasında 666 adet veri bulunmaktadır. Bu veriler ile BoostFK, VoteFK, LSTM-RNN, MLP, ARIMA, Random Forest, Stacking, Voting,

Bagging algoritmaları ile testler yapılmıştır. Bu tarihler arası, ons altın, EUR/USD, GARA, USD/TRY, BIST100, USD Endeks, EUR/TRY finansal enstrümanları ile testler yapılmıştır. Finansal enstrüman türüne göre farklı veriler giriş değeri olarak kullanılmıştır.

Tablo 27. 14-05-2018 İle 15-06-2018 Tarihleri Arası USD/TRY Sonuçları

USD/TRY	Başarı Adet	Başarı Yüzde	Başarısız Adet	Başarısız Yüzde
BoostFK	453	68	213	32
VoteFK	446	67	220	33
LSTM-RNN	446	67	220	33
MLP	440	66	226	34
ARIMA	386	58	280	42
Random Forest	440	66	226	34
Stacking	426	64	240	36
Voting	400	60	266	40
Bagging	433	65	233	35

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 27 te 14-05-2018 İle 15-06-2018 tarihleri arası USD/TRY tahmin sonuçları yer almaktadır. Bu tahmin sonuçlarına göre en başarılı tahmin sonucu %68 ile önerilen BoostFK algoritmasıdır.

Tablo 28. 14-05-2018 İle 15-06-2018 Tarihleri Arası Ons Altın Sonuçları

Ons Altın	Başarı Adet	Başarı Yüzde	Başarısız Adet	Başarısız Yüzde
BoostFK	526	79	140	21
VoteFK	513	77	153	23
LSTM-RNN	519	78	147	22
MLP	506	76	160	24
ARIMA	466	70	200	30
Random Forest	500	75	167	25
Stacking	493	74	173	26
Voting	480	72	186	28
Bagging	500	75	167	25

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 28 te 14-05-2018 İle 15-06-2018 tarihleri arası ons altın tahmin sonuçları yer almaktadır. Bu tahmin sonuçlarına göre en başarılı tahmin sonucu %79 ile önerilen BoostFK algoritmasıdır.

Tablo 29. 14-05-2018 İle 15-06-2018 Tarihleri Arası EUR/USD Sonuçları

EUR/USD	Başarı Adet	Başarı Yüzde	Başarısız Adet	Başarısız Yüzde
BoostFK	506	76	160	24
VoteFK	493	74	173	26
LSTM-RNN	480	72	186	28
MLP	433	65	233	35
ARIMA	473	71	193	29
Random Forest	466	70	200	30
Stacking	473	71	193	29
Voting	486	73	180	27
Bagging	493	74	173	26

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 29 de 14-05-2018 İle 15-06-2018 tarihleri arası EUR/USD tahmin sonuçları yer almaktadır. Bu tahmin sonuçlarına göre en başarılı tahmin sonucu %76 ile önerilen BoostFK algoritmasıdır.

EUR/USD 18-11-2019 / 16-12-2020		
LSTM - RNN doğru tahmin sayısı = 197 Yüzde = 69 yanlış tahmin sayısı = 85 Yüzde = 31	MLP doğru tahmin sayısı = 179 Yüzde = 63 yanlış tahmin sayısı = 103 Yüzde = 37	ARIMA- BOX JENKINS doğru tahmin sayısı = 123 Yüzde = 43 yanlış tahmin sayısı = 159 Yüzde = 57
Random Forest doğru tahmin sayısı = 180 Yüzde = 63 yanlış tahmin sayısı = 102 Yüzde = 37	Stacking doğru tahmin sayısı = 160 Yüzde = 56 yanlış tahmin sayısı = 122 Yüzde = 44	Vote doğru tahmin sayısı = 130 Yüzde = 45 yanlış tahmin sayısı = 152
Bagging doğru tahmin sayısı = 177 Yüzde = 62 yanlış tahmin sayısı = 105 Yüzde = 38	Boost FK doğru tahmin sayısı = 199 Yüzde = 70 yanlış tahmin sayısı = 83 Yüzde = 30	Vote FK doğru tahmin sayısı = 176 Yüzde = 62 yanlış tahmin sayısı = 106

Şekil 38. EUR/USD 2020 Test Sonuçları Ekran Görüntüsü

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 38 üzerinde bir diğer EUR/USD testi ise 2020 yılı için yapılmıştır. Bu test sonuçlarına göre BoostFK algoritması %70 lik bir başarı oranı yakalamıştır.

Tablo 30. 14-05-2018 İle 15-06-2018 Tarihleri Arası GARAN Sonuçları

GARAN	Başarı Adet	Başarı Yüzde	Başarısız Adet	Başarısız Yüzde
BoostFK	500	75	167	25
VoteFK	480	72	186	28
LSTM-RNN	500	75	167	25
MLP	480	72	186	28
ARIMA	420	63	246	37
Random Forest	486	73	180	27
Stacking	466	70	200	30
Voting	466	70	200	30
Bagging	486	73	180	27

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 29 de 14-05-2018 İle 15-06-2018 tarihleri arası GARAN tahmin sonuçları yer almaktadır. Bu tahmin sonuçlarına göre en başarılı tahmin sonucu %75 ile önerilen BoostFK algoritmasıdır.

Tablo 31. 14-05-2018 İle 15-06-2018 Tarihleri Arası BIST100 Sonuçları

BIST100	Başarı Adet	Başarı Yüzde	Başarısız Adet	Başarısız Yüzde
BoostFK	466	70	200	30
VoteFK	453	68	213	32
LSTM-RNN	460	69	206	31
MLP	446	67	220	33
ARIMA	406	61	260	39
Random Forest	453	68	213	32
Stacking	426	64	240	36
Voting	440	66	226	34
Bagging	460	69	206	31

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 31 da 14-05-2018 İle 15-06-2018 tarihleri arası BIST100 tahmin sonuçları yer almaktadır. Bu tahmin sonuçlarına göre en başarılı tahmin sonucu %70 ile önerilen BoostFK algoritmasıdır.

Tablo 32. 14-05-2018 İle 15-06-2018 Tarihleri Arası USD Endeks Sonuçları

USD Endeks	Başarı Adet	Başarı Yüzde	Başarısız Adet	Başarısız Yüzde
BoostFK	493	74	173	26
VoteFK	473	71	193	29
LSTM-RNN	493	74	173	26
MLP	466	70	200	30
ARIMA	426	64	240	36
Random Forest	486	73	180	27
Stacking	446	67	220	33
Voting	460	69	206	31
Bagging	480	72	186	28

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 32 da 14-05-2018 İle 15-06-2018 tarihleri arası USD Endeks tahmin sonuçları yer almaktadır. Bu tahmin sonuçlarına göre en başarılı tahmin sonucu %74 ile önerilen BoostFK algoritması ve LSTM-RNN algoritmalarıdır. Sonuçlara göre önerilen yöntem ile en başarılı tahmin sonucu aynı başarı oranını göstermektedir.

Tablo 33. 14-05-2018 İle 15-06-2018 Tarihleri Arası EUR/TRY Sonuçları

EUR/TRY	Başarı Adet	Başarı Yüzde	Başarısız Adet	Başarısız Yüzde
BoostFK	460	69	206	31
VoteFK	446	67	220	33
LSTM-RNN	453	68	213	32
MLP	446	67	220	33
ARIMA	386	58	280	42
Random Forest	440	66	226	34
Stacking	420	63	246	37
Voting	433	65	233	35
Bagging	426	64	240	36

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 33 de 14-05-2018 İle 15-06-2018 tarihleri arası EUR/TRY tahmin sonuçları yer almaktadır. Bu tahmin sonuçlarına göre en başarılı tahmin sonucu %69 ile önerilen BoostFK algoritmasıdır.

3.3.3. 2019 USD/TRY Uygulama Test Sonuçları

1 yıllık USD/TRY kuru ile orta vade de bir menkul kıymetin hareketleri analiz edilmiştir.

Tablo 34. 2019 USD/TRY Uygulama Test Sonuçları

USD/TRY	Başarı Adet	Başarı Yüzde	Başarısız Adet	Başarısız Yüzde
BoostFK	174	67	86	33
VoteFK	164	63	96	37
LSTM-RNN	169	65	91	35
MLP	161	62	99	38
ARIMA	88	34	172	66
Random Forest	172	66	88	34
Stacking	172	66	88	34
Voting	125	48	135	52
Bagging	156	60	104	40

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 34 üzerinde 2019 yılı USD/TRY kuru uygulama test sonuçları bulunmaktadır. Uygulama üzerinde bulunan 9 adet algoritmanın başarı yüzdeleri, başarısızlık yüzdeleri, başarı adetleri, başarısızlık adetleri bulunmaktadır. 2019 yılı içinde toplamda 260 adet gün analiz edilmiştir. Tabloya bakılacak olursak Vote Fonksiyonel Kümeleme algoritması random forest ve neural network sonuçlarından daha geridedir, Boost Fonksiyonel Kümeleme algoritması başarı yüzdesi en yüksek olan algoritma olarak görülmektedir.

Kolektif Sınıflandırmaya Göre Tahmin Et

Kolektif Sınıflandırmaya Sonuc

USD/TRY 02-01-2019 / 27-01-2020

LSTM - RNN doğru tahmin sayısı = 175 Yüzde = 65 yanlis tahmin sayısı = 199 Yuzde = 35	MLP doğru tahmin sayısı = 171 Yüzde = 64 yanlis tahmin sayısı = 95 Yuzde = 36	ARIMA- BOX JENKINS doğru tahmin sayısı = 84 Yüzde = 46 yanlis tahmin sayısı = 182 Yuzde = 54
Random Forest doğru tahmin sayısı = 172 Yüzde = 64 yanlis tahmin sayısı = 94 Yuzde = 36	Stacking doğru tahmin sayısı = 168 Yüzde = 62 yanlis tahmin sayısı = 98 Yuzde = 38	Vote doğru tahmin sayısı = 129 Yüzde = 48 yanlis tahmin sayısı = 137
Bagging doğru tahmin sayısı = 170 Yüzde = 63 yanlis tahmin sayısı = 96 Yuzde = 37	Boost FK doğru tahmin sayısı = 178 Yüzde = 66 yanlis tahmin sayısı = 95 Yuzde = 34	Vote FK doğru tahmin sayısı = 171 Yüzde = 64 yanlis tahmin sayısı = 95

Şekil 39. 2019 USD/TRY Test Sonuçları Ekran Görüntüsü

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 39 üzerinde 2019 USD/TRY uygulama test sonuçları ekran görüntüsü bulunmaktadır.

3.3.4. 2003-2020 USD/TRY Test Sonuçları


17 yıllık USD/TRY kuru ile uzun vade de bir menkul kıymetin hareketleri analiz edilmiştir.

Tablo 35. 2003-2020 2019 USD/TRY uygulama test sonuçları

USD/TRY	Başarı Adet	Başarı Yüzde	Başarısız Adet	Başarısız Yüzde
BoostFK	2747	64	1546	36
VoteFK	2662	62	1631	38
LSTM-RNN	2748	64	1545	36
MLP	2619	61	1674	39
ARIMA	1932	45	2361	55
Random Forest	2705	63	1588	37
Stacking	2705	63	1588	37
Voting	2576	60	1717	40
Bagging	2705	63	1588	37

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 35 üzerinde 17 yıllık(2003-2020) USD/TRY kurunu uygulama üzerinde çalıştırdığında 1 yıllık verilere göre farklı sonuçlar vermektedir. Bu tarihler arasında toplamda 4293 adet gün analiz edilmiştir. Tabloya bakılacak olursak LSTM-RNN ve Boost Fonksiyonel Kümeleme %64 ile ilk sırada yer almaktalar. Adet olarak bakılacak olursak Boost Fonksiyonel Kümeleme algoritması başarı yüzdesi en yüksek olan algoritma olarak görülmektedir.



Şekil 40. 2003-2020 2019 USD/TRY uygulama test sonuçları ekran görüntüsü

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 40 üzerinde 2003-2020 USD/TRY kuru tahmin sonuçlarının ekran görüntüsü bulunmaktadır.

USD/TRY 14-05-2018 / 27-11-2020

LSTM - RNN doğru tahmin sayısı = 443 Yüzde = 66 yanlış tahmin sayısı = 221 Yüzde = 34	MLP doğru tahmin sayısı = 427 Yüzde = 64 yanlış tahmin sayısı = 237 Yüzde = 36	ARIMA- BOX JENKINS doğru tahmin sayısı = 258 Yüzde = 38 yanlış tahmin sayısı = 406 Yüzde = 62
Random Forest doğru tahmin sayısı = 428 Yüzde = 64 yanlış tahmin sayısı = 236 Yüzde = 36	Stacking doğru tahmin sayısı = 423 Yüzde = 63 yanlış tahmin sayısı = 241 Yüzde = 37	Vote doğru tahmin sayısı = 332 Yüzde = 49 yanlış tahmin sayısı = 332
Bagging doğru tahmin sayısı = 424 Yüzde = 63 yanlış tahmin sayısı = 240 Yüzde = 37	Boost FK doğru tahmin sayısı = 451 Yüzde = 67 yanlış tahmin sayısı = 213 Yüzde = 33	Vote FK doğru tahmin sayısı = 427 Yüzde = 64 yanlış tahmin sayısı = 237

Şekil 41. USD/TRY 2018-2020 Test Sonuçları Ekran Görüntüsü

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 41 üzerinde USD/TRY 2018-2020 test sonuçları ekran görüntüsü bulunmaktadır.

USD/TRY 14-05-2018 / 27-11-2020

LSTM - RNN doğru tahmin sayısı = 443 Yüzde = 66 yanlış tahmin sayısı = 221 Yüzde = 34	MLP doğru tahmin sayısı = 432 Yüzde = 64 yanlış tahmin sayısı = 232 Yüzde = 36	ARIMA- BOX JENKINS doğru tahmin sayısı = 258 Yüzde = 38 yanlış tahmin sayısı = 406 Yüzde = 62
Random Forest doğru tahmin sayısı = 436 Yüzde = 65 yanlış tahmin sayısı = 228 Yüzde = 35	Stacking doğru tahmin sayısı = 417 Yüzde = 62 yanlış tahmin sayısı = 247 Yüzde = 38	Vote doğru tahmin sayısı = 332 Yüzde = 49 yanlış tahmin sayısı = 332
Bagging doğru tahmin sayısı = 424 Yüzde = 63 yanlış tahmin sayısı = 240 Yüzde = 37	Boost FK doğru tahmin sayısı = 451 Yüzde = 67 yanlış tahmin sayısı = 213 Yüzde = 33	Vote FK doğru tahmin sayısı = 434 Yüzde = 65 yanlış tahmin sayısı = 230

Şekil 42. USD/TRY 2018-2020 Test Sonuçları CDS Etkisi

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 42 üzerinde USD/TRY 2018-2020 test sonuçları ekran görüntüsü bulunmaktadır. CDS etkisinin sonuçlara etkisi gözlemlendiği bu test sonuçlarına göre VoteFK algoritmasının da %1 lik bir artış gözlemlenmiştir.

3.3.5. 2017 Ons Altın Test Sonuçları

1 yıllık ons altın kuru ile orta vade de bir menkul kıymetin hareketleri analiz edilmiştir. USD-TRY kurundan farklı olarak ons altın daha az oynaklığa sahiptir.

Tablo 36. 2007 Yılı Ons Altın Uygulama Test Sonuçları

Ons Altın	Başarı Adet	Başarı Yüzde	Başarısız Adet	Başarısız Yüzde
BoostFK	195	78	55	22
VoteFK	173	69	78	31
LSTM-RNN	190	76	60	24
MLP	170	68	80	32
ARIMA	138	55	113	45
Random Forest	165	66	85	34
Stacking	173	69	78	31
Voting	120	48	130	52
Bagging	165	66	85	34

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 36 üzerinde 250 günlük ons altın verisi test sonuçları bulunmaktadır. Tabloya bakılacak olursak Boost Fonksiyonel Kümeleme algoritması yüzde 78 doğruluk oranı ile en başarılı tahmin yapan algoritma durumundadır. LST-RNN algoritması da çok yakın bir doğruluk oranına sahiptir.

GC 02-01-2017 / 29-12-2017

LSTM - RNN doğru tahmin sayısı = 193 Yüzde = 76 yanlış tahmin sayısı = 57 Yüzde = 24	MLP doğru tahmin sayısı = 167 Yüzde = 66 yanlış tahmin sayısı = 83 Yüzde = 34	ARIMA- BOX JENKINS doğru tahmin sayısı = 83 Yüzde = 48 yanlış tahmin sayısı = 167 Yüzde = 52
Random Forest doğru tahmin sayısı = 167 Yüzde = 66 yanlış tahmin sayısı = 83 Yüzde = 34	Stacking doğru tahmin sayısı = 167 Yüzde = 66 yanlış tahmin sayısı = 83 Yüzde = 34	Vote doğru tahmin sayısı = 122 Yüzde = 48 yanlış tahmin sayısı = 128
Bagging doğru tahmin sayısı = 167 Yüzde = 66 yanlış tahmin sayısı = 83 Yüzde = 34	Boost FK doğru tahmin sayısı = 196 Yüzde = 78 yanlış tahmin sayısı = 83 Yüzde = 22	Vote FK doğru tahmin sayısı = 167 Yüzde = 66 yanlış tahmin sayısı = 83

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 43. 2007 yılı ons altın uygulama test sonuçları ekran görüntüsü

Şekil 43 üzerinde 2007 yılı ons altın tahmin sonuçlarının ekran görüntüsü bulunmaktadır.

4. KORELASYON SONUÇLARI

Diğer bir önerilen yöntem değişken, formül ve indikatörlerin yapay zeka algoritmalarında giriş değeri olarak kullanılmasıdır. Giriş değeri olarak farklı verilerin kullanılması sonucunda korelasyonlar ortaya çıkmaktadır. Bu korelasyon sonuçları aşağıdaki gibidir.

- Değişkenlerin sayısının artması tahmin sonuçlarını daha iyi hale getirmemiştir.
- Değişkenlerin 2-3 den fazlasının bir arada kullanılması overfitting oluşmasına neden olmaktadır. Bu nedenle değişkenler many to one yapıda 2 şerli olarak kullanılmıştır.
- TÜFE artışı USD/TRY, EUR/TRY artışa sebep olmaktadır. Azalışı da azalışa sebep olmaktadır.

- Amerikan 10 yıllık tahvil faizlerinin artışı USD/TRY ve EUR/TRY de artışa sebep olurken EUR/USD de düşüşe sebep olmaktadır.
- CDS'in artması USD/TRY ve EUR/TRY de artırmıştır. Düşmesi ise düşürmüştür.
- PMI'in artması USD/TRY ve EUR/TRY de azaltmıştır. Azalması USD/TRY ve EUR/TRY de artırmıştır.
- Dış ticaret açığı artması USD/TRY ve EUR/TRY de artırmıştır. Azalması USD/TRY ve EUR/TRY de azaltmıştır.
- Bist100'ün artması USD/TRY ve EUR/TRY de azaltmıştır. Düşmesi ise artırmıştır.
- USD endeks artması USD/TRY ve EUR/TRY de artırmıştır. Düşmesi ise düşürmüştür.
- Tüketici güven endeksi ve ekonomik güven endeksi'nin artması USD/TRY ve EUR/TRY de azaltmış. Düşmesi ise artırmıştır.
- Formüller ve indikatörler paralel bir sonuç çıkmıştır.
- TÜFE, Amerikan 10 yıllık faiz, CDS, Dış Ticaret Açığı, USD endeks, formüller ve İndikatörler birbirlerine paralel sonuçlar ortaya koymuştur.
- PMI, Bist100, Tüketici güven endeksi, Ekonomik güven endeksi ise birbirine zır sonuçlar ortaya koymuştur.

SONUÇ ve TARTIŞMA

Çalışma kapsamında zaman serisi analizine farklı bir bakış açısı sunulmuştur. Bu kapsamda üç farklı önerme ile literatüre katkıda bulunulmuştur. Bu önermelerden ilki aktivasyon fonksiyonlarının modifiye edilmesi üzerinedir. İkinci önerme ise kollektif sınıflandırma yöntemleri ile yapay zeka algoritmalarının yarışdırılması üzerinedir. Üçüncü önerme ise formül, indikatör ve değışkenlerin yapay zeka algoritmalarında kullanılması ile giriş değeri olarak kullanılması ile yapay zeka algoritmalarının başarı oranlarının artırılması ve korelasyonların ortaya çıkarılmasıdır. Çalışma ile literatüre iki farklı yapay zeka algoritması, yeni modifiye aktivasyon fonksiyonu yöntemi ve volatilitte aktivasyon fonksiyonu önerileri ile katkıda sağlanmıştır.

Önermelerden ilki olan aktivasyon fonksiyonları yapay sinir ağlarında farklı veriler için ve ağı farklı katmanlarında çeşitlenebilmektedir. Yaygın olarak kullanılan aktivasyon fonksiyonlarında lineer olma, gradyan koruma, veriye yakınsama, vanishing gradyan problemleri bulunmaktadır. Ayrıca bu aktivasyon fonksiyonları zaman serisi verilerine duyarlı olarak hareket etmekte genel bir kullanım söz konusudur. Çalışma kapsamında belirtilen aktivasyon fonksiyonlarının problemlerinin çözümü ve zaman serisi verilerine duyarlı aktivasyon fonksiyonu için modifiye aktivasyon fonksiyonlarını önerilmektedir. Farklı verilere duyarlı aktivasyon fonksiyonları geliştirilebilir fakat bu çalışma kapsamında finansal enstrüman verilerine duyarlı aktivasyon fonksiyonları tasarlanmıştır. Çalışma kapsamında Leaky ReLU ve Sigmoid fonksiyonu üzerine modifiye işlemi yapılmak suretiyle Modifiye Sigmoid ve Modifiye Leaky ReLU fonksiyonları önerilmiştir. Modifiye sigmoid fonksiyonu ile vanishing gradyan ve Relu fonksiyonunda bulunan linear olma problemleri çözülmüştür. Ayrıca volatilitte fonksiyonu ile modifiye işlemi ile de zaman serisi verilerine duyarlı hale getirilmek suretiyle veriye özel bir aktivasyon fonksiyonu olmuştur.

AF	EUR/USD	Yağmur	Twitter
Sigmoid	0,992	0,8159	0,7861
Modifiye Sigmoid	0,992992	0,8362	0,7948
Leaky ReLU	0,9929	0,8213	0,7932
Modifiye Leaky ReLU	0,9938929	0,8412	0,8123

Yukarıda görüldüğü gibi farklı zaman serileri üzerinde yapılmış modifiye aktivasyon fonksiyonları ve literatürdeki aktivasyon fonksiyonlarının karşılaştırmaları sonuçları yer almaktadır. Bu modifiye fonksiyonları ile yapılan testler sonucunda doğruluk değerlerinde artış kayıp değerlerinde ise azalış gözlemlenmiştir. Önerilen yöntem literatür deki çalışmalarla kıyaslanmıştır tutarlı sonuç alabildiğini ve yöntemin uygulanabilirliğini göstermiştir. Önerilen yöntemler için bir uygulama geliştirilmiş. Geliştirilen uygulama üzerinden yapılan EUR/USD 18-11-2019 ile 16-12-2020 tarihleri arasında finansal enstrüman verisi ile aktivasyon fonksiyonlarında önerilen modifiye yöntemi ile %6 oranında daha başarılı tahmin sonuçları elde edilmiştir.

Önerilen bir diğer yöntem ise yapay zeka algoritmalarının kollektif bir şekilde bir araya getirilmesi ve yarıştırlmasını sağlayan yöntemdir. Çalışma kapsamında literatürde daha önce rastlanılmayan şekilde çoklu algoritma kullanımı gerçekleştirilerek kapsayıcı ve parametrik bir model mimarisi oluşturulması ile birlikte finansal enstrüman tahmininde kullanılan formüller yapay zeka algoritmaların da değişken olarak kullanılmış ve bu sayede farklı bir yaklaşım ortaya konulmuştur. İndikatörlerin yapay zeka algoritmalarında değişken olarak kullanılmıştır ve değişkenler arası korelasyonları çıkaracak bir mimari oluşturulması ise bir diğer önemli noktadır. Oluşturulan mimarinin kendini sürekli besleyip güncellemesi ve iyileştirmesini sağlayacak entegrasyonlar yapılmıştır. Zaman serisi algoritmalarının kolektif bir şekilde çalışacakları bir yapı oluşturulmuş bu sayede yapay zeka algoritmalarının farklı bir alanda başarılı olabileceği doğrulanmıştır.

Çalışmada LSTM, CNN, RNN gibi yapay zeka algoritmaları ile finansal enstrüman verileri üzerine çalışmalar yapılmıştır. Bu çalışmaları yaparken bir LSTM katmanı ve bir RNN çıktı katmanından oluşan bir ağ oluşturulmuştur. İlave olarak LSTM ve CNN algoritmaları hibrit bir şekilde kullanılmış ve diğer yapay zeka algoritmalarından da yararlanılmıştır. Bu algoritmaların kullanılması ile birlikte tahmin sonuçlarını daha iyi hale getirmek için bir çözüm önerilmiştir. Bu çözüm algoritma sonuçlarının kolektif sınıflandırma boosting ve bagging yöntemleri uygulanmasıdır. Bu çözümü uygulamak sonuçlarını gözlemek ve diğer algoritma sonuçları ile yarıştırmak adına bir uygulama geliştirilmiştir. Geliştirilen uygulama ile önerilen çözüm ve algoritmalar farklı zaman aralıkları ve farklı eğitim verileri ile test edilmiştir.

Bu tez kapsamında geliştirilen uygulama üzerinde 9 farklı algoritma ile testler yapılmıştır. Bu algoritmalar içerisinde 2 tanesi önerilen ve bu çalışma kapsamında

geliştirilen algoritmalarıdır. Bunlar Boost Fonksiyonel Kümeleme ve Vote Fonksiyonel Kümeleme algoritmalarıdır. Bu algoritmalarındaki öneriler bu tez kapsamında yapılan çalışmalar sonucunda ortaya çıkmıştır. Bu iki algoritma diğer algoritmaların sonuçlarını kolektif bir şekilde bir araya getirerek çalıştığı için bu algoritmalara kolektif algoritmalar diyebiliriz.

	2019 USD/TRY Başarı Yüzde	2017 ons altın Başarı Yüzde	2003-2020 USD/TRY Başarı Yüzde
BoostFK	67	78	71
VoteFK	63	62	69
LSTM-RNN	65	76	70
MLP	62	61	68
ARIMA	34	45	55
Random Forest	66	63	66
Stacking	66	63	69
Voting	48	60	48
Bagging	60	63	66

Yukarıda görüldüğü gibi 3 farklı zaman aralığı ve 2 farklı finansal enstrüman üzerinde yapılan çalışmanın başarı yüzdeleri bulunmaktadır. USD/TRY kuru ons altına göre daha fazla oynaklığı olan bir kurdur. 2019 yılında USD/TRY kurundaki %15 kadarlık bir oynama olmuştur. Ons altın USD/TRY kuruna göre daha az oynama göstermektedir. 2007 yılında %10 civarında bir değişim göstermiştir. 2 farklı finansal enstrüman seçilerek hem daha fazla oynaklık gösteren bir finansal enstrüman üzerinde analiz hem de daha az oynayan bir kur üzerinde analiz yapılmak istenmiştir. 2003-2020 yılları arası USD/TRY kurunun seçilmesindeki amaç ise uzun vadeli yatırımlar açısından analizin ne yönde olduğunun görülmek istenmesidir.

	USD/TRY	Ons altın	EUR/USD	GARAN	BIST100	USD Endeks	EUR/TRY
BoostFK	68	79	76	75	70	74	69
VoteFK	67	77	74	72	68	71	67
LSTM-RNN	67	78	72	75	69	74	68
MLP	66	76	65	72	67	70	67
ARIMA	58	70	71	63	61	64	58
Random Forest	66	75	70	73	68	73	66
Stacking	64	74	71	70	64	67	63
Voting	60	72	73	70	66	69	65
Bagging	65	75	74	73	69	72	64

Yukarıda görüldüğü gibi 14-05-2018 ile 15-06-2018 tarihleri arası farklı finansal enstrümanların doğruluk yüzdeleri bulunmaktadır. Sonuçlara göre en başarılı tahmin sonuçları önerilen yöntem olan BoostFK algoritmasıdır. En başarılı tahmin sonuçları ise Ons altın finansal enstrümanında gözlemlenmiştir. Yine önerilen bir yöntem olan indikatör ve formüllerin değişken olarak kullanılması tahmin sonuçlarını genel olarak artırmıştır. Çıkan test sonuçlarına göre önerilen çözüm Boost FK algoritmasının ons altın testlerinde %7, 1 yıllık USD/TRY kurunda %3, 17 yıllık USD/TRY kurunda %4 daha başarılı olduğu gözlemlenmiştir. Ons altın test sonuçlarının USD/TRY kuruna göre tahmin edilebilir olduğu sonucuna ulaşılmıştır. Bu bulgular ile yapay zeka algoritmalarının performans ölçümü sonucuna göre boosting yapılması sonucunda daha başarılı hale getirilmiştir.

Yapılan çalışma sonucunda literatüre yapay zeka algoritmaları önerilmiş, aktivasyon fonksiyonlarının modifiye edilmesi ile aktivasyon fonksiyonları ile ilgili problemler çözülmüştür. İlave olarak indikatör, formül ve değişkenlerin yapay zeka algoritmalarında giriş değeri olarak kullanılması ile kolerasyonlar ortaya konulmuştur. Genel kapsayıcı bir mimari yapı ile bir uygulama geliştirilmiştir. Geliştirilen uygulama ile önerilerin doğruluk ve ispatları yapılmıştır. Sonuç olarak önerilen yöntemlerin uygulanabilir olduğu ve literatürdeki çalışmalarda bazı verilerde aynı sonuçlar verdiği bazı verilerde ise daha iyi sonuçlar verdiği gözlemlenmiştir.

Çalışmada önerilen volatilité aktivasyon fonksiyonu için 2 kısıt bulunmaktadır. Volatilité aktivasyon fonksiyonu giriş değeri olarak zaman periyodu almaktadır ve bu özelliği bir kısıt oluşturmaktadır. Bir diğer kısıt ise volatilité aktivasyon fonksiyonun sadece zaman serileri üzerinde başarılı sonuçlar veriyor olmasıdır.

KAYNAKÇA

- Abubakar, Adamu , Haruna Chiroma, ve Sameem Abdulkar. «Modified Neural Network Activation Function.» IEEE, 2014.
- Access, Microsoft. «Operate database applications.» 17-29. Melbourneby Watsonia Software Pty Ltd Watsonia Publishing, 2012.
- Agus Kartono, Marina Febriyanti. «Predicting foreign currency exchange rates using the numerical solution of the incompressible Navier–Stokes equations.» *Elsevier*, 2020: 1-2.
- Akşehirli, Mehmet Emin. «Küme Sayısını Otomatik Bulan bir Kümelenme Birleştirme Algoritması ve İkili Veride Komşuların Hızlı Bulunması için Yeni Budama Yönetimi.» 16. İstanbul: Bahçeşehir Üniversitesi, 2011.
- Aladag, Cagdas Hakan . «Advances in Time Series Forecasting.» 1-6. Department of Statistics, Hacettepe University,Türkiye, 2017.
- Alfonso, Lianes . «Why do we use the derivatives of activation functions in a neural network.» <https://medium.com/@alfonsollanes/why-do-we-use-the-derivatives-of-activation-functions-in-a-neural-network>, 2022 .
- Alqatawneh, Ibrahim , Khalid Rabeyee, ve Chao Zhang. «A Modified Activation Function for Deep Convolutional Neural Network and Its Application to Condition Monitoring.» 5-19. Part of the Mechanisms and Machine Science book series (Mechan. Machine Science,volume 105), 2021.
- Angus, Dempster, Daniel F. Schmidt, ve Webb Geoffrey . «HYDRA: Competing convolutional kernels for fast and accurate time series classification.» 18. 2022.
- Animas, Barrera, ve Ari Yair . «Rainfall prediction: A comparative analysis of modern machine learning algorithms for time-series forecasting.» 1-10. Elsevier , 2022.
- Anireh, Vincent Ike, ve Emmanuel Ndidi Osegi. «A Modified Activation Function with Improved Run-Times For Neural Networks.» Cornell University: Computer Science , Neural and Evolutionary Computing, 2016.

Aoki Toshiki , The Nippon Technical Analysts Association, Sayfa 5. 2018.

Arass, Mohammed El. «Data Lifecycle From Big Data to Smart Data.» 2-8. Institut National des Sciences Appliquées de Lyon, 2018.

Arporn, Bunchalit Eua, Shao-Lun Huang , ve Ercan Engin Kuruoğlu. «Enhancing Neural Network Based Hybrid Learning with Empirical Wavelet Transform for Time Series Forecasting.» IEEE 33rd International Conference on Tools with Artificial Intelligence (ICTAI), 2021.

Avishek, Pal. «Practical Time Series Analysis.» 19-29. Master Time Series Data Processing, Visualization, and Modeling using Python: Birmingham, 2017.

Babu, R. V, ve S. Suresh . «Human action recognition using a fast learning fully complex-valued classifier.» *Neurocomputing*, vol. 89,, Jul. 2012: pp. 202-212.

Baig, Yousuf. «Buil Web Application with Java.» Yazan Mirza Yousuf Ahmed Baig, 12. 2015.

Bakkal, Süreyya , ve Şule Korkmaz. «Yapılandırılmış finansal araçlar ve aracı kuruluşların kaldıraçlıhisse senedi piyasaları.» 7. Hiperlink Yayınları, Ekim 2011.

Banyal, Kumar Rahul Rohitash Kumar. «Data Life Cycle Management in Big Data Analytics.» 2. International Conference on Smart Sustainable Intelligent Computing and Applications under, 2020.

Basha, Shaik Johny, Tamminina Ammannamma, ve Kolla Viv. «Comparative Analysis of Time Series Forecasting Models to Predict Amount of Rainfall in Telangana.» 8th International Conference on Advanced Computing and Communication Systems (ICACCS), 2022.

Bates, Martin. «PIC Microcontrollers (Third Edition).» 2011.

Bengio, Y., ve A. Courville. «Deep learning. MIT press,» *I. Goodfellow*, 2016.

Billah, M.Raki . «Comparative Study on Data-Mining using Boosting Algorithms.» 1-3. Daffodil International University, 2020.

- Boran, Levent. «Veri Madenciliğinin Türk İşletmelerin Finansal Tablolarına Uygulanması ve Uygulama Örneği.» İstanbul: Marmara Üniveristesi, Doktora, 2012. 70.
- Box, George E. P., ve Gwilym M. Jenkins. «Time Series Analysis : Forecasting and Control.» 709. John Wiley & Sons, Incorporated, 2015.
- Boyarsky, Jeanne. «oracle certified professional java se 11 programmer i study guide.» 266. 2015.
- Breiman, L. «Arcing the edge, Technical Report Technical Report 486.» 1-9. Statistics Department, University of California, Berkeley., 1997.
- Breiman, Leo. «Bagging Predictors.» *Technical Report No. 421*. California: Department of Statistics University of California, 1994. 2-10.
- Bühlmann, Peter. «Bagging, Boosting and Ensemble Methods.» Zurich, Switzerland: Seminar fur Statistik, Haziran 2012. 3.
- Camuffo, D. *Theoretical Grounds for Humidity. In Microclimate for Cultural Heritage;* Amsterdam, The Netherlands: Elsevier: Chapter 2A; pp. 49–76. ISBN 9780444632982, 2014.
- Cao, C., ve F. Liu. «Deep learning and its applications in biomedicine. Genomics, Proteomics and Bioinformatics.» 2018: 16(1):17{32,.
- Carpenter , Marcus , Chunbo Luo , ve Xiao-Si Wang. «The effects of regularisation on RNN models for Covid-19 time series forecasting.» 20th International Conference on Ubiquitous Computing and Communications (IUCC/CIT/DSCI/SmartCNS), 2021.
- Charlton, Martin , ve Alberto Caimo. «Time Series Analysis.» 1-18. Espon m4d Multi-dimensional Data Design and Development, 2012.
- Chiang, Alpha C. « Fundamental Methods of Mathematical Economics, McGraw-Hill.» third edition, Sayfa 316,318., 1984.
- Choi, Jeong-Hwan, Yoon-Young Yang, ve Joon-Hyuk Chang. «Short-Utterance Embedding Enhancement Method Based on Time Series Forecasting Technique for Text-

- Independent Speaker Verification.» IEEE Automatic Speech Recognition and Understanding Workshop (ASRU), 2021 .
- Clevert, Djork Arne, ve Thomas Unterthiner. «Fast and accurate deep network learning by exponential linear units (elus).» *arXiv preprint arXiv:1511.07289*, 2015.
- Cui, N. «Applying Gradient Descent in Convolutional Neural Networks.» *Journal of Physics: Conference Series*, 1004, 2018.
- Çolpan, Ela. «Döviz kuru belirlenmesinde parasalcı yaklaşım Türkiye uygulaması.» 1. İzmir: Ege Üniversitesi, Yüksek Lisans Tezi, 2005.
- Data.tuik. <https://data.tuik.gov.tr/Kategori/GetKategori?p=enflasyon-ve-fiyat-106&dil=1>
ET. 01.01.2021
- Demidova, Liliya A, ve Artyom V. Gorchakov. «A Study of Biology-inspired Algorithms Applied to Long Short-Term Memory Network Training for Time Series Forecasting.» 3rd International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA), 2021.
- Deniz Kılınç, Emin Borandağ , Fatih Yücalar, Akın Özçift, Fatma Bozyiğit. «Yazılım Hata Kestiriminde Kolektif Sınıflandırma Modellerinin Etkisi.» 115. Manisa: Celal Bayer Üniversitesi, Hasan Ferdi Turgutlu Teknoloji Fakültesi, 2015. 115.
- Ding, Lei, Lin Xiao, Kaiqing Zhou, Yonghong Lan, ve Yongsheng Zhang. «A New RNN Model With a Modified Nonlinear Activation Function Applied to Complex-Valued Linear Equations.» *IEEE xplore*, 2018: volume 6.
- Dussen , Van der J., ve S. Roode . *Factors Controlling Rapid Stratocumulus Cloud Thinning*. J.Atmos. Sci. ,71, 655–664., 2014.
- Eduardo Santos de Oliveira, Marques , Tele Kaike Sa, Pekaslan Direnç , ve Eduardo Pestana de Aguiar. «Kernel Evolving Participatory Fuzzy Modeling for Time Series Forecasting: New Perspectives Based on Similarity Measures.» *IEEE Xplore*, 2022.
- Eric , Bauer, ve Ron Kohavi. «An Empirical Comparison of Voting Classification Algorithms: Bagging, Boosting, and Variants.» 1-38. Kluwer Academic Publishers, Boston. Manufactured in The Netherlands., 1998.

- Fanjiang, Yong-Yi, Yang Syu, ve Wei-Lun Huang. «Time Series QoS Forecasting for Web Services Using Multi-Predictor-Based Genetic Programming.» 1423 - 1435. IEEE Transactions on Services Computing Volume: 15, Issue: 3, 2022.
- Fathian , Mohammad , Yaser Hoseinpoor , ve Behrouz Mina. «Offering a hybrid approach of data mining to predict the customer churn based on bagging and boosting methods.» 1-2. ResearchGate, 2016.
- Fei Wang, Quan Wang , Feiping Nie , Zhongheng Li , Weizhong Yu , Fuji Ren. «A linear multivariate binary decision tree classifier based on K-means splitting.» *Pattern Recognition* içinde. Contents lists available at ScienceDirect, 2020.
- Fioka, Krzysztof , ve Waldemar Karwowskia. *Analysis of sentiment in tweets addressed to a single domain-specific Twitter account: Comparison of model performance and explainability of predictions*. Volume 186: Expert Systems with Applications, 2021.
- Freund, Y. , ve R. E. Schapire. «Experiments with a new boosting algorithm, in L. Saitta, ed.,» 148-156. Machine Learning: Proceedings of the Thirteenth National Conference, Morgan Kaufmann, 1996.
- Gamaliy, Volodymyr. «Exchange rates the influence of political and economic events. A fundamental analysis approach.» *Consulting Publishing Company Business Perspectives* içinde, 2-8. 2018.
- Garg, Ankita. «Master Thesis in Statistics and Data Mining.» *Forecasting exchange rates using machine learning models with time-varying volatility*. standford, Haziran 2012.
- Gavrilă,, Veronica, Lidia Băjenaru, ve Ciprian Dobre. «Modern Single Page Application Architecture:A Case Study.» 231. Romanya: National Institute for Research and Development in Informatics, 2019.
- Gehani, Narain, Annamalai, Melliya. «The Database Book : Principles & Practice Using the Oracle Database.» 1-5. United States of America: silicon-press, 2011.
- Giovanni , Elder, ve John F. Seni . «Ensemble Methods in Data Mining: Improving Accuracy Through Combining Predictions.» 1-29. Morgan publishers, Elder Research, Inc. and Santa Clara University, 2010.

- Gnecco, Nicola , Edossa Merga Terefe, ve Sebastian Enge. «Extremal Random Forests.» 1-4. Cornell University, 2022.
- Goodfellow, I., ve Y. Bengio. «Deep Learning. MIT Press.» Düzenleyen: <http://www.deeplearningbook.org>. 2016.
- Guangcan , Liu. «Time Series Forecasting via Learning Convolutionally Low-Rank Models.» 3362 - 3380. IEEE Transactions on Information Theory Volume: 68, 2022.
- Gupta , Rahul , Anıl Kumar Yadav , SK Jha , ve Pawan Ku. «Time Series Forecasting of Solar Power Generation Using Facebook Prophet and XG Boost.» 1-5. 2022 IEEE Delhi Bölüm Konferansı, 2022.
- Gutierrez, Alfonso , ve Ivonne Cruz. *Algorithm to Predict the Rainfall Starting Point as a Function of Atmospheric Pressure, Humidity, and Dewpoint*. Climate, 2019.
- Gümüş, Umut Tolga , ve Pailer Murat Kutay «The Effect of Students Finance Learning Situation on the Level of Financial Literacy: A Case Of Nazilli.» *International Journal of Society Researches* ISSN:2528-9527 E-ISSN : 2528-9535 içinde, 12-53. June 2019.
- Hammori, Abdülaziz I. . «Responsive Web Design Techniques.» 18-27. International Journal of Computer Applications, 2016.
- Han, Jiawei. «Data Mining Concepts and Techniques.» *University of Illinois at Urbana–Champaign* . MA 02451, USA: Simon Fraser University, 2012.
- Harvey, John T. . «Modeling Interest Rate Parity: A System Dynamics Approach.» *Journal of economic issues* içinde, 1-8. Vol. XL No. 2, Haziran 2006.
- Hayou , Soufiane , Arnaud Doucet , ve Judith Rousseau. «On the Impact of the Activation Function on Deep Neural Networks Training.» arXiv:1902.06853v2, 2019.
- He, Kaiming , ve Xiangyu Zhang. «Delving deep into rectifiers: Surpassing humanlevel performance on imagenet classification.» *In Proceedings of the IEEE international conference on computer vision*, pp. 1026–1034, 2015.

- Hegui , Zhu, Zhang Jiapeng , Hao Wang Cui, ve Kai Tan. «TCRAN: Multivariate time series classification using residual channel attention networks with time correction.» 114. Elsevier ,College of Sciences, Northeastern University, Shenyang, 110819, China, 2022.
- Hendrycks, Dan , ve Kevin Gimpel. «GAUSSIAN ERROR LINEAR UNITS (GELUS).» *University of California, Berkeley*, 2020.
- Fiki Hidayat , ve T. Mhd. Sofyan Astsauri. «Applied random forest for parameter sensitivity of low salinity water Injection (LSWI) implementation on carbonate reservoir.» 1-2. Alexandria University: Alexandria Engineering Journal, 2021.
- Hlavats, Ian. «JSF 1.2 Components : Develop Advanced Ajax-enabled JSF Applications.» 12. 2009.
- Hou , T, ve F. Kong . *Impact of 3DVAR Data Assimilation on the Prediction of Heavy Rainfall over Southern China. Adv. Meteorol.* 129642, 2013.
- Hu , Zheng . «Handling Vanishing Gradient Problem Using Artificial Derivative.» IEEE Access PP(99):1-1: Nanchang Hangkong University, 2021.
- Hua, Zhi, ve Zhou. «Ensemble Methods Foundations and Algorithms.» *Taylor & Francis Group* içinde, 23. 2012.
- İnan, Onur. «Veri Madenciliği Uygulamaları için Veri İndirgeme Algoritmalarının geliştirilmesi ve Resim Madenciliğine Uygulaması.» 19. Konya: Selçuk Üniversitesi, 2015.
- Jacoby , Dror , Jonatan Ostrometzky , ve Hagit Messer. «Adaptive Fuzzy-Based Models for Attenuation Time Series Forecasting.» IEEE International Conference on Microwaves, Antennas, Communications and Electronic Systems (COMCAS), 2021 .
- Jamali, Ibrahim. «Out-of-sample exchange rate predictability in emerging markets: Fundamentals versus technical analysis.» *Journal of International Financial Markets, Institutions & Money* içinde, 4-8. American University of Beirut, Lebanon, 2019.
- Jastrzebska, Agnieszka . «Time series classification through visual pattern recognition.» 134-142. Journal of King Saud University - Computer and Information Sciences, 2022.

- Jiang, Mingxue, Youlong Yang , ve Haiquan Qiu. «Fuzzy entropy and fuzzy support-based boosting random forests for imbalanced data.» 4126–4143. Springer, 2022.
- Jiawei Han, Micheline Kamber, Jian Pei. «Data Mining Concepts an Techniques.» Yazan Jiawei Han, 379. Simon Fraser University: University of Illinois at Urbana, 2012.
- Maheu John M., Thomas H. McCurdy & Yong Song. «Components of Bull and Bear Markets: Bull Corrections and Bear Rallies.» *Journal of Business & Economic Statistics* içinde. 2012.
- Jonna, Sudheer, Benedetti, Benoit, Pillai, Ramkumar. «PrimeFaces Blueprints.» 9. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB, UK., 2014.
- Kaur, Sharma A. and. «A research review on comparative analysis of data mining tools, techniques and parameters.» *International Journal of Advanced Research in Computer Science*, vol. 8, no. 7 içinde. 2017.
- Kaynar, Oğuz , ve Serkan Taştan. «Zaman Serileri Tahmininde Arima-mlpmelez modeli.» *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, Cilt: 23, Sayı: 3, içinde, 141. 2009.
- Kellermann, Christoph , Eric Neumann, ve Jörn Ostermann. «A New Preprocessing Approach to Reduce Computational Complexity for Time Series Forecasting with Neuronal Networks: Temporal Resolution Warping.» International Symposium on Computer Science and Intelligent Controls (ISCSIC), 2021 .
- Khalil , Namir, Hassan Labriji, Ben Lahmar, ve El Habib. «Decision Support Tool for Dynamic Inventory Management using Machine Learning, Time Series and Combinatorial Optimization.» 423-428. elsevier, Procedia Computer Science, 2022.
- Khare, Tanuj. «Apache Tomcat 7 Essentials.» 20. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham, 2012.
- Kim, Dong whan , ve Kyu HoKang. «Conditional value-at-risk forecasts of an optimal foreign currency portfolio.» 838-861. International Journal of Forecasting, Elsevier, 2021.

- Kočenda, Evžen , ve Černý Alexandr . «Elements of Time Series Econometrics: An Applied Approach.» 2-18. Karolinum Press is the publishing department of Charles University in Prague, 2015.
- Krugman, Paul , ve R. Obstfeld. «International Economics: Theory and Policy.» 336. Boston: Maurice 8th Ed. : Pearson Education., 2009.
- Kumar, Naveen B. «The Use of Technical and Fundamental Analysis in the Stock Market in Emerging and Developed Economies.» Yazan Sanjay Mohapatra, 20-21. Indian School of Business, Hyderabad, India, 2020.
- Kunjumohamed, Shameer, Sattari, Hamidreza. «Spring Essentials.» 12. Livery Place 35 Livery Street Birmingham B3 2PB, UK., 2016.
- LeCun, Y., ve Y. Bengio. «Deep learning. nature, 521(7553):436{444, .» 2015.
- Liao, L., Y. Zeng, H. Zhang, ve Y. Liang. «Data Mining: A Novel Strategy for Production Forecast in Tight Hydrocarbon Resource in Canada by Random Forest Analysis, Int. Petrol. Technol. Conf.» 1-13. <https://doi.org/10.2523/IPTC-20344-MS>., 2020.
- Liao, Yanping , ve Chao Liang. «A Temperature Time Series Forecasting Model Based on DeepAR.» 7th International Conference on Computer and Communications (ICCC), 2021 .
- Lifei Yao, Ruimin Mab, Hua Wang. «Baidu index-based forecast of daily tourist arrivalsthrough rescaled range analysis, support vectorregression, and autoregressive integrated movingaverage.» *School of Geography and Tourism, Guangdong University of Finance and Economics, Guangzhou 510320, China içinde*. 2020.
- Lin , Yang, Irena Koprinska , ve Meşud Rana. «SSDNet: State Space Decomposition Neural Network for Time Series Forecasting.» IEEE International Conference on Data Mining (ICDM), 2021.
- Liu, Minhao , Ailing Zeng, ve Zhijian Xu. «Time Series is a Special Sequence:Forecasting with Sample Convolution and Interaction.» The Chinese University of Hong Kong, 2021.

- Liu, Shizhan , Hang Yu, Cong Liao, ve Jianguo Li. «Pyraformer: Low-Complexity Pyramidal Attention for Long-Range Time Series Modeling and Forecasting.» Published as a conference paper at ICLR, 2022.
- Leo Xiao «A finite-time convergent neural dynamics for online solution of time-varying linear complex matrix equation.» *Neurocomputing*, 2015: vol. 167, pp. 254-259,.
- Maas, Andrew L, ve Awni Hannun. «Rectifier nonlinearities improve neural network acoustic models.» *In International Conference on Machine Learning volume 30*, 2013.
- Malhan, Priyanka , ve Monika Mittal. «Comparison of Decomposition-based Machine Learning Models for Multi-step Time Series Forecasting of Wind Power Generation.» IEEE 2nd International Conference On Electrical Power and Energy Systems, 2021.
- Markova, M. «Foreign exchange rate forecasting by artificial neural networks.» *AIP Conf. Proc.* 2164, 2019: 5-10.
- Martin, Bates. «PIC Microcontrollers Third Edition.» 225 Wyman Street, Waltham, MA 02451, USA içinde, yazan Newnes is an imprint of Elsevier, 1-25. 2011.
- Math , centre. «Introduction to functions.» mc-TY-introfns-2009-1: <https://www.mathcentre.ac.uk/>, ET: 2009.
- Maya, Mario , Wen Yu, ve Xiaou Li. «Time series forecasting with missing data using neural network and meta-transfer learning.» IEEE Symposium Series on Computational Intelligence, 2021 .
- Melvin, Michael, ve S. C. Norrbin. «International Money and Finance.» 115. 8th Ed., Oxford: Elsevier., 2013.
- Mercioni, Marina Adriana, ve Alexandru Tiron. «Dynamic Modification of Activation Function using the Backpropagation Algorithm in the Artificial Neural Networks.» *Vol. 10, No. 4*, içinde, 1-7. International Journal of Advanced Computer Science and Applications,, 2019.
- MGM. . <https://www.mgm.gov.tr/>. ET. 01.01.2021

- Mosley, Mark. «The Dama Guide to The Data Management Body of Knowlege.» Yazan author, 42. USA, Brandley Beach: Technics Publications, LLC, 2009.
- Mouine , Esma, Yan Liu , Jincheng Sun , ve Mathieu Nay. «The Analysis of Time Series Forecasting on Resource Provision of Cloud-based Game Servers.» 2021 IEEE International Conference on Big Data , 2021.
- N.D. Vanli, M.O. Sayin , N.M. Mohaghegh , H. Ozkan , S.S. Kozat. «Nonlinear regression via incremental decision trees, Pattern Recognit. 86.» 1-13. 2019.
- Nagpure, A.R. «Prediction of multi-currency exchange rates using deep learning.» *International Journal of Innovative Technology and Exploring Engineering* Volume 8, Issue 6 içinde, 316-322. Department of Computer Science and Engineering, Ramdeobaba College of Engineering and Management, Nagpur, India, April 2019.
- Nezhad, Zahra Bokaee , ve Mohammad Ali Deihimi. *Twitter sentiment analysis from Iran about COVID 19 vaccine*. Diabetes & Metabolic Syndrome: Clinical Research & Reviews, 2022-01-01, Volume 16, Issue 1, Article 102367, 2021.
- Niu , Guangxing, Xuan Wang , ve Michael Golda . «An optimized adaptive PReLU-DBN for rolling element bearing fault diagnosis.» 26-34. Neurocomputing, Elsevier, 2021.
- Olah, Christopher. «Understanding LSTM Networks.» <http://colah.github.io/posts/2015-08-Understanding-LSTMs/> içinde, 4. 2015.
- Örüş, Erhan. «Fisher etkisi: Türkiye üzerine bir uygulama.» 299. Kastamonu Üniversitesi: İktisadi ve İdari Bilimler Fakültesi Dergisi, 2016.
- Özdemir , Abdulkadir , Uğur Yavuz, ve Abdulhafidh Fares . «Performance evaluation of different classification techniques using different datasets.» *International Journal of Electrical and Computer Engineering*, 2019.
- Palma, Wilfredo. «Time Series Analysis.» 20-91. John Wiley & Sons, Incorporated, 2016.
- Pandey, Trilok Nath. «A novel committee machine and reviews of neural network and statistical models for currency exchange rate prediction: An experimental analysis.» *Science Direct*, 2017: 1-5.

- Panneerselvam, Lakshmi . «Activation Functions and their Derivatives – A Quick & Complete Guide.» Sayfa 5, Data Science Blogathon., 2022.
- Parisi, Luca , ve Daniel Neagu. «QReLU and m-QReLU: Two novel quantum activation functions to aid medical diagnostics.» *1Faculty of Engineering & Informatics, University of Bradford, Richmond Road, Bradford, BD7 1DP, United Kingdom*, 2020.
- Pearson , Karl . «Notes on regression and inheritance in the case of two parents.» 240–242. *Proceedings of the Royal Society of London*. 58: . Bibcode:1895RSPS...58..240P, 1895.
- Peiyuan , Teng, ve Min Xu. «Random Matrix Time Series.» 1-15. USA: The Ohio State University, 191 West Woodruff Ave, Columbus, 2022.
- Pereira, S., ve A. Pinto. «D.M.L.D. Rasteiro , C. Silva , Hierarchical brain tumour segmentation using extremely randomized trees, *Pattern Recognit.* 82.» 105-117. 2018.
- Pilgrim, Peter. «Digital Java EE 7 Web Application Development.» 18. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB, UK., 2015.
- Point, Tutorials. «Hibernate Java Persistence Tutorial.» 12. Tutorials Point (I) Pvt. Ltd, 2015.
- Praekhaow, Puchong. «Determination of Trading Points using the Moving Average Methods.» *Department of Mathematics, Faculty of Science, King Mongkut's University of Technology Thonburi, Bangkok içinde*, 2-6. 2010.
- Prokop, Jörg, ve Benno Kammann. «The effect of the European Markets in Financial Instruments Directive on affiliated analysts' earnings forecast optimism.» 75-86. *Journal of Economics and Business: Elsevier*, 2018.
- Qi, Ling Khushi, Matloob Poon, Josiah. «Event-Driven LSTM For Forex Price Prediction.» 16-18. *Quantitative Finance - Statistical Finance: IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE)*, Gold Coast, QLD, Australia,, 2020.
- Radcliffe, Mary. «Math 127: Functions.» *Department of Mathematics, University of California, San Diego*, 2020.

- Radoslaw, Sobko, ve Klonowska-Matynia Maria. «The Relationship between the Purchasing Managers' Index (PMI) and Economic Growth: The Case for Poland.» 22 . European Research Studies. Vol. 24 Issue SI 1, p198, 2021.
- Raissi, M. « Deep hidden physics models Deep learning of nonlinear partial different.» 19(1):932{955, , 2018.
- Ramachandran, Prajit , ve Barret Zoph. «SWISH A SELF-GATED ACTIVATION FUNCTION.» *Google Brain arXiv:1710.05941v1*, ET. 01.01.2021.
- Reaz Chowdhurya, M. ArifurRahmanbM. ,SohelRahmanc, M.R.C.Mahdy. «An approach to predict and forecast the price of constituents and index of cryptocurrency using machine learning.» *Physica A: Statistical Mechanics and its Applications Volume 551* , 124569 içinde. 2020.
- Romps, D. Clausius. *Clapeyron Scaling of CAPE from Analytical Solutions to RCE.* . J. Atmos. Sci.,73,3719–3737., 2016.
- Benferhat S., Boudjelida A., Tabia K., Drias H.. «An intrusion detection and alert correlation approach based on revising probabilistic classifiers using expert knowledge, Appl. Intell. 38 (4).» 520-540. 2013.
- Saad, Noha Gamal El-Din, Samy Ghoniemy, ve Hossam Fahe. «An Evaluation of Time Series-Based Modeling and Forecasting of Infectious Diseases Progression using Statistical Versus Compartmental Methods.» 5th International Conference on Computing and Informatics IEEE, 2022 .
- Safiullin, M.R., Elshin, L.A. Author, Gilmanov, A.M. «Prospects of LSTM Neural Networks Use in Supply Chain Management When Developing a Crypto Currency Rate Forecast.» 815-819. Volume 8, Issue 6,: Kazan Federal University, Russian Federation State Budgetary Institution 'Centre of Perspective Economic Researches', Academy of Sciences, Republic of Tatarstan, Russian Federation, 2019.
- Salman, Ahmed, UIHassan Saeed, ve Naif RadiAljohan. «FLF-LSTM: A novel prediction system using Forex Loss Function.» *Applied Soft Computing Volume 97, Part B*, 106780 içinde, 40- 89. December 2020.

- Salter, David, Dantas, Rhawi. «NetBeans IDE 8 Cookbook.» 7. Packt Publishing Ltd.Livery Place35 Livery StreetBirmingham, 2014.
- Samal, K. Krishna Rani , ve Korra Sathya Babu. «Time Series Forecasting of Air Pollution using Deep Neural Network with Multi-output Learning.» IEEE 18th India Council International Conference, 2021 .
- Sarikaa , S., S. Niranjana , ve Sri Vishnu Deepika . «Time Series Forecasting of Cloud Resource Usage.» IEEE 6th International Conference on Computing, Communication and Automation (ICCCA), 2021 .
- Schmidhuber, Jurgen, ve Sepp Hochreiter . «Lstm can solve hard long time lag problems. Advances in neural information processing system.» 473–479. 1996.
- Schmidhuber, S., ve J. Hochreiter . «“Long short-term memory,” Neural Computation.» Technische Universität München: vol. 9, no. 8, pp. 1735–1780, Dec. 1997., 2019.
- Schober, Patrick , ve Boer Christa . «Correlation Coefficients: Appropriate Use and Interpretation.» 1-3. Amsterdam: Amsterdam University Medical Center, 2018.
- Seonwoo, M, ve L. Byunghan. «Deep learning in bioinformatics. Briefing in bioinformatics, 18(5):851 {869.» 2017.
- Shabbir, Ahmed, ve Kopsaftopoulos Fotis. «Time-varying Identification of Guided Wave Propagation under Varying Temperature via Non-Stationary Time Series Models.» 9. Electrical Engineering and Systems Science - Signal Processing, 2022.
- Shah, Sanjay. «Maven for Eclipse.» 28. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB, UK., 2014.
- Shan, Chuan Hui, ve Xi-Rong Guo. «Deep Leaky Single-peaked Triangle Neural Networks.» *International Journal of Control, Automation and Systems* içinde, 1-5. springer, 2019.
- Sikora, Zbigniew M. «Java Practical Guide for Programmers.» Yazan The Morgan Kaufmann Practical Guides Series, 2-10. San Francisco, 2003.
- Silahtaroglu, Gökhan. «Veri Madenciliği Kavram ve Algoritmaları.» 1. İstanbul: Papatya Yayıncılık Eğitim, 2013.

Siriwardena, Prabath. «Maven essential.» 15. Packt Publishing Ltd., 2015.

Sridevi, R. , Srimathi, S. «Populating indian GST details into java apache derby database powered by glassfish server.» 409-421. Department of Computer Science and Engineering, K Ramakrishnan College of Engineering Samayapuram, Trichy, 621112, India, 2020.

Suparta , W., ve K. Alhasa . *Estimation water vapor content using the mixing ratio method and validated with the ANFIS PWV model..* J. Phys. Conf. Ser,852, 012041., 2017.

Susmel, Rauli. «International Financial Management.» Bauer College of Business Univ. of Houston, 2016.

Szandała, Tomasz . «Review and Comparison of Commonly Used Activation Functions for Deep Neural Networks.» Wroclaw-University-of-Science-and-Technology, 2020.

Şahin, Burcu Yılmaz. «Türkiye için Denge Döviz Kuru Tahmini.» *Giresun Üniversitesi*. Giresun: Giresun Üniversitesi, Haziran 2010. 14.

Tanaka, Katsuto. «Time Series Analysis : Nonstationary and Noninvertible Distribution Theory.» 1-50. John Wiley & Sons, Incorporated, 2017.

TCMB EVDS. 2020-02. <https://evds2.tcmb.gov.tr/index.php?> ET. 03.03.2021

TCMB. *Türkiye Cumhuriyet Merkez Bankası..*
https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket/#collapse_2. ET. 03.03.2021

Tekin, Bahri Fatih. «Döviz kuru tahmininde yapay sinir ağları ve çoklu doğrusal regresyon analizi performans karşılaştırması.» 25. Sivas: Sivas Cumhuriyet üniversitesi, Yüksek Lisans Tezi, 2019.

Telek, Cebail. «Uluslararası fisher etkisi hipotezi kapsamında nominal faiz oranları ve döviz kurları arasındaki ilişkinin incelenmesi: türkiye örneği.» 1. Malatya, 2018.

Thakuri, Madhuri , ve Dheeraj Vaidya. «Volatility Formula.» *wallstreetmojo*, 2022: <https://www.wallstreetmojo.com/volatility-formula/> ET. 01.05.2022

- ThuBui, Lam , Truong Vua Van, ve Thi Thu Huong Dinh. «A novel evolutionary multi-objective ensemble learning approach for forecasting currency exchange rates.» *Data & Knowledge Engineering Volume 114* içinde, 40-66. 2018.
- Tolon, Metehan, ve Nuray Güneri Tosunoğlu. «TÜKETİCİ TATMİNİ VERİLERİNİN ANALİZİ: YAPAY SİNİR AĞLARI ve REGRESYON ANALİZİ Karşılaştırması.» *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi 10 / 2*, 2008: 7.
- Topçu, Ahmet. «Bilgisayar Destekli Numerik Analiz.» Eskişehir Üniversitesi, 2014.
- Tutal, Erol. «Veri madenciliği teknikleri ile döviz kuru tahmini.» Kocaeli: Gebze Yüksek Teknoloji Enstitüsü, 2011. 20-21.
- Uğur, Ahmet. «Hisse Senedi Getirilerinin Panel Veri Analizi ile Tahmini: İstanbul Menkul Kıymetler Borsasında Bir İnceleme.» Malatya: İnönü Üniversitesi, Temmuz 2009.
- Yung-Shun Tsai, Chun-Ping ChangShyh-Weir Tzang. «The Impact of Golden Cross and Death Cross Frequency on Stock Returns in Pre- and Post-financial Crisis.» 1. Department of FinanceAsia UniversityTaichungTaiwan, 2017.
- Vinesha, Peiris. «Rational activation functions in neural networks with uniform based loss functions and its application in classification.» *Mathematics - Optimization and Control*, 2021.
- Wang , J., ve D. Gaffen . *Late-Twentieth-Century Climatology and Trends of Surface Humidity and Temperature in China. J. Clim. , 14*. China: 2833–2845, 2001.
- William , Clive , ve John Granger. «Spectral Analysis of Economic Time Series.» 1-80. Prenceton University Press, 2015.
- Wu , Haixu , Jiehui Xu , Jianmin Wang , ve Mingsheng Lo. «Autoformer: Decomposition Transformers with Auto-Correlation for Long-Term Series Forecasting.» <https://paperswithcode.com/paper/autoformer-decomposition-transformers-with>. 2021.
- Wu, Haixu , Jiehui Xu, Jianmin Wang, ve Mingsheng Long. «Autoformer: Decomposition Transformers with Auto-Correlation for Long-Term Series Forecasting.» School of Software, BNRist, Tsinghua University, China, 2022.

- Xiao, L. «A nonlinearly activated neural dynamics and its finite-time solution to time-varying nonlinear equation.» *Neurocomputing*, 2016: vol. 173, pp. 1983-1988.
- Xiao, L., ve B. Liao. «A finite-time convergent dynamic system for solving online simultaneous linear equations.» *Int. J. Comput. Math*, 2017: vol. 94, pp. 1778-1786.
- Yanga, Mo , ve Wang Jing. «Adaptability of Financial Time Series Prediction Based on BiLSTM.» 18-25. *Procedia Computer Science: Elsevier*, 2022.
- YAO, Jingtao & POH, Hean- Lea & JASIC, Teo. «Foreign Exchange Rates Forecasting With Neural Networks.» National University of Singapore: Department of Information Systems and Computer Science, 1996.
- Yaviloğlu, C. ve Delice, G. « Tezgah üstü Türev Piyasalar: Bir Değerlendirme. Maliye Dergisi.» (151), 53-84. içinde. 2006.
- Yıldıran, Cenk Ufuk. «İşletmelerde döviz kuru tahmini ve bir uygulama.» *Kocaeli Üniversitesi*. Kocaeli, 2017.
- Yıldız, Ömür. «Döviz Kuru Tahmininde Yapay Sinir Ağları Kullanımı.» Eskişehir: Osman Gazi Üniversitesi, Temmuz 2006. 5-10.
- Yılmaz, Atıncı. *Yapay Zeka*. İstanbul: Kodlab 5.baskı, sayfa:88, 2019.
- Yılmaz, Cem. «Teknik Analiz Göstergelerinin Performans Analizi Borsa İstanbul Üzerine Uygulama.» *Yüksek Lisans Tezi*. İzmir: Dokuz Eylül Üniversitesi, 2016.
- Young, Joe. *Predict next-day rain in Australia*. <https://www.kaggle.com/jsphyg/weather-dataset-rattle-package>, 2021.
- Yua, Manzhu , Xu Fangcao , ve Weiming Hu. «Using Long Short-Term Memory (LSTM) and Internet of Things for localized surface temperature forecasting in an urban environment.» *Department of Geography and Institute for Computational and Data Science, The Pennsylvania State University* içinde, 6. University Park, PA, USA, 2020.
- Zeng, Ailing , Muxi Chen , Lei Zhang , ve Qiang Xu. «Are Transformers Effective for Time Series Forecasting.» *The Chinese University of Hong Kong*, 2022.

- Zeytinoğlu, ve Filiz Çakir. «Bayesyen İstatistik.» 77. İstanbul: Yalın Yayıncılık, 2015.
- Zhang, Y., ve L. Xiao. «Zeroing Dynamics Gradient Dynamics and Newton Iterations.» *Boca Raton, FL, USA: CRC Press*, 2016.
- Zheng, Zijian, ve Pan Lu. «Commercial truck crash injury severity analysis using gradient boosting data mining model.» 1-8. *Journal of Safety Research* 65, 2018.
- Zhou, Haoyi , Shanghang Zhang, Jieqi Peng, ve Shuai Zha. «Informer: Beyond efficient transformer for long sequence time-series forecasting.» In *AAAI*, 2021.
- Zhou, Zhi-Hua. «Ensemble Methods Foundations and Algorithms.» Taylor & Francis Group, 2012. 23.
- Znaczko, Timothy M. «Forecasting Foreign Exchange Rates.» 14. State University of New York College at Buffalo - Buffalo State College, 2013.
- Zúñiga, Gerardo , ve Gonzalo Acuña. «Probabilistic Multistep Time Series Forecasting Using Conditional Generative Adversarial Networks.» *IEEE Latin American Conference on Computational Intelligence (LA-CCI)*, 2021.

EKLER

EK 1: Uygulama pom.xml

```
<?xml version="1.0" encoding="UTF-8"?>
<project xmlns="http://maven.apache.org/POM/4.0.0"
xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
xsi:schemaLocation="http://maven.apache.org/POM/4.0.0
http://maven.apache.org/xsd/maven-4.0.0.xsd">
  <modelVersion>4.0.0</modelVersion>
  <groupId>tr.com.kayimsoft</groupId>
  <artifactId>MavenWebProject</artifactId>
  <version>0.0.1-SNAPSHOT</version>
  <packaging>war</packaging>
  <name>MavenWebProject</name>
  <properties>
    <project.build.sourceEncoding>UTF-8</project.build.sourceEncoding>
    <maven.compiler.source>1.7</maven.compiler.source>
    <maven.compiler.target>1.7</maven.compiler.target>
    <hibernate.version>4.3.5.Final</hibernate.version>
    <spring-framework.version>4.0.3.RELEASE</spring-framework.version>
  </properties>
  <build>
    <plugins>
      <plugin>
        <groupId>org.apache.maven.plugins</groupId>
        <artifactId>maven-compiler-plugin</artifactId>
        <configuration>
          <source>1.6</source>
          <target>1.6</target>
        </configuration>
      </plugin>
    </plugins>
  </build>
  <url>https://maven.apache.org</url>
  <repositories>
    <repository>
      <id>prime-repo</id>
      <name>PrimeFaces Maven Repository</name>
      <url>https://repository.primefaces.org</url>
      <layout>default</layout>
    </repository>
    <repository>
      <id>ebi-repo</id>
      <name>Weka Maven Repository</name>
      <url> https://www.ebi.ac.uk/intact/maven/nexus/content/repositories/ebi-
repo/</url>
    </repository>
  </repositories>
  <dependencies>
```

```

<dependency>
  <groupId>org.apache.derby</groupId>
  <artifactId>derby</artifactId>
  <version>10.13.1.1</version>
</dependency>
<dependency>
  <groupId>org.apache.derby</groupId>
  <artifactId>derbyclient</artifactId>
  <version>10.13.1.1</version>
</dependency>
<dependency>
  <groupId>junit</groupId>
  <artifactId>junit</artifactId>
  <version>4.12</version>
  <scope>test</scope>
</dependency>
<dependency>
  <groupId>javax.servlet</groupId>
  <artifactId>servlet-api</artifactId>
  <version>2.5</version>
  <scope>provided</scope>
</dependency>
<!-- Faces Implementation -->
<dependency>
  <groupId>com.sun.faces</groupId>
  <artifactId>jsf-impl</artifactId>
  <version>2.2.4</version>
</dependency>
<!-- Faces Library -->
<dependency>
  <groupId>com.sun.faces</groupId>
  <artifactId>jsf-api</artifactId>
  <version>2.2.4</version>
</dependency>
<!-- Primefaces Version 5 -->
<dependency>
  <groupId>org.primefaces</groupId>
  <artifactId>primefaces</artifactId>
  <version>5.0</version>
</dependency>
<!-- JSP Library -->
<dependency>
  <groupId>javax.servlet.jsp</groupId>
  <artifactId>javax.servlet.jsp-api</artifactId>
  <version>2.3.1</version>
</dependency>
<!-- JSTL Library -->
<dependency>
  <groupId>javax.servlet</groupId>
  <artifactId>jstl</artifactId>

```

```

    <version>1.1.2</version>
</dependency>
<!-- Primefaces Theme Library -->
<dependency>
    <groupId>org.primefaces.themes</groupId>
    <artifactId>blitzer</artifactId>
    <version>1.0.10</version>
</dependency>
<!-- Hibernate -->
<dependency>
    <groupId>org.hibernate</groupId>
    <artifactId>hibernate-entitymanager</artifactId>
    <version>${hibernate.version}</version>
</dependency>
<dependency>
    <groupId>org.hibernate</groupId>
    <artifactId>hibernate-core</artifactId>
    <version>${hibernate.version}</version>
</dependency>
<!-- Spring and Transactions -->
<dependency>
    <groupId>org.springframework</groupId>
    <artifactId>spring-context</artifactId>
    <version>${spring-framework.version}</version>
</dependency>
<dependency>
    <groupId>org.springframework</groupId>
    <artifactId>spring-tx</artifactId>
    <version>${spring-framework.version}</version>
</dependency>
<!-- Spring ORM support -->
<dependency>
    <groupId>org.springframework</groupId>
    <artifactId>spring-orm</artifactId>
    <version>${spring-framework.version}</version>
</dependency>
<!-- Spring Web -->
<dependency>
    <groupId>org.springframework</groupId>
    <artifactId>spring-webmvc</artifactId>
    <version>${spring-framework.version}</version>
</dependency>
<!-- Required By Hibernate -->
<dependency>
    <groupId>commons-dbcp</groupId>
    <artifactId>commons-dbcp</artifactId>
    <version>1.4</version>
</dependency>
<dependency>
    <groupId>javassist</groupId>

```

```

        <artifactId>javassist</artifactId>
        <version>3.12.1.GA</version>
    </dependency>
    <dependency>
        <groupId>org.apache.poi</groupId>
        <artifactId>poi</artifactId>
        <version>4.1.1</version>
    </dependency>
    <dependency>
        <groupId>org.apache.poi</groupId>
        <artifactId>poi-ooxml</artifactId>
        <version>4.1.1</version>
    </dependency>
    <dependency>
        <groupId>nz.ac.waikato.cms.weka</groupId>
        <artifactId>weka-stable</artifactId>
        <version>3.6.6</version>
    </dependency>
    <dependency>
        <groupId>tw.edu.ntu.csie</groupId>
        <artifactId>libsvm</artifactId>
        <version>3.24</version>
    </dependency>
    <!--
https://mvnrepository.com/artifact/nz.ac.waikato.cms.weka/timeseriesForecasting
    <dependency>
        <groupId>nz.ac.waikato.cms.weka</groupId>
        <artifactId>timeseriesForecasting</artifactId>
        <version>1.1.27</version>
    </dependency>-->
</dependencies>
</project>

```