

Metode dubokog učenja za analizu i predviđanje tržišta dionica

Medić, Tomislav

Master's thesis / Diplomski rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Economics and Business / Sveučilište u Zagrebu, Ekonomski fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:148:934056>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-10-15**



Repository / Repozitorij:

[REPEFZG - Digital Repository - Faculty of Economics & Business Zagreb](#)



Sveučilište u Zagrebu

Ekonomski fakultet

Studij „Menadžerska Informatika“

**METODE DUBOKOG UČENJA ZA ANALIZU I PREDVIĐANJE
TRŽIŠTA DIONICA**

Diplomski rad

Tomislav Medić

Zagreb, rujan, 2019.

Sveučilište u Zagrebu

Ekonomski fakultet

Studij „Menadžerska Informatika“

**METODE DUBOKOG UČENJA ZA ANALIZU I PREDVIĐANJE
TRŽIŠTA DIONICA**

**DEEP LEARNING METHODS FOR STOCK MARKET
ANALYSIS AND PREDICTION**

Diplomski rad

Tomislav Medić, 0067463964

Mentor: Prof.dr.sc. Mirjana Pejić Bach

Zagreb, rujan, 2019.

SAŽETAK

U posljednjih nekoliko godina, svjedočimo nevjerojatnom razvoju umjetne inteligencije i njenih podvrsta poput strojnog i dubokog učenja. Po prvi puta u povijesti, pristup podacima i razvoj tehnologije omogućuju efikasnu primjenu umjetne inteligencije u različitim područjima, od samovoznih (*engl. self driving*) automobila do virtualnih asistenata, robota u skladištima (npr. Alibaba), robota na proizvodnim trakama, i sl.

Razvoj interneta potaknuo je razvoj različitih tehnologija koje su umjetnoj inteligenciji omogućile „skok“ sa teoretskih modela na praktične, uključujući: rudarenje podataka, razvoj programskih jezika (npr. Python) i knjižnica programskog koda, različitih alata poslovne inteligencije i sl. Danas vrlo jednostavno i brzo možemo napraviti umjetne neuronske mreže (duboko učenje) te ih primijeniti na različite analize i zadatke, a time metode dubokog učenja iz dana u dan pronalaze nova područja u kojima optimiziraju procese, smanjuju troškove i potiču inovacije.

Jedno od tih područja je i tržište vrijednosnih papira, gdje se duboko učenje koristi za različite analize, uočavanje trendova i predviđanje, a razvoj neuronskih mreža na tom području i nedavni uspjesi te tehnologije, predstavljaju poticaj za daljnje istraživanje i sve dublju primjenu metoda dubokog učenja na tržištu vrijednosnih papira.

Ključne riječi: umjetna inteligencija, duboko učenje, umjetne neuronske mreže, tržište dionica, predviđanje

ABSTRACT

In recent years, we are witnessing the incredible development of artificial intelligence and its subtypes such as machine learning and deep learning. For the first time in history, access to data and technological development enable the effective application of artificial intelligence in a variety of fields, from self-driving cars to virtual assistants, warehouse robots (eg. Alibaba), production lane robots, and the like.

The development of the Internet has encouraged the development of various technologies that have allowed artificial intelligence to „jump“ from theoretical models to practical ones, including: data mining, development of programming languages (eg. Python) and code libraries, various business intelligence tools, etc. Today, we can build artificial neural networks (deep learning) easily and quickly, and apply them to a variety of analyses and tasks, which have allowed deep learning to constantly find new areas where they optimize processes, reduce costs and drive innovation.

One of these areas is the securities market, where deep learning is used for various analyses, trend recognition and forecasting, and the development of neural networks in this area along with recent technological successes are an incentive for further research and deeper application of deep learning methods to securities market.

Key words: artificial intelligence, deep learning, artificial neural networks, stock market, forecasting, prediction

SADRŽAJ

1. UVOD	1
1.1. Predmet i cilj rada.....	1
1.2. Izvori podataka i metode prikupljanja	2
1.3. Sadržaj i struktura rada	2
2. UMJETNA INTELIGENCIJA I DUBOKO UČENJE	3
2.1. Povijest umjetne inteligencije i dubokog učenja	4
2.2. Primjena umjetne inteligencije u 21. stoljeću.....	11
2.3. Definiiranje dubokog učenja i neuronskih mreža	14
2.3.1. Uvod u duboko učenje.....	14
2.3.2. Kako duboko učenje funkcionira	16
2.3.3. Revolucija dubokog učenja	18
2.4. Kritike i komentari na duboko učenje	21
3. TRŽIŠTE VRIJEDNOSNIH PAPIRA.....	23
3.1. Opseg i ograničenja analize vrijednosnih papira	24
3.2. Investitorski pristup	25
3.2.1. Fundamentalna analiza.....	25
3.2.2. Tehnička analiza.....	26
4. PRIMJENA DUBOKOG UČENJA NA TRŽIŠTE DIONICA	27
4.1. Priprema podataka za potrebe analize upotrebom neuronske mreže.....	27
4.2. Karakteristike podataka iz dataset-a	28
4.3. Metodologija rada.....	30
4.3.1. Weka.....	30
4.3.2. Model vremenskih serija (Time series).....	31

4.3.3. Višeslojni Perceptron (Multilayer Perceptron)	32
4.4. Postupak analize podataka i predviđanje budućih cijena	33
4.4.1. Priprema Weka softvera	33
4.4.2. Priprema podataka.....	34
4.4.3. Podešavanje modela	35
4.4.4. Rezultati modela.....	38
4.5. Usporedba rezultata	40
5. ZAKLJUČAK	42
POPIS LITERATURE	43
POPIS TABLICA.....	45
POPIS SLIKA	46
PRILOZI.....	47
ŽIVOTOPIS AUTORA.....	61

1. UVOD

U posljednjih nekoliko godina, točnije od 2011. godine i pojave IBM-ovog Watsona, svjedočimo munjevitom razvoju umjetne inteligencije koja se postepeno integrira u poslovni svijet, a izgledno je da će se taj rast i nastaviti. Umjetna inteligencija može se primijeniti u svim gospodarskim djelatnostima, a već sada vidimo primjenu ove tehnologije u mnogima od njih. Umjetna inteligencija predstavlja softver koji oponaša ljudske kognitivne procese poput učenja, rasuđivanja i prilagodbe. Ovaj jednostavan opis nedovoljan je da se shvati puni potencijal takvog softvera pa je cilj ovoga rada predstaviti, opisati i istražiti primjenu tehnologije umjetne inteligencije, odnosno dubokog učenja, u području trgovanja dionicima.

1.1. Predmet i cilj rada

Predmet istraživanja ovog rada je utvrđivanje mogućnosti umjetne inteligencije da na temelju određenog skupa podataka (dataset-a) o prijašnjim kretanjima pokuša predvidjeti buduće kretanje cijena dionica. U sklopu rada, izraditi će se i testirati jednostavni model (umjetne neuronske mreže) koji će na temelju dubokog učenja analizirati uzorke dionica i pokušati predvidjeti kretanje njihovih cijena. Rezultati ovog istraživanja mogli bi poslužiti svima zainteresiranima za trgovanje dionicama kao dodatni alat za smanjenje rizika i povećanje dobiti. Bitno je napomenuti da koliko god sofisticiran softver bio i koliko god se tehnologija umjetne inteligencije razvila u budućnosti, ono nikada neće moći sa stopostotnom sigurnošću predvidjeti kretanje cijena na tržištu. Međutim, gotovo sigurno će predstavljati koristan alat za efikasnije trgovanje. Cilj rada, kao što je spomenuto u uvodu, predstaviti je, opisati i istražiti primjenu tehnologije umjetne inteligencije, odnosno dubokog učenja, u području trgovanja dionicama.

1.2. Izvori podataka i metode prikupljanja

Istraživanje je provedeno na skupu podataka o cijenama dionice AMD, preuzetih sa interneta (finance.yahoo.com). Preuzeti skup podataka analiziran je pomoću umjetne neuronske mreže zvane Višeslojni Perceptron koja je stvorena uz pomoć Weka softvera, verzija 3.8.3.

Teorijski dio rada, uključujući umjetnu inteligenciju, duboko učenje i tržište vrijednosnih papira, temeljen je na istraživanju relevantne literature (knjige, znanstveni i stručni radovi) iz navedenih područja.

1.3. Sadržaj i struktura rada

Ovaj rad podijeljen je u 5 poglavlja koji daju pregled tehnologije umjetne inteligencije, dubokog učenja i tržišta vrijednosnih papira te moguće primjene te tehnologije na dio tog tržišta, tržište dionica.

Prvo poglavlje predstavlja kratki uvod u temu rada, a opisani su i predmet te cilj rada. Navedena je i metoda dubokog učenja koja se koristila za potrebe istraživanja, kao i izvori podataka te sadržaj i struktura rada.

U drugom poglavlju objašnjena je glavna tehnologija koja se koristila u ovom radu, a to su umjetne neuronske mreže. Dan je povijesni pregled razvoja te tehnologije, način na koji funkcionira te su predstavljene glavne kritike i dani komentari.

Treće poglavlje donosi kratak pregled aspekata tržišta vrijednosnih papira koji su bitni za ovaj rad i provedeno istraživanje, te su opisane glavne analize tržišta dionica čija je optimizacija dio ovog rada.

Četvrto poglavlje predstavlja samo istraživanje. Opisan je skup podataka na kojem je rađena analiza i na koji se primijenila umjetna neuronska mreža, zatim je opisan i prikazan postupak konfiguracije Weka softvera koji se koristio za primjenu neuronske mreže te su dani i grafički prikazani rezultati.

Peto poglavlje predstavlja zaključke donesene u sklopu ovog istraživanja.

2. UMJETNA INTELIGENCIJA I DUBOKO UČENJE

Posljednjih nekoliko godina svjedočimo velikom razvoju umjetne inteligencije i njenoj sve široj primjeni u različitim sferama gospodarstva. Kao pojam, umjetna inteligencija nije novina, o njoj se govorilo već davnih 1940-ih godina (više o povijesti umjetne inteligencije u potpoglavlju 2.1). Međutim, prvi puta u povijesti ljudska tehnologija sposobna je podržati efikasnu primjenu umjetne inteligencije pa ne čudi njen nagli razvoj.

Duboko učenje jedna je od grana strojnog učenja, a strojno učenje je grana umjetne inteligencije. Da bi razumjeli kako duboko učenje funkcionira prvo je potrebno predstaviti umjetnu inteligenciju. Iako vrlo kompleksno područje, umjetnu inteligenciju u kratko možemo objasniti kroz četiri pristupa. Sva četiri pristupa opisuju umjetnu inteligenciju na svoj način, a svaki od njih povijesno su proučavali različiti znanstvenici sa različitim metodama. Pregled ova četiri pristupa možemo vidjeti u tablici 2.1. (Russel & Norvig, 2010):

Tablica 1. Neke od definicija umjetne inteligencije, organizirane u 4 kategorije prema (Russel & Norvig, 2010)

Ljudsko razmišljanje <i>„Uzbudljiv novi trud stvaranja računala koja razmišljaju... strojevi s umom, u punom i doslovnom smislu.“ (Haugeland, 1985)</i> <i>„[Automatizacija] aktivnosti koje vežemo uz ljudsko razmišljanje, aktivnosti poput odlučivanja, rješavanja problema, učenja...“ (Bellman, 1978)</i>	Racionalno razmišljanje <i>„Istraživanje mentalnih sposobnosti upotrebom računalnih modela.“ (Charniak i McDermott, 1985)</i> <i>„Istraživanje izračuna koji omogućuju opažanje, rasuđivanje i djelovanje.“ (Winston, 1992)</i>
Ljudsko ponašanje <i>„Umjetnost stvaranja strojeva koji izvršavaju funkcije za koje je, kada ih izvode ljudi, potrebna inteligencija.“ (Kurzweil, 1990)</i> <i>„Istraživanje o tome kako napraviti računalo da radi stvari koje, u ovom trenutku, ljudi rade bolje.“ (Rich and Knight, 1991)</i>	Racionalno ponašanje <i>„Računalna inteligencija je proučavanje dizajna inteligentnih agenata.“ (Poole i sur., 1998)</i> <i>„AI... se bavi inteligentnim ponašanjem u artefaktima.“ (Nilsson, 1998)</i>

„Ljudsko-centrirani pristupi djelomično su empirijska znanost, a uključuju zapažanja i pretpostavke o ljudskom ponašanju. Racionalni pristup uključuje kombinaciju matematike i strojarstva“ (Russel & Norvig, 2010).

Koliko god ovi pristupi bili različiti, iz njih možemo izvući osnovno razumijevanje tehnologije umjetne inteligencije. Umjetna inteligencija je sposobnost računala i računalnog koda da oponašaju ljudske kognitivne procese te da ih primjenjuju na različite zadatke.

„Danas je umjetna inteligencija rastuće polje sa puno praktičnih aplikacija i aktivnih istraživačkih tema. Sve više gledamo u inteligentni softver kako bismo automatizirali rad, razumjeli govor ili slike, postavili dijagnoze u medicini te podržali osnovna znanstvena istraživanja“ (Goodfellow, Bengio, & Courville, 2016).

Prije nego li pređemo na duboko učenje i kako ono funkcionira danas, korisno je pogledati cijelu povijest umjetne inteligencije i dubokog učenja za lakše razumijevanje današnjih modela i načina rada umjetnih neuronskih mreža, glavnih metoda dubokog učenja.

2.1. Povijest umjetne inteligencije i dubokog učenja

Povijest umjetne inteligencije, a sa time i dubokog učenja, duga je i ispunjena različitim modelima i teorijama. Neki od njih su odbačeni, neki su razvijeni dalje, a neki su ostali nepromijenjeni. Za potrebe ovog rada i lakšeg razumijevanja kako je umjetna inteligencija nastala i kako se razvijala tokom godina, u ovom poglavlju predstaviti će se najvažniji događaji i prekretnice u genezi umjetne inteligencije.

Prvi rad koji se sada prepoznaje kao umjetna inteligencija pripisuje se Warren McCullochu i Walter Pittsu (Russel & Norvig, 2010). Davne 1943. godine McCulloch i Pitts predstavljaju model kojeg čine umjetni neuroni, od kojih svaki sadrži dvije moguće vrijednosti, „uključen“ i „isključen“ (engl. on and off). Prelazak na „uključeno“ podrazumijeva stimulaciju dovoljnim brojem susjednih neurona. Svojim radom, pokazali su da se bilo koja računalna funkcija može izračunati upotrebom neke vrste mreže povezanih neurona i da se sve logičke poveznice (i, ili, ne, itd.) mogu implementirati jednostavnim mrežnim strukturama. Također su tvrdili da odgovarajući definirane mreže mogu učiti.

Iako su McCulloch i Pitts pokazali snagu neuronskog računanja, zanimanje za taj pristup procvatilo je tek razvojem algoritama praktičnog učenja (Luger, 2009). Do toga je došlo tek 1949. Godine kada je Donald Hebb demonstrirao jednostavno pravilo ažuriranja za promjenu snage veze između neurona. Njegovo pravilo, koje sada zovemo Hebbijano učenje (engl. Hebbian learning), ostaje utjecajan model dandanas (Russel & Norvig, 2010).

Prvo računalo s neuronskom mrežom pojavljuje se 1950. Sagrađili su ga Marvin Minsky i Dean Edmonds, dva studenta sa Harvarda, a zvao se SNARC (Russel & Norvig, 2010). Istovremeno, Alan Turing izdaje članak pod nazivom „Computing Machinery and Intelligence“ (1950.) u kojem predstavlja turingov test, strojno učenje, genetske algoritme i učenje ojačanja (engl. reinforcement learning). Uz SNARC, i viziju Alana Turinga, polako se primicalo razdoblje umjetne inteligencije.

Počeci umjetne inteligencije obilježeni su uspjesima. Od 1952. godine do 1969. godine, uz tadašnja primitivna računala i alate za programiranje, istraživači umjetne inteligencije uspješno su demonstrirali sposobnosti ove tehnologije na različitim zadacima.

1958. godine John McCarthy definira programski jezik visoke razine, Lisp, koji postaje dominantan programski jezik umjetne inteligencije narednih 30 godina. Iste godine, McCarthy objavljuje rad pod nazivom „Programs with Common Sense“, u kojem opisuje hipotetski program „Advice Taker“ koji se može smatrati prvim kompletnim sustavom umjetne inteligencije. Interesantno je koliki dio ovog rada ostaje relevantan i danas (Russel & Norvig, 2010).

1959. godine Herbert A. Simon, J.C. Shaw i Allen Newell predstavljaju „General Problem Solver“ ili GPS. GPS je program koji je dizajniran da imitira ljudske protokole za rješavanje problema. GPS je predstavljao prvi program umjetne inteligencije koji je djelovao pristupom ljudskog razmišljanja, a upravo je on, i programi koji su ga pratili, vodio Newella i Simona (1976) da formuliraju poznatu hipotezu fizičkog sustava simbola (engl. *physical symbol system*). Ova hipoteza govori da „fizički sustav simbola sadrži potrebna i dostatna sredstva za opće inteligentne akcije“. Odnosno, da bilo koji inteligentni sustav (ljudski ili računalni) mora djelovati manipuliranjem strukture podataka sastavljene od simbola (Russel & Norvig, 2010).

Također u ovom razdoblju, pod nadzorom stručnjaka umjetne inteligencije Marvin Minskyja, studenti MIT-a (*Massachusetts Institute of Technology*) rade na ograničenim problemima čije rješenje zahtjeva inteligenciju. Ti ograničeni problemi, ili domene, nazvani su mikrosvjetoima (*engl. microworlds*), a njihov rad donosi nam još neke značajne programe umjetne inteligencije. Neki od njih su (Russel & Norvig, 2010):

- James Slagle - SAINT program (1963) - program koji je bio sposoban riješiti različite matematičke zadatke.
- Tom Evans - ANALOGY program (1968) - program koji je uspješno rješavao zadatke geometrijske usporedbe, kakvi su karakteristični za klasične IQ testove.
- Daniel Bobrow - STUDENT program (1967) - rješavao je tekstualne matematičke zadatke.

Ranije spomenuti rad McCullocha i Pittsa također se razvijao. Djelo Winograd-a i Cowan-a (1963) pokazuje da veliki broj elemenata zajednički može predstavljati pojedinačni koncept s odgovarajućim povećanjem robusnosti i paralelizma. Bernie Widrow (Widrow i Hoff, 1960; Widrow, 1962) unaprjeđuje Hebijanovo učenje te razvija vlastitu mrežu „ADALINE“ (Adaptive Linear Neuron), a Frank Rosenblatt (1962) predstavlja Perceptron i teorem konvergencije perceptrona (*engl. perceptron convergence theorem*) (Russel & Norvig, 2010). Perceptron je algoritam za nadzirano učenje binarnih klasifikatora, a teorem konvergencije perceptrona u osnovi govori da se algoritam učenja Perceptron konvergira u ograničenom broju koraka s obzirom na linearno odvojivi skup podataka.

Krajem šezdesetih godina i početkom sedamdesetih umjetna inteligencija po prvi puta nailazi na prepreke. Te prepreke oslikane su kroz tri problema. Prvi problem pojavljuje se jer većina ranih programa umjetne inteligencije nije imala adekvatno znanje o svom području rada. Njihov uspjeh bazirao se na jednostavnim sintaktičkim manipulacijama. Najveći primjer ovoga problema oslikan je u prijevodu ruskih znanstvenih dokumenata koje je financiralo Američko nacionalno vijeće za istraživanje u pokušaju ubrzanja procesa prijevoda s ruskog na engleski ususret lansiranju Sputnika 1957. godine. Vjerovalo se da su jednostavne sintaktičke transformacije ,na temelju gramatike ruskog i engleskog jezika, i zamjena riječi pomoću elektroničkog rječnika, dovoljne da se očuva točno značenje rečenica (Russel & Norvig, 2010). Naravno, prijevod sa jednog jezika na drugi nije tako jednostavan, a čak i moderni programi koji se bave prijevodom

ponekad imaju poteškoća. To nas dovodi do poznate anegdote doslovnog prijevoda rečenice s ruskog na engleski, „the spirit is willing but the flesh is weak“ u „the vodka is good but the meat is rotten“, i prve veće prepreke umjetne inteligencije općenito, a posebno projekata akademskog prevođenja koji su izgubili gotovo svako financiranje.

Druga poteškoća bila je ograničenost mnogih problema koji su se rješavali upotrebom umjetne inteligencije. Većina ranih programa umjetne inteligencije rješavala je probleme isprobavanjem različitih kombinacija mogućih rješenja sve dok konačno točno rješenje ne bi bilo pronađeno. Ta je strategija u početku djelovala jer su mikrosvijetovi sadržavali vrlo malo objekata i stoga vrlo malo mogućih radnji te jako kratki proces rješavanja (Russel & Norvig, 2010). Prije razvoja teorije računske složenosti, vjerovalo se da se uspjeh postignut u mikrosvijetovima jednostavno može prenijeti na veće projekte te da je to samo pitanje bržeg hardvera, odnosno povećanja memorije i procesne snage. Međutim, to se pokazalo neistinitim. Istraživači koji su kasnije pokušavali dokazati teoreme koji uključuju više od nekoliko desetaka činjenica, nisu uspjeli. Činjenica da program u načelu može naći rješenje ne znači da program sadrži bilo koji od mehanizama potrebnih za njegovo pronalaženje u praksi (Russel & Norvig, 2010).

Treća poteškoća javlja se zbog temeljnih ograničenja osnovnih struktura koje se koriste za stvaranje inteligentnog ponašanja (Russel & Norvig, 2010). Ovu činjenicu potvrdili su Marvin Minsky i Seymour Papert 1969. godine u svojoj knjizi „Perceptrons“. Knjiga koja je uvelike promijenila opće mišljenje o umjetnoj inteligenciji tada, te se vjeruje dovela do takozvane zime umjetne inteligencije (*engl. AI winter*). U svojoj knjizi Minsky i Papert pokazuju znatna ograničenja Rosenblattovog Perceptrona te pokazuju da Perceptron nije u stanju naučiti jednostavnu isključivo-ili petlju (XOR). Odnosno, dokazuju da koliko god takva mreža učila, nikada neće biti u stanju riješiti XOR petlju. Retrospektivno, ovaj zaključak ima smisla budući da su perceptron mreže linearne, a XOR petlja nelinearna, ali tada je to bilo dovoljno da entuzijazam za umjetnu inteligenciju splasne što je dovelo do drastičnog pada u financiranju istraživanja umjetne inteligencije.

Ironično je da su novi algoritmi učenja unatrag (*engl. back-propagation learning algorithms*) koji su izazvali ogroman preporod u istraživanju neuronskih mreža i umjetne inteligencije kasnih 80-ih, u stvari prvo otkriveni 1969. godine (Russel & Norvig, 2010).

Iako se razdoblje od 1969. godine do 1979. godine smatra zimom umjetne inteligencije, u pozadini ova tehnologija i dalje se razvijala. Problem ograničenja koji se javio u prvim godinama razvoja umjetne inteligencije nastojao se ukloniti. Dotadašnji procesi po kojim su funkcionirali programi umjetne inteligencije nazvani su „slabe metode“ (*engl. weak methods*), jer iako su se mogle primijeniti na općenite probleme, nisu se mogli adaptirati na veće i složenije projekte i zadatke. Kao rješenje na problem slabih metoda bilo je uvesti jače, područno-specifično znanje koje bi omogućilo veće korake zaključivanja i koje bi lakše svladalo tipične slučajeve u uskim područjima stručnosti (Russel & Norvig, 2010).

Primjer takvog pristupa donose nam Ed Feigenbaum, Bruce Buchanan i Joshua Lederberg sa svojim „DENDRAL“ programom. Razlog zbog kojeg je DENDRAL značajan je da je to prvi uspješan sustav temeljen na znanju (*engl. knowledge-intensive system, knowledge-based system*), a njegova stručnost proizašla je iz velikog broja pravila posebne namjene (Russel & Norvig, 2010).

Potaknuto uspjehom DENDRAL-a, kasniji sustavi također inkorporiraju sličan pristup, odvajanje znanja (u obliku pravila) od zaključivanja. Feigenbaum i Buchanan nastavljaju proučavati novu metodologiju ekspertnih sustava te istražuju u kojoj se mjeri ona može primijeniti na druga područja ljudske stručnosti. Uz pomoć Dr. Edward Shortliffe-a, razvijaju „MYCIN“, program za dijagnozu infekcija krvi. Sa oko 450 pravila, MYCIN je davao rezultate gotovo na razini doktora stručnjaka, a znatno bolje od mladih liječnika (Russel & Norvig, 2010).

Početak 80-ih godina označava kraj prve zime umjetne inteligencije. U tom razdoblju pojavljuje se prvi komercijalni ekspertni sustav R1 koji je pomagao sklapati narudžbe za nove računalne sustave. Procjenjuje se da je do 1986. godine poduzeću Digital Equipment štedio 40 milijuna dolara godišnje. Do 1988. godine gotovo su sve veće američke kompanije uvele ili istraživale ekspertne sustave. Industrija umjetne inteligencije skočila je sa nekoliko milijuna dolara vrijednosti 1980. godine na milijarde dolara 1988. godine, što je uključivalo ekspertne sustave, robotiku, softver i hardver specijaliziran za upotrebu umjetne inteligencije (Russel & Norvig, 2010).

Sredinom 80-ih vraćaju se i algoritmi učenja unatrag, odnosno duboko učenje. Ovi algoritmi primijenjeni su na različite probleme učenja u informatici i psihologiji te su davali impresivne rezultate (Russel & Norvig, 2010).

Ti takozvani konekcionistički modeli (*engl. connectionist models*) inteligentnih sustava smatrali su se direktnom konkurencijom simboličkim modelima koje su zagovarali Newell i Simon te logičkim pristupom McCarthyja i drugih (Smolensky, 1988).

Moderni pristup, međutim, gleda ove modele komplementarno, a ne u suprotnosti. Moderni razvoj neuronskih mreža podijelio se na dva područja. Prvo područje bavi se stvaranjem efikasnih mrežnih arhitektura i algoritama te shvaćanjem njihovih matematičkih svojstava, dok se drugo područje bavi modeliranjem empirijskih svojstava stvarnih neurona i cjelina neurona (Russel & Norvig, 2010).

U metodološkom smislu, krajem 1980-ih, umjetna inteligencija napokon postaje legitimna znanstvena metoda. „Da bi bile prihvaćene, hipoteze moraju biti podvrgnute strogim empirijskim eksperimentima, a rezultati i njihova važnost, moraju biti analizirani statistički“ (Cohen, 1995). Danas je moguće replicirati eksperimente upotrebom dijeljenih repozitorija testnih podataka i računalnog koda.

Taj razvoj metodologije i pristupa umjetnoj inteligenciji vidimo i kod neuronskih mreža. 1980-te godine obilježene su razvojem metodologije i teorijskih okvira neuronskih mreža. Zajednica istraživača neuronskih mreža donijela je zaključak da se neuronske mreže mogu usporediti sa odgovarajućim metodama iz statistike, prepoznavanja uzoraka i strojnog učenja pa je cijela metodologija dubokog učenja evoluirala u tom smjeru. Razvoj umjetne inteligencije i dubokog učenja 1980-ih jedan je od razloga što je tehnologija rudarenja podataka (*engl. data mining*) pokrenula novu snažnu industriju početkom 1990-ih godina (Russel & Norvig, 2010).

Sredinom 90-ih pojavljuju se takozvani inteligentni agenti ili autonomni agenti. Pojam koji označava računalni program koji mora snažno djelovati u brzo mijenjajućim, nepredvidljivim ili otvorenim okruženjima gdje postoji značajna mogućnost da akcije završe neuspjehom (Wooldridge, 2001). Suprotno klasičnim programima i aplikacijama čije je akcije izričito predvidio, planirao i kodirao programer.

Najbolji primjer kompletne arhitekture inteligentnog agenta donose nam Allen Newell, John Laird i Paul Rosenbloom. Arhitektura nazvana „SOAR“ koja se koristi čak i danas. Razvoj inteligentnih agenata potaknut je najviše razvojem interneta (Russel & Norvig, 2010).

Na kraju dolazimo do 21. stoljeća. U zadnjih 20 godina, tehnologija umjetne inteligencije doživljava nevjerojatan rast te se polako širi na gotovo sve grane ljudske djelatnosti. 2000-te godine označavaju preusmjeravanje naglaska sa algoritama koji se koriste u umjetnoj inteligenciji na sve veću dostupnost podataka kao ključnog sastojka uspješnog programa umjetne inteligencije.

Danas postoji veliki broj različitih oblika umjetne inteligencije te različitih oblika neuronskih mreža. Neke od vrsta neuronskih mreža u upotrebi su:

- Konvolucionarna neuronska mreža (*engl. Convolutional Neural Network - CNN*)
- Ponavljajuća neuronska mreža - Duga kratkoročna memorija (*engl. Recurrent Neural Network - Long Short Term Memory [RNN - LSTM]*)
- Višeslojni Perceptron (*engl. Multilayer Perceptron*)
- Modularna neuronska mreža (*engl. Modular Neural Network*)

Ovo su samo neke od neuronskih mreža koje postoje danas, a njihov broj raste i dalje. Svaka od mreža pogodna je za različite zadatke, a ponekad iste mreže imaju različite verzije koje se koriste u različite svrhe. Višeslojni Perceptron koristio se i u ovom radu, a njegov opis i prikaz vidljivi su u poglavlju 4.

U sljedećem potpoglavlju (2.2) navedeni su neki od primjera programa umjetne inteligencije koji su razvijeni u 21. stoljeću, od kojih se mnogi razvijaju i koriste i danas.

2.2. Primjena umjetne inteligencije u 21. stoljeću

Umjetna inteligencija posljednjih godina doživljava dramatičan rast. Razvoj teorija i metodologije primjene umjetne inteligencije, kao i razvoj tehnologije koja je prvi puta u povijesti dovoljno snažna da omogući efikasnu primjenu različitih oblika umjetne inteligencije, omogućili su sve veću primjenu umjetne inteligencije u različitim sferama ljudske djelatnosti, privatne i poslovne.

Izgledno je da će se rast umjetne inteligencije nastaviti te da ćemo vidjeti još veću primjenu te tehnologije u budućnosti. U ovom potpoglavlju navedeni su neki od primjera umjetne inteligencije koji su u upotrebi danas te primjeri umjetne inteligencije koji bi se potencijalno mogli pojaviti u bližoj budućnosti.

Prema Forbesu¹ ovo su neki od najuspješnijih primjera umjetne inteligencije danas:

- **Siri** - Jedan od najpoznatijih primjera umjetne inteligencije je Appleov osobni asistent, Siri. Siri je računalo koje se aktivira pomoću glasovnih naredbi, a sposobna je davati informacije, upute, slati poruke i slično. Siri koristi tehnologiju strojnog učenja kako bi postala bolja i pametnija te sa većom preciznošću predviđela upite te da bi bolje razumjela jezik, pitanja i zahtjeve.
- **Alexa** - Amazonova Alexa, poput Siri, virtualni je asistent koji može glasovno komunicirati sa korisnicima, davati različite informacije, puštati glazbu, zakazivati sastanke, namještati alarme i slično. Alexa trenutno razumije i prima glasovne naredbe na engleskom, njemačkom, francuskom, talijanskom, španjolskom, hindskom i japanskom jeziku.
- **Tesla Autopilot** - Napredni sustav podrške vozačima Teslinih automobila. Ovaj sustav temeljen na umjetnoj inteligenciji sposoban je samostalno voziti, parkirati, promijeniti traku, a vozači ga pritiskom na gumb mogu „dozvati“ iz garaže ili sa parkirnog mjesta. To su samo neke od sposobnosti ovog sustava, a Tesla kompanija obznanila je svoje namjere da ovaj sustav uskoro i unaprijede te da on postane potpuno autonoman sustav vožnje.

¹<https://www.forbes.com/sites/robertadams/2017/01/10/10-powerful-examples-of-artificial-intelligence-in-use-today/#46e63dba420d>

- **Cogito** - Kombinacija strojnog učenja i bihevioralne znanosti, Cogito koristi umjetnu inteligenciju kako bi poboljšao telefonske interakcije korisnika i korisničke podrške. Čak je i DARPA financirala razvoj ove platforme, a danas Cogito koristi umjetnu inteligenciju u kombinaciji sa bihevioralnim modelima kako bi interpretirao ljudsko psihološko stanje i ponudio adekvatno rješenje u komunikaciji sa korisnicima te je vodeće rješenje u području korisničke podrške.
- **Boxever** - kompanija i proizvod koji se snažno oslanjaju na strojno učenje u području turizma. Boxever je inovativna personalizacijska platforma koja donosi odluke na temelju umjetne inteligencije. Osim umjetne inteligencije, koristi podatke i analitiku za prilagođavanje interakcija sa korisnicima na temelju njihove povijesti, onoga što trenutno rade i onoga što žele postići.
- **John Paul** - cijenjena concierge tvrtka za luksuzna putovanja, još je jedan moćan primjer umjetne inteligencije u komercijalnoj upotrebi. Služi za interakciju sa gostima, a koristi algoritme za predviđanje kako bi predvidio potrebe i želje gostiju. John Paul daje concierge usluge milijunima kupaca kroz najveće svjetske kompanije poput VISA, Orange i Air France.
- **Amazon.com** - Amazonov transakcijski softver temeljen na umjetnoj inteligenciji i dubokom učenju postoji već dugo vremena, a svoje algoritme i efikasnost nadograđuje iz godine u godinu. Mozak Amazon.com-a i drugih amazonovih usluga već sada sa velikom preciznošću predviđa navike i želje kupaca, a iz godine u godinu Amazon ulaže u razvoj i unaprjeđivanje svoje umjetne inteligencije.
- **Netflix** - Netflix svojom umjetnom inteligencijom pruža visoko preciznu prediktivnu uslugu preporuke materijala koje nudi na svojoj platformi, koja se temelji na prijašnjim reakcijama korisnika. Analizira milijarde zapisa kako bi sugerirao materijal svojim korisnicima, a kao i prethodni primjer, iz godine u godinu postaje sve efikasniji.
- **Pandora** - Pandora je jedna od prvih, a definitivno najefikasnija muzička platforma, koja koristiti vlastite algoritme dubokog učenja za analizu slušatelja i ciljanu ponudu glazbe.
- **Nest** - Nest je termostat koji uči. To je elektronički, programibilni, wi-fi termostat koji je sposoban učiti kako bi optimizirao grijanje i hlađenje prostora te uštedio potrošnju energije.

Navedeni primjeri su neki od najpoznatijih primjera umjetne inteligencije danas, ali naravno, nisu jedini. Neki od primjera vrijedni spomena su: IBM-ov Deep Blue, superračunalo koje je 1997. u šahu pobijedilo svjetskog šahovskog prvaka Garry Kasparova. Također IBM-ov, Watson, računalni sustav stvoren za odgovaranje na pitanja postavljena prirodnim jezikom. Prvobitno je razvijen za natjecanje na televizijskom kvizu „Jeopardy!“, na kojem 2011. godine pobjeđuje dva tadašnja prvaka. Danas se koristi kao podrška odlučivanju u tretmanu raka pluća u centru za liječenje raka u New Yorku. Googleov AlphaGO 2016. godine svladava svjetskog prvaka igre Go, Lee Sedol. Pobjeda koja je još impresivnija od pobjede Deep Bluea u šahu, budući da je igra Go puno složenija.

U svrhu optimizacije poslovnih aktivnosti, umjetnu inteligenciju danas koristi veliki broj kompanija. Kompanije različitih veličina, umjetnu inteligenciju koriste za analizu i povećanje prodaje, analizu tržišta, analizu navika potrošača, otkrivanje prijevare, poboljšanja korisničkog iskustva, automatizaciju procesa, prediktivnu analizu i dr.

Sposobnosti umjetne inteligencije ograničene su samo ljudskom maštovitosti, a svakim danom, pronalazi se sve više mogućih primjena ove tehnologije te sve više organizacija primjećuje koristi i potencijal ove tehnologije.

2.3. Definiranje dubokog učenja i neuronskih mreža

2.3.1. Uvod u duboko učenje

Duboko učenje specifično je područje strojnog učenja: novi pristup učenju iz podataka koji stavlja naglasak na učenje iz uzastopnih slojeva rastuće značajnih reprezentacija (Chollet, 2018).

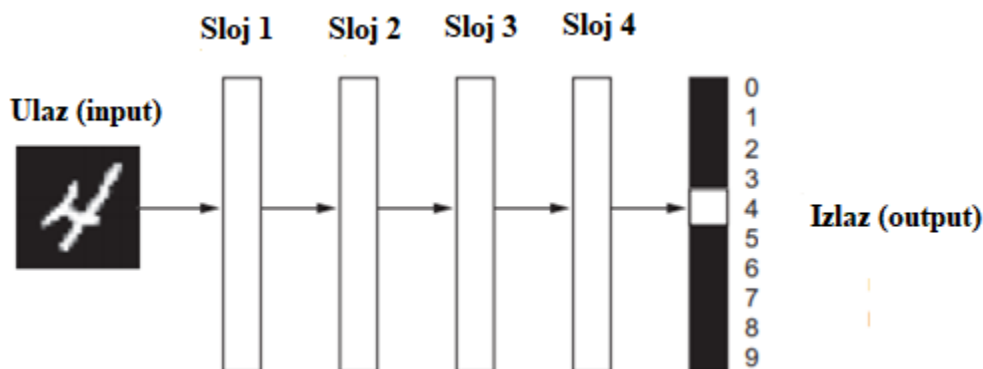
Duboko kod dubokog učenja ne znači dublje razumijevanje proizašlo takvim pristupom, već predstavlja ideju uzastopnih slojeva reprezentacija, a koliko slojeva čini neki model podataka zove se dubina modela (Chollet, 2018).

Moderno duboko učenje često uključuje desetke ili čak stotine uzastopnih slojeva reprezentacije, a svi oni uče se automatski pri izlaganju testnim podacima. Istovremeno, drugi pristupi strojnom učenju obično se fokusiraju na učenje koristeći samo jedan ili dva sloja reprezentacije podataka, stoga ih ponekad zovemo plitko učenje (*engl. shallow learning*) (Chollet, 2018).

U dubokom učenju, spomenuti slojevi reprezentacija uče se gotovo uvijek putem modela zvanog neuronske mreže, ili umjetne neuronske mreže (*engl. artificial neural network - ANN*). Neuronske mreže referenca su na neurobiologiju, i iako su neki od ključnih koncepata razvijeni temeljem našeg razumijevanja ljudskog mozga, modeli dubokog učenja nisu modeli mozga te nemaju nikakvu direktnu poveznicu sa načinom na koji ljudski mozak uči (Chollet, 2018).

Jednostavno, duboko učenje matematički je okvir za učenje reprezentacija iz podataka (Chollet, 2018), a kako algoritmi dubokog učenja izgledaju vidljivo je na slikama 1 i 2.

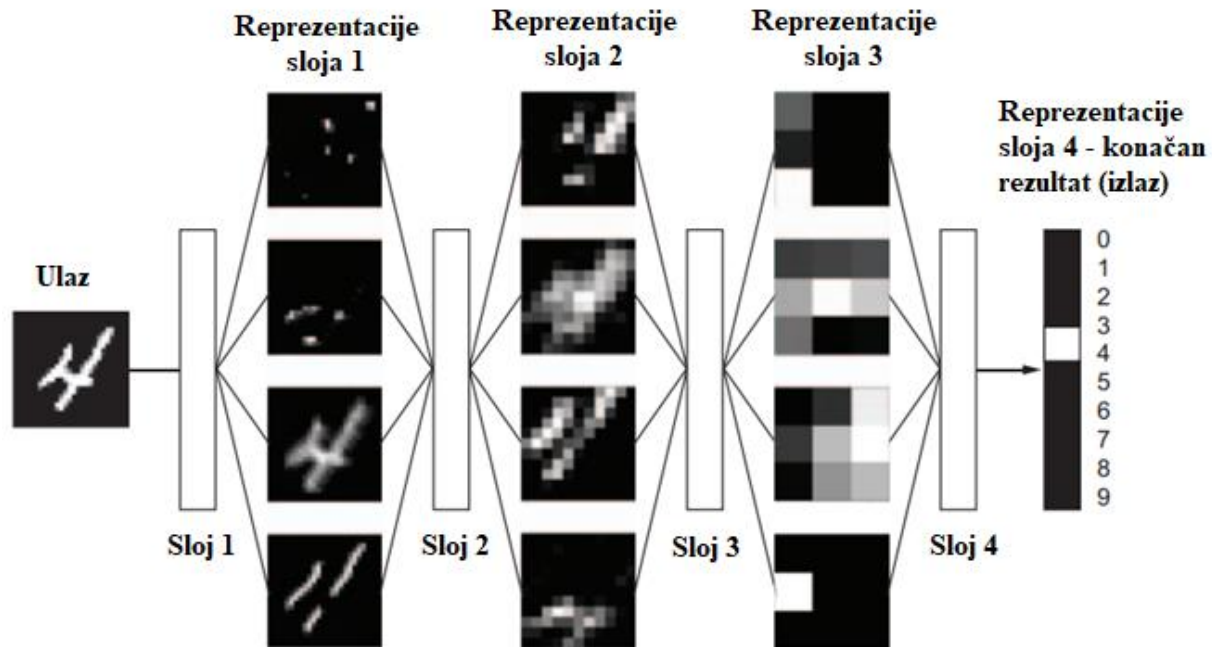
Slika 1. Duboka neuronska mreža za klasifikaciju znamenki



Izvor: (Chollet, 2018)

Slika 1. predstavlja osnovni model neuronske mreže za klasifikaciju znamenki, koje računalo putem dubokog učenja pokušava prepoznati. Početna slika predstavlja ručno napisanu znamenku, a slojevi 1-4 (Layer 1, 2, 3, 4) slojevi su reprezentacija koji poboljšavaju razumijevanje početne slike. Ti slojevi zovu se i skriveni slojevi (*engl. hidden layers*). Tumačenjem reprezentacija podataka računalo pronalazi rješenje, odnosno interpretira početni unos, tj. sliku.

Slika 2. Duboke reprezentacije naučene modelom klasifikacije znamenki



Izvor: (Chollet, 2018)

Kao što možemo vidjeti na slici 2., mreža pretvara sliku znamenke u reprezentacije koje su postepeno drugačije od početne, ali sve informativnije o konačnom rezultatu, odnosno izlazu (Chollet, 2018).

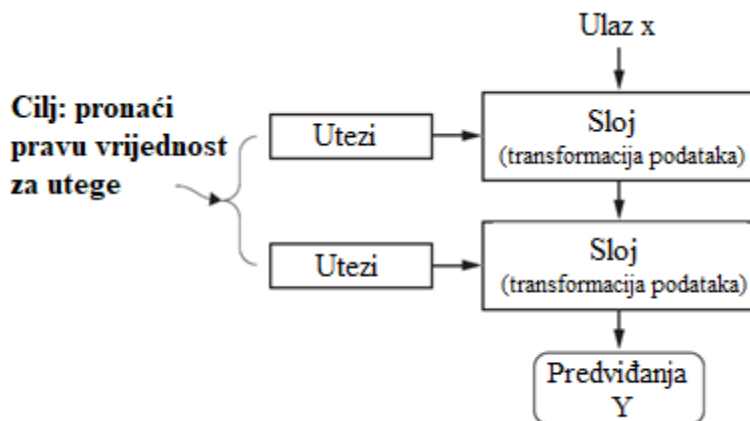
Dakle, duboko učenje je višeslojni način učenja reprezentacija podataka. Vrlo jednostavna ideja - ali, kako se čini, vrlo jednostavni mehanizmi, proporcionalno i dovoljno uvećani, mogu se primijeniti na nevjerovatan broj zadataka (Chollet, 2018).

2.3.2. Kako duboko učenje funkcionira

Dakle, duboko učenje odnosi se na mapiranje ulaza (poput slike) ka ciljevima (poput oznake „brojka“), što se čini promatranjem i analizom mnogih primjera unosa i ciljeva. Također je bitno naglasiti da duboke neuronske mreže rade ovo ulaz-u-cilj mapiranje putem dubokog slijeda jednostavnih transformacija podataka (slojeva) i da se te transformacije uče izlaganjem primjerima (Chollet, 2018).

Pogledajmo sada kako se to učenje zapravo događa u praksi. Specifikacija onoga što sloj čini sa svojim ulaznim podacima pohranjena je u „utezima“ sloja. Utezi sloja duboke neuronske mreže u principu su parametri sloja, a transformacija koju provodi određeni sloj parametrizira se prema težini (slika 3.). Dakle, učenje u biti predstavlja pronalaženje skupa vrijednosti za sve utege svih slojeva mreže, kako bi mreža ispravno mapirala primjere ulaza njihovim pridruženim ciljevima.


Slika 3. Parametrizacija neuronskih mreža utezima



Izvor: (Chollet, 2018)

Za kontrolu izlaza neuronske mreže, mora postojati način mjerenja i usporedbe dobivenih rezultata od očekivanih kako bi se napravile korekcije, odnosno kako bi neuronska mreža mogla učiti. Tu nastupa funkcija gubitka (*engl. loss function*) neuronske mreže. Funkcija gubitka uzima rezultate, odnosno predviđanja, neuronske mreže te stvarni cilj i izračunava udaljenost među njima. Pri tome dodjeljuje brojčanu vrijednost udaljenosti predviđenog i stvarnog cilja te time mjeri uspješnost neuronske mreže (slika 4.).

Slika 4. Mjerenje kvalitete izlaza neuronske mreže (funkcija gubitka)



Izvor: (Chollet, 2018)

Temeljno obilježje dubokog učenja je korištenje ovog rezultata kao povratnog signala za prilagodbu vrijednosti utega kako bi se smanjila vrijednost funkcije gubitka (slika 5.). Za to služi takozvani optimizator koji implementira ono što se naziva algoritmom s povratnim postupkom (*engl. backpropagation algorithm*).

U početku, utezima neuronskih mreža pridružuju se nasumične vrijednosti, tako da neuronska mreža provodi nasumične transformacije. Naravno, rezultat mreže daleko je od onoga što bi trebao biti, a vrijednost funkcije gubitka vrlo je visoka. Ali, sa svakim primjerom kojeg mreža procesuirala, utezi se podešavaju, a vrijednost funkcije gubitka smanjuje se. To je takozvana petlja učenja (*engl. training loop*), koja, kada se ponovni dovoljan broj puta (tipično desetak iteracija preko tisuća primjera), daje optimalnu vrijednost utega koja minimizira vrijednost funkcije gubitka. Mreža sa minimalnom vrijednosti gubitka je ona čiji je rezultat maksimalno blizu ciljanom rezultatu. To je istrenirana, odnosno naučena, mreža. (Chollet, 2018).

2.3.3. Revolucija dubokog učenja

Pitanje koje se postavlja, zašto je duboko učenje toliko napredovalo te postalo jedno od najvažnijih oblika strojnog učenja, odnosno umjetne inteligencije, danas? Odgovor se može dati kroz 5 stavki koje obilježavaju revoluciju dubokog učenja u 21. stoljeću, a ovo potpoglavlje dati će kratak pregled tih stavki.

Prvi faktor nedavnog razvoja umjetne inteligencije općenito, a onda i dubokog učenja, jest hardver.

Između 1990. godine i 2010. procesna snaga računala povećala se za otprilike 5000 puta. Kao rezultat, danas je moguće pokretati manje modele dubokog učenja na običnom prijenosnom računalu, dok je to, ne tako davno, bilo nemoguće (Chollet, 2018).

Naravno, tipični modeli dubokog učenja koji se koriste za prepoznavanje govora ili računalnog vida koriste daleko veću procesnu snagu od običnog prijenosnog računala. Osim procesne snage, razvoj umjetne inteligencije potaknuto je razvojem različitih tehnologija poput CUDA sučelja (2007) kompanije NVIDIA (<https://developer.nvidia.com/about-cuda>). CUDA je sastavni dio NVIDIA grafičkih kartica (*engl. GPU - graphical processing unit*), a razlog zbog kojeg igra bitnu ulogu u razvoju dubokog učenja, je taj što takvi grafički čipovi imaju sposobnost efikasnog pokretanja visoko paralelnih aplikacija. Duboke neuronske mreže, koje se uglavnom sastoje od manjih matričnih množenja, također su vrlo paralelizirane. 2011. godine istraživači dubokog učenja počinju razvijati CUDA implementacije neuronskih mreža (Chollet, 2018).

Drugi faktor razvoja dubokog učenja su svakako podaci. Kada su u pitanju podaci, u kombinaciji sa eksponencijalnim razvojem uređaja za pohranu podataka, najveći utjecaj imao je svakako razvoj interneta koji je omogućio prikupljanje i distribuciju vrlo velikih skupova podataka (*engl. datasets*) za strojno učenje. Danas, velike kompanije koriste i obrađuju skupove podataka koji uključuju slike, video i tekst, a koje ne bi bilo moguće prikupiti bez interneta (Chollet, 2018).

Iz toga je proizašlo i rudarenje podataka (*engl. data mining*) koje igra veliku ulogu u bilo kakvim prognostičkim modelima pa tako i pri primjeni neuronskih mreža.

„Rudarenje podataka je nova metodologija kojom se otkrivaju vrijedni podaci u bazama podataka poduzeća. Metoda se naziva rudarenje podataka, jer se u velikim količinama podataka traže informacije koje 'vrijede zlata'.“ (Pejić Bach, 2005).

Pored hardvera i podataka, najveću ulogu u razvoju dubokog učenja imaju algoritmi. Sve do kraja 2000-tih godina, nije postojao efikasan i pouzdan način za treniranje dubokih neuronskih mreža. Kao posljedica toga, neuronske mreže bile su prilično plitke te su koristile samo jedan ili dva sloja reprezentacija.

Sve se to promijenilo 2009-2010 razvojem nekoliko jednostavnih ali bitnih algoritmičkih poboljšanja koja su omogućila bolje širenje gradijenata (Chollet, 2018):

- Bolje funkcije aktiviranja neuronskih slojeva
- Bolje sheme inicijalizacije težine
- Bolje optimizacijske sheme, kao što su RMSProp i Adam

Tek kada su ova poboljšanja omogućila modele učenja sa 10 i više slojeva, duboko učenje je napokon krenulo u brzi rast i razvoj. Nadalje, u 2014., 2015. i 2016. godini otkriveni su još napredniji načini za pomoć širenju gradijenata, kao što su normalizacija serija podataka (*engl. batch normalization*), preostali priključci (*engl. residual connection*) i konvolucije djeljive po dubini (*engl. depthwise separable convolutions*), a danas iz nule možemo istrenirati neuronsku mrežu sa tisućama slojeva (Chollet, 2018).

Kako je duboko učenje postalo novo umijeće za računalni vid u 2012-2013, i na kraju, za sve perceptivne zadatke, voditelji industrije primili su to na znanje. Ono što je uslijedilo bilo je postupan val ulaganja u industriju daleko veći od svega viđenog u povijesti umjetne inteligencije (Chollet, 2018).

2011. godine, prije revolucije dubokog učenja, ukupno kapitalno ulaganje u umjetnu inteligenciju po procjeni bilo je oko 19 milijuna dolara, što je gotovo u potpunosti išlo na praktične primjene plitkih pristupa strojnog učenja. Do 2014. godine porastao je na zapanjujućih 394 milijuna dolara. Deseci startupa pokrenuti su u te tri godine, pokušavajući iskoristiti prilike koje je duboko učenje nudilo. U međuvremenu, velike tehnološke kompanije poput Googlea, Facebooka, Baidua i Microsofta također ulažu u razvoj internih istraživačkih odjela u svrhu primjene dubokog učenja.

Kao posljedica ovog vala investicija, broj ljudi u industriji skočio je sa nekoliko stotina na desetke tisuća u samo pet godina (Chollet, 2018).

Prema Forbesu², u 2018. godini ukupna vrijednost industrije dubokog učenja iznosila je 24 milijarde dolara. To je ujedno i četvrti faktor koji je potaknuo revoluciju dubokog učenja.

Kao posljednji faktor, dolazi nam demokratizacija dubokog učenja. Jedan od glavnih faktora povećanja zajednice dubokog učenja i pristizanja novih stručnjaka jest demokratizacija alata potrebnih za razvoj metoda dubokog učenja. U početku, obavljanje bilo kakvog zadatka pomoću dubokog učenja zahtijevalo je znatne vještine C++ jezika, a kasnije i CUDA vještine, što je posjedovalo vrlo malo ljudi. Danas su za iste zadatke dovoljne osnovne vještine programskog jezika Python. Te iste vještine dovoljne su i za naprednije proučavanje dubokog učenja (Chollet, 2018).

To je ponajviše vođeno razvojem Theano-a i TensorFlow-a, dva simbolička tenzor-manipulacijska okvira za Python koji podržavaju autodiferencijaciju, uvelike pojednostavljujući primjenu novih modela. Osim njih, veliku ulogu igra i porast knjižnica prilagođenih korisnicima, poput Kerasa, što duboko učenje čini puno jednostavnijim nego u prošlosti (Chollet, 2018).

Za kraj, bitno je spomenuti zašto je duboko učenje predvodnik revolucije umjetne inteligencije općenito, i koja su to točno obilježja koja duboko učenje čine tako moćnim.

Ta obilježja široko se mogu svrstati u tri kategorije (Chollet, 2018):

- Jednostavnost
- Skalabilnost
- Svestranost i ponovna upotrebljivost

²<https://www.forbes.com/sites/louiscolombus/2019/03/27/roundup-of-machine-learning-forecasts-and-market-estimates-2019/#b7594b67695a>

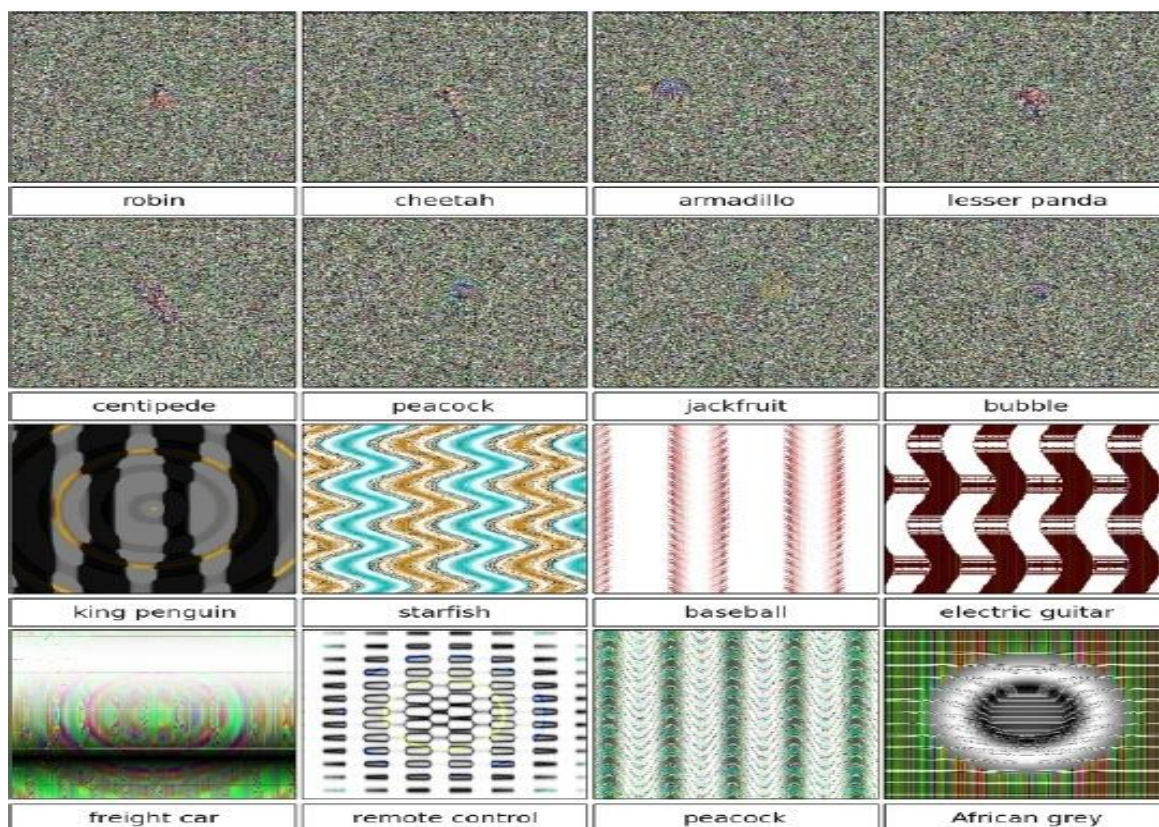
2.4. Kritike i komentari na duboko učenje

Iako neuronske mreže i duboko učenje u posljednje vrijeme postižu vrhunske rezultate na raznim zadacima (npr. prepoznavanje uzoraka, razumijevanje prirodnog jezika, detektiranje anomalija i sl.) postoje i neke negativne strane ove tehnologije koje treba uzeti u obzir prilikom bilo kakve primjene metoda dubokog učenja.

Najznačajnije negativne strane, odnosno kritike koje duboko učenje dobiva usprkos uspjesima su pogreške i interpretabilnost rezultata.

Što se grešaka tiče, nedavna studija otkrila je veliku razliku između „vida“ dubokih neuronskih mreža i ljudi (Szegedy, i dr., 2014). Promjena slike (kodiranje), izvorno ispravno klasificirane (npr. kao lav), na način neprimjetan ljudskom oku, može uzrokovati da duboka neuronska mreža sliku klasificira kao nešto potpuno drugačije (npr. sliku lava klasificira kao knjižnicu) (Nguyen, Yosinski, & Clune, 2015). Primjer te pogrešne klasifikacije vidljiv je na slici 5.

Slika 5. Pogrešna klasifikacija objekata nakon promjene (kodiranja) slika



Izvor: (Nguyen, Yosinski, & Clune, 2015)

Osim grešaka, interpretabilnost rezultata također je jedan od razloga zbog kojeg duboko učenje, a i umjetna inteligencija općenito, primaju kritike.

Iako modeli dubokog učenja dostižu impresivne točnosti predviđanja, ugniježdjena nelinearna struktura čini ih vrlo netransparentnim, tj. nije jasno koje informacije u ulaznim podacima utječu na donošenje odluka. Stoga se ovi modeli obično smatraju crnim kutijama (*engl. black box*) (Samek, Wiegand, & Müller, 2017).

37. potez u drugoj igri povijesne Go partije između Go prvaka Lee Sedol-a i AlphaGo-a, DeepMind-ovog sustava umjetne inteligencije, primjer je netransparentnosti umjetne inteligencije. AlphaGo odigrao je potez koji je bio potpuno neočekivan, a koji su Go stručnjaci komentirali na sljedeći način (Samek, Wiegand, & Müller, 2017):

„To nije ljudski potez. Nikada nisam vidio da je čovjek odigrao takav potez.“ (Fan Hui, 2016).

Taj potez, iako ljudima neshvatljiv, bio je presudan za pobjedu AlphaGo u igri. U ovom slučaju karakteristika crne kutije AlphaGo sustava nije bila važna, ali u mnogim aplikacijama nemogućnost razumijevanja i potvrđivanja postupaka odlučivanja sustava umjetne inteligencije jasan je nedostatak. Na primjer, u medicinskoj dijagnozi bilo bi neodgovorno vjerovati predviđanjima sustava crne kutije bez da je dostupna odgovarajuća provjera valjanosti od strane ljudskog stručnjaka za svaku dalekosežnu odluku (Samek, Wiegand, & Müller, 2017).

Usprkos manama koje duboko učenje za sada još posjeduje, ova tehnologija može se itekako efikasno primijeniti u različitim područjima. Jedno takvo područje je i analiza i predviđanje tržišta dionica, koje je tema ovoga rada. U 3. poglavlju prezentiran je model dubokog učenja za analizu i predviđanje tržišta dionica, ali prije toga (poglavlje 2) daje kratak pregled postojećih analiza na tržištu dionica.

3. TRŽIŠTE VRIJEDNOSNIH PAPIRA

Kako bi primjena metoda dubokog učenja (dubokih neuronskih mreža) bila efikasna, u obzir treba uzeti cijelo tržište vrijednosnih papira, a pogotovo analize koje se koriste pri ulaganju na istom. Ovo poglavlje dati će kratki uvod u tržište vrijednosnih papira, kratak pregled fundamentalne i tehničke analize, njihov opseg i ograničenja te prednosti i nedostatke. Ovi aspekti analiza uzeti će se u obzir pri izradi modela dubokog učenja koji će ih nadopuniti, a koji je tema ovog rada.

Tržište vrijednosnica (vrijednosnih papira) je mjesto gdje se susreću ponuda i potražnja po vrijednosnim papirima i gdje su pravila trgovanja uglavnom unaprijed određena (ovisno da li je tržište organizirano ili ne). Drugim riječima, to je mjesto na kojem se susreću burzovni posrednici i u ime svojih klijenata ili sebe kupuju i prodaju dionice i druge vrijednosnice³.

Ukratko, dionica je vlasnički vrijednosni papir koji predstavlja pravo vlasništva u određenom dioničkom društvu. Prema pravima koja daju, razlikuju se dva roda dionica: redovne i povlaštene dionice. Redovne dionice daju imateljima pravo glasa na glavnoj skupštini dioničkog društva, pravo na isplatu dijela dobiti (dividendu) i pravo na isplatu vrijednosti ostatka imovine nakon likvidacije društva. Povlaštene dionice daju svojim imateljima neka povlaštena prava, npr. pravo na dividendu u unaprijed utvrđenom novčanom iznosu. Cijenu dionica određuje ponuda i potražnja, a one se mogu kupiti ili prodati na uređenom tržištu ili izvan njega⁴.

Previše ljudi pristupa tržištu dionica s fokusom na brzu zaradu. Takva orijentacija uključuje nagađanja, a ne ulaganja i temelji se na nadi da će cijene dionica rasti bez obzira na procjenu vrijednosti. Špekulanti uglavnom dionice smatraju komadima papira kojima treba brzo trgovati naprijed i nazad, bezumno ih razdvajajući od poslovne stvarnosti i kriterija vrednovanja (Graham & Dodd, 2008).

Suprotno špekulativnoj preokupaciji brzom zaradom, (vrijednosni) investitori pokazuju svoju averziju riziku nastojeći izbjeći gubitak. Investitori s averzijom prema riziku oni su investitori za koje je percipirana korist bilo koje dobiti nadmašena percipiranim troškom ekvivalentnog gubitka (Graham & Dodd, 2008), a model u 4. poglavlju ovog rada u velikoj je mjeri namijenjen njima.

³ <http://www.ekonomskirjecnik.com/definicije/trziste-vrijednosnica.html>

⁴ <http://www.hanfa.hr>

3.1. Opseg i ograničenja analize vrijednosnih papira

Analiza podrazumijeva pažljivo proučavanje dostupnih činjenica s pokušajem da se iz njih izvuku zaključci temeljeni na ustaljenim principima i zdravoj logici. Ona je dio znanstvene metode. Ali u primjeni analize u području vrijednosnih papira susrećemo se s ozbiljnom preprekom - ulaganje po prirodi nije egzaktna znanost (Graham & Dodd, 2008). Međutim, područje ulaganja, iako djelomično ovisi o vjerojatnosti, ovisi i o individualnoj vještini (umijeću), a analiza ne samo da je korisna već je neophodna.

Iako kvalitetna analiza ne može jamčiti siguran dobitak (uvijek postoji faktor sreće), ona je važan alat vrijednosnim investitorima te donekle može umanjiti rizik ulaganja.

Cilj analize vrijednosnih papira je odgovoriti, ili pomoći pri odgovoru, na pitanja praktične prirode. Od tih pitanja, možda i najčešća su: Koje vrijednosne papire treba kupiti u određenu svrhu? Treba li vrijednosni papir S kupiti, prodati, ili zadržati? (Graham & Dodd, 2008).

Kod svih takvih pitanja, četiri glavna faktora igraju presudnu ulogu, izričito ili implicitno (Graham & Dodd, 2008):

1. Vrijednosni papir
2. Cijena
3. Vrijeme
4. Osoba

Preciznije rečeno, drugo najčešće pitanje glasil bi: Treba li kupiti (prodati, ili zadržati) vrijednosni papir S, po cijeni P, u vremenskom razdoblju T, osoba I.

Odgovor ili odgovore na takva pitanja obično daju različite analize vrijednosnih papira, koje će biti opisane u nastavku ovog poglavlja.

3.2. Investitorski pristup

Promatranje vrijednosnih papira iz perspektive ulagača, odnosno investitora. Pristup koji je dio efikasnog upravljanja investicijama, a razmatra vrijednosne papire kroz emisiju do kupnje i prodaje na tržištu. Duga je povijest izučavanja vrijednosnih papira, a do danas ono je postalo zasebna znanstvena disciplina, koju nazivamo investitorski pristup, investicijska analiza, upravljanje portfoliom i dr. (Orsag, 2015).

Predstavljeni model neuronske mreže (poglavlje 4), odnosno duboko učenje općenito, u pogledu analize i predviđanja cijena dionica, potencijalno je unaprjeđenje ovog pristupa kao nadopuna postojećim analizama, tehničkoj i fundamentalnoj (pogotovo tehničkoj, iako se naprednije mreže mogu primijeniti i na fundamentalnu). Kao zasebna analiza, duboko učenje još nije dovoljno razvijeno, međutim, izgledno je da će u skorijoj budućnosti, neuronske mreže igrati sve veću ulogu u analizi vrijednosti dionica, sudeći po nedavnim istraživanjima i razvoju dubokog učenja, i umjetne inteligencije općenito, u posljednjih nekoliko godina.

Kao što je već spomenuto, analiza vrijednosnih papira može se podijeliti na dva temeljna pravca, tehničku i fundamentalnu analizu.

3.2.1. Fundamentalna analiza

U pogledu analize vrijednosnih papira i efikasnog investiranja u iste, fundamentalna analiza uključuje analizu cjelokupnih industrija, ili pojedinih industrijskih grana, međunarodnih industrijskih kretanja, inflacije i sl. Kod analize dioničkih društva analizira se njihovo poslovanje temeljem javno dostupnih financijskih izvještaja i drugih javnih informacija bitnih za njihovo poslovanje. Pri tome se koriste različiti standardizirani pokazatelji koji su javno dostupni, i koji se prate kontinuirano. Glavni cilj fundamentalne analize je, na temelju različitih pokazatelja, utvrditi koji to čimbenici utječu na određenu cijenu vrijednosnog papira, te otkriti one vrijednosne papire koji su precijenjeni ili podcijenjeni u svrhu ostvarivanja prinosa (Orsag, 2015).

3.2.2. Tehnička analiza

Tehnička analiza koristi se pri analizi različitih uvjeta na tržištu kapitala, poput promjena cijene, volumena razmjene, ponude i potražnje itd. Svi ti uvjeti grafički se prikazuju i obrađuju kako bi se pronašlo najbolje vrijeme za djelovanje, bilo to kupnja ili prodaja. Također se koriste i indikatori tržišta kapitala poput Dow Jones Industrial Averages, S&P 500 Indeks (Standard & Poors), NASDAQ i dr. (Orsag, 2015).

Tehnička analiza vrlo je korisna kod određivanja optimalnog vremena kupnje, odnosno prodaje vrijednosnih papira, posebno dionica te se vrlo često koristi u praksi, doduše, češće za praćenje različitih trendova nego li za konkretnu kupnju i prodaju. U tu svrhu, tehničkoj analizi karakteristična je intenzivna uporaba različitih grafikona poput linijskih grafikona, histograma i dr., a razvila su se i različita tehnička pomagala kao podrška očitavanju trendova i vremena za kupnju i prodaju (Orsag, 2015).

Jednostavnije neuronske mreže više odgovaraju tehničkoj analizi, budući da je uvjete i indekse koji se promatraju putem tehničke analize puno lakše zabilježiti, preuzeti i učitati u neuronsku mrežu. Takav slučaj je i kod modela u ovom radu. Preuzeti data set sadrži različite podatke sa burze (NASDAQ), što je ovoj neuronskoj mreži dovoljno da napravi jednostavne prognoze. Kod fundamentalne analize, prikupljanje podataka bilo bi nešto teže, ali ne nemoguće. Više o primjeni neuronske mreže u nastavku.

4. PRIMJENA DUBOKOG UČENJA NA TRŽIŠTE DIONICA

4.1. Priprema podataka za potrebe analize upotrebom neuronske mreže

Podaci za potrebe analize preuzeti su sa web stranice finance.yahoo.com⁵, a uključuju povijesne cijene AMD dionica, kompanije Advanced Micro Devices, Inc, na NASDAQ burzi dionica. To je američka kompanija sa sjedištem u Kaliforniji, a bavi se proizvodnjom računalnih procesora, grafičkih kartica i povezanih tehnologija za poslovno i potrošačko tržište.

Preuzeti skup podataka (dataset) sadrži dnevne podatke o početnoj cijeni, najvišoj cijeni, najnižoj cijeni, zaključnoj cijeni, podešenoj zaključnoj cijeni dionica te broju transakcija, od 1. rujna 2017. godine do 1. rujna 2019. godine.

Taj skup podataka služiti će kao testni podaci na kojima će neuronska mreža „učiti“, i onda pokušati predvidjeti buduće kretanje cijena, od 1. rujna 2019. godine do 15. rujna 2019. godine nakon čega će se usporediti stvarne cijene (od 1. do 15. rujna 2019.) i cijene koje je predvidjela neuronska mreža.

Povijesni podaci preuzeti sa finance.yahoo.com prikazani su na slici 6.

Slika 6. Povijesni podaci AMD dionica (1.9.2017 - 1.9.2019)



Izvor: finance.yahoo.com

⁵<https://finance.yahoo.com/quote/AMD/history?period1=1504216800&period2=1567288800&interval=1d&filter=history&frequency=1d>

4.2. Karakteristike podataka iz dataset-a

Kao što je navedeno u prethodnom poglavlju, preuzeti dataset sadrži dnevne podatke o početnoj cijeni, najvišoj cijeni, najnižoj cijeni, zaključnoj cijeni, podešenoj zaključnoj cijeni dionica te broju transakcija, od 1. siječnja 2000. godine do 31. prosinca 2018. godine. Dakle, dataset sadrži 7 atributa te 503 instance.

6 atributa iskazano je numerički i 1 atribut je nominalni (datum) a u nastavku dan je kratki opis njihovih karakteristika (tablica 2) i grafički prikaz (slika 7).


Tablica 2. Karakteristike podataka

Naziv atributa	Opis atributa	Format atributa
Datum trgovanja	Označava dane kada je burza otvorena i kada se na njoj trguje	Nominalni
Početna cijena dionice	Cijena po kojoj se dionicom trguje po otvaranju burze	Numerički
Najviša cijena dionice	Najviša cijena po kojoj se dionicom trgovalo kroz određeni period. Pokazatelj kojeg neki investitori vide kao važan faktor u određivanju trenutne vrijednosti i budućeg kretanja cijena.	Numerički
Najniža cijena dionice	Najniža cijena po kojoj se dionicom trgovalo kroz određeni period. Pokazatelj kojeg neki investitori vide kao važan faktor u određivanju trenutne vrijednosti i budućeg kretanja cijena.	Numerički

Zaključna cijena dionice	Zadnja cijena po kojoj se dionicom trgovalo tijekom redovnog dana trgovanja. Zaključna cijena dionice je standardna referentna vrijednost koju investitori koriste za praćenje uspješnosti tijekom vremena te predmet predviđanja modela u ovom radu.	Numerički
Podešena zaključna cijena dionice	Podešena cijena zatvaranja prilagođava cijenu zatvaranja dionica tako da točno odražava vrijednost dionice.	Numerički
Broj transakcija	Količina dionica kojima se trgovalo na tržištu tijekom određenog razdoblja.	Numerički

Izvor: Izrada autora

Slika 7. Grafički prikaz atributa



Izvor: (Weka 3.8.3., 2018)

4.3. Metodologija rada

Budući da je upotreba modela dubokog učenja, odnosno neuronskih mreža, iznimno kompleksan proces, koji zahtjeva značajne investicije, znanje i vrijeme, kako bi se neuronska mreža sagradila, naučila i testirala, cilj ovog rada predstaviti je jednostavan model neuronske mreže kao primjer upotrebe dubokog učenja u području predviđanja budućih kretanja, u ovom slučaju cijena.

Kao što je spomenuto u prethodnim poglavljima, postoji više vrsta neuronskih mreža koje mogu prihvaćati različite podatke kako bi riješile različite zadatke. Radi jednostavnosti, u ovom radu, koristiti će se već izgrađena neuronska mreža koja će podatke analizirati preko modela vremenskih serija kako bi pokušala predvidjeti buduće kretanje cijena dionica.

Dakle, predmet rada usporedba je stvarnih cijena AMD dionica od 1.9.2019. do 15.9.2019. sa cijenama previđenim modelom neuronskih mreža, a za potrebe ovog rada, preuzeti dataset analizirat će se pomoću „Weka“ softvera⁶, upotrebom modela vremenskih serija (engl. time series) primjenom neuronske mreže pod nazivom, višeslojni perceptron (engl. multilayer perceptron).

Bitno je naglasiti, da ova neuronska mreža i podaci koji su korišteni u izradi ovog modela samo su jednostavni prikaz principa po kojem neuronska mreža djeluje. Za daljnje dubinske analize i preciznije predviđanje kretanja cijena, potrebno bi bilo programirati novu neuronsku mrežu, koja bi u obzir uzimala puno više faktora te koju bi se trebalo trenirati u više faza na različitim podacima.

4.3.1. Weka

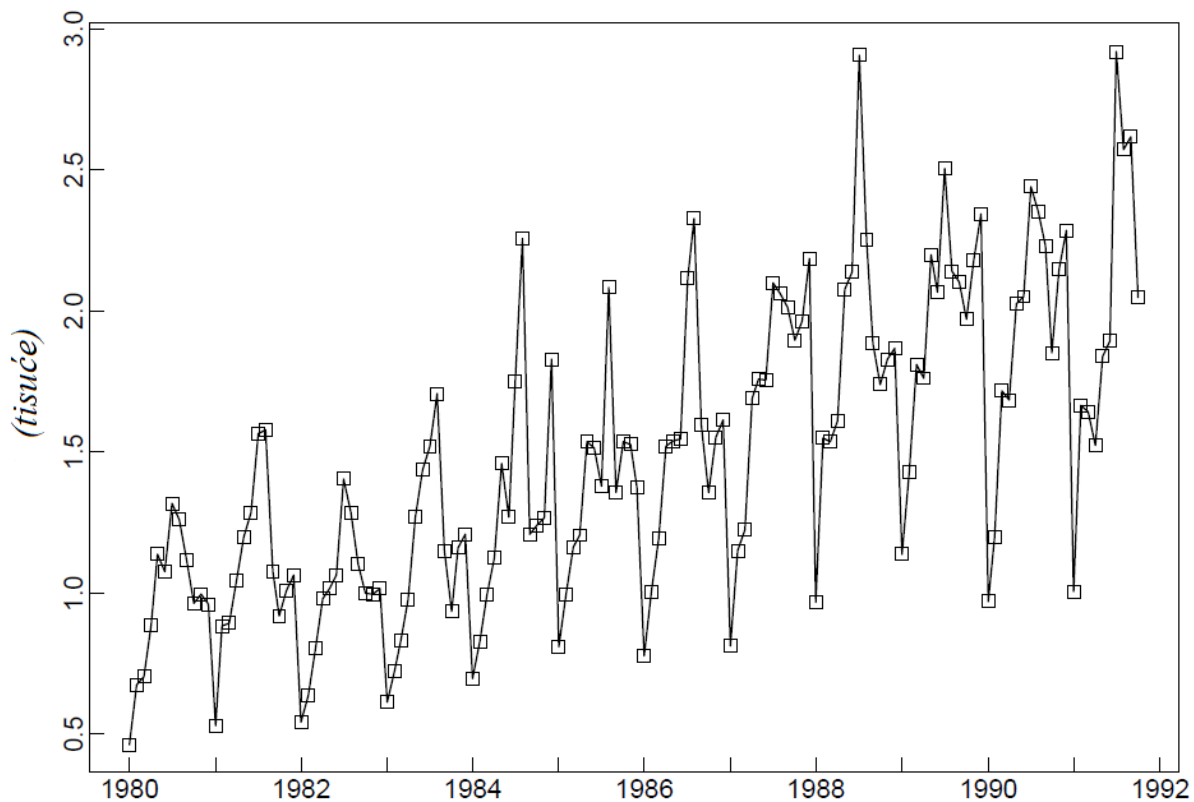
Weka (Waikato Environment for Knowledge Analysis) je kolekcija algoritama strojnog učenja primarno namijenjena zadacima rudarenja podataka. Sadrži alate za pripremu podataka, klasifikaciju, regresiju, klasteriranje, asocijativna pravila i vizualizaciju te podržava metode dubokog učenja. Weka je softver otvorenog koda izdan pod GNU licencom (General Public License) (Weka 3.8.3., 2018).

⁶ <https://www.cs.waikato.ac.nz/~ml/weka/index.html>

4.3.2. Model vremenskih serija (Time series)

Jednostavno rečeno, model vremenskih serija skup je opažanja x_t , koja se bilježe u određenom vremenu t . Postoje *diskretna vremenska serija*, ona u kojoj je vremenski skup T_0 , vrijeme u kojem se vrše opažanja, diskretni set ili na primjer, kada su zapažanja vršena u fiksnim vremenskim intervalima te *kontinuirana vremenska serija* kada se zapažanja bilježe kontinuirano kroz neki vremenski interval, npr. kada je $T_0[0,1]$ (Brockwell & Davis, 2002). Primjer jednostavnog modela vremenskih serija prikazan je na slici 8.

Slika 8. Mjesečna prodaja crvenog vina u kilolitrarna (Australija), 1980 - 1991.



Izvor: (Brockwell & Davis, 2002)


U ovom slučaju skup T_0 sastoji se od 142 vremena [(Siječanj 1980), (Veljača 1980), ..., (Listopad 1991)], koja su radi pogodnosti pretvorena u $[1, 2, \dots, n]$. Iz grafa se može zaključiti da prodaja vina ima rastući trend i sezonski karakter s vrhuncem u srpnju te najnižom vrijednosti u siječnju. Ovo je naravno vrlo malen i jednostavan model, čija je svrha pokazati postupak opažanja koji će provoditi i neuronska mreža.

4.3.3. Višeslojni Perceptron (Multilayer Perceptron)

Višeslojni Perceptron oblik je neuronske mreže koji je stvoren kao odgovor na probleme koje Perceptron nije mogao riješiti, a to su nelinearne funkcije (poglavlje 2.1).

Uzimajući u obzir pravilo da se učenje u neuronskoj mreži događa pomoću utega, čini se razumnim dodati veći broj utega. Dakle, da bi omogućili više računskih operacija možemo dodati veze unatrag, tako da se izlazni neuroni ponovno spoje na ulazne, ili dodati više neurona. Prvi pristup karakterističan je za ponavljajuće neuronske mreže (RNN). Takve mreže ne koriste se tako često u praksi, ali njihova primjena i dalje se proučava. Drugi pristup, dodavanje neurona između ulaznih i izlaznih čvorova dovesti će do složenije (višeslojne) neuronske mreže (Marsland, 2014). Takvu mrežu nazivamo Višeslojni Perceptron (slika 9), a jednostavni primjer primjene takve mreže vidljiv je u nastavku poglavlja.

Slika 9. Višeslojna Perceptron mreža




Izvor: (Marsland, 2014)

4.4. Postupak analize podataka i predviđanje budućih cijena

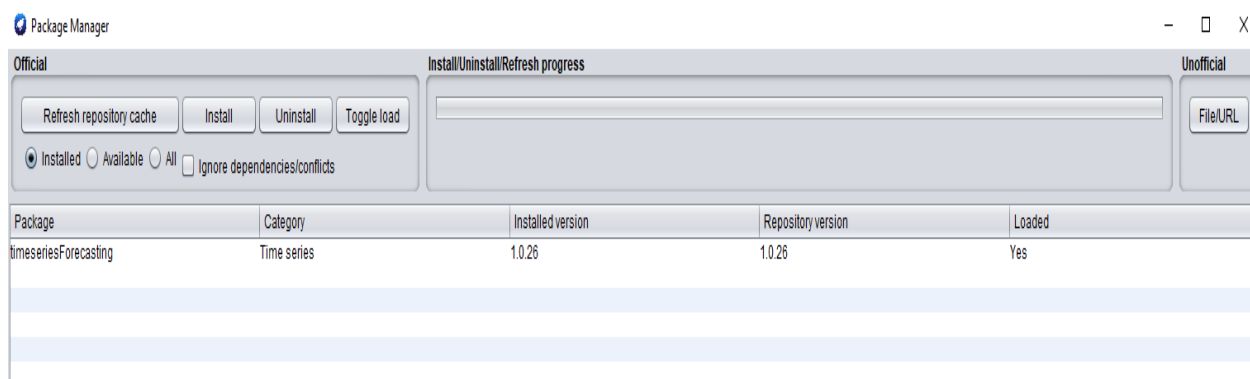
4.4.1. Priprema Weka softvera

Kako bi pomoću Weka softvera mogli primijeniti metode dubokog učenja na određeni skup podataka, softver moramo nadograditi sa paketom „timeseriesForecasting“ koji uključuje i jednostavnu Višeslojnu Perceptron mrežu za osnovne analize i predviđanja (slika 10 i 11).

Slika 10. Instalacija "timeseriesForecasting" paketa i Višeslojne Perceptron mreže



Slika 11. Instalacija "timeseriesForecasting" paketa Weka 3.8.3.



4.4.2. Priprema podataka

Nakon nadogradnje Weka softvera, učitavamo podatke koje želimo analizirati i predvidjeti, u ovom slučaju učitani je preuzeti dataset (poglavlje 4.1). Nakon učitavanja vidimo kratak pregled podataka, broj atributa i broj instanci. Za svaki od atributa možemo vidjeti najveću i najmanju vrijednost, srednju vrijednost i standardno odstupanje te njegov format (slika 12).

Slika 12. Učitani dataset

The screenshot shows the Weka Explorer application window. The 'Preprocess' tab is active. The 'Current relation' section displays 'Relation: AMD-Diplomski' and 'Instances: 503'. The 'Attributes' section lists 7 attributes: Date, Open, High, Low, Close (selected), Adj Close, and Volume. The 'Selected attribute' section shows statistics for 'Close': Name: Close, Missing: 0 (0%), Distinct: 447, Type: Numeric, Unique: 395 (79%). A histogram for 'Class: Volume (Num)' is displayed, showing the distribution of values for the selected attribute. The histogram has 6 bins with the following counts: 158, 62, 61, 66, 43, 73, 50. The x-axis ranges from 9.53 to 34.39, and the y-axis represents frequency.

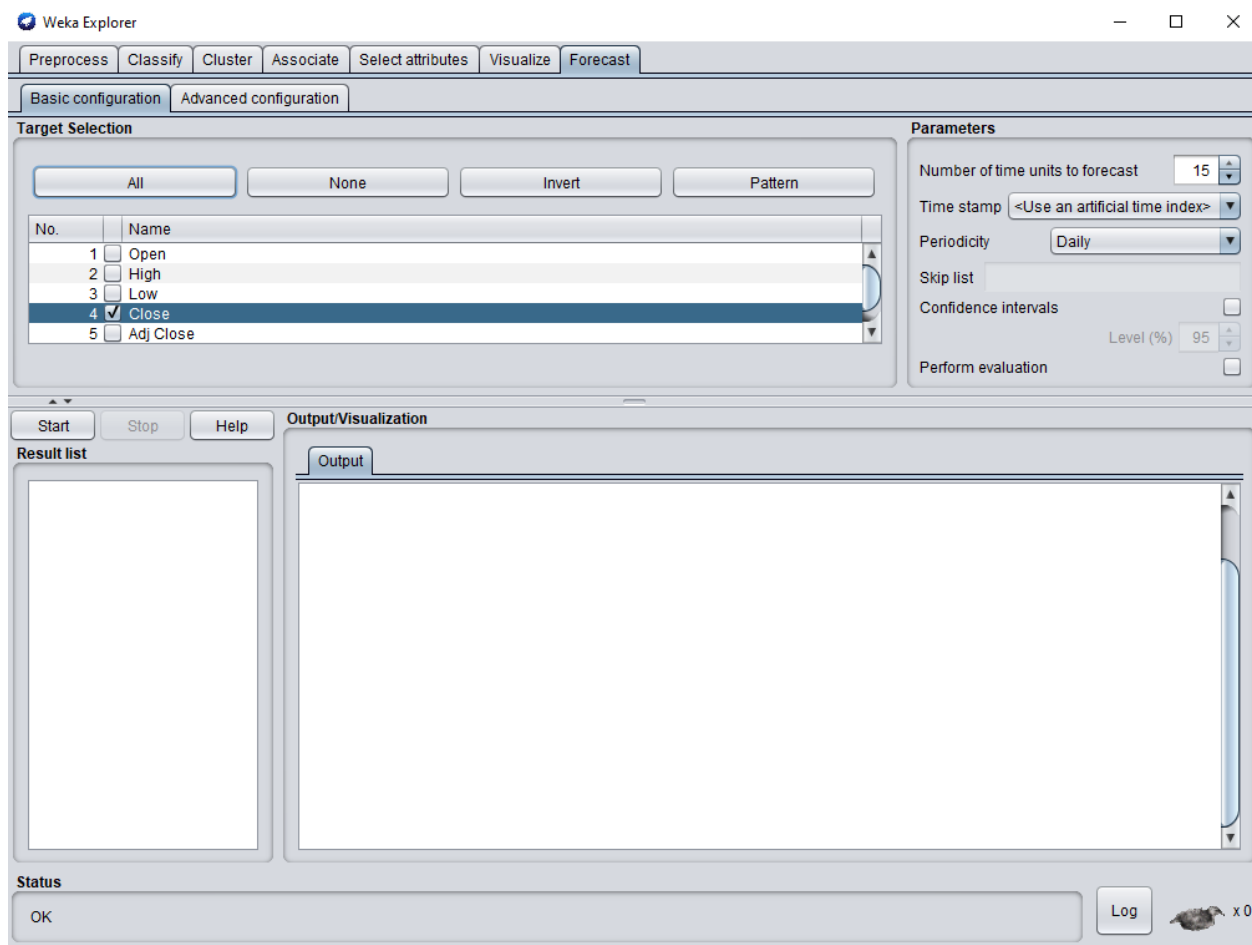
Statistic	Value
Minimum	9.53
Maximum	34.39
Mean	19.702
StdDev	7.579

Bin Range	Count
9.53 - 11.00	158
11.00 - 12.50	62
12.50 - 14.00	61
14.00 - 15.50	66
15.50 - 17.00	43
17.00 - 18.50	73
18.50 - 20.00	50

4.4.3. Podešavanje modela

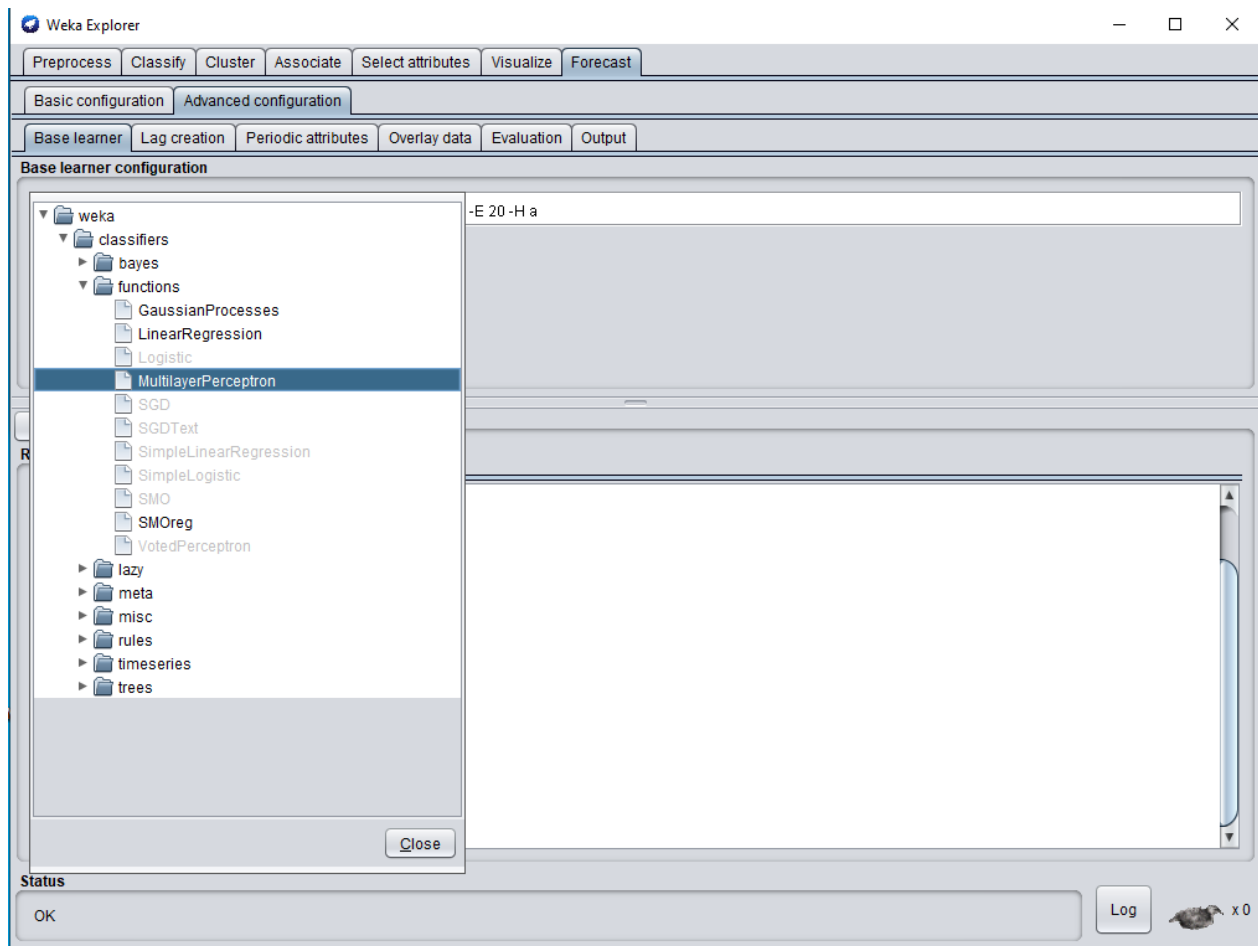
Nakon učitavanja podataka, klikom na karticu „Forecast“ otvara nam se prozor na kojem podešavamo prediktivni model (slika 13). Pod osnovnim postavkama (*engl. Basic configuration*) je kao ciljani (output) atribut izabrana zaključna cijena, a broj vremenskih jedinica koje će neuronska mreža predviđati 15 (postavljeno na dnevni interval), vidljivo na slici 13.

Slika 13. Osnovne postavke modela



U naprednim postavkama (engl. Advanced configuration) pod osnovno učenje (engl. base learner) odabran je MultilayerPerceptron (slika 14). Dakle, odabrani model učenja je Višeslojna Perceptron neuronska mreža koja će unesene podatke analizirati, iz njih probati naučiti te pokušati predvidjeti buduće kretanje cijena. Rezultati vidljivi u nastavku.

Slika 14. Napredne postavke - neuronska mreža

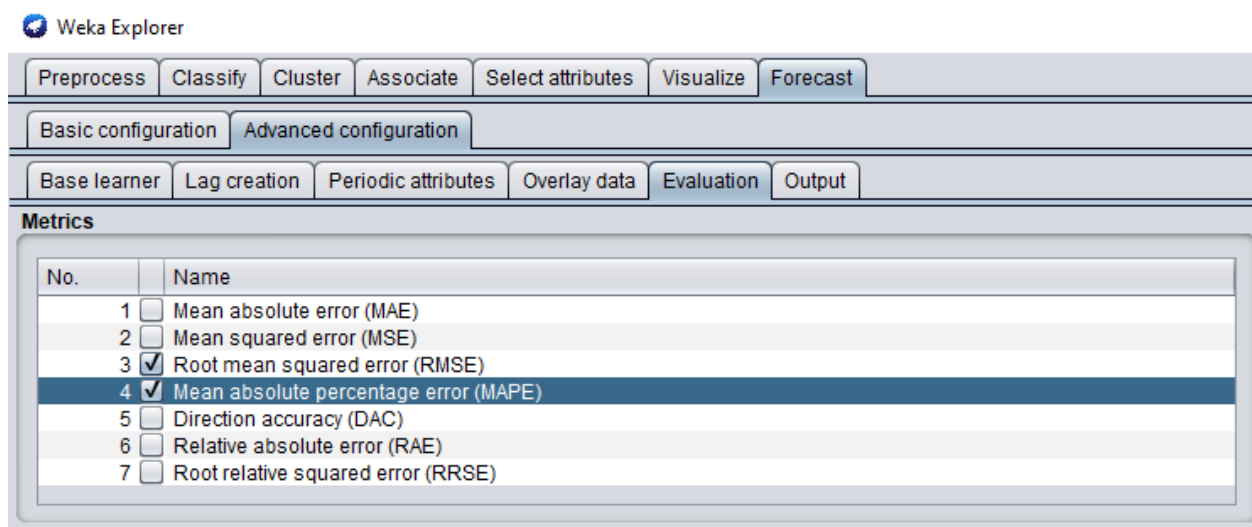


Bitno je napomenuti da će ova neuronska mreža podatke analizirati samo jednom te će iz njih probati donijeti zaključak o vjerojatnosti kretanja cijena u budućnosti. Međutim, bilo kakva neuronska mreža u praksi zahtjeva veći broj ponavljanja (analiza i učenja), koji se onda po principu utega (poglavlje 2.3.2) podešavaju, a mreža se postepeno nadograđuje i optimizira te daje sve preciznije rezultate.

Osim tipa učenja iz podataka, Weka nam nudi još neke napredne postavke za konfiguraciju naprednijih modela, poput stvaranja odgode (*engl. lag creation*), koji korisniku omogućava kontrolu i manipulaciju odgođenih varijabli. Zatim stvaranje periodičnih atributa (*engl. periodic attributes*), prekrivajuće podatke (*engl. overlay data*), procjenu (*engl. evaluation*) te izlazne postavke (*engl. output options*).

Model koji je dio ovog rada koristi procjenu (slika 15). Dostupne mjere točnosti su: MAE, MSE, RMSE, MAPE, DAC, RAE, RRSE, a za potrebe ovog modela odabrane su prosječna apsolutna postotna pogreška (MAPE - *engl. Mean Absolute Percentage Error*) i korijen srednje kvadratne pogreške (RMSE - *engl. Root Mean Squared Error*). Ostale napredne postavke ostavljene su na zadanim vrijednostima.

Slika 15. Napredne postavke - mjere točnosti



Mjere točnosti odabrane su jer su MAPE i RMSE najviše korištene mjere u komparativnim studijama metoda predviđanja (Chen, Twycross, & Garibaldi, 2017), te u ovom jednostavnom modelu daju nabolje rezultate.

4.4.4. Rezultati modela

Nakon podešavanja postavki modela, treniranje mreže i predviđanje budućih cijena pokreće se klikom na gumb „Start“, nakon čega neuronska mreža automatski počinje učiti na dostupnom data setu. Nakon zadovoljavajućeg stupnja pouzdanosti, model prikazuje rezultate predviđanja neuronske mreže. Na slici 16 i 17 možemo vidjeti dio procesa učenja i predviđene cijene.

Slika 16. Neuronska mreža - učenje

```
01:52:29 - MultilayerPerceptron [-F Close -L 1 -M 7 -dayofweek -weekend]
Output Train future pred.
Attrib ArtificialTimeIndex*Lag_Close-7 -0.4150620870211059
Sigmoid Node 2
Inputs Weights
Threshold -2.420457470692907
Attrib ArtificialTimeIndex -0.3400218211228818
Attrib Lag_Close-1 1.139089968200147
Attrib Lag_Close-2 0.02792509679836645
Attrib Lag_Close-3 -0.1621197717922937
Attrib Lag_Close-4 -0.348471267596206
Attrib Lag_Close-5 -0.2449044092524218
Attrib Lag_Close-6 -0.011370553120672658
Attrib Lag_Close-7 0.07461584818494323
Attrib ArtificialTimeIndex^2 0.3332456469863977
Attrib ArtificialTimeIndex^3 0.6999596856498432
Attrib ArtificialTimeIndex*Lag_Close-1 0.09173643332993467
Attrib ArtificialTimeIndex*Lag_Close-2 -0.2687702925453988
Attrib ArtificialTimeIndex*Lag_Close-3 0.04499248864201935
Attrib ArtificialTimeIndex*Lag_Close-4 -0.3145861617201104
Attrib ArtificialTimeIndex*Lag_Close-5 -0.04379999348467184
Attrib ArtificialTimeIndex*Lag_Close-6 -0.017694961760699474
Attrib ArtificialTimeIndex*Lag_Close-7 0.31393027986341376
Sigmoid Node 3
Inputs Weights
Threshold -2.0532410690773775
Attrib ArtificialTimeIndex -0.22594508183263295
Attrib Lag_Close-1 -1.0845067738041734
Attrib Lag_Close-2 -0.15215270922342097
Attrib Lag_Close-3 -0.36070761001255836
Attrib Lag_Close-4 0.14735998615905033
Attrib Lag_Close-5 -0.05149428016535514
Attrib Lag_Close-6 -0.35564563704695834
Attrib Lag_Close-7 -0.49824162988647475
Attrib ArtificialTimeIndex^2 0.22162438252646036
Attrib ArtificialTimeIndex^3 0.5362657987282148
Attrib ArtificialTimeIndex*Lag_Close-1 0.86303054591572
Attrib ArtificialTimeIndex*Lag_Close-2 0.43260217147599106
Attrib ArtificialTimeIndex*Lag_Close-3 -0.20740048471937347
Attrib ArtificialTimeIndex*Lag_Close-4 0.19258852559401307
Attrib ArtificialTimeIndex*Lag_Close-5 -0.002614789360140207
Attrib ArtificialTimeIndex*Lag_Close-6 0.007913480024121034
Attrib ArtificialTimeIndex*Lag_Close-7 -0.3072506299115032
Sigmoid Node 4
Inputs Weights
Threshold -2.3038780618154764
Attrib ArtificialTimeIndex -0.5193136856761096
Attrib Lag_Close-1 0.7730902843615232
.....
```

Slika 17. Neuronska mreža - rezultati

498	29.54
499	30.28
500	30.2
501	30.78
502	31.45
503	31.45
504*	31.5811
505*	31.1989
506*	30.9336
507*	30.6744
508*	30.5889
509*	30.6763
510*	30.8139
511*	30.9883
512*	31.0703
513*	31.0623
514*	30.9693
515*	30.8451
516*	30.7452
517*	30.6949
518*	30.7055

Kao što možemo vidjeti, neuronska mreža je na temelju dostupnog data seta ponudila predviđanje za 15 dana (korigirano zbog dana u kojima burza nije otvorena za trgovanje). Kao što je prethodno spomenuto, naprednije neuronske mreže trebaju ovaj postupak ponoviti veći broj puta na većem skupu podataka, nakon čega se „ručno“ podešavaju. Na ovaj način neuronske mreže uočavaju korelaciju različitih podataka i njihov utjecaj na buduće cijene, a njihova efikasnost i preciznost raste. Međutim, za takve naprednije modele neuronskih mreža potrebna je velika vještina i vrijeme da bi se mreža adekvatno sagradila, specijalizirala te naučila da bi bila primjenjiva u praksi.

4.5. Usporedba rezultata

U ovom poglavlju pogledati ćemo stvarne podatke o kretanju cijena od 1. rujna 2019. godine do 15. rujna 2019. godine za AMD dionice te ih usporediti sa onima koje je predvidjela neuronska mreža. Podaci su ponovno preuzeti sa finance.yahoo.com⁷. Usporedba stvarnih i predviđenih podataka u treniranju neuronske mreže jedan je od najvažnijih faktora. Razlika u cijenama ključan je pokazatelj efikasnosti neuronske mreže, a nakon usporedbe, neuronska mreža trebala bi se podesiti s tim novim informacijama. Svaka nova informacija, pa tako i rezultati prošlih analiza i predviđanja, neuronskoj mreži služe da svoj proces optimizira, a time poveća efikasnost. S obzirom da je neuronska mreža u ovom modelu proces učenja provela na zatvorenom skupu podataka u samo jednom ponavljanju, stupanj preciznosti je prilično zadovoljavajući. Razliku stvarnih i predviđenih zaključnih cijena možemo vidjeti u tablici 3 i na slici 18.

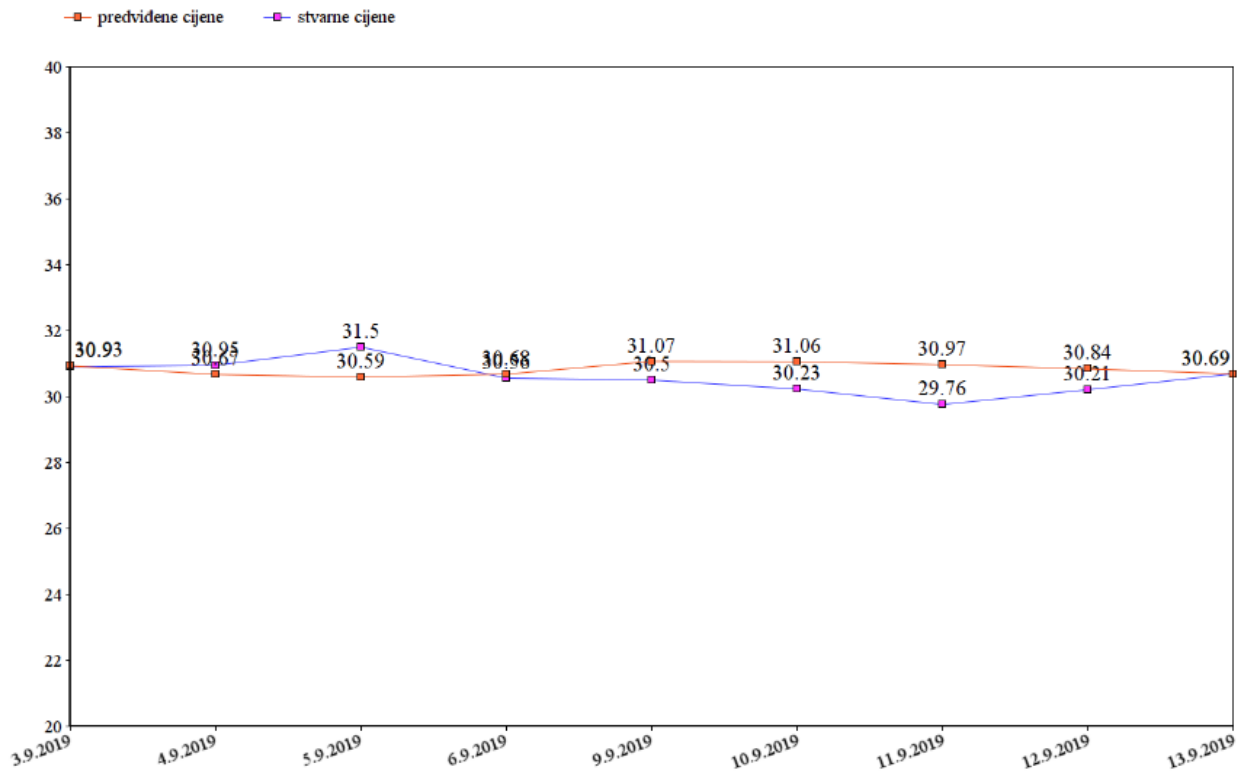
Tablica 3. Usporedba stvarnih cijena i cijena predviđenih neuronskom mrežom

Datum	Predviđene cijene (u dolarima)	Stvarne cijene (u dolarima)	Razlika (centi) predviđene/stvarne
3.9.2019	30.93	30.90	+0.03
4.9.2019	30.67	30.95	-0.28
5.9.2019	30.59	31.50	-0.91
6.9.2019	30.68	30.56	+0.12
9.9.2019	31.07	30.50	+0.57
10.9.2019	31.06	30.23	+0.83
11.9.2019	30.97	29.76	+1.21
12.9.2019	30.84	30.21	+0.63
13.9.2019	30.69	30.69	0.00

Izvor: Izrada autora

⁷<https://finance.yahoo.com/quote/AMD/history?period1=1567288800&period2=1568498400&interval=1d&filter=history&frequency=1d>

Slika 18. Usporedba stvarnih cijena i cijena predviđenih neuronskom mrežom (graf)



Izvor: Izrada autora

U tablici 3. možemo vidjeti koliko precizno je ova neuronska mreža predviđjela kretanje cijena. Istina, postoje procjene koje su daleko od stvarnih vrijednost, npr. za 5.9. gdje je razlika 91 cent, 10.9. razlika od 83 centa, i najgora procjena za 11.9. gdje je razlika 1 dolar i 21 cent. Međutim, mreža je uspješno predviđjela 3.9. i 6.9., sa razlikama od 3 centa i 12 centi te 13.9., gdje je mreža točno predviđjela cijenu dionica. Naravno, u obzir treba uzeti stupanj razvijenosti mreže i stupanj istreniranosti, a budući da je ovaj model vrlo jednostavan možemo zaključiti da su rezultati donekle uspješni. Kada bi ovu mrežu dalje razvijali, predviđena cijena zasigurno bi bila bliža stvarnoj. Također treba napomenuti, da budući da je kretanje cijena relativno stabilno, mreža je približno predviđjala cijene. Tamo gdje je cijena pala ili skočila kao posljedica eksternih čimbenika, mreža je pokazala slabije rezultate (jer nema pristup tim informacijama). Naravno, neke takve čimbenike razvijenije mreže mogu uzeti u obzir pa su i njihova predviđanja, kod većih oscilacija, uglavnom točnija.

5. ZAKLJUČAK

Cilj ovog rada bio je predstaviti jedan od oblika dubokog učenja, Višeslojnu Perceptron mrežu u području predviđanja cijena dionica u kratkom roku. To je postignuto implementacijom te neuronske mreže putem Weka softvera, verzije 3.8.3.

Višeslojna Perceptron mreža dostupna putem Weka softvera, jednostavan je model koji se koristio radi jednostavnosti, a da bi se postigao cilj ovog rada. Naprednije neuronske mreže, posebice Konvolucijske neuronske mreže, istim bi principom postigle puno bolje rezultate što je dokaz sposobnosti ove tehnologije i njenog potencijala na tržištu dionica. Budući da razvoj naprednijih mreža zahtjeva veće investicije, vrijeme i vještine, istraživanje se provelo jednostavnijom Višeslojnom Perceptron mrežom.

Međutim, rezultati omogućuju donošenje zaključaka na temu primjene neuronskih mreža na tržištu dionica, a jedan od zaključaka je da one mogu biti moćan alat u analizi dionica, mogu smanjiti rizik investiranja, a istodobno povećati efikasnost.

U današnje vrijeme, laka dostupnost podataka, Internet, jača procesna snaga računala i razvoj srodne tehnologije, omogućava i velikim i malim investitorima da svoje investicije ojačaju upotrebom različitih alata. Klasične analize, tehnička i fundamentalna, mogu se optimizirati primjenom različitih metoda, posebice metoda dubokog učenja, čemu i sami svjedočimo. Broj istraživanja na temu dubokog učenja eksponencijalno raste, a metodologija i tehnologija razvijaju se iz dana u dan pa je izgledno da će metode dubokog učenja, i umjetne inteligencije općenito, postati standardni instrumenti analize i predviđanja dionica.

POPIS LITERATURE

1. Brockwell, P. J., & Davis, R. A. (2002). *Introduction to Time Series and Forecasting, 2nd ed.* New York: Springer.
2. Chen, C., Twycross, J., & Garibaldi, J. M. (2017). A new accuracy measure based on bounded relative error for time series forecasting [online]. *PLos One* , 12(3); doi: 10.1371/journal.pone.0174202.
3. Chollet, F. (2018). *Deep Learning with Python*. Greenwich, CT, USA: Manning Publications Co.
4. Cohen, P. R. (1995). *Empirical Methods for Artificial Intelligence, 11*. MIT Press.
5. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press (html).
6. Graham, B., & Dodd, D. L. (2008). *Security Analysis: Principles and Technique, 6 ed.* New York: McGraw-Hill.
7. Hall, M. (2014). *Time Series Analysis and Forecasting with Weka [online]*. Dohvaćeno iz wiki.pentaho.com:
<https://wiki.pentaho.com/display/DATAMINING/Time+Series+Analysis+and+Forecasting+with+Weka>
8. Luger, G. F. (2009). *Artificial intelligence : structures and strategies for complex problem solving, 6th ed.* Harlow, England; New York: Addison-Wesley.
9. Marsland, S. (2014). *Machine Learning: An Algorithmic Perspective, 2nd ed.* Chapman & Hall/CRC.
10. Nguyen, A., Yosinski, J., & Clune, J. (2015). Deep Neural Networks are Easily Fooled: High Confidence Predictions for Unrecognizable Images. *In Computer Vision and Pattern Recognition (CVPR '15)* , IEEE.
11. Orsag, S. (2015). *Poslovne financije*. Zagreb: Avantis.

12. Pejić Bach, M. (2005). Rudarenje podataka u bankarstvu [Data mining in banking]. *Zbornik Ekonomskog fakulteta u Zagrebu, godina 3. , 1*; 181-193.
13. Russel, S., & Norvig, P. (2010). *Artificial Intelligence - A Modern Approach, 3rd ed.* Upper Saddle River, New Jersey: Prentice Hall.
14. Samek, W., Wiegand, T., & Müller, K.-R. (2017). *Explainable Artificial Intelligence: Understanding, Visualizing and Interpreting Deep Learning Models.* Artificial Intelligence (cs.AI); Dostupno na: arXiv:1708.08296v1.
15. Smolensky, P. (1988). On the proper treatment of connectionism. *Behavioral and brain sciences, 11* , 1-74.
16. Szegedy, C., Zaremba, W., Sutskever, I., Bruna, J., Erhan, D., Goodfellow, I., i dr. (2014). *Intriguing properties of neural networks.* Computer Vision and Pattern Recognition (cs.CV); Dostupno na: arXiv:1312.6199v4 [cs.CV].
17. Weka 3.8.3. (2018). *The University of Waikato [NZ]*. Preuzeto 1. 9. 2019 iz <https://www.cs.waikato.ac.nz/~ml/weka/index.html>
18. Wooldridge, M. (2001). Intelligent Agents: The Key Concepts. *Multi-Agent Systems and Applications II* , pp 3-43.

POPIS TABLICA

Tablica 1. Neke od definicija umjetne inteligencije, organizirane u 4 kategorije prema (Russel & Norvig, 2010)	3
Tablica 2. Karakteristike podataka.....	28
Tablica 3. Usporedba stvarnih cijena i cijena predviđenih neuronskom mrežom	40

POPIS SLIKA

Slika 1. Duboka neuronska mreža za klasifikaciju znamenki	14
Slika 2. Duboke reprezentacije naučene modelom klasifikacije znamenki	15
Slika 3. Parametrizacija neuronskih mreža utezima.....	16
Slika 4. Mjerenje kvalitete izlaza neuronske mreže (funkcija gubitka)	17
Slika 5. Pogrešna klasifikacija objekata nakon promjene (kodiranja) slika.....	21
Slika 6. Povijesni podaci AMD dionica (1.9.2017 - 1.9.2019).....	27
Slika 7. Grafički prikaz atributa	29
Slika 8. Mjesečna prodaja crvenog vina u kilolitrama (Australija), 1980 - 1991.	31
Slika 9. Višeslojna Perceptron mreža.....	32
Slika 10. Instalacija "timeseriesForecasting" paketa i Višeslojne Perceptron mreže.....	33
Slika 11. Instalacija "timeseriesForecasting" paketa Weka 3.8.3.	33
Slika 12. Učitani dataset.....	34
Slika 13. Osnovne postavke modela	35
Slika 14. Napredne postavke - neuronska mreža	36
Slika 15. Napredne postavke - mjere točnosti.....	37
Slika 16. Neuronska mreža - učenje.....	38
Slika 17. Neuronska mreža - rezultati	39
Slika 18. Usporedba stvarnih cijena i cijena predviđenih neuronskom mrežom (graf)	41

PRILOZI

Zadatak - OZUBP - Neuronske mreže

BROJ TIMA:	
PRISUTNI ČLANOVI TIMA:	

STUDIJA SLUČAJA: Preuzeti su podaci o povijesnim cijenama dionica poduzeća AMD, od 2017. do 2019. godine. Podaci o dionicama uključuju, početnu cijenu dionice, najvišu, najnižu, zaključnu cijenu, podešenu zaključnu cijenu, broj dionica te datum trgovanja. Upotrebom umjetnih neuronskih mreža, na temelju povijesnih podataka dionice AMD, napravite prediktivni model koji će pokušati predvidjeti buduće cijene dionica.

KORAK 1:

Pokrenite Weka-u te otvorite Package Manager (Pod Tools, prije pokretanja Explorera). U tražilicu upišite forecasting i stisnite enter. Odaberite paket „timeseriesForecasting“ pa „Install“ (na vrhu stranice). Pričekajte da se paket instalira, te izađite iz Weka programa.

KORAK 2:

Ponovno pokrenite Weka-u te Explorer sučelje. S web stranice kolegija preuzmite i pokrenite datoteku DioniceAMD.arff. Otvorite bazu podataka DioniceAMD.arff u Notepad-u kako bi dobili predodžbu o strukturi arff datoteke.

Koliko atributa, a koliko primjera(instanci) sadrži baza podataka DioniceAMD.arff?

Koji tip vrijednosti poprimaju atributi u skupu podataka?

U tablicu upišite attribute, njihove formate i modalitete.

Tablica 1. Atributi i formati atributa datoteke DioniceAMD.arff

Naziv atributa	Format atributa	Modalitet atributa (nominalnih)

KORAK 3:

Otvorite Forecast panel. Pod Basic configuration odaberite Close (zaključna cijena) te pod Parameters izaberite 15 (number of time units to forecast), Time stamp ostavite na Use an artificial time index, a pod Periodicity odaberite Daily.

Otvorite Advanced configuration. Pod Base learner kliknite na Choose i odaberite MultilayerPerceptron. Pokrenite model (start).

Spremite sliku predviđenih cijena dionica (screenshot).

Otvorite karticu Train future pred. te mišem zaokružite procijenjeno kretanje kako bi uvećali grafikon. *Komentirajte previđeno kretanje dionica.*

KORAK 4:

Na istom modelu, vratite se na Base learner, te uz Close odaberite Open, High i Low. Ponovno pokrenite model.

Da li se predviđene vrijednosti Close cijene (4. Kolona) razlikuju od prvog modela? Objasnite zašto.

KORAK 5:

Ponovno spremite sliku predviđenih cijena dionica (screenshot). Otvorite Internet preglednik te u tražilicu upišite finance.yahoo.com. Na stranici u search upišite Advanced Micro Devices i kliknite na AMD.

Pod Historical Data odaberite Time Period i označite 9/1/2019 na Start Date, te 9/15/2019 na End Date i potvrdite (Done). Pod Frequency odaberite Daily i pod Show odaberite Historical Prices. Na kraju potvrdite s Apply.

U tablicu upišite prva 4 datuma, te prve 4 cijene pod Close koje prikazuje finance.yahoo.com. Otvorite prvu snimku zaslona (iz koraka 3) te upišite prve 4 predviđene cijene. Isto ponovite i sa drugom snimkom zaslona (korak 5).

Isti proces ponovite sa zadnjom prikazanom cijenom na [finance yahoo.com](http://finance.yahoo.com) i sa snimki zaslona. Obratite pozornost na datume. Budući da model u obzir ne uzima vikende (kada burza ne radi) treba korigirati upisane cijene. Dakle, prva cijena sa finance.yahoo.com je za 3. rujana, međutim u modelu je 3. rujana pod brojem 506* (3. predviđena cijena). Zadnji broj na finance.yahoo.com je 13. rujana, a 13. rujana u modelu zabilježen je pod brojem 516*.

Datum	Zaključna cijena(yahoo)	Prva predviđena cijena	Druga predviđena cijena

Usporedite stvarne cijene i predviđene. Koji model je preciznije predvidio kretanje cijena? Objasnite zašto.

PODACI O DIONICAMA (.arff):

Date,Open,High,Low,Close,Adj Close,Volume
8/31/2017,12.82,13.16,12.79,13,13,51822100
9/1/2017,13.12,13.49,13.04,13.19,13.19,53158600
9/5/2017,12.88,13.18,12.65,12.92,12.92,51445500
9/6/2017,13.02,13.08,12.75,12.86,12.86,34182400
9/7/2017,12.84,12.94,12.6,12.63,12.63,35816900
9/8/2017,12.57,12.61,12.04,12.25,12.25,60886200
9/11/2017,12.46,12.74,12.4,12.55,12.55,43346100
9/12/2017,12.66,12.68,12.21,12.3,12.3,54413100
9/13/2017,12.22,12.36,12.12,12.22,12.22,37210700
9/14/2017,12.15,12.46,12.11,12.26,12.26,37220200
9/15/2017,12.33,12.66,12.31,12.52,12.52,50337400
9/18/2017,12.77,13.3,12.74,13.08,13.08,83517400
9/19/2017,13.25,13.29,12.88,13.12,13.12,65455200
9/20/2017,13.07,13.8,12.8,13.74,13.74,102682400
9/21/2017,14,14.24,13.32,13.41,13.41,166821900
9/22/2017,13.2,13.4,13.12,13.3,13.3,50547000
9/25/2017,13.25,13.28,12.49,12.61,12.61,84172200
9/26/2017,12.85,12.93,12.43,12.45,12.45,68302000
9/27/2017,12.65,12.87,12.5,12.74,12.74,59947200
9/28/2017,12.76,12.84,12.55,12.74,12.74,35812300
9/29/2017,12.77,12.82,12.6,12.75,12.75,33926900
10/2/2017,12.8,12.85,12.62,12.71,12.71,34461100
10/3/2017,12.73,13.48,12.7,13.42,13.42,85174000
10/4/2017,13.31,13.5,13.15,13.31,13.31,42303200
10/5/2017,13.38,13.46,13.21,13.34,13.34,34758600
10/6/2017,13.22,13.39,13.18,13.23,13.23,28258700
10/9/2017,13.26,13.83,13.26,13.47,13.47,54032500
10/10/2017,13.72,13.79,13.44,13.7,13.7,43304000
10/11/2017,13.62,13.96,13.61,13.88,13.88,38746600
10/12/2017,13.85,14.37,13.81,14.2,14.2,69874100
10/13/2017,14.32,14.41,14.12,14.22,14.22,37515800
10/16/2017,14.25,14.35,14.12,14.26,14.26,34136800
10/17/2017,14.24,14.35,14.14,14.16,14.16,28995600
10/18/2017,14.2,14.28,13.76,14.07,14.07,39020300
10/19/2017,13.85,14.04,13.69,13.95,13.95,33795700
10/20/2017,14.03,14.09,13.8,13.81,13.81,32538900
10/23/2017,13.94,14.19,13.9,14.1,14.1,49838000
10/24/2017,14.2,14.36,14.15,14.25,14.25,84891600
10/25/2017,12.95,13.13,12.29,12.33,12.33,166762100
10/26/2017,12.45,12.46,12,12.01,12.01,87625400
10/27/2017,12.17,12.19,11.35,11.84,11.84,115650400
10/30/2017,11.26,11.42,10.65,10.89,10.89,137785100
10/31/2017,10.76,11.31,10.69,10.99,10.99,78600000

11/1/2017,11.25,11.29,10.72,10.8,10.8,66875500
11/2/2017,10.87,10.99,10.66,10.85,10.85,47942500
11/3/2017,10.95,11.13,10.82,11.12,11.12,44264300
11/6/2017,12.04,12.09,11.64,11.93,11.93,96349800
11/7/2017,11.94,12.27,11.92,12.05,12.05,67900200
11/8/2017,11.94,11.95,11.51,11.71,11.71,59065000
11/9/2017,11.25,11.35,11.03,11.12,11.12,76821200
11/10/2017,11.22,11.43,11.12,11.26,11.26,50209900
11/13/2017,11.18,11.2,10.92,11.09,11.09,54068300
11/14/2017,11.03,11.26,11,11.12,11.12,37245000
11/15/2017,11.01,11.13,10.77,11.07,11.07,33524700
11/16/2017,11.13,11.32,11.13,11.25,11.25,31800400
11/17/2017,11.3,11.75,11.28,11.38,11.38,56775600
11/20/2017,11.47,11.51,11.19,11.34,11.34,35960200
11/21/2017,11.42,11.49,11.24,11.4,11.4,31881700
11/22/2017,11.41,11.49,11.3,11.37,11.37,23816500
11/24/2017,11.38,11.42,11.3,11.38,11.38,11035800
11/27/2017,11.34,11.74,11.34,11.55,11.55,41798300
11/28/2017,11.45,11.54,11,11.17,11.17,65325700
11/29/2017,11.08,11.17,10.73,10.83,10.83,63333800
11/30/2017,10.87,11.03,10.76,10.89,10.89,43205000
12/1/2017,10.81,10.97,10.53,10.73,10.73,42128800
12/4/2017,10.85,10.86,9.82,10.03,10.03,97328300
12/5/2017,9.89,10.34,9.7,9.91,9.91,67304100
12/6/2017,9.9,10.05,9.71,10,10,38952200
12/7/2017,10.07,10.19,9.95,10.04,10.04,32665600
12/8/2017,10.15,10.2,9.92,9.94,9.94,34897000
12/11/2017,9.97,10.16,9.96,10.16,10.16,29956400
12/12/2017,10.13,10.14,9.88,9.9,9.9,36211000
12/13/2017,9.97,10.21,9.95,10.11,10.11,41494800
12/14/2017,10.1,10.17,9.96,10.13,10.13,29006800
12/15/2017,10.13,10.32,10.02,10.29,10.29,45462300
12/18/2017,10.6,11,10.51,10.98,10.98,63797700
12/19/2017,11,11.19,10.87,10.95,10.95,43852900
12/20/2017,11.1,11.18,10.8,10.98,10.98,31420300
12/21/2017,10.98,11.08,10.87,10.89,10.89,21884300
12/22/2017,10.75,10.77,10.2,10.54,10.54,50744500
12/26/2017,10.38,10.58,10.34,10.46,10.46,20437900
12/27/2017,10.45,10.74,10.4,10.53,10.53,22921800
12/28/2017,10.57,10.64,10.43,10.55,10.55,18609400
12/29/2017,10.57,10.58,10.27,10.28,10.28,26678900
1/2/2018,10.42,11.02,10.34,10.98,10.98,44146300
1/3/2018,11.61,12.14,11.36,11.55,11.55,154066700
1/4/2018,12.1,12.43,11.97,12.12,12.12,109503000
1/5/2018,12.19,12.22,11.66,11.88,11.88,63808900
1/8/2018,12.01,12.3,11.85,12.28,12.28,63346000
1/9/2018,12,12.02,11.71,11.82,11.82,62560900

1/10/2018,11.63,12.15,11.56,11.96,11.96,52561200
1/11/2018,12.07,12.19,11.9,12.14,12.14,38354900
1/12/2018,11.82,12.07,11.8,12.02,12.02,47149300
1/16/2018,12.05,12.2,11.8,11.91,11.91,42686600
1/17/2018,11.9,12.19,11.82,12.18,12.18,39020800
1/18/2018,12.18,12.68,12.15,12.47,12.47,62086200
1/19/2018,12.56,12.88,12.54,12.59,12.59,46800700
1/22/2018,12.61,12.74,12.37,12.65,12.65,34758600
1/23/2018,12.82,13,12.76,12.94,12.94,46417200
1/24/2018,13.02,13.05,12.6,12.71,12.71,41956400
1/25/2018,12.78,12.94,12.32,12.41,12.41,42966600
1/26/2018,12.7,12.95,12.62,12.95,12.95,44239000
1/29/2018,13.13,13.47,13.05,13.32,13.32,66645400
1/30/2018,13.12,13.27,12.69,12.87,12.87,91236400
1/31/2018,13.24,13.85,13.15,13.74,13.74,140977800
2/1/2018,13.62,13.84,13.21,13.25,13.25,67543300
2/2/2018,13.05,13.06,12.43,12.45,12.45,79432600
2/5/2018,12.05,12.18,10.93,11.57,11.57,116568900
2/6/2018,11.04,11.74,11,11.65,11.65,87123200
2/7/2018,11.7,11.9,11.53,11.6,11.6,55758400
2/8/2018,11.72,11.85,11.21,11.22,11.22,56471800
2/9/2018,11.54,11.57,10.63,11.31,11.31,85458200
2/12/2018,11.47,11.8,11.43,11.68,11.68,63160900
2/13/2018,11.6,11.82,11.53,11.78,11.78,33661400
2/14/2018,11.72,12.31,11.63,12.2,12.2,51756800
2/15/2018,12.4,12.63,12.07,12.19,12.19,59593800
2/16/2018,12.11,12.23,11.82,11.82,11.82,47332300
2/20/2018,11.72,12.19,11.71,12.02,12.02,47096500
2/21/2018,12.12,12.12,11.72,11.72,11.72,40195800
2/22/2018,11.82,12,11.63,11.84,11.84,37886300
2/23/2018,11.95,12.16,11.94,12.07,12.07,33317600
2/26/2018,12.14,12.43,12.05,12.42,12.42,42265200
2/27/2018,12.43,12.88,12.39,12.53,12.53,55975300
2/28/2018,12.66,12.73,12.1,12.11,12.11,43387500
3/1/2018,12.26,12.27,11.66,11.9,11.9,63207400
3/2/2018,11.67,11.93,11.43,11.81,11.81,58123500
3/5/2018,11.69,12.06,11.61,11.91,11.91,43734800
3/6/2018,12.01,12.05,11.71,11.76,11.76,46751200
3/7/2018,11.58,12.82,11.55,12.24,12.24,127603200
3/8/2018,12.4,12.59,11.74,11.97,11.97,76011200
3/9/2018,12.03,12.04,11.58,11.7,11.7,89674400
3/12/2018,11.76,11.82,11.48,11.52,11.52,83748700
3/13/2018,11.5,12.04,11.1,11.64,11.64,174302600
3/14/2018,11.7,11.72,11.26,11.36,11.36,80540800
3/15/2018,11.43,11.55,11.19,11.46,11.46,66373900
3/16/2018,11.49,11.55,11.32,11.47,11.47,37591000
3/19/2018,11.41,11.74,11.35,11.43,11.43,53308600

3/20/2018,11.41,11.52,11,11.11,11.11,65116900
3/21/2018,11.16,11.34,11.11,11.26,11.26,44691700
3/22/2018,11.1,11.26,10.85,10.91,10.91,59944200
3/23/2018,10.91,10.97,10.57,10.63,10.63,54844500
3/26/2018,10.71,10.8,10.18,10.44,10.44,75878500
3/27/2018,10.51,10.59,9.9,10,10,68551300
3/28/2018,9.99,10.17,9.79,9.81,9.81,64832100
3/29/2018,9.94,10.08,9.81,10.05,10.05,48681400
4/2/2018,9.99,10.14,9.51,9.53,9.53,64824600
4/3/2018,9.63,9.77,9.3,9.55,9.55,54891600
4/4/2018,9.08,9.81,9.04,9.77,9.77,67356900
4/5/2018,10.05,10.2,9.91,10.02,10.02,65758800
4/6/2018,9.83,10.1,9.5,9.61,9.61,51087100
4/9/2018,9.75,9.84,9.52,9.53,9.53,38382600
4/10/2018,9.75,10.04,9.71,9.98,9.98,42849200
4/11/2018,9.87,10.03,9.79,9.82,9.82,29169300
4/12/2018,9.98,10.1,9.82,10.08,10.08,47784400
4/13/2018,10.2,10.22,9.88,9.93,9.93,38935700
4/16/2018,10,10.17,9.9,10.09,10.09,28875100
4/17/2018,10.28,10.53,10.2,10.52,10.52,45360300
4/18/2018,10.51,10.65,10.33,10.36,10.36,42449600
4/19/2018,10.18,10.33,9.99,10.11,10.11,57841600
4/20/2018,10.05,10.14,9.95,9.99,9.99,39011900
4/23/2018,10.09,10.19,9.97,10.04,10.04,42971300
4/24/2018,10.19,10.35,9.95,10.09,10.09,44992200
4/25/2018,10.06,10.09,9.56,9.71,9.71,90578000
4/26/2018,10.87,11.19,10.61,11.04,11.04,145284100
4/27/2018,11.2,11.36,11.02,11.11,11.11,74347800
4/30/2018,11.06,11.14,10.87,10.88,10.88,50608800
5/1/2018,10.83,11.15,10.77,11.13,11.13,43441600
5/2/2018,11.1,11.16,10.97,10.97,10.97,29267300
5/3/2018,10.9,11.06,10.83,10.93,10.93,33310600
5/4/2018,10.88,11.29,10.87,11.28,11.28,47884900
5/7/2018,11.32,11.68,11.3,11.59,11.59,54001700
5/8/2018,11.49,11.66,11.4,11.61,11.61,35218400
5/9/2018,11.65,11.98,11.57,11.95,11.95,49605700
5/10/2018,11.98,12.18,11.95,12.13,12.13,49744500
5/11/2018,11.89,12.03,11.69,11.95,11.95,43863700
5/14/2018,12.14,12.36,12.11,12.23,12.23,50263800
5/15/2018,12.18,12.46,12.16,12.45,12.45,44183200
5/16/2018,12.64,12.98,12.62,12.82,12.82,73364000
5/17/2018,12.79,12.9,12.66,12.82,12.82,38692500
5/18/2018,13.06,13.26,12.91,13,13,54063400
5/21/2018,13.25,13.31,12.88,12.99,12.99,49714200
5/22/2018,13,13.14,12.71,12.98,12.98,43267000
5/23/2018,12.93,13.18,12.9,13.1,13.1,44517800
5/24/2018,13.06,13.43,13.03,13.41,13.41,47785700

5/25/2018,13.4,13.72,13.36,13.54,13.54,43850100
5/29/2018,13.45,13.63,13.26,13.36,13.36,39578500
5/30/2018,13.48,13.95,13.48,13.82,13.82,58186400
5/31/2018,13.74,13.93,13.69,13.73,13.73,46797700
6/1/2018,13.98,14.4,13.92,14.4,14.4,71677900
6/4/2018,14.76,14.98,14.52,14.85,14.85,74546000
6/5/2018,14.85,14.92,14.63,14.85,14.85,56122700
6/6/2018,15.07,15.74,15.04,15.67,15.67,97089000
6/7/2018,15.83,15.97,14.85,14.89,14.89,99860300
6/8/2018,14.52,15.33,14.31,15.25,15.25,81930500
6/11/2018,15.21,15.89,15.01,15.73,15.73,80737600
6/12/2018,15.84,15.95,15.43,15.85,15.85,67002600
6/13/2018,15.81,16.52,15.78,16.32,16.32,90227300
6/14/2018,16.620001,16.790001,15.58,16.25,16.25,113048600
6/15/2018,16.059999,16.52,15.82,16.34,16.34,77612200
6/18/2018,16.18,17.34,16.129999,17.110001,17.110001,104317400
6/19/2018,16.85,17.290001,16.309999,16.690001,16.690001,92542900
6/20/2018,16.83,17.129999,16.370001,16.52,16.52,76280600
6/21/2018,16.65,16.870001,15.46,15.65,15.65,95638400
6/22/2018,15.78,15.91,15.56,15.8,15.8,59257100
6/25/2018,15.64,15.74,14.54,15.11,15.11,94418400
6/26/2018,15.32,15.6,15.1,15.5,15.5,54213500
6/27/2018,15.65,15.76,14.96,14.97,14.97,56014300
6/28/2018,14.85,15.36,14.75,15.31,15.31,48716800
6/29/2018,15.41,15.49,14.98,14.99,14.99,41527800
7/2/2018,14.8,15.18,14.74,15.16,15.16,43398800
7/3/2018,15.21,15.34,14.96,15,15,32094000
7/5/2018,15.13,15.5,15.02,15.5,15.5,40703300
7/6/2018,15.52,16.389999,15.48,16.360001,16.360001,65101700
7/9/2018,16.73,16.84,16.17,16.610001,16.610001,58525500
7/10/2018,16.59,16.65,16.309999,16.549999,16.549999,37093000
7/11/2018,16.15,16.530001,16.02,16.27,16.27,42544100
7/12/2018,16.41,16.790001,16.379999,16.559999,16.559999,44188100
7/13/2018,16.68,16.690001,16.219999,16.27,16.27,40614100
7/16/2018,16.42,17,16.41,16.58,16.58,65275300
7/17/2018,16.5,16.879999,16.48,16.870001,16.870001,42313500
7/18/2018,16.940001,16.99,16.549999,16.85,16.85,40881500
7/19/2018,16.709999,16.879999,16.549999,16.709999,16.709999,41267800
7/20/2018,16.66,16.879999,16.440001,16.5,16.5,42879800
7/23/2018,16.469999,16.68,15.9,16.66,16.66,44940800
7/24/2018,16.75,16.860001,16.110001,16.190001,16.190001,58201500
7/25/2018,16.299999,16.389999,15.72,16.049999,16.049999,82604900
7/26/2018,17.16,18.450001,16.83,18.35,18.35,192661100
7/27/2018,19.07,19.879999,18.309999,18.940001,18.940001,161903800
7/30/2018,19.4,20.18,19.309999,19.42,19.42,160823400
7/31/2018,19.35,19.5,18.27,18.33,18.33,118403400
8/1/2018,18.34,18.950001,18.32,18.48,18.48,75495200

8/2/2018,18.17,18.83,18,18.790001,18.790001,52867100
8/3/2018,18.940001,19.059999,18.370001,18.49,18.49,53232100
8/6/2018,18.889999,19.440001,18.459999,19.43,19.43,83579700
8/7/2018,19.530001,19.709999,19.08,19.559999,19.559999,72822600
8/8/2018,19.459999,19.77,19.26,19.58,19.58,52081400
8/9/2018,19.58,19.709999,19.08,19.1,19.1,46653400
8/10/2018,19.09,19.48,18.85,19.059999,19.059999,65821100
8/13/2018,19.16,19.93,19.120001,19.73,19.73,81411300
8/14/2018,19.969999,20.280001,19.629999,20.02,20.02,89195500
8/15/2018,19.860001,20.1,19.200001,19.700001,19.700001,86355700
8/16/2018,19.860001,20.07,19.25,19.33,19.33,69733700
8/17/2018,19.120001,19.82,18.73,19.77,19.77,60616600
8/20/2018,19.790001,20.08,19.35,19.98,19.98,62983200
8/21/2018,19.98,20.42,19.860001,20.4,20.4,55629000
8/22/2018,20.280001,20.92,20.209999,20.9,20.9,62002700
8/23/2018,21.190001,22.32,21.139999,22.290001,22.290001,113444100
8/24/2018,22.91,24,22.67,23.98,23.98,164328200
8/27/2018,24.940001,27.299999,24.629999,25.26,25.26,325058400
8/28/2018,25.51,26.18,24.040001,25.049999,25.049999,215771200
8/29/2018,24.360001,25.41,24.01,25.200001,25.200001,143223200
8/30/2018,25.290001,25.67,24.76,24.889999,24.889999,103607300
8/31/2018,24.889999,25.24,24.719999,25.17,25.17,65206400
9/4/2018,25.620001,28.110001,25.57,28.059999,28.059999,192541300
9/5/2018,29.41,29.940001,26.84,28.51,28.51,257349000
9/6/2018,28.120001,28.58,27.190001,27.84,27.84,143942900
9/7/2018,26.959999,28.27,26.799999,27.379999,27.379999,123348700
9/10/2018,28.15,29.93,27.84,29.889999,29.889999,162253800
9/11/2018,30.02,30.59,29.370001,30.1,30.1,159902500
9/12/2018,29.91,32.290001,29.450001,32.209999,32.209999,197889600
9/13/2018,33.16,34.139999,29.870001,30.48,30.48,304147100
9/14/2018,31.43,33.09,30.540001,32.720001,32.720001,217762800
9/17/2018,31.75,33.23,31.6,32.43,32.43,180410600
9/18/2018,32.990002,33.369999,31.200001,31.93,31.93,176673200
9/19/2018,31.52,31.83,30.51,31.209999,31.209999,124287000
9/20/2018,32.099998,32.200001,30.639999,31.18,31.18,123116500
9/21/2018,31.190001,32.419998,30.91,31.02,31.02,129792900
9/24/2018,31.129999,32.650002,30.91,32.610001,32.610001,118332600
9/25/2018,33.18,33.599998,32.189999,32.57,32.57,118570200
9/26/2018,32.400002,32.599998,31.719999,32.189999,32.189999,79347300
9/27/2018,31.860001,32.630001,31.389999,32.59,32.59,87934400
9/28/2018,32.240002,32.779999,29.98,30.889999,30.889999,165453500
10/1/2018,30.690001,31.91,30.25,31.42,31.42,94742900
10/2/2018,30.73,30.82,28.65,29.02,29.02,145276500
10/3/2018,29.040001,29.219999,26.540001,28.43,28.43,190137200
10/4/2018,27.99,28.83,27.370001,27.780001,27.780001,95831200
10/5/2018,28.07,28.469999,26.93,27.35,27.35,88008500
10/8/2018,26.73,27.540001,25.959999,26.459999,26.459999,103789500

10/9/2018,26.15,27.709999,26,27.24,27.24,105461800
10/10/2018,27.379999,27.4,24.91,25,25,147682900
10/11/2018,24.74,26.200001,24.549999,25.299999,25.299999,147013800
10/12/2018,26.77,26.969999,25.67,26.34,26.34,111059400
10/15/2018,26.379999,26.77,25.75,26.26,26.26,70523500
10/16/2018,26.629999,28.23,26.17,28.18,28.18,92529000
10/17/2018,28.41,28.530001,26.92,27.299999,27.299999,89466900
10/18/2018,27.08,27.75,26.4,26.620001,26.620001,79623700
10/19/2018,27.030001,27.1,23.6,23.66,23.66,130799900
10/22/2018,24.459999,25.639999,24.09,25.030001,25.030001,114158900
10/23/2018,24.18,25.26,23.85,25.09,25.09,101763000
10/24/2018,25.040001,25.1,22.75,22.790001,22.790001,134489100
10/25/2018,17.92,20.15,17.719999,19.27,19.27,189173700
10/26/2018,18.49,18.780001,17.049999,17.629999,17.629999,119689000
10/29/2018,18.209999,18.23,16.27,16.85,16.85,94479600
10/30/2018,16.379999,17.24,16.17,17.200001,17.200001,99049400
10/31/2018,17.870001,18.34,17.120001,18.209999,18.209999,110463700
11/1/2018,18.41,20.33,18.08,20.219999,20.219999,136896500
11/2/2018,20.59,21.059999,19.469999,20.23,20.23,123788000
11/5/2018,20.120001,20.18,18.879999,19.9,19.9,108016700
11/6/2018,19.5,21.65,19.48,20.68,20.68,144995700
11/7/2018,21.42,22.219999,21.07,21.84,21.84,121115800
11/8/2018,21.77,22.08,20.969999,21.200001,21.200001,92387600
11/9/2018,20.77,21.190001,20.110001,21.030001,21.030001,85900700
11/12/2018,20.68,20.85,18.799999,19.030001,19.030001,95948200
11/13/2018,19.280001,20.02,18.969999,19.610001,19.610001,76126000
11/14/2018,20.18,21.110001,19.76,20.809999,20.809999,106344300
11/15/2018,20.719999,21.77,20.42,21.49,21.49,97715500
11/16/2018,19.870001,20.969999,19.719999,20.66,20.66,112376600
11/19/2018,20.4,20.59,19.09,19.110001,19.110001,93578200
11/20/2018,17.4,19.58,17.18,19.209999,19.209999,109869400
11/21/2018,20.049999,20.309999,18.5,18.73,18.73,81585600
11/23/2018,18.610001,19.83,18.559999,19.379999,19.379999,54611300
11/26/2018,19.959999,20.190001,19.110001,20.08,20.08,83211000
11/27/2018,19.77,21.450001,19.73,21.049999,21.049999,119230100
11/28/2018,21.82,21.879999,20.18,21.34,21.34,134425300
11/29/2018,21.190001,21.610001,20.73,21.43,21.43,79853700
11/30/2018,21.299999,21.360001,20.52,21.299999,21.299999,82370700
12/3/2018,22.48,23.75,22.370001,23.709999,23.709999,139607400
12/4/2018,23.35,23.42,21.07,21.120001,21.120001,127392900
12/6/2018,20.219999,21.41,20.059999,21.299999,21.299999,103434700
12/7/2018,21.299999,21.379999,19.17,19.459999,19.459999,105764500
12/10/2018,19.35,20.129999,19.27,19.99,19.99,77984500
12/11/2018,20.709999,21.139999,19.690001,19.98,19.98,88027400
12/12/2018,20.32,21.02,19.709999,20.48,20.48,100340700
12/13/2018,20.629999,20.870001,19.76,19.860001,19.860001,88108300
12/14/2018,19.58,20.700001,19.52,19.9,19.9,84713600

12/17/2018,20.01,20.02,18.639999,18.83,18.83,115437900
12/18/2018,19.15,19.84,18.879999,19.5,19.5,101512900
12/19/2018,19.440001,19.719999,18,18.16,18.16,120644500
12/20/2018,18.110001,18.860001,17.34,17.940001,17.940001,119394500
12/21/2018,18.120001,18.34,16.76,16.93,16.93,132246000
12/24/2018,16.52,17.219999,16.370001,16.65,16.65,62933100
12/26/2018,16.879999,17.91,16.030001,17.9,17.9,108811800
12/27/2018,17.43,17.74,16.440001,17.49,17.49,111373000
12/28/2018,17.530001,18.309999,17.139999,17.82,17.82,109214400
12/31/2018,18.15,18.51,17.85,18.459999,18.459999,84732200
1/2/2019,18.01,19,17.98,18.83,18.83,87148700
1/3/2019,18.42,18.68,16.940001,17.049999,17.049999,117277600
1/4/2019,17.549999,19.07,17.43,19,19,111878600
1/7/2019,19.440001,20.68,19,20.57,20.57,107157000
1/8/2019,21.190001,21.200001,19.68,20.75,20.75,121271000
1/9/2019,20.889999,21.440001,20.07,20.190001,20.190001,163944100
1/10/2019,19.76,19.83,18.9,19.74,19.74,115629400
1/11/2019,19.469999,20.35,19.190001,20.27,20.27,85110800
1/14/2019,19.959999,20.620001,19.75,20.23,20.23,71350200
1/15/2019,20.440001,20.68,20.26,20.379999,20.379999,62785800
1/16/2019,20.4,20.540001,19.709999,19.73,19.73,70849300
1/17/2019,19.49,20.51,19.02,20.25,20.25,85018400
1/18/2019,20.370001,21.049999,20.02,20.77,20.77,88131000
1/22/2019,20.48,20.92,19.700001,19.76,19.76,78513700
1/23/2019,20.030001,20.48,19.549999,19.799999,19.799999,77811300
1/24/2019,20.059999,21.01,20.040001,20.85,20.85,97433400
1/25/2019,20.99,22.030001,20.790001,21.93,21.93,110239500
1/28/2019,20.32,21.01,20.02,20.18,20.18,135164100
1/29/2019,20.26,20.389999,19.049999,19.25,19.25,131202500
1/30/2019,21.49,23.129999,21.370001,23.09,23.09,211421200
1/31/2019,23.02,25.139999,22.83,24.41,24.41,182575600
2/1/2019,24.610001,24.84,24.07,24.51,24.51,105356200
2/4/2019,24.43,24.66,24.07,24.129999,24.129999,70843800
2/5/2019,23.42,23.860001,22.98,23.309999,23.309999,122226000
2/6/2019,23.629999,24.139999,23.219999,23.26,23.26,78684300
2/7/2019,22.99,23.219999,22.32,22.67,22.67,86723900
2/8/2019,22.33,23.280001,22.27,23.049999,23.049999,78129300
2/11/2019,23.049999,23.280001,22.66,22.959999,22.959999,60578700
2/12/2019,23.43,23.559999,22.75,22.82,22.82,67595400
2/13/2019,22.98,23.24,22.709999,22.85,22.85,57544200
2/14/2019,22.74,23.370001,22.59,23.129999,23.129999,64441200
2/15/2019,23.58,24.049999,23.200001,23.68,23.68,78644100
2/19/2019,23.629999,24.41,23.610001,23.950001,23.950001,57517900
2/20/2019,24.139999,24.370001,23.9,23.950001,23.950001,57091600
2/21/2019,24.040001,24.33,23.85,23.92,23.92,49608200
2/22/2019,24.049999,24.360001,23.879999,24.360001,24.360001,52650700
2/25/2019,25.01,25.52,24.68,24.709999,24.709999,63221000

2/26/2019,24.65,24.719999,24.15,24.209999,24.209999,48470100
2/27/2019,24.110001,24.23,23.209999,23.48,23.48,62649300
2/28/2019,23.209999,23.67,23.110001,23.530001,23.530001,39384900
3/1/2019,23.969999,24.190001,23.450001,23.68,23.68,48084000
3/4/2019,23.889999,24.129999,23.01,23.370001,23.370001,48147700
3/5/2019,23.34,23.68,23.01,23.5,23.5,35462600
3/6/2019,23.469999,23.530001,22.4,22.41,22.41,60479400
3/7/2019,22.33,22.41,21.73,22.08,22.08,52186300
3/8/2019,21.35,22.09,21.040001,22.01,22.01,49967700
3/11/2019,22.15,23.08,21.98,22.959999,22.959999,54420200
3/12/2019,23.1,23.799999,22.780001,23.49,23.49,56410600
3/13/2019,23.66,24.15,23.35,23.379999,23.379999,56705800
3/14/2019,23.370001,23.49,22.799999,22.82,22.82,42818600
3/15/2019,23.1,23.65,23.01,23.290001,23.290001,46519900
3/18/2019,23.299999,23.620001,23.040001,23.25,23.25,34731800
3/19/2019,23.6,26.08,23.59,26,26,156052200
3/20/2019,26.49,26.879999,25.309999,25.700001,25.700001,151292100
3/21/2019,25.780001,28.110001,25.709999,27.889999,27.889999,129610300
3/22/2019,27.540001,27.75,26.33,26.370001,26.370001,115323300
3/25/2019,26.290001,26.99,25.540001,25.969999,25.969999,78438200
3/26/2019,26.690001,26.98,25.459999,25.690001,25.690001,75754100
3/27/2019,25.700001,25.879999,24.549999,24.889999,24.889999,88585300
3/28/2019,25.1,25.559999,24.65,25.059999,25.059999,64667500
3/29/2019,25.58,25.73,25.25,25.52,25.52,53502800
4/1/2019,26.42,26.559999,25.83,26.360001,26.360001,63000300
4/2/2019,26.51,26.799999,26.09,26.75,26.75,53358800
4/3/2019,28.02,29.950001,27.879999,29.02,29.02,197650500
4/4/2019,28.879999,29.389999,28.610001,29.09,29.09,82191100
4/5/2019,29.639999,29.690001,28.799999,28.98,28.98,65662700
4/8/2019,28.690001,28.950001,28.18,28.530001,28.530001,58002500
4/9/2019,28.24,28.379999,27.190001,27.24,27.24,75539800
4/10/2019,27.459999,28.120001,27.32,27.83,27.83,64368100
4/11/2019,27.809999,28.049999,27.459999,27.790001,27.790001,44801200
4/12/2019,28.209999,28.379999,27.66,27.85,27.85,41048800
4/15/2019,27.799999,27.84,26.959999,27.33,27.33,40812500
4/16/2019,27.719999,28.18,27.49,27.93,27.93,47340100
4/17/2019,28.209999,28.27,27.219999,27.49,27.49,48240800
4/18/2019,27.6,27.879999,27.34,27.68,27.68,39880900
4/22/2019,27.620001,28.23,27.389999,28.18,28.18,36477300
4/23/2019,28.18,28.49,27.790001,27.969999,27.969999,41777500
4/24/2019,28.1,28.85,27.93,28.459999,28.459999,51784700
4/25/2019,28.67,28.860001,27.360001,27.66,27.66,57329700
4/26/2019,27.66,27.9,27.049999,27.879999,27.879999,48827900
4/29/2019,27.9,28.139999,27.5,27.690001,27.690001,44532700
4/30/2019,27.59,27.799999,26.940001,27.629999,27.629999,73165900
5/1/2019,28.950001,29.15,26.780001,26.809999,26.809999,136066900
5/2/2019,26.940001,28.639999,26.610001,28.290001,28.290001,100514800

5/3/2019,28.299999,28.42,27.66,28.219999,28.219999,55503100
5/6/2019,26.719999,27.5,26.450001,27.42,27.42,70344100
5/7/2019,27.200001,27.35,26.209999,26.66,26.66,75868800
5/8/2019,26.41,27.709999,26.27,27.09,27.09,65967500
5/9/2019,26.700001,27.379999,26.030001,27.209999,27.209999,73150900
5/10/2019,27.030001,28.1,26.93,27.959999,27.959999,82930100
5/13/2019,26.98,27.23,26.1,26.24,26.24,99017900
5/14/2019,26.530001,27.48,26.15,27.32,27.32,82980400
5/15/2019,26.870001,27.790001,26.73,27.58,27.58,55689900
5/16/2019,27.370001,28.370001,27.27,28.01,28.01,67330100
5/17/2019,27.690001,28.459999,27.4,27.5,27.5,65385400
5/20/2019,26.98,27.24,26.49,26.68,26.68,69757400
5/21/2019,27.18,27.370001,26.93,27.35,27.35,46079200
5/22/2019,27.120001,27.59,27.07,27.41,27.41,40035300
5/23/2019,26.99,27.1,26.030001,26.360001,26.360001,67809200
5/24/2019,26.610001,26.93,26.4,26.440001,26.440001,39835800
5/28/2019,27.27,29.67,27.059999,29.049999,29.049999,146949600
5/29/2019,29,29.32,27.73,28.09,28.09,99969600
5/30/2019,28.4,28.559999,27.6,28.030001,28.030001,65289100
5/31/2019,27.57,28.360001,27.4,27.41,27.41,68667800
6/3/2019,28.75,29.620001,27.290001,27.58,27.58,147532200
6/4/2019,28.389999,29.59,27.91,29.57,29.57,107549500
6/5/2019,29.93,29.99,29.030001,29.5,29.5,79481500
6/6/2019,29.870001,31.98,29.84,31.82,31.82,131267800
6/7/2019,31.940001,32.599998,31.57,32.41,32.41,86841100
6/10/2019,33.529999,34.299999,33.080002,33.23,33.23,97668800
6/11/2019,33.43,33.490002,31.82,32.41,32.41,82834900
6/12/2019,32,32.57,31.92,32.18,32.18,56298700
6/13/2019,32.389999,32.5,31.059999,31.389999,31.389999,63556000
6/14/2019,30.700001,30.959999,30.02,30.360001,30.360001,70373000
6/17/2019,30.25,30.450001,29.18,29.200001,29.200001,70865700
6/18/2019,29.76,30.969999,29.58,30.450001,30.450001,86444500
6/19/2019,30.67,30.790001,30.059999,30.5,30.5,63233900
6/20/2019,31.24,31.360001,29.84,30.01,30.01,72418200
6/21/2019,29.65,30.35,28.969999,29.1,29.1,81861300
6/24/2019,29.32,29.4,28.67,29.26,29.26,55724800
6/25/2019,29.26,29.719999,28.799999,28.860001,28.860001,53680900
6/26/2019,29.98,30.48,29.780001,29.92,29.92,65064200
6/27/2019,30.41,30.959999,30.209999,30.74,30.74,55623300
6/28/2019,31.08,31.110001,30.33,30.370001,30.370001,50090900
7/1/2019,31.790001,32.040001,30.870001,31.200001,31.200001,60525500
7/2/2019,30.959999,31.26,30.73,31.24,31.24,37721700
7/3/2019,31.129999,31.33,30.74,31.190001,31.190001,23462000
7/5/2019,30.879999,31.559999,30.75,31.5,31.5,34011900
7/8/2019,31.799999,32.150002,31.26,32.040001,32.040001,49689400
7/9/2019,31.76,33.18,30.1,33.150002,33.150002,61419800
7/10/2019,33.560001,34.029999,33.360001,33.790001,33.790001,60388400

7/11/2019,33.91,34,32.759998,33.060001,33.060001,63081800
7/12/2019,32.759998,33.389999,32.59,33.209999,33.209999,51509700
7/15/2019,33.34,34.549999,33.27,34.389999,34.389999,65565200
7/16/2019,34.299999,34.860001,33.799999,33.849998,33.849998,66912700
7/17/2019,34.009998,34.299999,33.490002,33.599998,33.599998,42557900
7/18/2019,33.029999,33.459999,32.419998,33,33,58610900
7/19/2019,33.080002,33.349998,32.450001,32.509998,32.509998,44617700
7/22/2019,32.799999,33.310001,32.740002,32.849998,32.849998,37777300
7/23/2019,33.169998,33.5,32.93,33.490002,33.490002,38532500
7/24/2019,33.639999,34.360001,33.450001,34.110001,34.110001,41952300
7/25/2019,34.049999,34.25,33.619999,33.669998,33.669998,36705600
7/26/2019,34.23,34.77,33.869999,34.02,34.02,43502800
7/29/2019,34.139999,34.18,32.98,33.48,33.48,45922000
7/30/2019,33.209999,33.939999,32.939999,33.869999,33.869999,72198900
7/31/2019,32.080002,32.299999,30.299999,30.450001,30.450001,119190000
8/1/2019,30.5,31.48,29.1,29.860001,29.860001,80878900
8/2/2019,29.48,29.73,28.940001,29.440001,29.440001,60410900
8/5/2019,28.26,28.49,27.65,27.99,27.99,74333200
8/6/2019,28.860001,29.049999,28.200001,28.860001,28.860001,60578400
8/7/2019,28.469999,29.280001,28.370001,29.190001,29.190001,58577500
8/8/2019,31.530001,34.27,31.48,33.919998,33.919998,167278800
8/9/2019,33.450001,35.549999,33.080002,34.189999,34.189999,132483900
8/12/2019,34.16,34.650002,32.080002,32.43,32.43,106737000
8/13/2019,32.360001,33.139999,31.719999,32.110001,32.110001,102009700
8/14/2019,31,31.049999,29.51,30.24,30.24,127521500
8/15/2019,30.629999,30.73,29.209999,29.67,29.67,71674400
8/16/2019,30.309999,31.48,30.209999,31.18,31.18,70469800
8/19/2019,32,32.189999,31.42,31.48,31.48,67596900
8/20/2019,30.940001,31.309999,30.450001,30.719999,30.719999,47924000
8/21/2019,31.049999,31.74,30.84,31.700001,31.700001,41441500
8/22/2019,31.76,31.92,30.98,31.9,31.9,47667900
8/23/2019,31.299999,31.83,29.4,29.540001,29.540001,83681100
8/26/2019,30.34,30.719999,29.940001,30.280001,30.280001,50612500
8/27/2019,30.6,30.889999,29.6,30.200001,30.200001,53229200
8/28/2019,29.92,31.18,29.700001,30.780001,30.780001,55835900
8/29/2019,31.469999,31.83,31.33,31.450001,31.450001,44422800
8/30/2019,31.6,31.870001,31.129999,31.450001,31.450001,40307000

ŽIVOTOPIS AUTORA

Tomislav Medić

29.03.1991.

tmedic91@gmail.com

091/785-1224

RADNO ISKUSTVO

HelloFresh/Meritus Plus - Agent korisničke podrške (engleski jezik)

04.2018 - 12.2018 - Posao agenta korisničke podrške za američku firmu HelloFresh. Posao sam obavljao isključivo na engleskom jeziku putem livechat-a, e-maila i telefona.

Wüstenrot stambena štedionica d.d. - Mlađi financijski savjetnik

09.2013 - 02.2015 - Posao sam obavljao 6 mjeseci kao honorarni zaposlenik i godinu dana kao zaposlen na određeno (SSS). Posao je obuhvaćao prodaju štednje, životnog osiguranja i stambenih kredita. Uz prodaju sastavni dio posla bili su svakodnevna komunikacija s klijentima, rješavanje različitih problema i održavanje baze podataka (Excel).

Hypo Alpe-Adria-Bank d.d. - Agent u Call centru

03.2013 - 09.2013 - Posao koji sam obavljao 6 mjeseci preko studentskog ugovora. Agent u call centru odjela „Naplatu potraživanja“. Stečene vještine: komunikativnost, snalažljivost, rad pod pritiskom.

OBRAZOVANJE

Otvoreno učilište Algebra

04.2019 - (09.2019) - Tečaj „Programer Internet aplikacija - C# i ASP.NET“ u sklopu kojeg sam stekao vještine: C#, ASP.NET, MVC, MS SQL.

Ekonomski fakultet Zagreb - diplomski studij

10.2018 - (09.2019) - Diplomski studij, smjer „Menadžerska Informatika“. Tema diplomskog rada „Metode dubokog učenja za analizu i predviđanje tržišta dionica“.

Ekonomski fakultet Zagreb - preddiplomski studij

09.2009 - 06.2016 - Završio smjer „Poduzetništvo“ i stekao titulu univ.bacc.oec.

XVIII. Gimnazija Zagreb

09.2005 - 06.2009 - XVIII. Gimnazija jezična je gimnazija u Zagrebu u sklopu koje sam usavršio znanje engleskog jezika i stekao osnove njemačkog jezika.

ZNANJA I VJEŠTINE

Strani jezici:

- Engleski - napredno poznavanje jezika u govoru i pismu
- Njemački - osnovno poznavanje jezika u govoru i pismu

Tehničke vještine:

- C#, ASP.NET, MVC
- SQL - MS i Oracle
- Windows - napredno
- MS Office (Word, PowerPoint, Excel) - napredno
- MacOS, Linux - osnovno/srednje
- HTML/CSS- osnovno
- Python - osnovno
- Iznadprosječna brzina tipkanja (oko 90 wpm)
- Vozačka dozvola B kategorija

Hobiji: šah, plivanje, nogomet, mozgalice i programski zadaci (SoloLearn, Codewars), video igre