

Na tehničkoj analizi zasnovano algoritamsko trgovanje

Konjevod, David

Master's thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Electrical Engineering and Computing / Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:168:684507>

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

Download date / Datum preuzimanja: **2025-04-01**



Repository / Repozitorij:

[FER Repository - University of Zagreb Faculty of Electrical Engineering and Computing repository](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 671

**NA TEHNIČKOJ ANALIZI ZASNOVANO ALGORITAMSKO
TRGOVANJE**

David Konjevod

Zagreb, lipanj 2024.

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 671

**NA TEHNIČKOJ ANALIZI ZASNOVANO ALGORITAMSKO
TRGOVANJE**

David Konjevod

Zagreb, lipanj 2024.

DIPLOMSKI ZADATAK br. 671

Pristupnik: **David Konjevod (0036518805)**

Studij: Računarstvo

Profil: Računarska znanost

Mentor: prof. dr. sc. Damir Seršić

Zadatak: **Na tehničkoj analizi zasnovano algoritamsko trgovanje**

Opis zadatka:

U sklopu diplomskog rada, cilj je implementirati algoritamsko trgovanje financijskim instrumentima koje se temelji na tehničkoj analizi. Ovo uključuje detaljnu analizu, obradu i ekstrakciju karakteristika iz vremenskih nizova financijskih podataka. Potrebno je precizno definirati ciljeve analize financijskih signala i opisati ključne značajke koje ih čine relevantnima za postavljeni zadatak. Proces dalje uključuje razradu i usporedbu različitih modela trgovanja. To obuhvaća klasični pristup koji se temelji na unaprijed definiranim pravilima, pristup koji se oslanja na algoritme strojnog učenja, kao i model predikcije koji se dizajnira na temelju analize događaja iz prošlosti i sadašnjosti. Svaki od ovih pristupa ima svoje specifičnosti i prednosti, te će se detaljno razmotriti kako bi se utvrdilo koji je najprikladniji za dati kontekst. Ključni korak u evaluaciji ovih modela je testiranje na neovisnim skupovima financijskih podataka koji nisu korišteni u fazi analize i učenja. Ovo osigurava pouzdanost i poopćivost rezultata, omogućujući validaciju performanci algoritama u realnim uvjetima trgovanja.

Rok za predaju rada: 28. lipnja 2024.

Ovaj diplomski rad ne bi bio moguć bez podrške i pomoći mnogih ljudi kojima sam izuzetno zahvalan.

Prije svega, želim izraziti svoju duboku zahvalnost svom mentoru, prof. dr. sc. Damiru Šerešiću, na strpljenju, stručnim savjetima i neiscrpoj podršci tijekom cijelog procesa izrade ovog rada. Vaše znanje i vodstvo bili su neprocjenjivi.

Posebnu zahvalnost dugujem svojoj obitelji, koja je uvijek bila uz mene, pružala mi podršku i poticala me da nastavim dalje, čak i u trenucima kada sam sumnjao u sebe. Hvala vam što ste vjerovali u mene. Veliko hvala majci Mariji, ocu Peri, bratu Božidaru, sestrama Dragani, Ivani i Anđeli.

Hvala i svim profesorima, asistentima, nastavnom i nenastavnom osoblju i kolegama s Fakulteta elektrotehnike i računarstva u Zagrebu, koji su svojim predavanjima, savjetima i prijateljstvom doprinijeli mom akademskom razvoju i uspjehu.

Na kraju, želim zahvaliti svim prijateljima i kolegama koji su mi bili podrška i motivacija kroz ove godine studiranja. Vaše razumijevanje, podrška i druženje učinili su ovaj put lakšim i ugodnijim. Hvala na jednom prekrasnom i nezaboravnom putovanju.

Ovaj rad posvećujem svima vama.

SADRŽAJ

1. Uvod	1
1.1. Burza	2
1.2. Motivacija	3
1.3. Postavljanje problema	3
1.4. Ciljevi	4
2. Algoritamsko trgovanje	5
2.0.1. Kratki povijesni osvrt	5
2.1. Strategije trgovanja	7
2.2. Sustav za algoritamsko trgovanje	8
3. Tehnička analiza financijskih vremenskih nizova	11
3.0.1. Razlike između Tehničke i Temeljne Analize	12
3.1. Tehnički indikatori	12
4. Jednostavne metode	14
4.1. Prikaz skupa podataka	14
4.2. Strategija temeljena na jednostavnim pomičnim prosjecima	17
4.2.1. Strategija presjeka pomičnih prosjeka	18
4.2.2. Metrike za evaluaciju strategija	21
4.2.3. Evaluacija strategije temeljene na presijecima jednostavnih pomičnih prosjeka	26
4.3. Indeks relativne snage (engl. <i>Relative Strength Index, RSI</i>)	30
4.4. Zaključak za jednostavne metode	38
5. Moderni pristup	39
5.1. Transformator	39
5.1.1. Motivacija	40
5.1.2. Arhitektura	40

5.1.3.	Ugrađivanje ulaza (engl. Input Embedding)	41
5.1.4.	Pozicijsko kodiranje	43
5.1.5.	Koder i Dekoder	44
5.1.6.	Softmax	48
5.2.	Primjena transformator modela na cijene nafte	49
5.2.1.	Priprema Podataka	49
5.2.2.	Rezultati	54
5.2.3.	Monetizacija predikcija strategijom za trgovanje	57
6.	Budući rad	59
7.	Zaključak	60
	Literatura	62

1. Uvod

Živimo u doba stalnih promjena, a čak ni tradicionalne industrije nisu imune na poremećaje. Ovo je vrijeme nove industrijske revolucije u kojoj računarstvo i umjetna inteligencija pronalaze svoju primjenu u svakoj grani čovjekovog djelovanja.

Financije su danas najrasprostranjenija globalna industrija, a trgovina je jedna od najstarijih industrija čovječanstva. Trgovina roba postoji od davnina i predstavlja jedan od temeljnih aspekata ljudske interakcije. Počela je kao način za ljude da zadovolje svoje potrebe ili želje za dobrima koje nisu mogli sami proizvesti. Prvi tragovi trgovine datiraju iz prapovijesnog doba, kada su ljudi razmjenjivali alate i druge proizvode na velike udaljenosti.

Kako su društva napredovala, trgovina je postala sve složenija, potičući razvoj novih oblika razmjene dobara i usluga. Zamjena je bila jedan od najranijih oblika trgovanja, gdje su ljudi razmjenjivali robu ili usluge za druge artikle ili usluge. Iako je ovaj sustav uspješno funkcionirao stoljećima, često je bilo izazovno pronaći osobu koja je imala potrebne artikle ili bila spremna na razmjenu. Kako bi prevladali ove izazove, neka primitivna društva su koristila različite predmete kao zamjenu za novac, poput školjki ili bisera, kako bi olakšala trgovinu.

U drevnim civilizacijama poput Mezopotamije i Egipta, zlatne poluge su korištene kao oblik valute, ali proces trgovine bio je složeniji jer su težina i vrijednost tih poluga morale biti provjerene svaki put kada se obavljala razmjena dobara. Međutim, razvoj metalnih kovanica, koji se procjenjuje da se dogodio između 700. i 500. godine prije Krista, donio je revoluciju u trgovini. Standardizirajući koncept vrijednosti, kovanice su omogućile lakše brojanje i razmjenu bez potrebe za vaganjem, što je značajno pojednostavilo trgovinu.

Kada su zlatni i srebrni novčići počeli kružiti oko 500. godine prije nove ere, trgovina među različitim zemljama postala je moguća zbog standardizirane vrijednosti ovih plemenitih metala. To je omogućilo zemljama s viškom određenih proizvoda da ih prodaju drugim nacijama koje su ih trebale, potičući međunarodnu trgovinu i ekonomski rast. Iako se osnovne ideje o trgovini nisu mnogo promijenile od prapovijesti,

tehnološki napredak tijekom prošlog stoljeća doveo je do potpunog preoblikovanja načina na koji obavljamo transakcije.

Danas su financijska tržišta složena i sofisticirana, s širokim rasponom instrumenata i trgovačkih strategija na raspolaganju. Igraju ključnu ulogu u globalnoj ekonomiji, olakšavajući protok kapitala i omogućavajući poduzećima pristup sredstvima potrebnima za rast i inovacije. Financijska tržišta prošla su dug put od ranih dana zamjene i trgovine i nastavljaju se razvijati kako se pojavljuju moderne tehnologije i inovacije.

1.1. Burza

U svijetu financija, pojam burze predstavlja ključnu instituciju koja omogućuje trgovanje vrijednosnim papirima i drugim financijskim instrumentima. Burze, poput tržišta dionica, funkcioniraju kao centralizirana platforma na kojoj se izdaju i trguju dionicama javnih poduzeća, omogućujući investitorima da sudjeluju u razvoju tvrtki i dijele u njihovom uspjehu.

Investitori, kako pojedinci tako i financijske institucije, koriste burze kao mjesto za kupnju i prodaju dionica radi ostvarivanja različitih financijskih ciljeva. Kroz inicijalnu javnu ponudu (IPO), tvrtke mogu prikupiti kapital od investitora prodajom svojih dionica na burzi. Ovaj kapital može se koristiti za proširenje poslovanja, ulaganje u nove projekte ili druge strategije rasta.

Tržišta dionica omogućuju investitorima da trguju dionicama na transparentan i reguliran način. Ovdje se cijene dionica formiraju na temelju očekivanja investitora o budućoj vrijednosti tvrtki. Strogi nadzor i pravila osiguravaju poštenu trgovinu i transparentnost, što doprinosi povjerenju investitora u tržište.

Osim što predstavljaju indikator ekonomskog zdravlja, tržišta dionica pružaju različite mogućnosti ulaganja, uključujući dionice, obveznice, ETF-ove, opcije i druge izvedenice. Investitori mogu koristiti ove instrumente kako bi ostvarili prihod ili izgradili bogatstvo tijekom vremena, ali s obzirom na visok potencijalni rizik, važno je pažljivo upravljati ulaganjima.

Danas, moderne burze su visoko tehnološke i globalne. Elektroničke platforme za trgovanje omogućuju investitorima da trguju dionicama na burzama diljem svijeta putem interneta. Burze igraju ključnu ulogu u poticanju gospodarskog rasta i prosperiteta putem podrške inovativnim tvrtkama i olakšavanjem pristupa kapitalu. Stoga, prisutnost burzi je ključna za funkcioniranje modernih gospodarstava koja se oslanjaju na slobodnom tržišnom kapitalizmu.

1.2. Motivacija

Algoritamsko trgovanje predstavlja dinamično rastuće područje unutar financijske industrije koje se oslanja na napredne matematičke modele i računalne algoritme kako bi automatski izvršavalo trgovanje. S napretkom tehnologije i sve većom dostupnošću obilja financijskih podataka, algoritamsko trgovanje privlači sve veću pažnju trgovaca i ulagača.

Ovo područje već značajno oblikuje globalna tržišta. U Sjedinjenim Američkim Državama, algoritamsko trgovanje sudjeluje u 60% do 73% trgovine dionicama, dok u Europi ta brojka iznosi 60%, a na azijsko-pacifičkom području 45%(8). Očekuje se značajan rast veličine tržišta algoritamskog trgovanja, s predviđenim porastom sa 15,77 milijardi USD u 2023. na 23,74 milijarde USD do 2028. Ova putanja rasta odražava snažnu prosječnu godišnju stopu rasta od 8,53 posto tijekom cijelog predviđenog razdoblja (2023. - 2028.)(24).

Sofisticirani matematički modeli i statističke analize koriste se kako bi se otkrili obrasci i trendovi u obilju financijskih podataka. Njihova upotreba obuhvaća različite svrhe, kao što su analiza tržišta, upravljanje rizicima i provođenje trgovinskih operacija. Donošenje trgovinskih odluka uz pomoć algoritama postao je uobičajen način ponašanja na financijskim tržištima. Trgovci ih mogu koristiti za razvijanje strategija koje automatski izvršavaju trgovinske aktivnosti na temelju određenih tržišnih uvjeta, poput promjena cijena ili pojavljivanja određenih signala. Na primjer, algoritam može pokrenuti kupnju dionica kada njihova cijena dosegne određenu razinu ili kada se pojavi važna vijest ili događaj.

Zbog svega ovog, ovo područje predstavlja zanimljivo i dinamično područje za istraživanje, te pruža mnogobrojna područja primjene u budućnosti.

1.3. Postavljanje problema

Financijska tržišta i signali izloženi su dinamičnim promjenama i složenim uzorcima, predstavljaju složeno područje istraživanja u kojem sve značajniju ulogu igra umjetna inteligencija, statistika, znanost o podacima i algoritamski pristup. Kako bi se stvorio algoritam za trgovanje najčešće koriste dva pristupa a to su tehnička i fundamentalna analiza. U sklopu ovog diplomskog rada fokus će biti na korištenju tehničke analize financijski signala kako bi se stvorila prednost pri trgovanju. Zadatak pred nama pokriva analizu i obradu vremenskih slijedova podataka kako bih izvukli relevantne značajke signala. Signali će biti ključni za odlučivanje o trgovanju, tehničkom analizom tih sig-

nala potrebno je steći prednost u odnosu na osnovne pristupe i ljudsko trgovanje. Cilj je analizirati i usporediti postojeća rješenja, te simulirati samostalni sustav za trgovanje. Potrebno je proučiti jednostavni pristup temeljen na klasičnim metodama i moderni pristup temeljen na modelima strojnog učenja za predikciju budućih cijena.

1.4. Ciljevi

Cilj istraživanja je istražiti, implementirati te usporediti različite strategije trgovanja temeljene ili na strogo definiranim pravilima zasnovanim na iskustvu i matematičkoj podlozi, ili strategije koje proizlaze iz modela strojnog učenja generirajući signale za kupovinu i prodaju. Konačno rješenje su strategije temeljena na jednostavnim i modernim metodama, u okviru ovog istraživanja/diplomskog rada nećemo primjenjivati strategije u stvarnom radu. Svrha je istražiti i proučiti mogućnosti ovog pristupa trgovanju te ispitati rizik i mogući povrat različitih strategija kako bismo pružili bolju podlogu za daljnju realizaciju ovakvih sustava za samostalno automatizirano trgovanje bez ljudskog nadzora.

2. Algoritamsko trgovanje

Algoritamsko trgovanje (engl. *Algorithmic Trading*) odnosi se na korištenje računalnih programa za automatsko izvršavanje trgovinskih naloga prema unaprijed definiranim pravilima i strategijama. Ova vrsta trgovanja koristi matematičke modele i statističke analize za donošenje odluka o trgovanju, smanjujući ljudsku intervenciju i subjektivnost. Algoritmi mogu analizirati tržišne podatke u stvarnom vremenu, prepoznati trgovačke prilike i izvršiti naloge brže nego što bi to bilo moguće ručno. (7) Algoritamsko trgovanje koristi različite vrste podataka, uključujući cijene dionica, volumene trgovanja, tehničke indikatore, i druge relevantne informacije. Cilj je optimizirati profit i minimizirati rizik putem automatiziranih strategija koje mogu uključivati razne strategije. (3) Algoritamsko trgovanje obuhvaća tri glavne kategorije algoritama: algoritme za izvršenje naloga, algoritme za traženje profita poznate kao "crne kutije" i algoritme visokofrekventnog trgovanja (engl. *High-Frequency Trading, HFT*). Iako se ove kategorije u stvarnom svijetu često preklapaju, zajedničko im je to što svi koriste automatizirane procese za obavljanje financijskih transakcija i donošenje odluka. (6)

2.0.1. Kratki povijesni osvrt

Algoritamsko trgovanje prvi se put pojavilo krajem 20. stoljeća, točnije tijekom 1970-ih i 1980-ih godina, kada su brokerske kuće i investicijske banke počele koristiti računala za bržu i precizniju izvedbu transakcija. U početku su se koristili jednostavni programi za izvršenje naloga s ciljem smanjenja troškova trgovanja i poboljšanja brzine izvršenja. Računala su preuzimala zadatke poput upravljanja narudžbama i izvođenja jednostavnih strategija trgovanja (1).

Tijekom 1990-ih, razvoj tehnologije, posebno interneta, omogućio je brži prijenos podataka i poboljšanu komunikaciju između tržišnih sudionika, što je dovelo do sofisticiranijih algoritama i strategija, uključujući arbitražu i trgovanje temeljem kvantitativnih modela (4). Algoritamsko trgovanje doživjelo je pravu eksploziju popularnosti tijekom 2000-ih kada su tržišta postala elektronička, a platforme poput NASDAQ-a

omogućile bržu i učinkovitiju trgovinu. Hedge fondovi i investicijske banke počele su intenzivno koristiti algoritamske strategije.

Pojava visokofrekventnog trgovanja (HFT) tijekom 2010-ih označila je novo doba u algoritamskom trgovanju. HFT koristi vrlo brze algoritme za izvršenje velikog broja transakcija u milisekundama, što je postalo kontroverzno zbog potencijalnog utjecaja na tržišnu stabilnost (13). Danas algoritamsko trgovanje dominira mnogim financijskim tržištima, a tehnologija je napredovala do te mjere da algoritmi mogu obrađivati velike količine podataka u stvarnom vremenu, koristeći napredne modele strojnog učenja i umjetne inteligencije za donošenje trgovačkih odluka (1).

Algoritamsko trgovanje koristi se za različite strategije, uključujući arbitražu, trgovanje na temelju novinskih vijesti i sentiment analizu. Očekuje se da će algoritamsko trgovanje nastaviti rasti i evoluirati, a napredak u umjetnoj inteligenciji, kvantnom računalstvu i analizi podataka vjerojatno će dodatno poboljšati sposobnosti trgovačkih algoritama. Regulatori će također nastaviti razvijati nove mjere kako bi osigurali tržišnu stabilnost i spriječili zlouporabe (4).

Algoritamsko trgovanje prošlo je dug put od svojih skromnih početaka u 1970-ima do danas, kada dominira mnogim financijskim tržištima. Razvoj tehnologije, računalne moći i analitičkih metoda omogućio je stvaranje sofisticiranih trgovačkih strategija koje značajno utječu na način funkcioniranja financijskih tržišta.

Prednosti

Jedna od glavnih prednosti algoritamskog trgovanja je brzina izvršenja naloga. Algoritmi mogu izvršiti trgovinske naloge u milisekundama, što ljudski trgovci ne mogu postići. Ovo omogućava iskorištavanje sitnih tržišnih anomalija koje traju vrlo kratko. (1) Druga prednost je mogućnost obrade velikih količina podataka u stvarnom vremenu. Algoritmi mogu analizirati i koristiti razne vrste podataka, uključujući cijene dionica, volumene trgovanja, tehničke indikatore i druge relevantne informacije, što im omogućava donošenje informiranih trgovačkih odluka. (3) Treća prednost je eliminacija emocija iz procesa trgovanja. Algoritmi djeluju prema unaprijed definiranim pravilima i strategijama, čime se smanjuje mogućnost donošenja iracionalnih odluka temeljenih na strahu ili pohlepi. (4)

Nedostatci

Jedna od glavnih mana algoritamskog trgovanja je složenost izrade i održavanja algoritama. Potrebno je veliko znanje i iskustvo u programiranju, matematici i financijama

kako bi se razvili učinkoviti algoritmi.

Druga mana je rizik od tehnoloških problema i kvarova. Algoritmi se oslanjaju na tehnologiju koja može biti podložna kvarovima, pogreškama u kodiranju ili kibernetičkim napadima. Ovi problemi mogu dovesti do značajnih gubitaka. (13)

Treća mana je potencijalni negativan utjecaj na tržište. Visokofrekventno trgovanje može dovesti do povećane volatilnosti tržišta i smanjenja likvidnosti, što može negativno utjecati na druge sudionike na tržištu. (1)

Konačno, algoritamsko trgovanje može dovesti do povećanog rizika od regulatornih problema. Kako se tržišta i regulacije mijenjaju, algoritmi se moraju kontinuirano prilagođavati kako bi bili u skladu s novim pravilima i propisima. (4)

2.1. Strategije trgovanja

U suvremenom financijskom tržištu, strategije trgovanja igraju ključnu ulogu u postizanju profitabilnosti i smanjenju rizika. Korištenjem različitih metoda i alata, ove strategije omogućuju analizu tržišta i donošenje informiranih odluka o kupnji i prodaji financijskih instrumenata. Strategija trgovanja je skup pravila i smjernica koje trgovac primjenjuje kako bi odredio najpovoljnije vrijeme za kupnju i prodaju financijske imovine. Ove strategije mogu se temeljiti na tehničkoj analizi, fundamentalnoj analizi ili njihovoj kombinaciji. Tehnička analiza uključuje korištenje grafikona i drugih alata za prepoznavanje obrazaca u tržišnim podacima te predviđanje budućih kretanja cijena. S druge strane, fundamentalna analiza procjenjuje financijsko stanje tvrtke i trendove u industriji kako bi se procijenio njezin potencijal za rast.

Globalno gledano, prva i osnovna podjela strategija bila bi na strategije temeljene na tehničkoj analizi, one koje su temeljene na fundamentalnoj analizi te kombinirane strategije. U ovom radu fokus će biti na tehničkoj analizi; međutim, ovdje ćemo dati samo kratki pregled postojećih strategija. Strategije koje se temelje na tehničkoj analizi oslanjaju se na povijesne informacije o cijeni, volumenu trgovanja i druge opipljive informacije s kojima možemo zdravorazumski i strogo analitički rukovati. Zbog toga razlikujemo strategije koje prate trend i/ili momentum. Ako trgovac primijeti da cijene određenog financijskog instrumenta imaju neki trend, pretpostavlja da će se taj trend nastaviti te sukladno tome ulaže svoj novac. Strategije povratka na prosjek (engl. *Mean Reversion*) temelje se na pretpostavci da cijena varira oko svog prosjeka i da će se, u slučaju udaljavanja od tog prosjeka, vratiti na svoju prosječnu vrijednost. Strategije probijanja (engl. *Breakout Strategies*) temelje se na praćenju razina otpora ili podrške te u trenutku njihovog probijanja generiraju signal za kupnju ili pro-

daju. Strategije temeljene na oscilatorima koriste oscilatore kako bi identificirali prekupljenost ili preprodanost instrumenta, što može dati signal za kupovinu ili prodaju. Također postoje strategije temeljene na obrascima grafikona i strategije temeljene na različitim tehničkim indikatorima. Ovo su samo neke od mnogih strategija temeljenih na tehničkoj analizi. Svaki trgovac gradi svoju strategiju prema svojim znanjima i preferencijama, tako da se u praksi koristi još mnogo drugih strategija.

Strategije temeljene na fundamentalnoj analizi usredotočuju se na pronalaženje podcijenjenih dionica na temelju njihove stvarne vrijednosti. Cilj je identificirati tvrtke s velikim potencijalom za budući rast, omogućujući investitorima da pravovremeno ulože svoj kapital. Ove strategije uključuju detaljno proučavanje financijskih izvještaja, upravljačkih timova, konkurentskih prednosti, tržišnih trendova i drugih ključnih čimbenika koji utječu na poslovanje tvrtki. Na taj način, investitori pokušavaju predvidjeti tržišne osjećaje, prepoznati što je trenutno popularno i iskoristiti taj rastući zamah. Također, ove metode često uključuju istraživanje tržišta, prepoznavanje prilika, te primjenu praktičnog znanja i iskustva.

Za kombinirane strategije možemo navesti primjer arbitraže, koja iskorištava razlike u cijenama na različitim tržištima kako bi ostvarila profit bez preuzimanja značajnog rizika. Drugi primjer je kvantitativno trgovanje, koje se oslanja na matematičke i statističke modele za donošenje investicijskih odluka. Kvantitativno trgovanje koristi složene algoritme i računalne modele za analizu velikih količina podataka i identifikaciju profitabilnih prilika na tržištu. Ove strategije omogućuju investitorima da sustavno i objektivno pristupaju trgovanju, smanjujući subjektivne čimbenike i emocionalne utjecaje na njihove odluke.

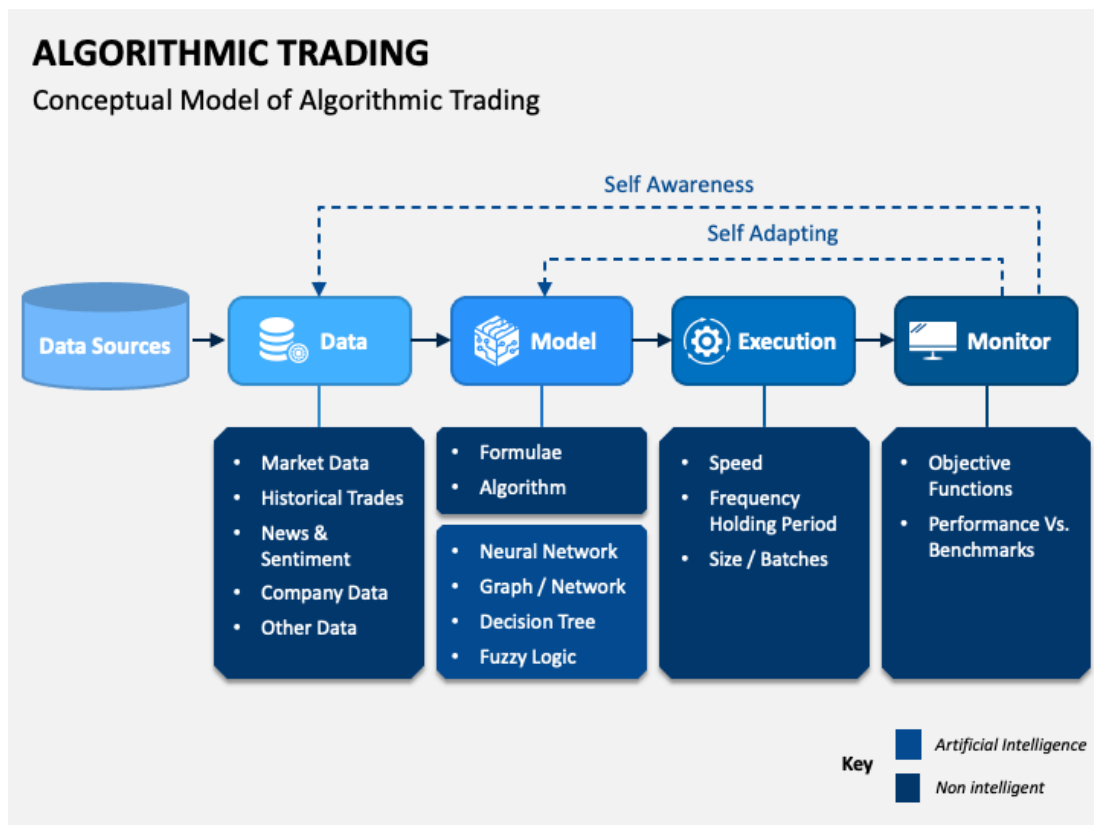
2.2. Sustav za algoritamsko trgovanje

Kako bismo izgradili sustav za algoritamsko trgovanje, moramo proći kroz mnoge korake, budući da se takav sustav sastoji od mnogo kompleksnih komponenti. Na slici 2.1 prikazan je konceptualni model glavnih koraka jednog algoritamskog sustava. Algoritamsko trgovanje obuhvaća niz koraka koji su potrebni za izgradnju funkcionalnog sustava.

Na slici 2.1 prikazana su četiri glavna koraka algoritamskog trgovanja:

1. Podaci

Prvi korak u kreiranju modela za algoritamsko trgovanje je prikupljanje i priprema podataka. Podaci koje ćemo proučavati, koristiti za učenje i izvlačenje



Slika 2.1: Konceptualni model algoritamskog trgovanja (20)

obrazaca koji se ponavljaju, ključni su za uspješno funkcioniranje modela. Kvaliteta i količina podataka direktno utječu na performanse modela.

2. Model

Nakon što imamo validne podatke, možemo pristupiti kreiranju modela. Postoji više pristupa za kreiranje strategija i signala za kupovinu i prodaju financijskih instrumenata. Korištenjem različitih algoritama i tehnika strojnog učenja, možemo razviti modele koji će na temelju podataka generirati optimalne trgovačke signale.

3. Izvršavanje

Nakon što smo kreirali model, sljedeći logičan korak je njegovo puštanje na stvarno tržište. Model tada počinje izvršavati kupovine i prodaje prema generiranim signalima. Cilj je ostvarivanje profita kroz automatizirane trgovačke operacije. U ovom koraku važno je integrirati sustav s brokerskim API-jima kako bi transakcije bile pravovremeno i točno izvršene.

4. Nadgledanje

Iako model može isprva raditi dobro, dugoročna profitabilnost ovisi o kontinuiranom nadgledanju i unapređivanju. Potrebno je pratiti performanse modela, detektirati eventualne greške i prilagođavati ga promjenjivim uvjetima na tržištu. Kontinuirano poboljšanje i dorada modela ključni su za održavanje njegove učinkovitosti i profitabilnosti.

U ovom radu usmjerit ćemo se na prva dva koraka koja se bave prikupljanjem i pripremom podataka te stvaranjem modela. Puštanje modela na stvarno tržište i njegovo nadgledanje prelazi okvir ovog diplomskog rada te će biti predmet budućih istraživanja i razvoja.

3. Tehnička analiza financijskih vremenskih nizova

Prije nego što započnemo s proučavanjem stvarnih tehnika i alata koji se koriste u tehničkoj analizi, prvo je potrebno definirati što je tehnička analiza. Tehnička analiza je proučavanje tržišnih aktivnosti, prvenstveno kroz uporabu grafikona, s ciljem predviđanja budućih trendova cijena. Pojam "tržišnih aktivnosti" uključuje tri glavna izvora informacija dostupna tehničaru - cijenu, obujam trgovanja i otvoreni interes.⁽¹⁸⁾ Tehnička analiza počiva na tri ključne pretpostavke: prvo, događaji na tržištu već su ugrađeni u cijenu; drugo, da se cijene kreću u trendovima; i treće, da se povijest ponavlja. U stvarnosti, kada bismo imali potpuno savršeno tržište, mogli bismo odbaciti sve ove tri pretpostavke. Međutim, živimo u nesavršenom svijetu, pa tako i tržište teži savršenstvu, iako ga ne postiže u potpunosti. Zbog toga se možemo osloniti na ove pretpostavke kao korisne alate u analizi tržišta.

Prva pretpostavka koju smo naveli za tehničku analizu događaji na tržištu već su ugrađeni u cijenu. Vjerujemo da je sve što može utjecati na cijenu - bilo temeljno, političko, psihološko ili na neki drugi način - već odraženo u cijeni tog tržišta. Iz toga proizlazi da je proučavanje kretanja cijena sve što je potrebno. Tehničar vjeruje da bi kretanje cijena trebalo odražavati promjene u ponudi i potražnji. Ako potražnja premašuje ponudu, cijene bi trebale rasti, a ako ponuda premašuje potražnju, cijene bi trebale padati. Tehničar ne zagovara pronalaženje razloga zašto cijene rastu ili padaju jer vjeruje da su temeljne sile ponude i potražnje te ekonomske osnove tržišta te koje uzrokuju bikovska i medvjedska tržišta. Umjesto toga, proučava kretanje cijena kako bi shvatio u kojem smjeru je najvjerojatnije da će tržište ići. Tehnički alati koje koristi su samo tehnike koje mu pomažu u tom procesu proučavanja tržišne aktivnosti.

Druga pretpostavka koncept trenda je apsolutno ključan za tehnički pristup. Cilj praćenja kretanja cijena na tržištu je identificirati trendove u ranoj fazi njihovog razvoja kako bi se trgovalo u smjeru tih trendova. Postoji i uzročna veza s pretpostavkom da cijene kreću u trendovima - trend koji je u pokretu vjerojatnije će nastaviti nego se

obrnuti. Ova veza je, naravno, prilagodba Newtonovom prvom zakonu gibanja. Cijeli pristup praćenja trendova temelji se na tome da se prati postojeći trend sve dok ne pokaže znakove obrtanja.

Velik dio tehničke analize i proučavanja tržišta ima veze s proučavanjem ljudske psihologije. Na primjer, obrasce na grafikonima koji su identificirani i kategorizirani tijekom proteklog stoljeća odražavaju određene uzorke koji se pojavljuju na grafikonima cijena. Ti uzorci otkrivaju optimističnu ili pesimističnu psihologiju tržišta. Budući da su ovi uzorci dobro funkcionirali u prošlosti, pretpostavlja se da će i u budućnosti dobro funkcionirati. Oni se temelje na proučavanju ljudske psihologije, koja obično ne mijenja. Drugi način izražavanja ove posljednje pretpostavke da se povijest ponavlja je da ključ za razumijevanje budućnosti leži u proučavanju prošlosti, ili da je budućnost samo ponavljanje prošlosti.

3.0.1. Razlike između Tehničke i Temeljne Analize

Tehnička analiza i temeljna analiza su dva glavna pristupa u analizi financijskih tržišta, no razlikuju se po metodologiji, fokusima i pretpostavkama. Tehnička analiza usredotočuje se na analizu povijesnih tržišnih podataka, osobito cijena i volumena trgovanja, kako bi se identificirali obrasci i trendovi koji mogu pomoći u predviđanju budućih kretanja cijena. S druge strane, temeljna analiza uključuje analizu fundamentalnih čimbenika koji mogu utjecati na vrijednost financijskog instrumenta, poput prihoda, dobiti, dividendi, makroekonomskih pokazatelja, konkurencije, industrijskih trendova itd. Dok se tehnička analiza usredotočuje na tržišne podatke i ponašanje cijena, temeljna analiza se fokusira na intrinzičku vrijednost financijskog instrumenta, odnosno procjenu da li je trenutna cijena tržišta iznad ili ispod te vrijednosti. Prema temeljnoj analizi, dugoročno će fundamentalne vrijednosti odrediti kretanje cijena financijskih instrumenata, dok se također oslanja na pretpostavku da tržišta nisu uvijek efikasna i da se mogu pojaviti prilike za profitiranje iz nepravilnosti u cijenama.(21) (11)

3.1. Tehnički indikatori

Tehnička analiza ima za cilj otkriti osnovne obrasce kupnje i prodaje dionica ili vrijednosnih papira koji mogu pružiti tragove o mogućim točkama ulaska i izlaska. To se postiže korištenjem tehničkih indikatora - matematičkih izračuna koji analiziraju povijesne podatke o cijeni i volumenu kako bi pružili objektivne signale za kupnju i prodaju. Ti se indikatori široko koriste za analizu izvedbe dionica i donošenje infor-

miranih odluka. Iako neki tehnički indikatori mogu spadati u iste kategorije, obično se grupiraju u pet glavnih tipova: indikatori trenda, indikatori zamaha, indikatori volatilnosti, indikatori volumena i alati za identificiranje podrške i otpora.(16)

Postoje različite primjene i podjele tehničkih indikatora, no u suštini ih možemo podijeliti u 5 glavnih kategorija:

- Indikatori koji prate trendove
- Indikatori momentuma
- Indikatori volatilnosti
- Indikatori volumena
- Alati za potporu i otpor

Indikatori koji prate trendove dizajnirani su za identifikaciju smjera trenda dionica. Prepoznavanje trendova ključno je za uspješno trgovanje, jer omogućuje trgovcima usklađivanje strategija s prevladavajućim tržišnim sentimentom. Evo nekoliko ključnih indikatora koji prate trendove: Pomični prosjek (engl. *Moving Average, MA*), Parabolični SAR (engl. *Parabolic SAR*), Prosječni indeks smjera (engl. *Average Directional Index, ADX*). Indikatori momentuma pružaju uvid u brzinu promjena cijena dionica. Oni pomažu trgovcima identificirati potencijalne preokrete ili nastavke trenutnog trenda. Ključni indikatori momentuma uključuju: RSI (engl. *Relative Strength Index*), Stohastički oscilator (engl. *Stochastic Oscillator*), MACD (engl. *Moving Average Convergence Divergence*). Indikatori volatilnosti mjere fluktuacije cijena dionica. Razumijevanje volatilnosti pomaže trgovcima prilagoditi svoje strategije trgovanja i upravljati rizikom. Neke od ključnih indikatora volatilnosti su: Bollingerove trake (engl. *Bollinger Bands*), ATR (engl. *Average True Range*), Volatilnost Chaikinovog oscilatora. Indikatori volumena pružaju informacije o trgovinskom volumenu dionica. Razumijevanje volumena može pomoći trgovcima potvrditi snagu trenutnog trenda ili identificirati potencijalne preokrete. Ključni indikatori volumena uključuju: OBV (engl. *On-Balance Volume*), CMF (engl. *Chaikin Money Flow*), VWAP (engl. *Volume Weighted Average Price*). Alati za potporu i otpor pomažu trgovcima identificirati razine na kojima se očekuje da će cijena dionica pronaći podršku ili otpor. Oni su važni za određivanje optimalnih razina ulaska i izlaska iz trgovine. Neke od ključnih alata za potporu i otpor uključuju: Fibonacci retracement, Pivot točke, i Gann linije.

4. Jednostavne metode

Kako bismo dobili jasniju viziju kako funkcionira izrada strategije te kako stvarni trgovci trguju koristeći tehničku analizu, implementirat ćemo nekoliko jednostavnih strategija koje se temelje na tehničkim indikatorima. Tehnička analiza koristi povijesne podatke o cijenama i obujmu trgovanja kako bi identificirala obrasce i trendove koji mogu pomoći u predviđanju budućih kretanja cijena. Ovakve strategije trgovci koriste svakodnevno u donošenju odluka, pažljivo prateći razne tehničke indikatore kako bi odredili optimalne trenutke za kupovinu i prodaju financijskih instrumenata.

Tehnički indikatori su matematički izračuni na temelju cijena, volumena ili otvorenog interesa vrijednosnih papira ili ugovora. Među najčešće korištenim tehničkim indikatorima su pokretni prosjeci, indeks relativne snage (engl. *Relative Strength Index, RSI*), MACD (engl. *Moving Average Convergence Divergence*)

4.1. Prikaz skupa podataka

U svrhu diplomskog rada korišten je skup podataka dnevnih cijena nafte, preuzet s Trading Economics. Ovaj skup podataka obuhvaća cijene terminskih ugovora sirove nafte, koji predstavljaju referentnu vrijednost za cijene nafte u Sjedinjenim Američkim Državama i služe kao referentna točka za globalne cijene nafte. Skup podataka sadrži cijene od 30. ožujka 1983. do 1. travnja 2024.

Kao što tablica 4.1 prikazuje podaci sadrže četiri ključna atributa za svaki dan:

1. **Cijena otvaranja (engl. *Open*):** Cijena nafte na početku dnevnog trgovanja.
2. **Najviša cijena tijekom trgujućeg dana (engl. *High*):** Najviša cijena nafte tijekom dnevnog trgovanja.
3. **Najniža cijena tijekom trgujućeg dana (engl. *Low*):** Najniža cijena nafte tijekom dnevnog trgovanja.
4. **Cijena zatvaranja (engl. *Close*):** Cijena nafte na kraju dnevnog trgovanja.

Date	Open	High	Low	Close
1983-03-30	29.25	29.5600	29.01	29.4000
1983-03-31	29.40	29.6000	29.25	29.2700
1983-04-04	29.30	29.7000	29.29	29.4400
1983-04-05	29.50	29.8000	29.50	29.7100
1983-04-06	29.90	29.9200	29.65	29.9000
...
2024-03-26	81.94	82.3600	81.22	81.6200
2024-03-27	81.29	81.7400	80.55	81.3500
2024-03-28	81.71	83.2100	81.52	83.1700
2024-03-29	81.71	83.1235	81.71	83.1235
2024-04-01	83.14	84.4900	82.60	83.7100

Tablica 4.1: Primjer podataka dnevnih cijena nafte

Svaki redak predstavlja cijene za jedan dan, a stupci sadrže cijene u valuti USD (američki dolar) za svaku od ovih kategorija.

Vizualizacija cijena

Slika 4.1 prikazuje linijski graf dnevnih cijena nafte u cijelom vremenskom razdoblju za koje posjedujemo podatke. Promatrajući ovaj grafikon, možemo uočiti tri osnovna obrasca ponašanja cijena. Prvi obrazac uključuje razdoblja očitog trenda, bilo da se radi o rastućem ili padajućem trendu, gdje cijene konstantno rastu ili opadaju tijekom određenog vremena. Drugi obrazac su razdoblja konsolidacije, kada cijene osciliraju oko neke prosječne vrijednosti bez jasnog trenda, ukazujući na stabilnost i balans između ponude i potražnje. Treći obrazac može uključivati volatilna razdoblja, gdje cijene pokazuju visoku fluktuaciju unutar kratkog vremenskog okvira, često uzrokovano vanjskim faktorima poput geopolitičkih događaja, promjena u proizvodnji ili potražnji, te ekonomskih kriza.



Slika 4.1: Linijski graf dnevnih cijena nafte

Na slici 4.2 prikazan je grafikon svijećnjaka za dnevne cijene nafte u prva dva mjeseca 2024. godine. Grafikon svijećnjaka trgovci koriste svakodnevno, puno češće od linijskih grafova jer im omogućuje uočavanje mnogo više informacija. Kroz ovaj grafikon, trgovci mogu analizirati različite aspekte tržišta, uključujući otvaranje, zatvaranje, najniže i najviše cijene unutar određenog razdoblja. Grafikon svijećnjaka sastoji se od tijela svijeće i sjena (ili fitilja). Tijelo svijeće predstavlja raspon između otvaranja i zatvaranja cijene, dok sjene pokazuju najniže i najviše cijene u određenom razdoblju. Ako je cijena zatvaranja viša od cijene otvaranja, svijeća je obično zelena ili bijela, što označava rast cijene. Ako je cijena zatvaranja niža od cijene otvaranja, svijeća je crvena ili crna, što označava pad cijene. Ova vrsta grafikona omogućuje trgovcima da brže prepoznaju obrasce koji mogu ukazivati na potencijalne preokrete ili nastavke trenda. Neki trgovci donose odluke o ulasku ili izlasku iz trgovanja isključivo na temelju izgleda ovog grafikona, koristeći ga kao ključni alat za tehničku analizu tržišta.



Slika 4.2: Grafikon svijećnjaka

4.2. Strategija temeljena na jednostavnim pomičnim prosjecima

Strategija trgovanja pomoću pomičnog prosjeka široko je korištena metoda tehničke analize koja koristi pomični prosjek cijene vrijednosnog papira za prepoznavanje potencijalnih tržišnih trendova. Pomični prosjek izračunava prosječnu cijenu vrijednosnog papira u određenom razdoblju. Izgladivanjem fluktuacija cijena, može pomoći trgovcima da uoče temeljne trendove i procijene cjelokupno tržišno raspoloženje. Jednostavni pomični prosjek (engl. *Simple Moving Average, SMA*) je aritmetički prosjek zadanog skupa cijena kroz određeno razdoblje. SMA je definiran kao zbroj cijena vrijednosnog papira tijekom određenog broja razdoblja, podijeljen s brojem tih razdoblja. Matematička definicija SMA je:

$$SMA = \frac{1}{N} \sum_{i=1}^N P_i$$

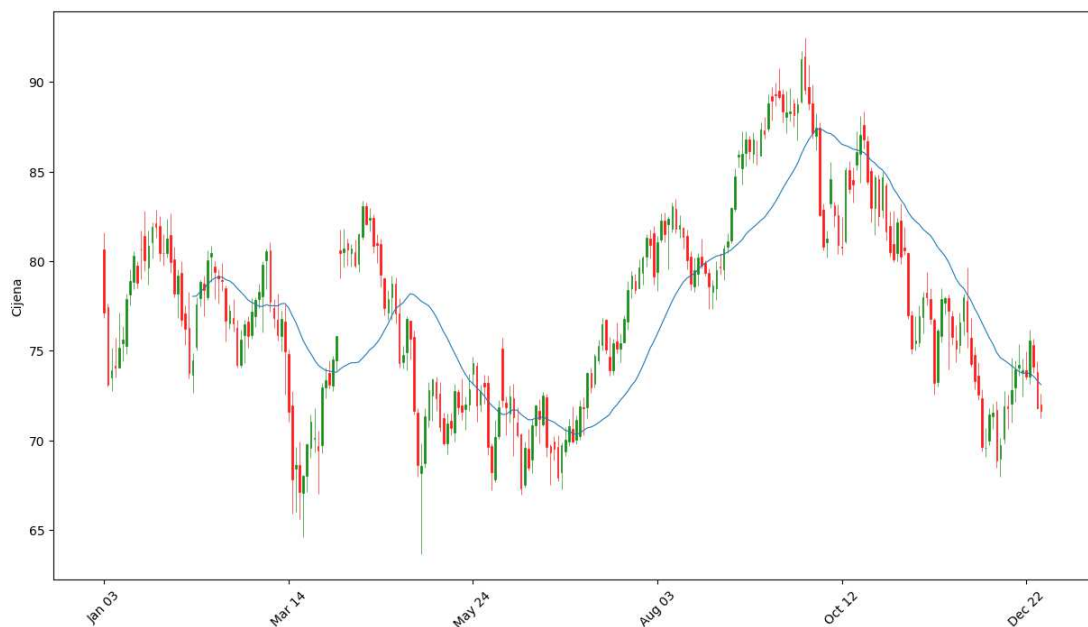
gdje je:

- N - broj razdoblja (npr. dana)
- P_i - cijena vrijednosnog papira na dan i

Pomični prosjek dostupan je na većini platformi za trgovanje i prikazuje se kao linija koja prati grafikon. Na primjer, na donjoj slici 4.3, 25-dnevni pomični prosjek prika-

zan je kao plava linija na grafikonu svijećnjaka. Trgovci mogu birati između različitih vremenskih okvira, poznatih i kao razdoblja "pogleda unatrag", koja mogu varirati od nekoliko sati do nekoliko mjeseci. Kraći vremenski okviri čine indikator pomičnog prosjeka osjetljivijim na promjene cijena, dok duži vremenski okviri mogu pružiti glatkiju indicaciju osnovnog trenda. Pomični prosjeci se široko koriste za prepoznavanje trendova cijena. Kada se cijena kreće iznad pomičnog prosjeka, to se smatra signalom potencijalnog uzlaznog trenda, dok kretanje cijene ispod pomičnog prosjeka može ukazivati na mogući silazni trend. Osim toga, nagib pomičnog prosjeka može pružiti dodatne informacije o zamahu trenda.

Nafta - SMA25



Slika 4.3: 25-dnevni pomični prosjek prikazan na grafikonu svijećnjaka

4.2.1. Strategija presjeka pomičnih prosjeka


Strategija presjeka pomičnih prosjeka temelji se na ideji da kada se dva pomična prosjeka različitih razdoblja presijecaju, to može signalizirati potencijalnu promjenu trenda na tržištu.

Križanje se događa kada kratkoročni pomični prosjek prijeđe preko dugoročnog pomičnog prosjeka. Kratkoročni pomični prosjek osjetljiviji je na nedavne promjene cijena, dok dugoročni pomični prosjek reagira sporije i pruža glatkiji prikaz trenda cijene. Kada se ova dva prosjeka presijeku, to može ukazivati na promjenu tržiš-

nog raspoloženja, sugerirajući da bi se trend mogao preokrenuti ili ubrzati. Postoje dvije glavne vrste križanja pomičnog prosjeka: bikovsko križanje i medvjede križanje. Svaka vrsta križanja signalizira drugačiji tržišni scenarij.

Bikovsko križanje događa se kada kratkoročni pomični prosjek prijeđe iznad dugoročnog pomičnog prosjeka. Ovaj događaj označava da je nedavni zamah cijena jači od dugoročnog trenda, što može značiti da tržište ulazi u fazu rasta. Trgovci obično tumače bikovsko križanje kao signal za kupnju, sugerirajući da bi mogli ući u dugu poziciju ili povećati postojeću. Bikovska križanja mogu se pojaviti s različitim vrstama pomičnih prosjeka, kao što su jednostavni, eksponencijalni ili ponderirani pomični prosjeci, ovisno o preferencijama i strategiji trgovca.

Medvjede križanje nastaje kada kratkoročni pomični prosjek prijeđe ispod dugoročnog pomičnog prosjeka. U ovom scenariju, nedavni zamah cijene slabiji je od dugoročnog trenda, što vjerojatno ukazuje na silaznu fazu tržišta. Trgovci općenito tumače medvjede križanje kao signal za prodaju, sugerirajući da bi mogli izaći iz dugih pozicija, ući u kratke pozicije ili smanjiti izloženost tržištu. Kao i kod bikovskih križanja, medvjeda križanja mogu uključivati različite vrste pomičnih prosjeka, kao što su jednostavni, eksponencijalni i ponderirani pomični prosjeci.



Slika 4.4: Presjek kratkoročnog i dugoročnog jednostavnog pomičnog prosjeka

Slika 4.4 prikazuje presjeke dugoročnog i kratkoročnog pomičnog prosjeka. Za

kratkoročni prosjek korišten je prozor od 13 zadnjih cijena, dok je za dugoročni korišten prozor od 100 prošlih cijena. Na slici je također prikazana cijena zatvaranja koja je korištena za izračunavanje ovih prosjeka.

Sada, na temelju ovih presjeka, možemo generirati signale za kupnju i prodaju te ih koristiti za izvršavanje trgovanja. Kako bismo generirali pozicije, to možemo jednostavno učiniti u programskom jeziku Python. Kao što je prikazano u donjem kodu generiramo novi stupac pozicija.

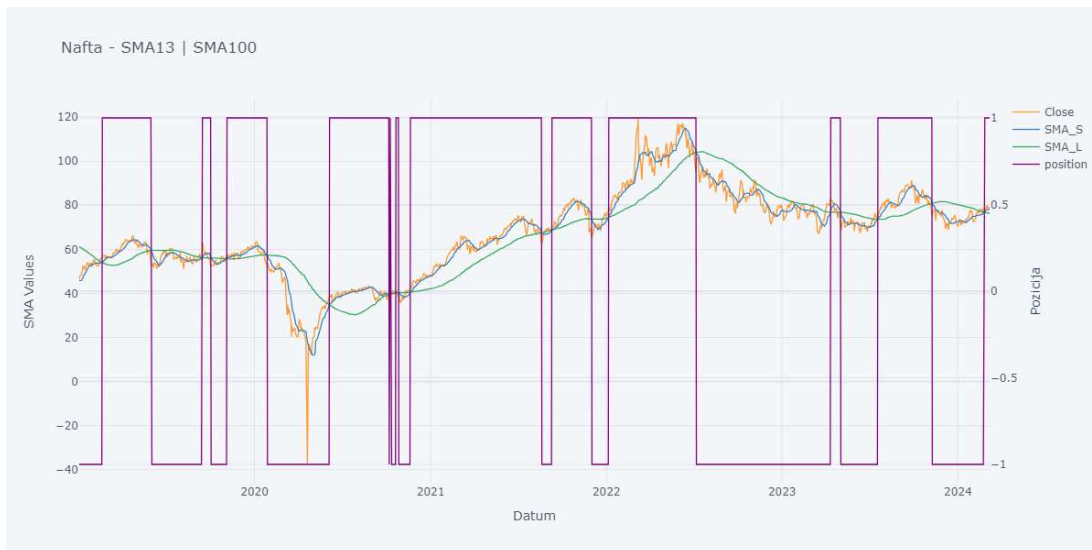
```
# Generiranje pozicija na temelju pomi nih prosjeka
data["pozicija"] = np.where(data["SMA_S"] > data["SMA_L"], 1, -1)
```

Nakon što smo u podatkovni okvir dodali tri nova stupca, a to su kratkoročni i dugoročni pomični prosjek, za kratkoročni smo koristili vremenski okvir od 13 dana, dok za dugoročni 100 dana. Na temelju njihovih vrijednosti smo generirali signale za pozicije. Nadopunjenu tablicu možemo vidjeti ispod.

Date	Open	High	Low	Close	SMA_S	SMA_L	pozicija
1984-06-07	30.44	30.4800	30.3800	30.4000	30.716154	30.423200	1
1984-06-08	30.41	30.4400	30.3300	30.3700	30.673077	30.429700	1
1984-06-11	30.34	30.3800	30.0900	30.1500	30.633077	30.435500	1
1984-06-12	30.13	30.2000	30.1100	30.1700	30.600000	30.439300	1
1984-06-13	29.98	30.1100	29.9500	30.1000	30.550000	30.440400	1
...
2024-03-01	78.28	80.8500	78.0500	79.9700	77.941538	76.533300	1
2024-03-04	80.14	80.4100	78.5600	78.7400	78.032308	76.474700	1
2024-03-05	78.74	79.4900	77.5200	78.1500	78.170000	76.430500	1
2024-03-06	78.15	80.6700	77.9900	79.1300	78.288462	76.412600	1
2024-03-07	79.13	79.3897	77.9636	78.8864	78.321262	76.394164	1

Tablica 4.2: Podaci s pomičnim prosjecima i pozicijama

Na slici 4.5 možemo vidjeti kako bi izgledalo zauzimanje pozicija temeljeno na strategiji presjecanja jednostavnih pomičnih prosjeka.



Slika 4.5: Grafikon s pozicijama

Nakon što smo implementirali strategiju i definirali pozicije, potrebno je evaluirati našu strategiju. U trgovanju, validacija strategije provodi se usporedbom s nekom referentnom strategijom (engl. *benchmark*), pri čemu se analizira jesu li naši rezultati bolji ili lošiji u odnosu na referentnu strategiju. Osim toga, koriste se različite metrike za evaluaciju strategija, poput Sharpeovog omjera, maksimalnog povlačenja (engl. *Drawdown*), omjera dobitka i gubitka te ukupnog povrata. Ove metrike omogućuju dublju analizu performansi i pomažu u identificiranju snaga i slabosti naše strategije, čime se osigurava da donosite informirane odluke u trgovanju.

4.2.2. Metrike za evaluaciju strategija

U svijetu financija i trgovanja, ključna je sposobnost precizne evaluacije uspješnosti investicijskih strategija. Metrike za evaluaciju strategija pružaju vitalne uvide u rizik, povrat i ukupnu učinkovitost različitih pristupa, omogućujući investitorima donošenje informiranih odluka o svojim ulaganjima. U ovom poglavlju razmatramo najvažnije metrike koje se koriste za ocjenu i usporedbu strategija trgovanja.

Povrat (engl. *Return*)

Povrat (engl. *Return*) u financijama i investiranju odnosi se na dobit ili gubitak ostvaren na investiciji tijekom određenog vremenskog razdoblja. Povrat se obično izražava kao postotak od početne vrijednosti investicije.

Dnevni povrat R_t obično se definira kao:

$$R_t = \frac{P_t - P_{t-1}}{P_{t-1}}$$

Gdje:

- R_t predstavlja dnevni povrat na dan t .
- P_t predstavlja cijenu imovine (npr. cijenu dionice) na dan t .
- P_{t-1} predstavlja cijenu imovine prethodnog dana, dan $t - 1$.

Ova formula izračunava postotnu promjenu cijene od jednog dana do sljedećeg. Mjeri koliko je cijena imovine porasla ili pala u odnosu na prethodni dan. Povrat (engl. *return*) se koristi u financijama iz nekoliko razloga:

1. **Mjerenje uspješnosti investicije:** Povrat omogućava investitorima da procijene koliko su profitabilne njihove investicije. To je osnovni pokazatelj koji pokazuje koliko je investicija donijela zarade ili gubitka u određenom razdoblju.
2. **Usporedba različitih investicija:** Povrat omogućava usporedbu performansi različitih investicija. Investitori mogu koristiti povrate kako bi odlučili koje su investicije isplativije i koje imaju bolji omjer rizika i nagrade.
3. **Procjena rizika:** Analiza povrata pomaže u procjeni rizika povezanog s investicijom. Viši povрати često dolaze s višim rizikom, dok stabilni povрати obično sugeriraju manji rizik.
4. **Odluke o portfelju:** Povrat se koristi za optimizaciju portfelja. Investitori mogu koristiti povrate za diversifikaciju portfelja i smanjenje rizika kombiniranjem različitih vrsta imovine.
5. **Praćenje tržišnih trendova:** Analiza povrata pomaže u praćenju tržišnih trendova i identificiranju prilika za trgovanje. Povrati mogu ukazati na promjene u ekonomskim uvjetima, industrijskim trendovima i drugim faktorima koji utječu na tržište.
6. **Planiranje i ciljevi:** Povrat se koristi za postavljanje financijskih ciljeva i planiranje budućih investicija. Investitori mogu definirati ciljeve povrata kako bi osigurali ostvarenje svojih financijskih planova.

Postoji više vrsta povrata koje se koriste u financijama, uključujući:

- **Ukupni povrat (engl. *Total Return*):** Ukupni povrat uključuje kapitalne dobitke (porast vrijednosti imovine) i prihode od dividendi ili kamata. To je sveobuhvatan pokazatelj uspješnosti investicije.
- **Godišnji povrat (engl. *Annual Return*):** Godišnji povrat predstavlja prosječni godišnji prirast investicije.
- **Dnevni povrat (engl. *Daily Return*):** Dnevni povrat mjeri prirast ili pad vrijednosti investicije u jednom danu.
- **Očekivani povrat (engl. *Expected Return*):** Očekivani povrat je procjena budućeg povrata na temelju povijesnih podataka i predviđanja tržišnih uvjeta.
- **Realni povrat (engl. *Real Return*):** Realni povrat uzima u obzir inflaciju i mjeri stvarnu kupovnu moć zarade od investicije.
- **Nominalni povrat (engl. *Nominal Return*):** Nominalni povrat je ukupni povrat koji ne uzima u obzir inflaciju.

Maksimalno povlačenje (engl. *Maximum Drawdown*)

Maksimalno povlačenje (engl. *Maximum Drawdown*) je financijski pojam koji se koristi za mjerenje najvećeg gubitka koji je neka investicija doživjela od svog vrhunca do najniže točke tijekom određenog vremenskog razdoblja. Maksimalno povlačenje je najveći postotni gubitak u vrijednosti portfelja ili imovine od najvišeg do najnižeg stanja tijekom određenog vremenskog razdoblja. Izračunava se kao razlika između vrhunca (najviše vrijednosti) i najniže vrijednosti nakon toga, podijeljena s najvišom vrijednošću i izražava se kao postotak.

Formula:

$$\text{Maksimalno povlačenje (MD)} = \frac{\text{Najviša vrijednost} - \text{Najniža vrijednost}}{\text{Najviša vrijednost}} \times 100\%$$

Primjer: Ako investicija dosegne najvišu vrijednost od 10.000 USD, a zatim padne na 6.000 USD, maksimalno povlačenje bi bilo:

$$\text{MD} = \frac{10.000 - 6.000}{10.000} \times 100\% = 40\%$$

Ovaj pokazatelj je koristan za investitore jer pokazuje koliko je neka investicija rizična i koliki gubitak može podnijeti tijekom loših razdoblja.

Postotak uspješnosti (engl. *Win Rate*)

Postotak uspješnosti (engl. *Win Rate*) je financijski pojam koji se koristi za mjerenje uspješnosti investicijske strategije ili trgovinskog sustava. Predstavlja omjer broja profitabilnih transakcija u odnosu na ukupan broj transakcija tijekom određenog vremenskog razdoblja.

Postotak uspješnosti izražava se kao postotak i računa se kao broj pobjedničkih transakcija podijeljen s ukupnim brojem transakcija, pomnožen sa 100.

Formula:

$$\text{Postotak uspješnosti (WR)} = \frac{\text{Broj profitabilnih transakcija}}{\text{Ukupan broj transakcija}} \times 100\%$$

Primjer: Ako investitor izvrši 50 transakcija, od kojih je 30 profitabilno, postotak uspješnosti bi bio:

$$\text{WR} = \frac{30}{50} \times 100\% = 60\%$$

Ovaj pokazatelj je koristan za investitore jer pokazuje koliko je često investicijska strategija uspješna u ostvarivanju dobiti. Visok postotak uspješnosti može ukazivati na pouzdanost strategije, ali važno je uzeti u obzir i druge čimbenike poput veličine dobiti i gubitaka kako bi se dobila cjelovita slika o uspješnosti investicijske strategije.

Faktor profita (engl. *Profit Factor*)

Faktor profita (engl. *Profit Factor*) je financijski pojam koji se koristi za mjerenje uspješnosti investicijske strategije ili trgovinskog sustava. Predstavlja omjer ukupne ostvarene dobiti u odnosu na ukupne ostvarene gubitke tijekom određenog vremenskog razdoblja.

Faktor profita izražava se kao broj koji pokazuje koliko puta je ukupna dobit veća od ukupnih gubitaka. Faktor veći od 1 znači da je strategija profitabilna, dok faktor manji od 1 znači da strategija generira gubitke.

Formula:

$$\text{Faktor profita (PF)} = \frac{\text{Ukupna ostvarena dobit}}{\text{Ukupno ostvareni gubitci}}$$

Primjer: Ako investitor tijekom određenog razdoblja ostvari ukupnu dobit od 20.000 USD i ukupne gubitke od 10.000 USD, faktor profita bi bio:

$$\text{PF} = \frac{20.000}{10.000} = 2$$

Ovaj pokazatelj je koristan za investitore jer pokazuje koliko je neka investicijska strategija uspješna u generiranju dobiti u odnosu na gubitke. Visok faktor profita uka-

zuje na to da je strategija učinkovita u ostvarivanju dobiti, dok nizak faktor profita može biti znak da strategija nije dovoljno profitabilna.

Sharpeov omjer (engl. *Sharpe Ratio*)

Sharpeov omjer (engl. *Sharpe Ratio*) je financijski pojam koji se koristi za mjerenje uspješnosti investicijske strategije prilagođene za rizik. Izračunava se kao omjer razlike između povrata portfelja i bezrizične stope povrata u odnosu na standardnu devijaciju povrata portfelja.

Sharpeov omjer izražava se kao broj koji pokazuje koliko je povrat na investiciju visok u odnosu na preuzeti rizik. Veći Sharpeov omjer označava bolji prinos prilagođen za rizik.

Formula:

$$\text{Sharpeov omjer (SR)} = \frac{\text{Povrat portfelja} - \text{Bezrizična stopa povrata}}{\text{Standardna devijacija povrata portfelja}}$$

Primjer: Ako portfelj ostvari povrat od 15

$$\text{SR} = \frac{15\% - 3\%}{10\%} = 1.2$$

Ovaj pokazatelj je koristan za investitore jer pokazuje koliko je povrat na investiciju visok u odnosu na rizik. Visok Sharpeov omjer ukazuje na to da je strategija učinkovita u ostvarivanju dobiti u odnosu na preuzeti rizik, dok nizak Sharpeov omjer može biti znak da strategija nije dovoljno profitabilna s obzirom na rizik.

Ovo su metrike koje se koriste za usporedbu i vrednovanje strategija trgovanja. Na temelju ovih metrika možemo donijeti informirani sud o tome je li neka strategija učinkovita ili ne.

Svaka metrika pruža različite uvide u performanse strategije, omogućujući investitorima da procijene ne samo koliko je strategija profitabilna, već i koliki rizik nosi te koliko je stabilna tijekom vremena. Na primjer, Sharpeov omjer pomaže razumjeti prinos prilagođen za rizik, dok maksimalno povlačenje pokazuje najveći gubitak koji je investicija pretrpjela.

Kombiniranjem ovih metrika, investitori mogu dobiti cjelovitiju sliku o uspješnosti i održivosti strategije, što im omogućava donošenje bolje informiranih odluka o ulaganju. U konačnici, korištenje ovih metrika doprinosi većoj sigurnosti i povjerenju u odabrane strategije trgovanja.

4.2.3. Evaluacija strategije temeljene na presjecima jednostavnih pomičnih prosjeka

Ako podijelimo skup podataka na skup za trening i skup za testiranje na sljedeći način: podatke od početka mjerenja, tj. od 30.03.1983. do 1.1.2019., koristimo za trening, a podatke od 1.1.2019. do 01.04.2024. koristimo za testiranje. Ispod je prikazan kod koji možemo koristiti za podjelu podataka, naime oslanjati ćemo se samo na cijenu zatvaranja pošto za pomične prosjeke treba samo jedna cijena.

```
split_date = '2019-01-01' # datum koji koristimo kao granicu
#Učitavanje podataka
data = pd.read_csv(data_filepath, parse_dates = ["Date"], index_col
    = "Date")
data = data[['Close']]
test_start_date = data[data.index < split_date].index[-100]
data_test = data[(data.index >= test_start_date)]
data_test = data[data.index < test_start_date]
```


Nakon što smo podijelili skup podataka na trening i testni skup, možemo optimizirati dužinu kratkog i dugog prozora za pomične prosjeke. Da bismo to postigli, moramo imati određeni kriterij za ocjenu koja kombinacija je bolja.

Prvo ćemo izračunati dnevne logaritamske povrate za naše dnevne cijene nafte. Korištenje logaritamskih povrata omogućava nam da dobijemo točnije i usporedivije rezultate za vremenske nizove. Zatim ćemo izračunati povrate naše strategije, ovisno o poziciji koju smo zauzeli prethodnog dana. Te povrate strategije ćemo kumulirati kako bismo dobili kumulativne povrate strategije.

Kumulativni povrati nam pomažu da vidimo ukupnu učinkovitost strategije kroz vrijeme. Izračun povrata prikazan je u kodu ispod:

```
data_test["returns"] = np.log(data_test["Close"].div(data_test["
    Close"].shift(1)))
data_test["strategy"] = data_test.position.shift(1) * data_test["
    returns"]
data_test["creturns"] = data_test["returns"].cumsum().apply(np.exp)
data_test["cstrategy"] = data_test["strategy"].cumsum().apply(np.exp
    )
```

Nakon što smo izračunali povrate, možemo ih grafički prikazati kako bismo dobili bolji osjećaj o uspješnosti naše strategije trgovanja u usporedbi s jednostavnim kumulativnim povratom koji bismo ostvarili da smo samo kupili instrument i držali ga tijekom vremena. Slika 4.6 prikazuje nam grafikon usporedbe povrata.



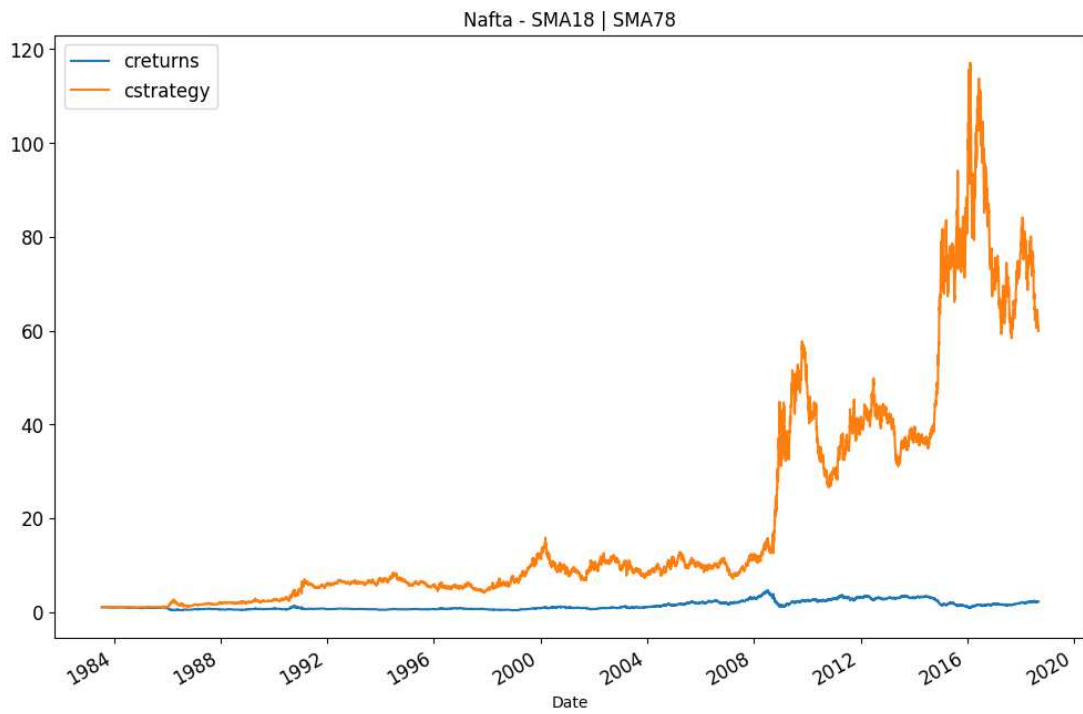
Slika 4.6: Grafikon kumulativnih povrata

Sada kada imamo definiran kriterij za optimizaciju, možemo usporediti učinkovitost naše strategije s jednostavnom strategijom. Točnije, uspoređivat ćemo ukupni povrat naše strategije trgovanja s ukupnim povratom jednostavne strategije "kupi i drži". Ove informacije ćemo koristiti za optimizaciju ili evaluaciju strategije, kako bismo utvrdili koliko je naša strategija bolja u odnosu na osnovnu strategiju. Optimirat ćemo koristeći grubu silu (engl. *brute force*) pošto je ovo jednostavna strategija, to radimo pomoću funkcije `brute`, prije toga smo napravili metodu `run_strategy` koja izvršava našu strategiju i vraća vraća negativnu vrijednost za ukupni povrat strategije trgovanja kao eksponencijalnu vrijednost kumuliranih logaritamskih povrata:


```
from scipy.optimize import brute # Uvoz funkcije "brute" iz paketa "
    scipy.optimize"
brute(run_strategy, ((10, 50, 1), (70, 252, 1)))
```

U kodu vidimo da se za kratki prozor koristi raspon od 10 do 50 s korakom od 1, a za dugi prozor koristi se raspon od 80 do 252 koristeći korak 1. Koristimo grubu silu (engl. *brute force*) i kao rezultat smo dobili optimalne vrijednosti 18 za kratki i 78 za dugi prozor. Nakon što smo odabrali optimalne duljine prozora, možemo procijeniti performanse na skupu za trening i testiranje. Primijetit ćemo da strategija pokazuje iznimno dobre rezultate na trening skupu, no istovremeno primjećujemo da odabir

prozora na ovaj način ne jamči dobre rezultate na testnom skupu. Na slici 4.7 prikazani su povrti na trening skupu, dok su na slici 4.8 prikazani povrti na testnom skupu.

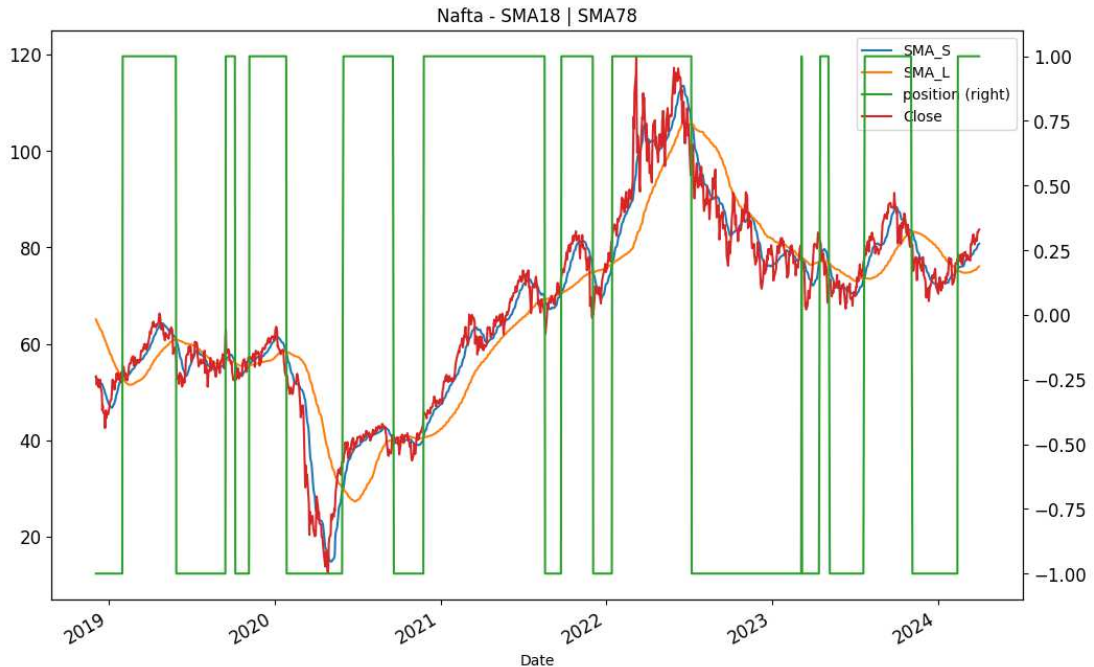


Slika 4.7: Grafikon kumulativnih povrata na skupu za trening



Slika 4.8: Grafikon kumulativnih povrata na testnom skupu

Važno je uzeti u obzir da se u periodu koji koristimo za test dogodila korona kriza, kada su cijene na tržištu pokazivale izrazito neobično ponašanje. To također može biti jedan od razloga za loše performanse.



Slika 4.9: Pozicije na test skupu

Slika 4.9 prikazuje kako bi to izgledalo zauzimanja pozicija temeljno na ovoj strategiji. Ukupno u periodu od 01.01.2019 do 01.04.2024, bi izvršili 10 transakcija. Simulacija trgovanja pretpostavlja da je početni kapital 10000 USD i tijekom svake transakcije ulaže se potpuni iznos koji se posjeduje u tom trenutku, u obzir nisu uzete troškovi transakcija. Tablica 4.3 prikazuje sve transakcije koje su izvršene. Postotak uspješnosti iznosi 50% znači da od 10 transakcija 5 je bilo profitabilno, faktor profita iznosi 1.575. Maksimalno povlačenje za dati skup podataka iznosi -0.2152, što se može tumačiti kao pad od 21.52% od maksimuma do minimuma u kumulativnim povratcima.

Tablica 4.3: Podaci o transakcijama

Entry Date	Exit Date	Entry Price	Exit Price	Profit	Cash
2019-02-01	2019-05-30	55.26	56.59	240.68	10240.68
2019-09-16	2019-10-07	62.90	52.75	-1652.51	8588.17
2019-11-07	2020-01-28	57.15	53.48	-551.51	8036.66
2020-06-01	2020-09-20	35.44	40.80	1215.48	9252.14
2020-11-25	2021-08-19	45.71	63.50	3600.87	12853.01
2021-09-24	2021-12-03	73.98	66.10	-1369.04	11483.97
2022-01-14	2022-07-08	82.42	101.53	2662.69	14146.65
2023-03-07	2023-03-08	77.72	76.81	-165.64	13981.01
2023-04-17	2023-05-08	80.83	72.81	-1387.20	12593.81
2023-07-24	2023-11-06	78.40	80.60	353.40	12947.21

4.3. Indeks relativne snage (engl. *Relative Strength Index, RSI*)

Indeks relativne snage (engl. *Relative Strength Index, RSI*) je oscilirajući tehnički indikator koji je dizajniran za mjerenje zamaha dionice, odnosno brzine i veličine promjena cijene. Mnogi ulagači koriste ovaj pokazatelj kako bi lakše utvrdili je li dionica prekupljena ili preprodana (9).

RSI se računa na temelju prosječnih dobitaka i gubitaka u određenom vremenskom razdoblju, obično 14 dana. Formula za izračunavanje RSI-ja je:

$$\mathbf{RSI} = 100 - \left(\frac{100}{1 + \mathbf{RS}} \right)$$

Gdje je RS (engl. *relative strength*) omjer prosječnih dobitaka i prosječnih gubitaka tijekom određenog razdoblja. Konkretno:

$$\mathbf{RS} = \frac{\text{Prosječni dobitak tijekom određenog razdoblja}}{\text{Prosječni gubitak tijekom određenog razdoblja}}$$

Vrijednosti RSI-ja kreću se između 0 i 100. Obično tumačenje vrijednosti RSI-ja su sljedeća:

- Ako je RSI oko i iznad razine 70, pretpostavlja se da je instrument prekupljen. To možemo tumačiti kao signal da će slijediti promjena trenda, odnosno cijene će početi padati.

- Ako je RSI oko i ispod razine 30, to je signal da bi instrument mogao biti preprodan. U tom slučaju cijene su preniske i trebalo bi doći do promjene, odnosno cijene će početi rasti.
- Ako se indikator horizontalno oscilira oko razine 50, to znači da na tržištu nedostaje trend. Odnosno, cijene su u fazi konsolidacije.

Ulagачi često koriste ove granice kao signale za kupnju ili prodaju. Na primjer, kada RSI padne ispod 30, to se može smatrati signalom za kupnju jer sugerira da je instrument preprodan. S druge strane, kada RSI poraste iznad 70, to se može smatrati signalom za prodaju jer sugerira da je instrument prekupljen. Vođeni ovom idejom, tako ćemo i kreirati našu strategiju.

RSI možemo jednostavno izračunati uz pomoć biblioteke TA i metode `RSIIndicator`.


```
df["RSI"] = ta.momentum.RSIIndicator(df["Close"], window=14).rsi()
```

Nakon što smo izračunali RSI možemo prikazati prošireni podatkovni okvir:

Date	Open	High	Low	Close	RSI
1983-04-19	30.70	30.8500	30.7000	30.7500	73.719070
1983-04-20	30.65	30.7700	30.6000	30.7000	71.408553
1983-04-21	30.75	30.7500	30.5800	30.6800	70.457291
1983-04-22	30.62	30.8500	30.6200	30.7500	71.869751
1983-04-25	30.78	30.8900	30.7800	30.8400	73.616337
...
2024-03-01	78.28	80.8500	78.0500	79.9700	61.622565
2024-03-04	80.14	80.4100	78.5600	78.7400	56.563905
2024-03-05	78.74	79.4900	77.5200	78.1500	54.262835
2024-03-06	78.15	80.6700	77.9900	79.1300	57.365336
2024-03-07	79.13	79.3897	77.9636	78.8864	56.342249


Tablica 4.4: Tablica s povijesnim podacima

Slika 4.10 prikazuje vizualizaciju vrijednosti indeksa relativne snage i kako bismo mogli generirati signale ovisno o njegovoj vrijednosti.



Slika 4.10: RSI strategija

Slika 4.11 prikazuje vizualizaciju indeksa relativne snage (RSI) paralelno s cijenom, kako bismo dobili bolji uvid u to prati li RSI zaista kretanje cijene na ispravan način. Ova vizualizacija omogućuje lakšu procjenu pouzdanosti RSI-a kao indikatora trenda cijene.



Slika 4.11: RSI prikazan na grafu zajedno s kretanjem cijene

Sada kada smo se uvjerali da ima smisla koristiti RSI za generiranje signala, definirat ćemo novi stupac u našem podatkovnom okviru koji ćemo nazvati "pozicija" (engl. *position*). Ovaj stupac predstavljat će signale za trgovanje: -1 je signal za pro-

daju, 0 za neutralnu poziciju i 1 za kupovinu. Kod ispod prikazuje kako to jednostavno možemo napraviti.

```
rsi_upper = 70
rsi_lower = 30
data_train["position"] = np.where(data_train.RSI > rsi_upper, -1, np
    .nan)
data_train["position"] = np.where(data_train.RSI < rsi_lower, 1,
    data_train.position)
data_train.position = data_train.position.fillna(0)
```


Ovaj kod postavlja poziciju na -1 kada je RSI iznad 70 (signal za prodaju), na 1 kada je RSI ispod 30 (signal za kupovinu) i na 0 kada je RSI između ovih vrijednosti (neutralna pozicija).

Tablica 4.5 prikazuje primjer proširenog podatkovnog okvira s dodanim stupcem za pozicije.

Date	Close	RSI	position
1983-04-19	30.75	76.264591	-1.0
1983-04-26	30.71	68.663594	0.0
1983-05-06	30.12	21.100917	1.0

Tablica 4.5: Primjer podatkovnog okvira nakon dodavanja stupca za pozicije

Slika 4.12 prikazuje vizualizaciju vrijednosti indeksa relativne snage (RSI) paralelno sa zauzetim pozicijama. Ova vizualizacija omogućuje jasniji uvid u povezanost između RSI signala i zauzetih pozicija na tržištu.



Slika 4.12: RSI s pozicijama


Sada možemo evaluirati našu strategiju na isti način kao strategiju temeljenu na presjecima jednostavnih prosjeka. To ćemo učiniti izračunavanjem kumulativnog povrata za RSI strategiju i jednostavnu strategiju "Kupi i drži". Sljedeći kod prikazuje kako možemo provesti ovu evaluaciju:

```
data_train["prinosi"] = np.log(data_train.Close.div(data_train.Close
    .shift(1)))
data_train["strategija"] = data_train.position.shift(1) * data_train
    ["prinosi"]
data_train["kumulativni_prinosi"] = data_train["prinosi"].cumsum().
    apply(np.exp)
data_train["kumulativni_strategija"] = data_train["strategija"].
    cumsum().apply(np.exp)
```

U ovom kodu, "prinosi" predstavljaju dnevne logaritamske prinose, "strategija" je prinos temeljen na RSI signalima, a "kumulativni prinosi" i "kumulativni strategija" prikazuju kumulativne prinose za strategiju "Kupi i drži" i RSI strategiju.

Slika 4.13 prikazuje kumulativne prinose za strategiju temeljenu na RSI indikatoru u usporedbi s kumulativnim prinosisima strategije "Kupi i drži". Na grafu, plava linija predstavlja kumulativne prinose "Kupi i drži" strategije, dok narančasta linija predstavlja kumulativne prinose RSI strategije. Od 1984. do 2020. godine, može se vidjeti kako obje strategije prate opći trend rasta, ali postoje periodi u kojima jedna strategija

nadmašuje drugu. Primjerice, tijekom određenih razdoblja volatilnosti na tržištu, RSI strategija može pokazati bolju prilagodljivost na tržišne uvjete, dok strategija "Kupi i drži" može bolje performirati u stabilnim i rastućim tržišnim uvjetima. Općenito, ova vizualizacija pomaže u procjeni učinkovitosti RSI strategije u odnosu na jednostavnu strategiju "Kupi i drži" kroz dugoročno razdoblje.




Slika 4.13: Kumulativni prinosi RSI strategije

Sada možemo optimirati tri hiperparametra, a to su prozor koji se koristi za izračun indeksa relativne snage (RSI), donja granica za RSI i gornja granica koje nam služe za donošenje odluke je li instrument prekupljen ili preprodan. To ćemo napraviti na isti način kao i za prijašnju strategiju uz pomoć metode 'brute()' iz biblioteke 'scipy.optimize'. Za optimizaciju, koristit ćemo sljedeće intervale:

- Prozor za izračun RSI: od 5 do 20 s korakom 1.
- Donji iznos RSI: od 20 do 35 s korakom 1.
- Gornji iznos RSI: od 65 do 80 s korakom 1.


Metoda 'brute()' na skupu za trening vratila je sljedeće optimalne vrijednosti:

- Veličina prozora za izračun RSI: 12
- Gornji RSI: 65
- Donji RSI: 30



Slika 4.14: Kumulativni prinosi rsi strategije nakon optimizacije na skupu za treniranje

Slika 4.14 prikazuje kumulativne prinose uz optimalne hiperparametre. Može se primijetiti značajno poboljšanje rezultata nakon optimizacije na skupu za treniranje. Međutim, ovi rezultati ne garantiraju izvrsne rezultate na neviđenim podacima.



Slika 4.15: Kumulativni prinosi rsi strategije nakon optimizacije na skupu za test

Slika 4.15 prikazuje kumulativne prinose na skupu za test nakon optimizacije hiperparametara. Ovdje možemo vidjeti da optimalni hiperparametri, iako učinkoviti na skupu za treniranje, pokazuju loše rezultate na skupu za test, što ukazuje na problem prekomjernog prilagođavanja podacima za treniranje

Ukupno u periodu od 01.01.2019 do 01.04.2024, bi izvršili 20 transakcija. Simulacija trgovanja pretpostavlja da je početni kapital 10000 USD i tijekom svake transakcije ulaže se potpuni iznos koji se posjeduje u tom trenutku, u obzir nisu uzete troškovi transakcija. Tablica 4.6 prikazuje sve transakcije koje su izvršene. Postotak uspješnosti iznosi 24% znači da od 20 transakcija 5 je bilo profitabilno, faktor profita iznosi 0.1121.

entry_date	exit_date	entry_price	exit_price	profit	cash
2019-05-07	2019-05-19	61.4000	63.4379	331.905537	10331.905537
2019-05-23	2019-06-20	57.9100	56.6500	-224.800569	10107.104968
2019-07-24	2019-08-21	55.8800	55.6800	-36.174320	10070.930648
2019-09-29	2019-10-23	56.1258	55.9700	-27.955967	10042.974681
2020-01-17	2020-02-20	58.5400	53.7800	-816.613589	9226.361093
2020-02-28	2020-04-03	44.7600	28.3400	-3384.648104	5841.712989
2020-04-20	2020-05-06	-37.6300	23.9900	-9565.940855	-3724.227866
2020-09-04	2020-09-23	39.7700	39.9300	-14.983064	-3739.210930
2020-10-02	2020-10-20	37.0500	41.4600	-445.072070	-4184.283000
2020-10-30	2020-11-16	35.7900	41.3400	-648.861991	-4833.144991
2021-03-23	2021-04-19	57.7600	63.4300	-474.444808	-5307.589799
2021-07-20	2021-09-06	67.2000	68.8800	-132.689745	-5440.279544
2021-11-26	2021-12-16	67.8400	71.7500	-313.553848	-5753.833391
2022-04-08	2022-04-28	97.0100	103.4700	-383.153940	-6136.987331
2022-06-22	2022-10-07	103.9900	91.3500	745.951725	-5391.035606
2022-11-22	2022-12-23	80.7300	79.6400	72.788664	-5318.246943
2023-02-03	2023-03-31	73.7400	75.8000	-148.570500	-5466.817443
2023-04-27	2023-07-10	74.7600	72.9500	132.356067	-5334.461376
2023-08-24	2023-08-31	78.6600	82.9600	-291.611797	-5626.073173
2023-10-04	2023-12-22	82.5500	73.5600	612.700155	-5013.373017

Tablica 4.6: Podaci o transakcijama

4.4. Zaključak za jednostavne metode

Ove dvije metode daju nam uvid u način funkcioniranja svijeta algoritamskog trgovanja te su nam pomogle u razumijevanju ovog problema i pristupa klasičnih trgovaca. Trgovci, koristeći tehničku analizu i prateći indikatore, donose informirane odluke i grade svoje strategije. Iako su ove strategije jednostavne i primitivne, stvarni trgovci koriste mnoštvo indikatora i različite izvore podataka kako bi donijeli odluke.

U ovom radu implementirali smo dvije osnovne strategije trgovanja temeljene na tehničkim indikatorima – strategiju presjeka jednostavnih pomičnih prosjeka i strategiju temeljenu na indeksu relativne snage (RSI). Prva strategija koristi kratkoročne i dugoročne pomične prosjeke za identifikaciju promjena u trendu, dok druga koristi oscilator RSI za prepoznavanje prekupljenih i preprodanih uvjeta na tržištu.

Evaluacija ovih strategija pokazala je određenu razinu uspješnosti na povijesnim podacima, no također je istaknula izazove vezane uz promjenjivost tržišta i prilagodljivost strategija na nove podatke. Iako su strategije pokazale potencijal tijekom razdoblja treninga, performanse na testnom skupu ukazale su na problem prekomjernog prilagođavanja podacima.

U stvarnom svijetu trgovci koriste naprednije metode i kombinacije više indikatora kako bi povećali točnost svojih predviđanja. Jedan od smjerova istraživanja koji nudi mogućnost značajnog unapređenja performansi strategija trgovanja je primjena strojnog učenja i umjetne inteligencije. Korištenjem ovih naprednih tehnika moguće je izgraditi modele koji bolje generaliziraju na nove podatke i prilagođavaju se promjenama na tržištu.

Stoga, u nastavku rada istražiti ćemo revolucionarne metode predikcije cijena uz pomoć strojnog učenja. Proučiti ćemo algoritme i modele strojnog učenja kako bismo utvrdili mogu li pružiti prednost na tržištu i omogućiti donošenje informiranih odluka. Kroz ovu analizu cilj nam je istražiti potencijal strojnog učenja u algoritamskom trgovanju i identificirati pristupe koji mogu pomoći u ostvarivanju većih povrata uz smanjenje rizika.

5. Moderni pristup

U ovom poglavlju istražujemo suvremeni pristup trgovanju koji se oslanja na napredne tehnike dubokog učenja. Cilj nam je razviti strategiju trgovanja koja će nam omogućiti preciznije predviđanje kretanja cijena u budućnosti. Kroz primjenu metoda dubokog učenja, analizirat ćemo postojeće podatke kako bismo identificirali uzorke i trendove na tržištu. Osnovni postupak bit će predviđanje budućih cijena na temelju analize povijesnih podataka te donošenje trgovačkih odluka temeljenih na tim prognozama. Ovaj pristup omogućuje nam da koristimo snagu umjetne inteligencije kako bismo efikasnije upravljali rizicima i povećali potencijalne dobitke u trgovačkim operacijama. U nastavku ćemo detaljnije istražiti metodologiju koja stoji iza ove strategije te analizirati njezine prednosti i ograničenja u kontekstu suvremenog tržišta.

5.1. Transformator

Područje dubokog učenja prolazi kroz značajne promjene zahvaljujući pojavi i brzom razvoju modela transformatora. Ove inovativne arhitekture ne samo da su redefinirale standarde u obradi prirodnog jezika (engl. *Natural Language Processing, NLP*), već su također donijele revoluciju u mnoge druge aspekte umjetne inteligencije. Modeli transformatora, sa svojim jedinstvenim mehanizmima pažnje i sposobnostima paralelne obrade, predstavljaju značajan napredak u razumijevanju i kreiranju ljudskog jezika s dosad neviđenom točnošću i učinkovitošću. Od svog prvog pojavljivanja 2017. godine u Googleovom radu "Pažnja je sve što vam treba" (engl. *Attention is all you need*) (25), arhitektura transformatora postala je ključna za revolucionarne modele poput ChatGPT-a, izazivajući novi val uzbuđenja unutar AI zajednice. Ovi modeli igraju ključnu ulogu u vrhunskim jezičnim modelima OpenAI-ja i u DeepMind-ovom AlphaStaru.

5.1.1. Motivacija

Nas u ovom radu zanima kako izgleda arhitektura modela transformatora. Nakon što temeljito razumijemo sve gradivne blokove ovog modela, moći ćemo to znanje primijeniti na naš problem predviđanja cijena nafte. Modeli transformatora su izuzetno učinkoviti u radu sa sekvencama i predviđanjem sljedećeg člana sekvence. Ako vremenske podatke o cijenama nafte koje posjedujemo promatramo na takav način, tada bismo mogli primijeniti arhitekturu transformatora na podatke vremenskih nizova.

Modeli transformatora koriste mehanizam samo-pažnje (engl. *self-attention*), koji omogućava modelu da obraća pažnju na različite dijelove ulazne sekvence pri generiranju izlaza. Ovo je posebno korisno kod podataka vremenskih nizova, gdje je bitno uzeti u obzir dugoročne ovisnosti između podataka. Korištenjem pažnje, transformatori mogu bolje shvatiti složene obrasce i odnose u podacima, što ih čini idealnim za predviđanje cijena nafte.

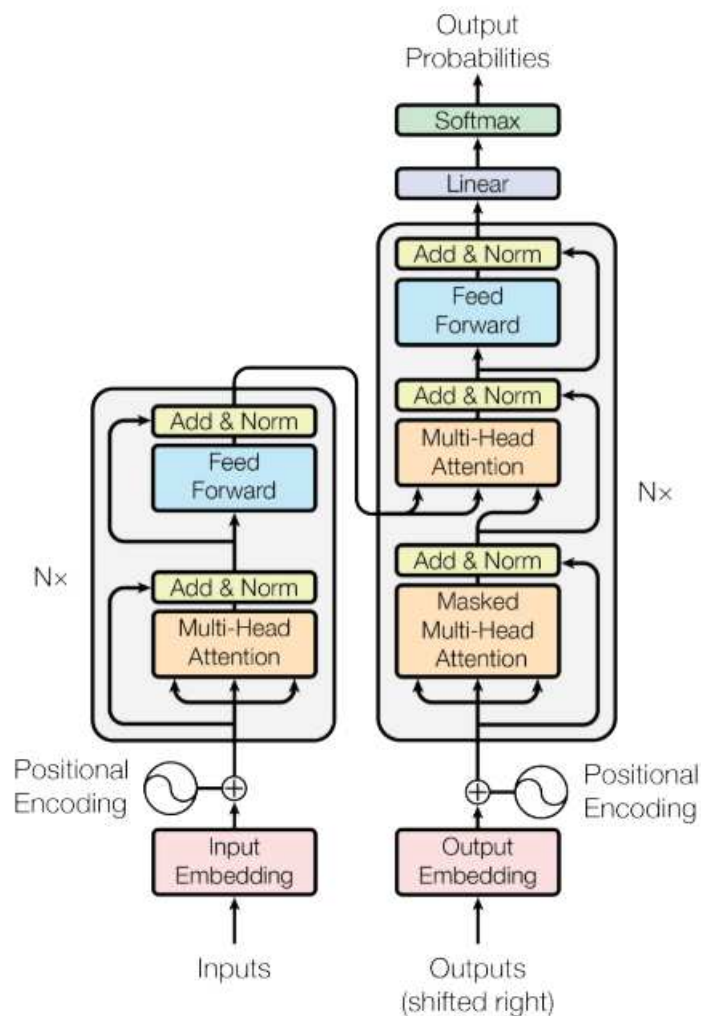
Pored toga, prednost transformatora leži u njihovoj sposobnosti paralelizacije, što omogućava bržu obradu velikih količina podataka u usporedbi s tradicionalnim rekurzivnim neuronskim mrežama. Ovo može značajno ubrzati proces treniranja modela na velikim skupovima podataka, kao što su vremenski nizovi cijena nafte.

5.1.2. Arhitektura

Arhitektura transformator modela može na prvu izgledati poprilično složeno i zastrašujuće, međutim, ako je razlomimo na komponente, možemo primijetiti da se sastoji od nekoliko glavnih dijelova:

- Ugrađivanje ulaza (engl. *Input Embedding*)
- Pozicijsko kodiranje (engl. *Positional Encoding*)
- Transformator blok (Koder i Dekoder)
- Softmax

Slika 5.1 prikazuje vizualizaciju osnovnog "vanilla" modela transformatora koji je prezentiran u radu "Attention is All You Need" iz 2017. godine.



Slika 5.1: Arhitektura modela (25)

Sada ćemo proći korak po korak kroz svaku komponentu.

5.1.3. Ugrađivanje ulaza (engl. Input Embedding)

Ugrađivanje ulaza ovisi o domeni primjene transformatora. Osnovna primjena transformatora je za probleme obrade prirodnog jezika (engl. *Natural Language Processing, NLP*), gdje se ugrađivanje ulaza sastoji od dva ključna dijela: tokenizacije i ugrađivanja značenja (engl. *embedding*).

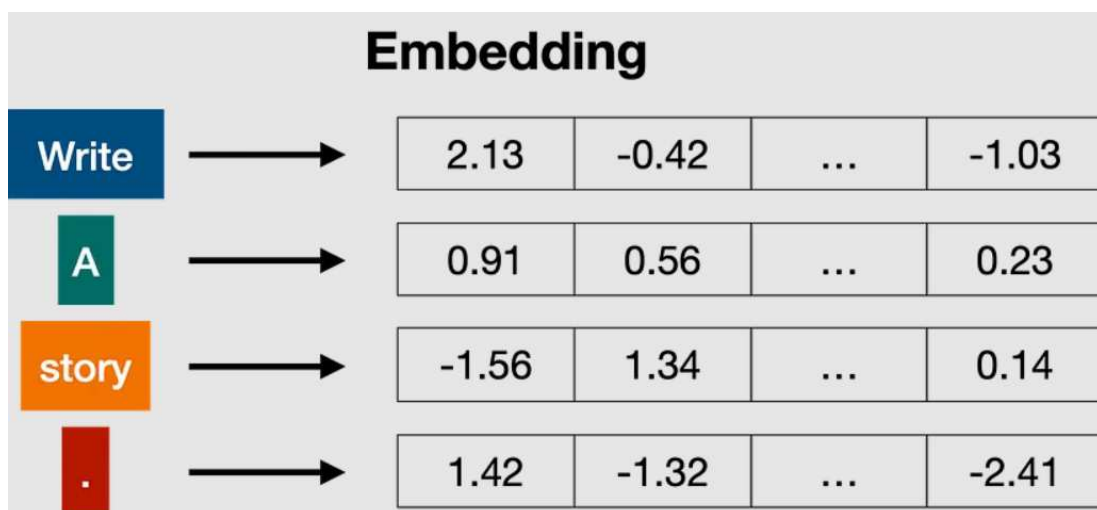
Korak tokenizacije razbija tekst na manje jedinice kao što su riječi, prefiksi, sufiksi i interpunkcijski znakovi, te ih povezuje s odgovarajućim tokenima iz unaprijed definirane biblioteke. Ovaj proces omogućava modelu da razumije strukturu i značenje teksta. Slika 5.2 prikazuje jednostavan primjer tokenizacije.



Slika 5.2: Primjer tokenizacije (2)

Nakon što smo tekst razdvojili na dijelove (tokenizirali), trebamo te dijelove (riječi) pretvoriti u brojeve jer računala bolje rade s brojevima nego s riječima. Ovaj postupak se zove "ugradnja" (engl. *embedding*). Ugradnja je način na koji svaku riječ pretvaramo u niz brojeva, tj. vektor. Na primjer, riječ "mačka" može biti predstavljena vektorom [0.1, 0.3, 0.9], dok riječ "pas" može biti predstavljena vektorom [0.2, 0.1, 0.8]. Ovi brojevi predstavljaju koordinate u višedimenzionalnom prostoru. Ako su dvije riječi ili fraze slične po značenju, njihovi vektori će također biti slični. To znači da će brojevi na odgovarajućim pozicijama u vektorima biti bliski jedni drugima.

Na primjer, vektori za "mačka" i "tigar" vjerojatno će biti sličniji nego vektori za "mačka" i "stolica". Ova sličnost vektora omogućuje modelu da prepozna semantičke veze između riječi, što je ključno za mnoge zadatke u obradi prirodnog jezika. Slika 5.3 prikazuje vizualizaciju primjera "ugradnje" riječi u vektore.



Slika 5.3: Primjer ugradnje riječi u vektore (2)

Vektor od riječi stvaramo pomoću tehnika koje pretvaraju riječi u numeričke reprezentacije koje model može razumjeti i obraditi. Ove tehnike se nazivaju ugradnje riječi (engl. *word embeddings*). Najčešće korištene metode za stvaranje vektora od riječi su: One-Hot Encoding, Word2Vec, GloVe (Global Vectors for Word Representation), Fas-

tText, BERT (engl. *Bidirectional Encoder Representations from Transformers*) i drugi. Međutim, tema ovog rada nije obrada prirodnog jezika, stoga nećemo ulaziti u detalje.

Nas zanima kako ćemo pripremiti naš skup podataka o cijenama nafte za primjenu transformator modela. Cijene nafte su već u numeričkom obliku, pa nije potrebna pretvorba riječi u vektore kao kod obrade prirodnog jezika. Međutim, kako bi model bolje učio, potrebna je normalizacija podataka.

Normalizacija podataka je ključan korak u pripremi podataka za treniranje modela. Cilj normalizacije je skaliranje podataka tako da svi podaci budu u sličnom rasponu, obično između 0 i 1 ili -1 i 1. To omogućava modelu da brže konvergira i poboljšava stabilnost treniranja. Bez normalizacije, model bi mogao imati problema s učenjem zbog velike varijabilnosti vrijednosti u podacima.

Osim normalizacije, potrebno je kreirati sekvence podataka koje će model koristiti za učenje. U kontekstu vremenskih nizova, to znači podjelu podataka na ulazne sekvence (npr. cijene u prethodnih 10 dana) i odgovarajuće izlazne vrijednosti (npr. cijena na 11. dan). Ovaj pristup omogućava modelu da uči obrasce i odnose u podacima kroz vrijeme.

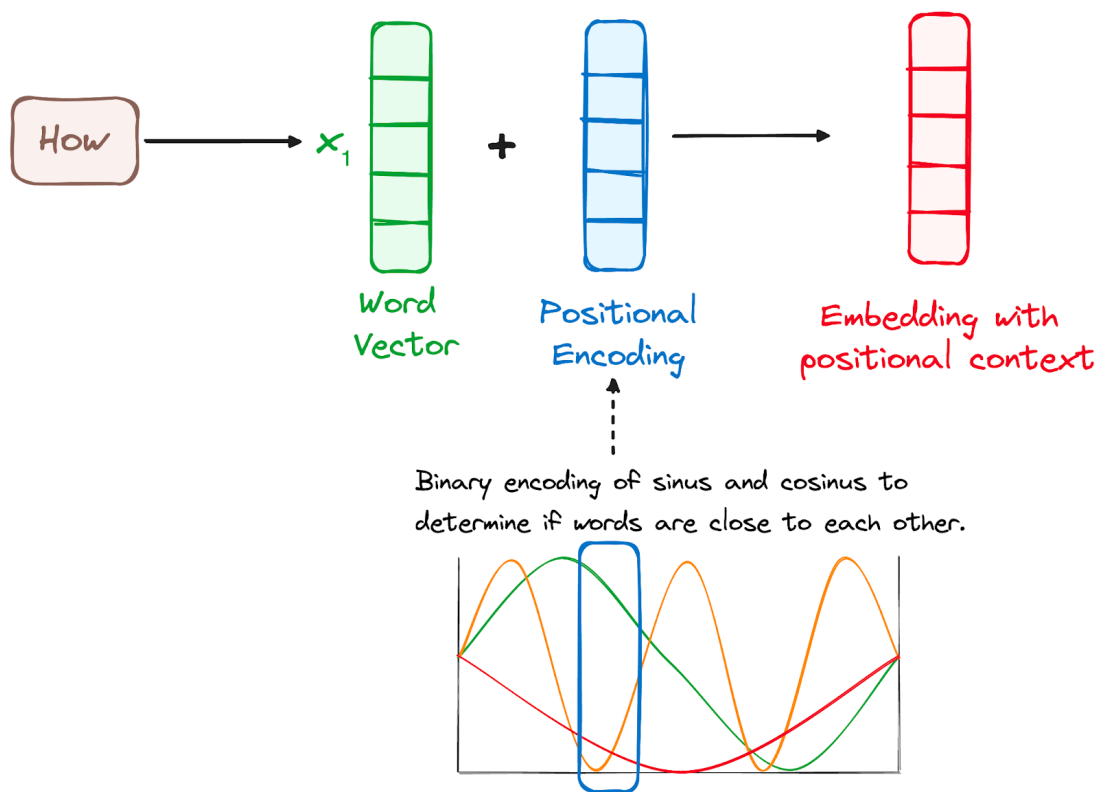
Još jedan važan korak je dodavanje pozicijskog kodiranja.

5.1.4. Pozicijsko kodiranje

Budući da transformatori ne obrađuju podatke sekvencijalno, pozicijsko kodiranje dodaje informacije o redoslijedu podataka u sekvenci, omogućavajući modelu da razumije vremensku ili pozicijsku komponentu podataka. Kako bi to postigli, istraživači su predložili korištenje kombinacije različitih sinusnih i kosinusnih funkcija za stvaranje pozicijskih vektora, omogućujući korištenje ovog pozicijskog kodera za rečenice bilo koje duljine.

U ovom pristupu, svaka dimenzija je predstavljena jedinstvenim frekvencijama i pomacima valova, s vrijednostima u rasponu od -1 do 1, učinkovito predstavljajući svaku poziciju.

Slika 5.4 prikazuje vizualizaciju kako izgleda dodavanje pozicijskog kodiranja vektoru.



Slika 5.4: Primjer pozicijskog kodiranja (10)

Kod cijena nafte izuzetno je važna vremenska komponenta u sekvenci. Ako koristimo posljednjih 30 dana cijena kao ulazne podatke i pokušavamo predvidjeti cijenu za sljedeći dan, cijena od jučer ima veći utjecaj na predikciju nego cijena od prije 20 dana. Upravo zbog toga je bitno pozicijsko kodiranje.

5.1.5. Koder i Dekoder

Počeli smo s riječima koje smo u prvom koraku pretvorili u tokene. Tokenizirane riječi smo zatim pretvorili u brojeve (engl. *Word embedding*), konkretno u vektore. Nakon toga, ugradili smo informacije o redoslijedu (engl. *Positional Encoding*). Kao rezultat tih koraka, dobili smo vektor za svaki token/riječ koju unosimo u model. Sljedeći korak bio bi predviđanje idućih riječi u rečenici ili prijevod, ovisno o tome za što koristimo naš model.

Taj proces se postiže pomoću vrlo velike neuronske mreže koja je trenirana upravo s tim ciljem – da obavlja prijevod ili generira novi tekst. Međutim, obučavanje tako velike mreže predstavlja izazovan problem. Kako bismo poboljšali taj proces, uvodimo komponentu pažnje. Ovaj koncept je predstavljen u radu "Attention is All You Need" (25) iz 2017. godine. To je ključni koncept uspjeha transformatora.

Središte transformatora su strukture kodera i dekodera. Pokušat ćemo objasniti komponente koje ih izgrađuju. Možemo početi s ključnim konceptom, a to je koncept pažnje.

Mehanizam Pažnje (engl. *Attention*)

Mehanizam pažnje je srž arhitekture transformatora — stoga je naslov rada "Pažnja je sve što trebate". U transformatoru, mehanizam pažnje omogućuje modelu da dodjeljuje različite težine različitim tokenima u nizu. Na taj način model može dati veću važnost relevantnim informacijama, zanemariti nebitne informacije i učinkovito uhvatiti dugotrajne ovisnosti u podacima.

Mehanizam pažnje funkcionira tako da svaki token u nizu procjenjuje svoj odnos prema svim ostalim tokenima. Model koristi ove procjene za generiranje novih reprezentacija tokena koje bolje odražavaju njihov kontekst u sekvenci. Ove nove reprezentacije zatim se koriste za izvođenje različitih zadataka, poput prevođenja, sažimanja teksta ili predviđanja vremenskih nizova.

Matematička formula za izračunavanje pažnje je:

$$\text{Pažnja}(Q, K, V) = \text{softmax} \left(\frac{QK^T}{\sqrt{d_k}} \right) V$$

Gdje je:

- Q matrica upita (engl. *query*).
- K matrica ključeva (engl. *key*).
- V matrica vrijednosti (engl. *value*).
- d_k dimenzija ključnih vektora (skaliranje se koristi za stabilnost).

U arhitekturi transformatora, pojmovi ključevi (engl. *keys*), upiti (engl. *queries*) i vrijednosti (engl. *values*) predstavljaju vektorske reprezentacije koje se koriste za izračunavanje pažnje.

Upiti (engl. *queries*) su vektorske reprezentacije koje se koriste za pretraživanje relevantnih informacija među ključevima. Generiraju se primjenom linearne transformacije na ulazne podatke. Za svaku poziciju u ulaznoj sekvenci, upit (engl. *query*) je rezultat množenja ulaznog vektora s težinskom matricom specifičnom za upite. Ako imamo ulazne podatke X , upiti Q se dobivaju kao:

$$Q = XW_Q$$

Gdje je W_Q težinska matrica za upite.

Ključevi (engl. Keys) su vektorske reprezentacije koje model koristi za identifikaciju relevantnih informacija u ulaznim podacima. Oni djeluju kao indeksi ili "ključne riječi". Također se generiraju primjenom linearne transformacije na ulazne podatke, slično kao upiti. Za svaku poziciju u ulaznoj sekvenci, ključ (engl. *key*) je rezultat množenja ulaznog vektora s težinskom matricom specifičnom za ključeve. Ako imamo ulazne podatke X , ključevi K se dobivaju kao:

$$K = XW_K$$

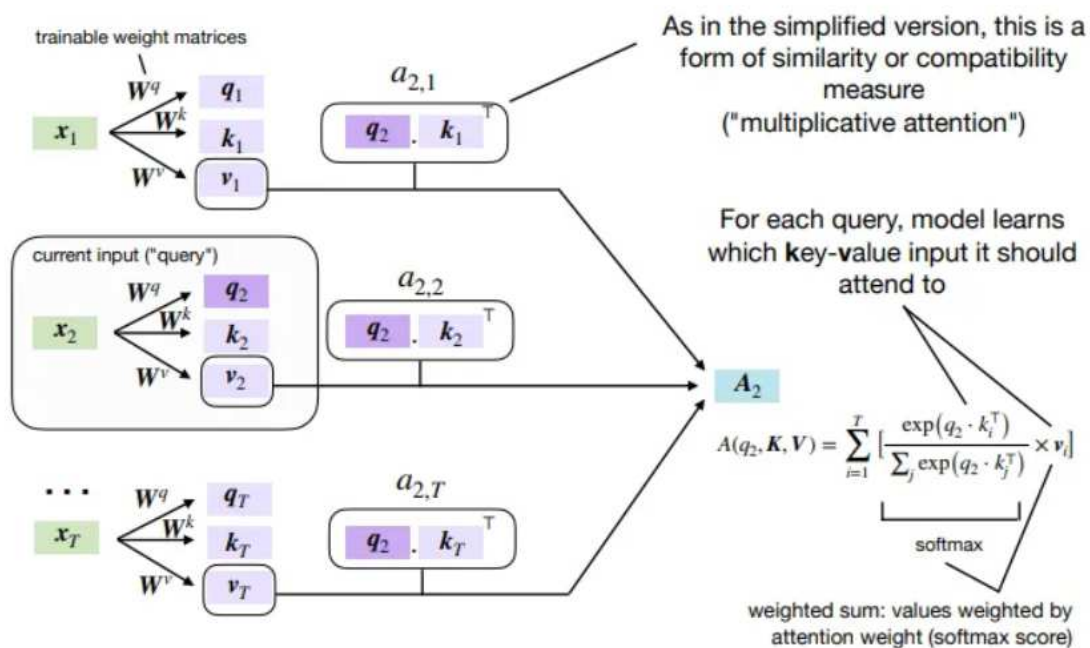
Gdje je W_K težinska matrica za ključeve.

Vrijednosti (engl. Values) su vektorske reprezentacije koje sadrže stvarne informacije koje odgovaraju ključevima. Oni predstavljaju sadržaj koji će se koristiti za generiranje izlaza. Također se generiraju primjenom linearne transformacije na ulazne podatke. Za svaku poziciju u ulaznoj sekvenci, vrijednost (engl. *value*) je rezultat množenja ulaznog vektora s težinskom matricom specifičnom za vrijednosti (engl. *values*). Ako imamo ulazne podatke X , vrijednosti V se dobivaju kao:

$$V = XW_V$$

Gdje je W_V težinska matrica za vrijednosti.

Self-Attention Mechanism



Slika 5.5: Mehanizam pažnje s izračunom ključeva, vrijednosti i upita (23)

Slika 5.5 prikazuje vizualizaciju izračuna ključeva, upita i vrijednosti. Ova vizualizacija pomaže u razumijevanju navedenih definicija za ključeve, upite i vrijednosti.

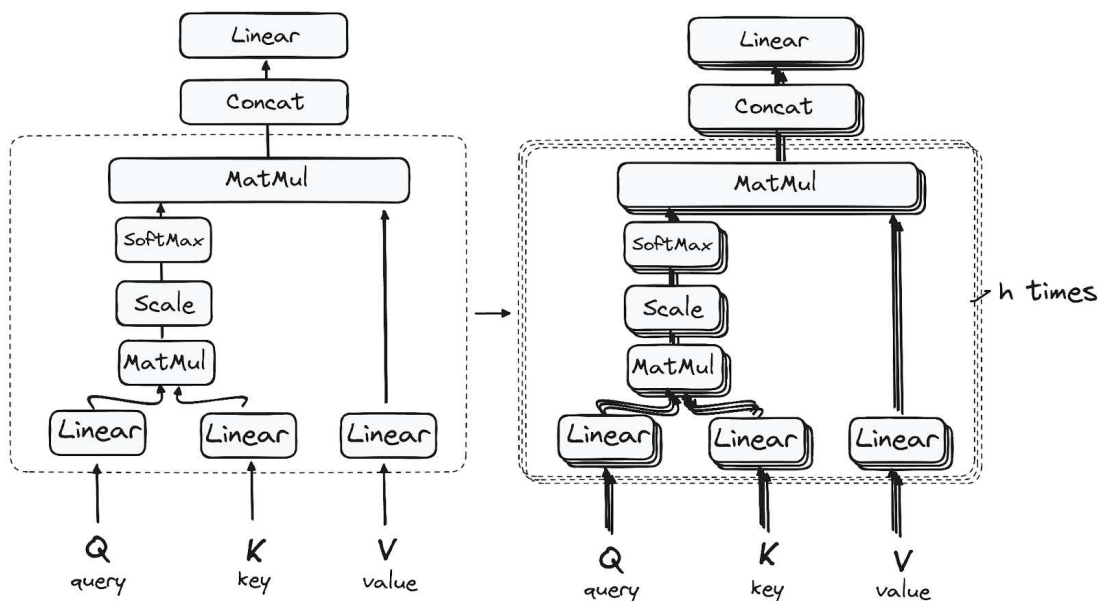
Slika 5.6 prikazuje dva dijagrama: jedan za jednostavan mehanizam pažnje i drugi za višestruku (engl. *multi-head*) pažnju.

Jednostavan mehanizam pažnje (lijevo):

- Ulazni podaci prolaze kroz linearne slojeve kako bi se generirali Q , K i V .
- Skalarni produkt između Q i K računa se koristeći matrično množenje (MatMul).
- Rezultat se skalira dijeljenjem sa korijenom dimenzije ključnih vektora ($\sqrt{d_k}$).
- Primjenjuje se softmax funkcija kako bi se dobile težine pažnje.
- Te težine se koriste za ponderiranje vektora V , što se također postiže matričnim množenjem.
- Konačni izlaz je kombinacija ponderiranih vektora.

Višestruka (engl. *Multi-head*) pažnja (desno):

- Proces se ponavlja h puta (broj glava pažnje).
- Svaka glava pažnje ima svoje zasebne linearne transformacije za Q , K i V .
- Rezultati svih glava se konkatenuiraju i prolaze kroz završni linearni sloj.
- Ovo omogućava modelu da uhvati različite aspekte informacija u paralelnim podprostorima.



Slika 5.6: Mehanizam pažnje (10)

Sloj dodavanja i normalizacije (engl. *Add & Norm Layer*)

Nakon sloja pažnje slijedi sloj (engl. *Add & Norm*). Ovaj sloj ima ključnu ulogu u stabilizaciji i normalizaciji podataka. U koraku dodavanja (engl. *Add*), izlaz iz sloja pažnje se zbraja s izvornim ulazom u sloj pažnje. Ovaj postupak se naziva "rezidualno povezivanje" (engl. *residual connection*) i pomaže u rješavanju problema degradacije signala, čime omogućava modelu da uči dublje slojeve bez gubitka važnih informacija.

Nakon rezidualnog povezivanja, izlaz se normalizira koristeći sloj normalizacije (engl. *Layer Normalization*). Normalizacija pomaže u stabilizaciji i ubrzanju treniranja modela, te smanjuje ovisnost o početnim uvjetima i omogućava modelu da uči učinkovitije.

Feed Forward sloj

Nakon sloja pažnje i sloja dodavanja i normalizacije, slijedi (engl. *Feed Forward Layer*). Ovaj sloj sastoji se od dva potpuno povezana sloja s nelinearnom aktivacijskom funkcijom između njih.

Prvi sloj prima ulazne podatke i množi ih težinskom matricom, nakon čega se primjenjuje nelinearna aktivacijska funkcija (često (engl. *ReLU*)). Ovaj korak dodaje nelinearnost modelu, omogućujući mu da uči složene obrasce u podacima. Nakon toga, izlaz iz nelinearne funkcije prolazi kroz drugi potpuno povezani sloj koji ga ponovno množi težinskom matricom i generira konačni izlaz sloja. Matematička formulacija sloja može se definirati kao:

$$\text{FFLayer}(x) = W_2(\text{ReLU}(W_1x + b_1)) + b_2$$

Ovaj sloj je ključan za obogaćivanje reprezentacija koje model uči, omogućujući mu da bolje generalizira i prilagodi se složenim zadacima. (engl. *Feed Forward*) sloj pomaže modelu u razdvajanju i prepoznavanju relevantnih značajki u podacima, čime doprinosi ukupnoj sposobnosti modela da precizno predviđa i donosi odluke.

5.1.6. Softmax

Nakon što smo naučili da se transformator sastoji od mnogih slojeva koda i dekodera, možemo ga zamisliti kao veliku neuronsku mrežu koja predviđa sljedeće riječi u rečenici. Transformator generira rezultate za sve riječi, pri čemu najvišu ocjenu dobivaju one riječi koje će najvjerojatnije slijediti u rečenici.

Softmax sloj predstavlja završni korak u transformatorima i omogućuje pretvorbu rezultata modela u vjerojatnosti. Kroz ovaj proces, transformator može identificirati i generirati najvjerojatnije riječi koje će slijediti u sekvenci, omogućujući time učinkovito prevođenje, predikciju i generiranje teksta. Softmax funkcija osigurava da su sve vjerojatnosti normalizirane i zbrojene do 1, čime pruža jasnu i preciznu distribuciju vjerojatnosti za svaku riječ u kontekstu.

U slučaju klasifikacijskih problema, softmax u transformatoru se koristi za dodjeljivanje vjerojatnosti različitim kategorijama. Međutim, kod regresijskih problema softmax se obično ne koristi jer je priroda izlaza kontinuirana i nije ograničena na diskretne klase. U regresijskim zadacima koriste se druge metode koje omogućuju modelu da predviđa kontinuirane vrijednosti.

5.2. Primjena transformator modela na cijene nafte

U ovom poglavlju ću implementirati transformator i prilagoditi ga za predviđanje budućih cijena nafte. Transformator modeli, koji su postali popularni u području obrade prirodnog jezika, također pokazuju veliki potencijal u vremenskim nizovima i predviđanju cijena. Korištenjem ovog modela, cilj je točno predvidjeti kretanja cijena nafte analizom povijesnih podataka.

5.2.1. Priprema Podataka

Za treniranje koristim već opisani skup podataka iz poglavlja 4.1. Međutim, kako bi podaci bili spremni za treniranje modela, moraju proći kroz nekoliko koraka pripreme.

Prvi korak je uklanjanje ili interpolacija nedostajućih vrijednosti. Ipak, već smo se uvjerali u potpunost podataka, odnosno od 30. ožujka 1983. do 1. travnja 2024. imamo sve četiri cijene za svaki trgovački dan. Sljedeći korak je obično uklanjanje outliera, no kod financijskih podataka, svako kretanje tržišta, iako možda neobično, ključno je za dobru generalizaciju i predviđanje pravilnog kretanja.

Pošto naši podaci sadrže za svaki dan četiri cijene, a to su cijena otvaranja i zatvaranja za trgujući dan (engl. *Open*, *Close*) te najvišu i najnižu cijenu za taj dan (engl. *High*, *Low*), predviđat ćemo samo jednu izlaznu cijenu. Odabrali smo cijenu zatvaranja (*Close*). Potrebno je provesti i eksploraciju značajki (*Feature Exploration*).

Eksploracija značajki (*Feature Exploration*) je proces analize i razumijevanja različitih značajki (atributa ili varijabli) unutar skupa podataka. Cilj ovog procesa je identificirati ključne značajke koje najviše doprinose predviđanju ili klasifikaciji, te razu-

mjeti međusobne odnose između značajki. Konkretno, naš skup podataka moguće je proširiti tehničkim indikatorima.

Sljedeći kod prikazuje kako jednostavno, uz pomoć biblioteke `ta`, možemo izračunati tehničke indikatore te proširiti naš podatkovni okvir. Tehnički indikatori su dodatne značajke koje mogu pomoći modelu da prepozna obrasce u podacima. U primjeru smo izračunali nekoliko popularnih tehničkih indikatora kao što su SMA (engl. *Simple Moving Average*), EMA (engl. *Exponential Moving Average*), RSI (engl. *Relative Strength Index*), MACD (engl. *Moving Average Convergence Divergence*), Bollinger Bands.

```
# Dodavanje tehničkih indikatora
data['SMA_20'] = ta.trend.sma_indicator(data['Close'], window=20)
data['EMA_20'] = ta.trend.ema_indicator(data['Close'], window=20)
data['RSI'] = ta.momentum.rsi(data['Close'], window=14)
data['MACD'] = ta.trend.macd(data['Close'])
data['MACD_Signal'] = ta.trend.macd_signal(data['Close'])
data['MACD_Diff'] = ta.trend.macd_diff(data['Close'])
bollinger = ta.volatility.BollingerBands(data['Close'], window=20,
    window_dev=2)
data['BB_High'] = bollinger.bollinger_hband()
data['BB_Low'] = bollinger.bollinger_lband()
data['ATR'] = ta.volatility.average_true_range(data['High'], data['Low'], data['Close'], window=14)
data['CCI'] = ta.trend.cci(data['High'], data['Low'], data['Close'], window=20)
data['Stochastic_Oscillator'] = ta.momentum.stoch(data['High'], data['Low'], data['Close'], window=14, smooth_window=3)
data['Parabolic_SAR'] = pta.psar(data['High'], data['Low'], data['Close'], step=0.02, max_step=0.2)['PSAR1_0.02_0.2']
```

Tablica 5.1 prikazuje kako izgleda prošireni podatkovni okvir. Ovdje možemo vidjeti sve izvorne značajke (Open, High, Low, Close) kao i novododane tehničke indikatore.

Date	Open	High	Low	Close	SMA_20	EMA_20	RSI	MACD	MACD_Signal	MACD_Diff	BB_High	BB_Low	ATR	CCI	Stochastic_Oscillator	Parabolic_SAR
1983-05-17	30.00	30.20	29.90	29.91	30.3805	30.1961	42.4732	-0.0753	0.0046	-0.0799	31.0852	29.6758	0.3022	-82.4440	27.7372	29.5300
1983-05-20	30.10	30.66	30.10	30.30	30.2740	30.1500	53.3319	-0.0733	-0.0412	-0.0321	30.9835	29.5645	0.3499	13.6364	72.4138	29.2500
1983-05-23	30.25	30.50	30.25	30.27	30.2455	30.1615	52.5926	-0.0532	-0.0436	-0.0096	30.9058	29.5852	0.3427	17.3039	72.3404	29.2782

Tablica 5.1: Prošireni podatkovni okvir s tehničkim indikatorima

Značajke koje bi također mogle pomoći našem modelu su vremenske značajke. Dodavanjem vremenskih značajki kao što su dan, mjesec, godina i dan u tjednu, možemo pomoći modelu da prepozna sezonske obrasce i druge vremenske regularnosti u podacima.

```
# Dodavanje vremenskih značajki
data['day'] = data['Date'].dt.day
data['month'] = data['Date'].dt.month
data['year'] = data['Date'].dt.year
data['day_of_week'] = data['Date'].dt.dayofweek
```


Tablica 5.2 prikazuje kako izgleda prošireni podatkovni okvir. Ovdje možemo vidjeti sve izvorne značajke (Open, High, Low, Close) kao i novododane vremenske značajke.

Open	High	Low	Close	day	month	year	day_of_week
29.2500	29.5600	29.0100	29.4000	30	3	1983	2
29.4000	29.6000	29.2500	29.2700	31	3	1983	3
29.3000	29.7000	29.2900	29.4400	4	4	1983	0
29.5000	29.8000	29.5000	29.7100	5	4	1983	1
29.9000	29.9200	29.6500	29.9000	6	4	1983	2
...

Tablica 5.2: Prošireni podatkovni okvir s vremenskim značajkama

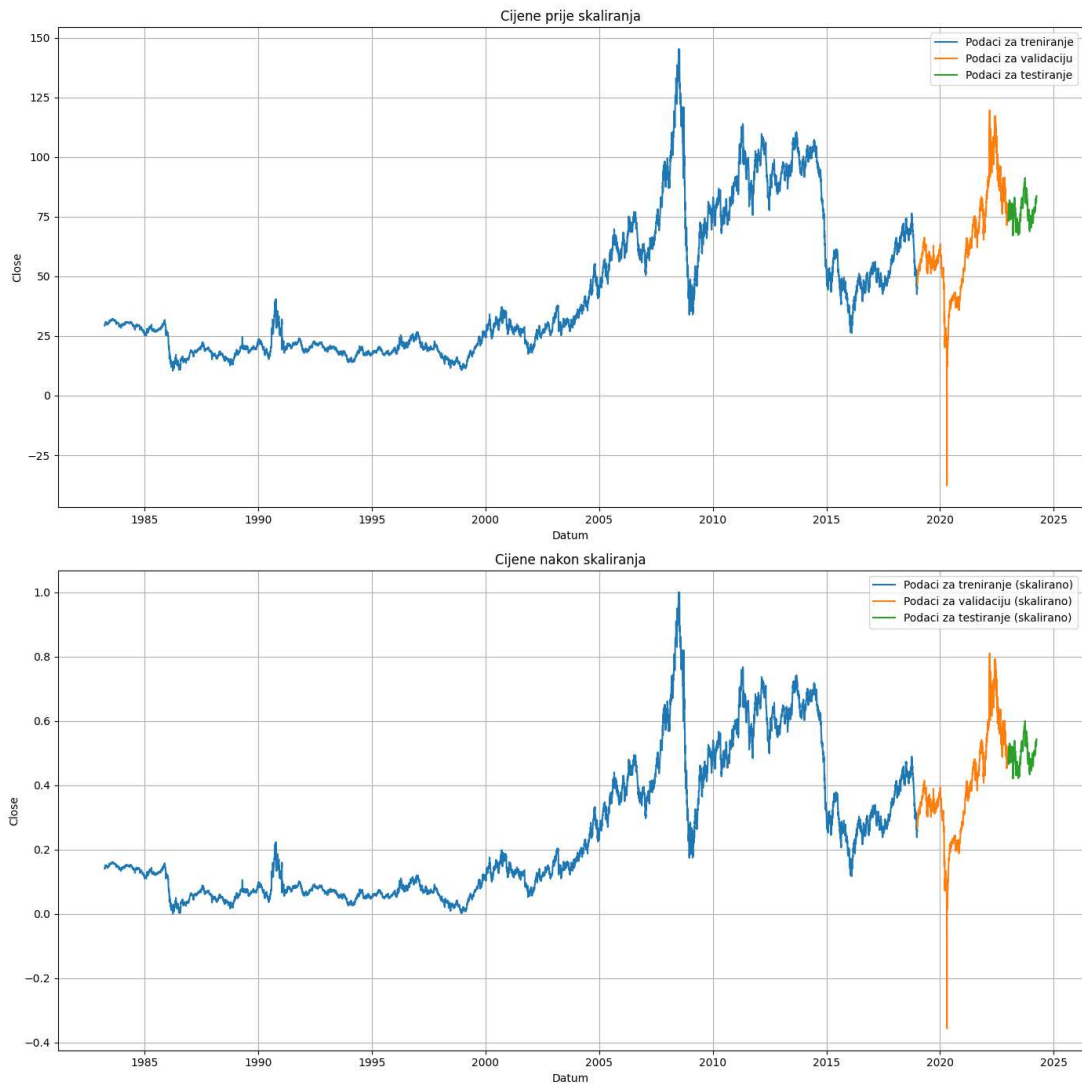
Nakon što smo dodali mnogobrojne značajke, potrebno je odabrati one koje imaju najveći utjecaj na našu ciljanu varijablu. Izračunavanjem korelacijskih koeficijenata između značajki i ciljne varijable možemo identificirati značajke koje imaju najveći utjecaj na ciljnu varijablu. Korelacijska matrica može pomoći u vizualizaciji ovih odnosa, što je prikazano na slici 5.7.

Na temelju korelacija, značajke poput Open, High, Low, SMA_20, EMA_20, BB_High i BB_Low su vrlo informativne za predviđanje cijene zatvaranja (Close). No, zbog visoke međusobne korelacije, potrebno je izabrati samo nekoliko od njih kako bismo smanjili redundanciju. Značajke poput MACD, RSI i ATR, iako manje korelirane s Close, mogu pružiti dodatne informacije koje poboljšavaju performanse modela. Iako vremenske značajke same po sebi nemaju visoku korelaciju s Close, mogu biti korisne u kombinaciji s drugim značajkama za prepoznavanje sezonskih i drugih obrazaca u podacima. Prilikom definiranja i treniranja modela dodatno ćemo proučiti te testirati koje značajke daju najbolje rezultate.



Slika 5.7: Korelacijska matrica

Kako bi model mogao efikasno učiti iz podataka, važno je standardizirati ili normalizirati podatke. Time se osigurava da sve značajke imaju slične skale, što olakšava proces optimizacije tijekom treniranja modela. Upravo slika 5.8 prikazuje cijene prije i poslije upotrebe MinMax Scaler-a.



Slika 5.8: Normalizacija podataka

Standardizacija i normalizacija podataka pomažu u poboljšanju konvergencije modela tijekom treniranja, smanjujući utjecaj značajki s velikim varijacijama u vrijednostima. To omogućava modelu da brže i efikasnije nauči obrasce u podacima, što rezultira boljim performansama i preciznijim predviđanjima.

Također, podatke ćemo podijeliti u skupove za treniranje i testiranje kako bismo mogli procijeniti performanse modela. Nakon pripreme podataka, možemo ih koristiti za treniranje našeg transformator modela. Model će pokušati naučiti obrasce u povijesnim cijenama nafte i koristiti te obrasce za predviđanje budućih cijena.

5.2.2. Rezultati

Sada kada imamo teorijsko razumijevanje transformator modela, možemo se posvetiti analizi rezultata njegove praktične primjene. Iako ovdje nećemo prikazivati kod korišten u izradi modela, isti je dostupan u priloženim materijalima uz rad. Umjesto toga, fokusirat ćemo se na rezultate i spoznaje koje smo dobili tijekom testiranja modela.

Testirali smo razne kombinacije parametara, ulaznih podataka, duljine prozora koji gleda unazad i duljine predikcijskog prozora. Prikazat ćemo rezultate za nekoliko kombinacija koje smo pronašli zanimljivima. Osnovna ideja je da se pogled unazad može mijenjati, kao i predikcijski pogled unaprijed.

Prva kombinacija uključuje pogled unazad od 30 dana i predikciju za sljedećih 5 dana, druga predviđa sljedeći 30 dana uz isti pogled unazad. Zbog kraćeg vremenskog intervala koji predviđamo, prvi model ima šanse dati kvalitetne predikcije. Model je postigao sljedeće rezultate na trening skupu:

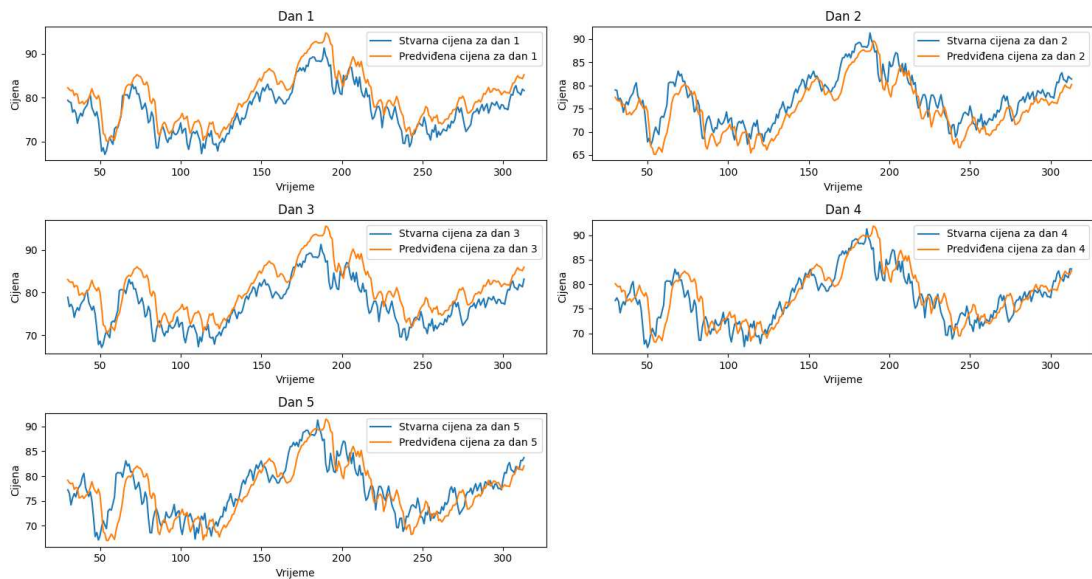
- MSE (engl. *Mean Squared Error*): 7.6132 (30, 5), 27.4312 (30, 30)
- MAE (engl. *Mean Absolute Error*): 2.1080 (30, 5), 4.1868 (30, 30)

Koristili smo sljedeće hiperparametre:

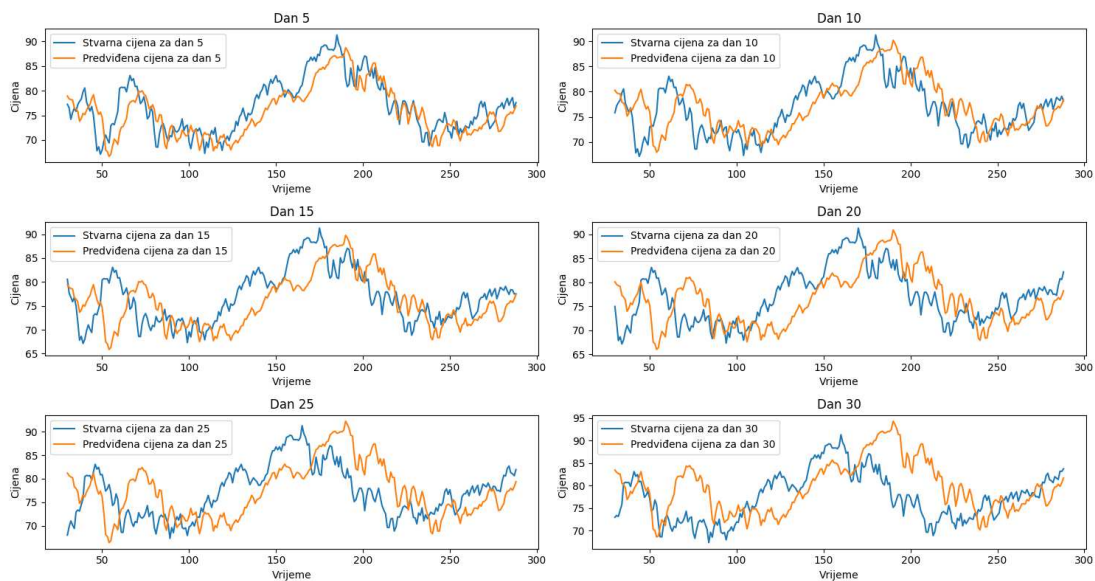
- `d_model`: Dimenzija ugrađenih (embedding) vektora. Ovaj parametar određuje veličinu vektora koji predstavljaju svaku ulaznu značajku nakon što prođu kroz početni embedding sloj: 64
- `nhead`: Broj glava u višestrukoj pažnji. Više glava pažnje omogućuje modelu da simultano obradi informacije iz različitih perspektiva: 4
- `num_encoder_layers`: Broj slojeva u koderu. Više slojeva omogućuje modelu da nauči dublje i složenije značajke iz podataka: 6
- `dim_feedforward`: Dimenzija feedforward mreže unutar svakog koder sloja. Ovo određuje broj neurona u unutarnjim slojevima feedforward mreže: 128
- `dropout`: Postotak neurona koji se nasumično isključuju tijekom treniranja kako bi se spriječilo prekomjerno učenje i poboljšala generalizacija modela: 0.1

Slika 5.9 prikazuje predikcije na testnom skupu uspoređene sa stvarnim vrijednostima za svaki dan predviđanja. Na svakoj od podslika možemo vidjeti kako model predviđa cijene za svaki od prvih pet dana. Plava linija predstavlja stvarne cijene, dok narančasta linija predstavlja predviđene cijene. Jasno se može vidjeti da predikcije modela uglavnom prate stvarne vrijednosti, ali postoje određena odstupanja koja su uočljiva.

Ova analiza nam omogućuje procjenu koliko je model točan i pouzdan u različitim vremenskim točkama.



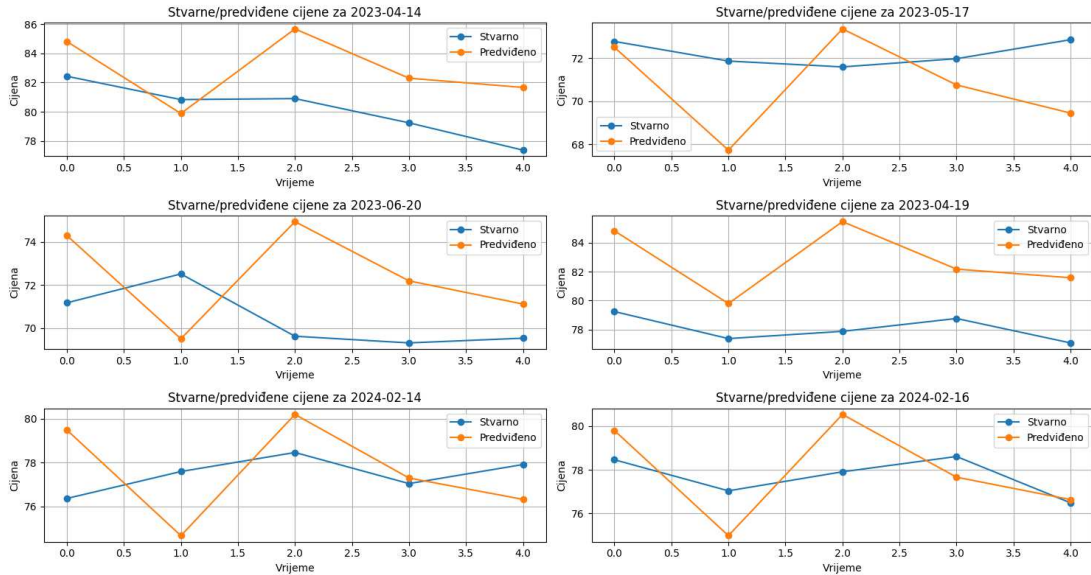
Slika 5.9: Predikcije na testnom skupu za svaki dan predviđanja



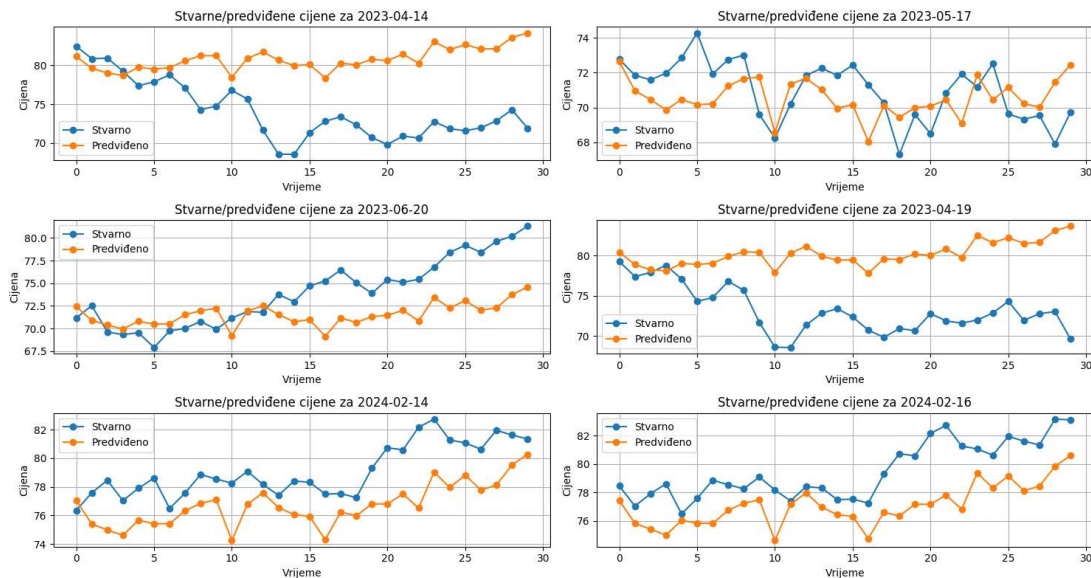
Slika 5.10: Predikcije na testnom skupu za interval 30

Slika 5.11 prikazuje predikcije za idućih 5 dana uspoređene sa stvarnim vrijednostima na odabranim datumima radi demonstracije. Na ovim grafikonima možemo vidjeti stvarne (plava linija) i predviđene (narančasta linija) cijene za nekoliko specifičnih datuma. Iz ovih grafova jasno je vidljivo da predikcije prate opći trend stvarnih cijena, ali odstupaju u određenim točkama. Ova odstupanja ukazuju na to da, iako

model može biti koristan za prepoznavanje općih trendova, predikcije ne bi trebale biti korištene kao apsolutno točne cijene pri izradi strategija, već više kao smjernice za moguće kretanje cijena.



Slika 5.11: Predikcije za idućih 5 dana na odabranim datumima



Slika 5.12: Predikcije za idućih 30 dana na odabranim datumima

Za iste parametre model LSTM postigao je slične, ali malo lošije rezultate:

- MSE (engl. *Mean Squared Error*): 8.6063 (30, 5), 27.9610 (30, 30)
- MAE (engl. *Mean Absolute Error*): 2.2204 (30, 5), 4.19769 (30, 30)

Iz rezultata možemo zaključiti da transformator model daje nešto bolje rezultate u smislu manjih grešaka (MSE i MAE) u odnosu na LSTM model. Ovo sugerira da transformatori bolje hvataju obrasce i zavisnosti u podacima vremenskih nizova, što može rezultirati preciznijim predikcijama. Međutim, iako su transformatori pokazali bolju performansu u ovom slučaju, izbor između LSTM-a i transformatora može zavisi o specifičnom problemu, dostupnim resursima za treniranje i potrebama za interpretabilnošću modela.

5.2.3. Monetizacija predikcija strategijom za trgovanje

Predikcije cijena nafte mogu biti izuzetno vrijedne za kreiranje profitabilnih strategija trgovanja. Korištenjem modela za predviđanje cijena, trgovci mogu donositi informiranije odluke o kupnji i prodaji, minimizirati rizike i maksimizirati dobit.

Na temelju predikcija moguće je razviti različite strategije trgovanja. Na primjer:

- **Strategija koja slijedi trend:** Kupujemo kad model predviđa porast cijene i prodajemo kad predviđa pad.
- **Strategija povratka na sredinu:** Prodajemo kad cijena poraste iznad određenog praga i kupujemo kad padne ispod njega.
- **Kombinacija strategija:** Kombiniramo različite strategije kako bismo optimizirali dobit i smanjili rizik.

Tablica 5.3 prikazuje cijenu zatvaranja na određeni datum i predviđene cijene za sljedećih 5 dana. Ovaj testni skup bi mogli koristiti za izgradnju i testiranje strategije.

Date	Close	Predicted
2023-02-14	79.40	[82.25, 77.42, 83.06, 80.11, 79.15]
2023-02-15	79.02	[81.83, 76.90, 82.56, 79.71, 78.67]
2023-02-16	78.90	[81.57, 76.64, 82.39, 79.48, 78.45]
...
2024-03-22	80.63	[84.51, 79.52, 85.32, 82.18, 81.37]
2024-03-25	81.95	[84.31, 79.33, 85.12, 82.00, 81.17]
2024-03-26	81.62	[85.20, 80.19, 85.97, 82.82, 82.05]

Tablica 5.3: Test skup

Na temelju današnje cijene i cijene koju je naš model predvidio, možemo kreirati strategiju trgovanja. Međutim, s obzirom na to da gradnja strategije spada u područje ekonomske stručnosti, ovdje nećemo ulagati dodatno vrijeme u razvoj konkretne

strategije trgovanja temeljene na predikcijama. Idealno bi bilo uz predikcije dodatno se oslanjati na ostale faktore prije donošenja odluka. Ovo ostavljamo kao jednu od otvorenih točaka za mogući dodatni rad u bliskoj budućnosti.

6. Budući rad

Nakon što smo stekli uvid u svakodnevni život trgovaca koji prate mnogobrojne indikatore i faktore kako bi donosili objektivne i informirane odluke, možemo primijetiti da s razvojem računalne snage računala imaju puno veće mogućnosti brzog procesiranja velikih količina podataka. Na taj način računalo može nadmašiti čovjeka trgovca. Međutim, i dalje je potrebno uložiti mnogo vremena i znanja za stvaranje algoritamskog sustava koji bi bio potpuno neovisan i samostalno provodio trgovanje.

U ovom radu dotakli smo se samo jednog aspekta tog cijelog sustava, a to su modeli za generiranje signala za kupovinu. Međutim, tu su mnogi drugi dijelovi kao što su analiza rizika, proučavanje i diversifikacija portfelja, zatim uračunavanje troškova trgovanja, brzina izvršenja kupovine i prodaje. Naš sustav morao bi biti povezan s bankovnim ili virtualnim računom s kapitalom te s burzom ili platformom (virtualnim brokerom) koja omogućuje trgovanje, uz mnoge druge detalje.

Za budući rad bitno bi bilo posvetiti se usavršavanju modela i pokušati izgraditi strategiju koja bi stvarno unovčila predikcije tog modela. Potrebno je izgraditi sustav nadzora kako bi se model svakodnevno unapređivao. U strategiju je važno ugraditi neke osigurače, a također je bitno da donošenje odluka bude transparentno, s obzirom na osjetljivo područje financija.

Sigurno je da postoji mnogo područja za daljnji rad i razvoj, što ostavlja prostora za kreativnost i inovacije.

7. Zaključak

Kroz ovaj rad dali smo sveobuhvatan pregled algoritamskog trgovanja temeljenog na tehničkoj analizi, uspoređujući klasične metode s modernim pristupima koji koriste strojno učenje. Implementirane su dvije osnovne strategije trgovanja: strategija presjecanja jednostavnih pomičnih prosjeka (SMA) i strategija temeljena na indeksu relativne snage (RSI). Za moderni pristup korišten je model transformatora za predviđanje budućih cijena za idućih 5 dana.

Evaluacija strategija na povijesnim podacima pokazala je određenu razinu uspješnosti, ali i izazove povezane s promjenjivošću tržišta i prilagodljivošću strategija novim podacima. Iako su strategije pokazale potencijal tijekom razdoblja treninga, performanse na testnom skupu ukazale su na problem prekomjernog prilagođavanja podacima. Spoznali smo da tehnički indikatori mogu pomoći u donošenju odluka i signalizirati promjene na tržištu, međutim, oslanjanje samo na njih ne obećava da će naša strategija biti profitabilna. Potrebno je uključiti mnoge dodatne parametre i analize kako bi se točno predvidjelo stvarno kretanje tržišta.

U stvarnom svijetu, trgovci koriste naprednije metode i kombinacije više indikatora kako bi povećali točnost svojih predviđanja. Primjena strojnog učenja i umjetne inteligencije nudi značajan potencijal za poboljšanje performansi trgovačkih strategija, omogućujući izgradnju modela koji bolje generaliziraju na novim podacima i prilagođavaju se promjenama na tržištu. Zbog toga smo stvorili model transformatora koji predviđa buduća kretanja cijena. Na testnom skupu pokazali smo da predviđanja mogu biti pouzdana i pomoći u izgradnji strategije. Konkretno, implementirali smo model koji predviđa interval od pet dana u budućnosti i za taj interval postigli smo obećavajuće rezultate.

Rad je pokazao da algoritamsko trgovanje, uz korištenje tehničke analize i naprednih algoritama, ima potencijal postati moćan alat za donošenje trgovačkih odluka. Međutim, zahtijeva kontinuirano istraživanje i prilagodbu kako bi se postigla dugoročna profitabilnost i pouzdanost. Razvoj algoritama i modela treba biti usmjeren na stvaranje fleksibilnih i prilagodljivih sustava koji mogu reagirati na stalne promjene tržišta,

osiguravajući tako optimalne rezultate za trgovce i investitore.

Napredak u tehnologiji, posebno u području umjetne inteligencije i strojnog učenja, pruža ogromne mogućnosti za unapređenje algoritamskog trgovanja. Kroz integraciju ovih tehnologija, možemo očekivati daljnji rast i razvoj ovog područja, s ciljem postizanja veće točnosti, učinkovitosti i profitabilnosti trgovačkih strategija.

LITERATURA

- [1] Irene Aldridge. *High-Frequency Trading: A Practical Guide to Algorithmic Strategies and Trading Systems*. John Wiley & Sons, 2013.
- [2] Mohammad Amanatulla. Transformer architecture explained. <https://medium.com/@amanatulla1606/transformer-architecture-explained-2c49e2257b4c>, 2023. Accessed: 2024-06-11.
- [3] Ernest Chan. *Quantitative Trading: How to Build Your Own Algorithmic Trading Business*. John Wiley & Sons, 2009.
- [4] Ernest Chan. *Algorithmic Trading: Winning Strategies and Their Rationale*. John Wiley & Sons, 2013.
- [5] Shomesh Ernesto Chaudhuri. *Financial Signal Processing: Applications to Asset-Market Dynamics and Healthcare Finance*. Massachusetts Institute of Technology, 2018.
- [6] JAMES CHEN. Algorithmic trading: Definition, how it works, pros and cons. <https://www.investopedia.com/terms/a/algorithmictrading.asp>, 2024. Accessed: 2024-05-29.
- [7] David Easley, Marcos Lopez de Prado, and Maureen O'Hara. The volume clock: Insights into the high-frequency paradigm. *The Journal of Portfolio Management*, 39(1):19–29, 2012.
- [8] AJ Fabino. What percentage of stock trades are made by bots and algorithms? <https://www.benzinga.com/general/topics/23/06/32861724/what-percentage-of-stock-trades-are-made-by-bots-protect-penalty-@M-and-algorithms>, 06 2023.

- [9] JASON FERNANDO. Relative strength index (rsi). <https://www.investopedia.com/terms/r/rsi.asp>, 2024. Accessed: 2024-06-13.
- [10] Josep Ferrer. How transformers work: A detailed exploration of transformer architecture. <https://www.datacamp.com/tutorial/how-transformers-work>, 2024. Accessed: 2024-06-11.
- [11] Ryan Hogg. Fundamental vs technical analysis: What's the difference? <https://www.ig.com/en/trading-strategies/fundamental-vs-technical-analysis--what\protect\penalty-\@M-s-the-difference--230605>. Accessed on 2024-05-04.
- [12] Investopedia. Introduction to trading. <https://www.investopedia.com/trading-4427765>.
- [13] Investopedia. Algorithmic trading, 2023.
- [14] Investopedia, 2024.
- [15] Stefan Jansen. *Machine Learning for Algorithmic Trading*. Odjel za matematiku, Sveučilište J.J. Strossmayera u Osijeku, 2002.
- [16] Brian Lund. Technical indicators: The tools of the trade. <https://www.britannica.com/money/technical-indicator-types>, Mar 2023. Accessed on 4 May 2024.
- [17] Medium, 2024.
- [18] John J. Murphy. *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*. New York Institute of Finance, 1999.
- [19] Shitoshna Nepal. Signal processing in finance. <https://sites.tufts.edu/eeseniordesignhandbook/2015/signal-processing-in-finance/>.
- [20] SketchBubble. Algorithmic trading powerpoint template. <https://www.sketchbubble.com/en/presentation-algorithmic-trading.html>. Accessed: 2024-05-30.

- [21] Cedric Thompson. Fundamental vs. technical analysis: What's the difference? <https://www.investopedia.com/ask/answers/difference-between-fundamental-and-technical-analysis>, 2023.
- [22] Ruey S. Tsay. *Analysis of Financial Time Series*. John Wiley & Sons, Inc., Hoboken, New Jersey, 2nd edition, 2005.
- [23] Zain ul Abideen. Attention is all you need: The core idea of the transformer. <https://medium.com/@zaiinn440/attention-is-all-you-need-the-core-idea-of-the-protect\penalty-\@Mtransformer-bbfa9a749937>, 2023. Accessed: 2024-06-11.
- [24] uTradealgorithms. Read about algo trading market size & share analysis. <https://utradealgorithms.com/blog/algorithmic-trading-market/>, 09 2023.
- [25] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. *Advances in neural information processing systems*, 30, 2017.
- [26] Wikipedia. Wikipedia, the free encyclopedia, 2024.

Algoritamsko trgovanje temeljeno na tehničkoj analizi

Sažetak

Ovaj diplomski rad fokusira se na razvoj algoritama za donošenje odluka u algoritamskom trgovanju temeljenih na tehničkoj analizi. Cilj je implementirati algoritam koji može analizirati, obraditi i izdvojiti značajke iz financijskih vremenskih nizova kako bi se donosile informirane odluke u trgovanju. Studija uspoređuje klasične strategije trgovanja temeljene na pravilima s modernim pristupima koji uključuju algoritme strojnog učenja, konkretno pokušavajući primijeniti model transformatora na financijske nizove podataka. Rad ocjenjuje ove modele testiranjem na neovisnim skupovima financijskih podataka kako bi se osigurala pouzdanost i mogućnost generalizacije u stvarnim uvjetima trgovanja.

Ključne riječi: Algoritamsko trgovanje, tehnička analiza, financijski vremenski nizovi, strategije trgovanja, modeli temeljeni na pravilima, RSI, SMA, transformator, koder, dekoder, strojno učenje.

Algorithmic trading based on technical analysis

Abstract

This thesis focuses on the development of decision-making algorithms in algorithmic trading based on technical analysis. The objective is to implement an algorithm capable of analyzing, processing, and extracting features from financial time series to make informed trading decisions. The study compares classical rule-based trading strategies with modern approaches that incorporate machine learning algorithms, specifically attempting to apply the transformer model to financial time series data. The work evaluates these models by testing them on independent sets of financial data to ensure reliability and the ability to generalize in real trading conditions.

Keywords: Algorithmic trading, technical analysis, financial time series, trading strategies, rule-based models, RSI, SMA, transformer, encoder, decoder, machine learning.