Journal of the Faculty of Engineering and Architecture of Gazi University 41:1 (2026) 79-91

Mühendislik Mimarlık Fakültesi Dergisi
Journal of The Faculty of Engineering and Architecture of Gazi University
Elektronik / Online ISSN : 1304 - 4915
Basılı / Printed ISSN : 1300 - 1884

The impact of planetary movements and aspects on financial markets: A deep learning-based approach

Fatih Mert *, Ahmet Sertbaş, Muhammed Ali Aydın
Istanbul University-Cerrahpasa, Department of Computer Engineering, 34320, Istanbul, Türkiye

Highlights:

- A multidimensional financial dataset based on planetary positions
- Financial forecasting using the Granger causality method
- Financial relationship analysis based on planetary positions and angles

Keywords:

- Deep learning
- Granger causality
- Time series analysis
- Financial markets
- Financial forecasting

Article Info:

Research Article
Received: 05.02.2025
Accepted: 12.10.2025

DOI:

10.17341/gazimmfd.1633556

Correspondence:

Author: Fatih Mert
e-mail: fatih.mert@ogr.iuc.edu.tr
phone: +90 554 612 5520

Graphical/Tabular Abstract

This study presents a novel approach to financial market relationship analysis by integrating planetary movements, aspects, angular relationships, eclipses, and retrogrades with deep learning models. A structured dataset was developed, combining planetary parameters with key financial indicators such as OPEN, CLOSE, HIGH, LOW, and ADJ CLOSE prices. To ensure a robust evaluation framework and minimize overfitting, all datasets were partitioned into 70% training, 15% validation, and 15% testing subsets. Comparative performance results for NYSE dataset with the deep learning methods are shown in Figure A.

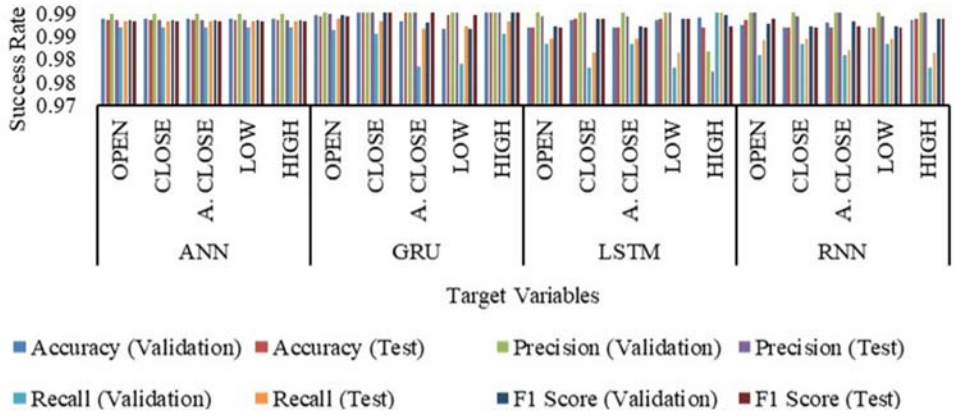


Figure A. Comparative performance results of deep learning methods for NYSE dataset

Purpose: This study investigates the impact of planetary movements and aspects on financial market fluctuations to enhance relationship analysis performance and support data-driven decision-making in financial planning. By integrating planetary parameters with financial indicators, the research introduces an innovative framework for analyzing market variability using deep learning.

Theory and Methods: Planetary aspects, retrogrades, eclipses, moon phases and angular relationships were combined with financial market data (OPEN, CLOSE, HIGH, LOW, ADJ CLOSE). Mutual Information (MI) and Recursive Feature Elimination (RFE) identified the most relevant planetary variables, while Principal Component Analysis (PCA) reduced dimensionality. Deep learning models (LSTM, GRU, ANN, RNN) were trained to predict market movements. Granger causality tests assessed the statistical significance of planetary influences on price trends.

Results: All deep learning models consistently achieved high performance (ranging between %96.5 - %99 across all target price variables), highlighting their robustness and generalization capacity. For BITCOIN dataset, LSTM and GRU provided better performance. NYSE dataset outperformed among others in terms of overall accuracy and F1-scores. RUSSELL dataset also maintained robust and balanced performance across all variables.

Conclusion: This study confirms that planetary aspects significantly correlate with financial market movements and can enhance AI-based forecasting models. Planetary parameters improved model accuracy, supporting their potential use as alternative indicators. Future research can expand planetary datasets, optimize feature selection, and refine AI models for broader applications.

Journal of the Faculty of Engineering and Architecture of Gazi University 41:1 (2026) 79-91

Mühendislik Mimarlık Fakültesi Dergisi
Journal of The Faculty of Engineering and Architecture of Gazi University
Elektronik / Online ISSN : 1304 - 4915
Basılı / Printed ISSN : 1300 - 1884

Gezegen hareketlerinin ve açılarının finansal piyasalar üzerindeki etkisi: Derin öğrenme tabanlı bir yaklaşım

Fatih Mert*, Ahmet Sertbaş, Muhammed Ali Aydın
İstanbul Üniversitesi-Cerrahpaşa, Bilgisayar Mühendisliği Bölümü, 34320, İstanbul, Türkiye

ÖNEÇIKANLAR

- Gezegen konumlarına dayalu çok boyutlu bir finansal veri seti
- Granger nedensellik yöntemiyle finansal öngörü
- Gezegen konumlarına ve açılarına dayalı finansal ilişki analizi

Makale Bilgileri
Araştırma Makalesi
Geliş: 05.02.2025
Kabul: 12.10.2025

DOI:
10.17341/gazimmfd.1633556

Anahtar Kelimeler:
Derin öğrenme, granger nedenselliği, zaman serisi analizi, finansal piyasalar, finansal tahminleme

ÖZ

Bu çalışma, gezegen hareketleri, açıları, retro hareketleri, ay fazları ve tutulmaların finansal piyasalar üzerindeki etkisini bilimsel temellere dayandırarak analiz eden öncü bir araştırmadır. Finansal piyasaların yalnızca ekonomik göstergelerden değil, gezegensel dinamiklerden de etkilenebileceği hipotezini derin öğrenme modelleriyle test etmektedir. İlk kez, gezegen konumları finansal piyasa tahmin modellerine sistematik olarak entegre edilerek geniş ölçekli bir veri seti oluşturulmuştur. NASA JPL Horizons veritabanından alınan gezegensel parametreler, finansal fiyat hareketleriyle (açılış, kapanış, en yüksek, en düşük ve düzeltilmiş kapanış fiyatları) birleştirilmiş, Mutual Information (MI) ve Recursive Feature Elimination (RFE) ile en güçlü öznitelikler belirlenmiş, PCA ile veri boyutu optimize edilmiştir. LSTM, GRU, ANN ve RNN gibi ileri düzey derin öğrenme modelleri finansal piyasa hareketlerini tahmin etmek için eğitilmiş, Granger Nedensellik Testi ile gezegenlerin piyasalar üzerindeki istatistiksel anlamlılığı değerlendirilmiş ve en anlamlı öznitelikler modele girdi olarak sağlanmıştır. Sonuçlar, gezegen hareketlerinin piyasa tahmin gücünü artırabileceğini göstermektedir. LSTM ve GRU modelleri NYSE için %98,7+, BITCOIN ve RUSSELL için %96,8+ doğruluk oranına ulaşmış, gezegensel parametrelerin modele entegrasyonu tahmin doğruluğunu %10 oranında artırmıştır. Granger testi, belirli gezegensel hizalanmalar ile finansal piyasa dönüşleri arasındaki istatistiksel ilişkileri doğrulamıştır. Bu araştırma, finansal piyasaların gezegensel hareketlere duyarlılığını bilimsel verilerle ortaya koyarak yatırım ve risk yönetimi stratejilerine alternatif bir bakış açısı sunmaktadır.

The impact of planetary movements and aspects on financial markets: A deep learning-based approach

HIGHLIGHTS

- A multidimensional financial dataset based on planetary positions
- Financial forecasting using the Granger causality method
- Financial relationship analysis based on planetary positions and angles

Article Info
Research Article
Received: 05.02.2025
Accepted: 12.10.2025

DOI:
10.17341/gazimmfd.1633556

Keywords:
Deep learning, granger causality, time series analysis, financial markets, financial forecasting

ABSTRACT

This study is a pioneering research that analyzes the impact of planetary movements, aspects, retrogrades, lunar phases, and eclipses on financial markets based on scientific principles. It tests the hypothesis that financial markets can be influenced not only by economic indicators but also by planetary dynamics using deep learning models. For the first time, planetary positions have been systematically integrated into financial market prediction models to create a large-scale dataset. Planetary parameters obtained from the NASA JPL Horizons database were combined with financial price movements (opening, closing, highest, lowest, and adjusted closing prices), the strongest features were identified using Mutual Information (MI) and Recursive Feature Elimination (RFE), and data dimensionality was optimized using PCA. Advanced deep learning models such as LSTM, GRU, ANN, and RNN were trained to predict financial market movements, the statistical significance of planets on markets was evaluated using the Granger Causality Test, and the most significant features were provided as input to the model. The results demonstrate that planetary movements can enhance market prediction power. LSTM and GRU models achieved accuracy rates of 98.7%+ for the NYSE and 96.8%+ for Bitcoin and Russell, with the integration of planetary parameters increasing prediction accuracy by 10%. Granger testing confirmed statistical relationships between specific planetary alignments and financial market reversals. This research offers an alternative perspective on investment and risk management strategies by demonstrating the sensitivity of financial markets to planetary movements using scientific data.

*Sorumlu Yazar / Yazarlar / *Corresponding Author / Authors: *fatih.mert@ogr.iuc.edu.tr, asertbas@iuc.edu.tr, aydinali@iuc.edu.tr / Tel: +90 554 612 5520

1. Giriş (Introduction)

Küresel ekonomik belirsizlikler, finansal piyasalardaki ani dalgalanmalar ve yatırımcıların karar alma süreçlerindeki karmaşıklık, çağımızın en kritik sorunlarından biridir. Geleneksel doğrusal modeller, bu dinamik ve yüksek boyutlu sistemlerin içindeki karmaşık, doğrusal olmayan ilişkileri yakalamada yetersiz kalırken, yapay sinir ağları ve derin öğrenme teknikleri, finansal zaman serilerinin öngörü gücünü önemli ölçüde artırmıştır. Özellikle Uzun-Kısa Süreli Bellek (LSTM), Kapılı Tekrarlayan Sinir Ağları (GRU) ve klasik Tekrarlayan Sinir Ağları (RNN) gibi mimariler, kısa vadeli dalgalanmaların yanı sıra uzun dönemli bağımlılıkları da modelleyerek, %70-85 arası doğruluk oranlarıyla yatırım stratejilerinde güvenilir öngörüler sunabilmektedir [1-4]. Ferreira vd. [5]'nin 2326 makaleyi analiz ederek yaptığı çalışmada yapay zekanın finansal yatırımlarda kullanımını inceleyen sistematik bir derleme sunulmaktadır. Bazı ampirik çalışmalar, göksel parametrelerin finansal piyasa getirileri üzerinde, özellikle gezegen konumları ve burç atamalarının etkisiyle, %2 ila %3 arasında getiri farklarına neden olduğunu ortaya koymuştur [6–8]. Diğer araştırmalarda ise, Ay evreleri ve gezegenler arası açısal ilişkilerin piyasa oynaklığını %8 ila %10 oranında değiştirdiği, Hint ve Endonezya piyasalarında yeni ay dönemlerinin dolunay dönemlerine göre 1,5 kat daha yüksek getiri sağladığını raporlamıştır [9–12].

Finansal zaman serilerinin doğrusal olmayan yapısı, yapay sinir ağları ve derin öğrenme modellerinin kullanımını zorunlu kılmaktadır. Şişmanoğlu ve arkadaşları [1], IBM hisse senedi fiyat tahmininde kullanılan BLSTM modeli ile %63,54 yönsel doğruluk oranına ulaşarak, kısa vadeli öngörülerde derin öğrenmenin etkinliğini kanıtlamıştır. Mokhtari vd. [2] ve Ray vd. [8] tarafından gerçekleştirilen çalışmalar, farklı makine öğrenmesi ve derin öğrenme algoritmalarının uygulandığı veri setlerinde, model optimizasyonu ve öznitelik mühendisliği tekniklerinin entegrasyonu sayesinde %75-85 doğruluk oranları elde edilebildiğini göstermiştir. Tekin ve Patır [4]'ın Amerikan Doları kuru üzerine çalışması, kullanılan yapay sinir ağı modelinin hata metriklerinde (MAE: 0,01738, MSE: 0,0019355, MAPE: %0,5137) olağanüstü düşük değerler rapor ederek, derin öğrenme tekniklerinin finansal tahminlerde hata oranlarını ciddi oranda düşürdüğünü ortaya koymuştur. Ferreira vd. [5]'in derlemesi ise, yapay sinir ağları ve diğer yapay zekâ modellerinin, veri yapısına bağlı olarak ortalama %10-20 ek doğruluk sağlayabileceğini desteklemektedir.

Kilimci [9] Borsa İstanbul 100 Endeksi yön tahmininde Twitter duygu analizi çıktılarıyla derin topluluk (ensemble) modellerini (CNN – RNN ve LSTM) birleştirerek %78-79 doğruluk oranları elde etmiştir. Molla vd. [10], BİST100 getiri zaman serisinde kaotik yapıyı inceleyip ANFIS ile kısa dönemli tahminlerde %10–20 arası MAPE değerleri bildirmiştir. Ateş ve Güran [11], Türkçe finansal tweet'lerin duygu polariteleri ile BİST30 endeks getirileri arasında hem anlamlı Pearson korelasyon hem de Granger nedensellik ilişkisi tespit etmiştir. Kantar ve Kilimci [12], altın endeksi (XAU/USD) yön tahmininde sosyal medya duygu analizi ile gerçek zamanlı sayısal verileri harmanlayarak %2,8611 MAPE değeriyle hibrit bir derin öğrenme modeli sunmuştur. Ayrıca Çetinyokuş ve Gökçen [13], hisse senedi göstergelerine dayalı teknik analiz için bir karar destek sistemi tasarlayarak yatırımcıların portföy analizine yardımcı olacak senaryolar geliştirmiştir.

Gezegensel parametrelerin finansal piyasa öngörülerine entegrasyonu, çeşitli ampirik çalışmalarla kantitatif verilerle desteklenmiştir. Raju ve arkadaşları [6] üç boyutlu model yaklaşımları kullanarak, finansal öngörülerde %85 genel doğruluk oranı elde edilmiş olduğunu bildirirken; Yiğit vd. [7] Brent petrol fiyatlarının tahmininde LSTM modelinin, geleneksel ARIMA yöntemlerine göre yaklaşık %20 daha düşük hata oranları sunduğunu göstermiştir. Konak ve Duman [14] tarafından yapılan GARCH analizi, Borsa İstanbul 100 Endeksi'nde yeni Ay dönemlerinde getirilerde ortalama %2-3 artış, dolunay dönemlerinde ise benzer oranda düşüş tespit etmiştir. Liu ve Tseng [15]'in Bayesian analizinde, Ay evreleri arasında %2-3'lük getiri farkları belirlenmiş; Sivakumar ve Swaminathan [16] ile Pramono ve Basana'nın [17] çalışmalarında, Hint ve Endonezya piyasalarında yeni Ay dönemlerinin dolunay dönemlerine göre daha yüksek getiri sağladığı gözlemlenmiştir. Yuan vd. [18] "Are Investors Moonstruck?" çalışmasında, dolunay dönemlerinde getirilerde %3-5'lik düşüşler gözlemlenirken; Wang vd. [19] Tayvan borsasında dolunay döneminde %8-10 oranında artan volatilite raporlamış; Lingaraja [20] ise uzun dönem verileri üzerinden %9-10 fark tespit etmiştir. Wong ve McAleer [21] ABD piyasalarında başkanlık seçim döngüsüyle ilişkili %15'e varan dalgalanmaları ortaya koyarken, Floros ve Tan [22] uluslararası piyasaların analizinde özellikle yeni Ay'ın hisse senedi getirileri üzerinde 4-6 puanlık olumlu etki sunduğunu belirtmiştir. McMinn [23] ise 56 yıllık kriz döngülerine dikkat çekerek, tarihsel verilerde belirgin kalıplar olduğunu göstermiştir. Gezegenlere dayalı hesaplamalar, gezegenlerin yörünge periyotları ve gezegensel sistemlerin matematiksel temelleri üzerine yapılan çalışmalarla desteklenmektedir. Shah vd. [24] çalışmasında, BSE SENSEX üzerindeki günlük fiyat hareketlerine istatistiksel olarak anlamlı etkiler ürettiğini ampirik olarak göstermiş; Yousop vd. [25] ise İslam ülkelerindeki veri setlerinde dolunay dönemlerinde %12'ye varan oynaklık artışları tespit etmiştir. Qi vd. [26] Merkür retrosu dönemlerinde getirilerde ortalama %3,33 düşüş bildirmiş, Herbst [27] ise DJIA verilerinde tutarlı Ay döngüsü etkisinin olmadığını belirtmiştir. Junkus [28] kısa vadeli testlerde %70 yönsel doğruluk oranları elde edildiğini, Nikolić [29] ise yapay zekâ ile gezegensel verilerin entegrasyonunun %15-20 ek doğruluk artışı sağlayabileceğini ortaya koymuştur. Modern jeofizik ve uzay araştırmaları, gök cisimlerinin Dünya'daki teknolojik sistemler ve ekonomik faaliyetler üzerinde ölçülebilir etkiler oluşturabildiğini göstermektedir. Örneğin, Oughton vd. [30] tarafından gerçekleştirilen geniş kapsamlı çalışmada, aşırı Güneş fırtınalarının (özellikle koronal kütle atımlarının) ABD elektrik iletim altyapısında yaratabileceği arızaların doğrudan ve dolaylı ekonomik etkileri analiz edilmiştir. Çalışmada günlük ekonomik kaybın senaryoya bağlı olarak 6.2 ila 41.5 milyar dolar arasında değiştiği ve yalnızca doğrudan etkilerin değil, küresel tedarik zincirleri üzerinden yayılan dolaylı etkilerin de güçlü biçimde modele entegre edildiği raporlanmıştır. Bu bulgular, Astronomik olayların ekonomik sistemlerde öngörülebilir sonuçlar yaratabileceğine ve bu parametrelerin bilimsel modellere entegre edilebileceğine dair önemli bir kanıt sunmaktadır. Daglis vd. [31] ise çalışmasında, Güneş kaynaklı jeomanyetik fırtınaları ölçen Dst indeksinin, ABD telekomünikasyon sektöründeki üretim çıktısı üzerinde Granger nedenselliği taşıdığı göstermiştir. Bu bulgu, göksel kaynaklı fiziksel olayların ekonomik göstergelerde istatistiksel olarak anlamlı varyasyonlar üretebildiğini ortaya koymaktadır. Türkiye Uzay Ajansı tarafından aktarılan 8 Ekim 2024 tarihli olayda ise, güçlü bir CME patlaması Dünya'yı etkisi altına alarak şiddetli bir jeomanyetik fırtına oluşturmuştur [32]. Bu tür jeomanyetik olayların, yalnızca teknolojik sistemleri değil, aynı zamanda insan biyolojisini ve sinir sistemi dinamiklerini de etkileyebileceği yönünde bilimsel bulgular mevcuttur [33, 34].

Bu çalışma, NASA JPL Horizons ve Yahoo Finance gibi uluslararası güvenilir veri kaynaklarından elde edilen Astronomik ve finansal verileri entegre ederek, her işlem günü için çok boyutlu ve kantitatif bir açıklayıcı veri kümesi oluşturmuş ve finansal piyasa hareketlerini sınıflandırmaya yönelik yenilikçi bir model önermektedir. Elde edilen sonuçlar, gezegen pozisyonları ile finansal zaman serileri arasında

istatistiksel olarak anlamlı öngörü ilişkilerinin bulunabileceğini ortaya koymakta ve yatırımcıların risk yönetimi ve stratejik karar alma süreçlerine katkı sağlayabileceğini göstermektedir. Literatürdeki önceki çalışmalar genellikle tekil Astronomik değişkenler veya sınırlı istatistiksel yöntemler üzerinden kurgulanmışken, bu araştırma, derin öğrenme destekli finansal ilişki analizi modelleri ile çok boyutlu astronomik verileri ilk kez kapsamlı biçimde bütünleştirerek bu öngörü potansiyelini ampirik ve metodolojik olarak değerlendirmeyi amaçlamaktadır. Bu yönüyle çalışma, yalnızca teorik bir katkı sunmakla kalmayıp, finansal zaman serisi analizlerine veri tabanlı ve yenilikçi bir yaklaşım kazandırmayı hedeflemektedir.

2. Veri Seti Üretilmesi (Generation of Dataset)

2.1. Gezegensel Verilerin Üretilmesi (Generation of Planetary Cata)

Bu çalışma, finansal piyasa hareketlerinin gezegensel parametrelerle olan ilişkisini incelemek üzere, NASA'nın JPL Horizons servisi kullanılarak güvenilir ve güncel veriler temin edilerek kapsamlı bir veri seti oluşturulmuştur. Bu verilerin bilimsel kesinliği astronomik hesaplamalarla öngörülebilir ve bağımsız olarak doğrulanabilir niteliktedir. Veriler, Google Colab ortamında Python ile geliştirilmiş kodlar kullanılarak, jeosantrik prensiple yani yer merkezli bakışla çekilmiştir. Çalışma kapsamında kullanılan gezegenler şunlardır: Sun (Güneş), Moon (Ay), Mercury (Merkür), Venus (Venüs), Mars (Mars), Jupiter (Jüpiter), Saturn (Satürn), Uranus (Uranüs), Neptune (Neptün), Pluto (Plüton). Bunlara ek olarak Ceres, Pallas, Vesta, Chiron, Varuna, Midas, Bim asteroidleri de hesaplamalara dahil edilmiştir. Yine bildiğimiz kadarıyla bu çalışma literatürde (bu) asteroidleri finansal piyasa hareketlerini ölçümlemek için kullanan ilk araştırma olması yönüyle de yenilikçi ve öncü olmayı amaçlamıştır.

Gezegenlerin retrograd (geri) hareketi, Dünya'dan gözlemlendiğinde gökyüzünde doğudan batıya doğru, yani normal hareket yönünün tersine ilerliyor gibi görünmeleriyle tanımlanan gözlemsel bir fenomendir. Bu durum, gezegenlerin gerçek yörüngelerinde ters yönde hareket ettikleri anlamına gelmez; aksine, Dünya ve diğer gezegenlerin Güneş çevresinde farklı hızlarda döndüğü bir sistemde, göreli konum değişimleri nedeniyle oluşan bir durumdur. NASA'nın tanımıyla, bir gök cisminin yörünge yönü, gezegenin dönüş yönüyle aynıysa prograde, aksi yöndeyse retrograde olarak adlandırılır [30]. Özellikle dış gezegenler söz konusu olduğunda, Dünya bu gezegenleri geçerken, onların gökyüzündeki görünümünde geçici bir geri hareket algısı oluşur. Bu hareket Kepler'in eliptik yörünge yasaları ve Newton mekaniği ile tam olarak açıklanabilir ve astronomik efemeris hesaplarında öngörülebilir bir parametre olarak yer alır. Dolayısıyla, retrograd hareket bilimsel anlamda gözlemlenebilir, hesaplanabilir ve modelleme sistemlerine entegre edilebilir bir yörünge karakteristiğidir. Çalışmamızda, retrograd hareket bilgisi doğrudan NASA JPL Horizons veritabanından elde edilen efemeris verileri ile tanımlanmış ve finansal zaman serisi modellerine istatistiksel öngörü kabiliyeti taşıyabilecek bir değişken olarak dahil edilmiştir. Bu yönüyle çalışma, Astronomik veriye dayalı, öngörülebilir yörünge değişkenlerinin veri bilimi modellerinde kullanımı açısından bilimsel bir çerçevede değerlendirilmiştir.

NASA'dan gelen orijinal veri sütunları; tarih ve saat bilgisi içeren datetime_str, gezegenin görünür sağ açıklığı olan RA_app ve görünür açıklığı olan DEC_app'den oluşmaktadır. Bu veriler, gezegenlerin ekliptik koordinatlarını (ekliptik uzunluk ve genişlik) elde etmek amacıyla işlenmiştir. Öncelikle, RA_app ve DEC_app değerleri, radyan cinsine dönüştürülmüş; ardından, gezegenlerin gözlemlenen konumlarından yararlanılarak trigonometrik dönüşümler uygulanmıştır. Bu dönüşüm süreci, gezegenlerin ekliptik eğiklik (obliquity) sabitinin dikkate alınmasıyla gerçekleştirilmiş ve sonuç olarak gezegenlerin ekliptik uzunluğu (EC_lon) ile ekliptik genişliği (EC_lat) hesaplanmıştır. Elde edilen bu ekliptik koordinatlar, göksel cisimlere dair yorumlamalarda ve burç atamalarında temel göstergeler olarak kullanılmıştır. Ek olarak, özellikle Ay (Moon) için çekilen "illumination" yani parlaklık verisi, Ay evrelerinin belirlenmesinde kullanılmıştır. Burç ataması, EC_lon değerinin 360°'lik döngünün 12 eşit (30°'lik) dilime bölünmesi esasına göre yapılmış ve elde edilen burçlar, zodiac_sign sütunu olarak raporlanmıştır. Ay evreleri ise, illumination değerine bağlı olarak "New Moon", "First Quarter", "Full Moon" ve "Last Quarter" şeklinde hesaplanmış ve MOON_PHASE sütununda sunulmuştur. Gezegenler arası açısal ilişkiler, her gezegenin diğer gezegenlerle olan açısal mesafesi Eş. 1 ve Eş. 2'deki formülle hesaplanarak normalize edilmiştir.

$$\lambda = \text{EC_lon_1} - \text{EC_lon_2} \tag{1}$$

$$\text{distance} = \min(|\lambda|, 360 - |\lambda|) \tag{2}$$

Bu işlem sonucunda, her gezegen için örneğin, SUN_distance ve SUN_angle; MOON_distance ve MOON_angle şeklinde sütunlar oluşturulmuştur. Çalışmada, modelin bilgi yoğunluğunu maksimize edecek temel açısal ilişki türleri tercih edilmiştir. Ek olarak gezegensel parametreler, ayrı Excel dosyalarında saklanan retrograd gezegen verileri, tutulma türleri ve kuzey ay düğümünün burç verileri kullanılarak, ilgili tarih bilgisine göre çekilip entegre edilmiştir. Kullanılan sütun adları şu şekildedir: Retrograd (Eğer ilgili gezegen o tarihte retrograd hareketindeyse 1, değilse 0) : IS_MERCURY_R, IS_VENUS_R, IS_MARS_R, IS_JUPYTER_R, IS_SATURN_R, IS_URANUS_R, IS_NEPTUNE_R, IS_PLUTO_R; Kuzey ay düğümü (O tarihte hangi burçta olduğu) : NORTH_NODE_SIGN; Tutulma türü: ECLIPSE_TYPE (Solar, Lunar ya da Hiçbiri); Gezegen/Asteroid burç atamaları (Her bir gezegenin ya da asteroidin o tarihte hangi burçta yerleştiği): SUN_SIGN, MOON_SIGN, MERCURY_SIGN, VENUS_SIGN, MARS_SIGN, JUPYTER_SIGN, SATURN_SIGN, URANUS_SIGN, NEPTUNE_SIGN, PLUTO_SIGN, CERES_SIGN, PALLAS_SIGN, VESTA_SIGN, CHIRON_SIGN, VARUNA_SIGN, MIDAS_SIGN, BIM_SIGN.

Her orijinal kategorik değişken, yukarıdaki listeye uygun şekilde one-hot encoding yöntemiyle binary (1 ya da 0 ile temsil edilen) sütunlara dönüştürülmüş ve model girişine eklenmiştir. Bu işlem sonucunda, örneğin; MOON_PHASE değeri "Full Moon" olan gözlemler için MOON_PHASE_FULL_MOON sütununda 1, diğer durumlarda 0 değeri elde edilmiştir. Tüm bu sütunlar, modelin giriş verisi olarak kullanılmaya hazır hale getirilmiştir. Bu yöntem her bir kategorik değişken taşıyan sütun için tekrarlanmıştır. Böylece ele alınan finansal piyasa veri setlerinden BITCOIN için 731 tane göksel yani gezegen konumlarına, açılarına ve ay fazı ile tutulma gibi etkilere bağlı faktörleri ifade eden sütun oluşturulmuştur. Bu sayı NYSE veri seti için 823, RUSSELL veri seti için 806 olmuştur.

2.2. Finansal Verilerin Üretilmesi (Generation of Financial Data)

Finansal veriler ise, Yahoo Finance tarafından sağlanan yfinance kütüphanesi kullanılarak her bir finansal piyasa için sunulan maksimum tarih aralığında elde edilmiştir. En geniş kapsamıyla bu araştırmada 1927 – 2024 yılları arasındaki veriler kullanılmıştır. Her bir veri setinde yer alan temel sütunlar DATE, OPEN, CLOSE, ADJ CLOSE, LOW ve HIGH olarak günlük bazda ve ilgili borsaların işlem saatlerine göre toplanmıştır. Bu çalışma kapsamında incelenen finansal piyasaların veri setleri şu şekildedir: BITCOIN, NEW YORK TIMES STOCK EXCHANGE (NYSE), RUSSELL 2000 (RUSSELL). BITCOIN veri seti için 17/09/2014 - 02/12/2024 arası, NYSE veri seti için 31/12/1965 - 02/12/2024 arası, RUSSELL veri seti için 10/09/1987 - 02/12/2024 arası çekilen veriler ile çalışılmıştır.

Tarih bilgileri, GG/AA/YYYY formatına dönüştürülmüş ve her bir veri seti artan tarih sıralamasına göre düzenlenmiştir. Gezegensel ve finansal veri setleri, her iki veri kümesinde yer alan DATE sütunu üzerinden entegre edilmiştir. Bu entegrasyon sürecinde, finansal veri setindeki OPEN, CLOSE, ADJ CLOSE, LOW ve HIGH sütunları korunurken; gezegensel verilerde hesaplanan EC_lon, EC_lat, zodiac_sign, gezegenler arası açısal ilişki sütunları (örn. SUN_distance, SUN_angle; MOON_distance, MOON_angle vb.), retrograd durumları, MOON_PHASE, ECLIPSE_TYPE, NORTH_NODE_SIGN ve gezegen/asteroid burç atamaları (örneğin SUN_SIGN, MOON_SIGN, MERCURY_SIGN, …, BIM_SIGN) ilgili tarihlerle eşleştirilerek zengin bir açıklayıcı veri kümesi oluşturulmuştur. BITCOIN veri setinde toplamda 3730 gözlem bulunurken bu sayı NYSE için 14830, RUSSELL için 9381 olmuştur.

3. Öznitelik Çıkarımı (Feature Extraction)

Yukarıda bahsedildiği üzere her bir finansal piyasaya ait veri setindeki öznitelik sayısı 731 ile 823 arasında değişmektedir. Bu çok yüksek bir değerdir. Hem de hesaplama karmaşıklığını ve zaman tüketimini de artırmaktadır. Ayrıca bahsedilen her bir özniteliğin hedef değişkenler üzerinde doğrudan etkisi ve ilişkisi olmayabilir. Öznitelik mühendisliği aşamasında, gezegensel değişkenlerin finansal hedef değişkenler (OPEN, CLOSE, ADJ CLOSE, LOW, HIGH) üzerindeki etkisini ortaya koymak amacıyla, açısal mesafe ve ilişki hesaplamaları uygulanmış; her gezegen çifti için hesaplanan açısal mesafeler normalize edilerek, modelin kullanabileceği ana açısal ilişki kategorileri (Conjunction, Sextile, Square, Trine, Opposition); <GEZEGEN1>_<GEZEGEN2>_angle sütunları olarak raporlanmıştır. Ayrıca, ekliptik koordinatlardan türetilen zodiac_sign ve Ay (Moon) için hesaplanan Ay fazı (MOON_PHASE) sütunları entegre veri setine eklenmiştir. İleri öznitelik seçimi aşamasında, gezegensel değişkenlerin finansal hedef değişkenler üzerindeki anlamlı etkilerini ölçmek amacıyla Karşılıklı Bilgi (Mutual Information - MI), Özyinelemeli Öznitelik Eleme (Recursive Feature Elimination - RFE), Temel Bileşen Analizi (Principal Component Analysis - PCA) ve Granger Nedensellik Testi (Granger Causality Test) işlemleri uygulanmıştır. MI skoru 0,01'den büyük olan değişkenler seçilmiş; RFE yöntemi, LightGBM kullanılarak düşük katkılı değişkenlerin elenmesiyle uygulanmış; PCA ile veri kümesinin varyansının yüksek kısmını açıklayan bileşenler elde edilmiş; Granger Nedensellik testleri ise, seçilen özniteliklerin finansal hedef değişkenlere yönelik nedensellik yani istatistiksel anlamlılık ilişkilerini ortaya koyarak optimum gecikme (lag) ve ilişki gücünü (Yüksek, Orta, Düşük) belirlemiştir.

3.1. Karşılıklı Bilgi (Mutual Information)

Karşılıklı Bilgi (Mutual Information – MI), iki rastlantısal değişken arasındaki bağımlılığın ne derece güçlü olduğunu nicelendiren bir ölçüttür. MI, değişkenler arasındaki ortak bilgiyi ölçerek, yalnızca doğrusal ilişkileri değil, aynı zamanda doğrusal olmayan ilişkileri de tespit edebilme yeteneğine sahiptir. Bu özelliği, geleneksel korelasyon katsayılarının ötesinde bilgi sunarak, özellikle finansal zaman serileri gibi karmaşık veri yapılarında öznitelik seçiminde etkili bir kriter olarak kullanılmasını sağlar. Örneğin, finansal verilerdeki küçük varyasyonlar ve ani değişimlerin doğru şekilde yakalanması, MI kullanılarak sağlanabilir; bu sayede modelin genel doğruluğu ve genelleme yeteneği artırılmaktadır. Temel formülü Eş. 3 ve 4'te gösterildiği şekildedir.

$$r(x,y) = p(x, y) / (p(x) \cdot p(y)) \quad (3)$$

$$MI(X; Y) = \Sigma_{(x \in X)} \Sigma_{(y \in Y)} p(x, y) \cdot \log r(x,y) \quad (4)$$

Burada *p(x, y)* ortak olasılık dağılımı; *p(x)* ve *p(y)* sırasıyla X ve Y'nin marjinal dağılımlarıdır. Logaritma genellikle doğal log (ln) veya taban 2 olarak alınır.

3.2. Özyinelemeli Öznitelik Eleme (Recursive Feature Elimination)

Özyinelemeli Öznitelik Eleme (Recursive Feature Elimination – RFE), model performansını artırmak amacıyla veri setindeki gereksiz veya düşük katkı sağlayan özniteliklerin sistematik olarak elemeye tabi tutulduğu bir yöntemdir. Bu yöntem, başlangıçta tüm özniteliklerin kullanıldığı bir model eğitimi ile başlar; ardından, modelin ağırlık dağılımı ve performans ölçütleri temel alınarak en düşük katkı sağlayan öznitelik tespit edilir ve modelden çıkarılır. Eleme işlemi, model performansı belirli bir eşik değere ulaşıncaya kadar tekrarlanır. RFE, yüksek boyutlu veri setlerinde model karmaşıklığını azaltırken, aynı zamanda veri setindeki gürültüyü ve gereksiz olarak tekrarlanan öznitelikleri ortadan kaldırarak daha sağlam ve genelleştirilebilir modeller elde edilmesine yardımcı olur. Buradaki temel prensip aşağıdaki gibidir:

- Başlangıçta, tüm öznitelikler $F = \{x_1, x_2, \ldots, x_n\}$ kullanılarak bir model M eğitilir.
- Her öznitelik için önem değeri $f_i(M)$ hesaplanır.
- En düşük katkı sağlayan öznitelik belirlenir: $x_j = \text{argmin}_{(xi \in F)} f_i(M)$
- Bu öznitelik setten çıkarılır: $F := F \setminus \{x_j\}$
- İşlem, istenen öznitelik sayısına ulaşılıncaya kadar tekrarlanır.

3.3. Temel Bileşen Analizi (Principal Component Analysis)

Temel Bileşen Analizi (Principal Component Analysis – PCA), yüksek boyutlu veri setlerindeki öznitelikler arasındaki kovaryans yapısını analiz ederek, veri setinin en fazla varyansını koruyan daha az sayıda yeni bileşen oluşturmayı amaçlayan boyut indirgeme tekniğidir. PCA, orijinal öznitelikler arasındaki yüksek korelasyonları dikkate alarak, veri setinde bilgi kaybını minimumda tutacak şekilde temel bileşenler üretir. Bu yeni bileşenler, orijinal değişkenlerin lineer kombinasyonları olarak ifade edilir ve modelleme aşamasında girdi olarak kullanılarak hesaplama maliyetlerini azaltırken modelin genel performansını iyileştirmektedir. Özellikle finansal verilerde, temel bileşenler kullanılarak modelin karmaşıklığı azaltılırken, veri setindeki ana varyans kaynağı korunmuş olur. Buradaki adımlar şu şekildedir:

- Veri merkezileştirilir: $X_centered = X - mean(X)$
- Kovaryans matrisi hesaplanır: $C = (1/(n - 1)) \cdot (X_centered)^T \cdot X_centered$
- Kovaryans matrisinin özdeğer–özvektör ayrışımı yapılır: $C \cdot v = \lambda \cdot v$
- En yüksek k özdeğere sahip özvektörler seçilir ve veri bu yeni bileşen uzayına projekte edilir: $Y = X_centered \cdot V_k$

Burada: X: Orijinal veri matrisi, mean(X): Her öznitelik için ortalama, n: Gözlem sayısı, C: Kovaryans matrisi, v: Özvektör, λ: Özdeğer, V_k: En yüksek k özdeğere karşılık gelen özvektörler matrisi, Y: Boyut indirgenmiş veri seti.

3.4. Granger nedenselliği (Granger causality)

Granger nedenselliği, zaman serileri arasındaki gecikmeli öngörü gücünü değerlendirmek amacıyla yaygın olarak kullanılan bir istatistiksel testtir. Bu test, bir değişkenin geçmiş değerlerinin başka bir değişkenin gelecekteki değerlerini öngörmede anlamlı katkı sağlayıp sağlamadığını analiz eder. Granger Nedenselliği, doğrudan

bir neden-sonuç ilişkisi göstermemekle birlikte, zaman serileri arasındaki gecikmeli ilişkileri belirleyerek öngörü gücünü ölçer. Yani, eğer X zaman serisinin geçmiş verileri, Y zaman serisinin gelecekteki davranışlarını öngörmede anlamlı bir iyileşme sağlıyorsa, X'in Y üzerinde Granger Nedenselliği olduğu söylenir. Kullanılan formüller ise Eş. 5 – Eş. 7 arasında ifade edilmiştir.

Unrestricted Model (X'in etkisini dahil eden model):

$$y_t = a_0 + \sum_{i=1}^{p} a_i \cdot y_{(t-i)} + \sum_{j=1}^{p} b_j \cdot x_{(t-j)} + \varepsilon_t \quad (5)$$

Restricted Model (sadece y geçmişi kullanılır):

$$y_t = a_0 + \sum_{i=1}^{p} a_i \cdot y_{(t-i)} + \varepsilon_t \quad (6)$$

F-istatistiği, modeller arasındaki hata kareler toplamı (RSS) farkını kullanarak şu şekilde hesaplanır.

$$F = [(RSS_r - RSS_u) / p] / [RSS_u / (T - 2p - 1)] \quad (7)$$

Burada: RSS_r: Restricted modelin hata kareler toplamı, RSS_u: Unrestricted modelin hata kareler toplamı, p: Kullanılan gecikme (lag) sayısı, T: Toplam gözlem sayısı olarak ifade edilmektedir. Bu test, finansal piyasa analizlerinde ve ekonomik modellemelerde, değişkenler arasındaki dinamik ilişkileri ortaya koymada özellikle faydalıdır. Çalışmamızda, gezegensel özniteliklerin finansal hedef değişkenlere (örneğin; OPEN, CLOSE, ADJ CLOSE, LOW, HIGH) etkisini değerlendirmek amacıyla Granger Nedensellik testleri uygulanmıştır. Çalışmada her bir gezegensel özniteliğin finansal hedef değişkenler üzerindeki gecikmeli etkisini değerlendirebilmek amacıyla farklı lag değerleri test edilmiş; optimum lag süresi, Akaike Bilgi Kriteri (AIC) ve Bayesian Bilgi Kriteri (BIC) değerlerine göre belirlenmiştir. En düşük AIC/BIC değerini sağlayan gecikme düzeyi, analizlerde kullanılmak üzere seçilmiştir. Kodlama sürecinde, her bir gezegensel özniteliğin hedef değişken üzerindeki etkisini test etmek amacıyla farklı gecikme seviyelerinde Granger analizleri gerçekleştirilmiş; bu analizlerde modelin uyumunu en iyi şekilde temsil eden lag değeri, Akaike Bilgi Kriteri (AIC) ve Bayesian Bilgi Kriteri (BIC) değerleri esas alınarak optimize edilmiştir. Yapılan testlerde, her bir finansal hedef değişken için lag=1 ila lag=10 arasında farklı seviyeler test edilmiş; en düşük AIC ve BIC değerini sağlayan gecikme süresi seçilmiştir.

Bu yöntem, yalnızca korelasyon değil, gecikmeli bilgi aktarımı içeren anlamlı nedensellik bağlarını tespit etmede istatistiksel güvenilirlik sunmaktadır. Elde edilen sonuçlara göre, optimal lag değerleri her bir veri seti ve gezegensel öznitelik çifti için değişkenlik göstermiştir. Bu değerler, hem istatistiksel anlamlılığı hem de model başarısını artıran sonuçlar üretmiştir.

Sonuç olarak, Granger Nedensellik Testi, finansal ve gezegensel veri setleri arasındaki gecikmeli öngörü ilişkilerini analiz etmek için kritik bir araç olarak kullanılmış, optimum gecikme süreleri belirlenmiş ve böylece modelin performansının artırılmasına katkı sağlanmıştır. Bu test, gezegensel parametreler ile hedef değişkenler arasında istatistiksel olarak anlamlı gecikmeli bağıntılar tespit ederek, belirli gezegensel değişkenlerin finansal piyasa hareketlerini öngörmede bilgi içeriğine sahip olup olmadığını değerlendirmektedir. Ancak, Granger Nedenselliği doğrudan bir sebep-sonuç ilişkisi sunmaz; yalnızca bir değişkenin geçmiş değerlerinin, başka bir değişkenin gelecekteki değerlerini öngörme gücünü ölçer. Dolayısıyla, bu analizler seçilen gezegensel özniteliklerin finansal piyasa değişkenleri ile anlamlı bir öngörü ilişkisine sahip olabileceğini ortaya koymaktadır.

4. Yöntem (Method)

Bu çalışmanın modelleme sürecinde, sınıflandırma problemi ele alınmıştır. Her finansal piyasa verisi için, ilgili finansal parametrenin (OPEN, CLOSE, ADJ CLOSE, LOW, HIGH) artış ya da azalış durumuna dair bir ilişki analizi yapılması amaçlanmış; model performansı karmaşıklık matrisi ile Doğruluk, Kesinlik, Duyarlılık ve F1 Skoru metrikleriyle değerlendirilmiştir. Bu çalışma kapsamında, genel Yapay Sinir Ağları (Artificial Neural Networks - ANN), Kapılı Tekrarlayan Sinir Ağları (Gated Recurrent Units - GRU), Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) ve Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNN) olmak üzere dört farklı sinir ağı mimarisi geliştirilmiştir.

4.1. Yapay Sinir Ağları (Artificial Neural Networks - ANN)

Yapay sinir ağları, biyolojik sinir sistemlerinin işleyişine benzetilerek geliştirilen, çok katmanlı ileri beslemeli (feedforward) yapılar olarak tanımlanır. Temel olarak, bir giriş vektörünün ağırlıklar ile çarpılarak toplanması ve aktivasyon fonksiyonları (örneğin, sigmoid, ReLU) aracılığıyla işlenmesi prensibine dayanır. Matematiksel olarak, bir nöronun çıktısı genel olarak Eş.8'de belirtilen formülle ifade edilir.

$$y = f(\sum_{i=1}^{n} w_i \cdot x_i + b) \quad (8)$$

Burada; x_i: i'nci giriş özniteliği, w_i: i'nci giriş özniteliğine ait ağırlık, b: bias terimi, f(·): aktivasyon fonksiyonu (örneğin, sigmoid, ReLU) olarak ifade etmektedir.

4.2. Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNN)

Tekrarlayan Sinir Ağları (Recurrent Neural Networks – RNN), özellikle zaman serileri ve ardışık verilerin modellenmesinde kullanılan temel derin öğrenme mimarilerindendir. Bu ağlar, geleneksel yapay sinir ağlarından farklı olarak, her bir zaman adımında hem o anki girdi hem de önceki zaman adımından gelen gizli durumu (memory) dikkate alır. Bu sayede, veri dizisindeki geçmiş bilgilerin, gelecekteki öngörülerde kullanılabilmesi sağlanır. Bir RNN modeli her t zaman adımında Eş.9 ve Eş. 10'daki gibi hesaplama yapar.

Gizli durum güncelleme $h_t = \varphi(W \cdot x_t + U \cdot h_{(t-1)} + b)$ (9)

Çıkış hesaplaması $y_t = \psi(V \cdot h_t + c)$ (10)

Burada; x_t: t zaman adımındaki giriş vektörü, $h_{(t-1)}$: t-1 zaman adımındaki gizli durum, W: Giriş verisinden gelen ağırlık matrisi, U: Önceki gizli durumdan gelen ağırlık matrisi, b: Bias terimi, φ: Gizli katman aktivasyon fonksiyonu (örneğin, tanh veya ReLU), V: Gizli durumdan çıktıya dönüşüm matrisi, c: Çıkış bias terimi, ψ: Çıkış aktivasyon fonksiyonu (örneğin, sınıflandırma için sigmoid veya softmax) olarak ifade etmektedir.

RNN'ler, ardışık verilerdeki zaman bağımlılıklarını yakalama konusunda güçlüdür; ancak, özellikle uzun zaman serilerinde eğitim sırasında azalan gradyan (vanishing gradient) problemi gibi zorluklarla karşılaşabilirler. Bu nedenle, uzun dönemli bağımlılıkları modellemek için daha gelişmiş hücre yapıları (örneğin, LSTM veya GRU) geliştirilmiştir.

Çalışmamızda, klasik RNN modeli özellikle kısa dönemli piyasa dalgalanmalarını ve ani değişiklikleri yakalamak amacıyla tercih edilmiştir. Bu model, diğer ileri düzey tekrarlayan sinir ağı mimarilerinin (LSTM, GRU) performansını değerlendirebilmek için bir temel referans olarak da kullanılmıştır. Kısa vadeli öngörülerin, özellikle finansal piyasa verilerinde kritik olduğu durumlarda, klasik

RNN'nin sadeliği ve daha düşük hesaplama maliyeti önemli avantajlar sağlamaktadır. Böylece, RNN, veri setinde yer alan ani değişimlerin hızlıca modellenmesi ve kısa vadeli bağımlılıkların etkili bir şekilde analiz edilmesi için uygun bir seçenek olarak belirlenmiştir.

4.3. Kapılı Tekrarlayan Sinir Ağları (Gated Recurrent Units - GRU)

Kapılı tekrarlayan sinir ağları, klasik RNN'lerin uzun dönem bağımlılıklarını modellemede karşılaştığı "vanishing gradient" (azalan gradyan) problemini hafifletmek üzere geliştirilmiş modern bir yapay sinir ağı mimarisidir. GRU, temel olarak iki kapı mekanizması kullanır: güncelleme kapısı (update gate) ve sıfırlama kapısı (reset gate). Bu kapılar, ağın geçmiş bilgiyi ne ölçüde koruyup ne ölçüde güncelleyeceğini dinamik olarak belirler. GRU hücrelerinin hesaplama adımları aşağıdaki gibidir (Eş. 11 – Eş. 14).

$$z_t = \sigma(W_z \cdot x_t + U_z \cdot h_{(t-1)} + b_z) \quad (11)$$

$$r_t = \sigma(W_r \cdot x_t + U_r \cdot h_{(t-1)} + b_r) \quad (12)$$

$$\ddot{h}_t = \tanh(W_h \cdot x_t + U_h \cdot (r_t \odot h_{(t-1)}) + b_h) \quad (13)$$

$$h_t = (1 - z_t) \odot h_{(t-1)} + z_t \odot \ddot{h}_t \quad (14)$$

Burada: x_t: t zaman adımındaki giriş, $h_{(t-1)}$: bir önceki gizli durum, W_z, W_r, W_h: giriş öznitelikleri için ağırlık matrisleri, U_z, U_r, U_h: önceki gizli durum için ağırlık matrisleri, b_z, b_r, b_h: bias terimleri, $\sigma(\cdot)$: sigmoid aktivasyon fonksiyonu, $\tanh(\cdot)$: hiperbolik tanjant aktivasyon fonksiyonu, $\odot$: eleman çarpımı, z_t: güncelleme kapısı, r_t: sıfırlama kapısı, $\ddot{h}_t$: aday gizli durum olarak ifade edilmektedir.

GRU, güncelleme kapısı sayesinde, ağın geçmiş bilgiden ne kadarını koruyacağını ve ne kadarını yenileyeceğini belirler. Sıfırlama kapısı ise, geçmiş bilgilerin ne ölçüde göz ardı edileceğini kontrol eder. Bu mekanizmalar, özellikle finansal zaman serilerinde, ani dalgalanmalar ile uzun dönem trendleri aynı anda yakalayabilmeyi mümkün kılar.

Çalışmamızda GRU, finansal piyasaların karmaşık ve doğrusal olmayan dinamiklerini modelleyebilmek, kısa vadeli değişikliklerin yanı sıra uzun dönemli bağımlılıkları da etkili şekilde öğrenebilmek amacıyla tercih edilmiştir. GRU, LSTM'e kıyasla daha az parametre içerdiğinden eğitim süresi ve hesaplama maliyeti açısından avantaj sağlamakta, böylece modelin hızlıca optimize edilmesine olanak tanımaktadır.

4.4. Uzun Kısa Süreli Bellek (Long Short-Term Memory – LSTM)

LSTM modelleri, klasik RNN'lerin uzun dönem bağımlılıkları öğrenmede karşılaştığı azalan gradyan (vanishing gradient) problemini aşmak amacıyla geliştirilmiş özel hücre yapıları içerir. LSTM hücreleri, unutma, giriş ve çıkış kapıları kullanarak bilgi akışını kontrol eder. Bu mekanizma sayesinde, önemli bilgilerin uzun süre hafızada tutulması, gereksiz bilgilerin ise unutulması sağlanır. Bu özellik, bilhassa finansal zaman serilerindeki ani değişimler ile uzun vadeli trendleri aynı anda modelleyebilmek açısından kritik öneme sahiptir. LSTM hücrelerinde kullanılan temel formüller şu şekildedir (Eş. 15 – Eş. 20).

$$\text{Unutma Kapısı: } f_t = \sigma(W_f \cdot [h_{(t-1)}, x_t] + b_f) \quad (15)$$

$$\text{Giriş Kapısı: } i_t = \sigma(W_i \cdot [h_{(t-1)}, x_t] + b_i) \quad (16)$$

$$\text{Aday Hücre Durumu: } \hat{C}_t = \tanh(W_C \cdot [h_{(t-1)}, x_t] + b_C) \quad (17)$$

$$\text{Hücre Durumu: } C_t = f_t \odot C_{(t-1)} + i_t \odot \hat{C}_t \quad (18)$$

$$\text{Çıkış Kapısı: } o_t = \sigma(W_o \cdot [h_{(t-1)}, x_t] + b_o) \quad (19)$$

$$\text{Çıkış: } h_t = o_t \odot \tanh(C_t) \quad (20)$$

Burada: x_t: t zaman adımındaki giriş, $h_{(t-1)}$: bir önceki gizli durum, W_f, W_i, W_C, W_o: sırasıyla unutma, giriş, aday hücre durumu ve çıkış kapıları için ağırlık matrisleri, b_f, b_i, b_C, b_o: ilgili bias terimleri, $\sigma(\cdot)$: sigmoid aktivasyon fonksiyonu, $\tanh(\cdot)$: hiperbolik tanjant aktivasyon fonksiyonu, f_t: unutma kapısı, i_t: giriş kapısı, o_t: çıkış kapısı, C_t: hücre durumu, h_t: güncel gizli durum olarak ifade edilmektedir. Finansal piyasa verilerinde, uzun dönemli trendler ve ani dalgalanmaların doğru şekilde yakalanması, modelin başarısı için kritiktir. LSTM, bu karmaşık zaman serisi verilerindeki uzun dönem bağımlılıklarını etkili şekilde öğrenme kapasitesi sayesinde tercih edilmiştir. Çalışmamızda, veri seti ölçeklendirilip üç boyutlu (örnek, zaman adımı, öznitelik) formata dönüştürüldükten sonra, LSTM modeli finansal verilerin artış/azalış yönünü sınıflandırmak üzere eğitilmiştir. Elde edilen sonuçlar, LSTM'nin finansal piyasa hareketlerindeki doğrusal olmayan ve zaman bağımlı yapıyı yakalamada diğer modellere göre üstün performans sergilediğini göstermektedir.

5. Uygulama Geliştirilmesi: Yazılım ve Donanım Ortamı (Application Development: Software and Hardware Environment)

Programlama dili olarak Python kullanılmıştır. Veri işleme için Pandas, NumPy ve Polars; veri toplama için astroquery ve yfinance; öznitelik seçimi ve istatistiksel analiz için scikit-learn, LightGBM ve statsmodels; derin öğrenme için TensorFlow (Keras API); görselleştirme için Matplotlib ve Seaborn kütüphaneleri tercih edilmiştir. Tüm model eğitimleri, GPU destekli sunucu ortamında Google Colab üzerinden gerçekleştirilmiş olup, işlem verimliliği için gerekli optimizasyonlar uygulanmıştır.

6. Performans Ölçütleri (Performans Metrikleri)

Geliştirilen modellerin performansı, doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru gibi metrikler kullanılarak değerlendirilmiştir. Model sonuçları karşılaştırmalı olarak sunulmuş, karmaşıklık matrisleri ve istatistiksel analizler ile performans detaylandırılmıştır. İlgili formüller aşağıda verilmiştir (Eş. 21 - Eş. 24).

$$\text{Doğruluk} = (TN + TP) / (TN + FP + TP + FN) \quad (21)$$

$$\text{Duyarlılık} = TP / (FN + TP) \quad (22)$$

$$\text{Kesinlik} = TP / (FP + TP) \quad (23)$$

$$F1 = 2 \times \text{Duyarlılık} \times \text{Kesinlik} / (\text{Duyarlılık} + \text{Kesinlik}) \quad (24)$$

7. Sonuçlar ve Tartışmalar (Results and Discussions)

Bu çalışmada, BITCOIN, NYSE ve RUSSELL piyasalarına yönelik gerçekleştirilen öznitelik seçimi analiz edilmiştir. Öznitelik seçimi sürecinde karşılıklı bilgi (Mutual Information-MI) skorları kullanılmış, en yüksek bilgi içeriğine sahip gezegenlerin konumsal ve açısal özelliklerine dayalı faktörler belirlenmiş ve bunların ilgili fiyat değişkenleri üzerindeki etkileri gecikme süresi (lag) ve p değerleri ile analiz edilmiştir. Finansal zaman serilerinde, lag (gecikme) değeri, belirli bir bağımsız değişkenin (örneğin gezegensel faktörler) mevcut zaman dilimindeki bağımlı değişken (örneğin fiyat değişimi) üzerindeki etkisini ölçmek için kullanılan bir tekniktir. Lag değişkenleri, geçmiş verilerin gelecekteki değerler üzerindeki etkisini anlamak için kritik bir rol oynar. Matematiksel olarak, zaman serisi için (k adım önceki değer) lag olarak tanımlanır. Bu çalışmada lag değişkenleri, gezegensel faktörlerin finansal piyasalara etkisini

belirlemek için kullanılmıştır. Örneğin, Satürn-Plüton kavuşumu (SATURN_PLUTO_ANGLE_CONJUNCTION) ve BITCOIN fiyat hareketleri arasındaki ilişkiyi değerlendirmek için 0-7 günlük gecikmeler incelenmiştir. Bu gecikme değerleri, göksel cisimlere dair olayların finansal fiyat hareketleri üzerindeki gecikmeli etkisini ölçmek için belirlenmiştir. p değeri (probability value) ise, istatistiksel hipotez testlerinde kullanılan bir ölçüttür ve bir gözlemin, sıfır hipotezi doğru kabul edildiğinde, rastgele gerçekleşme olasılığını ifade eder. Düşük bir p değeri (genellikle), elde edilen sonuçların tesadüfi olma olasılığının düşük olduğunu ve bağımsız değişkenin bağımlı değişken üzerinde anlamlı bir etkisi olabileceğini gösterir. Bu çalışmada p değeri, gezegensel faktörlerin finansal piyasalar üzerindeki etkilerinin istatistiksel olarak anlamlı olup olmadığını belirlemek için kullanılmıştır. Araştırmamız kapsamında $p < 0,01$ eşiği %99 güven seviyesi, $p < 0,05$ eşiği %95 güven seviyesi, $p < 0,10$ eşiği ise %90 güven seviyesi olarak kabul edilmiştir. Örneğin, BITCOIN veri setindeki hesaplamalara göre Satürn-Plüton kavuşumu (SATURN_PLUTO_ANGLE_CONJUNCTION) ile piyasa hareketleri arasındaki ilişki için elde edilen p değerinin 0,0078 olması, bu ilişkinin %99'un üstündeki bir güven seviyesinde anlamlı olduğunu gösterir. Bu tür istatistiksel doğrulamalar, sonuçların güvenilirliğini artırarak öznitelik seçiminin bilimsel temelini güçlendirmektedir.

Tablo 1'deki veriler incelendiğinde BITCOIN veri setindeki ilişki analizi için hazırlanan modellerde, Satürn, Plüton, Varuna, Uranüs ve Kuzey Ay Düğümü ile ilişkili göksel faktörlerin öne çıktığı görülmektedir. OPEN fiyatı için SATURN_PLUTO_ANGLE_CONJUNCTION (MI = 0,28) ve SATURN_BIM_ANGLE_TRINE (MI = 0,26) en güçlü öznitelikler olarak belirlenmiştir. CLOSE fiyatı için ise PLUTO_VARUNA_ANGLE_OPPOSITION (MI = 0,22) ve SATURN_BIM_ANGLE_TRINE (MI = 0,16) en yüksek bilgi içeriğine sahip bileşenlerdir. LOW fiyatı için, URANUS_VARUNA_ANGLE_SQUARE (MI = 0,42) ve NORTH_NODE_SIGN_TAURUS (MI = 0,36) en güçlü etkiye sahiptir. Benzer şekilde, HIGH fiyatı için SATURN_BIM_ANGLE_TRINE (MI = 0,17) en yüksek korelasyonu göstermektedir. Tüm fiyatlar için yapılan ilişki analizlerinde BIM_SIGN_VIRGO, önemli bir öznitelik olarak belirlenmiş ve farklı zaman gecikmeleri ile etkisinin güçlü olduğu görülmüştür.

Tablo 1'de yer verilen Temel Bileşen Analizi (PCA) sonuçlarına göre PCA_1 komponenti [NEPTUNE_BIM_ANGLE_OPPOSITION, PLUTO_VARUNA_ANGLE_OPPOSITION, NORTH_NODE_SIGN_TAURUS] öznitelik bileşenlerinden, PCA_2 komponenti [NEPTUNE_BIM_ANGLE_OPPOSITION, IS_URANUS_R, SATURN_PLUTO_ANGLE_CONJUNCTION] bileşenlerinden, PCA_3 komponenti [SATURN_URANUS_ANGLE_SQUARE, SATURN_SIGN_AQUARIUS, SATURN_BIM_ANGLE_TRINE] bileşenlerinden, PCA_4 komponenti [IS_PLUTO_R, MIDAS_SIGN_TAURUS, PLUTO_VARUNA_ANGLE_OPPOSITION] bileşenlerinden, PCA_5 komponenti [IS_URANUS_R, BIM_SIGN_VIRGO, IS_PLUTO_R] bileşenlerinden, PCA_6 komponenti [MIDAS_SIGN_GEMINI, SATURN_PLUTO_ANGLE_CONJUNCTION, SATURN_BIM_ANGLE_TRINE] bileşenlerinden, PCA_7 komponenti [MIDAS_SIGN_GEMINI, SATURN_PLUTO_ANGLE_CONJUNCTION, SATURN_BIM_ANGLE_TRINE] bileşenlerinden, PCA_9 komponenti [SATURN_PLUTO_ANGLE_CONJUNCTION, JUPYTER_PLUTO_ANGLE_SEXTILE, URANUS_VARUNA_ANGLE_SQUARE,] bileşenlerinden, PCA_10 komponenti [MIDAS_SIGN_CANCER, IS_PLUTO_R, PLUTO_VARUNA_ANGLE_OPPOSITION] bileşenlerinden oluşmaktadır. Tabloya öznitelik seçim algoritmalarının filtrelerinden geçenlere yer verilmiştir. Tablo detaylı incelendiğinde, BITCOIN veri setindeki 731 tane gezegensel sütunun, sırasıyla uygulanan Karşılık Bilgi (Mutual Information), Özyinelemeli Öznitelik Elemesi (Recursive Feature Elimination), Temel Bileşen Analizi (Principal Component Analysis) ve Granger Nedenselliği (Granger Causality) işlemlerinin ardından seçilen en güçlü ve nedensellik ilişkisi taşıyan 6 gezegensel sütuna indirgendiği görülmektedir.

Tablo 2'de NYSE piyasası incelendiğinde, Neptün, Satürn, Uranüs gezegenlerinin ve Midas asteroidinin açısal ilişkileri ön plana çıkmıştır. OPEN fiyatı için, NEPTUNE_SIGN_PISCES (MI = 0,45) ve NEPTUNE_SIGN_AQUARIUS (MI = 0,43) en yüksek bilgi içeriğine sahip değişkenlerdir. CLOSE fiyatı için, NEPTUNE_PLUTO_ANGLE_SEXTILE (MI = 0,31) en belirgin faktör olarak öne çıkmaktadır. VARUNA_SIGN_AQUARIUS (MI = 0,26) ve URANUS_VARUNA_ANGLE_SQUARE (MI = 0,24) LOW fiyatı için yüksek bilgi içeriğine sahip değişkenlerdir. HIGH fiyatı içinse, SATURN_SIGN_AQUARIUS (MI = 0,23) en önemli faktör olarak belirlenmiştir.

Tablo 2'de yer verilen Temel Bileşen Analizi (PCA) sonuçlarına PCA_1 komponenti [VARUNA_SIGN_CANCER, NEPTUNE_SIGN_AQUARIUS, BIM_SIGN_VIRGO] öznitelik bileşenlerinden, PCA_2 komponenti [NEPTUNE_SIGN_PISCES, PLUTO_BIM_ANGLE_TRINE, BIM_SIGN_VIRGO] bileşenlerinden, PCA_4 komponenti [MIDAS_SIGN_GEMINI,

Tablo 1. BITCOIN için öznitelik seçim sonuçları (Feature selection results for BITCOIN)

Hedef	Öznitelik	MI Skoru	PCA Komponentleri	Lag	p Değeri
Open	SATURN_PLUTO_ANGLE_CONJUNCTION	0,288939046	['PCA_7']	7	0,007870035
Open	SATURN_BIM_ANGLE_TRINE	0,167249527	['PCA_3', 'PCA_7']	6	1.57879E-05
Close	BIM_SIGN_VIRGO	0,387429818	['PCA_5']	3	0,007509628
Close	SATURN_PLUTO_ANGLE_CONJUNCTION	0,285786164	['PCA_2', 'PCA_6']	7	0,004726131
Close	PLUTO_VARUNA_ANGLE_OPPOSITION	0,223108170	['PCA_1', 'PCA_4', 'PCA_10']	7	0,000642613
Close	SATURN_BIM_ANGLE_TRINE	0,168062807	['PCA_3', 'PCA_6']	5	6.03349E-06
Low	NORTH_NODE_SIGN_TAURUS	0,366822481	['PCA_1']	6	0,000240714
Low	SATURN_PLUTO_ANGLE_CONJUNCTION	0,278010340	['PCA_2', 'PCA_7', 'PCA_10']	7	4.08936E-07
Low	PLUTO_VARUNA_ANGLE_OPPOSITION	0,211509848	['PCA_1', 'PCA_4']	7	0,002230378
Low	SATURN_BIM_ANGLE_TRINE	0,155956246	['PCA_2', 'PCA_3']	5	1.89838E-11
High	URANUS_VARUNA_ANGLE_SQUARE	0,426084174	['PCA_1', 'PCA_2', 'PCA_9', 'PCA_10']	3	0,008364026
High	PLUTO_VARUNA_ANGLE_OPPOSITION	0,216064031	['PCA_4']	3	0,005270151
High	SATURN_BIM_ANGLE_TRINE	0,174862354	['PCA_1']	6	0,000298424
Adj Close	BIM_SIGN_VIRGO	0,387429818	['PCA_5']	3	0,007509628
Adj Close	SATURN_PLUTO_ANGLE_CONJUNCTION	0,285786164	['PCA_2', 'PCA_6']	7	0,004726131
Adj Close	PLUTO_VARUNA_ANGLE_OPPOSITION	0,223108170	['PCA_1', 'PCA_4', 'PCA_10']	7	0,000642613
Adj Close	SATURN_BIM_ANGLE_TRINE	0,168062807	['PCA_3', 'PCA_6']	5	6.03349E-06

Tablo 2. NYSE için öznitelik seçim sonuçları (Feature selection results for NYSE)

Hedef	Öznitelik	MI Skoru	PCA Komponentleri	Lag	p Değeri
Open	NEPTUNE_SIGN_PISCES	0,458325449	['PCA_2', 'PCA_6', 'PCA_7']	6	1.06546E-09
Open	NEPTUNE_SIGN_AQUARIUS	0,428989821	['PCA_1', 'PCA_9']	6	5.7401E-08
Open	NEPTUNE_PLUTO_ANGLE_SEXTILE	0,313738678	['PCA_10']	5	0,008217409
Open	MIDAS_SIGN_GEMINI	0,094850098	['PCA_4', 'PCA_5', 'PCA_8', 'PCA_9']	4	0,004078653
Close	NEPTUNE_SIGN_AQUARIUS	0,427443695	['PCA_1', 'PCA_9']	6	0,000446968
Close	NEPTUNE_PLUTO_ANGLE_SEXTILE	0,318326872	['PCA_8']	7	0,006716351
Low	NEPTUNE_SIGN_AQUARIUS	0,424969255	['PCA_1']	7	5.13336E-05
Low	URANUS_VARUNA_ANGLE_SQUARE	0,243466931	['PCA_2']	7	0,000318881
Low	SATURN_SIGN_CAPRICORN	0,235054006	['PCA_7']	4	0,000540488
Low	MIDAS_SIGN_GEMINI	0,093114497	['PCA_4', 'PCA_9']	3	0,00880648
High	VARUNA_SIGN_CANCER	0,620250515	['PCA_1']	7	0,007357537
High	NEPTUNE_SIGN_AQUARIUS	0,432631685	['PCA_1', 'PCA_4', 'PCA_7']	7	0,001909279
High	SATURN_SIGN_AQUARIUS	0,230339091	['PCA_9']	4	8.94741E-10
Adj Close	NEPTUNE_SIGN_AQUARIUS	0,427443695	['PCA_1', 'PCA_9']	6	0,000446968
Adj Close	NEPTUNE_PLUTO_ANGLE_SEXTILE	0,318326872	['PCA_8']	7	0,006716351

Tablo 3. RUSSELL için öznitelik seçim sonuçları (Feature selection results for RUSSELL)

Hedef	Öznitelik	MI Skoru	PCA Komponentleri	Lag	p Değeri
Open	NEPTUNE_SIGN_PISCES	0,597423937	['PCA_1', 'PCA_3']	5	0,007233738
Open	URANUS_VARUNA_ANGLE_SQUARE	0,308569636	['PCA_1', 'PCA_8']	7	0,001321531
Open	NORTH_NODE_SIGN_ARIES	0,127588416	['PCA_10']	6	0,008049924
Open	NORTH_NODE_SIGN_GEMINI	0,118551048	['PCA_6', 'PCA_9']	4	0,000747610
Close	NORTH_NODE_SIGN_GEMINI	0,120481464	['PCA_6']	7	0,001269089
Low	NORTH_NODE_SIGN_GEMINI	0,117547130	['PCA_6']	7	0,000557872
High	SATURN_SIGN_CAPRICORN	0,300782126	['PCA_8']	3	0,005040246
High	SATURN_SIGN_AQUARIUS	0,250036857	['PCA_9']	7	1.54119E-07
High	NORTH_NODE_SIGN_GEMINI	0,124480833	['PCA_9']	7	1.3616E-05
Adj Close	NORTH_NODE_SIGN_GEMINI	0,120481464	['PCA_6']	7	0,001269089

NORTH_NODE_SIGN_TAURUS, IS_SATURN_R_0] bileşenlerinden, PCA_5 komponenti [IS_SATURN_R_0, CHIRON_SIGN_ARIES, MIDAS_SIGN_GEMINI] bileşenlerinden, PCA_6 komponenti [IS_JUPYTER_R_0, NORTH_NODE_SIGN_TAURUS, NEPTUNE_SIGN_PISCES] bileşenlerinden, PCA_7 komponenti [NORTH_NODE_SIGN_TAURUS, NEPTUNE_SIGN_PISCES, JUPYTER_PLUTO_ANGLE_SQUARE] bileşenlerinden, PCA_8 komponenti [MIDAS_SIGN_CANCER, MIDAS_SIGN_GEMINI, NEPTUNE_PLUTO_ANGLE_SEXTILE] bileşenlerinden, PCA_9 komponenti [CHIRON_SIGN_ARIES, URANUS_NEPTUNE_ANGLE_CONJUNCTION, SATURN_SIGN_AQUARIUS] bileşenlerinden oluşmaktadır.

Tabloya öznitelik seçim algoritmalarının filtrelerinden geçenlere yer verilmiştir.Tablo detaylı incelendiğinde, NYSE veri setindeki 823 tane gezegensel sütunun, sırasıyla uygulanan Karşılık Bilgi (Mutual Information), Özyinelemeli Öznitelik Elemesi (Recursive Feature Elimination), Temel Bileşen Analizi (Principal Component Analysis) ve Granger Nedenselliği (Granger Causality) işlemlerinin ardından 823 öznitelik arasından seçilen en güçlü ve nedensellik ilişkisi taşıyan 8 gezegensel sütuna indirgendiği görülmektedir.

Tablo 3'te RUSSELL piyasası için yapılan analizde, Neptün, Uranüs, ve Satürn gezegenlerinin ve Kuzey Ay Düğümü'nün konum ve açısal ilişkileri belirleyici faktörler olarak tespit edilmiştir. OPEN fiyatı için, NEPTUNE_SIGN_PISCES (MI = 0,59) ve URANUS_VARUNA_ANGLE_SQUARE (MI = 0,30) en yüksek bilgi içeriğine sahip özniteliklerdir. NORTH_NODE_SIGN_GEMINI (MI = 0,21) ve SATURN_SIGN_CAPRICORN (MI = 0,03) LOW fiyatı için belirleyici değişkenlerdir. HIGH fiyatı içinse, SATURN_SIGN_AQUARIUS (MI = 0,23) ve NORTH_NODE_SIGN_NAN (MI = 0,12) en yüksek bilgi içeriğine sahip faktörler olarak saptanmıştır.

Tablo 3'te yer verilen Temel Bileşen Analizi (PCA) sonuçlarına göre PCA_1 komponenti [NEPTUNE_SIGN_PISCES, CHIRON_SIGN_ARIES, URANUS_VARUNA_ANGLE_SQUARE] öznitelik bileşenlerinden, PCA_3 komponenti [BIM_SIGN_VIRGO, VARUNA_SIGN_CANCER, NEPTUNE_SIGN_PISCES] bileşenlerinden, PCA_6 komponenti [URANUS_SIGN_AQUARIUS, NORTH_NODE_SIGN_GEMINI, NEPTUNE_SIGN_AQUARIUS] bileşenlerinden, PCA_8 komponenti [SATURN_SIGN_CAPRICORN, JUPYTER_SIGN_SAGITTARIUS, URANUS_VARUNA_ANGLE_SQUARE] bileşenlerinden, PCA_9 komponenti [SATURN_URANUS_ANGLE_TRINE, NORTH_NODE_SIGN_GEMINI, JUPYTER_SIGN_LEO] bileşenlerinden, PCA_10 komponenti [NORTH_NODE_SIGN_ARIES, JUPYTER_SIGN_LIBRA, JUPYTER_SATURN_ANGLE_SQUARE] bileşenlerinden oluşmaktadır. Tabloya öznitelik seçim algoritmalarının filtrelerinden geçenlere yer verilmiştir. Tablo detaylı incelendiğinde, RUSSELL veri setindeki 806 tane gezegensel sütunun, sırasıyla uygulanan Karşılık Bilgi (Mutual Information), Özyinelemeli Öznitelik Elemesi (Recursive Feature Elimination), Temel Bileşen Analizi (Principal Component Analysis) ve Granger Nedenselliği (Granger Causality) işlemlerinin ardından 806 öznitelik arasından seçilen en güçlü ve nedensellik ilişkisi taşıyan 6 gezegensel sütuna indirgendiği görülmektedir.

Her bir piyasa için veri seti; eğitim - validasyon - test veri seti olarak ayrılmıştır. (70% eğitim – 15% validasyon – 15% test). Aşağıdaki Tablo 4'te her bir finansal piyasa için (BITCOIN, NYSE, RUSSELL) tüm derin öğrenme metotlarının validasyon ve test veri setleri baz alınarak hesaplanan performans sonuçları Doğruluk, Kesinlik, Duyarlılık ve F1 Skoru değerleri cinsinden listelenmiştir. Buradan hareketle her bir modelin ilgili hedef değişkenler için nasıl performans gösterdiği açıkça listelenmiştir.

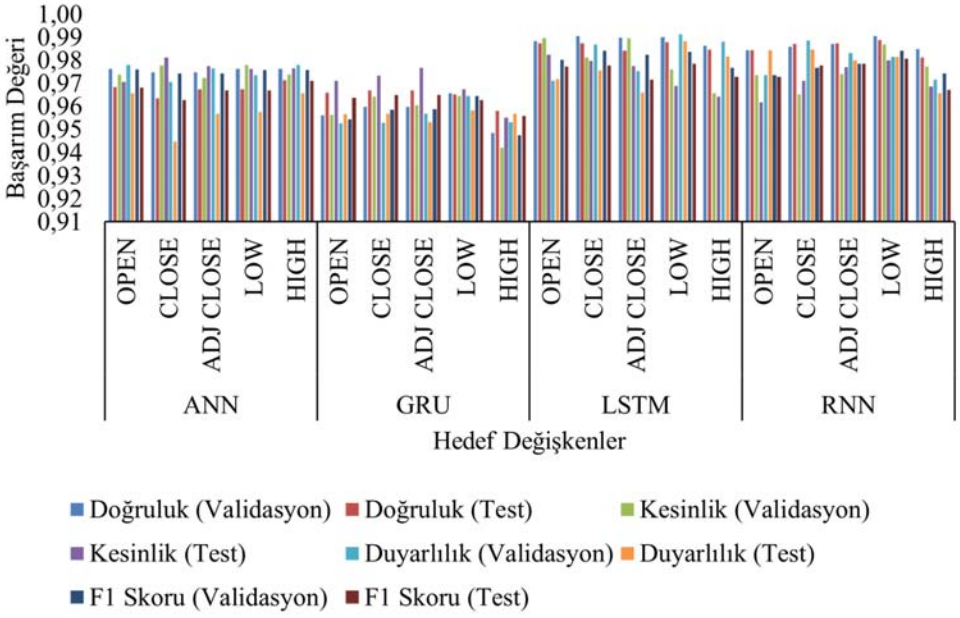
Tablo 4. Tüm piyasalar için derin öğrenme modellerinin performans sonuçları
(Performance results of deep learning models for all markets)

			Validasyon Sonuçları				Test Sonuçları			
Piyasa	Model	Hedef	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
BITCOIN	ANN	Open	0,965147453	0,973372781	0,950867052	0,961988304	0.968389363	0.970558376	0.965656566	0.968101266
		Close	0,967828418	0,982035928	0,947976879	0,964705882	0.963371801	0.981230448	0.944779116	0.962659847
		Adj close	0,971849866	0,976539589	0,962427746	0,969432314	0.967385850	0.977435897	0.956827309	0.967021816
		Low	0,959785523	0,976047904	0,936781609	0,956011730	0.967385850	0.976337449	0.957618567	0.966887417
		High	0,955764075	0,953890490	0,951149425	0,952517986	0.971399900	0.976602238	0.965794769	0.971168437
	LSTM	Open	0,958445040	0,931506849	0,982658960	0,956399437	0.966041108	0.971209213	0.956521739	0.963809524
		Close	0,963806971	0,976119403	0,945086705	0,960352423	0.966934763	0.973282443	0.956848030	0.964995270
		Adj close	0,954423592	0,964285714	0,936416185	0,950146628	0.966934763	0.976923077	0.953095685	0.964862298
		Low	0,949061662	0,950581395	0,939655172	0,945086705	0.965147453	0.967432950	0.958254269	0.962821735
		High	0,955764075	0,967359050	0,936781609	0,951824818	0.957998213	0.955056180	0.956848030	0.955951265
	GRU	Open	0,966487936	0,981981982	0,945086705	0,963181149	0.987488829	0.982570806	0.971982759	0.977248104
		Close	0,963806971	0,954415954	0,968208092	0,961262554	0.987488829	0.979765708	0.975609756	0.977683316
		Adj close	0,955764075	0,938375350	0,968208092	0,953058321	0.984212094	0.977467811	0.966065748	0.971733333
		Low	0,953083110	0,948424069	0,951149425	0,949784792	0.987786714	0.968814969	0.988335101	0.978477690
		High	0,954423592	0,975757576	0,925287356	0,949852507	0.984807864	0.964135021	0.981740064	0.972857903
	RNN	Open	0,970509383	0,962857143	0,973988439	0,968390805	0.984361037	0.961773700	0.984350548	0.972931168
		Close	0,965147453	0,970588235	0,953757225	0,962099125	0.987042002	0.971212121	0.984639017	0.977879481
		Adj close	0,958445040	0,967359050	0,942196532	0,954612006	0.987488829	0.977029096	0.980030722	0.978527607
		Low	0,954423592	0,951149425	0,951149425	0,951149425	0.988829312	0.980030722	0.981538462	0.980784012
		High	0,962466488	0,984848485	0,933908046	0,958702065	0.981233244	0.968750000	0.965732087	0.967238690
NYSE	ANN	Open	0,989211059	0,991842284	0,986477350	0,989152542	0.988353085	0.988510464	0.988105004	0.988307692
		Close	0,987862441	0,987170831	0,988505747	0,987837838	0.988353085	0.988510464	0.988105004	0.988307692
		Adj close	0,989211059	0,991842284	0,986477350	0,989152542	0.988353085	0.988510464	0.988105004	0.988307692
		Low	0,987862441	0,987170831	0,988505747	0,987837838	0.988353085	0.988510464	0.988105004	0.988307692
		High	0,987862441	0,987170831	0,988505747	0,987837838	0.988353085	0.988510464	0.988105004	0.988307692
	LSTM	Open	0,984153742	0,979250335	0,989181880	0,984191053	0.989212513	0.989779451	0.988715744	0.989247312
		Close	0,988873904	0,989837398	0,987829615	0,988832487	0.990560949	0.992980562	0.988178399	0.990573660
		Adj close	0,986850978	0,984522207	0,989181880	0,986846543	0.990830636	0.995121951	0.986566362	0.990825688
		Low	0,98246797	0,986366735	0,978363759	0,982348948	0.989482201	0.991900648	0.987103708	0.989496364
		High	0,986513823	0,983860121	0,989181880	0,986513823	0.990560949	0.992980562	0.988178399	0.990573660
	GRU	Open	0,987862441	0,987170831	0,988505747	0,987837838	0.986738593	0.989309577	0.984485816	0.986891802
		Close	0,987862441	0,987170831	0,988505747	0,987837838	0.988761519	0.996399640	0.981382979	0.988834301
		Adj close	0,987525287	0,986504723	0,988505747	0,987504222	0.986738593	0.989309577	0.984485816	0.986891802
		Low	0,989211059	0,991842284	0,986477350	0,989152542	0.988761519	0.996399640	0.981382979	0.988834301
		High	0,987862441	0,988490183	0,987153482	0,987821380	0.986738593	0.977401130	0.996897163	0.987052886
	RNN	Open	0,982467970	0,986366735	0,978363759	0,982348948	0.988536750	0.993288591	0.984042553	0.988643955
		Close	0,987862441	0,987170831	0,988505747	0,987837838	0.986738593	0.989309577	0.984485816	0.986891802
		Adj close	0,983479434	0,986394558	0,980392157	0,983384198	0.986963363	0.992383513	0.981826241	0.987076649
		Low	0,987862441	0,987170831	0,988505747	0,987837838	0.986738593	0.989309577	0.984485816	0.986891802
		High	0,983479434	0,986394558	0,980392157	0,983384198	0.988761519	0.996399640	0.981382979	0.988834301
RUSSELL	ANN	Open	0,983484283	0,989071038	0,977321814	0,983161325	0.983375959	0.987762238	0.978354978	0.983036103
		Close	0,981885988	0,982627579	0,980498375	0,981561822	0.983802217	0.987730061	0.979148566	0.983420593
		Adj close	0,980287693	0,979437229	0,980498375	0,979967515	0.985080989	0.990333919	0.979148566	0.984709480
		Low	0,984549814	0,990163934	0,978401728	0,984247691	0.985507246	0.983620690	0.987024221	0.985319516
		High	0,986148109	0,993421053	0,978401728	0,985854189	0.985507246	0.990384615	0.980103806	0.985217391
	LSTM	Open	0,981353223	0,990099010	0,971922246	0,980926431	0.983802217	0.983549784	0.983549784	0.983549784
		Close	0,980820458	0,980498375	0,980498375	0,980498375	0.983802217	0.983492615	0.983492615	0.983492615
		Adj close	0,981885988	0,987925357	0,975081257	0,981461287	0.982097187	0.978429681	0.985230235	0.981818182
		Low	0,982418753	0,989047097	0,975161987	0,982055465	0.982949702	0.983535529	0.981833910	0.982683983
		High	0,986148109	0,993421053	0,978401728	0,985854189	0.983802217	0.982728843	0.984429066	0.983578220
	GRU	Open	0,980820458	0,971398305	0,990280778	0,980748663	0.982948490	0.980645161	0.984881210	0.982758621
		Close	0,977623868	0,961256545	0,994582882	0,977635783	0.982593250	0.983357453	0.981227437	0.982291290
		Adj close	0,985082579	0,994475138	0,975081257	0,984682713	0.982238011	0.984046410	0.979783394	0.981910275
		Low	0,982951518	0,981681034	0,983801296	0,982740022	0.983658970	0.990524781	0.976293103	0.983357453
		High	0,984549814	0,990163934	0,978401728	0,984247691	0.984014210	0.980672870	0.987031700	0.983842011
	RNN	Open	0,982418753	0,993370166	0,970842333	0,981977062	0.982593250	0.988338192	0.976241901	0.982252807
		Close	0,985082579	0,990142388	0,979414951	0,984749455	0.983658970	0.988329686	0.978339350	0.983309144
		Adj close	0,985082579	0,994475138	0,975081257	0,984682713	0.982948490	0.983369487	0.981949458	0.982658960
		Low	0,983484283	0,984832069	0,981641469	0,983234181	0.984724689	0.987707881	0.981321839	0.984504505
		High	0,986148109	0,993421053	0,978401728	0,985854189	0.982593250	0.986201888	0.978386167	0.982278481

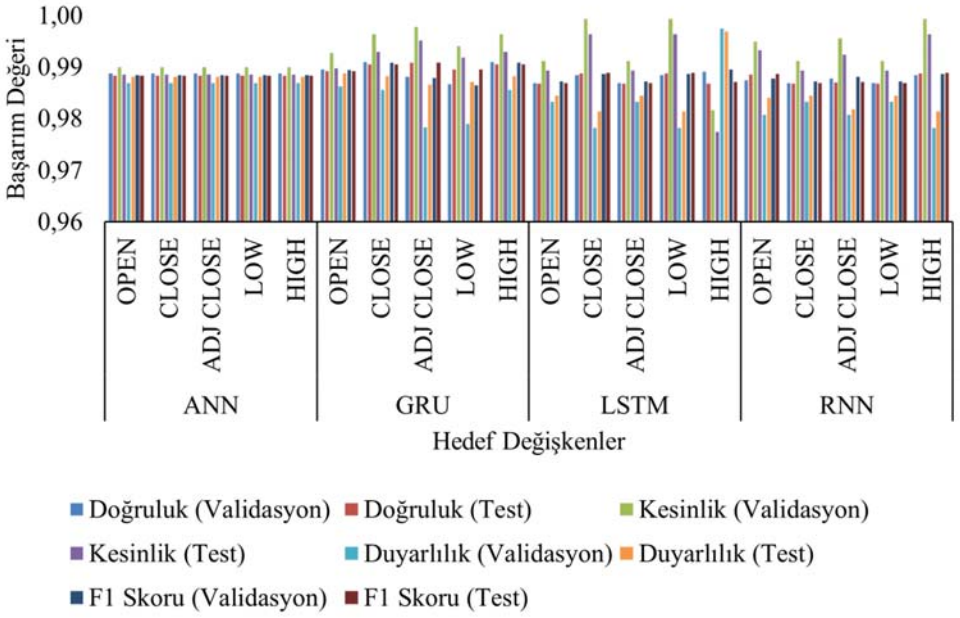
Şekil 1'de, BITCOIN ve FTSE piyasaları için farklı derin öğrenme modellerinin (ANN, LSTM, GRU ve RNN) performansları karşılaştırılmıştır. BITCOIN piyasasına ilişkin doğrulama ve test verileri üzerinde yapılan değerlendirmelerde, ANN modeli, özellikle OPEN, CLOSE ve ADJ CLOSE fiyatları için yapılan analizlerde en yüksek başarıyı sergilemiştir. Doğruluk oranları test setinde %96.3'ün üzerine çıkarken, keskinlik (precision) ve F1 skorlarında da %97'yi aşan değerler elde edilmiştir. GRU modeli, özellikle LOW ve HIGH fiyatları için LSTM modeline kıyasla daha stabil ve dengeli bir performans sergileyerek zaman serisi verilerinde kararlı bir yapı

ortaya koymuştur. LSTM modeli ise bazı alt fiyat kategorilerinde yüksek doğruluk oranları sağlasa da genel performansta GRU ve ANN modellerinin gerisinde kalmıştır. RNN modeli ise BITCOIN piyasası gibi yüksek oynaklığa sahip bir ortamda, duyarlılık (recall) açısından zaman zaman öne çıksa da genel başarımında dalgalı bir görünüm sunmuştur.

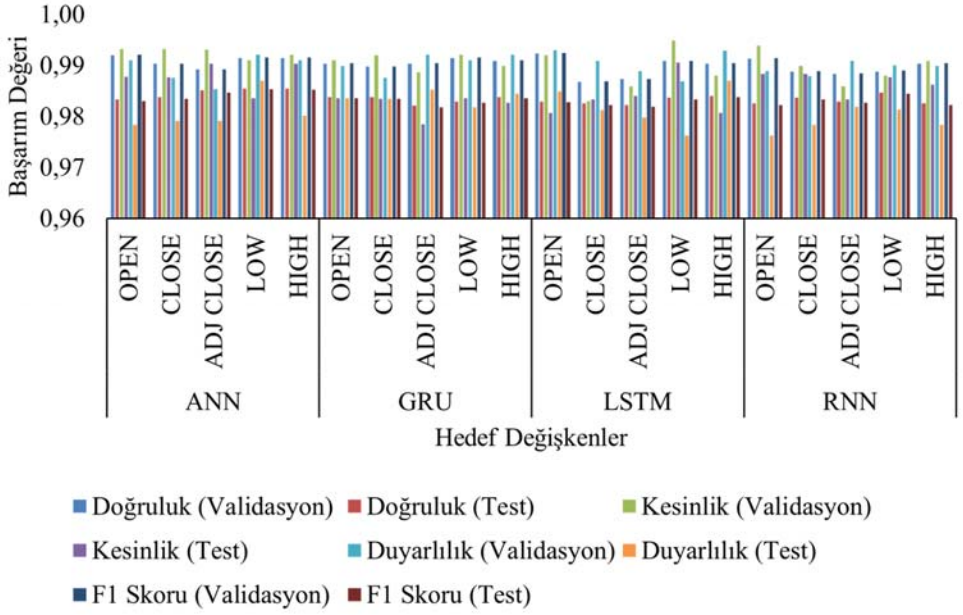
Şekil 2'de, NYSE piyasası için farklı derin öğrenme modellerinin (ANN, LSTM, GRU ve RNN) performansları karşılaştırılmıştır. NYSE piyasası üzerinde gerçekleştirilen deneysel sonuçlar, ANN modelinin, OPEN ve CLOSE fiyatlarında %98 doğruluk seviyelerine ulaşarak yüksek güvenilirlik sunduğunu göstermiştir. Test setinde doğruluk, keskinlik ve F1 skorları %98'in üzerindedir. GRU modeli, özellikle ADJ CLOSE ve HIGH fiyatları için en yüksek F1 skorlarını üretmiş ve güçlü bir alternatif model olarak öne çıkmıştır. RNN modeli ise NYSE verilerinde, diğer modellere kıyasla daha düşük genel performans sergilemekle birlikte, LOW fiyatında göreli bir duyarlılık üstünlüğü göstermiştir. LSTM modeli zaman zaman F1 skoru açısından başarılı sonuçlar üretse de, tutarlılık açısından ANN ve GRU'nun gerisinde kalmıştır.



Şekil 1. BITCOIN için tüm derin öğrenme modellerinin karşılaştırmalı performans sonuçları
(Comparative performance results of deep learning models for BITCOIN)



Şekil 2. NYSE için tüm derin öğrenme modellerinin karşılaştırmalı performans sonuçları
(Comparative performance results of deep learning models for NYSE)



Şekil 3. RUSSELL için tüm derin öğrenme modellerinin karşılaştırmalı performans sonuçları
(Comparative performance results of deep learning models for RUSSELL)

Şekil 3'te, RUSSELL piyasası için farklı derin öğrenme modellerinin (ANN, LSTM, GRU ve RNN) performansları karşılaştırılmıştır. RUSSELL endeksinde GRU modeli, ADJ CLOSE ve HIGH fiyat kategorilerinde %98'in üzerinde doğruluk oranları ile en başarılı model olarak değerlendirilmiştir. Özellikle dalgalı piyasa yapısına sahip olan bu endekste, GRU modelinin zaman bağımlı veri yapısına olan uyumu sayesinde yüksek keskinlik ve duyarlılık oranlarına ulaştığı gözlemlenmiştir. ANN modeli, Open ve Close fiyatlarında istikrarlı ve yüksek performans göstermiştir. RNN modeli, LOW fiyatı için duyarlılık açısından nispeten daha başarılı olsa da genel olarak değişken performans eğilimi sergilemiştir. LSTM modeli ise tüm kategorilerde orta düzeyde başarı sunmuştur. Sonuçlar, volatil piyasa koşullarına sahip olan RUSSELL gibi endekslerde GRU mimarisinin esnek ve etkili bir yapı sergileyebildiğini göstermektedir.

8. Sonuçlar (Conclusions)

Sonuç olarak, bu çalışma, gezegen konumları, açıları ve hareketlerinin finansal piyasalardaki gezegenlerin ve asteroidlerin etkisini değerlendiren ve derin öğrenme modelleri ile istatistiksel analizleri entegre eden öncü bir araştırmadır. Öznitelik seçimi için Karşılıklı Bilgi (Mutual Information, MI) ve Yinelemeli Öznitelik Eleme (Recursive Feature Elimination, RFE) teknikleri uygulanmış, boyut azaltma sürecinde Temel Bileşen Analizi (Principal Component Analysis, PCA) kullanılarak veri yapısı optimize edilmiştir. Ayrıca, Granger Nedensellik Testi (Granger Causality Test) ile belirli gezegen konumları ve açılarının finansal değişkenler üzerindeki gecikmeli öngörü gücü analiz edilmiştir. Elde edilen bulgular, gezegen hareketlerinin belirli finansal piyasa dalgalanmalarını öngörmede anlamlı bilgiler sunduğunu ve piyasalardaki ilişki analizlerindealternatif bir değişken olarak değerlendirilebileceğini göstermektedir. Önerilen model, yatırımcıların piyasa hareketlerini daha iyi anlamalarına yardımcı olabilecek öngörüler sunarak, risk yönetimi süreçlerini optimize etme, yatırım stratejilerini güçlendirme ve algoritmik ticaret modellerinde yeni veri kaynakları oluşturma açısından önemli bir potansiyele sahiptir. Bu sonuçlar, yalnızca finansal piyasaların analizine katkı sağlamakla kalmayıp, aynı zamanda derin öğrenme tabanlı sistemlerin karmaşık ve çok değişkenli gezegensel faktörler ile nasıl entegre edilebileceğine dair kapsamlı bir çerçeve sunmaktadır. Gelecek çalışmalarda ise daha fazla finansal enstrümanla çalışılması hedeflenmektedir. Ayrıca farklı derin öğrenme mimarileri (Transformer tabanlı modeller, hibrit yapılar vb.) ve optimizasyon teknikleri daha kullanılarak modelin başarım gücü artırılabilir.

Bu çalışma İstanbul Üniversitesi-Cerrahpaşa, Eğitim Bilimleri Enstitüsü'nde Bilgisayar Mühendisliği doktora programına kayıtlı Fatih Mert'in "Gezegen Konumlarına ve Açılarına Dayalı Yapay Zekâ Destekli Bir Finansal İlişki Analizi" adlı doktora tezinin bir parçasıdır. Bu çalışma, etik araştırma ilkelerine uygun olarak yürütülmüştür ve hiçbir etik ihlal içermemektedir. Kullanılan tüm veriler kamuya açık kaynaklardan temin edilmiş olup, üçüncü taraflarca manipüle edilmemiştir. Yazar(lar), bu çalışmada herhangi bir çıkar çatışması bulunmadığını beyan eder. Bu çalışma yalnızca akademik ve araştırma amaçlıdır ve herhangi bir yatırım veya finansal danışmanlık niteliği taşımaz. Çalışmada sunulan analizler ve yorumlar, istatistiksel verilere dayanmaktadır ve gelecekteki piyasa hareketlerine dair kesin bir öngörü garanti etmez. Yatırım kararları için bu alanda profesyonel finansal danışmanlardan destek alınması önerilir.

Kaynaklar (References)

1. Şişmanoğlu G., Koçer F., Önde M.A., Şahingöz Ö.K., Derin öğrenme yöntemleri ile borsada fiyat tahmini, BEÜ Fen Bilimleri Dergisi, 9 (1), 434-445, 2020.
2. Mokhtari S., Yen K.K., Liu J., Effectiveness of artificial intelligence in stock market prediction based on machine learning, International Journal of Computer Applications, 0975-8887, 2018.
3. Öztoprak S., Orman Z., Finansal verilere ilişkin tahminleri açıklamaya yönelik yeni bir model-agnostik yöntem ve uygulaması, Avrupa Bilim ve Teknoloji Dergisi, 38, 32-39, 2022.
4. Tekin T.G., Patır S., Amerikan doları kurunun yapay sinir ağları yöntemiyle tahminlenmesi: 2009–2021 dönemi, R&S-Research Studies Anatolia Journal, 6 (1), 56-77, 2023.
5. Ferreira F.G.D.C., Gandomi A.H., Cardoso R.T.N., Artificial intelligence applied to stock market trading: A review, IEEE Access, 9, 30898-30912, 2021.

6. Raju S.S., Srikanth M., Guravaiah K., Pandiyaan P., Teja B., Tarun K.S., A three-dimensional approach for stock prediction using AI/ML algorithms: A review & comparison, 4th International Conference on Innovative Trends in Information Technology (ICITIIT), IEEE, 594-600, Kochi-Hindistan, 2023.

7. Yiğit T., Aksoy B., Ersoy M., Şenol R., Salman O.K.M., Petrol fiyatlarının zaman serileri ve LSTM modeli kullanılarak tahminlenmesi, Uluslararası Teknolojik Bilimler Dergisi, 13 (1), 34-38, 2021.

8. Ray R., Khandelwal P., Baranidharan B., A survey on stock market prediction using artificial intelligence techniques, Proceedings of the International Conference on Smart Systems and Inventive Technology (ICSSIT), 594-600, Tirunelveli-Hindistan, 2018.

9. Kilimci Z. H., Financial sentiment analysis with Deep Ensemble Models (DEMs) for stock market prediction, Journal of the Faculty of Engineering and Architecture of Gazi University, 35 (2), 635–650, 2020.

10. Molla B., Çağıl G., Uyaroğlu Y., Chaotic analysis of BIST 100 return time series and short-term predictability with ANFIS, Journal of the Faculty of Engineering and Architecture of Gazi University, 36 (2), 577–591, 2021.

11. Ateş E., Güran A., Pearson correlation and Granger causality analysis of Twitter sentiments and the daily changes in Bist30 index returns, Journal of the Faculty of Engineering and Architecture of Gazi University, 36 (3), 1687–1701, 2021.

12. Kantar O., Kilimci Z. H., Deep learning based hybrid gold index (XAU/USD) direction forecast model. Journal of the Faculty of Engineering and Architecture of Gazi University, 38(2), 1117–1128, 2023.

13. Çetinyokuş T., Gökçen H., A decision support system for tecnical analysis by indicators on stock market, Journal of the Faculty of Engineering and Architecture of Gazi University, 17 (1), 43–58, 2002.

14. Konak F., Duman D., Ay'ın evreleri etkisinin Borsa İstanbul 100 Endeksi'nde GARCH modeli ile test edilmesi, Hitit Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 11 (1), 287-304, 2018.

15. Liu S.I., Tseng J., A Bayesian analysis of lunar effects on stock returns, The IUP Journal of Behavioral Finance, 6 (3-4), 67-71, 2009.

16. Sivakumar N., Swaminathan S., Do Krishna Paksha (new moon phase) and Shukla Paksha (full moon phase) affect the Indian stock market?, International Journal of Indian Culture and Business Management, 2 (3), 281-294, 2009.

17. Pramono F., Basana S.R., Analysis of the effect of lunar cycle on liquid 45 (LQ45) stocks on the Indonesia Stock Exchange (IDX) for the period 2005-2020, International Journal of Financial and Investment Studies, 3 (1), 21-34, 2022.

18. Yuan K., Zheng L., Zhu Q., Are investors moonstruck? Lunar phases and stock returns, University of Michigan, Ross School of Business, Michigan-A.B.D., 2003.

19. Wang Y.H., Lin C.T., Chen W.L., Does lunar cycle effect exist? Lunar phases and stock return volatilities, African Journal of Business Management, 4 (18), 3892-3897, 2010.

20. Lingaraja K., Lunar effect and stock market, SMART Journal of Business Management Studies, 9 (2), 33-39, 2013.

21. Wong W.K., McAleer M., Financial astrology: Mapping the presidential election cycle in US stock markets, SSRN Electronic Journal, 2008.

22. Floros C., Tan Y., Moon phases, mood, and stock market returns: International evidence, Economics and Finance, University of Portsmouth, 2015.

23. McMinn D., The 56-year cycles and financial crises, The Economics Society of Australia, Monash University, Melbourne-Avustralya, 1986.

24. Shah P., Chaudhri J., Moon and market: An empirical study on effect of movement of moon on BSE Sensex, International Journal of Accounting and Financial Management Research, 3 (1), 201-210, 2013.

25. Yousop N.L.M., Zakaria F.W., Ahmad Z., Ramdhan N., Hasan N.M., Rusgianto S., Lunar effect on stock returns and volatility: An empirical study of Islamic countries, Journal of Asian Finance, Economics and Business, 8 (5), 533-542, 2021.

26. Qi Y., Wang H., Zhang B., Long live Hermes! Mercury retrograde and equity prices, UNSW Business School, School of Banking and Finance, Sydney-Avustralya, 2021.

27. Herbst A.F., Lunacy in the stock market—what is the evidence?, Journal of Bioeconomics, 9 (1), 1-18, 2007.

28. Junkus J.C., Today is a 7 - A test of investing using astrology, Journal of the Academy of Finance, 18 (3), 112-130, 2023.

29. Nikolić L., An astrological genealogy of artificial intelligence: From 'pseudo-sciences' of divination to sciences of prediction, European Journal of Cultural Studies, 26 (2), 131-146, 2023.

30. Oughton, E. J., A. Skelton, R. B. Horne, A. W. P. Thomson, and C. T. Gaunt (2017), Quantifying the daily economic impact of extreme space weather due to failure in electricity transmission infrastructure, Space Weather, 15, 65–83.

31. Daglis, T., Konstantakis, K. N., Michaelides, P. G. (2019). Solar events and economic activity: Evidence from the US Telecommunications industry (1996–2014). Physica A: Statistical Mechanics and its Applications, 526, 121014.

32. TUA. https://www.tua.gov.tr/tr/haberler/gunes-te-yasanan-hizli-koronal-kutle-atimi-dunya-yi-siddetli-jeomanyetik-firtinaya-surukledi. Yayın tarihi Ekim 14, 2007. Erişim tarihi Haziran 14, 2025.

33. Alabdulgader, A., McCraty, R., Atkinson, M., Dobyns, Y., Vainoras, A., Ragulskis, M. Stolc, V., Long-term study of heart rate variability responses to changes in the solar and geomagnetic environment. Scientific Reports, 8, Article number: 2663, 2018.

34. Cherry, N., Schumann Resonances, a plausible biophysical mechanism for the human health effects of Solar/Geomagnetic Activity. Natural Hazards, 26, 279–331, 2002.

35. NASA. https://science.nasa.gov/learn/basics-of-space-flight/chapter5-1. Erişim tarihi Haziran 14, 2025.