

Primjena metoda strojnog učenja u domeni tržišta kapitala

Ive Botunac

Odjel za informatiku, Sveučilište u Rijeci

Radmile Matejčić 2, 51 000 Rijeka

e-mail: ive.botunac@gmail.com

Sažetak – Zbog svojih nelinearnih i nestabilnih kretanja tržište kapitala kao jedan od bitnih dijelova financijske industrije predstavlja izazov istraživačima u provođenju analiza i predviđanja budućih kretanja. Razvojem računalne tehnologije kao i metoda strojnog učenja razvijaju se automatizirani sustavi trgovanja koji samostalno mogu donositi odluke o kupovini odnosno prodaji vrijednosnica. Ovakvi sustavi uvelike pomažu trgovcima kako bi mogli ostvariti što veći prinosi od trgovanja na ovakvim tržištima. U radu se prikazuju neke od najkorišteniji metoda strojnog učenja i njihova primjena u razvoju automatskog sustava za trgovanje. Prikazuju se i način definiranja strategija trgovanja koje na temelju modela predviđanja donose odluke.

Ključne riječi – strojno učenje, tržište kapitala, umjetne neuronske mreže, automatsko trgovanje, povratne neuronske mreže

I. UVOD

U vrijeme ekonomske globalizacije i napredaka računalne tehnologije primjena sofisticiranih rješenja u svim sferama ljudskih djelatnosti preuzima značajan udio. Ovom trendu priklonila se i financijska industrija u mnogim svojim područjima pri čemu kao jedno izdvajamo tržište kapitala. Tržište kapitala ovime predstavlja jedan od bitnih pokazatelja rasta i razvoja zemlje kao i tvrtki koje su sudionici tog tržišta. Sve većom dostupnošću podataka na ovom tržištu premašuje se ljudska sposobnom u njihovom ručnom analiziranju.

Podatci financijske vremenske serije su složeniji od ostalih statističkih podataka zbog dugoročnih promjenjivih trendova, cikličkih razlika, sezonskih promjena i općenito nepravilnih kretanja. Ovakvo ponašanje nastaje pod utjecajem brojnih vanjskih čimbenika, poput mnogih međusobno povezanih ekonomskih, političkih ili socijalnih fenomena. Neprekidni rast tako fluktuirajućih i neregularnih podataka doveo je do potrebe za razvijanjem automatiziranih sustava za učinkovitu analizu velikih financijskih vremenskih serija podataka kako bi se iz toga izvukle određene informacije [1].

Automatizirani sustavi trgovanja koriste napredne modele temeljene na metodama strojnog učenja za generiranje odluka o trgovanju kao što je predaja naloga o kupnji ili prodaji određene vrijednosnice. Jedna od najvećih prednosti automatiziranih sustava za trgovanja je ta što oni uklanjaju emocije u svom procesu donošenja odluke što s druge strane kod ljudi može rezultirati donošenjem pristrane odluke.

Kod razvoja ovakvog sustava potrebno je provesti tri etape. Prvo, sustav mora imati modele predviđanja koji na temelju prijašnjih podataka generiraju procjenu budućeg kretanje. U drugoj etapi potrebno je definirati strategije prema kojima sustav donosi odluku o kupnji ili prodaji te posljednjom etapom treba

provesti provjeru odnosno simulaciju nad povijesnim podacima sustava kako bi se dobila ocjena uspješnosti [2].

II. FINANCIJSKE VREMENSKE SERIJE

Podatci financijskih vremenskih serija koje promatramo na tržištu kapitala definirani su kao nizovi ponovljenih promatranih varijabli. Pri tome možemo nabrojati: cijene dionica, tečajne liste, povrat obveznica i cijene robe mjereno u ujednačenim vremenskim razmacima. Osnovne varijable financijskih vremenskih serija uključuju vremensku oznaku, cijenu otvaranja, najvišu cijenu, najnižu cijenu, cijenu zatvaranja i volumen trgovanja. Cijene se prate u određenoj vremenskoj frekvenciji i time se stvaraju ove vremenske serije. Osnovna značajka financijskih vremenskih serija je visoka učestalost pojedinačnih vrijednosti [3]. Ovom definicijom financijske vremenske serije su osnova za provođenje bilo koje vrste analize na tržištu kapitala, njih možemo nazvati polazišnom točkom.

A. Tehnički indikatori

Kao osnovu za provođenje tehničke analize možemo navesti korištenje tehničkih indikatora koji su matematički izračuni temeljeni na cijeni, količini ili otvorenom interesu nekog vrijednosnog papira, primjerice dionice ili burzovnog indeksa. Njih koriste uglavnom aktivni trgovci kako bi mogli analizirati kretanja cijena i na temelju toga predviđati buduća kretanja. Korištenje tehničkih indikatora može biti više informativno nego korištenje samo primjerice cijena i to je vrlo praktičan način za analitičare vrijednosnica i upravitelje fondova da analiziraju tržište kapitala [4].

III. METODE STROJNOG UČENJA

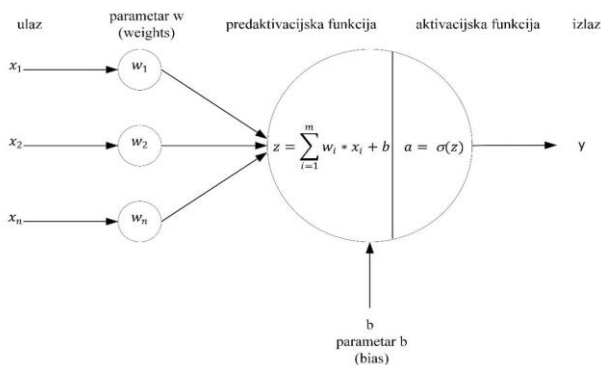
Kako bi se razvili automatizirani sustavi za trgovanje na tržištu kapitala nužno je koristiti neku od metoda strojnog učenja koja će biti najbolja za rješavanje postavljenog zadatka. Danas su dostupne brojne metode strojnog učenja koje gotovo svakodnevno bivaju unapređenje u cilju da se poboljšaju performanse izvedbe i time točnosti. Prema istraživanjima autora [5]–[7] možemo primijetiti da je veći trend korištenja umjetnih neuronskih mreža (engl. Artificial Neural Networks - ANN) i njihovih varijacija nego nekih drugih popularnih metoda. Također korištenjem stroja s potpornim vektorima (engl. Support Vector Machine - SVM) ili metodama ansambla (engl. Ensemble Methods) ostvareni su iznimni rezultati u mjeri točnosti klasifikacije trenda promatrane dionice [8][9].

A. Umjetne neuronske mreže

Umjetne neuronske mreže spadaju pod vrstu nadziranog strojnog učenja te je njihovo nastajanje inspirirano biološkim živčanim sustavom. Osnova umjetne neuronske mreže je neuron za kojega možemo reći da obavlja dvije operacije, nad ulazima obavlja se sumiranje što se dodatno naziva predaktivacijom koja predstavlja ulaz u tzv. prijenosnu funkciju što se naziva aktivacijom. Ukoliko se informacije u umjetnoj neuronskoj mreži kreću samo od ulaza u neuron, njegova izlaza pa u sljedeći neuron kažemo da se radi o unaprijednim neuronskim mrežama (engl. Feedforward Neural Network - FFNN) [10].

Na slici 1. nalazi se prikaz umjetnog neurona za kojeg možemo identificirati tri osnovna elementa:

- Skup veza od kojih je svaka okarakterizirana težinom koja čini njezinu vlastitu snagu. Signal x_i ulazne sinapse koja je spojena na neuron množi se s težinom w_i (engl. Weight).
- Zbrajanje svih ulaznih signala x_i pomnoženih s odgovarajućim težinama w_i
- Funkcija aktivacije za ograničavanje amplitude izlaznog signala neurona u kojoj se smanjuje dopušteni raspon amplitude izlaznog signala do neke konačne vrijednosti.



Slika 1. Model umjetnog neurona


Osim unaprijednih neuronskih mreža razlikujemo još i povratne neuronske mreže (engl. Recurrent Neural Network – RNN) te povratne neuronske mreže ćelijama s dugoročnom memorijom (engl. Long-Short Term Memory – LSTM). Kod standardnih unaprijednih neuronskih mreža podatci se kreću u samo jednom smjeru od ulaznog sloja prema izlaznom dok se kod povratnih može reći da podatci kruže kroz petlju. Povratna neuronska mreža unutar svakog čvora koristi određenu internu memoriju (engl. Context Unit) koja uzima informacije s prethodnih izlaza i standardno prosljeđenu ulaznu informaciju. Može se reći da povratna neuronska mreža svoj izračun generira na temelju sadašnje informacije i nedavne prošlosti. Upravo zbog ovoga svojstva, povratne neuronske mreže pokazale su se iznimno korisne kod sekvencijalnih podataka koji se mijenjaju s vremenom jer će u obzir uzeti prethodno naučene informacije iz danih vremenskih serija [10].

B. Stroj sa potpornim vektorima

Stroj s potpornim vektorima je metoda nadziranog strojnog učenja koja se koristi većinom za rješavanje klasifikacijskih zadataka. Ova metoda radi na način da neki skup označenih

podataka dijeli u određene klase koristeći pri tome liniju razdvajanja. Stroj s potpornim vektorima pokušava maksimizirati udaljenost između različitih klasa koje se nalaze u skupu podataka. Ovu udaljenost naziva se marginom iz čega slijedi što je margina veća, to je manja pogreška generalizacije klasifikatora. Važna karakteristika ove metode strojnog učenja je da se rješenje temelji samo na onim podatkovnim točkama koje se nalaze na rubovima margina nazvanih potpornim vektorima [11].

S obzirom na vektor $N \{x_1, x_2, \dots, x_N\}$ svaki vektor x_j ima m svojstva $\{a_{j1}, a_{j2}, \dots, a_{jm}\}$ I pripada jednoj od dvije klase C1 ili C2. Kažemo da su navedeni podatci linearno razdvajivi ako je moguće pronaći hiperliniju u zadanom prostoru koja može odvojiti između instanci iz klase C1 I instanci iz klasa C2.



Slika 2. Prikaz linearnog otvaranja podataka [20]

Na slici 2 prikazujemo linearno razdvajanje podataka u dvodimenzionalnom prikazu. Diskretna crta predstavlja hiperliniju razdvajanja [20].

C. Metode ansambla

Metode ansambla spadaju pod tehniku strojnog učenja koja kombinira nekoliko osnovnih metoda strojnog učenja kako bi se time stvorio optimalan model. Ovakvo kombiniranje metoda strojnog učenja je izrazito učinkovito jer se iskorištavanjem raznolikosti korištenih metoda može smanjiti ukupnu grešku čime se povećava točnost modela [12].

IV. MODELI PREDVIĐANJA

Kod razvoja automatiziranog sustava za donošenje odluka vezanih za trgovanje na tržištu kapitala kako je već u uvodu spomenuto treba provesti određene etape. Prva od etapa je razvoj modela predviđanja koji putem metoda strojnog učenja i podataka financijske vremenske serije mogu predviđati buduće linearno kretanje promatrane varijable ili binarno klasificirati kretanje samog trenda.

A. Obrada podataka

Jedna od prvih i temeljnih radnji koje se provode u samoj metodologiji kreiranja modela predviđanja je obrada podataka financijske vremenske serije. Obradom podataka želimo primjenom odgovarajućih tehnika transformirati podatke u oblik prihvatljiv za primjenu unutar odabranog modela strojnog učenja [21].

Pri početku obrade podataka moraju se definirati ulazne varijable na temelju kojih se predviđaju željene izlazne varijable.

Najčešće ulazne varijable čine prošle cijene zatvaranja, volumen trgovanja ili tehnički indikatori dok izlaznu varijablu čini predviđena cijena zatvaranja ili predviđen smjer kretanja trenda u obliku binarne klasifikacije. Za generiranje binarne klasifikacije trenda koristi se jednostavno pravilo: ako je vrijednost (i) veća od vrijednosti (i-1), onda je trend „1“ (u rastu), u suprotnom trend je „0“ (u padu) [21].

Nakon odabira varijabli i definiranja željenog izlaza podaci se normaliziraju unutar vrijednosti -1 i 1 kako bi se omogućili znatno brže izvršavanje modela te se isti dijele na trening i test set u različitim omjerima.

B. Mjere kvalitete izvedbe

Nakon odabira metode strojnog učenja i potom obrade podataka financijske vremenske serije slijedi izvršavanje modela predviđanja kako bi dobili rezultate koji se u daljnjim etapama koriste u automatiziranom sustavu trgovanja.

Kao mjeru uspješnosti ove regresijske analize najčešće koristimo:

Srednju apsolutnu pogrešku (engl. Mean Absolute Error - MAE) što označava prosjek razlike između stvarnih vrijednosti i predviđenih vrijednosti. Ona nam daje mjeru koliko daleko su predviđene vrijednosti udaljene od stvarnih vrijednosti, ali bez smjera udaljenosti.

Srednju apsolutnu pogrešku izračunava se pomoću jednadžbe:

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

Srednju kvadratnu pogrešku (engl. Mean Squared Error - MSE) koja je vrlo slična srednjoj apsolutnoj pogreški. Razlika je u tome što srednja kvadratna greška uzima prosjek kvadrata razlike između stvarnih vrijednosti i predviđenih vrijednosti.

Srednju kvadratnu pogrešku izračunava se pomoću jednadžbe:

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

Osim predviđanje točne buduće cijene zatvaranja odabrane vrijednosnice putem modela predviđanja možemo predviđati i budući trend. Kod predviđanja budućeg trena na temelju binarne klasifikacije dobivamo rezultat da li se predviđa rast ili pad. Kod rješavanja ovako postavljenog klasifikacijskog problema kao mjeru uspješnosti koristimo:

Točnost (engl. Accuracy - ACC) koja izračunava broj ispravnih predviđanja modela i to se izražava u postotku od 0 % do 100 %. Ovo je najčešće korišten mjerni pokazatelj kod rješavanja problema klasifikacije izračunava se putem izraza:

$$točnost = \frac{\text{broj stvarno pozitivnih} + \text{broj stvarno negativnih}}{\text{ukupni broj}} \quad (3)$$

F1 mjeru koja je harmonijska sredina preciznosti i opoziva te se često koristi mjera koja pokazuje pravu točnost modela. F1 mjera izračunava se pomoću jednadžbe:

$$F1 = 2 * \frac{\text{preciznost} * \text{opoziv}}{\text{preciznost} + \text{opoziv}} \quad (4)$$

V. SUSTAVI AUTOMATSKOG TRGOVANJA

U ovoj sekciji pobliže se opisuje sam proces druge etape u procesu razvoja automatiziranih sustava za trgovanje na tržištu kapitala. Prethodno definiran model predviđanja čini osnovnu za daljnju implementaciju ovog sustava te ujedno uz strategiju trgovanja čine najvažnije dijelove sustava. Mnoga istraživanja u ovom području znatno više pažnje prosvjeđuju točnosti svojih modela nego profitabilnosti koji ti modeli ostvaraju u smislu novčane kompenzacije. Predvidivost ne mora nužno podrazumijevati profitabilnost. Dobit ovisi ne samo o točnosti predviđanja, već i o korištenoj strategiji trgovanja i veličini transakcijskih troškova [13].

A. Strategija trgovanja

Kod razvoja automatiziranog sustava trgovanja potrebno je definirati strategije trgovanja koje koriste prethodno spomenute modele predviđanja. Kod brojnih autora [14]–[17] možemo pronaći različite pristupe u definiranju strategija kao i različite mjere koje se koriste u mjerenje performansi izvedbe sustava.

Nije dovoljno svaki put kad model predviđanja na izlazu generira signala o rastu ili padu trenda poduzeti radnju kupnje ili prodaje vrijednosnice. Dobra strategija trgovanja ne bi trebala u potpunosti koristiti rezultate modela predviđanja, već bi trebala u obzir uzeti i postojeće pozicije u kojoj se nalazi sam trgovac pri generiranju trgovačkih naloga prodaje ili kupnje.

B. Primjer strategije 1: Osnovna strategija

Ka lakšem razumijevanju strategije trgovanja možemo promotriti primjer osnovne strategije trgovanja. Ukoliko na dan t+1 modelom predviđanja dobijemo rezultat 1 što označava rast trenda, na dan t otvoriti ćemo nalog za kupnju. Suprotno od toga ukoliko je na dan t+1 modelom predviđanja dobiven rezultat 0 što označava pad trenda, otvoriti ćemo nalog za prodaju. Osim ove jednostavne strategije trgovanja broji autori [14]–[17] razvili su daleko naprednije strategije od kojih se neke prikazuju u nastavku sekcije.

C. Primjer strategije 2: Stohastički oscilator %K i %D i Williams %R oscilator [16]

U ovoj strategiji signali za kupovinu/prodaju generiraju se temeljem tehničkih indikatora %K, %D i WILL%R [16].

Stohastički oscilator %K i %D su indikatori koji prate i uspoređuju cijenu zatvaranja s cjenovnim rasponom tijekom određenog razdoblja. Trenutačna cijena tada se izražava kao postotak tog raspona s 0% što ukazuje na dno raspona i 100 % što ukazuje na gornju granicu raspona tijekom promatranog vremenskog razdoblja [18].

$$\%K = 100 \frac{P - Pl_n}{Ph_n - Pl_n} \quad (5)$$

Gdje P označava cijenu zatvaranja trenutnog dana, Pl_n i Ph_n označavaju najnižu i najvišu cijenu tijekom promatranog perioda.

Potom slijedi jednadžba za stohastički oscilator %D:

$$\%D = EMA(\%K, 3) \quad (6)$$

Williams %R oscilator prikazuje se kao razlika trenutne cijene te najviše i najniže cijene u promatranom periodu. Prilikom izračuna najčešće se odabiru razdoblja od 14 i 28 dana [19].

Williams %R oscilator prikazuje se jednadžbom:


$$\%R = 100 \frac{P_{h(n)} - P}{P_{h(n)} - P_{l(n)}} \quad (7)$$

gdje oznake indeksa $h(n)$ i $l(n)$ prikazuju najvišu odnosno najnižu zaključnu cijenu promatranog razdoblja.


Kad su %K i %D indikatori na visokoj razini (dostižu 80%), a %D indikator prelazi %K indikator s gornje na donju, stručnjaci predlažu prodaju vrijednosnice. Suprotno tome, kada su %K i %D indikatori na niskoj razini (dostižu 20%), a %D indikator prelazi %K indikator s donje na gornju, stručnjaci savjetuju kupnju vrijednosnice.

Kada je došlo do presijecanja %K i %D oscilatora na nižoj razini (manje od 20%), a vrijednost WILL%R iznosi 100% generira se točka za kupnju prikazana na slici 1 i 2.

Kad je došlo do presijecanja %K i %D na višoj razini (većoj od 80%), a vrijednost WILL%R je 0% generira se točka prodaje prikazana na slici 3 i 4.



Slika 3. %K i %D oscilator [16]



Slika 4. WILL%R oscilator [16]

D. Primjer strategije 3: Guided D-threshold [14]

Ova strategija se bazira na predviđanju, odnosno klasifikaciji trenda povrata ulaganja što je čini drugačijom od ostalih strategija koje se temelje na predviđanju trenda same cijene [14].

Ako model predvidi da će dnevna najviša cijena za promatranu vrijednosnicu j porasti sljedeći dan t , te ako je relativna razlika između najviše cijene zatvaranja prethodnog

dana ($high_{t-1}$) i cijene otvaranja trenutnog dana ($open_t$) (1) veća od postavljenog praga D izvršiti (optimalni D postavlja se eksperimentalno) će se kupnja promatrane vrijednosnice j . Ukoliko je dogodi obrnuta situacija da je cijena manja taj dan se neće trgovati sa vrijednosnicom j .

$$relative\ diff_{t,j} = \left(\frac{high_{t-1,j}}{open_{t,j}} - 1 \right) \times 100 \quad (8)$$

Rezultati istraživanja [14] gdje je korištena ova strategija prikazani su koristeći mjeru prosječne stope godišnjeg rasta (engl. Compound Annual Growth Rate – CAGR) te kao model predviđanja korišten je stroj sa potpornim vektorima sa raznim postavkama. Ovisno o postavkama ostvarivani su rezultati od 22.67% do visokih 48.07% rasta u spomenutoj mjeri. Kako bi se napravila usporedba za osnovni pokazatelj koristio se burzovni indeks S&P 500 koji prosječno ostvaruje rast od 4.17% u istoj mjeri CAGR.

E. Simulacija trgovanja

Zadnja od spomenutih etapa u razvoju automatiziranog sustava za trgovanje na tržištu kapitala je upravo simulacija trgovanja (engl. Backtest). Provođenjem simulacije trgovanja možemo dobiti određene mjere uspješnosti u vidu povrata ulaganja i time ocijeniti uspješnost modela predviđanja i strategije trgovanja. Upravo provedene simulacije marketa označava jednu prednost automatiziranog trgovanja nad ljudskim trgovcima.

Simulacija funkcionira na način da se na temelju povijesnih financijskih vremenskih serija simulira okruženje u kojem se model predviđanja i strategije trgovanja izvršavaju u prošlosti gdje mi znamo kako su se trendovi kretali dok samo simulacijsko okruženje nema taj podataka. Simulacijsko okruženje dalje pomaže programerima kako bi poboljšali strategije trgovanja i ispravljali greške ne bi li time ostvarili bolje rezultate.

VI. ZAKLJUČAK I BUDUĆI RAD

U ovom radu napravljen je pregled postupka za razvoj automatiziranog sustava za trgovanje na tržištu kapitala koristeći metode strojnog učenje. Cilj je bio prikazati kako se putem metoda strojnog učenja na tržištu kapitala mogu predviđati buduća kretanja i na temelju tih predviđanja razviti sustavi za pomoć trgovcima pri donošenju investicijski odluka.

Temeljni dio pri razvoju ovakvih sustav čine modeli predviđanja koji na temelju podataka financijskih vremenskih serija predviđaju buduća kretanja na tržištu kapitala. Na temelju rezultata ovih modela definiraju se strategije trgovanja koje se izvršavaju ovisno o postavljenim uvjetima koji se trebaju zadovoljiti. Daljnjim postupkom na temelju strategija trgovanja sustav donosi odluku o kupnji, prodaju ili čekanju te pokretanju naloga za izvršavanje istih. Ovakvi sustavi trgovcima mogu poslužiti kao dodatni alat u procesu donošenja odluka i izvor informacija kako bi ostvarili što bolje prinose kao rezultat trgovanja.

U ovom području postoji daljnji prostor za unapređenje kako modela predviđanja tako i strategija prema kojim sustav donosi odluke. Jedan od većih izazova za buduća istraživanja je uključivanje sentiment podataka dobivenih sa raznih portala i društvenih mreža u proces predviđanja budućih kretanja i u proces definiranja strategija za donošenje odluka. Također na temelju priklopljeni podataka mogu se razviti skeneri i sustavi za

preporuku koji bi trgovcima pomogli pri donošenju prve odluke o odabiru vrijednosnice prije nego li započne samo predviđanje i trgovanje.

LITERATURA

- [1] R. Dash & P. K. Dash, "A hybrid stock trading framework integrating technical analysis with machine learning techniques," *J. Financ. Data Sci.*, vol. 2, no. 1, pp. 42–57, 2016.
- [2] N. Lu & S. Alvarez, "A Machine Learning Approach to Automated Trading," 2016.
- [3] J. Arlt & M. Arltová, "Financial Time Series and Their Features," *Acta oeconomica pragensia VŠE Praha*, vol. 9, no. 4, pp. 7–20, 2001.
- [4] M. Göçken, M. Özçalici, A. Boru, & A. T. Dosdogru, "Integrating metaheuristics and Artificial Neural Networks for improved stock price prediction," *Expert Syst. Appl.*, vol. 44, pp. 320–331, 2016.
- [5] T. Fischer & C. Krauss, "Deep learning with long short-term memory networks for financial market predictions," *Eur. J. Oper. Res.*, vol. 270, no. 2, pp. 654–669, 2018.
- [6] W. Long, Z. Lu, & L. Cui, "Deep learning-based feature engineering for stock price movement prediction," *Knowledge-Based Syst.*, vol. 164, pp. 163–173, 2019.
- [7] M. Hansson, "On stock return prediction with LSTM networks," 2017.
- [8] B. Weng, "Application of machine learning techniques for stock market prediction," Auburn University, 2017.
- [9] B. Weng, L. Lu, X. Wang, F. M. Megahed, & W. Martinez, "Predicting short-term stock prices using ensemble methods and online data sources," *Expert Syst. Appl.*, vol. 112, pp. 258–273, 2018.
- [10] M. A. Nielsen, "Neural Networks and Deep Learning." Determination Press, 2015.
- [11] A. Tandel, "Support Vector Machines — A Brief Overview - Towards Data Science," 2017. [Online]. Available: <https://towardsdatascience.com/support-vector-machines-a-brief-overview-37e018ae310f>. [Accessed: 20-Oct-2019].
- [12] C. Zhang & Y. Ma, *Ensemble machine learning: Methods and applications*. 2012.
- [13] M. Qi & G. S. Maddala, "Economic factors and the stock market: A new perspective," *J. Forecast.*, vol. 18, no. 3, pp. 151–166, 1999.
- [14] M. Gorenc Novak & D. Velušček, "Prediction of stock price movement based on daily high prices," *Quant. Financ.*, vol. 16, no. 5, pp. 793–826, 2016.
- [15] C. Tilakaratne, "Predicting stock market index trading signals using neural networks," *Proc.*, no. i, pp. 1–14, 2007.
- [16] P. C. Chang, C. H. Liu, J. L. Lin, C. Y. Fan, & C. S. P. Ng, "A neural network with a case based dynamic window for stock trading prediction," *Expert Syst. Appl.*, vol. 36, no. 3 PART 2, pp. 6889–6898, 2009.
- [17] W. C. Chiang, D. Enke, T. Wu, & R. Wang, "An adaptive stock index trading decision support system," *Expert Syst. Appl.*, vol. 59, pp. 195–207, 2016.
- [18] J. L. Person, *Complete Guide to Technical Trading Tactics*. Wiley Trading, 2004.
- [19] J. J. Murphy, *Technical Analysis in Financial Markets*. New York Institute of Finance, 1999.
- [20] M. Mohammed, M. B. Khan & E. B. M. Bashiet, *Machine Learning: Algorithms and Applications*, CRC Press, 2017
- [21] I. Botunac, A. Panjkota & M. Matetic, *The importance of time series data filtering for predicting the direction of stock market movement using neural networks*, Proceedings of the 30th DAAAM International Symposium, 2019