



BİST-30' daki Firmaların Hisse Senedi Getirilerinin Tahmini

Yazılım Mühendisliği Ana Bilim Dalı

Dönem Projesi

Yasemin Kayıçoğlu

Proje Danışmanı: Prof. Dr. Femin Yalçın Küçükbayrak

Ocak 202

BİST-30' daki Firmaların Hisse Senedi Getirilerinin Tahmini

ÖZ

Türkiye'deki Borsa İstanbul'un (BİST) önemini vurgulayarak, borsa tahmininin karmaşıklığını incelemektedir. Teknik analiz, temel analiz ve evrimsel analiz olmak üzere üç ana kategori altında incelenen borsa tahmin yöntemlerinin avantajları ve sınırlamaları değerlendirilmektedir.

Çalışma, borsayı etkileyebilecek çeşitli faktörlerin varlığına dikkat çekerek, başarılı tahminler için çok sayıda değişkenin analiz edilmesi gerektiğini vurgulamaktadır. Özellikle, makine öğrenme teknikleri ve yapay zekanın bilgi işleme teknolojisini gelişmiş kullanımı ile piyasa tahminini daha doğru hale getirme potansiyeli üzerinde durulmaktadır.

Yapay Sinir Ağı (YSA) modeli üzerinden yapılan hisse senedi tahminleri ve modelin başarı oranları detaylı bir şekilde sunulmaktadır. R-Kare, RMSE, MAE ve MSE gibi değerlerle modellerin performansı değerlendirilmiştir. Elde edilen sonuçlar, YSA modellerinin borsa tahmininde etkili bir şekilde kullanılabileceğini göstermektedir.

Grafiklerle desteklenen çalışmada, AKBANK, ALARKO, ARÇELİK, ASELSAN ve EKGYO gibi hisse senetlerinin tahmin edilen değerlerinin gerçek değerlere ne kadar yakın olduğu gösterilmektedir. Özellikle ARÇELİK hisse senedindeki yüksek MSE değeri daha detaylı incelenmeyi gerektirebileceği vurgulanmaktadır.

Sonuç olarak, çalışma yapay zeka ve makine öğrenme tekniklerinin borsa tahminlerinde değerli bir rehberlik sağlayabilecek potansiyele sahip olduğunu öne sürmektedir.

Anahtar Sözcükler: YSA, Makine öğrenmesi, Teknik Analiz, BİST30, Borsa Tahmini

Prediction of Stock Returns of Firms in BIST-30

Abstract

It examines the complexity of stock market forecasting, emphasising the importance of Borsa Istanbul (BIST) in Turkey. The advantages and limitations of three main categories of stock market forecasting methods, namely technical analysis, fundamental analysis and evolutionary analysis, are evaluated.

The study draws attention to the existence of various factors that can affect the stock market and emphasises that a large number of variables should be analysed for successful forecasts. In particular, the potential of machine learning techniques and artificial intelligence to make market forecasting more accurate through the advanced use of information processing technology is emphasised.

Stock forecasts based on the Artificial Neural Network (ANN) model and the success rates of the model are presented in detail. The performance of the models is evaluated with values such as R-Square, RMSE, MAE and MSE. The results obtained show that ANN models can be used effectively in stock market forecasting.

In the study supported by graphs, it is shown how close the predicted values of stocks such as AKBANK, ALARKO, ARÇELİK, ASELSAN and EKGYO are to the actual values. It is emphasised that especially the high MSE value in ARÇELİK stock may require more detailed analysis.

In conclusion, the study suggests that artificial intelligence and machine learning techniques have the potential to provide valuable guidance in stock market forecasting.

Keywords: Artificial Neural Networks, Machine Learning, Technical Analysis, BIST30, Stock Market Forecast

İçindekiler

Öz	i
Abstract	ii
Şekiller Listesi.....	iv
Tablolar Listesi.....	v
Kısaltmalar Listesi	vi
1 GİRİŞ.....	1
2 LİTERATÜR TARAMASI	4
3 VERİ SETİ ve ALGORİTMALAR	8
3.1 Veri Seti	8
3.2 Algoritma ve Doğrulama Ölçütleri	12
3.2.1 Yapay Sinir Ağları.....	12
3.2.2 R-Kare	14
3.2.3 RMSE	16
3.2.4 MAE	17
3.2.5 MSE.....	19
4 YÖNTEM.....	21
4.1 Makine Öğrenme Yöntemleri.....	21
4.1.1 Yapay Sinir Ağları.....	21
5 SONUÇ	27
Kaynaklar	32

Şekiller Listesi

Şekil 3.1	WMA Hesaplaması	9
Şekil 3.2	WMA Hesaplamasının Sonucu	9
Şekil 3.4	AKBNK Hisse Senedi Kapanış Fiyatı.....	10
Şekil 3.5	ASELSAN Hisse Senedi Kapanış Fiyatı	10
Şekil 3.6	EKGYO Hisse Senedi Kapanış Fiyatı	11
Şekil 3.7	ARÇELİK Hisse Senedi Kapanış Fiyatı.....	11
Şekil 3.8	ALARK Hisse Senedi Kapanış Fiyatı	11
Şekil 3.9	Yapay Sinir Ağaları Örneği.....	13
Şekil 3.10	R- Kare Örnek Grafiği.....	15
Şekil 3.11	RMSE Örnek Grafiği.....	17
Şekil 3.12	MAE Örnek Grafiği.....	19
Şekil 3.13	MSE Örnek Grafiği	20
Şekil 4.1	Eğitim ve Test Veri Seti Ön İşleme.....	22
Şekil 4.2	YSA Modeli Birinci Katman.....	23
Şekil 4.3	YSA Modeli İkinci Katman.....	24
Şekil 4.4	YSA Modeli Son Katman.....	24
Şekil 4.5	YSA Modeli Optimizer ve Kayıp.....	24
Şekil 4.6	YSA Modeli Epoch ve Batch_size Sayısı	25
Şekil 4.7	Verilerin Performans Değerlendirmesi.....	25
Şekil 4.8	Tahmin ve Gerçek Verilerin Karşılaştırılması.....	26
Şekil 4.9	Tahmin ve Gerçek Verilerin Karşılaştırma Grafiğinin Kodu	26
Şekil 5.1	AKBANK Tahmin ve Gerçek Verilerin Karşılaştırma Grafiği.....	29
Şekil 5.2	ALARKO Tahmin ve Gerçek Verilerin Karşılaştırma Grafiği	29
Şekil 5.3	ARÇELİK Tahmin ve Gerçek Verilerin Karşılaştırma Grafiği.....	30
Şekil 5.4	ASELSAN Tahmin ve Gerçek Verilerin Karşılaştırma Grafiği	30
Şekil 5.6	EKGYO Tahmin ve Gerçek Verilerin Karşılaştırma Grafiği.....	31

Tablolar Listesi

Tablo 3.1	AKBNK Hisse senetlerinin günlük verileri	8
Tablo 5.1	Beş BİST30 Firmaların Performan Değerlendirmeleri	27

Kısaltmalar Listesi

BİST	Borsa İstanbul
İMKB	İstanbul Menkul Kıymetler Borsası
BİST30	Borsa İstanbul'da işlem gören 30 en likit hisse
RELU	Rektifiye Doğrusal Birim (Rectified Linear Unit)
ML	Makine Öğrenmesi (Machine Learning)
WMA	Ağırlıklı Hareketli Ortalama (Weighted Moving Average)
RMSE	Kök Ortalama Kare Hatası (Root Mean Square Error)
R Kare	Belirleme Katsayısı (R-squared)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
MSE	Ortalama Kare Hatası (Mean Squared Error)
ARCLK	Arcelik
ASELS	Aselsan
AKBNK	Akbank
ALARK	Alarko Holding
EKGYO	Emlak Konutları Gayrimenkul Yatırım Ortaklığı
SSR	Toplam Kareler Hatası (Sum of Squares Residuals)
SST	Toplam Kareler Toplamı (Total Sum of Squares)

Bölüm 1

Giriş

Finansal piyasalarda yatırım yapma süreci, karmaşıklığı ve belirsizliği ile bilinen borsa dünyası, yatırımcılar için hem fırsatlar sunan hem de riskler barındıran bir arenadır. Türkiye'de, bu dinamik piyasada faaliyet gösteren tek borsa kurumu olan Borsa İstanbul (BİST), 1986 yılında İstanbul Menkul Kıymetler Borsası (İMKB) olarak kurulmuş ve 2013'te ismini değiştirerek günümüzdeki halini almıştır. BİST, halka açık şirketlerin hisse senetlerinin alınıp satıldığı, likiditenin olduğu ve yatırımcıların bir araya geldiği kritik bir finansal platformdur.

Borsa, ekonomik, politik, sosyal ve doğal faktörlerin etkileşimindeki karmaşık bir sistemdir. Hem yerel hem de küresel olaylar, ekonomik dengesizlikler, siyasi olaylar, doğal afetler gibi unsurlar borsa üzerinde derin etkiler bırakabilir. Bu nedenle, borsada başarılı tahminler yapmak için çok sayıda değişkenin dikkatlice analiz edilmesi gerekmektedir.

Hisse senedi tahminleri genellikle üç ana kategori altında incelenir: teknik analiz, temel analiz ve evrimsel analiz. Teknik analiz, geçmiş fiyat hareketlerini inceleyerek gelecekteki hareketleri tahmin etmeye odaklanır. Bu analiz yöntemi, grafik desenleri ve teknik göstergeler gibi araçları kullanarak yatırımcılara rehberlik eder.

Teknik analizin önemli bir aracı olan hareketli ortalama (MA), fiyat verilerini düzgünleştirir ve eğilimleri belirlemeye yardımcı olur. 5 yıllık ve günlük olarak hareketli ortalamalar genellikle yatırımcılar arasında takip edilen önemli göstergelerdir. Ancak, teknik analizin de sınırlamaları vardır ve tarihsel performansa dayandığı için gelecekteki piyasa hareketlerini kesin olarak tahmin etmek mümkün değildir.

Borsa tahmini karmaşık bir süreçtir ve yatırımcılar, bu alanda başarılı olabilmek için dikkatli bir analiz ve strateji geliştirmelidirler.

Görüldüğü üzere, borsa tahmini süreci oldukça karmaşık bir yapıya sahiptir. Teknik analiz, genellikle istatistiksel analizlere dayanır, ancak borsayı etkileyen çeşitli dış faktörler, hisse senetlerinin ait olduğu şirketin durumu, siyasi düzen ve evrensel olaylar gibi, bu analizin doğrusal olmayan ve dinamik bir süreç olmasına neden olur. Bu nedenle, borsa zaman serileri genellikle karmaşık, dalgalı ve gürültülüdür.

Borsada dalgalanmanın şiddeti ve verilerin gürültülü olması, piyasa tahminini zorlaştırır ve risk yönetimini önemli kılar. Ancak, son yıllarda gelişen güçlü bilgi işleme teknolojisi ve son teknoloji makine öğrenme teknikleri, borsa değeri tahminlerini daha doğru ve etkili hale getirmiştir. Bu noktada, yapay zekâ uygulamaları ve makine öğrenme teknikleri, borsa tahminlerinde diğer geleneksel istatistiksel modellere göre daha yüksek başarı oranlarına ulaşmıştır. Bu bağlamda, yapılan araştırmalar genellikle makine öğrenme algoritmalarından yapay sinir ağları ve değerlendirme metrikleri üzerine odaklanmıştır. Bu çalışmada, bu önemli makine öğrenme algoritması kullanılmıştır. Bu algoritmaların kullanılmasıyla, piyasa tahmininde daha güçlü ve etkili sonuçlar elde edilebilmektedir.

Bu çalışmanın temel amacı, borsa alanındaki yatırımcılara rehberlik edecek etkili tahmin çalışmaları gerçekleştirmektir. Bu bağlamda, özellikle geçmiş hisse senedi fiyat verilerini kullanarak gelecekteki fiyat hareketlerini tahmin etmeye odaklanılmıştır. Derin öğrenme ve makine öğrenme algoritmalarının kullanılmasıyla, bu tahminlerin yapılırken düşük riskli olması önemli bir hedef olarak belirlenmiştir.

Yapay zeka ve makine öğrenme alanındaki büyük gelişmelerle birlikte, bu çalışma, bu teknolojilerin borsa tahminleri üzerindeki etkinliğini ve kullanılabilirliğini doğrulamayı amaçlamaktadır. Yatırımcıların karar alma süreçlerine değerli bir katkı sağlayacak bu tahminler, finansal piyasalardaki belirsizlikleri azaltma potansiyeline sahiptir.

Çalışmanın genel yapısı 5 bölümden oluşmaktadır. Literatür taraması bölümünde, önceki benzer çalışmaların incelenerek alanyazında var olan bilgilerin özetlenmesi yer almaktadır. Ardından, kullanılan algoritmalar ve bu algoritmalar için seçilen veri setleri detaylı bir şekilde açıklanmaktadır.

Yöntem bölümü, uygulanan algoritma modellerinin ayrıntılı bir anlatımını içermekte ve hangi parametrelerin nasıl kullanıldığını açıklamaktadır.

Sonuç bölümü, oluşturulan modellerin performansı ile ilgili elde edilen verileri sunmaktadır. Bu yapı, çalışmanın borsa tahminlerindeki etkisini anlamak ve gelecekteki benzer araştırmalara rehberlik etmek amacıyla oluşturulmuştur. Bu çalışma, yapay zeka ve makine öğrenme tekniklerinin borsa tahminlerinde ne kadar etkili olabileceğine dair önemli bir katkı sunmayı hedeflemektedir.

Bölüm 2

Literatür Taraması

Borsanın bir ülkenin ekonomik durumuyla yakından ilişkili olduğunu ve brokerlerin, şirketlerin ve yatırımcıların yatırım yapması için tarafsız bir platform sağladığını görülmektedir. Yatırımcılar genellikle geleneksel bankalara göre borsalara yönelmektedir, çünkü borsalarda daha yüksek yatırım getirisi potansiyeli bulunmaktadır. Ancak, döviz kurlarındaki dalgalanmalar nedeniyle borsalara yatırım yapma riski de yüksektir.

Bu riskleri azaltmak ve yatırımcılara daha iyi kararlar verme konusunda yardımcı olmak amacıyla güçlü bir borsa tahmin sistemi geliştirmek önemlidir. Bu alandaki çalışmalar, gelişen teknoloji ve artan ilgi nedeniyle önemli bir odak noktası haline gelmiştir. Makine öğrenme teknikleri ve yapay zeka uygulamaları, borsa tahmini alanında kullanılmaktadır ve birçok istatistiksel modelden daha yüksek başarı oranları sağlayabilmektedir.

Son yıllarda yapay sinir ağları, borsa tahmini konusunda öne çıkan bir araştırma alanı haline gelmiştir. Bu alanda kullanılan çeşitli makine öğrenme algoritmaları bulunmaktadır. Bu teknikler, büyük veri setleri üzerinde karmaşık ilişkileri analiz ederek daha doğru tahminler yapma yeteneğine sahiptir.

Karmaşık bir finansal piyasa olan menkul kıymetler piyasasında endeks değerlerinin tahmin edilmesinde yapay sinir ağları, karmaşık veri yapılarını analiz etme yetenekleri, yüksek tahmin doğruluğu, uygulama kolaylığı ve hızlı işlem süreleri nedeniyle bu tür finansal tahmin uygulamalarında tercih edilen bir yapay zeka yöntemidir. (AKBAŞ, 2022)

BIST 100 endeksinin tahmininde Yapay Sinir Ağları modeli daha iyi bir performans göstermiştir. ARMA(1,1) modelinin R2 değeri 0.95 ve MSE değeri 0.004526 iken, Yapay Sinir Ağları modelinde bu değerler sırasıyla 0.99 ve 0.001316 olarak hesaplanmıştır. Yüksek R2 ve düşük MSE değerleri, Yapay Sinir Ağları modelinin endeks tahminlerinde daha doğru ve etkili olduğunu göstermektedir. (KANTAR, 2020)

Tsai ve Wang çalışmasında, yatırımcıların daha iyi hisse senedi seçim kararları alabilmeleri amacıyla gelecekteki fiyat tahminlerini yapmak için Yapay Sinir Ağları (YSA) ve Karar Ağaçları yöntemleri kullanılmıştır. Çalışma, Tayvan elektronik sanayi firma hisse senedi verilerini temel almıştır. Analiz sonuçlarına göre, Yapay Sinir Ağları ve Karar Ağaçları yöntemlerinin entegre edildiği modelin doğruluk oranının, bu yöntemlerin ayrı ayrı uygulandığı modellere kıyasla daha yüksek olduğu belirlenmiştir. Bu durum, entegrasyonun hisse senedi fiyat tahminlerinde daha etkili bir sonuç elde edilmesine katkı sağladığını göstermektedir. (TSAI, WANG, 2009)

BİST 30 hisselerinin Yapay Sinir Ağları (YSA) ile yapılan tahminlerin diğer algoritmalarla karşılaştırıldığında, Portföy 1, 2 ve 3'te daha başarılı olduğu görülmektedir. Özellikle Portföy 2 için YSA ile yapılan tahminlerin minimum hata elde ettiği belirtilmiştir. Portföy 3 için genel olarak çoklu regresyon analizinde minimum hata elde edilirken, OMYH değerinde YSA ile minimum hata elde edilmiştir. Yapay sinir ağları ile R2 değerlerinin incelenmesi sonucunda, üç portföyde de %99 başarı elde edildiği vurgulanmıştır. Buna karşın, çoklu regresyonla yapılan tahminlerde Portföy 1 için %86, Portföy 2 için %97 ve Portföy 3 için %67 R2 değerleri elde edildiği belirtilmiştir. Bu değerler üzerinden yapılan karşılaştırmada, yapay sinir ağlarının daha başarılı bir performans sergilediği söylenebilir. (AYTEKİN, 2021)

Bu çalışmada, yapay sinir ağları ile tahmin yapma olanakları araştırılarak bu yöntemle İMKB Ulusal 100 Endeksi tahmin edilmeye çalışılmıştır. Yapılan uygulamalarda, yapay sinir ağları yönteminin regresyon yöntemine göre daha yüksek bir tahmin performansı sergilediği gözlemlenmiştir. Performans ölçütü olarak, tahmin değerlerinin gerçek değerlerden sapmalarını değerlendiren hata kareleri ortalamasının karekökü (RMSE) kriteri kullanılmıştır. Yapay sinir ağı yönteminin RMSE değeri, regresyon yöntemine göre daha düşük bir değer elde etmiştir.

Bu durum, yapay sinir ağlarının daha doğru tahminler yapma konusunda regresyon yönteminden üstün olduğunu göstermektedir. (KARAATLI, GUNGOR, DEMIR, KALAYCI, 2005)

BIST-50 endeksini etkileyen değişkenlerin değerleri bilindiğinde, makine öğrenmesi ve Yapay Sinir Ağları (YSA) yöntemleriyle BIST-50 endeksinin değişim yönünün yaklaşık %89-%93 arasında başarıyla sınıflandırıldığı söylenebilir. Bu, yatırımcının gün içinde daha başarılı kararlar almasına ve doğru günlük planlama yapmasına yardımcı olabilir. Sınıflandırma başarısının en yüksek olduğu algoritmanın %92.71 ile C4.5 olması, basit ve anlaşılabilir makine öğrenmesi yöntemlerinin, özellikle yatırımcılar tarafından kolaylıkla kullanılabileceğini göstermektedir. Bu tür sınıflandırma modelleri, finansal piyasalardaki değişimleri anlamak ve bu değişimlere hızlı bir şekilde tepki vermek adına yatırımcılara değerli birer araç sağlayabilir. (FILIZ, KARABOGA, AKOGUL, 2017)

Bu çalışmada elde edilen eğitim, test ve onaylama seti üzerinde %2'ye yakın MAPE (Mean Absolute Percentage Error) sonuçları, Yapay Sinir Ağları (YSA) ile hisse senedi tahmininin başarılı olduğunu göstermektedir. Genel olarak değerlendirildiğinde, YSA'nın kullanılmasıyla finansal tahminlerde başarılı sonuçlar elde edilebileceği belirtilmektedir. İyi bir tahmin, yatırımcıları ve hisse senedi ile ilgili diğer paydaşları getiri performansını artırmada olumlu bir şekilde etkileyebilir. Bu sonuçlar, YSA'nın finans biliminde etkili bir tahmin aracı olarak kullanılabilirliğini vurgulamaktadır. (YÜRÜK, 2021)

Yapay Sinir Ağları (ANN) yöntemi ile M1 modelinin, hareketli ortalamalar kuralına göre elde edilen tahmin değerleri arasında bir karşılaştırma yaparak, test kümesi üzerindeki doğruluk oranlarını değerlendirdiğini belirtmektedir. Ayrıca, bu değerlendirme sonucunda yapay sinir ağlarının, basit hareketli ortalama yöntemine kıyasla biraz daha iyi bir performans gösterdiği görülmektedir. (KUTLU, BADUR, 2009)

Çalışmada, yapay sinir ağlarının (YSA) günlük NASDAQ borsa oranını tahmin etme yeteneği üzerine bir araştırma yapılmıştır. Bu amaçla, geri yayılma algoritması tarafından eğitilen birkaç ileri beslemeli YSA değerlendirilmiştir. Çalışmanın metodolojisi, kısa vadeli tarihsel hisse senedi fiyatlarını ve haftanın gününü girdi olarak kullanmıştır. Yapılan değerlendirmeler sonucunda, model çıktıları ile gerçek veriler arasında belirgin bir fark olmadığı ve yüksek doğruluk oranına ulaşıldığı belirlenmiştir. (MOGHADDAM ET AL., 2016)

Bölüm 3

Veri Seti ve Algoritmalar

3.1 Veri Seti

Bu çalışmada veri setimiz olan borsada tanınmış beş Türk şirketin hisse senedi değerini tahmin etmek için Yapay Sinir Ağları (YSA) kullandık. Bu çalışmada kullanacağımız veri seti, Borsa İstanbul'un BIST 30 listesinde yer alan 5 hisseden oluşuyor. Bu şirketler arasında Borsa İstanbul'un BIST 30 listesindeki Akbank (AKBNK), Alarko (ALARK), Arçelik (ARCLK), Aselsan (ASELS) ve Emlak Konut GYO (EKGYO) şirketleri bulunmaktadır. Veriler, 2019-2023 yıllarına ait son 5 yıllık verilerdir. Veri setimizdeki hisselerin herbiri bir günlük verilerden oluşmaktadır. Tablo 1, işlemlerden önceki halini göstermektedir.

Kaynak: <https://tr.investing.com/equities/turkey>

	Tarih	Kapanış	Açılış	Yüksek	Düşük	Hac.	Fark %
0	26.12.2023	37,68	38,38	38,50	36,96	84,35M	-0,95%
1	25.12.2023	38,04	39,02	39,02	37,08	51,31M	-2,86%
2	22.12.2023	39,16	39,16	39,78	38,96	92,07M	0,15%
3	21.12.2023	39,10	39,94	40,72	39,02	129,39M	-2,10%
4	20.12.2023	39,94	38,88	40,00	38,76	95,52M	2,73%

Tablo 3.1: AKBNK Hisse senetlerinin günlük verileri

Finansal piyasalardaki geçmiş fiyat hareketlerini inceleyerek, gelecekteki fiyat hareketlerini tahmin etmeye çalışan bir yöntem olan teknik analiz, oluşumlar ve göstergeler gibi ana unsurları içerir. Teknik analizde kullanılan göstergelere ise teknik analiz göstergeleri veya indikatörler denir.

Bu göstergeler, hisse senetleri ve diğer finansal enstrümanların alım satım sinyalleri konusunda yatırımcılara rehberlik etmeye yardımcı olur. Göstergeler genellikle hisse senedi fiyatları ve hacim verileri gibi bilgileri kullanarak hesaplanır.

```
# WMA hesaplamak için dönem sayısını belirleme
N = 10
# WMA hesaplaması
data['WMA'] = data['Kapanış'].rolling(window=N).mean()
```

Şekil 3.1: WMA Hesaplaması

```
# Grafik çizme
plt.figure(figsize=(10, 6))
plt.plot(data['Kapanış'], label='Kapanış Fiyatı', color='blue')
plt.plot(data['WMA'], label=f'Ağırlıklı Hareketli Ortalama ({N} Günlük)', color='red')

# Hareketli ortalama çizgisinin üzerine bir çizgi ekleyebilirsiniz (bu bir alım sinyali olabilir)
plt.axhline(y=data['Kapanış'].mean(), color='green', linestyle='--', label='Ortalama Fiyat')

plt.title('AKBNK Hisse Senedi Fiyatları ve WMA')
plt.xlabel('Tarih')
plt.ylabel('Fiyat')
plt.legend()
plt.grid(True)
plt.show()
```

Şekil 3.2: WMA Hesaplamasının Sonucu

Çalışmamızda bahsedilen Ağırlıklı Hareketli Ortalama (WMA) göstergesi, geçmiş dönemlerin ortalamasını gösterir ve mevcut fiyatın genel trende ne kadar uygun olduğunu gösterir. WMA'nın kullanılmasıyla, fiyat hareketlerinin düzgünleştirilmesi ve trendin daha belirgin hale getirilmesi amaçlanır.

WMA hesaplama formülü ise şu şekildedir:

$$WMA = (P_1 \times w_1) + (P_2 \times w_2) + \dots + (P_n \times w_n)$$

Burada:

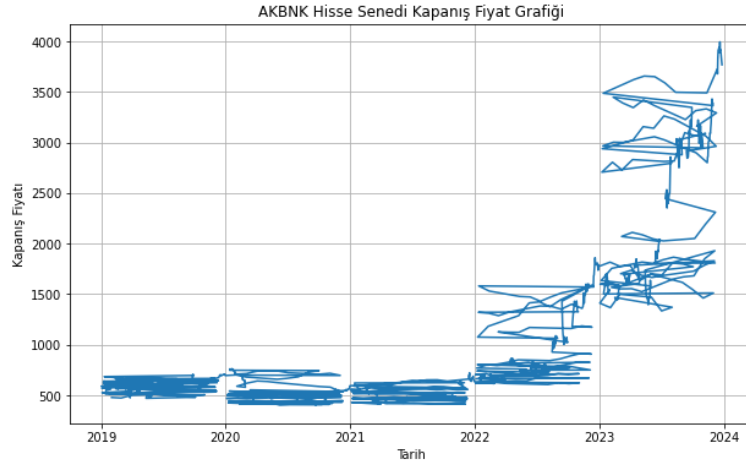
P_1, P_2, \dots, P_n : Sırasıyla, belirli bir dönem içindeki fiyatlar.

w, w_2, \dots, w_n : Sırasıyla, bu fiyatların ağırlıkları.


Örneğin, 10 günlük bir ağırlıklı hareketli ortalama hesaplamak için her günün fiyatına aşağıdaki gibi ağırlıklar atanabilir:

$$WMA = (P_1 \times w_1) + (P_2 \times w_2) + (P_3 \times w_3) + \dots + (P_{10} \times w_{10})$$


Bu tür göstergeler, yatırımcılara analizlerinde yardımcı olmak için kullanılır, ancak tek başına kesin sonuçlar vermezler. Teknik analizin genelinde, bir dizi farklı gösterge ve yöntem bir arada kullanılarak daha kapsamlı bir analiz yapılabilir. Ancak, her zaman hatırlanmalıdır ki finansal piyasalardaki gelecek hareketleri öngörmek her zaman belirsizlik içerir ve riskleri içerir.




Şekil 3.4: AKBNK Hisse Senedi Kapanış Fiyatı




Şekil 3.5: ASELSAN Hisse Senedi Kapanış Fiyatı



Şekil 3.6: EKGYO Hisse Senedi Kapanış Fiyatı



Şekil 3.7: ARÇELİK Hisse Senedi Kapanış Fiyatı



Şekil 3.8: ALARK Hisse Senedi Kapanış Fiyatı

3.2 Algortima

Makine öğrenimi (ML) algoritmaları, yapay zekâ alanındaki en popüler yaklaşımlardan biridir. Veri miktarı arttıkça, makine öğrenimindeki teknolojik ilerlemeler hız kazanmıştır. Son on yılda, makine öğrenimi hayatımızın ayrılmaz bir parçası haline gelmiştir. İnsan el yazısını tanımak kadar basit veya kendi kendini süren arabalar kadar karmaşık görevlerde uygulanabilir. Ayrıca, birkaç on yıl içinde, daha mekanik tekrarlayan görevlerin sona ereceği de bekleniyor.

Artan veri miktarı, makine öğreniminin teknolojik ilerleme için gerekli bir unsur olarak daha yaygın hale gelmesine olan inancı güçlendirmektedir. Makine öğreniminin büyük bir etki yarattığı birçok önemli endüstri bulunmaktadır; bunlar arasında finansal hizmetler, teslimat, pazarlama ve satış, sağlık hizmetleri gibi sektörler yer almaktadır.

Makine öğrenimi, uzun zamandır borsa tahmininde kullanılmaktadır. ML algoritmalarının borsa endeks hareketlerinde ve gelecekteki projeksiyonlarda başarılı olduğu bilinmektedir. Sıralı verilerle başa çıkma yeteneğine sahiptir ve borsa değer tahmininin eğitimi ve testi için son derece uygundur.

Bu bölümde, kısaca en popüler makine öğrenme algoritmalarından Yapay Sinir Ağı (YSA) hakkında konuşacağız.

3.2.1 Yapay Sinir Ağı

Yapay Sinir Ağları (YSA), öğrenme yeteneği ile bilgi toplama, genelleme yapma ve örnekleri değerlendirme kabiliyetine sahip yapay zeka modellerinden biridir. Tarihsel verilere dayanarak, hiç görmediği örneklerle karşılaştırma yapabilen ve bu temelde kararlar verebilen YSA, insan beyninin karmaşıklığına benzer bir yapı sergiler. Bu modeller, çok katmanlı algılayıcı mimarisi gibi çeşitli yapılarla tasarlanabilir.

YSA'nın temel birimi nöron, dendritler, akson ve nöron gövdesi olmak üzere üç ana bileşenden oluşur. Dendritler, sinyalleri alırken, akson sinyalleri iletir. Bu nöronlar, bir araya gelerek karmaşık hesaplamalar gerçekleştirir ve insan vücudunu yöneten en karmaşık makine olan beyinle benzer bir işleyiş sergiler.

Yapay Sinir Ağları genellikle ağırlıklar ve bias'lar kullanarak öğrenirler. Ağırlıklar, giriş verileri ile çıkış arasındaki ilişkiyi belirlerken, bias'lar nöronların aktivasyon eşiğini kontrol eder.


Matematiksel olarak, genel bir Yapay Sinir Ağı hücresinin çıkışını hesaplamak için kullanılan formül şu şekildedir:

$$y = f\left(\sum_{i=1}^n (w_i \cdot x_i) + b\right)$$

Burada:

- y : nöronun çıkışını,
- f : aktivasyon fonksiyonunu,
- w_i : girişlere ait ağırlıkları,
- x_i : giriş verilerini,
- b : bias'ı temsil eder.

Bu formül, her bir girişin ağırlığı ile çarpılıp toplandıktan sonra bias eklenerek nöronun aktivasyonunu hesaplar. Sonuç, aktivasyon fonksiyonundan geçirilir ve nöronun çıkışını verir.



Şekil 3.9 Yapay Sinir Ağları Örneği

Bilgisayar nöronları, girişler, ağırlıklar, aktivasyon fonksiyonları ve çıkışlar arasında bir bağlantı kurar. Giriş katmanındaki nöronlar, beyindeki dendritlere karşılık gelirken, çıkış ise aksonu temsil eder.

Her bir giriş sinyalinin ağırlığı ile çarpılması sonucunda nöron, tüm giriş değişkenlerinin ağırlıklı toplamını elde eder. Öğrenme aşamasında, bu ağırlıklar geri yayılım ve eğim inişi kavramlarıyla güncellenir.

Sinir ağları, beş duyu parametresini örneğin aldığı anda, giriş katmanından başlayarak işlem yapar. İki gizli katman, girdileri işleyerek duygusal ve karar mekanizmalarını oluşturur. Bu, örneğin hisse senedi fiyatlarını tahmin etmek için kullanılan bir sinir ağında, giriş parametrelerinin kombinasyonlarına dayanarak çıkış katmanında bir fiyat tahmini üretir.

Sinir ağları, öğrenme eğitimi aşamasında, örnek verilerle beslenerek kendilerini eğitirler. Bu süreçte, ağırlıklar geri yayılım ve eğim inişi ile güncellenir. Her nöronun farklı ağırlıkları ve aktivasyon fonksiyonları vardır, bu da modele esneklik ve genelleme yeteneği kazandırır. Öğrenilen bilgiler, modelin belirli bir görevi daha iyi gerçekleştirmesine olanak tanır.

Yapay Sinir Ağları, karmaşık problemleri çözme yeteneği, genelleme kabiliyeti ve öğrenme yeteneği ile dikkat çeken güçlü bir yapay zeka modelidir.

İnsan beynine benzer bir yapı sergileyerek, bilgi işleme ve karar verme süreçlerinde etkileyici bir performans gösterir. Bu nedenle, yapay sinir ağları, çeşitli uygulama alanlarında başarıyla kullanılan önemli bir teknoloji olarak öne çıkar.

3.3 Regresyon Model Değerlendirme Metrikleri

3.3.1 R-Kare

Regresyon analizi, bir veya birden fazla bağımsız değişkenin bağımlı değişken üzerindeki etkisini modellemek için kullanılan istatistiksel bir yöntemdir. Bu analizler, bağımsız değişkenlerin bağımlı değişkeni ne kadar iyi açıkladığını değerlendirmek için kullanılan çeşitli metrikler içerir. R-kare, regresyon modellerinin performansını değerlendirmek ve açıklanan varyansın yüzdesini ölçmek için kullanılan önemli bir istatistiksel ölçüdür.

R-kare, regresyon modelinin bağımsız değişkenlerle bağımlı değişken arasındaki uyumu açıklama yeteneğini ölçen bir ölçüdür. Bu ölçü, 0 ile 1 arasında bir değer alır. 0'a yaklaşan değerler, modelin bağımlı değişkenin varyansını açıklamada başarısız olduğunu gösterirken, 1'e yaklaşan değerler, modelin bağımlı değişkenin varyansını tamamen açıkladığını gösterir.

Ancak, R-kare'nin yüksek olması her zaman iyi bir model anlamına gelmez; aşırı uydurma durumlarını ve gerçek dünya genelleme yeteneğini göz önünde bulundurmak önemlidir.

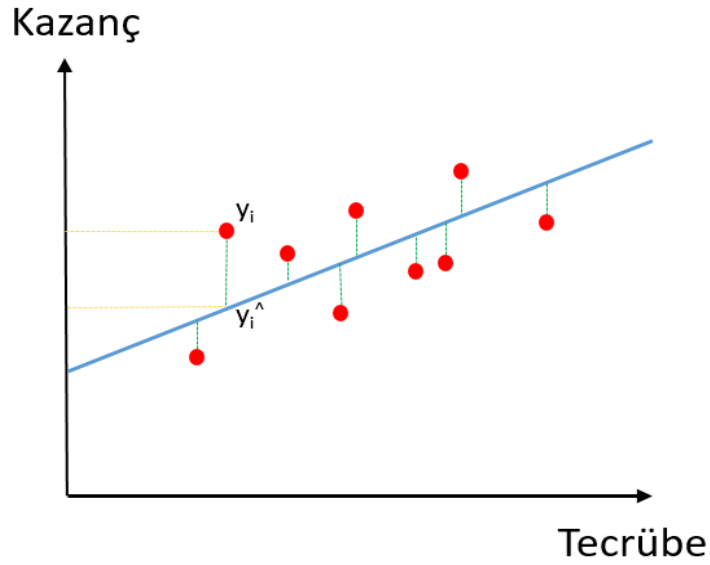
R-kare, aşağıdaki formülle hesaplanır:

$$R^2 = 1 - \frac{SSR}{SST}$$

Burada:

- *SSR*, Regresyon (Modelin Açıkladığı) Toplam Kareler,
- *SST*, Toplam (Gözlemlenen) Toplam Karelerdir.

Bu formülde, *SSR*, modelin tahmin ettiği değerlerle beklenen değerler arasındaki farkın karesinin toplamını temsil ederken, *SST*, gözlemlenen değerlerle ortalama değer arasındaki farkın karesinin toplamını temsil eder.



Şekil 3.10 : R- Kare Örnek Grafiği

R-kare, regresyon modellerinin performansını ölçen önemli bir istatistiksel metrik olarak karşımıza çıkmaktadır. R-kare değeri, bağımsız değişkenlerin bağımlı değişkeni ne kadar iyi açıkladığını gösterir.

Ancak, bu metriğin anlamlı bir değerlendirme için diğer metriklerle birlikte kullanılması ve modelin genelleme yeteneğinin dikkate alınması önemlidir.

3.3.2 RMSE (Root Mean Squared Error)

RMSE (Root Mean Squared Error), bir regresyon modelinin tahminlerinin gerçek değerlerden ne kadar sapma gösterdiğini ölçen bir hata metriğidir. Genellikle tahmin performansını değerlendirmek için kullanılır ve hata değerlerinin büyüklüğünü nicel olarak ifade eder.

RMSE'nin hesaplanması şu şekildedir:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}$$

Burada:

- n : nöronun çıkışı,
- y_i : aktivasyon fonksiyonunu,
- \hat{y}_i : model tarafından yapılan tahminleri ifade eder.


Bu formülde, her bir gözlem için gerçek değer ile tahmin arasındaki farkın karesi alınır, bu değerler toplanır, ardından n'e bölünür ve son olarak karekök alınır.

Avantajları;

- Hassas Hata Ölçümü: RMSE, hataların büyüklüğünü ölçer ve bu nedenle bir modelin ne kadar doğru tahminler yaptığını daha hassas bir şekilde gösterir.
- Hata Ölçeklendirmesi: Hataların karesi alınarak büyük hataların daha fazla vurgulanması, modelin aykırı değerlere karşı daha hassas olmasını sağlar.

Sınırlamaları;

- Duyarlılık: Birimlerin büyüklüğüne duyarlıdır, bu nedenle farklı ölçeklerdeki değişkenlerle çalışırken dikkat edilmesi gerekmektedir.
- Outlier Duyarlılığı: Aykırı değerlere (outlier) karşı hassastır, bu nedenle modelin aykırı değerlere olan duyarlılığını değerlendirmek için diğer metriklerle birlikte kullanılmalıdır.



Şekil 3.11: RMSE Örnek Grafiği

RMSE, genellikle regresyon modellerinin performansını değerlendirmek için yaygın olarak kullanılan bir metriktir. Daha küçük bir RMSE değeri, modelin daha iyi bir tahmin yapma yeteneğini gösterir.

3.3.3 MAE (Mean Absolute Error)

Regresyon modelleri, bir bağımlı değişkenin bağımsız değişkenler tarafından nasıl etkilendiğini modellemek için kullanılır. Bu modellerin performansını değerlendirmek, yapılan tahminlerin gerçek değerlere ne kadar yakın olduğunu anlamak önemlidir.

Mean Absolute Error (MAE), bu tahmin hatalarını ölçmek ve modellerin başarılarını değerlendirmek için yaygın olarak kullanılan bir hata metriğidir.

Mean Absolute Error (MAE), bir regresyon modelinin tahminlerinin gerçek değerlerden sapmalarını ölçen bir hata metriğidir. Bu metrik, her bir gözlem için gerçek değer ile model tarafından yapılan tahmin arasındaki mutlak farkları ifade eder ve bu farkların ortalaması alınarak hesaplanır.

Formülü şu şekildedir;

$$RMSE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n}$$

Burada:

- n : gözlem sayısını temsil eder,
- y_i : gerçek değerleri,
- \hat{y}_i : model tarafından yapılan tahminleri ifade eder

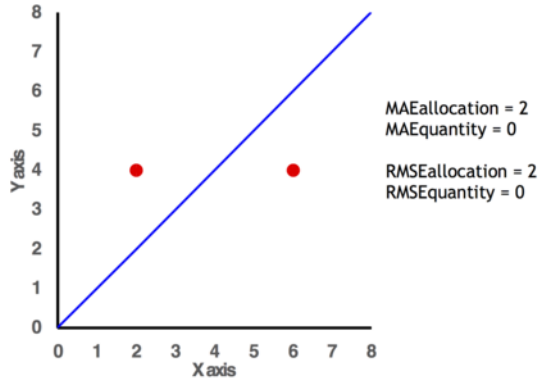
Avantajları;

- Aykırı Değerlere Direnç: MAE, hataların mutlak farklarını kullanarak çalıştığı için aykırı değerlere karşı daha dirençlidir. Bu, modelin tahminlerinin genel hata düzeyini daha sağlıklı bir şekilde yansıtmasını sağlar.
- Duyarlılık: Hataların karesini almadan çalıştığı için birim büyüklüklerine daha duyarlıdır. Bu özellik, farklı ölçeklerdeki değişkenlerle çalışırken daha dikkatli bir performans değerlendirmesi sağlar.

Sınırlamaları;

- Duyarlılık: Yine de birim büyüklüklerine duyarlıdır, bu nedenle farklı ölçeklerdeki değişkenlerle çalışırken dikkat edilmesi gerekir.

Comparison of two observations where $X_1 = 2$ and $X_2 = 6$



Şekil 3.12: MAE Örnek Grafiği

MAE, regresyon modellerinin tahmin performansını değerlendirmek için güvenilir bir hata metriğidir. Daha küçük bir MAE değeri, modelin daha az hata yaptığını ve daha iyi tahminler yaptığını gösterir. Ancak, her hata metriği gibi, MAE de tek başına bir modelin performansını değerlendirmek için yeterli olmayabilir; genellikle diğer metrikler ve görsel analizlerle birlikte kullanılır.

3.3.4 MSE (Ortalama Kare Hatası)

Ortalama Kare Hatası (Mean Squared Error veya kısaltılmış olarak MSE), bir regresyon modelinin tahminlerinin ne kadar doğru olduğunu ölçen bir performans metriğidir. Bu ölçüm, gerçek değerlerle model tarafından yapılan tahminler arasındaki ortalama karesel farkı ifade eder.


Formülü şu şekildedir

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Burada:

- n : gözlem sayısını temsil eder,
- y_i : gerçek değerleri,
- \hat{y}_i : model tarafından yapılan tahminleri ifade eder

Bu formülde, her bir veri noktası için gerçek değer ile modelin tahmini arasındaki fark alınır, bu farkların karesi alınır ve ardından bu karelerin ortalaması alınarak MSE hesaplanır.



Şekil 3.13: MSE Örnek Grafiği

MSE'nin değeri sıfıra ne kadar yakınsa, modelin tahminleri gerçek değerlere o kadar yakındır. Ancak, MSE'nin değeri genellikle pozitif bir sayıdır ve sıfıra yaklaştıkça daha iyi bir model performansını gösterir. Bu nedenle, MSE küçüldükçe, modelin regresyon performansının arttığı söylenebilir.

MSE, özellikle regresyon problemlerinde yaygın olarak kullanılan bir hata ölçüsüdür, ancak aykırı değerlere karşı hassas olabilir. Başka durumlar için farklı hata ölçümleri de kullanılabilir.

Bölüm 4

Yöntem

Makine öğrenimi algoritmalarından yapay sinir ağları (YSA), finansal piyasalarda, özellikle borsa tahminlerinde kullanılan popüler araçlardan biridir. Bu bölümde algortimanın uygulanış şekilleri ve tahmin modelleri anlatılacaktır.

4.1 Makine öğrenmesi Algoritması

4.1.1 Yapay Sinir Ağları Modeli

Yapay Sinir Ağları (YSA) tarihsel verileri öğrenerek gelecekteki tahminlerde başarılı bir şekilde kullanılmaktadır, özellikle de zaman serisi tahminlerinde tercih edilen bir yöntem olmuştur.

2019-2023 yılları arasındaki BIST 30 endeksine ait Akbank (AKBNK), Alarko (ALARK), Arçelik (ARCLK), Aselsan (ASELS) ve Emlak Konut GYO (EKGYO) şirketlerine ait 5 yıllık günlük verilerle bir veri seti oluşturduk. Bu veri setini analiz etmek ve Yapay Sinir Ağı (YSA) modelimizi eğitmek için gerekli kütüphaneleri Python programına ekledik. Numpy, bilimsel hesaplamalar için temel bir araç sağladı, Pandas ise veri çerçeveleri üzerinde etkili çalışmamıza yardımcı oldu. Veriler, her bir şirketin günlük fiyat hareketleri gibi önemli özellikleri içeren bir veri çerçevesinde depolandı.

Veri setini %70 eğitim ve %30 test verileri olarak ayırdık. Ayrıca, tüm giriş özelliklerini standartlaştırdık. Bu önemli adım, modelin farklı ölçekli özelliklere dengeli bir şekilde tepki vermesini sağlar. Bu standardizasyon işlemi için scikit-learn kütüphanesinden Min-Max Scaler yöntemini kullandık.

Sonrasında, Keras kütüphanesini kullanarak Yapay Sinir Ağı modelini oluşturduk. Bu model, giriş katmanı, gizli katmanlar ve çıkış katmanından oluşmaktadır. Modeli derledik ve eğitim verileri üzerinde eğitimini gerçekleştirdik. Modelin performansını değerlendirmek için test verilerini kullandık ve kayıp (loss) değerini ve ortalama mutlak hata (MAE) değerini elde ettik. Oluşturduğumuz bu temel modeli, gerçek veri setine ve ihtiyaçlara uyacak şekilde daha fazla özelleştirmek mümkündür.

```
# Veriyi normalize et
scaler = MinMaxScaler()
data_normalized = scaler.fit_transform(data)

C:\anaconDAa\envs\minik\lib\site-packages\sklearn\preprocessing\_data.py:400: RuntimeWarning: All-NaN slice encountered
data_min = np.nanmin(X, axis=0)
C:\anaconDAa\envs\minik\lib\site-packages\sklearn\preprocessing\_data.py:401: RuntimeWarning: All-NaN slice encountered
data_max = np.nanmax(X, axis=0)

# Özellikleri ve hedef değişkeni belirleme
X = data_normalized[:, 1:5] # Açılış, Yüksek, Düşük, Hac.
y = data_normalized[:, 0]   # Kapanış

# Veriyi %70 eğitim, %30 test olacak şekilde ayır
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)

# Ölçekleyicilerin oluşturulması
scaler_x = MinMaxScaler(feature_range=(0, 1))
scaler_y = MinMaxScaler(feature_range=(0, 1))

# Verilerin ölçeklenmesi
X_train_scaled = scaler_x.fit_transform(X_train)
y_train_scaled = scaler_y.fit_transform(y_train.reshape(-1, 1))
X_test_scaled = scaler_x.transform(X_test)
y_test_scaled = scaler_y.transform(y_test.reshape(-1, 1))

# Ölçekli veri setlerinin oluşturulması
train_scaled = np.concatenate((y_train_scaled, X_train_scaled), axis=1)
test_scaled = np.concatenate((y_test_scaled, X_test_scaled), axis=1)

# Verilerin boyutlarının yazdırılması
print("Eğitim Veri Seti Boyutu:", train_scaled.shape)
print("Test Veri Seti Boyutu:", test_scaled.shape)
```

Şekil 4.1 : Eğitim ve Test Veri Seti Ön İşleme

Şimdi, yapay sinir ağı oluşturmak için gerekli fonksiyonları içe aktardık. Bu adımda, sinir ağları öğreniminin katmanlarını sırayla oluşturmak için tensorflow.python.keras.models kütüphanesinden Sequential yöntemini içe aktarıyoruz. Bu yöntem, sinir ağıımızdaki katmanları sıralı bir şekilde eklememize olanak tanır. Ardından, bir sonraki adımda içe aktardığımız yöntem, tensorflow.python.keras.layers kitaplığındaki Dense fonksiyonudur. Bu fonksiyon, yapay sinir ağıımızın katmanlarını oluşturmak için kullanılır.

Oluşturulan Yapay Sinir Ağı (YSA) Modeli, 5 giriş parametresi (Kapanış, Açılış, Yüksek, Düşük, Hac.) kullanılarak inşa edildi. Modelde iki gizli katman bulunmaktadır ve her bir gizli katmandaki birim değeri 128 olarak belirlendi. Birim değeri, gizli katmandaki nöron veya düğümlerin sayısını ifade eder. Çıkış katmanındaki nöron, hisse senedi kapanış fiyatını tahmin etmek için kullanılır. Gizli katmandaki nöronlar, altı giriş parametresi ve her bir aktivasyon fonksiyonu için farklı ağırlıklara sahip olacak şekilde tasarlanmıştır. Bu yapı, modelin giriş parametrelerini etkinleştirmek ve karmaşık ilişkileri öğrenmek için geniş bir öğrenme kapasitesine sahip olmasını sağlar.

```
model = Sequential()
model.add(Flatten())
model.add(Dense(units=128, kernel_initializer='uniform', activation='relu', input_dim=X_train.shape[1]))
```

Şekil 4.2: YSA Modeli Birinci Katman

Oluşturulan model değişkeni, Yapay Sinir Ağı öğrenim katmanlarını başlatmak üzere Sequential() işlevi ile başlatıldı. Bu değişken, daha sonra Python'da yapay sinir ağı katmanlarını oluşturmak için kullanılacaktır. Modeldeki katmanları eklemek için add() işlevi kullanıldı. Add işlevinin bağımsız değişkeni, Dense() işlevidir ve sırasıyla aşağıdaki bağımsız değişkenlere sahiptir:

- Units: Belirli bir katmandaki düğüm veya nöron sayısını tanımlar. Bu değer 128 olarak belirlendi, yani gizli katmanda 128 nöron bulunacak.
- Kernel_initializer: Gizli katmandaki farklı nöronların ağırlıkları için başlangıç değerlerini belirler. Bu, "aynı, değişmeyen" olarak tanımlandı; yani ağırlıklar, tekdüze bir dağılımdan değerler ile başlatılacak.
- Activation: Belirli gizli katmandaki nöronlar için aktivasyon fonksiyonudur. Burada, fonksiyon olarak "ReLU" veya rektifiye edilmiş Doğrusal Birim fonksiyonu kullanılmaktadır.
- Input_dim: Gizli katmana giriş sayısını tanımlar. Bu değer, girdi veri çerçevesinin sütun sayısına eşittir. Model, önceki katmanın çıktı sayısını bilir, bu nedenle bu katmanın sonraki katmanlarda gerekli olmamasını sağlar.

```
model.add(Flatten())
model.add(Dense(units=128, kernel_initializer='uniform', activation='relu'))
```

Şekil 4.3: YSA Modeli İkinci Katman

Modelimize, düzgün bir çekirdek başlatıcı ve "ReLU" aktivasyon fonksiyonu kullanılarak 128 nöronlu ikinci bir katman ekledik. Model, bu katmanda her nöronun kendi ağırlıklarını ve aktivasyon fonksiyonunu kullanarak çıkış değerini üretecektir. Bu işlem, modelin eğitim verilerine dayanarak nöronlara özgü ağırlıklı bir ek aktivasyon fonksiyonu uygulamasını içerir. Bu sayede her nöronun belirli bir çıkış değeri oluşacaktır. Bu yapımızda sadece iki gizli katman oluşturduk.

```
model.add(Flatten())
model.add(Dense(units=1, kernel_initializer='uniform', activation='sigmoid'))
```

Şekil 4.4: YSA Modeli Son Katman

Sonraki katman, tek bir çıktıya sahip olan çıktı katmanıdır. Bu nedenle, bu katmandaki birim sayısı 1'dir ve aktivasyon fonksiyonu olarak Sigmoid seçilmiştir. Bu tercih, tahminin pazarın yukarı yönlü bir hareket olasılığı olmasını istediğimiz için yapılmıştır.

```
model.compile(optimizer='adam', loss='mean_squared_error')
```

Şekil 4.5: YSA Modeli Optimizer ve Kayıp

Son olarak, modelimizi derlerken şu argümanları kullanarak derleme işlemini gerçekleştirdik:

- Optimizer: "adam" optimizer'ı, stokastik gradyan inişinin bir türü olarak seçilmiştir.
- Loss: Eğitim sırasında optimize edilecek olan kayıp fonksiyonu, ortalama kare hatası olarak belirlenmiştir.

```
# Modeli eđit
model.fit(X_train, y_train, batch_size=10, epochs=50)

Epoch 1/50
88/88 [=====] - 1s 2ms/step - loss: 0.0857
Epoch 2/50
88/88 [=====] - 0s 3ms/step - loss: 0.0032
Epoch 3/50
88/88 [=====] - 0s 3ms/step - loss: 0.0012
```

Şekil 4.6: YSA Modeli Epoch ve Batch_size Sayısı

Şimdi, oluşturulan sinir ađını eđitim veri setlerine uygulama zamanı geldi. Bu işlem, X_train ve y_train verilerini, batch_size ve fit() işlemindeki epoch sayısı ile geçirerek gerçekleştirilir. Batch_size, modelin hataları geri yaymadan ve ađırlıkları güncellemeden önce hesapladıđı veri noktalarının sayısını ifade eder.

Epoch sayısı, modelin eđitiminin kaç kez tamamlandıđını temsil eder. Bu örnekte, geriye dönük işlem 50 epoch olarak tekrarlandı. Oluşturulan Yapay Sinir Ađı modeli, hisse senedi fiyatı tahmini üzere bu adımları takip ederek çalışmaktadır.

```
# Modeli Deđerlendirme
# y_test: Gerçek deđerler, predictions: Tahmin edilen deđerler
r2 = r2_score(y_test, predictions)
print(f'R-Kare: {r2:.2f}')

rmse = np.sqrt(mean_squared_error(y_test, predictions))
print(f'RMSE: {rmse:.2f}')

mae = mean_absolute_error(y_test, predictions)
print(f'MAE: {mae:.2f}')
```

Şekil 4.7: Verilerin Performans Deđerlendirmesi

İlk kod blođu, modelin performansını deđerlendirmek için kullanılan üç farklı metrik olan R-Kare (R2), Kök Ortalama Kare Hatası (RMSE) ve Ortalama Mutlak Hata (MAE) deđerlerini hesaplar.

- R-Kare (R2): Bu metrik, modelin veri setindeki varyansın ne kadarını açıkladıđını gösterir. 1'e yaklaşan deđerler, modelin veriyi iyi açıkladıđını gösterir. Bu deđer, gerçek ve tahmin edilen deđerler arasındaki korelasyonu ölçer.

- Kök Ortalama Kare Hatası (RMSE): Bu metrik, modelin tahminlerinin gerçek değerlere olan ortalama karesel uzaklığını ölçer. Düşük bir RMSE, modelin iyi performans gösterdiğini gösterir.
- Ortalama Mutlak Hata (MAE): Bu metrik, tahminlerin gerçek değerlere olan ortalama mutlak uzaklığını ölçer. MAE değeri ne kadar düşükse, modelin o kadar iyi tahmin yaptığı anlamına gelir.

```
# Tahminleri gerçek değerlerle karşılaştır
mse = mean_squared_error(y_test, predictions)
print(f'Mean Squared Error: {mse}')
```

Şekil 4.8: Tahmin ve Gerçek Verilerin Karşılaştırılması

İkinci kod bloğu, Hata Kareler Ortalaması (Mean Squared Error - MSE) değerini hesaplar ve yazdırır. MSE, modelin tahminlerinin gerçek değerlere olan ortalama karesel uzaklığını ölçer. Düşük bir MSE, modelin iyi performans gösterdiğini gösterir.

```
# Gerçek ve tahmin verilerin grafiklerini çiz
plt.plot(y_test, label='Gerçek Değerler')
plt.plot(predictions, label='Tahminler')
plt.title('AKBANK Hisse Senedinin Gerçek ve Tahmin Değerler Grafiği')
plt.legend()
plt.show()
```

Şekil 4.9: Tahmin ve Gerçek Verilerin Karşılaştırma Grafiğinin Kodu

Son kod bloğu ise gerçek ve tahmin edilen değerlerin bir grafiğini çizer. Bu grafik, modelin performansını daha açık bir şekilde görselleştirmek için kullanılır. Gerçek değerler ile tahmin edilen değerlerin grafikte ne kadar benzer olduğu gözlemlenerek modelin başarısı değerlendirilebilir. Bu tür grafikler, modelin tahminlerini hızlı bir görsel kontrol sağlayarak anlamamıza yardımcı olmasını sağlar.

Bölüm 5

SONUÇ

Yapılan YSA modeli, tarihsel verileri öğrenerek gelecekteki değerleri tahmin etmek için oldukça iyi sonuçlar elde etmiştir. Tabloya bakıldığında, modelin gerçek değerlere ne kadar yakın tahminler yaptığını göstermektedir.

Beş firmaya baktığımızda da aynı sonuçları görmekteyiz. RMSE ve MAE'nin düşük olması, modelin hata oranının çok az olduğunu gösterir. Bu da YSA modelinin tahminlerinin gerçek değerlere çok yakın olduğunu gösterir.

5 BIST 30 Firması

	AKBANK	ALARKO	ARÇELİK	ASELSAN	EKGYO
R- Kare	1.00	1.00	1.00	1.00	1.00
RMSE	0.01	0.02	0.01	0.01	0.01
MAE	0.01	0.01	0.01	0.01	0.01
MSE	0.00010	0.00036	9.7907	0.00019	0.00023

Tablo 5.1 : Beş BİST30 Firmaların Performan Değerlendirmeleri

Tabloya baktığımızda:

R-Kare Değerleri;

AKBANK, ALARKO, ARÇELİK, ASELSAN ve EKGYO için R-Kare değerleri sırasıyla 1.00 olarak belirtilmiştir. Bu değerler, modellerin veri setini mükemmel bir şekilde açıkladığını ve tahminlerin gerçek değerlere tam bir uyum içinde olduğunu gösterir.

RMSE (Kök Ortalama Kare Hatası) Değerleri;

AKBANK ve ARÇELİK için RMSE değerleri 0.01, ALARKO için 0.02 olarak belirtilmiştir. Bu düşük RMSE değerleri, bu modellerin tahminlerinin gerçek değerlere yakın olduğunu gösterir. Düşük RMSE, modelin tahminlerinin gerçek değerlere olan uzaklığının düşük olduğunu gösterir.

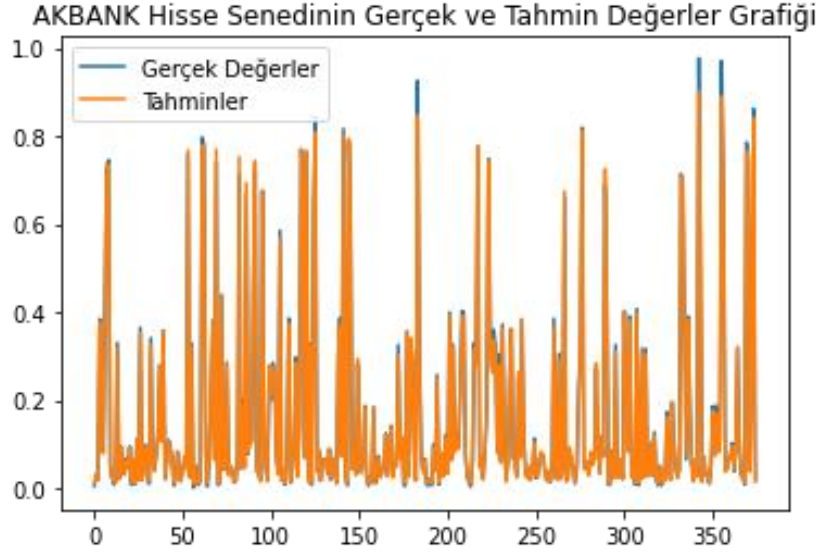
MAE (Ortalama Mutlak Hata) Değerleri;

AKBANK, ALARKO, ARÇELİK, ASELSAN ve EKGYO için MAE değerleri sırasıyla 0.01 olarak belirtilmiştir. Bu değerler, modellerin tahminlerinin gerçek değerlere olan ortalama mutlak uzaklığının düşük olduğunu gösterir.

MSE (Ortalama Kare Hatası) Değerleri;


AKBANK için MSE değeri 0.00010, ALARKO için 0.00036, ARÇELİK için 9.7907, ASELSAN için 0.00019 ve EKGYO için 0.00023 olarak belirtilmiştir. MSE, modelin tahminlerinin gerçek değerlere olan ortalama karesel uzaklığını ölçer. Düşük MSE değerleri, modelin başarılı tahminler yaptığını gösterir. Ancak, ARÇELİK için yüksek MSE değeri dikkat çekicidir ve bu durum modelin bazı tahminlerde daha fazla hata yaptığını gösterebilir.

Genel olarak, tablodaki düşük R-Kare, RMSE ve MAE değerleri, modellerin başarılı olduğunu ve iyi tahminler yaptığını gösterir. Ancak, ARÇELİK için yüksek MSE değeri, bu özel modelin bazı durumlarda daha fazla hata yaptığını gösterebilir, bu nedenle dikkatle incelenmelidir.




Şekil 5.1 : AKBANK Tahmin ve Gerçek Verilerin Karşılaştırma Grafiği

AKBANK hisse senedi için tahmin edilen değerlerin gerçek değerlere ne kadar yakın olduğunu göstermektedir. AKBANK hisse senedinde elde edilen sonuçlar, tahmin edilen değerlerin gerçek değerlere çok yakın olduğunu vurgulamaktadır.




Şekil 5.2 : ALARKO Tahmin ve Gerçek Verilerin Karşılaştırma Grafiği

ALARKO hisse senedi için oluşturulan grafik, modelin başarısını yansıtmaktadır. Tahmin edilen değerlerin gerçek değerlere olan yakınlığı göz önüne alındığında, ALARKO hisse senedi için güçlü bir tahmin modeli elde edildiği söylenebilir.




Şekil 5.3 : ARÇELİK Tahmin ve Gerçek Verilerin Karşılaştırma Grafiği

ARÇELİK hisse senedi için grafiğin incelenmesi, genel olarak başarılı bir tahmin modeli olduğunu göstermektedir. Ancak, daha önce belirtildiği gibi, MSE değerinin yüksek olması dikkat çekicidir ve bu durumu daha detaylı olarak değerlendirmek gerekebilir.



Şekil 5.4 : ASELSAN Tahmin ve Gerçek Verilerin Karşılaştırma Grafiği

ASELSAN hisse senedi için elde edilen grafik, tahmin edilen değerlerin gerçek değerlere oldukça yakın olduğunu göstermektedir. Modelin başarısı, grafikteki benzerlikten anlaşılmaktadır.



Şekil 5.6: EKGYO Tahmin ve Gerçek Verilerin Karşılaştırma Grafiği

EKGYO hisse senedi için oluşturulan grafik, tahmin edilen değerlerin gerçek değerlere ne kadar yakın olduğunu göstermektedir. EKGYO hisse senedinde de başarılı bir tahmin modeli oluşturulduğu söylenebilir.

Genel olarak, tüm hisse senetleri için grafikler, oluşturulan modellerin gerçek değerlere çok yakın tahminler yaptığını göstermektedir. Bu durumda YSA eğitiminin sona erdiği ve artık Python kullanarak kendi Yapay Sinir Ağı'nı oluşturabilme yeteneğine sahip olduğu belirtiliyor. Ancak, özellikle ARÇELİK hisse senedindeki yüksek MSE değeri daha detaylı bir incelemeyi gerektirebilir. Ayrıca, bu yetenekle makinelerin gücünü ve zekasını kullanarak ticaret yapmaya başlanabileceğine vurgu yapılıyor. Bu, modelin başarıyla eğitildiğini ve uygulama alanlarında kullanılabilirliğini gösterir.

Kaynaklar

- Akbaş, S. (2022). Yapay sinir ağları ile borsa endeksleri tahmini: BIST 100 örneği. *Süleyman Demirel Üniversitesi Fen Bilimleri Dergisi*, 25(2), 499-506.
- Aytekin, M. (2021). BIST 30 hisselerinin yapay sinir ağları ile tahmini. *Süleyman Demirel Üniversitesi Fen Bilimleri Dergisi*, 24(3), 705-712.
- Bing, Y., Hao, J. K., & Zhang, S. C. (2012). Stock Market Prediction Using Artificial Neural Networks. *Advanced Engineering Forum*, 6–7, 1055–1060. <https://doi.org/10.4028/www.scientific.net/aef.6-7.1055>
- Filiz, M. F., Karaboga, D., & Akogul, O. (2017). BIST-50 endeksinin makine öğrenmesi ve yapay sinir ağları yöntemleriyle tahmini. *Süleyman Demirel Üniversitesi Fen Bilimleri Dergisi*, 20(3), 635-644.
- Karaatlı, M., Güngör, Z., Demir, E., & Kalaycı, T. (2005). Yapay sinir ağları ile İMKB Ulusal 100 Endeksi tahmini. *İstanbul Üniversitesi İktisat Fakültesi Mecmuası*, 60(2), 175-190.
- Kantar, M. (2020). BIST 100 endeksinin yapay sinir ağları ve ARMA modelleri ile tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 25(2), 401-414.
- Kutlu, H., & Badur, B. (2009). Yapay sinir ağları ile hisse senedi fiyat tahmini: BIST 30 örneği. *Süleyman Demirel Üniversitesi Fen Bilimleri Dergisi*, 22(2), 439-446.
- Moghaddam, M. H., Moghaddam, A. H., & Eslami, M. (2016). Stock market prediction using artificial neural networks: A case study of NASDAQ. *International Journal of Advanced Computer Science and Applications*, 7(2), 354-360.

- Shastri, M., Roy, S., & Mittal, M. (2018). Stock Price Prediction using Artificial Neural Model: An Application of Big Data. *ICST Transactions on Scalable Information Systems*, 0(0), 156085. <https://doi.org/10.4108/eai.19-12-2018.156085>
- Tsai, C. F., & Wang, C. J. (2009). Stock market prediction by using artificial neural networks and decision trees. *Expert Systems with Applications*, 36(10), 7910-7916.
- Wanjawa, B. W., & Muchemi, L. (2014). ANN Model to Predict Stock Prices at Stock Exchange Markets. 1–23. <http://arxiv.org/abs/1502.06434>
- Yürük, M. (2021). Hisse senedi fiyat tahmininde yapay sinir ağları ve teknik göstergelerin kullanımı: BIST 100 örneği. *Süleyman Demirel Üniversitesi Fen Bilimleri Dergisi*, 24(4), 837-844.