

Analiza kriptovaluta

Radić, Marinko

Undergraduate thesis / Završni rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of Science / Sveučilište u Splitu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:166:774085>

Rights / Prava: [Attribution 4.0 International](#)/[Imenovanje 4.0 međunarodna](#)

Download date / Datum preuzimanja: **2024-11-27**

Repository / Repozitorij:

[Repository of Faculty of Science](#)



SVEUČILIŠTE U SPLITU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
ODJEL ZA INFORMATIKU

ANALIZA KRIPTOVALUTA

ZAVRŠNI RAD

Marinko Radić

Split, rujan 2023.

Temeljna dokumentacijska kartica

Završni rad

Sveučilište u Splitu

Prirodoslovno-matematički fakultet

Odjel za informatiku

Ruđera Boškovića 33, 21000 Split, Hrvatska

ANALIZA KRIPTOVALUTA

Marinko Radić

SAŽETAK

Kriptovalute su posljednja novost u razvoju novca koga ne emitira i regulira nijedna središnja banka ni institucija te nemaju pokriće u zlatu ili srebru već se zasnivaju na matematici i algoritmima, a smatra se rizičnim ulaganjem čija cijena ovisi o dobroj tehnologiji i sigurnosti koja stoji iza te kriptovalute. Ulagачe u kriptovalute zanima je moguće na temelju povijesnih podataka kretanja tečaja kriptovalute predvidjeti cijenu u budućnosti pri čemu se koriste razne tehnike uključujući LSTM algoritam koji je korišten u ovom projektu. Za izradu projekta korišten je dataset koji sadrži povijesne podatke cijene Bitcoina u američkim dolarima od 2010. do 2019. godine, a ima za cilj stvoriti model koji će predvidjeti cijenu Bitcoina u USD-u na temelju tih povijesnih podataka. Da bi se utvrdila preciznost predviđanja modela uspoređujemo predviđene cijene s stvarnim cijenama iz dataseta.

Ključne riječi: Kriptovalute, strojno učenje, LSTM, tehnička analiza, sentiment tržišta, google collab.

Rad je pohranjen u knjižnici Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

Rad sadrži: 31 stranica, 5 grafičkih prikaza, 0 tablica i 15 literaturnih navoda.

Izvornik je na hrvatskom jeziku.

Mentor: Dr.sc. Saša Mladenović, redoviti profesor Prirodoslovno-matematičkog fakulteta,

Ocjenjivači:

Dr.sc. Saša Mladenović, redoviti profesor Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

Dino Nejašmić, predavač Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

Ivana Marin, predavač Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

Rad prihvaćen: Rujan, 2023.

Basic documentation card

Thesis

University of Split
Faculty of Science
Department of Computer Science
Ruđera Boškovića 33, 21000 Split, Croatia

CRYPTOCURRENCY ANALYSIS

Marinko Radić

ABSTRACT

Cryptocurrencies are the latest innovation in the development of money that is not issued and regulated by any central bank or institution and is not backed by gold or silver, but is based on mathematics and algorithms, and is considered a risky investment whose price depends on the good technology and security behind that cryptocurrency. Investors in cryptocurrencies are interested in the possibility of predicting the price in the future based on the historical data of the cryptocurrency exchange rate, using various techniques including the LSTM algorithm that was used in this project. The project used a dataset containing historical Bitcoin price data in US dollars from 2010 to 2019, and aims to create a model that will predict the Bitcoin price in USD based on this historical data. To determine the precision of the model's predictions, we compare the predicted prices with the actual prices from the dataset.

Key Words: Cryptocurrencies, machine learning, LSTM, technical analysis, market sentiment, google collab.

Thesis deposited in library of Faculty of science, University of Split.

Thesis consist of: 31 pages, 5 figures, 0 tables and 15 references

Original language: Croatian

Supervisor: **Saša Mladenović, Ph.D.** Regular Professor of Faculty of Science, University of Split,

Reviewers: **Saša Mladenović, Ph.D.** Regular Professor of Faculty of Science, University of Split,

Dino Nejašmić, Lecturer of Faculty of Science, University of Split,

Ivana Marin, Lecturer of Faculty of Science, University of Split

Thesis accepted: September, 2023.

IZJAVA

kojom izjavljujem s punom materijalnom i moralnom odgovornošću da sam završni rad s naslovom Analiza kriptovaluta izradio samostalno pod voditeljstvom Dr.sc. Saše Mladenovića. U radu sam primijenio/la metodologiju znanstvenoistraživačkog rada i koristio/la literaturu koja je navedena na kraju diplomskog rada. Tuđe spoznaje, stavove, zaključke, teorije i zakonitosti koje sam izravno ili parafrazirajući naveo/la u diplomskom radu na uobičajen, standardan način citirao/la sam i povezo/la s fusnotama s korištenim bibliografskim jedinicama. Rad je pisan u duhu hrvatskog jezika.

Student/ica

Marinko Radić

Sadržaj

1. UVOD.....	1
1.1. Motivacija.....	2
1.2. Cilj.....	2
2. TEHNIKE PREDVIĐANJA CIJENA.....	3
2.1. Specifičnosti predviđanja cijena valuta	6
2.2. Specifičnost kriptovaluta	8
2.3. Alati i aplikacije za analizu kriptovaluta	9
2.4. Modeli za predviđanje cijena	10
3. ODABIR PLATFORME ZA EKSPERIMENT (TEHNOLOGIJSKE PLATFORME)....	11
3.1. Prednosti korištenja Google Collab-a.....	11
3.2. Nedostaci korištenja Google Collab-a.....	12
4. PROJEKT- IZRADA PROTOTIPA	13
5. ZAKLJUČAK	22
LITERATURA	23
POPIS GRAFIČKIH PRIKAZA I TABLICA.....	25

1. UVOD

Čovječanstvo je u svom povijesnom razdoblju koristilo razne oblike novca. Na prijelazu iz prvobitne zajednice u robovlasništvo s pojavom prvih viškova roba javlja se robni ili prirodni novac pri čemu se međusobno razmjenjuju (trampe) različite robe. S otkrićem metala dolazi do prvog kovanog novca od plemenitih (zlato, srebro) i drugih metala (bakra, nikla i cinka) te njihovim slitina. U početku je to penzatorni kovani novac koji nije bio standardiziran pa se prilikom svake uporabe trebao mjeriti i provjeravati njegov sastav. U sljedećoj fazi razvoja kovanog novca, vladari udaraju svoj žig na kovanice čime jamče standardiziranost kovanog novca. Krajem XVIII. stoljeća javlja se prvi papirnati novac koji emitiraju državne središnje banke, a ima pokriće u zlatu i srebru. U toj fazi je moguća konverzija novca za pripadajuću količinu zlata ili srebra. Izdavanjem novčanica bez pokrića dolazi do inflacije i pada vrijednosti emitiranog novca. Današnji fiducijalni (fiat) novac nema pokriće u plemenitim metalima te počiva na povjerenju. U suvremenom svijetu gotovo 90 % transakcija se ne obavlja novčanicama i kovanicama već bezgotovinski s računa na račun depozitnim novcem (novcem građana i poslovnim subjekata na računima u bankama) koji ne postoji u fizičkom obliku, ali se mora uredno knjižiti kako bi novčani sustav bio stabilan.

Kriptovalute su posljednja novost u razvoju novca koga ne emitira i regulira nijedna središnja banka ni institucija. Kriptovalute su digitalni ekvivalenti fizičkom novcu te nemaju pokriće u zlatu ili srebru već se zasnivaju na matematici i algoritmima. U početku su se trgovanjem kriptovalutama bavili pojedinci, a danas sve veći postotak populacije upušta u rudarenje kriptovaluta koje ima mnoge sličnosti trgovanju dionicama. Cijene dionica ovise o poslovanju tvrtke čija je dionica kupljena, dok je kod kriptovaluta mogućnost promjene cijene veća te je moguće ostvariti puno veći dobitak ili gubitak u kratkom vremenskom periodu te se smatra rizičnijim ulaganjem.

Za svaku jedinstvenu kriptovalu upravljanje se distribuira među onima koji se bave rastom i održavanjem njegove tehnologije. Cijena kriptovalute ovisi o dobroj tehnologiji i sigurnosti koja stoji iza te kriptovalute.

Ulagачe u kriptovalute zanima je moguće na temelju povijesnih podataka kretanja tečaja kriptovalute predvidjeti cijenu u budućnosti pri čemu se koriste razne tehnike uključujući LSTM algoritam koji je korišten u ovom projektu.

1.1. Motivacija

Živimo u turbulentnom vremenima uzrokovanim krizama, epidemijama i ratovima. suočavamo se problemima sigurnosti i isplativosti raznih oblika ulaganja u budućnosti što ovisi o mnogim čimbenicima. Činjenica je da ništa nije sigurno od trgovanja dionicama, obveznicama, valutama i bilo kojim robama. Kako iza nijedne službene valute ne stoji pokriće u zlatu i srebru već povjerenje u njenu vrijednost koje središnja banka može izigrati prekomjernom emisijom novca bez pokrića, smatram da bi na temelju toga vrijedila ista pravila i za kriptovalute. Dapače, za razliku od standardnih valuta koje vlade mogu prekomjerno emitirati da bi zadovoljile apetite svojih birača, kreatori virtualnih valuta nemaju taj problem. Iako se radi o vrlo rizičnom ulaganju s daleko većim oscilacijama cijena kriptovaluta, zanimalo me je li moguće tehnikama strojnog učenja predvidjeti kretanje cijena kriptovaluta u budućnosti.

1.2. Cilj

Cilj je odabrati primjerenu metodu strojnog učenja koja će u zadovoljavajućoj mjeri predvidjeti kretanje cijena kriptovaluta. To je vrlo izazovno jer su cijene kriptovaluta vrlo nestabilne i podložne utjecaju raznih čimbenika kao što su vijesti iz svijeta, sentiment tržišta te ekonomski pokazatelji. Izuzetno je važno odabrati metodu strojnog učenja koja može efikasno obraditi velike količine povijesnih podataka i prepoznati uzorke i trendove. Odabrao sam tehniku LSTM strojnog učenja koju smatram dobrim izborom za predviđanje cijena kriptovaluta, zbog njezine sposobnosti obrade vremenskih serija podataka, dugoročnog pamćenja uzoraka i prilagodljivost. LSTM može analizirati prošle podatke o cijenama, prepoznati obrasce i koristiti ih za predviđanje budućih kretanja uzimajući u obzir tržišne vijesti i sentiment tržišta.

2. TEHNIKE PREDVIĐANJA CIJENA

Različite tehnike se primjenjuju za predviđanje cijena, a izbor ovisi o vrsti cijena o kojoj je riječ. U nastavku primjeri metoda koje se koriste za predviđanje cijena.

Algoritmi strojnog učenja: Strojno učenje (ML) je grana umjetne inteligencije gdje algoritmi “uče” informacije i odnose među njima. Modeli strojnog učenja povećavaju svoju točnost porastom broja uzoraka. To znači da što više podataka imamo, to će model biti bolji u predviđanju novih podataka. Glavni zadatak strojnog učenja je razviti algoritme i modele koji omogućuju strojevima da uče iz podataka i unaprjeđuju njihovu izvedbu na zadanom zadatku. Primjeri algoritama strojnog učenja koji se često koriste za predviđanje cijena su algoritam linearne regresije, algoritam slučajne šume i Long Short-Term Memory algoritam.

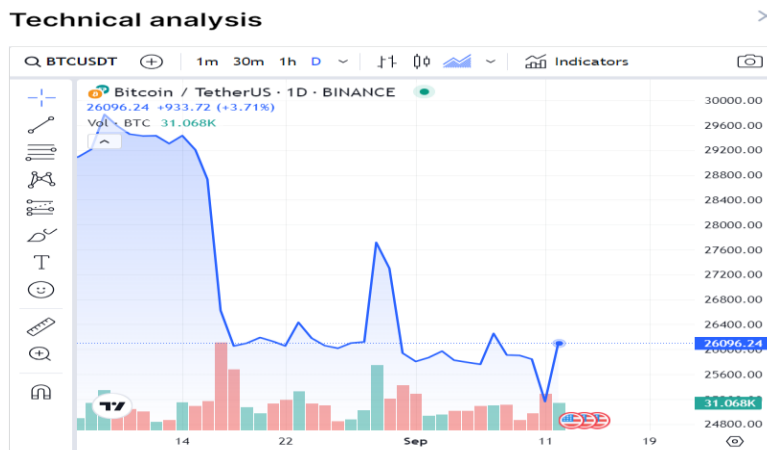
Linearna regresija je jednostavan algoritam koji modelira linearnu vezu između nezavisnih varijabli i ciljne varijable. Koristi se za predviđanje kontinuiranih vrijednosti, poput cijena nekretnina ili dionica. (Bolf, 2021)

Algoritam slučajnih šuma je da generira nekoliko stabala odluke iz nasumično odabranih podskupova podataka. Svako stablo se sastoji od čvorova koji određuju određeni broj varijabli koje se koriste za predviđanje. Za binarnu podjelu u tom čvoru koristi se prediktivna varijabla koja postiže najbolju separaciju podataka, što se mjeri putem određenih objektivnih funkcija.

LSTM mreže su posebna vrsta rekurentnih neuronskih mreža (RNN) stvorena da se uhvate u koštac s problemom nestanka gradijenta u tradicionalnim RNN-ovima. Njihova glavna prednost je sposobnost bolje obrade vremenskih serija, kao što su povijesni podaci o cijenama dionica, kretanja tržišta i valuta. LSTM mreže imaju sposobnost dugoročnog pamćenja i predviđanja, što ih čini korisnim alatom za predviđanje cijena na temelju sekvencijalnih podataka. (Zaytar & El Amrani, 2016)

Tehnička analiza: Tehnička analiza je metoda koja se koristi za predviđanje cijena temeljena na analizi povijesnih podataka o kretanju cijena i tržišnim trendovima. Ova metoda se često koristi u financijskom svijetu za predviđanje kretanja cijena dionica, valuta, roba i drugih financijskih instrumenata. Tehnička analiza uključuje upotrebu različitih alata i pokazatelja, kao što su grafikoni, indikatori, obrasci te podrška i otpor. Grafikoni se koriste za vizualizaciju povijesnih podataka o cijenama u nekom vremenu dok se indikatori koriste za analizu uzoraka i trendova kretanja cijene na tom grafikonu kako bi se donijele ispravne

odluke o kupnji ili prodaji. Najpoznatije vrste grafikona su linijski grafikon, stupčasti grafikon te grafikon s japanskim svijećama. Tehnička analiza prepoznaje različite obrasce koji se javljaju u kretanju cijena. Obrasci, poput trokuta, zastave, glava i ramena, mogu ukazivati na buduće promjene u cijenama. Analitičari koriste ove obrasce kako bi predvidjeli buduće kretanje cijena. (<https://financijskiimpuls.org/2017/01/15/tehnicka-analiza-analiza-kretanja-cijena-financijskih-instrumenata/>)



Slika 1. Linijski grafikon



Slika 2. Stupčasti grafikon



Slika 3. Grafikon s japanskim svijećama

Razine podrške i otpora ključni su pojmovi u tehničkoj analizi koji se koriste za određivanje smjera kretanja cijene vrijednosnog papira. To su razine na grafikonu cijena gdje se susreću ponuda i potražnja. Razina podrške je mjesto na grafikonu gdje cijena uglavnom prestaje padati. Što više puta cijena dođe do razine podrške i prestane padati to će razina podrške biti jača. Razina otpora je mjesto na grafikonu gdje cijena uglavnom prestaje rasti i pada natrag. Kada se probiju razine podrške i otpora, vjerojatno će se uspostaviti nove razine podrške i otpora. (https://www.agrambrokeri.hr/UserDocsImages/Arhiva/UserDocsImages/publikacije/Uvod_u_tehnicku_analizu.pdf)

Duboko učenje: Duboko učenje je dio strojnog učenja koje uključuje korištenje neuronskih mreža za analizu velikih količina podataka kako bi se predvidjele buduće cijene. (<https://www.fer.unizg.hr/predmet/dubuce>). Duboko učenje zahtijeva velike količine podataka na skupu za treniranje, ali može dati odlične rezultate.

Statističke metode: Ova metoda koristi statističke modele za analizu povijesnih podataka o cijenama kako bi se predvidjele buduće cijene. Ovo su najčešće metode koje se koriste za predviđanje cijena:

1. Metode regresije su statističke metode koje se koriste za predviđanje vrijednosti cijena nekretnina ili dionica. Ove metode pronalaze matematički model koji najbolje odgovara podacima i koriste ga za predviđanje budućih vrijednosti
2. Analiza vremenskih serija je statistička metoda koja se često koristi za predviđanje cijena, kretanja tržišta i drugih financijskih vrijednosti. Analiza vremenskih serija uključuje različite tehnike, poput ARIMA i GARCH modela.

3. Klaster metoda je statistička metoda koja se može primijeniti na podatke o cijenama kako bi se identificirali slični obrasci i trendovi. Klaster analiza može pomoći u identificiranju skupina vrijednosnih papira koji se ponašaju slično i mogu imati slične cijene u budućnosti
 4. Analiza korelacije je statistička metoda koja se koristi kako bi se identificirale veze između različitih varijabli iz skupa podataka. Postoji pozitivna korelacija, negativna korelacija i nulta korelacija. Pozitivna korelacija znači da kad jedna varijabla raste da i druga raste. Negativna korelacija je kad jedna varijabla raste da druga pada. Nulta korelacija znaci da nije utvrđena neka specifična veza između dvije varijable.
- Ukratko, postoji mnogo metoda koje se koriste za predviđanje cijena, a odabir odgovarajuće metode ovisi o vrsti cijena i drugim čimbenicima. (Čičin-Šain, 2007)

2.1. Specifičnosti predviđanja cijena valuta

Predviđanje cijena valuta složen je zadatak koji uključuje analizu brojnih čimbenika, uključujući ekonomske pokazatelje, političke događaje, sentiment tržišta i tehničku analizu. Razvijene su različite metode i modeli za predviđanje kretanja tečaja, ali niti jedan pristup ne jamči točnost. Neki od specifičnosti predviđanja cijena valuta uključuju:

Ekonomске pokazatelje: Najvažniji ekonomski pokazatelji za predviđanje cijena valuta su inflacija, razina zaposlenosti CPI. Visok CPI ukazuje da cijene proizvoda rastu, što može dovesti do inflacije, a inflacija može uzrokovati pad vrijednosti valute neke zemlje. Visoka razina zaposlenosti može dovesti do povećanja potrošnje što može dovesti do gospodarskog rasta a time i povećati potražnju za valutom te zemlje

Politika: Odluke centralnih banaka, kao što su promjene kamatnih stopa mogu utjecati na vrijednost valuta. Tako na primjer, podizanje kamatnih stopa može privući strane investitore i pojačati interes za valutu, što može ojačati njezinu vrijednost, dok spuštanje kamatnih stopa može umanjiti atraktivnost valute i uzrokovati njezino slabljenje. Politika trgovine, na primjer, uvođenje visokih tarifa na uvoz može smanjiti izvoz i potražnju za valutom te rezultirati slabljenjem valute. S druge strane, sklapanje trgovinskih sporazuma može povećati izvoz i potražnju za valutom, što može rezultirati jačanjem valute. (Vlada Republike Hrvatske, 2019)

Fiskalna politika, na primjer, smanjenje poreza može potaknuti potrošnju i gospodarski rast, što može rezultirati jačanjem valute. S druge strane, povećanje javne potrošnje može povećati javni dug i potencijalno rezultirati slabljenjem valute (Vizjak, 2000). Geopolitički događaji, poput političkih sukoba i promjena vlasti, također mogu utjecati na vrijednost valuta. Politički sukobi mogu smanjiti povjerenje investitora te bi to rezultiralo slabljenjem valute. S druge strane, politička stabilnost i povoljni geopolitički uvjeti mogu povećati povjerenje investitora i jačanje valute.

Sentiment tržišta: Tržišni sentiment odnosi se na opći stav koji ulagači osjećaju prema tržištu. Rastuće cijene ukazuju na pozitivno raspoloženje na tržištu, dok pad cijena ukazuje na padajuće raspoloženje. Najpoznatiji indeks za mjerenje sentimenta tržišta je indeks straha i pohlepe (Fear & Greed Indeks).

Tehnička analiza: Tehnička analiza je metoda predviđanja cijene valuta u budućnosti pomoću povijesnih podataka o cijenama oslanjajući se na različite vrste grafova i indikatora. Ovaj pristup pretpostavlja da se sve relevantne informacije već odražavaju na cijenu valute i da se povijesni obrasci cijena često ponavljaju tijekom vremena. Tehnički analitičari koriste različite alate i tehnike za izradu grafikona kako bi identificirali trendove, razine podrške i otpora te potencijalne točke preokreta u kretanju cijena valute. Jedna od glavnih prednosti tehničke analize je njezina relativna jednostavnost uspoređujući je s drugim metodama, kao što su ekonometrijski modeli, koji često zahtijevaju složene izračune i duboko razumijevanje ekonomske teorije. Međutim, tehnička analiza je kritizirana zbog svoje subjektivne prirode i oslanjanja na vizualnu interpretaciju, što može dovesti do nedosljednih rezultata i različitih zaključaka među praktičarima.

Korelacije valuta: Valutne korelacije su statistička mjera mjere u kojoj su valutni parovi povezani u vrijednosti i u kojoj će se kretati zajedno. Postoji pozitivna korelacija, negativna korelacija i nulta korelacija. Pozitivna korelacija je kad jedna varijabla raste da i druga raste. Negativna korelacija je kad jedna varijabla raste da druga pada dok Nulta korelacija znači da nije utvrđena neka specifična veza između dvije varijable

Sveukupno, predviđanje cijena valuta zahtijeva duboko razumijevanje čimbenika koji mogu utjecati na njihovu vrijednost, kao i sposobnost analiziranja složenih podataka. Analitičari koriste različite alate i tehnike za donošenje informiranih predviđanja o cijenama valuta i donošenje profitabilnih trgovačkih odluka na tržištu.

2.2. Specifičnost kriptovaluta

Kriptovaluta je vrsta digitalnog novca. Kriptovalute imaju neke specifične karakteristike koje ih razlikuju od tradicionalnih valuta i financijske imovine.

Neke od specifičnosti kriptovaluta su:

1. **Decentralizacija:** To je glavna značajka kriptovaluta, a to znači da ih ne kontrolira niti jedno središnje tijelo ili vlada, već se transakcije između korisnika obavljaju direktno i bez posrednika.
2. **Nepromjenjivost:** Transakcije potvrđene blockchain tehnologijom su nepromjenjive, što znači da se ne mogu mijenjati. To sprječava hakere da proizvedu lažne zapise o transakcijama i uspostavlja povjerenje među korisnicima.
3. **Visoka volatilnost:** Vrijednosti nekih kriptovaluta iznimno su promjenjive. Zbog velike volatilnosti vrlo je nepraktično koristiti kriptovalute kao svakodnevno sredstvo plaćanja jer cijene kriptovaluta nisu stabilne. Osim toga, neke kriptovalute ograničene su količini koja se može proizvesti, što ih čini različitima od klasičnog fiat novca koji se može tiskati u neograničenim količinama.

Razlike između kriptovaluta i klasičnog (fiat) novca:

Fiat novac:

- Izdaje ga vlada i podržan je povjerenjem u vladu koja ga izdaje.
- Nije ograničen u količini koja se može tiskati.
- Transakcije se obavljaju putem posrednika, poput banaka.
- Vrijednost se može mijenjati ovisno o političkim i ekonomskim uvjetima u zemlji koja ga izdaje.

Kriptovalute:

- Izdaju se decentralizirano i ne kontroliraju ih centralne institucije.
- Ograničene su u količini koja se može proizvesti.
- Transakcije se obavljaju direktno između korisnika bez posrednika.
- Vrijednost se može mijenjati ovisno o ponudi i potražnji na tržištu kriptovaluta.

(Kozarević & Ibrić, 2021)

Bitcoin je prva moderna kriptovaluta pokrenuta 2009. Godine i još uvijek se njome najčešće trguje. Temelji se na blockchain tehnologiji koja eliminira potrebu za tradicionalnim posrednicima, poput banaka, kada se sredstva prenose između dva subjekta. Kriptovalute se koriste kao alternativni način plaćanja ili kao investicija. Nakon Bitcoina, na tržištu se pojavilo puno drugih kriptovaluta, najpoznatiji među njima su Ethereum, Litecoin i Ripple (<https://kriptomat.io/hr/kriptovalute/vrste-kriptovaluta/>).

2.3. Alati i aplikacije za analizu kriptovaluta

Postoje mobilne aplikacije koje omogućuju pregled tržišta kriptovaluta, pregled cijena i grafikona, te obavještavanje o promjenama cijena. Također, postoje i web stranice koje pružaju informacije o kriptovalutama. CoinMarketCap je najpoznatiji izvor informacija o kriptovalutama, koja pruža informacije o cijenama kriptovaluta, tržišnim kapitalizacijama, volumenu trgovanja i druge podatke vezane uz tržište kriptovaluta. Platforma često sadrži članke i ažuriranja vezana uz kriptovalute kako bi korisnici u svakom trenutku bili informirani o najnovijim događanjima iz kripto svijeta. CoinMarketCap također nudi grafove na koje možemo dodati različite indikatore koji bi mogli pomoći trgovcima i investitorima da naprave bolju analizu. S ovom aplikacijom u svakome trenutku možemo vidjeti trenutačnu cijenu, te cijenu u odnosu na neku drugu valutu. CoinMarketCap nam omogućuje stvaranje vlastitog portfelja kriptovaluta. To znači da korisnici mogu pratiti svoja ulaganja u različite kriptovalute na jednom mjestu. Jedna od najpoznatijih web stranica koja se koristi za praćenje financijskog tržišta je Investing.com. Osim web stranice, Investing.com također nudi mobilnu aplikaciju koja se može instalirati na pametne telefone. Investing.com nam pruža najnovije vijesti iz svijeta financija kako bi korisnici uvijek bili informirani. Investing.com pruža korisnicima da u svakom trenutku mogu pristupiti trenutnim cijenama različitih financijskih

instrumenata u stvarnom vremenu. Za analizu kriptovaluta se također koriste i različiti alati za tehničku analizu, najpoznatiji od njih je TradingView. TradingView nam omogućuje pregled grafikona, analizu trendova, te identificiranje potencijalnih prilika za ulaganje (<https://www.bug.hr/mobilne-aplikacije/mobilne-aplikacije-za-rad-s-kriptovalutama-18805>).

Postoje i alati koji koriste AI tehnologiju za otkrivanje trendova i analizu raspoloženja tržišta kriptovaluta. Ovi alati prikupljaju podatke iz kripto razgovora i pružaju korisne informacije o tržištu. (<https://portalcripto.com.br/hr/najbolji-kripto-alati/>)

2.4. Modeli za predviđanje cijena

Za prognoziranje cijena koriste se različiti modeli koji se primjenjuju u različitim područjima pa tako i za predviđanje kretanja cijena kriptovaluta kao što su:

- Statistički modeli temelje na statističkim metodama i koriste se za predviđanje cijena na temelju povijesnih podataka. Neki od statističkih modela koji se koriste za predviđanje cijena su Jednostavna linearna regresija, Višestruka linearna regresija, ARIMA model i Stohastički modeli.
- Duboko učenje: Neke popularne tehnike dubokog učenja koriste se za predviđanje cijena dionica uključuju mreže s dugim kratkoročnim pamćenjem (LSTM) i duboke konvolucijske generativne antagonističke mreže (DCGAN). LSTM mreže su posebno korisne za prognoziranje vremenskih serija i koriste se za predviđanje cijena dionica. (<https://www.simplilearn.com/tutorials/machine-learning-tutorial/stock-price-prediction-using-machine-learning>)
- AI modeli: Umjetna inteligencija se može koristiti za analizu velike količine podataka kako bi se identificirali uzorci te na temelju tih uzoraka umjetna inteligencija može stvoriti model koji će predviđati cijene. (<https://mpost.io/hr/most-promising-stocks-predicted-by-chatgpt-ai/>)
- Algoritmi slučajnih šuma: Algoritmi slučajnih šuma su popularni za predviđanje cijena nekretnina. Oni koriste ansambl metodu koja kombinira više stabala odlučivanja kako bi se postigla bolja prediktivna točnost.

3. ODABIR PLATFORME ZA EKSPERIMENT (TEHNOLOGIJSKE PLATFORME)

Za izradu ovog projekta korišten je Google Colaboratory (Colab). Colab je omogućio besplatno korištenje moćnih GPU resursa, što je bilo presudno za ubrzanje treniranja dubokih modela. Isto tako Colab je omogućio jednostavan pristup podacima putem interneta, što je bilo ključno s obzirom na to da su podaci o cijenama Bitcoina bili dostupni na webu. To je eliminiralo potrebu za ručnim preuzimanjem i postavljanjem datoteka lokalno. U konačnici, korištenje Colaba znatno je olakšalo proces razvoja i treniranja dubokih modela za predviđanje cijena Bitcoina, čime je ubrzano istraživanje i eksperimentiranje u okviru ovog projekta.

Collab-a ima svoje prednosti i nedostatke.

3.1. Prednosti korištenja Google Collab-a

Prednosti korištenja Google Collab-a su:

- Besplatni GPU i TPU resursi: Colab nudi besplatnu upotrebu grafičkih i tenzorskih procesora (GPU i TPU), što je izuzetno korisno za ubrzanje treniranja dubokih modela poput LSTM-a. Ovo je osobito važno ako nemate pristup jakim računalima s GPU-ima ili TPU-ima.
- Dijeljenje i suradnja: Colab omogućuje jednostavno dijeljenje i suradnju s drugima. Možete dijeliti svoje Colab bilježnice s kolegama ili suradnicima i zajedno raditi na projektima. Google Colab bilježnice mogu se jednostavno dijeliti s drugima. Svatko s Google računom može kopirati bilježnicu na vlastiti Google Drive račun.
- Spremanje i automatsko backupiranje: Colab automatski sprema promjene u bilježnici, čime se osigurava da ne izgubite svoj kod ili podatke ako slučajno prekinete vezu ili se dogodi neočekivana pogreška.
- Unaprijed instalirane biblioteke: Google Colab dolazi unaprijed instaliran s mnogim Python bibliotekama, što znači da ih korisnici ne moraju preuzimati.

- GitHub integracija: Možete povezati svoj GitHub račun s Google Colabom kako biste bez problema uvozili i izvozili datoteke s kodom. Za uvoz, možete pritisnuti Ctrl+O i kliknuti na karticu GitHub kako biste dobili datoteke s kodom. S druge strane, jednostavno kliknite na "Spremi kopiju na GitHub" u izborniku Datoteka kako biste poslali datoteke na GitHub.

3.2. Nedostaci korištenja Google Collab-a

Nedostaci korištenja Google Collab-a su:

- Ograničeno trajanje sesije: besplatna verzija Google Colaba ima ograničeno trajanje sesije, što znači da se korisnici moraju ponovno povezati nakon određenog vremenskog razdoblja.
- Ograničena pohrana: besplatna verzija Google Colaba ima ograničenu pohranu, što znači da korisnici ne mogu beskonačno pohranjivati svoje modele na Colabovoj besplatnoj infrastrukturi.
- Ovisnost o internetskoj vezi: Colab zahtijeva internetsku vezu, pa ako izgubite vezu, nećete moći raditi na svojoj bilježnici. Također, brzina internetskog pristupa može utjecati na brzinu izvođenja koda.
- Nema pristupa lokalnim resursima: Colab vam omogućuje pristup besplatnim udaljenim resursima, ali nemate pristup lokalnim datotekama i resursima na vašem računalu.
- Nema potpore za neke specifične biblioteke i postavke: Colab možda neće podržavati određene biblioteke ili postavke koje biste mogli koristiti u svojoj lokalnoj okolini za razvoj.
- Privatnost i sigurnost: Ako radite s osjetljivim podacima, može biti zabrinutosti oko privatnosti i sigurnosti kada koristite udaljeni alat kao što je Colab.
- Ovisnost o Googleovim uslugama: Google Colab ovisi o Googleovim uslugama, što znači da korisnici moraju imati Google račun za korištenje (<https://geekflare.com/google-colab/>)

4. PROJEKT- IZRADA PROTOTIPA

Za izradu projekta koristimo dataset koji sadrži povijesne podatke cijene bitcoina u američkim dolarima. Dataset sadrži datum, cijenu otvaranja, najvišu cijenu, najnižu cijenu, cijenu zatvaranja i obujam trgovanja za svaki dan od 2010 do 2019 godine. Naš cilj je stvoriti model koji će predvidjeti cijenu Bitcoina u USD-u na temelju povijesnih podataka. Nakon što model bude treniran, usporedit ćemo predviđene cijene s stvarnim cijenama iz dataseta kako bismo vidjeli koliko je naš model precizan u predviđanju cijena.

Izrada prototipa

```
csv_path = "https://raw.githubusercontent.com/curiously/Deep-Learning-For-Hackers/master/data/3.stock-prediction/BTC-USD.csv"

Dvapat kliknite (ili pritisnite enter) za uređivanje

[3] df = pd.read_csv(csv_path, parse_dates=['Date'])

[4] df = df.sort_values('Date')
```

Učitavamo podatke iz CSV datoteke koja sadrži cijene Bitcoina u američkim dolarima od 2010 do 2019 godine. Nakon toga, podaci se čitaju iz te datoteke i pohranjuju u varijablu df kao DataFrame objekt. Zatim se DataFrame sortira po datumu.


```
[ ] df.head()
```

	Date	Open	High	Low	Close	Adj Close	Volume
0	2010-07-16	0.04951	0.04951	0.04951	0.04951	0.04951	0
1	2010-07-17	0.04951	0.08585	0.05941	0.08584	0.08584	5
2	2010-07-18	0.08584	0.09307	0.07723	0.08080	0.08080	49
3	2010-07-19	0.08080	0.08181	0.07426	0.07474	0.07474	20
4	2010-07-20	0.07474	0.07921	0.06634	0.07921	0.07921	42

U ovoj tablici imamo prvih 5 podataka u dataframe objektu poredanih po datumu.

```
[7] ax = df.plot(x='Date', y='Close');  
ax.set_xlabel("Date")  
ax.set_ylabel("Close Price (USD)")
```

```
Text(0, 0.5, 'Close Price (USD)')
```



Grafikon 1. Prikaz cijena Bitcoina

Pomoću funkcije `plot` stvaramo grafikon koji prikazuje cijene Bitcoina po datumu. Na x-osi se nalaze datumi, a na y-osi se nalaze cijene. Oznake x-osi i y-osi postavljaju se pomoću funkcija `set_xlabel` i `set_ylabel`.

```
[ ] scaler = MinMaxScaler()  
  
close_price = df.Close.values.reshape(-1, 1)  
  
scaled_close = scaler.fit_transform(close_price)
```

```
[ ] scaled_close.shape  
  
(3201, 1)
```

```
[ ] np.isnan(scaled_close).any()  
  
False
```

```
[ ] scaled_close = scaled_close[~np.isnan(scaled_close)]
```

```
[ ] scaled_close = scaled_close.reshape(-1, 1)
```

```
[ ] np.isnan(scaled_close).any()  
  
False
```

MinMaxScaler() koristimo za skaliranje vrijednosti cijene Bitcoina na raspon od 0 do 1. To se postiže tako što se najmanja vrijednost u nizu podataka postavlja na 0, a najveća vrijednost se postavlja na 1. Skalirane vrijednosti se koriste za treniranje neuronske mreže. reshape() se koristi za oblikovanje niza podataka u obliku stupca kako bi se mogao koristiti s funkcijom MinMaxScaler() za skaliranje podataka. Funkcija isnan() se koristi da bi se provjerilo ima li niz podataka NaN vrijednosti, ako ima te vrijednosti se uklanjaju kako bi se osiguralo da se treniranje provodi samo na valjanim podacima. Nakon toga, skalirane vrijednosti se ponovno oblikuju u obliku stupca pomoću funkcije reshape().

```
✓ [14] SEQ_LEN = 100
0s

def to_sequences(data, seq_len):
    d = []

    for index in range(len(data) - seq_len):
        d.append(data[index: index + seq_len])

    return np.array(d)

def preprocess(data_raw, seq_len, train_split):

    data = to_sequences(data_raw, seq_len)
    num_train = int(train_split * data.shape[0])

    X_train = data[:num_train, :-1, :]
    y_train = data[:num_train, -1, :]

    X_test = data[num_train:, :-1, :]
    y_test = data[num_train:, -1, :]

    return X_train, y_train, X_test, y_test

X_train, y_train, X_test, y_test = preprocess(scaled_close, SEQ_LEN, train_split = 0.95)
```

Funkcija to_sequences() se koristi za pretvaranje niza podataka u sekvence duljine SEQ_LEN. Ova funkcija prolazi kroz niz podataka i stvara sekvence duljine SEQ_LEN tako da se svaka sekvenca sastoji od SEQ_LEN uzastopnih vrijednosti cijene Bitcoina. Funkcija vraća niz sekvenci. Bez pretvaranja podataka u sekvence, neuronska mreža ne bi mogla naučiti uzorke u podacima jer neuronska mreža zahtijeva ulazne podatke u obliku sekvenci. Nakon što se skalirane vrijednosti bitcoina pretvore u sekvence duljine seq_len, funkcija preprocess() dijeli podatke na skup za treniranje i skup za testiranje pomoću varijable num_train. X_train i X_test su varijable koje sadrže ulazne sekvence podataka. Ulazne sekvence su sekvence duljine SEQ_LEN - 1, koje se sastoje od uzastopnih vrijednosti

Bitcoina. `y_train` i `y_test` su varijable koje sadrže izlazne vrijednosti. Izlazne vrijednosti su posljednje vrijednosti u sekvencama duljine `SEQ_LEN`, koje se koriste za treniranje i testiranje neuronske mreže. Izlazne vrijednosti se koriste za uspoređivanje s predviđenim vrijednostima kako bi se utvrdila točnost predviđanja neuronske mreže. `train_split` postavljen je na 0.95, što znači da se 95% podataka koristi za treniranje, a 5% podataka koristi za testiranje

```
✓ [17] DROPOUT = 0.2
5s WINDOW_SIZE = SEQ_LEN - 1

model = keras.Sequential()

model.add(Bidirectional(LSTM(WINDOW_SIZE, return_sequences=True),
                        input_shape=(WINDOW_SIZE, X_train.shape[-1])))
model.add(Dropout(rate=DROPOUT))

model.add(Bidirectional(LSTM((WINDOW_SIZE * 2), return_sequences=True)))
model.add(Dropout(rate=DROPOUT))

model.add(Bidirectional(LSTM(WINDOW_SIZE, return_sequences=False)))

model.add(Dense(units=1))

model.add(Activation('linear'))
```

Za izradu modela koristimo sekvencijalni model. Sekvencijalni model je model koji se sastoji od niza slojeva koji se izvršavaju jedan za drugim. U ovom slučaju, sekvencijalni model se koristi za definiranje neuronske mreže koja se sastoji od tri sloja LSTM neurona i jednog Dense povezanog sloja. Svaki sloj se dodaje u sekvencijalni model koristeći metodu `model.add()`. Prvi sloj je Bidirectional LSTM sloj, što znači da se neuroni izvode u oba smjera, naprijed i unatrag. "input_shape" se koristi za definiranje oblika ulaznih podataka u neuronsku mrežu. U prvom sloju je postavljen na `(WINDOW_SIZE, X_train.shape[-1])`, što znači da se očekuje ulazni oblik koji ima `WINDOW_SIZE` stupaca i `X_train.shape[-1]` značajki. Dropout sloj se koristi za sprječavanje prenaučivosti neuronske mreže. Dropout sloj odbacuje ulazne jedinice s vjerojatnošću koja je postavljena na vrijednost 0.2. Drugi sloj LSTM neurona je također Bidirectional LSTM sloj, ali ima dvostruko više neurona od prvog sloja kako bi se poboljšala njegova sposobnost predviđanja cijene Bitcoina. Međutim, prevelik broj neurona može dovesti do prenaučivosti neuronske mreže, stoga je važno pronaći optimalan broj neurona u svakom sloju kako bi se postigle najbolje performanse modela.

Treći sloj je također Bidirectional LSTM sloj, ali ovaj put ne vraća sekvence. To znači da ovaj sloj prima sekvence ulaznih podataka, ali vraća samo jednu vrijednost. Ovaj sloj se koristi za predviđanje cijene Bitcoina na temelju ulaznih sekvenci. Zadnji sloj je Dense sloj koji ima jednu jedinicu i koristi se za predviđanje cijene Bitcoina. Dense povezani sloj je sloj u neuronskoj mreži koji se sastoji od potpuno povezanih neurona. Svaki neuron u Dense povezanom sloju je povezan sa svakim neuronima u prethodnom sloju. Dense slojevi se koriste za klasifikaciju i regresiju. aktivacijska funkcija koja se koristi je linearna funkcija. Koristimo Linearnu aktivacijsku funkciju koja se koristi za predviđanje cijene Bitcoina na temelju izlaza Dense povezanog sloja koji ima jednu jedinicu.

```
✓ [16] model.compile(  
0s     loss='mean_squared_error',  
       optimizer='adam'  
)
```

Definiramo funkciju gubitka (loss funkcija) i optimizator koji će se koristiti tijekom treniranja modela. Funkcija gubitka je "mean squared error" (MSE), što znači da se srednja vrijednost kvadrata razlike između stvarnih i predviđenih vrijednosti koristi kao mjera gubitka. Koristimo optimizator "Adam", popularni optimizacijski algoritam koji se često koristi u dubokom učenju.

```
✓ 2 min ▶ BATCH_SIZE = 64  
history = model.fit(  
    X_train,  
    y_train,  
    epochs=50,  
    batch_size=BATCH_SIZE,  
    shuffle=False,  
    validation_split=0.1  
)
```

Koristimo BATCH_SIZE veličine 64. To znači da će se tijekom jedne iteracije treniranja modela koristiti 64 uzorka iz skupa za treniranje. U varijablu history se spremaju podaci o treniranju modela na skupu podataka X_train i y_train. Model će se trenirati 50 epoha, a u svakoj epohi će se koristiti 64 uzorka iz skupa za treniranje. Parametar shuffle=False

označava da se podaci neće miješati prije svake epohe. Parametar `validation_split` označava udio podataka koji će se koristiti kao validacijski skup podataka. U ovom slučaju, vrijednost parametra `validation_split=0.1` znači da će se 10% podataka iz skupa za treniranje koristiti kao validacijski skup podataka.

```
15 y_hat = model.predict(X_test)

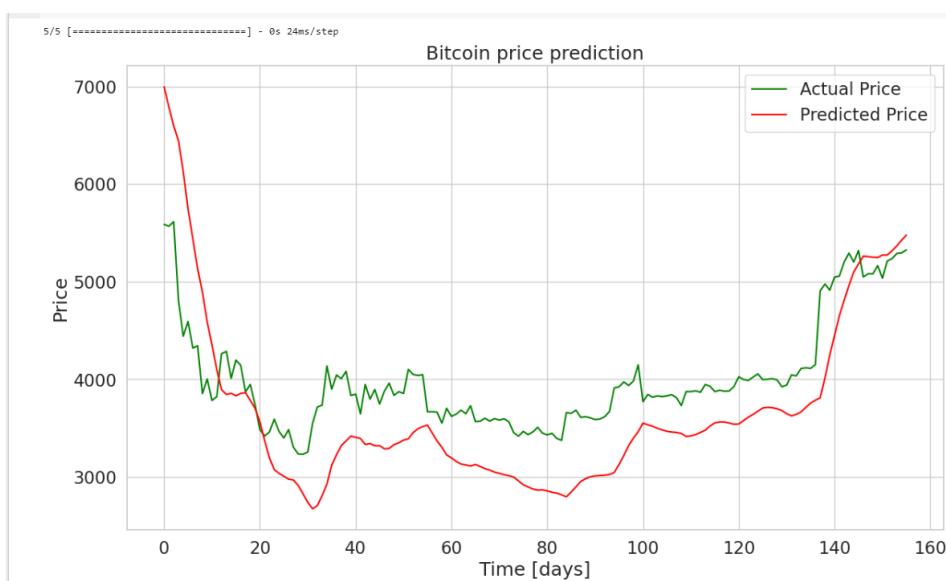
y_test_inverse = scaler.inverse_transform(y_test)
y_hat_inverse = scaler.inverse_transform(y_hat)

plt.plot(y_test_inverse, label="Actual Price", color='green')
plt.plot(y_hat_inverse, label="Predicted Price", color='red')

plt.title('Bitcoin price prediction')
plt.xlabel('Time [days]')
plt.ylabel('Price')
plt.legend(loc='best')

plt.show();
```

Varijabla `y_hat` sadrži predviđene vrijednosti cijena Bitcoina za skup podataka `X_test`, koje su dobivene na temelju modela koji je treniran na skupu za treniranje. Metoda `scaler.inverse_transform()` se koristi kako bi se skalirane vrijednosti vratile u normalne vrijednosti. Ove stvarne vrijednosti se zatim koriste za grafikon koji prikazuje stvarne i predviđene vrijednosti cijena Bitcoina tijekom vremena.



Grafikon 2. Prikaz stvarnih vrijednosti Bitcoina i vrijednosti modela

Grafikon 2. prikazuje stvarne vrijednosti cijena Bitcoina u odnosu na vrijednosti koje su dobivene na temelju našeg modela. Ovaj grafikon se koristi za vizualnu usporedbu stvarnih i predviđenih vrijednosti cijena Bitcoina te za procjenu uspješnosti našeg modela. Koristili smo LSTM (Long Short-Term Memory) model za predviditi cijenu Bitcoina. LSTM modeli su učinkoviti jer mogu zadržati informacije o prošlim stanjima te ih koristiti za predviđanje budućih stanja. Iako smo koristili LSTM model za predviđanje cijena Bitcoina, postoji mogućnost da bi se korištenjem nekih drugih algoritama mogli dobiti bolji rezultati. Na primjer, algoritam slučajnih suma (eng. Random Forest) je algoritam strojnog učenja koji se često koristi za predviđanje vrijednosti. Međutim, nije pronađen nijedan projekt koji koristi ovaj isti dataset cijena bitcoina u USD, pa nismo imali s čim usporediti ove vrijednosti kako bismo znali koja je metoda bolja.

Biblioteke koje su korištene su:

- numpy: Biblioteka za Python koja se koristi za rad s višedimenzionalnim nizovima i matricama, te brojnim matematičkim operacijama.
- tensorflow: TensorFlow je biblioteka za strojno učenje otvorenog koda koju je razvio Google. Koristi se za izgradnju i treniranje modela strojnog učenja, uključujući duboke neuronske mreže. TensorFlow pruža fleksibilan ekosustav alata, biblioteka i resursa zajednice za stvaranje modela strojnog učenja proizvodne razine. TensorFlow se može koristiti za pronalaženje unaprijed obučениh modela, istraživanje s najsuvremenijim modelima, izradu vlastitih modela i njihovu implementaciju bilo gdje, u bilo kojoj mjeri.
- Keras je API za neuronske mreže visoke razine napisan u Pythonu koji može raditi povrh TensorFlow, CNTK ili Theano. U Google Colabu, Keras se može koristiti za izradu i treniranje modela strojnog učenja. Keras u Colabu može se koristiti za stvaranje širokog raspona modela neuronskih mreža, uključujući konvolucijske neuronske mreže (CNN), rekurentne neuronske mreže (RNN) i duboke neuronske mreže (DNN). Keras u Colabu također se može koristiti za zadatke kao što su klasifikacija slika, obrada prirodnog jezika i analiza vremenskih serija.
- Pandas je biblioteka za manipulaciju i analizu podataka koja se koristi za analizu podataka. Pruža podatkovne strukture i funkcije jednostavne za korištenje za rad sa strukturiranim podacima, što ga čini bitnim alatom za čišćenje podataka, istraživanje, transformaciju i pripremu prije analize ili zadataka strojnog učenja.

- Seaborn je Python biblioteka za vizualizaciju podataka temeljena na Matplotlib-u koja pruža sučelje visoke razine za stvaranje informativnih grafova. Obično se koristi za izradu statističkih grafova kao što su dijagrami raspršenosti, stupčasti dijagrami, okvirni dijagrami i još mnogo toga. Seaborn je posebno koristan za vizualizaciju složenih skupova podataka i odnosa između varijabli.
- rcParams je dio biblioteke Matplotlib u Pythonu. Matplotlib je popularna biblioteka za stvaranje statičnih, animiranih i interaktivnih vizualizacija u Pythonu. rcParams je objekt koji vam omogućuje da konfigurirate različite aspekte ponašanja Matplotliba, kao što su veličina figure, stilovi linija, fontovi i još mnogo toga. Možete koristiti rcParams za prilagođavanje izgleda vaših dijagrama i brojki.
- matplotlib.pyplot u Google Colabu omogućuje vam stvaranje raznih vrsta dijagrama, kao što su linijski grafikoni, dijagrami raspršenosti, stupčasti dijagrami, histogrami i više, sa samo nekoliko redaka koda. Osim toga, možete prilagoditi izgled svojih crteža dodavanjem oznaka, naslova, legendi, boja i drugih opcija oblikovanja.
- Rc(runtime configuration) u Google Colabu omogućuje prilagodbu postavki kao što su veličina figure, stilovi linija, veličina fonta, karte boja i mnoga druga svojstva povezana s iscrtavanjem. To vam omogućuje stvaranje grafova koje odgovaraju vašim specifičnim zahtjevima ili osobnim preferencijama.
- MinMaxScaler se koristi za skaliranje značajki ili normalizaciju podataka. Skalira i transformira vrijednosti značajki skupa podataka u određeni raspon, obično između 0 i 1. Ovo se skaliranje postiže oduzimanjem minimalne vrijednosti značajke od svih vrijednosti u toj značajki i zatim dijeljenjem rezultata s rasponom
- "Bidirectional" sloj iz tensorflow.keras.layers koji se koristi za poboljšanje modeliranja sekvencijalnih podataka, gdje razumijevanje konteksta iz prošlih i budućih elemenata sekvence može biti korisno. Dvosmjerni slojevi obično se koriste u zadacima koji uključuju sekvencijalne podatke, kao što je obrada prirodnog jezika (NLP), prepoznavanje govora.
- Dropout sloj iz tensorflow.keras.layers se koristi tijekom uvježbavanja neuronskih mreža kako bi se spriječilo prekomjerno prilagođavanje, što je čest problem u dubokom učenju gdje model dobro funkcionira na podacima treniranja, ali se ne uspijeva generalizirati na nove, neviđene podatke. Dropout pomaže poboljšati generalizaciju modela nasumičnim deaktiviranjem frakcije neurona ili jedinica tijekom svake iteracije treniranja.

- Activation sloj iz `tensorflow.keras.layers` koristi se za primjenu nelinearne aktivacijske funkcije na izlaz prethodnog sloja u neuronskoj mreži. Aktivacijske funkcije uvode nelinearnost u model, omogućujući mu da nauči složene obrasce i odnose u podacima. Oni su bitna komponenta dubokih neuronskih mreža.
- Dense sloj iz `tensorflow.keras.layers` koristi se za stvaranje potpuno povezanih slojeva neuronske mreže. Dense" sloj je potpuno povezan, što znači da svaki neuron u tom sloju ima vezu s svakim neuronima iz prethodnog sloja
- LSTM sloj iz `tensorflow.keras.layers` koristi se za stvaranje jedinica dugotrajne kratkoročne memorije (LSTM) u rekurentnoj neuronskoj mreži (RNN). LSTM je vrsta rekurentnog sloja posebno dizajnirana za hvatanje dugoročnih ovisnosti i učinkovito rukovanje sekvencijalnim podacima, što ga čini prikladnim za zadatke poput obrade prirodnog jezika (NLP), prepoznavanja govora i predviđanja vremenskih nizova.
- Sequential je klasa iz `tensorflow.keras.models` koristi se za stvaranje linearnog niza slojeva u modelu neuronske mreže. Omogućuje nam da izgradimo neuronsku mrežu dodavanjem slojeva jednog za drugim, s podacima koji teku sekvencijalno od ulaznog sloja kroz svaki sloj do izlaznog sloja.

5. ZAKLJUČAK

Kriptovalute su digitalni ekvivalenti fizičkom novcu koji nemaju pokriće u zlatu ili srebru već se zasnivaju na matematici i algoritmima. Za razliku od cijena dionica koje ovise o poslovanju tvrtki, volatilnost cijena kriptovaluta je daleko veća i daleko rizičnije ulaganje.

Cijena kriptovalute ovisi o dobroj tehnologiji i sigurnosti koja stoji iza te kriptovalute, ali su i vrlo nestabilne i podložne utjecaju raznih čimbenika kao što su vijesti iz svijeta, sentimentu tržišta te ekonomskim pokazateljima.

Ulagачe u kriptovalute zanima je li moguće na temelju velike količine povijesnih podataka kretanja tečaja kriptovalute predvidjeti cijenu u budućnosti pri čemu se koriste razne tehnike uključujući LSTM algoritam koji je korišten u ovom projektu.

LSTM mreže su posebna vrsta rekurentnih neuronskih mreža (RNN) stvorena da se uhvate u koštac s problemom nestanka gradijenta u tradicionalnim RNN-ovima. Njihova glavna prednost je sposobnost bolje obrade vremenskih serija, kao što su povijesni podaci o cijenama dionica, kretanja tržišta i valuta. LSTM mreže imaju sposobnost dugoročnog pamćenja i predviđanja, što ih čini korisnim alatom za predviđanje cijena na temelju sekvencijalnih podataka.

Rastom tržišta kriptovaluta razvijene su mnoge mobilne aplikacije i platforme koje pružaju informacije o različitim kriptovalutama kao što su cijene, tržišna kapitalizacija, volumen trgovanja i druge ažurirane podatke i članke vezane uz tržište kriptovaluta s kojima investitori mogu bolje analizirati tržište i donositi kvalitetnije odluke.

Za izradu ovog projekta korišten je Google Colaboratory (Colab) koji ima jednostavan pristup podacima putem interneta što je znatno je olakšalo proces razvoja i treniranja dubokih modela za predviđanje cijena Bitcoina.

Za izradu projekta korišten je dataset koji sadrži povijesne podatke cijene Bitcoina u američkim dolarima od 2010 do 2019 godine, a ima za cilj stvoriti model koji će predvidjeti cijenu Bitcoina u USD-u na temelju tih povijesnih podataka. Da bi se utvrdila preciznost predviđanja modela uspoređujemo predviđene cijene s stvarnim cijenama iz dataseta.

LITERATURA

1. Bolf, N. (2021). Osvježimo znanje: Strojno učenje. *Kemija u industriji: Časopis kemičara i kemijskih inženjera Hrvatske*, 70(9-10), 591-593. (Dostupno 11.09.2023. na: <https://hrcak.srce.hr/file/382926>)
2. Čičin-Šain, D. (2007). Osnove menadžmenta. *U: Predavanja iz menadžmenta. Zadar: Sveučilište u Zadru*, 19. (Dostupno 11.09.2023. na: http://www.unizd.hr/portals/4/nastavni_mat/2_godina/menadzment/menadzment_07.pdf)
3. Kozarević, E. & Ibrić, M. (2021). Specifičnosti kriptovaluta u odnosu na klasični (fiat) novac (Dostupno 11.09.2023. na: https://www.researchgate.net/publication/350871815_Specificnosti_kriptovaluta_u_odnosu_na_klasicni_fiat_novac)
4. Sajter, D. (2009). Pregled određenih metoda i istraživanja poslovnih poteskoca uz predviđanje stecaja. *Ekonomska misao i praksa*, 18(2), 429. (Dostupno 11.09.2023. na: <https://hrcak.srce.hr/file/74939>)
5. Vizjak, A. (2000). Utjecaj monetarne Unije i uvođenje eura na gospodarske sustave europskih zemalja i Republike Hrvatske. *Ekonomski vjesnik: Review of Contemporary Entrepreneurship, Business, and Economic Issues*, 13(1-2), 109-121. (Dostupno 11.09.2023. na: <https://hrcak.srce.hr/file/294953>)
6. Vlada RH (2018). Strategija za uvođenje eura kao službene valute u Republici Hrvatskoj (Dostupno 11.09.2023. na: <https://www.mingo.hr/public/documents/Eurostrategija%20-%20FINAL.pdf>)
7. Zaytar, M. A., & El Amrani, C. (2016). Sequence to sequence weather forecasting with long short-term memory recurrent neural networks. *International Journal of Computer Applications*, 143(11), 7-11. (Dostupno 11.09.2023. na: [researchgate.net](https://www.researchgate.net))

Internetski izvori (dostupno 11.09.2023.):

1. <https://financijskiimpuls.org/2017/01/15/tehnicka-analiza-analiza-kretanja-cijena-financijskih-instrumenata/>
2. <https://geekflare.com/google-colab/>

3. <https://kriptomat.io/hr/kriptovalute/vrste-kriptoaluta/>
4. <https://mpost.io/hr/most-promising-stocks-predicted-by-chatgpt-ai/>
5. <https://portalcripto.com.br/hr/najbolji-kripto-alati/>
6. https://www.agrambrokeri.hr/UserDocsImages/Arhiva/UserDocsImages/publikacije/Uvod_u_tehnicku_analizu.pdf
7. <https://www.bug.hr/mobilne-aplikacije/mobilne-aplikacije-za-rad-s-kriptoalutama-18805>
8. <https://www.simplilearn.com/tutorials/machine-learning-tutorial/stock-price-prediction-using-machine-learning>

POPIS GRAFIČKIH PRIKAZA I TABLICA

Slika 1. Linijski grafikon	4
Slika 2. Stupčasti grafikon	4
Slika 3. Grafikon s japanskim svijećama.....	5
Grafikon 1. Prikaz cijena Bitcoina	14
Grafikon 2. Prikaz stvarnih vrijednosti Bitcoina i vrijednosti modela	18