



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



YAPAY ZEKA YÖNTEMLERİYLE KRİPTO
PARA FİYAT TAHMİNİ

Mehmet ACAR

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı
Yazılım Mühendisliği Bilim Dalı

Aralık-2022
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Mehmet ACAR tarafından hazırlanan “Yapay Zeka Yöntemleriyle Kripto Para Fiyat Tahmini” adlı tez çalışması 05/12/2022 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Hüseyin HAKLI

.....

Danışman

Dr. Öğr. Üyesi Vahit TONGUR

.....

Üye

Doç. Dr. Sait Ali UYMAZ

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Mehmet ACAR
05.12.2022

ÖZET

YÜKSEK LİSANS TEZİ

YAPAY ZEKA YÖNTEMLERİYLE KRIPTO PARA FİYAT TAHMİNİ

Mehmet ACAR

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Yazılım Mühendisliği Bilim Dalı**

Danışman: Dr. Öğr. Üyesi Vahit TONGUR

2022, 78 Sayfa

Jüri

**Doç. Dr. Hüseyin HAKLI
Doç. Dr. Sait Ali UYMAZ
Dr. Öğr. Üyesi Vahit TONGUR**

Son yıllarda yapay zeka hemen hemen her sektörde yer almakla birlikte önemi giderek artmaktadır. Gelişen teknolojiler ve artan veri miktarı, yapay zekayı bütün sektörlerde kaçınılmaz hale getirmiştir. Bu çalışmada yapay zeka yöntemlerinden derin öğrenme, polinomal regresyon ve destek vektör regresyonu modelleri oluşturularak hayatımıza yakın bir zaman önce giren ve şu an toplumun büyük bir kesimi tarafından bilinen kripto para birimi bitcoin'in 01.03.2017 – 01.10.2022 tarihleri arasındaki 2.072 adet veri noktasından oluşan veri kümesi üzerinde eğitilip test edilmiştir. Veri kümesi bitcoin'in günlük *kapanış, en yüksek, en düşük, açılış, hacim ve piyasa değeri* niteliklerinden oluşmaktadır. Modeller, veri kümesindeki öznitelikleri kullanarak hedef nitelik olan bitcoin'in kapanış fiyatını tahmin etmeye çalışmıştır. Modellerin eğitimi sırasında veri kümesinden bağımsız bir şekilde yüksek başarı elde etmek için 5 kat çapraz doğrulama ve ızgara arama yöntemi kullanılmıştır. Modeller, eğitildikten sonra daha önce görmediği test verileriyle test edilip performans değerleri ölçülmüştür. Performans ölçütü olarak R-kare, ortalama mutlak hata ve ortalama karesel hataların karekökü metrikleri kullanılmıştır. Modellerin performans değerleri göz önüne alındığında birbirlerine yakın sonuçlar elde ettiği görülmekle birlikte derin öğrenme ve destek vektör regresyonu modelleri polinomal regresyon modeline göre daha başarılı olduğu tespit edilmiştir.

Anahtar Kelimeler: Bitcoin, Blokzincir, Derin Öğrenme, Destek Vektör Regresyonu, Kripto Para, Makine Öğrenmesi, Polinomal Regresyon, Yapay Zeka

ABSTRACT

MS THESIS

CRYPTOCURRENCY PRICE PREDICTION WITH ARTIFICIAL INTELLIGENCE METHODS

Mehmet ACAR

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

Advisor: Asst. Prof. Dr. Vahit TONGUR

2022, 78 Pages

Jury

**Assoc. Prof. Dr. Hüseyin HAKLI
Assoc. Prof. Dr. Sait Ali UYMAZ
Asst. Prof. Dr. Vahit TONGUR**

In recent years, artificial intelligence has taken place in almost every sector, but its importance is gradually increasing. Developing technologies and increasing amount of data have made artificial intelligence inevitable in all sectors. In this study, deep learning, polynomial regression and support vector regression models from artificial intelligence methods were created, and the crypto currency bitcoin, which has entered our lives recently and is now known by a large part of the society, is selected from 2.072 data points between 01.03.2017 and 01.10.2022. trained and tested on the resulting dataset. The dataset consists of bitcoin's daily close, high, low, open, volume and market cap attributes. The models tried to predict the closing price of the target attribute, bitcoin, using the attributes in the dataset. During the training of the models, 5-fold cross validation and grid search method were used to achieve high success regardless of the data set. After the models were trained, they were tested with test data that they had not seen before and their performance values were measured. R-square, mean absolute error, and root mean square error metrics were used as performance measures. Considering the performance values of the models, it is seen that the results are close to each other, but it has been determined that the deep learning and support vector regression models are more successful than the polynomial regression model.

Keywords: Artificial Intelligence, Bitcoin, Blockchain, Cryptocurrency, Deep Learning, Machine Learning, Polynomial Regression, Support Vector Regression

ÖNSÖZ

Günümüzde oldukça önemli olan ve her geçen gün birçok sektörde yer edinen yapay zeka, blokzincir ve kripto varlıklar gibi konuları içeren bu tez çalışmasını gerçekleştirmekten dolayı mutluluğumu ifade etmek isterim.

Çalışma sürecinin her aşamasında bilgilerini, tecrübelerini ve değerli zamanını esirgemeyerek bana her fırsatta yardımcı olan kıymetli hocam Sayın Dr. Öğr. Üyesi Vahit TONGUR'a ve yüksek lisans öğrenimim boyunca bilgilerinden faydalandığım değerli tüm hocalarıma teşekkürlerimi sunarım.

Her zaman ve her koşulda olduğu gibi tüm bu çalışma süreci boyunca bana destek olan sevgili eşim Ayşenur ACAR'a, üzerimde çok büyük emekleri olan kıymetli anneme ve babama, varlıklarından her zaman güç aldığım kardeşlerim Hakan ACAR'a ve Furkan ACAR'a sevgilerimi sunarım.

Mehmet ACAR
KONYA-2022

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER.....	vii
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	3
3. MATERYAL VE YÖNTEM.....	8
3.1. Kripto Para ve Bitcoin	8
3.1.1. Kripto para	8
3.1.2. Bitcoin.....	12
3.2. Veri Kümesi	19
3.2.1. Temel kavramlar	19
3.2.2. Veri kümesinin oluşturulması	23
3.2.3. Bağımlı ve bağımsız nitelikler	26
3.2.4. Veri kümesinin analizi	27
3.3. Derin Öğrenme	27
3.3.1. Aktivasyon fonksiyonları	30
3.3.2. Seyreltme (dropout)	33
3.3.3. Optimizasyon algoritmaları	34
3.4. Polinomal Regresyon	35
3.5. Destek Vektör Regresyonu	36
3.6. Çapraz Doğrulama	36
3.7. Izgara Arama.....	38
3.8. Performans Metrikleri	38
3.8.1. Ortalama mutlak hata (MAE)	38
3.8.2. Ortalama karesel hata (MSE).....	39
3.8.3. Ortalama karesel hata karekökü (RMSE)	39
3.8.4. R kare	40
3.9. Deneysel Çalışma Ortamı	40
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	42
4.1. Derin Öğrenme Modeli	42
4.2. Polinomal Regresyon Modeli	45
4.3. Destek Vektör Regresyonu Modeli.....	47
5. SONUÇLAR VE ÖNERİLER	51
5.1 Sonuçlar	51
5.2 Öneriler	52

KAYNAKLAR	54
EKLER	64



1. GİRİŞ

Kripto para birimleri, şu an herhangi bir merkezi olmayan tamamen elektronik ortamda şifreli bir şekilde belirli algoritmalarla üretilen fiziksel olmayan para birimleridir. Aynı zamanda bir merkezi olmayan bu elektronik para birimleri birbirleriyle takas edilebilmektedir (Doran, 2014).

Para transferleri günümüzde elektronik olarak banka sistemleriyle yapılmaktadır. Bankalar bu işlemler için müşterilerden ücret almaktadır. Bununla birlikte alıcı ve gönderici arasında bir aracıya ihtiyaç duyulmaktadır (Şahin ve Özkan, 2018). Bu yüzden finans ve teknolojiye alıcı ve gönderici dışında bir tarafa ihtiyaç duyulmayan sistemler üzerinde çalışılmıştır. Kripto para birimlerinin merkezi otoritelerce kontrol edilmemesi en çok gözen çarpan özelliğidir (Rose, 2015).

Kripto para birimlerinin sayısı gün geçtikçe artmaktadır. Aynı zamanda ekonomik hacmi, yatırımcı sayısı ve bu alandaki akademik çalışmalar da artmaktadır (Karaağaç ve Altınırnak, 2018). Akademik topluluk da benzer şekilde kripto para ticaretini araştırmak için önemli çabalar harcamaktadır (Fang ve ark., 2022).

Kripto para birimleri, merkezi bir yapıda olmama, değişmezlik ve şeffaflık elde etmek için blokzincir teknolojisinden faydalanır (Meunier, 2018).

Yapay zekanın herkes tarafından benimsenen belirli bir tanımı olmadığı iyi bilinmektedir (Allen, 1998; Brachman, 2006; Kirsh, 1991; Simon ve ark., 2000). Bununla birlikte yapay zekayı şöyle tanımlayabiliriz; herhangi bir durumda insanı taklit eden ve topladığı bilgilerle kendisini daha iyi duruma getiren sistem veya makinelerdir. Yapay zeka sistemleri gün geçtikçe daha zeki hale gelmektedir (İnik ve Ülker, 2017a). Yapay zeka birçok alanda kullanılmaktadır. Kullanımının ve öneminin artmasıyla birlikte hemen hemen herkes tarafından bilinmektedir. Yapay zeka ekonomi, bilim, teknoloji ve sosyal yaşam gibi birçok alanı olumlu yönde etkilemektedir. Son yıllarda yapay zeka, Avrupa Birliği ülkeleri ve Amerika Birleşik Devletleri gibi gelişmiş ülkelerde olduğu kadar Hindistan ve Çin gibi dünyanın üretim merkezi olan ülkelerde ekonomik büyümeye katkısından dolayı dikkat çekmektedir (Lu ve ark., 2018).

İkinci dünya savaşından sonra birkaç araştırmacı bağımsız olarak akıllı makineler üzerinde çalışmaya başlamıştır. Bu alandaki ilk araştırmacılardan birisi Alan Turing'dir. Turing bu konu üzerine 1947 yılında bir konferans vermiştir (Mccarthy, 2007).

Günlük yaşantımızdaki işler, hemen hemen her alanda internetle yürütülmektedir. Teknolojinin gelişmesiyle birlikte bu durum giderek artmaktadır. Yazılım ve internetle

birlikte her sektörde büyük bir gelişim sağlanmaktadır. Tüm bunlara ek olarak yapay zeka bütün sektörlerde hızlı bir giriş yapmıştır.

Bu çalışmada kripto para olarak ilk ortaya atılan, en çok bilinen ve en büyük piyasa hacmine sahip olan bitcoin'in günlük verileri ele alınarak ilgili güne ait kapanış verisi üç farklı makine öğrenmesi yöntemiyle tahmin edilmeye çalışılmıştır. Bu yöntemler derin öğrenme, polinomal regresyon ve destek vektör regresyonudur. Çalışmada kullanılan yöntemlerin hangi parametrelerle ne kadar başarılı olduğu belirlenerek her bir yöntem için en iyi tahminleri yapan modeller ve parametreleri ortaya koyulup literatüre katkı yapılarak sonraki çalışmalara ışık tutması amaçlanmıştır.

Bu çalışmanın “Kaynak Araştırması” bölümünde literatürde çalışmayla benzer yapılan çalışmalar incelenmiş ve aynı zamanda yapay zekanın tarihsel süreci anlatılmıştır.

Çalışmada kullanılan yapay zeka yöntemleri ve modellerin geliştirilmesinde kullanılan teknikler “Materyal ve Yöntem” bölümünde anlatılmıştır.

Her bir model için elde edilen performans metrikleri ve modellerin tahmini ile gerçek verilerin karşılaştırıldığı nokta grafikleri “Araştırma Sonuçları ve Tartışma” bölümünde yer almıştır.

Elde edilen sonuçların karşılaştırılmasına, değerlendirilmesine ve önerilere “Sonuçlar ve Öneriler” bölümünde yer verilmiştir.

2. KAYNAK ARAŞTIRMASI

Yapay zekanın temelleri 1943 yılına dayanmaktadır. Bu tarihte Warren McCulloch ve Walter Pitts ilk yapay sinir ağı modelini geliştirmişlerdir (McCulloch ve Pitts, 1943). İnsan beyninden esinlenerek elektronik devreleriyle yapay sinir ağı geliştiren McCulloch ve Pitts, bu alanda ilk adımı atmıştır (Keskenler ve Keskenler, 2017).

Alan Turing 1950’de kaleme aldığı “Computing Machinery and Intelligence” adlı makalesinde bir makineyi akıllı olarak değerlendirmenin koşullarını ortaya koymuştur. Eğer makine bilgili bir gözlemciye karşı başarılı bir şekilde insanmış gibi davranabiliyorsa, o zaman kesinlikle onu akıllı olarak düşünmeniz gerektiğini savunmuştur. Turing’in düşüncesine göre gözlemci, makine ve bir insanla etkileşime girecek ve insan, gözlemciyi insan olduğuna ikna etmeye çalışırken makine de aynı şekilde kendisini insanmış gibi göstermeye çalışacaktı (Turing, 1950). Turing’in fikirleri geniş çapta tartışılmıştır. Bir tarafta, Turing’in makalesinin yapay zekanın başlangıcı kabul edilirken diğer tarafta, Turing Testi yararsız, hatta zararlı olarak adlandırılmıştır. Arada bilinç, davranışçılık, “öteki zihinler” sorunu, zekanın işlevsel tanımları vb. üzerine tartışmalar devam etmektedir (Copeland, 2000; Saygın ve ark., 2000).

Turing Testi sezgisel olarak ilgi çekicidir ve insanlar tarafından yapay zekanın tanımı olarak geniş bir kitle tarafından kabul edilmiştir. Ancak, uygulamaya geçildiğinde çoğu projede insan gibi davranmayı amaçlamaz. Yapay zekanın tüm alanları arasında Turing Testine en yakın olan sohbet robotları ve uygulamaları üzerinde yapılan çalışmalar, son yıllarda çoğu araştırmacılar tarafından ciddiye alınmamıştır (Wang, 2019). Turing Testi, bazı etkili yapay zeka araştırmacıları tarafından dikkat dağıtıcı ve hatta zararlı olarak eleştirilmiştir (Hayes ve Ford, 1995; Laird ve ark., 2009; Marcus ve ark., 2016).

1951 yılında Snark adlı nörobilgisayar Marvin Minsky tarafından ilk defa ortaya konulmuş ancak bu kullanılamamıştır (Kriesel, 2007).

1957 yılında ilk başarılı nörobilgisayar Mark I Perceptron Rosenblatt ve ekibi tarafından ortaya konulmuştur. 20x20 piksellik sensörle sayı tanıyan bir yapıya sahipti (Rosenblatt, 1961).

Modern mikroişlemcilerin mucidi olarak bilenen Widrow ve onun doktora öğrencisi Hoff tarafından Stanford Üniversitesinde 1959’da mühendislik alanındaki ilk yapay sinir ağı modeli olan ADALINE (Adaptive Linear Neuron) geliştirilmiştir (Widrow

ve Hoff, 1960). Bu modelin literatüre girmesiyle kendisinden sonraki çalışmalara da ışık tutmuştur.

Yapay zeka konusunda bilinen isimlerden Papert ve Minsky, “perceptrons” adlı kitabı kaleme almıştır (Minsky ve Papert, 1969). Bu kitapta yapay sinir ağlarının yetersiz ve birçok problemi çözemediğini ispat etmeye çalışmışlardır.

Fukushima, Neocognitron modelini bilim dünyasına kazandırmıştır. Neocognitron 1970’li yıllarda görüntü işleme amacıyla ortaya konulmuştur (Fukushima, 1986; Fukushima ve ark., 1983). Modelin literatüre kazandırılmasıyla birlikte yapay sinir ağları mühendislik alanında ilerleme kaydetmiştir (Kriesel, 2007).

Günümüzde elde edilen veri miktarı, teknoloji ve internet kullanımının artmasıyla birlikte çok büyük boyutlara gelmiştir. Örnek olarak Google 20.000 TB günlük veri işlemektedir. Amerikan Ulusal Güvenlik Ajansı günlük 1840 TB veri işlemektedir (Q. Zhang ve ark., 2018). Bu yüzden derin öğrenme modellerinde kullanılacak veri kümelerine çok daha rahat erişilmektedir.

2012 yılında düzenlenen ImageNet (Görsel tanıma) yarışması derin öğrenme için büyük bir çıkış yılı olmuştur (İnik ve Ülker, 2017b). Yarışmayı Evrişimsel Sinir Ağı ile geliştirilen model kazanmıştır (Krizhevsky ve ark., 2012). Bununla birlikte derin öğrenmenin önemi artmıştır.

Derin Öğrenme siyah beyaz resimler ve filmlerin renklendirilmesi için kullanılmıştır ve bu alanda çeşitli çalışmalar yapılmıştır (Cheng ve ark., 2015; Hwang ve Zhou, 2016; Larsson ve ark., 2016; R. Zhang ve ark., 2016).

Borsa İstanbul (BİST 100) endeksinin tahminine yönelik çalışmada Arma, yapay sinir ağı ve Newton nümerik arama modeli karşılaştırılmıştır. Bu yöntemler arasında yapay sinir ağı modeli en başarılı sonuçları vermiştir (Aygören ve ark., 2012).

Destek Vektör Makinesi ve Doğrusal Regresyon modelleri kullanılarak 2012 ile 2018 yılları arasındaki bitcoin verileri analiz edilmiştir. Bu analizde bitcoin kapanış fiyatı tahmin etme konusunda hangi modelin daha başarılı olduğu araştırılmıştır. Gözlemler sonucunda istatistiksel metrikler yardımıyla değerlendirildiğinde önerilen destek vektör makinesi modelinin daha başarılı olduğu gözlemlenmiştir (Karasu ve ark., 2018).

Kripto para birimi tahmininde derin öğrenmeyi kullanan ve ilk çalışmalardan birisini yapan Lahmire ve Bekiros, Bitcoin, Digital Cash ve Ripple gibi en çok işlem gören üç dijital para biriminin fiyatını tahmin etmek için derin öğrenme tekniklerini uygulamışlardır. Uzun-kısa süreli bellek (LSTM) ile genelleştirilmiş regresyon sinir ağları (GRNN) arasında deneysel bir karşılaştırma yapılmış ve LSTM sinir ağlarının

Bitcoin, Digital Cash ve Ripple'ın gelecekteki fiyat değerlerini tahmin etmede GRNN'den daha iyi performans gösterdiğini savunmuşlardır (Lahmiri ve Bekiros, 2019).

Graves ve Au 2015 yılında yaptığı çalışmada makine öğrenmesi yöntemleriyle bitcoin'nin gelecek fiyat verisinin başarılı bir şekilde elde etmenin teknik veri kümeleriyle pek mümkün olmadığını, başarılı olmak için bu teknik bilgilere ek olarak bitcoin yatırımcılarının davranışları gibi ağ dışı verilerin eklenmesi gerektiğini belirtmişlerdir (Greaves ve Au, 2015).

Bitcoin fiyatının Amerikan doları cinsinden ne kadar doğru tahmin edilebildiğini tespit etmek için McNally ve arkadaşları tarafından bir çalışma yapılmıştır. Çalışmada (LSTM) uzun kısa süreli bellek, ARIMA modeli ve tekrarlayan sinir ağı (RNN) kullanılmıştır. Derin öğrenme modelleri RNN ve LSTM, ARIMA'ya göre daha başarılı sonuçlar vermiştir. LSTM %52 başarı ile en yüksek sonucu vermiştir (McNally ve ark., 2018).

Ji ve arkadaşları bitcoin blok zinciri bilgilerini kullanarak çeşitli derin öğrenme tabanlı bitcoin fiyat tahmin modelleri geliştirip karşılaştırmışlardır. Derin sinir ağları (DNN), uzun kısa süreli bellek (LSTM) modelleri, evrişimli sinir ağları (CNN), derin artık ağlar (ResNet) gibi son teknoloji derin öğrenme modellerini test etmişlerdir. Çalışmada gelecekteki bitcoin fiyatını ve fiyatın yükselip yükselmeyeceğini tahmin eden hem regresyon hem de sınıflandırma problemleri ele alınmıştır. Regresyon problemleri için LSTM, diğer modellerden biraz daha iyi performans gösterirken, sınıflandırma problemlerinde DNN, bitcoin fiyat tahmini ile ilgili önceki literatürün aksine diğer modellerden biraz daha iyi performans göstermiştir. Sonuç olarak karşılaştırmanın bariz bir kazananının olmadığı ve tahmin doğruluğunu geliştirmek için borsa endeksleri, büyük döviz kurları gibi diğer faktörlerin yanında haberler ve sosyal medyanın dahil edilebileceği vurgulanmıştır (Ji ve ark., 2019).

Almasri ve Arslan 2018 yılında 6. Uluslararası Kontrol Mühendisliği ve Bilgi Teknolojisi Konferansında yapay sinir ağlarıyla kripto para birimlerinin kapanış fiyatlarını tahmin ettikleri çalışmayı yayınlamışlardır. Çalışmaya göre oluşturulan modelin eğitimi için toplanan ilk veri seti, günlük kapanış fiyatı ve hacim değerlerine dayalı olarak 03.02.2017 ile 10.03.2018 tarihleri arasındaki 400 gözleme aittir ve tahminler Mart-Nisan 2018 arasındaki 31 günlük kapanış fiyatları üzerinden yapılmıştır. Diğer veri seti, 27.03.2018 ile 03.04.2018 arasındaki saatlik kapanış fiyatlarına dayanan 200 gözleme ait olup tahminler 04.04.2018 ile 11.04.2018 arasındaki saatlik kapanış fiyatları üzerinde gerçekleştirilmiştir. Modelin bitcoin için tahmin başarısı %75 ile %97,3

arasında olduğu açıklanarak belirli bir kripto para biriminin tahmini konusunda iyi sonuçlar elde etmek için özel model veya stratejilere ihtiyaç duyabileceği açıklanmıştır (Almasri ve Arslan, 2018).

Malsa ve arkadaşlarının yaptığı çalışmada Ethereum, Cardano, EOS, NEO ve Tron kripto para birimlerini tahmin etmek için bir LSTM modeli kullanılmıştır. Modelin değerlendirilmesi için ortalama hata kare kökü (RMSE) metriği kullanılmıştır. TRON'un en yüksek ve en düşük kapanış fiyatları arasındaki farkın diğerlerine göre birbirine daha yakın olduğu, bunun aksine Ethereum'un ise en yüksek ve en düşük kapanış fiyatları arasındaki farkın diğer birimlere göre daha büyük olduğu gözlemlenmiştir. Bir para biriminin kapanış fiyatları arasında daha az fark varsa, LSTM modelinin o para birimi için daha iyi performans gösterdiği ve daha büyük fark olması durumunda tersine döndüğü sonucuna varılmıştır. Bu nedenle, daha fazla fiyat değişikliği durumunda daha fazla risk olduğu görülmüştür. Tron kripto para birimi en az RMSE'ye sahiptir ve Ethereum en kötü RMSE'ye sahiptir. Dolayısıyla, LSTM modelinin Tron veri seti için en uygun model olduğu ve gelecek için doğru fiyatları tahmin edebileceği sonucuna varılmıştır (Malsa ve ark., 2021).

Ji ve arkadaşları bitcoin blok zinciri bilgilerini kullanarak derin öğrenme tabanlı Bitcoin fiyat tahmin modellerini karşılaştırmışlardır. Derin sinir ağları (DNN), uzun kısa süreli bellek (LSTM), evrişimli sinir ağları (CNN) ve derin artık ağlar (ResNet) gibi derin öğrenme modeller test edilmiştir. İlkini gelecekteki Bitcoin fiyatını tahmin ettiği ve ikincisinin gelecekteki fiyatın yükselip yükselmeyeceğini tahmin ettiği hem regresyon hem de sınıflandırma problemleri ile ele alınmıştır. Regresyon problemleri için, LSTM diğer modellerden biraz daha iyi performans gösterirken, sınıflandırma problemlerinde DNN, Bitcoin fiyat tahmini üzerine önceki literatürün aksine diğer modellerden biraz daha iyi performans gösterdiği belirtilmiştir. Genel olarak, net bir kazananın olmadığı açıklanmıştır (Ji ve ark., 2019).

McNally ve ark. bitcoin'in gelecekteki fiyatlarının tahmini konusunda yapılan bir başka bir çalışmada ise LSTM en yüksek doğruluğu elde ederken, RNN en düşük RMSE'yi elde etmiştir. ARIMA'nın tahmini, doğruluk ve RMSE açısından zayıf performans göstermiştir. Doğrulama verilerindeki sonuçlara dayanarak, tüm modellerin verilerden etkili bir şekilde öğrenmeyi gerçekleştirdiği açıklanmıştır (McNally ve ark., 2018).

Saad ve arkadaşlarının 2020 yılında yaptığı çalışmada üç yöntem bitcoin fiyat tahmini konusunda ele alınmıştır. Çalışmaya göre, linear regression (LR), Bitcoin veri

kümesinde en yüksek doğruluk ve düşük hata elde ederken, bunu sırasıyla random forest (RF) ve gradient boosting (GB) izlemiştir. GB, Ethereum veri kümesinde en yüksek doğruluğu elde etmiştir, bunu RF ve LR izlemiştir. Eğitim verilerinin yüzdesi azaldıkça, doğruluk azalmış ve hata artmıştır. Bitcoin veri kümesinde elde edilen maksimum doğruluk, %10 test verisi ile 0,9957 olarak bulunmuştur. Ethereum veri kümesinde elde edilen maksimum doğruluk, %10 test verisi ile 0,9999 olmuştur. Tasarım tabanlı örnekleme, rastgele örneklemeyle kıyasla her zaman daha düşük doğruluk (maksimum 0,901) elde etmiştir. Tasarım tabanlı örneklemede LR, GB ve RF'den daha iyi performans göstermiştir. Bitcoin özellikleri arasında fiyatı ile Ethereum'a kıyasla daha doğrusal bir ilişki olduğu görülmüştür (Saad ve ark., 2020).




3. MATERYAL VE YÖNTEM

3.1. Kripto Para ve Bitcoin

3.1.1. Kripto para

Kripto para birimlerini kısaca açıklamak gerekirse; fiziksel olmayan, tamamen internet ortamında işlem gören ve bir merkezi olmayan para birimleridir. Bununla birlikte kısa bir süre önce finans sektörüne girmesine rağmen oldukça yaygın bir şekilde kullanılmaktadır. Kripto para teknolojileri gün geçtikçe hızla geliştirilmekte ve yenilikler getirilmektedir.

Para transferleri günümüzde elektronik olarak banka sistemleriyle yapılmaktadır. Bankalar bu işlemler için müşterilerden ücret almaktadır. Bununla birlikte alıcı ve gönderici arasında bir aracıya ihtiyaç duyulmaktadır (Farell, 2015; Şahin ve Özkan, 2018). Bu yüzden finans ve teknolojide alıcı ve gönderici dışında bir tarafa ihtiyaç duyulmayan sistemler üzerinde çalışılmıştır. Şekil 3.1’de merkezi ve merkeziyetsiz sistemler basit bir şekilde gösterilmiştir.



Şekil 3.1. Merkezi ve merkeziyetsiz sistemler (Cointelegraph, 2022)

Bankacılık sistemleri merkezi bir sistem olarak çalışır. İki kişi arasındaki para transferi üçüncü bir kişi olarak bankalar tarafından kayıt altındadır. Kripto para sistemleri

merkeziyetsiz bir yapıda olduğu için herhangi bir kontrol mekanizması yoktur (Lepore ve ark., 2020). Doğrudan iki kişi arasındaki iletişim gerçekleşir.

Kripto paraların temeli, ilk olarak 2008 yılında blokzincir teknolojisinin tanıtıldığı ve bu tanıtılan algoritmayı kullanarak ortaya atılan “Bitcoin: A Peer-to-Peer Electronic Cash System” isimli makalesinde bitcoin ile atılmıştır (Nakamoto, 2008). Bitcoin kısa bir zaman içerisinde yatırımcılardan, finans sektöründen ve medyadan büyük ilgi görmüştür (Caporale ve ark., 2018). Kripto paralar uçtan uca elektronik nakit sistemleri olduğu için para transferleri ve ödemelerde herhangi bir kurum ya da kuruluşun onayından geçmeden doğrudan gönderilmesine olanak sağlamaktadır (Carrick, 2016; Corbet ve ark., 2019; Dwyer, 2015). Bu durum güvenlik açısından herhangi bir sorun oluşturmamaktadır (Kesebir ve Günceler, 2019).



Çizelge 3.1. Piyasa değeri en yüksek ilk 20 kripto para


No	Kripto Para	Sembol	Piyasa Değeri (\$)	Fiyat (\$)	Dolaşan Arz
1	Bitcoin	BTC	815.525.085.029	43.061,11	18.929.937
2	Ethereum	ETH	396.187.174.778	3.322,33	119.168.256
3	BNB	BNB	82.318.415.943	493,27	166.801.148
4	Tether	USDT	78.438.945.488	1	78.399.569.301
5	Solana	SOL	45.730.866.226	145,90	314.010.762
6	USD Coin	USDC	45.217.210.066	0,9999	45.234.923.702
7	Cardano	ADA	42.661.505.854	1,27	33.526.778.052
8	XRP	XRP	37.123.349.587	0,7775	47.663.117.635
9	Terra	LUNA	29.425.226.733	82,03	359.212.247
10	Polkadot	DOT	27.216.916.754	27,52	987.579.315
11	Dogecoin	DOGE	25.116.453.584	0,1894	132.670.764.300
12	Avalanche	AVAX	22.094.121.111	90,42	244.353.374
13	Polygon	MATIC	17.170.065.321	2,35	7.312.892.503
14	Shiba Inu	SHIB	17.068.563.633	0,00003109	549.063.278.876.302
15	Binance USD	BUSD	14.402.707.419	1	14.392.136.790
16	Chainlink	LINK	12.107.542.301	25,93	467.009.550
17	Near Protocol	NEAR	11.922.403.012	19,42	614.069.768
18	Crypto.com Coin	CRO	11.669.218.204	0,4619	25.263.013.692
19	Wrapped Bitcoin	WBTC	11.510.142.691	43.128,41	266.881
20	TerraUSD	UST	10.619.662.705	0,9992	10.628.271.541

Kaynak: <https://coinmarketcap.com> (Erişim Tarihi: 15.01.2022)

Çizelge 3.1’de şu an piyasada en büyük hacme sahip ilk yirmi kripto para verileri listelenmiştir. Çizelgede bulunan kripto paraların dışında binlerce kripto para mevcuttur.

Şu an dünya piyasasında <https://coinmarketcap.com> (erişim tarih: 15.01.2022) internet sitesinden alınan bilgiye göre bütün mevcut kripto paraların toplam piyasa değeri 2.064.366.947.876 Amerikan dolarıdır (CoinMarketCap, 2022).

Şekil 3.2’de kripto paraların piyasa hakimiyeti gösterilmektedir. Grafiğe göre piyasada en büyük varlığa sahip kripto para bitcoin olarak görülmektedir.



Şekil 3.2. Kripto paraların piyasa hakimiyeti (Coin Dance, 2022)

Daha önceden bitcoin’nin piyasa hakimiyeti daha fazla olmasına rağmen gün geçtikçe yeni kripto varlıkların çıkması, teknolojik gelişmeler ve kripto para sektöründeki hızlı değişimle beraber düşmektedir. Yerini yeni teknolojilere bırakmaktadır.

3.1.2. Bitcoin

Bitcoin, merkezi olmayan elektronik bir ödeme sistemidir. Üçüncü taraflara veya aracıya ihtiyaç duymadan şifrelenmiş şekilde doğrudan uçtan uca para transferi yapılabilir. Bitcoin tasarımı açık kaynaklıdır ve bir sahibi yoktur (Conti ve ark., 2018; Wust ve Gervais, 2018; Yaga ve ark., 2019).

Başka bir tanım yapmak gerekirse; Bitcoin, banka ve finans kuruluşları gibi merkezi yapıların aksine eşler arası teknolojiyi kullanır. İşlemlerin yönetimi ve bitcoinlerin verilmesi ağ tarafından toplu olarak gerçekleştirilir. Bitcoin açık kaynak bir algoritmadır, önceki ödeme sistemlerinden farklı bir kullanıma sahiptir (*Bitcoin.Org*, 2022). Bitcoin ilk ortaya çıktığı günden bu zamana kadar çok popüler hale gelmiştir (Urquhart, 2016).


Kripto paraların birçoğunun arkasındaki çalışma şekli “blokzincir” sistemidir. Blokzincir teknolojisi ilk defa Satoshi Nakamoto isimli kişinin “Bitcoin: A Peer-to-Peer Electronic Cash System” (www.bitcoin.org/bitcoin.pdf) isimli yazısında bahsedilmiştir. Bu yazı çok ses getirmesine rağmen hiçbir zaman bilimsel bir metin olarak hakemli bir dergilerde yer almamıştır. Yazarın gerçek kimliği bilinmemektedir. Blokzincir sistemi sadece kripto paraların altyapısında değil, günümüzde uygulanan finans sistemlerinde de kullanılmaya başlanmıştır (Treleaven ve ark., 2017). Akıllı kontratlar gibi yepyeni sistemlerin gelişmesine katkıda bulunmuştur (Pierro, 2017).

Blokzincir kavramı literatüre girdiğinden beri hızlı bir şekilde bilinirliği artmıştır. Özellikle son 5 yılda insanlar arama motorlarında sıklıkla bu kelimeyi araştırmıştır. Şekil 3.3’te Google arama motorunda “blokzincir” kelimesinin tarihlere göre aranma sıklığı gösterilmektedir. Şekilde görüldüğü üzere 2017 ve 2018 yıllarını kapsayan zaman aralığında çok yüksek bir aranma oranı görülmektedir.




Şekil 3.3. “Blokzincir” kelimesinin aranma sıklığı (Google Trends)

Blokzincir, açık bir ortamda bilgi depolamak, işlemleri yürütmek, işlevleri yerine getirmek ve güven oluşturmak için yenilikçi bir yaklaşım sunar. Bitcoin gibi kripto para biriminden akıllı sözleşmelere, Nesnelerin İnterneti üzerinden akıllı şebekelere ve benzerlerine kadar çeşitli kullanım örnekleriyle blok zinciri kriptografi ve siber güvenlik için bir teknoloji atılımı olarak görülmüştür (R. Zhang ve ark., 2019). Blokzincir dijital dünyada devrim yaratmıştır. Sistemlerin güvenliğine, esnekliğine ve verimliliğine yeni bir bakış açısı getirmiştir. Başlangıçta Bitcoin tarafından popüler hale getirilmiş olsa da blokzincir, kripto para birimi için çok daha fazlasıdır. Her türlü mal, hizmet veya işlemin güvenli bir yolunu sunabilmektedir (Ahram ve ark., 2017). Şekil 3.4'te bitcoin'e yatırım yapan yatırımcıların yaş aralıklarına göre yüzdelik dilimleri görülmektedir.




Şekil 3.4. Yaşlara göre bitcoin'e katılım oranları (Coin Dance, 2022)

Şekil 3.5'te bitcoin'e cinsiyetlere göre yatırım yapan kişilerin yüzdelik dilimleri görülmektedir.



Şekil 3.5. Cinsiyete göre bitcoin'e katılım oranları (*Coin Dance*, 2022)

Blokszincir yapısı, üçüncü taraflara ihtiyaç duymak yerine şifreli algoritmalarla doğrudan iki taraf arasında birbiriyle bilgi transferi yapabilmeyi mümkün kılar (Nakamoto, 2008). Bu sistemle merkezi yapılara yani banka, finans kuruluşları ve merkez bankası gibi üçüncü taraflara ihtiyaç duyulmamaktadır. Basit bir mantıkla blokszincir sistemi muhasebe defterine benzer bir yapıda düşünülebilir (Mukhopadhyay ve ark., 2016; Şahin, 2018). Taraflar arasında yapılan işlemler şifrelenmiş şekilde kayıt altına alınır. Şekil 3.6'da blokszincir sisteminin temel işleyişi görülmektedir.




Şekil 3.6. Blokzincir işlem süreci (Nakamoto, 2008)

Bitcoin sistem olarak 21 milyon adet olacak şekilde tasarlanmıştır ve bunu belirli bir ödül sistemine göre madencilik hizmeti yapan kişilere dağıtmaktadır (Bhaskar ve Chuen, 2015; Malone ve O'Dwyer, 2014; Nakamoto, 2008). Sınırlı bir kaynak olan bitcoin şu an piyasada 18.933.218 adet arza sahiptir (CoinMarketCap, 2022). Her bir bitcoin 100 milyon parçaya bölünebilir ve en küçük parçaya “satoshi” denilmektedir (Berentsen ve Schär, 2018).

Ödül sistemi blokzincir yapısının temelini oluşturur (Yuan ve Wang, 2016). Madencilik yapan sistem belirli kriptolanmış problemleri çözerek ödülü almaya çalışır. Problemi ilk çözen madenci daha önceden belirlenmiş ödülü kazanır. Madencilere verilen ödül her 210 bin blokta bir yarılanmaktadır (Ghosh ve ark., 2020). Sonuç olarak bitcoin bilinen para sistemleri gibi belirli bir kontrol mekanizmasından geçerek arz edilmeyip kendi kendine çalışan bir algoritmaya göre sistemli bir şekilde arz edilir (Cheung ve ark., 2015).

Şekil 3.7’de blokchain yapının nasıl olduğu ve her bloğun kendisinden önceki ve sonraki bloklarla ardışık bir şekilde bağlı olduğunu gösteren basit bir tablo verilmiştir.



Şekil 3.7. Blokchain'deki blok bağlantıları (Cointelegraph, 2022)

Blockchain, bilinen veri tabanı sistemlerinin aksine bir kayıt defteri gibi çalışır. Veriler değiştirilemez. Veriler arka arkaya eklenerek adeta bir zincir halinde çoğalır (Cointelegraph, 2022). Bloklar kendisinden önceki blokların bilgisi içerdiği için birbirine bağlıdır.

Proof of work: İş kanıtı anlamına gelir. Bir görevi yerine getirmek için emek harcadığının veya enerji tüketildiğini ispatlayan bir yöntemdir.

Blokszincir ile ilgili bazı temel terimlerin açıklamaları Çizelge 3.2'de verilmiştir.

Çizelge 3.2. Blokzincir ile ilgili anahtar terimler (Mukhopadhyay ve ark., 2016)


Teknik Terimler	Tanım
Block	İşlem verilerini içeren bir veri yapısı.
Blockchain	Şu ana kadar gerçekleşmiş bütün işlemlerin yer aldığı açık kaynaklı dijital bir defter. Dağıtılmış, kronolojik bir blok zincirinden oluşur ve tamamlanmış bloklara yeni bir kayıt eklendikçe sürekli büyür. Bloklar, önceki bloklardan gelen işlemleri ve bilgileri içerir. Her blok bir önceki bloğun bilgilerini içerdiğinden, şimdiye kadar gönderilen ilk bloktan mevcut bloğa benzersiz bir doğrusal yol vardır.
Mining	Bir kripto para birimi işlemi ve işlem kayıtlarının genel muhasebeye eklenmesi için gerekli doğrulama adıdır. Madencilik ayrıca sistemde yeni kripto para birimleri de sunmaktadır. Bu da ödül olarak madencilik yapan sisteme verilmektedir.
Hash	Girdi olarak herhangi bir boyuttaki veriyi alan ve sabit uzunlukta bir çıktı üreten tek yönlü bir işlev. Önceki bloktaki verilere ait özet fonksiyondur. Hash hesaplaması hızlı ve kolay olmalı, işlemi tersine çevirmek ise pahalı ve zor olmalıdır. Girdideki herhangi bir değişiklik tüm çıktıya yayılmalıdır, böylece benzer girdi için çıktılar tahmin edilebilir bir benzerliği olmaz.
Nonce	Genellikle belirli bir amaç için bir kez kullanılan rastgele seçilen ve sonra atılan bir sayı. Rastgele seçilen iki nonce aynı olduğunda meydana gelen nonce çarpışmaları göz ardı edilir.
Block Header	Blok başlığı, önceki bloğun hash'i, zaman damgasını, blok sürüm numarasını, bloktaki tüm işlemlere dayalı hash'i ve nonce'yi içerir.
Transaction counter	İşlem sayacı, bloğa dahil edilen işlem sayısı.
Transactions	İşlemler, blok tarafından eklenen numaralandırılmış doğrulanmış işlemler kümesi.

Block zincirde bulunan her bir blokta; blok numarası, önceki blok verilerinin özet fonksiyonu (hash), blok başlığı, zaman damgası, özet şifre, sihirli sayı gibi bilgiler bulunur. Çizelge 3.3'te blok içeriğinin temel olarak nasıl olduğunu gösteren bir tablo verilmiştir.

Çizelge 3.3. Blokzincir temel blok yapısı (*Cointelegraph*, 2022)

BLOK İÇERİĞİ			
Sihirli sayı		4 byte	"0xD9B4BEF9" şeklinde sabit değer
Yükseklik		4 byte	Blok numarası
BAŞLIK (HEADER)	Versiyon	4 byte	Kullanılan güncel sürüm
	Önceki başlık	32 byte	Önceki bloğun başlık özeti (hash)
	Merkle kökü	32 byte	İşlemlerin özet değeri (hash)
	Zaman damgası	4 byte	1 Ocak 1970'ten itibaren geçen süre
	Zorluk	4 byte	Ağın zorluk bilgisi
	Nonce	4 byte	Ağ zorluğuna göre ayarlanmış rastgele sayı
İşlem sayısı		1-9 byte	Belirli uzunlukta tam sayı değeri (integer)
İşlemler		-	Bloktaki transferlerin listesi

Bitcoin'nin piyasa değeri herhangi bir para birimine veya madene bağlı değildir. Tamamen arz talep dengesine bağlı olarak şeffaf bir şekilde fiyat belirlenmektedir. Bitcoin ortaya çıktıktan sonra birçok kripto para üretilmeye başlanmıştır. Bitcoin en büyük hacme sahip ve ilk ortaya çıkan birim oluğu için diğer "Altcoin" olarak adlandırılan kripto para birimlerinin piyasa değerini doğrudan etkilemektedir (Temelli, 2019).



Şekil 3.8. Bitcoin fiyat verileri (*Google Finans*, 2022)

Şekil 3.8’de Google finans sitesinden elde edilen bitcoin fiyat verileri gösterilmektedir. Bu grafiğe bakarak bitcoin hareketliliğinin 2017 yılından sonra hızla arttığını görülmektedir. Son birkaç yıldır da aşırı dalgalı bir fiyat verisi görülmektedir. Grafikteki yeşil sütunlar günlük işlem hacminin büyüklüklerini göstermektedir.

3.2. Veri Kümesi

3.2.1. Temel kavramlar

Veri kümesini kısaca açıklamak gerekirse; bir konu hakkında elde edilmiş sayısal ya da kategorik veriler bütününe denir. Örneğin bir sınıftaki öğrencilerin final puanları, cinsiyetleri, yaşları, saç rengi vb. bilgilerin olduğu tablo bir veri kümesidir.

Yapay zeka alanında veri kümesi, bir bilgisayar tarafından işlenmesi amacı için ele alınabilen veriler topluluğudur. Bu, makine öğrenmesi için toplanan verilerin tek tip ve anlaşılır hale getirilmesi gerektiği anlamına gelir. Bunun için, verileri topladıktan sonra ön işleme tabi tutmak gerekebilir. Sorunsuz ve hızlı eğitim için veri kümesi temiz ve dengeli olmalıdır. Mümkün olduğunda canlı verileri kullanılmalıdır. Verilerin hacmi ve toplanacağı kaynak hakkında deneyimli kişilerden yardım alınabilir (*Machine Learning Mastery*, 2022; *Towards Data Science*, 2022; Sydorenko, 2022).

Yapay zeka projesi için özgün ve sıfırdan bir veri kümesi oluşturmak, zaman ve kaynak bakımından oldukça maliyetli olabilir. Bu nedenle çalışmalarda genellikle önceden hazırlanmış veri kümeleri kullanılmaktadır.

	A	B	C	D	E	F	G
1							
2							
3							
4							
5							
6							
7							
8							
9							
10							
11							
12							
13							
14							
15							
16							
17							

Şekil 3.9. Örnek bir veri kümesi şablonu

Genellikle bir veri kümesinin yapısı Şekil 3.9’da görüldüğü gibidir. İlgili değişkenler altında gerekli veriler bulunur. Veri kümesi oluşturulmadan önce gözlemler çok iyi yapılmalı ve alakalı veriler ele alınmalıdır. Yeterli gözlem ve titiz bir değerlendirme yapılmadan elde edilen veri kümesi, oluşturulan model ne kadar iyi olursa olsun doğru sonuçlar vermeyecektir.

Veri kümesini daha detaylı incelemek gerekirse Şekil 3.10’da görüldüğü gibi düşünülebilir.

	x	y	z	class
	0.5351795492	0.9443102776	0.1582435145	1
	0.2372136152	0.6406416746	0.2375401506	1
	0.9115356348	0.3311024322	0.5615073269	0
	0.5634070287	0.4183148035	0.151904445	0
	0.3728975195	0.3816657621	0.616341473	1
	0.6783527289	0.938524515	0.5269012505	1
	0.09568660734	0.04465749689	0.0133451798	0
	0.2173318229	0.6170559076	0.3122273853	1
	0.818890594	0.7459451367	0.9026713492	0
	0.6064854042	0.5945985792	0.2188024961	0
	0.1546966824	0.1579937453	0.1333579164	0

Şekil 3.10. Örnek bir veri kümesinin özellikleri (*Machine Learning Mastery*, 2022)

Instance: Tek bir veri satırıdır. Bir gözlem verisidir. Diğer isimleri *Samples*, *Rows*, *Instances*, *Observations*, *Records*, *Examples*.


Feature: Tek bir veri sütunudur. Türkçe karşılığı “Özellik” olup “Öznitelik” olarak isimlendirilebilir. Diğer isimleri *Variables*, *Features*, *Attributes*, *Fields*, *Columns*, *Dimensions*.

Yapay zeka çalışmalarında veri kümesi kullanılırken genellikle temel olarak iki bölüme ayrılır. Bunlar “training data set” ve “test data set” olarak isimlendirilir.

Eğitim Kümesi (Training Set): Model olarak oluşturulan algoritmayı eğitmek için kullanılan veri setidir. Eğitim veri kümesi kendi içinde eğitim ve doğrulama kümesi olarak iki gruba ayrılır.

Doğrulama Kümesi (Validation Set): Modelin eğitimi sırasında kullanılan veri kümesidir. Model bu veri kümesini eğitim sırasında gördüğü için test için kullanılması uygun olmaz.


Test Kümesi (Test Set): Modelin, eğitim veri seti ile ne kadar iyi eğitildiğini değerlendirmek için kullanılır. Test veri kümesi ile modelin tahminleri karşılaştırılarak başarı metrikleri hesaplanır. Model eğitimden sonra test kümesini görür.



Şekil 3.11. Eğitim, doğrulama ve test veri kümeleri (Towards Data Science, 2022)

Veri kümesi temel olarak eğitim ve test verileri olarak iki ayrıldıktan sonra eğitim verileri modeli eğitip belirli bir seviye getirmek için kullanılır. Şekil 3.11’de görüldüğü gibi model eğitimi tamamlandıktan sonra son olarak test verileriyle işleme sokulur. Model test verilerini değerlendirerek sonuçlarını ortaya koyar.

Bu çalışmada makine öğrenmesi alanında yapılan çalışmalar ve literatür göz önüne alınarak veri kümesi Şekil 3.12’de belirtilen oranlarda eğitim, doğrulama ve test kümesi olarak ayrılmıştır. Eğitim ve doğrulama kümeleri için veri kümesinin %80’i ayrılarak 5 kat çapraz doğrulama yöntemiyle eğitim ve doğrulama yapıp en uygun model oluşturulduktan sonra modelin daha önce görmediği %20’lik test kümesiyle başarısı ölçülmüştür (Lyons ve ark., 2018; Nanda ve ark., 2016; Narin ve ark., 2014; Rácz ve ark., 2021; Rodriguez ve ark., 2010; Üstüner ve Şanlı, 2019; Wong ve Yeh, 2020). Bu oranların belirlenmesinde genel bir yöntem bulunmamakla birlikte yapılan çalışmaya ve veri kümesinin yapısına göre değişmektedir.



Şekil 3.12. Veri kümesinin eğitim, doğrulama ve test oranları (scikit-learn.org)

Model eğitimi yapılırken belirli yöntemler kullanılarak model başarımı artırılmaya çalışılır. Bu yöntemlerin detayları ilerleyen bölümlerde bahsedilecektir.

3.2.2. Veri kümesinin oluşturulması

Bu çalışmada ele alınan veri kümesi, şu an itibariyle işlem hacmi en büyük olan ve ilk ortaya çıkan kripto para birimi bitcoin verilerinden oluşmaktadır. Veri kümesi bitcoin'nin günlük verilerini içermektedir.

Veri kümesi, tarih olarak 01.03.2017 – 01.10.2022 arasındaki verileri kapsamaktadır. Veri kümesi açık kaynak olup internet ortamında birçok yerden elde edilebilir. Bu çalışma için veri kümesi coindocex.com sitesinden elde edilmiştir.

Elde edilen veri kümesi 2.072 adet satır (instance) ve 7 adet özniteliğe (feature) sahiptir. Bu öznitelikler sırasıyla Date, High, Low, Open, Close, Volume, Marketcap olarak veri kümesinde yer almaktadır. Satırlarla ilgili detaylı bilgi Çizelge 3.4'te verilmiştir.

Çizelge 3.4. Özniteliklerin tanımı

Öznitelikler (feature)	Tanım
<i>Date</i>	Veri kümesindeki her bir satır günlük verilerden oluşmaktadır. Bu öznitelik ilgili tarihi belirtmektedir.
<i>High</i>	Gün içindeki ulaşılan en yüksek bitcoin fiyatını ifade etmektedir.
<i>Low</i>	Gün içindeki ulaşılan en düşük bitcoin fiyatını ifade etmektedir.
<i>Open</i>	Bitcoin günlük açılış fiyatıdır.
<i>Close</i>	Kapanış verisini ifade etmektedir. Bitcoin'nin ilgili güne ait fiyat verisidir. Veri kümesi içerisinde hedef niteliklidir.
<i>Volume</i>	Günlük işlem hacmini ifade etmektedir.
<i>Marketcap</i>	Bitcoin'nin toplam piyasa değerini ifade etmektedir.

Veri kümesine ait örnek bir kesit Çizelge 3.5'te yer almaktadır. Tabloda gösterilen veriler gerçek verilerdir. Çok fazla veri olduğu için bir kısmına yer verilmiştir. Çizelge 3.5'te verilen tüm değerler Amerikan Doları cinsinden verilmiştir.

Çizelge 3.5. Veri kümesinden bir kesit

High	Low	Open	Volume	Marketcap	Close
8.997,57	8.652,15	8.848,79	7,54855e+09	1,5115e+11	8.895,58
9.001,64	8.779,61	8.925,06	6,6299e+09	1,49586e+11	8.802,46
8.958,55	8.788,81	8.794,39	6,92519e+09	1,51785e+11	8.930,88
8.562,41	8.205,24	8.246,99	5,19106e+09	1,4511e+11	8.513,25
8.557,52	8.365,12	8.522,33	5,15499e+09	1,43519e+11	8.418,99
8.423,25	8.004,58	8.419,87	5,13701e+09	1,37104e+11	8.041,78
4.049,88	4.015,96	4.022,71	9,57885e+09	7,1056e+10	4.035,83
3.985,08	3.944,75	3.969,23	1,07077e+10	7,01841e+10	3.985,08
4.113,50	4.034,10	4.068,30	1,09187e+10	7,22021e+10	4.098,37
11.048,70	10.451,30	10.525,80	2,02066e+10	1,91964e+11	10.767,10
10.446,90	9.922,02	10.077,40	1,71653e+10	1,85653e+11	10.399,70
7.589,95	7.525,71	7.547,27	1,54535e+10	1,36687e+11	7.556,24
9.723,01	9.589,74	9.611,78	4,09305e+10	1,76587e+11	9.686,44
12.151,00	11.685,50	11.772,70	2,4238e+10	2,17265e+11	11.768,90
15.916,30	15.290,00	15.290,90	2,97724e+10	2,91077e+11	15.701,30
17.853,90	16.910,70	17.112,90	3,2601e+10	3,28783e+11	17.717,40
19.749,30	18.178,30	18.178,30	4,77285e+10	3,6423e+11	19.625,80
28.288,80	25.922,80	26.439,40	6,64799e+10	4,88213e+11	26.272,30
33.155,10	29.091,20	29.376,50	6,78654e+10	5,97206e+11	32.127,30
40.180,40	36.491,20	36.833,90	8,47621e+10	7,32063e+11	39.371
39.577,70	34.659,60	39.156,70	6,77608e+10	6,85006e+11	36.825,40
48.370,80	44.454,80	47.180,50	3,50968e+11	8,63752e+11	46.339,80
9.100,71	8.564,90	8.939,44	5,53039e+09	1,47809e+11	8.728,47

Not: Veri kümesi üzerinde veri önışleme yapıldığı için çizelgede *Date* öznitelğine yer verilmemiştir.

3.2.3. Bağımlı ve bağımsız nitelikler

Veri kümesi ile modeli eğitmek için bağımlı ve bağımsız nitelikler belirlenmelidir. Bunlar birbirleriyle doğrudan ilişkilidir.

Bağımsız Nitelik: Model eğitiminde girdi verisi olarak kullanılan özniteliklere (feature) denir. Diğer değişkenlerden etkilenmezler. Her bir veri kümesinde bir veya birden fazla bağımsız değişken olabilir.

Bağımlı Nitelik: Modelin ulaşması gereken hedefe (target) denir. Bağımsız niteliklere doğrudan bağlıdır. Model, eğitim sürecinde bağımlı niteliğe ulaşmaya çalışır.

Veri kümesinde yer alan öznitelikler (feature) Çizelge 3.6’da bağımlı ve bağımsız olarak gruplara ayrılmıştır.

Çizelge 3.6. Bağımlı ve bağımsız nitelikler

Bağımsız Nitelikler	High Low Open Volume Marketcap
Bağımlı Nitelik	Close

Modelin eğitim ve test aşamalarında bağımsız değişken olarak *High*, *Low*, *Open*, *Volume*, *Marketcap* öznitelikleri ve bağımlı değişken olarak *Close* hedef niteliği kullanılmıştır.

3.2.4. Veri kümesinin analizi

Daha önceki bölümlerde bahsedildiği üzere veri kümesi 2072 adet satır (instance) ve 7 adet özneliğe (feature) sahiptir ve sırasıyla *Date*, *High*, *Low*, *Open*, *Close*, *Volume*, *Marketcap* olarak veri kümesinde yer almaktadır. Bu özneliklerden *Date*, modelin başarısını olumsuz etkilememesi için kullanılmamıştır.

Veri kümesinin özeti Çizelge 3.7’de yer almaktadır.

Çizelge 3.7. Veri kümesinin istatistiksel ayrıntıları

	High	Low	Open	Volume	Marketcap	Close
Mean	18.548,84	11.827,22	18.079,56	35.234.683.327	334.712.022.776	18.090,44
Standart sapma	17.402,58	12.707,73	16.968,98	36.599.312.020	322.376.196.979	16.967,38
Min	975,76	903,71	937,52	136.216.811	15.175.434.107	935,19
%25	6607,83	6.395,56	6.500,74	4.220.788.261	112.224.516.212	6.508,35
%50	9845,46	9.444,76	9.672,96	21.668.005.566	174.015.288.059	9.667,55
%75	29.979,17	28.722,89	29.197,50	57.740.677.770	559.721.080.231	29.238,02
Max	68.769,95	66.358,93	67.510,91	212.151.513.117	1.273.517.674.317	67.500,02


3.3. Derin Öğrenme

Derin öğrenme, insan beyninin hiyerarşik yapısını taklit eder, verileri alt seviyeden üst seviyeye işler ve giderek daha fazla anlamsal kavram oluşturur.

Derin öğrenme, modellenecek verilerin temel dağılımının birden çok temsil düzeyinin otomatik olarak öğrenilmesine olanak tanır (Lauzon, 2012; Mater ve Coote, 2019). Başka bir deyişle lineer olmayan ve birden fazla nöron katmanlarının olduğu karmaşık bir mimari ile verileri modelleyip anlamlı çıkarımlar yapabilen makine öğrenmesidir. Derin öğrenme, makine öğrenmesinin bir dalı olarak yapay sinir ağını kullanır. Aynı zamanda yapay sinir ağı olarak kabul edilebilir ve terimleri sıklıkla birbirinin yerine kullanılır (Kim, 2022).

Bilgisayar birimlerinin teknik kapasitesinin artmasıyla birlikte daha gelişmiş ve daha karmaşık sinir ağı modelleri geliştirilmiştir (Hao ve ark., 2016). Gün geçtikçe hayatımızın her alanında kullanılmaya başlanmıştır.

Yapay sinir ağları insan beynini temel alarak geliştirilip matematiksel bir modele dökülmüş halidir. Beynin temel hesaplama birimi sinir hücreleri yani diğer adıyla nöronlardır. İnsan sinir sisteminde milyarlarca nöron bulunur ve bunlar sinapslarla bağlantılıdır. Şekil 3.13'te bir biyolojik nöronun genel yapısı gösterilmektedir.



Şekil 3.13. Biyolojik sinir hücresi (Fumo, 2017)


Akson (Axon): Çıkış birimidir.

Dentrit (Dendrite): Giriş birimidir.

Cell Body: Hücre Gövdesi

Nucleus: Hücre çekirdeği. Zarla kaplı bir organelidir.

Biyolojik sinir hücresinin matematiksel modellemiş hali Şekil 3.14'te gösterilmektedir. Giriş değerleri ve ağırlıklar çarpılarak hücreye iletilir. Bu değerler hücrede toplanarak çıkışa iletilir. Çıkış değerleri bir başka hücrenin giriş değerleri olabilir.




Şekil 3.14. Yapay sinir hücresi (Fumo, 2017)

$x_1 \dots x_n$: Girdi değerleri, bağımsız değişken

$w_1 \dots w_n$: Ağırlık değerleri

f : Aktivasyon fonksiyonu

Yukarıda bahsedildiği üzere derin öğrenme bir makine öğrenme dalıdır. Yapay sinir ağlarından oluşur. Birden çok gizli katmana sahip yapay sinir ağı derin öğrenme olarak adlandırılır. Şekil 3.15'te basit bir sinir ağı ve derin öğrenme sinir ağı arasındaki fark gösterilmiştir.



Şekil 3.15. Basit sinir ağı ve derin öğrenme sinir ağı (Vázquez, 2017)

İnput Layer: Giriş katmanı

Hidden Layer: Gizli katman

Output Layer: Çıkış katmanı

Şekil 3.15'in sol tarafında bulunan basit sinir ağı modeli ile birçok problem çözülebilir ama problem karmaşıklığı artıkça çözüm üretilemez hale gelebilir. Bununla birlikte birçok parametreye ihtiyaç duyulabilir. Şekil 3.15'in sağında bulunan derin öğrenme ağı ile çok daha karmaşık sorunlar çözülebilir. Karmaşıklık arttıkça birkaç gizli katman eklenerek problemlere çözüm bulunabilir.

Özet olarak derin öğrenmedeki 'derin' ifadesi birden fazla gizli katmanı olan sinir ağları için kullanılır. Derin öğrenme birden fazla gizli katmana ya da ara katmana sahip sinir ağlarıdır.

3.3.1. Aktivasyon fonksiyonları

Aktivasyon fonksiyonu, derin öğrenme modelinde yer alan bir nöronun aktive edilip edilmeyeceğine karar verir. Derin öğrenmede bir giriş sinyalini, bir sonraki katmana girdi olarak veren çıkış sinyaline dönüştürmek için kullanılır. Girdilerin çarpımlarının toplamını ve bunlara karşılık gelen ağırlıkları hesaplar. Daha sonra o katmanın çıktısını almak ve bir sonraki katmana girdi olarak sağlamak için bir aktivasyon fonksiyonu uygular (Sharma ve ark., 2020). Bu durum modelin başarısını doğrudan etkilediği için son derece önemlidir.

Aktivasyon fonksiyonu, derin öğrenme modelinin başarısı için oldukça etkilidir. Model içerisinde bulunan her bir katman için farklı aktivasyon fonksiyonu belirlenebilmektedir. Bir derin öğrenme modelinin sinir ağı üç temel katmandan oluşur. Bunlar giriş katmanı, gizli katmanlar ve çıkış katmanıdır. Gizli katman sayısı genellikle birden fazladır.

Tüm gizli katmanlarda genel olarak aynı aktivasyon fonksiyonu kullanır. Çıktı katmanında ise gizli katmanlardan farklı bir etkinleştirme işlevi kullanır.


Birden fazla aktivasyon fonksiyonu vardır. Sigmoid, ReLU ve Tanh en bilinen fonksiyonlardır.

3.3.1.1. Sigmoid fonksiyonu

Sigmoid aktivasyon fonksiyonunun bilinen diğer adı lojistik fonksiyonudur. Bu fonksiyon herhangi bir gerçekte değeri girdi olarak alır ve 0 ile 1 aralığında değere üretir. Türevlenebilir bir fonksiyondur. Sigmoid fonksiyonun formülü Denklem 3.1’de gösterilmiştir.

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.1)$$

Sigmoid fonksiyona ait grafik çizimi Şekil 3.16’da yer almaktadır.



Şekil 3.16. Sigmoid fonksiyonu grafiği

3.3.1.2. ReLU (rectified linear unit) fonksiyonu


Derin öğrenme alanında en çok tercih edilen aktivasyon fonksiyonlarından birisidir. ReLU fonksiyonu $[0, +\infty)$ aralığında değere alır.

ReLU, diğer aktivasyon fonksiyonlarından daha verimlidir. Çünkü bütün nöronların çalıştırılması yerine yalnızca belirli nöronlar aktif edilir (Sharma ve ark., 2020).

ReLU fonksiyonu negatif girdiler için 0 değerini alır. Pozitif bir x girdisinde ise x değerini almaktadır. Bu fonksiyonun matematiksel ifadesi Denklem 3.2’de gösterilmiştir.

$$f(x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (3.2)$$

ReLU fonksiyona ait grafik çizimi şekil 3.17’de yer almaktadır.



Şekil 3.17. ReLU fonksiyonu grafiği

3.3.1.3. Tanh fonksiyonu


Hiperbolik tanjant fonksiyonu (Tanh) sigmoid fonksiyona benzer bir aktivasyon fonksiyonudur. Fonksiyon herhangi bir değeri girdi olarak alır ve (-1, +1) aralığında bir değer üretir. Doğrusal olmayan bir fonksiyondur.

Giriş değeri ne kadar büyükse çıkış değeri o kadar 1’e yakındır. Aynı şekilde girdiler ne kadar küçükse fonksiyonun çıkışı -1’e o kadar yakındır.

Tanh fonksiyonunun matematiksel ifadesi Denklem 3.3’te gösterilmiştir.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.3)$$

Tanh fonksiyonuna ait grafik çizimi şekil 3.18’de gösterilmiştir.




Şekil 3.18. TanH fonksiyonu grafiği

3.3.2. Seyreltme (dropout)

Bir derin öğrenme modelinde, modeli eğitirken aşırı öğrenme ya da ezber (overfitting) olarak bilinen bir durum ortaya çıkabilir. Bu sorun modelin başarısını tamamen etkilediği için buna karşı önlemler alınmalıdır.

Nöronlar, eğitim sırasında birbirleri arasında karşılıklı bağımlılık geliştirir ve bu da her bir nöronun bireysel gücünü kısıtlayarak eğitim verilerinin aşırı uymasına yol açar. Nöronlar arasındaki bu bağımlılığı azaltarak modelin aşırı öğrenmesini ya da ezberlemesini engellemek için son zamanlarda seyreltme (dropout) tekniği kullanılmaktadır.

Seyreltme temel olarak eğitim sırasında modelde yer alan bazı düğümleri rasgele kapatarak modelin ezberleme eğilimini azaltmaya çalışır (Srivastava ve ark., 2014).



Şekil 3.19. Seyreltme (Srivastava ve ark., 2014)

Şekil 3.19’da sol tarafta normal bir sinir ağı modeli gösterilmektedir. Sağ tarafta ise “Seyreltme” tekniği uygulanmış bir sinir ağı gösterilmiştir. Görüldüğü gibi bazı nöronlar kapatılarak ağı dahil edilmemiştir.

3.3.3. Optimizasyon algoritmaları

Optimizasyon algoritmaları, bir derin öğrenme modelini mümkün olduğunca verimli ve işlevsel hale getirmeyi, hata oranını en aza indirmeyi amaçlar (Seyyarer ve ark., 2020; Yousoff ve ark., 2016).

3.3.3.1. Adam

Adam optimizasyon algoritması ilk defa *Kingma* ve *Ba* tarafından ortaya atılmıştır (Kingma ve Ba, 2014). Adaptif momentum olarak da isimlendirilir. Birçok makine öğrenimi çerçevesinde uygulanan derin öğrenme projeleri için oldukça popüler bir algoritmadır (Bock ve Weiß, 2019).

Yöntemin uygulanması basittir, hesaplama açısından verimlidir ve az bellek gereksinimine ihtiyaç duyar (Kingma ve Ba, 2014). Bu algoritma, AdaGrad ve RMSPop gibi popüler olan 2 yöntemin avantajlı yönleri bir araya getirilerek oluşturulmuştur (Kingma ve Ba, 2014). Her adımda öğrenme katsayısını güncelleyen bir algoritmadır (Yazan ve Talu, 2017). Her parametre için uyarlanabilir öğrenme oranlarını hesaplayan Adam algoritması, geçmiş gradyanların katlanarak azalan bir ortalamasını tutar (Taqi ve ark., 2018).

3.3.3.2. RMSProp

RMSprop, ilk olarak Geoff Hinton tarafından “Makine Öğrenimi için Sinir Ağları” isimli online dersinde önerdiği sinir ağları için tasarlanmış optimizasyon algoritmasıdır (Hinton ve ark., 2012; Ruder, 2016). RMSprop, son yıllarda popüleritesi artan bir algoritmadır.

RMSprop algoritması, salınımları dikey yönde kısıtlar. Böylece öğrenme hızı artırılabilir ve algoritma yatay yönde daha hızlı yakınsayarak daha büyük adımlar atabilir (Babu ve ark., 2020).

3.4. Polinomal Regresyon

Polinomal regresyon, bir problem hakkında tahminde bulunmak için kullanılan makine öğrenme yöntemlerinden birisidir. Temel olarak polinomal regresyonda, bağımsız değişken (x) ile bağımlı değişken (y) arasındaki ilişkiyi n'inci derece polinom olarak açıklayan bir regresyon algoritmasıdır (Chen ve ark., 2018; Maulud ve Abdulazeez, 2020). Doğrusal olmayan bir regresyon türüdür.

Polinomal regresyon, doğrusal regresyonunun özelleşmiş bir türüdür. Doğrusal regresyonda öznitelikler 1. derece fonksiyon kullanılırken polinomal regresyonda öznitelikler en az 2. dereceden fonksiyon olarak kullanılır.

Doğrusal regresyon çeşitlerinden birisi olan çoklu doğru regresyon ile oldukça benzerdir. Her iki regresyon çeşidinde de birden fazla öznitelik kullanılır.

Polinomal regresyonun matematiksel modeli Denklem 3.4'te verilmiştir (Chen ve ark., 2018; Niu ve ark., 2018; Roziqin ve ark., 2016).

$$y = b_0 + b_1x + b_2x^2 + \dots + b_nx^n \quad (3.4)$$

y: Tahmin değerleri

b_{0-n} : Öznitelik katsayıları

x : Öznitelikler

3.5. Destek Vektör Regresyonu

Destek Vektör Makineleri, sınıflandırma ve regresyonda kullanılan öğrenme yöntemlerinden birisidir. Vapnik tarafından geliştirilmiştir (V. N. Vapnik, 1995).

Destek Vektör Regresyonu, sınıflandırma problemlerinde kullanılan ve oldukça bilinen destek vektör makineleriyle aynı alt yapıya sahiptir. Destek vektör makineleri kategorik verilerde kullanılırken destek vektör regresyonu sürekli değerler üzerinde kullanılmaktadır (Kavitha S ve ark., 2016). Destek vektör regresyonu, destek vektör makinelerinden uyarlanarak ortaya konulmuştur (Drucker ve ark., 1996; Smola ve Schölkopf, 2004; V. Vapnik ve ark., 1996).

Destek vektör makinesinden daha az popüler olmasına rağmen, destek vektör regresyonunun gerçek değerli fonksiyon tahmininde etkili bir araç olduğu kanıtlanmıştır (Acı ve ark., 2017; Müller ve ark., 1997; Wu ve ark., 2004). Diğer yöntemlere göre doğrusal olmayan problemleri çözmedeki performansı oldukça iyidir (Acikkar ve ark., 2013). Denetimli bir öğrenme yaklaşımı olarak, yüksek ve düşük yanlış tahminleri eşit olarak cezalandıran simetrik bir kayıp işlevi kullanarak eğitir (Awad ve Khanna, 2015).

3.6. Çapraz Doğrulama


Çapraz doğrulama (cross validation) makine öğrenmesinde oluşturulan modellerin performansının mümkün olduğunca objektif bir şekilde değerlendirilmesi için kullanılan bir başarı ölçme tekniğidir.

Temel olarak bir model için kullanılan veri kümesi eğitim ve test gruplarına ayrılır. Eğitim verileriyle eğitilen model belirlenen test verileriyle başarısı test edilir. Ancak bu şekilde veri parçalanırken modelin eğitimi ve testi sırasında bazı sapmaların ve hataların oluşma ihtimali vardır. Çapraz doğrulama ile bu olumsuz durumun önüne kısmen geçilebilir.

Çapraz doğrulama tekniğinde veri kümesi k adet alt kümeye bölünür. Her bir alt küme test verisi olarak kullanılırken geri kalan $k-1$ adet alt kümede eğitim verisi olarak kullanılır. Oluşturulan model, belirlenen k değeri adedince çalıştırılır ve her seferinde bir başarı değeri elde edilir. Elde edilen k adet başarı değerinin ortalaması alınarak daha sağlıklı ve objektif bir başarı değeri elde edilmiş olur.

Bu yöntem uygulandıktan sonra veri kümesindeki her bir veri noktası bir defa test kümesinde ve k-1 defa eğitim kümesinde yer almış olur ve tüm süreç homojen bir şekilde yürütülerek sonuçlandırılır.

Çapraz doğrulama ile makine öğrenmesi algoritmalarının performansını değerlendirmek günümüzde popülerdir. Bununla birlikte k değerinin genellikle 5 veya 10 olarak seçilmesi önerilir (Narin ve ark., 2014; Rodriguez ve ark., 2010; Wong ve Yeh, 2020).



Şekil 3.20. K-katmanlı çapraz doğrulama (Üstüner ve Şanlı, 2019)

Görsel bir şekilde çapraz doğrulama Şekil 3.20’de gösterilmektedir. Şekilde görüldüğü üzere örnek olarak k=5 değeri kullanılmıştır. Her bir k katmanında test ve eğitim kümeleri sırasıyla kaymaktadır ve tüm veriler doğrulama işlemine katılmaktadır.

Şekil 3.20’de gösterilen örnekte her bir k katmanındaki işlem sonucunda modelin bir A başarı ölçütü elde edilmektedir. Doğrulama sonucunda elde edilen k adet A başarı değerlerinin ortalaması, yapılan çapraz doğrulamanın genel doğruluk başarı değerini vermektedir.

Model adaylarının analizini ve performansını belirlerken uygulamada k katman sayısı 5 olarak belirlenmiştir.

Doğruluk değeri Denklem 3.5’te hesaplanmaktadır. Her bir k katmanındaki performans değerlerinin ortalaması olarak hesaplanmaktadır.

$$\text{Doğruluk} = \frac{1}{k} \sum_{i=1}^k A_i \quad (3.5)$$

3.7. Izgara Arama

Makine öğrenmesi modellerinde önemli parametreler vardır. Her bir yöntem için parametreler farklıdır. Bu parametreler model başarısını oldukça etki etmektedir. Bu yüzden parametrelerin alacağı değerler oldukça önemlidir. En uygun modeli tasarlamak için hangi parametrenin ne değer alacağını bulma yöntemlerinden birisi ızgara arama (grid search) yöntemidir.

Bu yöntemde her bir parametrenin alabileceği değerler teker teker işleme sokularak başarı hesabı yapılır ve en uygun parametre değerleri bulunur. Parametre sayısı arttıkça hesaplama maliyeti de artmaktadır (Ataci ve Osanloo, 2004; Gençal ve Oral, 2022).

3.8. Performans Metrikleri

Makine öğrenimi modellerinin performanslarını değerlendirirken doğru metriği seçmek çok önemlidir. Oluşturulan modelin tahminleri gerçek değerlere ne kadar yakınsa, modelin performansı o kadar yüksektir. Bu bölümde en çok bilinen performans metrikler anlatılmıştır.

3.8.1. Ortalama mutlak hata (MAE)

Ortalama mutlak hata (MAE), model tarafından tahmin edilen değerler ile gerçek (hedef) değerler arasındaki ortalama mutlak mesafeyi bulan bir metriktir. Oldukça yaygın bir kullanıma sahiptir.

Ortalama mutlak hata metriğinin matematiksel modeli Denklem 3.6'da verilmiştir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.6)$$

y_i : gerçek değer

$\hat{y}_i$: tahmin edilen değer

3.8.2. Ortalama karesel hata (MSE)

Ortalama kare hatası (MSE), regresyon sorunları için popüler bir hata ölçümüdür. Tahmin edilen ve beklenen hedef değerler arasındaki kare farklarının ortalaması olarak hesaplanır.

Temel olarak tahmin ile gerçek değerler arasındaki farkı hesaplar, bu sonuçların karesini alır ve ardından ortalamalarını hesaplar.

MSE, MAE'ye benzer, ancak tek fark mutlak değeri kullanmak yerine hepsini toplamadan önce gerçek ve tahmin edilen değerlerin farkının karesini almasıdır.

MSE'nin matematiksel modeli Denklem 3.7'de verilmiştir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.7)$$

y_i : gerçek değer

$\hat{y}_i$: tahmin edilen değer

3.8.3. Ortalama karesel hata karekökü (RMSE)

Ortalama hata kare kökü (RMSE), MSE'ye oldukça benzerdir. Ek olarak MSE değerinin karekökü alınarak RMSE hesaplanır.

Bir model veya tahmin edici tarafından tahmin edilen değerlerle gerçek değerler arasındaki farkların hesaplanmasında çok sık tercih edilen bir metriktir.

RMSE'nin matematiksel modeli Denklem 3.8'de verilmiştir. Görüldüğü üzere MSE değerinin karekökü alınmış halidir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.8)$$

y_i : gerçek değer

$\hat{y}_i$: tahmin edilen değer

3.8.4. R kare

R kare metriği, modelin tahmin ettiği değerler ile gerçek değerlerin birbirine ne kadar uyduğunun göstergesidir. 0 ile 1 arasında değerler alır. 1'e ne kadar yakınsa model o kadar anlamlıdır.

Metriğin matematiksel modeli Denklem 3.9'da gösterilmektedir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (3.9)$$

y_i : gerçek değer

$\hat{y}_i$: tahmin edilen değer

$\bar{y}_i$: değerlerin ortalaması

3.9. Deneysel Çalışma Ortamı

Bu çalışmada son zamanlarda yapay zeka alanında en çok kullanılan programlama dillerinden birisi olan python (3.8.10 sürümü) dili kullanılmıştır. Python, kütüphaneleri sayesinde veri bilimi ve makine öğrenmesi gibi alanlarda oldukça kabiliyetlidir. Nesne yönelimli ve yüksek seviyeli olan python anlaşılır bir söz dizime sahiptir.

Geliştirme ortamı olarak veri bilimi ve makine öğrenmesi için oldukça kullanışlı olan spyder (5.0.3 sürümü) kullanılmıştır.

Çalışmada kullanılan bilgisayar intel core i5-10210u işlemciye, 16 GB belleğe ve windows 10 pro işletim sistemine sahiptir.

Ayrıca bu çalışmada aşağıdaki python kütüphaneleri kullanılmıştır.

- **Scikit-learn:** Python dilinde yazılmış bir makine öğrenmesi kütüphanesidir. Açık kaynak bir kütüphane olup kullanıcılar için çalışmayı oldukça kolaylaştırmaktadır. Kütüphane içerisinde sınıflandırma, regresyon, kümeleme, model seçimi ve veri ön işleme algoritmaları bulunmaktadır.
- **Keras:** Açık kaynak kodlu ve python dilinde yazılmış yapay sinir ağı kütüphanesidir. Keras ile özellikle derin öğrenme modellerini tasarlamak daha kolay hale gelmiştir.

- **Numpy:** Açık kaynak kodlu olup python dili için kullanılan bir kütüphanedir. Dizi ve matris işlemleri için kullanılır.
- **Pandas:** python ile yazılmış bir kütüphanedir. Veri bilimi ve makine öğrenmesi gibi çalışmalarda veri okuma, veri temizleme, veri ön işleme vb. işlemler için kullanılır.



4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

4.1. Derin Öğrenme Modeli

Bir derin öğrenme modelinin yapısına bakıldığında başarıya etki eden birçok parametre vardır. En başarılı modeli elde etmek için bu parametrelerin hangi değerleri alacağı tespit edilmelidir.

Bu çalışmada en uygun derin öğrenme modelinin belirlenmesi için ızgara arama (grid search) ve çapraz doğrulama (cross validation) yöntemleri kullanılarak birçok parametre adayının başarısı hesaplanmıştır.

Parametre deneyi için 5 katlı çapraz doğrulama ve ızgara arama yöntemiyle en uygun modeli bulmak için 972 parametre kombinasyonu oluşturulup her bir kombinasyon için R^2 , MAE ve RMSE hesaplanmıştır. Hesaplama süresi 32 saat 16 dakika sürmüştür.

Hesaplamalar sonucunda elde edilen en başarılı 150 parametre kombinasyonu ve başarı sonuçları EK-1’de verilip ilk 30’u Çizelge 4.1’de gösterilmiştir.

Çizelge 4.1. Derin öğrenme modeli için parametre sonuçları

Derin Öğrenme Modeli Parametreleri						Başarı Metrikleri		
activation	batch_size	dropout	epochs	learning_rate	neurons	R^2	MAE	RMSE
relu	10	0,5	50	0,0005	256	0,9957	448	913
relu	20	0,5	30	0,0005	256	0,9952	483	955
relu	30	0,5	30	0,0005	256	0,9957	529	808
relu	30	0,5	50	0,0005	128	0,9942	555	1139
relu	10	0,5	30	0,0005	256	0,9949	571	1041
relu	20	0,5	100	0,0005	256	0,9940	586	923
relu	40	0,5	30	0,001	256	0,9939	590	939
relu	40	0,5	100	0,0005	256	0,9959	590	962
relu	40	0,5	30	0,0005	256	0,9941	619	864
relu	40	0,6	30	0,0005	256	0,9938	640	1061
relu	10	0,5	100	0,001	256	0,9853	653	950
relu	30	0,5	50	0,0005	256	0,9949	685	1140
relu	30	0,5	30	0,001	256	0,9915	686	998
relu	10	0,7	100	0,0005	256	0,9832	692	1071
relu	40	0,5	50	0,0005	256	0,9963	693	893
relu	20	0,5	30	0,001	256	0,9962	710	1038
relu	20	0,6	30	0,0005	256	0,9967	726	1032
relu	10	0,5	100	0,0005	128	0,9974	729	1160
relu	40	0,5	100	0,001	256	0,9943	733	1144
relu	40	0,5	100	0,0015	128	0,9901	743	1080
relu	20	0,6	100	0,0015	256	0,9858	753	1145
relu	30	0,5	30	0,001	128	0,9882	766	988
relu	10	0,5	100	0,0005	256	0,9940	772	851
relu	10	0,5	100	0,001	128	0,9886	778	881
relu	30	0,5	50	0,001	256	0,9922	782	898
relu	30	0,6	30	0,001	256	0,9932	785	1022
relu	30	0,6	50	0,0005	256	0,9948	799	905
relu	30	0,6	100	0,0005	256	0,9942	811	1075
relu	20	0,6	50	0,0005	256	0,9918	819	1177
relu	20	0,5	50	0,0005	128	0,9933	837	1118

Çizelge 4.1’de yer alan sonuçlar değerlendirildiğinde belirlenen en uygun derin öğrenme modelinin yapısı Çizelge 4.2’de verilmiştir.

Çizelge 4.2. Derin öğrenme modelinin yapısı


Derin Öğrenme Modeli						
Giriş katmanı	Gizli Katmanlar					Çıkış Katmanı
	1. Katman	2. Katman	3. katman	4. Katman	5. Katman	
Nöron Sayısı: 5	Nöron Sayısı: 256 Aktivasyon Fonksiyonu: ReLU Dropout: 0,5	Nöron Sayısı: 256 Aktivasyon Fonksiyonu: ReLU Dropout: 0,5	Nöron Sayısı: 256 Aktivasyon Fonksiyonu: ReLU Dropout: 0,5	Nöron Sayısı: 256 Aktivasyon Fonksiyonu: ReLU Dropout: 0,5	Nöron Sayısı: 256 Aktivasyon Fonksiyonu: ReLU Dropout: 0,5	Nöron Sayısı: 1
Batch size: 30 Epochs: 30 Learning rate: 0,0005						

Oluşturulan derin öğrenme modeli, daha önce hiç görmediği test kümesi verileriyle test edilerek başarısı hesaplanmıştır. Başarı sonuçları Çizelge 4.3’te yer almaktadır.

Çizelge 4.3. Derin öğrenme modelinin başarı sonuçları

Derin Öğrenme			
Başarı Metrikleri	R^2	MAE	RMSE
Sonuçlar	0,9958	851	1169

Modelin tahminleri ile gerçek verilerin karşılaştırıldığı nokta grafiği Şekil 4.1’de verilmiştir.



Şekil 4.1. Derin öğrenme modelinin tahmini ve gerçek değerler

4.2. Polinomal Regresyon Modeli

Polinomal regresyon modelinde başarıya etki eden parametreler vardır. En başarılı modeli elde etmek için bu parametrelerin hangi değerleri alacağı diğer modellerde olduğu gibi tespit edilmelidir.

En uygun polinomal regresyon modelinin belirlenmesi için yapılan parametre deneyinin sonuçları Çizelge 4.4'te verilmiştir. Hesaplama süresi 12 dakika sürmüştür.

Çizelge 4.4. Polinomal regresyon modeli için parametre sonuçları

Polinomal Regresyon Parametreleri				Başarı metrikleri		
<i>Degree</i>	<i>Include_bias</i>	<i>Interaction_only</i>	<i>Order</i>	R^2	MAE	RMSE
2	False	True	F	0,9994	211	394
2	False	True	C	0,9994	211	394
2	False	False	F	0,9994	215	400
2	False	False	C	0,9994	215	400
2	True	True	F	0,9994	211	394
2	True	True	C	0,9994	211	394
2	True	False	F	0,9994	215	400
2	True	False	C	0,9994	215	400
3	False	True	F	0,9993	219	421
3	False	True	C	0,9993	219	421
3	False	False	F	0,9977	238	654
3	False	False	C	0,9977	238	654
3	True	True	F	0,9993	219	421
3	True	True	C	0,9993	219	421
3	True	False	F	0,9977	238	654
3	True	False	C	0,9977	238	654
4	False	True	F	0,9993	218	419
4	False	True	C	0,9993	218	419
4	False	False	F	0,9900	321	1452
4	False	False	C	0,9900	321	1452
4	True	True	F	0,9993	218	419
4	True	True	C	0,9993	218	419
4	True	False	F	0,9900	321	1452
4	True	False	C	0,9900	321	1452

Çizelge 4.4’te yer alan deney sonuçları değerlendirildiğinde modelin başarısına “*Degree*” ve “*Interaction_only*” parametreleri etki etmektedir. Bu parametreler “*Degree=2*” ve “*Interaction_only=True*” değerlerini aldıkları zaman polinomal regresyon modeli en başarılı sonuçları vermiştir. Diğer parametrelerin sonucu değiştirmedigi görülmektedir. Bu bilgilere göre belirlenen en uygun polinomal regresyon modelinin yapısı Çizelge 4.5’te verilmiştir.

Çizelge 4.5. Polinomal regresyon modelinin yapısı


Polinomal Regresyon Modeli	
<i>Degree</i>	2
<i>Include_bias</i>	“True” veya “False”
<i>Interaction_only</i>	“True”
<i>Order</i>	“F” veya “C”

Oluşturulan polinomal regresyon modeli, daha önce hiç görmediği test kümesi verileriyle test edilerek başarısı hesaplanmıştır. Başarı sonuçları Çizelge 4.6’da yer almaktadır.

Çizelge 4.6. Polinomal regresyon modelinin başarı sonuçları

Polinomal Regresyon			
Başarı Metrikleri	R^2	MAE	RMSE
Sonuçlar	0,9860	1311	2135

Modelin tahminleri ile gerçek verilerin karşılaştırıldığı nokta grafiği Şekil 4.2’de verilmiştir.



Şekil 4.2. Polinomal regresyon modelinin tahmini ve gerçek değerler

4.3. Destek Vektör Regresyonu Modeli

Destek vektör regresyonu modelinde başarıya etki eden bazı parametre vardır. En başarılı modeli elde etmek için bu parametrelerin hangi değerleri alacağı diğer modellerde olduğu gibi tespit edilmelidir.

Parametre deneyi için 5 katlı çapraz doğrulama ve ızgara arama yöntemi kullanılmıştır. En uygun model için 162 parametre kombinasyonu vardır. Her bir kombinasyon için R^2 , MAE ve RMSE hesaplanmıştır. Hesaplama süresi 3 saat 44 dakika sürmüştür.

En uygun destek vektör regresyonu modelinin belirlenmesi için yapılan parametre deneyinin sonuçlarının tamamı EK-2’de yer alıp bir kısmı Çizelge 4.7’de verilmiştir.

EK-2’de yer alan deney sonuçları incelenip analiz edildiğinde model başarısına etki eden parametrelerin “*Kernel*” ve “*C*” olduğu tespit edilmiştir.

Çizelge 4.7. Destek vektör regresyonu için en başarılı bazı parametre adayları

Destek Vektör Regresyonu Parametreleri					Başarı metrikleri		
<i>C</i>	<i>Degree</i>	<i>Epsilon</i>	<i>Gamma</i>	<i>Kernel</i>	R^2	MAE	RMSE
10^5	2	0.1	'scale'	'linear'	0,9994	215	398
10^5	2	0.1	'auto'	'linear'	0,9994	215	398
10^5	2	0.2	'scale'	'linear'	0,9994	215	398
10^5	2	0.2	'auto'	'linear'	0,9994	215	398
10^5	2	0.3	'scale'	'linear'	0,9994	215	398
10^5	2	0.3	'auto'	'linear'	0,9994	215	398
10^5	3	0.1	'scale'	'linear'	0,9994	215	398
10^5	3	0.1	'auto'	'linear'	0,9994	215	398
10^5	3	0.2	'scale'	'linear'	0,9994	215	398
10^5	3	0.2	'auto'	'linear'	0,9994	215	398
10^5	3	0.3	'scale'	'linear'	0,9994	215	398
10^5	3	0.3	'auto'	'linear'	0,9994	215	398
10^5	4	0.1	'scale'	'linear'	0,9994	215	398
10^5	4	0.1	'auto'	'linear'	0,9994	215	398
10^5	4	0.2	'scale'	'linear'	0,9994	215	398
10^5	4	0.2	'auto'	'linear'	0,9994	215	398
10^5	4	0.3	'scale'	'linear'	0,9994	215	398
10^5	4	0.3	'auto'	'linear'	0,9994	215	398
10^6	2	0.1	'scale'	'linear'	0,9994	211	403
10^6	2	0.1	'auto'	'rbf'	0,9994	212	400
10^6	2	0.1	'auto'	'linear'	0,9994	211	403
10^6	2	0.2	'scale'	'linear'	0,9994	211	403
10^6	2	0.2	'auto'	'rbf'	0,9994	212	400
10^6	2	0.2	'auto'	'linear'	0,9994	211	403
10^6	2	0.3	'auto'	'rbf'	0,9994	212	400
10^6	3	0.1	'scale'	'linear'	0,9994	211	403
10^6	3	0.1	'auto'	'rbf'	0,9994	212	400
10^6	3	0.1	'auto'	'linear'	0,9994	211	403
10^6	3	0.2	'scale'	'linear'	0,9994	211	403
10^6	3	0.2	'auto'	'rbf'	0,9994	212	400

Çizelge 4.7’de yer alan sonuçlar değerlendirilerek belirlenen en uygun destek vektör regresyonu modelinin yapısı Çizelge 4.8’de verilmiştir.

Çizelge 4.8. Destek vektör regresyonu modelinin yapısı


Destek Vektör Regresyonu Modeli	
<i>C</i>	10^5
<i>Degree</i>	2, 3 veya 4
<i>Epsilon</i>	0,1, 02 veya 0,3
<i>Gamma</i>	“scale” veya “auto”
<i>Kernel</i>	“linear”

Oluşturulan destek vektör regresyonu modeli, daha önce hiç görmediği test kümesi verileriyle test edilerek başarısı hesaplanmıştır. Başarı sonuçları Çizelge 4.9’da yer almaktadır.

Çizelge 4.9. Destek vektör regresyonu başarı sonuçları

Destek Vektör Regresyonu			
Başarı Metrikleri	R^2	MAE	RMSE
Sonuçlar	0,9952	808	1247

Modelin tahminleri ile gerçek verilerin karşılaştırıldığı nokta grafiği Şekil 4.3’te verilmiştir.



Şekil 4.3. Destek vektör regresyonu modelinin tahmini ve gerçek değerler

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Bu çalışmada derin öğrenme, polinomal regresyon ve destek vektör regresyonu modelleri oluşturularak bitcoin'in 01.03.2017 – 01.10.2022 tarihleri arasındaki 2.072 adet veri noktasından oluşan veri kümesi üzerinde eğitilip test edilmiştir. Veri kümesi bitcoin'in günlük *kapanış, en yüksek, en düşük, açılış, hacim ve piyasa değeri* niteliklerinden oluşmaktadır.

Modeller, her bir güne ait *en yüksek, en düşük, açılış, hacim ve piyasa değeri* özniteliklerini kullanarak aynı günün bitcoin'in kapanış fiyatını tahmin etmeye çalışmışlardır. Modellerin eğitimi sırasında veri kümesinden bağımsız bir şekilde yüksek başarı elde etmek için 5 kat çapraz doğrulama ve ızgara arama yöntemi kullanılmıştır.

Test kümesinde modellerin daha önce görmediği ve veri kümesinin %20'lik kısmını oluşturan 415 adet veri noktası bulunmaktadır. Bu test kümesiyle yapılan testler ve analizler sonucunda bitcoin'in kapanış fiyatının gerçek değerleri ve modellerin yaptığı tahmin değerleri EK-3'te yer alıp bir kısmı Çizelge 5.1'de verilmiştir.

Çizelge 5.1. Gerçek değerler ve modellerin tahminlerinden bir kesit

Gerçek Değerler	Modellerin Tahmin Değerleri		
	Derin Öğrenme Modelinin Tahmini	Polinomal Regresyon Modelinin Tahmini	Destek Vektör Regresyon Modelinin Tahmini
50.117,00	48.731,50	53.353,70	52.207,40
22.600,80	22.487,40	24.289,80	23.745,40
5.303,99	5.063,98	5.387,27	5.378,35
21.029,20	21.269,00	22.630,90	22.303,60
1.281,09	1.908,61	1.195,68	1.223,48
11.395,40	11.467,10	12.057,50	11.865,30
12.808,80	12.178,80	13.583,30	13.502,00
63.528,50	60.623,00	69.463,60	66.030,30
36.705,90	35.026,70	37.514,00	36.465,60
9.503,27	9.154,50	9.883,26	9.792,64
14.063,20	12.164,10	14.291,70	14.295,50
6649,44	6190,83	6788,06	6782,31
8286,91	7995,46	8630,79	8572,14
7207,20	6873,46	7545,14	7532,20
7246,42	7024,17	7454,00	7397,65
1281,09	1908,61	1195,68	1223,48
11395,40	11467,10	12057,50	11865,30
12808,80	12178,80	13583,30	13502,00
63528,50	60623,00	69463,60	66030,30
5090,03	4898,34	5200,06	5191,12

Hesaplamalar sonucunda modellere ait başarı metriklerinin değerleri Çizelge 5.2’de verilmiştir.

Çizelge 5.2. Modellerin başarı metriklerinin sonuçları

Başarı Metrikleri	Modellerin Başarı Sonuçları		
	Derin Öğrenme	Polinomal Regresyon	Destek Vektör Regresyonu
R^2	0,9958	0,9860	0,9952
MAE	851	1311	808
RMSE	1169	2135	1247

Sonuçlar incelendiğinde üç modelinde başarısının birbirine yakın olduğu görülmüştür. Bununla birlikte derin öğrenme modeli ve destek vektör regresyonu modeli polinomal regresyon modeline göre daha iyi sonuçlar verildiği gözlenmiştir.

Bu çalışmada yapılan analizler ile Karasu ve arkadaşlarının (2018) yaptığı çalışmada önerilen destek vektör makinesi analizi göz önüne alındığında bitcoin’in kapanış fiyatını tahmin etme konusunda derin öğrenme ve destek vektör regresyon modelleri, polinomal regresyon modelinden daha başarılı olduğu söylenebilir. Her üç modelin başarısı, Saad ve arkadaşlarının (2020) yaptığı çalışmada doğrusal regresyon modelinin başarısıyla (0,9944) oldukça yakın olup random forest (0,9272) ve gradient decent (0,9404) yöntemlerinden daha başarılı olduğu görülmüştür.

5.2 Öneriler

Bitcoin’in geçmiş verilerinden oluşan veri kümesini kullanarak oluşturulan modeller belirli bir başarı elde etmiştir. Bu modeller ve geçmiş veriler kullanılarak kripto paraların gelecek zaman dilimlerindeki fiyatlarını tespit eden sistemler üzerinde çalışabilir.

Kripto paraların, şu ana kadar gözlemlendiği kadarıyla sayısal verilerin yanında toplumsal, siyasi ve ekonomik olaylar gibi etkenlerden oldukça etkilendiği

görülmektedir. Kripto paralarla ilgili yapılacak çalışmalarda bahsedilen bu etkenlerinde göz önünde bulundurulması çalışmaların başarısını artırabilir.



KAYNAKLAR

- Acikkar, M., Akay, M. F., Akturk, E., & Gulec, M. (2013). Intelligent regression techniques for non-exercise prediction of VO₂max. *2013 21st Signal Processing and Communications Applications Conference (SIU)*, 1–4. <https://doi.org/10.1109/SIU.2013.6531534>
- Acı, M., Avcı, M., & Acı, Ç. (2017). Destek Vektör Regresyonu Yöntemiyle Karbon Nanotüp Benzetim Süresinin Kısaltılması. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 32(3). <https://doi.org/10.17341/gazimmfd.337642>
- Ahram, T., Sargolzaei, A., Sargolzaei, S., Daniels, J., & Amaba, B. (2017). Blockchain technology innovations. *2017 IEEE Technology and Engineering Management Society Conference, TEMSCON 2017*, 137–141. <https://doi.org/10.1109/TEMSCON.2017.7998367>
- Allen, J. F. (1998). AI Growing Up: The Changes and Opportunities. *AI Magazine*, 19(4). <https://doi.org/https://doi.org/10.1609/aimag.v19i4.1422>
- Almasri, E., & Arslan, E. (2018). Predicting Cryptocurrencies Prices with Neural Networks. *2018 6th International Conference on Control Engineering & Information Technology (CEIT)*, 1–5. <https://doi.org/10.1109/CEIT.2018.8751939>
- Ataei, M., & Osanloo, M. (2004). Using a Combination of Genetic Algorithm and the Grid Search Method to Determine Optimum Cutoff Grades of Multiple Metal Deposits. *International Journal of Surface Mining, Reclamation and Environment*, 18(1), 60–78. <https://doi.org/10.1076/ijsm.18.1.60.23543>
- Awad, M., & Khanna, R. (2015). Support Vector Regression. In *Efficient Learning Machines* (pp. 67–80). Apress. https://doi.org/10.1007/978-1-4302-5990-9_4
- Aygören, H., Sarıtaş, H., & Moralı, T. (2012). İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 4(1), 73–88.
- Babu, D. V., Karthikeyan, C., Shreya, & Kumar, A. (2020). Performance Analysis of Cost and Accuracy for Whale Swarm and RMSprop Optimizer. *IOP Conference Series: Materials Science and Engineering*, 993(1), 12080. <https://doi.org/10.1088/1757-899x/993/1/012080>
- Berentsen, A., & Schär, F. (2018). A short introduction to the world of cryptocurrencies. *Federal Reserve Bank of St. Louis Review*, 100(1), 1–16. <https://doi.org/10.20955/r.2018.1-16>
- Bhaskar, N. D., & Chuen, D. L. K. (2015). Bitcoin Mining Technology. In *Handbook of Digital Currency* (pp. 45–65). Elsevier. <https://doi.org/10.1016/B978-0-12-802117-0.00003-5>
- bitcoin.org*. (2022, January 22). <https://bitcoin.org/en/>

- Bock, S., & Weiß, M. (2019). A Proof of Local Convergence for the Adam Optimizer. *2019 International Joint Conference on Neural Networks (IJCNN)*, 1–8. <https://doi.org/10.1109/IJCNN.2019.8852239>
- Brachman, R. J. (2006). (AA)AI More Than the Sum of Its Parts. *AI Magazine*, 27(4), 19–34. <https://doi.org/https://doi.org/10.1609/aimag.v27i4.1907>
- Caporale, G. M., Gil-Alana, L., & Plastun, A. (2018). Persistence in the cryptocurrency market. *Research in International Business and Finance*, 46, 141–148. <https://doi.org/10.1016/j.ribaf.2018.01.002>
- Carrick, J. (2016). Bitcoin as a Complement to Emerging Market Currencies. *Emerging Markets Finance and Trade*, 52(10), 2321–2334. <https://doi.org/10.1080/1540496X.2016.1193002>
- Cheng, Z., Jiao, S., Yang, Q., & Sheng, B. (2015). Deep Colorization. *Proceedings of the IEEE International Conference on Computer Vision*, 415–423.
- Chen, Y., He, P., Chen, W., & Zhao, F. (2018). A polynomial regression method based on Trans-dimensional Markov Chain Monte Carlo. *2018 IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, 1781–1786. <https://doi.org/10.1109/IAEAC.2018.8577769>
- Cheung, A. (Wai K., Roca, E., & Su, J. J. (2015). Crypto-currency bubbles: an application of the Phillips–Shi–Yu (2013) methodology on Mt. Gox bitcoin prices. *Applied Economics*, 47(23), 2348–2358. <https://doi.org/10.1080/00036846.2015.1005827>
- Coin Dance. (2022, January 15). <https://coin.dance/>
- CoinMarketCap. (2022, January 15). <https://coinmarketcap.com/>
- Cointelegraph. (2022, January 15). <https://tr.cointelegraph.com/>
- Conti, M., Sandeep, K. E., Lal, C., & Ruj, S. (2018). A survey on security and privacy issues of bitcoin. *IEEE Communications Surveys and Tutorials*, 20(4), 3416–3452. <https://doi.org/10.1109/COMST.2018.2842460>
- Copeland, B. J. (2000). The Turing Test*. *Minds and Machines*, 10, 519–539. <https://doi.org/https://doi.org/10.1023/A:1011285919106>
- Corbet, S., Lucey, B., Urquhart, A., & Yarovaya, L. (2019). Cryptocurrencies as a financial asset: A systematic analysis. *International Review of Financial Analysis*, 62, 182–199. <https://doi.org/10.1016/j.irfa.2018.09.003>
- Doran, M. D. (2014). *A Forensic Look At Bitcoin Cryptocurrencies*. Utica College.
- Drucker, H., Burges, C. J. C., Kaufman, L., Smola, A., & Vapnik, V. (1996). Support Vector Regression Machines. In M. C. Mozer, M. Jordan, & T. Petsche (Eds.), *Advances in Neural Information Processing Systems (NIPS 1996)* (Vol. 9, pp. 155–

- 161). MIT Press.
<https://proceedings.neurips.cc/paper/1996/file/d38901788c533e8286cb6400b40b386d-Paper.pdf>
- Dwyer, G. P. (2015). The economics of Bitcoin and similar private digital currencies. *Journal of Financial Stability*, 17, 81–91. <https://doi.org/10.1016/j.jfs.2014.11.006>
- Fang, F., Ventre, C., Basios, M., Kanthan, L., Martinez-Rego, D., Wu, F., & Li, L. (2022). Cryptocurrency trading: a comprehensive survey. *Financial Innovation*, 8(1), 13. <https://doi.org/10.1186/s40854-021-00321-6>
- Farrell, R. (2015). An Analysis of the Cryptocurrency Industry. In *Wharton Research Scholars*. https://repository.upenn.edu/wharton_research_scholars/130
- Fukushima, K. (1986). A Neural Network Model for Selective Attention in Visual Pattern Recognition. *Biological Cybernetics*, 55, 5–15.
- Fukushima, K., Miyake, S., & Ito, T. (1983). Neocognitron: A Neural Network Model for a Mechanism of Visual Pattern Recognition. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-13(5), 826–834. <https://doi.org/10.1109/TSMC.1983.6313076>
- Fumo, D. (2017, August 4). *A Gentle Introduction To Neural Networks Series — Part 1*. <https://towardsdatascience.com/a-gentle-introduction-to-neural-networks-series-part-1-2b90b87795bc>
- Gençal, M. C., & Oral, M. (2022). A novel meta-optimizer for evolutionary algorithms: bipolar mating tendency. *Pamukkale University Journal of Engineering Sciences*, 28(2), 313–323. <https://doi.org/10.5505/pajes.2021.29165>
- Ghosh, A., Gupta, S., Dua, A., & Kumar, N. (2020). Security of Cryptocurrencies in blockchain technology: State-of-art, challenges and future prospects. *Journal of Network and Computer Applications*, 163, 102635. <https://doi.org/10.1016/j.jnca.2020.102635>
- Google Finans. (2022, January 18). https://www.google.com/finance/quote/BTC-USD?sa=X&ved=2ahUKEwjX2InAgrz1AhUwR_EDHcv6AigQ-fUHegQIFBAS&window=MAX
- Greaves, A., & Au, B. (2015). *Using the Bitcoin Transaction Graph to Predict the Price of Bitcoin*.
- Hao, X., Zhang, G., & Ma, S. (2016). Deep Learning. *International Journal of Semantic Computing*, 10(03), 417–439. <https://doi.org/10.1142/S1793351X16500045>
- Hayes, P., & Ford, K. (1995). Turing Test Considered Harmful. *Proceedings of the 14th International Joint Conference on Artificial Intelligence*, 972–977.

- Hinton, G., Srivastava, N., & Srivastava, N. (2012, February 6). *Neural Networks for Machine Learning*.
http://www.cs.toronto.edu/~tijmen/csc321/slides/lecture_slides_lec6.pdf
- Hwang, J., & Zhou, Y. (2016). *Image Colorization with Deep Convolutional Neural Networks*.
- İnik, Ö., & Ülker, E. (2017a). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. In *Gaziosmanpaşa Bilimsel Araştırma Dergisi* (Vol. 6, Issue 3, pp. 85–104). Tokat Gaziosmanpaşa University.
- İnik, Ö., & Ülker, E. (2017b). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85–104.
<http://dergipark.gov.tr/gbad>
- Ji, S., Kim, J., & Im, H. (2019a). A comparative study of bitcoin price prediction using deep learning. *Mathematics*, 7(10). <https://doi.org/10.3390/math7100898>
- Ji, S., Kim, J., & Im, H. (2019b). A Comparative Study of Bitcoin Price Prediction Using Deep Learning. *Mathematics*, 7(10), 898.
<https://doi.org/10.3390/math7100898>
- Karaağaç, G. A., & Altınırnak, S. (2018). En Yüksek Piyasa Değerine Sahip On Kripto Paranın Birbirleriyle Etkileşimi. *Muhasebe ve Finansman Dergisi*, 127–144.
<https://doi.org/10.25095/mufad.438852>
- Karasu, S., Altan, A., Sarac, Z., & Hacıoglu, R. (2018). Zaman Serisi Verilerini Kullanarak Makine Öğrenmesi Yöntemleri ile Bitcoin Fiyat Tahmini. *26th IEEE Signal Processing and Communications Applications Conference, SIU 2018*, 1–4.
<https://doi.org/10.1109/SIU.2018.8404760>
- Kavitha S, Varuna S, & Ramya R. (2016). A comparative analysis on linear regression and support vector regression. *2016 Online International Conference on Green Engineering and Technologies (IC-GET)*, 1–5.
<https://doi.org/10.1109/GET.2016.7916627>
- Kesebir, M., & Günceler, B. (2019). Kripto Para Birimlerinin Parlak Geleceği. *Iğdır Üniversitesi Sosyal Bilimler Dergisi*, 17, 601–621.
- Keskenler, M. F., & Keskenler, E. F. (2017). Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi. *Takvim-i Vekayi*, 5(2), 8–18.
- Kim, H. (2022). Deep Learning. In *Artificial Intelligence for 6G* (pp. 247–303). Springer International Publishing. https://doi.org/10.1007/978-3-030-95041-5_6
- Kingma, D. P., & Ba, J. (2014). *Adam: A Method for Stochastic Optimization*.
- Kirsh, D. (1991). Foundations of AI: The big issues. *Artificial Intelligence*, 47(1–3).
[https://doi.org/10.1016/0004-3702\(91\)90048-O](https://doi.org/10.1016/0004-3702(91)90048-O)

- Kriesel, D. (2007). *A brief Introduction on Neural Networks*. www.dkriesel.com
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105. <http://code.google.com/p/cuda-convnet/>
- Lahmiri, S., & Bekiros, S. (2019). Cryptocurrency forecasting with deep learning chaotic neural networks. *Chaos, Solitons and Fractals*, 118, 35–40. <https://doi.org/10.1016/j.chaos.2018.11.014>
- Laird, J. E., Wray, R. E., Marinier, R. P., & Langley, P. (2009). Claims and Challenges in Evaluating Human-Level Intelligent Systems. *Proceedings of the Second Conference on Artificial General Intelligence*, 91–96.
- Larsson, G., Maire, M., & Shakhnarovich, G. (2016). Learning Representations for Automatic Colorization. *European Conference on Computer Vision*, 9909 LNCS, 577–593. https://doi.org/10.1007/978-3-319-46493-0_35
- Lauzon, F. Q. (2012). An introduction to deep learning. *2012 11th International Conference on Information Science, Signal Processing and Their Applications (ISSPA)*, 1438–1439. <https://doi.org/10.1109/ISSPA.2012.6310529>
- Lepore, C., Ceria, M., Visconti, A., Rao, U. P., Shah, K. A., & Zanolini, L. (2020). A Survey on Blockchain Consensus with a Performance Comparison of PoW, PoS and Pure PoS. *Mathematics*, 8(10), 1782. <https://doi.org/10.3390/math8101782>
- Lu, H., Li, Y., Chen, M., Kim, H., & Serikawa, S. (2018). Brain Intelligence: Go beyond Artificial Intelligence. *Mobile Networks and Applications*, 23, 368–375. <https://doi.org/https://doi.org/10.1007/s11036-017-0932-8>
- Lyons, M. B., Keith, D. A., Phinn, S. R., Mason, T. J., & Elith, J. (2018). A comparison of resampling methods for remote sensing classification and accuracy assessment. *Remote Sensing of Environment*, 208, 145–153. <https://doi.org/10.1016/j.rse.2018.02.026>
- Machine Learning Mastery*. (2022, January 11). <https://machinelearningmastery.com/>
- Malone, D., & O'Dwyer, K. J. (2014). Bitcoin Mining and its Energy Footprint. *25th IET Irish Signals & Systems Conference 2014 and 2014 China-Ireland International Conference on Information and Communities Technologies (ISSC 2014/CICT 2014)*, 280–285. <https://doi.org/10.1049/cp.2014.0699>
- Malsa, N., Vyas, V., & Gautam, J. (2021). RMSE calculation of LSTM models for predicting prices of different cryptocurrencies. *International Journal of System Assurance Engineering and Management*. <https://doi.org/10.1007/s13198-021-01431-1>
- Marcus, G., Rossi, F., & Veloso, M. (2016). Beyond the Turing Test. *AI Magazine*, 37(1), 3–4. <https://doi.org/https://doi.org/10.1609/aimag.v37i1.2650>

- Mater, A. C., & Coote, M. L. (2019). Deep Learning in Chemistry. *Journal of Chemical Information and Modeling*, 59(6), 2545–2559.
<https://doi.org/10.1021/acs.jcim.9b00266>
- Maulud, D., & Abdulazeez, A. M. (2020). A Review on Linear Regression Comprehensive in Machine Learning. *Journal of Applied Science and Technology Trends*, 1(4), 140–147. <https://doi.org/10.38094/jastt1457>
- Mccarthy, J. (2007). *What Is Artificial Intelligence?* <http://www-formal.stanford.edu/jmc/>
- Mcculloch, W. S., & Pitts, W. (1943). A Logical Calculus Of The Ideas Immanent In Nervous Activity. *Bulletin Of Mathematical Biophysics*, 5, 115–133.
<https://doi.org/https://doi.org/10.1007/BF02478259>
- McNally, S., Roche, J., & Caton, S. (2018a). Predicting the Price of Bitcoin Using Machine Learning. *2018 26th Euromicro International Conference on Parallel, Distributed and Network-Based Processing (PDP)*, 339–343.
<https://doi.org/10.1109/PDP2018.2018.00060>
- McNally, S., Roche, J., & Caton, S. (2018b). Predicting the Price of Bitcoin Using Machine Learning. *26th Euromicro International Conference on Parallel, Distributed, and Network-Based Processing, PDP 2018*, 339–343.
<https://doi.org/10.1109/PDP2018.2018.00060>
- Meunier, S. (2018). Chapter 3 - Blockchain 101: What is Blockchain and How Does This Revolutionary Technology Work? In A. Marke (Ed.), *Transforming Climate Finance and Green Investment with Blockchains* (pp. 23–34). Academic Press.
<https://doi.org/https://doi.org/10.1016/B978-0-12-814447-3.00003-3>
- Minsky, M. L., & Papert, S. A. (1969). *Perceptrons*.
- Mukhopadhyay, U., Skjellum, A., Hambolu, O., Oakley, J., Yu, L., & Brooks, R. (2016). A brief survey of Cryptocurrency systems. *2016 14th Annual Conference on Privacy, Security and Trust, PST 2016*, 745–752.
<https://doi.org/10.1109/PST.2016.7906988>
- Müller, K.-R., Smola, A. J., Rätsch, G., Schölkopf, B., Kohlmorgen, J., & Vapnik, V. (1997). Predicting time series with support vector machines. In W. Gerstner, A. Germond, M. Hasler, & J.-D. Nicoud (Eds.), *Artificial Neural Networks — ICANN'97* (pp. 999–1004). Springer Berlin Heidelberg.
<https://doi.org/https://doi.org/10.1007/BFb0020283>
- Nakamoto, S. (2008). *Bitcoin: A Peer-to-Peer Electronic Cash System*.
www.bitcoin.org/bitcoin.pdf
- Nanda, S., Zafari, F., DeCusatis, C., Wedaa, E., & Yang, B. (2016). Predicting network attack patterns in SDN using machine learning approach. *2016 IEEE Conference on Network Function Virtualization and Software Defined Networks (NFV-SDN)*, 167–172. <https://doi.org/10.1109/NFV-SDN.2016.7919493>

- Narin, A., İşler, Y., & Özer, M. (2014). Konjestif Kalp Yetmezliği Teşhisinde Kullanılan Çapraz Doğrulama Yöntemlerinin Sınıflandırıcı Performanslarının Belirlenmesine Olan Etkilerinin Karşılaştırılması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 16(48), 1–8. <https://dergipark.org.tr/en/download/article-file/588363>
- Niu, H., Lu, Q., & Wang, C. (2018). Color Correction Based on Histogram Matching and Polynomial Regression for Image Stitching. *2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC)*, 257–261. <https://doi.org/10.1109/ICIVC.2018.8492895>
- Pierro, M. di. (2017). What Is the Blockchain? *Computing in Science and Engineering*, 19(5), 92–95. <https://doi.org/10.1109/MCSE.2017.3421554>
- Rácz, A., Bajusz, D., & Héberger, K. (2021). Effect of Dataset Size and Train/Test Split Ratios in QSAR/QSPR Multiclass Classification. *Molecules*, 26(4), 1111. <https://doi.org/10.3390/molecules26041111>
- Rodriguez, J. D., Perez, A., & Lozano, J. A. (2010). Sensitivity Analysis of k-Fold Cross Validation in Prediction Error Estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(3), 569–575. <https://doi.org/10.1109/TPAMI.2009.187>
- Rose, C. (2015). The Evolution Of Digital Currencies: Bitcoin, A Cryptocurrency Causing A Monetary Revolution. *International Business & Economics Research Journal (IBER)*, 14(4), 617. <https://doi.org/10.19030/iber.v14i4.9353>
- Rosenblatt, F. (1961). *Principles of neurodynamics. perceptrons and the theory of brain mechanisms*.
- Roziqin, M. C., Basuki, A., & Harsono, T. (2016). A comparison of Montecarlo linear and dynamic polynomial regression in predicting dengue fever case. *2016 International Conference on Knowledge Creation and Intelligent Computing (KCIC)*, 213–218. <https://doi.org/10.1109/KCIC.2016.7883649>
- Ruder, S. (2016). *An overview of gradient descent optimization algorithms*.
- Saad, M., Choi, J., Nyang, D., Kim, J., & Mohaisen, A. (2020). Toward Characterizing Blockchain-Based Cryptocurrencies for Highly Accurate Predictions. *IEEE Systems Journal*, 14(1), 321–332. <https://doi.org/10.1109/JSYST.2019.2927707>
- Şahin, E. E. (2018). Kripto Para Bitcoin: ARIMA ve Yapay Sinir Ağları İle Fiyat Tahmini. *Fiscaoeconomia*, 2(2), 74–92. <https://doi.org/10.25295/fsecon.2018.02.005>
- Şahin, E. E., & Özkan, O. (2018). Asimetrik Volatilitenin Tahmini: Kripto Para Bitcoin Uygulaması. *Bilecik Şeyh Edebali Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 3(2), 240–247. <http://dergipark.gov.tr/bseusbed>

- Saygın, A. P., Çiçekli, İ., & Akman, V. (2000). Turing Test: 50 Years Later. *Minds and Machines*, 10, 463–518. <https://doi.org/https://doi.org/10.1023/A:1011288000451>
- Seyyarer, E., Ayata, F., Uçkan, T., & Karci, A. (2020). Derin Öğrenmede Kullanılan Optimizasyon Algoritmalarının Uygulanması ve Kiyaslanması. *Anatolian Journal of Computer Sciences*, 5(2), 90–98. <https://dergipark.org.tr/en/download/article-file/1148741>
- Sharma, S., Sharma, S., & Athaiya, A. (2020). Activation Functions In Neural Networks. *International Journal of Engineering Applied Sciences and Technology*, 4(12), 310–316. <http://www.ijeast.com>
- Simon, H. A., Bibel, W., Bundy, A., & Berliner, H. (2000). AI's greatest trends and controversies. *IEEE Intelligent Systems and Their Applications*, 15(1), 8–17. <https://doi.org/10.1109/5254.820322>
- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199–222. <https://doi.org/10.1023/B:STCO.0000035301.49549.88>
- Srivastava, N., Hinton, G., Krizhevsky, A., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15, 1929–1958. https://www.jmlr.org/papers/volume15/srivastava14a/srivastava14a.pdf?utm_content=buffer79b43&utm_medium=social&utm_source=twitter.com&utm_campaign=buffer
- Sydorenko, I. (2022, January 11). *Label Your Data*. <https://labeleyourdata.com/>
- Taqi, A. M., Awad, A., Al-Azzo, F., & Milanova, M. (2018). The Impact of Multi-Optimizers and Data Augmentation on TensorFlow Convolutional Neural Network Performance. *2018 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)*, 140–145. <https://doi.org/10.1109/MIPR.2018.00032>
- Temelli, F. (2019). Kripto Para Birimlerinden Bitcoin ve Muhasebe Açısından Değerlendirilmesi. *İktisadi Yenilik Dergisi*, 6(2). <https://coinmarketcap.com/all/views/all/>
- Towards Data Science*. (2022, January 11). <https://towardsdatascience.com/>
- Treleaven, P., Brown, R. G., & Yang, D. (2017). Blockchain Technology in Finance. *Computer*, 50(9), 14–17. <https://ieeexplore.ieee.org/document/8048631>
- Turing, A. M. (1950). Computing Machinery and Intelligence. *Mind*, 49, 433–460.
- Urquhart, A. (2016). The inefficiency of Bitcoin. *Economics Letters*, 148, 80–82. <https://doi.org/10.1016/j.econlet.2016.09.019>

- Üstüner, M., & Şanlı, F. B. (2019). Çok zamanlı polarimetrik SAR verileri ile tarımsal ürünlerin sınıflandırılması. *Journal of Geodesy and Geoinformation*, 7(1), 1–10. <https://doi.org/10.9733/JGG.2020R0001.T>
- Vapnik, V., Golowich, S., & Smola, A. (1996). Support Vector Method for Function Approximation, Regression Estimation and Signal Processing. In M. C. Mozer, M. Jordan, & T. Petsche (Eds.), *Advances in Neural Information Processing Systems* (Vol. 9). MIT Press. <https://proceedings.neurips.cc/paper/1996/file/4f284803bd0966cc24fa8683a34afc6e-Paper.pdf>
- Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. Springer New York. <https://doi.org/10.1007/978-1-4757-2440-0>
- Vázquez, F. (2017, November 21). *Deep Learning made easy with Deep Cognition*. <https://becominghuman.ai/deep-learning-made-easy-with-deep-cognition-403fbe445351>
- Wang, P. (2019). On Defining Artificial Intelligence. *Journal of Artificial General Intelligence*, 10(2), 1–37. <https://doi.org/10.2478/jagi-2019-0002>
- Widrow, B., & Hoff, M. E. (1960). *Adaptive Switching Circuits*.
- Wong, T.-T., & Yeh, P.-Y. (2020). Reliable Accuracy Estimates from k-Fold Cross Validation. *IEEE Transactions on Knowledge and Data Engineering*, 32(8), 1586–1594. <https://doi.org/10.1109/TKDE.2019.2912815>
- Wu, C.-H., Ho, J.-M., & Lee, D. T. (2004). Travel-Time Prediction With Support Vector Regression. *IEEE Transactions on Intelligent Transportation Systems*, 5(4), 276–281. <https://doi.org/10.1109/TITS.2004.837813>
- Wust, K., & Gervais, A. (2018). Do you need a blockchain? *Proceedings - 2018 Crypto Valley Conference on Blockchain Technology, CVCBT 2018*, 45–54. <https://doi.org/10.1109/CVCBT.2018.00011>
- Yaga, D., Mell, P., Roby, N., & Scarfone, K. (2019). *Blockchain Technology Overview*. <https://doi.org/10.6028/NIST.IR.8202>
- Yazan, E., & Talu, M. F. (2017). Comparison of the stochastic gradient descent based optimization techniques. *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*, 1–5. <https://doi.org/10.1109/IDAP.2017.8090299>
- Yousoff, S. N. M., Baharin, A., & Abdullah, A. (2016). A review on optimization algorithm for deep learning method in bioinformatics field. *2016 IEEE EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, 707–711. <https://doi.org/10.1109/IECBES.2016.7843542>
- Yuan, Y., & Wang, F. Y. (2016). Towards blockchain-based intelligent transportation systems. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, 2663–2668. <https://doi.org/10.1109/ITSC.2016.7795984>

Zhang, Q., Yang, L. T., Chen, Z., & Li, P. (2018). A survey on deep learning for big data. *Information Fusion*, 42, 146–157.
<https://doi.org/10.1016/j.inffus.2017.10.006>

Zhang, R., Isola, P., & Efros, A. A. (2016). Colorful Image Colorization. In B. Leibe, J. Matas, N. Sebe, & M. Welling (Eds.), *European Conference on Computer Vision* (Vol. 9907, pp. 649–666). Springer International Publishing.
https://doi.org/10.1007/978-3-319-46487-9_40

Zhang, R., Xue, R., & Liu, L. (2019). Security and privacy on blockchain. *ACM Computing Surveys*, 52(3), 1–34. <https://doi.org/10.1145/3316481>



EKLER

EK-1 Derin Öğrenme modeli parametre deneyi sonuçları

Derin Öğrenme Modeli Parametreleri						Başarı Metrikleri		
activation	batch_size	dropout	epochs	learning_rate	neurons	R^2	MAE	RMSE
relu	10	0,5	50	0,0005	256	0,9957	448	913
relu	20	0,5	30	0,0005	256	0,9952	483	955
relu	30	0,5	30	0,0005	256	0,9957	529	808
relu	20	0,5	50	0,0005	256	0,9965	531	1251
relu	30	0,5	50	0,0005	128	0,9942	555	1139
relu	10	0,5	30	0,0005	256	0,9949	571	1041
relu	20	0,5	100	0,0005	256	0,9940	586	923
relu	40	0,5	30	0,001	256	0,9939	590	939
relu	40	0,5	100	0,0005	256	0,9959	590	962
relu	20	0,5	100	0,0015	256	0,9951	616	1454
relu	40	0,5	30	0,0005	256	0,9941	619	864
relu	40	0,6	30	0,0005	256	0,9938	640	1061
relu	30	0,5	30	0,0015	128	0,9905	647	1467
relu	30	0,5	50	0,0005	256	0,9949	685	1140
relu	30	0,5	30	0,001	256	0,9915	686	998
relu	40	0,5	50	0,0005	256	0,9963	693	893
relu	20	0,5	30	0,001	256	0,9962	710	1038
relu	20	0,6	30	0,0005	256	0,9967	726	1032
relu	10	0,5	100	0,0005	128	0,9974	729	1160
relu	40	0,5	100	0,001	256	0,9943	733	1144
relu	40	0,5	100	0,0015	128	0,9901	743	1080
relu	10	0,6	100	0,0005	256	0,9957	744	1368
relu	30	0,7	100	0,0005	256	0,9922	753	1467
relu	40	0,6	100	0,001	256	0,9970	754	1657
relu	30	0,5	30	0,0015	256	0,9933	757	1360
relu	30	0,5	100	0,0005	128	0,9937	761	1313
relu	40	0,5	100	0,0005	128	0,9941	763	1569
relu	30	0,5	30	0,001	128	0,9882	766	988
relu	20	0,6	100	0,001	256	0,9972	769	1219
relu	10	0,5	100	0,0005	256	0,9940	772	851
relu	20	0,6	100	0,0005	256	0,9939	774	1425
relu	40	0,6	50	0,001	256	0,9914	776	1432
relu	10	0,5	100	0,001	128	0,9886	778	881
relu	30	0,5	50	0,001	256	0,9922	782	898
relu	30	0,6	30	0,001	256	0,9932	785	1022
relu	20	0,5	100	0,001	256	0,9956	794	1594
relu	20	0,7	50	0,0005	256	0,9923	795	1490
relu	30	0,6	50	0,0005	256	0,9948	799	905
relu	40	0,7	30	0,0005	256	0,9878	803	1550
relu	40	0,5	30	0,0005	128	0,9948	804	1346
tanh	10	0,5	100	0,0005	256	0,9941	806	1293
relu	20	0,6	50	0,0015	256	0,9887	809	1328
relu	30	0,6	100	0,0005	256	0,9942	811	1075

relu	20	0,6	30	0,001	128	0,9881	813	1403
relu	20	0,6	50	0,0005	256	0,9918	819	1177
relu	40	0,6	100	0,0005	256	0,9964	826	1228
relu	40	0,5	50	0,001	256	0,9943	830	1518
relu	20	0,5	50	0,0005	128	0,9933	837	1118
relu	10	0,5	30	0,0005	128	0,9956	838	1335
tanh	20	0,5	100	0,001	256	0,9947	841	1256
relu	40	0,5	30	0,0015	128	0,9924	842	868
relu	40	0,6	30	0,001	256	0,9939	843	1485
tanh	10	0,5	100	0,001	256	0,9945	844	1476
tanh	20	0,5	50	0,0015	256	0,9930	850	1583
relu	40	0,6	50	0,0005	256	0,9963	852	860
sigmoid	10	0,5	100	0,0015	256	0,9943	853	1248
relu	20	0,6	30	0,0005	128	0,9880	862	1749
relu	30	0,5	30	0,0005	128	0,9911	867	1230
tanh	30	0,5	100	0,001	256	0,9940	867	1207
relu	10	0,6	30	0,001	128	0,9878	868	1505
relu	30	0,5	100	0,0005	256	0,9961	870	1142
tanh	20	0,5	100	0,0005	256	0,9943	870	1502
relu	40	0,5	100	0,001	128	0,9942	887	1105
relu	40	0,6	30	0,0015	256	0,9933	891	1542
relu	40	0,5	50	0,0005	128	0,9926	891	1301
relu	10	0,5	100	0,0015	256	0,9937	895	1566
relu	10	0,6	50	0,001	256	0,9946	898	1569
tanh	20	0,5	50	0,001	256	0,9915	902	1310
tanh	30	0,6	100	0,0015	256	0,9929	902	1456
relu	40	0,5	50	0,001	128	0,9947	908	1234
tanh	20	0,5	100	0,0015	256	0,9930	910	1370
tanh	20	0,6	100	0,001	256	0,9904	911	1447
tanh	30	0,5	100	0,0015	256	0,9936	917	1313
tanh	30	0,6	100	0,001	256	0,9910	917	1559
relu	30	0,5	50	0,001	128	0,9914	919	1152
relu	30	0,6	30	0,0005	256	0,9953	920	1053
tanh	10	0,5	100	0,0015	256	0,9912	921	1280
relu	40	0,5	100	0,0015	256	0,9941	921	983
tanh	10	0,6	100	0,0005	256	0,9907	921	1400
sigmoid	20	0,5	100	0,0015	256	0,9936	923	1258
relu	10	0,5	50	0,001	256	0,9886	924	1186
tanh	10	0,6	50	0,001	256	0,9907	927	1550
relu	10	0,6	30	0,0015	256	0,9952	929	1298
relu	10	0,5	30	0,001	256	0,9893	931	942
relu	40	0,6	50	0,0005	128	0,9892	937	1705
relu	20	0,5	30	0,0005	128	0,9939	937	1037
relu	40	0,6	30	0,001	128	0,9882	942	1424
relu	40	0,5	50	0,0015	128	0,9914	943	1586
sigmoid	10	0,5	100	0,0015	128	0,9946	948	1344
relu	20	0,6	30	0,001	256	0,9914	949	1579
relu	30	0,7	100	0,001	256	0,9916	951	1170
tanh	30	0,5	50	0,0015	256	0,9928	956	1530
relu	30	0,5	50	0,0015	256	0,9934	956	1426

relu	10	0,7	50	0,0005	256	0,9940	958	1375
tanh	10	0,6	100	0,001	256	0,9926	959	1535
relu	10	0,6	100	0,0015	256	0,9954	963	1616
relu	10	0,6	30	0,0005	256	0,9919	965	1260
tanh	40	0,5	50	0,0015	256	0,9925	966	1512
relu	30	0,5	100	0,0015	256	0,9933	967	1052
relu	30	0,5	50	0,0015	128	0,9919	973	1663
relu	20	0,5	100	0,0005	128	0,9955	980	1029
sigmoid	10	0,5	100	0,001	256	0,9940	981	1390
relu	20	0,5	50	0,001	256	0,9948	983	1201
tanh	40	0,6	100	0,0015	256	0,9918	984	1438
relu	20	0,5	50	0,001	128	0,9910	985	1391
tanh	10	0,5	50	0,0005	256	0,9929	986	1292
sigmoid	30	0,5	100	0,0015	256	0,9924	986	1461
relu	20	0,7	100	0,0005	256	0,9896	995	1370
relu	40	0,7	30	0,0015	256	0,9901	1000	1743
sigmoid	10	0,5	50	0,0015	256	0,9911	1002	1485
relu	40	0,7	50	0,001	256	0,9917	1005	1738
tanh	10	0,5	50	0,0015	256	0,9912	1015	1397
tanh	10	0,6	100	0,0015	256	0,9911	1029	1402
tanh	10	0,5	100	0,001	128	0,9893	1030	1741
tanh	10	0,5	50	0,001	256	0,9909	1032	1358
tanh	20	0,6	100	0,0015	256	0,9917	1038	1316
relu	30	0,5	100	0,0015	128	0,9952	1044	1176
relu	40	0,6	30	0,0015	128	0,9926	1049	1418
tanh	40	0,5	100	0,0015	256	0,9928	1049	1222
relu	10	0,5	50	0,0015	128	0,9881	1051	1235
relu	30	0,7	30	0,001	256	0,9907	1055	1382
relu	10	0,5	30	0,0015	256	0,9909	1059	1501
relu	30	0,5	100	0,001	256	0,9954	1061	1242
relu	30	0,5	100	0,001	128	0,9925	1064	1000
sigmoid	20	0,5	100	0,001	256	0,9920	1072	1365
relu	30	0,7	30	0,0005	256	0,9925	1081	1243
relu	40	0,7	100	0,001	256	0,9952	1081	1426
sigmoid	10	0,5	100	0,0005	256	0,9914	1083	1445
tanh	40	0,6	100	0,001	256	0,9921	1093	1542
sigmoid	10	0,6	100	0,0015	256	0,9891	1099	1561
tanh	30	0,6	50	0,001	256	0,9888	1228	1667
tanh	30	0,5	100	0,0005	256	0,9914	1099	1769
relu	40	0,7	50	0,0015	256	0,9934	1101	1621
relu	30	0,6	30	0,0015	256	0,9917	1103	1557
tanh	10	0,6	50	0,0015	256	0,9890	1108	1567
sigmoid	20	0,6	100	0,0015	256	0,9893	1115	1690
relu	20	0,6	100	0,0005	128	0,9887	1115	1439
relu	30	0,7	50	0,0005	256	0,9947	1121	1313
tanh	20	0,6	50	0,0015	256	0,9915	1121	1730
tanh	20	0,5	30	0,0015	256	0,9904	1123	1525
tanh	40	0,5	100	0,001	256	0,9932	1125	1207
tanh	40	0,6	50	0,0015	256	0,9909	1139	1644
tanh	30	0,5	50	0,001	256	0,9903	1143	1516

relu	20	0,6	50	0,001	256	0,9944	1147	1362
sigmoid	10	0,5	100	0,001	128	0,9908	1149	1608
relu	40	0,6	50	0,001	128	0,9893	1172	1130
tanh	30	0,5	30	0,0015	256	0,9879	1180	1721
tanh	10	0,6	30	0,001	256	0,9899	1183	1603
relu	40	0,6	100	0,0015	128	0,9881	1193	1328
relu	30	0,6	50	0,001	256	0,9960	1209	1246



EK-2 Destek vektör regresyonu modeli parametre deneyi sonuçları

Destek Vektör Regresyonu Parametreleri					Başarı Metrikleri		
C	Degree	Epsilon	Gamma	Kernel	R^2	MAE	RMSE
10^4	2	0,1	'scale'	'rbf'	0,9991	265	493
10^4	2	0,1	'scale'	'poly'	0,9326	3170	4322
10^4	2	0,1	'scale'	'linear'	0,9990	280	496
10^4	2	0,1	'auto'	'rbf'	0,9985	352	621
10^4	2	0,1	'auto'	'poly'	0,9327	3238	4316
10^4	2	0,1	'auto'	'linear'	0,9990	280	496
10^4	2	0,2	'scale'	'rbf'	0,9991	265	493
10^4	2	0,2	'scale'	'poly'	0,9326	3170	4322
10^4	2	0,2	'scale'	'linear'	0,9990	280	496
10^4	2	0,2	'auto'	'rbf'	0,9985	352	621
10^4	2	0,2	'auto'	'poly'	0,9327	3238	4316
10^4	2	0,2	'auto'	'linear'	0,9990	280	496
10^4	2	0,3	'scale'	'rbf'	0,9991	265	493
10^4	2	0,3	'scale'	'poly'	0,9326	3170	4322
10^4	2	0,3	'scale'	'linear'	0,9990	280	496
10^4	2	0,3	'auto'	'rbf'	0,9985	352	621
10^4	2	0,3	'auto'	'poly'	0,9327	3238	4316
10^4	2	0,3	'auto'	'linear'	0,9990	280	496
10^4	3	0,1	'scale'	'rbf'	0,9991	265	493
10^4	3	0,1	'scale'	'poly'	0,8083	5003	7288
10^4	3	0,1	'scale'	'linear'	0,9990	280	496
10^4	3	0,1	'auto'	'rbf'	0,9985	352	621
10^4	3	0,1	'auto'	'poly'	0,8188	5390	7075
10^4	3	0,1	'auto'	'linear'	0,9990	280	496
10^4	3	0,2	'scale'	'rbf'	0,9991	265	493
10^4	3	0,2	'scale'	'poly'	0,8083	5003	7288
10^4	3	0,2	'scale'	'linear'	0,9990	280	496
10^4	3	0,2	'auto'	'rbf'	0,9985	352	621
10^4	3	0,2	'auto'	'poly'	0,8188	5390	7075
10^4	3	0,2	'auto'	'linear'	0,9990	280	496
10^4	3	0,3	'scale'	'rbf'	0,9991	265	493
10^4	3	0,3	'scale'	'poly'	0,8083	5003	7288
10^4	3	0,3	'scale'	'linear'	0,9990	280	496
10^4	3	0,3	'auto'	'rbf'	0,9985	352	621
10^4	3	0,3	'auto'	'poly'	0,8188	5390	7075
10^4	3	0,3	'auto'	'linear'	0,9990	280	496
10^4	4	0,1	'scale'	'rbf'	0,9991	265	493
10^4	4	0,1	'scale'	'poly'	0,6405	6459	9969
10^4	4	0,1	'scale'	'linear'	0,9990	280	496
10^4	4	0,1	'auto'	'rbf'	0,9985	352	621
10^4	4	0,1	'auto'	'poly'	0,6849	6772	9328
10^4	4	0,1	'auto'	'linear'	0,9990	280	496
10^4	4	0,2	'scale'	'rbf'	0,9991	265	493
10^4	4	0,2	'scale'	'poly'	0,6405	6459	9969
10^4	4	0,2	'scale'	'linear'	0,9990	280	496
10^4	4	0,2	'auto'	'rbf'	0,9985	352	621
10^4	4	0,2	'auto'	'poly'	0,6849	6772	9328
10^4	4	0,2	'auto'	'linear'	0,9990	280	496
10^4	4	0,3	'scale'	'rbf'	0,9991	265	493
10^4	4	0,3	'scale'	'poly'	0,6405	6459	9969
10^4	4	0,3	'scale'	'linear'	0,9990	280	496
10^4	4	0,3	'auto'	'rbf'	0,9985	352	621

10 ⁴	4	0,3	'auto'	'poly'	0,6849	6772	9328
10 ⁴	4	0,3	'auto'	'linear'	0,9990	280	496
10 ⁵	2	0,1	'scale'	'rbf'	0,9993	215	410
10 ⁵	2	0,1	'scale'	'poly'	0,9346	3126	4261
10 ⁵	2	0,1	'scale'	'linear'	0,9994	214	397
10 ⁵	2	0,1	'auto'	'rbf'	0,9993	234	422
10 ⁵	2	0,1	'auto'	'poly'	0,9284	3220	4452
10 ⁵	2	0,1	'auto'	'linear'	0,9994	214	397
10 ⁵	2	0,2	'scale'	'rbf'	0,9993	215	410
10 ⁵	2	0,2	'scale'	'poly'	0,9346	3126	4261
10 ⁵	2	0,2	'scale'	'linear'	0,9994	214	397
10 ⁵	2	0,2	'auto'	'rbf'	0,9993	234	422
10 ⁵	2	0,2	'auto'	'poly'	0,9284	3220	4452
10 ⁵	2	0,2	'auto'	'linear'	0,9994	214	397
10 ⁵	2	0,3	'scale'	'rbf'	0,9993	215	410
10 ⁵	2	0,3	'scale'	'poly'	0,9346	3126	4261
10 ⁵	2	0,3	'scale'	'linear'	0,9994	214	397
10 ⁵	2	0,3	'auto'	'rbf'	0,9993	234	422
10 ⁵	2	0,3	'auto'	'poly'	0,9284	3220	4452
10 ⁵	2	0,3	'auto'	'linear'	0,9994	214	397
10 ⁵	3	0,1	'scale'	'rbf'	0,9993	215	410
10 ⁵	3	0,1	'scale'	'poly'	0,8027	4968	7396
10 ⁵	3	0,1	'scale'	'linear'	0,9994	214	397
10 ⁵	3	0,1	'auto'	'rbf'	0,9993	234	422
10 ⁵	3	0,1	'auto'	'poly'	0,8057	5316	7336
10 ⁵	3	0,1	'auto'	'linear'	0,9994	214	397
10 ⁵	3	0,2	'scale'	'rbf'	0,9993	215	410
10 ⁵	3	0,2	'scale'	'poly'	0,8027	4968	7396
10 ⁵	3	0,2	'scale'	'linear'	0,9994	214	397
10 ⁵	3	0,2	'auto'	'rbf'	0,9993	234	422
10 ⁵	3	0,2	'auto'	'poly'	0,8057	5316	7336
10 ⁵	3	0,2	'auto'	'linear'	0,9994	214	397
10 ⁵	3	0,3	'scale'	'rbf'	0,9993	215	410
10 ⁵	3	0,3	'scale'	'poly'	0,8027	4968	7396
10 ⁵	3	0,3	'scale'	'linear'	0,9994	214	397
10 ⁵	3	0,3	'auto'	'rbf'	0,9993	234	422
10 ⁵	3	0,3	'auto'	'poly'	0,8057	5316	7336
10 ⁵	3	0,3	'auto'	'linear'	0,9994	214	397
10 ⁵	4	0,1	'scale'	'rbf'	0,9993	215	410
10 ⁵	4	0,1	'scale'	'poly'	0,6269	6462	10155
10 ⁵	4	0,1	'scale'	'linear'	0,9994	214	397
10 ⁵	4	0,1	'auto'	'rbf'	0,9993	234	422
10 ⁵	4	0,1	'auto'	'poly'	0,6861	6709	9317
10 ⁵	4	0,1	'auto'	'linear'	0,9994	214	397
10 ⁵	4	0,2	'scale'	'rbf'	0,9993	215	410
10 ⁵	4	0,2	'scale'	'poly'	0,6269	6462	10155
10 ⁵	4	0,2	'scale'	'linear'	0,9994	214	397
10 ⁵	4	0,2	'auto'	'rbf'	0,9993	234	422
10 ⁵	4	0,2	'auto'	'poly'	0,6861	6709	9317
10 ⁵	4	0,2	'auto'	'linear'	0,9994	214	397
10 ⁵	4	0,3	'scale'	'rbf'	0,9993	215	410
10 ⁵	4	0,3	'scale'	'poly'	0,6269	6462	10155
10 ⁵	4	0,3	'scale'	'linear'	0,9994	214	397
10 ⁵	4	0,3	'auto'	'rbf'	0,9993	234	422
10 ⁵	4	0,3	'auto'	'poly'	0,6861	6709	9317
10 ⁵	4	0,3	'auto'	'linear'	0,9994	214	397
10 ⁶	2	0,1	'scale'	'rbf'	0,9993	216	426
10 ⁶	2	0,1	'scale'	'poly'	0,9354	3095	4234

10 ⁶	2	0,1	'scale'	'linear'	0,9994	211	402
10 ⁶	2	0,1	'auto'	'rbf'	0,9994	212	399
10 ⁶	2	0,1	'auto'	'poly'	0,9304	3189	4392
10 ⁶	2	0,1	'auto'	'linear'	0,9994	211	402
10 ⁶	2	0,2	'scale'	'rbf'	0,9993	217	426
10 ⁶	2	0,2	'scale'	'poly'	0,9354	3095	4234
10 ⁶	2	0,2	'scale'	'linear'	0,9994	211	402
10 ⁶	2	0,2	'auto'	'rbf'	0,9994	212	399
10 ⁶	2	0,2	'auto'	'poly'	0,9304	3189	4392
10 ⁶	2	0,2	'auto'	'linear'	0,9994	211	402
10 ⁶	2	0,3	'scale'	'rbf'	0,9993	217	426
10 ⁶	2	0,3	'scale'	'poly'	0,9354	3095	4234
10 ⁶	2	0,3	'scale'	'linear'	0,9994	211	403
10 ⁶	2	0,3	'auto'	'rbf'	0,9994	212	399
10 ⁶	2	0,3	'auto'	'poly'	0,9304	3189	4392
10 ⁶	2	0,3	'auto'	'linear'	0,9994	211	403
10 ⁶	3	0,1	'scale'	'rbf'	0,9993	217	426
10 ⁶	3	0,1	'scale'	'poly'	0,8054	4914	7347
10 ⁶	3	0,1	'scale'	'linear'	0,9994	211	402
10 ⁶	3	0,1	'auto'	'rbf'	0,9994	212	399
10 ⁶	3	0,1	'auto'	'poly'	0,8075	5257	7303
10 ⁶	3	0,1	'auto'	'linear'	0,9994	211	402
10 ⁶	3	0,2	'scale'	'rbf'	0,9993	217	426
10 ⁶	3	0,2	'scale'	'poly'	0,8054	4914	7347
10 ⁶	3	0,2	'scale'	'linear'	0,9994	211	402
10 ⁶	3	0,2	'auto'	'rbf'	0,9994	212	399
10 ⁶	3	0,2	'auto'	'poly'	0,8075	5257	7303
10 ⁶	3	0,2	'auto'	'linear'	0,9994	211	402
10 ⁶	3	0,3	'scale'	'rbf'	0,9993	217	426
10 ⁶	3	0,3	'scale'	'poly'	0,8054	4914	7347
10 ⁶	3	0,3	'scale'	'linear'	0,9994	211	403
10 ⁶	3	0,3	'auto'	'rbf'	0,9994	212	399
10 ⁶	3	0,3	'auto'	'poly'	0,8075	5257	7303
10 ⁶	3	0,3	'auto'	'linear'	0,9994	211	403
10 ⁶	4	0,1	'scale'	'rbf'	0,9993	217	426
10 ⁶	4	0,1	'scale'	'poly'	0,6253	6448	10183
10 ⁶	4	0,1	'scale'	'linear'	0,9994	211	402
10 ⁶	4	0,1	'auto'	'rbf'	0,9994	212	399
10 ⁶	4	0,1	'auto'	'poly'	0,6880	6656	9289
10 ⁶	4	0,1	'auto'	'linear'	0,9994	211	402
10 ⁶	4	0,2	'scale'	'rbf'	0,9993	217	426
10 ⁶	4	0,2	'scale'	'poly'	0,6259	6451	10174
10 ⁶	4	0,2	'scale'	'linear'	0,9994	211	402
10 ⁶	4	0,2	'auto'	'rbf'	0,9994	212	399
10 ⁶	4	0,2	'auto'	'poly'	0,6880	6656	9289
10 ⁶	4	0,2	'auto'	'linear'	0,9994	211	402
10 ⁶	4	0,3	'scale'	'rbf'	0,9993	217	426
10 ⁶	4	0,3	'scale'	'poly'	0,6252	6448	10185
10 ⁶	4	0,3	'scale'	'linear'	0,9994	211	403
10 ⁶	4	0,3	'auto'	'rbf'	0,9994	212	399
10 ⁶	4	0,3	'auto'	'poly'	0,6880	6656	9289
10 ⁶	4	0,3	'auto'	'linear'	0,9994	211	403

EK-3 Modellerin tahminleri ve gerçek değerler

Gerçek Değerler	Modellerin Tahmin Değerleri		
	Derin Öğrenme Modelinin Tahmini	Polinomal Regresyon Modelinin Tahmini	Destek Vektör Regresyon Modelinin Tahmini
3.893,27	3.759,87	3.988,15	3.995,90
13.443,50	13.116,10	14.073,10	13.887,20
23.261,80	23.247,50	25.039,50	24.260,60
6.407,75	6.172,12	6.625,21	6.594,16
47.816,30	47.093,70	50.906,70	49.667,00
50.117,00	48.731,50	53.353,70	52.207,40
22.600,80	22.487,40	24.289,80	23.745,40
5.303,99	5.063,98	5.387,27	5.378,35
21.029,20	21.269,00	22.630,90	22.303,60
46.605,60	45.588,70	49.352,00	47.929,90
10.374,80	10.143,40	10.797,10	10.654,80
6.649,44	6.190,83	6.788,06	6.782,31
8.286,91	7.995,46	8.630,79	8.572,14
7.207,20	6.873,46	7.545,14	7.532,20
7.246,42	7.024,17	7.454,00	7.397,65
1.281,09	1.908,61	1.195,68	1.223,48
11.395,40	11.467,10	12.057,50	11.865,30
12.808,80	12.178,80	13.583,30	13.502,00
63.528,50	60.623,00	69.463,60	66.030,30
5.090,03	4.898,34	5.200,06	5.191,12
1.176,21	1.880,62	1.072,43	1.100,44
10.344,50	9.956,54	10.580,50	10.491,00
37.287,50	37.876,90	41.602,50	39.928,90
47.800,00	44.976,00	50.711,30	49.288,40
15.687,50	15.325,60	16.668,80	16.458,20
20.187,20	19.447,20	21.064,00	20.688,00
5.627,48	5.427,00	5.747,95	5.731,28
8.099,31	8.004,78	8.391,40	8.386,56
46.430,70	45.608,60	50.101,80	48.956,40
17.700,80	17.659,40	18.802,80	18.688,90
39.184,60	37.215,20	41.360,40	40.048,60
35.312,40	34.483,40	37.736,30	37.046,60
2.718,49	2.650,95	2.711,68	2.739,31
7.332,61	7.177,92	7.706,34	7.651,04
8.865,05	8.281,79	8.877,50	8.846,18
8.272,02	8.274,94	8.827,36	8.765,95
60.190,00	60.808,70	65.619,30	63.075,20
18.812,10	19.474,50	20.541,70	20.179,80
41.955,10	39.998,90	45.131,50	43.786,80
7.255,13	7.054,65	7.532,17	7.484,13
11.976,70	11.394,00	12.474,10	12.372,60
21.516,10	21.244,80	22.632,30	22.149,90
3.980,62	3.838,15	4.032,06	4.031,64
19.610,40	19.195,10	20.741,70	20.355,80
21.378,10	21.386,90	22.864,00	22.421,80
7.391,41	6.927,16	7.579,70	7.559,66
33.548,80	33.286,10	36.129,30	35.122,90
8.291,94	7.821,74	8.301,52	8.293,74
56.563,80	56.089,10	61.108,20	59.161,70
19.816,70	19.454,80	20.338,40	19.953,20
8.338,94	7.665,52	8.515,88	8.506,96

7.202,62	7.056,63	7.498,08	7.443,35
6.577,85	6.005,31	6.852,89	6.891,55
18.570,00	17.991,30	19.259,50	18.854,70
8.092,44	7.477,59	8.034,87	8.049,93
61.340,00	60.346,00	65.751,40	63.775,80
38.467,10	37.507,10	40.906,20	40.049,30
10.371,80	9.510,24	10.600,90	10.587,10
19.721,90	18.536,80	20.648,80	20.380,00
8.155,22	7.713,33	8.414,45	8.377,13
7.576,28	7.260,24	7.807,36	7.783,82
6.156,30	5.892,23	6.392,45	6.372,97
15.218,60	15.456,80	17.189,90	17.368,00
41.512,90	41.849,10	45.135,90	43.498,40
6.413,99	6.212,17	6.616,59	6.582,06
8.651,13	7.654,08	8.751,35	8.784,45
2.447,51	2.468,77	2.452,71	2.485,28
10.334,60	10.145,80	10.915,70	10.795,80
3.842,99	3.721,02	3.886,76	3.888,47
3.872,14	3.758,43	3.938,81	3.941,42
46.878,40	45.779,60	49.483,90	48.455,10
8.268,09	7.812,76	8.551,67	8.517,87
51.698,70	49.521,40	54.890,20	53.475,50
35.507,10	33.991,00	38.210,90	37.160,40
1.205,76	1.884,94	1.106,17	1.133,94
4.103,26	3.736,38	4.112,18	4.146,05
30.892,80	33.066,20	35.217,20	33.322,20
41.504,40	40.589,70	44.368,60	43.148,30
1.265,30	1.902,68	1.169,40	1.196,39
37.824,40	38.061,40	40.405,20	39.991,40
46.408,30	46.817,10	50.864,30	49.204,20
35.538,30	35.740,10	38.134,80	37.094,40
48.940,00	47.280,30	52.017,50	50.684,80
54.766,50	53.996,20	59.700,10	57.623,60
1.533,93	1.999,59	1.507,22	1.540,38
14.033,60	12.721,60	14.485,30	14.453,80
6.856,79	6.896,43	7.229,30	7.171,40
6.377,75	6.508,58	6.812,24	6.759,96
6.468,14	6.281,96	6.697,71	6.664,28
10.523,90	10.195,10	11.034,20	10.936,80
9.014,22	8.939,87	9.398,29	9.326,03
7.082,64	6.712,91	7.289,09	7.263,42
26.326,50	26.660,10	29.864,80	28.985,80
6.856,18	6.719,44	7.155,09	7.103,10
19.606,70	19.838,00	20.954,60	20.614,10
7.559,67	7.323,21	7.873,38	7.821,76
6.587,23	6.196,79	6.733,81	6.718,12
2.360,24	2.464,62	2.342,59	2.364,04
5.305,98	5.095,66	5.410,42	5.402,06
34.834,70	35.000,30	36.630,90	35.398,00
6.108,69	5.870,09	6.297,39	6.272,72
10.821,60	10.400,40	11.331,60	11.178,80
2.401,80	2.440,71	2.382,45	2.411,93
3.615,97	3.522,29	3.658,87	3.664,21
10.129,80	10.117,40	10.734,50	10.535,40
6.086,12	5.815,11	6.243,27	6.221,58
35.227,30	33.880,00	37.056,70	36.325,00
14.552,80	13.766,70	15.406,60	15.248,20
7.293,58	7.140,03	7.524,79	7.450,11

43.119,10	42.806,30	47.071,70	45.013,60
61.661,30	60.746,30	66.157,80	63.936,50
3.464,84	3.420,56	3.525,36	3.542,33
6.277,68	6.057,72	6.561,34	6.547,51
11.368,50	11.162,30	11.863,40	11.740,30
1.151,83	1.885,97	1.076,43	1.108,18
3.873,67	3.733,27	3.918,66	3.920,58
57.392,20	56.476,70	61.987,50	59.520,40
57.351,70	56.667,90	62.411,80	60.436,00
44.990,00	44.411,10	47.450,70	46.317,50
37.937,30	37.363,00	39.913,40	39.324,00
1.119,92	1.854,55	1.006,29	1.038,59
34.249,80	33.323,30	36.579,50	35.706,60
6.252,27	6.122,68	6.473,97	6.452,00
9.254,75	9.067,59	9.548,03	9.459,20
57.103,50	56.177,10	61.343,50	59.060,30
8.212,77	8.014,59	8.548,22	8.479,07
3.833,46	3.673,69	3.867,97	3.876,82
3.888,25	3.755,37	3.950,95	3.953,20
6.598,29	6.234,59	6.628,70	6.597,72
45.096,10	44.510,80	48.910,70	47.671,60
11.748,40	11.403,30	12.218,20	12.113,30
2.511,31	2.504,69	2.438,77	2.462,76
39.302,00	38.667,70	41.292,70	40.445,20
11.312,70	11.235,60	11.896,10	11.752,90
9.903,08	9.947,98	10.554,90	10.398,00
38.464,90	38.648,80	40.918,50	40.352,20
2.522,07	2.557,97	2.498,90	2.523,24
8.181,18	7.822,69	8.276,61	8.242,70
44.533,20	43.793,60	47.578,80	46.479,50
21.340,50	21.999,60	23.288,50	22.669,50
7.849,17	7.164,53	7.994,29	8.004,21
6.905,96	7.399,87	7.378,46	7.491,28
47.161,00	46.442,40	51.694,70	49.522,40
47.225,30	46.488,00	51.117,10	49.778,40
6.479,30	6.277,04	6.693,87	6.661,07
37.242,90	38.289,90	40.937,20	38.849,30
4.128,30	3.932,50	4.150,24	4.156,49
3.905,39	3.891,83	4.006,49	4.024,79
1.172,48	1.879,45	1.083,21	1.111,25
12.019,30	11.559,80	12.316,80	12.169,10
3.218,02	3.115,66	3.224,99	3.241,34
63.715,80	64.097,40	70.052,80	67.648,00
40.850,00	38.870,00	42.119,70	41.232,20
36.705,90	35.026,70	37.514,00	36.465,60
9.503,27	9.154,50	9.883,26	9.792,64
14.063,20	12.164,10	14.291,70	14.295,50
6.520,26	6.306,46	6.729,71	6.696,56
7.548,61	7.476,68	7.878,88	7.822,52
6.670,00	6.453,49	6.922,93	6.883,40
9.327,37	8.880,78	9.611,86	9.545,97
8.158,49	7.719,32	8.424,71	8.396,33
3.858,95	3.600,30	3.880,92	3.903,75
3.596,82	3.476,76	3.644,83	3.651,76
3.931,90	3.767,15	3.979,14	3.984,00
18.709,10	18.466,10	19.961,50	19.539,20
9.328,08	8.929,45	9.721,08	9.658,77
11.516,40	10.916,70	11.758,90	11.651,40

6.819,73	6.532,79	6.995,85	6.973,16
48.787,20	47.420,90	51.384,20	50.228,20
3.575,70	3.467,89	3.600,55	3.606,89
49.176,80	47.418,20	51.810,60	50.529,70
7.829,06	7.754,98	8.203,58	8.114,65
39.248,40	38.222,40	41.912,10	40.802,60
7.443,66	7.101,42	7.670,98	7.630,01
7.740,42	7.385,19	8.014,82	7.983,22
7.277,24	6.952,26	7.479,31	7.443,23
57.339,60	55.879,10	62.511,10	60.108,90
6.397,94	6.215,13	6.613,13	6.582,07
5.417,51	5.195,13	5.547,85	5.532,10
7.900,82	7.768,14	8.355,26	8.279,04
9.570,01	9.571,32	10.194,70	10.053,90
4.295,39	4.117,90	4.394,09	4.409,29
8.262,03	8.492,68	8.744,32	8.806,33
9.864,56	9.636,86	10.326,30	10.233,60
8.900,07	8.493,64	9.235,22	9.176,37
19.310,10	19.100,90	20.346,60	20.088,90
8.832,98	8.598,47	9.362,11	9.285,14
11.490,00	11.236,80	11.969,30	11.858,00
3.755,24	3.700,04	3.854,10	3.865,20
44.986,70	44.460,60	48.364,90	46.414,20
10.629,00	9.686,60	10.741,70	10.719,90
5.912,44	5.823,02	6.138,74	6.127,89
8.236,68	7.799,07	8.435,08	8.391,21
21.592,70	21.550,40	23.376,70	22.697,10
5.334,17	5.126,19	5.533,93	5.530,78
12.732,40	13.062,20	13.191,60	13.290,70
3.153,86	3.466,52	3.394,47	3.457,09
6.363,86	6.080,63	6.546,46	6.521,88
12.961,20	11.847,10	13.730,10	13.713,20
6.807,47	6.609,18	7.254,92	7.252,77
45.573,50	45.990,10	50.453,30	48.389,90
58.215,20	56.554,50	63.022,90	60.412,70
9.240,37	9.182,18	9.658,66	9.574,69
7.290,35	7.210,28	7.487,30	7.419,70
6.293,90	6.051,69	6.489,76	6.464,95
43.104,70	42.451,50	45.950,20	44.858,10
8.174,78	8.083,21	8.555,32	8.494,60
16.725,10	16.048,60	17.528,40	17.325,10
4.034,59	3.889,28	4.095,92	4.094,84
4.062,87	3.799,67	4.183,98	4.210,91
34.106,80	33.684,90	37.225,00	36.303,80
8.088,95	7.959,70	8.486,09	8.447,31
20.255,60	19.423,20	21.052,10	20.790,50
1.754,51	2.103,95	1.740,27	1.771,48
17.806,30	17.560,80	18.992,90	18.555,10
6.751,17	6.086,31	6.415,33	6.461,97
1.317,93	1.915,04	1.219,92	1.248,37
6.399,52	6.183,13	6.615,24	6.579,60
37.714,50	38.126,20	40.523,20	39.968,80
8.801,60	8.531,12	9.094,07	9.016,33
20.554,90	19.152,60	21.188,30	20.657,00
7.738,85	7.476,70	8.039,46	8.014,59
9.240,34	8.989,61	9.659,75	9.585,76
8.829,54	8.898,14	9.372,42	9.239,04
56.008,80	55.309,50	62.329,30	59.072,10

36.177,50	36.348,80	40.306,60	38.847,00
19.121,50	18.442,50	20.224,20	19.826,90
6.732,83	6.692,47	7.159,82	7.151,48
9.666,85	9.378,05	10.069,30	10.005,20
6.509,22	6.273,02	6.728,07	6.700,84
20.831,30	20.641,20	22.346,40	21.825,40
61.026,00	60.554,20	66.757,80	64.562,30
37.991,90	37.858,00	41.016,00	40.067,00
6.772,87	6.659,42	7.088,18	7.085,11
10.438,40	10.210,60	10.871,60	10.746,90
8.040,01	7.978,42	8.448,87	8.390,97
58.019,90	55.877,00	62.745,00	60.273,10
5.309,26	5.122,06	5.457,73	5.439,86
10.010,20	10.310,30	10.734,30	10.649,50
19.768,10	20.055,50	21.343,20	20.862,90
7.211,34	7.079,20	7.611,85	7.572,31
10.766,50	10.548,80	11.184,70	11.074,30
4.099,95	3.739,69	3.911,75	3.944,16
3.778,64	3.753,29	3.881,46	3.894,08
10.917,30	10.765,90	11.298,90	11.351,40
43.019,80	43.355,80	48.283,00	46.570,20
7.149,25	7.022,96	7.506,71	7.479,48
4.149,94	3.941,94	4.275,26	4.284,96
11.014,00	10.605,90	11.398,80	11.277,20
3.630,27	3.488,78	3.649,11	3.655,82
62.220,30	60.433,90	67.526,70	65.164,40
10.080,10	9.529,44	10.399,10	10.340,30
9.545,09	9.223,53	9.794,15	9.722,10
48.876,80	47.895,80	52.101,30	50.931,80
7.133,15	7.032,35	7.414,54	7.346,49
41.752,90	41.105,10	44.801,60	43.371,90
9.187,07	9.034,88	9.620,39	9.512,14
53.954,40	50.526,10	57.959,30	55.737,10
10.576,20	10.469,90	11.152,10	11.128,60
34.580,40	33.241,30	36.383,10	35.544,70
8.745,15	8.863,16	9.309,48	9.081,53
9.118,12	8.892,03	9.482,87	9.412,41
19.436,30	19.325,20	20.509,60	20.220,50
9.164,07	9.027,19	9.544,12	9.463,00
31.708,50	33.221,70	35.247,40	34.514,60
20.172,40	21.555,70	22.807,20	21.950,50
29.130,00	28.477,70	31.614,50	29.757,20
6.387,92	6.166,44	6.567,17	6.533,46
34.698,30	33.542,50	36.561,20	35.899,70
10.604,40	10.537,30	11.090,10	10.981,20
10.374,90	10.055,20	10.938,50	10.856,90
3.881,08	3.724,95	3.924,90	3.929,44
8.791,64	8.838,61	9.301,53	9.216,54
46.511,50	46.021,10	52.417,30	48.902,40
8.596,11	8.346,55	8.940,19	8.848,81
9.191,27	8.465,17	9.183,49	9.215,30
10.917,00	10.755,20	11.469,40	11.313,40
50.482,40	54.301,30	57.211,50	55.894,90
8.775,60	8.558,16	9.242,94	9.152,47
17.076,80	16.792,20	18.099,30	17.616,80
10.719,80	10.285,80	11.405,10	11.356,80
10.702,50	10.655,50	11.349,50	11.237,70
6.239,84	6.125,40	6.397,39	6.344,98

10.890,30	10.275,00	11.223,70	11.156,80
39.976,20	39.898,50	43.102,80	41.968,10
3.883,17	3.568,47	3.908,23	3.936,51
11.139,60	10.322,80	10.641,50	10.713,20
11.865,40	11.654,70	12.524,40	12.366,50
1.175,65	1.879,46	1.073,64	1.101,54
3.689,71	3.570,45	3.741,61	3.750,73
1.596,72	2.020,02	1.501,36	1.527,24
9.219,01	9.053,21	9.635,93	9.535,49
10.118,40	9.891,66	10.610,20	10.521,20
9.807,41	9.530,30	10.143,20	10.045,30
11.742,90	11.565,30	12.368,30	12.173,70
8.391,61	8.334,06	8.782,45	8.700,34
36.178,20	36.354,90	40.480,80	38.575,50
58.693,90	57.155,60	63.823,70	61.317,60
22.882,20	22.948,90	24.916,40	24.042,50
8.347,20	8.096,81	8.637,95	8.571,86
2.679,51	2.592,98	2.625,37	2.653,31
41.653,60	38.174,10	43.841,00	42.674,00
6.736,04	6.437,01	6.926,35	6.894,50
54.600,00	53.657,20	59.836,30	57.326,10
1.046,40	1.834,63	923.997,00	957,78
1.209,93	1.889,46	1.112,59	1.139,33
48.523,80	49.081,90	54.536,80	51.854,50
19.533,00	19.705,30	20.933,90	20.432,80
6.420,37	6.196,45	6.608,95	6.574,06
24.146,60	24.243,80	26.269,90	25.709,60
7.317,18	6.945,56	7.516,89	7.498,29
19.449,60	19.551,70	21.247,50	20.653,20
49.223,90	48.006,50	52.321,20	51.026,50
55.723,90	57.241,20	63.723,80	60.352,00
10.764,70	10.393,50	11.364,30	11.282,10
46.882,00	49.007,10	49.172,90	48.886,00
30.366,00	29.383,70	31.882,00	31.396,00
40.169,20	39.478,40	43.310,80	42.033,20
3.928,40	3.806,52	3.996,20	4.009,95
8.894,86	8.877,88	9.455,87	9.437,04
33.867,50	33.923,40	36.953,60	36.064,00
9.386,11	9.162,71	9.824,53	9.720,15
46.304,90	46.556,70	50.852,80	49.398,30
9.518,90	9.231,21	9.845,27	9.761,15
56.484,50	56.092,30	61.708,60	59.290,00
973,31	1.848,78	900,18	937,70
39.419,50	39.218,50	42.386,70	41.318,60
6.718,70	6.355,14	6.865,07	6.837,82
8.269,03	7.842,24	8.342,76	8.305,60
9.845,46	9.165,03	10.146,50	10.093,00
46.888,20	46.670,40	51.392,80	49.923,60
37.303,80	35.428,40	39.045,80	37.853,20
1.183,19	1.880,45	1.085,57	1.112,94
7.279,16	6.840,90	7.461,52	7.450,35
7.245,99	7.156,89	7.567,71	7.506,34
55.861,90	54.774,60	60.250,50	58.129,40
10.427,90	10.558,30	11.104,40	10.960,70
7.360,99	7.047,69	7.610,28	7.570,76
19.834,80	19.784,80	21.027,30	20.632,10
7.828,22	7.722,08	8.204,28	8.175,49
64.315,40	63.097,00	68.120,70	66.461,50

8.134,77	7.955,41	8.437,26	8.357,54
21.163,40	20.955,00	22.594,20	22.129,80
7.078,96	7.006,75	7.360,91	7.318,41
29.114,10	29.681,90	31.361,00	30.850,50
6.284,59	6.053,39	6.483,67	6.452,11
61.238,60	60.039,10	66.409,90	63.858,10
55.002,80	51.968,80	59.157,30	56.912,30
54.759,50	52.500,70	59.074,10	56.684,80
2.557,05	2.541,06	2.487,91	2.514,55
8.772,48	8.618,82	9.162,95	9.043,04
8.591,00	8.235,97	8.869,48	8.813,88
20.123,60	19.845,50	21.344,30	20.909,50
3.592,90	3.488,88	3.637,26	3.643,32
7.505,89	7.326,13	7.813,40	7.773,45
3.902,81	3.781,56	3.951,58	3.952,06
1.142,26	1.866,65	1.040,97	1.071,87
23.311,80	23.665,70	25.414,60	24.886,20
1.422,50	1.942,36	1.330,45	1.362,08
2.711,93	2.702,07	2.700,91	2.719,87
16.599,70	16.457,60	17.537,90	17.399,60
15.280,20	15.088,40	16.148,50	15.856,00
6.837,42	6.669,15	7.016,96	6.942,26
1.741,64	2.103,74	1.669,36	1.697,73
61.526,30	58.287,70	66.820,70	64.285,00
6.359,15	6.074,51	6.493,26	6.467,22
6.599,43	6.367,27	6.766,94	6.735,88
19.035,30	19.124,40	20.186,70	19.875,70
10.353,50	10.100,10	10.810,30	10.704,30
6.127,56	5.731,94	6.253,24	6.250,42
60.860,90	60.584,20	67.096,90	63.930,00
11.892,70	11.646,20	12.378,30	12.221,00
7.454,69	6.965,29	7.673,83	7.663,21
3.653,19	3.544,37	3.687,45	3.692,10
55.653,20	55.315,20	61.764,20	58.485,60
8.032,09	7.951,59	8.412,41	8.378,51
9.864,06	9.443,76	10.335,50	10.252,90
7.962,76	7.724,22	8.191,57	8.127,30
10.273,80	9.594,73	10.585,50	10.612,60
9.413,41	9.004,56	9.763,08	9.694,22
56.369,50	56.721,40	60.668,50	59.418,50
19.393,60	19.773,90	20.785,50	20.396,50
7.240,62	7.128,85	7.570,09	7.514,55
43.780,20	43.737,80	47.682,10	46.214,00
30.452,60	29.837,40	32.319,00	31.672,00
47.313,60	46.751,60	50.722,40	49.169,60
1.200,85	1.887,22	1.102,87	1.129,64
3.595,15	3.490,53	3.667,98	3.675,19
65.255,00	63.290,10	69.164,80	67.385,20
1.232,13	1.892,82	1.126,32	1.154,13
6.992,04	6.964,60	7.487,27	7.452,23
6.595,64	6.349,96	6.792,40	6.759,46
14.133,00	13.733,10	14.642,70	14.419,70
9.072,77	8.909,20	9.369,63	9.301,45
8.155,66	7.966,59	8.435,66	8.369,88
8.195,28	7.869,55	8.457,21	8.397,52
18.325,10	18.660,40	19.689,70	19.384,30
9.686,12	9.438,81	10.095,00	10.005,00
58.755,60	57.885,10	64.452,80	61.395,00

64.471,00	63.010,70	68.965,00	66.994,40
2.366,40	2.513,88	2.354,20	2.384,38
7.349,79	7.185,94	7.711,61	7.676,00
49.270,60	46.872,30	52.470,90	50.992,70
37.660,50	37.932,60	40.537,30	39.701,90
8.556,95	8.337,49	8.889,14	8.809,12
55.917,90	54.236,30	60.228,20	58.012,10
3.577,37	3.476,39	3.626,43	3.631,70
7.744,86	7.678,90	8.145,94	8.083,64
43.529,70	44.847,20	48.446,60	46.533,10
1.275,14	1.904,29	1.180,15	1.208,23
10.914,70	10.792,80	11.402,50	11.256,80
57.687,50	57.750,00	64.349,50	61.361,00
7.061,62	6.661,54	7.267,57	7.247,81
9.652,63	9.379,77	10.018,20	9.902,83
1.167,81	1.879,33	1.080,63	1.109,31

