

Hisse Senedi Fiyat Tahmininde Yapay Zekâ: Apple'ın Geleceği İçin GRU, LSTM VE XGBoost'un Rekabeti

Diler Türkoğlu¹

Özet

Hisse senedi fiyat tahminleri, yatırımcılar ve finansal analistler için büyük bir önem taşımaktadır. Finansal piyasaların karmaşık ve dinamik yapısı, doğru tahminlerin yapılmasını hem zorlaştırmakta hem de daha değerli hale getirmektedir. Doğru tahminler, yatırımcıların risklerini minimize etmelerine, portföylerini daha etkin bir şekilde yönetmelerine ve stratejik kararlar almalarına olanak tanımakta ve bu da yatırımcılara piyasada rekabet avantajı sağlamaktadır. Özellikle volatilitenin yüksek olduğu dönemlerde doğru tahminler, yatırımcıların büyük kayıplar yaşamasını önleyebilir ve daha istikrarlı kazançlar elde etmelerine yardımcı olabilmektedir. Günümüzde gelişen teknoloji ve veri analizi yöntemleri, hisse senedi fiyat tahminlerinde önemli bir rol oynamaktadır. Bu çalışmada, Apple firmasına ait hisse senedi fiyatlarını tahmin etmek için üç farklı model kullanılmıştır: GRU (Gated Recurrent Unit), LSTM (Long Short-Term Memory) ve XGBoost (Extreme Gradient Boosting). Her bir model, zaman serisi verilerini analiz etmek ve gelecekteki fiyat hareketlerini tahmin etmek için özel olarak tasarlanmıştır. Çalışma, Python programlama dili kullanılarak Jupyter Notebook ortamında gerçekleştirilmiştir. Modellerin performanslarını en üst düzeye çıkarmak için hiperparametre ayarlamaları yapılmış ve her model için optimal parametreler belirlenmiştir. Bu süreçte, modellerin doğruluk oranları, hata oranları ve genel performansları karşılaştırılmıştır. Analizler sonucunda, LSTM modelinin GRU ve XGBoost modellerine kıyasla daha doğru ve verimli tahminler sağladığı görülmüştür. LSTM modelinin üstün performansının, modelin uzun vadeli bağımlılıkları yakalayabilme yeteneği ile ilişkili olduğun söylenebilmektedir. LSTM, özellikle zaman serisi verilerinde geçmişe yönelik önemli bilgileri hafızasında tutarak daha isabetli tahminler yapabilmektedir.

1 Dr. Öğr. Üyesi, Kurum Bilgisi: Ardahan Üniversitesi İktisadi ve İdari Bilimler Fakültesi
e-Mail: dilerurturkoglu@ardahan.edu.tr, ORCID ID: <https://orcid.org/0000-0001-5247-1590>

Bu özellik, finansal veriler gibi dalgalı ve karmaşık veri setlerinde büyük bir avantaj sağlamaktadır. GRU modeli de benzer bir yapıya sahip olmakla birlikte, LSTM kadar uzun vadeli bağımlılıkları yakalama konusunda sınırlı kalmıştır. XGBoost ise güçlü bir makine öğrenmesi algoritması olmasına rağmen, zaman serisi verilerindeki ardışıklığı yakalamada derin öğrenme modelleri kadar etkili olamamıştır. Sonuç olarak, bu çalışmada elde edilen bulgular, hisse senedi fiyat tahminlerinde LSTM modelinin potansiyelini ortaya koymaktadır. LSTM modeli, yalnızca Apple hisse senedi için değil, genel olarak finansal veri analizlerinde de etkin bir şekilde kullanılabilir. Bu sonuçlar, finansal piyasaların daha doğru analiz edilmesi ve yatırım stratejilerinin daha sağlam temellere oturtulması açısından önemli bir katkı sağlamaktadır. Gelecekte yapılacak çalışmalarda, farklı şirketlerin hisse senetleri üzerinde benzer modellerin performansları incelenerek, daha geniş bir perspektif elde edilebilir. Ayrıca, model kombinasyonları ve hibrit yaklaşımlar kullanılarak tahmin doğrulukları daha da artırılabilir.

Giriş

Borsa piyasasında hisse senedi fiyat tahmin teknikleri uzun yıllardır incelenmektedir. Hisse senetlerinin fiyatı veya trendi belirli bir zaman aralığında doğru bir şekilde tahmin edilebilirse, borsa yatırımcılarının yüksek karlar elde etmesi muhtemeldir. Bu ideal tahmin, borsa piyasasının doğrusal olmayan dalgalanmaları tarafından her zaman bozulmakta ve araştırmacılar, yalnızca matematiksel modeller ve geçmiş veriler aracılığıyla mevcut ve gelecekteki hisse senedi fiyatları için doğru tahmin sonuçları verememektedir (Jiang, 2022). Hisse tahmininde hisse senetlerinin geçmiş verilerinden elde edilen bilgilerle yapılan tahminlemeler temel ve teknik analizler aracılığıyla sağlanabilmektedir. Temel ve teknik analizler, yatırımcılara değerli bilgiler sunabilmekle birlikte, kısa vadeli piyasa hareketleri ve dışsal faktörler gibi önemli dinamikleri gözden kaçırma riski taşır ve dolayısıyla tahminleme kabiliyetlerini sınırlayabilir. Bu bağlamda, hisse senedi fiyat tahminleri de dahil olmak üzere finansal tahminlerde makine öğrenimi uygulamalarına olan ilgi son yıllarda önemli ölçüde artmıştır. Makine öğrenimi algoritmaları, büyük veri setlerini analiz etme ve geleneksel analiz yöntemleriyle tespit edilemeyen karmaşık desenleri ortaya çıkarma potansiyeline sahip olup, bu alanda önemli katkılar sağlamaktadır (Karim vd, 2021).

Makine öğrenimi, geleneksel istatistiksel modellere kıyasla bazı önemli avantajlar sunarak, finansal tahminlerdeki doğruluk ve verimlilik sorunlarını giderebilmektedir. Özellikle, hisse senedi fiyat tahminlerinde sıklıkla tercih edilen ayrıştırma-entegrasyon modelleri, zaman serisi verilerini analiz etmek için güçlü araçlar sunmakta, ancak bu modellerin geleneksel yaklaşımlarda karşılaşılan bazı kusurları da barındırmaktadır. Geleneksel modeller,

doğrudan modellenen veri ve gürültü etkilerini göz ardı edebildikleri için tahmin verimliliği ve doğruluğunu olumsuz yönde etkileyebilir. Bu noktada, ayrıştırma-entegrasyon modellerinde dizi yeniden yapılandırması için makine öğrenimi algoritmalarının uygulanması, gürültüyü daha etkili bir şekilde ele alarak tahmin doğruluğunu artırmakta önemli bir rol oynamaktadır. Wang ve arkadaşlarının (2023) belirttiği üzere, bu tür gelişmiş tekniklerin benimsenmesi, hisse senedi fiyat tahminlerinin doğruluğunu artırmanın yanı sıra, finansal modelleme süreçlerinin verimliliğini de iyileştirmektedir. Bu bağlamda, makine öğrenimi yöntemlerinin hisse senedi tahminlerindeki etkinliği, özellikle büyük ve likit piyasalarda faaliyet gösteren şirketlerin hisse senetleri üzerinde yapılan analizlerle daha belirgin hale gelmektedir. Örneğin, Apple gibi teknoloji devi bir şirketin hisse fiyatlarının tahmin edilmesi, dinamik piyasa koşullarına ve dışsal faktörlere karşı duyarlı olması nedeniyle, makine öğrenimi algoritmalarının güçlü bir şekilde uygulanmasını gerektiren bir durumdur.

Apple, 2007 yılında piyasaya sürdüğü ilk akıllı telefonu iPhone ile teknoloji dünyasında önemli bir dönüm noktası oluşturmuştur. iPhone, kullanıcılarına masaüstü bilgisayarlarındaki internet gezinme deneyimini mobil cihazlarda sunma imkânı tanıyarak, mobil teknolojinin gelişiminde büyük bir etki yaratmıştır. Bu yenilik, Apple'ın global çapta bilinirliğini artırmış ve şirketin piyasa değeri üzerinde belirgin bir yükselişe neden olmuştur. Özellikle, Apple'ın Ocak 2007'de 73,8 milyar dolar olan piyasa değeri, yalnızca bir yıl içinde 120 milyar dolara çıkmıştır. Pandemi sürecinin başlangıcıyla birlikte, Apple'ın piyasa değeri Mart 2020'de 1,1 trilyon dolara ulaşmış, ardından bu dönemde yaşanan ekonomik dalgalanmalara rağmen şirketin değeri hızla artmaya devam etmiştir. Ağustos 2020'de, Apple'ın piyasa değeri iki katına çıkarak 2,2 trilyon dolara ulaşmıştır. Bu büyüme, Apple'ın pandemi dönemindeki dijitalleşme ve uzaktan çalışma taleplerinden yararlanarak, teknolojik yeniliklerine olan talebi artırmasının bir sonucu olarak değerlendirilebilir (Anadolu Ajansı, 2024). Ticaret Bakanlığı verilerine göre Apple, marka değeri geçen yıla göre %15 artışla 1 trilyon doları aşan ilk marka olmuştur (ticaret.gov.tr, 2024). Apple'ın 6 Kasım 2024 itibarıyla piyasa değeri veya net değeri 3,37 trilyon dolardır. Piyasa değeri bir yılda %24,47 oranında artmıştır (stockanalysis.com, 2024). Markaya piyasa değeri ve değişim yüzdeleri Tablo 1'de sunulmuştur.

Tablo 1. Apple'ın yıl bazında Piyasa Değeri ve Yıllık Değişimi

Tarih	Piyasa Değeri (\$)	Değişim (%)
5 Kasım 24	3.377,63 milyar	12.80%
29 Aralık 23	2.994,37 milyar	44.87%
30 Aralık 22	2.066,94 milyar	-29.05%
31 Aralık 21	2.913,28 milyar	29.14%
31 Aralık 20	2.255,97 milyar	72.90%
31 Aralık 19	1.304,76 milyar	74.31%
31 Aralık 18	748.54 milyar	-13.85%
29 Aralık 17	868.87 milyar	40.69%
30 Aralık 16	617.59 milyar	5.24%
31 Aralık 15	586.86 milyar	-9.35%
31 Aralık 14	647.36 milyar	28.24%
31 Aralık 13	504.79 milyar	0.83%
31 Aralık 12	500.61 milyar	33.00%
30 Aralık 11	376.40 milyar	27.21%
31 Aralık 10	295,89 milyar	55.90%
31 Aralık 09	189.80 milyar	150.18%
31 Aralık 08	75.87 milyar	-56.25%
31 Aralık 07	173.42 milyar	137.88%
29 Aralık 06	72.90 milyar	20.35%
30 Aralık 05	60.57 milyar	133.95%
31 Aralık 04	25.89 milyar	229.14%

Kaynak: (stockanalysis.com, 2024).

Tablo 1'de Apple firmasının 10 yıllık piyasa değeri ve piyasa değerlerinde meydana gelen değişimler gösterilmektedir. Apple'ın piyasa değeri, son 10 yıl içinde dikkat çekici bir büyüme göstermiştir. Apple'ın piyasa değeri, 2007 yılından önce büyük bir artış göstermiş olsa da, 2008 yılındaki küresel finansal kriz sırasında önemli bir düşüş yaşamıştır. 2008 yılı sonunda, piyasa değeri %56,25 oranında bir kayıp yaşamış ve şirketin değeri 75,87 milyar dolar seviyesine gerilemiştir. Ancak, 2009'dan itibaren, Apple'ın piyasa değeri hızlı bir toparlanma sürecine girmiş ve sadece bir yıl içinde %150,18'lik bir artış sağlamıştır. Bu toparlanma, özellikle Apple'ın iPhone'unun piyasaya sürülmesi ve mobil cihazlara olan talebin artmasıyla ilişkilidir. 2010-2018 dönemi boyunca Apple, %137,88'lik bir artış ile önemli bir büyüme kaydetmiş ve 2018 sonunda piyasa değeri 748,54 milyar dolar olmuştur. Apple'ın piyasa değeri 2019 yılından 2021 yılına kadar oldukça yüksek bir artış göstermiştir. Özellikle 2020 ve 2021 yıllarında, pandemi sonrası teknolojiye olan talep ve Apple'ın güçlü ürün lansmanlarıyla birlikte şirketin piyasa değeri %72,90 ve %29,14 oranlarında sırasıyla artmıştır. Özellikle 2009'dan sonraki dönemde, şirketin piyasa değerinin büyük bir hızla

arttığı gözlemlenmektedir. Bu artış, şirketin hem gelirlerini artıran hem de yatırımcıların şirketin gelecekteki büyüme potansiyeline olan güvenini yansıtmaktadır. Bir önceki yıl olan 2022 yılsonunda, piyasa değerindeki düşüş dikkat çekmektedir. Apple, 2022'de piyasa değerinde %29,05'lik bir azalma yaşamıştır. Bu gerileme, küresel ekonomik durgunluk, enflasyonist baskılar gibi dışsal faktörlerden kaynaklanmış olabilir. Ancak şirket, hızla toparlanarak 2023 yılında %44,87'lik bir artış sağlamıştır. 5 Kasım 2024 itibarıyla, Apple'ın piyasa değeri 3.377,63 milyar dolar olarak kaydedilmiş ve bu, 2023 yılsonuna göre %12,80'lik bir artışı göstermektedir. Bu büyüme oranı, şirketin finansal gücünü ve piyasa algısını yansıtan önemli bir gösterge olarak değerlendirilebilmektedir.

Görüldüğü üzere Apple, her yıl milyonlarca dolar gelir elde eden bir şirkettir. Ayrıca, finansal stabilitesi ve sürdürülebilir büyümesi ile yatırımcılar için önemli bir referans noktası olarak değerlendirilebilmektedir. Piyasa değerinin, şirketin gelecekteki büyüme potansiyelini ve risklerini yansıtan kritik bir gösterge olması nedeniyle Apple'ı analiz etmek, hisse tahmin modellerini geniş bir ölçekle test etmek için değerli bir fırsat sunmaktadır. Bu motivasyonla çalışmanın amacı, Apple Inc. hisselerinin fiyat tahminlerini geliştirmek için yapay zeka tabanlı yöntemlerin etkinliğini araştırmaktır. Gated Recurrent Unit (GRU), Long Short-Term Memory (LSTM) ve XGBoost modellerinin performanslarını karşılaştırarak, hangi modelin daha iyi tahmin sonuçları sağladığını belirlenmemesi hedeflenmektedir. Bu bağlamda, hisse senedi fiyatlarının gelecekteki dalgalanmalarını öngörmek için farklı makine öğrenimi yaklaşımlarının uygulanabilirliğini ve doğruluğunu değerlendirmek amaçlanmaktadır. Elde edilen sonuçlar, yatırım kararlarını desteklemek için pratik bir rehber sunmayı da hedeflemektedir.

1. Literatür Taraması

Liu vd (2019) hisse senedi fiyat endekslerinin tahminindeki model karşılaştırması yaparak en iyi modeli tespit etmeyi amaçladığı çalışmada GRU ve LSTM modellerine dayanarak düzenlenmiş GRULSTM sinir ağı modeli önermişlerdir. Bu amaçla yapılan analizler neticesinde önerilen modelin hisse zaman serisi tahminlerinde mevcut GRU ve LSTM ağ modellerine göre daha üstün performans sergilediği tespit edilmiştir. Aynı bakış açısıyla Patra ve Mohanty (2022) çalışmalarında S&P 500 endeksinin ayarlanmış kapanış fiyatını tahmin etmek için hibrit bir LSTM-GRU modeli önermişlerdir. Söz konusu modeli LSTM, GRU ve MLP modelleri ile karşılaştırılmışlar ve elde edilen sonuçlar, önerilen modelin borsa fiyatlarını daha doğru tahmin etme kapasitesine sahip olduğunu gözler önüne sermektedir. Bhavani vd (2022) hisse endeksi vadeli işlemlerinin tahminine yönelik yeni bir model önermeyi

amaçladığı çalışmasında LSTM, GRU ve hibrit model (LSTM-GRU) olmak üzere üç modeli karşılaştırmayı amaçlamaktadırlar. Yapılan analizler neticesinde GRU modelinin LSTM ve önerilen hibrit modele göre daha iyi sonuçlar verdiği yönündedir.

Liwei vd (2021) çalışmalarında borsa fiyatlarının “yükseliş ve düşüş” tahminine odaklanmışlardır. Hisse verileri üzerinde yapılan korelasyon analizi ile eksik değerler işlenmiş ve LSTM modeli kullanılarak tahminler yapılmıştır. Bunun yanı sıra XGBoost tabanlı Bo-XGBoost modeli, parametre optimizasyonu için Bayesian hesaplamalarıyla eğitilmiştir. Elde edilen sonuçlar, önerilen LSTM-BO-XGBoost modelinin, diğer modellere göre daha iyi performans gösterdiğini ortaya koymaktadır. Aynı doğrultuda Yu vd (2021) çalışmalarında hisse senedi piyasası dalgalanmalarını tahmin etmek için LSTM-XGBoost modelini geliştirmektedir. Yapılan ampirik analizler neticesinde elde edilen bulgular, LSTM-XGBoost modelinin hisse senedi fiyat tahminlerinde belirli bir istikrar ve uygulanabilirlik sağladığını göstermektedir. Jiang (2022) çalışmasında hisse senedi fiyatlarının ve piyasa endekslerinin tahmininde en başarılı modelin belirlenmesini amaçladıkları çalışmalarında ARIMA ve LSTM modellerinin yanı sıra hibrit bir model olarak önerilen GRU-XGBoost modelini test etmişlerdir. Elde edilen bulgular, önerilen hibrit yöntemin RMSE değerlendirme sonuçlarının daha iyi olduğunu göstermektedir.


Liu (2024) Hang Seng Endeksinin gelecek fiyatlarının tahmininde CNN-GRU-XGBoost modeline dayalı bir hiperparametre ayarlama yaklaşımı önerilmiştir. Çalışmada CNN-GRU için Bayesian ayarlama ve XGBoost için rastgele arama yöntemleri kullanılarak optimal hiperparametreler belirlenmiştir. Yapılan testler, tahmin doğruluğunda önemli iyileşmeler, gürültünün azaltılması ve modelin açıklanabilirliğinde artış sağladığını göstermektedir.

Zhu ve He (2022) çalışmalarında Amazon'un hisse fiyatını tahmin etmek için en iyi modeli bulmayı amaçlamışlardır. Bu amaçla çalışmada ARIMA, XGBoost ve LSTM modelleri ile yapılan analizlerde en uygun modeli belirlemek amacıyla ortalama kare hatası (MSE) kullanılmış ve LSTM modelinin en iyi uyum sağladığı ve gerçek eğriye en yakın sonuçları verdiği tespit edilmiştir. Benzer şekilde Ramani vd (2023) Bitcoin fiyatının tahminlemesini amaç edindikleri çalışmada LSTM, ARIMA, XGBoost, Prophet ve duygu analizi gibi derin öğrenme ve makine öğrenimi algoritmaları kullanmışlardır. Elde edilen bulgular, duygu analizi ile LSTM kombinasyonunun, diğer algoritmalara kıyasla Bitcoin fiyat tahmininde daha iyi performans yönündedir.

Wang vd. (2023) ise CSI 500 hisse senedi endeksi vadeli işlemleri, NASDAQ 100 endeksi vadeli işlemleri, FTSE 100 endeksi vadeli işlemleri ve CAC 40 endeksi vadeli işlemleri örnekleminde hisse senedi endeksi vadeli işlemlerinin tahmin doğruluğunu artırmak için yeni bir hibrit model ortaya koymayı amaçlamışlardır. Netice olarak önerilen modelin hisse senedi endeksi vadeli işlemlerinin doğruluğunu artırabildiği yönünde bulgulara ulaşılmıştır. Öte yandan Sathiyapriya vd (2023) makalelerinde işlenmiş ve spam filtrelenmiş Twitter verilerini kullanarak Ether kripto para biriminin fiyat tahmininde Extreme Gradient Boosting (XGBoost) ve Long Short-Term Memory (LSTM) modellerini karşılaştırmaktadırlar. Elde edilen sonuçlara göre LSTM, Ether fiyatlarını tahmin etmede XGBoost'tan daha iyi performans göstermektedir.

2. Veri seti ve Metodoloji

Bilgisayarların hızla gelişmesi sayesinde, eğitim verileri artık çok düzenli bir şekilde elde edilebilmektedir. Yatırımcılar dakika bazlı veya bazen nanosaniye bazlı verilerle uğraşmaktadır. Bu nedenle, yararlı bilgilerin nasıl analiz edileceğini belirlemek ve teknik bir yaklaşımın uygun olup olmadığına karar vermek özellikle önemlidir. Kapanış fiyatını birkaç dakika önceden tahmin etmek ve öngörmek risk yönetimi stratejileri daha etkin uygulanması açısından önemli görülmektedir. (Lanbouri ve Achchab, 2020, s. 603). Bu önem çerçevesinde çalışmada makine öğrenimi yöntemleri ile Apple firmasına ait hissenin gelecek fiyatlarının tahmin edilmesinde en iyi performans gösteren modelin tespiti hedeflenmektedir. Apple, uzun süredir halka açık bir şirket olup, hisse senedi verileri, finansal raporlar ve diğer piyasa bilgileri konusunda zengin bir veri kaynağına sahiptir. Bu da Apple'ı, makine öğrenimi tabanlı tahminler için ideal bir aday yapmaktadır. Bu doğrultuda çalışmanın amacı Apple hisselerinin fiyat tahminlerini geliştirmek için yapay zekâ tabanlı yöntemlerin etkinliğini araştırmaktır. Bu amaçla söz konusu hissenin gelecek fiyat tahminleri literatürde dakikalık analiz yapan çalışmalar (Khare vd, 2017; Henrique vd, 2018; Lamiri, 2018; Lanbouri ve Achchab, 2020) referans alınarak 5 günlük 1 dakikalık verileriyle oluşturulan GRU, LSTM ve XGBoost modellerinin performanslarını karşılaştırarak, hangi modelin daha iyi tahmin sonuçları sağladığını belirlemeyi hedeflemektedir. Tüm bu amaç çerçevesinde veriler Yahoo Finans aracılığıyla elde edilmiştir. Toplam 1931 gözlemle gerçekleşen analizler Python Jupyter Notebook 7.0.8 sürümüyle gerçekleştirilmiştir. Grafik 1'de Apple hisselerinin son 5 günlük 1 dakikalık fiyat hareketleri gösterilmiştir.

Grafik 1. Apple hissesi son 5 günlük 1 dakikalık fiyat hareketleri**Kaynak: Yahoo Finans**

Apple hissesinin son 5 gün içindeki 1 dakikalık fiyat hareketleri, piyasadaki kısa vadeli volatilitiyi ve anlık yatırımcı duyarlılığını yansıtmaktadır. Özellikle belirli zaman dilimlerinde görülen ani fiyat dalgalanmaları, piyasa haberleri ve yatırımcı tepkilerinin etkisini gösterirken, genel olarak fiyat hareketlerinin belirli bir seviyede konsolide olduğu gözlemlenmektedir. Söz konusu grafikte gösterilen verilerle yapılan analizlerin performans metrikleri olan kök ortalama kare hatası (RMSE), ortalama kare hata (MSE), ortalama mutlak hata (MAE) ve maksimum mutlak yüzde hata (MAPE) istatistiklerine ait formüller ve açıklamalar Tablo 2’de gösterilmektedir (Sathiyapriya vd, 2023, s. 653; Shaloo vd, 2024, s. 963):

Tablo 2. Geliştirilen modellerin performans ölçüm metrikleri

Performans Kriterleri	Tanım	Formül
Kök ortalama kare hata (RMSE)	Hata büyüklüğünü gösteren bir metriktir ve daha düşük bir RMSE, modelin tahminlerinin gerçek verilere daha yakın olduğunu göstermektedir.	$\sqrt{\frac{\sum_i^N (Predicted_i - Actual_i)^2}{N}}$
Ortalama kare hata (MSE)	Özellikle büyük hataları cezalandırır; dolayısıyla daha düşük MSE, daha iyi bir model olarak kabul edilmektedir.	$\frac{1}{N} \sum_{i=1}^N (Predicted_i - Actual_i)^2$
Ortalama mutlak hata (MAE)	Tahminlerin ne kadar sapma gösterdiğini ölçmekte; daha düşük MAE, daha doğru bir model anlamına gelmektedir.	$\frac{1}{N} \sum_{i=1}^N ET_{0sim} - ET_{0PM} $
Maksimum mutlak yüzde hata (MAPE)	En büyük yüzde hatayı gösterir ve düşük bir MAPE, modelin en büyük hatalarının bile küçük olduğunu ifade etmektedir.	$\frac{1}{N} \sum_{i=1}^N \left \frac{Predicted_i - Actual_i}{Actual_i} \right $

Tablo 2’de yer alan metriklerle ait değerlendirmeler analiz ve bulgular bölümünde sunulmaktadır.

2.1. Long Short-Term Memory (LSTM) Modeli

Hochreiter ve Schmidhuber (1997) gradyan tabanlı bir öğrenme algoritması ile yeni bir tekrarlayan ağ mimarisi, uzun kısa süreli bellek (LSTM) tasarlamışlardır. LSTM modelinin zaman serileri tahminlerinde oldukça etkili olduğu söylenebilmektedir. Bir LSTM modeli uzun süreli ve kısa süreli verileri temsil etmesini sağlayan beş temel bileşenden geçmektedir. Hem kısa süreli hem de uzun süreli belleklerden oluşan hücrenin dahili belleğine hücre durumu denmektedir. Gizli durum ise bu, mevcut girdiden, geçmişteki gizliden ve mevcut hücre girdisinden çıkış durumunun hesaplanmasıyla ilgili bilgidir ve gelecekteki borsa değerlerini tahmin etmek için kullanılabilir (Bhavani vd, 2022, s. 535). RNN’nin (Tekrarlayan Sinir Ağı) değiştirilmiş bir versiyonu olan LSTM modeli zaman serisi modellerini analiz edebilmesi nedeniyle hisse senedi fiyat tahmini uygun yöntemlerden biri olarak bilinmekte ve aşağıdaki formülle ifade edilmektedir (Bathla, 2020):

$$c_t = F_t * c_{t-1} + l_t * \bar{c}_t \quad (1)$$

LSTM modelleri, diğer derin öğrenme modelleri gibi büyük miktarda veri ile eğitilmektedir. Eğitim sürecinde geriye yayılım (backpropagation) algoritması kullanılır ve LSTM'in iç kapılarının uygun şekilde ayarlanması için kayıp fonksiyonları (loss functions) minimize edilmektedir. Bunun yanı sıra LSTM katmanları modelin temel yapı taşlarıdır ve girdi dizisinin işlenmesinden ve girdi özellikleri arasındaki ilişkilerin öğrenilmesinden sorumludur (Han ve Fu, 2023, s. 52).

2.2. Gated Recurrent Unit (GRU) Modeli

GRU, Cho ve arkadaşları tarafından tanıtılan RNN'nin varyantlarından biri olarak bilinmektedir. LSTM ile karşılaştırıldığında, GRU basitleştirilmiştir ve yalnızca güncelleme kapısı ve sıfırlama kapısı ile öne sürülmüştür. GRU modelinde, güncelleme (veya giriş) kapısı, bir sonraki hücreye ne kadar girişin ve önceki çıktının geçirileceğine karar verilir ve sıfırlama kapısı, geçmiş bilginin ne kadarının unutulacağını belirlemek için kullanılmaktadır. Mevcut bellek içeriği, yalnızca ilgili bilginin bir sonraki yinelemeye geçirilmesi gerektiğini garanti etmek ve bu da ağırlık (W) tarafından belirlenmektedir (Gao vd, 2021, s. 3; Bhavani vd, 2022, s. 535).

LSTM sinir ağının eksikliğini giderirken farklı zaman ölçeklerindeki bağımlılıkları yakalamak için moedllenirken; GRU modeli LSTM'den ilham alan, hesaplanması ve uygulanması çok daha basit olan kapılı yinelemeli birim olarak bilinmektedir. Bu modelde hem giriş hem de çıkış kapıları birleştirilerek güncelleme kapısı adı verilen tek bir kapı oluşturulmaktadır. Güncelleme kapısı, önceki aktivasyon ile aday aktivasyon arasında geçiş yapıp ve birimin içeriğini nasıl güncelleyeceğine karar vermektedir. GRU modeli, gizli birimler yerine bellek modülleri kullanmakta ve bu da eğimin çok sayıda yinelemeden sonra kaybolmamasını sağlamaktadır. GRU modelinin çıkış katmanı, modelin dahili durumu olarak işlev gören sıfırlama birimine doğrudan bağlıdır. Sıfırlama kapısı, önemsiz bilgileri göz ardı ederek önceki gizli durumu yoksayıp kullanmamaya karar vermekle daha kompakt bir gösterime izin vermektedir (Muhammad vd, 2020, s. 2):

$$r_t = \sigma_g(W_r x_t + U_r h_{t-1} + b_r) \quad (2)$$

$$Z_t = \sigma_g(W_z x_t + U_z h_{t-1} + b_z) \quad (3)$$

$$h_t = (1 - z_t) o h_{t-1} + z_t o \sigma_h(W_h x_t + U_h (r_t o h_{t-1}) + b_h) \quad (4)$$

Burada, x_t ve h_t giriş ve çıkış vektörünü, z_t ve r_t sırasıyla güncelleme ve sıfırlama vektörünü, σ_g ve σ_h sigmoid fonksiyonları ve hiperbolik tanjantı temsil ederken W , U ve b parametre matrislerini ve vektörlerini temsil etmektedir.

2.3. XGBoost Modeli

XGBoost modeli, gradyan artırmada güçlü bir rol oynayabilen bir gradyan artırma ağacına dayalı bir algoritmadır. Sınıflandırma ve regresyon ağacı teorisine dayalı XGBoost, regresyon ve sınıflandırma sorunları için çok etkili bir yöntem olabilmektedir (Qiu vd, s. 4147). XGBoost modelinin temel avantajları, aşırı uyumu önlemek için hedef fonksiyonda düzenli bir terim bulunmasıdır. Paralel optimizasyonu, daha verimli olan özellik granüleritesindedir. Sütun örneklemesini desteklemek, yalnızca aşırı uyumu azaltmakla kalmaz, aynı zamanda hesaplama miktarını da azaltmaktadır. Eğitim verilerinin seyrek olduğu düşünüldüğünde, bazı değerler için dalın varsayılan yönü belirtilebilmektedir (Yang vd, 2021, s. 2):

$$\sum_{i=1}^n = L(y_i, p_i) + \frac{1}{2} \alpha 0_v^2 \quad (5)$$

Zhang (2022) XGBoost'un temel algoritmik fikrini şu şekilde açıklamaktadır: Öncelikle ağaçlar eklenir dolayısıyla son tahminin kalıntılarına uyması için yeni bir $f(x)$ fonksiyonu öğrenmeye devam edilir. Ardından eğitim aşamasına geçilir ve özelliklerine göre k ağaç elde etmek için tamamlanır, her ağaç karşılık gelen bir yaprak düğümüne düşer, her yaprak düğümü bir puana karşılık gelir. Son olarak, her ağaca karşılık gelen puanlar örneğin tahmin edilen değerine eklenerek nihai sonuca ulaşılır.

3. Analiz ve Bulgular

Çalışmada Apple firmasına ait hisse senedinin 5 günlük 1 dakikalık verileriyle gelecek fiyat tahmininde optimal modelin tespit edilmesi amaçlanmaktadır. Bu amaçla GRU derin öğrenme, LSTM derin öğrenme ve XGBoost geleneksel makine öğrenimi modellerinin karşılaştırması yapılmıştır. Apple hissesine ait veriler Yahoo Finans aracılığıyla elde edilmiş olup toplam 1931 veri elde edilmiştir. Veriler zaman serisine göre sıralanarak algoritma performansı ve ölçeklendirme sorunlarının önüne geçebilmek için normalize edilmiştir. Ardından veri seti %70 eğitim, %30 test gruplarına ayrılmıştır. Veri seti eğitildikten sonra model oluşturulmuş, en iyi performans gösteren parametreler belirlenmiştir. Performans ölçütleri olarak modelin


tahmin ettiği değerlerle gerçek değerler arasındaki farkı ifade eden MSE, RMSE, MAE, MAPE hata ölçümleri ve doğruluk değerlendirme kriterleri kullanılmıştır. Tablo 3'te LSTM modeline ait parametreler gösterilmektedir.

Tablo 3. LSTM Modeli parametreleri

Performans parametreleri	Window Size: 5, Units: 50, epochs:50	Window Size: 5, Units: 75, epochs: 50	Window Size: 5, Units: 100 epochs:50	Window Size: 5, Units: 50, epochs:100	Window Size: 5, Units: 75, epochs: 100	Window Size: 5, Units: 100 epochs:100
MSE	0,0151	0,0168	0,0145	0,0303	0,0137	0,0234
RMSE	0,1228	0,1294	0,1206	0,1741	0,1171	0,1529
MAE	0,0790	0,0905	0,0735	0,1385	0,0688	0,1144
MAPE	%0,03	%0,04	%0,03	%0,06	%0,03	%0,05

En iyi performansı gösteren konfigürasyon Window Size: 5, Units: 75, Epochs: 100'dür. Bu konfigürasyon, tüm metriklerde (MSE, RMSE, MAE ve MAPE) en düşük değerleri sağlamıştır. Özellikle MSE, RMSE ve MAE değerleri en düşük seviyelerde kalırken, MAPE değeri de %0,03 ile en düşük yüzde hatayı göstermektedir. Bu da modelin daha yüksek epoch sayısıyla (100 epoch) ve ortalama 75 unit ile daha iyi bir doğruluk ve genelleme sağladığını ortaya koymaktadır. Grafik 2'de Window Size: 5, Units: 75, epochs: 100 konfigürasyona ait LSTM model grafiği sunulmuştur.

Grafik 2. Optimal LSTM model grafiği




Tablo 4'te GRU modeline ait model parametreleri gösterilmektedir.

Tablo 4. GRU Modeli parametreleri

Performans parametreleri	Window Size: 5, Units: 50, epochs:50	Window Size: 5, Units: 75, epochs: 50	Window Size: 5, Units: 100 epochs:50	Window Size: 5, Units: 50, epochs:100	Window Size: 5, Units: 75, epochs: 100	Window Size: 5, Units: 100 epochs:100
MSE	0,0210	0,0208	0,0143	0,0140	0,1444	0,0149
RMSE	0,1448	0,1442	0,1195	0,1185	0,1201	0,1221
MAE	0,1071	0,1057	0,0749	0,0736	0,0752	0,0747
MAPE	%0,05	%0,05	%0,03	%0,03	%0,03	%0,03

Tablo 4'e göre, Window Size: 5, Units: 50, Epochs: 100 konfigürasyonu, GRU modelinde en düşük MSE, RMSE, MAE ve MAPE değerlerini sağlamakta ve dolayısıyla en iyi performansı göstermektedir. Bu konfigürasyon, modelin tahmin hatalarını minimize ederek daha doğru sonuçlar elde ettiğini göstermektedir. Ayrıca, epoch sayısının artışı, modelin doğruluğunu olumlu yönde etkilemiştir. Grafik 3'te Window Size: 5, Units: 50, epochs: 100 konfigürasyona ait GRU model grafiği sunulmuştur.

Grafik 3. Optimal GRU model grafiği




Grafik 3'te sunulan GRU model grafiğinin ardından Tablo 5'te XGBoost modeline ait model parametreleri gösterilmektedir.

Tablo 5. XGBoost Modeli parametreleri

Performans parametreleri	Window Size: 5, n_est: 100, learing_rate:0,01	Window Size: 5, n_est: 300, learing_rate:0,03	Window Size: 5, n_est: 500, learing_rate:0,05	Window Size: 5, n_est: 700, learing_rate:0,1	Window Size: 5, n_est: 1000, learing_rate:0,3
MSE	0,3346	0,1237	0,1312	0,1407	0,1103
RMSE	0,5784	0,3517	0,3622	0,3750	0,3322
MAE	0,5352	0,1491	0,1550	0,1641	0,1521
MAPE	%0,23	%0,06	%0,07	%0,07	%0,07

Tablo 5'e göre, Window Size: 5, n_estimators: 1000, learning rate: 0,3 konfigürasyonu, XGBoost modelinde en iyi performansı sergileyerek MSE, RMSE ve MAPE metriklerinde en düşük değerleri sağlamaktadır. n_estimators: 300 ve learning rate: 0,03 ise MAE değerinde en iyi sonucu vermektedir. Genel olarak, daha yüksek n_estimators ve learning rate değerleri, modelin doğruluğunu artırmakta etkili olmuştur. Grafik 4'te Window Size: 5, n_est: 1000, learing_rate:0,3 konfigürasyona ait XGBoost model grafiği sunulmuştur.

Grafik 4. Optimal XGBoost model grafiği



Grafik 2-3-4'te GRU, LSTM ve XGBoost modellerinin Apple hissesinin gelecek fiyat tahminlerine ait karşılaştırmalar verilmektedir. Grafiklerde mavi çizgi güncel kapanış fiyatlarını, kırmızı çizgi ise elde edilen tahmin fiyatlarını ifade etmektedir. Her model için de kapanış fiyatı ile tahmin fiyatı eğrilerinin birbirine çok yakın hareketler sergilediği görülmektedir. Bu nedenle,

ortaya çıkan bulguların güvenilirliğinin ve ilgili modellerin geçerliliğinin desteklendiği savına ulaşılabilir.

Tablo 6. Optimal model karşılaştırması

Performans ölçütleri	LSTM	GRU	XGBOOST
MSE	0,0137	0,0140	0,1103
RMSE	0,1171	0,1185	0,3322
MAE	0,0688	0,0736	0,1521
MAPE	%0,03	%0,03	%0,07

Tablo 6 incelendiğinde, MSE değerleri açısından bakıldığında LSTM ve GRU modellerinin, 0,0137 ve 0,0140 ile oldukça düşük hata değerlerine sahip olduğu görülmektedir. XGBoost modeli ise 0,1103 ile belirgin bir şekilde daha yüksek hata sergilemekte, bu da tahminlerinin diğer modellere nazaran gerçek değerlerden daha uzak olduğunu ifade etmektedir. RMSE değerleri göz önüne alındığında LSTM (0,1171) ve GRU (0,1185) benzer şekilde düşük RMSE değerlerine sahipken, XGBoost (0,3322) daha yüksek bir hata sergilemektedir. MAE değerlerinde LSTM (0,0688) en düşük MAE'ye sahiptir. Bu da LSTM modelinin tahminlerinin gerçek değerlere ortalama olarak en yakın olduğunu göstermektedir. GRU (0,0736) ve XGBoost (0,1521) modelleri ise daha yüksek hatalar vermektedir. Son olarak MAPE değerlerinde ise LSTM ve GRU modelleri %0,03 ile oldukça düşük MAPE değerleri gösterirken, XGBoost %0,07 ile daha yüksek bir hata oranına sahiptir. Nihayetinde LSTM modeli MSE, RMSE, MAE ve MAPE değerlerinde diğer modellerle karşılaştırıldığında en düşük hataları elde ettiği gözlemlenmiştir. Dolayısıyla LSTM modeli hem GRU hem de XGBoost modellerine göre belirgin bir üstünlük göstermektedir. Genel olarak, LSTM modelinin en iyi performansı sergilediği, GRU modelinin de iyi bir alternatif olduğu sonucuna varabilmektedir.

Sonuç

Apple, teknoloji dünyasında en bilinen ve en büyük şirketlerden biri olduğu için üzerinde yapılan analizlerin pek çok açıdan ilgi uyandırması mümkündür. Apple, son yıllarda yalnızca donanım satışlarıyla değil, yazılım ve servis gelirleriyle de büyümesini sürdürmektedir. Bu da yatırımcıların gelecekteki performansı tahmin etme noktasında ilgisini çekmektedir. Apple, finansal açıdan güçlü bir şirket, piyasa değeri yüksek ve inovasyon konusunda liderdir. Bu nedenle, makine öğrenimi tabanlı hisse tahmin

modeli oluşturmak için Apple, sağlam bir veri kaynağı, güçlü finansal performans, yatırımcı ilgisi ve gelecekteki büyüme potansiyeli sunmaktadır. Bu motivasyonla çalışmada Apple firmasına ait hisse senedinin potansiyel gelecek fiyatlarının tahmininde GRU, LSTM ve XGBoost modellerinin performanslarını karşılaştırmak ve en iyi tahmini yapan modeli tespit etmek amaçlanmaktadır. Bu amaçla yapılan analizler Python Jupyter Notebook aracılığıyla gerçekleştirilmiş ve her model için optimal parametreler tespit edilmiştir. Söz konusu parametreler baz alınarak yapılan model karşılaştırmaları neticesinde LSTM modelinin diğer modellere nazaran daha optimal sonuçlar verdiği tespit edilmiştir. Bu doğrultuda çalışma Zhu ve He (2022) ve Sathiyapriya vd (2023) çalışmalarıyla benzerlik göstermekle birlikte; Bhavani vd (2022) çalışmasıyla çelişmektedir. Gelecek çalışmalarda geleneksel modellerle karşılaştırmaların yapılması ve endeks bazında ya da seçili hisselerde tahminlemeler farklı algoritmalarla analiz edilebilir. Bu çalışmanın literatüre katkısının yanı sıra gelecekte yapılacak çalışmalara literatür karşılaştırması açısından fırsat sunabileceği düşünülmektedir.

Kaynakça

- Anadolu Ajans. (2027, 07 23). En değerli 10 teknoloji şirketinin toplam piyasa değeri Çin'in GSYH'sinden daha fazla. 11 07, 2024 tarihinde Anadolu Ajans: <https://www.aa.com.tr/tr/ekonomi/en-degerli-10-teknoloji-sirketinin-toplam-piyasa-degeri-cinin-gsyhsinden-daha-fazla/3282852> adresinden alındı
- Bathla, G. (2020). Stock price prediction using LSTM and SVR. 2020 Sixth International Conference on Parallel, Distributed and Computing (PDGC) (s. 211-214). IEEE.
- Bhavani, A., Ramana, V., & Chakravarthy, A. (2022). Comparative analysis between lstm and gru in stock price prediction. 2022 International Conference on Edge Computing and Applications (ICECAA) (s. 532-537). IEEE.
- Gao, Y., Wang, R., & Zhou, E. (2021). Stock prediction based on optimized LSTM and GRU models. *Scientific Programming* (1).
- Han, C., & Fu, X. (2023). Challenge and opportunity: deep learning-based stock price prediction by using Bi-directional LSTM model. *Frontiers in Business, Economics and Management*, 8(2), 51-54. <https://doi.org/10.54097/fbem.v8i2.6616>
- Henrique, B., Sobreiro, V., & Kimura, H. (4, 3). Stock price prediction using support vector regression on daily and up to the minute prices. *The Journal of finance and data science*, 183-201. <https://doi.org/10.1016/j.jfds.2018.04.003>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.173>
- Jiang, Z. (2022). An Attention GRU-XGBoost Model for Stock Market Prediction Strategies. *Proceedings of the 4th International Conference on Advanced Information Science and System*, 1-5. <https://doi.org/10.1145/3573834.3573837>
- Karim, R., Alam, M., & Hossain, M. (2021). Stock market analysis using linear regression and decision tree regression. In 2021 1st International Conference on Emerging Smart Technologies and Applications (eSmarTA) (s. 1-6). IEEE. <https://doi.org/10.1109/eSmarTA52612.2021.9515762>
- Khare, K., Darekar, O., Gupta, P., & Attar, V. (2017). Short term stock price prediction using deep learning. 2017 2nd IEEE international conference on recent trends in electronics, information & communication technology (RTEICT) (s. 482-486). IEEE.
- Lahmiri, S. (2018). Minute-ahead stock price forecasting based on singular spectrum analysis and support vector regression. *Applied Mathe-*

- matics and Computation, 320, 444-451. <https://doi.org/10.1016/j.amc.2017.09.049>
- Lanbouri, Z., & Achchab, S. (2020). Stock market prediction on high frequency data using long-short term memory. *Procedia Computer Science*, 175, 603-608.
- Liu, Y. (2024). CNN-GRU-XGBoost stock price prediction model under hyperparameter-based optimisation. *Financial Engineering and Risk Management*, 7(5), 151-158. <https://doi.org/10.23977/ferm.2024.070519>
- Liu, Y., Wang, Z., & Zheng, B. (2019). Application of regularized GRU-LSTM model in stock price prediction. 2019 IEEE 5th International Conference on Computer and Communications (ICCC) (s. 886-1890). IEEE.
- Liwei, T., Li, F., Yu, S., & Yuankai, G. (2021). Forecast of lstm-xgboost in stock price based on bayesian optimization. *Intelligent Automation & Soft Computing*, 29(3), 855-868. <https://doi.org/10.32604/iasc.2021.016805>
- Muhammad, A., Yahaya, A., Kamal, S., Adam, J., Muhammad, M., & Elsafi, A. (2020). A hybrid deep stacked LSTM and GRU for water price prediction. 2020 2nd International Conference on Computer and Information Sciences (ICCIS) (s. 1-6). IEEE.
- Patra, G., & Mohanty, M. (2022). An LSTM-GRU based hybrid framework for secured stock price prediction. 25(6), 1491-1499. <https://doi.org/10.1080/09720510.2022.2092263>
- Qiu, Y., Zhou, J., Khandelwal, M., Yang, H., Yang, P., & Li, C. (2022). Performance evaluation of hybrid WOA-XGBoost, GWO-XGBoost and BO-XGBoost models to predict blast-induced ground vibration. *Engineering with Computers*, 28(5), 4145-4162. <https://doi.org/10.1007/s00366-021-01393-9>
- Ramani, K., Jahnvi, M., Reddy, P., VenkataChakravarthi, P., Meghanath, P., & Imran, S. (2023). Prediction of bitcoin price through LSTM, ARIMA, XGBoost, prophet and sentiment analysis on dynamic streaming data. 2023 9th International Conference on Advanced Computing and Communication Systems (ICACCS) (s. 1514-1518). IEEE.
- Saloo, Kumar, B., Bisht, H., Rajput, J., Mishra, A., Kumara, K., & Brahmanand, P. (2024). Reference evapotranspiration prediction using machine learning models: An empirical study from minimal climate data. *Agronomy Journal*, 116(3), 956-972. <https://doi.org/10.1002/agj2.21504>
- Sathiyapriya, K., Vankadara, S., Babu, K., & Muralidharan, M. (2023). Performance comparison of LSTM and XGBOOST for ether price prediction from spam filtered tweets. 2023 International Conference on Intelligent Systems for Communication, IoT and Security (ICISCOIS) (s. 650-655). IEEE.

- Stock Analysis. (2024, 11 06). stockanalysis.com. 11 07, 2024 tarihinde Apple Piyasa Değeri: <https://stockanalysis.com/stocks/aapl/market-cap/> adresinden alındı
- Ticaret Bakanlığı. (2024, 06 13). Ticaret Bakanlığı. 11 07, 2024 tarihinde Apple, 1 Trilyon dolarlık İlk Küresel Marka Oldu; Nvidia'nın Değeri Üç Katına Çıktı: <https://ticaret.gov.tr/blog/sektor-haberleri/apple-1-trilyon-dolarlik-ilk-kuresel-marka-oldu-nvidianin-degeri-uc-katina-cikti> adresinden alındı
- Wang, J., Cheng, Q., & Dong, Y. (2023). An XGBoost-based multivariate deep learning framework for stock index futures price forecasting. *Kybernetes*, 52(10), 4158-4177. <https://doi.org/10.1108/K-12-2021-1289>
- Yang, Y., Wu, Y., Wang, P., & jiali, X. (2021). Stock price prediction based on xgboost and lightgbm. In *E3s web of conferences*. 275, s. 01040. EDP Sciences. <https://doi.org/10.1051/e3sconf/202127501040>
- Yu, S., Tian, L., Liu, Y., & Guo, Y. (2021). LSTM-XGBoost application of the model to the prediction of stock price. *Artificial Intelligence and Security: 7th International Conference, ICAIS 2021* (s. 86-98). Dublin, Ireland: Springer International Publishing.
- Zhang, Y. (2022). Stock Price Prediction Method Based on XGboost Algorithm. In *2022 International Conference on Bigdata Blockchain and Economy Management (ICBBEM 2022)* (s. 595-603). Atlantis Press. https://doi.org/10.2991/978-94-6463-030-5_60
- Zhu, Z., & He, K. (2022). Prediction of amazon's stock price based on ARIMA, XGBoost, and LSTM models. *Proceedings of Business and Economic Studies*, 5(5), 127-136. <https://doi.org/10.26689/pbes.v5i5.4432>

