



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**DOLAR ENDEKSİ, NASDAQ ENDEKSİ,
ALTIN VE BİTCOİN DEĞERLERİNİN
BİRBİRLERİNE BAĞLI OLARAK MAKİNE
ÖĞRENMESİ YÖNTEMLERİYLE TAHMİN
EDİLMESİ**

Samet Kaan KANAK

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Ocak-2023
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Samet Kaan KANAK tarafından hazırlanan “Dolar Endeksi, Nasdaq Endeksi, Altın ve Bitcoin Değerlerinin Birbirlerine Bağlı Olarak Makine Öğrenmesi Yöntemleriyle Tahmin Edilmesi.” adlı tez çalışması 20/01/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Prof. Dr. Halife KODAZ

Danışman

Dr. Öğr. Üyesi Hazim İŞCAN

Üye

Dr. Öğr. Üyesi Ahmet ÖZKIŞ

İmza

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

TEZ BİLDİRİMİ

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

DECLARATION PAGE

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

Samet Kaan KANAK

Tarih: 20.01.2023

ÖZET**YÜKSEK LİSANS TEZİ****DOLAR ENDEKSİ, NASDAQ ENDEKSİ, ALTIN VE BİTCOİN DEĞERLERİNİN BİRBİRLERİNE BAĞLI OLARAK MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE TAHMİN EDİLMESİ****Samet Kaan KANAK****Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı****Danışman: Dr. Öğr. Üyesi Hazim İŞCAN****2023, 69 Sayfa****Jüri****Prof. Dr. Halife KODAZ
Dr. Öğr. Üyesi Hazim İŞCAN
Dr. Öğr. Üyesi Ahmet ÖZKİŞ**

Yatırım bizler için önemli bir kaynaktır. İnsanlar birikimlerini yatırım araçları ile değerlendirmek isterler. Günümüzde dolar, altın, euro, gümüş, borsa ve son zamanlarda popüler olan Bitcoin ve diğer kripto paralar gibi çok fazla yatırım aracı mevcuttur. Makine öğrenmesi birçok alanda kullanılmaktadır. Finans alanında da geçmişteki verilerden yararlanılarak geleceğe yönelik tahminlerde makine öğrenmesinden yararlanılmaktadır. Bu çalışmada yatırımcılara yardımcı olabilmek ve ileriye dönük tahminlerde bulunabilmek amacıyla doların önemli para birimlerine karşı gücünü gösteren dolar endeksi, Amerika'daki finansal olmayan firmaları barındıran Nasdaq 100 endeksi, en eski ve kıymetli yatırım araçlarından altının ons değeri ve son zamanlarda gittikçe popüleritesi artan Bitcoinin değeri kullanılmıştır. Investing.com internet sitesinden alınan 2012-2022 yılları arasındaki kapanış değerleri ile iki, beş ve on yıllık veri setleri oluşturulmuştur. Python programlama dili ile makine öğrenmesinde Lineer Regresyon, Lasso ve Karar ağaçları yöntemleri kullanılmıştır. Üç para birimi bağımsız değişken yapılmış, bağımlı değişken para birimi tahmin edilmiştir. Çalışma sonucunda on yıllık veri setiyle çalıştırılan uygulamanın daha başarılı sonuçlar verdiği, yöntem olarak da Lasso ve Karar ağaçlarının doğrusal regresyondan başarılı sonuçlar çıkardığı gözlemlenmiştir. Veri setinde olmayan gerçek değerler ile test edilen uygulamanın gerçek değerlere yakın sonuçlar verdiği ortaya çıkmıştır.

Anahtar Kelimeler: Altın, Bitcoin, Dolar, Makine Öğrenmesi, Nasdaq

ABSTRACT**MS THESIS****ESTIMATING THE VALUES OF DOLLAR INDEX, NASDAQ INDEX, GOLD AND BITCOIN DEPENDING ON EACH OTHER BY MACHINE LEARNING METHODS****Samet Kaan KANAK****Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering****Advisor: Assist. Prof. Dr. Hazim İŞCAN****2023, 69 Pages****Jury****Prof. Dr. Halife KODAZ****Assist. Prof. Dr. Hazim İŞCAN****Assist. Prof. Dr. Ahmet ÖZKİŞ**

Investment is an important resource for people. Individuals want to use their savings with financial instruments. There are many financial instruments available today, such as the dollar, gold, euro, silver, stock market and, recently popular Bitcoin and other cryptocurrencies. Machine learning is used in many fields. In the field of finance, machine learning is used to predict the future by making use of past data. In this study, the dollar index, which shows the strength of the dollar against major currencies, the Nasdaq 100 index, which hosts non-financial companies in the United States, the ounce value of gold, one of the oldest and most valuable investment instruments, and the value of Bitcoin, which has been increasing in popularity recently, have been used to help investors and make forward-looking predictions. The biennial, three-year and ten-year data were created with the data taken from Investing.com website, in the light of closing values for the years 2012-2022. Linear Regression, Lasso and Decision tree models are used in machine learning with Python programming language. Three currencies were made as independent variables, and the dependent variable currency was estimated. As a result of the study, it was observed that the application run with ten-year data set gave more successful results, and as a method, Lasso and Decision Tree models obtained successful results from linear regression. It has also been revealed that the application tested with real values that are not in the data set gives results close to the real values.

Keywords: Bitcoin, Dollar, Gold, Machine Learning, Nasdaq

ÖNSÖZ

Bu tez çalışması sürecinde deneyim ve tecrübelerinden faydalandığım Dr. Öğr. Üyesi Hazim İŞCAN'a, desteğini hiçbir zaman esirgemeyen canım eşim Çiğdem KANAK'a ve aileme teşekkürü bir borç bilirim.

Samet Kaan KANAK
KONYA-2023



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
Singeler	ix
Kısaltmalar	ix
1. GİRİŞ	1
2. LİTERATÜR TARAMASI.....	3
3. MATERYAL VE YÖNTEM.....	7
3.2 Makine Öğrenmesi.....	7
3.2.1 Denetimli öğrenme (supervised learning).....	8
3.2.2 Denetimsiz öğrenme (unsupervised learning)	9
3.2.3 Yarı denetimli öğrenme (semi-supervised learning)	11
3.2.4 Pekiştirmeli öğrenme	11
3.3 Makine Öğrenmesi Algoritmaları	12
3.3.1 Regresyon	12
3.3.2 Doğrusal regresyon	13
3.3.3 Çoklu doğrusal regresyon	14
3.3.4 Doğrusal olmayan regresyon (polinomsal regresyon)	15
3.3.5 LASSO regresyon	17
3.3.6 Karar ağaçları.....	18
4.PARA PİYASALARI	23
4.1 Altın	23
4.1.1 Altının para piyasalarındaki yeri.....	24
4.1.2 Spot (fiziki) piyasa.....	26
4.1.3 Vadeli işlem piyasası	27
4.2 Dolar	27
4.2.1 Dolar endeksi (DXY).....	29
4.3 Nasdaq Borsası	30
4.3.1 Nasdaq 100 endeksi (NDX).....	31
4.4 Kripto Para.....	33
4.4.1 Blok-Zincir.....	33
4.4.2 Bitcoin.....	33
5. UYGULAMA	37

5.1 İki Yıllık Veriler ile Yapılan Çalışma.....	41
5.2 Beş Yıllık Veriler ile Yapılan Çalışma	43
5.3 On Yıllık Veriler ile Yapılan Çalışma	45
5.4 Uygulama Çıktıları	48
6. SONUÇ VE ÖNERİLER.....	53
KAYNAKLAR	54



SİMGELER VE KISALTMALAR

Simgeler

\$: Amerika Birleşik Devletleri Doları
₺	: Türk Lirası
β	: Beta
λ	: Lamda
Σ	: Toplama

Kısaltmalar

ABD	: Amerika Birleşik Devletleri
ANFIS	: Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi
BİST	: Borsa İstanbul
BTC	: Bitcoin
CAD	: Kanada Doları
CBOT	: Chicago Board Of Trade
CHF	: İsviçre Frangı
CME	: Chicago Mercantile Exchange
COMEX	: New York Commodity Exchange
DXY	: Dolar Endeksi
ETS	: Üstel Düzeltme Modeli
EUR	: Avrupa Para Birimi
GBP	: İngiliz Sterlini
GWI	: Global Web Index
IMF	: Uluslararası Para Fonu
İAB	: İstanbul Altın Borsası
İMKB	: İstanbul Menkul Kıymetler Borsası
JPY	: Japon Yeni

KNN	: K En Yakın Komşu
LASSO	: En Küçük Mutlak Daralma ve Seçim Operatörü
LBMA	: Londra Külçe Altın Piyasası
LS-SVM	: En Küçük Kareler Destek Vektör Makineleri
LSTM	: Uzun Kısa Süreli Bellek
MKK	: Merkezi Kayıt Kuruluşu
MLP	: Çok Katmanlı Algılayıcı
NASDAQ	: National Association of Securities Dealers Automatic Quotation
NDX	: Nasdaq 100 Endeksi
NYSE	: New York Menkul Kıymetler Borsası
SEK	: İsveç Kronu
SPK	: Sermaye Piyasası Kurulu
SVM	: Destek Vektör Makineleri
TRY	: Türk Lirası
TSPAKB	: Türkiye Sermaye Piyasası Aracı Kuruluşları Birliği
TÜFE	: Tüketici Fiyat Endeksi
USD	: Amerika Para Birimi
USGS	: Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu
VOB	: Vadeli İşlem ve Opsiyon Borsası
VOIP	: Vadeli İşlemler Borsası

1. GİRİŞ

İnsanođlu ticaret yapabilmek için para bulunmadan önce nesnelere takas etmiştir. Paranın icat edilmesiyle ticarete, nesnelere takası yerine para kullanılmaya başlanmıştır. Paranın kullanılmasıyla ticaret daha hızlı ve kolay hale gelmiştir. Para günümüze kadar hep aynı amaçlarla kullanılmıştır. Sadece, şekli, ismi ve birim değeri değişmiştir. Örneğin, altın, gümüş, Dolar, Euro, Türk Lirası veya borsadaki bir hisse senedi gibi. Yeni yeni yaygınlaşmaya başlayan, sıra dışı olan, para piyasasına yeni bir kavram getiren kripto para para çeşitlerinin arasına dahil olmuştur. Para ticaretin yanında yatırım için de her zaman kullanılmıştır. İnsanlar paralarının değerini korumak ve artırmak adına çoğunlukla döviz ve altın para birimlerini tercih etse de kripto para aynı amaçla kullanılmaya başlanmıştır.

Altın yüzyıllar boyunca en kıymetli metal para birimidir. Günümüzde de para piyasalarında güvenli liman olarak tanımlanmaktadır. Kadınların zıynet eşyası olarak en çok kullandıkları değerli metaldir. Alım satımı kolay olan yatırım aracıdır. SPK, BİST, VOB, İAB, Takas bank, MKK ve TSPAKB iş birliğiyle yapılan araştırmada altın, "ilk tercih edilecek yatırım aracı" olmuştur (TSPAKB, 2011).

Dolar dünyada en çok kullanılan, en çok çaprazlanması yapılan para birimidir. Amerika Birleşik Devletleri'nin resmi para birimidir. Ülkemizde hem ticaret hem de yatırım için en çok tercih edilen para birimlerinden biridir. DXY, 1973 yılında ABD Federal Rezervi tarafından, ABD dolarının küresel para birimlerine karşı karşılıklı dış ticaret ağırlıklı bir ortalama değer hesaplamak için geliştirilmiştir (Tradingview, 2021). DXY, ABD dolarının, başlıca para birimleri karşısındaki değerini gösteren bir göstergedir.

Günümüzde borsa çeşitleri, her tür menkul kıymetin, payın, tahvilin ya da emtianın borsaya kaydedilmesiyle işlem gördüğü ve devletin ilgili gözetim ve denetim kurumlarının denetiminde olarak işleyen organize piyasalardır. Nasdaq ABD'de işlem gören, 1971'de kurulmuş olan bir borsadır. Nasdaq 100 (NDX) bu borsada en yüksek piyasa değerine sahip 100 şirketi kapsamaktadır. Sadece ABD'li şirketlerin olduğu bir borsa değildir. 2021 yılında Türk menşeli bir şirkette bu borsaya giriş yapmıştır (Nasdaq, 2021).

Para dünyasına yeni bir bakış açısı kazandıran, altın dolar gibi fiziksel bir karşılığı bulunmayan kripto paraların günümüzde önemi ve kullanımını giderek artırmıştır. Kripto

para birimleri iyi yatırım varlıklarıdır; bu nedenle, kripto para birimlerinin etkin tahmini, trend olan bir araştırma alanı haline gelmiştir. 2009 yılında ortaya çıkan Bitcoin kripto para birimi, en çok tercih edilen kripto para çeşididir. Bitcoin haricinde yüzlerce çeşit altcoin olarak tanımlanan kripto para çeşidi de mevcuttur.

Yatırımcılar için sahip oldukları paraları nasıl değerlendirecekleri hep bir soru işareti olmuştur. Bu değerlendirme ev veya arsa olarak olabilir. Ya da altın, dolar, Bitcoin veya hisse senedi satın alarak da paralarını değerlendirebilme şansları olabilmektedir.

Günümüzdeki bilgisayar teknolojilerinin giderek yaygınlaşması paramı nasıl değerlendirebilirim sorusuna cevap bulmada yardımcı olabilmektedir. Bunun için makine öğrenmesi yöntemlerinden yararlanılabilir. Makine öğrenmesi, bilgisayar yardımı ile çeşitli matematiksel işlemler kullanılarak veriler üzerinden anlamlar oluşturmak ve tahminlerde bulunmaktır.

Bu çalışmada, yatırımcılara yardımcı olabilmek ve ileriye dönük tahminlerde bulunabilmek amacıyla, dolar endeksi, Nasdaq 100 endeksi, altın ve Bitcoin fiyatları ile veri seti oluşturulmuş ve bu veri seti ile makine öğrenmesi yardımıyla tahmin yapılmıştır. Bu sayede önceki yıllardaki fiyatlardan yararlanılarak ileri ki yıllar için bu üç para birimindeki fiyatlar tahmin edilebilecektir.

Bu tez beş temel bölümden oluşmaktadır. Bu bölüm, tezin içeriği, konusunun anlatıldığı giriş bölümüdür.

İkinci bölümde konu ile ilgili daha önceden yapılmış olan çalışmalarla ilgili kaynak araştırması yapılmıştır. Para piyasalarında yapılan tahmin çalışmalar ve bu çalışmalarda çıkan sonuç incelenmiştir.

Üçüncü bölümde çalışmamıza konu olan yöntemler hakkında bilgi içermektedir. Makine öğrenmesi, doğrusal ve doğrusal olmayan regresyon, karar ağaçları ile ilgili bilgiler bu bölümde yer almaktadır.

Dördüncü bölümde kullanılan para birimleri hakkında bilgiler içermektedir. Veri setini oluşturan dolar endeksi, Nasdaq 100 endeksi, altın ve Bitcoin hakkında bilgiler verilmiştir.

Beşinci bölüm de geliştirilen uygulama hakkında bilgi verilmiştir. Çalıştırılan uygulamanın çıktıları analiz sonuçları bu bölümde yer almaktadır.

Altıncı bölümde ise elde ettiğimiz sonuçlar değerlendirilmiş ve sonraki çalışmalar için önerilerde bulunulmuştur.

2. LİTERATÜR TARAMASI

Para piyasalarında doğru tahminde bulunmak oldukça zordur. Bunun için çeşitli yöntemlerden faydalanılmaktadır. Bu konuda literatür incelendiğinde yapay zekâ ve makine öğrenmesinden çokça faydalandığı görülmektedir.

Parisi ve ark (2008), yaptığı çalışmada yapay sinir ağları ile altın fiyatlarındaki değişimin yönünü tespit etmeye çalışmışlardır. Yapılan bu çalışmada veri seti olarak altın fiyatı ve Dow Jones endüstri endeksi kullanılmıştır. Zaman serileri yöntemleri olan ARIMA modelleri ile yapay sinir ağlarını karşılaştırmışlardır. Yapay sinir ağları %60 doğruluk oranı ile ARIMA modellerinden daha başarılı bulunmuştur.

Shen ve ark. (2009), Nasdaq 100, Djiaa (Dow Jones Borsası Endüstri Endeksi) ve S&P 500 endekslerini 10 bağımsız değişken ile (altın, gümüş, platin, euro, Usd, Avustralya doları, Japon yeni, Alman birleşik borsa endeksi, Avustralya menkul kıymetler borsa endeksi, Londra borsası endeksi) SVM algoritması ile tahmin etmiştir. Yapılan çalışmada her endeks için %76-77 doğruluk oranına ulaşılmıştır.

Yayar ve Karaca (2011), 1997-2009 yılları arasındaki İMKB (şimdiki adıyla BİST100) kapanış verileri kullanılarak zaman serisine dayalı tahmin yöntemi olan Box-Jenkins modeli ile endeks tahmini yapılmıştır. Bu çalışma ile %67 başarı oranı elde edilmiştir.

Sureshkumar ve Elango (2012), Hindistan'da yaptığı bir çalışma da Ulusal Menkul Kıymetler Borsa'sındaki bir hisse senedini yapay sinir ağları çok katmanlı algılayıcı (MLP) modeli ile tahmin etmişlerdir. Veri olarak Tata Danışmanlık Hizmetleri (TCS) firmasının 2009-2011 yılları arasındaki verilerden yararlanmışlardır. Yapılan çalışmada %93 tahmin başarısını yakalamışlardır.

Aygöre ve ark. (2012), altın fiyatı, faiz oranı, bankalar arası çift taraflı işlem miktarı ve dolar kuru bağımsız değişkenleri ile İMKB 100 endeksini tahmin etmişlerdir. Veri seti, 1995–2010 yılları arasındaki verilerden oluşturulmuş, ARIMA, Newton Yöntemi ve Yapay sinir ağları yöntem olarak kullanılmıştır. Yapay sinir ağları ile yapılan tahminin diğerlerine göre daha başarılı olduğu tespit edilmiştir.

Kocatepe (2016), Türkiye'deki gram altın fiyatlarını yapay sinir ağlarını kullanarak tahmin etmeye çalışmıştır. Çalışmada on üç değişken (dolar endeksi, dolar kuru, ham petrol fiyatı, Standard&Poor's 500 endeksi, Borsa İstanbul 100 endeksi, Türkiye enflasyon oranı, Türkiye tahvil ve faiz oranları, ABD enflasyon, ABD tahvil ve

faiz oranları, gümüş ve bakır fiyatları) kullanılmıştır. Bu değişkenlerin 2007-2015 yılları arasında aylık değerleri alınmıştır. Oluşturulan yapay sinir ağ modeli ile altın fiyatlarını tahmin etmede %75,24 başarı elde etmiştir.

Yalçın (2016), bist30 endeksi, dolar, euro ve altının birbirleri ile olan ilişkisini araştırmıştır. Analizlerde, Bist30 endeksi, dolar, euro ve altının 2010-2014 tarihleri arasında gerçekleşen günlük fiyat verilerini, çoklu doğrusal regresyon ve lojistik regresyon analizlerinde kullanmıştır. Çoklu regresyonda bağımlı değişken olarak Bist30'u kullanmıştır. Yaptığı çalışmada %50'nin üzerinde doğruluk değerine ulaşmıştır. Lojistik regresyonda ise %80'lere kadar başarıya ulaşabilmiştir.

Yıldıran (2016), dolar kurunu (USD/TRY) yapay sinir ağları ve zaman serilerine dayalı ARIMA yöntemi ile 2005–2016 yılları arasındaki verileri kullanarak tahmin çalışmasında bulunmuştur. Çalışma sonucunda yapay sinir ağlarının daha başarılı olduğunu ortaya koymuştur.

Aras (2018), yapay zekâ ile ETS, ARIMA, MLP, ANFIS ve LS-SVM modellerini kullanarak 4 farklı kripto paranın (Bitcoin, Ripple, Litecoin, Ethereum) iki yıllık verilerini ele alarak tahminde bulunmuştur. Çalışma da LS-SVM modeli ile Bitcoin %67 lik başarı oranı elde etmiştir.

Karakoyun (2018), yaptığı çalışmada Nasdaq ile Bitcoin tahminleme çalışmasında bulunmuştur. Bu çalışma ile Nasdaq'daki Apple hisse senedi ve Bitcoin fiyatları, ayrı ayrı, istatistiksel yöntem olan ARIMA ve Uzun Süreli Kısa Dönemli Hafıza (LSTM) ile tahmin edilmiştir. Çalışmada Apple hisse senedi için 1984-2018 yılları arası, Bitcoin için de 2013-2017 yılları arası veriler kullanılmıştır. Çalışma sonucunda LSTM modeli her iki piyasa için daha başarılı olmuştur.

Aktaş (2019), Nasdaq 100 endeksi ve Dow Jones Endüstri Ortalaması için makine öğrenmesi yöntemlerinden Rassal Orman Algoritması ve Destek Vektör Makineleri ile tahmin çalışması yapmıştır. Çalışma iki farklı veri seti ile yapılmıştır. İlk oluşturulan veri setinde bağımsız değişken olarak 2012-2018 yılları arasındaki yedi farklı ekonomik göstergeler (Brent petrol fiyatı, altın fiyatı vb.) kullanılmıştır. Bu değişkenler ile çıkan sonuçta Rassal Orman Algoritması hem Nasdaq 100 endeksi hem de Dow Jones Endüstri Ortalaması için daha başarılı sonuç vermiştir. Diğer oluşturulan veri seti ise Alpha Vantage üzerinden sağlanan teknik göstergelerle oluşturulmuştur. Bu oluşturulan veri setinde ise Destek Vektör Makineleri her iki değişken için de daha başarılı olmuştur.

Demirel (2019), bist100 hisse senetlerinin 2010-2019 yılları arasındaki fiyatlarını makine öğrenmesi ve derin öğrenme ile tahmin çalışması yapmıştır. Makine öğrenmesinde çok katmanlı algılayıcılar ve destek vektörü kullanmıştır. Derin öğrenmede ise uzun kısa dönemli hafıza yöntemini kullanmıştır. Çalışmasında derin öğrenme ve çok katmanlı algılayıcılarının, destek vektörüne göre daha başarılı sonuçlar verdiğini görmüştür.

Öndes ve Oğuzlar (2019), altın fiyatlarını, 2005-2017 yılları arasındaki petrol fiyatı, gümüş fiyatı, USD/EURO paritesi, Euronext100 endeksi ve Dow Jones endüstri endeksini kullanarak yapay sinir ağlarının Levenberg – Marquardt algoritması ile tahmin çalışması yapmışlardır. Çalışmada %81,43 doğruluk oranına ulaşmışlardır.

Sakarya ve Yılmaz (2019), 2001-2018 yılları arasındaki BİST 30 endeks verisi Derin öğrenme LSTM yöntemi ile tahmin edilmeye çalışılmıştır. %80 başarı oranı elde edilmiştir.

Abar (2020), yaptığı çalışmada altının ons fiyatını, gümüş ons fiyatı, ham petrol varil fiyatı, dolar endeksi, S&P500 endeksi, ABD birleşik faiz oranı ve ABD TÜFE oranlarını bağımsız değişken kullanarak tahmin de bulunmuştur. Veri setini 2015-2020 yılları arasındaki veriler ile oluşturmuştur. Çalışmada karar ağacına benzer olan XGBoost makine öğrenmesi yöntemini ve MARS modelini kullanmıştır. XGBoost modeli ile %99,6, MARS modeli ile %97,8 başarı oranı ile tahmin de bulunmuştur.

Bayraktar (2020), bu çalışmada piyasa değeri en büyük olan Bitcoin, Ethereum ve Ripple kripto paraları K en yakın komşu, Destek Vektör Regresyonu ve Rasgele Orman algoritmaları ile analiz ve tahmin edilmiştir. Veri seti, bu kripto para çeşitlerinin piyasaya çıktığı tarihten itibaren 2020 yılına kadar olan verilerden oluşturulmuştur. Destek Vektör Regresyonu en başarılı, K en yakın komşu ise en başarısız yöntem olarak bulunmuştur.

Kaya ve ark. (2020), covid-19 öncesi ve sonrası zaman dilimlerindeki Bitcoin fiyatlarını ele alarak makine öğrenmesi (SVM), zaman serileri analizi (LSTM) ve derin öğrenme (ARIMA) ile tahmin çalışmasında bulunmuşlardır. Covid-19 öncesi olarak Şubat 2018-Ekim 2019, covid-19 sonrası olarak Şubat 2018-Haziran 2020 arası tarihlerdeki BTC/USD fiyatlarını ele almışlardır. Bitcoin fiyatlarındaki ani değişikliklerden dolayı fiyatları günlük ve aylık almak yerine haftalık ele almışlardır. Covid-19 öncesi zaman için SVM algoritması, LSTM ve ARIMA ya göre %83 başarı oranıyla daha başarılı bulunmuştur. Covid-19 sonrası dönem incelendiğinde ise ARIMA %93 doğruluk oranı ile diğerlerine göre daha başarılı bulunmuştur.

Keçeci (2020), yapay sinir ağı ile yapılan tahmin çalışmasında yinelemeli sinir ağı kullanılmıştır. Uzun Süreli Kısa Dönemli Hafıza (LSTM) kullanılarak Borsa İstanbul VOIP’de işlem gören Endeks30 verilerinin düşüş ve yükseliş trendleri tahmin edilmiştir. Veri seti olarak 2015-2020 yılları arasındaki veriler kullanılmıştır. Çalışmada %68 başarı oranı olan LSTM’nin %64 başarı oranı olan ileri beslemeli sinir ağlara göre daha başarılı olduğu tespit edilmiştir.

Aytekin (2021), yapılan diğer bir çalışmada BİST 0 endeksindeki 12 hisse senedinin 2019 ve 2020 yıllarındaki 3’er aylık dönemlerinin fiyatları yapay sinir ağı ve çoklu regresyon analizi ile tahmin edilmiştir. Bağımsız değişken olarak; piyasa değeri, hisse başına düşen kar, kaldıraç oranı, öz sermaye karlılığı ve fiyat kullanılmıştır. Bu çalışmada yapay sinir ağı ile daha başarılı bir sonuç elde edilmiştir.

Gülhan ve Temurlenk (2021), kripto paralarda tahmin yapılan diğer bir çalışmada 2015-2020 yılları arasındaki altın fiyatı, petrol fiyatı, EURO/USD paritesi, S&P 500 endeksi. Londra para piyasalarındaki bankalar arası borç verme faiz oranı, Bitcoin Google trend endeksi ve elektrik fiyatları değişkenlerinin Bitcoin fiyatları üzerindeki etkisi incelenmiştir. Yöntem olarak ARIMA yöntemi kullanılmıştır. Çalışma sonucunda Bitcoin fiyatlarının, elektrik fiyatları ile negatif anlamsız bir ilişkisi olduğu, diğer değişkenlerle ise anlamlı ve pozitif bir ilişkisi olduğu gözlemlenmiştir.

Ustalı ve ark. (2021), para piyasaları ile ilgili yapılan çalışmada BİST 30 endeksindeki hisseler makine öğrenmesi ile tahmin edilmeye çalışılmıştır. 2010-2019 yılları arasındaki bu endekste 22 firma ele alınmıştır. Yöntem olarak Yapay Sinir Ağları, Rastgele Orman algoritması ve XGBoost algoritması kullanılmıştır. Yapay Sinir Ağları ve Rastgele Orman algoritmaları %70 başarı oranı elde etmiştir. XGBoost ise %75 oran ile daha başarılı bir oran elde etmiştir.

Nayak ve ark. (2022), kripto paralar ile ilgili yaptığı çalışmada, Bitcoin, Litecoin, Ethereum, Ripple, CMC 200 ve Tether coinlerinin 2019-2021 yılları arasındaki verilerini kullanarak Yapay Sinir Ağları Rao algoritması ile tahmin çalışmasında bulunmuştur. Yapılan bu çalışmada Bitcoin’de %70, Ripple’da %60, Ethereum’da %61, Litecoin’de %68, CMC200’de %73 ve Tether’da %99 doğruluk oranlarını yakalamıştır.

3. MATERYAL VE YÖNTEM


3.2 Makine Öğrenmesi

Makine öğrenmesi terimi 1959 yılında Arthur Lee Samuel'in "dama oyunu kullanılarak makine öğrenimi üzerine bazı çalışmalar" isimli makalesinde ortaya atılmıştır. Dama oyununu seçmesinin nedeni, oyundaki iyi ya da kötü hamlelerin not edilebilmesidir, bu şekilde iyi ya da kötü hamleler arasında ayırım yapılabilmektedir (Samuel, 1959). Samuel'in yaptığı program, farklı kişilerle öğrenme modunda iken oynadıktan sonra çok daha iyi bir oyuncu oldu. Yapılan program yapılan hareketlerin hangilerinin daha başarılı olduğunu öğrenmiş ve programlamasını da bu planlar içerecek şekilde uyarlamıştı. 1965 yılında bu konu ile ilgili ilk kitap Nilsson tarafından yazılmıştır (Nilsson, 1965).

1990'dan itibaren insanların teknolojiye olan erişiminin hızla artmasıyla işlenmeyi bekleyen birçok veri oluşmuştur. Zaman geçtikçe bu verilerden bilgi elde etme ihtiyacı ortaya çıkmıştır. Veri madenciliği sayesinde veri setindeki verilerle işlem yapılarak anlamlı hale getirilmiş daha sonra da makine öğrenmesi vasıtasıyla öğrenilen bilgilerin istenilen amaca yönelik hizmet etmesi sağlanmıştır (Tekin ve ark., 2018).

Günümüzde birçok alanda makine öğrenmesinden yararlanılmaktadır. Örneğin tıp alanında hastalıkların daha kolay tespit edilebilmesi, emlak alanından evin özelliklerine göre fiyatlamaların tahmin edilmesi, sosyal medya devlerinin makine öğrenmesinden yararlanarak kullanıcıların ihtiyacına göre reklam tavsiyelerinde bulunması gibi. Satış ve perakende sektöründe müşteri kayıpları ve nedenlerinin araştırmasında da makine öğrenmesinden yararlanılmaktadır. Bu sayede müşterileri elinde tutmak ve onları kaybetmemek için kullanılır. Finans alanında geçmişteki verilerden yararlanılarak geleceğe yönelik tahminlerde yine makine öğrenmesinden yararlanılmaktadır.

Makine öğrenmesi iki aşamadan oluşmaktadır. İlk aşama modelin öğrenme aşamasıdır. Bu aşamada eldeki verilerden öğrenme olayı gerçekleşir. İkinci aşama çıkarım aşamasıdır. Bu aşamada öğrenilen bilgilerden çıkarım yapabilme yeteneğidir. Şekil 3.1'de makine öğrenmesinin aşamaları gösterilmiştir.



Şekil 3.1. Makine öğrenmesi aşamaları (turhost.com, 2021)

Makine öğrenmesi türleri aşağıdaki gibidir;


- ✓ Denetimli Öğrenme (Supervised Learning)
- ✓ Denetimsiz Öğrenme (Unsupervised Learning)
- ✓ Yarı denetimli Öğrenme (Semi-Supervised Learning)
- ✓ Pekiştirmeli Öğrenme

3.2.1 Denetimli öğrenme (supervised learning)

Denetimli Öğrenme türünde daha önce verilen girdi verileri ile etiketli çıktı verisini tahmin eder. Önceden oluşturulan etiketli veriler eğitim aşamasından geçer. Eğitim aşamasından sonra test aşamasında daha önce görmediği veriyi tahmin etme gücüne bakılır (Kotsiantis ve ark., 2007).

Denetimli öğrenme ikiye ayrılır:

Sınıflandırma: Bu model verileri sınıflandırarak oluşturur. Sistem hangi durumda hangi sınıfa ait olacağını eğitim verisi ile öğrenir. Örneğin meyveler ile ilgili bir veri setimiz olsun, bu veri setinde elmanın şeklini, rengini, ağırlığını, tadını girelim. Yine aynı şekilde diğer meyvelerin bilgilerini girelim. Test verisinde daha önce görmediği bilgiler ile meyveyi tahmin etmeye çalışır. Şekil 3.2 de denetimli öğrenmenin çalışma yapısı gösterilmektedir.



Şekil 3.2. Denetimli öğrenme (researchgate.net, 2021)

Regresyon: Bu modelde girilen değişken değerlerine göre çıktı değişkenini tahmin etmeye çalışır. Örneğin, daire özelliklerinin ve fiyatlarının olduğu bir veri setimiz olsun burada evin özelliklerine göre fiyatını eğitim verisinden öğrendiği bilgiler ile tahmin etmeye çalışır.

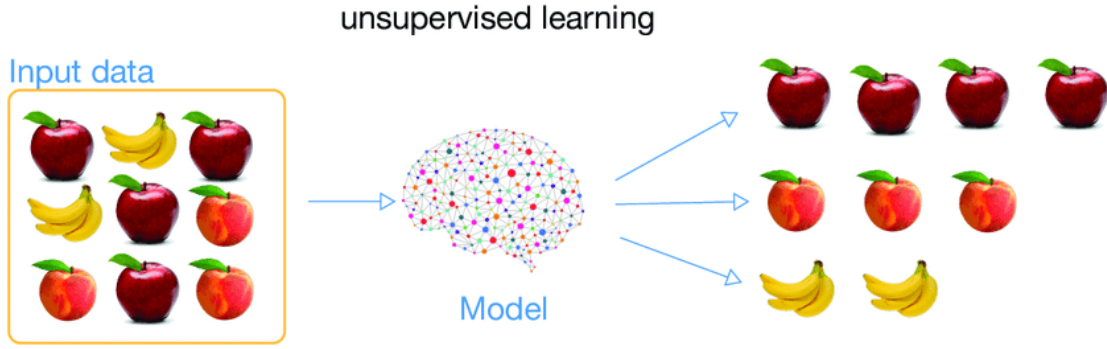
3.2.2 Denetimsiz öğrenme (unsupervised learning)

Denetimsiz öğrenmede eğitim verisi bulunmamaktadır, dolayısıyla herhangi bir sınıflandırma ve etiketleme bilgisi bulunmaz. Verilerdeki doğal sınıflandırma bu öğrenme türünde keşfedilir. Bu keşif sonrası verilere sınıflandırma yapılır. Bir olayı öğrenmek için kullanılabilir. Temelde farklı olan anlayışlar türetildiği için insanlar tarafından yapılan geleneksel analizlerden farklı olarak tamamen makine tarafından analizler yapılır (Julian ve ark., 2021). Genellikle veri madenciliği bu öğrenme yöntemine örnektir. Örneğin; bir e-ticaret şirketinin bayan müşterilerin en çok hangi ürünü satın aldığını öğrenmesi olabilir.

Denetimsiz öğrenme ile;

- ✓ Verinin sınıfları keşfedilir,
- ✓ Verilerde dikkat çekici yönler keşfedilir,
- ✓ Yeni sonuçlar keşfedilir.

Şekil 3.3 denetimsiz öğrenmenin çalışma yapısını göstermektedir.



Şekil 3.3. Denetimsiz öğrenme (researchgate.net, 2021)

Denetimsiz öğrenme, denetimli öğrenme algoritmalarından daha karmaşık verileri işleme görevlerini gerçekleştirebilir ancak, denetimsiz öğrenme, denetimli öğrenme modelinden daha öngörülemez olabilir. Örneğin, denetimsiz bir öğrenme sistemi, kedileri köpeklerden nasıl ayıracağını kendi başına çözebilirken, sıra dışı türlerle başa çıkmak için öngörülemeyen ve istenmeyen kategoriler ekleyerek düzen yerine dağınıklık yaratabilir (Pratt, 2020).

3.2.2.1 Kümeleme

Kümeleme, denetimsiz öğrenme için önemli bir kavramdır. Genel olarak, sınıflandırma yapılmamış bir veri setinde bir yapı veya ilişki bulmakla ilgilidir. Denetimsiz öğrenme kümeleme algoritmaları, verileri işler ve işlenen verilerdeki doğal kümeleri (sınıfları) bulur (Johnson, 2021).

Kümeleme türleri:

Hiyerarşik kümeleme: Bir küme hiyerarşisi oluşturmamızı sağlayan algoritmadır. İlk olarak kendi kümelerine atanmış veriler ile başlar. Burada yer alan, iki yakın olan küme aynı kümede yer alacaktır. Bu algoritma, sadece bir küme kalana kadar sürer.

K means kümeleme: Oluşan her yinelemede en yüksek değeri bulmamızı sağlayan yinelemeli kümeleme algoritma türüdür. Bu türde, veri noktalarını k grup halinde kümelememiz gerekir. Daha büyük bir k, daha çok ayrıntıya sahip olan daha küçük grup demektir. Daha düşük bir k, daha az ayrıntı düzeyine sahip daha büyük grup demektir.

K-NN (k en yakın komşu): K-En Yakın Komşu (KNN) algoritması, en temel makine öğrenimi algoritmalarından biridir. İki nokta arasındaki mesafeyi hesaplama yöntemidir. Basitlik ve uygulama kolaylığı nedeniyle yaygın olarak kullanılan bir kümeleme türüdür. KNN, Öklid gibi çoklu teknikler kullanarak iki nokta arasındaki mesafeyi belirler (Jamil ve ark., 2021). Belirlenen mesafeler sıralanır. En küçük mesafedeki K adet sınıfa sahip veri noktası tespit edilir. Seçilmiş olan K adedi kadar sınıfa sahip veri noktası içinde çoğunluğa sahip olan bir sınıf belirlenir. Bu sınıf, bilinmeyen nokta için kestirim sonucudur.


3.2.3 Yarı denetimli öğrenme (semi-supervised learning)

Bazı veri setleri incelendiğinde denetimli öğrenme kullanmak isterken ilişkili etiket bulunamayabilir veya çok az etiket bulunabilir. Bu durumlarda yarı denetimli öğrenme kullanılabilir. Bu algoritmalar hem denetimli hem de denetimsiz algoritmaların özelliklerinin birleştirildiği öğrenme yönetimidir. Eğitim için hem etikete sahip hem de etiketi olmayan veriler kullanır. Genellikle az bulunan etiketli veri ile çok bulunan etiketlenmemiş veri kullanan sistemler, öğrenme doğruluk puanını önemli ölçüde artırabilir (turkhost.com, 2021).

3.2.4 Pekiştirmeli öğrenme

Pekiştirmeli öğrenmede öğrenen, bir ortamda eylemde bulunan ve ödül (veya ceza) alan bir karar verme aracıdır. Bir sorunu çözmeye çalışırken yaptığı eylemler için bir dizi deneme-yanılma çalışmasından sonra, en iyi politikayı öğrenir. Bu öğrenme türünde eğitim ve test aynı anda yapılır. Hedefe ulaşınca ödülle ulaşamazsa ceza puanı verilir (Alpaydin ve Bach, 2014).

Robot bu sisteme en iyi örnek verilebilir. Örneğin robota bir hedef verilir robot o hedefe ulaşırken çarptığı her yer ona ceza olarak yansır ve bu şekilde hedefe ulaşır. Bir dahaki denemede daha az çarpma yapar. Zamanla öğrenim artıkça artık robot çarpma yapmandan direk hedefe ulaşacaktır. Şekil 3.4 ile pekiştirmeli öğrenme gösterilmiştir.



Şekil 3.4. Pekiştirmeli öğrenme (turhost.com, 2021)

3.3 Makine Öğrenmesi Algoritmaları

3.3.1 Regresyon

Sınıflandırma algoritmalarında sonuç elimizdeki veri setine göre bir sınıf da yer almasıdır yani sonuç değerleri bellidir. Regresyon da ise sonuç değerleri belli değildir. Regresyon analizi, bağımsız değişkenlerden yararlanarak bağımlı değişkenleri tahmin etmeye yardımcı olan analiz yöntemidir. Makine öğrenmesinde yaygın kullanılır.

Tüm denetimli öğrenme yöntemlerinde olduğu gibi öğrenen etiketli bir örnek alır ve bu etiketler gerçek sayılardır. Regresyonda sonuçların benzersiz olduğu durumlarda doğru sonuç veya tam ortalama sonuç beklenmemelidir. Bunun yerine tahminlerin doğrulara yakın olması beklenmelidir. Regresyonda sınıflandırmadaki gibi kesin sonuçlar alınmaz. Regresyonda hata ölçüsü gerçek değerle bulunan değer arasındaki farkın büyüklüğüne dayanır. Ölçmek için kullanılan kayıp fonksiyonu hatanın büyüklüğü $L: Y \times Y \rightarrow R^+$ ile belirtilir. Burada Y, R 'nin ölçülebilir bir alt kümesidir (Mohri, 2018).

Regresyon ile yapılabilecekler;

Popülasyonların ve bireylerin ölçümlerine göre nasıl değiştiğini incelenebilir, ekonomi, sosyoloji, psikoloji, fizik ve ekoloji gibi çeşitli alanlarda bilimsel araştırmalar yapılabilir.

Bir olay ile yanıt arasındaki nedensel ilişkiyi ölçmek; klinik ilaç denemelerinde, mühendislik güvenlik testlerinde veya pazarlama araştırmalarında olduğu gibi.

Önceden bilinen ve gelecekteki davranışları tahmin etmek için kullanılacak kalıpları belirleme, sigorta taleplerinin tahmin edilmesi, doğal afet hasarları, seçim sonuçları ve suç oranları (Lantz, 2013).

3.3.2 Doğrusal regresyon

Doğrusal regresyon, Denklem 3.1 ile gösterilen bir çizgi kullanarak bağımsız bir değişken ile bir bağımlı değişkeni arasındaki ilişkiyi tanımlar. Bağımsız değişken yardımıyla bağımlı değişkeni tahmin etmek için kullanılır.

$$y = \beta_0 + \beta_1 x + e \quad (3.1)$$

y = Tahmin edilen bağımlı değişken,

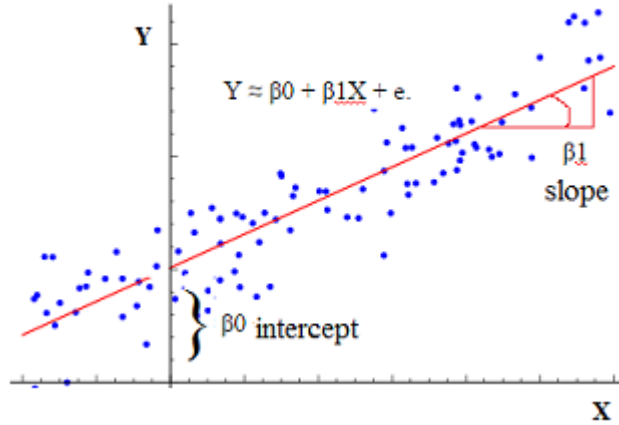
β_0 = Doğrunun y-eksenini kestiği yerdir, $x=0$ olduğunda regresyon doğrusunun dikey eksen y 'yi kestiği noktayı göstermektedir.

β_1 = Doğrunun eğimidir. Regresyon analizinde bağımsız değişken x 'deki bir birim değişimin bağımlı değişken y 'de ne kadarlık bir değişme yaptığını gösteren regresyon katsayısıdır. Burada β_1 'in işareti x ve y arası ilişki yönünü gösterir. Her iki değişken de aynı anda artıyor ya da azalıyor ise işaret pozitif olur. Biri artıyor diğeri azalıyor ise işaret negatif olur. Eğer β_1 0(sıfır) ise, bu durumda iki değişken arasında ilişki yoktur (Neyren, 1996).

x = Tahminde yardımcı olacak bağımsız değişken değeri,

e = hata değeridir.

Regresyon grafiđi Őekil 3.5’de gsterilmektedir.



Őekil 3.5. Doğrusal regresyon grafiđi (datacadamia.com, 2021)

Yukarıdaki Őekilde grleceđi zere tahmin edilen deđer, dođruya uzaklıđı arttıka tahmin baŐarısı dŐer. Dođruya yaklaŐtıka tahmin baŐarısı artar.

Dođrusal regresyon ile yapılabilecek tahminler;

- ✓ rnn satıŐ fiyatının tahmini,
- ✓ Finansal tahminler,
- ✓ Hava durumu tahmini,
- ✓ lke nfus tahmini.

Regresyonun baŐarısı R^2 katsayısı ile gsterilir. Bu dođruluk skoru olarak da anılabilir. R^2 bađımsız deđiŐken x 'in tahmin edilecek bađımlık deđiŐken y 'yi yzdesel olarak aıkladıđı lttr. R^2 0 ile 1 arasında bir deđer alır. 1'e yaklaŐması baŐarının yksek olduđunu, 0'a yaklaŐması baŐarının dŐk olduđunu gsterir (ztrk, 2020).

3.3.3 oklu dođrusal regresyon

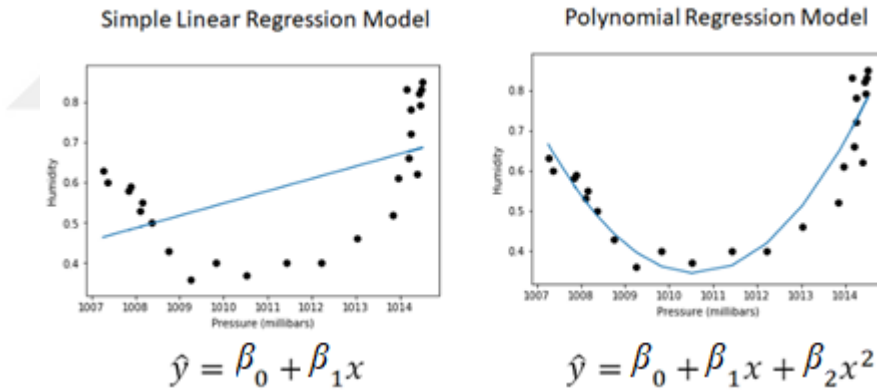
Regresyon ile tahmin edebilmek iin tek bir bađımsız deđiŐken yeterli olmayabilir. Birden fazla bađımsız deđiŐken olduđu durumlarda da oklu regresyon ile bađımlı deđiŐken tahmin edilebilir. rneđin bir rnn satıŐ fiyatını belirleyen tek bir zellik bulunmayabilir. Diđer zelliklerini de katarak satıŐ fiyatı belirlenebilir.

Çoklu doğrusal regresyon formülünün farkı, burada her bir bağımsız değişkenin değeri toplama dahil edilmektedir. Burada birden fazla x mevcut olduğundan x'e sayılar verilmiştir. Her bir x farklı bağımsız değişkeni göstermektedir. Tek bağımsız değişkenli regresyondaki varsayımlar bu regresyonda da geçerlidir. Denklem 3.2 ile çoklu doğrusal regresyon formülü gösterilmiştir.

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_ix_i + e \quad (3.2)$$


3.3.4 Doğrusal olmayan regresyon (polinomsal regresyon)

Değişkenler arası ilişki her zaman doğrusal olmayabilir. Burada doğru yerine bir eğri söz konusudur. Polinomsal regresyon bu eğrinin fonksiyonunu verir. Polinomsal regresyon da önemli olan polinom fonksiyonun derecesidir. Derece değiştikçe doğruluk oranı da değişmektedir (Şener, 2020). Şekil 3.6 ile doğrusal regresyon ile doğrusal olmayan regresyon arasındaki grafik farkı gösterilmiştir.



Şekil 3.6. Doğrusal olmayan regresyon (ichi.pro, 2021)

Şekil 3.6 ile örnek bir veri grafiği incelendiğinde formül olarak doğrusal regresyondan farkı derece eklenmesidir. Formüle eklenen bu derece ile değişken değerlerinin çizgiye yaklaşması sağlanmakta ve bu şekilde başarı şansı artırılmaktadır. Şekil 3.6'daki formülde derece artırıldığında ise Şekil 3.7'deki grafik elde edilmektedir.



Şekil 3.7. Ezberlenmiş polinom eğrisi (ichi.pro, 2021)

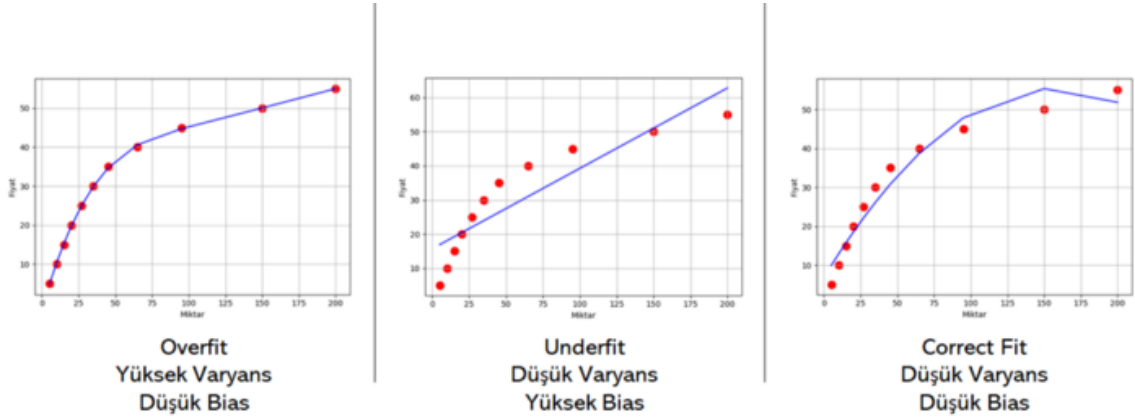
Şekil 3.7 incelendiğinde grafiğin değişkenlere göre tam uyum içinde olduğu görülmektedir. Bu durumda başarı çok yüksek çıkar ama aynı zamanda modelin ezberlendiği anlamına gelir ki buda istenmeyen bir durumdur. Her derecenin artırılması modelin kesin başarılı olacağını göstermemektedir. Burada dengedeki bir dereceyi seçmek önemlidir.

Polinomun derecesi arttıkça, veri kümesindeki küçük değişiklikler, uygun polinomlarda daha büyük bir değişikliğe neden olur; böylece varyans artar. Ancak ortalamada karmaşık bir model, temel işleve daha iyi uymayı sağlar; böylece bias azalır. Buna bias/varyans ikilemi denir ve yalnızca polinom regresyonu için değil, herhangi bir makine öğrenimi sistem bias/varyans ikilemi için de geçerlidir. Sapmayı azaltmak için model, yüksek varyansa sahip olma riski altında esnek olmalıdır. Varyans düşük tutulursa, verilere iyi uyum sağlayamayabilir ve yüksek bias'a sahip olabilir. Optimal model, bias ve varyans arasında en iyi dengeyi sağlayan modeldir (Alpaydın, 2014).

Bias, modeldeki verileri yerleştirmedeki tahminlerden ortaya çıkan hatayı temsil etmektedir. Yüksek bir bias, modelin tahmininin düşük olduğu anlamına gelir ve bu düşük öğrenmedir (underfitting).

Varyans, verileri yerleştirmeye çalışan karmaşık modelden kaynaklanan hatayı temsil eder. Yüksek varyans, model eğrisinin veri noktalarının çoğunluğundan geçtiği ve


çıkan sonucun aşırı öğrenmeye (overfitting) neden olduğu anlamına gelir (Şener, 2020). Şekil 3.8’de Varyans ve Bias grafikleri gösterilmiştir.



Şekil 3.8. Varyans ve Bias (Şener, 2020)

3.3.5 LASSO regresyon

Standart çoklu regresyonda bağımsız değişkenlerin bağımlı değişken üzerinde etkisinin anlamlı olup olmadığına bakılır. Oluşturulan modelde bir bağımsız değişken anlamsız bile çıksa, modelde yine yer alır. Anlamsız değişkenin anlamı, ilgili değişkenin beta katsayısının sıfıra eşit olmasıdır. Bu katsayı sıfıra eşit olduğunda modele dahil edilmez. Standart regresyonda değişken anlamsız bile olsa modelden çıkarılmadığı için 1996’da Robert Tibshirani tarafından Lasso geliştirilmiştir (Tibshirani, 1996). Lasso (Least Absolute Shrinkage and Selection Operator) regresyon analizi, anlamsız olan değişkenleri modelden çıkarma yeteneğine sahiptir. Yani ortaya çıkan modelde doğruluk skorunu arttırmak için hem değişken seçimi hem de regülasyon yapar (Fonti, 2017). Şekil 3.9 da λ değerlerinin değişimi gösterilmiştir.



Şekil 3.9. Lasso λ değerleri değişimi (Muratlar, 2021)

Beta katsayısının mutlak değeri λ ile çarpılır. Şekil 9'da λ değerine göre değişen doğrunun eğimi gösterilmiştir. λ büyük oldukça katsayıları sıfır yapar. Bu şekilde değişken seçimi yapılmış olur. λ çok düşük bir değer seçildiğinde veya sıfır yapıldığında standart çoklu regresyona dönmüş olur (Fonti, 2017).

Örneğin dört bağımsız değişkenli bir veri seti olduğunda standart regresyon formülü Denklem 3.3'deki gibi olur.

$$y = \beta_0 + \beta_1 * x_1 + \beta_2 * x_2 + \beta_3 * x_3 + \beta_4 * x_4 \quad (3.3)$$

Formüle λ katsayısını eklendiğinde,

$$\lambda * (|\beta_1| + |\beta_2| + |\beta_3| + |\beta_4|) \quad (3.4)$$


λ değerini artırdıkça bazı beta parametreleri biraz azalacak, alakasız parametreler ise sıfır olacaktır. Bu şekilde anlamsız değişkenler modelden çıkarılmış olur. Formülün son hali Denklem 3.5'deki gibi olabilir (Muratlar, 2021).

$$y = \beta_0 + \beta_1 * x_1 + \beta_2 * x_2 + 0 * x_3 + 0 * x_4 \quad (3.5)$$

Lasso'nun bu şekilde değişken seçimi yapabilmesi yüksek boyutlu verilerde kullanım açısından büyük bir avantaj sağlar.

3.3.6 Karar ağaçları

Karar ağacı, dal ve yaprak gibi bölümler bulunduğu için ağaç tipine benzemektedir. Bir karar ağacında karar düğümleri ve yaprak düğümleri bulunmaktadır. Karar düğümleri, veri setinde karar vermek, sınıflandırma veya tahmin yapmak için kullanılmaktadır. Bu düğümler iki ya da daha fazla dalla ayrılabilir. Yaprak düğümleri ise kararları tutmaktadırlar. Ağacın en tepesindeki düğüm kök düğümüdür. Bir karar veya sonuca ulaşmak için kökünden yaprak düğümlere kadar yol izlenmelidir. Şekil 3.10 ile karar ağacının yapısı gösterilmiştir.



Şekil 3.10. Basit bir karar ağacı yapısı (Kavzaoğlu, 2010)

Karar ağacı oluştururken kullanılacak aşamalar şu şekildedir (Özcan, 2015).

- Ağaç kök düğümünden aşağı doğru yinelemeli şekilde parçala ve çöz metodu ile oluşturulmalıdır.
- İlk durumda eğitim veri setindeki bütün örnekler bir kökte yer alır. Yani ağaç eğitim verisinin oluştuğu tek bir düğümle başlar.
- Tahmin edici özellikler ve hedef özellik kategoriktir. Sürekli özellikler ayrıştırılarak analizlere dahil edilir.
- Örneklerin tümü aynı sınıfa ait olduğunda düğüm, yaprak görevini alır ve sonlanır.
- Eğer örneklerin tümü aynı sınıfa ait değilse, örnekleri sınıfa en iyi şekilde ayıracak özellik seçilir.
- Özellikler, sezgiseller ya da istatistiksel ölçütler temelinde seçilir.
- Yeni gelen örneğin sınıfı çıkarılan ağaç kuralları ölçüsünde hesaplanır.

Bir veri seti ile birden fazla çeşitli ağaçlar oluşturulabilir.

Karar ağaçlarında, ID3, C4.5 gibi algoritmalar kullanarak karar ağacını en az hata ile oluşturmak hedeflenebilir (Rokach ve Maimon, 2005).

ID3 Karar ağacı algoritması

En basit algoritma çeşididir. Sadece kategorik özellikler ile çalışmaktadır. Karar ağacı oluşturulurken her aşamada tüm özelliklere ait bilgi kazancı hesaplanmaktadır. Bilgi kazancı hesaplaması yapılırken entropiden faydalanılır.

Entropi: Bir veri setinin düzensizliğinin, safsızlığının ve belirsizliğinin ölçüsü ve matematiksel ifadesidir (Shannon, 1948). Denklem 3.6'da Entropinin formülü gösterilmiştir.

$$Entropi = - \sum_{i=1}^k P (deger_i * \log_2(P(deger_i))) \quad (3.6)$$

Formüldeki P değeri yakalanma ihtimali olan veya veri setindeki rasgele seçilen bir değerdir.

Örneğin bir grupta 15'si siyah ve 8'i beyaz olmak üzere 23 bilye var. Bu grubun entropisi aşağıdaki şekilde bulunur.

$$Entropi (Siyah) = \log_2 \left(\frac{15}{23} \right) = -0.62148837674627$$

$$Entropi (Beyaz) = \log_2 \left(\frac{8}{23} \right) = -1.5145731728298$$

$$Entropi Toplam = -(15/23)*(-0,62148837674627) - (8/23)*(-1,5145731728298) = \mathbf{0,93}$$

Bilgi kazancı: Veri setindeki bir özelliğin sınıf hakkında bize verdiği bilginin ölçüsüdür. Bilgi kazancı (A) = Entropi (X) – Entropi a(X) formülü ile bulunur. Bu formülle A özelliğini kullanarak karar ağacı yapıldığında ne kadarlık bilgi kazancının elde edileceği bulunabilir. Yüksek bilgi kazancı veren özellik, dal ayrımının yapılacağı özellik olarak belirlenmektedir (Balaban ve Kartal, 2015).

C4.5 Karar Ağacı Algoritması

Bu algoritmada bilgi kazancı varsayılan olarak kullanılan bölme kriteridir. Bilgi kazancına bölme bilgisi adı verilen bir çeşit normalizasyon uygulanmaktadır (Kartal, 2015). Denklem 3.7'de bölme bilgisi formülü verilmiştir.

$$BölmeBilgisi_A(D) = - \sum_{j=1}^V \frac{|D_j|}{|D|} * \log_2 \left(\frac{|D_j|}{|D|} \right) \quad (3.7)$$

Buradaki $BölmeBilgisi_A$, eğitim verisinin A niteliğinin aldığı v farklı değere bağlı olarak v parçaya ayrıldığında, oluşturulan potansiyel bilgiyi temsil etmektedir. En yüksek kazanç oranını sağlayan özellik ayırımın yapılacağı özellik olarak seçilmektedir (Kartal, 2015).

$$\text{Kazanç oranı (A)} = \text{Bilgi Kazancı (A)} / \text{Bölme Bilgisi (A)}$$

Bu algoritmada sayısal değer alan özellikler ile çalışılabilmektedir. Bir eşik değer seçilmesi ve bu değere göre özelliğin aldığı değerlerin ayrıklaştırılması şeklinde yapılabilir veya kümeleme gibi diğer ayırma çeşitlerinden yararlanılarak farklı sayıda bölüme elde edilerek çoklu ayrıklaştırma yapılabilir (Kartal, 2015).

3.3.6.1 Karar ağaçları regresyon

Karar ağaçları regresyon, doğrusal regresyon yöntemlerini kullanmaz; bunun yerine bir yaprağa ulaşan örneklerin ortalama değerine göre tahminde bulunur. Tahmin için ikinci tür ağaç, model ağaçlar olarak bilinir. Karar ağaçları regresyonda da, ağaçlar aynı şekilde oluşturulur, ancak her yaprakta, o düğüme ulaşan örneklerden çoklu doğrusal bir regresyon modeli oluşturulur. Yaprak düğümlerinin sayısına bağlı olarak, bir model ağacı, bu türden onlarca, hatta yüzlerce model oluşturabilir. Bu, model ağaçlarının anlaşılmasını eşdeğer regresyon ağacından daha zor hale getirebilir ve daha doğru bir modelle sonuçlanabilmeleri yararına olabilir (Lantz, 2013).

Standart regresyon yöntemlerine göre regresyon ağaçlarının avantaj ve dezavantajları Çizelge 3.1'de listelenmiştir (Lantz, 2013).

Çizelge 3.1. Karar ağaçlarının avantaj ve dezavantajları

Avantaj	Dezavantaj
Karar ağaçlarının güçlü yanlarını sayısal verileri modelleme yeteneğiyle birleştirir.	Doğrusal regresyon kadar yaygın olarak kullanılmaz.
Yaklaşımın çok sayıda özellik ile kullanılmasına izin veren otomatik özellik seçimi yapar.	Büyük miktarda eğitim verisi gerektirir.
Kullanıcının, modeli önceden belirlemesini gerektirmez.	Sonuç üzerindeki bireysel özelliklerin genel net etkisini belirlemek zordur.
Bazı veri çeşitlerine doğrusal regresyona göre çok daha iyi uyum sağlayabilir.	Bir regresyon modelinden daha zor yorumlanabilir.
Modeli yorumlamak için istatistik bilgisi gerektirmez.	

Bilinen regresyon yöntemleri tipik olarak sayısal tahmin görevleri için ilk tercih olsa da, bazı durumlarda karar ağaçları regresyon belirgin avantajlar sunar. Örneğin; karar ağaçları, birçok özelliğe sahip görevler, özellikler ve sonuç arasında birçok karmaşık, doğrusal olmayan ilişkiler için daha uygun olabilir.

4.PARA PİYASALARI

4.1 Altın

Altının keşfedilmesi M.Ö. 5000 yıllara dayanmaktadır. O yıllarda ilk kez mısırlılar, bakır ile alaşıma giren altını topraktan çıkarmışlardır. Mısır'ın madencilik tarihine ait ulaşılan belgelerde de altın madenlerinin krokileri bulunmuştur. Yine o yıllarda Anadolu'da altın süs eşyaları keşfedilmiştir. M.Ö. 3000 yıllarında yine Mısırlılar altının diğer metallerle alaşıma girmesi konusunda başarı sağlamışlardır (Sağlam, 1993). Para olarak kullanılması M.Ö 1091 yılında Çin'de yasal hale gelmiştir. M.S. yıllara gelindiğinde 1100 yılında Venedik önemli ticaret yollarından olması sebebiyle o yılların altın pazarı olmuştur. Dünyada altın madenciliğinin yayılmasıyla ilerleyen zamanlarda Romalılar altın üretiminde ilk sırada yer almışlardır. Romalılardan sonra Bizanslılara geçmiş ve Bizanslılar devrildikten sonra Osmanlı Devleti'nin üç kıtaya hâkim olmasıyla, Osmanlılar önemli bir altın üreticisi konumuna gelmiştir (Pekcan, 1998). 1870 yıllara kadar altın para olarak kullanılmaya devam etmiştir. 20.yy'a gelindiğinde Bretton Woods Sistemi'nde dolara karşın koruma aracı olarak kullanılmıştır (Güvenç, 2006). Günümüzde de devletlerin rezerv ve insanlarda takı, süs eşyası, yatırım aracı gibi çeşitli alanlarda kullanılmaya devam etmektedir.

Altın, çok yoğun parlak sarı renkte, bozulmayan yapısıyla metalik bir elementtir. Maden olarak doğada alüvyon olan yataklarda, kumla karışarak parçacıklar veya kayalar içinde damarlar halinde bulunur. Kolay kolay zarar görmez, rengi matlaşmaz, paslanma yapmaz. İyi bir iletkenlik özelliğine sahiptir. Erime sıcaklığı 1064 °C, kaynama sıcaklığı 2970 °C'dir (Hoppe, 1972).

Saf halinde iken çok yumuşaktır, kolayca şekillendirme yapılabilir. Altın, tel yapımına en uygun (bir gr altın ile bir km tel yapılabilir), en kolay dövülen metal çeşididir. 0,1 um kalınlığına sahip yaprak altınlar oluşturabilir. (10000 um = 1mm)(MTA). Bu özelliği ile kolay işlenebilmesi, kuyumculuk alanında en çok altının kullanılmasını sağlamaktadır (Aslan, 1999).

Altın diğer metallerle alaşım ile kullanılabilir. Altın ve diğer alaşım oranı altının saflığını belirtmektedir. Bu oran ayar olarak söylenmektedir. En yüksek ayarlı altın

(%100 saf altın) 24 ayardır. 22 ayarda altın saflık oranı %91,66'dır. 14 ayarda ise %58,3 dür. Ayar düştükçe altının değeri de o kadar düşmektedir (Çıtak, 2004).

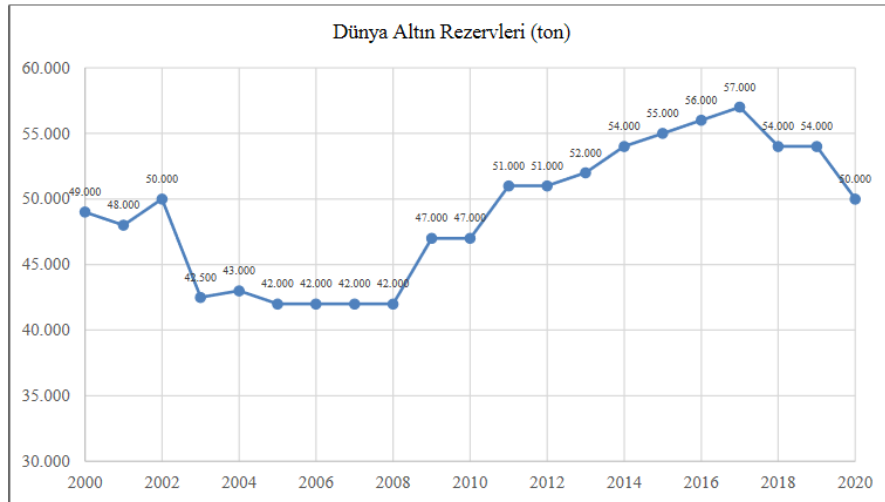
Altın, kullanılan alanlar yönünden, gelişmiş ülkeler ile gelişmekte olan ülkeler arasında önemli farklar vardır. Gelişmiş ülkelerde mücevherat alanı haricinde elektronik ve diğer sektörlerde, altın para basımında, diş yapımı gibi alanlarda altın kullanımı önemli bir yer tutmaktadır. Gelişmekte olan ülkelerde ise mücevherat alanı dışında kullanımı çok düşük seviyededir (Sağlam, 1993).

2021 yılı itibariyle, dünyanın en çok altın üreten ülkelerinin başında dünya üretiminin %11'ni oluşturan Çin ve onu sırayla; Rusya, Avusturalya, ABD, Kanada, Gana ve Brezilya takip etmektedir (gold.org, 2021).

4.1.1 Altının para piyasalarındaki yeri

Altın önemli bir yatırım aracıdır. Özellikle kriz olan zamanlarda çok rağbet gören bir yatırım aracı olarak tercih edilir. Bunun nedeni, insanların altını sağlam ve güvenli bir liman olarak görmesidir. Altın ekonomide enflasyona karşı korunmak için de kullanılmaktadır. Bu sebeplerden ötürü altın dünyadaki merkez bankaları tarafından rezerv olarak saklanmaktadır.

2000-2008 yılları arasındaki dünyadaki altın rezervleri 40.000-42.000 ton iken 2011 yılından günümüze yaklaşık 50.000 tonun üzerine çıkmıştır (Şekil 4.1).













(USGS 2010-2020)

Şekil 4.1. Dünyadaki altın rezerv durumu (USGS, 2020)

Şekil 4.2 incelendiğinde 2021 yılı itibariyle ülkelerin altın rezerv durumları incelendiğinde en büyük pay ABD ye aittir. Almanya, İtalya, Fransa, Rusya ve Çin sıralamadaki diğer ülkelerdir. Türkiye ise 394 ton rezerv ile 15. ülkedir (gold.org, 2021).

Central Banks Ranked By Largest Gold Holdings

		Tonnes	Percent of Total Reserves
	United States	8,134	79
	Germany	3,364	76
	Italy	2,452	71
	France	2,436	66
	Russia	2,300	23
	China	1,948	3
	Switzerland	1,040	7
	Japan	765	3
	India	658	8
	Netherlands	613	71

Şekil 4.2. Ülkelerin rezerv durumu (gold.org, 2021)

Rezervdeki altının, döviz bazlı herhangi bir yatırım aracının aksine, hiçbir ülkenin yükümlülüğünde yer almaması nedeniyle ülkelerin politikalarından doğrudan etkilenmemesi ve altının evrensel olarak başvurulacak son kaynak kabul edilmesi de merkez bankaları açısından altını önemli kılmaktadır. Dövizde ve borsada meydana gelebilecek olumsuzluklara rağmen altının kendini koruyabilmesi ve gerektiğinde piyasada nakde çevrilebilir olması, merkez bankalarının altın tutmalarının en önemli nedeni sayılmaktadır (Ferhani, 2003).

Dünya altın borsalarında çoğunlukla altının geçerli olduğu birim ONS/USD'dir. bir ons 31,103 gram saf altına karşılık gelir. Kasım 2022 tarihi itibariyle bir ons altın ortalama 1629\$'dir (LBMA, 2022). Türkiye'de her ne kadar 24 ayar, 22 ayar, gram altın, çeyrek altın gibi birimler olsa da bu birimler ons/\$ üzerinden dönüştürülmektedir. Kasım 2022 de ortalama 1\$=18,60₺ dir (investing.com, 2022). Bir ons altın 30.299₺ ve saf altının gramı 974₺'ye karşılık gelmektedir. Bu saf altının değeri saflığı (Türkiye'deki tabirle ayar) düştükçe düşmektedir. 22 ayar altının saflığı 0.916'dır. Bir gram 22 ayar altın 892₺'dir. Kuyumculuk sektöründeki fiyatlanmalar bu dönüştürmeler üzerinden oluşturulmaktadır. Şekil 4.3 ile son 5 yılın altın ons fiyatının grafiği gösterilmiştir.



Şekil 4.3. 2018-2022 Onsd/Usd grafiği (tradingview.com, 2022)

Dünya altın borsalarında iki tür altın piyasası mevcuttur. Spot (fiziki) altın piyasası, külçe altın, altın para, gram altın gibi fiziki altınların pazar araçları arasında fiziki sirkülasyonun olduğu piyasadır. Diğer tür ise fiziki altından ziyade ona sahip olma imkânı veren kontratlarda işlemlerin yapıldığı vadeli işlemler piyasasıdır (O'Callaghan, 1993).

4.1.2 Spot (fiziki) piyasa

Bu piyasa türünde altının külçe formu temel alınmaktadır. Bunun sebebi altın rafine edildikten sonra ilk yapılan işlem, külçe formuna çevrilmesidir. Borsaların kabul ettiği ölçütler (ağırlık ve saflık dereceleri) farklılık gösterebilir.

Dünyadaki altın piyasalarına bakıldığında, Londra, New York, Zürih, Paris ve Singapur önce çıkmaktadır. Ama Londra borsasının örgütlü bir yapısının olması, hareketli bir ticari alanının olması, yüksek hacimli işlem yapan büyük firmaların bu borsada yer alması dünya altın borsaları fiyatlarının Londra borsasından alınmasını sağlar (LBMA, 2022).

Spot piyasanın önemi, altın arzı yapanlar ile altın talep eden yatırımcılar arasında köprü vazifesi görmesidir. Çünkü fiziki altının dolaştığı yer bu piyasadır.

4.1.3 Vadeli işlem piyasası


Değeri ileri bir zamanda ödenmek suretiyle yapılan alışverişe vadeli işlem ve bu işlemlerin yapıldığı piyasa çeşidine vadeli piyasa denir. Bu piyasa da işlem yapanlar düzenledikleri sözleşmelerle, belirlenen miktardaki mal ve mal karşılığı tutarı ileri bir zamanda karşılıklı olarak takas etmeyi hedeflerler. Buradaki mal çeşidi; altın, gümüş, euro, petrol, arpa, pamuk vs. olabilir. Dünyada 15.yy'dan itibaren vadeli işlemler uygulanmaya başlamıştır (Sağlam, 1993).

Vadeli altın sözleşmeleri ilk 1974 yılında New York Commodity Exchange (COMEX), Chicago Board Of Trade (CBOT) ve Chicago Mercantile Exchange (CME) tarafından gerçekleştirilmiştir.

Vadeli altın işlemlerinde yer alan katılımcılar, işlemleri farklı hedefler için kullanabilirler. Örnek verilecek olursa, maden üretimi yapan şirketler bu piyasada daha üretmedikleri ama ileri zamanda planladıkları altını satarak, ileriki günlerde olabilecek fiyat düşüşüne karşı şirketi korumaya alabilirler.

4.2 Dolar

İspanyolların Amerika kıtası keşfi sonrası, İngilizlerinde Amerika keşfi hevesi doların doğuşuna sebep olmuştur. 15.yy. sonlarında Amerika'da koloni kuran İngilizler, İspanyollar ile ticari anlaşma yapmak için doları basmaya başladılar. 1690 yılı doların doğuş yılı olarak kabul edilebilir. Aynı zamanda askeri giderleri karşılamak için de bu parayı kullanmak istemişlerdir. 1739 yılında Benjamin Franklin, Philadelphia'daki matbaada benzersiz kabartmalı desenler olan doğa baskılarıyla kalpazanlığa karşı koruma sağlamıştır. Bu durum, banknotlarda yenilikçi, etkili ve sahtecilikte caydırıcı etkisi olmuştur. İlerleyen yıllarda da ABD'nin resmi parası olmuştur ve darphanelerde basılmaya başlanmıştır. 1785 yılında ise dolar işareti İspanyol pezosundan esinlenerek kabul edilmiştir (uscurrency.gov, 2021). Şekil 4.4 ile dolar işaretinin değişimi gösterilmiştir.



Şekil 4.4. Dolar işaretinin evrimi (uscurrency.gov, 2021)

1944 yılında, İkinci Dünya Savaşı sürerken, ABD’de Bretton Woods kasabasında 45 ülkenin katılımıyla bir konferans yapılmıştır. Bu konferansta, küresel yönetim mekanizmaları düzenlenerek sistemin iki temel ayağı olan IMF ile Dünya Bankası’nın görevleri ve operasyonel alanları tanımlanmıştır. Bu konferansta imzalanan Bretton Woods Anlaşmasıyla beraber yeni parasal sistemi ikinci dünya savaşı öncesine göre daha kararlı bir yapı haline gelmiştir (Pauly, 1993). Yapılan bu anlaşma ile merkezi ABD doları olan sabit kur sistemi kurulmuş ve IMF bu sistemin merkezi yapılmıştır. 1945-71 yıllarında IMF üyeleri ülkeler, resmi döviz kurlarını (para birimlerinin ABD doları cinsinden değeri ve ABD örneğinde doların altın cinsinden değeri) sabit tutmayı kabul edip IMF’den onay alınmadan kur oranlarının değişmeyeceğinin garantisini vermişlerdir (IMF, 2021).

Bretton Woods Anlaşması, ABD ekonomisinin gücüne güç katmış ve bu sistem içinde söz sahibi ülke konumuna getirmiştir. Bu sayede sağlanan ekonomik istikrar ve büyüme, ekonomide olumlu yansımalara başlamıştır. ABD doları, ilk olarak 1944 Bretton Woods Anlaşması’nda dünyanın para birimi olarak kurulmuş olup ve daha sonra dünyanın en baskın para birimi haline gelmiştir (corporatefinanceinstitute.com, 2022). Dolar başlangıçta, ağırlığına göre altın veya gümüş olarak değerlendirilen bir madeni para olarak işlem görmüş ve daha sonra altın olarak kullanılabilen bir kâğıt banknot olarak işlem görmüştür. 1970’lerde altın standardı kaldırılmış ve USD değerinin dalgalanmasına izin verilmiştir (Erek, 2009).

4.2.1 Dolar endeksi (DXY)

DXY, 1973 yılında ABD Federal Rezervi tarafından, ABD dolarının küresel para birimlerine karşı karşılıklı dış ticaret ağırlıklı bir ortalama değer hesaplamak ve doların diğer ülkelerin para birimlerine karşı değerini ölçebilmek veya karşılaştırmaları yapmak sebebiyle geliştirilmiştir. DXY, ABD dolarının başlıca para birimleri karşısındaki değerini gösteren bir göstergedir. Dolar diğer para birimlerine karşı güç (değer) kazandıkça DXY endeksi yukarı çıkar (Ercan, 2018).

Serbest kur sistemine geçilmesiyle birlikte doların ve döviz kurlarının genel durumunu belirlemek amacıyla oluşturulan endeks, 6 gelişmiş ülkenin döviz kurunun geometrik ortalamasının oluşturduğu kritik bir endekstir (Erek, 2009).

Bu 6 döviz kuru;

- Euro (EUR) %57,6 ağırlık,
- Japon Yeni (JPY) %13,6 ağırlık,
- İngiliz Sterlini (GBP) %11,9 ağırlık,
- Kanada Doları (CAD) %9,1 ağırlık,
- İsveç Kronu (SEK) %4,2 ağırlık,
- İsviçre Frangı (CHF) %3,6 ağırlık,

Endeks, karşılaştırılabilir sepete dahil edilen dolar ve yabancı para birimlerindeki enflasyon/deflasyon gibi makroekonomik faktörlerin yanı sıra bu ülkelerdeki durgunluk ve ekonomik büyümeden etkilenir (Chen, 2022). Şekil 4.5 son beş yılın DXY grafiğini göstermektedir.



Şekil 4.5. 2017-2022 DXY grafiği (tradingview.com, 2022)

Şekil 4.5'deki Son beş yılın DXY grafiği incelendiğinde en yüksek seviyeyi 10 Ekim 2022'de 113,298 ile yakaladığı görülmektedir. Eylül 2022'deki 75 puanlık faiz artışı doların güçlenmesini sağlamıştır (federalreserve.gov, 2022). Bu da DXY'nin zirve yapmasını sağlamıştır. Bu yıllardaki en düşük seviye ise 22 Ocak 2018'deki 89 endeks puanıdır. Bu tarihte ABD'de bütçe krizi yaşanmış, hükümetin kısmi kapanmasından dolayı dolar uluslararası düzeyde değer kaybetmiştir (bloomberght.com, 2018).

120'lik bir endeks değeri, ilgili zamanda ABD dolarının sepet karşısında %20 değer kazandığını ifade etmektedir. Endeks eğer 80 ise ve başlangıç değerinden 20 düşüyorsa, bu %20 değer kaybettiği anlamına gelmektedir.

4.3 Nasdaq Borsası

National Association of Securities Dealers Automatic Quotation'ın kısaltması olan Nasdaq, 1971 yılında kurulmuştur. Ticaret hacmi bakımından dünyanın en büyük elektronik ve ilk borsasıdır (Hautsch, 2011). Nasdaq borsası, bilgisayar donanımı ve yazılımı, telekomünikasyon, perakende/toptan ticaret ve biyoteknoloji alanındaki firmalardan oluşmaktadır (nasdaq.com, 2022).

Borsada Apple, Microsoft, Google ve Amazon gibi dünyanın en büyük teknoloji firmalarından bazıları dahil olmak üzere 3.700'den fazla şirket listelenmiştir. Aynı zamanda Türkiye'den Hepsiburada firması 2021 yılında bu borsada listelenme başarısı göstermiştir (nasdaq.com, 2021).

Nasdaq bileşik endeksi (genellikle sadece 'Nasdaq' olarak bilinir) en yaygın kullanılan endekslerden biridir. Nasdaq borsasında işlem gören hisse senetlerinin performansını takip eder. Piyasanın bir bütün olarak nasıl performans gösterdiğini temsil etmek için piyasa katılımcıları tarafından izlenen en popüler hisse senedi endekslerinden biridir.

Borsada kote olabilmek için bir hisse senedinin münhasıran Nasdaq borsasında işlem görmesi ve ABD merkezli bir şirketin adi hisse senedi olması veya yabancı bir şirketin ADR'si (Amerikan emanet makbuzu) olması gerekir. Adi hisse senetleri, komandit hisse senetleri ve takip hisse senetleri de endekse dahil edilebilir.

Nasdaq, teknoloji ağırlıklı bir endeks olarak bilinir. Temmuz 2021 itibariyle teknoloji firmaları endeksin yarısını oluşturmaktadır. Nasdaq Composite, piyasa değeri ağırlıklı bir endekstir. Bu, dahil edilen her şirketin toplam piyasa değerine göre ağırlıklandırıldığı anlamına gelir. Bu nedenle, daha büyük piyasa kapitalizasyonlarına sahip şirketler, daha küçük m-caps'lere sahip firmalara göre endeksin performansı üzerinde nispeten daha önemli bir etkiye sahiptir.

New York Menkul Kıymetler Borsası olan NYSE, borsada işlem gören hisse senetlerinin toplam piyasa değerine göre dünyanın en büyük borsasıdır. Nasdaq ile temel ayrımı, Nasdaq'ın bir bayi pazarı olması ve katılımcıların doğrudan birbirleriyle değil bir bayi aracılığıyla işlem yapmasıdır. Bu bayiler, müşteriler ve diğer bayiler ile yaptıkları işlemlerde hesaplarından alıp satmak için stok stokları bulundurlar. Öte yandan NYSE, yatırımcıların belirlenmiş piyasa yapımcılar aracılığıyla birbirleriyle işlem yapmalarını sağlayan bir açık artırma piyasasıdır (business-standart.com, 2020).

Her iki kurum da New York'ta yerleşik olsa da Nasdaq ve NYSE'de alım satım işlemlerinin yeri farklıdır. NYSE, fiziksel bir ticaret zeminini elinde tutar ve ayrıca New Jersey'den elektronik olarak ticaret yapar. Öte yandan, Nasdaq'ın fiziksel bir ticaret tabanı yoktur. Nasdaq teknoloji ağırlıklı bir endeks iken, 1792'de kurulan NYSE, Walmart ve Coca-Cola dahil olmak üzere birçok mavi çip firmasına ev sahipliği yapıyor. Mavi çip, Bir sektördeki köklü firmalara verilen addır (nesrakonk.ru, 2021).

4.3.1 Nasdaq 100 endeksi (NDX)


1985 yılında oluşturulan Nasdaq 100, piyasa değerlerine göre daha geniş Nasdaq borsasında işlem gören dünyanın en büyük 100 finansal olmayan (bankalar gibi) şirketleri içeren bir endekstir. Bu endeks Nasdaq'da işlem gören en büyük 100 hisse senedinden (piyasa değerine göre) oluşur. NDX Endeksi, bilgisayar yazılımından perakende veya biyoteknolojiye kadar büyük endüstri gruplarındaki her türlü şirketi temsil eder. Ancak, NDX şirketleri finansal ticaret veya yatırım firmalarını içermez (capital.com, 2017).

Çizelge 4.1 incelendiğinde en değerli şirketler olarak Amazon, Google gibi büyük firmaların liste başı olduğu görülmektedir.

Çizelge 4.1. NDX, En değerli 10 hisse (investing.com,2022)

Sıra	Şirket	Sembol	Değeri
1	Amazon.com	AMZN	2.912,82
2	Alphabet C(Google)	GOOG	2.642,44
3	Alphabet A (Google)	GOOGL	2.638,13
4	Booking	BKNG	1.985,04
5	MercadoLibre	MELI	1.055,78
6	Tesla	TSLA	838,29
7	O'Reilly Automotive	ORLY	674,09
8	Regeneron Pharma	REGN	620,41
9	Broadcom	AVGO	595,99
10	ASML ADR	ASML	594,32

Şekil 4.6'daki NDX'in son beş yılın değerlerine bakıldığında en yüksek değeri 15 Kasım 2021'de 16.563 ile yakalamıştır. 2018'de de düşük değerlere sahip olmuştur.



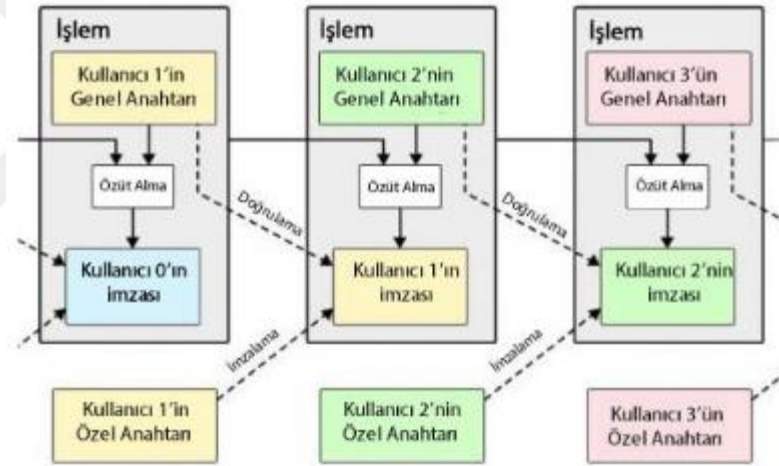
Şekil 4.6. 2018- 2022 NDX Grafiği (tradingview.com, 2022)

4.4 Kripto Para

Geleneksel paralara karşı alternatif olarak geliştirilmişlerdir. Kripto para dünyasının gelişmesi, parasal ve finansal sektörlerin büyüme sürecini hızlandırmıştır (Yamak, 2019). Kripto paralarda, diğer para çeşitleri gibi herhangi bir merkezi bağlılık bulunmamaktadır. İlk kripto para 2008 yılında blok-zincir teknolojisi ile ortaya atılmıştır.

4.4.1 Blok-Zincir

Blok-Zincir, geleneksel kayıt yöntemi olan defter-i kebir gibi yapılan işlemlerin tümünü kayıt altına alan bir blok dizisidir. Bu sistemde, yapılan işlemler blok adı verilen gruplara yazılmakta ve her bir bloktaki işlemler birbirlerine kronolojik olarak bir zincir gibi bağlanmaktadır (Şekil 4.7) (Crosby, 2016).



Şekil 4.7. Blok-Zincir şeması


4.4.2 Bitcoin

2008 yılında Satoshi Nakamoto tarafından blok-zincir teknolojisi ile oluşturulan ilk kripto paradır (Thakur ve Banik, 2018). Satoshi Nakamoto, 2008 yılında yayınladığı "Bitcoin: Eşler arası Elektronik Nakit Sistemi (Bitcoin: A Peer-to-Peer Electronic Cash System)" adlı makalesinde ortaya atmıştır. 2008 yılında ortaya çıkan Bitcoin ilk defa 2009 yılında ödeme için kullanılmıştır.

Satoshi Nakamoto, oluşturulan blok-zincir sisteminde Bitcoin üretiminin 21 milyon miktarla sınırlı olduğunu ve üretimin belirli bir tarihte duracağını belirtmiştir. İlginçtir ki Satoshi Nakamoto, 23 Nisan 2011 tarihinde Bitcoin geliştiricilerinden Mike Hearn'e, artık bundan böyle Bitcoin ile ilgilenmediğini ve bu sistemin emin ellerde olduğunu söyleyerek ortadan kaybolmuştur (Nebil, 2018).


Bitcoin'in eşler arası ağına erişmek için, bir kişinin Bitcoin cüzdanına sahip olması gerekir. Cüzdan sayesinde kullanıcıyı internet üzerinden Bitcoin merkezi olmayan ağına bağlar. Bu merkezi olmayan ağ, kullanıcının bir tür pazar yerine erişimini sağlar. Bu pazar yeri, diğer tüm Bitcoin kullanıcılarından oluşur. Bu pazarda, kullanıcı, Bitcoin borsasından Bitcoin satın alabilir, diğer kullanıcılardan Bitcoin satın alabilir, diğer kullanıcılara Bitcoin satabilir ve hatta mal veya hizmetler için ödeme olarak Bitcoin kabul edilebilir. Ancak, bu faaliyetlerden herhangi birine katılmak için, kullanıcının yazılım tarafından oluşturulan bir genel anahtar ve bir özel anahtar kullanması gerekir. Bu anahtarlar, kullanıcının işlemlerini doğrulamak ve işlemleri blok zincire kaydetmek için kullanılır. Bu anahtarlar kullanılmadan bir Bitcoin işlemi gerçekleşmiş olarak kaydedilmeyecektir (Sanchez, 2017).

2020 ve 2021 yıllarında, Bitcoin fiyat artışı ile Bitcoin'e olan ilgi çığ gibi artmıştır. İnsanlar evlerini arabalarını satarak veya kredi çekerek Bitcoin almaya başlamışlardır. Dünya Ekonomik Forumu'nun Şubat 2021'de yaptığı çalışmaya göre, dünyada en çok kripto para kullanan ülkeler Şekil 4.8'deki gibidir. Burada ülkemizin ilk sıralarda olması ve Avrupa da birinci olması şaşırtıcı bir sonuçtur.



Şekil 4.8. Kripto Para Kullanan Ülkeler (weforum.org, 2022)

Ekim 2022'de Londra'daki Global Web Index (GWI) adlı şirketin dünya geneli yaptığı bir araştırmaya göre, 16-64 yaş arası internet kullanıcıları arasında kripto paraya yatırım yapan insanların en fazla Türkiye'de olduğu ortaya çıkmıştır (Kemp, 2022). Şekil 4.9'da bu araştırmanın sonucu gösterilmiştir.



Şekil 4.9. Dünya geneli kripto paraya sahip olan ülkeler (datareportal.com, 2022)

Türkiye'de talebin artması yerli borsalarında artmasına yol açmıştır. 2021 yılı Nisan ayında Thodex adlı Türk borsası kurucusu borsayı kapatarak yurt dışına çıkmıştır. Bu borsada alışveriş yapan binlerce yatırımcı mağdur olmuştur. Yine birkaç borsa, faaliyetlerine son vermiştir. Bu yaşanan olaylar kripto paralara olan güveni sarsmıştır.

4.4.2.1 Bitcoin özellikleri

- ✓ Bitcoin merkezi değildir. Herhangi bir devletin, kuruluşun kontrolünde değildir.
- ✓ Bitcoin işlemleri, geleneksel para birimlerindeki banka transferlerine kıyasla nispeten daha hızlıdır. Bitcoin işlemleri nominal veya bazen sıfır işlem ücreti ile yapılır. İşlemlerde isim gözükmeyen sadece genel anahtarlar gözüktür. Özel anahtar güvende olduğu sürece sahip olunan para güvendedir.

- ✓ Bitcoin hesaplarının işlem kolaylığı nedeniyle Bitcoin göndermek ve almak çok kolaydır. 7/24 para gönderilip bozdurma yapılabilir. Günümüzdeki gibi mesai saati sonrası kur farkı yaşanmaz.
- ✓ Çok küçük miktarlara kadar Bitcoin gönderilebilir. En düşük tutar 0.000001 BTC dir. Bu miktara 1 satoshi denilmektedir. (Nebil, 2018)
- ✓ Bitcoin için farklı çeşit cüzdanlar ve borsalar kullanılabilir. Sıcak cüzdan olan online cüzdan veya borsalarda saklanabilir. Ya da bir kâğıda cüzdan bilgileri yazılarak soğuk cüzdanlarda saklanabilir.




5. UYGULAMA

Veri seti, investing.com internet sitesi 17 Ekim 2012 – 17 Ekim 2022 tarihleri arasındaki Bitcoin (USD), ons altın (USD), dolar endeksi ve Nasdaq 100 endeksi kapanış fiyatlarından alınmıştır. Bitcoin hariç diğer piyasalar hafta sonları kapalı olduğu için Bitcoin deki hafta sonu değerlerinde temizlik yapılmıştır. Uygulama python dilinde yazılmış olup pandas, numpy, matplotlib, seaborn, sckirt learn kütüphaneleri kullanılmıştır. Derleyici olarak Pycharm 2021 tercih edilmiştir.


Veri setindeki değişkenlerin çift olarak yoğunluk haritası incelendiğinde;

Şekil 5.1'deki Altın-Dolar ikilisinde altın değerinin yüksek olduğu zamanlarda dolar endeksinin 100 bandında olduğu, dolar endeksinin 115'lere uzandığı dönemlerde altının fiyatlarının ortalamalarda yani 1600 bandında olduğu gözlemlenmektedir.



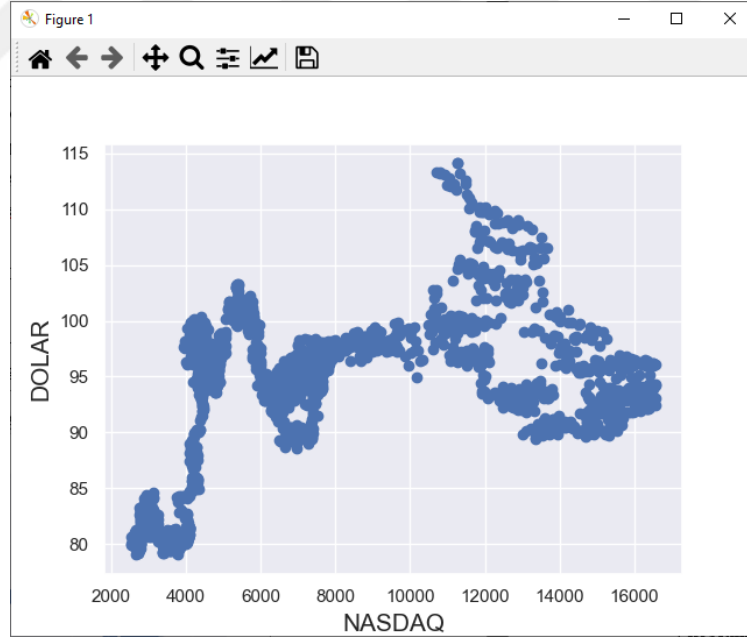
Şekil 5.1. Altın-Dolar ikilisi yoğunluk haritası

Şekil 5.2'deki Bitcoin-Dolar ikilisi incelendiğinde birbirine ters orantılı olduğu gözlemlenmektedir. Dolar endeksinin yüksek olduğu zamanlarda Bitcoin'in düştüğü, Bitcoin'in güçlü olduğu durumlarda ise dolar endeksinin düşük olduğu gözlemlenmektedir.




Şekil 5.2. Bitcoin-Dolar ikilisi yoğunluk haritası

Şekil 5.3 Nasdaq-Dolar ikilisine bakıldığında altın haritasına benzer bir durum söz konusudur.



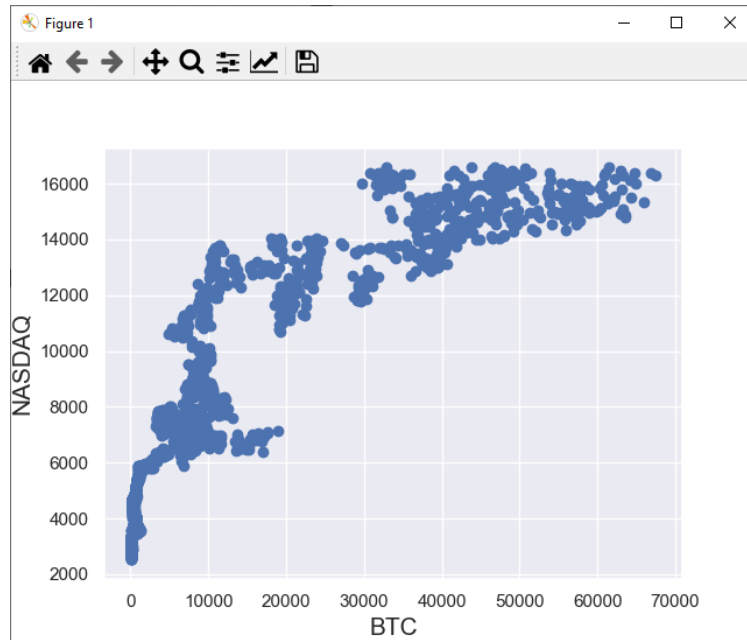
Şekil 5.3. Nasdaq-Dolar ikilisi yoğunluk haritası

Şekil 5.4'deki Bitcoin-Altın ikilisinde bakıldığında doğru orantı gözlemlenmektedir. Her iki para biriminin yüksek ve düşük fiyatlanmaları aynı zamanlara denk gelmiştir.



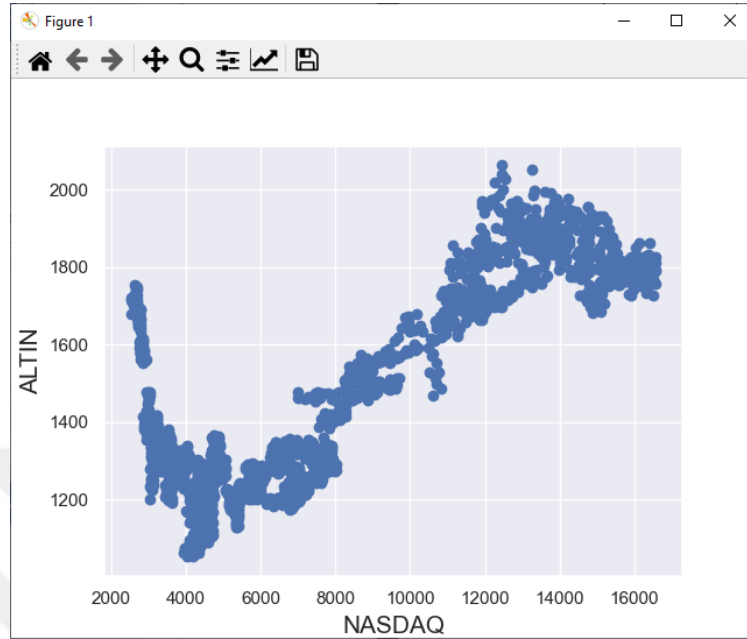
Şekil 5.4. Bitcoin-Altın ikilisi yoğunluk haritası

Şekil 5.5'deki Bitcoin-Nasdaq ikilisine bakıldığında doğru bir orantı söz konusudur. Her ikisinin de yükseliş ve düşüş zamanlarının aynı dönemlerde olduğu görülmektedir.



Şekil 5.5. Bitcoin-Nasdaq ikilisi yoğunluk haritası

Şekil 5.6'da Nasdaq-Altın haritası incelendiğinde yükseliş ve düşüş dönemlerinin aynı zamanlara geldiğini görülmektedir.



Şekil 5.6. Nasdaq-Altın ikilisi yoğunluk haritası

Bu çalışmada veri seti iki, beş ve on yıllık olmaz üzere üçe ayrılmıştır. Tahmin değerleri bu üç veri setinde ayrı ayrı değerlendirilmiştir. Uygulama, doğrusal regresyon, Lasso ve karar ağaçları modelleri ile çalıştırılmıştır. Her üç modelde, oluşturulan veri setlerinin %75'i eğitim verisi, %25'i test verisi olarak ayrılmıştır.

Lasso'nun polinom derecesi 12 olarak belirlenmiştir. Daha düşük bir derece girildiğinde daha kötü sonuçlar çıktığı, daha yüksek derecede ise işlemlerin uzun sürdüğü ve düşük başarı oranlarının ortaya çıktığı gözlemlenmiştir. Çizelge 5.1'de on yıllık verilerle altın tahmininde, 2 ile 20 arasındaki polinom derecesine göre elde edilen doğruluk oranları gösterilmektedir. 12.dereceye kadar doğruluk oranının yükseldiği daha üst derecelerde ise düşmeye başladığı ve 12. dereceden sonraki derecelerde işlem süresinin uzadığı gözlenmiştir.

Çizelge 5.1. Polinom dereceleri

Polinom Derecesi	Doğruluk Oranı	Polinom Derecesi	Doğruluk Oranı
2. Derece	0.8496885726909	12. Derece	0.9229607997154661
3.Derece	0.8860805502475996	13.Derece	0.9228063281171876
4. Derece	0.900176785571901	14. Derece	0.9227496751705496
5.Derece	0.908512917629656	15.Derece	0.923038192309188
6. Derece	0.9142988935761542	16. Derece	0.9223198795615204
7.Derece	0.9186911942030094	17.Derece	0.9226750647803711
8. Derece	0.9207754754048145	18. Derece	0.9219684412391989
9.Derece	0.9211099190289921	19.Derece	0.9212473678086026
10. Derece	0.9215474774843557	20. Derece	0.9215382280624034
11.Derece	0.9222208315097652		

5.1 İki Yıllık Veriler ile Yapılan Çalışma

Veri seti, 19.10.2020-17.10.2022 tarihleri arasındaki 513 günden oluşmaktadır. Veri setinin özeti Çizelge 5.2’de gösterilmektedir.

Çizelge 5.2. İki yıllık veri özeti

	BTC	ALTIN	DOLAR	NASDAQ 100
Gün Sayısı	513	513	513	513
Ortalama	37.939	1.813	97	14.253
Standart Sapma	13.875	71	6	1.500
Minimum	11.753	1.622	89	10.692
25%	23.774	1.769	92	13.090
50%	39.143	1.808	94	14.525
75%	47.809	1.862	100	15.490
Maximum	67.528	2.052	114	16.573

İki yıllık veriler ile Altın fiyatı tahmin edilmek istendiğinde kullanılan doğrusal regresyon, Lasso ve karar ağaçları modellerinde aşağıdaki gibi doğruluk skorları elde edilmiştir.

- ✓ Doğrusal Regresyon %25,
- ✓ Lasso %76,
- ✓ Karar Ağaçları %77,

Bu oranlar sonucunda 3 Kasım 2022'de investing.com'daki altının ons kapanış değeri 1629\$'dır. Dolar endeksi, Nasdaq 100 endeksi ve Bitcoin fiyatı ile uygulama çalıştırıldığında altının fiyat tahminleri aşağıdaki gibi olmuştur.

- ✓ Doğrusal Regresyon 1765\$
- ✓ Lasso 1633\$
- ✓ Karar Ağaçları 1642\$

Tahminlerden çıkan sonuca göre doğruluk değerleri ile paralel olarak karar ağaçları modeli gerçek değere daha yakın bir değer bulmuştur. Bir gün sonraki altının kapanış değeri 1680\$ olmuştur.

Veri seti ile dolar endeksi tahmin edilmek istendiğinde üç modelde aşağıdaki doğruluk oranları ortaya çıkmıştır.

- ✓ Doğrusal Regresyon %58,
- ✓ Lasso %76,
- ✓ Karar Ağaçları %90,

3 Kasım 2022'deki investing.com'daki dolar endeksinin kapanış değeri 112,93'tür. Nasdaq 100 endeksi, altın ve Bitcoin fiyatları ile uygulama çalıştırıldığında ortaya çıkan tahmini endeks değeri aşağıdaki gibi olmuştur.

- ✓ Doğrusal Regresyon 111,79
- ✓ Lasso 116,59
- ✓ Karar Ağaçları 112

Çıkan sonuca göre doğrusal regresyon modeli endeksin düşeceğini, diğer modeller ise çıkacağını düşünmektedir. Bir sonraki gün endeksin değeri 110,88 olmuştur. Her ne kadar doğruluk oranı doğrusal regresyonda düşük çıksa da bu modelin tahmini daha yakın olmuştur.

Nasdaq 100 endeksi tahmin edilmek istendiğinde aşağıdaki doğruluk oranları ortaya çıkmıştır.

- ✓ Doğrusal Regresyon %70,
- ✓ Lasso %79,
- ✓ Karar Ağaçları %82,

Bu oranlar doğrultusunda 3 Kasım 2022'deki investing.com'daki Nasdaq 100 endeksinin kapanış değeri 10.690'dır. Dolar endeksi, altın ve Bitcoin fiyatlarına göre uygulama çalıştırıldığında aşağıdaki tahminler ortaya çıkmıştır.

- ✓ Doğrusal Regresyon 11.831

- ✓ Lasso 11.664
- ✓ Karar Ağaçları 11.063

Doğruluk oranları ile paralel olarak Karar ağaçları daha yakın bir tahmin de bulunmuştur. Bir sonraki gün Nasdaq 100 endeksini kapanış değeri 10.857 olmuştur.

Diğer bir para birimi olan Bitcoin tahmin edilmek istendiğinde aşağıdaki doğruluk değerleri ortaya çıkmıştır.

- ✓ Doğrusal Regresyon % 56,
- ✓ Lasso % 73,
- ✓ Karar Ağaçları % 74,

Investing.com'daki 3 Kasım 2022 Bitcoin kapanış fiyatı 20.206\$'dır. Altın fiyatı, dolar ve Nasdaq 100 endekslerinin değerleri ile uygulama çalıştırıldığında ortaya çıkan tahmini fiyatı aşağıdaki gibi olmuştur.

- ✓ Doğrusal Regresyon 15.464\$
- ✓ Lasso 22.797\$
- ✓ Karar Ağaçları 19.182\$

Yapılan tahminlerden sonra bir sonraki günün Bitcoin kapanış değeri 21,145\$ olmuştur. Lasso modeli doğruya yakın bir tahminde bulunmuştur.

5.2 Beş Yıllık Veriler ile Yapılan Çalışma

Veri seti, 17.10.2017-17.10.2022 tarihleri arasındaki 1297 günden oluşmaktadır. Veri setinin özeti de Çizelge 5.3'de oluşturulmuştur.

Çizelge 5.3. Beş yıllık veri özeti

	BTC	ALTIN	DOLAR	NASDAQ 100
Gün Sayısı	1.297	1.297	1.297	1.297
Ortalama	19.930	1.586	96	10.780
Standart Sapma	17.111	253	5	3.324
Minimum	3.248	1.174	89	5.899
25%	7.444	1.314	93	7.508
50%	10.413	1.660	96	10.871
75%	33.516	1.808	98	13.771
Maximum	67.528	2.063	114	16.573

Oluşturulan veri seti ile altın fiyatı tahmin edilmek istendiğinde kullanılan doğrusal regresyon, Lasso ve karar ağaçları modellerinde aşağıdaki gibi doğruluk skorları elde edilmiştir.

- ✓ Doğrusal Regresyon %85,
- ✓ Lasso %98,
- ✓ Karar Ağaçları %97,

Bu oranlar sonucunda 3 Kasım 2022'de investing.com'daki altının ons kapanış değeri 1629\$'dır. Dolar endeksi, Nasdaq 100 endeksi ve Bitcoin fiyatı ile uygulama çalıştırıldığında altının fiyat tahminleri aşağıdaki gibi olmuştur.

- ✓ Doğrusal Regresyon 1629\$
- ✓ Lasso 1645\$
- ✓ Karar Ağaçları 1642\$

Tahminlerden çıkan sonuca göre doğruluk değerleri ile paralel olarak Lasso modeli gerçek değere daha yakın bir değer bulmuştur. Bir gün sonra ki altının kapanış değeri 1680\$ olmuştur.

Dolar endeksi tahmin edilmek istendiğinde üç modelde aşağıdaki doğruluk oranları ortaya çıkmıştır.

- ✓ Doğrusal Regresyon %52,
- ✓ Lasso %70,
- ✓ Karar Ağaçları %80,

3 Kasım 2022'deki investing.com'daki dolar endeksinin kapanış değeri 112,93'tür. Nasdaq 100 endeksi, altın ve Bitcoin fiyatları ile uygulama çalıştırıldığında ortaya çıkan tahmini endeks değeri aşağıdaki gibi olmuştur.

- ✓ Doğrusal Regresyon 96,32
- ✓ Lasso 107,79
- ✓ Karar Ağaçları 112

Çıkan sonuca göre bu veri setinde Karar ağaçları modeli başarılı bir oran elde etmiştir. Bir sonraki günün kapanış değeri 110,88 olmuştur. Karar ağaçları modeli gerçek değere yakın bir değer tahmin etmiştir.

Veri setindeki başka bir para birimi olan Nasdaq 100 endeksini tahmin edilmek istendiğinde aşağıdaki doğruluk oranları ortaya çıkmıştır.

- ✓ Doğrusal Regresyon %93,

- ✓ Lasso %96,
- ✓ Karar Ağaçları %98,

Bu oranlar doğrultusunda 3 Kasım 2022'deki investing.com daki Nasdaq 100 endeksinin kapanış değeri 10.690'dır. Dolar endeksi, altın ve Bitcoin fiyatlarına göre uygulama çalıştırıldığında aşağıdaki tahminler ortaya çıkmıştır.

- ✓ Doğrusal Regresyon 11.013
- ✓ Lasso 11.490
- ✓ Karar Ağaçları 10.692

Bir sonraki gün Nasdaq 100 endeksini kapanış değeri 10.857 olmuştur ve doğruluk oranları ile paralel olarak karar ağaçları daha yakın bir tahmin de bulunmuştur.

Veri setindeki bir diğer para birimi olan Bitcoin tahmin edilmek istendiğinde aşağıdaki doğruluk değerleri ortaya çıkmıştır.

- ✓ Doğrusal Regresyon %78,
- ✓ Lasso %87,
- ✓ Karar Ağaçları %91,

Investing.com'daki 3 Kasım 2022 Bitcoin kapanış fiyatı 20.206\$'dır. Altın fiyatı, dolar ve Nasdaq 100 endekslerinin değerleri ile uygulama çalıştırıldığında ortaya çıkan tahmini fiyatı aşağıdaki gibi olmuştur.

- ✓ Doğrusal Regresyon 14.812\$
- ✓ Lasso 17.716\$
- ✓ Karar Ağaçları 19.423\$

Bir sonraki günün Bitcoin kapanış değeri 21,145\$ olmuştur. Karar ağaçları modeli doğruya yakın bir tahminde bulunmuştur.

5.3 On Yıllık Veriler ile Yapılan Çalışma

Veri seti, 17.10.2012-17.10.2022 tarihleri arasındaki 2601 günden oluşmaktadır. Veri setinin özeti de Çizelge 5.4'de oluşturulmuştur.

Çizelge 5.4. On yıllık veri özeti

	BTC	ALTIN	DOLAR	NASDAQ 100
Gün Sayısı	2601	2601	2601	2601
Ortalama	10277,71969	1435,809066	93,121961	7522,938866
Standart Sapma	15461,46742	254,707427	7,074708	4066,361371
Minimum	10,2	1051,74	79,02	2524,36
25%	419,6	1242,55	90,12	4325,86
50%	3713,8	1318,22	94,8	6396,42
75%	10388,7	1699,12	97,44	10833,33
Maximum	67527,9	2063,19	114,11	16573,34

Bu veri seti ile altın fiyatı tahmin edilmek istendiğinde kullanılan doğrusal regresyon, Lasso ve karar ağaçları modellerinde aşağıdaki gibi doğruluk skorları elde edilmiştir.

- ✓ Doğrusal Regresyon %71,
- ✓ Lasso %91,
- ✓ Karar Ağaçları %98,

Bu oranlar sonucunda 3 Kasım 2022’de investing.com’daki altının ons kapanış değeri 1629\$’dır. Dolar endeksi, Nasdaq 100 endeksi ve Bitcoin fiyatı ile uygulama çalıştırıldığında altının fiyat tahminleri aşağıdaki gibi olmuştur.

- ✓ Doğrusal Regresyon 1469\$
- ✓ Lasso 1638\$
- ✓ Karar Ağaçları 1645\$

Yapılan tahminlerde Karar ağaçları modeli gerçek değere daha yakın bir değer bulmuştur. Bir gün sonra ki altının kapanış değeri 1680\$ olmuştur.

Dolar endeksi tahmin edilmek istendiğinde üç modelde aşağıdaki doğruluk oranları ortaya çıkmıştır.

- ✓ Doğrusal Regresyon %49,
- ✓ Lasso %71,
- ✓ Karar Ağaçları %92,

3 Kasım 2022’deki investing.com’daki dolar endeksinin kapanış değeri 112,93’tür. Nasdaq 100 endeksi, altın ve Bitcoin fiyatları ile uygulama çalıştırıldığında ortaya çıkan tahmini endeks değeri aşağıdaki gibi olmuştur.

- ✓ Doğrusal Regresyon 95,01
- ✓ Lasso 98,40

✓ Karar Ağaçları 110

Tahminlerden çıkan sonuca göre bu veri setinde Karar ağaçları modeli başarılı bir oran elde etmiştir. Bir sonraki günün kapanış değeri 110,88 olmuştur. Karar ağaçları modeli gerçek değere yakın bir değer tahmin etmiştir.

Veri setindeki başka bir para birimi olan Nasdaq 100 endeksini tahmin edilmek istendiğinde aşağıdaki doğruluk oranları ortaya çıkmıştır.

- ✓ Doğrusal Regresyon %90,8,
- ✓ Lasso %98,
- ✓ Karar Ağaçları %98,

Bu oranlar doğrultusunda 3 Kasım 2022'deki investing.com'daki Nasdaq 100 endeksinin kapanış değeri 10.690'dır. Dolar endeksi, altın ve Bitcoin fiyatlarına göre uygulama çalıştırıldığında aşağıdaki tahminler ortaya çıkmıştır.

- ✓ Doğrusal Regresyon 13.318
- ✓ Lasso 10.285
- ✓ Karar Ağaçları 11.927

Bir sonraki gün Nasdaq 100 endeksini kapanış değeri 10.857 olmuştur Lasso modeli gerçeğe daha yakın bir tahmin de bulunmuştur.

Veri setindeki bir diğer para birimi olan Bitcoin tahmin edilmek istendiğinde aşağıdaki doğruluk değerleri ortaya çıkmıştır.

- ✓ Doğrusal Regresyon %81,
- ✓ Lasso %91,
- ✓ Karar Ağaçları %94,

investing.com'daki 3 Kasım 2022 Bitcoin kapanış fiyatı 20.206\$'dır. Altın fiyatı, dolar ve Nasdaq 100 endekslerinin değerleri ile uygulama çalıştırıldığında ortaya çıkan tahmini fiyatı aşağıdaki gibi olmuştur.

- ✓ Doğrusal Regresyon 11.396\$
- ✓ Lasso 15.783\$
- ✓ Karar Ağaçları 19.380\$

Bir sonraki günün Bitcoin kapanış değeri 21,145\$ olmuştur. Karar ağaçları modeli doğruya yakın bir tahminde bulunmuştur.

5.4 Uygulama Çıktıları

Uygulamadan çıkan doğruluk oranlarına göre Çizelge 5.5 oluşturulmuştur. Oluşturulan çizelgeye göre, iki yıllık verilerde başarı oranının diğer verilere göre daha düşük olduğu tespit edilmiştir. Bu verilerle altın tahminin de doğrusal regresyon başarısız olmuştur. Karar ağaçları yöntemi diğer yöntemlere göre daha yüksek doğruluk oranı vermiştir.

Beş yıllık verilerle çıkan sonuçlar incelendiğinde, altın tahminin de, iki yıllık verilere kıyasla yüksek bir doğruluk oranı ortaya çıkmıştır. Lasso yöntemi altın tahminin de daha başarılı bulunmuştur. DXY tahmininde ise doğrusal regresyon daha düşük bir oran çıkarmıştır. Karar ağaçları DXY, Bitcoin ve Nasdaq 100 tahmininde daha başarılı olmuştur.

Diğer bir veri seti olan on yıllık verilerle çıkan sonuca bakıldığında genel olarak yüksek oranlar çıkmıştır. DXY tahmininde doğrusal regresyon düşük bir oranla başarısız olmuştur. Diğer tahminlerde başarılı sonuçlar çıkmıştır. Yine bu verilerde karar ağaçları yöntemi daha başarılı sonuçlar ortaya çıkarmıştır.

Çizelge 5.5. Uygulama sonuçları

İki yıllık veriler			
	Doğrusal	Lasso	Karar Ağaçları
Altın	25%	76%	77%
DXY	58%	76%	90%
Bitcoin	56%	73%	74%
Nasdaq 100	70%	79%	82%
Beş yıllık veriler			
Altın	85%	98%	97%
DXY	52%	70%	80%
Bitcoin	78%	87%	91%
Nasdaq 100	93%	96%	98%
On yıllık veriler			
Altın	71%	91%	98%
DXY	49%	71%	92%
Bitcoin	81%	91%	94%
Nasdaq 100	91%	98%	96%

Çizelge 5.6, 5.7 ve 5.8’de sırasıyla on yıllık, beş yıllık ve iki yıllık verilerin gerçek değerlere göre tahmin değerleri gösterilmektedir. Tahmin işlemindeki mutlak hata yüzdesi Denklem 5.1’e göre hesaplanmış ve en küçük hata yüzdeleri çizelgelerde koyu renk ile gösterilmiştir.

$$HY = \left| \frac{\text{Tahmin Değeri} - \text{Gerçek Değer}}{\text{Gerçek Değer} * 100} \right| \quad (5.1)$$

Çizelge 5.6’da, on yıllık veri seti içerisinde 4.11.2022-18.11.2022 tarihleri arasındaki birer gün arayla seçilen günlere ait değerler ile yapılan tahmin sonuçları gösterilmektedir. Bu sonuçlarla, Çizelge 5.5’de verilen doğruluk oranlarına göre Karar ağaçları ve Lasso yöntemlerinin doğrusal regresyona göre daha başarılı tahminlerde bulunduğu gözlemlenmiştir. Hata yüzdeleri incelendiğinde, Bitcoin’in diğerlerine göre yüksek hata yüzdesi verdiği gözlenmiştir. Bitcoin fiyatlarının dalgalı olması hata yüzdesinin yüksek çıkmasına neden olduğu saptanmıştır.

Çizelge 5.7’de, beş yıllık veriler kullanılarak 4.11.2022-18.11.2022 tarihleri arasındaki birer gün arayla seçilen günlere ait değerler ile elde edilen tahmin sonuçları gösterilmektedir. Bu sonuçlarla, Çizelge 5.5’de verilen doğruluk oranlarına göre Karar ağaçları ve Lasso yöntemlerinin doğrusal regresyona göre daha başarılı tahminlerde bulunduğu gözlemlenmiştir. Çizelge 5.5’deki doğruluk oranlarına göre on yıllık verilere göre daha başarısız olduğu yine bu sonuçlarla gözlemlenmiştir. Hata yüzdelere bakıldığında on yıllık verilere göre daha yüksek olduğu ortaya çıkmıştır.

Çizelge 5.8 ile iki yıllık veri seti ile çalıştırılan uygulama sonuçları gösterilmiştir. 4.11.2022-18.11.2022 tarihleri arasındaki birer gün arayla seçilen günlere ait girilen değerler ile tahmin yapıldığına bu sonuçlar ortaya çıkmıştır. Çizelge 5.5’de de gösterildiği üzere hata paylarının diğer veri setlerine göre daha yüksek olduğu gözlenmiştir.

Çizelge 5.6. On yıllık verilerle gerçek değerlere göre yapılan tahminler

		Tahminler			Hata Yüzdeleri			
	Para Birimi	Gerçek Değer	Doğrusal Regresyon	Lasso	Karar Ağacı	Doğrusal Regresyon	Lasso	Karar Ağacı
4.11.2022	Altın	1.680,27	1.404	1.677	1.726	16,44%	0,19%	2,72%
	DXY	110,88	94,18	104,58	112	15,06%	5,68%	1,01%
	Bitcoin	21.145	12.761	20.414	18.489	39,65%	3,46%	12,56%
	Nasdaq	10.857	13.434	11.411	12.588	23,74%	5,10%	15,94%
7.11.2022	Altın	1.674,68	1.424	1.679	1.819	14,97%	0,26%	8,62%
	DXY	110,12	94,81	104,65	112	13,90%	4,97%	1,71%
	Bitcoin	20.589	13.711	17.993	18.489	33,41%	12,61%	10,20%
	Nasdaq	10.977	13.195	11.095	11.927	20,21%	1,07%	8,65%
9.11.2022	Altın	1.706,32	1.419	1.685	1.716	16,84%	1,25%	0,57%
	DXY	110,55	94,19	105	111	14,80%	5,02%	0,41%
	Bitcoin	15.886	13.224	23.860	20.586	16,76%	50,20%	29,59%
	Nasdaq	10.797	13.459	11.603	12.098	24,65%	7,47%	12,05%
11.11.2022	Altın	1.770,69	1.545	1.744	1.734	12,75%	1,51%	2,07%
	DXY	106,29	96,41	102,35	92	9,30%	3,71%	13,44%
	Bitcoin	17.049	18.449	21.802	20.201	8,21%	27,88%	18,49%
	Nasdaq	11.817	12.651	13016	11.780	7,06%	10,15%	0,31%
14.11.2022	Altın	1.771,80	1.533	1.738	1.726	13,48%	1,91%	2,58%
	DXY	106,66	96,2	102,26	111	9,81%	4,13%	4,07%
	Bitcoin	16.613	17.759	22.300	20.201	6,90%	34,23%	21,60%
	Nasdaq	11.700	12.653	13.243	11.780	8,15%	13,19%	0,68%
16.11.2022	Altın	1.773,77	1.539	1.744	1.764	13,24%	1,68%	0,55%
	DXY	106,28	96,18	101,95	93	9,50%	4,07%	12,50%
	Bitcoin	16.540	17.940	22.636	22.157	8,46%	36,86%	33,96%
	Nasdaq	11.699	12.594	13.001	11.780	7,65%	11,13%	0,69%
18.11.2022	Altın	1.749,74	1.528	1.734	1.726	12,67%	0,90%	1,36%
	DXY	106,93	97	102,63	92	9,29%	4,02%	13,96%
	Bitcoin	16.638	17.699	20.211	22.157	6,38%	21,47%	33,17%
	Nasdaq	11.677	12.566	12.846	11.780	7,61%	10,01%	0,88%
En Küçük Hata Yüzdelerinin Toplamı						101,46%		

Çizelge 5.7. Beş yıllık verilerle gerçek değerlere göre yapılan tahminler

	Para Birimi	Gerçek Değer	Tahminler			Hata Yüzdeleri		
			Doğrusal Regresyon	Lasso	Karar Ağacı	Doğrusal Regresyon	Lasso	Karar Ağacı
4.11.2022	Altın	1.680,27	1.633	1.707	1.660	2,81%	1,59%	1,21%
	DXY	110,88	96,6	106,64	112	12,88%	3,82%	1,01%
	Bitcoin	21.145	13.309	24.607	19.059	37,06%	16,37%	9,87%
	Nasdaq	10.857	11.524	11.358	12.740	6,14%	4,61%	17,34%
7.11.2022	Altın	1.674,68	1.644	1.710	1.839	1,83%	2,11%	9,81%
	DXY	110,12	96,58	106,77	113	12,30%	3,04%	2,62%
	Bitcoin	20.589	14.564	21.093	18.489	29,26%	2,45%	10,20%
	Nasdaq	10.977	11.434	11.472	11.861	4,16%	4,51%	8,05%
9.11.2022	Altın	1.706,32	1.655	1.635	1.660	3,01%	4,18%	2,71%
	DXY	110,55	97,18	104,49	96	12,09%	5,48%	13,16%
	Bitcoin	15.886	11.953	28.795	20.340	24,76%	81,26%	28,04%
	Nasdaq	10.797	11.286	12.199	11.984	4,53%	12,99%	10,99%
11.11.2022	Altın	1.770,69	1.697	1.631	1.648	4,16%	7,89%	6,93%
	DXY	106,29	97,54	104,45	97	8,23%	1,73%	8,74%
	Bitcoin	17.049	10.464	27.110	22.448	38,62%	59,01%	31,67%
	Nasdaq	11.817	11.940	11.951	12.343	1,04%	1,13%	4,45%
14.11.2022	Altın	1.771,80	1.713	1.726	1.727	3,32%	2,58%	2,53%
	DXY	106,66	97,39	102,73	111	8,69%	3,68%	4,07%
	Bitcoin	16.613	16.672	22.674	20.111	0,36%	36,48%	21,06%
	Nasdaq	11.700	11.907	12.276	11.860	1,77%	4,92%	1,37%
16.11.2022	Altın	1.773,77	1.721	1.725	1.765	2,98%	2,75%	0,49%
	DXY	106,28	97,41	102,82	98	8,35%	3,26%	7,79%
	Bitcoin	16.540	16.677	22.440	20.201	0,83%	35,67%	22,13%
	Nasdaq	11.699	11.920	12.273	11.586	1,89%	4,91%	0,97%
18.11.2022	Altın	1.749,74	1.721	1.715	1.735	1,64%	1,99%	0,84%
	DXY	106,93	97	103,77	92	9,29%	2,96%	13,96%
	Bitcoin	16.638	17.304	21.557	21.101	4,00%	29,56%	26,82%
	Nasdaq	11.677	11.729	12.053	10.896	0,45%	3,22%	6,69%
En Küçük Hata Yüzdelerinin Toplamı						125,56%		

Çizelge 5.8. İki yıllık verilerle gerçek değerlere göre yapılan tahminler

	Para Birimi	Gerçek Değer	Tahminler			Hata Yüzdeleri		
			Doğrusal Regresyon	Lasso	Karar Ağacı	Doğrusal Regresyon	Lasso	Karar Ağacı
4.11.2022	Altın	1.680,27	1.776	1.687	1.711	5,70%	0,40%	1,83%
	DXY	110,88	109,95	112,37	112	0,84%	1,34%	1,01%
	Bitcoin	21.145	16.009	16.911	19.593	24,29%	20,02%	7,34%
	Nasdaq	10.857	12.007	11.886	12.588	10,59%	9,48%	15,94%
7.11.2022	Altın	1.674,68	1.779	1.721	1.716	6,23%	2,77%	2,47%
	DXY	110,12	106,74	112,49	112	3,07%	2,15%	1,71%
	Bitcoin	20.589	16.869	17.471	20.340	18,07%	15,14%	1,21%
	Nasdaq	10.977	12.071	11.958	11.583	9,97%	8,94%	5,52%
9.11.2022	Altın	1.706,32	1.781	1.884	1.665	4,38%	10,41%	2,42%
	DXY	110,55	106,35	113,22	113	3,80%	2,42%	2,22%
	Bitcoin	15.886	15.303	18.755	18.489	3,67%	18,06%	16,39%
	Nasdaq	10.797	11.695	11.807	12.011	8,32%	9,35%	11,24%
11.11.2022	Altın	1.770,69	1.794	1.815	1.734	1,32%	2,50%	2,07%
	DXY	106,29	104,63	106,08	106	1,56%	0,20%	0,27%
	Bitcoin	17.049	21.659	22.082	21.611	27,04%	29,52%	26,76%
	Nasdaq	11.817	12.098	12.490	11.780	2,38%	5,70%	0,31%
14.11.2022	Altın	1.771,80	1.833	1.796	1.726	3,45%	1,37%	2,58%
	DXY	106,66	104,95	106,78	107	1,60%	0,11%	0,32%
	Bitcoin	16.613	20.840	22.135	20.201	25,44%	33,24%	21,60%
	Nasdaq	11.700	12.031	12.133	11.780	2,83%	3,70%	0,68%
16.11.2022	Altın	1.773,77	1.796	1.844	1.808	1,25%	3,96%	1,93%
	DXY	106,28	104,9	106,16	108	1,30%	0,11%	1,62%
	Bitcoin	16.540	20.785	21.081	20.111	25,67%	27,45%	21,59%
	Nasdaq	11.699	12.065	11.951	11.504	3,13%	2,15%	1,67%
18.11.2022	Altın	1.749,74	1.792	1.829	1.726	2,42%	4,53%	1,36%
	DXY	106,93	105,8	108,19	108	1,06%	1,18%	1,00%
	Bitcoin	16.638	20.909	20.244	20.561	25,67%	21,67%	23,58%
	Nasdaq	11.677	12.047	12.085	11.780	3,17%	3,49%	0,88%
En Küçük Hata Yüzdelerinin Toplamı						147,47%		

6. SONUÇ VE ÖNERİLER

Bu çalışma ile dört farklı para birimlerinden altın ons fiyatı, Bitcoin fiyatı, dolar endeksi ve Nasdaq 100 endeksi değerleri için, makine öğrenmesi yöntemlerinden doğrusal regresyon, Lasso ve karar ağaçları ile tahmin yapılmıştır. Üç farklı zaman dilimlerinden oluşan veri setleri ile oluşan doğruluk oranları ile en başarılı doğruluk oranlarına on yıllık verilerle ulaşılmıştır. Yöntem olarak da Lasso ve karar ağaçları yöntemleri başarılı bulunmuştur. Gerçek değerlerle karşılaştırıldığında gerçek değerlere yakın tahminler ortaya çıkmıştır. Gerçek değerler ile yapılan tahmin sonuçları incelendiğinde mutlak hata yüzdelerinin en düşük on yıllık verilerde olduğu gözlemlenmiştir. Bitcoin fiyatlarının çok dalgalı olması tahminlerde başarısız sonuçlar çıkarmasına neden olmuştur. Aynı zamanda finansal, siyasal veya diğer oluşabilecek gelişmelerden dolayı ortaya çıkabilecek ani iniş veya çıkışlar tahmin edilememektedir. Bu çalışmadaki tahmin değerleri akademik bilgi vermek amaçlı gösterilmiştir. Yatırım tavsiyesi niteliğinde değildir.

Bu çalışmada dört farklı para biriminden yararlanılmıştır. Bu para birimleri artırılarak veri seti daha da genişletilebilir. Veri olarak daha geniş bir zaman dilimi seçilebilir. Makine öğrenmesinden farklı olarak yapay zekâ veya derin öğrenme ile tahmin yapılarak çalışma genişletilebilir.

KAYNAKLAR

- Abar H., 2020, Xgboost Ve Mars Yöntemleriyle Altın Fiyatlarının Kestirimi *Ekev Akademi Dergisi*, 24(83), 427.
- Aktaş S., 2019, Dow Jones Endüstri Ortalaması Ve Nasdaq 100 Endekslerinin Makine Öğrenmesi Algoritmaları İle Tahmini, Yüksek lisans Tezi, *Sosyal Bilimler Enstitüsü*, İstanbul Teknik Üniversitesi, 46-47.
- Alpaydin E. Ve Bach F., 2014, Introduction to Machine Learning, Third Edition, *MIT Press Yayınları*, İngiltere, 517.
- Anonim, 2021, Makine Öğrenmesi (Machine Learning) Nedir? [online] <https://www.turhost.com/blog/makine-ogrenmesi-machine-learning-nedir/>, [Ziyaret Tarihi: 15.03.2022].
- Anonim, Polinom Regresyonu Anlamak [online], <https://ichi.pro/tr/polinom-regresyonu-anlamak-25440022887028> [Ziyaret Tarihi: 29.03.2022].
- Anonim, Entropi ve Bilgi Kazanımı nedir? Karar ağaçları oluşturmak için nasıl kullanılırlar? [online], <https://ichi.pro/tr/entropi-ve-bilgi-kazanimi-nedir-karar-agacлари-olusturmak-icin-nasil-kullanilirlar-187876852050160>, [Ziyaret Tarihi:12.04.2022].
- Anonim, Lasso Regresyon Analizi ve Uygulama Amaçları [online], <https://www.28.com/lasso-regresyon-analizi/> [Ziyaret Tarihi: 15.04.2022].
- Anonim, 2022, About Nasdaq [online], <https://www.nasdaq.com/about> [Ziyaret Tarihi: 25.03.2022].
- Anonim, 2021, Hepsiburada Announces Launch of Initial Public Offering [online], <https://www.nasdaq.com/press-release/hepsiburada-announces-launch-of-initial-public-offering-2021-06-23> [Ziyaret Tarihi: 26.03.2022].
- Anonim, 2020, What is Nasdaq? [online], <https://www.business-standard.com/about/what-is-nasdaq#collapse> [Ziyaret Tarihi: 27.03.2022].
- Anonim, 2021, What Qualifies Company Blue Chip? [online], <https://nesrakonk.ru/what-qualifies-company-blue-chip/> [Ziyaret Tarihi: 30.03.2022].
- Anonim, 2017, What is the NASDAQ-100? [online], <https://capital.com/nasdaq-100-index-definition>, [Ziyaret Tarihi: 28.03.2022].
- Anonim, 2021, Global mine production [online], <https://www.gold.org/goldhub/data/historical-mine-production> [Ziyaret Tarihi: 10.09.2021].

- Anonim, 2021, Central bank holdings [online], <https://www.gold.org/goldhub/data/gold-reserves-by-country>, [Ziyaret Tarihi: 10.09.2021].
- Anonim, 2022, Xau-Usd [online], <https://tr.investing.com/currencies/xau-usd>, [Ziyaret Tarihi: 10.10.2022].
- Anonim, 2022, Usd-Try [online], <https://tr.investing.com/currencies/usd-try>, [Ziyaret Tarihi: 07.09.2022].
- Anonim, 2022, Xau-Usd [online], <https://tr.tradingview.com/symbols/XAUUSD/> [Ziyaret Tarihi: 12.03.2022].
- Anonim, 2021, History [online], <https://www.uscurrency.gov/history>, [Ziyaret Tarihi: 17.09.2021].
- Anonim, 2021, Dollar Usd [online], <https://corporatefinanceinstitute.com/resources/knowledge/finance/united-states-dollar-usd/>, [Ziyaret Tarihi: 20.09.2021].
- Anonim, 2021, İmf [online], <https://www.imf.org/external/about/histcoop.htm>, [Ziyaret Tarihi: 22.09.2021].
- Anonim, 2022, United States Dollar (USD), Corporate Finance İnstitute [online], <https://corporatefinanceinstitute.com/resources/knowledge/finance/united-states-dollar-usd/> [Ziyaret Tarihi: 10.03.2022].
- Anonim, 2022, Minutes of the Federal Open Market Committee September 20–21,2022 [online],<https://www.federalreserve.gov/monetarypolicy/files/fomcminutes20220921.pdf> [Ziyaret Tarihi: 11.03.2022].
- Anonim, 2022, Küresel Piyasalar: Dolar ABD hükümetinin kapanması ile düştü, hisse senetleri karışık [online], <https://www.bloomberght.com/haberler/haber/2088435-kuresel-piyasalar-hisseler-karisik-dolar-yatay> [Ziyaret Tarihi: 11.03.2022].
- Anonim, Altın [online], <https://www.mta.gov.tr/v3.0/metalik-madenler/altin> [Ziyaret Tarihi: 09.09.2021].
- Aras, S., 2019, Kripto Para Fiyatlarının Klasik ve Yapay Sinir Ağı Modelleri ile Tahmini. *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi KAÜİİBFD*, Kars, 10(20), 608-640.
- Aslan, S., 1999, Altın ve Altına Dayalı İşlemler Muhasebesi, *İstanbul Altın Borsası Yayınları*, İstanbul, 4.
- Aygören H., Sarıtaş H., Moralı T., 2012, İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini, *Uluslararası Alanya İşletme Fakültesi Dergisi*, 4(1), Alanya, 73-88.
- Aytekin, N. M., 2021, Yapay Sinir Ağları ve Regresyon Yöntemleri ile Hisse Senedi Getirilerinin Tahmini: Bist-30 Üzerine Bir Uygulama, Yüksek lisans Tezi, *Fen Bilimleri Enstitüsü*, Hacettepe Üniversitesi, 100-102.

- Balaban E., Kartal E., 2015, Sınıflandırmaya Dayalı Makine Öğrenmesi Teknikleri ve Kardiyolojik Risk Değerlendirmesine İlişkin Bir Uygulama, Doktora Tezi, *Fen Bilimleri Enstitüsü*, İstanbul Üniversitesi, 27-29.
- Balaban E., Kartal E., 2015, Veri madenciliği ve makine öğrenmesi, *Çağlayan kitabevi*, İstanbul, 103.
- Bayraktar F., 2020, Kripto Para Fiyat Değişimlerinin Büyük Veri Araçları ile Analizi, Yüksek Lisans Tezi, *Lisansüstü Eğitim Enstitüsü*, Eskişehir Teknik Üniversitesi, 47-49.
- Chen J., 2022, What Is the U.S. Dollar Index (USDX) and How to Trade It [online], <https://www.investopedia.com/terms/u/usdx.asp>, [Ziyaret Tarihi: 13.03.2022].
- Crosby, M., 2016, Blockchain Technology: Beyond Bitcoin., Applied Innovation Review, Mexico, 9-10.
- Çıtak, S., 2004, 24 Ayar, *Düş Yıldızı Yayınları*, Ankara, 15.
- Demirel U., 2019, Hisse Senedi Fiyatlarının Makine Öğrenmesi Yöntemleri ve Derin Öğrenme Algoritmaları ile Tahmini, Yüksek Lisans Tezi, *Sosyal Bilimler Enstitüsü*, Gümüşhane Üniversitesi, 93-94.
- Erek, M., 2009, Examining Us Dollar Index (DXY) Movements By Monte Carlo Simulation, *Bitlis Eren Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, Bitlis, 191-199.
- Ercan S., Demirbaş B., 2020, Abd Dolar Endeksi ile Vıx Korku Endeksi Arasındaki İlişki: Ardl Sınır Testi Yaklaşımı, *Bilgi Ekonomisi ve Yönetimi Dergisi*, 15(2), 115-129
- Ferhani, H., 2003, A New Role For Gold, *World Gold Council Research*, Peru, 200.
- Fonti V, Belitser E., 2017, Feature Selection Using Lasso, *Research Paper In Business Analytics*, Amsterdam, 4-5.
- Gülhan Ü., Temurlenk M.S., 2021, What are The Financial and Technologic Determinants of Cryptocurrency Prices? The Case of Bitcoin. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, Erzurum, 25 (1), 11-22.
- Güvenç M., 2006, Altın Piyasasında Arz-Talep ve Aktörler, *İstanbul Altın Borsası Yayınları*, İstanbul, 20-23.
- Hoppe D. J., 1972, How to invest in gold Stocks And Avoid the Pitfalls, New Rochelle, New York, 23-26.
- Hueffel J. A., 2021, Accelerated dinuclear palladium catalyst identification through unsupervised machine learning, *Science Dergisi*, sayı 374, 4-5.

- Jamil M. A., Khan A. A., Khanam S., 2021, Feature-based performance of SVM and KNN classifiers for diagnosis of rolling element bearing faults, *JVE Journals Vibroengineering Procedia*, Hindistan, Sayı 39, 37-38.
- Johnson D., 2021, Unsupervised Machine Learning: Algorithms, Types with Example [online], <https://www.guru99.com/unsupervised-machine-learning.html#4> [Ziyaret Tarihi: 10.02.2022].
- Karakoyun E. Ş., 2018, Derin Öğrenme ile Zaman Serilerinin Gerçek Zamanlı Tahmini, Yüksek lisans tezi, *Fen Bilimleri Enstitüsü*, Necmettin Erbakan Üniversitesi, 65.
- Kavzaoğlu T., Çölkesen İ., 2010, Karar Ağaçları ile Uydu Görüntülerinin Sınıflandırılması: Kocaeli Örneği, *Harita Teknolojileri Elektronik Dergisi*, 2(1), 36-45.
- Kaya U., Akba F, Medeni İ., Medeni T., 2020, Covid-19 Öncesi ve Sonrasındaki Bitcoin Fiyat Değişimlerinin Makine Öğrenmesi, Zaman Serileri Analizi ve Derin Öğrenme Yöntemleriyle Değerlendirilmesi, *Bilişim Teknolojileri Dergisi*, 13 (3) ,341-355.
- Keçeci E., 2020, Yinelemeli Sinir Ağları ile Finansal Veri Tahmini, Yüksek Lisans Tezi, *Fen Bilimleri Enstitüsü*, Hacettepe Üniversitesi, 34-35.
- Kemp S., 2022, Digital 2022: Big Rise in Cryptocurrency Ownership [online], <https://datareportal.com/reports/digital-2022-big-rise-in-cryptocurrency-ownership>, [Ziyaret Tarihi: 06.12.2022].
- Kocatepe C. İ. ,2017, Ekonomik Endeksler Kullanılarak Türkiye'deki Altın Fiyatındaki Değişim Yönünün Yapay Sinir Ağları ile Tahmini, Yüksek Lisans Tezi, *Bilişim Enstitüsü*, Gazi Üniversitesi, 45.
- Koç Ustalı N., Tosun, N., Tosun, Ö., 2021, Makine Öğrenmesi Teknikleri ile Hisse Senedi Fiyat Tahmini, *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 16(1), 1-16.
- Kotsiantis, S., 2007, Supervised machine learning: A review of classification techniques, *Informatica Dergisi*, 249-268.
- Lantz, B., 2013, Machine Learning with R. Olton, Packt Publishing, İngiltere, 160-188.
- Lbma, 2022, About The LBMA [online], <https://www.lbma.org.uk/about-us/about-the-lbma>, [Ziyaret Tarihi:08.02.2022].
- Mohri M., 2018, Foundations Machine Learning, second edition, *MIT Press Yayınları*, İngiltere,268.
- Muratlar E. R., 2021, Alternatif Regresyon Yöntemleri: Lasso Regresyon [online], <https://www.veribilimiokulu.com/lasso-regresyon/> [Ziyaret Tarihi: 15.04.2022].
- Nayak, S.K.; Nayak, S.C.; Das, S., 2022, Modeling and Forecasting Cryptocurrency Closing Prices with Rao Algorithm-Based Artificial Neural Networks: A Machine Learning Approach. *FinTech*, 2022 (1), 47–62.

- Nebil, F. S., 2018, Bitcoin ve Kripto Paralar, 1.Baskı, *Pusulula 20 Teknoloji ve Yayıncılık*, İstanbul, 27-30.
- Neyren O., 1996, Uygulamalı regresyon ve korelasyon analizi, *Nobel Akademik Yayıncılık*, İstanbul, 11-13.
- Nikolaus H., Huang R., 2011, Limit Order Flow, Market Impact and Optimal Order Sizes: Evidence From NASDAQ TotalView-ITCH Data, *Collaborative Research Center*, Berlin, 2011(056), 649.
- Nilsson N., 1965, *Learning Machines*, McGraw Hill.
- Öndes H., Oğuzlar A., 2019, Yapay Sinir Ağlarıyla Altın (Tl/Kg) Fiyatı Tahmini, *Akademik bakış Dergisi Sayı: 72*, 249-262.
- Öztürk E., 2020, Basit Doğrusal Regresyon Nedir? [online], <https://www.veribilimiokulu.com/basit-dogrusal-regresyon/> [Ziyaret Tarihi: 25.03.2022].
- Parisi, A., Parisi F. ve Diaz D. (2008). Forecasting Gold Price Changes: Rolling and Recursive Neural Network Models. *Journal of Multi. Fin. Manag.*, 18, 477-487.
- Pauly, L., 1997, *Who Elected the Bankers: Surveillance and Control in the World Economy*, Ithaca, NY: *Cornell University Press*.
- Pekcan E. ,1998, Altın Bankacılığı Borsası Rafinerisi ve Türkiye, *İstanbul Ticaret Odası Yayını*, İstanbul, 6-9.
- Pratt M.K. , 2020, Unsupervised Learning [online], <https://www.techtarget.com/searchenterpriseai/definition/unsupervised-learning>, [Ziyaret Tarihi:10.02.2022].
- O'callaghan G., 1993, *The Structure And Operation Of The World Gold Market International Monetart fund* , Washington DC, 3.
- Quinlan J.R., 1996, Improved Use Of Continuous Attributes in C4 5, *Journal of artificial intelligence Research*, 4,77-90.
- Rokach L., Maimon O., 2005, *Data Mining And Knowledge Discovery Handbook*, Springer, 165-192.
- Sağlam M. H., 1993, Dünya Borsalarında Vadeli Altın İşlemleri, *Scala yayıncılık*, 1.baskı İstanbul, 152-153.
- Sakarya, Ş., Yılmaz, U., 2019, Derin öğrenme mimarisi kullanarak BIST30 indeksinin tahmini. *European Journal of Educational and Social Sciences*, 4 (2), 106 – 121.
- Samuel L., 1959, *Some Studies in Machine Learning Using the Game of Checkers*.

- Sanchez E. G., 2017, Crypto-Currencies: The 21 St Century's Money Laundering And Tax Havens, *University of Florida Journal of Law & Public Policy*, Florida, 28(1), 167-168.
- Shannon C. E., 1948, A Mathematical Theory of Communication, *Reprinted with corrections from The Bell System Technical Journal*, Sayı:27, 379-423, 623-656.
- Shen S. , Jiang H., Zhang T., 2009, Stock Market Forecasting Using Machine Learning Algorithms, Stanford University, Amerika Birleşik Devletleri.
- Sureshkumar K.K, Elango Dr. N. M., 2012, Performance Analysis of Stock Price Prediction using Artificial Neural Network, *Global Journal of Computer Science and Technology dergisi*, 12 (1), 19-25.
- Şener Y.,2020, Polinomsal (Polynomial) Regresyon ve Python Uygulaması [online], <https://yigitsener.medium.com/polinomsal-polynomial-regresyon-ve-python-uygulamas%C4%B1-f742fb61a158> [Ziyaret Tarihi: 29.03.2022].
- Tekin, A. T., Özkale, L., & Ayhan, G., 2018, The Importance of R & D Investments in Information and Communication Technologies and Tax Policies Applied Through Information and Communication Technologies, *In International R&D, Innovation and Technology Management Congress*, İstanbul, 155-166.
- Thakur K. , Banik, D. G., 2018, Cryptocurrency: Its Risks and Gains and the Way Ahead, *IOSR Journal of Economics and Finance Volume*, Hindistan , 38-42.
- Tibshirani R., 1996, Regression Shrinkage and Selection via the Lasso , *Journal of the Royal Statistical Society. Series B (Methodological)* ,Kanada, 58(1), 267-288.
- TSPA KB, 2011, Sermaye Piyasası Algı ve Yatırım Potansiyeli Belirleme Araştırması [online]https://www.tspb.org.tr/wp-content/uploads/2015/06/ETM_baskanin_konusmalari_SP_algi_anketi_basin_sunumu_13042011.pdf [Ziyaret Tarihi: 25.03.2022].
- Yalçın S., 2016, Dolar, Euro ve Altın Fiyat Değişimlerinin Bist 30 Trendlerine Etkileri Üzerine Ampirik Bir Uygulama, Yüksek Lisans Tezi, *Sosyal Bilimler Enstitüsü İstanbul Arel Üniversitesi*, 99-101.
- Yamak R., 2019, Hayekyen Para Sisteminin Kripto Para Çerçevesinde Değerlendirilmesi, *Celepler Matbaacılık Yayın*, Trabzon, 235-247.
- Yayar R., Karaca S., 2011, Endeks Tahmini Ve İstanbul Menkul Kıymetler Borsası (İmkb) Sınâî Endeksi Üzerine Bir Uygulama, *Muhasebe Bilim Dünyası Dergisi*, İstanbul, 13(2), 163.
- Yıldırım C. U., 2016, İşletmelerde Döviz Kuru Tahmini Ve Bir Uygulama, Yüksek Lisans Tezi, *Sosyal Bilimler Enstitüsü*, Kocaeli Üniversitesi, 68-70.