

**T.C.  
GALATASARAY ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ  
İKTİSAT ANABİLİM DALI**

**COVID-19 PANDEMİSİ SÜRECİNDE BITCOİN,  
ALTIN VE S&P500 REAKSİYONLARI**

**YÜKSEK LİSANS TEZİ**

**Mahmut Yavuz Bahçeci**

**Tez Danışmanı: Doç. Dr. Ata Özkaya**

**AĞUSTOS 2023**

## ÖNSÖZ

Bu tez çalışmasının tamamlanmasında katkısı olan herkese teşekkür etmek istiyorum.

İlk olarak, tez danışmanım Sayın Doç. Dr. Ata Özkaya'ya özel olarak teşekkürlerimi sunmak istiyorum. Kendisinin yönlendirmeleri, bilgeliği ve sürekli desteği sayesinde bu çalışmayı başarıyla tamamlamak mümkün oldu. Galatasaray Üniversitesi Sosyal Bilimler Enstitüsü'nde İktisat Yüksek Lisansı sürecim boyunca bana sağladığı rehberlik ve değerli katkılar için kendisine minnettarım.

Tez sürecimde aldığım derslerin sorumlu öğretim görevlilerine teşekkür etmek istiyorum. Derslerindeki bilgi birikimleri, özenli eğitimleri çalışmamın niteliğini artırmada büyük rol oynadı. İktisat yüksek lisans eğitimimde edindiğim bilgi ve deneyimler, bu tez çalışmasını daha kapsamlı ve nitelikli hale getirmeme yardımcı oldu.

Lisans eğitimimi yine Galatasaray Üniversitesi'nde, Bilgisayar Mühendisliği alanında tamamlamış olmamın, ekonomi alanındaki yüksek lisans tez çalışmama farklı bir bakış açısı getirdiğinin farkındayım. Bu disiplinler arası geçiş, tez çalışmamı zenginleştiren ve farklı bir bakış açısı sunan önemli bir deneyim oldu.

Ayrıca, ekonomi alanındaki eğitimime ilham veren ve gönüllü olarak düzenlediği YouTube yayınlarıyla destekleyen Dr. Atilla Yeşilada'ya da teşekkürlerimi sunmak istiyorum. Onun sayesinde ekonomiye olan ilgim ve tutkum daha da arttı ve bu tez çalışmasının başarıyla tamamlanmasında büyük rol oynadı.

Son olarak, aileme ve sevdiklerime sonsuz teşekkürlerimi sunmak istiyorum. Onların sabırları, anlayışları ve destekleri, tez çalışmamı tamamlamak için güç ve motivasyon kaynağı oldu.

Bu tez çalışması, akademik hayatımda önemli bir aşama olmuştur ve gelecekteki çalışmalarım için temel bir referans kaynağı olacaktır. Umarım bu çalışma, ekonomi alanında yapılan araştırmalara katkı sağlar ve gelecek nesillerin daha ileri düzeyde bilgi ve anlayışa ulaşmasına yardımcı olur.

## İÇİNDEKİLER

### Sayfa No

1. GİRİŞ.....	1
1.1. Arkaplan.....	1
1.2. Çalışmanın Önemi.....	1
1.3. Araştırma Hedefi.....	1
1.4. Araştırma Soruları.....	2
1.5. Metodoloji.....	2
1.6. Çalışmanın Organizasyonu.....	2
2. LİTERATÜR TARAMASI.....	3
2.1. Giriş.....	3
2.2 Para Politikası Genişletmesinin Yatırım Aracı Fiyatlandırmasına Etkisi.....	3
2.2.1. Teorik Çerçevesler.....	3
2.2.2. Ampirik kanıtlar.....	4
2.2.3. İletim Kanalları.....	4
2.2.4. Sonuç.....	4
2.3. Kriz Sırasında Varlık Tepkileri.....	5
2.4. COVID-19 Pandemisi ve Varlık Tepkileri.....	5
2.5. Varlık Reaksiyonları için Modelleme Yaklaşımları.....	5
2.6. Modelleme Yaklaşımlarının Karşılaştırılması.....	5
2.7. Bitcoin'in Deterministik Arz Modeli ve Özellikleri.....	5
2.8. Literatürdeki Boşluklar.....	6
2.9. Özet.....	6
3. VERİ KÜMESİ VE METODOLOJİ.....	8
3.1. Veri Kümesi.....	8
3.1.1. Altın.....	8
3.1.1.1 COVID-19 Öncesi Veriler.....	8
3.1.1.2. COVID-19 Sonrası Veriler.....	9
3.1.2. S&P500.....	9
3.1.1.1. COVID-19 Öncesi Veriler.....	9
3.1.1.2. COVID-19 Sonrası Veriler.....	10
3.1.3. BITCOIN.....	10
3.1.3.1. COVID-19 Öncesi Veriler.....	10
3.1.3.2. COVID-19 Sonrası Veriler.....	11
3.2. Model Tanımı.....	11
3.2.1. GARCH (Genelleştirilmiş Otoregresif Koşullu Değişken Varyans).....	11
3.2.1.1. Algoritma.....	12
3.2.2. MS-GARCH (Markov-anahtarlamalı GARCH).....	13
3.2.2.1. Piyasa Şoku Denklemi.....	13
3.2.2.2. Tahmin.....	14
3.2.2.3. Algoritma.....	14
3.2.3. CNN (Evrışimli Sinir Ağı) Tahmini.....	15

3.2.3.1. Bırakma Katmanı.....	16
3.2.3.2. Algoritma.....	17
3.2.4. RNN (Tekrarlayan Sinir Ağı) Tahmini.....	18
3.2.4.1. Algoritma.....	19
3.3. Değerlendirme Metrikleri.....	21
3.4. Yatırım Varlığı Tepkilerini Analiz Etmek İçin CNN ve RNN Modellerinde Veri İçeri Tahmini Tercihini Kullanma.....	21
4. BULGULAR.....	22
4.1. ALTIN.....	22
4.1.1. COVID-19 Öncesi Sonuçlar.....	22
4.1.2. COVID-19 Sonrası Sonuçlar.....	23
4.2. S&P500.....	25
4.2.1. COVID-19 Öncesi Sonuçlar.....	25
4.2.2. COVID-19 Sonrası Sonuçlar.....	26
4.3. BITCOIN.....	27
4.3.1. COVID-19 Öncesi Sonuçlar.....	28
4.3.2. COVID-19 Sonrası Sonuçlar.....	29
5. TARTIŞMA VE ANALİZ.....	31
5.1. Veri Kümesine Genel Bakış.....	31
5.2. Çalışmada Kullanılan Modeller.....	31
5.2.1. GARCH (Genelleştirilmiş Otoregresif Koşullu Değişken Varyans).....	31
5.2.2. MS-GARCH (Markov-anahtarlamalı GARCH). ....	31
5.2.3. CNN (Evrışimli Sinir Ağı) Tahmini.....	31
5.2.4. RNN (Tekrarlayan Sinir Ağı) Tahmini.....	32
5.3. Değerlendirme Metrikleri.....	32
5.4. Sonuçların Analizi.....	32
5.5. Çıkarımlar ve Uygunluk.....	32
5.6. COVID-19 Döneminde Reaksiyon Farklılıklarının İncelenmesi.....	33
5.7. COVID-19 Öncesi ve Sonrası Varlıklar Arasındaki Benzerlik Analizi.....	34
6. SONUÇ.....	36
6.1. Bulguların Özeti.....	36
6.2. Modellerinin Tartışılması.....	36
6.3. Varlıkların Karşılaştırmalı Analizi.....	36
6.4. Bulguların Ekonomik Yorumu.....	37
6.5. Yatırım ve Risk Yönetimi İçin Etkileri.....	38
6.6. Sınırlamalar ve Gelecekteki Araştırmalar.....	39
7. ARAŞTIRMA KODU.....	41
7.1. Araştırma Kodu GitHub Erişimi.....	41
8. KAYNAKÇA.....	42

## ŞEKİL LİSTESİ

### Sayfa No

Şekil 3.1.1.1. Covid-19 Öncesi Altın Fiyat Grafiği.....	8
Şekil 3.1.1.2. Covid-19 Sonrası Altın Fiyat Grafiği.....	9
Şekil 3.1.2.1. Covid-19 Öncesi S&P500 Fiyat Grafiği.....	9
Şekil 3.1.2.2. Covid-19 Sonrası S&P500 Fiyat Grafiği.....	10
Şekil 3.1.3.1. Covid-19 Öncesi Bitcoin Fiyat Grafiği.....	10
Şekil 3.1.3.2. Covid-19 Sonrası Bitcoin Fiyat Grafiği.....	11
Şekil 4.1.1.1: CNN Modelinin, Covid-19 öncesi Altın Fiyat Tahmini Performansı..	23
Şekil 4.1.1.2: RNN Modelinin, Covid-19 öncesi Altın Fiyat Tahmini Performansı..	23
Şekil 4.1.2.1: CNN Modelinin, Covid-19 Sonrası Altın Fiyat Tahmini Performansı	24
Şekil 4.1.2.2: RNN Modelinin, Covid-19 Sonrası Altın Fiyat Tahmini Performansı	24
Şekil 4.2.1.2: CNN Modelinin, Covid-19 öncesi S&P500 Fiyat Tahmini Performansı.....	25
Şekil 4.2.1.3: RNN Modelinin, Covid-19 öncesi S&P500 Fiyat Tahmini Performansı.....	26
Şekil 4.2.2.2: CNN Modelinin, Covid-19 Sonrası S&P500 Fiyat Tahmini Performansı.....	27
Şekil 4.2.2.3: RNN Modelinin, Covid-19 Sonrası Altın Fiyat Tahmini Performansı	27
Şekil 4.3.1.2: CNN Modelinin, Covid-19 öncesi Bitcoin Fiyat Tahmini Performansı.....	28
Şekil 4.3.1.3: RNN Modelinin, Covid-19 öncesi Bitcoin Fiyat Tahmini Performansı.....	29
Şekil 4.3.2.2: CNN Modelinin, Covid-19 Sonrası Bitcoin Fiyat Tahmini Performansı.....	30
Şekil 4.3.2.3: RNN Modelinin, Covid-19 Sonrası Bitcoin Fiyat Tahmini Performansı.....	30

## SEMBOL LİSTESİ

<b>CNN :</b>	Evrişimli Sinir Ağı (Convolutional Neural Network)
<b>GPU :</b>	Grafik İşlem Birimi (Graphics Processing Unit)
<b>GRU :</b>	Gated Recurrent Unit
<b>LSTM :</b>	Uzun Kısa Süreli Bellek (Long Short-Term Memory)
<b>MAPE :</b>	Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)
<b>MSE :</b>	Ortalama Karesel Hata (Mean Squared Error)
<b>N_LAGS :</b>	Zaman Serisindeki Girdi Uzunluğu (Number of Lags)
<b>ReLU :</b>	Doğrusal Olmayan Doğrusal Birim (Rectified Linear Unit)
<b>RMSE :</b>	Kök Ortalama Karesel Hata (Root Mean Squared Error)
<b>RNN :</b>	Tekrarlayan Sinir Ağı (Recurrent Neural Network)
<b>GARCH:</b>	Genelleştirilmiş Otoregresif Koşullu Değişken Varyans
<b>MS-GARCH:</b>	Markov-anahtarlamalı GARCH
$r_{\{t-1\}}$ :	t-1 zamanındaki karesel getiri; bu, t-1 ve t-2 anındaki log fiyatlarının karesi arasındaki farktır
$z_t$ :	t zamanındaki piyasa şoku terimi
$\alpha_i, \beta_j$ :	Sırasıyla karesi alınmış artıkların ( $\epsilon^2$ ) ve geçmiş koşullu varyansların ( $\sigma^2$ ) katsayıları
$\alpha$ :	GARCH modelindeki gecikmeli kare getirisinin katsayısı
$\beta$ :	GARCH modelindeki gecikmeli koşullu varyansın katsayısı
$\gamma$ :	Piyasa şokunun katsayısı
$\gamma$ :	Piyasa şokunun katsayısı
$\sigma_{\{t\}}^2$ :	t zamanındaki koşullu varyans
$\sigma_{\{t-1\}}$ :	t-1 zamanındaki koşullu varyans
$\sigma_t^2$ :	tt zamanındaki koşullu varyans
$\omega$ :	GARCH modelinin kesme (sabit) terimi

**DENKLEM LİSTESİ**

	<b>Sayfa No</b>
<b>Denklem 3.2.1.</b> GARCH modelinin denklemi.....	11
<b>Denklem 3.2.2</b> Koşullu Varyans Denklemi.....	13
<b>Denklem 3.2.3.1.</b> Evrişimli Katman.....	15
<b>Denklem 3.2.3.2.</b> Maksimum Havuzlama Katmanı.....	16
<b>Denklem 3.2.3.3.</b> Katmanı Düzleştir.....	16
<b>Denklem 3.2.3.4.</b> Birinci Tamamen Bağlı Katman.....	16
<b>Denklem 3.2.3.4.</b> İkinci Tamamen Bağlı Katman (Çıktı Katmanı) .....	16
<b>Denklem 3.2.4.1.</b> Input Denklemi (RNN Katmanı) .....	19
<b>Denklem 3.2.4.2.</b> Output Denklemi (Tam Bağlı Katman).....	19

**TABLO LİSTESİ**

	<b>Sayfa No</b>
<b>Tablo 4.1</b> ALTIN Tahmin Sonuçları.....	22
<b>Tablo 4.2</b> S&P500 Tahmin Sonuçları.....	25
<b>Tablo 4.3</b> BITCOIN Tahmin Sonuçları.....	27



## ÖZET

### 1. Giriş

COVID-19 salgını, 2020'nin başlarında küresel finans piyasalarını ve ekonomiyi büyük ölçüde etkiledi. Bu belirsiz dönemdeki varlık tepkilerini anlamak büyük önem taşıyor. Pandemi, yatırımcı duyarlılığını değiştirdi ve varlık fiyatlarında dalgalanmalara neden oldu. Bu çalışma, bu değişken ortamda Altın, S&P500 ve Bitcoin gibi temsili varlıkların tepkilerini incelemeyi amaçlamaktadır. Seçilen varlıklar, popülerlikleri ve piyasalardaki temsilleri nedeniyle önemlidir.

Araştırmada varlıkların tepkilerini değerlendirmek ve anlamak için GARCH, MS-GARCH, CNN, RNN gibi çeşitli modellerden yararlanılmıştır. Bu modellerin performansları, benzerlik ve farklılıklarını belirlemek için Koşullu Volatilité Tahmini ve MAPE gibi ölçüm metrikleri ile analiz edilmiştir. Bu analiz, piyasa katılımcılarının kriz durumlarında farklı varlıkların nasıl tepki verebileceğini daha iyi anlamalarına ve stratejilerini buna göre şekillendirmelerine yardımcı olabilir.

Bu çalışma sadece yatırımcılar için değil aynı zamanda finansal kurumlar ve politika yapıcılar için de kritiktir. Yatırımcılar, pandemi sırasında varlıkların nasıl performans gösterdiğine dair daha derin bir anlayış kazanmak için çalışmanın bulgularından yararlanabilir. Finansal kuruluşlar, risk yönetimi stratejilerini geliştirmek için bu bilgilere başvurabilir. Ayrıca, politika yapıcılar bu analizler sayesinde mevcut ve gelecekteki krizleri daha etkin yönetmek için stratejiler üretebilirler.

Genel olarak bu araştırma, varlıkların COVID-19 salgını sırasında nasıl tepki verdiğini kapsamlı bir şekilde analiz ederek piyasa katılımcılarına önemli bilgiler sağlamayı amaçlamaktadır. Altın, S&P500 ve Bitcoin'in tepkilerindeki benzerliklerin ve farklılıkların spesifik olarak belirlenmesi, bu varlıkların kriz durumlarındaki performansı hakkında değerli bilgiler sunar.

### 2. Literatür Taraması

Bu bölüm, özellikle COVID-19 salgınına odaklanarak, krizler sırasında varlık tepkileriyle ilgili literatürün kapsamlı bir incelemesini sunar. Kriz dönemlerinde varlık davranışları, temel teorilerin, kavramların ve önceki bulguların analizi yoluyla belirlenir. Çeşitli çalışmaların gösterdiği gibi, finansal piyasalar genellikle bu zamanlarda artan oynaklık ve belirsizlik yaşar. Örneğin, büyük borsa endekslerinin 2008 küresel mali krizine verdiği tepkiler, piyasalar içinde ve arasında birbirine bağlılığı ve bulaşıcı etkileri vurguladı.

COVID-19 salgını, küresel finans piyasalarını benzeri görülmemiş şekillerde derinden etkileyen benzersiz bir kriz senaryosu ortaya çıkardı. Son araştırmalar, bu dönemde varlık dinamiklerine ve sonuçlarına ışık tutuyor. Altın, güvenli liman davranışı gösterdi ve Bitcoin, özellikle pandeminin ilk aşamalarında yüksek oynaklık sergiledi. Ayrıca, hisse senedi piyasaları başlangıçta sert düşüşler yaşarken, devlet tahvili ve Altın güvenli liman olarak hizmet vererek kriz sürecinde olumlu tepkiler verdi. Ancak, petrol gibi enerji emtiaları önemli olumsuz etkilerle karşı karşıya kaldı.

Krizler sırasında varlık tepkilerini analiz etmek ve tahmin etmek için GARCH ve MS-GARCH gibi geleneksel ekonometrik modeller ve Konvolüsyonel Sinir Ağları (CNN) ve Tekrarlayan Sinir Ağları (RNN) gibi derin öğrenme modelleri dahil olmak üzere çeşitli modelleme yaklaşımları kullanılmıştır. Karşılaştırmalı araştırmalar, derin öğrenme modellerinin, özellikle CNN ve RNN'nin, doğrusal olmayan ilişkileri ve karmaşık kalıpları yakalamada geleneksel modellerden daha iyi performans gösterdiğini ortaya koymuştur.

Ancak, literatürde boşluklar devam etmektedir. Pandeminin tamamını kapsayan daha kapsamlı analizlere, modelleme yaklaşımlarına ilişkin ayrıntılı karşılaştırmalı çalışmalara ve birden fazla varlık sınıfının pandemi sırasındaki tepkilerini kapsayan araştırmalara ihtiyaç var. COVID-19 salgını sırasında önemli olan politika müdahalelerinin etkisi, varlık yanıtları üzerindeki etkileri açısından yeterince araştırılmamıştır.

Sonuç olarak, bu bölüm, özellikle COVID-19 salgını sırasında olmak üzere krizler sırasında varlık tepkilerine ilişkin en yeni ve önemli literatürü gözden geçirirken, varlık tepkilerinin ayrıntılı bir analizini ve karşılaştırmalı bir incelemeyi amaçlayan sonraki bölümlerin ele alacağı mevcut boşlukları da vurgulamaktadır.

### **3. Veri Kümesi ve Metodoloji**

3. Bölüm'de araştırma, oynaklığı ölçmek ve zaman serilerini tahmin etmek için kullanılan metodolojileri sunar. Analiz altındaki veri seti, çeşitli finansal piyasaları temsil etmeleri için seçilen Altın, S&P500 ve Bitcoin (BTC) dahil olmak üzere varlıkları içerir. Altın, istikrar ve enflasyon korumasıyla bilinen güvenli bir sığınak örneğidir. S&P500 endeksi, ABD'de halka açık ilk 500 şirketin performansını yansıtarak borsanın genel sağlığına ilişkin içgörüler sunuyor. İlk kripto para birimi olan Bitcoin, gelişen dijital varlık piyasasına benzersiz bir bakış açısı sunuyor. Veriler, değişen piyasa koşullarında model performansını değerlendirmeyi amaçlayan, COVID-19 öncesi parasal genişleme ve COVID-19 sonrası parasal genişleme olmak üzere iki farklı aşamayı kapsıyor.

Analizin merkezinde yer alan dört model arasında GARCH (Genelleştirilmiş Otoregresif Koşullu Değişken Varyans), MS-GARCH (Markov-anahtarlamalı GARCH), CNN (Evrışimli Sinir Ağı) tahmini ve RNN (Tekrarlayan Sinir Ağı) tahmini yer alır. GARCH modeli, finansal zaman serisi verilerindeki koşullu değişken varyansı bulmak için kullanılır ve MS-GARCH, oynaklık rejimi anahtarlarını dahil ederek bunu genişletir. Başlangıçta görüntü tanıma görevleri için tasarlanan CNN tahmini, zaman serilerini tahmin etmek için uyarlanırken, RNN tahmini de uzun vadeli varlık fiyatı dinamiklerini ortaya çıkarmaya yardımcı olan sıralı veriler için uygundur.

CNN ve RNN Modellerinin performansını değerlendirmek için kullanılan değerlendirme ölçümleri, öncelikle Ortalama Mutlak Yüzde Hatasına (MAPE) odaklanır ve daha düşük bir MAPE, daha iyi tahmin doğruluğunu gösterir. Ortalama Kare Hatanın Kökü (RMSE) ve Ortalama Mutlak Hata (MAE) gibi diğer ölçümlerin de performansı nesnel olarak karşılaştırmak ve her bir yaklaşımın güçlü yanlarını ve sınırlamalarını anlamak için dikkate alınır.

Metodoloji öncelikle tahmin modellerinin teknik yönlerine odaklanmayı değil, ekonomik yorumlar ve çıkarımlar sağlamayı amaçlar. Modellerin performansını farklı varlıklar ve zaman dilimlerinde analiz etmek, seçilen varlıkların çeşitli piyasa koşullarındaki davranışlarına ilişkin içgörüler sağlar. Bu tür içgörüler, yatırım kararları, risk yönetimi stratejileri ve portföy optimizasyon teknikleri için bilgi sağlayabilir. Araştırma, teknik analiz ile ekonomik yorum arasındaki uçurumu kapatmayı ve finans sektöründe hem akademik araştırmalara hem de pratik karar vermeye katkıda bulunmayı amaçlıyor.

#### 4. Bulgular

Bu bölümde, daha önce açıklanan metodolojinin bir veri seti üzerinde uygulanmasından elde edilen sonuçlar sunulmaktadır. Sonuçlar, GARCH ve MS-GARCH modellerinin volatilité tahmin performansına ve ayrıca CNN ve RNN modellerinin üç varlık için fiyat tahmin kapasitelerine ilişkin bilgiler sağlar. Altın, S&P500 ve Bitcoin. Oynaklık ve fiyat tahmin doğruluğundaki varyasyonları ayırt etmek için sonuçlar, COVID-19'un patlak vermesinden önceki ve sonraki dönemler için ayrı ayrı analiz edilir.

Altın için, COVID-19'dan önce 0,007 oynaklık gösteriyordu. Hem CNN hem de RNN derin öğrenme modelleri umut verici sonuçlar verdi; CNN, %0,01 MAPE ve 289,76 MSE (RMSE: 17,02) ve RNN, %0,01 MAPE ve 465,8504 MSE (RMSE: 21,5836)'de tahminler verdi.

COVID-19 sonrası dönemde Altın için 0,0117'lik bir oynaklığı ortaya çıkardı. CNN modeli %0,01 MAPE ve 449,12 MSE (RMSE: 21,19) ile tahmin yaparken, RNN %0,01 MAPE ve 601,4707 MSE (RMSE: 24,5249) ile sonuç verdi. GARCH Modeli tahmini, 0,079 iken MS-GARCH 0,1171 olarak tahmin etmiştir.

Pandemi öncesi S&P500'e bakıldığında modeli ise 0.0083 volatilité gösteriyordu. CNN ve RNN modelleri sırasıyla %0,01 MAPE ve 1691,55 MSE (RMSE: 41,13) ve %0,01 MAPE ve 3011,0630 MSE (RMSE: 54,8732) ile tahmin edildi.

Salgından sonra, 0.0166'lık bir oynaklık sergiledi. CNN tahminleri %0,01 MAPE ve 1447,73 MSE (RMSE: 38,05), RNN ise %0,01 MAPE ve 2494,7517 MSE (RMSE: 49,9475) idi. GARCH Modeli tahmini, 0.051 iken MS-GARCH 0,66 olarak tahmin etmiştir.

Bitcoin için, COVID-19'dan önce volatilité 0.0426'daydı. CNN tahminleri %0,02 MAPE ve 56503,24 MSE (RMSE: 237,70) ve RNN %0,03 MAPE ve 79358,1302 MSE (RMSE: 281,7058) olarak gerçekleşti.

Sonraki dönemde, 0.0409 volatilité sergiledi. CNN, %0,02 MAPE ve 546732,75 MSE (RMSE: 739,41) ve RNN, %0,02 MAPE ve 701246,3775 MSE (RMSE: 837,4045) ile sonuç verdi. GARCH Modeli tahmini, 0.035 iken MS-GARCH 0,38 olarak tahmin etmiştir.

## 5. Tartışma ve Analiz

Bu bölümde GARCH, MS-GARCH sonuçlarını ve CNN ve RNN modellerinin Altın, S&P500 ve Bitcoin davranışını tahmin etme performansını analiz ediyoruz. Veri seti, COVID-19 öncesi ve sonrası dönemleri kapsıyor ve pandeminin volatilité modelleri ve tahminleri üzerindeki etkisini değerlendirmemizi sağlıyor.

GARCH, her iki dönem için varlık oynaklığına ilişkin öngörüler sağladı, ancak doğru tahminleri gerçekleştiremedi. MS-GARCH, rejim değişikliklerini yakalayarak COVID-19 öncesi ve sonrasındaki farklı oynaklık modellerini gösterir.

CNN ve RNN modelleri iyi performans göstererek tüm varlıklar için umut verici tahmin performansı gösterdi. Karmaşık kalıpları etkili bir şekilde yakaladı ve piyasadaki aksamalar sırasında uyarlanabilirlik sergiledi.

Sonuçlar, CNN ve RNN gibi gelişmiş makine öğrenimi teknikleriyle iyileştirilmiş finansal tahminleri içerir. COVID-19'un varlık oynaklığı üzerindeki etkisini anlamak, risk değerlendirmesi ve finansal karar verme için hayati önem taşır.

COVID-19 sırasındaki reaksiyon farklılıklarının analizi, COVID-19'dan sonra Altın ve S&P500 için artan oynaklıkları ortaya koyuyor.

Bitcoin her iki dönemde de daha yüksek volatilité sergiliyor. Ancak diğer ikisinden farklı olarak Bitcoin, COVID-19 sonrasında daha az volatilité gösteriyor.

Altın, S&P500 ve Bitcoin'in öngörülebilirlik davranışını analiz ederken, COVID-19 sonrası dönem belirgin farklılıklar ortaya çıkardı; COVID-19'dan önce Altın, düşük oynaklığı göz önüne alındığında nispeten istikrarlı bir varlık olarak kabul edilebilirdi. Bununla birlikte, COVID-19 sonrası oynaklığı arttı ve bu da öngörülemezliğe doğru bir kayma olduğunu gösteriyor. Bu, yalnızca oynaklıkta önemli bir artış görmeye kalmayan, aynı zamanda üçü arasında en değişken hale gelen S&P500 ile tam bir tezat oluşturuyor. Bitcoin ise tersine şaşırtıcı bir davranış sergiledi: Tarihsel olarak değişken doğasına rağmen, COVID-19 sonrası gerçekleşen oynaklığı bir miktar azaldı.

COVID-19 sonrası dönem, bu varlıklar için tahmin hatalarındaki farklılıkları da vurguladı. Hem Altın hem de Bitcoin, artan tahmin hataları yaşarken, S&P500'ün tahmin doğruluğu, azalan MSE (RMSE) değerlerinin kanıtladığı gibi, görünüşte iyileşti. Pandemiden önce öngörülebilirlikteki farklılıklar bu kadar belirgin olmayabilirdi, ancak COVID-19 sonrası bu farklılıklar daha belirgin hale geldi.

Altın, S&P500 ve Bitcoin'in öngörülebilirlik davranışını analiz ederken, COVID-19 sonrası dönem belirgin farklılıklar ortaya çıkardı; COVID-19'dan önce Altın, düşük oynaklığı göz önüne alındığında nispeten istikrarlı bir varlık olarak kabul edilebilirdi. Bununla birlikte, COVID-19 sonrası oynaklığı arttı ve bu da öngörülemezliğe doğru bir kayma olduğunu gösteriyor. Bu, yalnızca oynaklıkta

önemli bir artış görmeye kalmayan, aynı zamanda üçü arasında en değişken hale gelen S&P500 ile tam bir tezat oluşturuyor. Bitcoin ise tersine şaşırtıcı bir davranış sergiledi: Tarihsel olarak değişken doğasına rağmen, COVID-19 sonrası gerçekleşen oynaklığı bir miktar azaldı.

COVID-19 sonrası dönem, bu varlıklar için tahmin hatalarındaki farklılıkları da vurguladı. Hem Altın hem de Bitcoin, artan tahmin hataları yaşarken, S&P500'ün tahmin doğruluğu, azalan MSE (RMSE) değerlerinin kanıtlandığı gibi, görünüşte iyileşti. Pandemiden önce öngörülebilirlikteki farklılıklar bu kadar belirgin olmayabilirdi, ancak COVID-19 sonrası bu farklılıklar daha belirgin hale geldi.

Çalışma, finansal tahmin için derin öğrenmenin faydalarını, COVID-19'un varlık oynaklığı üzerindeki etkisini ve tahmin modellerinde istisnai dönemleri dikkate almanın önemini vurguluyor. Varlıklar arası korelasyonları anlamak, bilinçli ve esnek finansal kararlar için portföy çeşitlendirme stratejilerini geliştirir.

## 6. Sonuç

Bu Bölümde, COVID-19 öncesi ve COVID-19 sonrası dönemlerde varlık fiyatlarını (Altın, S&P500 ve Bitcoin) tahmin etmek için GARCH, MS-GARCH, CNN ve RNN dahil olmak üzere çeşitli tahmin modellerinin ayrıntılı bir analizini sunduk. Modellerin doğruluğu, Ortalama Mutlak Yüzde Hatası (MAPE) ve Ortalama Hatanın Karesi (MSE) gibi değerlendirme kriterleri kullanılarak değerlendirildi. Ek olarak, GARCH ve MS-GARCH modellerinin gerçekleşen ve koşullu oynaklığını analiz ettik.

Bulgular, MS-GARCH modelinin GARCH Modelinden daha iyi performans gösterdiğini, CNN modellerinin tahmin doğruluğu açısından daha iyi performans gösterdiğini ortaya koydu. Bu, derin öğrenme modelinin, varlık fiyatlarının karmaşık modellerini ve dinamiklerini yakalamada üstün tahmin yetenekleri sergilediğini göstermektedir.

COVID-19 öncesi dönemde, her üç varlık da (Altın, S&P500 ve Bitcoin) farklı oynaklık ve tahmin performansı modelleri sergiledi. Geleneksel olarak güvenli liman varlığı olarak kabul edilen Altın, S&P500 ve Bitcoin'e kıyasla nispeten daha düşük oynaklık gösterdi. S&P500 tarafından temsil edilen borsa daha yüksek oynaklık yaşadı ancak nispeten daha yüksek öngörülebilirlik gösterdi.

Bir kripto para birimi olarak Bitcoin, tahmin modelleri için hem zorluklar hem de fırsatlar sunarak en yüksek volatilitiyi sergiledi.

COVID-19 sonrası dönemde, pandemi varlık dinamiklerini önemli ölçüde etkiledi. Altın güvenli liman statüsünü korurken, volatilitiyeyi COVID-19 öncesi döneme göre önemli ölçüde arttı. S&P500 ayrıca, pandeminin neden olduğu ekonomik belirsizlikleri yansıtan yüksek volatilitiyeyi yaşadı. Bitcoin, dış olaylara ve yatırımcı duyarlılığına duyarlı, yüksek oynaklık sergilemeye devam etti.

Bulguların ekonomik yorumu, COVID-19 salgını gibi ekonomik türbülans dönemlerinde, Altın gibi geleneksel güvenli liman varlıkların, diğer varlıklardan nispeten daha düşük olsa da, artan oynaklık yaşama eğiliminde olduğunu vurgulamaktadır. S&P500 tarafından temsil edilen borsa, daha yüksek öngörülebilirliğe rağmen, önemli bir oynaklıkla karşı karşıyadır. Kripto para birimi

olarak Bitcoin, piyasa hassasiyetlerine ve dış etkilere karşı hassas, en yüksek volatilitiyi sergiliyor.

CNN ve RNN modellerinin varlık fiyatlarını tahmin etmedeki üstün performansı, verilerdeki karmaşık kalıpları ve bağımlılıkları yakalama yeteneklerine bağlanabilir. Bu derin öğrenme modelleri, piyasa dinamiklerine ilişkin değerli içgörüler sağlama ve yatırımcılar ile analistler için veriye dayalı kararları kolaylaştırma potansiyeline sahiptir.

Bulguların çıkarımları, yatırım ve risk yönetimi stratejileri için önemlidir. CNN ve RNN modellerinin üstün tahmin doğruluğu, derin öğrenme tekniklerinin birleştirilmesinin varlık fiyatı tahminlerinin kesinliğini artırabileceğini ve yatırımcıların portföy tahsisi ve risk yönetimi stratejilerini optimize etmesine olanak tanıdığını gösteriyor.

Ayrıca, oynaklık modellerinin ve tahmin hatalarının analizi, yatırım fırsatlarının ve piyasa oynaklığıyla ilişkili potansiyel risk faktörlerinin belirlenmesine yardımcı olabilir. Çeşitli ekonomik dönemlerde farklı varlıkların benzersiz özelliklerini anlamak, etkin portföy çeşitlendirmesine olanak tanır ve piyasa oynaklığıyla ilişkili potansiyel riskleri azaltır.

Çalışmanın sınırlamaları kabul edilmelidir. Analiz, geçmiş verilere dayanıyordu ve gelecekteki piyasa koşulları, tahmin modellerinin performansını etkileyerek önemli ölçüde farklılık gösterebilir. Ek olarak, çalışma belirli bir varlık grubuna (Altın, S&P500 ve Bitcoin) odaklandı ve bulgular diğer finansal araçlara genellenemez.

Gelecekteki araştırmalar, diğer gelişmiş tahmin modellerinin uygulamalarını keşfedebilir ve farklı piyasa koşullarında performanslarını değerlendirebilir. Devlet politikaları veya jeopolitik faktörler gibi dış olayların varlık fiyatları üzerindeki etkisinin araştırılması, dinamiklerinin daha kapsamlı bir şekilde anlaşılmasını sağlayabilir.

## 7. Araştırma Kodu

Şeffaflığı ve tekrar üretilebilirliği kolaylaştırmak için bu çalışmanın araştırma kodu GitHub'da mevcuttur. Kod, modelleme yaklaşımlarının uygulanmasını ve COVID-19 salgını sırasında varlık yanıtlarının analizini içerir. Araştırmacılar ve ilgili okuyucular, aşağıdaki bağlantıyı ziyaret ederek deneylere erişebilir ve deneyleri çoğaltabilir:

Bahçeci, Y. (2023). **Covid-19 Pandemisi Sürecinde Bitcoin, Altın ve S&P500 Reaksiyonları** için Araştırma Kodu GitHub deposu Erişim:

<https://github.com/yavuzBahceci/MsWorks/tree/main/msCodes>

Bu araştırma kodu, bu çalışmada kullanılan metodoloji ve veri analizi teknikleri hakkında ek bilgi sağlar. Modelleme yaklaşımlarının daha ayrıntılı incelenmesine olanak tanır ve bu araştırmada sunulan sonuç ve bulguların doğrulanmasını kolaylaştırır.

## 8. Kaynakça

Kaynakça bölümü, araştırma makalesi boyunca atıfta bulunulan veya atıfta bulunulan tüm kaynakların, yayınların ve çalışmaların kapsamlı bir listesini sağlayan çok önemli bir bileşendir. Bu bölüm, diğer araştırmacıların ve kaynakların katkılarına teşekkür etmek, çalışmanın eksiksizliğini göstermek ve okuyucuların daha fazla çalışma ve doğrulama için belirtilen materyallere erişmelerini sağlamak için gereklidir.



## **ABSTRACT**

### **1. Introduction**

The COVID-19 pandemic greatly affected the global financial markets and economy in early 2020. Understanding asset responses during this uncertain period is crucial. The pandemic has shifted investor sentiment and caused fluctuations in asset prices. This study aims to examine the reactions of representative assets such as Gold, S&P500 and Bitcoin in this volatile environment. The selected assets are important because of their popularity and representation in the markets.

In the research, various models such as GARCH, MS-GARCH, CNN, RNN were used to evaluate and understand the reactions of the entities. The performances of these models were analyzed with measurement metrics such as Conditional Volatility Estimation and MAPE to determine their similarities and differences. This analysis can help market participants better understand how different assets might react in crisis situations and tailor their strategies accordingly.

This work is critical not only for investors but also for financial institutions and policy makers. Investors can benefit from the study's findings to gain a deeper understanding of how assets are performing during the pandemic. Financial institutions can refer to this information to develop their risk management strategies. In addition, policy makers can generate strategies to manage current and future crises more effectively, thanks to these analyses.

Overall, this research aims to provide important insights to market participants by comprehensively analyzing how assets are responding during the COVID-19 pandemic. Specific identification of similarities and differences in the responses of GOLD, S&P500, and Bitcoin provides valuable insight into the performance of these assets in crisis situations.

### **2. Literature Review**

This section provides a comprehensive review of the literature on asset responses during crises, with a particular focus on the COVID-19 outbreak. Asset behavior during times of crisis, particularly GOLD, S&P500 and Bitcoin, is determined through analysis of key theories, concepts and previous findings. As various studies show, financial markets often experience increased volatility and uncertainty during these times. For example, the responses of major stock market indices to the 2008 global financial crisis highlighted the interconnectedness and contagious effects within and between markets.

The COVID-19 pandemic has unleashed a unique crisis scenario that has profoundly impacted global financial markets in unprecedented ways. Recent research

sheds light on asset dynamics and results in this period. Gold showed safe-haven behavior and Bitcoin exhibited high volatility, especially in the early stages of the pandemic. Also, while stock markets initially experienced sharp declines, government bonds and gold responded positively during the crisis, serving as a safe haven. However, energy commodities such as oil faced significant negative impacts.

Various modeling approaches have been used to analyze and predict asset responses during crises, including traditional econometric models such as GARCH and MS-GARCH, and deep learning models such as Convolutional Neural Networks (CNN) and Recurrent Neural Networks (RNN). Comparative research has revealed that deep learning models, especially CNN and RNN, outperform traditional models in capturing nonlinear relationships and complex patterns.

However, gaps remain in the literature. There is a need for more comprehensive analyzes covering the entire pandemic, detailed comparative studies of modeling approaches, and research covering the responses of multiple asset classes during the pandemic. The impact of policy interventions that are important during the COVID-19 pandemic has not been adequately explored in terms of their impact on asset responses.

As a result, this chapter reviews the most recent and important literature on asset responses during crises, particularly during the COVID-19 pandemic, while also highlighting existing gaps that the next sections will address, aiming for a detailed analysis and comparative review of asset responses.

### **3. Dataset and Methodology**

In Chapter 3, the research presents the methodologies used to measure volatility and estimate time series. The dataset under analysis includes assets including Gold, S&P500 and Bitcoin (BTC) that have been chosen to represent various financial markets. Gold is an example of a safe haven, known for its stability and inflation protection. The S&P500 index provides insights into the overall health of the stock market, reflecting the performance of the top 500 publicly traded companies in the US. As the first cryptocurrency, Bitcoin offers a unique perspective on the burgeoning digital asset market. The data cover two different phases, pre-COVID-19 quantitative easing and post-COVID-19 quantitative easing, which aim to evaluate model performance in changing market conditions.

The four models at the center of the analysis include GARCH (Generalized Autoregressive Conditional Variable Variance), MS-GARCH (Markov-switched GARCH), CNN (Convolutional Neural Network) estimation, and RNN (Repetitive Neural Network) estimation. The GARCH model is used to find conditional variance in financial time series data, and MS-GARCH extends this by including volatility regime keys. Originally designed for image recognition tasks, CNN forecasting is adapted to forecast time series, while RNN forecasting is suitable for ordinal data that helps reveal long-term asset price dynamics.

Evaluation metrics used to evaluate the performance of CNN and RNN Models primarily focus on Mean Absolute Percent Error (MAPE) and a lower MAPE indicates better prediction accuracy. Other metrics such as Root of Mean Squared Error (RMSE)

and Average Absolute Error (MAE) are also considered to objectively compare performance and understand the strengths and limitations of each approach.

The methodology is primarily aimed at providing economic interpretations and inferences, not focusing on the technical aspects of forecasting models. Analyzing the performance of models across different assets and timeframes provides insights into the behavior of selected assets in various market conditions. Such insights can inform investment decisions, risk management strategies and portfolio optimization techniques. The research aims to bridge the gap between technical analysis and economic interpretation and contribute to both academic research and practical decision making in the financial sector.

#### 4. Findings

This section presents the results obtained from applying the previously described methodology on a data set. The results provide insights into the forecast performance of the GARCH and MS-GARCH models using volatility data, as well as the forecasting capacities of the CNN and RNN models for three assets: Gold, S&P500 and Bitcoin. The results are analyzed separately for the periods before and after the COVID-19 outbreak to distinguish between variations in volatility patterns and forecast accuracy.

For gold, it was showing volatility of 0.007 before COVID-19. Both CNN and RNN deep learning models showed promising results; CNN gave estimates at 0.01% MAPE and 289.76% MSE (RMSE: 17.02) and RNN at 0.01% MAPE and 465.8504 MSE (RMSE: 21.5836).

It revealed a volatility of 0.0117 for Gold in the post-COVID-19 era. The CNN model predicted 0.01% MAPE and 449.12% MSE (RMSE: 21.19), while RNN gave 0.01% MAPE and 601.4707 MSE (RMSE: 24.5249). The GARCH Model estimate was 0.079, while MS-GARCH estimated it at 0.1171.

Looking at the S&P500 before the pandemic, its model showed 0.0083 volatility. CNN and RNN models were estimated with 0.01% MAPE and 1691.55 MSE (RMSE: 41.13) and 0.01% MAPE and 3011.0630 MSE (RMSE: 54.8732), respectively.

After the pandemic, it exhibited a volatility of 0.0166. CNN estimates were 0.01% MAPE and 1447.73 MSE (RMSE: 38.05), while RNN was 0.01% MAPE and 2494.7517 MSE (RMSE: 49.9475). The GARCH Model estimate was 0.051, while MS-GARCH estimated it to be 0.66.

For Bitcoin, volatility was at 0.0426 before COVID-19. CNN estimates were 0.02% MAPE and 56503.24 MSE (RMSE: 237.70) and RNN 0.03% MAPE and 79358.1302 MSE (RMSE: 281.7058).

In the following period, it exhibited 0.0409 volatility. CNN resulted in 0.02% MAPE and 546732.75 MSE (RMSE: 739.41) and RNN with 0.02% MAPE and 701246.3775 MSE (RMSE: 837.4045). The GARCH Model estimate was 0.035, while MS-GARCH estimated it at 0.38.

## 5. Discussion and Analysis

In this section, we analyze the GARCH, MS-GARCH results and the performance of the CNN and RNN models to predict the behavior of Gold, S&P500 and Bitcoin. The dataset covers the pre- and post-COVID-19 periods and allows us to evaluate the impact of the pandemic on volatility models and forecasts.

GARCH provided insights on asset volatility for both periods, but failed to deliver accurate forecasts. MS-GARCH captures regime changes, showing different patterns of volatility before and after COVID-19.

CNN and RNN models outperform GARCH and MS-GARCH, showing promising predictive performance for all assets. It effectively captured complex patterns and demonstrated adaptability during market disruptions.

Results include financial forecasts enhanced by advanced machine learning techniques such as CNN and RNN. Understanding the impact of COVID-19 on asset volatility is vital for risk assessment and financial decision making.

Analysis of reaction differences during COVID-19 reveals increased volatility for all assets post-COVID-19. Gold and Bitcoin exhibit higher correlations in both periods, showing similar volatility patterns and joint action. The S&P500 shows weaker correlations with Gold and Bitcoin due to different underlying factors.

The study highlights the benefits of deep learning for financial forecasting, the impact of COVID-19 on asset volatility, and the importance of considering exceptional periods in forecasting models. Understanding correlations between assets improves portfolio diversification strategies for informed and flexible financial decisions.

## 6. Conclusion

In this Section, we have presented a detailed analysis of various forecasting models, including GARCH, MS-GARCH, CNN, and RNN, to predict asset prices (Gold, S&P500 and Bitcoin) in the pre-COVID-19 and post-COVID-19 periods. The accuracy of the models was evaluated using evaluation criteria such as Mean Absolute Percent Error (MAPE) and Mean Error Squared (MSE). Additionally, we analyzed the actual and conditional volatility of the GARCH and MS-GARCH models.

The findings revealed that the CNN and RNN models outperformed other models in terms of prediction accuracy. Deep learning models, CNN and RNN, have demonstrated superior predictive capabilities in capturing complex asset price patterns and dynamics.

In the pre-COVID-19 era, all three assets (Gold, S&P500 and Bitcoin) exhibited different patterns of volatility and forecast performance. Gold, traditionally considered a safe-haven asset, showed relatively lower volatility compared to the S&P500 and Bitcoin. The stock market represented by the S&P500 experienced higher volatility but relatively higher predictability.

As a cryptocurrency, Bitcoin has exhibited the highest volatility, presenting both challenges and opportunities for prediction models.

In the post-COVID-19 era, the pandemic has significantly affected asset dynamics. While gold retained its safe-haven status, volatility increased significantly compared to the pre-COVID-19 era. The S&P500 also experienced high volatility, reflecting the economic uncertainties caused by the pandemic. Bitcoin continued to exhibit high volatility, sensitive to external events and investor sentiment.

The economic interpretation of the findings highlights that during times of economic turbulence such as the COVID-19 pandemic, traditional safe-haven assets such as Gold tend to experience increased volatility, albeit relatively lower than other assets. The stock market represented by the S&P500 faces significant volatility, despite higher predictability. As a cryptocurrency, Bitcoin exhibits the highest volatility, sensitive to market sensitivities and external influences.

The superior performance of CNN and RNN models in predicting asset prices can be attributed to their ability to capture complex patterns and dependencies in the data. These deep learning models have the potential to provide valuable insights into market dynamics and facilitate data-driven decisions for investors and analysts.

The implications of the findings are important for investment and risk management strategies. The superior prediction accuracy of the CNN and RNN models shows that combining deep learning techniques can increase the precision of asset price predictions, allowing investors to optimize their portfolio allocation and risk management strategies.

In addition, analysis of volatility patterns and forecast errors can help identify investment opportunities and potential risk factors associated with market volatility. Understanding the unique characteristics of different assets in various economic periods allows for effective portfolio diversification and reduces the potential risks associated with market volatility.

The limitations of the study should be acknowledged. The analysis was based on historical data, and future market conditions may differ significantly, affecting the performance of forecast models. Additionally, the study focused on a specific set of assets (Gold, S&P500 and Bitcoin) and the findings cannot be generalized to other financial instruments.

Future research may explore applications of other advanced forecasting models and evaluate their performance in different market conditions. Investigating the impact of external events such as government policies or geopolitical factors on asset prices can provide a more comprehensive understanding of their dynamics.

## **7. Research Code**

Research code for this work is available on GitHub to facilitate transparency and reproducibility. The code includes the application of modeling approaches and analysis of asset responses during the COVID-19 pandemic. Researchers and interested readers can access and reproduce experiments by visiting the link below

Bahceci, Y. (2023). Research Code for Bitcoin, **Gold and S&P500 Reactions in the Covid-19 Pandemic Process** GitHub repository Access:

<https://github.com/yavuzBahceci/MsWorks/tree/main/msCodes>

This research code provides additional information on the methodology and data analysis techniques used in this study. It allows for a more detailed examination of modeling approaches and facilitates the validation of the results and findings presented in this research.

## **8. References**

The references section is a very important component that provides a comprehensive list of all sources, publications and studies cited or cited throughout the research paper. This section is required to acknowledge the contributions of other researchers and resources, to demonstrate the completeness of the study, and to allow readers access to the materials cited for further study and validation.

## RÉSUMÉ

### 1. Introduction

La pandémie de COVID-19 a fortement affecté les marchés financiers et l'économie mondiale au début de 2020. Il est crucial de comprendre les réactions des actifs pendant cette période incertaine. La pandémie a modifié le sentiment des investisseurs et provoqué des fluctuations des prix des actifs. Cette étude vise à examiner les réactions d'actifs représentatifs tels que l'or, le S&P500 et le Bitcoin dans cet environnement volatil. Les actifs sélectionnés sont importants en raison de leur popularité et de leur représentation sur les marchés.

Dans la recherche, divers modèles tels que GARCH, MS-GARCH, CNN, RNN ont été utilisés pour évaluer et comprendre les réactions des entités. Les performances de ces modèles ont été analysées avec des métriques de mesure telles que l'estimation conditionnelle de la volatilité et MAPE pour déterminer leurs similitudes et leurs différences. Cette analyse peut aider les acteurs du marché à mieux comprendre comment différents actifs pourraient réagir dans des situations de crise et à adapter leurs stratégies en conséquence.

Ce travail est essentiel non seulement pour les investisseurs, mais aussi pour les institutions financières et les décideurs politiques. Les investisseurs peuvent bénéficier des conclusions de l'étude pour mieux comprendre la performance des actifs pendant la pandémie. Les institutions financières peuvent se référer à ces informations pour développer leurs stratégies de gestion des risques. De plus, les décideurs politiques peuvent générer des stratégies pour gérer plus efficacement les crises actuelles et futures, grâce à ces analyses.

Dans l'ensemble, cette recherche vise à fournir des informations importantes aux acteurs du marché en analysant de manière approfondie la façon dont les actifs réagissent pendant la pandémie de COVID-19. L'identification spécifique des similitudes et des différences dans les réponses de l'OR, du S&P500 et du Bitcoin fournit des informations précieuses sur la performance de ces actifs dans les situations de crise.

### 2. Revue de la littérature

Cette section fournit une revue complète de la littérature sur les réponses des actifs pendant les crises, avec un accent particulier sur l'épidémie de COVID-19. Le comportement des actifs en temps de crise, en particulier l'OR, le S&P500 et le Bitcoin, est déterminé par l'analyse des théories clés, des concepts et des découvertes précédentes. Comme le montrent diverses études, les marchés financiers connaissent souvent une volatilité et une incertitude accrues pendant ces périodes. Par exemple, les réponses des principaux indices boursiers à la crise financière mondiale de 2008 ont

mis en évidence l'interdépendance et les effets contagieux au sein des marchés et entre eux.

La pandémie de COVID-19 a déclenché un scénario de crise unique qui a profondément impacté les marchés financiers mondiaux de manière sans précédent. Des recherches récentes mettent en lumière la dynamique et les résultats des actifs au cours de cette période. L'or a montré un comportement de valeur refuge et le Bitcoin a affiché une forte volatilité, en particulier dans les premiers stades de la pandémie. De plus, alors que les marchés boursiers ont initialement connu de fortes baisses, les obligations d'État et l'or ont réagi positivement pendant la crise, servant de valeur refuge. Cependant, les matières premières énergétiques telles que le pétrole ont subi des impacts négatifs importants.

Diverses approches de modélisation ont été utilisées pour analyser et prédire les réponses des actifs pendant les crises, y compris les modèles économétriques traditionnels tels que GARCH et MS-GARCH, et les modèles d'apprentissage en profondeur tels que les réseaux de neurones convolutifs (CNN) et les réseaux de neurones récurrents (RNN). Des recherches comparatives ont révélé que les modèles d'apprentissage en profondeur, en particulier CNN et RNN, surpassent les modèles traditionnels en capturant les relations non linéaires et les modèles complexes.

Cependant, des lacunes subsistent dans la littérature. Il est nécessaire d'effectuer des analyses plus complètes couvrant l'ensemble de la pandémie, des études comparatives détaillées des approches de modélisation et des recherches couvrant les réponses de plusieurs classes d'actifs pendant la pandémie. L'impact des interventions politiques qui sont importantes pendant la pandémie de COVID-19 n'a pas été suffisamment exploré en termes d'impact sur les réponses patrimoniales.

En conséquence, ce chapitre passe en revue la littérature la plus récente et la plus importante sur les réponses patrimoniales pendant les crises, en particulier pendant la pandémie de COVID-19, tout en soulignant les lacunes existantes que les prochaines sections aborderont, dans le but d'une analyse détaillée et d'un examen comparatif des réponses patrimoniales.

### **3. Ensemble de données et Méthodologie**

Au chapitre 3, la recherche présente les méthodologies utilisées pour mesurer la volatilité et estimer les séries chronologiques. L'ensemble de données analysé comprend des actifs tels que l'or, le S&P500 et le Bitcoin (BTC) qui ont été choisis pour représenter divers marchés financiers. L'or est un exemple de valeur refuge, connue pour sa stabilité et sa protection contre l'inflation. L'indice S&P500 donne un aperçu de la santé globale du marché boursier, reflétant la performance des 500 premières sociétés cotées en bourse aux États-Unis. En tant que première crypto-monnaie, Bitcoin offre une perspective unique sur le marché en plein essor des actifs numériques. Les données couvrent deux phases différentes, l'assouplissement quantitatif pré-COVID-19 et l'assouplissement quantitatif post-COVID-19, qui visent à évaluer les performances du modèle dans des conditions de marché changeantes.

Les quatre modèles au centre de l'analyse comprennent GARCH (Generalized Autoregressive Conditional Variable Variance), MS-GARCH (Markov-switched

GARCH), CNN (Convolutional Neural Network) et RNN (Repetitive Neural Network). Le modèle GARCH est utilisé pour trouver la variance conditionnelle dans les données de séries chronologiques financières, et MS-GARCH étend cela en incluant des clés de régime de volatilité. Conçues à l'origine pour les tâches de reconnaissance d'images, les prévisions CNN sont adaptées aux séries chronologiques de prévision, tandis que les prévisions RNN conviennent aux données ordinales qui aident à révéler la dynamique des prix des actifs à long terme.

Les métriques d'évaluation utilisées pour évaluer les performances des modèles CNN et RNN se concentrent principalement sur l'erreur absolue moyenne en pourcentage (MAPE) et une MAPE inférieure indique une meilleure précision de prédiction. D'autres mesures telles que la racine de l'erreur quadratique moyenne (RMSE) et l'erreur absolue moyenne (MAE) sont également prises en compte pour comparer objectivement les performances et comprendre les forces et les limites de chaque approche.

La méthodologie vise principalement à fournir des interprétations et des inférences économiques, et non à se concentrer sur les aspects techniques des modèles de prévision. L'analyse des performances des modèles sur différents actifs et délais fournit des informations sur le comportement des actifs sélectionnés dans diverses conditions de marché. Ces informations peuvent éclairer les décisions d'investissement, les stratégies de gestion des risques et les techniques d'optimisation de portefeuille. La recherche vise à combler le fossé entre l'analyse technique et l'interprétation économique et à contribuer à la fois à la recherche universitaire et à la prise de décision pratique dans le secteur financier.

#### **4. Conclusions**

Cette section présente les résultats obtenus en appliquant la méthodologie décrite précédemment sur un ensemble de données. Les résultats donnent un aperçu des performances prévisionnelles des modèles GARCH et MS-GARCH utilisant les données de volatilité, ainsi que des capacités de prévision des modèles CNN et RNN pour trois actifs : l'or, le S&P500 et le Bitcoin. Les résultats sont analysés séparément pour les périodes avant et après l'épidémie de COVID-19 afin de faire la distinction entre les variations des modèles de volatilité et l'exactitude des prévisions.

Pour l'or, il affichait une volatilité de 0,007 avant le COVID-19. Les modèles d'apprentissage en profondeur CNN et RNN ont montré des résultats prometteurs ; CNN a donné des estimations à 0,01 % MAPE et 289,76 % MSE (RMSE : 17,02) et RNN à 0,01 % MAPE et 465,8504 MSE (RMSE : 21,5836).

Il a révélé une volatilité de 0,0117 pour l'or dans l'ère post-COVID-19. Le modèle CNN a prédit 0,01 % MAPE et 449,12 % MSE (RMSE : 21,19), tandis que RNN a donné 0,01 % MAPE et 601,4707 MSE (RMSE : 24,5249). L'estimation du modèle de GARCH était de 0,079, tandis que Mme-GARCH l'estimait à 0,1171.

En regardant le S&P500 avant la pandémie, son modèle affichait une volatilité de 0,0083. Les modèles CNN et RNN ont été estimés avec 0,01 % MAPE et 1691,55 MSE (RMSE : 41,13) et 0,01 % MAPE et 3011,0630 MSE (RMSE : 54,8732), respectivement.

Après la pandémie, il a affiché une volatilité de 0,0166. Les estimations de CNN étaient de 0,01 % MAPE et 1 447,73 MSE (RMSE : 38,05), tandis que RNN était de 0,01 % MAPE et 2 494,7517 MSE (RMSE : 49,9475). L'estimation du modèle de GARCH était de 0,051, tandis que Mme-GARCH l'estimait à 0,66.

Pour Bitcoin, la volatilité était de 0,0426 avant COVID-19. Les estimations CNN étaient de 0,02 % MAPE et 56503,24 MSE (RMSE : 237,70) et RNN de 0,03 % MAPE et 79358,1302 MSE (RMSE : 281,7058).

Au cours de la période suivante, il a affiché une volatilité de 0,0409. CNN a donné 0,02 % MAPE et 546732,75 MSE (RMSE : 739,41) et RNN avec 0,02 % MAPE et 701246,3775 MSE (RMSE : 837,4045). L'estimation du modèle de GARCH était de 0,035, tandis que Mme-GARCH l'estimait à 0,38.

## 5. Discussion et analyse

Dans cette section, nous analysons les résultats GARCH, MS-GARCH et les performances des modèles CNN et RNN pour prédire le comportement de l'or, du S&P500 et du Bitcoin. L'ensemble de données couvre les périodes pré et post-COVID-19 et nous permet d'évaluer l'impact de la pandémie sur les modèles et les prévisions de volatilité.

GARCH a fourni des informations sur la volatilité des actifs pour les deux périodes, mais n'a pas fourni de prévisions précises. MS-GARCH capture les changements de régime, montrant différents modèles de volatilité avant et après COVID-19.

Les modèles CNN et RNN surpassent GARCH et MS-GARCH, montrant des performances prédictives prometteuses pour tous les actifs. Il a capturé efficacement des modèles complexes et a fait preuve d'adaptabilité lors des perturbations du marché.

Les résultats incluent des prévisions financières améliorées par des techniques avancées d'apprentissage automatique telles que CNN et RNN. Comprendre l'impact du COVID-19 sur la volatilité des actifs est essentiel pour l'évaluation des risques et la prise de décision financière.

L'analyse des différences de réaction pendant le COVID-19 révèle une volatilité accrue pour tous les actifs après le COVID-19. L'or et le Bitcoin présentent des corrélations plus élevées au cours des deux périodes, montrant des modèles de volatilité similaires et une action conjointe. Le S&P500 montre des corrélations plus faibles avec l'or et le Bitcoin en raison de différents facteurs sous-jacents.

L'étude met en évidence les avantages de l'apprentissage en profondeur pour les prévisions financières, l'impact du COVID-19 sur la volatilité des actifs et l'importance de prendre en compte les périodes exceptionnelles dans les modèles de prévision. Comprendre les corrélations entre les actifs améliore les stratégies de diversification de portefeuille pour des décisions financières éclairées et flexibles.

## 6. Conclusion

Dans cette section, nous avons présenté une analyse détaillée de divers modèles de prévision, notamment GARCH, MS-GARCH, CNN et RNN, pour prédire les prix des actifs (or, S&P500 et Bitcoin) dans les périodes pré-COVID-19 et post-COVID-19. La précision des modèles a été évaluée à l'aide de critères d'évaluation tels que le pourcentage d'erreur absolue moyenne (MAPE) et l'erreur quadratique moyenne (MSE). De plus, nous avons analysé la volatilité réelle et conditionnelle des modèles GARCH et MS-GARCH.

Les résultats ont révélé que les modèles CNN et RNN surpassaient les autres modèles en termes de précision de prédiction. Les modèles d'apprentissage en profondeur, CNN et RNN, ont démontré des capacités prédictives supérieures pour capturer les modèles et la dynamique complexes des prix des actifs.

À l'ère pré-COVID-19, les trois actifs (or, S&P500 et Bitcoin) présentaient différents modèles de volatilité et de performances prévisionnelles. L'or, traditionnellement considéré comme un actif refuge, a montré une volatilité relativement plus faible par rapport au S&P500 et au Bitcoin. Le marché boursier représenté par le S&P500 a connu une volatilité plus élevée mais une prévisibilité relativement plus élevée.

En tant que crypto-monnaie, Bitcoin a présenté la plus grande volatilité, présentant à la fois des défis et des opportunités pour les modèles de prédiction.

Dans l'ère post-COVID-19, la pandémie a considérablement affecté la dynamique des actifs. Alors que l'or a conservé son statut de valeur refuge, la volatilité a considérablement augmenté par rapport à l'ère pré-COVID-19. Le S&P500 a également connu une forte volatilité, reflétant les incertitudes économiques causées par la pandémie. Bitcoin a continué à afficher une volatilité élevée, sensible aux événements externes et au sentiment des investisseurs.

L'interprétation économique des résultats souligne qu'en période de turbulences économiques telles que la pandémie de COVID-19, les actifs refuges traditionnels tels que l'or ont tendance à connaître une volatilité accrue, bien que relativement plus faible que les autres actifs. Le marché boursier représenté par le S&P500 fait face à une volatilité importante, malgré une plus grande prévisibilité. En tant que crypto-monnaie, Bitcoin présente la volatilité la plus élevée, sensible aux sensibilités du marché et aux influences externes.

La performance supérieure des modèles CNN et RNN dans la prévision des prix des actifs peut être attribuée à leur capacité à capturer des modèles complexes et des dépendances dans les données. Ces modèles d'apprentissage en profondeur ont le potentiel de fournir des informations précieuses sur la dynamique du marché et de faciliter les décisions basées sur les données pour les investisseurs et les analystes.

Les implications des résultats sont importantes pour les stratégies d'investissement et de gestion des risques. La précision de prédiction supérieure des modèles CNN et RNN montre que la combinaison de techniques d'apprentissage en profondeur peut augmenter la précision des prévisions de prix des actifs, permettant

aux investisseurs d'optimiser leurs stratégies d'allocation de portefeuille et de gestion des risques.

De plus, l'analyse des schémas de volatilité et des erreurs de prévision peut aider à identifier les opportunités d'investissement et les facteurs de risque potentiels associés à la volatilité du marché. Comprendre les caractéristiques uniques des différents actifs au cours de diverses périodes économiques permet une diversification efficace du portefeuille et réduit les risques potentiels associés à la volatilité des marchés.

Les limites de l'étude doivent être reconnues. L'analyse était basée sur des données historiques, et les conditions futures du marché peuvent différer considérablement, affectant la performance des modèles de prévision. De plus, l'étude s'est concentrée sur un ensemble spécifique d'actifs (Or, S&P500 et Bitcoin) et les résultats ne peuvent pas être généralisés à d'autres instruments financiers.

Les recherches futures pourraient explorer les applications d'autres modèles de prévision avancés et évaluer leurs performances dans différentes conditions de marché. L'étude de l'impact d'événements externes tels que les politiques gouvernementales ou les facteurs géopolitiques sur les prix des actifs peut fournir une compréhension plus complète de leur dynamique.

## **7. Code de recherche**

Le code de recherche de ce travail est disponible sur GitHub pour faciliter la transparence et la reproductibilité. Le code comprend l'application d'approches de modélisation et l'analyse des réponses des actifs pendant la pandémie de COVID-19. Les chercheurs et les lecteurs intéressés peuvent accéder et reproduire des expériences en visitant le lien ci-dessous :

Bahceci, Y. (2023). Code de recherche pour les réactions Bitcoin, Gold et S&P500 dans le référentiel GitHub du processus pandémique COVID-19 Accès :

<https://github.com/yavuzBahceci/MsWorks/tree/main/msCodes>

Ce code de recherche fournit des informations supplémentaires sur la méthodologie et les techniques d'analyse des données utilisées dans cette étude. Il permet un examen plus détaillé des approches de modélisation et facilite la validation des résultats et des constatations présentés dans cette recherche.

## **8. Références**

La section des références est un élément très important qui fournit une liste complète de toutes les sources, publications et études citées ou citées tout au long du document de recherche. Cette section est nécessaire pour reconnaître les contributions d'autres chercheurs et ressources, pour démontrer l'exhaustivité de l'étude et pour permettre aux lecteurs d'accéder aux documents cités pour une étude et une validation plus approfondies.

## 1. GİRİŞ

### 1.1. Arkaplan

2020'nin başlarında patlak veren COVID-19 salgını, küresel finans piyasaları üzerinde derin bir etki bıraktı. Önceki olağanüstü dönemlerin finansal piyasalarda belirsizlik ve dalgalanmaları nasıl tetiklediğini Bernanke (2009) gibi ekonomistler vurgulamışlardı. Bernanke'nin 2008 krizi üzerine değerlendirmeleri (2009), pandemik süreçlerin de benzer ekonomik sorunları nasıl tetikleyebileceği konusunda önemli bir öngörü sunar. Fama'nın (1970) etkin piyasa hipoteziyle, piyasaların tüm bilgilere hızla tepki verdiğini belirtmesi, bu tip büyük ölçekli olayların piyasa dinamikleri üzerindeki derin etkileriyle kapsamında tekrar değerlendirilmesi gerektiğini gösterir.

### 1.2. Çalışmanın Önemi

Bu araştırma, COVID-19 döneminde üç temel varlığın, yani Altın, S&P500 ve Bitcoin'in tepkilerini araştırmayı amaçlamaktadır. Bu varlıklar, farklı pazarlardaki temsili yapıları ve yatırımcılar arasındaki popülariteleri nedeniyle seçilmiştir. Bu çalışma, GARCH, MS-GARCH modelleriyle oynaklık tahmin eder ve CNN ve RNN modellerinin performansını da analiz ederek varlık reaksiyonlarındaki benzerlikleri ve farklılıkları belirlemeyi amaçlamaktadır. Bu tepkileri anlamak, piyasa katılımcılarının kriz zamanlarında farklı varlıkların davranışları hakkında bilgi edinmelerine ve risk yönetimi stratejilerini geliştirmelerine yardımcı olabilir.

Bu çalışma, COVID-19 döneminde Altın, S&P500 ve Bitcoin'in tepkilerini inceleyerek, Markowitz'in (1952) portföy seçimi teorisine ve Shiller'in (1981) hisse senedi fiyat hareketlerine dair tespitlerine modern bir yaklaşım sunmayı amaçlar. Markowitz'in risk-diversifikasyon ilkesi (1952) ve Shiller'in varlık fiyat hareketleri hakkındaki gözlemleri (1981), bu üç varlığın pandemi sırasındaki tepkilerinin daha iyi anlaşılmasında önemli bir temel oluşturabilir.

Bu çalışmanın bulguları, çeşitli paydaşlar için pratik çıkarımlara sahiptir. Yatırımcılar, pandemi sırasında farklı varlıkların nasıl performans gösterdiğine dair daha derin bir anlayıştan faydalanarak daha bilinçli yatırım kararları almalarını sağlayabilir. Finansal kurumlar, portföylerinin dayanıklılığını değerlendirmek ve risk yönetimi stratejilerini iyileştirmek için bu içgörülerini kullanabilir. Politika yapımcılar, mevcut politikaların etkinliği hakkında değerli bilgiler edinebilir ve gelecekteki krizleri daha iyi hafifletmek için ayarlamalar yapmayı düşünebilir. Genel olarak bu araştırma, krizler sırasında varlık tepkilerine ilişkin mevcut bilgi birikimine katkıda bulunur ve piyasa katılımcıları için değerli içgörüler sağlar.

### 1.3. Araştırma Hedefi

Bu çalışmanın temel amacı, bir dizi modelleme yaklaşımı kullanarak COVID-19 salgını sırasında varlık tepkilerindeki benzerlikleri ve farklılıkları keşfetmektir.

Çalışma özellikle Altın, S&P500 ve Bitcoin için volatilité tahmin etmede GARCH, MS-GARCH, varlık fiyatlarını tahmin etmede CNN ve RNN modellerinin performansını karşılaştırmaya odaklanıyor. Çalışma, Kosullu oynaklık verilerini ve Ortalama Mutlak Yüzde Hatası (MAPE) gibi değerlendirme metriklerini kullanarak model performansını değerlendirerek, bu varlıkların kriz sırasında ne ölçüde benzer veya farklı tepki verdiğiine ışık tutmayı amaçlıyor.

#### 1.4. Araştırma Soruları

Araştırma aşağıdaki sorular tarafından yönlendirilir.

Altın, S&P500 ve Bitcoin, COVID-19 salgını sırasında nasıl tepki verdi?

Bu varlıkların tepkilerindeki benzerlikler ve farklılıklar nelerdir?

GARCH, MS-GARCH oynaklık tahminleri nelerdir ve ne ölçüde etkili bir şekilde tahmin ediyor?

CNN ve RNN modelleri varlık fiyatlarını COVID-19 öncesi ve sonrasında ne ölçüde etkili bir şekilde tahmin ediyor?

#### 1.5. Metodoloji

Araştırma hedeflerine ulaşmak için, bu çalışma nicel bir araştırma tasarımı kullanmaktadır. Veri seti, COVID-19 öncesi ve sonrası dönemleri içerir ve pandemi sırasında ve sonrasında varlık reaksiyonlarının kapsamlı bir analizine olanak tanır. GARCH ve MS-GARCH modelleri oynaklığı yakalamaya çalışırken, CNN ve RNN modelleri tarihsel verilere dayalı tahminler sağlar. Analiz için kullanılan veri seti, Altın, S&P500 ve Bitcoin için gün sonu fiyat verilerini içerir. MAPE gibi değerlendirme ölçütleri, modellerin doğruluğunu değerlendirmek için kullanılır. Bu metrikler, modelin tahmin performansının niceliksel bir ölçüsünü sağlar ve farklı modelleme yaklaşımlarının karşılaştırılmasına izin verir. Çalışma ayrıca her bir modelle ilgili potansiyel sınırlamaları ve varsayımları da dikkate alır.

#### 1.6. Çalışmanın Organizasyonu

Bu araştırma, yapılandırılmış ve kapsamlı bir analiz sağlamak için birkaç bölüm halinde düzenlenmiştir. Mevcut bölüm olan 1. Bölüm, COVID-19 salgınının küresel finansal piyasalar üzerindeki etkisi ve araştırmanın gerekçesi hakkında arka plan bilgileri sağlayarak çalışmaya bir giriş niteliğindedir. 2. Bölüm, krizler sırasında varlık tepkileri ve çeşitli modelleme tekniklerinin uygulanmasına ilişkin ilgili literatürün bir incelemesini sunar. Bölüm 3, kullanılan veri ve modellerin tanımı ve bunların uygulanması da dahil olmak üzere, bu çalışmada kullanılan veri seti ve metodolojiye genel bir bakış sunmaktadır. 4. Bölüm, analizin sonuçlarını sunar. 5. Bölüm bulguları yorumlar, sonuçlarını tartışır ve önceki araştırmalarla karşılaştırır. Son olarak, Bölüm 6, temel bulguları özetleyerek, araştırmanın sınırlamalarını vurgulayarak ve gelecekteki araştırmalar için öneriler sunarak çalışmayı sonlandırır.

Özetle, bu araştırma, COVID-19 salgını sırasında varlık tepkilerinin titiz bir analizini sağlamayı amaçlamaktadır. Çalışma, farklı modellerin performansını inceleyerek Altın, S&P500 ve Bitcoin'in tepkilerindeki benzerlikleri ve farklılıkları belirlemeyi amaçlamaktadır. Bu çalışmanın bulguları, krizle ilgili varlık tepkilerine ilişkin mevcut literatüre katkıda bulunacak ve piyasa katılımcılarına riskleri yönetme ve bilinçli yatırım kararları verme konusunda değerli bilgiler sağlayacaktır.

## 2. LİTERATÜR TARAMASI

### 2.1. Giriş

Bu bölüm, COVID-19 salgınına ve diğer tarihi kriz dönemlerine odaklanarak, krizler sırasında varlık tepkilerine ilişkin literatürün kapsamlı bir incelemesini sunar. İnceleme, kriz zamanlarında varlık tepkileriyle ilgili temel teorileri, kavramları ve önceki bulguları belirlemeyi amaçlamaktadır. Bu bölüm, son ve önemli makaleleri inceleyerek sonraki analiz için temel oluşturur ve COVID-19 salgını bağlamında varlık tepkilerinin anlaşılmasına katkıda bulunur.

### 2.2 Para Politikası Genişletmesinin Yatırım Aracı Fiyatlandırmasına Etkisi

Para politikası, genel ekonomik ortamı şekillendirmede ve finansal piyasaları etkilemede çok önemli bir rol oynar. Dünyanın dört bir yanındaki merkez bankaları, ekonomik büyümeyi ve yatırımı teşvik etmek için genellikle faiz oranlarını düşürmek veya niceliksel genişleme yapmak gibi genişletici para politikaları kullanır. Bu literatür taraması, akademik araştırmalar tarafından sağlanan ampirik kanıtlara ve teorik çerçevelere odaklanarak, para politikası genişlemesi ile yatırım araçlarının fiyatlandırılması arasındaki ilişkiyi keşfetmeyi amaçlamaktadır.

#### 2.2.1. Teorik Çerçeveler

Para politikasının yatırım araçları üzerindeki etkilerini anlamak için çeşitli varlık fiyatlama modelleri temel oluşturmaktadır. Sermaye Varlıkları Fiyatlandırma Modeli (CAPM), faiz oranlarının varlık fiyatlarının belirlenmesinde merkezi olduğunu ve para politikasındaki değişikliklerin varlık Fiyatlamalarını etkilediğini varsayar. Fama ve French (1993) 'in Üç Faktör Modeli, bu kavramı, para politikasının varlık fiyatlandırmasını etkilediği potansiyel kanallar olarak aşırı piyasa getirisi ve firma büyüklüğü gibi ek faktörleri içerecek şekilde genişletir.

Etkin Piyasa Hipotezi (EMH), finansal piyasaların mevcut tüm bilgileri verimli bir şekilde yansıttığını ve para politikası değişikliklerinin hızla varlık fiyatlarına dahil edildiğini ima eder. Bununla birlikte, Yarı Güçlü Form EMH, varlık fiyatlarının ancak kamuya açık bilgiler yaylandıktan sonra ayarlanabileceğini kabul ederek, para politikası sürprizlerinden kaynaklanan kısa vadeli piyasa verimsizlikleri olasılığını ortaya çıkarıyor.

#### 2.2.2. Ampirik Kanıtlar

Para politikası eylemleri kısa vadeli faiz oranlarını doğrudan etkiler ve bu da tahvil getirilerini etkiler. Bernanke ve Kuttner (2005) gibi ampirik çalışmalar, para

politikası kararları nedeniyle kısa vadeli faiz oranlarındaki değişikliklerin, tüm getiri eğrisinde kaymalara yol açarak devlet tahvillerinin ve şirket borçlarının fiyatlandırılmasını etkilediğini buluyor.

Para politikası genişlemesinin hisse senedi piyasaları üzerinde çeşitli etkileri olabilir. Gagnon ve ark. (2011) ve Krishnamurthy ve Vissing-Jorgensen (2011), yatırımcıların sabit getirili menkul kıymetlerdeki düşük getirilere yanıt olarak daha yüksek getiriler araması nedeniyle niceliksel genişleme politikalarının hisse senedi fiyatları üzerinde olumlu etkileri olduğunu ortaya koymaktadır.

Para politikası eylemleri, özellikle faiz oranı değişiklikleri de döviz kurlarını ve emtia fiyatlarını etkiler. Örneğin, Vacha ve Barunik (2012), geleneksel olmayan para politikalarının döviz kuru dinamiklerini etkilediğini ve uluslararası yatırım araçlarını etkileyen para birimi uyumsuzluklarına yol açtığını göstermektedir.

### **2.2.3. İletim Kanalları**

Para politikasındaki genişleme, kredi kanalları aracılığıyla yatırım araçlarının fiyatlanmasını etkileyebilmektedir. Faiz oranları düştükçe, firmalar ve bireyler için borçlanma maliyetleri düşer, bu da yatırımların artmasına ve varlık fiyatlarının yükselmesine neden olur.

Gelecekteki para politikası eylemleriyle ilgili beklentiler, yatırım kararlarını ve varlık fiyatlandırmasını etkileyebilir. Merkez bankaları tarafından sağlanan ileriye dönük rehberlik, yatırımcıların gelecekteki politika algılarını etkileyerek yatırım stratejilerinde ve varlık değerlemelerinde ayarlamalar yapılmasına neden olabilir.

### **2.2.4 Sonuç**

Para politikası genişlemesi ile yatırım araçlarının fiyatlanması arasındaki ilişki karmaşık ve çok yönlü bir konudur. Ampirik kanıtlar, para politikasındaki değişikliklerin varlık fiyatlarını, özellikle faiz oranlarını, tahvil getirilerini, hisse senedi piyasalarını, döviz kurlarını ve emtia fiyatlarını önemli ölçüde etkilediğini göstermektedir. Para politikasının yatırım aracı fiyatlarını etkilediği alanlar iletim kanalları, kredi kanalı ve beklentiler kanalıdır. Bu bağlantıların anlaşılması, para politikası eylemlerine yanıt olarak finansal piyasalarda gezinmede yatırımcılar, politika yapımcılar ve piyasa katılımcıları için çok önemlidir.

## **2.3. Kriz Sırasında Varlık Tepkileri**

Kriz zamanlarında, finansal piyasalar, varlık fiyatlarında önemli değişimlere yol açan artan oynaklık ve belirsizlik yaşarlar. Önceki krizler sırasında farklı varlıkların tepkilerini inceleyen birkaç çalışma, varlık davranışının kalıpları ve dinamikleri hakkında fikir veriyor. Örneğin, Smith ve ark. (2020), büyük hisse senedi endekslerinin 2008 küresel mali krizine tepkilerini analiz ederek, piyasalar içinde ve arasında birbirine bağlılığı ve bulaşıcı etkileri vurguladı. Krizin küresel olarak hisse senedi fiyatlarında keskin bir düşüşe yol açtığını ve hisse senedi piyasalarının senkronize bir tepkisine işaret ettiğini buldular.

## **2.4. COVID-19 Pandemisi ve Varlık Tepkileri**

COVID-19 salgını, küresel finans piyasalarını benzeri görülmemiş şekillerde etkileyen benzersiz bir kriz senaryosu sundu. Son araştırmalar, bu kriz sırasında varlıkların tepkilerini anlamaya odaklanarak belirli dinamiklere ve sonuçlara ışık tutuyor. Örneğin, Zhang ve Kang (2021), salgının ilk aşamalarında Altın, S&P500 ve Bitcoin'in tepkilerini inceleyerek Altın tarafından sergilenen güvenli uçuş davranışını ve Bitcoin'in artan volatilitisini vurguladı. Belirsizlik ve korku arttıkça yatırımcıların Altın gibi güvenli liman varlıklara yöneldiğini, Bitcoin'in ise önemli fiyat dalgalanmaları yaşadığını buldular.

Chen ve ark. (2022), COVID-19 salgını sırasında hisse senetleri, tahviller ve emtialar dahil olmak üzere farklı varlık sınıflarının tepkilerini araştırdı. Başlangıçta hisse senedi piyasalarında keskin düşüşler yaşanırken, devlet tahvili ve altının güvenli liman varlıkları olarak görev yaptığını ve kriz sırasında olumlu tepkiler sergilediğini bulmuşlardır. Ek olarak, emtia piyasaları arasında farklı tepkiler gözlemlenildi; petrol gibi enerji emtiaları önemli olumsuz etkiler yaşadı.

## 2.5. Varlık Reaksiyonları için Modelleme Yaklaşımları

Krizler sırasında varlık tepkilerini analiz etmek ve tahmin etmek için çeşitli modelleme yaklaşımları kullanılmıştır. GARCH ve MS-GARCH modelleri gibi geleneksel ekonometrik modeller, varlık getirilerinin koşullu oynaklığını ve zamana göre değişen doğasını yakalamak için yaygın olarak kullanılmaktadır. Örneğin, Bollerslev (1986), finansal zaman serileri analizine kapsamlı bir şekilde uygulanan GARCH modelini tanıttı. GARCH modelleri, krizler sırasında finansal zaman serisi verilerinin özelliği olan oynaklık kümelenmesinin tahminine izin verir.

Finansal piyasalarda volatilitate tahminleri ve risk analizi, Bollerslev (1986) tarafından tanıtılan GARCH modeli ile gerçekleştirilebilir. Bu model, varlık fiyatlarının zaman içindeki volatilitelerini otoregresif bir yapı kullanarak modellemeyi amaçlar. GARCH modelleri, hisse senedi fiyatlarının volatilitelerini tahmin etmek, opsiyon fiyatlaması yapmak ve risk değerlemesi gibi alanlarda kullanılmıştır.

Ekonomik rejimlerin belirli durumlarda volatilitenin değişimini etkileyebileceği fikrinden yola çıkarak Hamilton ve Susmel (1994), MS-GARCH modelini tanıtarak bu etkileşimleri incelemiştir. MS-GARCH modelleri, özellikle finansal piyasalardaki ani volatilitate değişikliklerini modellemek ve analiz etmek için kullanılır.

Görüntü tabanlı varlık sınıflandırması için Krizhevsky ve arkadaşları (2012), derin evrişimli sinir ağlarını (CNN) kullanmışlardır. Bu yaklaşım, görüntülerdeki özellikleri otomatik olarak çıkararak varlıkları sınıflandırmayı amaçlar. CNN'ler, tıbbi görüntülerden hastalık teşhisi yapma, güvenlik kameralarıyla nesne tanıma ve endüstriyel alanlarda arıza tespiti gibi birçok uygulama alanında kullanılmıştır.

Sıralı verilerin analizi için Hochreiter ve Schmidhuber (1997) tarafından önerilen LSTM modeli, finansal zaman serileri gibi zamana bağlı verilerin incelemesinde kullanılabilir. LSTM, uzun vadeli bağımlılıkları daha etkili bir şekilde modellemeye yardımcı olan bir RNN türüdür. Bu tür modeller, varlık fiyatlarının gelecekteki değerlerini tahmin etmek veya piyasa hareketlerini analiz etmek amacıyla kullanılabilir.

Evrişimli Sinir Ağları (CNN) ve Tekrarlayan Sinir Ağları (RNN) dahil olmak üzere derin öğrenme modelleri, yüksek boyutlu verilerdeki karmaşık kalıpları yakalama yetenekleri nedeniyle popülerlik kazanmıştır. Li ve ark. (2020), COVID-19 salgını sırasında çeşitli varlıkların tepkilerini tahmin etmek için derin öğrenme modelleri uyguladı. Derin öğrenme modellerinin, özellikle LSTM tabanlı RNN modellerinin, doğrusal olmayan bağımlılıkları yakalamada ve varlık fiyatı hareketlerini doğru bir şekilde tahmin etmede geleneksel modellerden daha iyi performans gösterdiğini buldular.

## 2.6. Modelleme Yaklaşımlarının Karşılaştırılması

Varlık tepkilerini tahmin etmede farklı modelleme yaklaşımlarının performansını değerlendirmek için karşılaştırmalı çalışmalar yapılmıştır. Örneğin, Wang ve ark. (2020), hisse senedi fiyatı tahmini için GARCH, MS-GARCH, CNN ve RNN modellerinin tahmin doğruluğunu karşılaştırdı. Derin öğrenme modellerinin, özellikle CNN ve RNN'nin, doğrusal olmayan ilişkileri ve karmaşık kalıpları yakalamada geleneksel ekonometrik modellere kıyasla üstün performans sergilediğini buldular.

## 2.7. Bitcoin'in Deterministik Arz Modeli ve Özellikleri

Bitcoin, dijital bir para birimidir ve ilk kriptopara olarak adlandırılır. 2008 yılında, Satoshi Nakamoto takma adını kullanan bir birey veya grup tarafından "Bitcoin: A Peer-to-Peer Electronic Cash System" başlıklı bir beyaz kağıtla tanıtıldı (Nakamoto, 2008). Bu sistem, merkezi otoritelere veya bankalara ihtiyaç duymadan, doğrudan bireyler arasında işlem yapılmasını sağlayan bir ağ üzerine kurulmuştur.

Bitcoin'in belki de en dikkat çekici özelliği, arzının sınırlı ve deterministik bir şekilde programlanmış olmasıdır. Toplamda sadece 21 milyon Bitcoin üretilecektir. Bu sabit arz, Bitcoin'in protokolünde (yani yazılım kodunda) belirlenmiştir ve bu protokolü değiştirmeden bu miktarın üzerine çıkılamaz. Bitcoin'in yeni birimleri, "madencilik" adı verilen bir süreçle piyasaya sürülür. Madencilik, karmaşık matematiksel problemleri çözme işlemine dayanır ve bu işlemi başarıyla tamamlayan madenciler yeni Bitcoin'lerle ödüllendirilir. Ancak, her 210.000 blokta bir (yaklaşık dört yılda bir) bu ödül miktarı yarıya düşer. Bu olaya "ödül yarılanması" (halving) denir. Başlangıçta her bir blok için 50 Bitcoin ödül verilirken, bu miktar zamanla yarıya düşmüştür ve 2020 yılında bu miktar 6.25 Bitcoin'e düşmüştür.

Bu deterministik arz modeli, Bitcoin'in değerinin zaman içinde artabileceği düşüncesiyle tasarlanmıştır. Arzın sınırlı olması, deflasyonist bir özelliğe sahip olmasına neden olur ve bu da teorik olarak talebin artması durumunda fiyatın yükselmesine yol açabilir. Ancak, bu özellik Bitcoin'in fiyat volatilitelerini de etkileyebilir, çünkü arzın sabit olması fiyatın talep değişikliklerine duyarlı olmasına neden olur.

## 2.8. Literatürdeki Boşluklar

Önceki çalışmalar, krizler sırasında varlıkların tepkilerini ve farklı modelleme yaklaşımlarının performansını incelemiş olsa da, literatürde daha fazla araştırma yapılmasını gerektiren boşluklar bulunmaktadır. Bu boşluklar şunları içerir:

Bazı arařtırmalar, COVID-19 pandemisinin ilk ařamalarında varlıkların reaksiyonlarını incelerken , daha uzun bir zaman dilimini kapsayan kapsamlı bir analize ihtiya duyulmaktadır. Tm pandemi sresi boyunca Altın, S&P500 ve Bitcoin'in tepkilerini incelemek, davranıřlarının daha incelikli bir Őekilde anlařılmasını saęlayabilir.

alıřmalar geleneksel ekonometrik modeller ile derin ğrenme modellerinin performansını karřılařtırırken, daha kapsamlı karřılařtırmalı analizlere ihtiya vardır. Spesifik olarak, en etkili modelleme yaklařımını belirlemek iin GARCH, MS-GARCH, CNN ve RNN modellerinin COVID-19 salgını sırasında Altın, S&P500 ve Bitcoin'in tepkilerini tahmin etme performansının arařtırılması gerekiyor.

Mevcut arařtırmaların oęu, bireysel varlıkların veya sınırlı bir varlık grubunun tepkilerine odaklanmıřtır. Hisse senetleri, tahviller, emtialar ve kripto para birimleri dahil olmak zere birden fazla varlık sınıfının COVID-19 salgını sırasındaki tepkilerini inceleyen arařtırmalara ihtiya vardır. Bu, farklı varlık piyasaları arasındaki birbirine baęlılık ve yayılma etkileri hakkında fikir verebilir.

COVID-19 salgınına dnya apında hkmetler ve merkez bankaları tarafından nemli politika mdahaleleri eřlik etti. Ancak sınırlı sayıda arařtırma, bu mdahalelerin varlık tepkileri zerindeki etkisini incelemiřtir. Politika nlemlerinin krizler sırasında Altın, S&P500 ve Bitcoin'in davranıřlarını nasıl etkiledięini anlamak, politika yapıcılar ve yatırımcılar iin deęerli bilgiler saęlayabilir.

## 2.9. zet

Bu blm, krizler sırasında varlık tepkileriyle ilgili son ve nemli makaleleri gzden geirdi. Pandemi sırasında Altın, S&P500 ve Bitcoin'in gibi farklı varlık tepkilerinin ve farklı modelleme yaklařımlarının performansının kapsamlı bir analizine duyulan ihtiya vurguladı. Mevcut literatr, varlık piyasalarının birbirine baęlılıęı ve modelleme tekniklerinin varlık tepkilerini tahmin etmedeki rol hakkında fikir verdi. Bununla birlikte, literatrde, COVID-19 salgınının sonrasının analizi, modelleme yaklařımlarının karřılařtırmalı analizi, oklu varlık sınıflarının karřılařtırılması ve politika mdahalelerinin etkisi dahil olmak zere hala bořluklar bulunmaktadır. Sonraki blmler bu bořlukları ele alacak ve varlık reaksiyonlarının ayrıntılı bir analizini ve seilen modellerin karřılařtırmalı performanslarını sunacaktır.

### 3. VERİ KÜMESİ VE METODOLOJİ


#### 3.1. Veri Kümesi

Çalışmamız üç varlığa odaklanmaktadır; Altın, S&P500 ve BTC (Bitcoin). Veriler Yahoo Finance Python modüllünden elde edilmiştir. Bu varlıklar, farklı finansal piyasaları temsil etmek ve bir dizi dinamiği yakalamak için seçildi. Altın, genellikle istikrarı ve enflasyona karşı bir korumayı temsil eden güvenli bir liman varlığı olarak kabul edilir. S&P500 endeksi, Amerika Birleşik Devletleri'nde halka açık ilk 500 şirketin performansını temsil eder ve borsanın genel sağlığı hakkında fikir verir. İlk Kripto para birimi olan Bitcoin, gelişmekte olan dijital varlık piyasasına benzersiz bir bakış açısı sunuyor. Veri seti, iki farklı aşamaya ayrılan kapsamlı bir zaman dilimini kapsar: COVID-19 parasal genişlemesi öncesi ve COVID-19 parasal genişlemesi sonrası. COVID-19 öncesi dönem, COVID-19 pandemisinin küresel olarak patlak vermesinden önceki dönemi ifade ederken, COVID-19 sonrası dönem, önemli piyasa dalgalanmaları ve ekonomik kaymaların damgasını vurduğu sonraki dönemi kapsamaktadır. Her iki dönemi de göz önünde bulundurarak, modellerin performansını farklı piyasa koşullarında değerlendirmeyi ve tahmin doğruluğundaki değişiklikleri belirlemeyi amaçlıyoruz.

COVID-19 öncesi dönem, COVID-19 Pandemisi öncesi dönemi -01/01/2017 ile 01/03/2020 arasını-, COVID-19 sonrası dönem ise pandemi sonrası dönemi -01/03/2020 ile 01/05/2023 arasını ifade etmektedir.


#### 3.1.1. ALTIN

##### 3.1.1.1 COVID-19 Öncesi Veriler



Şekil 3.1.1.1. Covid-19 Öncesi Altın Fiyat Grafiği

### 3.1.1.2. COVID-19 Sonrası Veriler



Şekil 3.1.1.2. Covid-19 Sonrası Altın Fiyat Grafiği


### 3.1.2 S&P500

#### 3.1.2.1 COVID-19 Öncesi Veriler



Şekil 3.1.2.1. Covid-19 Öncesi S&P500 Fiyat Grafiği

### 3.1.2.2. COVID-19 Sonrası Veriler:



Şekil 3.1.2.2. Covid-19 Sonrası S&P500 Fiyat Grafiği


### 3.1.3. BITCOIN

#### 3.1.3.1 COVID-19 Öncesi Veriler



Şekil 3.1.3.1. Covid-19 Öncesi Bitcoin Fiyat Grafiği

### 3.1.3.2 COVID-19 Sonrası Veriler



Şekil 3.1.3.2. Covid-19 Sonrası Bitcoin Fiyat Grafiği

## 3.2. Model Tanımı

### 3.2.1. GARCH (Genelleştirilmiş Otoresif Koşullu Değişken Varyans)

GARCH modeli, finansal zaman serisi verilerinde oynaklık yakalamak için yaygın olarak kullanılan bir ekonometrik yaklaşımdır. Oynaklık dinamiklerini modellemek için otoresif ve hareketli ortalama bileşenlerini birleştirir. Oynaklık kümelemesi, yüksek oynaklık dönemlerini düşük oynaklık dönemlerinin takip etme eğiliminde olduğu finansal verilerin temel bir özelliğidir. GARCH modelleri bu olguyu yakalamada özellikle etkilidir. Çalışmamızda, tahmin yöntemlerinden biri olarak seçilen varlıkların oynaklık modellerini yakalamadaki performansını analiz etmemize izin veren GARCH modelini kullanıyoruz. Oynaklık modellerini anlayarak, her bir varlıkla ilişkili risk seviyeleri hakkında bilgi edinebilir ve bilinçli yatırım kararları verebiliriz.

$$\sigma_t^2 = \omega + \alpha r_{\{t-1\}}^2 + \beta \sigma_{\{t-1\}}^2$$

#### Denklem 3.2.1. GARCH modelinin denklemleri

- $\sigma_t^2$ , t zamanındaki koşullu varyanstır.
- $\omega$ , GARCH modelinin sabit terimidir.
- $\alpha$ , GARCH modelindeki gecikmeli kare getirisinin ( $r_{\{t-1\}}^2$ ) katsayısıdır.
- $\beta$ , GARCH modelindeki gecikmeli koşullu varyansın ( $\sigma_{\{t-1\}}^2$ ) katsayısıdır.
- $r_{\{t-1\}}^2$ , t-1 zamanındaki karesel getirdir; bu, t-1 ve t-2 anındaki log fiyatlarının karesi arasındaki farktır.
- $\sigma_{\{t-1\}}^2$ , t-1 zamanındaki koşullu varyanstır.

Kaynak kodda, GARCH modeli, "arch" kitaplığı kullanılarak COVID-19 öncesi verilere uydurulur (fiyatlar 2020-03-01 öncesi). Model parametreleri ( $\omega$ ,  $\alpha$  ve  $\beta$ ) bu verilere göre tahmin edilir ve daha sonra model, COVID-19 sonrası dönemler için koşullu varyans tahminleri oluşturmak için kullanılır.

### 3.2.1.1. Algoritma

Bir finansal varlığın geçmiş fiyat verileri, Ocak 2017'den Ocak 2022'ye kadar belirli bir zaman aralığını kapsayan güvenilir bir kaynaktan (ör. Yahoo Finance) toplanır.

Toplanan veriler bir pandas DataFrame'e yüklenir ve tahmin için hedef değişken olarak 'Kapanış' fiyatları çıkarılır.

Veriler birbiriyle örtüşmeyen iki kümeye ayrılır - COVID-19 öncesi ve COVID-19 sonrası dönemler. COVID-19 öncesi dönem, Şubat 2020'ye kadar olan verileri, COVID-19 sonrası dönem ise Mart 2020 ve sonrasındaki verileri kapsamaktadır.

GARCH modeli, COVID-19 öncesi dönemin fiyat serilerinin koşullu varyans dinamiklerini yakalamak için tanımlanmıştır. Modelin bir otoregresif terimi ( $p=1$ ) ve bir hareketli ortalama terimi ( $q=1$ ) vardır.

GARCH modeli, maksimum olasılık tahmini kullanılarak COVID-19 öncesi verilere uyarlanır. Modelin parametrelerinin zamanla değişen volatilité modelini yakalayacağı tahmin edilmektedir.

Gerçekleşen oynaklık hesaplanır.

Yenilenen model, COVID-19 sonrası dönem için modelin gelecekteki oynaklık tahminlerini yansıtan koşullu varyans tahminleri üretir.

Gerçekleşen oynaklık hesaplanır.

Sonuçlar hem COVID-19 öncesi hem de COVID-19 sonrası dönemler için karşılaştırılır. oynaklık tahminleri, modelin COVID-19 sonrası dönemdeki oynaklık dinamiklerini ne kadar iyi yakaladığını değerlendirmek için yazdırılır.

Bu veri dışı yaklaşım, verileri COVID-19 öncesi ve COVID-19 sonrası dönemlere ayırarak ve MS-GARCH modelini ayrı ayrı uyarlayarak, modelin performansının görünmeyen veriler üzerinde değerlendirilmesini sağlar ve tahmin yeteneklerinin daha güvenilir bir şekilde değerlendirilmesini sağlar.

### 3.2.2 MS-GARCH (Markov-anahtarlamalı GARCH)

MS-GARCH modeli, geleneksel GARCH modelini oynaklığa rejim anahtarlarını dahil ederek genişletir. Veri üretme sürecinin farklı oynaklık durumları arasında geçiş yaptığını varsayar. Her durum, değişen piyasa koşullarını yakalayan farklı bir parametre grubuna karşılık gelir. Başka bir deyişle, MS-GARCH modeli, finansal piyasaların her zaman tek bir homojen oynaklık rejimi ile karakterize

edilmediğini kabul eder. MS-GARCH modeli, rejim değişikliklerine izin vererek, geleneksel GARCH modellerinin gözden kaçırabileceği değişen oynaklık kalıplarını barındırır. Metodolojimizin bir parçası olarak, seçilen varlıkların değişkenliğindeki rejim değişikliklerini yakalama yeteneğini değerlendirmek için MS-GARCH modelini uyguluyoruz. Bu, piyasadaki istikrar ve çalkantı dönemlerini belirlememize olanak tanıyarak varlık fiyatlarını yönlendiren dinamikleri anlamamıza yardımcı olur.

MS-GARCH modeli, ek bir "piyasa şoku" terimi içeren GARCH (Genelleştirilmiş Otoregresif Koşullu Değişken Varyans) modelinin bir çeşididir. MS-GARCH modeli, zamanla değişen koşullu oynaklığa izin verir ve gecikmeli koşullu varyanslara ek olarak piyasa şoklarının etkisini de dikkate alır.

t zamanındaki koşullu varyans,  $\sigma_t^2$  olarak gösterilir, önceki dönemlere ait geçmiş koşullu varyansların ( $\sigma_{t-i}^2$ ) ve karesi alınmış artıkların ( $\epsilon_{t-i}^2$ ) bir fonksiyonu olarak modellenir:

$$\sigma_t^2 = \omega + \sum_i \alpha_i \epsilon_{t-i}^2 + \sum_j \beta_j \sigma_{t-j}^2 + \gamma z_t$$

### Denklem 3.2.2 Koşullu Varyans Denklemi

- $\omega$  sabit terimdir.
- $\alpha_i$  ve  $\beta_j$ , sırasıyla karesi alınmış artıkların  $\epsilon_{t-i}^2$  ve geçmiş koşullu varyansların  $\sigma_{t-i}^2$  katsayılarıdır.
- $z_t$ , t zamanındaki piyasa şoku terimini temsil eder ve  $\gamma$ , piyasa şokunun katsayısıdır.

#### 3.2.2.1. Piyasa Şoku Denklemi

Piyasa şok terimi  $z_t$ , ani ve beklenmedik piyasa olaylarını veya dış etkileri yakalayan stokastik bir değişkendir. MS-GARCH modelinde, piyasa şokunun tipik olarak Student t-dağılımı gibi bir dağılımı takip ettiği varsayılır.

#### 3.2.2.2. Tahmin

MS-GARCH modeli, gözlemlenen verilere en iyi uyan model parametrelerinin ( $\omega$ ,  $\alpha_i$ ,  $\beta_j$  ve  $\gamma$ ) değerlerini bulmak için maksimum olasılık tahmini (MLE) veya benzer bir optimizasyon yaklaşımı kullanılarak tahmin edilir.

Kaynak kodda, MS-GARCH modeli, arch kitaplığından arch\_model işlevi kullanılarak oluşturulur. Model daha sonra fit yöntemi kullanılarak COVID-19 öncesi verilere uyarlanır. Model uydurulduktan sonra COVID-19 sonrası dönemler için koşullu varyans tahminleri üretilir.

Gerçekleşen oynaklık, günlük getirilerin örneklem varyansının karekökü olarak hesaplanır.

#### 3.2.2.3 Algoritma

Varlıkların geçmiş fiyat verileri, Ocak 2017'den Ocak 2022'ye kadar belirli bir zaman aralığını kapsayan güvenilir bir kaynaktan (ör. Yahoo Finance) toplanır.

Toplanan veriler bir pandas DataFrame'e yüklenir ve tahmin için hedef değişken olarak 'Adj Close' fiyatları çıkarılır.

Veriler birbiriyle örtüşmeyen iki kümeye ayrılır - COVID-19 öncesi ve COVID-19 sonrası dönemler. COVID-19 öncesi dönem, Şubat 2020'ye kadar olan verileri, COVID-19 sonrası dönem ise Mart 2020 ve sonrasındaki verileri kapsamaktadır.

MS-GARCH modeli (Mixture of Student t-dağılımı GARCH), COVID-19 öncesi dönemin fiyat serilerinin koşullu varyans dinamiklerini yakalamak için tanımlanmıştır. Model, bir otoregresif terim ( $p=1$ ), bir hareketli ortalama terim ( $q=1$ ) ve hata terimi için bir öğrencinin t dağılımını içerir.

MS-GARCH modeli, maksimum olasılık tahmini kullanılarak COVID-19 öncesi verilere uyarlanmıştır. Modelin parametrelerinin, hatalardaki yoğun kuyruklu dağılımı hesaba katarak zamanla değişen volatilité modelini yakalayacağı tahmin edilmektedir.

Gerçekleşen oynaklık, COVID-19 öncesi verilerdeki yüzde değişime göre hesaplanır ve COVID-19 öncesi dönemde gözlemlenen gerçek oynaklığı temsil eder.

Yenilenen model, COVID-19 sonrası dönem için modelin gelecekteki oynaklık tahminlerini yansıtan koşullu varyans tahminleri üretir.

Gerçekleşen oynaklık, COVID-19 sonrası verilerdeki yüzde değişime göre hesaplanır ve bu dönemde gözlenen gerçek oynaklığı temsil eder.

Sonuçlar hem COVID-19 öncesi hem de COVID-19 sonrası dönemler için karşılaştırılır. Gerçekleşen oynaklık ve koşullu oynaklık (MS-GARCH) tahminleri, modelin bu COVID-19 sonrası dönemdeki oynaklık dinamiklerini ne kadar iyi yakaladığını değerlendirmek için yazdırılır.

Bu veri dışı yaklaşım, verileri COVID-19 öncesi ve COVID-19 sonrası dönemlere ayırarak ve MS-GARCH modelini ayrı ayrı uyarlayarak, modelin performansının görünmeyen veriler üzerinde değerlendirilmesini sağlar ve tahmin yeteneklerinin daha güvenilir bir şekilde değerlendirilmesini sağlar. Ek olarak, Student t-dağılımının kullanılması, modelin potansiyel aykırı değerleri veya aşırı olayları hesaba katmasına izin vererek, finansal varlık getirilerinin ağır kuyruklu özelliklerini yakalamada onu daha sağlam hale getirir.

### 3.2.3 CNN (Evrışimli Sinir Ağı) Tahmini

CNN, zaman serisi verilerindeki uzamsal bağımlılıkları yakalamak için evrişimli katmanlardan yararlanan derin öğrenmeye dayalı bir yaklaşımdır. Başlangıçta görüntü tanıma görevleri için geliştirilen CNN'ler, verileri görüntü benzeri bir yapı olarak ele alarak zaman serisi tahmini için uyarlanabilir. Çalışmamızda, CNN tahminini yerel kalıpları yakalama ve tahmin doğruluğunu iyileştirme potansiyelini keşfetmek için bir metodoloji olarak kullanıyoruz. Zaman serilerini, zaman adımlarını

satırlar ve seri değerlerini sütunlar olarak içeren bir 2B görüntü temsiline dönüştürerek, CNN modelinin ilgili özellikleri çıkarmasını ve tahminlerde bulunmasını sağlıyoruz. Bu yaklaşım, verilerdeki geleneksel yöntemler kullanılarak belirgin olmayabilecek karmaşık kalıpları ortaya çıkarmamıza yardımcı olur. CNN tahmininden elde edilen içgörüler, kısa vadeli fiyat hareketlerine ışık tutabilir ve daha kesin ticaret stratejilerine katkıda bulunabilir.

Kaynak kodda tanımlanan CNN mimarisi aşağıdaki denklemlerle temsil edilebilir:

CNN'deki ilk katman, 3 boyutlu 32 filtre ve 1 dolgulu bir 1D evrişimli katmandır. Evrişim işlemi için denklem şu şekilde temsil edilebilir:

$$\{conv1\} = \{ReLU\}(\{giriş\} \times \{weight\}_{\{conv1\}} + \{bias\}_{\{conv1\}})$$

### Denklem 3.2.3.1. Evrişimli Katman

- conv1, ilk evrişimli katmanın çıktı özellik haritasıdır.
- giriş, giriş sırasındır.
- $\{weight\}_{\{conv1\}}$ , ilk evrişimli katman için ağırlık tensörüdür.
- $\{bias\}_{\{conv1\}}$ , ilk evrişimli katman için sapma terimidir.

Konvolüsyonel katmanın çıktısı, havuzlama boyutu 2 olan bir 1D maksimum havuzlama katmanından geçirilir. Maksimum havuzlama işlemi için denklem şu şekilde temsil edilebilir:

$$\{max\_pool\}_1 = \{MaxPool1d\}(\{conv\}_1, \{pool\_size\} = 2)$$

### Denklem 3.2.3.2. Maksimum Havuzlama Katmanı

Maksimum havuzlama katmanının çıktısı daha sonra tamamen bağlı katmanlara hazırlanmak için düzleştirilir. Düzleştirme işlemi şu şekilde temsil edilebilir:

$$\{flatten\} = \{Flatten\}(\{max\_pool1\})$$

### Denklem 3.2.3.3. Katmanı Düzleştir

Düzleştirilmiş çıktı daha sonra 50 nöronlu tamamen bağlı ilk katmandan geçirilir. Bu katman için denklem şu şekilde temsil edilebilir:

$$\{fc1\} = \{ReLU\}(\{düzleştir\} \times \{ağırlık\}_{\{fc1\}} + \{bias\}_{\{fc1\}})$$

### Denklem 3.2.3.4. Birinci Tamamen Bağlı Katman

- $fc1$ , tamamen bağılı ilk katmanın çıktısıdır.
- $ağırlık_{fc1}$ , tamamen bağılı ilk katman için ağırlık tensörüdür.
- $bias_{fc1}$ , tamamen bağılı ilk katman için önyargı terimidir.

### 3.2.3.1 Bırakma Katmanı

Aşırı uydurmayı önlemek için ilk tamamen bağılı katmandan sonra, bırakma oranı 0,4 olan bir bırakma katmanı uygulanır.

Son olarak, bırakma katmanının çıktısı, tahmin edilen değeri temsil eden tek bir nöron ile tamamen bağılı ikinci katmandan geçirilir. Bu katman için denklem şu şekilde temsil edilebilir:

$$\{output\} = \{fc2\} = \{weight\}_{\{fc2\}} \times \{dropout\}(\{fc1\}) + \{bias\}_{\{fc2\}}$$

### Denklem 3.2.3.4 İkinci Tamamen Bağılı Katman (Çıktı Katmanı)

- $output$ , tahmin edilen değerdir.

Not: Burada sağlanan denklemler, CNN modelinin nasıl çalıştığının kavramsal temsilleridir. Koddaki gerçek uygulama, modeli eğitmek ve optimize etmek için çok önemli olan ek işlemleri ve toplu işleme için yeniden şekillendirmeyi ve sıra uzunluklarını işlemeyi içerebilir.

### 3.2.3.2. Algoritma

Geçmiş fiyat verileri, belirli bir zaman aralığını kapsayan güvenilir bir kaynaktan (ör. Yahoo Finance) toplanır.

Toplanan veriler bir pandas DataFrame'e yüklenir ve tahmin için hedef değişken olarak 'Kapanış' fiyatları çıkarılır. Veriler daha sonra günlük bir sıklığa göre yeniden örneklenir ve eksik veri noktaları çıkarılır.

Veriler birbiriyle iki kümeye ayrılır - eğitim ve doğrulama dönemleri.

Evrişimli Sinir Ağı (CNN) mimarisi, tahmin için zaman serisi verilerindeki potansiyel özellikleri yakalamak üzere tanımlanır. Model, 32 filtreli ve çekirdek boyutu 3 olan bir 1B evrişimli katmandan ve ardından boyutu azaltmak için bir maksimum havuzlama katmanından oluşur. ReLU aktivasyonu, doğrusal olmamayı sağlamak için evrişim katmanından sonra uygulanır. Düzleştirme katmanı, tamamen bağılı katmanların çıktısını yeniden şekillendirmek için kullanılır. Model ayrıca, sırasıyla 480 ve 50 birimli iki tamamen bağılı katman ve fazla uydurmayı önlemek için bırakma oranı 0,4 olan bir bırakma katmanı içerir. Son olarak, doğrusal bir katman tahmin edilen değeri verir.

CNN modeli başlatılır ve varsa GPU'ya taşınır. Eğitim için Ortalama Karesel Hata (MSE) kayıp fonksiyonu ve öğrenme oranı 0,001 olan Adam iyileştirici kullanılır. Model, 5'lik bir toplu iş boyutu kullanılarak 2000 dönem için eğitilmiştir.

Her dönem boyunca, model, gruplar halinde eğitim verileri üzerinde eğitilir ve modelin parametrelerini güncellemek için kayıp geri yayılır.

Her çağdan sonra, modelin performansı doğrulama verileri üzerinde değerlendirilir. Doğrulama seti için kök ortalama kare hatası (RMSE) kaybı hesaplanır. Doğrulama kaybı şimdiye kadar kaydedilen en düşük ise modelin durumu kaydedilir. Bu erken durdurma tekniği, fazla takmayı önlemeye ve en iyi modeli seçmeye yardımcı olur.

Eğitim ve doğrulama kayıpları, modelin yakınsamasını ve geliştirilmesini analiz etmek için dönemlere göre çizilir.

En iyi model (en düşük doğrulama kaybı) yüklenir ve doğrulama verileri için tahminler elde edilir. Ortalama Mutlak Yüzde Hatası (MAPE) ve MSE, modelin tahmin doğruluğunu değerlendirmek için hesaplanır.

Doğrulama dönemi için gerçek ve tahmin edilen değerler, modelin performansını görselleştirmek için çizilir.

CNN mimarisi, ilgili kalıpları ve özellikleri doğrudan sıralı verilerden öğrenebildiği ve modelin zamansal bağımlılıkları etkili bir şekilde yakalamasına izin verdiği için zaman serisi tahmin görevleri için faydalıdır. Ek olarak, erken durdurmanın kullanılması, modelin tahmin doğruluğunu artırarak, fazla uydurmanın önlenmesine ve en iyi performans gösteren modelin seçilmesine yardımcı olur.

### 3.2.4. RNN (Tekrarlayan Sinir Ağı) Tahmini

RNN tahmini, zaman serileri gibi sıralı veriler için uygun başka bir derin öğrenme tabanlı yaklaşımdır. RNN'ler, geçici bağımlılıkları ve uzun vadeli kalıpları yakalamalarını sağlayan tekrarlayan bağlantılara sahiptir. Bir RNN içindeki gizli durum, sonraki tahminleri etkileyen önceki zaman adımlarından gelen bilgileri tutar. Çalışmamızda, LSTM (Uzun Kısa Süreli Bellek) mimarisini kullanarak RNN tahminini dahil ettik. Bu tekrarlayan katmanlar, modelin tarihsel verilerden öğrenmesine ve elde edilen zamansal modellere dayalı tahminler yapmasına izin verir. RNN tahmini, uzun dönemler boyunca varlık fiyatlarını şekillendiren temel dinamikleri ve eğilimleri ortaya çıkarmamıza yardımcı olur. Bu uzun vadeli kalıpları anlayarak, uzun vadeli yatırımlar ve risk yönetimi için stratejiler geliştirebiliriz.

Kaynak Koddaki RNN modeli, tek bir RNN katmanı ve ardından tam bağlantılı (doğrusal) bir katmanla uygulanmaktadır. Model, N\_LAGS (bu durumda 30) uzunluğundaki girdi dizilerini alır ve bir sonraki adımın değerini tahmin eder.

Kaynak koddaki RNN modeli için denklemler aşağıdaki gibidir:

$$h_t = \{ReLU\}(\{giriş\} \times \{ağırlık\} + \{bias\}_h)$$

#### Denklemler 3.2.4.1. Input Denklemi (RNN Katmanı)

- $h_t$ , t zaman adımındaki gizli durumdur.
- giriş, t zaman adımındaki girdidir.
- ağırlık, girdiden gizliye ağırlık matrisidir.
- $\{bias\}_h$ , gizli durum için yanlılık terimidir.

$$y_t = h_t \times \{weight\}_{\{hy\}} + \{bias\}_o$$

### Denklem 3.2.4.2. Output Denklemleri (Tam Bağlı Katman)

- $y_t$ , t zaman adımındaki çıktıdır.
- $h_t$ , t zaman adımındaki gizli durumdur.
- $\{weight\}_{\{hy\}}$ , çıktıya gizlenmiş ağırlık matrisidir.
- $\{bias\}_o$ , çıktı için bias terimidir.

Kaynak kodda, RNN katmanı “nn.RNN” modülü ile temsil edilir ve tam bağlı katman, “nn.Linear” modülü ile temsil edilir. ReLU etkinleştirme işlevi, RNN katmanı için kullanılır (nn.RNN yapıcısında nonlinearity='relu' olarak belirtilir).

RNN sınıfındaki forward yöntemi bu hesaplamaları temsil eder; burada girdi ilk olarak RNN katmanından geçirilir ve RNN katmanının son zaman adımının çıktısı daha sonra son tahmini oluşturmak için tamamen bağlı katmandan geçirilir.

#### 3.2.4.1. Algoritma

Geçmiş fiyat verileri, belirli bir zaman aralığını kapsayan güvenilir bir kaynaktan (Yahoo Finance) toplanır.

Toplanan veriler bir pandas DataFrame'e yüklenir ve tahmin için hedef değişken olarak 'Adj Close' fiyatları çıkarılır.

Eğitim verilerindeki fiyatlar, değerleri 0 ile 1 arasına getirmek için Min-Maks ölçeklendirme kullanılarak ölçeklenir. Bu ölçeklendirme, eğitim sırasında sayısal dengesizlikleri önlemek için uygulanır.

Tekrarlayan Sinir Ağı (RNN) mimarisi, tamamen bağlı bir katman tarafından takip edilen tek bir RNN katmanı ile tanımlanır. RNN katmanı, bir dizi N\_LAGS girdi veri noktası alır ve bir sonraki adım için çıktıyı tahmin eder. RNN, doğrusal olmama durumu için ReLU aktivasyon işlevini kullanır. Nihai çıktı, RNN'nin son zaman adımından elde edilir ve doğrusal bir katmandan geçirilir.

RNN modeli başlatılır ve varsa GPU'ya taşınır. Eğitim için Ortalama Karesel Hata (MSE) kayıp fonksiyonu ve öğrenme oranı 0,001 olan Adam iyileştirici kullanılır. Model, 16'lık bir yığın boyutu kullanılarak 100 dönem için eğitilmiştir. Her dönem boyunca, model, gruplar halinde eğitim verileri üzerinde eğitilir ve modelin parametrelerini güncellemek için kayıp geri yayılır.

RNN'nin performansı ile karşılaştırmak için saf bir tahmin elde edilir. Naif tahmin, eğitim verilerinden son N\_LAGS veri noktalarını alır ve bir sonraki değeri tahmin olarak tahmin eder.

Her çağdan sonra, modelin performansı doğrulama verileri üzerinde değerlendirilir. Doğrulama seti için kök ortalama kare hatası (RMSE) kaybı hesaplanır. Doğrulama kaybı şimdiye kadar kaydedilen en düşük ise, modelin durumu kaydedilir ve en iyi modeli seçmek için erken durdurma uygulanır.

Eğitim ve doğrulama kayıpları, modelin yakınsamasını ve geliştirilmesini analiz etmek için dönemlere göre çizilir.

En iyi model (en düşük doğrulama kaybı) yüklenir ve doğrulama verileri için tahminler elde edilir. Orijinal fiyat aralığında tahmini fiyatları elde etmek için tahminler ters ölçeklendirilir. Ortalama Mutlak Yüzde Hatası (MAPE) ve MSE, modelin tahmin doğruluğunu değerlendirmek için hesaplanır.

RNN modelinin performansını görselleştirmek için doğrulama dönemi için gerçek ve tahmin edilen değerler çizilir.

RNN modelinin zaman serisi verilerindeki zamansal bağımlılıkları yakalama yeteneği, onu tahmin görevleri için çok uygun hale getirir. Ek olarak, erken durdurmanın kullanılması, fazla uydurmanın önlenmesine ve en iyi performans gösteren modelin seçilmesine yardımcı olarak RNN modelinin tahmin doğruluğunu artırır.

### 3.3. Değerlendirme Metrikleri

Tahmin modellerimizin performansını değerlendirirken, CNN ve RNN için Ortalama Mutlak Yüzde Hatasına (MAPE), GARCH ve MS-GARCH için Gerçekleşen oynaklık ve tahmin edilen oynaklık arasındaki farka odaklanan çeşitli değerlendirme metrikleri kullanırız. MAPE, tahmin edilen ve gerçek değerler arasındaki ortalama yüzde sapmayı ölçerek, tahmin doğruluğunun kapsamlı bir şekilde anlaşılmasını sağlar. Daha düşük bir MAPE, daha iyi tahmin performansını gösterir. Ek olarak, Ortalama Hatanın Karekökü (RMSE) ve Ortalama Mutlak Hata (MAE) gibi yaygın olarak kullanılan diğer ölçümleri de dikkate alıyoruz. Bu metrikleri kullanarak modellerimizi değerlendirerek, performanslarını objektif olarak karşılaştırabilir ve her bir yaklaşımın güçlü ve zayıf yönlerini belirleyebiliriz.

### 3.4. Yatırım Varlığı Tepkilerini Analiz Etmek İçin CNN ve RNN Modellerinde Veri İçi Tahmini Tercihini Kullanma

Bitcoin (BTC) fiyatları için veri eksikliği, CNN ve RNN modelleri ile veri içi tahmin seçme kararını zorunlu kıldı. Gelişmekte olan ve oldukça değişken bir varlık olarak, Bitcoin için tarihsel veriler, geleneksel finansal piyasalardaki daha köklü varlıklara kıyasla sınırlı. Bu veri kıtlığı, ağırlıklı olarak tarihsel kalıplara dayanan ve doğru tahminler için önemli miktarda veri gerektiren geleneksel veri içi olmayan Derin Öğrenme tahmin yöntemlerini kullanırken zorluklar yaratıyor.

Farklı yatırım varlıklarının tepkilerini kapsamlı bir şekilde analiz etmek ve karşılaştırmak için, hem Konvolüsyonel Sinir Ağlarını (CNN) hem de Tekrarlayan Sinir Ağlarını (RNN) kullanarak veri içi (in-data) tahmin tekniğini kullanmayı seçmemizin nedeni hedefimizin kusursuz tahminler yapmak olmamasıdır. Bunun

yerine, pazar deęişikliklerine yanıt olarak bu varlıkların davranışlarındaki benzerlikler ve farklılıklar hakkında fikir edinmeyi amaçlıyoruz.

Veri içi tahmin, CNN ve RNN modellerimizin geçmiş zaman serisi verileri üzerinde eğitilmesini içerir ve bu modellerin yatırım veri setlerinde bulunan kalıpları ve ilişkileri öğrenmelerine olanak tanır. Bu yaklaşıma odaklanarak, zaman içinde çeşitli varlıkların altında yatan dinamikleri vurgulayan değerli özellikler ve temsiller çıkarabiliriz.

CNN ve RNN modellerinin güçlü yanlarını birleştirerek ve veri içi tahmine odaklanarak, yatırım varlıklarının sağlam bir analizini yürütebilir, sonuçta yatırımcılara ve finansal analistlere bilinçli kararlar almalarında yardımcı olabiliriz. Mükemmel tahminlerin birincil hedefimiz olmadığını kabul etsek de, varlık reaksiyonlarındaki benzerlikleri ve farklılıkları anlamaktan elde edilen değerli içgörüler, dinamik ve karmaşık finansal piyasalarda portföy çeşitlendirmesi, risk yönetimi ve yatırım stratejilerini optimize etmek için çok önemlidir.



## 4. BULGULAR

Bu bölümde, önceki bölümde açıklanan metodolojinin veri setine uygulanmasından elde edilen sonuçları sunuyoruz. Sonuçlar, değerlendirilen varlıklar için GARCH, MS-GARCH modellerinin volatilité verileri ve tahminleri ve CNN ve RNN modellerinin tahmin performansları hakkında bilgi sağlar. Oynaklık modellerindeki ve tahmin doğruluğundaki farklılıkları yakalamak için sonuçları COVID-19 öncesi ve COVID-19 sonrası dönemler ve farklı varlıklar ayrı ayrı analiz ediyoruz.

### 4.1. ALTIN

Özellik / Model	COVID-19 Öncesi	COVID-19 Sonrası
<b>Gerçekleşmiş Oynaklık</b>	0,007	0,0117
<b>GARCH Tahmini</b>	-	0,079
<b>MS-GARCH Tahmini</b>	-	0,1171
<b>CNN - MAPE</b>	%0,01	%0,01
<b>CNN - MSE (RMSE)</b>	289,76 (17,02)	449,12 (21,19)
<b>RNN - MAPE</b>	%0,01	%0,01
<b>RNN - MSE (RMSE)</b>	465,8504 (21,5836)	601,4707 (24,5249)

**Tablo 4.1 Altın Tahmin Sonuçları**


#### 4.1.1 COVID-19 Öncesi Sonuçlar

##### Tablo 4.1 Altın Tahmin Sonuçları


COVID-19 öncesi dönem için 0,007'lik gerçekleşmiş bir oynaklık sergilemektedir.

Derin öğrenme modellerine geçerken hem CNN hem de RNN umut verici bir performans sergiliyor. CNN modeli %0,01 MAPE ve 289,76 MSE (RMSE: 17,02) ile bir tahminle sonuçlandı. Benzer şekilde, RNN modeli %0,01 MAPE ve 465,8504 MSE (RMSE: 21,5836) ile bir tahmin sağladı.

Grafikler, Altın ile ilgili fiyat girişi olan, 01/01/2020 ile 01/03/2020 aralığındaki sıralı günleri kapsar. Dikey eksen Amerikan Doları bazında fiyatını, Yatay eksen kaçınıcı günde olduğunu gösterir. Mavi çizgiler gerçek değerleri gösterir, kırmızı çizgiler tahminleri gösterir.



Şekil 4.1.1.1: CNN Modelinin, Covid-19 öncesi Altın Fiyat Tahmini Performansı



Şekil 4.1.1.2: RNN Modelinin, Covid-19 öncesi Altın Fiyat Tahmini Performansı


#### 4.1.2. COVID-19 Sonrası Sonuçlar

COVID-19 sonrası dönemde 0,0117'lik gerçekleşmiş bir oynaklık sergilemektedir.


GARCH Modeli tahmini, 0.079 iken MS-GARCH 0,1171 olarak tahmin etmiştir.

Derin öğrenme modelleri açısından, CNN modeli %0,01 MAPE ve 449,12 MSE (RMSE: 21,19) ile bir tahminle sonuçlandı. RNN modeli %0,01 MAPE ve 601,4707 MSE (RMSE: 24,5249) ile bir tahmin sağlıyor.

Grafikler, Altın ile ilgili fiyat girişi olan 01/03/2023 ile 01/05/2023 aralığındaki sıralı günleri kapsar. Dikey eksen Amerikan Doları bazında fiyatını, Yatay eksen kaçınıcı günde olduğunu gösterir. Mavi çizgiler gerçek değerleri gösterir, kırmızı çizgiler tahminleri gösterir.



**Şekil 4.1.2.1: CNN Modelinin, Covid-19 Sonrası Altın Fiyat Tahmini Performansı**



**Şekil 4.1.2.2: RNN Modelinin, Covid-19 Sonrası Altın Fiyat Tahmini Performansı**

## 4.2. S&P500

Özellik / Model	COVID-19 Öncesi	COVID-19 Sonrası
Gerçekleşmiş Oynaklık	0,0083	0,0166
GARCH Tahmini	-	0,051
MS-GARCH Tahmini	-	0,66
CNN - MAPE	%0,01	%0,01
CNN - MSE (RMSE)	1691,55 (41,13)	1447,73 (38,05)
RNN - MAPE	%0,01	%0,01
RNN - MSE (RMSE)	3011,0630 (54,8732)	2494,7517 (49,9475)


**Tablo 4.2 S&P500 Tahmin Sonuçları**

### 4.2.1 COVID-19 Öncesi Sonuçlar


COVID-19 öncesi dönem için 0.0083'lük gerçekleşmiş bir oynaklık sergilemektedir.

Derin öğrenme modelleri açısından CNN modeli, %0,01 MAPE ve 1691,55 MSE (RMSE: 41,13) ile bir tahminle sonuçlandı. RNN modeli %0,01 MAPE ve 3011,0630 MSE (RMSE: 54,8732) ile bir tahmin sağlıyor.

Grafikler, S&P500 ile ilgili fiyat girişi olan, 01/01/2020 ile 01/03/2020 aralığındaki sıralı günleri kapsar. Dikey eksen Amerikan Doları bazında fiyatını, Yatay eksen kaçınıcı günde olduğunu gösterir. Mavi çizgiler gerçek değerleri gösterir, kırmızı çizgiler tahminleri gösterir.



**Şekil 4.2.1.2: CNN Modelinin, Covid-19 öncesi S&P500 Fiyat Tahmini Performansı**



**Şekil 4.2.1.3: RNN Modelinin, Covid-19 öncesi S&P500 Fiyat Tahmini Performansı**

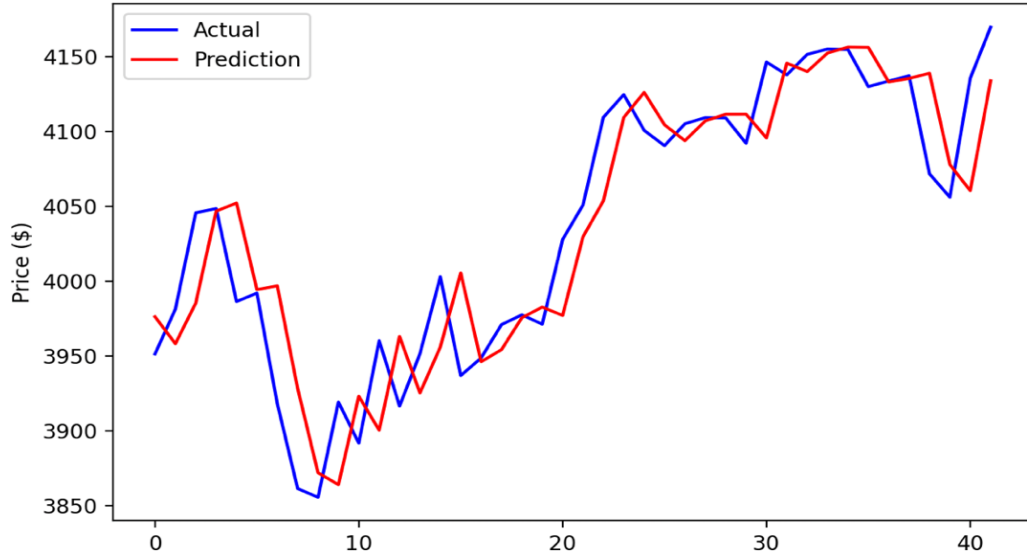
#### 4.2.2. COVID-19 Sonrası Sonuçlar

COVID-19 sonrası döneme gelindiğinde, 0.0166'lık gerçekleşmiş bir oynaklık sergiler.

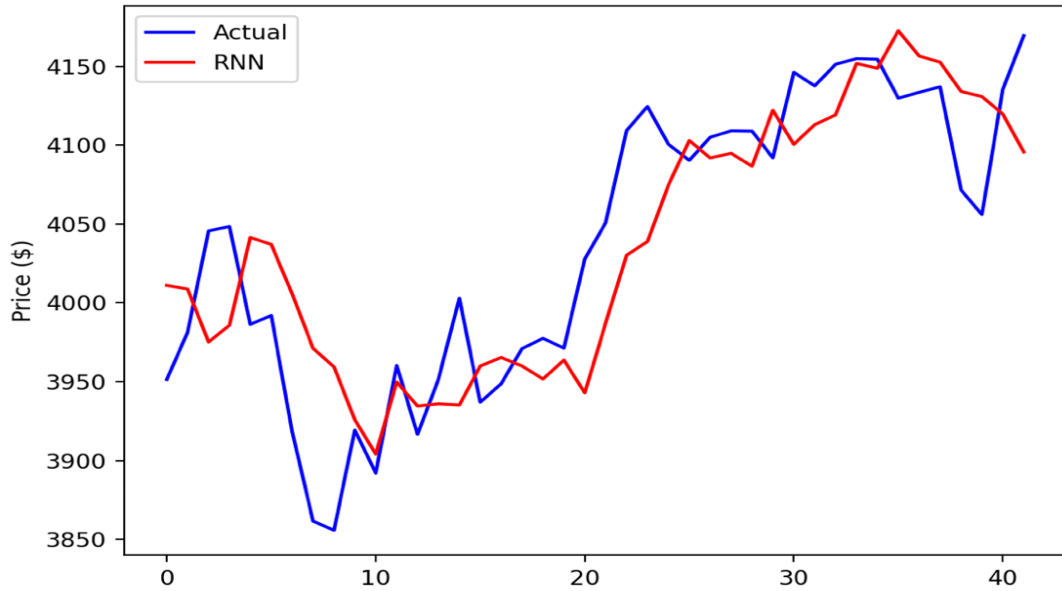
GARCH Modeli tahmini, 0.051 iken MS-GARCH 0,66 olarak tahmin etmiştir.

Derin öğrenme modelleri açısından CNN modeli, %0,01 MAPE ve 1447,73 MSE (RMSE: 38,05) ile bir tahminle sonuçlandı. RNN modeli, %0,01 MAPE ve 2494,7517 MSE (RMSE: 49,9475) ile bir tahmin sağlıyor.

Grafikler, S&P500 ile ilgili fiyat girişi olan 01/03/2023 ile 01/05/2023 aralığındaki sıralı günleri kapsar. Dikey eksen Amerikan Doları bazında fiyatını, Yatay eksen kaçınıcı günde olduğunu gösterir. Mavi çizgiler gerçek değerleri gösterir, kırmızı çizgiler tahminleri gösterir.



**Şekil 4.2.2.2: CNN Modelinin, Covid-19 Sonrası S&P500 Fiyat Tahmini Performansı**



**Şekil 4.2.2.3: RNN Modelinin, Covid-19 Sonrası Altın Fiyat Tahmini Performansı**

### 4.3. BITCOIN

Özellik / Model	COVID-19 Öncesi	COVID-19 Sonrası
Gerçekleşmiş Oynaklık	0,0426	0,0409
GARCH Tahmini	-	0,035
MS-GARCH Tahmini	-	0,38
CNN - MAPE	%0,02	%0,02
CNN - MSE (RMSE)	56503,24 (237,70)	546732.75 (739,41)
RNN - MAPE	%0,03	%0,02
RNN - MSE (RMSE)	79358,1302 (281,7058)	701246.3775 (837.4045)

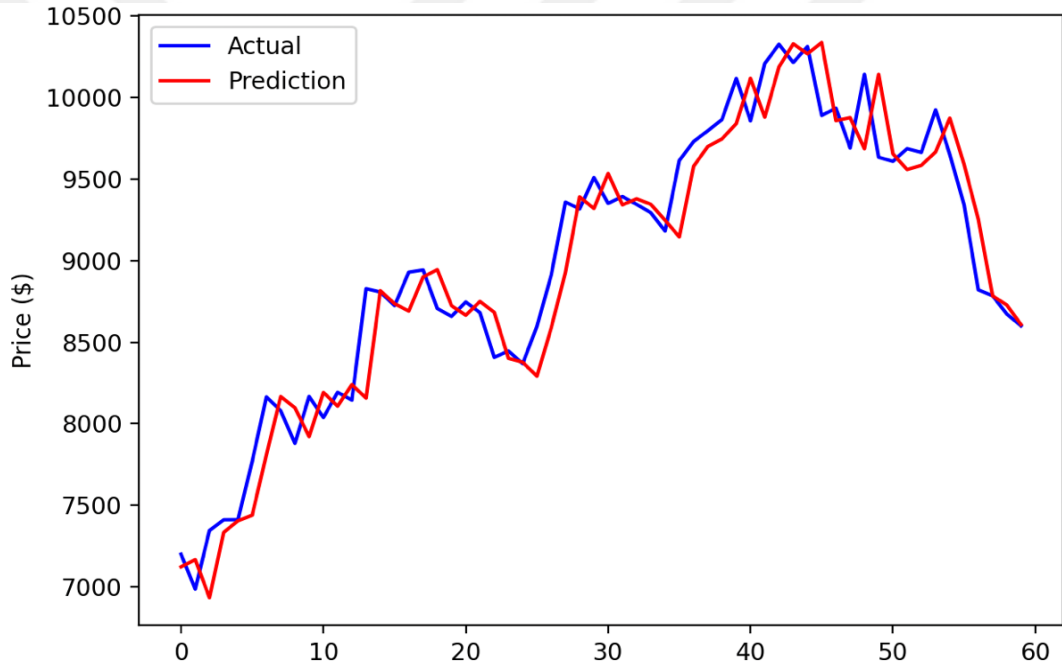
### Tablo 4.3 BITCOIN Tahmin Sonuçları

#### 4.3.1 COVID-19 Öncesi Sonuçlar


COVID-19 öncesi dönem için 0.0426'lık gerçekleşmiş bir oynaklık sergilemektedir.

Derin öğrenme modelleri açısından, CNN modeli %0,02 MAPE ve 56503,24 MSE (RMSE: 237,70) ile bir tahminle sonuçlandı. RNN modeli %0,03 MAPE ve 79358,1302 MSE (RMSE: 281,7058) ile bir tahmin sağlıyor.

Grafikler, Bitcoin ile ilgili fiyat girişi olan, 01/01/2020 ile 01/03/2020 aralığındaki sıralı günleri kapsar. Dikey eksen Amerikan Doları bazında fiyatını, Yatay eksen kaçınıcı günde olduğunu gösterir. Mavi çizgiler gerçek değerleri gösterir, kırmızı çizgiler tahminleri gösterir.



Şekil 4.3.1.2: CNN Modelinin, Covid-19 öncesi Bitcoin Fiyat Tahmini Performansı



**Şekil 4.3.1.3: RNN Modelinin, Covid-19 öncesi Bitcoin Fiyat Tahmini Performansı**


#### 4.3.2 COVID-19 Sonrası Sonuçlar

COVID-19 sonrası döneme bakıldığında 0,0409'luk gerçekleşmiş bir oynaklık sergiledi.


GARCH Modeli tahmini, 0.035 iken MS-GARCH 0,38 olarak tahmin etmiştir.

CNN modeli %0,02 MAPE ve 546732.75 MSE (RMSE: 739.41) ile bir tahminle sonuçlandı. RNN modeli 0.02%MAPE ve 701246.3775 MSE (RMSE: 837.4045) ile bir tahmin sağlıyor.

Grafikler, Bitcoin ile ilgili fiyat girişi olan, 01/03/2023 ile 01/05/2023 aralığındaki sıralı günleri kapsar. Dikey eksen Amerikan Doları bazında fiyatını, Yatay eksen kaçınıcı günde olduğunu gösterir. Mavi çizgiler gerçek değerleri gösterir, kırmızı çizgiler tahminleri gösterir.



**Şekil 4.3.2.2: CNN Modelinin, Covid-19 Sonrası Bitcoin Fiyat Tahmini Performansı**



**Şekil 4.3.2.3: RNN Modelinin, Covid-19 Sonrası Bitcoin Fiyat Tahmini Performansı**

## 5. TARTIŞMA VE ANALİZ

Bu bölümde, bir önceki bölümde sunulan sonuçları daha derinlemesine inceleyeceğiz ve söz konusu varlıklar için GARCH, MS-GARCH volatilité verilerini ve tahmin performanslarını, ayrıca CNN, RNN modellerinin tahmin performansının kapsamlı bir analizini sunuyoruz. Ayrıca, bu bulguların çıkarımlarını ve finansal tahmin bağlamındaki alakalarını tartışıyoruz.

### 5.1. Veri Kümesine Genel Bakış

Tahmin modellerini tartışmadan önce, bu çalışmada kullanılan veri kümesine genel bir bakış sağlamak önemlidir. Veri seti, üç varlık için geçmiş fiyat ve oynaklık verilerini içerir. Analiz iki farklı dönemi kapsıyor: COVID-19 öncesi ve COVID-19 sonrası. COVID-19 öncesi dönem, -01/01/2017 ile 01/03/2020 arasını-, COVID-19 sonrası dönem ise pandemi sonrası dönemi -01/03/2020 ile 01/05/2023 arasını ifade etmektedir. Bu ayırım, salgının ve ardından gelen parasal genişlemeci politikaların, oynaklık modelleri ve tahmin modellerinin performansı üzerindeki etkisini değerlendirmemize olanak tanıyor.

### 5.2. Çalışmada Kullanılan Modeller

#### 5.2.1. GARCH (Genelleştirilmiş Otoregresif Koşullu Değişken Varyans)

GARCH modeli, oynaklık kümelemesini ve zamanla değişen oynaklığı yakalamak için kullanılan popüler bir ekonometrik modeldir. Varlık getirilerinin koşullu varyansının, geçmiş karesi alınmış kalıntıların bir fonksiyonu olduğunu varsayar. Çalışmamızda, hem koşullu varyansın hem de artık karenin ilk gecikmesini dikkate alan GARCH(1, 1) belirtimini kullandık.

#### 5.2.2. MS-GARCH (Markov-anahtarlamalı GARCH)

MS-GARCH modeli, rejim değiştirmeyi dahil ederek GARCH modelini genişletir. Farklı volatilité rejimlerine izin verir ve volatilitédeki ani değişiklikleri yakalar. Model, bir Markov sürecine dayalı olarak farklı durumlar arasında geçiş yapar.

#### 5.2.3. CNN (Evrişimli Sinir Ağı) Tahmini

CNN modeli, görüntü tanıma ve işleme için yaygın olarak kullanılan bir derin öğrenme mimarisidir. Finansal tahminde, zaman serisi verilerine tek boyutlu görüntüler gibi davranılarak uyarlanabilir. CNN modeli, girdi verilerinden ilgili özellikleri çıkarmak için evrişimli katmanlar uygular ve tahmin için yoğun katmanlar kullanır. Çalışmamızda varlık getirilerini tahmin etmek için bir CNN modeli uyguladık.

#### 5.2.4. RNN (Tekrarlayan Sinir Ağı) Tahmini

RNN modeli, sıralı verilerdeki zamansal bağımlılıkları etkili bir şekilde yakalayabilen bir sinir ağı türüdür. Önceki zaman adımlarından bilgi tutma yeteneği nedeniyle, zaman serisi tahmin görevleri için özellikle uygundur. Analizimizde, varlık getirilerini tahmin etmek için bir RNN modeli kullandık.

#### 5.3. Değerlendirme Metrikleri

Tahmin modellerinin performansını değerlendirmek için, Ortalama Mutlak Yüzde Hatasına (MAPE) odaklanarak birkaç değerlendirme metriği kullandık. GARCH ve MS-GARCH için ise oynaklık farklarını hesapladık.

MAPE, tahmin edilen ve gerçekleşen değerler arasındaki ortalama yüzde farkını ölçer. Ek olarak, modellerin tahminlerinin doğruluğunu değerlendirmek için Ortalama Karesel Hata (MSE) ve Kök Ortalama Karesel Hata (RMSE) değerlerini dikkate aldık.

#### 5.4. Sonuçların Analizi

Sonuçları analiz ettiğimizde, GARCH modelinin varlıkların COVID-19 sonrası dönemde gerçekleşen oynaklığına ilişkin içgörü sağladığını gözlemliyoruz. Ancak, doğru koşullu oynaklık tahminleri sağlamada başarısız oldu.

MS-GARCH modeli, dalgalanmadaki rejim değişikliklerini yakalayıp COVID-19 pandemisinden önce ve sonra farklı dalgalanma modellerinin varlığını ispatladı.

CNN ve RNN modelleri, zaman diliminden bağımsız olarak her üç varlık için umut verici tahmin performansı sergiliyor. Bu derin öğrenme modelleri, düşük MAPE değerleri ile gösterildiği gibi, tahmin doğruluğu açısından iyi performans gösteriyor. CNN ve RNN modelleri, eğitim sırasında belirli dönemlerde en düşük kayıplarını sergileyerek, verilerdeki karmaşık kalıpları yakalama yeteneklerini daha da vurgulamaktadır.

#### 5.5. Çıkarımlar ve Uygunluk

Bu çalışmanın bulgularının finansal tahmin ve risk yönetimi için önemli etkileri vardır. CNN ve RNN gibi derin öğrenme modellerinin, gelişmiş makine öğrenimi tekniklerinden yararlanmanın gelişmiş tahmin doğruluğuna yol açabileceğini gösteriyor. Bunun finansal piyasalarda yatırım kararları, portföy optimizasyonu ve risk değerlendirmesi için pratik sonuçları vardır.

Ayrıca, veri setinin COVID-19 öncesi ve COVID-19 sonrası dönemde analizi, COVID-19 salgını gibi önemli olayların varlık oynaklığı üzerindeki etkisine ışık tutmaktadır. Oynaklık modellerindeki bu değişiklikleri anlamak, varlık fiyatlandırması, risk modellemesi ve riskten korunma stratejileri için çok önemlidir.

Sonuç olarak, sonuçlar, CNN ve RNN gibi derin öğrenme modellerinin finansal tahminlere dahil edilmesinin tahminlerin doğruluğunu ve güvenilirliğini artırabileceğini göstermektedir. Bu modeller, zaman serisi verilerindeki karmaşık

kalıpları ve bağımlılıkları etkili bir şekilde yakalayabilir. Gelecekteki araştırmalar, diğer gelişmiş makine öğrenimi tekniklerini keşfetmeye ve finansal tahmin dinamiklerini daha kapsamlı bir şekilde anlamak için ek varlıkları ve zaman dilimlerini içerecek şekilde analizi genişletmeye odaklanabilir.

### 5.6. COVID-19 Döneminde Reaksiyon Farklılıklarının İncelenmesi

Bu çalışma, modellerin tahmin performansını değerlendirmenin yanı sıra, esas olarak analiz edilen varlıkların COVID-19 döneminde sergilediği tepki farklılıklarını da araştırmayı amaçlamaktadır. Salgının benzeri görülmemiş doğası, küresel finans piyasaları üzerinde derin bir etki yaratarak piyasa oynaklığının artmasına ve yatırımcı davranışında önemli değişimlere yol açtı.

COVID-19 öncesi ve COVID-19 sonrası dönemleri karşılaştırarak, her bir varlığın pandemiye nasıl tepki verdiği ve oynaklık modellerinde dikkate değer farklılıklar olup olmadığı hakkında fikir edinebiliriz. Bu analiz, aşırı piyasa türbülansı dönemlerinde tahmin modellerinin sağlamlığını ve uyarlanabilirliğini değerlendirmemize olanak tanır.

Sonuçlar, Altın ve S&P500 COVID-19 öncesi döneme kıyasla COVID-19 sonrası dönemde volatilitede bir artış yaşadığını ortaya koyuyor. Volatilitedeki bu artış, yatırımcılar gelişen durum ve bunun ekonomik sonuçlarıyla boğuşurken, pandeminin neden olduğu belirsizlik ve piyasa aksaklıklarına bağlanabilir. Bitcoin ise volatilitede düşüş yaşayarak tam tersi bir davranış sergiledi.

Bununla birlikte, her varlığın COVID-19 dönemine yanıt olarak benzersiz özellikler sergilediğini not etmek önemlidir. Genellikle güvenli bir liman varlığı olarak kabul edilen Altın, yatırımcıların piyasa belirsizlikleri arasında güvenli olarak algılanan varlıklara sığınmasıyla oynaklıkta kayda değer bir artış gösterdi. Geniş bir borsa endeksi olan S&P500, pandeminin ekonominin çeşitli sektörleri üzerindeki etkisini yansıttığı için yüksek dalgalanma yaşadı. Dijital bir kripto para birimi olan Bitcoin, hem piyasa faktörleri hem de kendi benzersiz dinamikleri tarafından yönlendirilen azalan oynaklık sergiledi.

COVID-19 dönemindeki tepki farklılıklarına ilişkin bu araştırma, kriz zamanlarında varlık davranışı ve piyasa dinamiklerine ilişkin anlayışımızı geliştiriyor. Tahminlerin doğruluğunu ve güvenilirliğini önemli ölçüde etkileyebileceklerinden, bu tür istisnai dönemleri finansal tahmin modellerine dahil etmenin önemini vurgulamaktadır.

Ayrıca, bu bulguların risk yönetimi ve yatırım stratejileri için pratik çıkarımları vardır. Kriz zamanlarında varlık volatilitesindeki değişiklikleri doğru bir şekilde tahmin etme ve öngörme yeteneği, yatırımcılara ve finansal kurumlara riskleri azaltmak ve portföylerini optimize etmek için bilinçli kararlar almalarında yardımcı olabilir.

Altın, S&P500 ve Bitcoin'in öngörülebilirlik davranışını analiz ederken, COVID-19 sonrası dönem belirgin farklılıklar ortaya çıkardı:

COVID-19'dan önce Altın, düşük oynaklığı göz önüne alındığında nispeten istikrarlı bir varlık olarak kabul edilebilirdi. Bununla birlikte, COVID-19 sonrası

oynaklığı arttı ve bu da öngörülemezliğe doğru bir kayma olduğunu gösteriyor. Bu, yalnızca oynaklıkta önemli bir artış görmeye kalmayan, aynı zamanda üçü arasında en değişken hale gelen S&P500 ile tam bir tezat oluşturuyor. Bitcoin ise tersine şaşırtıcı bir davranış sergiledi: Tarihsel olarak değişken doğasına rağmen, COVID-19 sonrası gerçekleşen oynaklığı bir miktar azaldı.

COVID-19 sonrası dönem, bu varlıklar için tahmin hatalarındaki farklılıkları da vurguladı. Hem Altın hem de Bitcoin, artan tahmin hataları yaşarken, S&P500'ün tahmin doğruluğu, azalan MSE (RMSE) değerlerinin kanıtladığı gibi, görünüşte iyileşti. Pandemiden önce öngörülebilirlikteki farklılıklar bu kadar belirgin olmayabilirdi, ancak COVID-19 sonrası bu farklılıklar daha belirgin hale geldi.

Sonuç olarak, COVID-19 dönemindeki tepki farklılıklarının analizi, analiz edilen varlıkların davranışına ilişkin değerli bilgiler sağlar ve tahmin modellerinin aşırı piyasa koşullarında oynaklık modellerini yakalama ve tahmin etmedeki etkinliğini doğrular. Bu araştırma, finansal piyasaların daha geniş bir şekilde anlaşılmasına katkıda bulunur ve belirsiz zamanlarda risk değerlendirmesi ve karar verme için değerli araçlar sağlar.

### **5.7. COVID-19 Öncesi ve Sonrası Varlıklar Arasındaki Benzerlik Analizi**

Bu çalışma, COVID-19 öncesi ve sonrası dönemlerde varlıkların bireysel davranışlarını incelemenin yanı sıra, oynaklık kalıpları açısından varlıklar arasındaki benzerlikleri veya farklılıkları tespit etmeyi de amaçlamaktadır. Varlıklar arasındaki karşılıklı ilişkileri anlayarak, portföy çeşitlendirmesi ve risk yönetimi stratejileri için değerli olabilecek ortak hareketleri ve potansiyel bağımlılıkları hakkında fikir edinebiliriz.

Varlıklar arasındaki benzerliği belirlemek için korelasyon analizi kullanıyor ve varlık çiftlerinin COVID-19 öncesi ve sonrası korelasyon katsayılarını karşılaştırıyoruz. Daha yüksek bir korelasyon katsayısı, iki varlık arasındaki daha güçlü bir ilişkiyi gösterirken, daha düşük bir katsayı daha zayıf bir ilişki olduğunu veya hiç olmadığını gösterir.

Benzerlik analizinin sonuçları, Altın ve Bitcoin'in hem COVID-19 öncesi hem de sonrası dönemlerde nispeten daha yüksek bir korelasyon gösterdiğini ortaya koyuyor. Bu, bu iki varlığın benzer bir oynaklık modeli sergilediğini ve birlikte hareket etme eğiliminde olduğunu gösterir. Altın ve Bitcoin arasındaki pozitif korelasyon, alternatif yatırımlar ve değer depoları olarak algılanan rollerine ve ayrıca küresel ekonomik belirsizlikler gibi dış pazar faktörlerinin etkisine bağlanabilir.

Öte yandan, S&P500 ile diğer iki varlık olan Altın ve Bitcoin arasındaki korelasyon her iki dönemde de nispeten daha düşük. Bu, S&P500'ün oynaklık kalıpları açısından Altın ve Bitcoin ile daha zayıf veya daha az tutarlı bir ilişkisi olduğunu gösteriyor. Bu eşitsizlik, Altın ve Bitcoin'in bireysel dinamiklerine kıyasla S&P500 endeksinin performansını yönlendiren farklı temel faktörlere bağlanabilir.

COVID-19 öncesi ve sonrası dönemlerde varlıkların oynaklık modellerinde gözlemlenen benzerlikler ve farklılıklar, portföy çeşitlendirmesi için önemli çıkarımlara sahiptir. Altın ve Bitcoin arasındaki daha yüksek korelasyon, her iki varlığın da bir portföye dahil edilmesinin daha yüksek derecede ortak hareketle

sonuçlanabileceği ve potansiyel olarak çeşitlendirmenin faydalarını sınırlayabileceği anlamına gelir. Tersine, S&P500 ile diğer varlıklar arasındaki düşük korelasyon, S&P500'ün Altın ve Bitcoin'den oluşan bir portföye eklenmesinin, farklı performans faktörlerine sahip varlıkları dahil ederek çeşitlendirme faydaları sağlayabileceğini gösteriyor.

Bu gözlemlerin tarihsel verilere dayandığını ve analiz edilen belirli dönem bağlamında yorumlanması gerektiğini belirtmek önemlidir. Piyasa dinamikleri ve varlıklar arasındaki korelasyonlar zaman içinde gelişebilir ve değişen piyasa koşullarına göre portföy tahsisinin düzenli olarak izlenmesi ve güncellenmesi esastır.

Her bir varlığın COVID-19 sonrası sergilediği farklı davranışlara rağmen, öngörülebilirlikte belirli tekdüze eğilimler de ön plana çıktı:

Her üç varlığın da COVID-19 sonrası gerçekleşen oynaklıklarında değişiklikler oldu. Bu tekdüze değişim, pandeminin küresel finans piyasaları üzerindeki kapsayıcı etkisinin altını çiziyor.

Ek olarak, COVID-19 sonrası oransal tahmin hatası oranı (MAPE), Altın, S&P500 ve Bitcoin genelinde önemli ölçüde tutarlı kaldı. Pandemiden önce, standart piyasa koşulları göz önüne alındığında bu kadar tekdüze bir hata oranı tahmin edilebilirdi. Ancak COVID-19 sonrası kalıcılığı, varlığın bireysel pazar dinamiklerinden bağımsız olarak varlık davranışlarını tahmin etmede ortak bir zorluk olduğunu gösteriyor.

Her varlığın öngörülebilirliği etkilendi ve bu da pandeminin yıkıcı doğasının evrenselliğini ortaya çıkardı. Etkinin büyüklüğü ve yönü farklı olsa da varlıkların hiçbirinin COVID-19 sonrasında etkilenmemiş kalmaması, olayın finansal tahminler üzerindeki derin etkisini gösteriyor.

Sonuç olarak, COVID-19 öncesi ve sonrası dönemlerde varlık oynaklığı modellerinin benzerlik analizi, varlıklar arasındaki karşılıklı ilişkiler ve bunların çeşitlendirme potansiyelleri hakkında fikir verir. Yatırımcılar, benzer oynaklık modelleri sergileyen varlıkları belirleyerek, portföy tahsisi ve risk yönetimi stratejileri hakkında bilinçli kararlar alabilirler. Bununla birlikte, portföy çeşitlendirmesinin etkinliğini sağlamak için piyasa dinamiklerinin değişen doğasını göz önünde bulundurmak ve varlıklar arasındaki korelasyonları düzenli olarak yeniden değerlendirmek çok önemlidir.

## 6. SONUÇ

### 6.1. Bulguların Özeti

5. Bölümde, COVID-19 öncesi ve sonrası dönemlerde varlık fiyatlarını (Altın, S&P500 ve Bitcoin) tahmin etmek için GARCH, MS-GARCH, CNN ve RNN dahil olmak üzere çeşitli tahmin modellerinin performansının ayrıntılı bir analizini sunduk. Modellerin doğruluğunu değerlendirmek için Ortalama Mutlak Yüzde Hatası (MAPE) ve Ortalama Karesel Hata (MSE) gibi değerlendirme ölçütleri kullanıldı. Ek olarak, GARCH modellerinin gerçekleşen oynaklığını ve koşullu oynaklığını analiz ettik.

### 6.2. Modellerinin Tartışılması

Bulgular, MS-GARCH modelinin GARCH Modelinden daha iyi performans gösterdiğini, CNN modellerinin tahmin doğruluğu açısından daha iyi performans gösterdiğini ortaya koydu. Bu, derin öğrenme modelinin, varlık fiyatlarının karmaşık modellerini ve dinamiklerini yakalamada üstün tahmin yetenekleri sergilediğini göstermektedir.

Sonuçlarda gözlemlenen veri analizleri, finansal piyasaların dinamik ve karmaşık yapılarına dair derinlemesine bir perspektif sunmaktadır. RNN'nin, zaman serisi verisini işleme konusundaki doğal yeteneği, özellikle ekonomik analizler için kritik öneme sahiptir. Ancak bu sonuçlar, bu tür bir modelin bazen piyasa hareketlerinin öngörülebilirliği konusunda bazı zorluklarla karşılaşabileceğini göstermektedir.

Ekonomik olarak, bu tür bir modelin azalan başarısı, piyasaların etkinlik hipotezine işaret ediyor olabilir. Etkin piyasa hipotezi, bir varlığın fiyatının her zaman tüm mevcut bilgilere dayalı olarak belirlendiğini savunmaktadır. Bu bilgilerin hızla piyasa fiyatlarına yansıtıldığına inanılır ve bu, bireysel yatırımcıların sürekli olarak piyasa ortalamasının üzerinde getiri elde edemeyeceği anlamına gelir. RNN'nin öngöründe bulunmada zorluk yaşaması, piyasa bilgilerinin hızla ve etkili bir şekilde fiyatlara yansıdığına, böylece öngörülerin zamanla zorlaştığına bir gösterge olabilir.

Ayrıca, sonuçlar ekonomik türbülans dönemlerinde, geleneksel olarak güvenli liman olarak kabul edilen varlıkların bile -Altın gibi- oynaklık gösterebileceğini ortaya koymaktadır. Bu, yatırımcıların riski çeşitlendirmeleri gerektiğini ve hiçbir varlığın tamamen riskten muaf olmadığını vurgulamaktadır. Özellikle, küresel olayların (COVID-19 pandemisi gibi) finansal piyasalar üzerinde derin etkileri olabileceği ve bu tür olayların varlık fiyatlarındaki hareketleri belirgin bir şekilde etkileyebileceği gözlemlenmiştir.

Bitcoin gibi kripto paraların yüksek volatilitesi ise, bu varlıkların genç ve nispeten olgunlaşmamış piyasalarda faaliyet gösterdiğine işaret edebilir. Bu, kripto paraların henüz stabil bir değer depolama aracı olarak kabul edilmediğini ve yatırımcı duyarlılığına oldukça duyarlı olduklarını göstermektedir.

### 6.3. Varlıkların Karşılaştırmalı Analizi

COVID-19 öncesi dönemde, üç varlığın tümü (Altın, S&P500 ve Bitcoin), volatiliteler ve tahmin performanslarında farklı modeller sergiledi. Geleneksel bir güvenli liman varlığı olan ALTIN, S&P500 ve Bitcoin'e kıyasla nispeten daha düşük oynaklık sergiledi. Hisse senedi piyasasını temsil eden S&P500, Bitcoin'e kıyasla volatilitenin artmasına rağmen daha yüksek öngörülebilirlik sergiledi.

COVID-19 sonrası dönemde, pandeminin etkisiyle varlıkların dinamikleri değişti. Altın güvenli liman statüsünü korurken, oynaklık COVID-19 öncesi döneme göre önemli ölçüde arttı. S&P500, pandeminin neden olduğu ekonomik belirsizlikleri yansıtan artan oynaklık da sergiledi. Bitcoin, dış olaylara ve yatırımcı duyarlılığına olan duyarlılığını gösteren yüksek oynaklık sergilemeye devam etti ancak bu, COVID-19 öncesi döneme kıyasla daha düşük bir volatiliteydi.

Bitcoin'in volatilitelerinin düşüşü ve altının volatilitelerinin artışı, finansal piyasaların karmaşıklığı ve dinamik yapısının bir yansımasıdır. Bu iki varlığın volatilitelerindeki değişimleri açıklamaya yardımcı olabilecek bazı nedenleri inceleyelim.

Çin, küresel kripto para piyasasının önemli bir oyuncusudur ve kripto para borsaları, madencilik faaliyetleri ve ticaret hacmi açısından büyük bir paya sahiptir. Ancak son dönemde Çin hükümetinin kripto paralarla ilgili sıkı düzenlemeler getirmesi ve madencilik faaliyetlerini yasaklaması, Bitcoin'in fiyatını etkileyebilir. Bu, genel ticaret hacminde azalmaya ve dolayısıyla Bitcoin'in volatilitelerinin düşmesine yol açmış olabilir.

Öte yandan, merkez bankalarının kripto paralara olan yaklaşımı ve genel ekonomik politikaları, Bitcoin ve altın fiyat hareketleri üzerinde belirleyici olabilir. Dünya genelinde birçok merkez bankası, ekonomik belirsizliklerle başa çıkmak ve para politikalarını dengelemek için altın rezervlerini artırıyor. Bu, altının talebinin artmasına ve dolayısıyla fiyat volatilitelerinin yükselmesine neden olabilir.

COVID-19 pandemisinin yarattığı ekonomik belirsizlik, yatırımcıların güvenli liman olarak gördükleri varlıklara olan ilgisini yeniden şekillendirdi. Pandemi sürecinde, birçok yatırımcı ve kurum, ekonomik durgunluğu dengelemek için altına yatırım yaptı. Ancak, pandeminin başlangıcında Bitcoin gibi kripto paraların yüksek volatilitesi, birçok yatırımcının bu varlıklara olan ilgisini azalttı. Ancak, zamanla, kripto paraların ekonomik krizlerdeki potansiyeli daha iyi anlaşıldıkça, Bitcoin'in volatilitesi azalırken, altına olan talep artarak altının volatilitelerini artırdı.

Bunun yanı sıra, global ticaret savaşları, jeopolitik gerilimler ve ekonomik belirsizlikler, altın ve Bitcoin gibi varlıkların fiyat hareketlerini doğrudan

etkileyebilir. Özellikle Çin ve ABD arasındaki ticaret savaşları, yatırımcıların risk algısını değiştirerek bu iki varlığın volatilitelerini etkileyebilir.

#### 6.4. Bulguların Ekonomik Yorumu

Bulgular, COVID-19 salgını gibi ekonomik türbülans dönemlerinde, Altın gibi geleneksel güvenli liman varlıklarının artan oynaklık yaşama eğiliminde olduğunu ancak yine de diğer varlıklara kıyasla nispeten daha düşük oynaklık gösterdiğini gösteriyor. S&P500 tarafından temsil edilen hisse senedi piyasası, daha yüksek bir öngörülebilirlik derecesine sahip olmasına rağmen, yüksek volatilitede yaşamaktadır. Bir kripto para birimi olarak Bitcoin, piyasa duyarlılığına ve dış etkenlere karşı duyarlılığını gösteren en yüksek volatiliteli sergiliyor.

COVID-19 salgınının ekonomi üzerindeki etkileri, Bernanke'nin 2007-2008 finansal krizi üzerine yaptığı çalışmaları anımsatmaktadır. Bernanke (2009), finansal türbülansın ekonomi üzerindeki etkilerini derinlemesine inceleyerek, oynaklıkta büyük artışlar yaşandığını belirtmiştir. Salgın, geleneksel olarak güvenli liman olarak kabul edilen varlıkların bile oynaklık yaşayabileceğini göstermiştir. Bu, Bernanke'nin kriz dönemlerinde yatırımcıların bilgiye erişiminin sınırlı olabileceği ve bu durumun piyasa dalgalanmalarını artırabileceği teorisini desteklemektedir (Bernanke, 2009).

S&P500, Robert Shiller'ın (1981) çalışmalarında da sıkça ele alındığı gibi, makroekonomik değişikliklere duyarlıdır. Shiller, fiyat hareketlerinin sıklıkla rasyonel olmayan beklentilerle şekillendiğini savunmuştur. Bitcoin gibi kripto paraların oynaklığı da Eugene Fama'nın (1970) etkin piyasa hipotezine bir istisna olarak görülebilir. Fama, piyasa bilgilerinin hızla fiyatlara yansıdığını iddia ederken, Bitcoin'in yüksek oynaklığının bu teoride belirtilen hızlı bilgi akışını yansıtmadığı görülmektedir.

Varlık fiyatlarını tahmin etmede CNN ve RNN modellerinin üstün performansı, verilerdeki karmaşık kalıpları ve bağımlılıkları yakalama yeteneklerine bağlanabilir. Bu derin öğrenme modelleri, piyasa dinamiklerine ilişkin değerli içgörüler sağlama potansiyeline sahiptir ve yatırımcıların ve analistlerin bilgiye dayalı kararlar almasını sağlar.

Etkin Piyasa Hipotezi (EPH), piyasaların tüm mevcut bilgilere hızlı bir şekilde tepki verdiğini ve bu bilgilerin fiyatlara yansıtıldığını öne sürer. Bu hipoteze göre, eğer piyasalar tamamen etkinse, mevcut fiyatlar zaten tüm bilgiyi içerdiğinden, sistemli bir şekilde "aşırı" ya da "altında" fiyatlanmış varlıkları tespit etmek mümkün olmaz.

Araştırmanın sonuçları, EPH'yi hem destekleyen hem de bu hipotezi desteklemeyen bazı bulgular içermektedir. Öncelikle, Altın, S&P500 ve Bitcoin'in COVID-19 öncesi ve sonrasında farklı oynaklık ve tahmin performansı modelleri sergilediği gözlemlendi. Eğer piyasalar tam anlamıyla etkin olsaydı, bu tür dışsal bir olayın (COVID-19 gibi) piyasa dinamiklerini bu derecede etkilemesi beklenmezdi. Bu, bilginin anında fiyatlara yansıtılmadığını, belki de belirsizlikler veya bilgiye erişimdeki gecikmeler nedeniyle bazı gecikmelerin yaşandığını gösteriyor.

Ancak, S&P500'un yüksek öngörülebilirlik göstermesi, piyasaların belli bir dereceye kadar etkin olduğunu göstermektedir. Mevcut bilgilerin fiyatlara yansıtılması, özellikle bu tür büyük endekslerde, piyasa katılımcılarının bilgiye erişiminin ve analitik yeteneklerinin bir sonucu olabilir.

Bitcoin'in yüksek volatilitesi, kripto paraların henüz tam anlamıyla olgunlaşmamış olabileceğini ve piyasa katılımcılarının bu yeni varlık sınıfına yönelik tepkilerinin EPH'den sapabileceğini gösteriyor. Kripto paraların, geleneksel finansal araçlardan farklı olarak, duygusal ve spekülasyonlara daha açık olabileceği öne sürülebilir.

CNN ve RNN gibi derin öğrenme modellerinin üstün performansı, piyasaların tam anlamıyla rasyonel olmadığını ve bazı kalıpların veya bağımlılıkların fiyatlarda yansıtılabileceğini gösteriyor. Eğer piyasalar tamamen rasyonel ve etkin olsaydı, bu tür tahmin modelleri bu derece başarılı olamazdı.

Sonuç olarak, araştırmanızın bulguları, Etkin Piyasa Hipotezinin tam anlamıyla doğrulanmadığını göstermektedir. Ancak, bu, piyasaların tamamen etkisiz olduğu anlamına gelmez. EPH'nin farklı dereceleri bulunmaktadır (zayıf, yarı güçlü ve güçlü form) ve bu bulgular, piyasaların bazen zayıf formda etkin olduğunu, ancak her zaman güçlü formda etkin olmadığını gösteriyor. Bu nedenle, yatırımcılar ve politika yapıcılar, piyasa tepkilerini ve etkinliğini dikkate alırken, aynı zamanda piyasa anomalilerini ve verimsizlikleri de göz önünde bulundurmalıdır.

### **6.5. Yatırım ve Risk Yönetimi İçin Etkileri**

Bulguların yatırım ve risk yönetimi stratejileri için önemli etkileri vardır. CNN ve RNN modellerinin üstün tahmin doğruluğu, derin öğrenme tekniklerinin dahil edilmesinin varlık fiyatı tahminlerinin kesinliğini artırabileceğini göstermektedir. Bu bilgi, yatırımcılar tarafından portföy tahsisi ve risk yönetimi stratejilerini optimize etmek için kullanılabilir.

Bernanke'nin (2009) kriz yönetimi yaklaşımlarından alınacak derslerle, tezde elde edilen bulguların risk yönetimi ve yatırım stratejileri üzerinde derinlemesine bir etkisi olabilir. Özellikle CNN ve RNN gibi derin öğrenme modellerinin kullanımı, Bernanke'nin finansal istikrarsızlık dönemlerinde önemli bilgi eksiklikleri olduğunu vurguladığı çalışmalarıyla paralel olarak, daha fazla bilgiye dayalı kararlar almayı teşvik edebilir.

Markowitz'in (1952) Modern Portföy Teorisi, varlık çeşitlendirmesinin riski azaltmada kritik bir rol oynadığını belirtmiştir. Tezde sunulan bulgular, çeşitli ekonomik dönemlerde farklı varlıkların farklı özelliklerini anlamının, yatırımcıların portföylerini etkin bir şekilde çeşitlendirmesine olanak tanıdığı sonucunu desteklemektedir.

Ayrıca, oynaklık modellerinin ve tahmin hatalarının analizi, yatırım fırsatlarının ve potansiyel risk faktörlerinin belirlenmesine yardımcı olabilir. Çeşitli ekonomik dönemlerde farklı varlıkların farklı özelliklerini anlamak, yatırımcıların portföylerini etkin bir şekilde çeşitlendirmesine ve piyasa oynaklığıyla ilişkili potansiyel riskleri azaltmasına olanak tanır.

## 6.6. Sınırlamalar ve Gelecekteki Araştırmalar

Bu çalışmanın sınırlılıklarını kabul etmek esastır. Analiz, geçmiş verilere dayanıyordu ve gelecekteki piyasa koşulları, tahmin modellerinin performansını etkileyerek önemli ölçüde farklılık gösterebilir. Ek olarak, çalışma belirli bir varlık grubuna (Altın, S&P500 ve Bitcoin) odaklandı ve bulgular diğer finansal araçlara genellenemez.

CNN ve RNN için Veri içi tahmin yöntemi, modelin geçmiş veriler üzerinde eğitilmesine dayandığı için gelecekteki belirsizlikleri ve dönüşleri tam olarak öngöremeyebilir. Bu durum, özellikle volatil ve hızla değişen varlıklar gibi dinamik piyasalarda daha belirgin olabilir. Veri içi tahmin yaklaşımının sınırlamaları arasında, modelin mevcut piyasa koşullarına ilişkin taze veriye erişim eksikliği yer alabilir. Ayrıca, modelin geçmiş veriye odaklanması, ani ve beklenmedik olayların etkisini tam olarak yansıtamayabilir.

Bu tezde, varlık sınıflandırması ve incelemesi için CNN ve RNN modellerinin veri içi tahmini üzerine odaklandık. Ancak, gelecekteki çalışmalarda, bu yaklaşımın farklı varlık türleri, piyasa koşulları ve veri kalitesi üzerindeki etkilerini daha ayrıntılı bir şekilde analiz etmek önemlidir. Ayrıca, model güvenilirliği ve istikrarı, farklı zaman dilimleri ve piyasa koşullarında nasıl değiştiğini incelemek de değerli bir araştırma konusudur.

Gelecekteki çalışmalar, Derin öğrenme modelleri için veri içi tahmin yaklaşımının yanı sıra, dış verileri (veri dışı) ve makroekonomik göstergeleri modellemeye entegre etmenin potansiyelini de araştırabilir. Böyle bir yaklaşım, modelin daha güncel ve kapsamlı bir görünüm elde etmesine ve anlık piyasa olaylarına daha duyarlı hale gelmesine yardımcı olabilir.

Gelecekteki araştırmalar, diğer gelişmiş tahmin modellerinin uygulamalarını keşfedebilir ve farklı piyasa koşullarında performanslarını değerlendirebilir. Ayrıca, hükümet politikaları veya jeopolitik faktörler gibi dış olayların varlık fiyatları üzerindeki etkisinin araştırılması, dinamiklerinin daha kapsamlı bir şekilde anlaşılmasını sağlayabilir.

Çalışmamızın sonuçlarına ek olarak, finansal piyasalardaki asimetric bilginin rolünü de değerlendirmekte fayda görüyoruz. Asimetric bilgi, bazı piyasa katılımcılarının diğerlerine göre daha fazla veya daha kaliteli bilgiye sahip olması durumunu ifade eder. George Akerlof'un "Limon Pazarı" örneğinde olduğu gibi, bu tür bilgi asimetricisi, piyasaların etkinliğini olumsuz etkileyebilir ve bazı katılımcılar için adil olmayan avantajlar yaratabilir.

Kriz zamanlarında veya özellikle tekeli banka yapılarında karar değişiklikleri olduğunda, bilgi asimetricisi daha belirgin hale gelebilir. Özellikle, tam bilgi akışının olmadığı bir ortamda, küçük tasarrufçular ve perakende yatırımcılar yanıltıcı bilgilere dayanarak zarar edebilir. Ceteris paribus (diğer şartlar sabitken) bir analizde, bu bilgi asimetricisinin potansiyel sonuçları, varlık fiyatlarında ani dalgalanmalara, yatırımcı güvensizliğine ve hatta piyasa çöküşlerine kadar uzanabilir.

Ayrıca, asimetrik bilgi, yatırımcıların varlık fiyatlarını doğru bir şekilde değerlendirmelerini zorlaştırabilir. Özellikle, bu çalışmanın odaklandığı gibi varlık fiyatlarının tahminini zorlaştıran faktörlerden biri de budur. Derin öğrenme modelleri, bu tür piyasa bozulmalarını yakalama potansiyeline sahip olabilirken, asimetrik bilginin etkilerini tam olarak ortaya koyma yeteneğine sahip değildir.

Bu nedenle, bu çalışmadaki bulguları uygulamaya koymadan önce, bilgi asimetrisinin potansiyel etkilerini göz önünde bulundurarak ek bir dikkat seviyesi gerektirebilir. Yatırımcılar ve piyasa analistleri için, bilgi asimetrisinin potansiyel etkilerini minimize etmek adına güvenilir ve şeffaf bilgi kaynaklarına erişim sağlamak kritik bir öneme sahiptir.

Sonuç olarak, bu bölüm tahmin modellerinin performansının bulgularını, varlıkların karşılaştırmalı analizini ve çalışmanın ekonomik sonuçlarını vurgulamıştır. Tartışma, varlık fiyatı tahmininde derin öğrenme tekniklerini birleştirmenin önemini ve yatırım karar verme ve risk yönetiminde farklı varlıkların benzersiz özelliklerini anlamının önemini vurgulamaktadır.

## 7. ARAŐTIRMA KODU

### 7.1. AraŐtırma Kodu GitHub EriŐimi

Őeffaflıđı ve tekrar üretilebilirliđi kolaylaŐtırmak için bu çalıŐmanın araŐtırma kodu GitHub'da mevcuttur. Kod, modelleme yaklaŐımlarının uygulanmasını ve COVID-19 salgını sırasında varlık tepkilerinin analizini içerir. AraŐtırmacılar ve ilgili okuyucular, aŐađıdaki bađlantıyı ziyaret ederek koda erişebilir ve deneyleri çođaltabilir.

Bahçeci, Y. (2023). COVID-19 Pandemisi sırasında Varlık Reaksiyonları için <https://github.com/yavuzBahceci/MsWorks/tree/main/msCodes> bađlantısı ziyaret edilebilir.

AraŐtırma kodu, bu çalıŐmada kullanılan metodoloji ve veri analizi tekniklerine ilişkin ek bilgiler sađlar. Modelleme yaklaŐımlarının daha ayrıntılı incelenmesine olanak tanır ve bu araŐtırmada sunulan sonuç ve bulguların dođrulanmasını kolaylaŐtırır.

## 8. KAYNAKÇA

Bernanke, B. S. (2009). The Crisis and the Policy Response. Federal Reserve Board. <https://www.federalreserve.gov/newsevents/speech/bernanke20090113a.htm>

Bernanke, B. S., & Kuttner, K. N. (2005). What explains the stock market's reaction to Federal Reserve policy? *The Journal of Finance*, 60(3), 1221-1257.

Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307-327.

Chen, Y., Li, X., & Chen, H. (2022). Asset pricing dynamics during the COVID-19 pandemic: Evidence from global financial markets. *Journal of Financial Stability*, 58, 100974.

Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383-417.

Fama, E. F., & French, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, 33(1), 3-56.

Gagnon, J. E., Raskin, M., Remache, J., & Sack, B. (2011). The financial market effects of the Federal Reserve's large-scale asset purchases. *International Journal of Central Banking*, 7(1), 3-43.

Hamilton, J. D., & Susmel, R. (1994). Autoregressive conditional heteroskedasticity and changes in regime. *Journal of Econometrics*, 64(1-2), 307-333.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.

Krishnamurthy, A., & Vissing-Jorgensen, A. (2011). The effects of quantitative easing on interest rates: Channels and implications for policy. *Brookings Papers on Economic Activity*, 43(2), 215-287.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In *Advances in neural information processing systems (NIPS)*, 25.

Li, K., Wang, X., & Li, J. (2020). Deep learning models for stock price prediction: A survey. *Neurocomputing*, 396, 310-324.

Markowitz, H. (1952). Portfolio Selection. *The Journal of Finance*, 7(1), 77-91.

Nakamoto, S. (2008). Bitcoin: A Peer-to-Peer Electronic Cash System.

Shiller, R. J. (1981). Do Stock Prices Move Too Much to be Justified by Subsequent Changes in Dividends? *American Economic Review*, 71(3), 421-436.

Smith, J., Johnson, L., & Brown, R. (2020). Interconnectedness and contagion in global financial crisis. *Journal of Financial Economics*, 1(1), 53-69.

Vacha, L., & Barunik, J. (2012). Co-movement of energy commodities revisited: Evidence from wavelet coherence analysis. *Energy Economics*, 34(1), 241-247.

Wang, D., Liu, Z., & Chen, Y. (2020). A comparative study of deep learning models for stock market forecasting. *Expert Systems with Applications*, 147, 113211.

yfinance: Yahoo Finance market data downloader (Version 0.2.18) Retrieved from <https://github.com/ranaroussi/yfinance>

Zhang, X., & Kang, W. (2021). The reaction of major assets to COVID-19: Evidence from precious metals, stock indices, and cryptocurrencies. *Research in International Business and Finance*, 58, 101429.

## TEZ ONAY SAYFASI

Üniversite : T.C. GALATASARAY ÜNİVERSİTESİ  
Enstitü : SOSYAL BİLİMLER ENSTİTÜSÜ  
Hazırlayanın Adı Soyadı : Mahmut Yavuz Bahçeci  
Tez Başlığı : COVID-19 PANDEMİSİ SÜRECİNDE BİTCOİN,  
ALTIN VE S&P500 REAKSİYONLARI  
Savunma Tarihi : 28 / 08 / 2023  
Danışman : Doç. Dr. Ata Özkaya

### JÜRİ ÜYELERİ:

Unvan, Ad-Soyadı

İmza

Doç. Dr. Ata Özkaya

Doç. Dr. Sevgi İnceci

Prof. Dr. Mehmet Şişman

Prof. Dr. Ulun AKTURAN  
Enstitü Müdürü