



Yapay Sinir Ağları ve Derin Öğrenme Algoritmalarının Kripto Para Fiyat Tahmininde Karşılaştırmalı Analizi

Müberra Beyza Odabaşı¹ , Merve Cengiz Toklu^{2*} 

¹ Sakarya Üniversitesi, Endüstri Mühendisliği Bölümü, Sakarya, Türkiye

² Sakarya Üniversitesi, Endüstri Mühendisliği Bölümü, Sakarya, Türkiye

muberra.odabasi@ogr.sakarya.edu.tr, mertvoklu@sakarya.edu.tr

Öz

Gelişen teknolojinin sağladığı olanaklar sayesinde internet kullanımıyla gerçekleştirilen işlemlerde artış olmuş ve bu da verilerde artışa neden olmuştur. Bu durum işletmeler için verilerin güvenli bir şekilde saklanması, paylaşılması, kontrolünün sağlanması ve yönetilmesine yönelik yeni teknoloji ihtiyacı doğurmuştur. Bu kapsamda faydalanılabilecek güncel teknolojilerden birisi de blok zinciri (Blockchain) yapısıdır. Blok zinciri yapısı birçok alanda kullanılabilecek bir teknoloji olup günümüzde en popüler kullanım alanı kripto paralar üzerinde olmaktadır. Bu çalışmada önemli alt kripto para birimlerinden biri olan Polkadot kripto para birimi için tahminleme işlemi yapılması amaçlanmıştır. Yapılan çalışmada 20.08.2020 ve 27.02.2023 tarihleri arasındaki veriler kullanılmış olup, bu verilere göre çıktı değeri olarak günlük ortalama Polkadot değerinin tahmin edilmesi amaçlanmıştır. Girdi değerleri için kümeler iki farklı şekilde oluşturulmuştur. İlk girdi değerlerinde; Polkadot YouTube arama sayısı, Polkadot Google arama sayısı ve Polkadot hacmi kullanılmıştır. İkinci girdi değerlerinde ise ilk girdi değerlerinden farklı olarak alt kripto paraların lideri Ethereum eklenmiştir. İki farklı girdi yapısından oluşan bu çalışmada Polkadot para birimi günlük ortalama değerlerinin tahminlenebilmesi için yapay sinir ağlarında çok katmanlı algılayıcılar ile derin öğrenme yöntemlerinden olan uzun kısa süreli bellek yapısı kullanılarak tahminleme çalışması yapılmıştır. Sonuçlar incelendiğinde elde edilen yapay sinir ağlarında 4 girdi kümesinden oluşan değerlerin 0,93 korelasyon katsayısı ile daha iyi sonuç verdiği belirlenmiştir.

Anahtar kelimeler: Yapay Sinir Ağları, Derin Öğrenme, Geri Yayılım Algoritması, Uzun Kısa Süreli Bellek, Blok zinciri, Polkadot, Ethereum, Tahminleme

Comparative Analysis of Artificial Neural Networks and Deep Learning Algorithms for Crypto Price Forecast

Abstract

Thanks to the opportunities provided by developing technology, there had an increase in the transactions carried out using the internet. This development also led to an increase in data. This situation created the need for new technology for businesses to store, share, control, and manage data securely. One of the current technologies that can be used in this context is the blockchain structure. The blockchain structure is a technology that can be used in many areas, and the most popular usage area today is cryptocurrencies. In this study, it is aimed to estimate Polkadot cryptocurrency, which is one of the essential sub-cryptocurrencies. In the study, the data between 20.08.2020 and 27.02.2023 are used. According to these data, it aimed to estimate the daily average Polkadot value as the output value. Clusters for input values are created in two different ways. In the first input values; number of Polkadot YouTube search, number of Polkadot Google search, and Polkadot volume are used. Unlike the first input values, Ethereum, the leader of the alt cryptocurrencies, is added in the second input value. In this study, which consists of two different input structures, to estimate the daily average values of the Polkadot currency, an estimation study is carried out using multi-layered sensors in artificial neural networks and a long-short-term memory structure, which is one of the deep learning methods. When the results are examined, it is determined that the values of 4 input sets in the obtained artificial neural networks gave better results with a correlation coefficient of 0.93.

Keywords: Artificial Neural Networks, Deep Learning, Back-propagation Algorithm, Long Short-Term Memory, Blockchain, Polkadot, Ethereum, Prediction

* Sorumlu yazar.
E-posta adresi: mertvoklu@sakarya.edu.tr

Alındı : 4 Ocak 2023
Revizyon : 21 Şubat 2023
Kabul : 1 Nisan 2023

1. Giriş (Introduction)

Blok zinciri teknolojisi, Nakamoto tarafından 2008 yılında "Bitcoin: A Peer-to-Peer Electronic Cash System" başlıklı çalışma ile dünyaya tanıtılan günümüzün önemli teknolojilerinden birisidir (Yavuz vd., 2020). Blok zinciri, zincir şeklinde birbirine bağlı art arda bloklardan oluşan merkeziyetsiz bir yapıya sahiptir. Her blok, işleme ait bilgiler taşımakta olup bir önceki bloğun da şifrelenmiş bilgilerini taşır. Blok zinciri teknolojisi bir veri tabanı olduğu için verilerin saklandığı birçok alanda kullanılabilir.

Blok zinciri teknolojisinde işlem adımları arada bir aracı olmadan yapılabildiğinden daha hızlı ve daha güvenli olmaktadır. Günümüzde özellikle sosyal platformların da etkisiyle kendini kripto paralar üzerinden duyurmuştur. Kripto paralar blok zincirinin bir ürünü olup, blok zincirini sadece kripto paralar üzerinden yorumlamak doğru bir yaklaşım olmayacaktır. Kripto paraların günümüzde finans sektöründe önemli bir hacme sahip olduğu ve talep oranlarının da arttığı görülmektedir. Finansal piyasada yatırım yaparken, uzun vadeli kar elde edebilmek yatırımcılar için önemlidir. Yatırımcılar alternatifler arasında risk ve kar analizi yaparak en az riski içeren seçeneklere yönelmektedir. Bunun için yatırımcıların, yatırım yapacakları alternatif hakkında ve o alternatifin yönelimi hakkında bilgi sahibi olmaları alacakları riski en aza indirecektir.

Bu çalışmada alt kripto para birimlerinden olan Polkadot kripto para biriminin günlük ortalama değerini tahminlemek için 20.08.2020 ve 27.02.2023 tarihleri arasındaki veri seti kullanılmıştır. Kullanılan veri setinde iki farklı girdi kümesi oluşturulmuştur. İlk girdi kümesinde Polkadot hacim sayısı, Polkadot Google arama sayısı, Polkadot Youtube arama sayısı bulunmakta olup ikinci girdi kümesinde ise Polkadot hacim sayısı, Polkadot Google arama sayısı, Polkadot Youtube arama sayısı ve Ethereum günlük ortalama değerleri bulunmaktadır. Polkadot kripto para biriminin günlük ortalama değeri üzerinde tahminleme işlemi yapılmıştır. Ethereum önemli alt kripto para birimlerinden olup Polkadot kripto para birimine etkisini ölçmek için iki farklı girdili yapı kullanılmıştır. Çalışmada yapay sinir ağlarında (YSA) çok katmanlı algılayıcılar ve derin öğrenme yöntemlerinden uzun kısa süreli bellek ağları (LSTM) kullanılarak tahminleme yapılmıştır. Yapay sinir ağlarında dört girdili veri seti ile yapılan çalışmanın daha iyi sonuç verdiği belirlenmiştir.

Bu çalışmada önemli alt kripto para birimlerinden olan Polkadot kripto para birimi seçilmiştir. Polkadot kripto para birimi, diğer kripto para birimlerinden farklı olarak arzı sınırlı değildir. Polkadot kripto para birimi, genel ve özel şifreleme sistemleri kullanıp, transfer işlemlerinde bir dijital cüzdandan diğerine göndermeye izin veren yapısı vardır. Ayrıca Polkadot, geliştiricilere kendi projeleri için blok zinciri geliştirmesine imkân tanır. Sahip olduğu paralel zincir (parachain) sistemi

sayesinde birden fazla işlemde ağda aksaklık olmadan işlemleri gerçekleşmesine imkân sağlar. Diğer blok zinciri teknolojilerinde olduğu gibi tüm ağ boyunca sıralı değil, her bir parça üzerinden paralel olarak işlenmelerine izin vererek işlemlerin verimini artırır.

2. Literatür Araştırması (Literature Review)

Bu kısımda tahminleme üzerine yapılan çalışmalar incelenmiştir. Yatırıma zemin hazırlayan borsalarda doğru yatırımları yapabilmek için hareketli olan bu piyasa hakkında bilgi sahibi olunması gerekmektedir. Bu kapsamda, Kalyoncu (2020) çalışmasında borsa üzerinde tahminleme yapabilmek için k-en yakın komşu algoritması, LSTM, YSA ve ARIMA yöntemlerinden faydalanmış olup en iyi performansı LSTM yönteminin sağladığını belirlemiştir. Son zamanlarda finansal piyasalarda kripto paralar önemli yatırım araçları arasına girmiş olup doğru yatırımı yapabilmek de kritik bir konudur. Demirci (2021) yapmış olduğu çalışma ile LSTM, geçitli tekrarlayan birim ve tekrarlayan sinir ağlarından yararlanarak Ethereum, Bitcoin, Ripple para birimlerinde fiyat tahminlemesi yapmıştır. Kripto paralara olan talebin gün geçtikçe artması ticaret sektöründeki yerinin de merak edilmesine sebep olmuştur. Avşar (2020) kripto paraların uluslararası piyasalar üzerindeki etkisini belirlemek amacıyla LSTM metodu ile kripto paralar üzerinde tahminleme için analiz bulgularını incelemiştir. Çalışmasında kripto paraların sadece dijital para olarak değerlendirmemesi gerektiği arkasında önemli bir teknolojinin yattığı ve farklı projeleri de destekledikleri için uluslararası ticarete farklı süreçlerde dijital dönüşüme destek sağlayabileceğini göstermiştir. Baygıner (2022) yapmış olduğu çalışma ile yatırımcıların ne kadar bilgi sahibi olduğunu ve yatırımı etkileyen kriterleri incelemiştir.

Türkiye'de kripto paralar sosyal medyanın da etkisiyle hızla tanınmış olup, hareketli bir yapıda olması nedeniyle hızlı para kazanmak isteyen yatırımcıların ilgisini çekmiştir. Pamuk (2019) çalışmasında sosyal medya ile kripto para birimi fiyat dalgalanması arasında herhangi bir ilişki olup olmadığını makine öğrenme algoritmaları ile belirlemeye çalışmıştır. Çılgın vd. (2020) sosyal medyanın Bitcoin fiyatlarına olan etkisini Bayes, destek vektör makineleri, lojistik regresyon ve YSA yöntemlerinden faydalanılarak araştırmıştır. Köksal vd. (2021) Bitcoin ile ilgili Twitter platformunda yapılan yorumları lojistik regresyon ve Naive Bayes algoritmaları kullanarak duygu analizi çalışması gerçekleştirmiştir. Sonrasında günlük olumlu Bitcoin tweetleri ile Bitcoin açılış değerlerini kullanarak doğrusal regresyon ve rastgele orman regresyon yöntemleri ile kapanış değerleri için tahminleme çalışması gerçekleştirmiştir.

Kripto paralarda yatırım yaparken etkili faktörlerin bilincinde yatırım yapmak avantajlı olacaktır. Bu kapsamda Deniz (2020) yaptığı çalışmada Brent petrol ile altının kripto paralar üzerindeki etkisini anlayabilmek için Granger nedensellik analizi ile eş

bütünleşme testi yapmış ayrıca etki-tepki ve varyans ayrıştırması gerçekleştirmiştir. Sel (2020) Bitcoin, Ripple, EOS, Tether ve TRON kripto para birimlerinin pandemi döneminde altın fiyatları üzerindeki etkisini vektör makineleri, çok değişkenli karar ağacı ve rasgele orman regresyon modeli ile belirlemeyi amaçlamıştır. Kartal (2020) çalışmasında k-star algoritması kullanarak makroekonomik değişkenlerin Bitcoin üzerindeki etkilerini incelenmiştir. Bu çalışmalara ek olarak, Evlimoğlu ve Güder (2021) kripto paralardaki balon durumunu incelemiş, geçmişte yaşanan ekonomik balonlar gibi kripto paralarda da balonlar olduğunu, farklılıklar açısından da kimilerinde arzın belirli bir çerçevede olması, kimilerinde ise temel değerlerin bilinmemesinin farklılık sebebi olduğunu ifade etmiştir.

Kripto paralarla ilgili fiyat tahminlemede YSA ve farklı tahminleme metodları kullanan çalışmalar literatürde yer almaktadır. Sakız ve Gencer (2017) Bitcoin için tahminleme çalışması yapmıştır. Yapılan çalışmada YSA kullanılarak tahminleme gerçekleştirmiş ve spekülasyona çok açık olan Bitcoin'in tahminleme yaparken klasik tahminleme yöntemleri ile hesaplamasının zor olduğunu belirlemiştir. Şahin (2018) 2012-2018 yılları arasındaki Bitcoin kapanış fiyatlarını baz alarak ARIMA yöntemi ve YSA ile tahminleme yapmıştır. YSA ile yapılan tahminlemenin ARIMA yöntemine göre daha iyi sonuç verdiğini belirlemiştir. Aras (2019) çalışmasında Bitcoin, Ethereum, Ripple ve Litecoin kripto para birimlerinde klasik zaman serileri ve YSA yöntemiyle tahminleme yapmıştır. Atlan vd. (2020) Bitcoin, Ripple ve Ethereum kripto para birimlerinin 24 saatlik, 1 haftalık ve 1 aylık verilerini kullanarak bulanık çıkarım sistemi, YSA ve polinomsal eğri uydurma, LSTM gibi farklı yöntemlerle ileriye yönelik tahminleme çalışması gerçekleştirmiştir. Salman (2020) Bitcoin kripto para birimi ile ilgili olarak teknik ticari göstergeler ve YSA ile fiyat tahminlemesi yapılmıştır. Sel vd. (2020) çalışmasında altın, gümüş, sterlin, euro gibi girdileri kullanarak 2013-2018 yılları arasında Bitcoin'in günlük kapanış değerleri ile tahminleme gerçekleştirmiştir. Akay vd. (2021) Ripple, Binance coin ve Ethereum kripto para birimlerinin 2020-2021 yılları arasındaki verileri ile YSA ve LSTM yöntemlerini kullanarak tahminleme yapmıştır. Günlük açılış değeri, günlük en düşük değer ve en yüksek değerleri girdi değişkenleri, günlük kapanış değeri ise çıktı değişkeni olarak alınmıştır. Hata ölçütlerinden de faydalanarak gerçeğe en yakın değerlerin YSA ile verildiği belirlenmiştir. Hayradi vd. (2022) destek vektör regresyon algoritması ile günlük Polkadot kapanış değerlerini kullanarak fiyat tahminlemesi yapmıştır.


Bu çalışmada hem girdi olarak veri setleri hem de YSA ve derin öğrenme algoritmaları kıyaslanmıştır. Bu sayede verinin önemi vurgulanırken, farkı algoritmalar ile kıyaslama gerçekleştirilmiştir. Sonuç olarak yapılan çalışma ile dört girdili yapay sinir ağında çok katmanlı algılayıcılar için daha iyi sonuç verdiği gözlemlenmiştir.

3. Yöntem (Method)

3.1. Yapay sinir ağları (Artificial neural networks)

YSA öğrenme ve genelleme yapabilme özelliklerinin sağladığı esnek ve güçlü yapısı sayesinde pek çok karar verme sürecinde kullanılan bir yaklaşımdır. YSA, birçok özelliğine bağlı olarak farklı ve karmaşık problemleri çözmede etkili bir sistemdir. Her problemin çözümüne uygun farklı ağ yapıları vardır. Bu problemler için uygun çözüm ağının hangisi olduğuna karar vermek karar verici tarafından gerçekleştirilir. Bu durum çalışılan probleme göre değişkenlik gösterebilir (Karaatlı vd., 2012).

Teknik açıdan YSA'nın görevi, girdi katmanından gelen bilgileri ara katmanda işleyerek (ağın ağırlık değerleri kullanılarak) çıktıya dönüştürmektir (Yavuz ve Devceci, 2012). YSA'nın girdilerden doğru çıktılar üretebilmesi ağırlıklarının doğru değerler olmasına bağlıdır. YSA genel olarak girdi katman, gizli katman ve çıktı katmanından oluşmaktadır (Şekil 1).



Şekil 1. Yapay sinir ağı model yapısı (Artificial neural network model structure)

Daha geniş kapsamda, YSA yapısı beş temel süreç elemanından oluşmaktadır. Bunlar; girdi değerleri, ağırlıklar, toplama (birleştirme) fonksiyonu, aktivasyon fonksiyonu ve çıktı değerleridir. Girdi değerleri, yapay sinir ağına dışarıdan gelen veriler olup, bu verilerin ağ tarafından öğrenilmesi istenir. Ağırlıklar, girdi olarak gelen verinin hücre üzerindeki etkisini anlamaya yardımcı olmaktadır. Birleştirme fonksiyonu, bir hücredeki net girdiyi hesaplamakta olup, bunun için geliştirilmiş farklı fonksiyonlar bulunmaktadır. Aktivasyon fonksiyonu, net girdi sinyallerini çıkış sinyallerine çevirir. Çıktı katmanına aktarılan değerler üzerinde aktivasyon işlemi yapılmaktadır.

3.2. Derin öğrenme (Deep learning)

Derin öğrenme, en az bir adet yapay sinir ağının kullanıldığı insan beyninin bilgi edinme şeklini taklit eden makine öğrenme türüdür. Nöronlar arası sinyal iletimi ile birbirine bağlı hücreler gibi davranmasını sağlayarak, farklı durumları öğrenip karar sürecini destekleyen nöron bütünü yapay sinir ağını oluşturmaktadır. Tüm derin öğrenme modellerinde yapay sinir ağı olup, her yapay sinir ağının derin öğrenme modeli yoktur. Derin öğrenme algoritmaları en az iki katmana sahiptir, girdi çıktı katmanları da eklendiğinde durumda toplam dört katmandan

oluşmaktadır. Katmanlarda farklı nöron sayıları ve aktivasyon işlemleri olabilmekte olup, her düğümde sonucu optimize edebilmek için ağırlıklar eğitilmektedir.

Python programlama dilinde yapay sinir ağı oluşturmak için kullanılan iki kütüphane Tensorflow ve Pytorch'tur. Tensorflow kütüphanesine ait Keras sınıfı girdilerin nöronları beslediği ve bu nöronların çıktı sağladığı bir yapı oluşmasını amaçlar. Yapay sinir ağı oluşturmanın farklı yolları vardır ancak Keras sınıfı, katmanlar üzerinde kontrol ve esneklik sağlarken çok girdili ve çıktılı değerleri oluşturmakta kullanılabilir. Eğitim ve test aşamasında optimize edici (optimizer), kayıp değer (loss) ve metrikler tanımlanmakta olup, optimize ediciler arasında adaptive moment estimation (ADAM) algoritması en sık kullanılmaktadır (Turan, 2019). Derin öğrenmede kullanılan farklı algoritmalar aşağıdaki gibi özetlenebilir.

Evrişimli sinir ağı (CNN), ileri beslemeli sinir ağı modeli olup nesne algılama ve görüntü işlemede kullanılmaktadır. Tekrarlayan sinir ağı (RNN), LSTM ağlarından gelen çıktı değerlerinin, girdi olarak girilmesine izin verir ve dahili belleği sayesinde bir önceki girdileri ezberler böylece döngü oluşmasını sağlayan yapılar oluşturur. Uzun kısa süreli bellek ağlarına (LSTM), bu çalışmada kullanıldığından dolayı daha geniş yer verilmiştir. Uzun kısa süreli bellek, tekrarlayan sinir ağı türüdür. Diğer tekrarlayan sinir ağlarından farklı olarak uzun süre hatırlayabilen bellek hücreleri vardır. RNN'nin uzun vadede bellekteki bilgiyi tahmin etmekte zorlandığı, yakın tarihli işlemlerde daha iyi sonuç verdiği gözükmektedir. Bunlardan farklı olarak LSTM yapısı bilgiyi uzun süre saklayabilmektedir. Geleneksel sinir ağlarında girdi alınır ve bir çıktı üretir. LSTM yapısında ise veriler tekrarlayan şekilde işlenir, ilk adımda girdi alınır ve bu sonraki adımlarda çıktıyı etkilemek için kullanılabilir. Bu yineleme işlem adımları sayesinde LSTM yapısında veri dizileri öğrenilebilir. Sıralı olan verilerde uzun vadeli verileri LSTM yapısı öğrenip bellek hücrelerinde tutmaktadır. Bellek hücrelerinde üç adet kapı bulunmakta olup bunlar giriş, çıkış ve unutmaya kapısıdır. Bellek hücresi ve hücre durumu LSTM yapısını oluşturmaktadır. Giriş kapısında belirli zaman aralığında hücre durumuna ne kadar yeni bilgi eklendiği kontrol edilir. Bu sigmoid işlevi kullanılarak düzenlenir, belirli zamandaki giriş ve önceki hücre çıkışı kullanılarak hatırlanacak veriler filtrelenir. Tahn işlevi ile (-1) ve (+1) arası çıktı veren olası tüm değerleri içeren bir vektör oluşturulur. Daha sonraki işlemde gerekli bilgileri elde etmek için vektör değerleri ve düzenlenmiş değerler çarpılır. Çıkış kapısında ise bu zaman aralığında çıktıyı üretirken hücre durumunda ne kadar bilgi kullanıldığını kontrol edilir. Unutmaya kapısında, geçmiş zaman adımlarında ne kadar bilginin mevcut zaman adımlarında tutulacağı kontrol edilir. Hücre durumunda artık işe yaramayan bilgiler unutmaya kapısına kaldırılır. Çok Katmanlı Algılayıcılar (MLP),

ileri beslemeli sinir ağı olup birçok algılayıcı katmana sahiptir. Giriş katmanını besleyen çok katmanlı algılayıcılar, nöron katmanları sayesinde sinyali tek yönde geçecek şekilde grafiklere bağlar. Çok katmanlı algılayıcılar, girdi katmanla ile gizli katman arasındaki ağırlığın hesaplanmasında kullanılır. Radyal Temelli Fonksiyon Ağları (RBFN), ileri beslemeli yapay sinir ağı olup aktivasyon işlemlerinde radyal tabanları işlevleri kullanılmaktadır. Giriş katmanını besleyen giriş vektörüne sahiptir. Sınıflandırma, zaman serisi, regresyon analizi gibi birçok kısımda kullanılmaktadır. Kendi Kendini Düzenleyen Haritalar (SOM), veri boyutlarında küçülmeye giderek veri görselleştirmeyi sağlayarak, yüksek boyutlu görselleştirilemeyen verilere anlam kazandırmaktadır. En olası girdi vektöründe hangi ağırlık olduğunu bulmak için tüm düğümler incelenir ve hak eden düğüm en iyi eşleşen birim olarak isimlendirilir. En iyi eşleşen düğüm çevresini inceler böylece sayı git gide azalır. Bir düğüm en iyi eşleşen birime ne kadar yakın ise ağırlık o kadar fazla değişmektedir. Üretken Düşman Ağları (GAN) sahte veri üretmeyi öğrenen oluşturucu ve yanlış bilgiyi öğrenen ayırmacı olmak üzere iki kısımdan oluşur. Eğitim verilerine benzeyen veri setleri oluşturmaktadır. Sahte veri ile gerçek veri arasında ayırım yapmayı öğrenir. Eğitim sırasında sahte veriler üretilir ayırmacı da bunların yanlış olduğunu söylemeyi öğrenir. Kısıtlanmış Boltzmann Makineleri (RBM), girdi değerleri üzerinden olasılık dağılımını öğrenmekte olup regresyon, boyut azaltma, konu modelleme, iş birlikçi filtreleme gibi alanlarda kullanılmaktadır. Derin İnanç Ağları (DBN), katmanlar arası bağlantıları olup, Boltzmann makinesi yığıdır. Her katman önceki ve sonraki ile iletişim kurar. Derin inanç ağlarını eğiten aç gözlü algoritması olup, üretken ağırlıkları öğrenmek için katman katman yaklaşım uygular. Otomatik kodlayıcılar, ileri beslemeli sinir ağı olup denetimsiz öğrenme problemlerini çözmek için geliştirilmiştir.

4.Uygulama (Application)

Bu çalışmada Polkadot kripto para birimi için YSA'da fiyat modellemesi yapılmıştır. Polkadot para biriminde gün bazlı tahminleme yapabilmek için YSA'da çok katmanlı algılayıcılar ve derin öğrenme yöntemlerinden LSTM yapısı kullanılarak geliştirme yapılmıştır. Bu çalışmada 20.08.2020 ve 27.02.2023 tarihleri arasındaki veriler kullanılmış olup, nöron sayısı, test ve eğitim verilerindeki sayılar seçilirken çapraz doğrulama yönteminden yararlanılmıştır. Çıktı değeri olarak Polkadot'un günlük ortalama değeri alınmıştır. Ortalama değeri hesabında ilgili güne ait en yüksek ve en düşük değerlerin ortalaması alınmıştır. Girdi parametreleri iki farklı şekilde test edilmiştir. Bunun sebebi Polkadot kripto para biriminin Ethereum ağından türemiş olmasından dolayı Ethereum kripto para biriminin Polkadot üzerindeki etkisini görebilmektir. Bu nedenle ilk girdi parametreleri; Google arama sayısı, YouTube arama sayısı ve Polkadot

hacim değeri olarak belirlenmiştir. İkinci girdi parametreleri ise; Google arama sayısı, YouTube arama sayısı, Polkadot hacim değeri ve Ethereum ortalama değeri olarak belirlenmiştir.

Yapılan çalışma ile Polkadot ortalama değerinin, Ethereum ortalama değeri dikkate alınarak ve alınmayarak iki farklı şekilde tahminlenmesi amaçlanmıştır. Bunun için yapay sinir ağlarında çok katmanlı algılayıcılar ile derin öğrenmede LSTM yapısı kullanılarak başarı oranı korelasyon katsayısı üzerinden değerlendirme yapılarak karşılaştırılmıştır.

4.1. Yapay sinir ağlarında ağ tasarımı (Network design in artificial neural networks)

Bu çalışmada belirlenen parametreler doğrultusunda, Polkadot fiyatlarının yer aldığı veri seti kullanılmıştır. Polkadot fiyatlarını tahmin etmede kullanılan bir takım girdi parametreleri bulunmaktadır.

Tablo 1. Normalize edilmiş veriler (Normalized data)

Ethereum NM Data	Polkadot NM Data	NM Hacim	NM Youtube	NM WEB
0,63828023	0,82115869	0,1476941	0,7012987	0,20588235
0,73648822	0,73047859	0,26444834	0,06493506	0,29411765
0,64567961	0,60957179	0,17104495	0,28571429	0,30882353
0,72273337	0,72292191	0,18661218	0,46753247	0,22058824
0,81341916	0,91939547	0,32282545	0,07792208	0,13235294
0,944561	0,96473552	0,13485114	0,44155844	0,20588235
1	0,95717884	0,12239735	0,4025974	0,16176471

*Tüm veriler kısıtlı alan dolayısıyla gösterilemediği için verilerin bir kısmı örnek olarak verilmiştir.

Polkadot kripto para biriminin günlük ortalama değeri üzerinde tahminleme yapabilmek için, simülasyon ve eğitim verilerinden oluşan girdi ve çıktı kümeleri oluşturulmuştur. Yapay sinir ağlarında çok katmanlı algılayıcılarda yapılan geliştirmede MATLAB programından yararlanılmıştır. Yapay sinir ağlarında birçok model bulunmakta olup, bu çalışmada geri yayılım algoritması kullanılarak bir tahminde bulunulduğu için “feed-forward backdrop” tipi seçilmiştir. Eğitim fonksiyonu (training function) olarak, tahminlemede en çok kullanılan “traingdx” tercih edilmiştir. “Adaptation learning function” olarak “learnidx” seçilmiştir. Tahmin verilerinde daha iyi sonuç verdiği için katman sayısı iki olarak belirlenmiştir. Tasarlanan ağda bulunan yapay sinir ağı hücreleri için birleştirme fonksiyonu olarak toplama fonksiyonu kullanılmıştır. Aktarma fonksiyonu olarak ara katmanda bulunan yapay sinir hücreleri için sigmoid fonksiyonu, çıktı katmanında bulunan yapay sinir hücreleri içinse, doğrusal fonksiyon kullanılmıştır. Ağın eğitiminde eğitimli öğrenme dizisi ile hatayı geriye

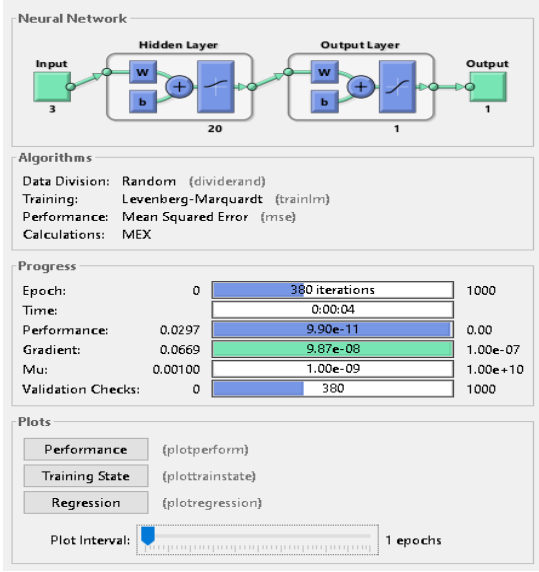
Parametrelerde günlük değerler kullanılmış olup Ethereum ve Polkadot fiyatların da günlük en yüksek ve en düşük fiyatın ortalaması alınarak Polkadot fiyatında tahminleme işlemi yapılmıştır. Tahminleme işlemi yapılmadan önce veri seti üzerinde normalizasyon işlemi yapılmıştır.

Yapay sinir ağını modellerken aktivasyon fonksiyonu olarak sigmoid (Logsig) fonksiyonu kullanılmıştır. Daha sonra normalize edilen verilerin transpozesi alınmıştır. Hem doğrusal hem doğrusal olmayan fonksiyonlarda çıktı üretilebiliyor olmasından dolayı sigmoid fonksiyonu tercih edilmiştir. Denklem (1)’de sigmoid fonksiyonun formülü verilmiştir. Bu denkleme bağlı olarak elde edilen normalize edilmiş veriler Tablo 1’de görülmektedir.


$$X_{norm} = (X - X_{min}) / X_{max} - X_{min} \quad (1)$$

doğru yayan “Levenberg-Marquardt” geri yayılım algoritması kullanılmıştır.

Polkadot para birimini tahminlemek için yapay sinir ağları çok katmanlı algılayıcı algoritması üzerinde yapılan geliştirmede, iki ayrı kümede girdi parametreleri oluşturularak buna göre ağ yapısı oluşturulmuştur. Oluşturulan ilk ağ yapısında üç parametreden oluşan Polkadot Google arama sayısı, Polkadot YouTube arama sayısı, Polkadot hacmi girdi değerleri, Polkadot günlük ortalama değeri ise çıktı değerlerini vermektedir. Yapay sinir ağları çok katmanlı algılayıcı algoritması üzerinde oluşturulan ikinci ağ yapısında, dört girdi parametreden oluşan Polkadot Google arama sayısı, Polkadot YouTube arama sayısı, Polkadot hacmi, Ethereum günlük ortalama değeri girdi değerlerini, Polkadot günlük ortalama değeri ise çıktı değerini vermektedir. Geliştirme test edilirken çapraz doğrulama yapılmış olup 10 ve 20 olmak üzere sırayla farklı nöron değerleri ve %70, %80 ve %90 eğitim verisi olacak şekilde karşılaştırma testi yapılmıştır. Üç girdili ve dört girdili tasarlanan ağın yapısı şekil 2’de gösterilmiştir.




(a)



(b)

Şekil 2. (a) Üç girdili tasarlanan ağ yapısı (Network structure designed with three inputs). (b) Dört girdili tasarlanan ağ yapısı (Network structure designed with four inputs)

Şekil 3'te dört girdili 10 nöronlu tasarlanmış ağ yapısı bulunmaktadır.



Şekil Hata! Belgede belirtilen stilde metne rastlanmadı.. Dört girdili 10 nöronlu tasarlanan ağ yapısı (Network structure designed with 10 neurons and four inputs)


4.2 Yapay sinir ağlarının eğitimi ve test edilmesi (Training and testing of artificial neural networks)

Ağın eğitilmesi aşamasında dört girdili ve üç girdili olmak üzere iki farklı girdi kümesi oluşturulmuştur.


Çıktı değerlerinde hangi değerlerde daha iyi sonuç verdiğini gözlemlemek için çapraz doğrulama yöntemi kullanılmıştır. Bunun için 10 ve 20 nöron değerleri seçilerek test edilmiştir.

Ayrıca 20.08.2020 ve 27.02.2023 tarihleri arasındaki veriler için %70, %80 ve %90 oranlarında eğitim verisi olacak şekilde test edilmiştir. Test sonuçlarına göre, 10 nöronlu %70 eğitim seti oranına göre "Training R" değeri 0,97214, "Validation R" değeri 0,92212, "Test R" değeri 0,73158 ve "All R" değeri 0,91656 olarak bulunmuştur (Şekil 4).

Şekil 5'te, 3 girdi parametresi, 10 nöron ve %80 oranındaki eğitim seti için ilgili veriler ve grafikler verilmiştir. Benzer şekilde Şekil 6'da 3 girdi parametresinden oluşan veri setinde, 10 nöronlu %90 eğitim seti kullanıldığında elde edilen veriler ve grafikler verilmiştir.




(a)




(b)

Şekil 1. (a) 3 girdili 10 nöronlu %70 eğitim verili gerçek-tahmin değeri grafiği (Predicted versus actual values scatter plot with 3 input, 10 neuron and 70% training data) (b) 3 girdili 10 nöronlu %70 eğitim verili Epoch-MSE grafiği (Number of epochs vs. MSE of 3 input, 10 neuron and 70% training data)




(a)



(b)

Şekil 5. (a) 3 girdili 10 nöronlu %80 eğitim verili gerçek-tahmin değeri grafiği (Predicted versus actual values scatter plot with 3 input, 10 neuron and 80% training data) (b) 3 girdili 10 nöronlu %80 eğitim verili Epoch-MSE grafiği (Number of epochs vs. MSE of 3 input, 10 neuron and 80% training data)




Şekil 6. (a) 3 girdili 10 nöronlu %90 eğitim verili gerçek-tahmin değeri grafiği (Predicted versus actual values scatter plot with 3 input, 10 neuron and 90% training data) (b) 3 girdili 10 nöronlu %90 eğitim verili Epoch-MSE grafiği (Number of epochs vs. MSE of 3 input, 10 neuron and 90% training data)

10 nöronlu işlem adımlarında uygulanan adımlar 20 nöron için de gerçekleştirilmiştir. 3 girdili 20 nöronlu %70 eğitim verisi kullanılarak “Training R” değeri 0,94048, “Validation R” değeri 0,78926, “Test R” değeri 0,9475, “All R” değeri ise 0,91059 olarak belirlenmiştir. 3 girdili 20 nöronlu, %80 eğitim verisi kullanılarak “Training R” değeri 0,95548, “Validation R” değeri 0,97673, “Test R” değeri 0,3744, “All R” değeri ise 0,91059 olarak tespit edilmiştir. 3 girdili 20 nöronlu, %90 eğitim verisi kullanılarak “Training R” değeri 0,88966, “Validation R” değeri 0,91949, “Test R” değeri 0,97199 ve “All R” değeri 0,91059 olarak belirlenmiştir. Eğitim veri seti oranı arttıkça başarı oranı da artmaktadır. Aynı adımlar 4 girdili veri seti için gerçekleştirildiğinde 10 nöron %90 eğitim seti için daha iyi sonuç verdiği gözlemlenmiştir. Sonuçlar incelendiğinde yapay sinir ağlarında 4 girdili 10 nöronlu %90 eğitim setinin olduğu 0,93944 değeri en iyi sonucu verdiği gözlemlenmiştir.

4.3 Derin öğrenme ile tahminleme (Prediction with deep learning)

Derin öğrenme, insan beyni işlevinden ilham almış yapay sinir ağlarını kullanan algoritmalarla alakalı makine öğreniminin bir alt dalıdır (Tuncer, 2022). Derin öğrenme yapay zekânın eğitilmesine olanak sağlayarak ilgili girdi değerlerine göre çıktı değerlerinin tahmin edilmesini sağlamaktadır.


Bu çalışmada derin öğrenme yöntemlerinden LSTM kullanılarak, Anaconda Navigator uygulaması üzerinden Jupyter Notebook kullanılarak Python 3 programlama dilinde geliştirme yapılmıştır. Polkadot fiyat tahmini için yapılan geliştirmede farklı kütüphaneler kullanılmıştır. Bunlar; numpy, pandas, matplotlib, sklearn, tensorflow kütüphaneleridir. Şekil 7’de, %70 eğitim seti, %80 eğitim seti ve %90 eğitim setine göre tarih bazlı test ve eğitim verilerinin dağılımı verilmiştir.



Şekil 7. (a) %70 eğitim verili test ve eğitim verilerinin tarih bazlı dağılımı (Date-based distribution of test and training data with 70% training data) (b) %80 eğitim verili test ve eğitim verilerinin tarih bazlı dağılımı (Date-based distribution of test and training data with 80% training data) (c) %90 eğitim verili test ve eğitim verilerinin tarih bazlı dağılımı (Date-based distribution of test and training data with 90% training data)


RNN, tekrarlayan sinir ağı olup, işlemlerin daha kalıcı olması için kendi içinde bir döngü yapısında çalışmaktadır. Veri setinde bulunan değer nörona verildiğinde tahmin üretilmektedir. Bu tahmin daha sonra gelen veri ile tekrar giriş yapıp, tekrar kullanılmaktadır. Kısaca çıkan sonuç bir sonrakini beslemektedir. LSTM ise tekrarlayan sinir ağlarının farklı bir sürümü olup, hafızadaki geçmiş verileri hatırlamayı sağlar. LSTM modeli geri yayılım algoritması olarak eğitmekte olup, zaman serileri ile sınıflandırmada tahmin edilmesinde uygundur. Bu nedenle bu çalışmada LSTM tercih edilmiştir.

Şekil 8’de 10 nöronlu %70 eğitim verisi ile epochs değerlerine (döngü sayısı) göre ortalama karesel hata (Mean Squared Error-MSE) değeri gösterilmektedir. MSE değeri sıfıra ne kadar yakınsa o kadar başarılı diye yorumlanır.



Şekil 8. Epochs-MSE grafiği (Epochs-MSE chart)

Şekil 9’da 10 nöronlu %80 eğitim verisi ile gerçek-tahmin grafiği ve hata/başarı oranları bulunmaktadır. Ayrıca ortalama karesel hata (Mean Squared Error-




(a)

Şekil 10. (a) Epochs-MSE grafiği (Epochs-MSE chart) (b) 3 girdili gerçek-tahmin grafiği ve hata/başarı oranları (Actual-prediction graph and error-success rates)

Şekil 11’de 3 girdili %80 eğitim seti ile oluşturulmuş grafikler gözükmektedir. Şekil 11(a) Epoch-MSE grafiğini verirken, Şekil 11(b)’de gerçek ve tahmin

değeri grafiği gözükmektedir. Ayrıca Şekil 11(b)’de yer alan başarı oranı 84,123 olarak okunmaktadır.


```
# Tahminiye yap.
model_predict = model.predict(test_set_x).squeeze()
# Hata oranlarını göster.
show_error_rate(model_predict, test_set_y)
# Başarı oranını göster.
show_success_rate(model_predict, test_set_y)
targets = test_set[ADN][SCREENLENGTH]
model_predict = test_set[ADN].values[: SCREENLENGTH] * (model_predict + 1)
model_predict = pd.Series(index=targets.index, data=model_predict)
# Gerçek ve tahminiye değerlerini karşılaştırarak ekranda göster.
show_on_screen(targets, model_predict, 'actual', 'prediction', title='MODEL PREDICT')
5/5 [*****] - 15 486/step
Mean Absolute Error : 0.02058095778097112
Mean Squared Error : 0.004668462227760682
Success Rate : 84.88678645535889
```




Şekil 9. Dört girdili gerçek-tahmin grafiği ve hata/başarı oranları (Actual-prediction graph and error-success rates)

Şekil 10’da üç girdili %70 eğitim seti ile oluşturulmuş grafikler gözükmektedir. Şekil 10(a) Epoch-MSE grafiğini verirken, Şekil 10(b)’de gerçek ve tahmin değeri grafiği gözükmektedir. Ayrıca Şekil 10(b)’de yer alan başarı oranına bakıldığında 73,123 çıktığı gözükmektedir.


Mean Absolute Error : 0.03975287698587716
Mean Squared Error : 0.0031816589888315143
Success Rate : 73.12397624898284



(b)




(a)



(b)

Şekil 11. (a) Epochs-MSE grafiği (Epochs-MSE chart) (b) 3 girdili gerçek-tahmin grafiği ve hata/başarı oranları (Actual-prediction graph and error-success rates)

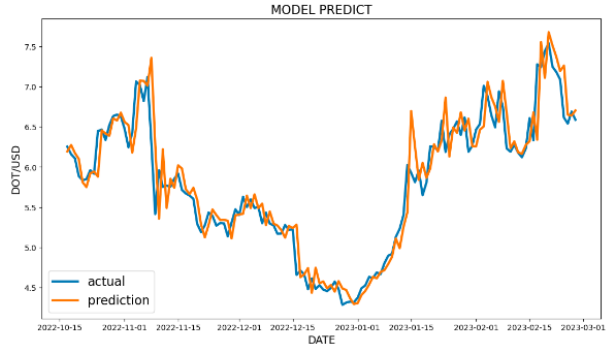
Şekil 12’de 3 girdili %90 eğitim seti ile oluşturulmuş grafikler gözükmemektedir. Şekil 12(a) Epoch-MSE grafiğini verirken, Şekil 12(b) gerçek ve tahmin değeri



(a)

grafiği gözükmemektedir. Ayrıca Şekil 12(b)’de yer alan başarı oranına bakıldığında 84,842 çıktığı gözükmemektedir

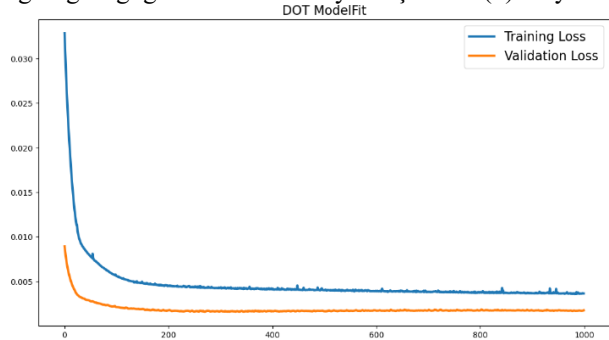
Mean Absolute Error : 0.031951285162638954
Mean Squared Error : 0.0018922689336639464
Success Rate : 84.84280494388586



(b)

Şekil 12. (a) Epochs-MSE grafiği (Epochs-MSE chart) (b) 3 girdili gerçek-tahmin grafiği ve hata/başarı oranları (Actual-prediction graph and error-success rates)


Şekil 13’te 4 girdili %70 eğitim seti ile oluşturulmuş grafikler gözükmemektedir. Şekil 13(a) Epoch-MSE grafiğini verirken, Şekil 13(b)’de gerçek ve tahmin değeri grafiği gözükmemektedir. Ayrıca Şekil 13(b)’de yer



(a)

alan başarı oranına bakıldığında 84,4048 çıktığı gözükmemektedir.

3/3 [=====] - 1s 10ms/step
Mean Absolute Error : 0.02395680854345226
Mean Squared Error : 0.0017372429181508408
Success Rate : 84.4048496144969




(b)


Şekil 13. (a) Epochs-MSE grafiği (Epochs-MSE chart) (b) 4 girdili gerçek-tahmin grafiği ve hata/başarı oranları (Actual-prediction graph and error-success rates)

Şekil 14'de 4 girdili %90 eğitim seti ile oluşturulmuş grafikler görülmektedir. Şekil 14(a) Epoch-MSE grafiğini verirken, Şekil 14(b)'de gerçek ve tahmin

değeri grafiği görülmektedir. Ayrıca Şekil 14(b)'de yer alan başarı oranı 86,036 olarak görülmektedir.



(a)



(b)

Şekil 14. (a) Epochs-MSE grafiği (Epochs-MSE chart) (b) 4 girdili gerçek-tahmin grafiği ve hata/başarı oranları (Actual-prediction graph and error-success rates)

Sonuçlara göre, eğitim veri sayısı arttığında başarı oranının arttığı görülmüştür. Ayrıca dört girdili olarak Ethereum kripto para biriminin de değerlerini eklemenin çalışmaya olumlu yansıdığı tespit edilmiştir. Bu çalışmadan elde edilen sonuçlar genel bir tablo halinde Tablo 2 ve Tablo 3'te verilmiştir.

Tablo 2. 4 girdili derin öğrenme ve yapay sinir ağı sonuç değerleri (Deep learning and neural network result values for 4 input)

Yöntem	R	MSE	RMSE
Derin Öğrenme	0,86036	0,01626	0,12751
Yapay Sinir Ağları	0,93944	0,01165	0,10793

Tablo 2'de korelasyon katsayısı (R) ile kıyaslandığında yapay sinir ağlarının daha iyi sonuç verdiği gözlemlenmiştir. Tablo 2'de dört girdi parametresi, Tablo 3'te ise 3 girdi parametresi için derin öğrenme ve yapay sinir ağları üzerindeki en yüksek değerler verilmiştir. İki algoritmada da 10 nöron ve %90 test verisi daha iyi sonuç verdiği gözlemlenmiştir.

Tablo 3. 3 girdili derin öğrenme ve yapay sinir ağı sonuç değerleri (Deep learning and neural network result values for 3 input)

Yöntem	R	MSE	RMSE
Derin Öğrenme	0,84842	0,01800	0,13416
Yapay Sinir Ağları	0,91059	0,01975	0,14053

5. Sonuçlar (Conclusions)

Teknolojinin gelişmesi ile bazı yatırımcılar fiziki yatırım araçlarından ziyade sanal yatırım araçlarına yönelmektedir. Güncel teknolojiler arasında yer alan blok zinciri teknolojisinin bir ürünü olan kripto paralar da son zamanların popüler yatırım araçları arasına girmeyi başarmıştır. Bir alım satım işleminin bazen saatler, günler sürdüğü geleneksel para birimleri yerine kripto paralarda saniyeler içinde işlemler tamamlanabilmektedir. Ayrıca blok zinciri teknolojisi sayesinde güvenilir olduğu düşünülmektedir. Kripto

paralarda merkezi kontrolün olmaması, şeffaf olması, değiştirilemez olması kötü kullanımın minimum olmasını sağlayacaktır.

Bu çalışma kapsamında Polkadot kripto para biriminin 20.08.2020 ve 27.02.2023 tarihleri arasındaki veriler kullanılarak tahminleme yapılmıştır. Tahminleme işlemi için yapay sinir ağlarında çok katmanlı algılayıcılar kullanılırken derin öğrenme metodlarında ise LSTM kullanılmıştır. Polkadot kripto birimini etkileyen girdi değerleri iki farklı şekilde ele alınmıştır. Bunlardan ilkinde Polkadot Youtube arama sayısı, Polkadot web arama sayısı, Polkadot hacim değerini oluşturmaktadır, ikinci girdi kümesinde Polkadot Youtube arama sayısı, Polkadot web arama sayısı, Polkadot hacim değerine ek olarak önemli alt kripto para birimlerinden olan Ethereum da katılarak üzerindeki etkisi anlaşılmasına çalışılmıştır. Çalışma yapılırken çapraz doğrulama yöntemi kullanılarak eğitim verilerinin oranı belirlenmiştir. Ayrıca nöron sayısı belirlenirken 10 ve 20 şeklinde test ederek belirlenmiştir. Yapılan çalışma neticesinde yapay sinir ağlarında çok katmanlı geri yayılım algoritmasında Ethereum değerinin de etkilendiği dört girdili 10 nöron sayılı, %90 eğitim verisinin olduğu veri setinde tahminleme yapıldığında 0,93 korelasyon katsayısı ile en yüksek başarıya ulaştığı görülmüştür. Aynı çalışma derin öğrenme yöntemlerinden LSTM kullanılarak gerçekleştirildiğinde en iyi sonuç 10 nöron ve dört girdili, %90 eğitim verisinin olduğu 0,86 korelasyon katsayısı ile elde edilmiştir. Yapılan çalışmada dört girdili, 10 nöronlu, %90 eğitim verisi ile yapılan çalışmanın hem yapay sinir ağlarında hem de derin öğrenmede daha iyi sonuç verdiği belirlenmiştir.

Yapılan çalışma ile farklı girdi değerlerinin, nöron ve eğitim verisini oranlarının başarıyı nasıl etkilediği belirlenmiştir. Ayrıca farklı algoritmalar üzerinde geliştirme yapmanın başarı oranlarında farklı değerler ortaya çıkarabileceği gösterilmiştir.

İleriki çalışmalarda farklı girdi parametreleri, farklı model yapıları, farklı algoritmalar kullanılarak kıyaslamalar yapılması doğru sonuca ulaşma önem arz etmektedir.

Teşekkür (Acknowledgment)

Bu çalışma, Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim dalında gerçekleştirilen, 2. yazarın danışmanlığında 1. yazara ait yüksek lisans tezinden üretilmiştir.

Kaynaklar (References)

- Aras, S., 2019. Kripto para fiyatlarının klasik ve yapay sinir ağı modelleri ile tahmini. *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(20), 608-640.
- Atlan, F., Pençe, İ., Çeşmeci, M., 2020. Kripto paralardan Bitcoin, Ethereum ve Ripple için yapay zekâ ile online fiyat tahmin modeli. 28th Signal Processing and Communications Applications Conference (SIU), 2165-0608.
- Avşar, İ.İ., 2020. Kripto paralar ve uluslararası ticaret üzerine bir araştırma: Bibliyometrik, LSTM ve kümeleme analizi. Doktora Tezi, Hasan Kalyoncu Üniversite ve Gaziantep Üniversitesi.
- Akay, M.K., Canik, F., Yeşilyurt, C., ve Günkut, M.Ş., 2021. Yapay zeka teknikleri ile kripto para değeri tahmini, *Ekonomi Bilimleri Dergisi*, 14(1), 72-101.
- Baygıner, O., 2022. Kripto para piyasaları ve Türkiye'de insanların piyasalara yaklaşımı. Yüksek Lisans Tezi, Üsküdar Üniversitesi.
- Çılgın, C., Ünal, C., Alıcı, S., Akkol E., ve Gökşen, Y., 2020. Metin sınıflandırmada yapay sinir ağları ile Bitcoin kodları ve sosyal medyadaki beklentilerin analizi. Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi, 4(1), 106-126.
- Deniz, E.A., 2020. Finansal piyasalarda kripto para uygulamaları: Kripto para fiyatlarını etkileyen faktörler. Yüksek Lisans Tezi, Işık Üniversitesi.
- Demirci, E., 2021. Kripto Para Fiyatlarının LSTM ve GRU modelleri ile tahmini. Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi.
- Evlimoğlu, U., Güder, M., 2021. Tarihteki ekonomik balonlar ışığında kripto paralara genel bir bakış. *Abant Sosyal Bilimler Dergisi*, 21(3), 469-496.
- Hayradi, D., Hâkim, A., Atmaja, D., Yutia, S., 2022. Implementation of support vector regression for Polkadot cryptocurrency price prediction. *Int. J. Inform. Visualization*, 6(1-2), 201-207
- Kalyoncu, Ş., 2020. Borsa analizi ve tahmini için derin öğrenme ağları. Yüksek Lisans Tezi, İstanbul Sabahattin Zaim Üniversitesi.
- Karaatlı, M., Helvacıoğlu, Ö., Ömürberk, N., ve Tokgöz, G., 2012. Yapay sinir ağları yöntemi ile otomobil satış tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.
- Kartal, C., 2020. K-Star algoritması ile Bitcoin fiyatları modelleme. *Business & Management Studies: An International Journal*, 8 (1), 213-231.
- Köksal, B., Erdem, G., Türkeli, C., Öztürk, Z.K., 2021. Twitter'da duygu analizi yöntemi kullanılarak Bitcoin değer tahminlemesi. *Düzce Üniversitesi Bilim ve Teknoloji*, 9(3), 280-297.

- Nakamoto, S., 2008. Bitcoin: A peer-to-peer electronic cash system. *Decentralized Business Review*, 21260.
- Pamuk, Ö.G., 2019. Cryptocurrency price prediction by using social media data. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi.
- Sakız, B., Gencer, A. H., 2017. Yapay sinir ağları ile bitcoin fiyatını tahminleme. In *International Conference on Eurasian Economies*, 438-444.
- Salman, M., 2020. Price prediction of different cryptocurrencies using technical trade indicators and machine learning. Yüksek Lisans Tezi, Altınbas Üniversitesi.
- Sel, A., 2020. Pandemi sürecinde altın fiyatları ile Kripto para ilişkisinin makine öğrenme metotları ile incelenmesi. *Journal of Statistics & Applied Science*, 1(2), 85-98
- Sel, A., Zengin, N., Yıldız, Z., 2020. Alternatif yatırım araçları ile Bitcoin fiyatları arasındaki ilişkinin yapay sinir ağları ile tahmini. *Sivas Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 21(2), 157-169.
- Şahin, E.E., 2018. Kripto para Bitcoin: ARIMA ve yapay sinir ağları ile fiyat tahmini. *Fiscaoeconomia*, 2(2), 74-92.
- Tuncer, A., 2022. LSTM metodu kullanılarak rüzgar hızının tahmin edilmesi. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi.
- Turan, S., 2019. Uzun kısa süreli hafıza ve geçitli yinelenen birim ile Borsa İstanbul 100 endeks değeri tahmini üzerine bir uygulama. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi.
- Yavuz, S., Deveci, M., 2012. İstatistiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167-187.
- Yavuz, U., Özen, Ü., Taş, K., Çağlar, B., 2020. Yapay sinir ağları ile Blockchain verilerine dayı Bitcoin fiyat tahmini, *Bilişim Sistemleri ve Yönetim Araştırmaları Dergisi*, 2(1), 1-9.