

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**UZUN KISA SÜRELİ BELLEK İLE
ALTIN FİYATI TAHMİNİ**

YÜKSEK LİSANS TEZİ

Sina BİRECİK

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Programı

TEMMUZ 2022

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**UZUN KISA SÜRELİ BELLEK İLE
ALTIN FİYATI TAHMİNİ**

YÜKSEK LİSANS TEZİ

**Sina BİRECİK
(518181032)**

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Programı

Tez Danışmanı: Doç. Dr. Gülay ÖKE GÜNEL

TEMMUZ 2022

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 518181032 numaralı Yüksek Lisans Öğrencisi Sina BİRECİK, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “UZUN KISA SÜRELİ BELLEK İLE ALTIN FİYATI TAHMİNİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Gülay ÖKE GÜNEL**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Volkan SEZER**
İstanbul Teknik Üniversitesi

Dr. Öğr. Üyesi Figen ÖZEN
Haliç Üniversitesi

Teslim Tarihi : 5 Ağustos 2022
Savunma Tarihi : 6 Temmuz 2022





Aileme ve eşime,



ÖNSÖZ

Günümüzün başlıca yatırım araçlarından biri olan altının gelecekteki tahminini sağlayabilen ve bize tahmini veriler sunabilen projeme 2021 yılında başladım. İstanbul Teknik Üniversitesi Makine Mühendisliği lisans öğrenimimde yapmış olduğum kişisel projeler doğrultusunda yazılıma yöneldim. Mekatronik Mühendisliği yüksek lisansına giriş yaptım. Yüksek lisans öğrenimimde derin öğrenme ile tanıştım.

Araştırma sürecinde bana önerileriyle ışık tutan, tez danışmanım Sayın Doç. Dr. Gülay Öke GÜNEL'e ve Sayın Ekonomist Hakan TOPKURULU'ya, ayrıca araştırma sürecindeki yardımlarıyla maddi ve manevi desteğini esirgemeyen Pınar ERTAN BİRECİK, Deniz ERTAN ve Şerif İNANIR'a teşekkürlerimi sunarım. Projem ve eğitimim sırasında gösterdikleri sabır, maddi ve manevi destek nedeniyle bu çalışma aileme, eşime ve yardımcı olan arkadaşlarıma adanmıştır.

Haziran 2022

Sina Birecik
Makine Mühendisi



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	ix
KISALTMALAR	xiii
ÇİZELGE LİSTESİ.....	xvii
ŞEKİL LİSTESİ.....	xix
ÖZET.....	xxiii
SUMMARY	xxv
1. GİRİŞ	1
1.1 Literatür Araştırması	2
2. KAVRAMSAL ÇERÇEVE.....	11
2.1 Ekonomi	11
2.1.1 Ekonomik göstergeler.....	12
2.1.2 Teknik analiz göstergeleri – İndikatörler.....	13
2.2 Yatırım Araçları	13
2.3 Altın.....	15
2.3.1 Türkiye’de altın	17
2.3.2 Küresel piyasada altın.....	24
2.4 Altını Etkileyen Majör Faktörler.....	25
2.4.1 ABD Dolar Endeksi (DXY)	25
2.4.2 Kripto para.....	26
2.4.2.1 Bitcoin.....	26
2.4.3 Emtialar	27
2.4.3.1 Petrol.....	27
2.4.3.2 Londra Metal Borsası Endeksi (LMEX).....	30
2.4.3.3 FAO Gıda Fiyat Endeksi (PFOOD).....	30
2.4.3.4 TRCCRBTR endeksi.....	31
2.4.3.5 Değerli madenler.....	31
2.4.4 Borsalar.....	32
2.4.4.1 NQ100 endeksi	32
2.4.4.2 DAX endeksi.....	33
2.4.4.3 US500 endeksi	34
2.4.4.4 TXBM endeksi.....	36
2.4.5 Volatilite endeksi.....	36
2.4.6 Enflasyon.....	38
2.4.7 Faiz	39
2.4.7.1 Mevduat faizleri.....	40
2.4.7.2 Merkez Bankası faiz oranları.....	40
2.4.7.3 Tahvil ve bono faizi	41
2.4.7.4 Gösterge faizi.....	41
2.4.7.5 Faizin etkileri	41

2.4.7.6 Avrupa Merkez Bankası politika faizi	43
2.4.7.7 Reel faiz	44
2.4.8 Makroekonomik göstergeler	49
2.4.8.1 Para arzı	49
2.4.8.2 FED bilançosu.....	52
2.4.8.3 İşsizlik oranı.....	53
2.4.8.4 Gayrisafi yurt içi hasıla	54
2.4.8.5 ABD tarım dışı istihdam	55
3. DERİN ÖĞRENME	57
3.1 Denetimli ve Denetimsiz Öğrenme	58
3.2 Tekrarlayan YSA (TYSA).....	60
3.2.1 TYSA eksiklikleri	61
3.3 Uzun Kısa Süreli Bellek (UKSB).....	62
3.3.1 UKSB'nin üstünlükleri	64
3.3.2 UKSB yapısı ve çalışma prensibi	65
3.3.2.1 Unutma kapısı operasyonu.....	65
3.3.2.2 Giriş kapısı operasyonu.....	66
3.3.2.3 Hücre durumu operasyonu	66
3.3.2.4 Çıkış kapısı operasyonu	67
3.3.3 Çift yönlü UKSB'ler.....	67
4. TYSA VE UKSB KULLANILARAK ALTIN FİYATI TAHMİNİ YAPILMASI.....	69
4.1 Tahminleme Yöntemleri.....	69
4.2 Zaman Serileri	70
4.3 Kullanılan Kütüphaneler	71
4.4 Veri Seti.....	73
4.5 Veri Ön İşleme	74
4.5.1 Aykırı değerlerin kaldırılması.....	82
4.5.2 Veri yumuşatma.....	84
4.5.3 Veri gruplama	86
4.6 Öznitelik Seçimi	87
4.6.1 Kovaryans matrisi ve ısı haritası.....	88
4.6.2 PCA.....	89
4.7 Öznitelik Çıkarma	90
4.7.1 MACD ve LMACD	90
4.7.2 Mevsimsel ayrıştırma.....	91
4.8 Tahmin Modeli Oluşturma	92
4.8.1 Tensorflow ve Keras.....	93
4.8.2 Tekrarlayan YSA ve UKSB mekanizmaları.....	94
4.9 Değerlendirme Yöntemi	94
5. SİMÜLASYON SONUÇLARI.....	97
5.1 Temsili Kayıp Fonksiyonu En Düşük Test Sonuçları	98
5.1.1 TYSA ağı.....	98
5.1.2 UKSB ağı.....	103
5.2 Test Seti Tahmin Hatası En Düşük Test Sonuçları	109
5.2.1 TYSA ağı.....	109
5.2.2 UKSB ağı.....	114
5.3 Diğer Bulgular	119
6. TARTIŞMA VE ÖNERİLER	125

KAYNAKLAR	127
EKLER.....	137
ÖZGEÇMİŞ.....	147





KISALTMALAR

ABD	: Amerika Birleşik Devletleri
ADP	: Automatic Data Processing (şirket)
ADX	: Average Directional Index (Ortalama Yön Endeksi)
AI	: Artificial intelligence (yapay zeka)
AISC	: All-In Sustaining Costs (Her Şeyi Sürdürme Maliyetleri)
ATR	: Average True Range (Ortalama Gerçek Aralık)
BAE	: Birleşik Arap Emirlikleri
BTC	: Bitcoin
CAD	: Canadian dollar (Kanada doları)
CBOE	: Chicago Board Options Exchange (Chicago Opsiyon Borsası)
CCI	: Commodity Channel Index (Emtia Kanal Endeksi)
CHF	: İsviçre frangı
COVID	: Coronavirus disease (Koronavirüs hastalığı)
CRB	: Commodity Research Bureau (Emtia Araştırma Bürosu)
DAX	: Deutscher Aktienindex (Alman Hisse Senedi Endeksi)
İİBS	: Devlet İç Borçlanma Senetleri
DXY	: ABD Dolar Endeksi
EUR	: Euro
FAO	: Food and Agriculture Organization (Gıda ve Tarım Örgütü)
FED	: Federal Reserve (ABD Merkez Bankası)
FOMC	: Federal Open Market Committee (Federal Açık Piyasa Komitesi)
GBP	: Great British pound (İngiliz sterlini)
GSYH	: Gayrisafi yurt içi hasıla
GUI	: Graphical User Interface (Grafiksel kullanıcı ara yüzü)
İMKB	: İstanbul Menkul Kıymetler Borsası
JPY	: Japon yeni
LBMA	: London Bullion Market Association (Londra Külçe Piyasası Birliği)
LCO	: Light crude oil (Hafif ham petrol)

LMACD	: Logarithmic moving average convergence divergence (Logaritmik Hareketli Ortalamanın Uyumu / Uyumsuzluğu)
LME	: London Metal Exchange (Londra Metal Borsası)
LMEX	: London Metal Exchange Index (Londra Metal Borsa Endeksi)
LSTM	: Long Short-Term Memory (Uzun kısa-süreli bellek)
MA	: Moving average (Hareketli ortalama)
MACD	: moving average convergence divergence (Hareketli Ortalamanın Uyumu / Uyumsuzluğu)
NASDAQ	: National Association of Securities Dealers Automated Quotations (Ulusal Menkul Kıymet Satıcıları Birliği Otomatik Fiyat Teklifleri)
NYMEX	: New York Mercantile Exchange (New York Ticaret Borsası)
NYSE	: New York Stock Exchange (New York Borsası)
OPEC	: Organization of the Petroleum Exporting Countries (Petrol İhraç Eden Ülkeler Örgütü)
PCA	: Principle Component Analysis (Temel bileşen analizi)
PFOOD	: Price of Food (Gıda fiyatı)
QE	: Quantitative Easing (Parasal Genişleme)
RNN	: Recurrent Neural Network (Tekrarlayan Yapay Sinir Ağı)
RSI	: Relative Strength Index (Görelî Güç Endeksi)
S&P	: Standard & Poor's
SAR	: Stop and Reverse (Dur ve ters pozisyon al)
SEK	: İsveç kronu
SPK	: Sermaye Piyasası Kurulu
TCMB	: Türkiye Cumhuriyet Merkez Bankası
TIPS	: Treasury Inflation-Protected Securities (Enflasyon endeksli devlet tahvili)
TL, TRY	: Türk lirası
TSX	: Toronto Stock Exchange (Toronto Borsası)
TÜFE	: Tüketici Fiyat Endeksi
TÜİK	: Türkiye İstatistik Kurumu
TXBM	: TSX Global Base Metals Index (Toronto Borsası Ana Metaller Endeksi)
UKSB	: Uzun Kısa Süreli Bellek
US	: Birleşik Devletler

USD	: United States dollar (Amerikan doları)
ÜFE	: Üretici Fiyat Endeksi
VECM	: Vector Error Correction Model (Vektör Hata Düzeltme Modeli)
VIX	: Volatility Index (Oynaklık endeksi)
WGC	: World Gold Council (Dünya Altın Konseyi)
WTI	: West Texas Intermediate (Batı Teksas Tipi Ham Petrol)
XAUUSD	: Spot ons altın / USD paritesi
XFRA	: Frankfurt Borsası
XTSE	: Toronto Stock Exchange Prices (Toronto Borsası Fiyatları)
YP	: Yabancı para
TYSA	: Tekrarlayan yapay sinir ağı





ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 : Dünya altın maden rezervleri.	17
Çizelge 2.2 : Madenlerin bulunduğu yerler ve üretim yapan şirketler (Yücel, 2020)19	19
Çizelge 2.3 : Dolar endeksi para birimleri ağırlık oranları.	25
Çizelge 2.4 : Para arzı çeşitleri.	49
Çizelge 4.1 : Çalışmada kullanılan değişkenler.....	73
Çizelge 4.2 : Python’a aktarılan verilerin tipi ve gözlem birimi sayısı.	75
Çizelge 4.3 : Değişkenlerin geçerli tarih aralığı.	76
Çizelge 4.4 : Haftanın günleri başına eksik veri oranı.....	78
Çizelge 4.5 : Değişken başına hafta içi eksik veri sayısı ve oranı	79
Çizelge 4.6 : Eksik veriler doldurulduktan sonra veri setine ait çeşitli bilgiler.....	81
Çizelge 4.7 : Lineer regresyon ve rastgele karar ağaçları ile öznitelik seçimi.	88
Çizelge 4.8 : PCA analizi sonucu.	90
Çizelge 4.9 : Testlerde kullanılacak ortak parametreler.	92
Çizelge 4.10 : Testlerde değiştirilecek parametreler.	92
Çizelge 4.11 : Seçilen veri seti kombinasyonları.....	93
Çizelge 4.12 : Deneylerde kullanılan ağların katman yapısı	94
Çizelge 5.1 : Veri seti varyantlarının genel performansı.	119



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Yer altı ve yer üstü altın rezervleri (Metals Focus, Refinitiv GFMS, US Geological Survey, WGC)	16
Şekil 2.2 : Dünya altın üretim oranları.	17
Şekil 2.3 : Türkiye'nin dünya altın üretimindeki payının grafiği	18
Şekil 2.4 : Türkiye altın üretimi grafiği (ton)	19
Şekil 2.5 : Altının kullanım alanına göre dağılımı (WGC, 2019).	20
Şekil 2.6 : Parasal değer bazında Türkiye altın dış ticareti.....	20
Şekil 2.7 : Miktar bazında Türkiye altın dış ticareti.	21
Şekil 2.8 : Ülkelere göre 2019'da yapılan altın ihracatları.	21
Şekil 2.9 : Türkiye altın ithalat-ihracatının miktar bazında oranları (YerTutucu2). .	22
Şekil 2.10 : Borsa İstanbul altın ithalat değerleri (ton, 2021).....	23
Şekil 2.11 : Merkez bankalarının kasalarındaki altın rezervleri (Goldhub, 2020). ...	23
Şekil 2.12 : Spot ons altın / USD fiyat grafiği.....	24
Şekil 2.13 : 2010-2021 dönemine ait ABD dolar endeksi.	26
Şekil 2.14 : 2010-2021 dönemi için Bitcoin / USD parite grafiği.....	27
Şekil 2.15 : 2010-2021 dönemi için WTI ham petrol fiyat grafiği.....	28
Şekil 2.16 : 2010-2021 dönemi için LCO Brent ham petrol fiyat grafiği.	29
Şekil 2.17 : 2010-2021 dönemi için LMEX endeks grafiği.....	30
Şekil 2.18 : 2010-2021 dönemi için PFOOD gıda fiyat endeks grafiği.	31
Şekil 2.19 : 2010-2021 dönemi için Thomson Reuters Emtia endeksi grafiği.....	31
Şekil 2.20 : 2010-2021 dönemi için Ons Gümüş / USD fiyat grafiği.	32
Şekil 2.21 : 2010-2021 dönemi için NQ100 endeks grafiği.....	33
Şekil 2.22 : 2010-2021 dönemi için DAX grafiği	33
Şekil 2.23 : Altın fiyatları (sarı çizgi, sağ eksen) ve S&P 500 Endeksi (yeşil çizgi, sol eksen) (FED St. Louis, 2020).....	35
Şekil 2.24 : 2010-2021 dönemi için US500 (S&P 500) grafiği.....	35
Şekil 2.25 : 2010-2021 dönemi için TXBM endeks grafiği	36
Şekil 2.26 : 2010-2021 dönemi için VIX volatilité endeks grafiği.....	37
Şekil 2.27 : Enflasyon oranlarının getirilerle karşılaştırılması (Turuncu: Yıllık enflasyon, gri: Gayrimenkul yatırımı, mavi: emtialar, sarı: altın, Morningstar Direct)	38
Şekil 2.28 : 2010-2021 dönemi için ABD TÜFE değerleri ve bu değerlerden hesaplanmış yıllık bazlı enflasyon.	39
Şekil 2.29 : 2010-2021 dönemi için ABD 5 ve 10 yıllık beklenen enflasyon.	39
Şekil 2.30 : 2010-2021 dönemi için ait FOMC kurulunun açıkladığı faiz kararları..	42
Şekil 2.31 : FOMC'nin açıkladığı faiz kararlarına göre şekillenen günlük efektif fon oranı grafiği.....	43
Şekil 2.32 : 2010-2021 dönemine ait ECB'nin açıkladığı faiz kararları.	44
Şekil 2.33 : 06/2015 – 12/2015 tarihleri arasındaki ABD reel faiz oranı ve altın karşılaştırması (Sunshine Profits)	46

Şekil 2.34 : 1971-2019 yılları arasındaki ABD reel faiz oranı ve altın karşılaştırması (Sunshine Profits).....	46
Şekil 2.35 : 2010-2021 dönemine ait reel faiz (MacroMicro).	47
Şekil 2.36 : Longtermrends sitesinde gösterilen ve elde edilen veriler ile Excel’de uyumlaştırılan reel faiz grafikleri.	48
Şekil 2.37 : Çalışmada kullanılan reel faiz değişkeni, 2010-2021 dönemi.....	48
Şekil 2.38 : 2010-2021 dönemi için M1 para arzı grafiği.....	50
Şekil 2.39 : 2010-2021 dönemi için FED bilançosu.	53
Şekil 2.40 : 2010-2021 dönemi için ABD işsizlik oranı.....	54
Şekil 2.41 : 2010-2021 dönemi için GSYH verilerinden elde edilen büyüme oranları.	55
Şekil 2.42 : 2010-2021 dönemi için aylık olarak yayınlanan ADP tarım dışı istihdam değişim grafiği.....	56
Şekil 3.1 : Yapay zeka, makine öğrenmesi ve derin öğrenmenin kapsamı.	57
Şekil 3.2 : Yapay sinir ağı katman yapısı	59
Şekil 3.3 : TYSA'daki sıralı işlem.	60
Şekil 3.4 : Geliştirilen ilk UKSB hücresi (Hochreiter ve Schmidhuber, 1997).	63
Şekil 3.5 : İlk UKSB hücresine unutmama kapısı eklenmiş versiyon (Gers vd., 1999).	63
Şekil 3.6 : Bir Vanilla UKSB bellek hücresi.	64
Şekil 3.7 : Çift yönlü tekrarlayan sinir ağı mimarisi. Kaynak: Baeldung.....	68
Şekil 4.1 : Temel bir zaman serisi grafiği.	71
Şekil 4.2 : Veri setinin eksik verilerinin görselleştirilmesi.....	76
Şekil 4.3 : Eksik verilerden oluşan LMEX grafiği	77
Şekil 4.4 : İnterpolasyon yöntemiyle doldurulan LMEX grafiği.....	77
Şekil 4.5 : Fiyat değişkenleri veri kümelerini doldurduktan sonra genel görünüm... ..	80
Şekil 4.6 : WTI veri setinin aykırı değer tespiti.....	83
Şekil 4.7 : Savitzky-Golay ile XAUUSD zaman serisinin veri yumuşatması.	85
Şekil 4.8 : Değişkenlerin kovaryans matrisinden elde edilen ısı haritası.	89
Şekil 4.9 : XAUUSD değişkeninin 2010-2020 dönemi için mevsimsel ayrıştırması.	91
Şekil 4.10 : XAUUSD değişkeninin 05/2019-08/2019 dönemi için mevsimsel ayrıştırması.	92
Şekil 5.1 : Test 2 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: base, parti boyutu: 16, pencere boyutu: 60).....	98
Şekil 5.2 : Test 14 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: macd, parti boyutu: 16, pencere boyutu: 60).....	99
Şekil 5.3 : Test 5 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: base, parti boyutu: 32, pencere boyutu: 60).....	100
Şekil 5.4 : Test 1 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: base, parti boyutu: 16, pencere boyutu: 30).....	101
Şekil 5.5 : Test 18 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: macd, parti boyutu: 32, pencere boyutu: 90).....	102
Şekil 5.6 : Test 245 sonuçları (Ağ: UKSB, Veri seti: model1, varyant: base, parti boyutu: 32, pencere boyutu: 60).....	103
Şekil 5.7 : Test 322 sonuçları (Ağ: UKSB, Veri seti: model2, varyant: macd, parti boyutu: 64, pencere boyutu: 30).....	104
Şekil 5.8 : Test 249 sonuçları (Ağ: UKSB, Veri seti: model1, varyant: base, parti boyutu: 48, pencere boyutu: 90).....	105

Şekil 5.9 : Test 317 sonuçları (Ağ: UKSB, Veri seti: model2, varyant: macd, parti boyutu: 32, pencere boyutu: 60).....	106
Şekil 5.10 : Test 353 sonuçları (Ağ: UKSB, Veri seti: model2, varyant: hist, parti boyutu: 32, pencere boyutu: 60).....	107
Şekil 5.11 : Test 18 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: macd, parti boyutu: 32, pencere boyutu: 90, test hatası: 212.85).....	109
Şekil 5.12 : Test 17 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: macd, parti boyutu: 32, pencere boyutu: 60, test hatası: 217,58).....	110
Şekil 5.13 : Test 53 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: hist, parti boyutu: 32, pencere boyutu: 60, test hatası: 690.9).....	111
Şekil 5.14 : Test 59 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: hist, parti boyutu: 64, pencere boyutu: 60, test hatası: 847.51).....	112
Şekil 5.15 : Test 26 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: both, parti boyutu: 16, pencere boyutu: 60, test hatası: 898.16).....	113
Şekil 5.16 : Test 271 sonuçları (Ağ: UKSB, Veri seti: model1, varyant: both, parti boyutu: 48, pencere boyutu: 30, test hatası: 241.44).....	114
Şekil 5.17 : Test 270 sonuçları (Ağ: UKSB, Veri seti: model1, varyant: both, parti boyutu: 32, pencere boyutu: 90, test hatası: 293.04).....	115
Şekil 5.18 : Test 264 sonuçları (Ağ: UKSB, Veri seti: model1, varyant: macd, parti boyutu: 64, pencere boyutu: 90, test hatası: 303.32).....	116
Şekil 5.19 : Test 330 sonuçları (Ağ: UKSB, Veri seti: model2, varyant: both, parti boyutu: 32, pencere boyutu: 90, test hatası: 466.78).....	117
Şekil 5.20 : Test 260 sonuçları (Ağ: UKSB, Veri seti: model1, varyant: macd, parti boyutu: 48, pencere boyutu: 60, test hatası: 474.47).....	118
Şekil 5.21 : Veri seti varyantlarının genel performansı.....	120
Şekil 5.22 : Veri seti kombinasyonları alt kırımında UKSB ve TYSA ağlarının temsili doğrulama kayıp fonksiyonu karşılaştırması	120
Şekil 5.23 : Veri seti kombinasyonları alt kırımında UKSB ve TYSA ağlarının test veri seti hata karşılaştırması.....	121
Şekil 5.24 : model0 temel veri seti kullanılarak parti boyutuna göre test seti tahmin hatası cinsinden ağ performansları.....	121
Şekil 5.25 : model1 temel veri seti kullanılarak parti boyutuna göre test seti tahmin hatası cinsinden ağ performansları.....	122
Şekil 5.26 : model2 temel veri seti kullanılarak parti boyutuna göre test seti tahmin hatası cinsinden ağ performansları.....	122
Şekil 5.27 : model0 temel veri seti kullanılarak pencere boyutuna göre test seti tahmin hatası cinsinden ağ performansları.....	123
Şekil 5.28 : model1 temel veri seti kullanılarak pencere boyutuna göre test seti tahmin hatası cinsinden ağ performansları.....	123
Şekil 5.29 : model2 temel veri seti kullanılarak pencere boyutuna göre test seti tahmin hatası cinsinden ağ performansları.....	124



UZUN KISA SÜRELİ BELLEK İLE ALTIN FİYATI TAHMİNİ

ÖZET

Altın, fiziki ve kimyasal birçok özelliği sayesinde ilk çağlardan beri insanların ilgisini çeken bir maden olmuştur. Savunma sanayi, elektrik elektronik sanayi ve mücevher gibi çeşitli kullanım alanlarına sahip olsa da ilk çağlardan günümüze kadar gelen süreçte en önemli özelliği olarak ekonomik değeri verilebilir. Lidyalıların sikkelerde altın kullanması ile altın bir takas ve yatırım aracı haline gelmiştir. Günümüzde bu özelliğini hala sürdürmektedir. Bu özellikleri sayesinde toplumlarda gücün sembolü olmuştur.

Günümüzde yatırım yapmak isteyen kişiler herhangi bir risk unsuru bulundurmada uzun veya kısa vadede kazanç sağlamak, bu sebeple yatırımlarına karşılık gelen getirilerinin tahminlerinin yapılmasını isterler. Yatırım yaparken tahminlemenin önemi büyüktür. Yatırım yaparken dünyadaki olaylardan etkilenen yatırım araçlarının, etkiye karşı tepkilerinin çözülmesi gerekmektedir. Bu araştırmadaki temel amacımız altının, geçmişteki verileri baz alarak gelecekteki davranış biçimlerini tahmin etmektir. Tahminleme yöntemi olarak seçilen yöntem; bir derin öğrenme türü olan tekrarlayan yapay sinir ağıdır. Bu çalışmada üzerinde çalışılacak problem, zaman serisi üzerinde lineer olmayan çözüm gerektiren regresyon problemi olarak ele alınmıştır.

Yapılan çalışmada çok değişkenli finansal zaman serilerinde değişken seçimi ve altın fiyat tahmini incelenmiştir. Yatırım için kullanılan altın fiyatlandırmak için çok sayıda dinamik faktör bulunmaktadır. Her faktör aynı etkiye sahip olmadığı için, altın fiyatında en çok etkiye sahip faktörler tespit edilmiştir. Veri mühendisliği bölümünden sonra, altını etkileyen ana faktörler tespit edilmiştir. İncelenen faktörlerden veri setleri belirlenmiş ve bu veri setlerinden en önemlileri seçilerek çalışmanın temelini oluşturmuştur. Bu veri setleri; ABD dolar endeksi, kripto paralar, emtialar, borsadaki endeksler, volatilité endeksi, enflasyon ve faiz gibi çeşitli parametrelerden oluşturulmuştur. Gerçek dünyada altın fiyatları temel teori ve kriterlere göre hareket ediyor olsa da altın birçok teknik ve temel değişkenden etkilenen bir emtia türüdür. Yapılan çalışmada temel bir tekrarlayan yapay sinir ağı (TYSA) ve uzun kısa süreli bellek derin öğrenme ağı (UKSB) kullanılmıştır. Tahmin modeli olarak temel TYSA modeline ek olarak UKSB, yani tekrarlayan yapay sinir ağlarının bir türü olan uzun kısa süreli bellek modelinden yararlanılmıştır. Veri seti içindeki öznitelikler, TYSA ve UKSB ağlarındaki parti boyutu ve pencere boyutu değiştirilerek altın fiyatının bu girdilere karşı tepkisi hakkında fikir verilmeye çalışılmıştır. Pencere boyutu, gözlem birimi oluştururken geçmişe dönük verilerin kaç güne kadar alınacağını belirleyen hiper parametredir. Değişik veri setlerinin kombinasyonlarından oluşturulan TYSA ve UKSB hiper parametrelerinin gelecek değer tahmininin başarısı bu çalışmada incelenmiştir. Çalışmada altın fiyatını en çok etkileyen parametrelerin USD/JPY paritesi, 10 yıllık beklenen enflasyon (ABD), 10 yıllık reel faiz (ABD), ABD gayrisafi

milli hasılası (GSYH) ve dolaşımdaki USD miktarı olduğu tespit edilmiştir. Daha fazla değişken seçmeye devam edildiğinde tahmin başarımlarında iyileşme gözlemlenmemiştir. Uygulamaların, eğitim sürecinden sonra tahmine ilişkin model başarımları hesaplanmıştır. Yapılan testlerde uygun tahmin sonuçları verilen parametreler belirlenmiştir. MACD indikatörünün eklenmesiyle oluşturulan veri setlerinin daha düşük pencere boyutlarıyla eğitildiği testlerde bu modeller diğer kombinasyonlardan daha üstün sonuçlar vermiştir. Modeli iyileştirmek için mevcut parametreler daha hassas seçilerek optimizasyon yapılmıştır. Henüz profesyonel anlamda kullanımı mümkün olmasa da ilk çalışma için umut verici sonuçlar vermiştir. Bu kapsamda çalışmanın amacı ve kapsamı karşılanmıştır. Ayrıca ileride yapılacak çalışmalar hakkında bir başlangıç noktası olacaktır.

Anahtar kelimeler: Altın, zaman serisi, derin öğrenme, UKSB, yapay sinir ağı, çok değişkenli.



GOLD PRICE FORECASTING USING LONG SHORT-TERM MEMORY

SUMMARY

Thanks to its many physical and chemical properties, gold has been a mineral that has attracted the attention of people since ancient times. Although it has various usage areas such as the defense industry, electrical electronics industry, and jewelry, its economic value can be given as the most important feature from the first ages to the present day. With the use of gold in coins by the Lydians, gold became a tool of exchange and investment. It still maintains this feature today. Thanks to these features, it has become a symbol of power in societies. With the Bretton-Woods system, which came into effect towards the end of World War II, the gold price was indexed to the US dollar. With the increasing tension in the world markets, this system collapsed, and gold started to be priced dynamically as of 1971. The gold price in Turkey is calculated using the worldwide accepted gold price in US dollars and the Turkish lira / US dollar parity.

Today, investors want to make a profit in the long or short term with minimum risk factors. The most risk-free investment instruments preferred by investors can be given as precious commodities such as gold, foreign currencies, stocks, real estate, cryptocurrencies, bonds, mutual funds, and government bonds. It is preferable to make estimates of the corresponding returns or losses on such investments. For this reason, forecasting is of great importance when investing and the reaction of investment instruments affected by events in the world should be analyzed. Our main purpose in this research is to predict the future behavior of gold based on past data. The recurrent neural network (RNN), which is a type of deep learning, was chosen as the forecasting method. The problem to be studied in this research is considered a regression problem that requires a nonlinear solution to the time series.

In this study, feature selection and gold price prediction in multivariate financial time series were examined. There are many dynamic factors for pricing gold used for investment. Since not every factor has the same effect, the most effective factors on gold should be determined. After the data engineering part, the main factors affecting gold price have been identified. Features were determined using the factors examined, and the most important of these features were selected and formed the basis of the study. The datasets were created using various features such as the US dollar index, cryptocurrencies, commodities, stock market indices, volatility index, inflation, and interest rates. Although gold prices in the real-world act according to basic theory and criteria, gold is a commodity type that is affected by many technical and fundamental parameters.

Before the forecasting section, feature selection was made using Random Forest Regression and Linear Regression. In this section, it has been determined that the parameters that affect the gold price the most are the USD/JPY parity, 10-year expected inflation (USA), 10-year real interest rate (USA), US gross national product

(GDP), and the amount of USD in circulation. No improvement was observed in the forecasting performance criterion even if more variables were added.

In the principal component analysis, the most important variables representing the main dataset were determined as oil, US real interest rate, Bitcoin, silver price, LME index, 10-year inflation (USA), TXBM index, USD money supply M1, and volatility index.

A basic recurrent artificial neural network (RNN) and long short-term memory deep learning network (LSTM) were used in the forecasting study. The dataset combinations were created by using 5 variant variables on 3 main datasets so that there are 15 combinations in total. These variant variables are economic indicators LMACD and MACD. Test combinations were created using dataset combinations also batch size and window size values determined for RNN and LSTM networks. It has been tried to give an idea about the reaction of the gold price against these inputs. The window size is the hyperparameter that determines how many days the historical data will be retrieved when creating the observation unit. RNN and LSTM hyperparameters were also derived on each dataset combination and forecasting was made.

After the training process, the predictive model performances of the applications were calculated. Parameters with appropriate estimation results were determined in the tests performed. While RNN performs at par with LSTM in one main dataset, LSTM has a higher predictive success than RNN in the other two main datasets. In tests where the datasets created by adding the MACD indicator were trained with lower window sizes, these models gave superior results than other combinations.

In addition, it was observed that there were deviation errors in the training of the models due to the Covid-19 crisis, which started in March 2020. In the forecasting study on the training set, it was determined that the network could not perform as well as before this date in the part of the training data after the onset of Covid-19. To improve the model, the existing parameters were selected more precisely, and optimization was made.

Although it is not possible to use it professionally yet, it has given promising results for the first study. In this context, the aim and scope of the study have been met. It will also be a starting point for future work.

Keywords: Gold, time series, deep learning, LSTM, neural network, multivariate.

1. GİRİŞ

Altın, tarihsel süreçte insanoğlunun kullandığı ilk metallerden biridir. Altın çeşitli medeniyetlerde süs eşyası ve mücevher olarak kullanılmıştır. Daha sonra para olarak kullanılmış ve dünyaya yayılarak uluslararası para sisteminin temelini oluşturmuştur. Günümüzde ise en önemli yatırım araçlarından biri olan altın; tarihte ve günümüzde hala önemini korumaktadır. Geçtiğimiz dönemlerde küresel çapta gerçekleşen koronavirüs salgını nedeniyle dünyada gerçekleşen ekonomik çalkantılar ve değişen hayat koşulları gibi faktörlerle birlikte altına ilgi daha da artmış ve insanlar güvenli bir liman olarak gördükleri altına yatırım yapmaya başlamışlardır. En önemli yeraltı kaynağı olan altın birçok sektörde kullanılmaktadır; bunlardan en önde gelenleri ise, uzay ve havacılık sanayi, elektrik ve elektronik sanayi, kuyumculuk, kaplama ve bilişim sektörüdür. Günümüzde değişen ekonomik çalkantılar insanların altına daha da yoğunlaşmasına yol açmıştır ve en güvenli yatırım aracı haline gelmiştir.

Tezdeki temel amaç altının değerini etkileyen en temel faktörlerin bulunması ve altın fiyatının gelecekteki davranış biçimlerini incelemektir. Problem, lineer olmayan çözüm gerektiren zaman serisi regresyon problemi olarak ele alınmış, veri mühendisliği ve derin öğrenme yöntemleri kullanılarak çözümlenmiştir. Literatürdeki araştırmalardan farklı olarak değişken sayısı kısıtlanmadan, çalışmaya toplamda 30 değişken dahil ederek daha efektif sonuçlar elde etmek amaçlanmıştır.

Çalışmada temel bileşen analizi yöntemi, rastgele orman regresyonu ve lineer regresyon kullanılarak öznetelik seçimi yapılmış, oluşturulan temel veri setlerine finasta kullanılan MACD indikatörleri eklenip veri seti kombinasyonları oluşturulmuştur. Tahmin aracı olarak temel tekrarlayan yapay sinir ağı ve UKSB ile derin öğrenme yöntemi kullanılmıştır. Farklı veri setleri kombinasyonlarının, UKSB hiper parametreleri olan parti boyutu (batch size) ve geçmişe dönük zaman penceresi boyutlarında farklı değerlerin tahmin başarısına etkisi incelenmiştir. Geçmiş veriler baz alınarak ileriki dönemlerdeki altın değerinin izleyebileceği yol haritası

tasarlanmaya çalışılmıştır. İleriye dönük olarak, sonraki araştırmalara yol haritası oluşturabilecek bir araştırma yapılması planlanmıştır.

1.1 Literatür Araştırması

Ekonomik yatırım araçları arasında belki de en eski ve en güvenilir birimlerin başında altın yer almaktadır. Sadece yatırımcılar için değerli olmayan altın, akademisyenler için de çeşitli çalışmaların konusu olmaktadır. Altının değerini etkileyen faktörler ve fiyat tahmini üzerine geçmişten günümüze birçok çalışma bulunmaktadır. Bu çalışmalar sadece ekonomi alanında olmayıp farklı alanlara yayılmakta ve çeşitli yöntemleri içermektedir. Bu tezde faydalanılan bazı makaleler aşağıda yer almaktadır.

McDonald ve Solnick'in araştırmasında altın fiyatları ve enflasyon arasında pozitif bir korelasyon olduğuna yer verilmiştir (McDonald ve Solnick, 1977).

Jastram ve Nelson, The Golden Constant (Altın Sabit) isimli kitabında altının tekil enflasyonlara karşı koruma olarak kullanılabildiğini, ancak periyodik olarak tekrarlayan enflasyonlara karşı bir strateji olarak kullanılamayacağını belirtmiştir. Kaynağa göre altın kısa ve orta vadede istikrarsız, uzun vadede kısmi olarak istikrarlıdır. Ayrıca altının emtia fiyatlarını takip etmediğini, emtia fiyatlarının sürekli olarak altın fiyatlarını izlediği belirtilmiştir (Nelson ve Jastram, 1980).

Ewing ve Malik, altın ve petrol fiyatları arasında volatilité geçişleri tespit etmişlerdir (Ewing ve Malik, 2013).

USD cinsinden ons altın fiyatlarını 2003-2012 tarihleri arasından alan Khan, ARIMA üzerinde çalışmış ve altın fiyat tahmini için en uygun ARIMA modelinin ARIMA (0,1,1) olduğunu belirtmiştir (Khan, 2013).

1971-1987 yılları arasındaki verilerle çalışan Jaffe, altın fiyatları ve enflasyon arasında bir paralellik olduğunu belirtse de altının enflasyon karşısında güçlü bir koruma olacak kadar güçlü bir ilişki içinde bulunmadığını aktarmıştır (Jaffe, 1989).

Malezya'daki altın fiyatlarını inceleyen Ping ve çalışma arkadaşları, altın fiyat tahmininde GARCH yönteminin ARIMA yönteminden üstün olduğunu bulmuştur (Ping vd., 2013).

Koutsoyiannis'in çalışmasında spekülâtif bir finansal varlığın veya dayanıklı spekülâtif emtianın fiyatının işlem günü olarak kabul edilen çok kısa vadede

belirlenmesi için genel bir dinamik model geliştirilmiştir. Ocak 1980 - Mart 1981 döneminden USD endeksi, faiz, beklenen enflasyon, spot gümüş, spot altın, petrol, finansal emtialar verileri kullanılarak yapılan çalışmadan çıkan sonuçlar; altın piyasalarının, genel kanının tersine, ekonomi teorileri ile tutarlı bir şekilde çalıştığı, iyi tanımlanmış bir dizi ekonomik ve ekonomik olmayan faktöre tepki vererek rasyonel ve tahmin edilebilir bir şekilde hareket ettiği, altın fiyatının Amerikan ekonomisinin durumuyla sıkı sıkıya ilişkili olduğu, Amerikan dolarının gücü, ABD enflasyon oranı ve geçerli ABD faiz oranının, altın fiyatının önemli belirleyicileri olduğudur. Koutsoyiannis, ayrıca siyasi istikrarsızlık gibi kolayca ölçülemeyen faktörlerin, nicel bir çalışmaya anlamlı bir şekilde dahil edilebildiğini belirtmiştir. Büyük siyasi gelişmeler ve jeopolitik faktörlerin temelinde oluşturulan bir siyasi gerilim endeksinin, altın fiyatı üzerinde güçlü bir etkisi olduğunu göstermiştir. Son sonuç olarak da altın piyasasının çok kısa vadede verimli olmadığını belirtmiştir (Koutsoyiannis, 1983).

Dooley ve ekibi, hazırladıkları çalışmalarında diğer parasal ve reel makroekonomik değişkenlere bağlı olarak altın fiyatlarının döviz kurları üzerindeki kısa ve uzun vadeli etkisini test etmek için çok değişkenli vektör oto regresyon ve eşbütünleşme modelleme tekniklerini uygulamıştır. Girdi olarak Ocak 1976 – Aralık 1990 dönemindeki verileri kullanmışlardır. Çıktı olarak USD'nin diğer başlıca para birimleriyle olan paritelerinin altın fiyatlarıyla güçlü bir negatif korelasyona sahip olduğuna yer verilmiştir (Dooley vd., 1992).

Topçu (2010)'nun yapmış olduğu çalışmada, altın fiyatlarını etkileyen faktörlerin tespit edilmesi amaçlanarak ABD enflasyon oranı, ABD reel faiz oranı, ABD Dolar Endeksi, petrol fiyatı, Dow Jones Sanayi Ortalaması Endeksi ve küresel para arzı verileri dahil edilmiştir. Sonuçlara göre altın getirileri; Dow Jones Sanayi Ortalaması Endeksi ve dolar faizleri ile ters korelasyonlu, küresel para arzıyla pozitif korelasyonludur. Kriz dönemi, altının üzerine pozitif etki etmiştir. Altın ile reel faiz oranları pozitif yönlü ilişkili olmasına rağmen istatistiksel olarak anlamlı olmadığı tespit edilmiştir.

Ghosh ve ekibi, ABD ve dünya enflasyonu, döviz pariteleri, faiz oranları ve küresel GYSH verilerini Ocak 1976 ve Aralık 1999 arasından alıp incelemişlerdir. İnceleme sonucunda altın fiyatının ABD enflasyonundan, parite oranları ve faiz oranından

etkilendiği görülmüştür. DXY'deki yükselmenin ABD dışındaki yatırımcıların altına olan taleplerinin azalmasına yol açtığı anlaşılmıştır (Ghosh vd., 2001).

Smith, SPDR için hazırladığı raporda Ocak 1991 – Ekim 2001 döneminden aldığı altın ve ABD borsa endekslerinin kısa vadede bir ilişkisi olduğunu, ancak bunun uzun vadede gözlemlenmediğini belirtmiştir (Smith, 2001).

Davis vd., aylık frekansa indirgenmiş 2003-2012 arasındaki 112 altın fiyatı gözlem biriminin 106'sını ARMA modelinde eğitimde kullanarak diğer 6 değeri tahmin etmişlerdir. Araştırmada gecikme aralığı arttıkça hata limitlerinin de genişlediği görülmüştür (Davis vd., 2014).

Apergis, hazırladığı çalışmada Avustralya'da bulunan döviz kurlarındaki nominal ve reel değişimlerin altın fiyatlarına etkisini incelemiştir. Avusturya doları/USD paritesinin tahmininde altın fiyatının kullanılabileceğini öne sürmüştür (Apergis, 2014).

Hassani vd., hem parametrik hem de parametrik olmayan zaman serisi modelleri kullanarak yaptığı altın tahminlerinde kısa veya uzun dönemde uygun bir başarımla sağlayamamıştır. Tek değişkenli (sadece altın fiyatı) modellerin çok değişkenli modellerden daha iyi sonuç verdiğini belirtmiştir (Hassani vd., 2014).

Toraman vd., (2011) yapmış oldukları çalışmada 1992-2010 yılları arasındaki verileri kullanarak altın fiyatını etkilediği iddia edilen petrol, ABD doları kuru, ABD enflasyon oranı, ABD reel faiz oranlarını incelemiştir. Kurulan model doğrultusunda koşullu korelasyon sonuçlarından elde edilen verilerde ABD doları kurunun negatif yönde en yüksek korelasyon miktarına sahip olduğu tespit edilmiştir. İkinci sırada ise petrol fiyatlarının pozitif yönde en yüksek korelasyon miktarına sahip olduğu gözlenmiştir (Toraman vd., 2011).

Khaemusunun, 2002 – 2008 döneminden çektiği Tayland altın fiyatları yanında Tayland bahtının USD, AUD, CAD, Peru, HK, JPY, EUR, Singapur bahtına olan paritelerini, petrol fiyatı ve reel faiz oranlarını ARIMA ve çoklu regresyon yöntemleriyle işlemiştir. USD, AUD, CAD ve JPY para birimlerinin Tayland altın fiyatlarını en fazla etkileyen faktörler olduğu sonucuna varılıp Tayland altın fiyatı tahmini için ARIMA (1,1,1) modeli önerilmiştir (Khaemusunun, 2009).

B. İncekara ve R. İncekara'nın yürüttüğü çalışmada küresel bazda altın piyasalarını etkileyen ülkelerin piyasadaki rolleri incelenmiştir. Altına bağlı yatırım araçları, bu yatırım araçlarının işlem gördüğü dünya piyasaları, tezgah üstü piyasalar, vadeli işlem piyasaları ve organize spot piyasaları ayrı kapsamlarda incelenmiştir ve bu piyasaların merkezleri ve kendine yer bulan ürünlerden bahsedilmiştir (B. İncekara ve R. İncekara, 2016).

Ismail vd. çoklu lineer regresyon kullanarak altın fiyat tahminlemesi yapmıştır. Çalışmada CRB endeksi, USD/EUR paritesi, reel faiz, para arzı, NYSE endeksi, SP500 endeksi, devlet tahvil getirisi ve DXY gibi pek çok parametre kullanılmıştır. Çalışma sonucunda CRB endeksi, USD/EUR paritesi reel faiz ve para arzının altın fiyatlarını çok etkilediği sunulmuştur (Ismail vd., 2009).

Sjaastad, altın fiyatı ve ABD'nin diğer para birimleriyle olan endekslerinin ilişkisini incelemiştir. 1980'lerde küresel olarak üstün olan Avrupa para birimleri, 1990'larda yerini USD'ye bırakmıştır. Özellikle Euro ve Japon Yeni'nin USD karşısındaki değer değişimlerinin altın fiyatı üzerinde etkiye sahip olduğu sonucuna varılmıştır (Sjaastad, 2008).

Hammoudeh ve çalışma ekibi, altın fiyatlarındaki ve USD/EUR paritesi arasındaki volatilitenin bağlantısına işaret etmiştir (Hammoudeh vd., 2010).

Altının Japonya ve ABD'deki kısa ve uzun dönemde enflasyona karşı koruma kabiliyetini inceleyen Wang ve ekibi, Ocak 1971 – Ocak 2010 verilerini kullanmış, altın fiyatının fiyat katılığının neden olduğu piyasa dengesizliği ile karakterize edildiğini ve bunun da altın fiyatının TÜFE'deki değişikliklere cevap verememesine neden olduğunu bulmuşlardır. Uzun vadede, altın getirisinin ne ABD'de ne de Japonya'da enflasyona karşı korunma sağlayamadığı bulunmuştur. Bununla birlikte, altının getirisi ABD'de enflasyona karşı kısa vadede koruma sağlayabilirken, Japonya'daki fiyat katılığı, altının fiyatının kısa vadede enflasyona karşı tam olarak korunmamasına neden olur (Wang vd., 2011).

Topçu ve Aksoy tarafından yürütülen çalışmada yatırım aracı olarak altın ile hisse senedi, devlet tahvili (DİBS), tüketici fiyat endeksi (TÜFE) ve üretici fiyat endeksi (ÜFE) arasındaki kısa ve uzun vadeli ilişkiler incelenmiştir. Analizde Ocak 2003-Aralık 2011 aralığındaki veriler kullanılmıştır. Başlangıçta belirlenen emtia fiyatlarının regresyon analizleri yapılmıştır. Ardından seçilen emtiaların altınla

ilişkisinin incelenmesi için serilerin durağanlık testleri ADF ile yapıldıktan sonra eşbütünleşme modelleri arasında yer alan, Engle-Granger eşbütünleşme testi, Granger nedensellik testi ve Johansen eşbütünleşme testleri yapılmıştır. Uzun dönemde altın, hisse senedi, DİBS, ÜFE ve TÜFE'yi yönlendiren ve dengeleyen bir eşbütünleşme vektörü olduğu ve değişkenler arasında uzun dönemli bir ilişkinin olduğu Johansen eşbütünleşme analizi ile belirlenmiştir. Hata düzeltme modeli (VECM) değişkenlerinin dengeden kısa dönemli sapmalar oluşturduğu analiz edilmiştir. Regresyon analizi sonuçları, altın getirisi ile hisse senedi getirisi arasında negatif, ÜFE bazında hesaplanan enflasyon ile pozitif bir ilişki olduğunu göstermiştir (Topçu ve Aksoy, 2013).

Sjaastad ve Scacciavillani, Euro ve Japon Yeni'nin USD karşısında gerçek değer artışları ve azalmalarının, diğer tüm dövizlerdeki altın fiyatlarına yüksek derecede etki ettiği sonucuna varmışlardır (Sjaastad ve Scacciavillani, 1996).

Bali ve Cinel'in yapmış olduğu çalışmada diğer çalışmalardan farklı olarak tek boyutlu analiz değil panel veri analizi tekniği kullanmıştır. Altın fiyatlarının İMKB 100 Endeksi'ne etkisi olup olmadığını, ayrıca oluşacak etkinin büyüklük ve yönünü tespit etmeyi amaçlamışlardır. Bu kapsamda sabit etki modelleri ile tesadüfi etki modellerinden faydalanılmıştır. Ağustos 1995'ten Mart 2011'e kadar olan veriler zaman serisi olarak kullanılmıştır. 9 farklı bağımsız değişkenin verileri ise yatay kesit olarak analiz edilmiştir. Çalışma sonucunda altın fiyatının İMKB 100 endeksini doğrudan etkilemediği, ancak İMKB 100 endeksindeki değişimleri açıklayan parametrelerden biri olduğu ortaya çıkarılmıştır (Bali ve Cinel, 2011).

Han vd., AUD/USD paritesinin altın fiyatlarıyla ilişkisini incelemişlerdir. Paritenin, uzun ve kısa dönemde Avusturya altın fiyatlarını etkilediğini bulmuşlardır.

Mombeini ve Yazdani-Chamzini, altın fiyatını yapay sinir ağları yöntemi ile tahmin etmeyi öneren bir model geliştirmiştir. Bu modele girdi olarak ons altın ve gümüş fiyatları, USD endeksi, petrol, ABD enflasyon ve faiz oranları, Dow Jones endeksi ve dünya altın üretimi seçilmiştir. Çalışmada Nisan 1990 – Temmuz 2008 dönemi değerleri kullanılmıştır. Ağ modelinin performansı, geleneksel ARIMA tahmin yöntemiyle R², RMSE, MAE performans ölçüm yöntemleri kullanarak karşılaştırılmıştır. YSA modelinin doğrulama aşamasında ARIMA'dan daha doğru tahmin ettiği gösterilmiştir (Mombeini ve Yazdani-Chamzini, 2015).

Küçükaksoy ve Yalçın'ın yapmış olduğu çalışmada altın fiyat spekülörleri için önemli olabilecek faktörler incelenmiştir. Çalışmada vektör otoregresyon modeli (VAR) kullanılmıştır. Petrol fiyatları, gümüş fiyatları, Dow Jones Sanayi Endeksi, Dolar-Sterlin paritesi ve FED fon faiz oranı bağımsız değişken olarak belirlenmiştir. Çalışma sonucunda bağımsız değişkenlerinin etkisinin 3 ay sonra yok olduğu tespit edilmiştir. Spot fiyat açıklama gücü %97 olarak tespit edilmiştir. Altının tahminlemesinde en verimli etkenin geçmiş veriler olduğu belirtilmiştir (Küçükaksoy ve Yalçın, 2017).

Shankar ve Reddy, Hindistan'daki gram altının Rupî cinsinden fiyatlarından oluşan 2016-2022 aralığına ait veri seti kullanmışlardır. Çalışmada ARIMA (2,1,2), çok katmanlı YSA, evrişimli sinir ağı (CNN) ve UKSB modelleriyle altın fiyat tahmini gerçekleştirip sonuçları MAE, MAPE ve RMSE yöntemleriyle değerlendirip karşılaştırmışlardır. UKSB yönteminin diğer yöntemlerden üstün olduğu sonucuna varılmıştır.

Tripathy, altın fiyatlarını ARIMA yöntemiyle incelemiş, doğrulama olarak MAE, MAPE, Max AE metriklerini kullanmıştır. Sadece Temmuz 1990 – Şubat 2015 arasındaki ons altın / INR kapanış verileri kullanılmıştır. Çalışmada ARIMA (0,1,1) modelinin Hindistan altın fiyatları için en uygun ARIMA modeli olduğu ve son 1 aylık verinin şimdiki altın fiyatına önemli bir etkisi olduğu sonuçlarına varılmıştır (Tripathy, 2015).

Riazuddin, altın fiyat tahmini çalışmasında 2010-2020 yıllarındaki spot altın, spot gümüş ile petrol fiyatları, SP500 endeksi ve MSCI EM ETF günlük fiyat verilerini kullanmıştır. PyCaret regresyon modelini kullanarak altının gelecek 2-3 haftalık periyottaki getirilerini tahmin etmiştir. Ayrıca hiperparametre optimizasyonu, aykırı değerleri kaldırma, topluluk öğrenmesi, modelleri karıştırma ve istifleme gibi veri bilimi ve makine öğrenmesi tekniklerini kullanmıştır. Elde edilen tahmin modeli ons başına yaklaşık 39 USD'lik bir sapmaya (%2,3) sahiptir (Riazuddin, 2020).

Wang vd., aşırı öğrenme makinesi (Extreme learning machine, ELM) tabanlı, “genetik algoritma düzenleme çevrimiçi aşırı öğrenme makinesi” (GA-ROSELM) adını verdikleri bir altın fiyat tahmin modeli geliştirmişlerdir. Girdi değişkenleri olarak gümüş, SP500 endeksi, petrol ve altından oluşan 8 farklı veri seti kombinasyonu oluşturulmuştur. Ekip, mevcut gümüş, SP500, petrol ve son 5 günün altın fiyatını

içeren veri setinin AIC değerlendirmesinde daha iyi sonuçlar verdiğini tespit etmişlerdir. Ayrıca geliştirilen model, ARIMA, SVM, BP, ELM ve OS-ELM modellerinden altın tahmini konusunda daha üstündür (Wang vd., 2021).

Ghosh vd., Hint hisse piyasasında UKSB kullanarak hisse senedi fiyat tahmini konusunu incelemişlerdir. Yöntem olarak bir şirketin gelecekteki büyüme tahminini analiz etmek için UKSB modeli ve şirketlerin net büyüme hesaplama algoritmasını kullanan bir çerçeve üzerinde çalışılmıştır. Veri seti olarak Bombay Borsası'nda belirlenen firmalara ait günlük hisse senetleri kullanılmış olup çalışma sonunda şu sonuçlara varılmıştır: Belirli bir sektördeki şirketler aynı büyüme hızının yanı sıra aynı bağımlılıklara da sahiptir. Tüm sektörler için hata seviyesinin, daha fazla geçmiş veri göz önüne alınarak oluşturulan veri setleriyle önemli ölçüde düştüğü gözlemlenmiştir. Daha fazla sayıda veri seti ile eğitime ek olarak kapanış fiyatıyla doğrudan ilişkili olmayan diğer parametreleri (örneğin yatırımcı duyarlılığı, seçim sonucu, jeopolitik istikrar) dahil etmek, tahmin doğruluğunu artırabilir (Ghosh vd., 2019).

He vd., UKSB-CNN modeline dayalı altın fiyat tahmini konusunu incelemişlerdir. Yöntem olarak UKSB, evrişimli sinir ağı (CNN) ve dikkat mekanizmasından oluşan bir entegrasyon modeline (UKSB-Attention-CNN ile ifade edilir) dayanan yeni bir altın fiyatı tahmin yöntemi üzerinde çalışılmıştır. Veri seti olarak ons altının USD cinsinden 1978-2019 arasındaki günlük fiyatları kullanılmış olup çalışma sonunda şu sonuçlara varılmıştır: Veri kümesi üzerinde yapılan kapsamlı deneylerle, önerilen yaklaşımın diğer geleneksel finansal tahmin yöntemlerinden daha iyi performans gösterdiği tespit edilmiştir (He vd., 2019).

Livieris vd., altın fiyatı zaman serisi tahminleri için bir CNN-UKSB modeli konusunu incelemişlerdir. Yöntem olarak UKSB ve evrişimli sinir ağı üzerinde çalışılmıştır. Veri seti olarak ons altının Ocak 2014 - Nisan 2018 dönemindeki USD cinsinden fiyatları kullanılmış olup çalışma sonunda şu sonuçlara varılmıştır: Ön deneysel analiz, ek evrişimli katmanlarla birlikte UKSB katmanlarının kullanılmasının, tahmin performansını artırmada önemli bir destek sağlayabileceğini göstermiştir (Livieris vd., 2020).

Mbah vd., kireçtaşı fiyat değişimlerini simüle etmek ve tahmin etmek için UKSB ve ARIMA kullanımı konusunu incelemişlerdir. Yöntem olarak TYSA ve otoregresif entegre hareketli ortalama (ARIMA) olarak iki tahmin modeli, aynı zamanda bu

modeller üzerinde farklı katmanlar ve parametreler ekleyerek performansta iyileştirme üzerinde çalışılmıştır. Veri seti olarak günlük kireç taşı fiyatlarının Ocak 2014 - Nisan 2020 dönemindeki verileri kullanılmış olup çalışma sonunda şu sonuçlara varılmıştır: ARIMA modelinin doğruluğu %95,7 iken TYSA modelinin doğruluğu %91,8'dir. Buna göre ARIMA modeli TYSA modelinden daha iyi performans göstermiştir (Mbah vd., 2021).

Vidal ve Kristjanpoller, CNN-UKSB yaklaşımını kullanarak altın volatilité tahmini konusunu incelemişlerdir. Yöntem olarak önceden eğitilmiş bir VGG-16 ile CNN-UKSB kombinasyonuna dayanan bir mimari, paralelde farklı gecikme süreleri ekleyerek modelin zaman algısını ve yapısını oluşturması üzerinde çalışılmıştır. Veri seti olarak Nisan 1968 - Ekim 2017 dönemindeki ons altının USD cinsinden fiyatları kullanılmış olup çalışma sonunda şu sonuçlara varılmıştır: Önerilen model, normal bir UKSB ağına ve GARCH'a göre sonuçları sırasıyla %18 ve %37 oranında iyileştirmektedir. Model Güven (MCS) ile hibrit modelin tahmininde önemli bir gelişme belirlenmiştir. Bu araştırmanın temel önemi, herhangi bir zaman serisi tahmin görevi için çeşitli bilgi kaynaklarını işleyebilen yeni bir mimari tipinin uygulanmasıdır (Vidal ve Kristjanpoller, 2020).

Vidya ve Hari, derin öğrenme tekniklerini kullanarak altın fiyat tahmini ve modelleme konusunu incelemişlerdir. Yöntem olarak CNN destekli UKSB ağı üzerinde çalışılmıştır. Veri seti olarak Dünya Altın Konseyi'nden toplanan altın fiyatları kullanılmış olup çalışma sonunda şu sonuçlara varılmıştır: Önerilen mimari, en iyi finansal tahmin yöntemi olarak ARIMA, kovaryans matris tahmini, derin regresyon ve SVR'den daha kullanılabilir bir yöntemdir. Ayrıca, model olarak UKSB bileşeni dışında çift yönlü UKSB gibi farklı TYSA türlerinin kullanılması ile daha iyi sonuç alınabilir (Vidya ve Hari, 2020).

Wu vd., önde gelen göstergelerle grafik tabanlı bir CNN-UKSB hisse senedi fiyatı tahmini algoritması konusunu incelemişlerdir. Yöntem olarak hisse senedi fiyatının daha doğru bir tahminini elde etmek için CNN ve UKSB'yi birleştiren yeni bir çerçeve yapısı (stok dizi dizisi evrişimli UKSB (SACLSTM) olarak adlandırılmıştır), bir dizi tarihsel veri ve öncü göstergelerin (opsiyon ve vadeler) oluşturulup CNN çerçevesinin giriş görüntüsü olarak kullanımı, evrişim katmanı ve havuz katmanı aracılığıyla belirli özellik vektörlerinin çıkarılması üzerinde çalışılmıştır. Veri seti olarak ABD ve

Tayvan'daki on hisse senedi fiyatı kullanılmış olup çalışma sonunda řu sonuçlara varılmıştır: Önceki yöntemlerle doğrudan karşılaştırıldığında, bu makalede önerilen algoritmanın tahmin performansı daha iyi sonuçlar vermektedir (Wu vd., 2021).

Zhang vd., bir UKSB-P sinir ağı modeli kullanarak yeni bir Bitcoin ve altın fiyat tahmin yöntemi konusunu incelemişlerdir. Yöntem olarak Bitcoin ve altının değerlerini tahmin etmek için bir UKSB-P sinir ağı modeli, yüksek frekanslı gürültü bileşenlerinin fiyatlar üzerindeki etkisini azaltmak için bir dalgacık dönüşümü uygulaması üzerinde çalışılmıştır. Veri seti olarak 9/11/2016 ile 9/10/2021 arasında Bitcoin ve altının tarihsel fiyat serileri kullanılmış olup çalışma sonunda řu sonuçlara varılmıştır: Önerilen model, gelecekteki fiyatlandırmayı tahmin ederken yüksek bir doğruluk derecesine sahiptir. Ayrıca, UKSB-P modeli, doğruluk ve kesinlik açısından hem geleneksel UKSB modellerinden hem de diğerk zaman serisi tahmin modellerinden daha iyi performans göstermektedir (Zhang vd., 2022).

2. KAVRAMSAL ÇERÇEVE

2.1 Ekonomi

Ekonomi, k t kaynaklarla sınırsız ihtiya ların karřılanmasını inceleyen sosyal bilim dalıdır. Ayrıca t ketim,  retim, deęiřim, gelir, kalkınma ve b y me gibi kritik sosyal konuları da inceler. D nyadaki sınırlı kaynaklar, insanları t ketim se enekleri arasında karar vermeye itmektedir. Bu nedenle ekonomi “se im bilimi” olarak da anılmaktadır (G neř ve Aydemir, 2005). İhtiya lar, faydalar,  retim, kaynak, tercihler, kıtlık,  r nler, deęer veya alternatif deęerler yaratmak, ekonominin temellerini oluřturur. Ekonomi, bireyleri, řirketleri,  lkeleri ve hatta t m d nyayı u tan uca birbirine baęlayan bir aędır. İ  ekonomi ve piyasalar, dıř d nyanın geliřmiř ekonomilerinin performansından b y k  l  de etkilenir.  zellikle g n m zde ABD ekonomisi dięer ekonomileri de etkilemektedir. Bunun nedeni, ABD'nin d nya ekonomisinde b y k bir paya sahip olmasıdır. Tabii sadece ABD'de deęil, dięer geliřmiř  lkelerde de ekonomik g stergeleri incelemek detaylı bir ekonomik analiz oluřturacaktır.  rneęin ABD'deki kriz d nemleri d nya piyasalarını b y k  l  de etkilemiř ve hisse senedi fiyatlarında b y k d ř řlere neden olmuřtur. K resel ekonomiyi inceledikten sonra,  lke ekonomisinin makro ekonomik g stergelerine bakılarak ekonomik analize devam edilir. Unutulmamalıdır ki  lke ekonomisinin makro ekonomik g stergelerini etkileyen en  nemli fakt r siyasi istikrar ve iyi siyasi y netimdir. Bu g stergeleri iyi incelemek ve yorumlamak  ok  nemlidir.

Ulusal ekonomi analizi yapılırken sıklıkla kullanılan makro ekonomik g stergeler ařaęıdaki gibidir.

- Enflasyon Oranı
- Faiz Oranı
- İstihdam
- Yıllık B y me Oranları
- Gayrisafi Milli Hasıla / Gayrisafi Yurt İ i Hasıla
- B t e A ıęı
- D viz Kuru ve D viz Rezervi
- Yabancı Sermaye

2.1.1 Ekonomik göstergeler

Ekonomik göstergeler, finans piyasalarında genel olarak kullanılan bir kavramdır. Piyasayı incelemek için analistler teknik ve temel olmak üzere iki analiz uygularlar. Temel analiz, para ve sermaye piyasası oyuncularının yani bireysel ve kurumsal yatırımcıların kullandığı yöntemlerden biridir. Kısa vadeli kararlar almak için kullanılan teknik analiz yöntemlerinin aksine, orta ve uzun vadeli kararlar genellikle temel analiz yöntemleri kullanılarak alınır. Elbette bu yaklaşım döviz piyasası için de geçerlidir. Birçok paritenin kaldıraçlı olduğu Forex piyasasında yatırımcılar bu yöntemleri kullanarak hangi para biriminin yükselip hangilerinin düşeceğini tahmin edebiliyor. Temel analiz yöntemlerini kullanarak, para biriminin işlem gördüğü veriler, bir ülkenin gelecekte hangi fiyat seviyesinde ticaret yapması gerektiğini tahmin etmek için kullanılabilir. Bu verilerden bazıları; Ülkedeki enflasyon, ülkenin merkez bankasının açıkladığı politika faizi veya ülkenin cari açığı/fazlası gibi makroekonomik verilerdir.

Teknik analiz, geçmiş fiyat hareketlerine bakarak gelecekteki fiyat hareketlerini tahmin etme yöntemi olarak açıklanabilir. Merkez Bankası sözlüğünde teknik analiz terimi, “Fiyat ve hacim gibi göstergelere dayalı olarak geçmiş piyasa hareketlerinin analiz edilerek geleceğe yönelik fiyat tahminlerinin hazırlanması” olarak tanımlanmıştır. Bunu yapmak için çeşitli grafik oluşumlar ve istatistiksel yöntemler kullanılır. Grafiklerdeki geçmiş fiyat hareketlerinden kaynaklanan oluşumların geleceğe yönelik göstergeler olduğu varsayımına dayanmaktadır, bu nedenle bu tür oluşumlar ticaret için gösterge olarak kullanılabilir. Analiz yapan yatırımcılar, volatilite, vade, işlem hacmi ve genel piyasa durumunu da dikkate almalıdır. Bu nedenle yatırım kararı vermek için teknik analiz tek başına yeterli olmayıp, temel analiz ile kullanılması daha sağlıklı bir yatırım kararı vermek açısından önemlidir. Örneğin, bu tür bir analiz, fiyatların yükselmeye başladığı noktalar olan tarihi düşüklerin “destek noktaları” olduğunu, dolayısıyla bu noktaların (temel çizgilerin) satın alma için bir işaret olduğunu gösterir. Geçmiş yüksek fiyatlar da aynı mantıkla "direnc" noktalarıdır ve dikkate alınması gereken beklenen satış noktalarıdır. Finansal araçların fiyatları arz ve talebe göre belirlenmekte olup, beklentilere göre fiyat değişimleri olmaktadır. Bu bağlamda teknik analiz, bir finansal aracın işlem hacmi ve fiyat grafiğinin zaman ekseninde analizidir. Teknik analiz, ekonomik bir

yapıdaki tüm bilgi ve haberlerin alıcı ve satıcılar tarafından ilgili finansal aracın fiyatlarına yansıtıldığını varsayar. Teknik analiz yaparken yatırımcılara yardımcı olabilecek bazı araçlar vardır. Bu araçlar sayesinde, tüccarlar ilgili enstrümanın tablosunda fiyat yönünü ve olası ticaret seviyelerini tahmin edebilirler. Özellikle trend analizi kısa, orta ve uzun vadede fiyatın yönünü belirlemede temel bir rol oynamaktadır. Trendi tespit etmek ve trendin gücünü ölçmek için hareketli ortalamalar vb. yöntemler kullanılır. Öte yandan, teknik analiz sırasında belirli fiyat hareketlerinin meydana gelmesi, grafikteki oluşumları tespit ederek tahmin yapmayı kolaylaştırabilir.

2.1.2 Teknik analiz göstergeleri – İndikatörler

Teknik analiz göstergeleri, söz konusu finansal ürünün gelecekteki fiyatı hakkında bize ipuçları verir. Teknik analizde en çok kullanılan göstergeler şunlardır;

- MA – Hareketli ortalamalar
- MACD – Yakınsayan ve ıraksayan hareketli ortalama
- LMACD – Logaritmik yakınsayan ve ıraksayan hareketli ortalama
- RSI – Göreli Güç Endeksi
- CCI – Emtia Kanal Endeksi
- Bollinger Bantları
- Momentum
- Stokastik
- Parabolik SAR

2.2 Yatırım Araçları

İnsanların doğal eğilimlerinden biri birikimlerini güvenli bir şekilde değerlendirmektir ve genellikle kısa vadede kendilerine gelir getirecek yatırım araçlarına başvururlar. Yatırım araçları, belirli bir değere sahip bir kaynaktan gelir elde edilmesi anlamında ifade edilen bir kavramdır. Belli bir değeri olan bu kaynaklardan önce altın, para, gayrimenkul gibi kazançlar gelir. Bu gelir kaynakları doğru kullanılırsa orta ve uzun vadede insanlara gelir sağlar. İnsanların yatırım yaparken ilk hedeflerinden biri risk almadan gelir elde etmektir. Bunun için piyasalardaki en güvenilir yatırım araçlarına

başvururlar. Yatırımcılar tarafından tercih edilen en risksiz temel yatırım araçları şunlardır:

Altın: Altın, insanlar tarafından en çok yatırım yapılan kaynak olarak onaylanmıştır. Uzun vadeli gelir elde etmek için altına yatırım yapmak mantıklı kabul edilir. Birçok çeşidi bulunan altına güvenle yatırım yapmak mümkündür. Evinde altın olmasını istemeyenler için bankalarda altın hesapları bulunmaktadır.

Döviz: Ayrıca dövize yani çeşitli para birimlerine yatırım yaparak da para kazanılabilir. Ancak bu durumda yatırımcılar risk aldıklarını unutmamalıdır. Bu para birimleri bazen yükselen ancak ne zaman düşeceği belirsiz olan yatırım araçlarıdır.

Hisse senetleri: Hisse senetleri de bu yönde getirileri değerlendirmek isteyenler için tercih edilen yatırım araçlarından biridir. Hisse senedi satın alarak birçok şirketle ortaklıklar kurmak mümkündür. Bir ortak şirket büyüyüp geliştiğinde hisseye sahip olan kişinin geliri de artar.

Gayrimenkul: Mülk aynı zamanda insanlara gelir sağlayan önemli bir yatırım aracıdır. Gayrimenkul satın alırken kişilerin farklı özellikleri göz önünde bulundurması gerekir. İlk alışveriş noktasına ulaşım kolaylığı ve okul ve hastanelere yakınlığı mülkün değerini artıracaktır.

Dijital para birimi: Son zamanlarda dijital para piyasası, insanların talep ettiği bir yatırım aracı olarak ortaya çıkmıştır. Bu yatırım araçları, internet üzerinden para alıp satılmasına olanak tanır. Ancak bu yatırım aracı da kendi risklerini barındırır. Bu konuda yeterli bilgiye sahip olmayan kişilerin küçük sermaye ile bu işe başlamaları teşvik edilmektedir.

Bono ve tahviller: Bono ve tahviller orta ve uzun vadede yatırımcıların gelir kaynaklarından biridir. Bu kaynaklar genellikle risksiz oldukları için insanlar tarafından tercih edilmektedir.

Vadeli mevduat: Vadeli mevduattan, vade sonunda ne kadar kar elde edileceği bellidir ve vade sonuna kadar faize tabi değildir. Risksiz bir yatırım aracı olarak kabul edilir. Gelecekteki risklerden elde edilen gelir vergiye tabidir.

Forex: Ülkemizde Forex işlemleri Sermaye Piyasası Komisyonu'nun (SPK) kontrolündedir. Forex ticareti çeşitli şirketler aracılığıyla gerçekleştirilir. Güvenilir Forex şirketleri lisans belgelerine sahiptir ve verdikleri hizmet, eğitim, kaldıraç oranları gibi detaylara dikkat ederler. Bu piyasada ülke parası, hisse senedi ve emtia gibi varlıkların alım satımı gerçekleşir.

Repo: Repo, bir menkul kıymetin başka bir kişi veya kuruma belirli bir fiyattan satılmasıdır. Daha sonra satılan varlığı gelecekte belirli bir fiyattan geri alır. Repo işlemleri genellikle bir gün içinde yapılır, ancak repo süreleri bir aydan uzun olabilir. Repo, devlet tahvili, bono ve bono gibi varlıkların ticaretini sağlar.

Yatırım fonları: Fon, yatırımcılarından birbirleri için topladıkları paralar nedeniyle hisse senedi, tahvil/tahvil, repo, emtia, kira gibi çeşitli finansal araçlar kullanılarak oluşturulan portföy kayıtlarına denir. Ortak finansmanda, yatırımcı tasarrufları bir portföy yöneticisi tarafından toplanır ve yönetilir. Yatırımcılar ayrıca fon portföyünden hisse satın alarak fona katılırlar. Belgenin alınmasından sonra, yatırımcı fon portföyüne ortak olacaktır. Hisse senedi fonları, dalgalı para birimleri, altın para birimleri, gayrimenkul yatırım fonları ve borsada işlem gören para birimleri dahil olmak üzere karşılıklı finansman çok çeşitlidir. Bu para, Sermaye Piyasası Komisyonu (SPK) tarafından belirlenen esaslara bağlı akredite kuruluşlar tarafından oluşturulmaktadır.


2.3 Altın

Yüzyıllardır mücevher, koruma ve değişim aracı olarak kullanılan altın, değerli metaller arasında farklı bir yere sahiptir. İşlenme kolaylığı, elektriksel ve ısı iletkenlik, asit direnci gibi mükemmel fiziksel ve kimyasal özellikleri nedeniyle eski çağlardan beri ilgi gören bu özel cevher, günümüz iş verimliliği ve finans piyasalarının vazgeçilmez bir parçası haline gelmiştir.

Lidyalılar M.Ö. 580'lerde ilk altın ayarlı sikkeleri (para) basmışlardır. Başkentleri Sardes'in içinden geçen Paktalos Çayı (Manisa- Salihli-Sart) kumlarından elde ettikleri altınlarla bu sikkeleri yapmışlardır. Altın, 1870-1930 yılları arasında para sisteminin temeli olmuş ve Bretton-Woods sisteminde (1944-1973) dolara tam dönüşüm için önemli bir rezerv enstrümanı olmuştur (Aytekin vd. 2000). Bu dönemde

tüm para birimlerinin dolar endeksli olması dünya piyasalarında gerilim yaratmıştır. Bu gerilimin en önemli nedenleri zincirleme sırayla şöyle açıklanabilir: ABD dışındaki ülkelerde dolar rezervlerinin artması, ABD'nin likidite açığını azaltmak için altın rezervlerini harcaması, bundan dolayı dolara güvenin azalması, ülkelerin ellerindeki doları altına çevirmek istemesi ve doların değerinin düşmesi. Sonuçta 1971'de ABD'nin duyurusuyla sabit kur sistemi sona ermiştir (Yatırım Kredi, 2022). 1980'ler ve 1990'lar finansal piyasaların hızla geliştiği ve altının bir yatırım aracı olarak çekiciliğini kaybettiği yıllar olmuştur. Ancak 2000'li yıllarda finans piyasasındaki çalkantı ve belirsizlik nedeniyle yeniden yatırımcıları çekmeye başlamıştır.

Şu anda mevcut olan en iyi tahminler, tarih boyunca yaklaşık 205 bin 238 ton altının çıkarıldığını ve bunun yaklaşık üçte ikisinin 1950'den beri çıkarıldığını göstermektedir. Altın neredeyse yok edilemez olduğundan, bu, bu metalin neredeyse tamamının hala şu veya bu şekilde bulunduğu anlamına geliyor. Çıkarılan tüm altın bir araya getirilseydi, ortaya çıkan saf altın küpün bir kenarı sadece 22 metre uzunluğunda olacaktı (Şekil 2.1).




Şekil 2.1 : Yer altı ve yer üstü altın rezervleri (Metals Focus, Refinitiv GFMS, US Geological Survey, WGC)

Dünya altın rezervinin başını yaklaşık %46 ile mücevherat çekmektedir. Mücevheratı %22 ile külçe ve sikkeler (altın destekli ETF'ler dahil), %17 ile merkez bankaları ve %15 ile altının diğer formları izlemektedir. Tespit yer altı rezervleri yaklaşık 50,000 t civarındadır. 2011 yılı sonunda ABD (FED) merkezi altın rezervlerinde ön sırada yer almaktadır, sırasıyla Almanya (Bundesbank), İtalya, Fransa ve Çin Merkez Bankası izlemektedir (Çizelge 2.1).

Çizelge 2.1 : Dünya altın maden rezervleri.

Ülke	Rezerv (ton)	Ülke	Rezerv (ton)	Ülke	Rezerv (ton)
ABD	3000	Gana	1000	Rusya	5300
Arjantin	1600	Endonezya	2600	Güney Afrika	3200
Avustralya	10000	Kazakistan	1000	Özbekistan	1800
Brezilya	2400	Meksika	1400	Türkiye	1446
Kanada	1900	Papua Yeni Gine	1000	Diğer Ülkeler	8554
Çin	2000	Peru	2100		
Toplam					50000

2010 yılında yapılan araştırmaya göre altın üretiminin en çok olduğu ilk beş ülke: Çin, ABD, Avustralya, Güney Afrika, Rusya, altın talebinin en yüksek olduğu beş ülke Hindistan, Çin, ABD, Türkiye ve Suudi Arabistan'dır (Şekil 2.2).




Şekil 2.2 : Dünya altın üretim oranları.

2.3.1 Türkiye'de altın


Cumhuriyet döneminin ilk yerli altın üretimi, 2001 yılında İzmir-Bergama'daki Ovacık Altın Madeni'nin yabancı işletmeden işletme hakları devralınarak başlamıştır. Ülkemizde üretim 1,4 ton/yıl seviyesinde başladı, ancak izleyen 10 yılda yeni açılan altın madenleri ve kapasite iyileştirmeleri ile 20 ton sınırını aşmıştır. 2013 yılında 33 tona, 2019 yılında ise 37 tona ulaştı. Halihazırda 18 projede altın üretimi faaliyet göstermektedir. Türkiye'de altın yatakları olmasına rağmen, çıkarılan altının tüketim için yeterli olmaması nedeniyle Türkiye önemli bir altın ithalatçısıdır. Türkiye son 20

yılda 156 ton altın ithal etti. Altın madenleri genellikle özel ve tüzel kişiler tarafından işletilmektedir. Altın madenlerinde üretilen altın saf değildir. Genellikle %90'ın üzerinde altın + gümüş + bakır + çinko vb. elementler içeren dore altın olarak imal edilmektedir. Bu saf olmayan altın, altın rafinerilerinde saflaştırılır ve sertifikalı altın olmak için %99,995 veya daha yüksek saflıkta saf altına dönüştürülür. Altın kuyumculuk sektöründe de piyasada %99,995 saf altın işlem görmektedir. Türkiye'de ikisi LBMA (İstanbul Altın Rafinerisi ve Nadir Metal Rafinerisi) ve ikisi Borsa İstanbul (Onsa Rafinerisi ve Ahlatcı Metal Rafinerisi) tarafından akredite edilmiş dört altın rafinerisi bulunmaktadır. Türk yatırımcı altın yatırımını TL ile yapar ancak dünyadaki altın fiyatları dolar ile belirlenmektedir. Dünyada altın fiyatı yükselirken, Türkiye'de dolar kuru yükselince altın yatırımcısı büyük kazançlar elde edebilir. Dünya genelinde altının fiyatı düştüğünde ve TL ABD doları karşısında değer kaybettiğinde, TL ile altına yatırım yapanlar çok büyük kayıplara uğrarlar. Bu iki durum arasındaki durumlarda ya USD/TRY kuru ya da uluslararası altın değeri düşebilir, sabit kalabilir ya da yükselebilir. Bu durumda, kazançlar veya kayıplar olabilir.



Şekil 2.3 : Türkiye'nin dünya altın üretimindeki payının grafiği


2001'den 2019'a kadar Türkiye'nin toplam altın üretimi yaklaşık 342 tondur (Şekil 2.4). 2012 yılından bu yana küresel metal fiyatlarında yaşanan düşüşe paralel olarak altın üreticilerimiz de altın fiyatlarının yükselmesinin beklendiği dönemde üretimi azaltmak ve üretim kapasitesini artırmak için yatırımlarını ertelediler. Türkiye'nin altın üretimi, dünya üretiminin yaklaşık %1,05'in oluşturmaktadır (Şekil 2.3).




Şekil 2.4 : Türkiye altın üretimi grafiği (ton)

Çizelge 2.2 : Madenlerin bulunduğu yerler ve üretim yapan şirketler (Yücel, 2020)

Madenin Bulunduğu yer	Şirket	Üretime Geçtiği Yıl
İzmir Ovacık	Koza	2001
Manisa Sart	Pomza	2002
Uşak Kışladağ	Tüprag	2006
Gümüşhane Mastra	Koza	2009
İzmir Çukuralan	Koza	2009
Erzincan Çöpler	Alacaer	2010
İzmir Efemçukuru	Tüprag	2011
Eskişehir Kaymaz	Koza	2011
Niğde Bolcardağ	Gümüştaş	2012
Gümüşhane Midi	Yıldızbakır	2012
Kayseri Himmetdede	Koza	2013
Fatsa Altıntepe	Bahar	2015
Sivas Bakırtepe	Demirexport	2015
Konya İnlice	Esan	2015
Balıkesir Kızıltepe	Zenit	2017
Çanakkale Lapseki	Tümad	2018
Balıkesir İvrindi	Tümad	2019
Kayseri Öksüt	Öksüt	2020




Şekil 2.5 : Altının kullanım alanına göre dağılımı (WGC, 2019).




Şekil 2.6 : Parasal değer bazında Türkiye altın dış ticareti.

Şekil 2.7 ve Şekil 2.8'den 2013 yılından itibaren ithalatın değer ve miktar bazında arttığını görebiliriz. Öte yandan, ihracat parasal değer ve miktar bazında gerilemiştir.




Şekil 2.7 : Miktar bazında Türkiye altın dış ticareti.



Şekil 2.8 : Ülkelere göre 2019'da yapılan altın ihracatları.


2019 verilerinde; TÜİK verileri, dış ticaretin ağırlıklı olarak "standart dışı işlenmemiş altın ve standart işlenmemiş altın" kategorisi miktar ve değerlerinde gerçekleştiğini gösteriyor. Toplam değeri yaklaşık 6 milyar dolar olan "standart dışı işlenmemiş altın" ithalatında ilk sırayı Irak, Birleşik Arap Emirlikleri, Almanya ve yaklaşık 6 milyar dolar değerinde "BAE, İsviçre, İngiltere, Avustralya'nın aldığı görülmektedir. "İngiltere, BAE, İsviçre'nin toplam 2 milyar dolarlık standart ham altın kategorisinde diğer ülkelerin önünde yer aldığı bilinmektedir. Bu bilgilerden, 2019 yılında ithalat ve ihracatın toplam ticaret değerinin 13 milyar doları aştığı sonucuna varılabilir.



Şekil 2.9 : Türkiye altın ithalat-ihracatının miktar bazında oranları (YerTutucu2).


1993 yılında altın ve diğer değerli madenlerin ithalat ve ihracatının yapılabilceği açıklandı (Resmi Gazete, 21.03.1993, s. 21531). 1995 yılında İstanbul Altın Borsası faaliyete geçirildi. Borsa İstanbul A.Ş. 2013 yılında yeni bir borsa olarak hizmete girdikten sonra, altın bu borsanın Kıymetli Madenler ve Kıymetli Taşlar Piyasası'nda işlem görmeye başladı. Borsada standart ve standart dışı işlenmemiş altın alıp satma serbest hale getirildi. Ayrıca yurt içinde madencilikten elde edilen dore bar, granül ve diğer formlardaki altınlar da rafinasyon ve düzeltme raporlarının ardından "Kıymetli Madenler Piyasası'nda işlem görmektedir. Yatırım fonlarına ait altınlar ve Merkez Bankası zorunlu karşılıkları da Borsa İstanbul AŞ'de tutulmaktadır. (Borsa İstanbul, 2015). Borsa İstanbul verilerine göre, yıllara göre ithal edilen altın miktarının değişimi Şekil 2.11'deki grafikte verilmektedir. Bu ithalat miktarlarının TÜİK verilerinden çok farklı olması muhtemel bilanço tekniklerinden kaynaklanmaktadır. Altının iç piyasadaki ticaret hacmi 2019 yılında 159 ton, 2020 yılı ortalarında 137 ton olarak gerçekleşti. Yapılan yerli cevherden elde edilen "Kapı demiri, granül vb." Altın ayrıca rafineriler ve ayarlamalar hakkında raporlar aldıktan sonra "kıymetli metal piyasasında" işlem görmektedir. Yatırım ortaklıklarına ait altınlar ve merkez bankası tarafından zorunlu tutulan rezervler de Borsa İstanbul AŞ'de saklanmaktadır (Borsa İstanbul, 2015). Şekil 20'deki grafik, Borsa İstanbul verilerinden ithal edilen altının yıllık değişimini göstermektedir. Bu ithalatın TÜİK verilerinden önemli ölçüde farklılık göstermesi muhtemelen bilanço yönteminden kaynaklanmaktadır. Sonuç

olarak, iç piyasada altın ithalatı 2019 yılında 159 tona, 2020 ortalarında ise 137 tona ulaştı (Şekil 2.11).



Şekil 2.10 : Borsa İstanbul altın ithalat değerleri (ton, 2021).

Altın; enflasyondan korunma, siyasi/ekonomik ortamda kredibilite ve yatırım aracı olarak önemini korumaktadır ve bu nedenle merkez bankası rezervlerinde önemli bir yer tutmaktadır (Vural). Merkez bankası dinamik bir finansman aracı olarak hareket ettiğinden, 2020 itibariyle rezervler Şekil 2.10'da gösterilmektedir. Her ülke, finansal güvenlik ve kriz ihtimaline karşı tasarruf için çeşitli borsa ve kurumlarda altın tutabilir.




Şekil 2.11 : Merkez bankalarının kasalarındaki altın rezervleri (Goldhub, 2020).

Ağustos 2020 itibariyle dünyadaki merkez bankalarının/kamu kurumlarının toplam rezervleri 35.017,79 tondur. Şekil 2.11, öne çıkan ülkelerin miktarını göstermektedir. Türkiye 583 ton rezerv (envanter) ile 12. sırada yer almaktadır.

2.3.2 Küresel piyasada altın

Küresel piyasada altın fiyatları 1978'lerin başında 200\$/ons civarındayken 1980'de 600\$'ın üzerine çıkmış ve 1985'te 300\$ civarına düşmüştür. 1990'larda ortalama fiyat 350 dolar civarındayken 2000'lerin başında 300 doların altına düştü. 2002'den beri tekrar 300 doları aştı ve 2009'un dördüncü çeyreğinde normal kurslarda 1.000 doları aştı. 1 Eylül 2011 tarihinde 1920 dolar seviyesine ulaşmış ve 2012 yılında ortalama fiyat 1.700 doların biraz altında kalmış ve düşüş eğiliminde olmuştur. 2019'un üçüncü çeyreğinde 1.400 doların üzerinde, 2020'nin ilk çeyreğinde 1.600 doların biraz altında ve ikinci çeyreğinde ortalama 1.700 doların üzerinde işlem gördü. Huzursuz atmosfer nedeniyle Ağustos 2020'nin başında 2.000 dolarla zirve yaptı. Son yıllardaki bu durum, dünya ekonomisindeki durgunluk ve arz ve talep piyasasında kilit oyuncu olan Çin'in yüksek oranda büyümemesi ve metal fiyatlarının düşmesiyle açıklanabilir. 2020'deki olağanüstü fiyat artışının nedeni, Covid-19 salgınının süregelen "küresel kriz" üzerindeki etkisi ve dolayısıyla güvenilir bir yatırım aracı olarak altına olan talebin artması olarak yorumlanabilir.

AISC-Her şeyi Sürdürme Maliyetleri'nin (All-in sustaining costs) dünya genelinde 2012'nin dördüncü çeyreğinde 1.250 dolardan 2019'un dördüncü çeyreğinde 1.000 dolara düştüğü bilinmektedir. (Çitilli, 2020). 2020 itibarıyla 1000 doların biraz altında olduğu bilinmektedir (Hamilton, 2020). Bu nedenle talep piyasasının fiyat oluşumu ve seyri üzerindeki etkisinin yanı sıra bu gelişmeler de göz önünde bulundurulmalıdır. Son yedi yıl incelendiğinde, 2015 yılında yavaşlayan altın fiyatının, küresel salgın ve kriz ortamının etkisiyle 2020 yılında toparlanmaya başladığı ve zirve yaptığı görülmektedir.



Şekil 2.12 : Spot ons altın / USD fiyat grafiği.

2.4 Altını Etkileyen Majör Faktörler

Günün 24 saati dünya çapında işlem gören altın fiyatını etkileyen çok sayıda faktör vardır ve altın fiyatını yönlendiren temel ekonomik faktörler çoğu insan tarafından büyük ölçüde bilinmemektedir.

Bu nedenler sayısız olmakla birlikte, altın fiyatını etkileyen birkaç iyi bilinen faktörü tespit edebiliriz. Bu faktörler arasında ABD para politikası, altının borsayla ilişkisi, arz ve talep ve siyasi istikrarsızlık sayılabilir.


2.4.1 ABD Dolar Endeksi (DXY)

ABD Dolar Endeksi, altı dünya para biriminden oluşan bir sepete karşı doların değerini ölçmek için kullanılır- Euro, İsviçre frangı, Japon yeni, Kanada doları, İngiliz sterlini ve İsveç kronu. Endeks, 1973'te Bretton Woods Anlaşması'nın feshedilmesinden kısa bir süre sonra 100 bazında kuruldu ve o zamandan beri değerler bu tabana göre belirlendi. Endeksin değeri, doların küresel piyasalardaki değerinin adil bir göstergesidir. Aşağıdaki seçili para birimlerine göre doların değerinin ağırlıklı geometrik ortalamasıdır:

Çizelge 2.3 : Dolar endeksi para birimleri ağırlık oranları.

Para Birimi	Kısaltma	Ağırlık
Euro	EUR	%57,6
Japon yeni	JPY	%13,6
İngiliz sterlini	GBP	%11,9
Kanada doları	CAD	%9,1
İsveç kronu	SEK	%4,2
İsviçre frangı	CHF	%3,6

Amerikan Dolar Endeksi Vadeli İşlemleri- Ara 2021 (DXZ1) ve ABD Dolar Endeksi (DXY) değerleri birbirine çok yakındır ve artış ve azalışlar eş zamanlıdır. Bundan dolayı çalışmada sadece DXY değeri alınacaktır. 2010-2021 zaman aralığına ait ABD Dolar Endeksi grafiği aşağıdadır.




Şekil 2.13 : 2010-2021 dönemine ait ABD dolar endeksi.

2.4.2 Kripto para

Kripto para, kriptografi ve para kelimelerinin birleşimidir. Kriptografi sayesinde, dönüştürülen para farklı kişilerin erişimine kapatılarak fonların güvence altına alınmasını sağlamaktadır. Kripto para, nakit paranın sanal ortama aktararak dijitalleştirilmiş haline denir. Kripto paraları kimin ortaya çıkardığı bilinmemektedir. 2008'de 9 sayfalık bir belge yayınlanmıştır. Belge, “Satoshi Nakamoto” takma adı kullanılarak yayımlanmıştır, ancak bu takma adın bir birey veya kuruluşa ait olduğu bilinmemektedir. Sonrasında 2009'da kripto para algoritmalarını içeren yazılımın kendisi kullanıma sunulmuştur. Kripto para piyasası, yatırımcıların geleneksel para birimleri veya diğer dijital para birimleri gibi diğer varlıklara karşı kripto para birimleri ve dijital para birimleri ile ticaret yapmalarına olanak tanıyan platformlardır. Borsalar, dijital para birimleri veya kripto para birimleri karşılığında kredi kartı ödemelerini, banka havalelerini veya diğer birçok ödeme şeklini kabul edebilir. Bir kripto para borsası, genellikle ticaret için ticaret komisyonları veya yalnızca eşleşen bir platform olarak üyelik ücreti talep eden bir piyasa yapıcı olabilir

2.4.2.1 Bitcoin

Çeşitli çalışmalarda uzun vadede Bitcoin ve altın arasında ters orantı olduğu gözlemlenmiştir. Ancak kısa vadede herhangi bir ilişki tespit edilememiştir.



Şekil 2.14 : 2010-2021 dönemi için Bitcoin / USD parite grafiği

2.4.3 Emtialar


Ekonomide ticari değeri olan tüm varlıklara emtia denir. Bunlar altın gümüş gibi değerli madenler olabileceği gibi tarım ürünleri, petrol doğalgaz gibi enerji kaynakları ve hatta hayvancılık ürünleri de olabilir.

2.4.3.1 Petrol

Siyah altın olarak da bilinen petrol, altın gibi geçmişten günümüze kadar gelen değerli emtialardan biridir. Petrolü diğer emtialardan ayıran en önemli faktörlerden biri petrole alternatif bir yapının olmaması ve kullanım alanının geniş olmasıdır. Altın ve petrolün birbirlerine alternatif olarak görülmesinin nedeni, fiyat hareketleri arasında bir ilişki kurulabilmesidir. Petrol ve altının arasındaki ilişkiyi sadece bu iki emtiayı gözlemleyerek tespit etmek doğru ve sağlıklı bir yöntem değildir. Bu korelasyonu incelerken ABD doları, enflasyon, ekonomik büyüme, altın madenciliği vb. performans kriterleri de aynı oranda incelenmelidir.

West Texas Intermediate Ham Petrol

West Texas Intermediate (WTI) ham petrolü, belirli bir ham petrol sınıfıdır ve Brent ve Dubai Ham Petrol ile birlikte petrol fiyatlandırmasında ana üç kriterden biridir. Tatlı ve düşük yoğunluklu petrol sınıfında olan WTI, New York Ticaret Borsası (NYMEX) petrol vadeli işlemleri sözleşmesinin temel emtiasıdır. Esas olarak Teksas'tan elde edilir ve rafine edilmesi kolay, dünyanın en kaliteli ham petrollerinden biridir. WTI genellikle, Kuzey Denizi'nde çıkarılan petrole dayalı dünya petrol sözleşmelerinin üçte ikisi için bir petrol kriteri olan Brent ham petrolü ile karşılaştırılır.



Şekil 2.15 : 2010-2021 dönemi için WTI ham petrol fiyat grafiği

Grafik incelendiğinde ilk göze çarpan, Nisan 2020'deki sert düşüştür. 2020'nin başlarında dünyaya hızla yayılan COVID-19 salgını bunun düşüşün ana nedenidir. Petrol piyasaları ve daha geniş fosil yakıt endüstrisi üzerinde derin bir şok yaratmıştır. Salgının seyrini şiddetlendirmesi ve enerji talebinin serbest düşüşte olmasıyla birlikte, dünya petrol piyasaları, küresel arzı önemli ölçüde artırmayı vaat eden Rusya ile Suudi Arabistan arasındaki Mart 2020 “Petrol Fiyatı Savaşı” ile eş zamanlı olarak darbe aldı. Sonuç olarak, küresel petrol fiyatları onlarca yılın en dip seviyelerine düştü ve üreticiler petrollerini zararına satmak yerine karada ve denizde depolama alanı aramayı tercih ettiler. Dikkat çekici bir şekilde, WTI fiyatı, fiziksel teslimat sözleşmeleri olan tüccarlar, depolama alanı eksikliği nedeniyle ellerindeki petrolü almak için başkalarına ödeme yapmak zorunda kaldıklarından 2020 Nisan ortasında negatif bölgeye düştü.

Brent Petrol

Kuzey Denizi Brent Ham Petrol (LCO), dünya çapında petrol fiyatları için ana kriterlerden biri olarak hizmet eden bir ham petrol ticaret sınıflandırmasıdır. Kuzey Denizi Brent Ham petrol sınıfı, sırasıyla nispeten düşük yoğunluğu ve düşük kükürt içeriği nedeniyle hafif ve tatlı olarak tanımlanmaktadır.


Brent Ham Petrol, dünyanın ticareti yapılan ham petrol arzının en az üçte ikisini fiyatlandırmak için kullanılır ve bu da onu en önemli petrol göstergelerinden biri haline getirmiştir. Petrol İhraç Eden Ülkeler Örgütü (Organization of Petroleum Exporting Countries, OPEC), fiyatlandırma kriteri olarak Brent Ham petrolünü kullanmaktadır. OPEC, 14 petrol üreticisi ülkeden oluşur ve petrol fiyatlarının belirlenmesinden büyük ölçüde sorumludur.

Market Realist'te yayınlanan makaleye göre, petrol fiyatı, altın ve altına dayalı ETF'lerin fiyatının belirlenmesinde önemli bir rol oynar (Shawn, 2020). Altın gibi, ham petrolün fiyatı da ABD doları cinsinden belirlenir. ABD doları yükseldiğinde, diğer para birimlerinin yatırımcıları dolar cinsinden varlıkları daha pahalı bulduklarından, dolar cinsinden varlıkların fiyatları genellikle düşer. Altın ve ham petrol, dolar cinsinden varlıklar olduğundan, birbirleriyle güçlü bir şekilde bağlantılıdır. Altın ve petrol arasındaki bir diğer önemli bağlantı da enflasyondur.

Ham petrol fiyatları yükseldikçe enflasyon da yükseldiğini aktaran Shawn, altının enflasyona karşı iyi bir korunma aracı olduğunu belirtmiştir. Altının değeri ancak enflasyon yükseldiğinde artar. Bir diğer ilişki ise madencilik faaliyetleridir. Maden arama şirketleri de petrol fiyatlarındaki artıştan etkilenir. Petrol, madencilik araştırmalarında yaygın olarak kullanılmaktadır ve petrol fiyatlarındaki artış, madencilerin karlarını baskı altına alarak hisse fiyatlarının düşmesine neden olabilir. Altın ile petrolün ilişkisi dönem dönem güçlenip zayıflamaktadır (Shawn, 2020).

Kasım 2019 - Kasım 2020 döneminde altın: %26 değer kazanırken, WTI petrolü yatırımcısına %33 zarar ettirmiştir. Kasım 2020 - Kasım 2021 döneminde varil başına WTI petrol fiyatı %121 değerlenirken, ABD doları cinsinden altın fiyatı, %5,5 değer kaybetmiştir.


Bu dönemler dünyaya yayılan Covid-19 salgınının getirdiği ekonomik durgunluğun etkisini anlamak açısından da yararlıdır.



Şekil 2.16 : 2010-2021 dönemi için LCO Brent ham petrol fiyat grafiği.

2.4.3.2 Londra Metal Borsası Endeksi (LMEX)


Londra Metal Borsası Endeksi (LMEX), dünyanın en büyük metal borsası olan Londra Metal Borsası'nda (LME) işlem gören baz metallerin fiyat hareketlerini izleyen bir ekonomik emtia endeksidir. Bunlar altı değerli olmayan metal olan alüminyum, bakır, kurşun, nikel, kalay ve çinkodur. Londra Metal Borsası (LME), dünyanın en büyük emtia borsalarından biridir. Aynı zamanda altın ve gümüş gibi değerli metallere ilişkin vadeli işlemler ve opsiyon sözleşmeleri, LME'de işlem görmek üzere listelenmektedir. Eğilim sürekli olarak elektronik ticarete yoğunlaştığından, LME Avrupa'da kalan tek fiziksel emtia ticareti piyasasıdır. Riskleri azaltmak için vadeli işlemlere ve seçeneklere yönelen kişi ve kurumlar (hedger) ve risk alarak kısa vadeli karlar elde etmeye çalışan yatırımcılar (spekülatör), metal borsasında aktiftir.



Şekil 2.17 : 2010-2021 dönemi için LMEX endeks grafiği.

2.4.3.3 FAO Gıda Fiyat Endeksi (PFOOD)


Gıda ve Tarım Organizasyonu (FAO) Gıda Fiyat Endeksi, gıdanın ortalama fiyatını ve gıda fiyatlarının nelerden etkilendiğinin belirlendiği bir ölçüdür. Genel fiyat endeksini oluşturmak için beş gıda fiyat endeksi numarasının ortalaması alınır; Bunlar süt, tahıllar, sıvı ve katı yağlar, şeker, et gıda endeksleridir.



Şekil 2.18 : 2010-2021 dönemi için PFOOD gıda fiyat endeks grafiği.

2.4.3.4 TRCCRBTR endeksi

Thomson Reuters/CoreCommodity CRB Endeksi, aylık yeniden dengeleme ile vadeli emtia fiyatlarının aritmetik ortalaması kullanılarak hesaplanır. Endeks 19 emtiadan oluşmaktadır: Ham petrol, kurşunsuz benzin, kalorifer yağı, alüminyum, doğal gaz, altın, bakır, canlı sığır, mısır, soya fasulyesi, pamuk, kahve, kakao, şeker, yağsız domuzlar, nikel, portakal suyu, gümüş ve buğday. Bu emtialar, farklı ağırlıklarda 4 gruba ayrılmaktadır: Enerji: %39, Tarım: %41, Kıymetli Metaller: %7, Baz/Endüstriyel Metaller: %13. Çalışmada kullanılacak TRCCRBTR verisinin zaman bazlı grafiği Şekil 2.19’da verilmiştir.




Şekil 2.19 : 2010-2021 dönemi için Thomson Reuters Emtia endeksi grafiği.

2.4.3.5 Değerli madenler

Gümüş: Gümüş altın gibi doğada sınırlı sayıda bulunan değerli metaller arasında yer almaktadır ancak gümüşü altından daha farklı kılan bazı özellikleri vardır. Gümüşün

fiyatı altına oranla daha düşüktür, volatilitesi daha yükseltir, daha fazla depolama alanına ihtiyaç duyar, kullanım alanı daha çeşitlidir ve son olarak gümüşün stokları azalırken altının stokları artmaktadır. Çalışmada kullanılacak ons gümüş fiyat verisinin zaman bazlı grafiği Şekil 2.20’de verilmiştir.




Şekil 2.20 : 2010-2021 dönemi için Ons Gümüş / USD fiyat grafiği.

2.4.4 Borsalar

2.4.4.1 NQ100 endeksi


NASDAQ-100 Endeksi, New York Menkul Kıymetler Borsası'ndan sonra dünyanın en büyük ikinci borsası olan NASDAQ Menkul Kıymetler Borsası'na kayıtlı en büyük 100 şirketten oluşur. Bu endekste yer alan şirketler teknoloji, telekomünikasyon, biyoteknoloji, medya ve hizmetler gibi birçok sektörden gelmektedir. NASDAQ-100 Endeksi ilk olarak 31 Ocak 1985'te NASDAQ tarafından hesaplanmıştır ve değiştirilmiş bir piyasa değeri ağırlıklı endekstir. Bu endeks, yatırımcılara finansal hizmet şirketleri hariç, borsa performansı hakkında mükemmel referans bilgileri sağlar. Daha önce de belirtildiği gibi, endeks finansal şirketleri içermemektedir.



Şekil 2.21 : 2010-2021 dönemi için NQ100 endeks grafiği

2.4.4.2 DAX endeksi

DAX (Deutscher Aktien Index veya GER40 olarak da bilinir), Frankfurt Menkul Kıymetler Borsası'nda işlem gören en büyük ve en likit Alman şirketlerini temsil eden bir hisse senedi endeksidir. DAX endeksini hesaplamak için kullanılan fiyatlar, elektronik ticaret sistemi Xetra aracılığıyla sağlanır. Ortalama işlem hacmi ölçümleriyle birlikte endeks ağırlıklarını hesaplamak için halka açıklık yöntemini kullanan DAX, 1988'de 1.163 puanlık bir başlangıç endeks düzeyiyle oluşturulmuştur. DAX üyesi şirketler, Frankfurt Menkul Kıymetler Borsası'nda işlem gören piyasa değerinin yaklaşık %80'ini oluşturmaktadır. Bu endeks başlangıçta 30 şirketten oluşuyordu, ancak 3 Eylül 2021 itibariyle 40 şirkete genişledi.



Şekil 2.22 : 2010-2021 dönemi için DAX grafiği

2.4.4.3 US500 endeksi

Standard and Poor's 500 Endeksi, Amerikan ekonomisindeki büyük endüstrileri temsil eden 500 şirkete ait hisse senetlerini izleyen bir hisse senedi endeksidir. Sermaye olarak en büyük 500 şirketin yer aldığı liste, NYSE ve NASDAQ'da işlem gören hisse senetlerinden oluşmaktadır. Ancak bu endeksin hesaplanması diğer Endekslerden farklıdır; 500 hisse senedinin fiyat bileşeni de bu endeksi diğerlerinden daha değişken yapan bir ağırlık faktörüne sahiptir. Dow Jones Endüstriyel Ortalamasının aksine, S&P 500, tüm sektörlerden 500 şirketi ve hem büyüme hisse senetlerini hem de değer hisselerini içeren piyasa değeri ağırlıklı bir endekstir. Bu nedenlerle, S&P 500 en çok takip edilen hisse senedi endekslerinden biridir ve ABD borsasının en iyi temsillerinden biri olduğuna inanılmaktadır.

Ekonomik kriz dönemlerinde, çoğu şirket daha düşük ticari büyüme ve kar beklentileri duyurmaya başlar. Bu haber üzerine yatırımcılar düşük kar bildiren şirketlerin hisse senetlerini satacak, arz-talep dengesinden ötürü hisse senedi fiyatları düşecek, doğal olarak da bu hisse senetlerini takip eden endekslerin fiyatı düşecektir.


Longtermrends'ten elde edilen veriye göre 2010 başından 2022 ortasına kadar geçen süreçte US500 endeksindeki artış %260 civarı iken altında bu durum %60 kadardır (Silvan, 2022a).

Hisse senedi değerlemeleri ile altın fiyatı arasındaki ilişki geniş çapta tartışılmaktadır. Standart görüş, bu iki pazarın negatif olarak bağlantılı olduğudur: hisse senetleri yükseldiğinde, sarı metal dalış yapar ve bunun tersi de geçerlidir. Altın güvenli bir liman olduğundan, bu durum genellikle böyledir, bu nedenle yatırımcılar korunma moduna geçtiklerinde, altını riskli hisse senetlerine tercih edebilirler. Açıkçası, aşağıdaki grafikte olduğu gibi, hisse senetlerinin ve altının zıt yönlerde hareket ettiği birçok dönem olmuştur. Bu nedenle altın, S&P 500 Endeksine karşı bir koruma sağladığı için iyi bir portföy çeşitlendiricisidir. Bu nedenle, hisse senedi yatırım portföyüne biraz altın eklemek iyi bir fikirdir.

Ancak altının fiyatını ve S&P 500 Endeksini sunan grafik aynı zamanda birlikte hareket dönemlerini de göstermektedir (2000'ler). Bu, altın-stok ilişkisinin dış koşullara, özellikle makroekonomik faktörlere bağlı olarak zaman içinde değiştiği


anlamına gelir. Bu nedenle, hisse senedi çöküş zamanlarında genellikle hisse senetlerinden altın piyasasına bir fon kayması olsa da S&P 500 ile altın arasındaki bağlantı karmaşıktır ve dış makroekonomik faktörlere bağlıdır.

En iyi örnek, 2020 koronavirüs çöküşü sırasında S&P 500 ve altın fiyatlarının ortak hareketi olabilir. Şekil 2.23'te gösterildiği gibi, borsa ve altın piyasası Mart 2020'de birlikte düşmüş ve Nisan ayında toparlanmıştır. Hisse senedi piyasası düştüğünde, yatırımcılar nakit toplamak ve marj çağrılarını karşılamak için altın varlıklarını satmışlardır.



Şekil 2.23 : Altın fiyatları (sarı çizgi, sağ eksen) ve S&P 500 Endeksi (yeşil çizgi, sol eksen) (FED St. Louis, 2020).


Çalışmada kullanılacak US500 verisinin zaman bazlı grafiği Şekil 2.24'te verilmiştir.



Şekil 2.24 : 2010-2021 dönemi için US500 (S&P 500) grafiği.

2.4.4.4 TXBM endeksi

S&P/TSX Küresel Ana Metaller Endeksi, yatırımcılara ana metallerin üretimi veya çıkarılmasıyla ilgili küresel menkul kıymetlerin yatırım yapılabilir bir endeksini sağlamak için tasarlanmıştır. Endeks, yatırımcılara küresel madencilik portföyleri için geniş ölçüde temsili bir kıyaslama ve yenilikçi, endeks bağlantılı yatırım araçları için bir temel sağlayan yatırım yapılabilir bir endeks olan S&P/TSX Global Mining Index'in bir alt kümesidir. S&P/TSX Küresel Ana Metaller Endeksi için uygun menkul kıymetler, iki Küresel Endüstri Sınıflandırma Standardı (GICS®) alt sektörü altında sınıflandırılır: Çeşitlendirilmiş Metaller ve Madencilik ve Alüminyum.



Şekil 2.25 : 2010-2021 dönemi için TXBM endeks grafiği

2.4.5 Volatilite endeksi

Volatilite, belirli bir süre boyunca fiyat değişimlerinin ölçümüdür. Yüksek volatilite koşulları bazı yatırımcılara cazip gelebilir: Daha yüksek volatilite seviyeleri, daha büyük fiyat hareketleri anlamına gelir ve daha büyük fiyat hareketleri, daha fazla potansiyel fırsat ve aynı zamanda daha fazla olası risk anlamına gelir.

Yatırımcıların bu senaryoyu tüm açılarıyla görmeleri gerekir: Daha yüksek volatilite seviyeleri, hiçbir gösterge ve gösterge grubu geleceği tam olarak tahmin edemezken, fiyat hareketlerinin daha da az tahmin edilebilir olduğu anlamına gelir. Fiyatlarda geri dönüşler daha agresif olabilir ve eğer bir tüccar kendisini hareketin yanlış tarafında bulursa, büyük fiyat hareketleri ve yüksek volatilite ortamında potansiyel kayıp daha da yüksek olabilir.


Ortalama Gerçek Aralık (Average True Range, ATR) göstergesi, volatilité ölçümü söz konusu olduđuunda teknik göstergelerin çoğundan daha üstündür. Daha önceden RSI, Parabolik SAR ve ADX göstergelerini yaratan J. Welles Wilder, ATR'nin de geliřtiricisidir (Wilder, 1978).

ATR hesabında, ilgili zaman adımı için ařağıdaki deęerlerden en büyüğünün mutlak deęeri olarak alınır:

- Mevcut periyottaki en yüksek deęer ve en düşük deęerin farkı
- Mevcut periyottaki en yüksek deęer ve önceki periyottaki kapanıř deęeri farkı
- Mevcut periyottaki en düşük deęer ve önceki periyottaki kapanıř deęeri farkı

Yukarıdaki deęerlerin mutlak deęeri alınıp en büyük deęer seçilir. Bu deęer gerçek aralık (true range) olarak isimlendirilir. Son olarak bu deęerler seçildikten sonra, kısa vadeli dalgalanmaları düzeltmek için belirli bir süre boyunca ortalamaları alınabilir (14 dönem yaygındır). Sonuç Ortalama Gerçek Aralıktır.

Volatilité endeksi, ilk defa VIX koduyla 1993 yılında CBOE (Chicago Opsiyon Borsası) tarafından oluřturulmuřtur. Endeks, CBOE'nda iřlem görmektedir ve S&P 500 endeksi opsiyonlarıyla hesaplandığı için bařta Amerikalı yatırımcılar olmak üzere tüm dünyada finansal medya ve piyasa oyuncularını tarafından takip edilen önemli bir göstergedir. CBOE tarafından gerçek zamanlı olarak hesaplanır ve dağıtılır. VIX korku endeksindeki amaç, piyasadaki risk algısını ölçmektir. Endeks yüksekse borsada yatırım riski de yükselir, bundan dolayı bu endekse “Korku endeksi” de denmektedir.




řekil 2.26 : 2010-2021 dönemi için VIX volatilité endeks grafiğı

Yatırımcılar, düşük volatilité koşullarında iki farklı yaklaşım kullanabilirler. İlk yaklaşımda, yatırımcılar düşük volatiliteli bir aralıkta alım-satım yaparlar. İkinci yaklaşımda yatırımcılar keskin fiyat kırılmaları beklerler. İlk yaklaşımda güvenli direnç ve destek seviyeleri arasında yapılan işlemler genellikle düşük getirili olurken, ikinci yaklaşımda kırılmalar potansiyel olarak büyük fiyat değişimlerine yol açsa da başarı olasılığı önemli ölçüde daha düşüktür. Bu düşük olasılığı dengeleyecek şekilde risk-ödül oranları daha agresiftir.

2.4.6 Enflasyon

Altın genellikle şu anda yatırımcılar için en başta gelen bir risk olan enflasyona karşı korunmanın bir yolu olarak lanse edilir. Enflasyona karşı koruma sağlayan bir yatırım, genellikle tüketici fiyatlarındaki hızlı artışla birlikte yükselir. Bununla birlikte, altın, ABD'deki en yüksek enflasyon dönemlerinden bazılarında yatırımcılar için negatif bir getiri sağlamıştır.

Genel anlamda bakılırsa altın ve enflasyon arasında güçlü bir korelasyon bulunmamaktadır. Geçmişe dönük küresel krizlerin olduğu ve enflasyonun arttığı dönemler incelenirse altının sürekli aynı davranışta bulunmadığı anlaşılacaktır.




Şekil 2.27 : Enflasyon oranlarının getirilerle karşılaştırılması (Turuncu: Yıllık enflasyon, gri: Gayrimenkul yatırımı, mavi: emtialar, sarı: altın, Morningstar Direct)


Örneğin, Arnott'un analizine göre, altın, yıllık enflasyon oranının yaklaşık %6,5 olduğu 1980'den 1984'e kadar ortalama %10 değer kaybetti (Federal Rezerv enflasyonu yılda %2 civarında tutmaya çalışır.). Benzer şekilde, altın, enflasyonun yaklaşık %4,6 olduğu bir dönem olan 1988'den 1991'e kadar %7,6'lık bir negatif getiri

sağladı. 1973'ten 1979'a kadar olan dönemde yatırımcılar, yıllık enflasyon oranının ortalama %8,8 olduğu bir ortamda altından %35 gibi büyük bir getiri sağladılar.

Birbiriyle paralel olmayan bu sonuçlar, enflasyondan endişe eden yatırımcıların portföylerinde bir riskten korunma aracı olarak altını kullanarak aslında zarar riskine girebileceklerini göstermektedir.



Şekil 2.28 : 2010-2021 dönemi için ABD TÜFE değerleri ve bu değerlerden hesaplanmış yıllık bazlı enflasyon.



Şekil 2.29 : 2010-2021 dönemi için ABD 5 ve 10 yıllık beklenen enflasyon.

2.4.7 Faiz

Faiz, ekonomik ve finansal sektörlerde anahtar kavramlardan biridir. Günlük hayatta sıkça duyulan bu terim, en kısa tanımıyla, bir banka veya benzeri bir kurumdan ödünç alınan paranın kullanım bedelidir. Bu bedellerin oran ve miktarı, çeşitli kriterlere göre değişiklik göstermektedir. Faiz oranını belirleyen faktörler arasında ülke ekonomisinin

durumu da yer almaktadır. Fiyatlandırma belirlenirken ekonomik olaylar da dikkate alınır. Örnek olarak merkez bankalarının uyguladığı politikalar verilebilir.

Başka bir tanımla faiz, banka ve benzeri yerlerden bireylere ödünç verilen varlıklardan elde edilen gelirdir. Bu gelir yüzdesine faiz oranı denir. Uygulanan faiz, anapara üzerinden hesaplanarak belirlenir. Bu terim, gayrimenkul satın alma, şirket kurma ve eğitim kredileri dahil olmak üzere çeşitli alanlarda bulunabilir. Bu, borcun geri ödenene kadar paranın değerinin kaybolmamasını sağlamak için yapılır.

Her ülkenin faiz oranları, ülkedeki merkez bankaları tarafından belirlenir. Ele alınması gereken ilk konu ulusal enflasyondur. Merkez bankası uygun faiz oranını belirlerken ithalat ve ihracat, üretim, döviz kurları, ekonomik veriler, istihdam ve resmi fiyatları dikkate alır. Kamuyla paylaşılan ücretler şeffaflık ve açıklık ilkelerine dayanmaktadır. Üreticiler ve tüketiciler, açıklanan oranlara göre önlem alırlar.

2.4.7.1 Mevduat faizleri

Mevduat faizi, bankalar tarafından müşterileri için oluşturduğu tasarruf hesaplarına müşteriler tarafından yatırılan paranın getirisidir. Vadeli mevduat hesabından para kazanmak için bir bankaya belirli bir süre para yatırılmış olması gerekir. Mevduat hesapları iki kısma ayrılabilir: vadeli mevduat ve vadesiz mevduat. Vadesiz mevduatta faiz işlemez. Vadeli mevduat türleri için ücreti banka belirler.

2.4.7.2 Merkez Bankası faiz oranları

Bir ülkenin merkez bankası, ekonomideki son likidite kaynağı olarak piyasalarda bankalara ödünç para vermekte veya bankalardan ödünç para alabilmektedir. Merkez bankaları, faiz oranlarını piyasaları etkilemek amacıyla belirlemektedir.

Türkiye’de Para Politikası Kurulunun faiz kararları, önceden ilan edilmiş bir takvim çerçevesinde yapılan toplantılarında alınmaktadır. Faizler aşağıdaki gibi üç çeşittir:

- 1) 1 haftalık repo faizi:** Bir hafta vadeli repo ihale faiz oranı, T.C. Merkez Bankası politika faizi olmuştur. (T.C. Merkez Bankası)
- 2) TCMB faiz oranları (%) gecelik (O/N):** Merkez Bankası gecelik vadede borçlanma ve borç verme oranlarının bir hafta vadeli repo ihale faiz oranına kıyasla +/- 150 baz puanlık bir marj ile belirler. (T.C. Merkez Bankası)

3) TCMB faiz oranları (%) geç likidite penceresi (LON): Geç likidite penceresi işlemlerinde uygulanacak Merkez Bankası borçlanma faiz oranı yüzde 0 olarak uygulanmaktadır. (T.C. Merkez Bankası)

2.4.7.3 Tahvil ve bono faizi

Tahvil ve bono faizi, devletin uyguladığı getiri türlerinden biridir. Devlet, kamu harcamalarından kaynaklanan açığı kapatmak için borç alır. Devlet tahvilleri bir yıldan uzun, Hazine tahvilleri bir yıldan kısadır. Müzayede yöntemi, Hazine faturaları için yaygın olarak kullanılmaktadır. Birçok banka ilk elden tahvilleri alır ve piyasaya satarak kar eder. Bu sayede birinci el, ikinci el şeklinde fiyat farkları oluşmaktadır.

2.4.7.4 Gösterge faizi

Gösterge faizi, vadesine iki yıl kalan devlet tahvilleri Türkiye’de en çok işlem gören getiri türlerinden biridir. ABD’de de 10 yıllık devlet tahvili faizi gösterge faizidir. Gösterge faiz türünde kuponlar bulunur ve bu kuponların 3 veya 6 ayda bir ödenmesi gerekir. Gösterge faiz oranları aşağıdaki faktörler nedeniyle yükselebilir:


- Merkez bankası para politikası (para talebindeki artış/azalış, izlenen politikadaki faiz oranları vb.)
- Devletin maliye politikası (vergiler, kamu harcamaları vb.)
- İç piyasadaki talepler (aşırı tüketim, talep vb.)
- Kredi taleplerindeki değişiklikler (taleplerdeki artış / azalış)
- Stratejik politika gelişmeleri
- Secim süreci
- İç karışıklıklar

2.4.7.5 Faizin etkileri

Ülkelerin merkez bankaları, bulunduğu ülke içindeki para politikası kararlarını almaktan sorumludur. Merkez bankası ülke içinde basılacak para tutarına ve verilen borcun getirisine (faiz) karar vermektedir. Gelişmekte olan ülkelerde ekonomik dengenin kurulmasında faiz önemli bir faktördür. Artan faiz oranlarının olumlu ve olumsuz sonuçları bulunmaktadır.

Artan faiz, dışarıdan spekülâtif para akışı ile piyasanın esnemesine yol açar. Ulusal para birimi değeri olarak yükselecek ve enflasyonu düşürecektir. Ancak bu yöntem yatırımda bir azalmaya da neden olabilir. Artan faiz oranları nedeniyle tüketimde azalma meydana gelir. Bu sayede kaynak bulmak kolaylaşır. Düşük tüketim, enflasyonu düşürür. Düşen enflasyon ile yatırım maliyetlerinde yükselmeler meydana gelir. Maliyetlerin artmasıyla birlikte yapılacak olan yatırımlarda gerilemeye yol açar. Bu durumda aşağıdaki bazı etki tepkiler oluşabilir:

- Şirketlerin daha az yatırım yapma sebepleri borç paranın faizini ödemektir.
- İnsanlarda yatırım yapma ihtiyacı artar.
- Banka kredilerinde geri ödeme güçlüğü başlar.
- Girişimciler yeni iş fırsatlarında, risksiz getiri imkânı yakalamak isterler bu sebeple bankalarda vadeli hesap açarak para kazanır.
- Üretim azalır.
- Sanayide ve ekonomide gerileme başlar.




Şekil 2.30 : 2010-2021 dönemi için ait FOMC kurulunun açıkladığı faiz kararları.

Federal fon oranı, mevduat kurumlarının federal fonları (Federal Rezerv Bankalarında tutulan bakiyeleri) bir gecede birbirleriyle takas ettiği faiz oranıdır. Bir mevduat kurumu rezerv hesabında fazla bakiyeye sahip olduğunda, daha büyük bakiyelere ihtiyacı olan diğer bankalara borç verir. Daha basit bir ifadeyle, genellikle likidite olarak adlandırılan fazla nakdi olan bir banka, likiditeyi hızla artırması gereken başka bir bankaya borç verir (FED New York, 2007).

Borç alan kurumun borç veren kuruma ödediği oran iki banka arasında belirlenir; bu tür müzakerelerin tümü için ağırlıklı ortalama orana efektif federal fon oranı denir.

Efektif federal fon oranı esasen piyasa tarafından belirlenir, ancak FED'in duyurduğu federal fon oranına yaklaşılabilmesi için açık piyasa işlemleri yoluyla FED tarafından müdahale edilebilir (FED).




Şekil 2.31 : FOMC'nin açıkladığı faiz kararlarına göre şekillenen günlük efektif fon oranı grafiği

2.4.7.6 Avrupa Merkez Bankası politika faizi

AB üye ülkelerinin 27 merkez bankası ve Frankfurt merkezli Avrupa Merkez Bankası, Avrupa Merkez Bankaları Sistemini oluşturur. Ülkeler arası iş birliğini ve para politikasının uygulanmasını kolaylaştırır. ECB'nin görevleri; faiz oranlarının belirlenmesi, para arzını kontrol etmek, döviz kurlarını sabit tutmak için döviz rezervlerini yönetmek ve bunları alıp satmak, finansal piyasaları, kurumları ve ödeme sistemlerini denetlemek, Euro Bölgesi üye ülkelerinin merkez bankalarına banknot ihraç etme yetkisi vermek ve enflasyonun izlenmesidir.

Altın rezervleri, merkez bankası tarafından bir değer deposu, mevduat sahiplerine ödeme garantisi veya para birimini güvence altına almanın bir yolu olarak tutulan altındır.

Son 6 senelik dönemde ECB'nin herhangi bir faiz artırımında bulunmaması, altının seyrini etkilememiştir (Şekil 2.32).



Şekil 2.32 : 2010-2021 dönemine ait ECB'nin açıkladığı faiz kararları.

2.4.7.7 Reel faiz

Nominal faizin enflasyondan arındırılmış halidir. Fonların borçluya gerçek maliyetini ve borç verene veya yatırımcıya gerçek getiriye yansıtmak için enflasyonun etkilerini ortadan kaldıracak şekilde ayarlanmış bir faiz oranıdır. Teknik olarak, nominal faiz oranından beklenen enflasyon oranının çıkarılması ile bulunur.

Reel faiz oranı, mevcut piyasadaki faiz oranının enflasyonun etkilerine göre endekslenmiş çeşididir. Bir yatırım veya krediye ödenen faizin satın alma gücü değerini yansıttığı için borç alan ile borç verenlerin doğru zamanda borçlanma / borç vermeleri açısından önemli bir göstergedir.

Enflasyon oranları sabit olmadığı için, ileriye dönük reel faiz oranları, bir kredinin veya yatırımın vadesine kadar olan süre boyunca beklenen gelecekteki enflasyon tahminlerine dayanmalıdır.

Reel faiz oranının (real interest rate) altın fiyatlarına etkisi: Genel olarak, reel faiz oranları altın fiyatı ile negatif korelasyondadır, yani artan reel faiz altın fiyatını olumsuz etkiler. Örneğin, bu çalışmanın ileri bölümlerinde oluşturulan korelasyon grafiğinde, reel faiz oranları ile altın fiyatları arasında (2010'den 2021'e kadar)-0.82'lik güçlü bir negatif korelasyon bulunmuştur. (-1 kusursuz bir negatif korelasyona tekabül eder.)

Bunun arkasındaki mantık, daha yüksek faiz oranlarının, değerli metaller gibi faizsiz varlıkları elde tutmanın daha yüksek fırsat maliyetleri anlamına gelmesi ve onları nispeten daha az çekici hale getirmesidir. Temelde, altın ne kâr payı ne de faiz getirir. Bu nedenle, reel faiz oranları yüksek olduğunda altını varlık listesinde tutmak

maliyetli, reel faiz oranları düşük olduğunda ise uygun görünmektedir. Başka bir deyişle, faiz oranları ne kadar yüksek olursa, emtianın taşıma maliyetleri de o kadar yüksek olur.


Bununla birlikte bu ilişki her zaman doğrusal değildir. Altın fiyatları negatif reel faiz oranlarının bulunduğu zaman aralıklarında ciddi yükselişler kaydeder. Negatif faiz oranları kredi veren kurumların da para kaybettikleri anlamına gelir, bu yüzden faiz veya kâr payı ödemesi olmamasına rağmen yatırımlarını altın üzerine gerçekleştirmeye daha eğilimli hale gelirler. Örnek vermek gerekirse 1970'lerde Amerikan ekonomisi yüksek nominal faize sahip olmasına rağmen enflasyon oranları faiz değerlerini aştığından, ki bu negatif reel faize işaret eder, altın fiyatı tarihi seviyelere çıkmıştır. 1981'den hemen önce yapılan kısa dönem nominal faiz artırımları sayesinde reel faiz pozitif tarafa geçmiş ve altının düşme eğrisi başlamıştır. Benzer durum 2000'li yılların başından beri de gözlenebilir. Bu dönemde enflasyon ve nominal faiz oranlarının ikisinin de düşük olmasına rağmen reel faiz oranları genellikle negatif bir grafik çizmektedir. Bu dönemde altın fiyatlarında yükseliş gözlenmektedir.

Reel faiz hesaplamada kullanılan veriler - Nominal faiz ve enflasyon kombinasyonları

Ekonomi analistlerinin reel faiz hesaplarırken kullandığı birçok enflasyon endeksi vardır, sonuç olarak birçok reel faiz oranı ölçüsü vardır. Bununla birlikte, analistler genellikle reel faiz oranları için enflasyon (TÜFE) endeksli ABD Hazine Enflasyon Korumalı Menkul Kıymetler (TIPS) 'e uygulanan faiz oranlarını kullanırlar. Reel faiz oranları, altın piyasasındaki yatırımcılar için, FED faiz oranı ve nominal faiz oranlarındaki değişikliklerden çok daha önemlidir.

Dünya Altın Konseyi'nin (WGC) hazırladığı bir raporda 3 aylık kısa vadeli hazine bonusu faizleri ve her ay açıklanan, TÜFE'nin yıllık değişiminden elde edilen enflasyon oranı kullanılmıştır (WGC, 2013).

Başka bir örnekte 10 yıllık enflasyon endeksli hazine tahvillerinin getirisi kullanılmıştır. Burada enflasyonu tekrar hesaplamaya katmanın anlamı yoktur. 2015 senesi içinde FED'in faiz artırım beklentileri ve sonuç olarak ABD dolar endeksinin ve sonunda reel faiz oranlarındaki artışı, altın fiyatlarında düşüşe neden olmuştur (Şekil 2.33).




Şekil 2.33 : 06/2015 – 12/2015 tarihleri arasındaki ABD reel faiz oranı ve altın karşılaştırması (Sunshine Profits)

Çalışmada kullanılacak Reel faiz oranı, FED St. Louis veri tabanından WFII10 koduyla erişilebilir.


Üçüncü bir örnekte kısa dönem reel faiz oranları, 1 yıllık hazine tahvil getirisi ve TÜFE’den hesaplanan yıllık enflasyon kullanılarak hesaplanmıştır. 1971-2019 yılları, incelenen zaman aralığı olarak alınmıştır.

Getiri oranı, FED St. Louis veri tabanından GS1 koduyla indirilebilir.



Şekil 2.34 : 1971-2019 yılları arasındaki ABD reel faiz oranı ve altın karşılaştırması (Sunshine Profits)

MacroMicro web sitesinde yer alan reel faiz oranı ve altın fiyatları karşılaştırmasında, reel faiz oranı hesabında, 10 yıllık hazine tahvili getirisi ve “5 yıl / 5 yıl ileri” beklenen enflasyon kullanılmıştır (Şekil 2.35).



Şekil 2.35 : 2010-2021 dönemine ait reel faiz (MacroMicro).

5 Yıl / 5 Yıl İleri beklenen enflasyon serisi: Bu seri, bugünden beş yıl sonra başlayan beş yıllık dönem boyunca (ortalama olarak) beklenen enflasyonun bir ölçüsüdür ve denklem 2.1’deki gibi oluşturulmuştur:


$$T5YIFRM = \left(\left(\frac{\left(1 + \frac{DGS10 - DFII10}{100} \right)^{10}}{\left(1 + \frac{DGS5 - DFII5}{100} \right)^5} \right)^{0.2} - 1 \right) * 100 \quad (2.1)$$

Burada DGS10, DFII10, DGS5 ve DFII5, sırasıyla 10 yıllık nominal, 10 yıllık enflasyona göre düzeltilmiş, 5 yıllık nominal ve 5 yıllık enflasyona göre düzeltilmiş hazine menkul kıymetleridir. Bu kodlar, FED St. Louis veri tabanında ilgili serilerin kimlikleridir.

FED St. Louis veri tabanındaki GS10 (faiz) ve T5YIFRM (beklenen enflasyon) verilerinin farkı alınarak reel faiz oranı hesaplanarak bulunabilir.


Son örnekte de reel faiz oranını hesaplamak için ABD hazine tahvili 1 yıllık nominal getiri oranı ve TÜFE’den hesaplanan yıllık enflasyon oranı kullanılmıştır (Longtermrends). 2010-2021 dönemi için Şekil 2.36’da görselleştirilmiştir.

Bu veriler faiz oranı ve ABD TÜFE endeksi FED St. Louis veri tabanından erişilebilir.



Şekil 2.36 : Longtermrends sitesinde gösterilen ve elde edilen veriler ile Excel’de uyumlaştırılan reel faiz grafikleri.

Bu çalışmada aşağıda grafiği verilen DFII10 kodlu reel faiz kullanılacaktır. 10 yıllık sabit vadeli, enflasyona endeksli ABD hazine menkul kıymetlerinin piyasa getirisi, bir çeşit beklenen enflasyon kullanılarak hesaplanan reel faiz türüdür.



Şekil 2.37 : Çalışmada kullanılan reel faiz değişkeni, 2010-2021 dönemi.

2.4.8 Makroekonomik göstergeler

2.4.8.1 Para arzı


Para; devletin denetiminde bulunan, mal ve hizmet satın alma gücüne sahip ve herkes tarafından kabul gören bir mübadele aracıdır. Bu çerçevede para toplumda mübadeleyi sağlar, bir değer ölçüsü, ayrıca yatırım ve tasarruf aracı olarak kullanılır. Tanımdan hareketle devletin parayı bastırdığı anlaşılmaktadır. Devlet, parayı Hazine'ye bağlı Darphane aracılığıyla basar, ancak kağıt parayı merkez bankasına bastırır. Günümüzdeki fiyat para birimlerinde para arzı Çizelge 2.4'te gösterilen çeşitlerde ve ilişkidir.

Çizelge 2.4 : Para arzı çeşitleri.

Para Arzı	Dahil olunan parasal varlıklar
M0	Dolaşımdaki para(Emisyon) - Banka Kasalarındaki Para
M1	M0 + TL ve YP Vadesiz Mevduat
M2	M1 + TL ve YP Vadeli Mevduat
M3	M2 + Repo ve Para Piyasası Fonları + Bankalarca İhraç Edilen Menkul Kıymetler

Para arzı / emtia eğilimlerinin temelleri aşağıdaki gibi sıralanabilir:

- Metaller, tarım ürünleri, petrol ve hayvancılık sözleşmeleri genellikle para arzıyla birlikte yükselme eğilimindedir.
- Para arzı artışıyla genel olarak, tahvil fiyatları düşer ve enflasyona tepki olarak faiz oranları veya tahvil getirileri yükselir.
- Hisse senedi endeksi vadeli işlemleri para arzı ile olan ilişkilerinde daha değişkendir, ancak nihayetinde faiz oranları düştüğünde yükselme eğilimi gösterirler ve faiz oranları yeterince yüksek bir seviyeye ulaştığında düşme eğilimindedirler.
- Para birimleri enflasyonla birlikte düşme eğilimindedir.
- Küresel bir ekonomide, bu dinamiklerin çoğu aynı anda veya birbirine çok yakın bir yerde meydana gelir; bu nedenle, küresel ekonomiyi anlamak, vadeli işlemlerde bireysel hisse senedi ticaretinden daha önemlidir.



Şekil 2.38 : 2010-2021 dönemi için M1 para arzı grafiği

Parasal Taban (Monetary Base, M0)

Para tabanı, ekonomide dolaşan en likit para türüdür. Parasal taban, fiziki paradan (madeni paralar, banknotlar) ve ticari bankaların merkez bankasındaki mevduatlarından oluşur. Parasal tabanın en önemli özelliği, tipik koşullar altında anında mal veya hizmetlere (veya diğer para birimlerine) çevrilebilmesidir. Çoğu durumda, parasal taban arzı, merkez bankası tarafından kontrol edilir. Merkez bankaları bunu örneğin daha fazla kağıt para basarak genişleterek yaparlar.

Parasal tabana 'yüksek güçlü para' da denir, çünkü basit bir para çarpanı modelinde para tabanındaki bir artış, toplam para arzında (geniş para) daha büyük bir oranda artışa yol açabilir. Genel para arzı ile olan bağları nedeniyle, parasal taban altının temel analizinde önemli bir rol oynamaktadır.

Altının temel analizinde para arzı ile altın fiyatı arasındaki ilişki önemlidir. Parasal taban, bir bütün olarak para arzının en büyük unsuru olmasa da agresif genişlemesi tüm para arzının patlamasına neden olabileceği için yine de önemlidir. Günümüzde dolaşımdaki paralar fiat para tipindedir. Fiat yani itibari para, sadece hükümetlerin onu yasal ödeme aracı olarak tanıma taahhüdüyle desteklenmektedir, herhangi bir fiziksel varlık karşılığı yoktur. Fiat para birimi sistemi, merkez bankalarına neredeyse sınırsız miktarda para basacak kadar geniş yetkiler verir. Teorik olarak, istikrarlı demokrasilerde merkez bankalarının hükümetlerden bağımsız olma gereksiniminin en büyük sebebi, hükümet harcamalarını finanse etmek için aşırı miktarda para basmayacaklarını garanti etmektir.

Merkez bankalarının basıp dolaşıma verdiği para arttıkça, vatandaş ve kurumlar sahip oldukları para artmasına rağmen sonuçta daha zengin olmayacaklardır. Fazla parası olduğunu hisseden insanlar harcamaya eğilimlidir, mal ve hizmetlere eskisinden daha çok talep gösterir. Üretici ve perakendeciler üretilen her şeyin satıldığını fark ederler ve fiyatları “bir miktar” artırıp üretim başına daha çok ciro elde etmeyi amaçlarlar. Fiyatlar yükselir ve artık eskisinden daha fazla tüketim yapılamaz. Özetle, paranın değeri, para arzıyla yakından ilişkilidir. Yüksek para arzı, talep enflasyonuna sebep olur.

Enflasyon ortamında, bir ekonomi zorlanıyorsa, borsadaki hisse senetleri daha az karlı yatırımlar haline gelir, yatırımcılar buradan devlet destekli tahvillere geçebilir. Çok yüksek miktarda basılan para yatırımcıların devlete olan güvenlerini kaybetmelerine ve daha fazla getiri sağlayan emtia ve varlıklara yönelmelerine sebep olabilir. Bu durumda altın ve gümüş gibi emtialara olan taleple değerli metallerin fiyatları yükselir.

Amerikalı iktisatçı Fisher tarafından önerilen Mübadele Yaklaşımı, bir diğer adıyla Para Miktar Teoremi 1911 yılında geliştirilmiştir.

Teorinin geliştiricisi Irwing Fisher olduğundan Fisher Denklemi olarak da bilinmektedir.

Mübadele yaklaşımı, denklem 2.2’deki gibi ifade edilir.

$$M * V = P * T \quad (2.2)$$

Burada M Para arzı (Para miktarı) V: Paranın dolaşım hızı P: Fiyatlar Genel Düzeyi T: Belirli bir dönemde üretilen malların fizik miktarını gösterir. P * T ifadesi GSYH olarak gösterilebilir (Denklem 2.3).

$$M * V = GSYH \quad (2.3)$$

Paranın dolaşım hızı, her bir para biriminin bir yıl içinde kaç kez el değiştirdiğini gösterir. Para arzı olarak, bir ekonomide gerektiğinde harcama için hızlıca kullanılabilen dolanımdaki para ve vadesiz hesaplarda bulunan yerli/yabancı paranın toplamı olan M1 tipi para göz önüne alınabilir (Denklem 2.4).

$$M1 * V = GSYH \quad (2.4)$$

Örneğin; 2021 yılının ikinci çeyreği için üretim yöntemiyle ve cari fiyatlarla 1 trilyon 581 milyar 120 milyon TL olarak duyurulan Türkiye GSYH ve yine aynı dönemdeki 115 milyar 851 milyon TL tutarında olan M1 para arzını ele alalım.

$$V = GSYH/M1 = 1581.12/115.851 = 13.7 \quad (2.5)$$

Yani 2021 ikinci çeyreğinde her 1 TL'nin 13.7 kez el değiştirdiği söylenebilir.

Stabil bir ekonomide fiziksel malların üretiminde çok ani yükselme ve azalmalar olmaz. Aynı durum toplumun geleneklerine ve alışkanlıklarına göre oluşan para dolaşım hızı için de düşünülebilir. Üretim ve dolaşım hızındaki değişimler orta ve uzun vadede gerçekleşir. V ve T'nin incelenen kısa dönemde sabit kalacağını kabul edersek, para arzında (M1) ortaya çıkan ani yükselmeler, fiyatlarda da (P) artışa yani enflasyona sebep olur.

2.4.8.2 FED bilançosu

Federal Rezerv bilançosu (FED assets), FED'in varlık ve yükümlülüklerini özetleyen bir tablodur. FED, bilançosundaki varlık ve yükümlülükleri düzenli olarak açıklar.

FED'in varlıkları, büyük ölçekli varlık satın alma programları kapsamında satın alınan Hazine tahvillerini ve ipotēge dayalı menkul kıymetleri içerir. FED yükümlülükleri, dolaşımdaki ABD para birimini ve ticari bankalar tarafından yatırılan rezervleri içerir.

FED bilançosu, standart, ticari bir bilançoya benzemektedir, ancak arada önemli bir fark vardır: FED, istediği kadar ABD doları basarak bilançosunu genişletebilir. Bu nedenle, FED'in para ödemek zorunda olduğu her şey (genellikle ABD Hazine tahvil ve bonoları), FED'in varlığı haline gelir.

Ekonomik krizler sırasında FED, niceliksel genişleme (QE) olarak da bilinen bir politika olan büyük ölçekli varlık satın alma programları kapsamında daha fazla varlık satın alarak bilançosunu genişletebilir.

2007'de başlayan küresel mali kriz, ABD merkez bankasını kısa vadeli faiz oranlarını yaklaşık sıfıra indirmeye ve uzun vadeli faiz oranları üzerinde aşağı yönlü baskı oluşturmak için (FED'in bilançosunun genişlemesiyle sonuçlanan) alışılmadık politika önlemleri almaya sevk etti.


FED'in para politikasının normalleşmesi, kısa vadeli faiz oranlarının seviyesini ve ABD Merkez Bankası'nın menkul kıymetlerini daha normal seviyelere döndürme

sürecidir. Ocak 2014'te ABD merkez bankası tahvil alım programını kademeli olarak azaltmaya başladı. Buna ekonomi tabiriyle “tapering” ya da “parasal daralma” denmektedir. Ekim 2014'te FED, niceliksel genişleme programını sonlandırdı. Aralık 2015'te ise para politikasının normalleşmesine yönelik önemli bir adım olan faiz oranlarını yükseltti.

Para politikasının normalleşmesi ABD ekonomisinde bir güvenoyu olarak algılanabilir. Bu dönemde altın fiyatı, 2013'te FED Başkanı Ben Bernanke'nin daralmayı önermesiyle, 2014'te daraltma sırasında ve 2015'te düştü.

FED bilançosundaki değişiklikler grafiksel olarak altın fiyatına yansımaya da bilançodaki daralma ve genişlemelerin altın piyasasına etkileri, bu etkilerin yatırımcılar tarafından nasıl algılandığına bağlıdır. 2008'deki kriz başında yapılan varlık alımları ABD ekonomisinde enflasyon endişeleri doğurdu. Ancak zamanla rezerv bankalarının aldığı önlemlerle ekonomi toparlandı ve yatırımcıların ekonomiye güveni artırıldı. Sonuç olarak altın fiyatları 2011'den itibaren düşmeye başladı.

Bu çalışmada kullanılacak olan FED bilançosu, Şekil 2.39'da incelenebilir.



Şekil 2.39 : 2010-2021 dönemi için FED bilançosu.


2.4.8.3 İşsizlik oranı

İşsizlik, kişinin çalışmak istemesi, iş araması ama bulamamasıdır. Bazı insanlar ne sebeple olursa olsun ne yazık ki işsizdir. Belirli bir ekonomideki çok sayıda veya az sayıda insanın işsiz olup olmadığını belirlemek için, toplam işgücü içindeki (çalışanlar ve işsizler) işsiz bireylerin yüzdesi olan işsizlik oranı kullanılır.

Resmi ABD işsizlik oranı, bir önceki ay için yayınlanan İstihdam Durum Raporu'nun bir parçası olarak Çalışma İstatistikleri Bürosu tarafından hesaplanmaktadır. Aynı

raporda tarım dışı istihdam da bulunmaktadır. İşgücü piyasasının gücü ve ekonominin kullanılmayan kaynakları hakkında bilgi sağladığı için işsizlik oranı, değerli metaller piyasasında yatırım yapan kişiler de dahil olmak üzere analistler ve yatırımcılar tarafından geniş çapta izlenmektedir.

Thraver ve Lopez'in araştırmasına göre 2008-2016 döneminde, işsizlik oranındaki her %1'lik değişim için altın fiyatı %4,7 artar (2016).



Şekil 2.40 : 2010-2021 dönemi için ABD işsizlik oranı

2.4.8.4 Gayrisafi yurt içi hasıla

Gayrisafi yurt içi hasıla (GSYH), bir ülkede belirli bir zaman diliminde üretilen tüm nihai mal ve hizmetlerin parasal değeridir. Aynı zamanda bir ulusun genel ekonomik faaliyetinin veya ekonominin boyutunun en yaygın ölçüsüdür. Giderek daha fazla ekonomist GSYH'nin kusurlu karakterini kabul etmektedir. Örneğin, GSYH yalnızca nihai malları ve hizmetleri içerir; tüketimi fazla gösterir, hükümet harcamalarının üretken olduğunu varsayar, ithalatı olumsuz bir şey olarak ele alır, ev işlerini hariç tutar, vb. Ancak hükümetler, merkez bankaları, finansal analistler ve yatırımcılar hala tüm ekonomiyi tek bir rakamla çerçevelemenin mümkün olduğunu düşünmektedir (Wolverson, 2013). Bu nedenle GSYH büyümesi altın piyasasında da yakından takip edilmektedir.


Literatürde, GSYH'nin parlak metalin fiyatı üzerindeki etkisi iki ayrı kısımda incelenir: Gelir-tüketim kanalı ve güvenli liman kanalı.

Gelir-tüketim kanalı yaklaşımında; ekonomi hızlı büyüdüğünde insanların gelirleri ve satın alma gücü yükselir (ardından durgunlaşır ya da azalır), altın talebi de artar. Bu savın doğruluğu her zaman geçerli değildir. Çünkü altın fiyatı, önemli ölçüde tüketici

talebi tarafından değil, yatırım talebi tarafından yönlendirilmektedir. Tüketiciler, fiyat belirleyici değil, fiyat alıcıdır. Dolayısıyla fiyatlar düştüğünde daha fazla satın alım yaparlar. Aynı mantıkla, fiyatlar yükseldikçe daha fazla satış yaparlar.

Diğer taraftan, güvenli liman yaklaşımına göre, GSYH bir ülkenin ekonomik durumunu gösterirken, yüksek olması vatandaşlara güven verir. Buna karşın, yükselen bir altın ekonomiye karşı güvenin azaldığını göster. Dolayısıyla, GSYH büyümesi ile altın fiyatı arasında negatif bir ilişki olmalıdır. Ekonomi genişlediğinde, (parlak metalin güvenli liman özelliğinden etkilenen) yatırım talebi düşer ve bunun tersi de geçerlidir.

Ancak, yatırımcılar iki şeyi hatırlamalıdır. Birincisi, GSYH gecikmiş ve sıklıkla güncellenen bir göstergedir. Bu nedenle GSYH'nin piyasa beklentilerinin üzerinde mi yoksa altında mı olduğu açıklanan rakamdan daha önemlidir. Oysa altın (genel olarak her para birimi gibi), yatırımcıların geleceğe ilişkin beklentilerini kısa süre içinde özetleyen öncü bir göstergedir ve bu nedenle ekonomik durgunluğu tahmin etmede kullanılabilir. Örneğin, altının fiyatı, daha 2005'in dördüncü çeyreğinde Büyük Durgunluk olasılığının yüksek olduğuna işaret ederken, GSYH ancak 2008'in üçüncü çeyreğinden sonra negatif tarafa geçmiştir (Ekonomik durgunluk resmi olarak Aralık 2007'de başlamıştır).



Şekil 2.41 : 2010-2021 dönemi için GSYH verilerinden elde edilen büyüme oranları.

2.4.8.5 ABD tarım dışı istihdam

ADP Ulusal İstihdam Raporu, yaklaşık 400.000 ABD çalışanı için maaş bordrosu verilerine dayalı olarak özel tarım dışı istihdamdaki aylık değişimin bir ölçüsüdür. Tarım dışı istihdam; mülk sahipleri, özel ev çalışanları, ücretsiz gönüllüler, tarım


işçileri ve tüzel kişiliği olmayan serbest meslek sahipleri hariç, ücretli ABD çalışanlarının toplam sayısını temsil eder. Bu kesim, ABD GSYH'ye katkıda bulunan çalışanların yaklaşık %80'ini oluşturur (Sunshine Profits, n.d.).

Hükümet verilerinden iki gün önce yayınlanan ADP raporu, analistler tarafından hükümetin tarım dışı istihdamının iyi bir göstergesi olarak görülmektedir. Tarım dışı maaş bordroları, ekonominin ve enflasyonist baskının büyüüp büyümediğini ve ne kadar hızlı büyüdüğünü gösterdiği için FED tarafından da yakından izlenir. Örneğin hızlı istihdam oranlarının potansiyel olarak enflasyonda bir artışa yol açacağı öngörülebilir. Bu göstergedeki değişkenlik oldukça yüksek olabilir.

Altın fiyat ve istihdam grafikleri üst üste konursa bir ilişki tespit edilmeyebilir. Bu ilişki daha çok verilerin piyasanın beklentisi düzeyin çıkıp çıkmamasıyla ilgilidir.

Beklenen değerden daha yüksek bir duyuru USD için pozitif/yükseliş olarak, daha düşük bir duyuru ise USD için negatif/düşüş olarak algılanır.

Ancak, tarım dışı istihdam ile altın fiyatları arasındaki ilişki basit olmaktan uzaktır. En iyi örnek Covid-2019 krizi olabilir. Aşağıdaki grafiğin gösterdiği gibi, tarım dışı istihdamdaki aylık değişim çökmüş (yani işsizlik artmış), ancak altının fiyatında sert bir yükselme yaşanmamıştır.




Şekil 2.42 : 2010-2021 dönemi için aylık olarak yayınlanan ADP tarım dışı istihdam değişim grafiği.

3. DERİN ÖĞRENME

Derin öğrenme, birden çok işleme katmanından oluşan hesaplama modellerinin, birden çok soyutlama düzeyiyle verilerin temsillerini öğrenmesine olanak tanıyan bir makine öğrenimi yöntemidir. Derin öğrenme yöntemleri, ham girdiden başlayarak her biri bir önceki katmandaki temsilden daha yüksek, biraz daha soyut bir temsile dönüştüren basit ancak doğrusal olmayan modüller oluşturarak elde edilen, birden çok temsil düzeyine sahip temsil-öğrenme yöntemleridir. Derin öğrenmenin kilit yönü, bu özellik katmanlarının insan mühendisler tarafından tasarlanmamasıdır: Bu katmanlardaki parametreler genel amaçlı bir öğrenme prosedürü kullanılarak verilerden öğrenilir (Goodfellow, Bengio ve Courville, 2016).

Derin öğrenme, makine öğrenmesi ve yapay zeka farklı anlamlara sahip terimlerdir. Derin öğrenme, makine öğrenmesinin; makine öğrenmesi de yapay zekanın bir alt dalı olarak belirtilebilir (Şekil 3.1). Bir derin öğrenme sistemi, çok katmanlı bir sinir ağı mimarisine, bulut veya kümede konuşlandırılmış yüksek performanslı bir grafik işleme birimine ve çok yüksek metin, ses ve görüntü tanıma doğruluğu elde etmek için büyük miktarda veriye sahiptir. Bu güçlü süreç, geliştiricilerin insan zekasına benzeyen dijital sistemler kurarak ve haftalarca süren model eğitiminin saatler içinde tamamlanmasına olanak tanıyarak daha hızlı katma değer sağlamasına yardımcı olur.



Şekil 3.1 : Yapay zeka, makine öğrenmesi ve derin öğrenmenin kapsamı.

Yapay zeka, genellikle insan zekası gerektiren görevleri gerçekleştirebilen akıllı makineler oluşturmakla ilgilenen bilgisayar biliminin geniş kapsamlı bir dalıdır. Makine öğrenmesinde Bir bilgisayarın veya bilgisayar kontrollü bir robota uyulması gereken birçok kural getirilir ve bu kurallar çerçevesinde karar alması sağlanır (McCarthy, 2007).

Derin öğrenme, sabit kodlanmış kurallar yerine büyük veri kümelerini kullanan makine öğrenimini ifade eder. Derin öğrenmede büyük veri setlerini kolayca işleyebilen, yüksek işlem gücü kullanan modern bilgisayarlar kullanılır (Goodfellow, Bengio ve Courville, 2016).

3.1 Denetimli ve Denetimsiz Öğrenme

Derin öğrenme, bir makine öğrenimi yöntemidir. Bu, belirli veri kümelerindeki çıktıları tahmin etmek için yapay zekayı eğitmeye olanak tanır. Yapay zeka, denetimli ve denetimsiz öğrenme yöntemleri kullanılarak eğitilebilir.

Denetimli öğrenme: Girdileri ve beklenen çıktıları içeren etiketli bir veri kümesi kullanır. Yapay zekayı denetimli öğrenme kullanarak eğitirken, yapay zekaya girdi verir ve beklenen çıktıyı iletir. Yapay zeka (YZ) tarafından üretilen çıktı yanlışsa, YZ hesaplamayı yeniden ayarlayacaktır. Bu işlem, YZ hata oranını en aza indirene kadar veri seti için tekrarlanır.


Denetimsiz öğrenme: Etiketlenmemiş veri kümelerini analiz etmek ve kümelemek için makine öğrenimi algoritmalarını kullanır. Bu algoritmalar, insan müdahalesine ihtiyaç duymadan gizli kalıpları veya veri gruplamalarını keşfeder. Bilgilerdeki benzerlikleri ve farklılıkları keşfetme yeteneği, onu keşifsel veri analizi, çapraz satış stratejileri, müşteri segmentasyonu ve görüntü tanıma için ideal çözüm haline getirir.

Pekiştirmeye dayalı öğrenme: Pekiştirmeye dayalı öğrenme durumunda sistem, basit olmayan bir ortamda bile belirli kararlar almak ve hedeflenen bir hedefe ulaşmak için bir deneme yanılma yöntemi kullanarak görevleri çözer. Pekiştirmeye dayalı öğrenme algoritması, karar vermek için veri kümeleri yerine bir ortamdan toplanan bilgileri kullanır.

Yapay sinir ağları: Yapay Sinir Ağları (YSA), insan beyninin yeteneklerini (yeni bilgi edinme, öğrenerek yeni bilgiler oluşturma ve keşfetme vb.) yardım almadan otomatik

olarak yürütmek için geliştirilmiş bilgisayar algoritmalarıdır. Yapay sinir ağları, insan beyni örnek alınarak öğrenme sürecinin matematiksel olarak modellenmesi sonucunda ortaya çıkmıştır. Gerçek dünya verilerinin dönüştürülmesi gereken vektörlerde bulunan sayısal kalıpları tanıyabilirler. Beyindeki biyolojik sinir ağlarının yapısını ve öğrenme, hatırlama ve genelleme yeteneklerini taklit eder. Bir makinenin ham girdisini algılayarak, etiketleyerek veya kümeleyerek sensör verilerini yorumlarlar. Yapay sinir ağları, nöron adı verilen yüksek düzeyde entegre olan çok sayıda işlemci birimden oluşur. Bir sorunu çözmek için birlikte çalışırlar.

Bir yapay sinir ağının öğrenme süreci bir örnek üzerinden gerçekleştirilmektedir. Eğitim sırasında giriş ve çıkış bilgileri verilir ve kurallar belirlenir.



Şekil 3.2 : Yapay sinir ağı katman yapısı

Nöronlar üç farklı katman kategorisine ayrılır:

1. Giriş Katmanı
2. Gizli Katman(lar)
3. Çıkış Katmanı

Giriş katmanı, giriş verilerini alır. Şekil 3.2'deki örnekte, giriş katmanında dört nöron bulunmaktadır. Girdi katmanı, girdiyi ilk gizli katmana gönderir.


Gizli katmanlar, girdi üzerinde matematiksel hesaplamalar yapar. Bir sinir ağı kurmanın zorluklarından biri, gizli katmanların sayısını ve her katmandaki nöron sayısını belirlemektir. Derin öğrenme ifadesindeki "derin" kelimesinin anlamı, çok

sayıda gizli katmana sahip olması anlamına gelir. Çıktı katmanı ise çıktı verilerini döndürür.

3.2 Tekrarlayan YSA (TYSA)

Tekrarlayan sinir ağı, dahili belleğe sahip ileri beslemeli bir sinir ağı türüdür. Önceki adımın çıktısı, mevcut adıma girdi olarak beslenir (Olah, 2015). TYSA'lar, giriş dizilerini işlemek için bellek adı verilen dahili durumlarını kullanabilir. Bu, onları bölümlere ayrılmamış el yazısı tanıma veya ifade tanıma gibi görevlere karşı özelleştirir. Her girdi için kullanılan aynı parametreler, çıktıyı üretmek için tüm gizli katmanlarda aynı görevi gerçekleştirmek için kullanılır. Diğer sinir ağlarından farklı olarak bu, parametrelerin karmaşıklığını azaltır.

TYSA'daki ana özellik, onu zaman serisi işleme açısından en iyi mimarilerden biri yapan sıralı tasarımıdır. Birçok TYSA türü vardır ve en çok tanınanı, önceki adımlardan gelen bilgileri depolamak ve bu bilgileri sonraki adımlarda sınıflandırma veya tahmin için daha doğru veriler oluşturmak üzere kullanmak için ideal olan UKSB'dir. TYSA sıralı olduğundan, zaman adımları olarak bilinen ardışık girdi beslemesine sahiptir (Şekil 3.3).



Şekil 3.3 : TYSA'daki sıralı işlem.

Modeldeki gizli katman, önceki adımların girdi ve çıktısını işlemek için bir sigmoid aktivasyon fonksiyonu kullanır ve bunları mevcut durumun çıktısı için tek bir değerde toplar (Denklem 3.1).

$$h_t = \sigma(W_H * h_{t-1} + W_x * x_t + b) \quad (3.1)$$

Burada h_t mevcut durumun çıktısı, $W_H * h_{t-1}$ önceki adımdan türetilen çıkış vektörü ve $W_x * x_t$ ise girdi vektörüdür. Her ardışık tekrara bir zaman adımı denir. Yeni zaman adımında girdinin kendisine (x_t) ek olarak önceki girdinin durumu (h_{t-1}) da hesaba katılır. Yineleme işlemi, her zaman adımında ağa aynı fonksiyon (3.1) ve aynı ağırlıklar (W_H, W_x) verilerek uygulanır. Formül sonraki gizli durumun mevcut işlem için karar vermesine yardımcı olur. Nöron, girdinin tüm serinin özeti için bir önemi olmadığına karar verirse, çıktı önceki adımlardakiyle aynı kalabilir. Bir başka deyişle W_H, W_x 'ten büyükse, mevcut durumdaki girdi x etkilenmez ve önceki vektörü sonraki adıma bir çıktı olarak aktarır. Ağırlık matrisleri, zaman adımları boyunca geri yayılım algoritması ve uygun bir eniyileyici kullanılarak güncellenir. Gizli durumun son adımı sınıflandırma için 0 ile 1 arasında çıktı veren sigmoid fonksiyonudur.

3.2.1 TYSA eksiklikleri

TYSA'lar sadece henüz gördükleri güncel bilgileri değil, aynı zamanda zaman içinde deneyimlediklerini de kullanırlar. Tekrar eden bir sistem tarafından $t-1$ zaman adımında verilen karar, t zaman adımında verilen kararı etkiler. Bu, tekrarlayan ağların, yeni verilere nasıl yanıt vereceklerini belirlemek için birleştirilen şimdi ve yakın geçmiş olmak üzere iki giriş noktasına sahip olduğu anlamına gelir. Bilgi, insan hafızasının bir beden içinde görünmez bir şekilde dolaşması gibi, tekrarlayan ağların gizli durumlarında dolaşır. Bir dizi harfle birlikte verilirse, ilk karakter, ikinci karaktere ilişkin algısını belirlemeye yardımcı olmak için yinelenen ağ tarafından kullanılacaktır.

TYSA'ların başlıca eksiklikleri girdi içeriğini anlamamaları ve kaybolan gradyan problemini önleyememeleridir. Kaybolan gradyan sorunu, sinir ağı eğitiminde geri yayılım optimizasyonunun karmaşıklığı nedeniyle ortaya çıkar. Bir sinir ağının farklı katmanlarındaki ağırlık ve yanlılık değerleri, kayıp fonksiyonu gözetilerek ağırlık/önyargı değerlerinin eğimi yönünde güncellenir. Buradaki sorun, geri yayılımda hesaplanan türevin bazı durumlarda yok denecek kadar düşük olması ve ağırlığın değerinin etkin bir şekilde güncellenmesini engellemesidir. TYSA'lar, bir tanh aktivasyon fonksiyonu kullanıyorlarsa uzun dizileri işleyemezler. Bu sebeplerden dolayı Bir TYSA'yı eğitmek de zor bir iştir.


3.3 Uzun Kısa Süreli Bellek (UKSB)

Yıllar içinde tekrarlayan sinir ağlarının eğitime zorluklarının üstesinden gelmek için birtakım girişimlerde bulunulmuştur. Bu zorluklar, sıralı görevlerin uzun süreli bağımlılıklarını öğrenmek için kapılı yapıya sahip bir tekrarlayan sinir ağları türü olan Uzun Kısa Süreli Bellek ağları (UKSB'ler) tarafından başarıyla ele alınmıştır. UKSB ağları, giriş dizilerinden gerekli bilgileri hatırlayan veya gerekli olmayanları unutan tekrarlayan sinir ağlarıdır. Bu, ağdaki bir dizi kapı kullanılarak elde edilir. Kapılı yapı bir dizinin terimleri arasındaki uzun vadeli bağımlılıkların modellenmesine yardımcı olur.

Böyle bir ağ görüntüleri, videoları, konuşmayı ve metin dizilerini modellemesini sağlayan geri bildirim bağlantılarına sahiptir. El yazısı tanıma ve oluşturma, dil modelleme ve çeviri, konuşmanın akustik modellemesi, konuşma sentezi, protein ikincil yapı tahmini, ses ve video verilerinin analizi gibi birçok farklı alanda kullanılmaktadır. UKSB'ler ve yığılmış UKSB'ler, dil çevirisi için kodlayıcı-kod çözücü mimarisi, metin üretimi için diziden diziye model, optik karakter tanıma ve akıllı karakter tanıma için diziden diziye model, adlandırılmış varlık tanıma ve konuşmadan metne dönüştürme gibi çeşitli görevlerde uygulanabilir.


S. Hochreiter ve J. Schmidhuber tarafından 1997 yılında önerilen UKSB, geleneksel tekrarlayan YSA'lardaki kaybolan gradyan problemiyle karşılaşmamak için hazırlanmış bir mimaridir ve sinir ağı mimarisi tekrarlama üzerine kuruludur. Katmanlar arasındaki hatalar kaybolmaya veya patlamaya eğilimlidir, bu da minimum kaybı verecek parametrelerin bulunmasında uzun yakınsama süresine neden olur. İlk UKSB yapısı, bu sorunu sabit hata karuselini tanıtarak çözer. Bu sayede mimari, kendinden bağlantılı birimler arasında sürekli hata akışını sağlar (Hochreiter ve Schmidhuber, 1997).

Geliştirilen ilk UKSB bellek hücresi, sadece giriş ve çıkış kapılarından oluşur. Giriş kapısı, bellek hücresinde hangi bilgilerin tutulması ve güncellenmesi gerektiğine karar verir; çıkış kapısı, hangi bilgilerin çıkış yapılması gerektiğine izin verir. Bu versiyona ait örnek Şekil 3.4'te incelenebilir.




Şekil 3.4 : Geliştirilen ilk UKSB hücresi (Hochreiter ve Schmidhuber, 1997).

Bu standart UKSB, unutma kapısı adı verilen yeni özelliğin tanıtılmasıyla genişletildi. Unutma kapısı, güncel olmayan bilgileri içeren bellek durumunu sıfırlamaktan sorumludur. Bu versiyona ait örnek Şekil 3.5'te verilmiştir.



Şekil 3.5 : İlk UKSB hücresine unutma kapısı eklenmiş versiyon (Gers vd., 1999).

Ayrıca, gözetleme deliği bağlantıları ve zaman içinde tam geri yayılım eğitimi, UKSB mimarisine dahil edilen son özelliklerdir. Bu modifikasyonlar ile mimari, Vanilla UKSB olarak adlandırılmıştır (Şekil 3.6).



Şekil 3.6 : Bir Vanilla UKSB bellek hücresi.

3.3.1 UKSB'nin üstünlükleri

UKSB ağları, sıralı verileri içeren öğrenme problemleri için etkili ve ölçeklenebilir bir model sunar (Hochreiter ve Schmidhuber, 1997). Bellekteki geçmiş verilerin hatırlanmasını kolaylaştırır. Belirsiz zaman gecikmeleri verilen zaman serilerini sınıflandırmak, işlemek ve tahmin etmek için idealdirler. Model, geri yayılım kullanılarak eğitilir. UKSB ağları, zaman ve katmanlar arasında geri yayılabilen hatayı korumaya yardımcı olur. Tekrarlayan ağların daha sabit bir hatayı koruyarak birden çok zaman adımında öğrenmeye devam etmesine izin verirler. Bu, nedenlerin ve sonuçların daha uzaktan bağlanmasını sağlar.

Uzun kısa süreli bellek ağları, özellikle kaybolan gradyanlar sorununu çözmek için geliştirildi. Geri yayılım sırasında, modelin uzun süreli bağımlılıkları yakalayamaması nedeniyle gradyanlar çok küçük olduğunda, modelin ağırlıkları güncellenmez. Uzun kısa süreli bellek ağları, bu sorunu mimarilerinde kapılar ve geri besleme bağlantıları kullanarak çözer.

UKSB'ler, kapılı bir hücrede, TYSA'nın normal akışının ötesinde bilgilere sahiptir. Bilgi, bir bilgisayarın belleğinde saklanan verilere benzer bir hücreye yazılabilir, depolanabilir veya bir hücreden okunabilir. Hücre, neyin saklanacağına ve ne zaman okunması, yazılması ve silinmesi gerektiğine, kapıları açıp kapatarak karar verir. Bununla birlikte, bu kapılar, elemanların sigmoid aktivasyon fonksiyonuna sokularak uygulanan analog kapılardır.

UKSB modellerinin bir başka avantajı, bir veri setini durağan hale getirme gibi ön koşullarının olmamasıdır. Büyük bir veri seti gerektirirler ve doğrusal olmayan fonksiyonları sinir ağlarıyla modelleyebilirler. Her iki tekrarlayan sinir ağı (UKSB, TYSA), sinir ağının tekrar eden modüller zinciri şekline sahiptir.

3.3.2 UKSB yapısı ve çalışma prensibi

Bir yinelenen modülde, standart TYSA'ler tek bir tanh katmanı gibi net bir yapıya sahiptir, ancak UKSB'ler farklı bir yapıdadır. UKSB ağı, hücre adı verilen bellek bloklarından oluşur. UKSB'nin öne çıkan yeniliği, zaman içinde durum bilgilerini biriktiren bellek hücresi c_t 'dir. Hücreler, uzun süreli bağımlılık probleminden kaçınmak amacıyla ezberleme sürecini kontrol eden kapılardan meydana gelmişlerdir. Yeni bir giriş geldiğinde, giriş kapısı etkinleştirilirse giriş bilgileri hücrede toplanacaktır. Ayrıca, unutma kapısı f_t aktifse, önceki zaman adımı c_{t-1} 'deki hücre durumu yeniden yazılabilir. Mevcut hücre çıkışı c_t 'nin son duruma (h_t) yayılıp yayılmayacağı, çıkış kapısına (o_t) bağlıdır. Hücre durumu ve gizli durum bir sonraki hücreye aktarılmaktadır. Hücre durumu, verilerin temelde değişmeden ileriye doğru akmasına izin veren ana akış veri zinciridir. Her bir UKSB hücresinde bir değil, dört sinir ağı katmanı vardır. Kapılar, sinir ağının sigmoid katmanına bağlı olarak hücrelerin verilerin geçmesine izin vermesine veya isteğe bağlı olarak atılmasına izin verir.

UKSB'ler üst üste sıralanabilir (yığılmış UKSB'ler), evrimsel sinir ağı modelleri ile birleştirilebilir ve hem ileri hem de geri yönde dizileri okumak için düzenlenebilir (çift yönlü UKSB'ler). UKSB'lerdeki bu varyasyonlar, çeşitli makine öğrenmesi problemlerini de ele almalarını sağlar.

3.3.2.1 Unutma kapısı operasyonu

Sürecin ilk aşamasının görevi gerekli olmayan ve o adımda hücreden çıkarılacak bilgileri tanımlamaktır. Verileri tanımlama ve hariç tutma işlemine, $(t-1)$ zamanında önceki UKSB hücresinin gizli durumu (h_{t-1}) ve t zamanında sensör girişini (X_t) alan sigmoid işlevi karar verir. Sigmoid katmanı, her bölümde hücrenin geçmesine izin verilmesi gereken veri miktarını yansıtan sıfır ile bir arasında bir aralık verir. Yani, 0 değer tahmini "hiçbir şeyin geçmesine izin verme" anlamına gelirken, 1 değeri "her

şeyin geçmesine izin ver" önerisinde bulunur (Christopher Olah. 2015). Bu kapıya unutmama kapısı da (veya f_t) denir (Denklem 3.2).

$$f_t = \sigma(W_{xf} * x_t + W_{hf} * h_{t-1} + b_f) \quad (3.2)$$

Burada σ , sigmoid fonksiyonudur ve W_f ve b_f unutmama geçidinin sırasıyla ağırlık matrisleri ve yanlılığıdır. f_t , önceki hücre durumundaki her sayıya (C_{t-1}) karşılık gelen, 0 ile 1 arasında değişen değerlere sahip bir vektördür.

3.3.2.2 Giriş kapısı operasyonu

Bellek Kapısı, hücrede hangi yeni verilerin depolanacağını bir sigmoid katmanı ve ardından bir tanh katmanı aracılığıyla seçer. “Giriş kapısı katmanı” olarak adlandırılan orijinal sigmoid katman, hangi değerlerin değiştirileceğini belirler. Önceki adımda, bir tanh katmanı, duruma yeni aday değerler eklenebilecek bir vektör oluşturur. Giriş kapısı, hücre durumunu güncellemek için aşağıdaki işlemleri gerçekleştirir.

İlk olarak, mevcut durum $X(t)$ ve önceki gizli durum h_{t-1} ikinci sigmoid fonksiyonuna geçirilir. Değerler 0 (önemli) ile 1 (önemli değil) arasında dönüştürülür (Denklem 3.3).

Daha sonra, gizli durum ve mevcut durumla ilgili aynı bilgiler tanh işlevinden geçirilecektir. Ağı düzenlemek için, tanh operatörü -1 ile 1 arasındaki tüm olası değerlere sahip bir vektör C'_t oluşturacaktır. Aktivasyon fonksiyonlarından üretilen çıkış matrisleri Hadamard yöntemiyle çarpılır (Denklem 3.4).

$$i_t = \sigma(W_{xi} * x_t + W_{hi} * h_{t-1} + b_i) \quad (3.3)$$

$$C'_t = \tanh(W_{xc} * x_t + W_{hc} * h_{t-1} + b_c) \quad (3.4)$$

Burada, W_{xi} , W_{hi} ve b_i , sırasıyla giriş kapısının ağırlık matrisleri ve sapmasıdır. W_{xc} , W_{hc} ve b_c , sırasıyla hücre durumunun ağırlık matrisleri ve sapmasıdır. C'_t ise yeni hücre durumu adayıdır.

3.3.2.3 Hücre durumu operasyonu

Bu aşamada ağ, unutmama kapısı ve giriş kapısından yeterli bilgiye sahiptir. Bir sonraki adım, eski hücre durumunu yeni durumdan gelen bilgilere göre güncellemek ve depolamaktır. Önceki hücre durumu C_{t-1} , unutmama vektörü f_t ile çarpılır. Bu, 0'a yakın değerlerle çarpılırsa, hücre durumundaki değerleri düşürme olasılığına sahiptir, yani sonuç 0 ise, değerler hücre durumunda bırakılır. Daha sonra hücre durumu adayı C'_t

giriş vektörü i_t 'nin çıkış değeri ile çarpılarak güncellenir, son olarak ağa yeni bir hücre durumu (C_t) veren noktadan noktaya ekleme gerçekleştirilir (Denklem 3.5)

$$c_t = f_t \odot c_{t-1} + i_t \odot C'_t \quad (3.5)$$

Burada, C_{t-1} ve C_t , (t-1) ve t zamanındaki hücre durumlarıdır.

3.3.2.4 Çıkış kapısı operasyonu

Çıkış kapısı, bir sonraki gizli durumun değerini belirler. Bu durum, önceki girişler hakkında bilgi içerir. İlk olarak, mevcut durumun ve önceki gizli durumun değerleri üçüncü sigmoid fonksiyonuna geçirilir (Denklem 3.6).

$$o_t = \sigma (W_{xo} * x_t + W_{ho} * h_{t-1} + b_o) \quad (3.6)$$

Burada W_{xo} , W_{ho} ve b_o , çıkış kapısının sırasıyla ağırlık matrisleri ve yanlılığıdır. Daha sonra hücre durumundan üretilen yeni hücre durumu tanh fonksiyonundan geçirilir. Bu çıktıların her ikisi de Hadamard yöntemiyle çarpılır (Denklem 3.7).

$$h_t = o_t \odot \tanh (c_t) \quad (3.7)$$


Nihai değere bağlı olarak ağ, gizli durumun hangi bilgileri taşıması gerektiğine karar verir. Bu gizli durum tahmin için kullanılır. Son olarak, yeni hücre durumu c_t ve yeni gizli durum h_t , bir sonraki zaman adımına taşınır.

Özetle, unutma kapısı, önceki adımlardan hangi ilgili bilgilerin gerekli olduğunu belirler. Giriş kapısı, mevcut adımdan hangi ilgili bilgilerin eklenebileceğine karar verir ve çıkış kapıları bir sonraki gizli durumu sonlandırır.

3.3.3 Çift yönlü UKSB'ler

Çift yönlü UKSB (BiLSTM), öncelikle doğal dil işlemede kullanılan tekrarlayan bir sinir ağıdır. Standart UKSB'den farklı olarak, girdi her iki yönde akar ve her iki taraftan da bilgi kullanabilir. Aynı zamanda, dizinin her iki yönünde de kelimeler ve ifadeler arasındaki ardışık bağımlılıkları modellemek için güçlü bir araçtır.

Özetle, BiLSTM, bilgi akışının yönünü tersine çeviren bir UKSB katmanı daha ekler. Ardından, her iki UKSB katmanından gelen çıktılar, ortalama, toplam, çarpma veya birleştirme gibi çeşitli yollarla birleştirilebilir. Şekil 3.7'da açılmış BiLSTM sunulmaktadır:



Şekil 3.7 : Çift yönlü tekrarlayan sinir ağı mimarisi. Kaynak: Baeldung

Bu iki gizli katman, aşağıdaki denklemler kullanılarak bir çıktı katmanında birleştirilir. Temsili olarak denklem 3.8, denklem 3.9 ve denklem 3.10’da bir çift yönlü TYSA’ya ait işlem sırası verilmiştir. Çift yönlü UKSB de benzer mantıkla çalışmaktadır.

$$h_t^F = \tanh(W_{xh}^F * X_t + W_{hh}^F * h_{t-1}^F + b_h^F) \quad (3.8)$$

$$h_t^B = \tanh(W_{xh}^B * X_t + W_{hh}^B * h_{t+1}^B + b_h^B) \quad (3.9)$$

$$y_t = W_{hy}^F * h_t^F + W_{hy}^B * h_t^B + b_y \quad (3.10)$$

4. TYSA VE UKSB KULLANILARAK ALTIN FİYATI TAHMİNİ YAPILMASI

4.1 Tahminleme Yöntemleri

İşletmeler talep, kar, gelir, satış miktarı, stok miktarı gibi konularda tahmin yapmak durumundadırlar. Doğru tahmin sonuçları elde etmek için de bilimsel teknikler kullanmaları gerekir. Talep tahmin yöntemleri en genel haliyle iki gruba ayrılmıştır.

- Kalitatif yöntemler (Yargıya dayalı tahmin yöntemleri)

Tahminler, istatistiksel teknikler kullanılmadan, alanında deneyimli kişiler tarafından sübjektif olarak yapılır.

- Kantitatif yöntemler (Sayısal tahmin yöntemleri)
 - Basit Ortalama (Simple Average)
 - Basit Hareketli Ortalama (Simple Moving Average)
 - Basit Üstel Düzleştirme Yöntemi (Simple Exponential Smoothing)
 - Holt Üstel Düzleştirme Yöntemi (Double Exponential Smoothing)
 - Winters Üstel Düzleştirme Yöntemi (Triple Exponential Smoothing)

Tahminleme yöntemleri sürelerine göre kendi içinde 3 grupta incelenmektedir. Kısa vadeli tahminlemeler günlük ve haftalık dönemleri kapsarken orta vadeli tahminler haftalık ve aylık verileri kapsar. Uzun vadeli tahminlemeler ise aylık ve yıllık dönemleri kapsamaktadır.

Yatırımcılar risk almaksızın paralarını katlamak ve yatırımlarının karşılığını almak ister. Yatırım yapılan ürünün kısa ve uzun vadede yatırımında ne tür bir getiri elde edebileceğinin tahmin edilmesi gerekir. Yatırım araçlarında tahminleme yöntemlerinin büyük önem taşıdığı aşıkardır. Yatırım aracının kendi kriterleri ve çevresel faktörler sayesinde ne tür bir hareket yapacağının incelenmesi ve tahmin edilmesi gerekmektedir bu noktada kalitatif ve kantitatif yöntemlere başvurulmaktadır.

4.2 Zaman Serileri

Zaman serisi analizi; Olayları ve süreçleri zaman içinde analiz etmek ve bunları içgörülere dönüştürmek ve tarihsel sonuçları anlamak önemli bir tekniktir. Bu etkileri karakterize eden zamanla değişen olaylardan elde edilen çıkarımlar, nedensel ve anlamlı ilişkiler kurmada çok faydalıdır. İşleri daha iyi (optimal) hale getirmek için bildiğimizden daha fazlasını bilmeye çalışmak, optimizasyon kültüründe gerekli bir kavramdır. Olayların ve olayların zaman boyutuyla etiketlenmesi, zaman boyutunun karakteristik (mevsimsel) özelliklerinden dolayı etkileyeceği durumlarda etkiyi açıklamaya da yardımcı olur. Örnek zaman serisi grafiği Şekil 4.1'den incelenebilir.

Bir zaman serisi 3 ana bileşenden oluşur. Aşağıdaki bileşenlerin, gözlemlenen zaman serilerini sağlamak için bir şekilde birleştiği düşünülebilir. Örneğin, aşağıdaki gibi bir model oluşturmak için bir araya toplanabilirler:

$$y = \text{seviye} + \text{trend} + \text{mevsimsel} + \text{gürültü} \quad (4.1)$$

Tüm bileşenlerin tek bir zaman serisinde olması gerekmez. Herhangi birini veya tümünü içerebilen zaman serileri vardır.

Seviye (Level): Zaman serisinin temel değeridir ve sabit bir sayı ile ifade edilir.

Trend (Eğilim): Veriler uzun vadeli bir yukarı veya aşağı trend gösterdiğinde, trendin yönünü temsil eden bir trend çizgisi oluşur. Bu eğilim çizgisi her zaman doğrusal değildir. Bazı trendler Trend grafiği yukarı yönlü bir eğimden aşağı yönlü bir eğime geçtiğinde (ya da tam tersi) buna yön değiştiren trend denir.

Mevsimsel: Mevsimsel örüntüler; günün saatleri, haftanın günleri veya yılın haftaları gibi döngüsel dönemlere göre sıralanan zaman serilerindeki veriler üzerindeki mevsimsel döngülerin etkilerinden oluşur.


Gürültü (Rastgelelik): Bir zaman serisindeki sıralı olmayan düzensiz hareketlerdir. Rastgele oluşabilir. Bu dalgalanmaların oluşumu öngörülemez.

Döngüsel (Konjonktürel): Zaman serilerinde mevsimsel olmayan ve tamamen nedensel bir faktörün neden olduğu dalgalardan oluşan döngüler de vardır. Bu dalgalanmalar genellikle kriz ve durgunluk gibi ekonomik koşullardan kaynaklanır ve genellikle iş çevrimi ile ilişkilendirilir.

Durağanlık: Bir serinin istatistiğinin zaman içinde değişmemesi anlamına gelir. Bir zaman serisinde ortalama, varyans ve kovaryans zamanla değişiyorsa bu serinin durağan olmadığını söyleyebiliriz. Örneğin, bir zaman serisi türü olan "beyaz gürültü" durağan bir seriye örnektir.

Zaman Serisi Analizleri

- Basit Ortalama Yöntemi
- Hareketli Ortalamalar Yöntemi
- Eksponansiyel (Üstel) Düzgünleştirme Yöntemi
- Trend Analizi Yöntemi
- Mevsimsel Dalgalanmalar ve Trende Oranlama Yöntemi



Şekil 4.1 : Temel bir zaman serisi grafiği.

4.3 Kullanılan Kütüphaneler

Çalışmada Python programlama dili ve Visual Studio Code kaynak kodu düzenleyicisi kullanılmıştır.

Python, modern yazılımlar oluşturmak için gereken esnekliği, basitliği ve güvenilir araçlarıyla kendisini diğer programlama dillerinden ayıran bir programlama dilidir.

Python tutarlıdır ve basitliğe bağlıdır, bu da onu makine öğrenimi için en uygun hale getirir.

Python programlama dili, bağımsız platformu ve programlama topluluğundaki popülaritesi nedeniyle makine öğreniminde çalışma yapan araştırmacılar için ilk seçeneklerden biridir.

Çalışmada kullanılan Python kütüphaneleri ve açıklamaları aşağıdadır:

Numpy: Numpy, Python'da bilimsel hesaplama için temel pakettir. Çok boyutlu bir dizi nesnesi, çeşitli türetilmiş nesneler (maskelenmiş diziler ve matrisler gibi) ve diziler üzerinde matematiksel, mantıksal, şekil işleme, sıralama, seçme, G/Ç dahil olmak üzere hızlı işlemler sağlayan bir Python kütüphanesidir. Ayrık Fourier dönüşümleri, temel lineer cebir, temel istatistiksel işlemler, rastgele simülasyon vb. işlemler bu kütüphane aracılığıyla gerçekleştirilebilir.

Matplotlib: Python'da çizimler ve grafikler oluşturmak için kullanılan modüldür. Matplotlib kütüphanesinin kullanımı oldukça yaygındır, çok önemli faydalar sunar.

Başlıca avantajları şunlardır:

- Kullanım kolaylığı,
- LATEX sembollerinin kullanılabilir olması,
- Grafikler ve stiller üzerinde düzenleme esnekliği,
- Birçok türde (PNG, PDF, SVG, EPS vb.) yüksek kaliteli yayın çıktısı üretebilme,
- Ayrıntılı grafik analizi için basit bir arayüz (GUI) sağlama.

Matplotlib çok büyük bir modül olduğundan daha ayrıntılı bilgi resmî web sayfasında bulunabilir

Scikit Learn: Makine öğrenmesi uygulamaları için geliştirilmiş sınıflandırma, regresyon gibi alanlarda Python diliyle hazırlanmış bir makine öğrenmesi kütüphanesidir, Numpy, SciPy ve Matplotlib üzerine kuruludur. İçeriğinde sınıflandırma, kümeleme, boyut azaltma, model seçimi, veri ön işleme, regresyon modülleri bulunur.

missingno: missingno, veri setinin eksiksizliğinin (veya eksikliğinin) hızlı bir görsel özetinin alınmasını sağlar. Esnek ve kullanımı kolay eksik veri görselleştirmeleri ve yardımcı programlarından oluşan küçük bir araç setidir.

datetime: Datetime modülü, tarih ve saatleri işlemek için sınıflar sağlar. Tarih ve saat aritmetiği desteklenirken, uygulamanın odak noktası, tarih/saat çıktısı biçimlendirme

ve veri manipölasyonu için verimli öznitelik çıkarmadır (*Datetime — Basic Date and Time Types*, 2002).

Statsmodels: İstatistiksel modelleri tahminini ve istatistiksel testler yapılmasını sağlayan bir kütüphanedir. Farklı tipteki verileri işleme, kapsamlı tanımlayıcı istatistiksel yapısı, istatistiksel test çözümleri, takip fonksiyonu ve sonuç istatistik listesi gibi çözümleri ile tercih edilmektedir.

4.4 Veri Seti

Finansal emtia fiyatlarının makine öğrenmesi modelleriyle gelecek tahminini amaçlayan çalışmalarda kullanılabilir, internet ortamında herkesin erişimine açık geçmişe dönük veriye sahip birçok veri seti bulunmaktadır. Bu tez çalışmasında altın fiyatlarına etki ettiği düşünülen aşağıdaki zaman serileri kullanılmıştır.

Çizelge 4.1 : Çalışmada kullanılan değişkenler

Değişken Adı	Değişken Açıklaması	Değişken Türü	Frekans	Tarih Aralığı
EURUSD	Euro / USD Paritesi	Döviz Kuru	Günlük	04.01.1999 - 30.10.2021
USDJPY	USD / Japon Yeni Paritesi	Döviz Kuru	Günlük	01.01.2010 - 31.12.2021
GBPUSD	Sterlin / USD Paritesi	Döviz Kuru	Günlük	01.01.2010 - 22.04.2022
BTCUSD	Bitcoin / USD Paritesi	Kripto Para	Günlük	18.07.2010 - 05.12.2021
XAUUSD	Ons Altın Spot Fiyatı	Emtia	Günlük	01.01.2010 - 08.11.2021
XAGUSD	Ons Gümüş Spot Fiyatı	Emtia	Günlük	01.01.2010 - 01.11.2021
WTI	West Texas Intermediate Ham Petrol Fiyatı	Emtia	Günlük	04.01.2010 - 01.11.2021
LCO	Brent Ham Petrol Fiyatı	Emtia	Günlük	04.01.2010 - 01.11.2021
DX1	ABD Dolar Endeksi	Endeks	Günlük	04.01.2010 - 29.10.2021
NQ100	Nasdaq 100 Endeksi	Endeks	Günlük	04.01.2010 - 08.11.2021
DAX	Alman Birleşik Borsa Endeksi	Endeks	Günlük	04.01.2010 - 11.11.2021
US500	Standart&Poor's 500 Endeksi	Endeks	Günlük	04.01.2010 - 08.11.2021
TRCCRBTR	Thomson Reuters Emtia endeksi	Endeks	Günlük	04.01.2010 - 09.11.2021
LMEX	Londra Metal Borsa Endeksi	Endeks	Günlük	05.01.2010 - 08.11.2021
PFOOD	Gıda Endeksi	Endeks	Aylık	01.01.2010 - 01.10.2021
TXBM	S&P/TSX Global Baz Metaller Endeksi	Endeks	Günlük	04.01.2010 - 24.11.2021
VIX	Volatilite Endeksi	Endeks	Günlük	04.01.2010 - 18.11.2021
Int_FOMC	FOMC Faiz Kararı	Faiz-ABD	Özel Frekans	27.01.2010 - 03.11.2021
Int_FEDFUNDS	FED Etkif Faiz Oranı	Faiz-ABD	Aylık	01.01.2010 - 01.09.2021
DGS10	ABD 10 Yıllık Devlet Tahvili Faiz Oranı	Faiz-ABD	Günlük	04.01.2010 - 12.11.2021
Int_R_US_10Y_D	ABD 10 Yıllık Devlet Tahvili Reel Faiz Oranı	Faiz-ABD	Günlük	04.01.2010 - 31.12.2021
Int_ECB	Avrupa Merkez Bankası Etkif Faiz Oranı	Faiz-AB	Aylık	14.01.2010 - 28.10.2021
T10YIEM	ABD 10 Yıllık Beklenen Faiz Oranı	Enflasyon-ABD	Aylık	01.12.2009 - 01.09.2021
T5YIFRM	ABD 5+5 Yıllık Beklenen Faiz Oranı	Enflasyon-ABD	Aylık	01.12.2009 - 01.09.2021
M1NS_US_BUSD	ABD M1 Para Arzı	Para Arzı	Aylık	01.01.2010 - 01.09.2021
WCURCIR	Dolaşımdaki ABD Doları	Makroekonomi	Haftalık	30.12.2009 - 10.11.2021
WALCL_MUSD	FED Bilançosu	Makroekonomi	Haftalık	30.12.2009 - 20.04.2022
Unemp_US	ABD İşsizlik Oranı	Makroekonomi	Aylık	08.01.2010 - 05.11.2021
GDP_Real	ABD Gayrisafi Yurtiçi Hasıla	Makroekonomi	Çeyreklik	01.01.2009 - 01.07.2021
ADP_NP_Change_k	ABD - ADP Tarım Dışı İstihdam Değişikliği	Makroekonomi	Aylık	06.01.2010 - 03.11.2021

Kullanılacak değişkenler belirlendikten sonra sayısal veriler internet üzerindeki veri tabanlarından çekilip bir Excel dosyasında farklı sekmelerde yerleştirilmiştir.

Python ortamına bu verileri düzenli bir şekilde alabilmek için Python’da veri tabloları üzerinde gelişmiş düzenleme fonksiyonlarına sahip Pandas kütüphanesi kullanılmıştır.

```
dataset_file = 'Kullanilacak_VeriSetleri.xlsm'
sheet_name_list_file = 'SheetNames_to_Import.txt'
sheet_name_list = pd.read_csv(sheet_name_list_path, header = None).values
```

Bazı değişkenlerin isimleri, bulundukları Excel sekmesi isminden farklı olduğu için Python ortamına veri setleri çekilirken hem sekme isimleri hem de veri seti adı kullanılmak zorunda kalmıştır. Bu isim çiftleri aşağıdaki örnekteki gibi SheetNames_to_Import.txt dosyasına yazılmıştır.

Int_FEDFUNDS

Int_US_10Y_D DGS10

İsmi ve sekme ismi farklı olan değişkenler ayrı ayrı yazılmıştır, aynı olan değişkenlerde sadece değişken ismi yazılmıştır. Örneğin, yukarıda “Int_US_10Y_D” sekmenin ismi, “DGS10” değişkenin ismidir.

Aşağıdaki kod ile farklı sekmelerde toplanmış verisetleri Python ortamında oluşturulan Pandas veri tabanlarına aktarılmıştır.

```
merged_dataset_imported = pd.DataFrame(columns = ['Date'])
merged_dataset_imported.set_index('Date', inplace=True)
ind = 1
for i in tqdm(range(len(sheet_name_list))):
    i = sheet_name_list[i]
    splitted_i = i[0].split(sep=" ")
    sheet_name = str(splitted_i[0])
    var_column = str(splitted_i[-1])
    var_dataset = pd.read_excel(dataset_path, sheet_name= sheet_name,
    parse_dates=["Date"], index_col='Date', usecols = ["Date", var_column])
    merged_dataset_imported = merged_dataset_imported.join(var_dataset,
    how='outer')
    ind += 1
```

4.5 Veri Ön İşleme

Veri setlerini Python ortamına aldıktan sonra ön işleme için inceleme yapılmıştır.

```
merged_dataset_imported.info()
```

Çizelge 4.2 : Python’a aktarılan verilerin tipi ve gözlem birimi sayısı.

#	Column	Non-Null	Count	Dtype
0	EURUSD	6029 non-null	float64	
1	USDJPY	3131 non-null	float64	
2	GBPUSD	3211 non-null	float64	
3	BTCUSD	4159 non-null	float64	
4	XAUUSD	3088 non-null	float64	
5	XAGUSD	3684 non-null	float64	
6	WTI	3076 non-null	float64	
7	LCO	3057 non-null	float64	
8	DXY	3086 non-null	float64	
9	NQ100	3100 non-null	float64	
10	DAX	3011 non-null	float64	
11	US500	3092 non-null	float64	
12	TRCCRBTR	2987 non-null	float64	
13	LMEX	1892 non-null	float64	
14	PFOOD	142 non-null	float64	
15	TXBM	2986 non-null	float64	
16	VIX	2997 non-null	float64	
17	Int_FOMC	96 non-null	float64	
18	Int_FEDFUNDS	141 non-null	float64	
19	DGS10	2971 non-null	float64	
20	Int_R_US_10Y_D	3003 non-null	float64	
21	Int_ECB	116 non-null	float64	
22	T10YIEM	142 non-null	float64	
23	TSYIFRM	142 non-null	float64	
24	M1NS_US_BUSD	141 non-null	float64	
25	WCURCIR	620 non-null	float64	
26	WALCL_MUSD	643 non-null	float64	
27	Unemp_US	143 non-null	float64	
28	GDP_Real	51 non-null	float64	
29	ADP_NP_Change_k	143 non-null	float64	

Ardından bu değişkenlerin hangi tarih aralığında bulunduğu incelenmiştir.

```
first_valid_indices = merged_dataset.apply(lambda series:
series.first_valid_index())
last_valid_indices = merged_dataset.apply(lambda series:
series.last_valid_index())


valid_indices = pd.DataFrame([first_valid_indices, last_valid_indices],
index = ("Min Date", "Max Date")).T
valid_indices
```

Çizelge 4.3 : Değişkenlerin geçerli tarih aralığı.

	Min Date	Max Date
EURUSD	4.01.1999	30.10.2021
USDJPY	1.01.2010	31.12.2021
GBPUSD	1.01.2010	22.04.2022
BTCUSD	18.07.2010	5.12.2021
XAUUSD	1.01.2010	8.11.2021
XAGUSD	1.01.2010	1.11.2021
WTI	4.01.2010	1.11.2021
LCO	4.01.2010	1.11.2021
DXY	4.01.2010	29.10.2021
NQ100	4.01.2010	8.11.2021
DAX	4.01.2010	11.11.2021
US500	4.01.2010	8.11.2021
TRCCRBTR	4.01.2010	9.11.2021
LMEX	5.01.2010	8.11.2021
PFOOD	1.01.2010	1.10.2021
TXBM	4.01.2010	24.11.2021
VIX	4.01.2010	18.11.2021
Int_FOMC	27.01.2010	3.11.2021
Int_FEDFUNDS	1.01.2010	1.09.2021
DGS10	4.01.2010	12.11.2021
Int_R_US_10Y_D	4.01.2010	31.12.2021
Int_ECB	14.01.2010	28.10.2021
T10YIEM	1.12.2009	1.09.2021
TSYIFRM	1.12.2009	1.09.2021
M1NS_US_BUSD	1.01.2010	1.09.2021
WCURCIR	30.12.2009	10.11.2021
WALCL_MUSD	30.12.2009	20.04.2022
Unemp_US	8.01.2010	5.11.2021
GDP_Real	1.01.2009	1.07.2021
ADP_NP_Change_k	6.01.2010	3.11.2021

Veri setindeki eksik veriler Şekil 4.2’de görselleştirilmiştir.

```
msno.matrix(merged_dataset);
```




Şekil 4.2 : Veri setinin eksik verilerinin görselleştirilmesi.

Yapılan incelemede EURUSD değişkeninin odaklanılan tarih aralığının dışında geriye dönük olarak alındığı görülmüştür. Veri tablosu 01.01.2010'dan önceki gözlem

birimleri silinir. Değişkenler arasında en erken son tarihli veriye sahip GDP_Real (01.07.2021) değişkeninden dolayı, tüm veri setinin ilgili tarihten sonraki gözlem birimleri silinir.

```
start_date, end_date = '2010-01-01', '2021-07-01'  
merged_dataset_cropped = merged_dataset.loc[start_date:]
```

LMEX değişkeni zaman serisi grafiğine dönüştürülüp incelendiğinde, özellikle 2010-2016 aralığında birçok eksik değer tespit edilmiştir (Şekil 4.3). Bunun nedeni farklı kaynaklardan veri alınması ve 2016'dan önceki verilerin eksikliğidir.



Şekil 4.3 : Eksik verilerden oluşan LMEX grafiği

Tüm değişken, interpolasyon yöntemi kullanılarak bu eksiklikler doldurulmuştur (Şekil 4.4).

```
merged_dataset_cropped.LMEX.interpolate(method="time", inplace=True)  
plt.plot(merged_dataset_cropped.LMEX)
```



Şekil 4.4 : İnterpolasyon yöntemiyle doldurulan LMEX grafiği

Bir sonraki aşamada eksik verilerin hafta sonlarında olup olmadığı, yani piyasa işlem gününde olup olmadığı kontrol edilir.

```
# Hafta sonunda boş olmayan değişkenler (tüm haftanın dolu hücre sayısına göre doluluk oranı)
# X değişkeninin hafta sonu dolu verilerinin tüm dolu verilere oranı (%)
print(weekend_df.notna().sum(axis=0)/merged_dataset_cropped.notna().sum(axis=0)*100)

# Tüm değişkenlerin hafta sonu boş verilerinin tüm gözlem birimi sayısına oranı ortalaması (%)
mean_missing_ratio =
weekend_df.isna().sum(axis=0).mean()/len(weekend_df)*100
print("Ortalama haftasonu boşluk oranı:
%{:.1f}".format(mean_missing_ratio))
```

Çizelge 4.4 : Haftanın günleri başına eksik veri oranı.

Gün	Eksik Veri Oranı (%)
Pazartesi	41.90%
Salı	39.70%
Çarşamba	32.00%
Perşembe	39.20%
Cuma	39.70%
Cumartesi	91.70%
Pazar	88.80%

XAGUSD ve BTCUSD değişkenleri dışındaki değişkenlerin hafta sonu veri eksiklik oranları %95'ten yüksek olduğu için, veri seti sadeleştirme amacıyla hafta sonları (Cumartesi ve pazar günleri) veri setinden çıkartılmıştır.

Hafta içi verilerin eksikliği üzerinde çalışılmıştır. Burada günlük veriler üzerine durulmuştur. Yalnızca iş günleri olan gözlem birimleri dikkate alınmıştır.

```
workday_df = merged_dataset_cropped[merged_dataset_cropped.index.dayofweek <= 4]
workday_missing_count = workday_df.isna().sum(axis=0)
workday_missing_ratio = workday_df.isna().sum(axis=0)/len(workday_df)*100

missing_count_ratio = pd.DataFrame( {'Count' : workday_missing_count}
).join(pd.DataFrame({'Ratio (Workdays with missing values / All
workdays)[%] ' :workday_missing_ratio} ) ,
how='outer').sort_values(by='Ratio (Workdays with missing values / All
workdays)[%] ', ascending=False)
missing_count_ratio
```

Çizelge 4.5 : Değişken başına hafta içi eksik veri sayısı ve oranı

Değişken	Hafta İçi Eksik Gün	Hafta İçi Eksik Gün Sayısı / Tüm Hafta İçi Gün Sayısı
	Sayısı	Oranı (%)
GDP_Real	2965	98.83
Int_FOMC	2908	96.93
PFOOD	2900	96.67
M1NS_US_BUSD	2900	96.67
T5YIFRM	2900	96.67
T10YIEM	2900	96.67
Int_FEDFUNDS	2900	96.67
Int_ECB	2887	96.23
Unemp_US	2862	95.40
ADP_NP_Change_k	2861	95.37
WALCL_MUSD	2400	80.00
WCURCIR	2400	80.00
Int_R_US_10Y_D	122	4.07
DGS10	121	4.03
TXBM	115	3.83
TRCCRBTR	104	3.47
VIX	101	3.37
DAX	84	2.80
EURUSD	49	1.63
WTI	42	1.40
US500	36	1.20
NQ100	36	1.20
LCO	31	1.03
XAGUSD	10	0.33
XAUUSD	5	0.17
LMEX	2	0.07
DXY	1	0.03
USDJPY	0	0.00
BTCUSD	0	0.00
GBPUSD	0	0.00


- Int_R_US_10Y_D ve DGS10 değişkenlerindeki çoğu eksik verinin, New York Stock Exchange (NYSE) ticaret takvimindeki tatil günlerinden kaynaklandığı tespit edilmiştir. Bu tatil günleri çıkartıldıktan sonra kalan günlerin de FED ticaret takvimindeki tatil günlerinden olan Memorial Day ve Columbus Day resmî tatiller kaynaklı eksik olduğu sonucuna varılmıştır.
- VIX, EURUSD, WTI, US500, NQ100, LCO, XAGUSD, XAUUSD, DXY, USDJPY, BTCUSD ve GBPUSD değişkenlerindeki eksik verinin NYSE ticaret takvimindeki tatil günlerinden kaynaklandığı tespit edilmiştir.
- TXBM değişkenindeki eksik verinin Toronto Stock Exchange (XTSE) ticaret takvimindeki tatil günlerinden kaynaklandığı tespit edilmiştir.

- DAX değişkenindeki eksik verinin Frankfurt Stock Exchange (XFRA) ticaret takvimindeki tatil günlerinden kaynaklandığı tespit edilmiştir.
- TRCCRBTR çoğu eksik verinin, New York Stock Exchange (NYSE) ticaret takvimindeki tatil günlerinden kaynaklandığı tespit edilmiştir. Bu tatil günleri çıkartıldıktan sonra verisi tek gün olan 18.02.2010 'a ait bir neden bulunamamıştır. Eksik veri uyarlarken ileriye dönük doldurma yöntemi kullanılmıştır.

Sonraki aşamada daha düşük frekansa sahip (aylık, haftalık, çeyreklik, özel frekans) değişkenlerin eksik verileri, interpolasyon yöntemiyle doldurulmuştur. Eksik değer görselleştirmesinde son 200 güne ait veriler kullanılmıştır.

```
pd.set_option('display.float_format', lambda x: '%0.2f' % x)
ft_list_intrpl = ['PFOOD', 'T10YIEM', 'T5YIFRM', 'M1NS_US_BUSD',
'WCURCIR', 'WALCL_MUSD', 'Unemp_US', 'GDP_Real', 'ADP_NP_Change_k']
df_intrpl =
merged_dataset_cropped[ft_list_intrpl].interpolate(method="time" )
merged_dataset_cropped.loc[:,ft_list_intrpl] = df_intrpl
msno.matrix(merged_dataset_cropped[-200:]);
```

Int_FOMC ve Int_ECB değişkenleri, sırasıyla ABD ve Avrupa merkez bankalarının duyurduğu faiz oranları olduğu için bu değişkenlere interpolasyon uygulanmamıştır.



Şekil 4.5 : Fiyat değişkenleri veri kümelerini doldurduktan sonra genel görünüm.

Şekil 4.5'te sol bölgede görülen boşluklar hafta sonlarına denk gelmektedir. Bunun nedenleri hafta sonunda işlem gününün olmaması ve dolayısıyla verilere ait kapanış değerlerinin genel olarak bulunmamasıdır.

Elde edilen veri setindeki boş veriler, Pandas kütüphanesinin ileriye ve geriye doğru doldurma komutlarıyla (pandas.ffill ve pandas.bfill) doldurulmuştur.

```
filled_df = merged_dataset_cropped.ffill(axis = 0)
filled_df = filled_df.bfill(axis = 0)
msno.matrix(filled_df)
```

Bu sayede veri setindeki tüm boşluklar doldurulmuş olur. Öznitelik seçimi ve tahmin çalışmasına sadece hafta içi verileriyle devam edileceğinden hafta sonlarına ait gözlem birimleri veri setinden kaldırılmıştır.

```
trading_df = filled_df[filled_df.index.dayofweek <= 4 ]
trading_df.describe().T
```

Bu aşamayla birlikte eksik verilerin uygun şekilde doldurulması işlemi tamamlanmıştır. Çizelge 4.6’da veri seti değişkenlerine ait bilgiler verilmiştir.

Çizelge 4.6 : Eksik veriler doldurulduktan sonra veri setine ait çeşitli bilgiler.

Değişken	Adet	Ortalama	Standart Sapma	Minimum	25%	50%	75%	Maksimum
EURUSD	3039	1.22	0.11	1.04	1.12	1.19	1.32	1.48
USDJPY	3039	102.13	13.22	75.82	91.98	106.36	111.06	125.62
GBPUSD	3039	14.52	1.44	11.49	13.08	14.82	15.78	17.17
BTCUSD	3039	5260.34	10778.09	0.10	14.10	516.10	6781.95	63540.90
XAUUSD	3039	1410.34	229.79	1051.74	1236.27	1320.58	1599.23	2063.19
XAGUSD	3039	21.86	6.47	11.98	17.21	18.98	26.13	48.58
WTI	3039	69.14	22.62	-37.63	50.13	65.07	91.51	113.93
LCO	3039	76.12	26.27	19.33	54.75	70.34	105.98	126.65
DXY	3039	89.15	8.10	72.93	80.72	91.89	96.47	103.30
NQ100	3039	5380.14	3227.00	1728.30	2747.45	4437.60	7042.75	15618.00
DAX	3039	10105.13	2659.36	5072.33	7502.28	10298.53	12287.23	15977.44
US500	3039	2192.90	811.18	1014.25	1441.00	2074.25	2749.63	4525.25
TRCCRBTR	3039	235.80	58.72	112.85	187.26	213.47	291.29	370.73
LMEX	3039	3123.04	515.81	2060.92	2795.40	3090.12	3392.27	4468.32
PFOOD	3039	109.80	11.46	92.32	100.30	105.82	120.64	137.29
TXBM	3039	118.41	26.89	53.14	103.96	115.56	131.66	191.04
VIX	3039	18.07	7.26	9.14	13.35	16.15	20.62	82.69
Int_FOMC	3039	0.69	0.72	0.25	0.25	0.25	1.00	2.50
Int_FEDFUNDS	3039	0.56	0.73	0.05	0.09	0.16	0.85	2.42
DGS10	3039	2.22	0.70	0.52	1.77	2.23	2.69	4.01
Int_R_US_10Y_D	3039	0.25	0.62	-1.19	-0.08	0.40	0.66	1.70
Int_ECB	3039	0.33	0.46	0.00	0.00	0.05	0.75	1.50
T10YIEM	3039	1.96	0.33	0.99	1.72	2.01	2.19	2.60
T5YIFRM	3039	2.19	0.37	1.30	1.93	2.16	2.53	2.89
M1NS_US_BUSD	3039	4656.98	4874.41	1674.20	2455.70	3056.20	3698.40	19875.30
WCURCIR	3039	1434.05	343.52	917.92	1153.22	1396.98	1686.89	2189.39
WALCL_MUSD	3039	4197508.46	1411307.38	2235304.00	2925722.00	4244188.00	4478236.00	8349173.00
Unemp_US	3039	6.40	2.24	3.50	4.40	5.90	8.20	14.70
GDP_Real	3039	17431.03	1175.68	15456.06	16300.04	17437.08	18590.00	19465.20
ADP_NP_Change_k	3039	57.56	1686.41	-20236.00	135.00	187.00	219.00	2369.00

4.5.1 Aykırı değerlerin kaldırılması

Bir makine öğrenme modeli hazırlarken harcanan vaktin önemli bir kısmı veri ön işleme ve kalan kısmının model seçimidir (García vd., 2015). Gerçekten de modelin önyargısız ve hatasız sonuç üretmesi için verinin modele uygun yöntemlerle tanıtılması gerekmektedir. Bu yöntemlerden biri de aykırı değer analizidir. Aykırı değer, bir verinin veri kümesindeki diğer gözlemlerden yüksek oranda farklı olduğu herhangi bir veri noktasıdır. Başka bir deyişle, genel eğilimin dışındaki gözlemdir. Aykırı değerler, istatistiksel modellerimizin ve analizlerimizin sonuçlarını istenmeyen yönde etkileyebilir. Aykırı değerli bir veri setiyle eğitilen bir makine öğrenmesi modeli aşırı uydurma hatasını artırır, bu nedenle aykırı değerlerin tespit edilmesi ve üzerinde işlem yapılması gerekmektedir.

Bu çalışmada zaman serisine özel bir yöntem olan standart sapma yöntemi kullanılmıştır.

Her bir değişken kendi içinde ayrı ayrı incelenmiştir. Standart sapma grafikleri oluşturulurken her tarih için veri setindeki ilk tarih ve mevcut tarih aralığını içeren bir alt veri seti oluşturulmuştur. Bu veri setindeki değerlerin standart sapması standart sapma grafiğinde mevcut tarihin karşısına yazılmıştır. Son olarak fark alma işlemi uygulanmıştır.

```
def detect_outliers(df, start_date, end_date):
    for var in df.columns:
        ind_df = df.loc[start_date:end_date][var]
        #infer the frequency of the data
        ind_df = ind_df.asfreq(pd.infer_freq(ind_df.index))
        #print(ind_df.head())
        rolling_deviations = pd.Series(dtype=float, index = ind_df.index)
        for date in rolling_deviations.index:
            #get the window ending at this data point
            window = ind_df.loc[:date]
            #get the deviation within this window
            rolling_deviations.loc[date] = window.std()
        #get the difference in deviation between one time point and the
        next
        diff_rolling_deviations = rolling_deviations.diff()
        diff_rolling_deviations = diff_rolling_deviations.dropna()

        plt.figure(figsize=(10,4))
        plt.plot(diff_rolling_deviations[start_date:end_date])
```


```

plt.title('Deviation Differences', fontsize=20)
plt.ylabel(('Var: ' + var), fontsize=16)
for year in range(start_date.year, end_date.year):
    plt.axvline(pd.to_datetime(str(year) + '-01-01'), color='k',
linestyle='--', alpha=0.2)

min_dev = 9999999
curr_anomaly = None
for date in ind_df.index:
    other_data = ind_df[ind_df.index != date]
    curr_dev = other_data.std()
    if curr_dev < min_dev:
        min_dev = curr_dev
        curr_anomaly = date
print("Var: ", var, "Current anomaly time: ", curr_anomaly)

```

Örnek bir aykırı değer tespit grafiği Şekil 4.6’da gösterilmiştir.



Şekil 4.6 : WTI veri setinin aykırı değer tespiti.

Her bir çıktının aykırı değeri verilmiştir. Örnek olarak WTI değişkeninin zaman serisinde 2020-04-20 tarihinde bir aykırı değer tespit edilmiştir. Aykırı değer grafiğinde ilk bölgeler güvenilir sonuç vermez. Çünkü bu bölgede üzerinde çalışılan veri sayısı daha azdır. Ve eklenen her bir veriyle standart sapma sert bir biçimde değişebilir.

Üzerinde çalışılan veri setinde önerilen aykırı değerlerden 3 aykırı değer düzeltilmiştir.

```

rm_outliers_dataset = filled_dataset.copy()
rm_outliers_dataset['WTI'].loc['2020-04-20'] = np.nan
rm_outliers_dataset['VIX'].loc['2020-03-12'] = np.nan
rm_outliers_dataset['XAUUSD'].loc['2020-08-06'] = np.nan
rm_outliers_dataset.interpolate(inplace=True)

```

4.5.2 Veri yumuşatma

Herhangi bir zaman serisinin değerlerini doğru bir şekilde tahmin etmek için, karar verilen bir aralığın dışına çıkan ve zaman serilerinde olağandışı dalgalanmalara neden olan değerlerin kaldırılması esastır. Örneğin, bir yıllık petrol fiyat serisi 99-100 USD arasındaki fiyatlardan oluşur. Ancak, arz sıkıntısı nedeniyle birkaç gün için fiyatın 105 USD'nin üzerine çıktığını varsayalım. Herhangi bir zaman serisindeki bu tür dalgalanma, fiyatların tahmini için herhangi bir modelde belirsizliğe neden olabilir. Bu dalgalanma modellemede gerekli değildir, bu yüzden filtreler kullanarak bunlar kaldırılabilir. İyi bir filtrenin, belirli bir frekanstaki ya da frekanstan bağımsız verilerin dalgalanmalarını izole edebilmesi gerekir.

Öncelikle veriler kategorik, seviye, oran ve değişim başlıkları altında gruplandırılmıştır.

```
df = data.copy()
df_vars_cat = ['Int_FOMC', 'Int_ECB']

df_vars_ratio = [ 'Int_FEDFUNDS',
                  'DGS10', 'Int_R_US_10Y_D',          # Gunluk
                  'T10YIEM', 'T5YIFRM', 'Unemp_US']    # Aylik

df_vars_level = ['EURUSD', 'USDJPY', 'GBPUSD', 'BTCUSD',
                 'XAUUSD', 'XAGUSD', 'WTI', 'LCO', 'DXY',
                 'NQ100', 'DAX', 'US500', 'TRCCRBTR', 'LMEX',
                 'TXBM', 'VIX',                      # Gunluk
                 'MINS_US_BUSD', 'WCURCIR',          # Haftalik
                 'PFOOD', 'WALCL_MUSD',              # Aylik
                 'GDP_Real']                          # Ceyreklik


df_vars_change = 'ADP_NP_Change_k'                  # Aylik
```

Çalışmada kullanılan Savitzky-Golay filtresi ile verilerin günlük aşırı sapmalarından oluşan rassal bileşen baskılanmıştır. Savitzky-Golay filtresi, verileri düzgünleştirmek, yani sinyal eğilimini bozmadan verilerin kesinliğini artırmak amacıyla bir dizi dijital veri noktasına uygulanabilen bir dijital filtredir. Bu, konvolüsyon olarak bilinen bir süreçte, lineer en küçük kareler yöntemiyle düşük dereceli bir polinomla ardışık veri noktalarının ardışık alt kümelerinin uydurulmasıyla elde edilir. Veri noktaları eşit aralıklarla yerleştirildiğinde, en küçük kareler denklemlerinin analitik bir çözümü,

düzgünleştirilmiş tahminleri vermek için tüm veri alt kümelerine uygulanabilen tek bir "evrişim katsayıları" kümesi biçiminde bulunabilir (Savitzky ve Golay, 1964).

```
def savitzky_golay(y, window_size, order, deriv=0, rate=1):
    try:
        window_size = np.abs(np.int(window_size))
        order = np.abs(np.int(order))
    except ValueError:
        raise ValueError("window_size and order have to be of type int")
    if window_size % 2 != 1 or window_size < 1:
        raise TypeError("window_size size must be a positive odd number")
    if window_size < order + 2:
        raise TypeError("window_size is too small for the polynomials order")
    order_range = range(order+1)
    half_window = (window_size -1) // 2
    # Katsayıların ön hesaplaması
    b = np.mat([[k**i for i in order_range] for k in range(-half_window, half_window+1)])
    m = np.linalg.pinv(b).A[deriv] * rate**deriv * factorial(deriv)
    # sinyalin kendisinden alınan değerlerle sinyali uç noktalarda doldur.
    firstvals = y[0] - np.abs( y[1:half_window+1][::-1] - y[0] )
    lastvals = y[-1] + np.abs(y[-half_window-1:-1][::-1] - y[-1])
    y = np.concatenate((firstvals, y, lastvals))
    return np.convolve( m[::-1], y, mode='valid')
```

Örneğin XAUUSD serisinin filtreye ait iki hiper parametre olan pencere genişliği ve üs katsayısı kullanarak veri yumuşatma sonuçları Şekil 4.7’de verilmiştir.



Şekil 4.7 : Savitzky-Golay ile XAUUSD zaman serisinin veri yumuşatması.

Çalışmada 13 pencere aralığı ve 2 üstel katsayı parametresi kullanılmıştır. Sadece oran ve seviye içeren veri setleri bu filtreden geçirilmiştir. Int_ECB ve Int_FOMC değişkenleri filtrelenmemiştir.

```
df = data.copy()
df_levels_ratios = df[df_vars_level].join(df[df_vars_ratio], how='outer')
for var in df_levels_ratios.columns:
    smoothed_df = savitzky_golay(df_levels_ratios[var], window_size=13,
order=2)
    df_levels_ratios[var] = pd.DataFrame(smoothed_df,
index=df_levels_ratios.index)
df_levels_ratios.head()
```

4.5.3 Veri gruplama

İstatistiksel veri gruplama, az ya da çok sürekli değerlerin sayılarını daha az sayıda temsili bir değere veya öğeye gruplandırmanın bir yoludur. Örneğin, bir grup insan yaş verileri, yaşlarını daha az sayıda yaş aralığıyla (örneğin, her beş yılda bir gruplama) temsil edecek şekilde düzenlenebilir. Aynı anda birkaç boyutta gruplama yaparak çok değişkenli istatistiklerde de kullanılabilir.

Çalışmada Int_ECB ve Int_FOMC veri setlerinde bulunan faiz değerleri gruplanmıştır. Int_FOMC için 0,0 – 0,26 aralığı, 0,26 – 1,40 aralığı ve 1,40 – 2,51 aralığı sırasıyla 1, 2 ve 3 rakamlarıyla temsil edilecektir.

Int_ECB için -0,10 – 0,16 aralığı, 0,16 – 0,76 aralığı ve 0,76 – 1,51 aralığı sırasıyla 1, 2 ve 3 rakamlarıyla temsil edilecektir.

```
def binning_function(df):
    df = df.assign(
Int_FOMC = pd.cut(df.Int_FOMC, bins=[ 0.0, 0.26, 1.4, 2.51] ,
labels = [1, 2, 3] ),
Int_ECB = pd.cut(df.Int_ECB, bins= [-0.1, 0.16, 0.76, 1.51],
labels = [1, 2, 3] ))
    return df
df_levels_ratios_cats = df_levels_ratios.join(df[df_vars_cat],
how='outer')
df_levels_ratios_cats = binning_function(df_levels_ratios_cats)
```

4.6 Öznitelik Seçimi

Çalışmada ilk olarak Rastgele Orman Regresyonu ve Lineer Regresyon kullanarak öznitelik seçimi yapılmıştır. SelectFromModel sınıfı özniteliklerin alt setlerinin seçimini düzenlemek için kullanılmıştır. Rastgele Orman Regresyonu ile öznitelik seçiminde eğitim verilerinden ilişki öğrenilmiştir. Öznitelikler ve etiket verilerinin tümü, etiket olarak 5 gün sonraki altın fiyatı kullanılmıştır.

```
def select_features(X_train, y_train, X_test, max_ft):
    fs = SelectFromModel(RandomForestRegressor(n_estimators=1000),
max_features=max_ft)
    fs.fit(X_train, y_train)
    X_train_fs = fs.transform(X_train)
    X_test_fs = fs.transform(X_test)
    return X_train_fs, X_test_fs, fs

def feature_selection_time_series_regression(df_features, df_label,
test_size):
    for i in range(len(df_features.columns)):
        # Ana veri seti eğitim ve test setlerine bölünür
        X_train, X_test, y_train, y_test = train_test_split(df_features,
df_label, test_size=test_size, shuffle=False)
        X_train_fs, X_test_fs, fs = select_features(X_train, y_train,
X_test, i+1)
        selected_bool = fs.get_support()
        mask = np.invert(selected_bool)
        mx = ma.masked_array(df_features.columns, mask)
        print("mx: ",mx)
        model = LinearRegression()
        model.fit(X_train_fs, y_train)
        # Eğitilen modelin tahminlemesi
        yhat = model.predict(X_test_fs)
        # Tahminin değerlendirilmesi
        calced_metric = mean_squared_error(y_test, yhat)
        print('Selected vars: {0}, Metric: {1}'.format(i+1,
calced_metric))

df_input_fs['XAUUSD_label'] = df_input_fs.shift(-5)['XAUUSD']
df_input_fs.drop('XAUUSD', axis=1, inplace= True)
df_input_fs.dropna(inplace=True)
df_input_fs_features = df_input_fs.drop('XAUUSD_label', axis=1)

feature_selection_time_series_regression(df_input_fs_features,
df_input_fs.XAUUSD_label, test_size=0.2)
```

Çizelge 4.7 : Lineer regresyon ve rastgele karar ağaçları ile öznitelik seçimi.

Seçilecek Değişken Sayısı	Seçilen Değişkenler	Metrik
1	USDJPY	202899.44
2	USDJPY, T10YIEM	208834.97
3	USDJPY, T10YIEM, Int_R_US_10Y_D	78006.01
4	USDJPY, T10YIEM, Int_R_US_10Y_D, GDP_Real	48763.28
5	USDJPY, T10YIEM, Int_R_US_10Y_D, GDP_Real, WCURCIR	67729.02

Algoritma ilerledikçe seçilecek değişken sayısı sabit kalmış ve ortalama karesel hata daha fazla düşmemiştir.


4.6.1 Kovaryans matrisi ve ısı haritası

Kovaryans yalnızca iki değişken arasında hesaplanabildiğinden kovaryans matrisleri, çok değişkenli verilerde her bir değişken çiftinin kovaryans değerlerini temsil eder. Ayrıca, aynı değişkenler arasındaki kovaryans varyansa eşittir, bu nedenle köşegen her bir değişkenin varyansını gösterir. Bir veri setinde x ve y’den oluşan iki değişken olduğu varsayılırsa, kovaryans matrisi Formül 4.1’teki gibi, x, y ve z ‘den oluşuyorsa kovaryans matrisi Formül 4.2’teki gibi olacaktır:

$$\begin{matrix} & \begin{matrix} x & y \end{matrix} \\ \begin{matrix} x \\ y \end{matrix} & \begin{bmatrix} var(x) & cov(x, y) \\ cov(x, y) & var(y) \end{bmatrix} \end{matrix} \quad \begin{matrix} x & y & z \\ \begin{bmatrix} var(x) & cov(x, y) & cov(x, z) \\ cov(x, y) & var(y) & cov(y, z) \\ cov(x, z) & cov(y, z) & var(z) \end{bmatrix} \end{matrix} \quad (4.1)$$

$$\begin{matrix} & \begin{matrix} x & y \end{matrix} \\ \begin{matrix} x \\ y \end{matrix} & \begin{bmatrix} var(x) & cov(x, y) \\ cov(x, y) & var(y) \end{bmatrix} \end{matrix} \quad \begin{matrix} & \begin{matrix} x & y & z \end{matrix} \\ \begin{matrix} x \\ y \\ z \end{matrix} & \begin{bmatrix} var(x) & cov(x, y) & cov(x, z) \\ cov(x, y) & var(y) & cov(y, z) \\ cov(x, z) & cov(y, z) & var(z) \end{bmatrix} \end{matrix} \quad (4.2)$$

Bu çalışmada bağımlı XAUUSD değişkeni dahil kovaryans matrisi hesaplaması yapılmış, ısı haritası oluşturularak değişkenlerin birbiriyle korelasyonu incelenmiştir. Rahat anlaşılması bakımından korelasyon değerleri [-100, +100] aralığına ölçeklenmiş, korelasyon değerlerinin mutlak değeri alınmış, değerler 0’dan 100’e kadar renklendirilmiştir. [-0.3, +0.3] aralığında olan korelasyon değerleri yazılmamıştır. Kovaryans matrisi simetrik bir matris olduğundan matrisin sadece ana köşegeninin altındaki üçgen yarısı gösterilmiştir.



Şekil 4.8 : Değişkenlerin kovaryans matrisinden elde edilen ısı haritası.

4.6.2 PCA

Şekil 4.8’den görüldüğü üzere ana veri setindeki pek çok değişken birbiriyle yüksek korelasyonludur. Çalışmada, çok sayıda değişkenin yüksek varyansı elde tutarken boyut azaltmak için Temel Bileşenler Analizi (PCA) kullanılmıştır. PCA yüksek boyutlu verilerdeki ortak özellikleri tespit ederek boyutta azaltma yani verinin çok yüksek bir kayıp olmadan sıkıştırılmasını sağlar. Genel bilgiyi ortaya çıkarmada kullanılan önemli bir yöntemdir.

Veri seti üzerinde PCA yöntemini uygulayabilmek için sklearn kütüphanesinden PCA modülü kullanılmıştır.

Artan değişken sayısı, tüm veri setinin daha iyi temsil edilmesini sağlayacak olmasına rağmen, belli bir sayıdan sonra işlem gücü ve analiz süresini uzatacaktır.

Çizelge 4.8 : PCA analizi sonucu.

Bileşen Sayısı	Kümülatif Açıklanabilir Varyans (%)	Değişim (%)
1	65.38	-
2	82.74	26.55
3	89.77	8.50
4	93.05	3.65
5	95.77	2.92
6	97.16	1.45
7	97.90	0.76
8	98.55	0.66
9	98.91	0.37
10	99.17	0.26
11	99.33	0.16
12	99.48	0.15
13	99.58	0.10
14	99.67	0.09
15	99.75	0.08
16	99.81	0.06
17	99.86	0.05
18	99.90	0.04
19	99.93	0.03
20	99.95	0.02

6. bileşenden sonra temsil yeteneğinde önemli bir iyileştirme hesaplanmamıştır.

PCA yöntemiyle ana veri setini temsil eden en önemli değişkenler WTI, Int_R_US_10Y_D, BTCUSD, XAGUSD, LMEX, T10YIEM, TXBM, M1NS_US_BUSD ve VIX olarak tespit edilmiştir.

4.7 Öznitelik Çıkarma

4.7.1 MACD ve LMACD


Bir yatırım aracının alımı ve satımı için doğru zaman hakkında fikir veren hareketli ortalama yakınsama sapması (moving average convergence divergence, MACD), yatırımcıların zararlarını en aza indirmek için piyasaya giriş ve çıkışlarını zamanlamalarına yardımcı olurlar. Bundan dolayı altın fiyatlarının tahmininde bu öznitelikler de kullanılacaktır. MACD ve LMACD işlemi, XAUUSD değişkeninin verileri kullanılarak oluşturulmuştur.

Bu indikatörler hesaplanırken standartta olduğu gibi kısa pencere, uzun pencere ve sinyal pencere boyutları, sırasıyla 12, 26 ve 9 gün olarak seçilmiştir. Çıktı olarak

MACD, MACD-sinyal, MACD-histogram, LMACD, LMACD-sinyal ve LMACD-histogram değerlerinden yeni veri setleri oluşturulmuştur.

4.7.2 Mevsimsel ayrıştırma


Çalışmanın başında da söylendiği gibi küresel altın fiyatları pek çok sosyal, ekonomik ve politik değişkenden etkilenebilmektedir. Altın fiyatının aynı zamanda mevsimsel olarak etkilenip etkilenmediği, yani sürekli aynı periyotta dalgalanıp dalgalanmadığını tespit etmek için mevsimsel ayrıştırma yöntemi kullanılmıştır.



Şekil 4.9 : XAUUSD değişkeninin 2010-2020 dönemi için mevsimsel ayrıştırması.

Şekil 4.9 incelendiğinde trend grafiğinin toplam grafiğe çok benzediği, mevsimsel bileşenin genliğinin rassal ve trend bileşenlerden çok düşük kaldığı görülmektedir. Bu durumda mevsimsellik ya hiç yoktur ya da önemsizmeyecek kadar küçüktür.

Grafik yaklaştırıldığında (Şekil 4.10) mevsimselliğin haftalık olduğu anlaşılmıştır. Mevsimsel bileşen grafiğinde, çalışma haftası başında ve sonunda düşen altın fiyatlarının çarşamba günleri en yüksek değere olduğu tespit edilmiştir. Düşük bir mevsimselliğe sahip olsa da veri seti kombinasyonlarına haftanın günü değişkeni de Pazartesi (0), ..., Cuma (4) olacak şekilde eklenmiştir.



Şekil 4.10 : XAUUSD değişkeninin 05/2019-08/2019 dönemi için mevsimsel ayrıştırması.

4.8 Tahmin Modeli Oluşturma

Testlerde kullanılacak ortak parametreler Çizelge 4.9’da değiştirilecek parametreler de Çizelge 4.10’da verilmiştir.

Çizelge 4.9 : Testlerde kullanılacak ortak parametreler.

Ortak Parametreler	Değer
UKSB birimi sayısı	128 düğümlü tek katman
Test Seti Başlangıç Tarihi	2021-01-01
Tahmin Edilen Gün	Ertesi Gün (t+1)
Veri Seti Yumuşatma Metodu	Savitzky Golay, window=13, order=2
Öğrenme oranı	0,001

Çizelge 4.10 : Testlerde değiştirilecek parametreler.

Değişen Parametreler	Değer / Açıklama
Veri Seti	15 kombinasyon
Ağ Modeli	TYSA, UKSB
Parti Boyutu (Batch Size)	16, 32, 48, 64
Girdi Zaman Penceresi Boyutu	30, 60, 90

Veri ön işleme ve özellik mühendisliği çalışmalarından sonra oluşturulacak tahmin modelinde Çizelge 4.11’deki veri seti kombinasyonları kullanılmıştır.

Çizelge 4.11 : Seçilen veri seti kombinasyonları.

Kombinasyon Adı	XAUUSD	XAGUSD	USDJPY	Int_R_US_10Y_D	T10YIEM	WCURCIR	M1NS_US_BUSD	Unemp_US	LMEX	VIX	XAUUSD_nom_macd	XAUUSD_nom_macd_s	XAUUSD_nom_macd_h	XAUUSD_nom_Lmacd	XAUUSD_nom_Lmacd_s	XAUUSD_nom_Lmacd_h	Day of Week
model0_base	X	X	-	X	-	-	-	X	X	X	-	-	-	-	-	-	X
model0_macd	X	X	-	X	-	-	-	X	X	X	X	X	X	-	-	-	X
model0_both	X	X	-	X	-	-	-	X	X	X	X	X	X	X	X	X	X
model0_Lmacd	X	X	-	X	-	-	-	X	X	X	-	-	-	X	X	X	X
model0_hist	X	X	-	X	-	-	-	X	X	X	-	-	X	-	-	X	X
model1_base	X	X	X	X	X	X	X	-	-	-	-	-	-	-	-	-	X
model1_macd	X	X	X	X	X	X	X	-	-	-	X	X	X	-	-	-	X
model1_both	X	X	X	X	X	X	X	-	-	-	X	X	X	X	X	X	X
model1_Lmacd	X	X	X	X	X	X	X	-	-	-	-	-	-	X	X	X	X
model1_hist	X	X	X	X	X	X	X	-	-	-	-	-	X	-	-	X	X
model2_base	X	X	X	X	X	X	X	-	X	X	-	-	-	-	-	-	X
model2_macd	X	X	X	X	X	X	X	-	X	X	X	X	X	-	-	-	X
model2_both	X	X	X	X	X	X	X	-	X	X	X	X	X	X	X	X	X
model2_Lmacd	X	X	X	X	X	X	X	-	X	X	-	-	-	X	X	X	X
model2_hist	X	X	X	X	X	X	X	-	X	X	-	-	X	-	-	X	X

4.8.1 Tensorflow ve Keras

Tensorflow (www.tensorflow.org), Google tarafından geliştirilen bir makine öğrenimi kütüphanesidir. Birçok sayısal ve karmaşık hesaplama gerektiren yüksek performanslı uygulamalar için çok güçlüdür. CPU'lar ve GPU'lar gibi birçok donanım türünde ve ayrıca mobil cihazlarda kullanılabilir. Tensorflow deneylerde kullanılan ana kütüphanedir. Keras (www.keras.io), Tensorflow, Theano ve Caffee gibi makine öğrenimi kitaplıklarının üzerinde kullanılabilen üst düzey bir kütüphane olarak kabul edilen makine öğrenimi ve derin öğrenme için bir kütüphanedir ve geniş bir geliştirici topluluğuna sahiptir. Model oluşturulurken Tensorflow üzerinde daha kapsamlı kontrol için Keras kullanılmıştır.

Bu çalışmada kullanılan yapay sinir ağı modelleri, daha önceki bölümlerde bahsedildiği gibi TYSA ve UKSB'dir. Modellerin mekanizmaları ile ilgili tüm detaylar ele alınmıştır ve son olarak çalışmada elde edilen tüm sonuçlar sunulmuştur.

4.8.2 Tekrarlayan YSA ve UKSB mekanizmaları

Çalışmada kullanılan ağ mimarileri temel TYSA ve temel UKSB'dir. Çalışmada veri seti kombinasyonları ve veri parametrelerinin tahmin sistemindeki etkisi incelendiğinden ağ modelleri sade seçilmiştir.

Deneylerde kullanılan gözlem birimi sayısı zaman adımı değiştiğinden deneyden deneye farklılık göstermektedir. Örnek olarak 30 gözlem birimi, 10 zaman adımı ve 11 öznitelik girişi olan bu ağların yapısı Çizelge 4.12'de verilmiştir.

Çizelge 4.12 : Deneylerde kullanılan ağların katman yapısı

Layer (type)	Output Shape	Param #
simple_rnn (SimpleRNN)	(None, 128)	17920
dropout_1 (Dropout)	(None, 128)	0
dense_4 (Dense)	(None, 1)	129
Total params:	18,049	
Trainable params:	18,049	
Non-trainable params:	0	

Layer (type)	Output Shape	Param #
lstm_1 (LSTM)	(None, 128)	71680
dropout_2 (Dropout)	(None, 128)	0
dense_5 (Dense)	(None, 1)	129
Total params:	71,809	
Trainable params:	71,809	
Non-trainable params:	0	

4.9 Değerlendirme Yöntemi

Bu çalışmada iki farklı değerlendirme yöntemi kullanılmıştır.

Bu değerlendirme yöntemleri makine öğrenmesi uygulamalarında regresyon/tahmin problemleri için sıklıkla kullanılan ortalama karesel hata (MSE) hesaplaması tabanlıdır. Çalışmada yapılan tahmin hatalarının karelerinin ortalamasını hesaplamak için kullanılmıştır. Eğitimle oluşturulan regresyon eğrisi ile gerçek verilerin aralarındaki uzaklığın bir ölçüsüdür (Formül 4.1).

$$MSE = \frac{1}{n} * \sum_{i=1}^n (y_i - y_{tahmin})^2 \quad (4.1)$$

İlk yöntem, temsili kayıp fonksiyonudur. Her testte model 30 dönem (epoch) eğitilmiştir. Son 10 döneme ait doğrulama hatası MSE kullanılarak hesaplanıp ortalaması alınmıştır. Bu ortalama, çalışmada temsili kayıp fonksiyonu olarak değerlendirilmiştir.

İkinci yöntem, test seti tahmin hatasıdır. Test seti üzerinde yapılan tahmin değerleri ve test setindeki gerçek (hedef) değerler zaman ekseninde Serilere dökülmüştür. Bu seriler arasındaki ortalama karesel hata değerleri, test seti tahmin hatası olarak değerlendirilmiştir.





5. SİMÜLASYON SONUÇLARI

Ek A'da verilen kombinasyonlarda ağ eğitimi ve fiyat tahmin işlemleri gerçekleştirilmiştir. Mevcut geçmişe dönük veriler kullanılarak 1 gün sonrasının altın fiyat tahmini yapılmıştır. Pencere boyutu, gözlem birimi oluştururken geçmişe dönük verilerin kaç güne kadar alınacağını belirleyen hiper parametredir. Eğitim sırasında öğrenme durumunu izleyebilmek amacıyla, eğitim seti zaman serisi olduğu için sırası karıştırılmadan, gözlem birimi sayısınınca 10/90 oranında doğrulama/eğitim verisine ayrılmıştır. Kayıp fonksiyonu, ortalama kare hatası yöntemi kullanılarak hesaplanmıştır. Her dönem sonrasında doğrulama tahmini çalıştırılmış, oluşturulan grafikte döneme ait eğitim kayıp fonksiyonu ve doğrulama kayıp fonksiyonu çizdirilmiştir.

Bu çalışmada kullanılan “temsili kayıp fonksiyonu değeri” kavramı, 30’ar dönem eğitilen her bir testin son 10 dönemi için hesaplanan doğrulama kayıp fonksiyonu değerlerinin ortalaması için kullanılmıştır.

Eğitimin uygun gerçekleşip gerçekleşmediğini kontrol etmek için eğitim seti kullanılarak eğitilen model, yine eğitim seti üzerinde tahminleme yapılarak çizdirilmiştir.


Sonraki adımda, tahmin işlemi test verisi üzerinde gerçekleştirilmiştir. Her test için tahmin edilen altın fiyatı ve gerçek altın fiyatı aynı şekle eklenmiştir.

Oluşturulan sonuç grafiklerinin sayısı göz önüne bulundurulduğunda, tüm grafiklerin bu çalışmaya eklenmesi mantıklı olmayacaktır. Temsili kayıp fonksiyonu en düşük ilk 10 test sonucu (5’i UKSB ve 5’i TYSA) ve test seti tahmini kriterine göre en iyi sonuçları veren ilk 10 test sonucu (5’i UKSB ve 5’i TYSA) sonraki bölümde verilmiştir. Her kriter için ortak bir açıklama test sonuçları verildikten sonra yapılmıştır.


5.1 Temsili Kayıp Fonksiyonu En Düşük Test Sonuçları

5.1.1 TYSA ağı


df: model0_base, batch:16, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0117



df: model0_base, batch:16, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0117




df: model0_base, batch:16, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0117



Şekil 5.1 : Test 2 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: base, parti boyutu: 16, pencere boyutu: 60)


df: model0_macd, batch:16, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0157



df: model0_macd, batch:16, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0157




df: model0_macd, batch:16, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0157




Şekil 5.2 : Test 14 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: macd, parti boyutu: 16, pencere boyutu: 60)


df: model0_base, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0195



df: model0_base, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0195




df: model0_base, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0195




Şekil 5.3 : Test 5 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: base, parti boyutu: 32, pencere boyutu: 60)


df: model0_base, batch:16, test from: 2021-01-01, time_steps: 30, rep_valloss: 0.0219



df: model0_base, batch:16, test from: 2021-01-01, time_steps: 30, rep_valloss: 0.0219




df: model0_base, batch:16, test from: 2021-01-01, time_steps: 30, rep_valloss: 0.0219



Şekil 5.4 : Test 1 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: base, parti boyutu: 16, pencere boyutu: 30)


df: model0_macd, batch:32, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0231



df: model0_macd, batch:32, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0231




df: model0_macd, batch:32, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0231




Şekil 5.5 : Test 18 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: macd, parti boyutu: 32, pencere boyutu: 90)

5.1.2 UKSB ağı


df: model1_base, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0208



df: model1_base, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0208




df: model1_base, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0208




Şekil 5.6 : Test 245 sonuçları (Ağ: UKSB, Veri seti: model1, varyant: base, parti boyutu: 32, pencere boyutu: 60)


df: model2_macd, batch:64, test from: 2021-01-01, time_steps: 30, rep_valloss: 0.0271



df: model2_macd, batch:64, test from: 2021-01-01, time_steps: 30, rep_valloss: 0.0271




df: model2_macd, batch:64, test from: 2021-01-01, time_steps: 30, rep_valloss: 0.0271




Şekil 5.7 : Test 322 sonuçları (Ağ: UKSB, Veri seti: model2, varyant: macd, parti boyutu: 64, pencere boyutu: 30)


df: model1_base, batch:48, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0279



df: model1_base, batch:48, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0279




df: model1_base, batch:48, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0279




Şekil 5.8 : Test 249 sonuçları (Ağ: UKSB, Veri seti: model1, varyant: base, parti boyutu: 48, pencere boyutu: 90)


df: model2_macd, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0311



df: model2_macd, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0311




df: model2_macd, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0311




Şekil 5.9 : Test 317 sonuçları (Ağ: UKSB, Veri seti: model2, varyant: macd, parti boyutu: 32, pencere boyutu: 60)

df: model2_hist, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0333



df: model2_hist, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0333



df: model2_hist, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0333



Şekil 5.10 : Test 353 sonuçları (Ağ: UKSB, Veri seti: model2, varyant: hist, parti boyutu: 32, pencere boyutu: 60)


Temsili kayıp deęerleri performansı deęerlendirmesinde eęitim sırasında kaydedilen eęitim ve doęrulama seti temsili kayıp deęerleri incelenmiřtir. UKSB aęı, model1 ve model2 ana veri setleriyle daha doęru řekilde eęitilirken, TYSA aęı, dięer ana veri setlerine gre model0 ile daha uygun bir řekilde eęitilebilmiřtir. Eęitim ve doęrulama seti zerinde yapılan tahmin hataları incelendięinde UKSB parti boyutu 48 veya 64 olan, model1 veya model2 ana veri setleriyle yapılan eęitimler ile hatalar hem sıfıra hem birbirilerine yaklařtıęı grlmřtr.

Modellerin eęitiminde genel olarak Mart 2020’de bařlayan Covid-19 krizinden dolayı sapmalar yařandıęı grlmřtr. Testlerin oęunda modeller, Mart 2020’de altın fiyatlarında yařanan ani dřř yakalamakta zorlanmıř ve tahminde sapma oluřmuřtur. Eęitim seti zerinde yapılan tahminleme alıřmasında eęitim verisinin bu tarihten sonraki kısmında, bu tarihten nceki kadar performans gsteremedięi anlařılmıřtır.

5.2 Test Seti Tahmin Hatası En Düşük Test Sonuçları

5.2.1 TYSA ağı


df: model0_macd, batch:32, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0231



df: model0_macd, batch:32, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0231




df: model0_macd, batch:32, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0231



Şekil 5.11 : Test 18 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: macd, parti boyutu: 32, pencere boyutu: 90, test hatası: 212.85)


df: model0_macd, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0277



df: model0_macd, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0277




df: model0_macd, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0277



Şekil 5.12 : Test 17 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: macd, parti boyutu: 32, pencere boyutu: 60, test hatası: 217,58)


df: model0_hist, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0591



df: model0_hist, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0591




df: model0_hist, batch:32, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0591




Şekil 5.13 : Test 53 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: hist, parti boyutu: 32, pencere boyutu: 60, test hatası: 690.9)


df: model0_hist, batch:64, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.1382



df: model0_hist, batch:64, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.1382




df: model0_hist, batch:64, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.1382




Şekil 5.14 : Test 59 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: hist, parti boyutu: 64, pencere boyutu: 60, test hatası: 847.51)


df: model0_both, batch:16, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0584



df: model0_both, batch:16, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0584




df: model0_both, batch:16, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0584




Şekil 5.15 : Test 26 sonuçları (Ağ: TYSA, Veri seti: model0, varyant: both, parti boyutu: 16, pencere boyutu: 60, test hatası: 898.16)

5.2.2 UKSB ağı


df: model1_both, batch:48, test from: 2021-01-01, time_steps: 30, rep_valloss: 0.0992



df: model1_both, batch:48, test from: 2021-01-01, time_steps: 30, rep_valloss: 0.0992




df: model1_both, batch:48, test from: 2021-01-01, time_steps: 30, rep_valloss: 0.0992




Şekil 5.16 : Test 271 sonuçları (Ağ: UKSB, Veri seti: model1, varyant: both, parti boyutu: 48, pencere boyutu: 30, test hatası: 241.44)


df: model1_both, batch:32, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0649



df: model1_both, batch:32, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0649




df: model1_both, batch:32, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0649




Şekil 5.17 : Test 270 sonuçları (Ağ: UKSB, Veri seti: model1, varyant: both, parti boyutu: 32, pencere boyutu: 90, test hatası: 293.04)


df: model1_macd, batch:64, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0466



df: model1_macd, batch:64, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0466




df: model1_macd, batch:64, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0466




Şekil 5.18 : Test 264 sonuçları (Ağ: UKSB, Veri seti: model1, varyant: macd, parti boyutu: 64, pencere boyutu: 90, test hatası: 303.32)


df: model2_both, batch:32, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0598



df: model2_both, batch:32, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0598




df: model2_both, batch:32, test from: 2021-01-01, time_steps: 90, rep_valloss: 0.0598




Şekil 5.19 : Test 330 sonuçları (Ağ: UKSB, Veri seti: model2, varyant: both, parti boyutu: 32, pencere boyutu: 90, test hatası: 466.78)


df: model1_macd, batch:48, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0353



df: model1_macd, batch:48, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0353



df: model1_macd, batch:48, test from: 2021-01-01, time_steps: 60, rep_valloss: 0.0353



Şekil 5.20 : Test 260 sonuçları (Ağ: UKSB, Veri seti: model1, varyant: macd, parti boyutu: 48, pencere boyutu: 60, test hatası: 474.47)

Temsili kayıp fonksiyon değeri en düşük sonuçlar veren modeller test setinde de kısmi olarak başarılı sonuçlar vermektedir. Ancak bu durum genellenemeyecek kadar azdır. TYSA ağının temsili doğrulama kayıp fonksiyon grafiği ve test seti hata verileri arasında %92.6 pozitif ilişki gözlemlenirken, UKSB ağında bu seviye %75.3

civarındadır. Güvenilirlik oranları da sırasıyla %80.1 ve %22.3 ‘tür. Yani TYSA ağıyla yapılan testlerde temsili doğrulama kayıp değerleri kullanılarak test setindeki olası hata güvenilir şekilde hesaplanabilirken, UKSB ağında bu durum uygun değildir.

Test seti üzerindeki eğitim verisine göre oldukça düşük tahmin başarımı, modellerin aşırı öğrenme yaptığının göstergesidir. Yine de test setinde yapılan tahminleme sonuçları, çalışmanın amacına ulaştığını göstermiştir.

Tüm testler test seti hata ölçekli tahmin performansına göre sıralandığında ilk 10 testin ilk 2 sırasında TYSA modelleri bulunmaktadır.

Test seti hatası en düşük testler incelendiğinde, bu modellerde de Covid-19’un küresel ekonomide etkisini hissettirdiği Mart 2020’den itibaren eğitim setindeki gerçek değerlere uyum azalmıştır.


5.3 Diğer Bulgular

Veri seti kombinasyonları, 3 ana veri seti üzerine 5’er varyant değişkeni eklenerek oluşturulmuştur ve toplamda 15 adettir.

Veri seti varyantlarının temsili kayıp fonksiyonu ve test seti üzerindeki tahmin performansları Çizelge 5.1 ve Şekil 5.21’te verilmiştir. Test sonuçlarına göre “both”, “hist” ve “Lmacd” veri seti varyantları ile eğitilen TYSA ağı diğer varyantlardan daha iyi performans göstermektedir; “both” ve “macd” veri seti varyantları ile eğitilen UKSB ağı diğer varyantlardan ortalama olarak daha başarılı sonuçlar elde etmiştir.


Çizelge 5.1 : Veri seti varyantlarının genel performansı.

	UKSB		TYSA	
	Temsili Doğrulama Kayıp Fonksiyonu Değeri	Test Seti Tahmin Hatası	Temsili Doğrulama Kayıp Fonksiyonu Değeri	Test Seti Tahmin Hatası
base	0.0889	11798.32	0.6663	92914.29
both	0.1096	10488.00	0.4741	65353.50
hist	0.1345	18228.64	0.4640	68596.25
Lmacd	0.1610	23763.76	0.4304	64753.64
macd	0.1054	10682.19	0.5794	90510.30




Şekil 5.21 : Veri seti varyantlarının genel performansı.

Eğitim sırasında hesaplanan temsili doğrulama kayıp fonksiyonları ve test sırasında hesaplanan test seti tahmin hataları, ağ tipi (TYSA ve UKSB) ve veri seti kombinasyonu alt kırılımında sırasıyla Şekil 5.22 ve Şekil 5.23'te karşılaştırılmıştır. "model0" temel veri setinin "both", "hist", "Lmacd" ve "macd" varyantları (toplam 4 kombinasyon) dışındaki tüm kombinasyonlarda UKSB ağı, TYSA'dan daha performanslıdır.




Şekil 5.22 : Veri seti kombinasyonları alt kırılımında UKSB ve TYSA ağlarının temsili doğrulama kayıp fonksiyonu karşılaştırması




Şekil 5.23 : Veri seti kombinasyonları alt kırılımında UKSB ve TYSA ağlarının test veri seti hata karşılaştırması.

Şekil 5.24'te parti boyutu değişimine göre ortalama test seti tahmin performansları incelendiğinde "model0" temel veri seti için TYSA'da 32, UKSB'de 48 parti boyutu civarında daha yüksek performanslar görülmektedir.




Şekil 5.24 : model0 temel veri seti kullanılarak parti boyutuna göre test seti tahmin hatası cinsinden ağ performansları.

"model1" ve "model2"de RNN ağıyla yapılan testlerin sonuçları parti boyutundan bağımsızdır, UKSB ağıyla yapılan testlerde parti boyutu arttıkça tahmin performansı artmaktadır (Şekil 5.25 ve Şekil 5.26).




Şekil 5.25 : model1 temel veri seti kullanılarak parti boyutuna göre test seti tahmin hatası cinsinden ağ performansları.




Şekil 5.26 : model2 temel veri seti kullanılarak parti boyutuna göre test seti tahmin hatası cinsinden ağ performansları.

Şekil 5.27’de pencere boyutu değişimine göre ortalama test seti tahmin performansları incelendiğinde "model10" temel veri seti için TYSA’da base varyantında, UKSB’de ise base ve hist varyantlarında pencere boyutu arttıkça düşen bir performans görülmektedir. Ayrıca UKSB’nin both varyantlı veri setiyle gösterdiği performans pencere boyutuyla doğru orantılı olduğu tespit edilmiştir.




Şekil 5.27 : model0 temel veri seti kullanılarak pencere boyutuna göre test seti tahmin hatası cinsinden ağ performansları.

Diğer taraftan UKSB ağının daha performanslı olduğu model1 temel veri setleriyle yapılan testler incelendiğinde (Şekil 5.28) hist ve Lmacd varyantlı veri setleri kullanılarak eğitilen UKSB ağının, pencere boyutu arttıkça tahmin performansının arttığı görülmüştür. model2_both ve model2_hist kombinasyonları ile yapılan testlerde tepencere boyutu arttıkça tahmin performansı düşmüştür (Şekil 5.29).



Şekil 5.28 : model1 temel veri seti kullanılarak pencere boyutuna göre test seti tahmin hatası cinsinden ağ performansları.



Şekil 5.29 : model2 temel veri seti kullanılarak pencere boyutuna göre test seti tahmin hatası cinsinden ağ performansları.

6. TARTIŞMA VE ÖNERİLER

Literatürde altın fiyatlarını etkileyen faktörlerle ilgili birçok çalışma olmasına rağmen bugüne kadar yapılan çalışmalarda 10'u geçen değişken sayısı ile yapılan çalışmaya çok sık rastlanmamıştır. Bu çalışmada, S&P 500 endeksi, ABD reel faiz oranı, dolar endeksi, petrol fiyatı, ABD enflasyonu gibi değişkenler de dahil olmak üzere 30 değişken kullanılarak uygulamada altın fiyatlarını etkileyen faktörlerin belirlenmesi amaçlanmıştır.

Yapılan tez çalışmasında çok değişkenli finansal zaman serilerinde değişken seçimi ve altın fiyat tahmini incelenmiştir. Buna göre bir yatırım aracı olan altını fiyatlayan çok sayıda dinamik faktör bulunmaktadır. Her faktör aynı etkiye sahip olmadığı için, altın fiyatında en çok etkiye sahip faktörler Lineer regresyon, rastgele karar ağaçları ve PCA kullanılarak tespit edilmiştir. Gerçek dünyada altın fiyatları temel teori ve kriterlere göre hareket ediyor olsa da altın birçok teknik ve temel değişkenden etkilenen bir emtia türüdür. Yapılan çalışmada temel bir tekrarlayan sinir ağı ve UKSB tipi derin öğrenme ağı kullanılmıştır. Veri seti içindeki öznitelikler, bu iki ağ tipinde parti boyutu ve pencere boyutu değiştirilerek altın fiyatının bu girdilere karşı tepkisi hakkında fikir verilmeye çalışılmıştır. Pencere boyutu, gözlem birimi oluştururken geçmişe dönük verilerin kaç güne kadar alınacağını belirleyen hiper parametredir.

Geleneksel istatistiksel modellerin doğrusal olmayan ve durağan olmayan zaman serisi verilerini tahmin etmedeki doğal kusurları göz önüne alındığında, araştırmacılar dikkatlerini uyarlanabilir özelliklere ve öğrenme yeteneğine sahip yapay zeka (AI) modellerine çevirmektedir.

Bir zaman serisinin tekrarlayan sinir ağı yöntemleri ile tahmininde ağın mimarisi oluşturulurken hangi katmanların kullanılacağı, katmanlardaki bileşenlerin sayısı ve boyutu, geçmiş verileri içeren pencere boyutu ve UKSB ağ modeli parti boyutu gibi parametrelerin belirlenmesi gerekir. Ayrıca, eğitim sürecinde öğrenme oranı, optimizasyon tipi ve Dropout gibi öğrenme parametrelerinin de başlangıç değerlerinin

eğitimden önce belirlenmesi gerekir. Ek olarak uygun bir ön işleme sürecinden geçen bir veri seti ağı performansı ve eğitim süresini etkilemektedir.

Gelişmiş yapay zeka motorlarının çok sayıda farklı özneliği işlediği düşünülecek olursa, kısa vadede altın fiyatlarının tahmininin aslında daha çok öznelikle işlenmesi gerektiği söylenebilir. Bu çalışmada, önceki çalışmalarda henüz ulaşılmamış sayıda farklı finansal değişken işlenmiş ve tahmin algoritmasına dahil edilmiştir.

Uygulamaların, eğitim sürecinden sonra tahmine ilişkin model başarıları hesaplanmıştır.

Yapılan testlerde uygun tahmin sonuçları veren parametreler belirlenmiştir. “model0” temel veri setiyle eğitilen TYSA’lar, genel olarak UKSB’lerden daha yüksek performanslı sonuçlar elde ederken, “model1” ve “model2” temel veri setlerinde UKSB’ler daha yüksek performansla tahmin yapmıştır.

MACD indikatörünün eklenmesiyle oluşturulan veri setlerinin daha düşük pencere boyutlarıyla eğitildiği testlerde bu modeller diğer kombinasyonlardan daha üstün sonuçlar vermiştir. Genel olarak UKSB ile yapılan testlerde parti boyutu arttıkça tahmin performansı artmıştır.

Modeli iyileştirmek için mevcut parametreler daha hassas seçilerek optimizasyon yapılmıştır. Henüz profesyonel anlamda kullanımı mümkün olmasa da ilk çalışma için umut verici sonuçlar vermiştir. Bu kapsamda çalışmanın amacı ve kapsamı karşılanmıştır.

Bu tezde yapılan çalışma, ileride yapılacak çalışmalar için bir başlangıç noktası olacaktır. İş analistleri, bankacılık sektöründe çalışanlar, yatırım sahipleri, yatırım danışmanları bu amaçla hazırlanan bir aracı kullanabilir ve geliştirebilirler. Henüz gerçekleştirilmeyen alt çalışmalar olarak, farklı tekrarlayan sinir ağı modellerinin denenmesi, farklı tekrarlayan sinir ağı yapılarının denenmesi, öğrenme hızı, optimizasyon türü gibi hiper parametrelerin değiştirilmesi, veri yumuşatma yöntemi veya mevcut filtrenin parametrelerinin değiştirilmesi, farklı öznelik çıkarma işlemleriyle veri setinin zenginleştirilmesi sayılabilir.

KAYNAKLAR

- Akca, M. F.** (2020, September 15). Gradient Descent Nedir? *Deep Learning Türkiye*. <https://bit.ly/3zbhsd4>
- Akca, M. F.** (2021, February 7). LSTM Nedir? Nasıl Çalışır? *Medium*. <https://bit.ly/3MeBgzn>
- Amerikan Dolar Endeksi (DXY).** (n.d.). Investing.com Türkiye. Retrieved May 29, 2022, from <https://tr.investing.com/indices/usdollar>
- Apergis, N.** (2014). Can gold prices forecast the Australian dollar movements? *International Review of Economics & Finance*, 29, 75–82. <https://doi.org/10.1016/j.iref.2013.04.004>
- Bali, S., ve Cinel, M.** (2011). Altın fiyatlarının İMKB 100 Endeksi'ne etkisi ve bu etkinin ölçülmesi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 25(3-4), 45–63. <https://dergipark.org.tr/en/pub/atauniiibd/issue/2703/35533>
- Board of Governors of the Federal Reserve System (US).** (2022a, May 30). *10-Year Treasury Constant Maturity Rate*. FRED, Federal Reserve Bank of St. Louis. <https://fred.stlouisfed.org/series/DGS10> Günlük güncellenir.
- Board of Governors of the Federal Reserve System (US).** (2022b, May 30). *Market Yield on U.S. Treasury Securities at 1-Year Constant Maturity*. FRED, Federal Reserve Bank of St. Louis. <https://fred.stlouisfed.org/series/GS1Aylık> güncellenir.
- Board of Governors of the Federal Reserve System (US).** (2022c, May 30). *Market Yield on U.S. Treasury Securities at 10-Year Constant Maturity, Inflation-Indexed*. FRED, Federal Reserve Bank of St. Louis. <https://fred.stlouisfed.org/series/WFII10Haftalık> güncellenir.
- Chen, J.** (2022a). DAX Stock Index. In *Investopedia*. <https://www.investopedia.com/terms/d/dax.asp>
- Chen, J.** (2022b). U.S. Dollar Index - USDx Definition. In *Investopedia*. <https://www.investopedia.com/terms/u/usdx.asp>

- Corporate Finance Institute.** (n.d.). *North Sea Brent Crude - Overview, Commodity Trading, Comparisons*. Corporate Finance Institute. Retrieved May 29, 2022, from <https://corporatefinanceinstitute.com/resources/knowledge/other/north-sea-brent-crude/>
- datetime** — *Basic date and time types*. (2002). Python 3.7.2 Documentations. <https://docs.python.org/3/library/datetime.html>
- Davis, R., Dedu, V., ve Bonye, F.** (2014). Modeling and Forecasting of Gold Prices on Financial Markets. *American International Journal of Contemporary Research*, 4(3). http://www.aijcrnet.com/journals/Vol_4_No_3_March_2014/12.pdf
- Dobilas, S.** (2022, February 6). LSTM Recurrent Neural Networks — How to Teach a Network to Remember the Past. *Medium*. <https://towardsdatascience.com/lstm-recurrent-neural-networks-how-to-teach-a-network-to-remember-the-past-55e54c2ff22e?gi=376caf70e47e>
- Dooley, M. P., Taylor, M. P., ve Isard, P.** (1992). Exchange Rates, Country Preferences, and Gold. *IMF Working Papers*, 92(51), i. <https://doi.org/10.5089/9781451847024.001>
- Eğilmez, M.** (2013, February 9). Türkiye Açısından Para Arzı Kavramları. *Kendime Yazılar*. <https://www.mahfiegilmez.com/2013/02/turkiye-acısından-para-arz-kavramlar.html>
- Eğilmez, M.** (2022, April 4). Enflasyon Dosyası. *Kendime Yazılar*. <https://www.mahfiegilmez.com/2022/04/enflasyon-dosyas.html>
- Ewing, B. T., ve Malik, F.** (2013). Volatility transmission between gold and oil futures under structural breaks. *International Review of Economics & Finance*, 25, 113–121. <https://doi.org/10.1016/j.iref.2012.06.008>
- Ferreira, J.** (2019, April 10). *US Inflation Rate Rises Above Forecasts in March*. Trading Economics. <https://tradingeconomics.com/articles/04102019123730.htm>
- Finanscepte.** (n.d.). Altın ve Gümüş Arasındaki Farklar. *Finanswebde*. Retrieved May 29, 2022, from <https://bit.ly/3PQmTUM>
- Frank, S.** (2022a, May 27). *Stocks vs Gold - Updated Historical Chart*. Longtermtrends. <https://www.longtermtrends.net/stocks-vs-gold-comparison/>
- Frank, S.** (2022b, May 30). *Real Interest Rate - 150 Year Chart*. Longtermtrends. <https://www.longtermtrends.net/real-interest-rate/>

- García, S., Luengo, J., & Herrera, F.** (2015). Data Preprocessing in Data Mining. In Intelligent Systems Reference Library. Springer International Publishing. <https://doi.org/10.1007/978-3-319-10247-4>
- Ghosh, A., Bose, S., Maji, G., Debnath, N. C., ve Sen, S.** (2019). Stock Price Prediction Using LSTM on Indian Share Market. *EPiC Series in Computing*, 63, 101–110.
- Ghosh, D., Levin, E. J. L., Macmillan, P., ve Wright, R. E.** (2001). Gold as an Inflation Hedge? *Studies in Economics and Finance*, 22(1), 1–25. <https://doi.org/10.1108/eb043380>
- Gold and Fed's Balance Sheet.** (2016). In *Sunshine Profits*. <https://www.sunshineprofits.com/gold-silver/dictionary/gold-fed-balance-sheet/>
- Gold and M0 (Monetary Base) - Critical Link.** (n.d.). In *Sunshine Profits*. Retrieved May 30, 2022, from <https://www.sunshineprofits.com/gold-silver/dictionary/gold-m0/>
- Gold and Nonfarm Payrolls.** (n.d.). *Sunshine Profits*. Retrieved July 26, 2022, from <https://www.sunshineprofits.com/gold-silver/dictionary/nonfarm-payrolls-gold/>
- Gold & S&P 500 - Link Explained.** (n.d.). In *Sunshine Profits*. Retrieved May 30, 2022, from <https://www.sunshineprofits.com/gold-silver/dictionary/gold-sp/>
- Goodfellow, I., Bengio, Y., ve Courville, A.** (2016). Deep learning. The MIT Press.
- Güneş, Dr. H. H., ve Aydemir, Yrd. Doç. Dr. C.** (2005). *Anayasal İktisat Teorisini Doğuran Arayışlar*. 74–86. <https://dergipark.org.tr/tr/download/article-file/69845>
- Hammoudeh, S. M., Yuan, Y., McAleer, M., ve Thompson, M. A.** (2010). Precious metals-exchange rate volatility transmissions and hedging strategies. *International Review of Economics & Finance*, 19(4), 633–647. <https://ideas.repec.org/a/eee/reveco/v19y2010i4p633-647.html>
- Han, A., Lai, K. K., Wang, S., ve Xu, S.** (2012). An interval method for studying the relationship between the Australian dollar exchange rate and the gold price. *Journal of Systems Science and Complexity*, 25(1), 121–132. <https://doi.org/10.1007/s11424-012-8116-x>
- Hanieh, A.** (2020). COVID-19 and global oil markets. *Canadian Journal of Development Studies / Revue Canadienne d'Études Du Développement*, 42(1-2), 1–8. <https://doi.org/10.1080/02255189.2020.1821614>

- Hassani, H., Silva, E. S., Gupta, R., ve Segnon, M. K.** (2014, June 1). *Forecasting the Price of Gold*. Ideas.repec.org. <https://ideas.repec.org/p/pre/wpaper/201428.html>
- Hayes, A.** (2021). Average True Range (ATR). In *Investopedia*. <https://www.investopedia.com/terms/a/atr.asp>
- Hayes, A.** (2022). London Metal Exchange (LME). In *Investopedia*. <https://www.investopedia.com/terms/l/londonmetalexchange.asp>
- He, Z., Zhou, J., Dai, H.-N., ve Wang, H.** (2019, August 1). *Gold Price Forecast Based on LSTM-CNN Model*. IEEE Xplore. <https://doi.org/10.1109/DASC/PiCom/CBDCCom/CyberSciTech.2019.00188>
- Hochreiter, S., ve Schmidhuber, J.** (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- How Money Supply Affects Commodity Tendencies.** (2016, March 27). *Dummies*. <https://www.dummies.com/article/business-careers-money/personal-finance/investing/investment-vehicles/commodities/how-money-supply-affects-commodity-tendencies-198213/>
- How Much Gold Has Been Mined?** (2022, January 28). World Gold Council. <https://www.gold.org/goldhub/data/how-much-gold>
- Iacurci, G.** (2021, June 8). Gold as an inflation hedge? History suggests otherwise. *CNBC*. <https://www.cnbc.com/2021/06/08/gold-as-an-inflation-hedge-history-suggests-otherwise.html>
- Incekara, B., ve Incekara, R.** (2016). Dünya Altın Piyasaları. *Nişantaşı Üniversitesi Sosyal Bilimler Dergisi*, 4(2), 116–143. <https://dergipark.org.tr/tr/pub/nisantasisbd/issue/40538/664470>
- Ismail, Z., Yahya, A., ve Shabri, A.** (2009). Forecasting Gold Prices Using Multiple Linear Regression Method. *American Journal of Applied Sciences*, 6(8), 1509–1514. <https://doi.org/10.3844/ajassp.2009.1509.1514>
- Jaffe, J. F.** (1989). Gold and Gold Stocks as Investments for Institutional Portfolios. *Financial Analysts Journal*, 45(2), 53–59. <https://doi.org/10.2469/faj.v45.n2.53>
- Khaemusunun, P.** (2009). *Forecasting Thai Gold Prices*. <https://bit.ly/3PMoQ4J>
- Khan, M. M. A.** (2013). Forecasting of gold prices (Box-Jenkins approach). *International Journal of Emerging Technology and Advanced Engineering*, 3(3), 662-670. From: <https://bit.ly/3NGJ65O>

- Koutsoyiannis, A.** (1983). A short-run pricing model for a speculative asset, tested with data from the gold bullion market. *Applied Economics*, 15(5), 563–581. <https://doi.org/10.1080/000368483000000037>
- Küçükaksoy, İ., ve Yalçın, D.** (2017). Altın Fiyatlarını Etkileyebilecek Faktörlerin İncelenmesi. *Ekonomik ve Sosyal Araştırmalar Dergisi*, 13(2), 1–20. <https://dergipark.org.tr/tr/pub/esad/issue/38974/456284>
- Livieris, I. E., Pintelas, E., ve Pintelas, P.** (2020). A CNN–LSTM model for gold price time-series forecasting. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-020-04867-x>
- MacroMicro.** (2022, May 30). *US Real Interest Rate & Gold Price*. MacroMicro. <https://en.macromicro.me/charts/724/3month-bond-real-yield-gold-price> Günlük güncellenir.
- Market Realist.** (2015, December). *The Correlation between Gold and Oil*. Market Realist. <https://marketrealist.com/2015/12/correlation-gold-oil/>
- Mbah, T. J., Ye, H., Zhang, J., ve Long, M.** (2021). Using LSTM and ARIMA to Simulate and Predict Limestone Price Variations. *Mining, Metallurgy & Exploration*, 38(2), 913–926. <https://doi.org/10.1007/s42461-020-00362-y>
- McDonald, J. G., ve Solnick, B. H.** (1977). Valuation and Strategy for Gold Stocks. *The Journal of Portfolio Management*, 3(3), 29–33. <https://doi.org/10.3905/jpm.1977.408606>
- Mombeini, H., ve Yazdani-Chamzini, A.** (2015). Modeling Gold Price via Artificial Neural Network. *Journal of Economics, Business and Management*, 3(7), 699–703. <https://doi.org/10.7763/joebm.2015.v3.269>
- Nelson, E. A., ve Jastram, R. W.** (1980). The Golden Constant: The English and American Experience 1560-1976. *Southern Economic Journal*, 46(3), 983. <https://doi.org/10.2307/1057185>
- Olah, C.** (2015, August 27). Understanding LSTM Networks. *Colah's Blog - Github.io*. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Phi, M.** (2019, July 10). Illustrated Guide to LSTM's and GRU's: A step by step explanation. *Medium*. <https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21>
- Ping, P. Y., Miswan, N. H., ve Ahmad, M. H.** (2013). Forecasting Malaysian gold using GARCH model. *Applied Mathematical Sciences*, 7, 2879–2884. <https://doi.org/10.12988/ams.2013.13255>

- Riazuddin, M.** (2020, May 11). Machine Learning to Predict Gold Price Returns. *Medium*. <https://towardsdatascience.com/machine-learning-to-predict-gold-price-returns-4bdb0506b132>
- S&P/TSX Global Base Metals Index.** (n.d.). TMX Money. Retrieved May 30, 2022, from <https://money.tmx.com/en/quote/%5ETXBM> Günlük güncellenir.
- Savitzky, A., Golay, M.J.E.** (1964). Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Analytical Chemistry*, 36(8), 1627–1639. <https://doi.org/10.1021/ac60214a047>
- Shankar, P. S. ve Reddy, M. K.** (2021). Forecasting Gold Prices in India using Time series and Deep Learning Algorithms. *Regular Issue*, 10(5), 21–27. <https://doi.org/10.35940/ijeat.d2537.0610521>
- Shawn, M.** (2020, July 26). The Correlation between Gold and Oil - Market Realist. Market Realist. <https://marketrealist.com/2015/12/correlation-gold-oil/>
- Sieron, A.** (2015, December 7). Does GDP Drive the Gold Price? *Kitco News*. <https://www.kitco.com/commentaries/2015-12-07/Does-GDP-Drive-the-Gold-Price.html>
- Singh, M.** (2022). Understanding the Federal Reserve Balance Sheet. In *Investopedia*. <https://www.investopedia.com/articles/economics/10/understanding-the-fed-balance-sheet.asp>
- Sjaastad, L. A.** (2008). The price of gold and the exchange rates: Once again. *Resources Policy*, 33(2), 118–124. <https://doi.org/10.1016/j.resourpol.2007.10.002>
- Sjaastad, L. A., ve Scacciavillani, F.** (1996). The price of gold and the exchange rate. *Journal of International Money and Finance*, 15(6), 879–897. [https://doi.org/10.1016/S0261-5606\(96\)00045-9](https://doi.org/10.1016/S0261-5606(96)00045-9)
- Smith, G.** (2001). The Price of Gold and Stock Price Indices for the United States. In *SPDR Gold Shares*. SPDR Gold Shares. <http://www.spdrgoldshares.com/media/GLD/file/Gold%26USStockIndicesDEC200120fina.pdf>
- Stanley, J.** (2021, June 21). How to Measure Volatility with Average True Range (ATR). *DailyFX*. <https://www.dailyfx.com/education/volatility/measure-volatility-with-average-true-range.html>
- Sunshine Profits.** (2019). Real Interest Rates and Gold - Explained | Sunshine Profits. In *Sunshine Profits*. <https://www.sunshineprofits.com/gold-silver/dictionary/real-interest-rates-gold/>

- Sunshine Profits.** (n.d.). Gold and Fed's Balance Sheet. In *Sunshine Profits*. Retrieved May 29, 2022, from <https://www.sunshineprofits.com/gold-silver/dictionary/gold-fed-balance-sheet/>
- Taş, B.** (2022). Faiz Nedir? In *Midas*. <https://www.getmidas.com/borsa-terimleri/faiz-nedir/>
- TCMB.** (n.d.-a). *Merkez Bankası Faiz Oranları*. Türkiye Cumhuriyeti Merkez Bankası. Retrieved May 30, 2022, from <https://www.tcmb.gov.tr/wps/wcm/connect/tr/tcmb+tr/main+menu/temel+faaliyetler/para+politikasi/merkez+bankasi+faiz+oranlari>
- TCMB.** (n.d.-b). *Terimler Sözlüğü*. Türkiye Cumhuriyeti Merkez Bankası. Retrieved May 30, 2022, from <https://www.tcmb.gov.tr/wps/wcm/connect/TR/TCMB+TR/Main+Menu/Banka+Hakkinda/Egitim-Akademik/Terimler+Sozlugu/>
- The Investopedia Team.** (2020, December 24). *Real Interest Rate Definition*. Investopedia. <https://www.investopedia.com/terms/r/realinterestrate.asp>
- Topçu, A.** (2010). Altın Fiyatlarını Etkileyen Faktörler. In *Sermaye Piyasası Araştırma Kurulu*. <https://www.spk.gov.tr/SiteApps/Yayin/YayinGoster/1016>
- Topçu, N., ve Aksoy, M.** (2013). ALTIN İLE HİSSE SENEDİ VE ENFLASYON ARASINDAKİ İLİŞKİ. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 27(1), 59–78. <https://dergipark.org.tr/tr/pub/atauniiibd/issue/2708/35846>
- Toraman, C., Başarır, Ç., ve Bayramoğlu, M. F.** (2011). Altın Fiyatlarını Etkileyen Faktörlerin Tespiti Üzerine: MGARCH Modeli ile bir İnceleme. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 3(1), 1–20. <https://dergipark.org.tr/tr/pub/uaifd/issue/21591/231830>
- Trade Forex Trading.** (n.d.). US500 Index – US500 Stock Indices Defined. *Trade Forex Trading*. Retrieved May 30, 2022, from <https://www.tradeforextrading.com/stock-indices/index.php/us-500-index>
- Tripathy, N.** (2017). Forecasting gold price with auto regressive integrated moving average model. *International Journal of Economics and Financial Issues*, 7(4), 324-329.
- United States Inflation Rate.** (2021, April 10). Trading Economics. <https://tradingeconomics.com/united-states/inflation-cpi> Aylık güncellenir.

- U.S. Bureau of Labor Statistics.** (1913, January 1). *Consumer Price Index for All Urban Consumers: All Items in U.S. City Average*. FRED, Federal Reserve Bank of St. Louis. <https://fred.stlouisfed.org/series/CPIAUCNS>
- Vidal, A., ve Kristjanpoller, W.** (2020). Gold volatility prediction using a CNN-LSTM approach. *Expert Systems with Applications*, 157, 113481. <https://doi.org/10.1016/j.eswa.2020.113481>
- Vidya, G. S., ve Hari, V. S.** (2020, December 1). *Gold Price Prediction and Modelling using Deep Learning Techniques*. IEEE Xplore. <https://doi.org/10.1109/RAICS51191.2020.9332471>
- Wang, J., Lu, S., Wang, S.-H., ve Zhang, Y.-D.** (2021). A review on extreme learning machine. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-021-11007-7>
- Wang, K.-M., Lee, Y.-M., ve Thi, T.-B. N.** (2011). Time and place where gold acts as an inflation hedge: An application of long-run and short-run threshold model. *Economic Modelling*, 28(3), 806–819. <https://doi.org/10.1016/j.econmod.2010.10.008>
- Wikipedia Kullanıcıları.** (2019). NASDAQ-100. In *Wikipedia*. Wikimedia Foundation. <https://en.wikipedia.org/wiki/NASDAQ-100>
- Wikipedia Kullanıcıları.** (2021). London Metal Exchange Index. In *Wikipedia*. https://de.wikipedia.org/wiki/London_Metal_Exchange_Index
- Wilder, J. Welles.** (1978). New concepts in technical trading systems. (s. III). Trend Research.
- Wolverson, R.** (2013, 7 Ağustos). GDP and Economic Policy. Council on Foreign Relations. <https://www.cfr.org/article/gdp-and-economic-policy>
- Wu, J. M.-T., Li, Z., Herencsar, N., Vo, B., ve Lin, J. C.-W.** (2021). A graph-based CNN-LSTM stock price prediction algorithm with leading indicators. *Multimedia Systems. Role of Deep Learning Models & Analytics in Industrial Multimedia Environment*. <https://doi.org/10.1007/s00530-021-00758-w>
- Yücel, M. Bayram.** (2020). Dünyada ve Türkiye’de Altın. In *Maden Tetkik ve Arama Genel Müdürlüğü*. Maden Tetkik ve Arama Genel Müdürlüğü. <https://www.mta.gov.tr/v3.0/sayfalar/bilgi-merkezi/maden-serisi/altin.pdf>
- Yıldırım, E.** (2020, 2 Mayıs). Yapay Sinir Ağı (Artificial Neural Network) Nedir? *Veri Bilimi Okulu*. <https://www.veribilimiokulu.com/yapay-sinir-agiartificial-neural-network-nedir/>

Zhang, X., Zhang, L., Zhou, Q., ve Jin, X. (2022). A Novel Bitcoin and Gold Prices Prediction Method Using an LSTM-P Neural Network Model. *Computational Intelligence and Neuroscience*, 2022, 1–12. <https://doi.org/10.1155/2022/1643413>





EKLER

EK A: Tahmin sonuçları

Test No	Ağ Modeli	Veri Seti Kombinasyonu	Parti Boyutu (Batch Size)	Pencere Boyutu (Time Step)	Temsili Doğrulama Kayıp Fonksiyonu Değeri	Test Seti Tahmin Hatası (MSE)
1	TYSA	model0_base	16	30	0.0219	13855.58
2	TYSA	model0_base	16	60	0.0117	5412.84
3	TYSA	model0_base	16	90	1.3834	102199.06
4	TYSA	model0_base	32	30	0.0334	2758.37
5	TYSA	model0_base	32	60	0.0195	5180.88
6	TYSA	model0_base	32	90	0.0384	3090.81
7	TYSA	model0_base	48	30	0.0704	1638.36
8	TYSA	model0_base	48	60	0.4666	68961.83
9	TYSA	model0_base	48	90	0.4970	15515.53
10	TYSA	model0_base	64	30	0.1491	10923.21
11	TYSA	model0_base	64	60	0.0942	11084.34
12	TYSA	model0_base	64	90	1.4390	179276.16
13	TYSA	model0_macd	16	30	0.0444	11524.95
14	TYSA	model0_macd	16	60	0.0157	983.15
15	TYSA	model0_macd	16	90	0.1153	39807.31
16	TYSA	model0_macd	32	30	0.0241	898.45
17	TYSA	model0_macd	32	60	0.0277	217.58
18	TYSA	model0_macd	32	90	0.0231	212.85
19	TYSA	model0_macd	48	30	0.0885	1534.01
20	TYSA	model0_macd	48	60	0.1074	5145.84
21	TYSA	model0_macd	48	90	0.0667	3704.84
22	TYSA	model0_macd	64	30	0.1046	8727.93
23	TYSA	model0_macd	64	60	0.0796	3360.49
24	TYSA	model0_macd	64	90	0.0867	5038.87
25	TYSA	model0_both	16	30	0.1140	9122.27
26	TYSA	model0_both	16	60	0.0584	898.16
27	TYSA	model0_both	16	90	0.1190	18513.22
28	TYSA	model0_both	32	30	0.0906	4794.48
29	TYSA	model0_both	32	60	0.1095	6904.46
30	TYSA	model0_both	32	90	0.0695	4711.85
31	TYSA	model0_both	48	30	0.0848	4464.49
32	TYSA	model0_both	48	60	0.1144	4600.32
33	TYSA	model0_both	48	90	0.0785	3323.76
34	TYSA	model0_both	64	30	0.1176	14973.97
35	TYSA	model0_both	64	60	0.1405	12920.13

EK A (devam): Tahmin sonuçları.

Test No	Ağ Modeli	Veri Seti Kombinasyonu	Parti Boyutu (Batch Size)	Pencere Boyutu (Time Step)	Temsili Doğrulama Kayıp Fonksiyonu Değeri	Test Seti Tahmin Hatası (MSE)
36	TYSA	model0_both	64	90	0.1250	9599.77
37	TYSA	model0_Lmacd	16	30	0.0721	6131.64
38	TYSA	model0_Lmacd	16	60	0.0647	5870.45
39	TYSA	model0_Lmacd	16	90	0.0533	4322.12
40	TYSA	model0_Lmacd	32	30	0.0590	2079.59
41	TYSA	model0_Lmacd	32	60	0.0615	1772.94
42	TYSA	model0_Lmacd	32	90	0.0515	2100.89
43	TYSA	model0_Lmacd	48	30	0.1126	9115.02
44	TYSA	model0_Lmacd	48	60	0.0978	8253.39
45	TYSA	model0_Lmacd	48	90	0.0738	6464.05
46	TYSA	model0_Lmacd	64	30	0.1214	3779.84
47	TYSA	model0_Lmacd	64	60	0.1311	3924.90
48	TYSA	model0_Lmacd	64	90	0.1189	6340.88
49	TYSA	model0_hist	16	30	0.0523	10189.23
50	TYSA	model0_hist	16	60	0.0344	3702.81
51	TYSA	model0_hist	16	90	0.1006	20430.19
52	TYSA	model0_hist	32	30	0.0491	3474.51
53	TYSA	model0_hist	32	60	0.0591	690.90
54	TYSA	model0_hist	32	90	0.0480	1176.15
55	TYSA	model0_hist	48	30	0.1300	15907.76
56	TYSA	model0_hist	48	60	0.0920	5367.44
57	TYSA	model0_hist	48	90	0.0806	7274.25
58	TYSA	model0_hist	64	30	0.1280	12616.58
59	TYSA	model0_hist	64	60	0.1382	847.51
60	TYSA	model0_hist	64	90	0.1302	18563.74
61	TYSA	model1_base	16	30	0.3679	41929.48
62	TYSA	model1_base	16	60	0.9200	104458.42
63	TYSA	model1_base	16	90	0.5131	34778.16
64	TYSA	model1_base	32	30	1.0599	157387.49
65	TYSA	model1_base	32	60	1.1133	173896.29
66	TYSA	model1_base	32	90	1.2331	233781.16
67	TYSA	model1_base	48	30	0.8790	126865.25
68	TYSA	model1_base	48	60	0.8599	140170.53
69	TYSA	model1_base	48	90	0.9641	159542.47
70	TYSA	model1_base	64	30	0.8054	146008.91
71	TYSA	model1_base	64	60	0.8566	74538.81
72	TYSA	model1_base	64	90	0.8943	83429.97
73	TYSA	model1_macd	16	30	0.3515	22355.97
74	TYSA	model1_macd	16	60	0.3994	26759.03

EK A (devam): Tahmin sonuçları.

Test No	Ağ Modeli	Veri Seti Kombinasyonu	Parti Boyutu (Batch Size)	Pencere Boyutu (Time Step)	Temsili Doğrulama Kayıp Fonksiyonu Değeri	Test Seti Tahmin Hatası (MSE)
75	TYSA	model1_macd	16	90	0.4264	45106.26
76	TYSA	model1_macd	32	30	1.0932	204024.66
77	TYSA	model1_macd	32	60	1.2782	170335.46
78	TYSA	model1_macd	32	90	1.6159	299707.41
79	TYSA	model1_macd	48	30	1.2407	242775.42
80	TYSA	model1_macd	48	60	1.3395	215629.39
81	TYSA	model1_macd	48	90	1.4505	220925.15
82	TYSA	model1_macd	64	30	0.7568	122678.17
83	TYSA	model1_macd	64	60	1.1752	128923.15
84	TYSA	model1_macd	64	90	0.9228	108308.05
85	TYSA	model1_both	16	30	0.3736	34682.46
86	TYSA	model1_both	16	60	0.4897	60839.42
87	TYSA	model1_both	16	90	0.4557	72434.15
88	TYSA	model1_both	32	30	0.9483	94511.40
89	TYSA	model1_both	32	60	0.8424	103426.71
90	TYSA	model1_both	32	90	0.8776	113121.14
91	TYSA	model1_both	48	30	0.8282	100028.88
92	TYSA	model1_both	48	60	0.8000	107751.33
93	TYSA	model1_both	48	90	0.8393	125701.57
94	TYSA	model1_both	64	30	0.8180	106270.20
95	TYSA	model1_both	64	60	0.7265	143712.60
96	TYSA	model1_both	64	90	0.6682	118504.32
97	TYSA	model1_Lmacd	16	30	0.4496	93777.91
98	TYSA	model1_Lmacd	16	60	0.6546	67732.11
99	TYSA	model1_Lmacd	16	90	0.4412	78306.91
100	TYSA	model1_Lmacd	32	30	0.8002	91192.94
101	TYSA	model1_Lmacd	32	60	0.8666	108267.72
102	TYSA	model1_Lmacd	32	90	0.8697	113047.90
103	TYSA	model1_Lmacd	48	30	0.6151	92636.45
104	TYSA	model1_Lmacd	48	60	0.6546	110617.54
105	TYSA	model1_Lmacd	48	90	0.7233	127333.99
106	TYSA	model1_Lmacd	64	30	0.6992	115105.46
107	TYSA	model1_Lmacd	64	60	0.6605	139093.45
108	TYSA	model1_Lmacd	64	90	0.6857	72864.08
109	TYSA	model1_hist	16	30	0.2711	43395.28
110	TYSA	model1_hist	16	60	0.8018	127979.35
111	TYSA	model1_hist	16	90	0.6928	111020.25
112	TYSA	model1_hist	32	30	0.9014	138926.82
113	TYSA	model1_hist	32	60	0.8903	107395.30

EK A (devam): Tahmin sonuçları.

Test No	Ağ Modeli	Veri Seti Kombinasyonu	Parti Boyutu (Batch Size)	Pencere Boyutu (Time Step)	Temsili Doğrulama Kayıp Fonksiyonu Değeri	Test Seti Tahmin Hatası (MSE)
114	TYSA	model1_hist	32	90	0.8404	169887.78
115	TYSA	model1_hist	48	30	0.7582	104015.91
116	TYSA	model1_hist	48	60	0.8742	139427.38
117	TYSA	model1_hist	48	90	0.7199	125984.61
118	TYSA	model1_hist	64	30	0.7197	117230.63
119	TYSA	model1_hist	64	60	0.7154	64682.54
120	TYSA	model1_hist	64	90	0.6485	82183.13
121	TYSA	model2_base	16	30	0.7893	140224.26
122	TYSA	model2_base	16	60	0.5656	101897.84
123	TYSA	model2_base	16	90	0.9064	178067.48
124	TYSA	model2_base	32	30	0.9323	114807.18
125	TYSA	model2_base	32	60	0.9037	132725.46
126	TYSA	model2_base	32	90	1.0113	144436.31
127	TYSA	model2_base	48	30	0.8010	165482.06
128	TYSA	model2_base	48	60	0.7256	52051.84
129	TYSA	model2_base	48	90	0.6122	45938.04
130	TYSA	model2_base	64	30	0.6534	102494.02
131	TYSA	model2_base	64	60	0.8274	158483.55
132	TYSA	model2_base	64	90	0.5678	111622.33
133	TYSA	model2_macd	16	30	0.4704	113031.13
134	TYSA	model2_macd	16	60	0.4811	57631.04
135	TYSA	model2_macd	16	90	0.7652	172681.29
136	TYSA	model2_macd	32	30	0.5731	83821.94
137	TYSA	model2_macd	32	60	0.9170	165385.14
138	TYSA	model2_macd	32	90	0.9163	152867.73
139	TYSA	model2_macd	48	30	0.5638	70336.24
140	TYSA	model2_macd	48	60	0.8527	100441.50
141	TYSA	model2_macd	48	90	0.5655	97290.79
142	TYSA	model2_macd	64	30	0.6436	149957.68
143	TYSA	model2_macd	64	60	0.6701	97299.73
144	TYSA	model2_macd	64	90	0.6069	108942.18
145	TYSA	model2_both	16	30	0.4133	68242.20
146	TYSA	model2_both	16	60	0.4682	59003.83
147	TYSA	model2_both	16	90	0.5597	85624.14
148	TYSA	model2_both	32	30	0.6028	78940.60
149	TYSA	model2_both	32	60	0.6860	96440.27
150	TYSA	model2_both	32	90	0.6052	117479.55

EK A (devam): Tahmin sonuçları.

Test No	Ağ Modeli	Veri Seti Kombinasyonu	Parti Boyutu (Batch Size)	Pencere Boyutu (Time Step)	Temsili Doğrulama Kayıp Fonksiyonu Değeri	Test Seti Tahmin Hatası (MSE)
151	TYSA	model2_both	48	30	0.6313	114154.43
152	TYSA	model2_both	48	60	0.7368	102515.42
153	TYSA	model2_both	48	90	0.8076	100145.60
154	TYSA	model2_both	64	30	0.5745	101118.77
155	TYSA	model2_both	64	60	0.5372	83229.75
156	TYSA	model2_both	64	90	0.5539	70020.17
157	TYSA	model2_Lmacd	16	30	0.4657	85790.28
158	TYSA	model2_Lmacd	16	60	0.6228	93132.13
159	TYSA	model2_Lmacd	16	90	0.6007	110282.04
160	TYSA	model2_Lmacd	32	30	0.5838	88710.01
161	TYSA	model2_Lmacd	32	60	0.5958	107113.84
162	TYSA	model2_Lmacd	32	90	0.7624	118932.11
163	TYSA	model2_Lmacd	48	30	0.5174	80148.65
164	TYSA	model2_Lmacd	48	60	0.5376	103297.07
165	TYSA	model2_Lmacd	48	90	0.3468	42600.89
166	TYSA	model2_Lmacd	64	30	0.4628	91346.85
167	TYSA	model2_Lmacd	64	60	0.5127	84402.38
168	TYSA	model2_Lmacd	64	90	0.3479	55242.75
169	TYSA	model2_hist	16	30	0.6480	108370.66
170	TYSA	model2_hist	16	60	0.8829	134947.49
171	TYSA	model2_hist	16	90	0.6521	104639.81
172	TYSA	model2_hist	32	30	0.6969	106868.58
173	TYSA	model2_hist	32	60	0.6990	93915.65
174	TYSA	model2_hist	32	90	0.5011	65662.59
175	TYSA	model2_hist	48	30	0.4274	58882.51
176	TYSA	model2_hist	48	60	0.5603	74977.39
177	TYSA	model2_hist	48	90	0.4006	26580.92
178	TYSA	model2_hist	64	30	0.4745	73605.99
179	TYSA	model2_hist	64	60	0.4882	105559.06
180	TYSA	model2_hist	64	90	0.3975	83084.37
181	LSTM	model0_base	16	30	0.0668	15706.68
182	LSTM	model0_base	16	60	0.0490	8774.85
183	LSTM	model0_base	16	90	0.0818	23296.14
184	LSTM	model0_base	32	30	0.0941	4675.97
185	LSTM	model0_base	32	60	0.1038	11498.89
186	LSTM	model0_base	32	90	0.1190	13391.97
187	LSTM	model0_base	48	30	0.0886	1633.99

EK A (devam): Tahmin sonuçları.

Test No	Ağ Modeli	Veri Seti Kombinasyonu	Parti Boyutu (Batch Size)	Pencere Boyutu (Time Step)	Temsili Doğrulama Kayıp Fonksiyonu Değeri	Test Seti Tahmin Hatası (MSE)
188	LSTM	model0_base	48	60	0.0841	833.04
189	LSTM	model0_base	48	90	0.0914	4357.90
190	LSTM	model0_base	64	30	0.1722	15636.61
191	LSTM	model0_base	64	60	0.1841	21576.55
192	LSTM	model0_base	64	90	0.1972	20024.10
193	LSTM	model0_macd	16	30	0.0514	7487.98
194	LSTM	model0_macd	16	60	0.0693	2113.66
195	LSTM	model0_macd	16	90	0.0534	5505.47
196	LSTM	model0_macd	32	30	0.1620	6573.62
197	LSTM	model0_macd	32	60	0.1735	4445.06
198	LSTM	model0_macd	32	90	0.1389	3851.90
199	LSTM	model0_macd	48	30	0.1756	16091.00
200	LSTM	model0_macd	48	60	0.1611	16080.43
201	LSTM	model0_macd	48	90	0.1366	12035.08
202	LSTM	model0_macd	64	30	0.1880	18000.71
203	LSTM	model0_macd	64	60	0.2071	18822.90
204	LSTM	model0_macd	64	90	0.2013	18465.22
205	LSTM	model0_both	16	30	0.1165	3518.78
206	LSTM	model0_both	16	60	0.1140	979.82
207	LSTM	model0_both	16	90	0.0746	1831.75
208	LSTM	model0_both	32	30	0.1737	18646.40
209	LSTM	model0_both	32	60	0.2549	7302.86
210	LSTM	model0_both	32	90	0.1987	10814.51
211	LSTM	model0_both	48	30	0.1905	9917.70
212	LSTM	model0_both	48	60	0.1815	13128.25
213	LSTM	model0_both	48	90	0.1495	3301.75
214	LSTM	model0_both	64	30	0.2172	19662.35
215	LSTM	model0_both	64	60	0.2189	20745.92
216	LSTM	model0_both	64	90	0.1969	21369.18
217	LSTM	model0_Lmacd	16	30	0.2188	8802.69
218	LSTM	model0_Lmacd	16	60	0.2343	24592.85
219	LSTM	model0_Lmacd	16	90	0.2525	40843.13
220	LSTM	model0_Lmacd	32	30	0.1733	15435.49
221	LSTM	model0_Lmacd	32	60	0.1987	10608.71
222	LSTM	model0_Lmacd	32	90	0.1476	14832.45
223	LSTM	model0_Lmacd	48	30	0.1313	11481.08
224	LSTM	model0_Lmacd	48	60	0.1200	3604.37

EK A (devam): Tahmin sonuçları.

Test No	Ağ Modeli	Veri Seti Kombinasyonu	Parti Boyutu (Batch Size)	Pencere Boyutu (Time Step)	Temsili Doğrulama Kayıp Fonksiyonu Değeri	Test Seti Tahmin Hatası (MSE)
225	LSTM	model0_Lmacd	48	90	0.1082	15113.84
226	LSTM	model0_Lmacd	64	30	0.2012	18758.04
227	LSTM	model0_Lmacd	64	60	0.1921	522.48
228	LSTM	model0_Lmacd	64	90	0.1667	20196.26
229	LSTM	model0_hist	16	30	0.2908	8146.84
230	LSTM	model0_hist	16	60	0.2102	27003.03
231	LSTM	model0_hist	16	90	0.1909	31674.51
232	LSTM	model0_hist	32	30	0.1720	7268.24
233	LSTM	model0_hist	32	60	0.2103	13331.61
234	LSTM	model0_hist	32	90	0.1786	7460.68
235	LSTM	model0_hist	48	30	0.1592	13091.73
236	LSTM	model0_hist	48	60	0.1366	2519.96
237	LSTM	model0_hist	48	90	0.1430	7806.10
238	LSTM	model0_hist	64	30	0.2169	17933.92
239	LSTM	model0_hist	64	60	0.2196	19863.94
240	LSTM	model0_hist	64	90	0.2114	24627.82
241	LSTM	model1_base	16	30	0.0953	9545.97
242	LSTM	model1_base	16	60	0.1109	21987.62
243	LSTM	model1_base	16	90	0.0850	5327.12
244	LSTM	model1_base	32	30	0.0465	9571.20
245	LSTM	model1_base	32	60	0.0208	1491.61
246	LSTM	model1_base	32	90	0.0383	1329.30
247	LSTM	model1_base	48	30	0.0432	2134.52
248	LSTM	model1_base	48	60	0.0430	3923.39
249	LSTM	model1_base	48	90	0.0279	915.61
250	LSTM	model1_base	64	30	0.0557	3178.24
251	LSTM	model1_base	64	60	0.0647	5272.53
252	LSTM	model1_base	64	90	0.1054	3161.77
253	LSTM	model1_macd	16	30	0.2005	24151.91
254	LSTM	model1_macd	16	60	0.3148	81176.26
255	LSTM	model1_macd	16	90	0.3261	20554.23
256	LSTM	model1_macd	32	30	0.0528	696.17
257	LSTM	model1_macd	32	60	0.0464	5841.41
258	LSTM	model1_macd	32	90	0.0855	24678.78
259	LSTM	model1_macd	48	30	0.0387	779.22
260	LSTM	model1_macd	48	60	0.0353	474.47
261	LSTM	model1_macd	48	90	0.0334	616.95

EK A (devam): Tahmin sonuçları.

Test No	Ağ Modeli	Veri Seti Kombinasyonu	Parti Boyutu (Batch Size)	Pencere Boyutu (Time Step)	Temsili Doğrulama Kayıp Fonksiyonu Değeri	Test Seti Tahmin Hatası (MSE)
262	LSTM	model1_macd	64	30	0.0477	2670.81
263	LSTM	model1_macd	64	60	0.0840	8719.15
264	LSTM	model1_macd	64	90	0.0466	303.32
265	LSTM	model1_both	16	30	0.2036	26509.21
266	LSTM	model1_both	16	60	0.1136	21552.31
267	LSTM	model1_both	16	90	0.1418	33663.89
268	LSTM	model1_both	32	30	0.0490	13652.76
269	LSTM	model1_both	32	60	0.0540	6336.46
270	LSTM	model1_both	32	90	0.0649	293.04
271	LSTM	model1_both	48	30	0.0992	241.44
272	LSTM	model1_both	48	60	0.0569	3569.84
273	LSTM	model1_both	48	90	0.0698	618.83
274	LSTM	model1_both	64	30	0.0702	3603.06
275	LSTM	model1_both	64	60	0.1013	6132.48
276	LSTM	model1_both	64	90	0.0847	3410.99
277	LSTM	model1_Lmacd	16	30	0.6696	239555.29
278	LSTM	model1_Lmacd	16	60	0.6284	90109.73
279	LSTM	model1_Lmacd	16	90	0.3358	21959.98
280	LSTM	model1_Lmacd	32	30	0.1639	25312.37
281	LSTM	model1_Lmacd	32	60	0.0889	10800.31
282	LSTM	model1_Lmacd	32	90	0.1020	11440.55
283	LSTM	model1_Lmacd	48	30	0.0730	25155.04
284	LSTM	model1_Lmacd	48	60	0.0512	936.49
285	LSTM	model1_Lmacd	48	90	0.0635	1218.51
286	LSTM	model1_Lmacd	64	30	0.0532	5944.70
287	LSTM	model1_Lmacd	64	60	0.0517	3845.93
288	LSTM	model1_Lmacd	64	90	0.0609	2741.17
289	LSTM	model1_hist	16	30	0.4271	146418.04
290	LSTM	model1_hist	16	60	0.3796	56596.57
291	LSTM	model1_hist	16	90	0.3091	47142.00
292	LSTM	model1_hist	32	30	0.0654	7204.73
293	LSTM	model1_hist	32	60	0.0775	3051.57
294	LSTM	model1_hist	32	90	0.0588	12343.56
295	LSTM	model1_hist	48	30	0.0686	43969.02
296	LSTM	model1_hist	48	60	0.0638	6239.99
297	LSTM	model1_hist	48	90	0.0956	8675.15
298	LSTM	model1_hist	64	30	0.0513	1971.80


EK A (devam): Tahmin sonuçları.

Test No	Ağ Modeli	Veri Seti Kombinasyonu	Parti Boyutu (Batch Size)	Pencere Boyutu (Time Step)	Temsili Doğrulama Kayıp Fonksiyonu Değeri	Test Seti Tahmin Hatası (MSE)
299	LSTM	model1_hist	64	60	0.0554	14933.22
300	LSTM	model1_hist	64	90	0.0471	814.79
301	LSTM	model2_base	16	30	0.1230	50317.31
302	LSTM	model2_base	16	60	0.2367	97535.91
303	LSTM	model2_base	16	90	0.0684	11713.09
304	LSTM	model2_base	32	30	0.1248	858.32
305	LSTM	model2_base	32	60	0.0883	7404.29
306	LSTM	model2_base	32	90	0.1371	1137.14
307	LSTM	model2_base	48	30	0.1155	31661.53
308	LSTM	model2_base	48	60	0.0685	850.46
309	LSTM	model2_base	48	90	0.0357	3706.02
310	LSTM	model2_base	64	30	0.0405	4551.14
311	LSTM	model2_base	64	60	0.0516	4854.46
312	LSTM	model2_base	64	90	0.0411	904.21
313	LSTM	model2_macd	16	30	0.0509	7055.64
314	LSTM	model2_macd	16	60	0.1784	21791.50
315	LSTM	model2_macd	16	90	0.0682	10654.76
316	LSTM	model2_macd	32	30	0.0383	10190.34
317	LSTM	model2_macd	32	60	0.0311	1181.86
318	LSTM	model2_macd	32	90	0.1073	2484.86
319	LSTM	model2_macd	48	30	0.0419	3604.61
320	LSTM	model2_macd	48	60	0.0450	10313.61
321	LSTM	model2_macd	48	90	0.0878	714.60
322	LSTM	model2_macd	64	30	0.0271	2016.75
323	LSTM	model2_macd	64	60	0.0339	1113.35
324	LSTM	model2_macd	64	90	0.0527	13301.42
325	LSTM	model2_both	16	30	0.0637	10908.18
326	LSTM	model2_both	16	60	0.1069	27832.87
327	LSTM	model2_both	16	90	0.0818	52088.96
328	LSTM	model2_both	32	30	0.0449	6916.43
329	LSTM	model2_both	32	60	0.0477	1677.23
330	LSTM	model2_both	32	90	0.0598	466.78
331	LSTM	model2_both	48	30	0.0468	2678.91
332	LSTM	model2_both	48	60	0.0580	7893.46
333	LSTM	model2_both	48	90	0.0556	2154.49
334	LSTM	model2_both	64	30	0.0400	1819.13
335	LSTM	model2_both	64	60	0.0600	1537.46

EK A (devam): Tahmin sonuçları.

Test No	Ağ Modeli	Veri Seti Kombinasyonu	Parti Boyutu (Batch Size)	Pencere Boyutu (Time Step)	Temsili Doğrulama Kayıp Fonksiyonu Değeri	Test Seti Tahmin Hatası (MSE)
336	LSTM	model2_both	64	90	0.0836	10790.56
337	LSTM	model2_Lmacd	16	30	0.1759	50756.38
338	LSTM	model2_Lmacd	16	60	0.3829	75601.34
339	LSTM	model2_Lmacd	16	90	0.2373	40709.16
340	LSTM	model2_Lmacd	32	30	0.0396	1430.87
341	LSTM	model2_Lmacd	32	60	0.0469	1858.88
342	LSTM	model2_Lmacd	32	90	0.0844	23184.26
343	LSTM	model2_Lmacd	48	30	0.0520	22865.57
344	LSTM	model2_Lmacd	48	60	0.0589	4599.79
345	LSTM	model2_Lmacd	48	90	0.0787	3139.50
346	LSTM	model2_Lmacd	64	30	0.0435	3356.75
347	LSTM	model2_Lmacd	64	60	0.0525	2764.85
348	LSTM	model2_Lmacd	64	90	0.0555	1416.57
349	LSTM	model2_hist	16	30	0.0499	20851.95
350	LSTM	model2_hist	16	60	0.0763	12019.64
351	LSTM	model2_hist	16	90	0.1674	29591.88
352	LSTM	model2_hist	32	30	0.0533	2330.45
353	LSTM	model2_hist	32	60	0.0333	13426.15
354	LSTM	model2_hist	32	90	0.0619	13698.68
355	LSTM	model2_hist	48	30	0.0500	4226.10
356	LSTM	model2_hist	48	60	0.0453	3089.34
357	LSTM	model2_hist	48	90	0.0583	1705.65
358	LSTM	model2_hist	64	30	0.0616	4301.84
359	LSTM	model2_hist	64	60	0.0703	12390.86
360	LSTM	model2_hist	64	90	0.0743	8509.66

ÖZGEÇMİŞ



Ad-Soyad : Sina BİRECİK



ÖĞRENİM DURUMU:

- **Lisans** : 2016, İstanbul Teknik Üniversitesi, Makina Fakültesi, Makina Mühendisliği
- **Yüksek Lisans** : 2022, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Mekatronik Mühendisliği

MESLEKİ DENEYİMLER:

- 2016-2018 yılları arasında Entes Elektronik'te Teknik Ürün Yöneticisi olarak çalıştı.
- 2019-2021 yılları arasında FEV Türkiye'de Güç Aktarım Sistemleri Simülasyon Mühendisi olarak çalıştı.
- 2021 yılından itibaren FEV Türkiye'de Gelişmiş Sürücü Destek Sistemleri Mühendisi olarak görev yapmaktadır.

PATENTLER:

- **Kenanoğlu, E., Balcı, İ. C., Birecik, S., Sezer, V.** 2021. Portable Biaxial Drawing Kit. Patent numarası: WO/2021/050024
Erişim: <https://patentscope.wipo.int/search/en/detail.jsf?docId=WO2021050024>