

Makine Öğrenmesi ve Derin Öğrenme Yöntemleriyle Bitcoin Fiyat Tahmini: SHAP Analiziyle En Etkili Modelin Açıklanması

Osman Nuri Akarsu¹

Özet

Makine öğrenmesi ve derin öğrenme, son yıllarda finansal piyasalarda tahminleme süreçlerinde sıklıkla başvuru alan yöntemler arasında yer almaktadır. Bu yöntemler, özellikle yüksek oynaklığa sahip kripto para piyasalarında, yatırım kararlarını destekleyici araçlar olarak öne çıkmaktadır. Denetimli öğrenme algoritmaları, geçmiş verilere dayanarak gelecekteki fiyatları tahmin etmeye yönelik güçlü çözümler sunarken; derin öğrenme yaklaşımları, özellikle sıralı veri yapılarındaki karmaşık ilişkileri yakalamada avantaj sağlamaktadır. Bitcoin gibi dijital varlıkların ekonomik değişkenlerle olan ilişkisini anlamak, hem bireysel yatırımcılar hem de finansal kurumlar açısından stratejik bir gereklilik haline gelmiştir. Bu bağlamda açıklanabilir yapay zeka (XAI) teknikleri, tahmin modellerinin iç mantığını şeffaf biçimde ortaya koyarak karar destek sistemlerine katkı sunmaktadır. Bu çalışmada, Bitcoin'in (BTC) günlük kapanış fiyatları, altın, USDX, VIX ve Brent petrol gibi ekonomik göstergeler dikkate alınarak SVR, LSTM, XGBoost ve ANN algoritmaları ile tahmin edilmiştir. 2014–2024 dönemini kapsayan veri setiyle gerçekleştirilen analizde, MAPE, MAE ve R^2 gibi performans ölçütleri üzerinden karşılaştırma yapılmıştır. Sonuçlara göre, en yüksek doğruluk oranını SVR modeli göstermiştir. Ayrıca SHAP analizi kullanılarak BTCY (yükseliş), BTCD (düşüş) ve BTCA (açılış) değişkenlerinin tahmin sürecinde pozitif katkı sunduğu belirlenmiştir. Buna karşılık, AK (altın) ve BrPK (petrol) gibi dışsal faktörlerin olumsuz etkiler yarattığı gözlemlenmiştir. Elde edilen bulgular ile hem model doğruluğunu hem de değişkenlerin etkisini şeffaf biçimde ortaya koyarak literatüre önemli katkılar sunulmuştur.

1 Dr., osmannuriakarsu@gmail.com, ORCID ID: 0000-0002-5393-956X

1. Makine Öğrenimi ve Derin Öğrenme

Makine öğrenimi (ML) ve derin öğrenme (DL), yapay zeka içinde hem akademide hem de endüstride önemli ölçüde ilgi gören iki önemli alt alandır. Temel önerileri, örüntüleri ortaya çıkarmak ve tahminlerde bulunmak için veriye dayalı yöntemleri kullanmak ve robotikten doğal dil işlemeye kadar çeşitli alanlarda farklı bakış açıları geliştirmektir.

Makine öğrenimi, bilgisayarların açık talimatlar olmadan görevleri yerine getirmesini sağlayan, bunun yerine verilerden türetilen kalıplara ve çıkarımlara dayanan bir dizi algoritma ve istatistiksel model olarak tanımlanmaktadır (Hural, 2023). Makine öğrenimi içerisinde denetimli ve denetimsiz öğrenme, pekiştirmeli öğrenme ve uzman olmayanlar için makine öğrenimi modellerinin uygulanmasını basitleştirmeyi amaçlayan otomatik makine öğrenimi (AutoML) gibi çeşitli yaklaşımlar mevcuttur (Topsakal ve Akıncı, 2023). Makine öğreniminin etkinliği, eğitim verilerinden görülmeyen verilere genelleme yapma, aşırı uyum sağlama ve gerçek ve sahte örüntüleri belirleme gibi sorunları hafifletme becerisine önemli ölçüde bağlılık göstermektedir (Bashir vd., 2020). Başka bir ifadeyle makine öğrenimi, çevresel ortamdan öğrenerek insan zekasını taklit etmek amacıyla tasarlanmış hesaplama algoritmalarının evrimleşen bir dalıdır. Büyük verinin yeni çağında “iş atı” olarak kabul edilirler.

Makine öğrenimi temelli teknikler, desen tanıma, bilgisayar görüşü, uzay araştırmaları, eğlence, hesaplamalı biyoloji ve tıbbi uygulamalar da dahil olmak üzere çeşitli alanlarda başarıyla uygulanabilir (El Naqa, 2015). Bunların yanı sıra makine öğrenimi, imalat sanayi, finans ve biyomedikal gibi çeşitli alanlarda geniş uygulama alanına sahiptir. Temel görevleri arasında sınıflandırma, regresyon ve kümeleme yer almaktadır. Sınıflandırma ve regresyon, etiketli verilerle çalışan denetimli öğrenme yöntemleri iken; kümeleme, etiketlenmemiş verilerle çalışan denetimsiz öğrenme yaklaşımlarıdır. Sınıflandırma, örnekleri önceden tanımlanmış kategorilere ayırırken; regresyon, sayısal çıktıların tahminini hedeflemektedir. Her ikisi de gözlemlenen etiketli örneklerden yola çıkarak yeni bir örneğin çıktısını doğru tahmin etmeyi amaçlamaktadırlar. Kümeleme algoritmaları ise, verilerin içsel benzerliklerine göre gruplar oluşturarak örnekleri sınıflandırır (Al-Sahaf vd., 2019). Buna karşılık, çok katmanlı sinir ağlarını (yani derin mimarileri) kullanan bir makine öğrenimi alt kümesi olan derin öğrenme, yüksek boyutlu verilerden karmaşık temsilleri ve soyutlamaları öğrenmede oldukça etkilidir (Bengio, 2009). Derin öğrenmenin robotik gibi alanlara dahil edilmesi, ham duyuşal verilerden özellik çıkarma yoluyla robotik sistemleri hem algılama hem de karar verme yeteneklerini geliştirerek umut

verici sonuçları ortaya çıkarmaktadır (Sünderhauf vd., 2018; Ait Mouha, 2021). Derin sinir ağları (DNN'ler) özellikle geniş veri kümelerini işleme ve gerçek dünya uygulamalarının doğasında bulunan gürültü ve belirsizliklerin yarattığı zorlukların üstesinden gelme konusunda daha başarılı sonuçlara ulaşılmasını sağlamaktadır (Barbastathis vd., 2019). Sıralı veriler için özel olarak uyarlanmış Uzun Kısa Süreli Bellek (LSTM) ağlarını kullanan çalışmalarda vurgulandığı gibi bu analizler, görüntü ve konuşma tanımadan zaman serisi tahminine kadar çeşitli uygulamaların geliştirilmesine katkı sunmaktadır (Pongsena vd., 2021).

Derin öğrenmenin büyümesi yalnızca algoritmalarındaki ilerlemelere değil, aynı zamanda özellikle grafik işlem birimleri (GPU'lar) ve dağıtık hesaplama ile ilgili donanım yeteneklerindeki önemli adımlara da borçludur ve bu da karmaşık modellerin büyük veri kümeleri üzerinde eğitilmesini sağlamaktadır (Barbastathis vd., 2019). Bu durum nihayetinde makine öğrenimi gibi yeni paradigmaların ortaya çıkmasına yol açmış ve makine öğrenimi sürecinde sadece öğrenenlerin değil öğretenlerin de rolünü vurgulamıştır (Simard vd., 2017). Modellerin verilerden nasıl öğrendiğini anlamaya yönelik bu değişim, farklı alanlarda çalışabilen üretici modellerin oluşturulmasında hayati bir rol oynayan temsil öğrenmeye ilişkin içgörüler sağlamaktadır (Bengio vd., 2013). Dahası, derin öğrenme, modellerin daha önce hesaplanan kuantum verilerine dayanarak kimyasal kaymalar ve faz geçişleri gibi özellikleri tahmin edebildiği malzeme bilimi gibi diğer alanlarla sinerjik bir şekilde etkileşime girmektedir (Paruzzo vd., 2018; Tantardini vd., 2022). Bu teknolojilerin ekonomik etkileri, finans ve risk tahminine kadar uzanan uygulamalarla daha da genişlemektedir (Hural, 2023). Ayrıca, robotik gibi bağlamlarda derin öğrenmenin sınırlarını çevreleyen teoriler, potansiyel tuzakların ve daha geniş uygulanabilirlik için gerekli iyileştirmelerin giderek daha fazla kabul edildiğini göstermektedir (Sünderhauf vd., 2018; , Ait Mouha, 2021).

2. Literatür

Bitcoin fiyatlarındaki dalgalanmaların nedeninin ve yönünün doğru bir şekilde tahmin edilmesi, bu alana yatırım yapan finansal aktörler açısından hem riski azaltmak hem de yüksek getiri elde etmek amacıyla kritik bir önem taşımaktadır. Bu doğrultuda yapılan çalışmalar artış göstermiş olsa da, konunun literatürdeki geçmişi oldukça yenidir. Makine öğrenmesi (ML) ve derin öğrenme (DL) modellerinin Bitcoin kapanış değerlerinin tahmini amacıyla kullanımı, özellikle kripto paraların yüksek volatilitesi ve ABD Dolar Endeksi (USDx), altın fiyatları, VIX (Volatilite Endeksi) ve BrP (Brent Petrol) ekonomik göstergelerin etkisi göz önüne alındığında, son yıllarda araştırmaların odak noktalarından biri haline gelmiştir. Bu bölümde,

Bitcoin'e yönelik gerçekleştirilen araştırmalar; kullanılan yöntemler ve tercih edilen farklı öznitelikler açısından ayrıntılı biçimde ele alınacaktır.

Ji vd. (2019), derin öğrenme uygulamaları bağlamında, LSTM tabanlı modellerin diğer sınıflandırma yöntemlerine kıyasla daha başarılı sonuçlar verdiğini ve tahmin edilen fiyat hareketlerine dayalı işlem stratejilerinin finansal olarak uygulanabilir olduğunu ortaya koymuşlardır.

Uras vd. (2020), doğrusal regresyon ile sinir ağı modellerini karşılaştırarak kripto para birimlerinin günlük kapanış fiyatlarını tahmin etmiş ve sinir ağlarının daha yüksek tahmin başarısı sunduğunu yeniden teyit etmişlerdir.

Çelik vd., (2022), makine öğrenmesi yöntemlerinin Bitcoin'in kapanış değerlerini tahmin etmede etkili olduğunu belirtmiş ve bu yaklaşımların denetimli öğrenme senaryoları için uygulanabilirliğine dikkat çekmişlerdir. Çalışmalarında, tahmin edilen kapanış değerleri ile gerçek değerler karşılaştırılmış ve bu yöntemlerin piyasa eğilimlerini anlamada önemli içgörüler sağlayabileceği vurgulanmıştır.

Hayradi vd. (2022), destek vektör regresyon (SVR) algoritması ile Polkadot kripto para biriminin günlük kapanış fiyatını tahmin etmiş ve başarılı sonuçlar elde etmişlerdir.

Ye vd. (2022), Bitcoin fiyat dinamiklerine ilişkin analizlerine sosyal medya duyarlılığı (sentiment) verilerini entegre eden çok katmanlı topluluk bir derin öğrenme çerçevesi önermişlerdir. Bu modelin, geleneksel fiyat tahmin yöntemlerine kıyasla anlamlı düzeyde daha yüksek doğruluk sağladığı belirlenmiştir. Bu tür çalışmalar, teknolojik yaklaşımların sosyal veriyle bütünleşerek kripto para piyasalarının öngörülmesinde çok boyutlu modellerin geliştirildiğini ortaya koymaktadır.

Ngai vd. (2023), zaman serisi tahmini için SVR, KNN, XGBoost ve LSTM algoritmalarını kapsayan kapsamlı bir model geliştirmişlerdir. 2018–2023 dönemi kapanış fiyatları üzerine yapılan analizde, söz konusu modellerin fiyat hareketlerini etkin biçimde yakalayabildiği, özellikle LSTM'nin ardışık verilerde üstün performans gösterdiği tespit edilmiştir.

Shen (2023), doğrusal regresyon, Hiyerarşik Pekiştirmeli Öğrenme (HRL) ve LSTM yöntemlerini karşılaştırmalı olarak incelemiş, özellikle LSTM'nin Bitcoin fiyat tahmininde belirgin biçimde daha başarılı olduğunu ortaya koymuştur.

Chen (2023) tarafından gerçekleştirilen bir meta-analiz çalışmasında, Bitcoin tahminine yönelik farklı metodolojiler incelenmiş; rastgele ormanlar, yinlemeli sinir ağları ve çeşitli topluluk (ensemble) tekniklerinin,

geleneksel ekonometrik modellere kıyasla daha yüksek performans sunduğu belirtilmiştir.

Zhang (2024), 2014–2022 yılları arasındaki Bitcoin kapanış fiyatlarını tahmin etmek amacıyla Doğrusal Regresyon, Karar Ağaçları, Rastgele Ormanlar ve Çok Katmanlı Algılayıcılar (MLP) gibi çeşitli makine öğrenmesi algoritmalarını kullanmıştır. Bu çalışmada, model sağlamlığını güvence altına almak için çapraz doğrulama uygulanmış ve performans değerlendirmesinde RMSE, MAE ve R^2 gibi metriklerden yararlanılmıştır.

Al-Zakhali ve Abdulazeez (2024), geleneksel ve ileri düzey modellere yönelik karşılaştırmalı analizlerinde LSTM ve GRU gibi yapılarla birlikte Rastgele Orman (RF) algoritmasını kullanmışlardır. Araştırmada, RF modeli en yüksek doğruluğu sağlarken GRU ve SVM modelleri de dikkate değer başarı göstermiştir.

Zhao (2024) da benzer şekilde, doğrusal regresyon ile LSTM performansını karşılaştırmış ve ileri seviye sinir ağlarının, geleneksel makine öğrenmesi yöntemlerine göre Bitcoin tahmin görevlerinde sürekli olarak daha iyi sonuçlar verdiğini belirtmiştir.

Alizadegan vd. (2024) ise bu eğilimi destekleyerek, LSTM ve çift yönlü LSTM (Bi-LSTM) yapılarını öne çıkarmış ve bu modellerin dalgalı kripto para piyasalarında zaman serisi tahminleri için giderek daha fazla tercih edildiğini belirtmişlerdir.

Jin (2024), yaptığı çalışmada COVID-19 sonrası dalgalı finansal piyasalarda geleneksel ekonometrik modeller (ARIMA ve Holt's LES) ile gelişmiş makine öğrenimi tekniklerini (SVR, LSTM ve GRU) karşılaştırmıştır. S&P 500 ve SSE Endeksi'nin günlük hisse senedi fiyatları kullanılarak R^2 , RMSE, MAPE ve MAE metrikleriyle modellerin tahmin doğruluğu değerlendirilmiştir. Bulgular, ARIMA'nın kısa vadeli tahminlerde iyi performans gösterdiğini, ancak LSTM'nin uzun vadeli tahminlerde karmaşık, doğrusal olmayan desenleri yakalayarak üstün olduğunu ortaya koymuştur. Bu sonuçlar, LSTM'nin pandemi sonrası finansal piyasalarda en etkili model olduğunu göstermektedir.

Pogorelova (2024), ARDL modelini kullanarak VIX endeksi ile Bitcoin fiyat oynaklığı arasında anlamlı bir ilişki olduğunu göstermiştir. Bu bulgular, piyasa endişelerinin Bitcoin'in istikrarı üzerinde etkili olabileceğini ortaya koymaktadır.

Köse vd. (2025), küresel ekonomik değişkenlerin Bitcoin fiyatları üzerindeki etkilerini derinlemesine analiz etmiş; çalışmada LSTM, GRU, CNN ve Temporal Fusion Transformer (TFT) gibi derin öğrenme

algoritmalarının yanı sıra XGBoost ve LightGBM gibi geleneksel makine öğrenmesi modelleri kullanılmışlardır. Araştırmanın bulguları, özellikle altın fiyatlarının Bitcoin tahmininde en etkili değişken olduğunu ve TFT modelinin en yüksek doğruluğu sağladığını ortaya koymuşlardır.

Parkooi (2025), Bitcoin fiyat tahmininde doğruluğu artırmak amacıyla petrol ve altın fiyatlarını içeren fraksiyonel gri model (FGM) yöntemini uygulamıştır. Elde edilen sonuçlar, bu modelin dışsal ekonomik faktörlerin Bitcoin üzerindeki etkisini daha başarılı şekilde yansıttığını ve basit modellere göre daha iyi sonuçlar verdiğini göstermiştir.

3. Yöntem

Bu bölümde, Bitcoin fiyat tahmini amacıyla kullanılan makine öğrenmesi (ML) ve derin öğrenme (DL) yöntemleri detaylandırılmış; verilerin işlenmesi, modelleme süreci ve performans analizleri açıklanmıştır.

3.1. Araştırma Modelleri

Makine öğrenmesi, farklı disiplinlerde yaygın şekilde kullanılan ve geleneksel bilgisayar yöntemleriyle çözülemeyen karmaşık problemlerin çözümünde fayda sağlayan bir yaklaşımdır (Abdullah vd., 2021). Bu yöntem, tahminleme süreçlerini geliştirmek amacıyla bilgisayar bilimi ile istatistiksel analizi bir araya getirmektedir. Veriye dayalı tahminleme ile belirsizliklerin azaltılmasına katkı sunmaktadır. Makine öğrenmesi algoritmaları genel olarak denetimli ve denetimsiz olmak üzere iki ana gruba ayrılmaktadır. Denetimli algoritmalar etiketli verilerle öğrenirken, denetimsiz algoritmalar yalnızca veri örüntülerini analiz ederek çıkarımlar üretmektedir. Regresyon modelleri bağımlı değişkenler ile bağımsız değişkenler arasındaki ilişkiyi tahmin etmektedir. Makine öğrenmesi ise daha karmaşık problemleri ele almaktadır (Kavitha vd., 2016).


Bu çalışmada 4 farklı algoritma kullanılmış olup bunlar sırasıyla Destek Vektör Makineleri (Support Vector Machines) SVM, Uzun Kısa Süreli Bellek (Long Short-Term Memory) LSTM, Aşırı Gradyan Güçlendirme (Extreme Gradient Boosting) XGBoost ve Yapısal Sinir Ağları (Artificial Neural Network) ANN yöntemleridir. Kullanılan algoritmalardan ilki SVM modelidir.

3.1.1 Destek Vektör Makineleri (Support Vector Machines-SVM)

SVM, sınıflandırma problemlerine yönelik etkili bir makine öğrenmesi yöntemidir. Az sayıda veriden yüksek doğrulukla öğrenme kapasitesine sahiptir ve doğrusal olarak ayrılabilen verileri sınıflandırmada başarılıdır.

SVM, verileri n-boyutlu bir uzayda ayıran en iyi hiperdüzlemi belirleyerek, yeni verilerin doğru kategorilere atanmasını sağlar. Özellikle büyük veri kümelerinde Yapay Sinir Ağları'na (ANN) göre daha hızlı ve verimli çalışabilmektedir (Chhajer vd., 2022). SVM hiperdüzlem aşağıdaki Şekil 1'de gösterilmektedir.

Şekil 1. SVM Hiperdüzlem




Kaynak: (Ahmadi vd., 2018; Chhajer vd., 2022).

3.1.2 Uzun Kısa Süreli Bellek (Long Short-Term Memory-LSTM)

Uzun Kısa Vadeli Bellek (LSTM), Tekrarlayan Sinir Ağları (RNN)'nin bir türüdür ve geçmiş bilgileri uzun süreli olarak hafızada tutabilir. Geleneksel RNN'lerin aksine, LSTM yapıları "hafıza hattı" ve kapı mekanizmaları sayesinde uzun dönemli bağımlılıkları öğrenmede daha etkilidir. Bu özelliğiyle zaman serisi tahminlerinde sıkça kullanılmaktadır. Şekil 2'de LSTM düğümlerinin yapısını açıklamaktadır.

Şekil 2. LSTM'nin İç Yapısı



Kaynak: (Chen, 2022).

3.1.3 Aşırı Gradyan Güçlendirme (Extreme Gradient Boosting-XGBoost)

Aşırı Gradyan Artırma (Extreme Gradient Boosting – XGBoost), genellikle karar ağaçları temelli bir model topluluğu oluşturarak tahmin gücünü artırmayı amaçlayan güçlü bir topluluk öğrenme (ensemble learning) algoritmasıdır. Sinir ağlarında olduğu gibi modelin öğrenme sürecinde hata fonksiyonunu minimize etmek için gradyan iniş (gradient descent) yöntemini kullanır. Gradyan artırma yönteminin gelişmiş bir versiyonu olan XGBoost, modelin aşırı öğrenmesini (overfitting) önlemeye yardımcı olurken aynı zamanda genel performansını da iyileştirmektedir (Sarker, 2021).

Bu algoritma, hem büyük ölçekli veri setlerinde yüksek işlem verimliliği sağlayabilmesi hem de yorumlanabilirliği kolaylaştıran yapısıyla öne çıkmaktadır. Veri madenciliği yarışmalarında elde ettiği başarılar, XGBoost'un güçlü bir alternatif olarak yaygın biçimde tercih edilmesini sağlamıştır. Ayrıca, özelleştirilebilir değerlendirme fonksiyonları ve hiperparametre ayarlama olanakları sayesinde hem akademik çalışmalarda hem de endüstriyel uygulamalarda geniş bir kullanım alanı bulmuştur. XGBoost, hem regresyon


hem de sınıflandırma problemleri için etkili çözümler sunabilmektedir (Terko vd., 2019).

3.1.4 Yapay Sinir Ağları (ANN)

Günümüz dünyasında, makine öğrenimi olmadan herhangi bir endüstriyel faaliyetin gerçekleşmesi neredeyse imkânsızdır. Makine öğrenimi, karmaşık sorunları kolayca tanıyabildiği ve bunlara çözümler sunabildiği için oldukça faydalı bir yöntemdir. Makine öğrenimi, Facebook, Netflix ve Amazon'dan gelen öneri motorları kullanılarak günlük hayatta uygulanmaktadır. Siri, Alexa ve Google Asistan, makine öğrenimini birincil olarak kullanan sanal asistan örnekleridir.

Yapay Sinir Ağları (Artificial Neural Networks), insan beyninden daha karmaşık ve karmaşık bir bağlantı ağı üzerine kurulu bir yöntemdir. Ayrıca yöntem, bilgiyi bir modele veya zaman serisi hattına yönlendirmeyi amaçlayan cebirsel denklemlere dayanmaktadır (Chhajer vd., 2022). Yapay Sinir Ağları yönteminin aşamaları Şekil 3'de verilmiştir.

Şekil 3. Yapay Sinir Ağları



Kaynak: (Ustalı vd., 2021).

3.2 Veri Seti


Araştırmada Bitcoin (BTC) ait 02/10/2014-31/12/2024 tarihleri arasındaki 2674 adet günlük fiyat hareketleri ile birlikte altın, ABD Dolar Endeksi (USDIX), Volatilite Endeksi (VIX) ve Brent Petrol (BrP) günlük kapanış değerleri öznitelik olarak belirlenip öznitelik veri kümesi oluşturulmuştur.

Tablo 1. Değişken Tanımları ve Kaynak

Değişken	Değişken Tanımları	Kaynak
BTC	Bitcoin günlük kapanış değerleri.	Matriks
BTCA	Bitcoin günlük açılış değerleri.	Matriks
BTCY	Bitcoin günlük yüksek değerleri.	Matriks
BTCD	Bitcoin günlük düşüş değerleri.	Matriks
Altın	Altın günlük kapanış değerleri.	Investing.com
USDY	ABD Dolar Endeksi günlük kapanış değerleri.	Matriks
VIX	Volatilite Endeksi günlük kapanış değerleri.	Investing.com
BrP	Brent Petrol günlük kapanış değerleri.	Investing.com

Bitcoin değerinin Eğitim ve Test verileri değişimleri Şekil 4'te gösterilmektedir.

Şekil 4. Veri Setinin Bölünmesi



3.3 Performans Ölçütleri

Çalışmamızda performans ölçütü olarak R^2 , MAPE'nin yanı sıra MSE ve MAE gibi yaygın performans metriklerini de kullanmayı tercih ettik. Bu metrikler, literatürde yaygın olarak kullanılmakta ve tahmin modellerinin doğruluğunu değerlendirmede önemli bir rol oynamaktadır. Bu ölçütler aşağıdaki gibi açıklanmaktadır.

MAE: Ortalama mutlak hata, tahmin edilen ve gerçekleşmiş değerler arasındaki farktır. Bu farklar toplanırken mutlak değer alınmaktadır. Bütün farklar toplandıktan sonra toplam miktarına bölünüp ortalama değer hesaplanmaktadır (Kurucan, 2019).

MSE: Ortalama kare hata, bir modelden tahmin edilen tahmin edilen değerler ile gerçek değerler arasındaki ortalama kare farkını temsil etmektedir (Moghaddam vd., 2016).

MAPE: Ortalama mutlak yüzde hata göstergeleri, tahmin edilen değerlerin gerçek değerlerden ne kadar uzağa yayıldığını analiz etmek için kullanılmaktadır (Demir ve Sağlam, 2023).

R-squared (R^2): R-kare, yararlılığı ve sınırlamaları uygulamalı araştırmacı tarafından az çok bilinen, yaygın olarak kullanılan bir uyum iyiliği ölçüsüdür. İstatistikte, R-kare olarak gösterilen belirleme katsayısı, verilerin istatistiksel modellere ne kadar iyi uyduğunu gösteren bir değerdir (Cameron ve Windmeijer, 1997).

3.4 Bulgular

Çalışmada yer alan değişkenlere ilişkin tanımlayıcı istatistikler sunulmaktadır. Bu istatistikler; ortalama (Ort.), standart sapma (Std.), minimum (Min) ve maksimum (Max) değerleri içermekte olup, değişkenlerin dağılımı ve genel eğilimleri hakkında ön bilgi sağlamaktadır.

	Ort.	Std.	Min	Max
USD XK	96,40104	6,478124	79,14	114,11
VIX K	17,9588	7,151772	9,14	82,69
AK	1536,304	339,6363	1050,8	2511,3
BTCA	19613,66	22070,47	176,897	106147,3
BTCY	20102,11	22618,59	215,241	108268,4
BTCD	19102,56	21502,79	171,51	105291,7
BTCK	19636,85	22096,73	178,103	106140,6
BrPK	69,23278	20,76246	19,33	127,98

Bu çalışmada, 4 farklı model kullanılmış olup farklı tahmin grafikleri ve performans ölçütleri elde edilmiş ve Tablo 2’de sunulmuştur.


Tablo 2. Model Performans Sonuçları

Modeller	MAE	MSE	MAPE%	R ²
SVM	826,355	10,035	2,235	0,997
LSTM	1381,583	10,015	2,734	0,996
XGBoost	4640,785	80,602	8,813	0,807
ANN	2766,734	11,498	7,562	0,972

Tablo 2'deki sonuçlar incelendiğinde, dört farklı modelin Bitcoin kapanış değerlerini tahmin etme performansları karşılaştırılmıştır. Elde edilen değerlere göre, en düşük MAE (826,355), MSE (10,035) ve MAPE (%2,235) oranlarıyla SVM modeli en başarılı tahmin performansını göstermiştir. Bunu, benzer şekilde düşük hata oranlarına ve yüksek R² değerine (0,996) sahip olan LSTM modeli takip etmektedir. ANN modeli, MAE (2766,734) ve MAPE (%7,562) açısından orta düzeyde bir performans sergilerken, R² skoru (0,972) ile yüksek doğruluk sunmaktadır. Buna karşın, XGBoost modeli, diğer modellere kıyasla en yüksek hata oranlarına (MAE: 4640,785; MAPE: %8,813) ve en düşük R² değerine (0,807) sahiptir. Bu sonuçlar, özellikle zaman serisi tabanlı derin öğrenme yöntemlerinin (LSTM) ve destek vektör makinelerinin (SVM), Bitcoin fiyat tahminlerinde daha güvenilir ve etkili yaklaşımlar sunduğunu göstermektedir.


Bitcoin gibi yüksek oynaklığa sahip finansal varlıkların gelecekteki fiyat hareketlerini öngörebilmek, yatırım kararları açısından büyük önem taşımaktadır. Bu kapsamda, farklı makine öğrenmesi ve derin öğrenme modellerinin tahmin başarısını karşılaştırmak amacıyla SVM, LSTM, XGBoost ve ANN algoritmaları uygulanmıştır. Aşağıda, her bir modelin gerçek kapanış değerleriyle tahmin edilen değerler arasındaki uyumu görsel olarak sunulmakta ve modellerin zaman serisi üzerindeki tahmin performansları karşılaştırmalı biçimde değerlendirilmektedir.

Şekil 5. Modellerin Gerçek ve Tahmin Edilen Değerlerle Performans Grafiği



Şekil 5'te yer alan grafikler, SVM, LSTM, XGBoost ve ANN modellerinin Bitcoin kapanış değerlerine ilişkin tahmin performanslarını gerçek verilerle karşılaştırmalı olarak sunmaktadır. Görsel incelemeye göre, SVM ve LSTM modelleri tahmin eğrileri ile gerçek değerler arasında yüksek oranda örtüşme sergileyerek güçlü bir uyum göstermektedir. Özellikle SVM modeli, zaman serisindeki ani fiyat değişimlerini başarılı biçimde yakalayabilmektedir. XGBoost modeli ise genel trendi takip edebilmekle birlikte, ani yükseliş ve düşüşlerde daha sınırlı bir tepki vererek doğruluk açısından geride kalmaktadır. ANN modeli, genel eğilimi makul düzeyde yansıtmakla birlikte bazı dönemlerde sapmalar göstermektedir. Bu grafiksel analiz, istatistiksel metriklerle elde edilen bulguları görsel olarak da desteklemekte ve özellikle SVM ile LSTM modellerinin Bitcoin fiyat tahmini açısından daha tutarlı ve güvenilir sonuçlar ürettiğini ortaya koymaktadır.


Farklı makine öğrenmesi ve derin öğrenme modellerinin tahmin doğruluklarını karşılaştırmak amacıyla, gerçek ve tahmin edilen değerler arasındaki ilişkiyi gösteren R^2 performans grafikleri oluşturulmuştur. Şekil 6'da yer alan bu grafikler, her bir modelin tahmin kapasitesini görsel olarak değerlendirme imkânı sunmaktadır.

Şekil 6. Modellerin Performans R^2 Grafikleri

Şekil 6'da yer alan R^2 performans grafiklerine göre, tüm modellerin gerçek ve tahmin edilen değerler arasındaki ilişki seviyesi görsel olarak değerlendirilmiştir. SVM modeli, $R^2=0.997$ ile gerçek değerlere en yakın tahminleri sunarak en yüksek doğruluk oranını yakalamıştır. LSTM modeli de $R^2=0.996$ değeriyle benzer şekilde güçlü bir tahmin performansı göstermiştir. ANN modeli, $R^2=0.972$ ile istikrarlı sonuçlar üretmiş olsa da bazı sapmalar dikkat çekmektedir. Öte yandan, XGBoost modeli $R^2=0.807$ ile en düşük korelasyon düzeyine sahip olup, özellikle yüksek değerlerde tahmin hatalarının arttığı gözlemlenmektedir. Bu grafikler, sayısal metriklerle elde edilen model karşılaştırmalarını görsel olarak desteklemekte ve SVM ile LSTM'nin tahmin başarısında öne çıktığını ortaya koymaktadır.

Şekil 7'de, renk skalası her bir bağımsız değişkenin model performansına katkısını görsel olarak temsil etmektedir. Mavi tonlar düşük, kırmızı tonlar ise yüksek etki derecelerini göstermektedir. Bu sayede yedi değişkenin etki düzeyleri açık şekilde ortaya konmuştur.

Şekil 7. SVM Modelinde Bağımsız Değişkenlerin Bitcoin Kapanış Değeri Üzerindeki Etki Dereceleri (7 Değişken)



Şekil 7’de sunulan SHAP özet grafiği, en yüksek doğruluk performansını gösteren SVM modeli temel alınarak oluşturulmuştur ve bağımsız değişkenlerin Bitcoin kapanış değeri üzerindeki etkilerini açıklayıcı bir şekilde ortaya koymaktadır. Şekil 7’de, her bir değişkenin model çıktısına katkısını hem büyüklük hem de yön açısından görselleştirmektedir. Özellikle BTCY (yükseliş oranı), BTCD (düşüş oranı) ve BTCA (açılış fiyatı) değişkenlerinin SHAP değerlerinin pozitif bölgede yoğunlaştığı ve yüksek değer aralıklarında model tahminine olumlu katkı sağladığı dikkat çekmektedir. Bu durum, söz konusu değişkenlerin artışının model tarafından Bitcoin kapanış değerinde yükselme olarak yorumlandığını göstermektedir.

Diğer taraftan, USDXK (döviz kuru) ve VIXK (volatilite endeksi) gibi makroekonomik göstergelerin SHAP değerleri genel olarak sıfıra yakın ve her iki yönde de dağılmış durumdadır. Bu da bu değişkenlerin model üzerindeki etkisinin sınırlı ve bağlama göre değişken olduğunu göstermektedir. AK (altın fiyatı) ve BrPK (Brent petrol fiyatı) gibi dışsal faktörlerin ise çoğunlukla negatif SHAP değerleriyle model çıktısını baskıladığı, yani bu değişkenlerdeki artışın Bitcoin kapanış tahminlerini düşürücü yönde etkilediği görülmektedir. Bu analiz, sadece modelin yüksek performansını değil, aynı zamanda hangi değişkenlerin fiyat tahmini sürecinde belirleyici olduğunu da ortaya koyarak modelin yorumlanabilirliğini artırmaktadır.

4. Sonuçlar

Finansal sektör, ekonomik yapının temel bir bileşeni olarak görülmektedir. Finans sektörü, yüksek kazanç potansiyeli taşıyan projelere sermaye akışını hızlandırabilmekte ve mali kaynakların verimli bir biçimde dağıtılmasını mümkün kılabilir (Güneysu ve Ergün, 2024).

Finansal ortam, kripto para birimlerinin, özellikle Bitcoin'in entegrasyonu tarafından derinden etkilenmiştir. Öncü bir dijital varlık olarak Bitcoin, fiyat tahminleri ve geleneksel finansal sistemlerle olan ilişkisi konusunda kapsamlı araştırmalara yol açmıştır. Bitcoin fiyatlarını tahmin etmek için gelişmiş matematiksel ve istatistiksel tekniklerden yararlanan çeşitli tahmin modelleri ortaya çıkmıştır. Literatüre bakıldığında; Bitcoin'in fiyat dalgalanmalarını analiz etmek için Otoregresif Entegre Hareketli Ortalama (ARIMA) modelini kullanarak, modelin kripto para piyasalarındaki eğilimleri ve oynaklığı açıklamadaki etkinliğini göstermektedir (Huo vd., 2024). Benzer şekilde, Loh, Bitcoin fiyat tahminlerinin doğruluğunu artırmada makine öğrenimi tekniklerinin, özellikle de Sinir Ağlarının etkinliğini tartışarak, gelişmiş hesaplama yöntemlerinin fiyat dinamiklerini anlamaya önemli ölçüde katkıda bulunduğunu öne sürmektedir (Loh, 2020).

Bitcoin'deki oynaklığın araştırılması, geleneksel finansal varlıklarla paralellikler kurarak, akademik araştırmaların önemli bir alanı olmaya devam etmektedir. Bu bağlamda, d., (2021) Bitcoin ve diğer finansal araçlar arasındaki oynaklık sürprizlerinin karşılaştırmalı bir analizini sunarak, makroekonomik değişkenlerin fiyat hareketlerini önemli ölçüde etkileyebileceğini belirtmişlerdir (Doumenis vd., 2021). Bu tür analizler, Bitcoin'in davranışının belirli koşullar altında bazen geleneksel varlık sınıflarıyla benzerlikler gösterdiği için, yatırımcıların ve politika yapıcıların finansal ekonominin daha geniş çerçevesi içinde Bitcoin'i incelikli bir şekilde anlamaları gerektiğini vurgulanmaktadır.

Bu çalışmada, Bitcoin (BTC) kapanış fiyatlarının tahmini amacıyla SVR, LSTM, ANN ve XGBoost olmak üzere dört farklı makine öğrenimi yöntemi karşılaştırılmış ve en başarılı modelin SVR (Destek Vektör Regresyonu) olduğu tespit edilmiştir. Model başarıları MAPE, MAE, RMSE ve R^2 gibi performans ölçütleri üzerinden değerlendirilmiş; SVR modelinin düşük hata oranları ve yüksek doğruluk katsayısı ile diğer modelleri geride bıraktığı görülmüştür. Bu bulgular, literatürde SVR'nin sınırlı veri ve karmaşık ilişkilere sahip finansal tahmin problemlerinde üstün performans gösterdiğini ifade eden çalışmaları desteklemektedir (Chen ve Hao, 2017; Kara vd., 2011).

Literatürde SVR modellerinin Bitcoin fiyat tahmininde başarılı sonuçlar verdiği birçok çalışmada ortaya konmuştur (Chowdhury vd., 2018; Gyamerah, 2021; Barjašić ve Antulov-Fantulin, 2021; Borrero ve Mariscal, 2023; Ngai vd., 2023; Tripathi ve Sharma, 2023). Benzer şekilde, bu çalışmada da SVR tabanlı model en yüksek tahmin doğruluğunu göstermiş; özellikle BTCY, BTCD ve BTCA değişkenlerinin model üzerindeki pozitif etkisi SHAP analizi ile açıkça ortaya konarak SVR'nin finansal zaman serilerindeki güçlü performansını bir kez daha doğrulamıştır.

Bitcoin fiyat tahmininde en başarılı performansı gösteren SVM modeli temel alınarak gerçekleştirilen SHAP analizi, modelin karar sürecinde etkili olan değişkenleri açıklayıcı biçimde ortaya koymuştur. Analize göre, BTCY (yükseliş oranı), BTCD (düşüş oranı) ve BTCA (açılış fiyatı) değişkenleri model tahminlerinde en yüksek pozitif katkıyı sağlayan değişkenler olarak öne çıkarken; AK (altın fiyatı) ve BrPK (Brent petrol fiyatı) gibi dışsal ekonomik göstergeler negatif etki göstermiştir. USDXX (döviz kuru) ve VIXX (volatilite endeksi) ise model üzerinde daha sınırlı ve bağlamsal etkiler yaratmıştır. Bu bulgular, modelin yorumlanabilirliğini artırmakta ve yatırım kararları açısından hangi değişkenlerin belirleyici olduğunu ortaya koyarak daha şeffaf bir tahmin süreci sağlamaktadır.

Literatürde, altın ve Brent petrol fiyatlarının Bitcoin üzerindeki etkilerine dair bulgular hem negatif hem de pozitif yönlü sonuçlar ortaya koymaktadır. Örneğin, Gunawan vd., (2021), COVID-19 sonrasında altının güvenli liman işlevini yeniden kazandığını ve bu durumun yatırımcıların Bitcoin yerine altına yönelmesine neden olarak BTC üzerinde negatif bir baskı oluşturduğunu belirtmiştir. Benzer şekilde, Tang ve Aruga (2021) ile Zhang vd., (2022), kriz dönemlerinde petrol ve Bitcoin arasındaki korelasyonun arttığını ve bunun Bitcoin'in çeşitlendirme aracı rolünü zayıflattığını ifade ederek petrol fiyatlarındaki artışın BTC'ye olumsuz yansıdığını ortaya koymuştur. Buna karşın, Nasution vd., (2023), altın fiyatlarının Bitcoin getirileri üzerinde hafif pozitif bir etkisi olduğunu vurgularken, Nguyen vd., (2024), geleneksel varlıklardan çıkan yatırımcıların Bitcoin'e yönelmesinin ters yönlü ama zaman zaman pozitif tepkilere neden olabileceğini göstermektedir. Ayrıca Jiang vd., (2021) ise altın ile Bitcoin arasında zayıf da olsa pozitif korelasyon gözlemlerken, Liu vd., (2023) ve Murty vd., (2022) gibi çalışmalar altın ve petrolün Bitcoin'e kıyasla daha istikrarlı güvenli limanlar olduğunu belirtmişler ve BTC'nin bu varlıklardan farklılaştığını vurgulamışlardır. Bu çalışmalar, BTC'nin geleneksel emtialarla ilişkisini bağlama bağlı olarak hem destekleyici hem de zayıflatıcı şekilde etkilenebileceğini ortaya koymaktadır.

Çalışmanın bulguları, yatırım stratejileri geliştirirken geleneksel finansal değişkenlerin BTC fiyatlarına olan etkisinin göz ardı edilemeyeceğini göstermekte ve bu alanda yapılacak daha derinlemesine analizler için temel oluşturmaktadır. Ayrıca, SHAP tabanlı açıklanabilir yapay zeka uygulamaları ile yatırım karar süreçlerinde şeffaflığın artırılması ve model sonuçlarının yorumlanabilirliğinin sağlanması açısından bu çalışma literatüre katkı sağlayıcı niteliktedir.

5. Kaynaklar

- Abdullah, D. M., Abdulazeez, A. M., & Sallow, A. B. (2021). Lung cancer prediction and classification based on correlation selection method using machine learning techniques. *Qubahan Academic Journal*, 1(2), 141-149.
- Ahmadi, E., Jasemi, M., Monplaisir, L., Nabavi, M. A., Mahmoodi, A., & Jam, P. A. (2018). New efficient hybrid candlestick technical analysis model for stock market timing on the basis of the Support Vector Machine and Heuristic Algorithms of Imperialist Competition and Genetic. *Expert Systems with Applications*, 94, 21-31.
- Ait Mouha, R. (2021). Deep learning for robotics. *Journal of Data Analysis and Information Processing*, 9(02), 63.
- Alizadegan, H., Radmehr, A., & Ilani, M. A. (2024). Forecasting Bitcoin prices: A comparative study of machine learning and deep learning algorithms.
- Al-Sahaf, H., Bi, Y., Chen, Q., Lensen, A., Mei, Y., Sun, Y., ... & Zhang, M. (2019). A survey on evolutionary machine learning. *Journal of the Royal Society of New Zealand*, 49(2), 205-228.
- Al-Zakhali, O. A., & Abdulazeez, A. M. (2024). Comparative analysis of machine learning and deep learning models for bitcoin price prediction. *The Indonesian Journal of Computer Science*, 13(1).
- Barbastathis, G., Ozcan, A., & Situ, G. (2019). On the use of deep learning for computational imaging. *Optica*, 6(8), 921-943.
- Barjašić, I., & Antulov-Fantulin, N. (2021). Time-varying volatility in bitcoin market and information flow at minute-level frequency. *Frontiers in Physics*, 9, 644102.
- Bashir, D., Montañez, G. D., Sehra, S., Segura, P. S., & Lauw, J. (2020). An information-theoretic perspective on overfitting and underfitting. In *AI 2020: Advances in Artificial Intelligence: 33rd Australasian Joint Conference, AI 2020, Canberra, ACT, Australia, November 29–30, 2020, Proceedings 33* (pp. 347-358). Springer International Publishing.
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and trends® in Machine Learning*, 2(1), 1-127.
- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798-1828.
- Borrero, J. D., & Mariscal, J. (2023). Elevating univariate time series forecasting: Innovative SVR-empowered nonlinear autoregressive neural networks. *Algorithms*, 16(9), 423.
- Cameron, A. C., & Windmeijer, F. A. (1997). An R-squared measure of goodness of fit for some common nonlinear regression models. *Journal of econometrics*, 77(2), 329-342.

- Chen, J. (2023). Analysis of bitcoin price prediction using machine learning. *Journal of risk and financial management*, 16(1), 51.
- Chen, Y., & Hao, Y. (2017). A feature weighted support vector machine and K-nearest neighbor algorithm for stock market indices prediction. *Expert Systems with Applications*, 80, 340-355.
- Chen, Y., Wu, J., & Wu, Z. (2022). China's commercial bank stock price prediction using a novel K-means-LSTM hybrid approach. *Expert Systems with Applications*, 202, 117370.
- Chhajer, P., Shah, M., & Kshirsagar, A. (2022). The applications of artificial neural networks, support vector machines, and long-short term memory for stock market prediction. *Decision Analytics Journal*, 2, 100015.
- Chowdhury, U. N., Chakravarty, S. K., & Hossain, M. T. (2018). Short-term financial time series forecasting integrating principal component analysis and independent component analysis with support vector regression. *Journal of Computer and Communications*, 6(03), 51.
- Çelik, İ. E., Arslan, M., Kuzu, S., & Yavuz, D. Ö. (2022). Researching the future of Bitcoin market with machine learning method: An application on the case of Turkey. *EKEV Akademi Dergisi*.
- Demir, A. S., & Sağlam, E. B. (2023). Electricity consumption estimation with differential polynomial and artificial neural networks: Case of Türkiye. *Journal of Engineering Research*, 11(3), 176-181.
- Doumenis, Y., Izadi, J., Dhamdhere, P., Katsikas, E., & Koufopoulos, D. (2021). A critical analysis of volatility surprise in Bitcoin cryptocurrency and other financial assets. *Risks*, 9(11), 207.
- El Naqa, I., & Murphy, M. J. (2015). What is machine learning?. In *Machine learning in radiation oncology: theory and applications* (pp. 3-11). Cham: Springer International Publishing.
- Gunawan, D., Sinurat, M., Cahyadi, L., & Ilham, R. N. (2021, February). Investigating the Dynamic Relationship Among JKSE, S&P 500, Cryptocurrencies and Gold Price After Covid-19 Outbreak. In *International Conference on Strategic Issues of Economics, Business and, Education (ICoSIE-BE 2020)* (pp. 71-75). Atlantis Press.
- Güneysu, Y., & Ergün, T. (2024). Dijital Finansın Bankacılık Sektörü İstikrarına Etkisi: Avrupa ve Orta Asya Ülkeleri (ECA) Örneği. *Uluslararası Ekonomi ve Yenilik Dergisi*, 10(2), 365-382.
- Gyamerah, S. A. (2021). Two-Stage Hybrid Machine Learning Model for High-Frequency Intraday Bitcoin Price Prediction Based on Technical Indicators, Variational Mode Decomposition, and Support Vector Regression. *Complexity*, 2021(1), 1767708.
- Haryadi, D., Hakim, A. R., Atmaja, D. M. U., & Yutia, S. N. (2022). Implementation of support vector regression for polkadot cryptocurrency price

- prediction. *JOIV: International Journal on Informatics Visualization*, 6(1-2), 201-207.
- Huo, L., Xie, Y., & Li, J. (2024). An Innovative Deep Learning Futures Price Prediction Method with Fast and Strong Generalization and High-Accuracy Research. *Applied Sciences*, 14(13), 5602.
- Hural, I. (2023). *Application of machine learning for economic trends and risk prediction*. Publishing House "Baltija Publishing.
- Ji, S., Kim, J., & Im, H. (2019). A comparative study of bitcoin price prediction using deep learning. *Mathematics*, 7(10), 898.
- Jiang, S., Li, Y., Lu, Q., Hong, Y., Guan, D., Xiong, Y., & Wang, S. (2021). Policy assessments for the carbon emission flows and sustainability of Bitcoin blockchain operation in China. *Nature communications*, 12(1), 1938.
- Jin, S. (2024). A Comparative Analysis of Traditional and Machine Learning Methods in Forecasting the Stock Markets of China and the US. *International Journal of Advanced Computer Science & Applications*, 15(4).
- Kara, Y., Boyacioglu, M. A., & Baykan, Ö. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert systems with Applications*, 38(5), 5311-5319.
- Kavitha, S., Varuna, S., & Ramya, R. (2016, November). A comparative analysis on linear regression and support vector regression. In *2016 online international conference on green engineering and technologies (IC-GET)* (pp. 1-5). IEEE.
- Köse, N., Gür, Y. E., & Ünal, E. (2025). Deep Learning and Machine Learning Insights Into the Global Economic Drivers of the Bitcoin Price. *Journal of Forecasting*.
- Kurucan, F. (2019). Büyük veri ve finansal piyasalarda istatistiki makine öğrenmesi metodlarının yatırım kararlarında kullanılması (Yüksek lisans tezi, Sosyal Bilimler Enstitüsü).
- Liu, Y., Naktnasukanjn, N., Tamprasirt, A., & Rattanadamrongaksorn, T. (2023). Comparison of the asymmetric relationship between bitcoin and gold, crude oil, and the US dollar before and after the COVID-19 outbreak. *Journal of Risk and Financial Management*, 16(10), 455.
- Loh, E. C., & Ismail, S. (2020). Emerging trend of transaction and investment: bitcoin price prediction using machine learning. *International Journal*, 9(1.4).
- Moghaddam, A. H., Moghaddam, M. H., & Esfandyari, M. (2016). Stock market index prediction using artificial neural network. *Journal of Economics, Finance and Administrative Science*, 21(41), 89-93.

- Murty, S., Victor, V., & Fekete-Farkas, M. (2022). Is bitcoin a safe haven for Indian investors? A GARCH volatility analysis. *Journal of Risk and Financial Management*, 15(7), 317.
- Nasution, M. R., Sadalia, I., & Irawati, N. (2023, September). Empirical Case Among Explanatory Asset, Financial Asset Dan Macro-Economic on Return Bitcoin. In *20th International Symposium on Management (INSYMA 2023)* (pp. 51-56). Atlantis Press.
- Ngai, E., Abdullah, S., Nazri, M. Z. A., Sani, N. S., & Othman, Z. (2023). Time series prediction of Bitcoin cryptocurrency price based on machine learning approach. *Data Science: Journal of Computing and Applied Informatics*, 7(2), 81-95.
- Ngai, E., Abdullah, S., Nazri, M. Z. A., Sani, N. S., & Othman, Z. (2023). Time series prediction of Bitcoin cryptocurrency price based on machine learning approach. *Data Science: Journal of Computing and Applied Informatics*, 7(2), 81-95.
- Nguyen, L. T. H., Vu, H. H., & Le, A. P. (2024). Testing bitcoin's safe-haven property and the correlation between Bitcoin, gold, oil, stock markets, and Google trends. *Investment Management & Financial Innovations*, 21(2), 103.
- Parkoohi, J. R., Heidari, H., & Malek, A. (2025). Predicting Changes in Bitcoin Price Using Fractional Grey Model. In *Blockchain, Crypto Assets, and Financial Innovation* (pp. 234-251). Springer, Singapore.
- Paruzzo, F. M., Hofstetter, A., Musil, F., De, S., Ceriotti, M., & Emsley, L. (2018). Chemical shifts in molecular solids by machine learning. *Nature communications*, 9(1), 4501.
- Pogorelova, P. (2024). Investigation of the impact of uncertainty indices on Bitcoin volatility using the ARDL model. *Applied Econometrics*, 74, 35-50.
- Pongsena, W., Sitsayabut, P., Kerdprasop, N., & Kerdprasop, K. (2021). Development of a model for predicting the direction of daily price changes in the forex market using long short-term memory. *International Journal of Machine Learning and Computing*, 11(1), 61-67.
- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN computer science*, 2(3), 160.
- Shen, H. (2023, November). Valuating Cryptocurrency Assets using Linear Regression, HRL, and LSTM: Machine Learning Evidence. In *2023 International Conference on Finance, Trade and Business Management (FTBM 2023)* (pp. 535-543). Atlantis Press.
- Simard, P. Y., Amershi, S., Chickering, D. M., Pelton, A. E., Ghorashi, S., Meek, C., ... & Wernsing, J. (2017). Machine teaching: A new paradigm for building machine learning systems. *arXiv preprint arXiv:1707.06742*.

- Sünderhauf, N., Brock, O., Scheirer, W., Hadsell, R., Fox, D., Leitner, J., ... & Corke, P. (2018). The limits and potentials of deep learning for robotics. *The International journal of robotics research*, 37(4-5), 405-420.
- Tang, C., & Aruga, K. (2021). Relationships among the fossil fuel and financial markets during the COVID-19 pandemic: evidence from bayesian DCC-MGARCH models. *Sustainability*, 14(1), 51.
- Tantardini, C., Kvashnin, A. G., & Ceresoli, D. (2022). GIPAW Pseudopotentials of d Elements for Solid-State NMR. *Materials*, 15(9), 3347.
- Terko, A., Žunić, E., & Ćonko, D. (2019, October). Neurips conference papers classification based on topic modeling. In *2019 XXVII International Conference on Information, Communication and Automation Technologies (ICAT)* (pp. 1-5). IEEE.
- Topsakal, O., & Akıncı, T. C. (2023). Classification and regression using automatic machine learning (AutoML)—open source code for quick adaptation and comparison. *Balkan Journal of Electrical and Computer Engineering*, 11(3), 257-261.
- Tripathi, B., & Sharma, R. K. (2023). Modeling bitcoin prices using signal processing methods, bayesian optimization, and deep neural networks. *Computational Economics*, 62(4), 1919-1945.
- Uras, N., Marchesi, L., Marchesi, M., & Tonelli, R. (2020). Forecasting Bitcoin closing price series using linear regression and neural networks models. *PeerJ Computer Science*, 6, c279.
- Ustalı, N. K., Tosun, N., & Tosun, Ö. (2021). Makine öğrenmesi teknikleri ile hisse senedi fiyat tahmini. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 16(1), 1-16.
- Ye, Z., Wu, Y., Chen, H., Pan, Y., & Jiang, Q. (2022). A stacking ensemble deep learning model for bitcoin price prediction using Twitter comments on bitcoin. *Mathematics*, 10(8), 1307.
- Zhang, H., Hong, H., Guo, Y., & Yang, C. (2022). Information spillover effects from media coverage to the crude oil, gold, and Bitcoin markets during the COVID-19 pandemic: evidence from the time and frequency domains. *International Review of Economics & Finance*, 78, 267-285.
- Zhang, J. (2024). Forecasting Bitcoin Closing Price by Four Machine Learning Algorithms. *Highlights In Business, Economics and Management*.
- Zhao, C. (2024). Research on prediction of bitcoin price based on machine learning methods. In *SHS Web of Conferences* (Vol. 181, p. 02006). EDP Sciences.

